

해석모델의 불확실성을 고려한 교량의 손상추정기법

Damage Detection of Bridge Structures Considering Uncertainty in Analysis Model

이 종 재*

윤 정 방*

Lee, Jong-Jae

Yun, Chung-Bang

(논문접수일 : 2004년 8월 21일 ; 심사종료일 : 2006년 6월 16일)

요 지

교량의 손상추정을 위한 구조계 규명기법은 신호취득시스템 및 정보처리기술의 발전과 함께 최근에 많은 연구개발이 이루어지고 있다. 신경망기법이나 유전자 알고리즘과 같은 소프트컴퓨팅 기법은 뛰어난 패턴인식능력 때문에 손상추정 문제에 활발히 활용되고 있다. 본 연구에서는 모드계수를 활용한 신경망기법기반 손상추정을 수행하였으며, 신경망을 훈련시키기 위한 훈련패턴을 생성하는 해석모델에서의 불확실성을 효과적으로 고려할 수 있는 방법을 제시하였다. 해석모델의 불확실성 대하여 민감하지 않은 입력자료인 손상 전·후의 모드형상의 차 또는 모드형상의 비를 신경망의 입력자료로 활용하였다. 단 순보와 다주형교량에 대한 수치예제를 통하여 본 연구에서 제시한 기법의 타당성 및 적용성을 검증하였다.

핵심용어 : 손상추정, 교량구조물, 신경망기법, 모델의 불확실성, 모드형상의 차, 모드형상의 비

Abstract

The use of system identification approaches for damage detection has been expanded in recent years owing to the advancements in data acquisition system and information processing techniques. Soft computing techniques such as neural networks and genetic algorithm have been utilized increasingly for this end due to their excellent pattern recognition capability. In this study, damage detection of bridge structures using neural networks technique based on the modal properties is presented, which can effectively consider the modeling uncertainty in the analysis model from which the training patterns are to be generated. The differences or the ratios of the mode shape components between before and after damage are used as the input to the neural networks in this method, since they are found to be less sensitive to the modeling errors than the mode shapes themselves. Two numerical example analyses on a simple beam and a multi-girder bridge are presented to demonstrate the effectiveness and applicability of the proposed method.

Keywords : damage detection, bridge structures, neural networks, modeling uncertainty, mode shape differences, mode shape ratios

1. 서 론

대부분의 토목구조물은 생애주기 동안에 지진, 바람, 교통, 파랑 하중 등의 외부하중에 노출되어 있으므로, 시간의 경과에 따라 열화되거나 예기치 못한 손상을 입는 경우가 발생하게 된다. 이러한 구조물의 손상은 때때로 파괴로 이어져 심각한 인적, 물적 피해를 야기하기도 한다. 따라서 구조물 건전도 감시기법을 활용한 구조물의 손상추정 및 안전성 평가 기술은 점차 그 중요성이 부각되고 있는 상황이다(Doebling

등, 1998; Zou 등, 2000; Chase 등, 2001). 구조계 규명기법을 활용한 구조물의 건전도 감시기법은 계측기술, 정보처리기술, 구조물 모델링기법의 발달과 더불어 많은 발전을 이루게 되었으며, 최근에는 실제 구조물의 손상추정에 대한 적용성을 높이기 위한 연구가 활발히 수행되고 있다.

구조실험을 통한 구조물의 손상추정은 어디에, 어느 정도의 손상이 발생했는지를 알아내는 문제이다. 구조적 손상의 결과로서 나타나는 현상은 국부적인 부재의 강성행렬의 감소로 나타나고, 강성행렬의 감소는 고유진동수의 감소나 모드

* 책임저자, 정회원 · 한국과학기술원 건설 및 환경공학과 박사후연구원,
전화: 042-869-3652 ; Fax: 042-869-3610
E-mail: jongjae@kaist.ac.kr

* 정회원 · 한국과학기술원 건설 및 환경공학과 교수

· 이 논문에 대한 토론을 2006년 9월 30일까지 본 학회에 보내주시
면 2006년 12월호에 그 결과를 게재하겠습니다.

형상의 변화를 초래하며, 손상 전·후의 강성행렬의 차이가 구조물의 손상상태를 나타낸다고 할 수 있다. 따라서 구조물의 동특성을 추정하는 것이 구조물의 손상을 평가하는데 필요하며, 이러한 개념에 기초하여 구조물의 동특성을 측정하여 구조물의 손상을 추정하는 방법들이 개발되어 왔다.

구조물의 손상을 추정하는 방법은 크게 데이터에 근거한 방법과 모델에 근거한 방법으로 나눌 수 있다. 데이터기반 손상추정기법은 구조물의 해석모델에 대한 정보를 사용하지 않고, 건전상태 혹은 초기상태의 구조물의 거동과, 손상상태 또는 사용상태에서의 거동을 비교함으로써 구조물의 손상을 추정하는 기법이다. 이 방법에서는 구조물의 주파수 응답함수 또는 모드계수를 직접 이용하여 손상지수를 구하거나(김정태 등, 2002; Sampaio 등, 1999; Gawronski 등, 2000), 웨이블릿 변환과 같은 시간-주파수영역의 신호처리 기법을 이용하여 손상을 추정한다(윤정방 등, 2002; 박승희 등, 2004; Quek 등, 2001; Zou 등 2002). 이 기법은 일반적으로 손상 유무 및 손상위치 추정에 적합한 반면, 손상의 정도를 판별하는 데에는 효과적이지 않다.

모델기반 손상추정기법은 구조물의 손상이 모드계수의 변화를 초래하며, 이는 구조물의 강성의 감소와 관계가 있으므로, 적절한 구조모델의 수정을 통하여 손상을 추정하는 방법이다. 이 방법은 손상 정도의 추정이 가능하나, 대상구조물이 복잡한 경우 직접 적용하기에 쉽지 않은 단점이 있다. 특히 교량구조물과 같은 대형 구조물의 경우, 구조물의 거동을 정확히 모사할 수 있는 해석모델을 구성하는 것이 어렵고, 해석모델의 불확실성에 의한 영향이 손상에 의한 모드특성의 민감도보다 큰 경우에는 모델기반 손상추정기법을 효과적으로 적용할 수 없다. 또한 대형구조물의 경우 자유도가 많아지는 단점이 있는데 이는 부구조기법을 사용하여 효과적으로 처리할 수 있다(Yun 등, 2000). 추정된 모드계수로부터 강성의 변화를 추정하는 방법으로는 수학적 모델에 근간을 둔 탐색방법과, 미분을 사용하지 않고 오직 함수값만을 이용하는 랜덤 탐색 방법으로 나눌 수 있다. 최근에는 이러한 탐색 방법들에 대한 대안으로 신경망 기법(Wu 등, 1992; Masri 등, 1999)이나 유전자 알고리즘(Chou 등, 2001)과 같은 소프트웨어 방법이 많이 제안되고 있다. 특히, 신경망기법은 여러 손상상태에 대한 구조물의 응답과 구조 계수 사이의 관계를 여러 패턴으로 구성한 후, 이 패턴집합을 사용하여 미리 신경망을 훈련하게 되므로, 실제 손상추정에서는 학습된 신경망을 바로 사용할 수 있어 구조물의 상시 모니터링에 큰 장점을 갖게 된다.

본 연구에서는 교량의 부재단위 손상추정을 위하여 모델기반 손상추정기법의 하나인 신경망 기법기반 손상추정에 대

한 연구를 수행하였다. 신경망의 입력자료로는 모드계수를 활용하였다. 모드데이터를 활용한 모델기반 손상추정의 과정은 패턴인식의 문제로 정의될 수 있으며, 신경망기법은 이러한 패턴인식의 문제에 매우 효과적인 기법이다. 또한 신경망 기법은 다양한 종류의 입·출력자료를 다룰 수 있으며, 훈련 시간에 비해 손상추정 단계에서의 빠른 계산능력 등의 장점을 가지고 있다. 따라서 구조물의 손상추정 문제에 신경망 기법을 적용하기 위하여 많은 연구가 수행되어 왔다. Wu 등(1992)은 3층 프레임 구조물의 부재손상의 위치와 정도를 추정하기 위하여 역전파 학습알고리즘을 적용하였으며, Szewczyk 등(1994)는 재하하중에 따른 정적변위를 활용하여 구조부재의 강성을 추정하였다. Yun 등 (2000)은 복잡한 구조물에 효과적으로 적용할 수 있는 부구조기법을 제안하였다. Lee 등(2002)은 모드데이터를 활용한 신경망 기법을 교량의 건전도 모니터링 문제에 대하여 적용하였으며, Ni 등(2000)은 사장교의 손상추정 문제에 확률신경망 기법을 이용하였다.

신경망 기법을 활용한 교량의 손상추정에는 두가지 불확실성에 대한 고려가 필요하다. 계측자료로부터 교량의 건전도를 평가하고자 할 때, 계측자료에는 어느 정도의 계측오차가 포함되어있다. 이는 환경적인 영향에 의한 잡음과, 시스템의 잡음 등을 포함하는 오차로서 이러한 계측오차는 신경망 기법에서 노이즈 첨가학습(Matsuoka, 1992; Yun 등, 2001)으로 효과적으로 고려할 수 있다. 또 하나의 불확실성은 훈련패턴의 생성에 사용하는 기저모델의 부정확성이다. 구조물이 대형화되고, 구조부재 및 형식이 다양해짐에 따라, 정확한 기저모델을 구현하는 것이 점점 어려운 일이 되고 있다. 교량의 건전도 평가에 이용하기 위한 기저모델은 판별하고자 하는 손상의 유형 및 정도를 잘 나타낼 수 있는 것이어야 한다. 교량의 운용 전 재하실험을 통하여 교량의 거동을 계측하고 이를 활용하여 초기 유한요소모델의 개선을 수행하더라도 수정된 기저모델이 손상에 대한 민감도에 비추어볼 때, 실제거동에 충분히 가깝도록 하는 것은 매우 어려운 일이다. Ni 등(2002)은 기저모델의 불확실성에 대한 영향을 줄이기 위하여 손상 전·후에 추정된 부재강성의 차이를 손상지수로 이용하는 방법을 제안한 바 있다.

본 연구에서는 신경망 기법을 활용한 교량의 손상추정 시, 기저모델의 불확실성을 효과적으로 고려할 수 있는 기법을 제안하였다. 신경망의 입력자료로서 손상 전·후의 모드형상의 차와 모드형상의 비를 해석모델의 불확실성에 민감하지 않은 입력자료로서 제시하고, 이를 단순보 및 다주형 교량에 대한 수치모의 실험을 통하여 제안한 기법의 타당성 및 적용성을 검증하였다.

2. 이론적 배경

2.1 모델오차에 민감하지 않은 입력자료

신경망을 활용한 교량의 손상추정에는 신경망을 학습시키기 위한 훈련패턴이 필요하다. 그러나, 교량의 손상과 관련된 다양한 훈련패턴을 실제 구조계에서 계측을 통해서 수집하는 것은 거의 불가능한 일이므로 해석모델을 사용하여 교량의 손상에 따른 거동을 분석하고 이로부터 훈련패턴을 구하게 된다. 따라서 해석모델이 실제 교량의 거동을 얼마나 잘 나타내느냐가 매우 중요한 문제이며, 해석모델로부터 구한 해석결과와 실제 교량의 거동차이가 해석모델의 불확실성에 대한 모델오차로 정의될 수 있다. 모드계수를 신경망의 입력자료로 활용하여 손상을 추정하는 경우, 훈련패턴의 생성에 사용되는 기저모델의 모델오차를 효과적으로 고려하기 위하여 기저모델의 모델오차에 민감하지 않은 입력자료를 활용하는 것이 매우 중요하다. 기존의 많은 연구에서는 신경망의 입력자료로서 고유주파수와 모드형상을 사용하였다. 그러나 고유주파수는 온도, 습도 등의 환경적인 영향에 따라 큰 변화를 나타내므로 실제 구조물에 적용하기 위해서는 이러한 영향을 배제하기 위한 방안이 필요하며 많은 연구가 활발히 진행 중에 있다(Ko 등, 2003). 따라서 본 연구에서는 상대적으로 환경적인 영향을 적게 받는 모드형상을 신경망의 입력자료로 활용하였다. 그러나 모델오차에 의한 모드형상의 영향이 손상에 의한 모드민감도 보다 큰 경우, 이러한 모드형상의 자료를 활용하여 손상추정을 수행하기는 쉽지 않다. 따라서 본 연구에서는 모델오차를 효과적으로 고려하기 위하여 모델오차에 대한 모드형상의 민감도를 살펴보고, 이를 통하여 모델오차에 민감하지 않은 모드자료를 제시하였다.

손상이 발생되기 전·후의 구조물의 모드방정식은 다음의 식 (1)과 같이 구할 수 있다.

$$[K_0]\{\phi_0\} = \omega_0^2 [M]\{\phi_0\} \quad (1a)$$

$$[K_0 + \Delta K_d]\{\phi_0 + \Delta\phi_d\} = (\omega_0^2 + \Delta\omega_d^2)[M]\{\phi_0 + \Delta\phi_d\} \quad (1b)$$

여기서, K는 강성행렬, M은 질량행렬, ω 는 고유주파수, ϕ 는 모드형상을 나타낸다. 또한 아래첨자 0은 손상이 없는 상태를, d는 손상이 있는 상태를 나타낸다. 위 식에서 손상은 강성행렬의 변화에만 관련되고, 손상 전·후의 질량은 변화가 없는 것으로 가정하면, 손상과 관련한 강성변화에 따른 1차 모드섭동식은 다음의 식 (2)와 같이 나타난다.

$$[\Delta K_d]\{\phi_0\} + [K_0]\{\Delta\phi_d\} = \omega_0^2 [M]\{\Delta\phi_d\} + \Delta\omega_d^2 [M]\{\phi_0\} \quad (2)$$

모델오차가 있는 구조계의 모드방정식은 모델오차가 없는 구조계의 모드방정식과 유사하게 다음의 식 (3)과 같이 나타난다.

$$[K_0 + \Delta\tilde{K}]\{\phi_0 + \Delta\tilde{\phi}\} = (\omega_0^2 + \Delta\tilde{\omega}^2)[M]\{\phi_0 + \Delta\tilde{\phi}\} \quad (3a)$$

$$[K_0 + \Delta\tilde{K} + \Delta K_d]\{\phi_0 + \Delta\tilde{\phi} + \Delta\tilde{\phi}_d\} = (\omega_0^2 + \Delta\tilde{\omega}^2 + \Delta\tilde{\omega}_d^2)[M]\{\phi_0 + \Delta\tilde{\phi} + \Delta\tilde{\phi}_d\} \quad (3b)$$

여기서, 모든 기호는 식 (1)에서와 같고, 단지 ‘ \sim ’는 모델오차가 있는 구조계를 나타내는 기호이다. 따라서 모델오차가 있는 구조계에서 손상에 의한 1차 모드섭동식은 다음과 같이 나타난다.

$$[\Delta K_d]\{\phi_0\} + [K_0]\{\Delta\tilde{\phi}_d\} = \omega_0^2 [M]\{\Delta\tilde{\phi}_d\} + \Delta\tilde{\omega}_d^2 [M]\{\phi_0\} \quad (4)$$

모델오차에 의한 영향($\Delta\tilde{K}$)과 손상에 의한 강성의 변화(ΔK_d)가 작다고 가정하면, 모델오차가 없는 구조계에서 손상에 의한 고유주파수의 변화($\Delta\omega_d$)는 모델오차가 있는 구조계에서 같은 크기의 손상에 의한 고유주파수의 변화($\Delta\tilde{\omega}_d$)와 유사하다고 근사화 될 수 있다($\Delta\omega_d \approx \Delta\tilde{\omega}_d$). 이 근사화에 대한 검증은 3.1절의 단순보에 대한 예제를 통하여 나타내었다. 따라서 식 (2)와 식 (4)로부터 다음과 같은 식을 얻게 된다.

$$[K_0 - \omega_0^2 M]\{\Delta\phi_d - \Delta\tilde{\phi}_d\} = 0 \quad (5)$$

식 (5)의 해는 다음과 같이 구할 수 있다.

$$\{\Delta\phi_d\} = \{\Delta\tilde{\phi}_d\} \quad (6a)$$

or

$$\{\Delta\phi_d - \Delta\tilde{\phi}_d\} = \alpha \{\phi_0\} \quad (6b)$$

식 (6a)는 모델오차가 없는 구조계에서의 어떤 작은 손상에 대한 모드형상의 변화량은 모델오차가 있는 구조계에서의 같은 크기의 손상에 대한 모드형상의 변화량과 같다는 것을 의미하고, 이는 손상에 대한 모드형상의 변화량은 모드형상 자체보다 모델오차에 대하여 민감하게 나타나지 않음을 보여준다. 식 (6b)는 모델오차 유무에 따른 모드형상 변화량의 차이가 모델오차가 없는 구조계의 모드형상의 크기에 비례한

다는 것을 의미한다. 식 (6b)에서 0이 아닌 비례상수 α 의 존재가능성을 살펴보기 위하여 $\{\phi_0\}^T$ 를 앞에 곱하면 다음의 식과 같다.

$$\{\phi_0\}^T \{\Delta\phi_d - \Delta\tilde{\phi}_d\} = \alpha \{\phi_0\}^T \{\phi_0\} \quad (7)$$

모드형상을 식 (8)과 같이 정규화하면,

$$\begin{aligned} \|\phi_0\|_2 = \phi_0^T \phi_0 = 1, \quad \|\phi_d\|_2 = \|\phi_0 + \Delta\phi_d\|_2 = 1, \\ \|\tilde{\phi}_d\|_2 = \|\phi_0 + \Delta\tilde{\phi}_d\|_2 = 1, \\ \|\tilde{\phi}_d\|_2 = \|\phi_0 + \Delta\tilde{\phi}_d + \Delta\tilde{\phi}_d\|_2 = 1 \end{aligned} \quad (8)$$

식 (9)와 같은 관계를 얻을 수 있다.

$$\phi_0^T \Delta\phi_d \approx 0, \quad \phi_0^T \Delta\tilde{\phi}_d \approx 0, \quad \phi_0^T \Delta\tilde{\phi}_d \approx 0 \quad (9)$$

따라서, 식 (7)의 좌변은 소거되어 비례상수 α 는 0이 되게 된다. 이것은 식 (5)의 가능해가 식 (6a)로 유일함을 나타낸다.

모델오차의 크기($\Delta\tilde{\kappa}$)가 작다고 가정하고 미소량의 교차항을 무시하면, 식 (6a)으로부터 모드형상의 비에 대한 다음의 식 (10)을 얻을 수 있다. 여기서 모델오차가 없는 구조계에서의 손상 전·후에 대한 모드형상의 비는 모델오차가 있는 구조계의 모드형상 비로 근사화 됨을 나타낸다.

$$\frac{\phi_{dj}^i}{\phi_{0j}^i} \approx \frac{\tilde{\phi}_{dj}^i}{\tilde{\phi}_{0j}^i} \quad \text{for } \forall i, j \text{ where } \phi_{0j}^i, \tilde{\phi}_{0j}^i \neq 0 \quad (10)$$

따라서, 본 연구에서는 모델오차를 효과적으로 고려하기 위한 방법으로, 손상 전·후의 모드형상의 차와 모드형상의 비를 모델오차에 민감하지 않은 입력자료로서 제안하였으며, 이를 손상추정을 위한 신경망의 입력자료로 활용하였다. 식 (10)에서 모드형상의 비를 각 측정지점마다 계산할 때, 지점부와 각 모드별 노드점 부근에서의 값은 제외하였다. 이는 지점부 및 노드점에서의 모드형상에 대한 측정자료의 신뢰성이 떨어진다는 점과, 모드형상의 비를 계산하는데 있어서의 수치적 불안정성 때문이다. 따라서 본 연구에서는 각각의 입력자료에 대한 공정한 비교를 위하여 지점부와 노드점 부근을 제외한 지점에서의 모드형상 값, 모드형상의 차, 모드형상의 비를 각각 이용하여 손상추정을 수행하였다.

2.2 신경망 기법에서 모델오차의 고려

본 연구에서는 일반적으로 많이 활용되는 역전파학습 알고리즘을 활용하였다. 본 연구에서 사용한 신경망의 구조는 그림 1에 나타난 바와 같이 하나의 입력층, 두개의 은닉층, 하나의 출력층을 갖는 다층퍼셉트론이며, 비선형 활성화함수로서 시그모이드 함수를 사용하였다. 모드계수를 이용한 기존의 손상추정기법은 고유주파수와 모드형상등의 모드계수를 사용하였으나, 본 연구에서는 모델오차를 효과적으로 고려하기 위하여 손상 전·후의 모드형상의 차와 모드형상의 비를 신경망의 입력자료로 활용하였다. 고유주파수는 외부환경의 변화에 영향을 크게 받으므로 손상 자체에 의한 고유주파수의 변화를 분리하여 고려하는 것이 바람직하다. 그러나 아직까지 온도 및 습도 등의 외부환경에 의한 영향을 완전히 고려하지 못하고 있는 실정이며, 많은 연구가 현재 진행 중에 있다. 따라서 본 연구에서는 외부환경의 영향에 상대적으로 영향을 적게 받는 모드형상 자료만을 활용하였다. 신경망의 출력은 다음의 식 (11)과 같이 정의되는 강성지수를 사용하였다.

$$S_i = k_{i,a} / k_{i,0} \quad (11)$$

여기서, 아래첨자 i 는 요소번호를 나타낸다. 따라서 부재별 손상지수는 다음과 같이 정의된다.

$$\alpha_i = 1 - S_i \quad (12)$$




그림 1 다층퍼셉트론

신경망의 훈련패턴 생성시, 유한요소모델 각 요소의 강성지수를 변화시켜가며 해석을 통해서 모드형상을 계산하고,

이를 강성지수가 1인 경우의 기저 유한요소모델로부터 구한 모드형상으로 빼거나 나누어 모드형상의 차와 모드형상의 비를 계산한다. 이때 지점부와 노드점 부근의 자료를 제외하여 훈련패턴을 생성하여 신경망을 학습하였다. 신경망의 학습 후, 계측된 실제 자료로부터 실험모드를 추출하고 이를 초기 계측자료 또는 이전 계측자료로부터 추출된 모드로 나누어 신경망의 입력패턴을 구성하여 훈련된 신경망에 입력하면 구조부재별 강성지수가 출력되고, 이를 이용하여 구조물의 부재별 손상지수를 평가하도록 한다.

3. 수치 검증 예제

3.1 단순보 예제

모드형상의 차와 모드형상의 비를 신경망의 입력자료로 활용하는 것이 모델오차를 효과적으로 고려할 수 있는가에

대한 검증을 그림 2와 같은 단순보에 대한 수치예제를 통하여 수행하였다. 단순보는 8개의 보요소로 이루어져 있으며 각 요소는 길이 1.25m, 휨강성 $EI = 7.75 \times 10^4 \text{ kN}\cdot\text{m}^2$ 로 동일하다. 모델오차는 각 보요소의 휨강성을 랜덤하게 교란시켜서 도입하였다. RMS 레벨로 5%와 10% 두가지 모델오차 수준에 대해서 각각 100개씩의 교란된 유한요소모델을 생성하였다. 그림 3에서는 도입한 모델오차를 5%와 10% 모델오차 수준에 대해서 각각 5개씩 예시하였다. 이때, 교란된 유한요소 모델의 휨 강성을 교란되지 않은 초기 강성에 대한 상대강성으로 나타내었다.

5%와 10% 모델 오차를 가지는 5개의 기저유한요소모델 각각에 대한 저차 4개의 고유주파수를 정확한 모델로부터 얻은 고유주파수와 함께 표 1에 나타내었다. 2.1절에서 가정한 $\Delta\omega_i \approx \Delta\tilde{\omega}_i$ 에 대한 수치검증을 Model 5A 및 Model 10E를 대상으로 표 2에 나타낸 바와 같은 6개의 손상시나






그림 3 도입된 모델오차의 예

표 1 단순보 모델의 고유주파수 (건전상태)

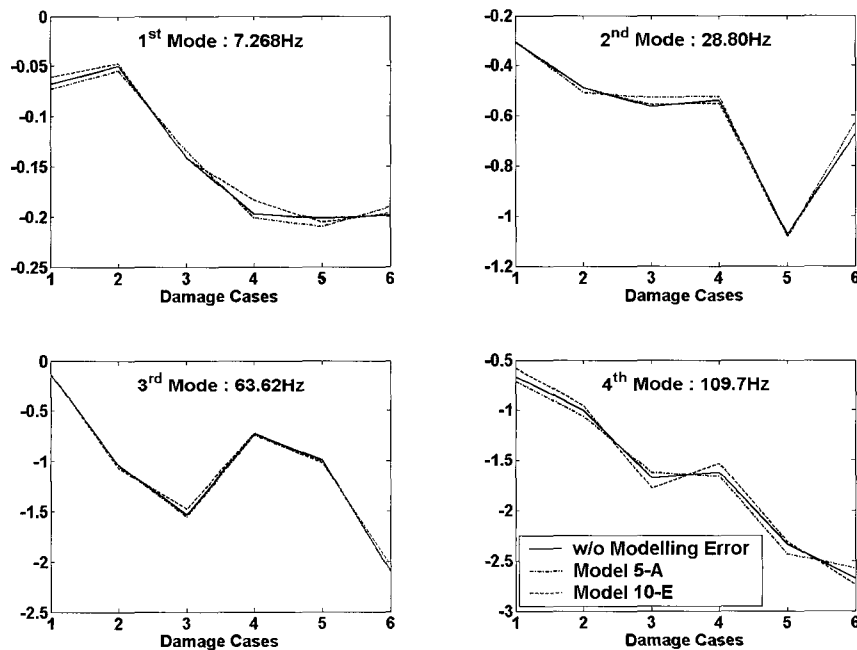
Modes	True	Models with 5% modeling error					Models with 10% modeling error				
		5-A	5-B	5-C	5-D	5-E	10-A	10-B	10-C	10-D	10-E
1	7.268	7.251	7.341	7.236	7.246	7.276	7.249	7.251	7.072	7.133	7.269
2	28.80	28.56	29.01	28.66	28.97	28.80	28.86	28.85	28.36	29.25	28.45
3	63.62	63.63	63.88	64.01	63.73	63.91	62.99	62.85	63.66	62.88	63.89
4	109.7	109.5	109.5	109.6	109.5	109.5	109.3	109.3	109.4	109.2	109.1

표 2 단순보 모델의 손상시나리오 (휨강성의 감소)

El. No.	El. 1	El. 2	El. 3	El. 4	El. 5	El. 6	El. 7	El. 8
Case 1	-	-	10%	-	-	-	-	-
Case 2	-	15%	-	-	-	-	-	-
Case 3	-	-	-	10%	-	-	15%	-
Case 4	-	-	15%	10%	-	-	-	-
Case 5	-	10%	15%	-	-	10%	-	-
Case 6	10%	-	-	15%	-	-	15%	-


리오에 대하여 수행하였다. 그림 4에서는 각 손상시나리오에 대한 고유주파수의 변화를 나타내었다. 모델오차가 없는 구조계에서 손상 전·후에 대한 고유주파수의 변화($\Delta\omega_d$)는 모델오차가 있는 구조계에서의 손상에 대한 고유주파수의 변화($\Delta\tilde{\omega}_d$)와 매우 유사하게 나타남을 알 수 있다. 모든 경우에 있어서 $\Delta\omega_d$ 와 $\Delta\tilde{\omega}_d$ 의 차이가 0.2%미만으로 매우 작게 나타나고 있어, 본 연구에서의 가정사항이 합리적임을 알 수 있다.

그림 5에서는 손상과 모델오차에 따른 첫번째 모드의 영향을 살펴보았다. 모델오차가 없는 건전상태에서의 참값과 10% 모델오차를 가지는 Model 10E의 건전상태 사이의 차이가 손상에 의한 영향보다 매우 크게 나타남을 알 수 있다. 여기서 손상은 3번 보요소의 휨강성을 20% 감소시킨 경우이다. 이러한 경우, 부정확한 기저유한요소모델(Model 10E)로 부터 얻은 모드형상 자료로는 모델오차가 없는 경우의 손상 전·후 상



(— : $\Delta\omega_d$ without modeling error, — — — : $\Delta\tilde{\omega}_d$ with 5% modeling error (5A), ···· : $\Delta\tilde{\omega}_d$ with 10% modeling error (10E)

그림 4 $\Delta\omega_d \approx \Delta\tilde{\omega}_d$ 에 대한 수치검증



Modal values of first mode			
Node No.	True intact	True damaged (10% at EL. 3)	Model 10E intact
2	0.1914	0.1926	0.1865
3	0.3535	0.3566	0.3454
4	0.4619	0.4644	0.4542
5	0.5001	0.4994	0.4975
6	0.4619	0.4597	0.4688
7	0.3535	0.3511	0.3649
8	0.1914	0.1899	0.1979

(—: True intact, — — —: True damaged (10% at EL. 3), - · - · -: Model 10E intact)

그림 5 손상과 모델오차에 따른 첫번째 모드의 변화

태를 판단할 수 없으며, 따라서 손상추정이 힘들게 된다.

표 2에 나타난 6개의 손상시나리오에 대하여 손상추정을 수행하였다. 저차 4개 모드에 대한 손상후의 모드형상, 손상 전·후의 모드형상의 차와 비를 각각 신경망의 입력자료로 활용하여 손상추정결과를 비교하였다. 기저유한요소모델에 대한 다양한 모델오차의 영향을 살펴보기 위하여 5%와 10% 모델오차를 가지는 기저모델 100개씩을 생성하였다. 따라서 100개의 신경망을 각각 훈련하여 손상추정을 수행하였다. 손상추정에 앞서, 본 연구에서 신경망의 입력자료로

제한한 손상 전·후의 모드형상의 차가 모델오차에 따라 어떻게 나타나는지 살펴보았다. 5%와 10%의 랜덤한 모델오차를 가지는 기저모델 100개에 대하여 표 2의 손상시나리오 1,3,5번에 대한 모드형상의 차($\Delta\tilde{\phi}_d$)를 계산하였다. 100개 모델에 대한 $\Delta\tilde{\phi}_d$ 의 평균을 모델오차가 없는 기저모델에서의 동일한 손상에 대한 모드형상의 차($\Delta\phi_d$)와 비교하여 그림 6에 나타내었다. 동일한 손상에 대하여 모드형상의 차가 모델오차의 유무에 관계없이 근사하게 나타남을 알 수 있으며,

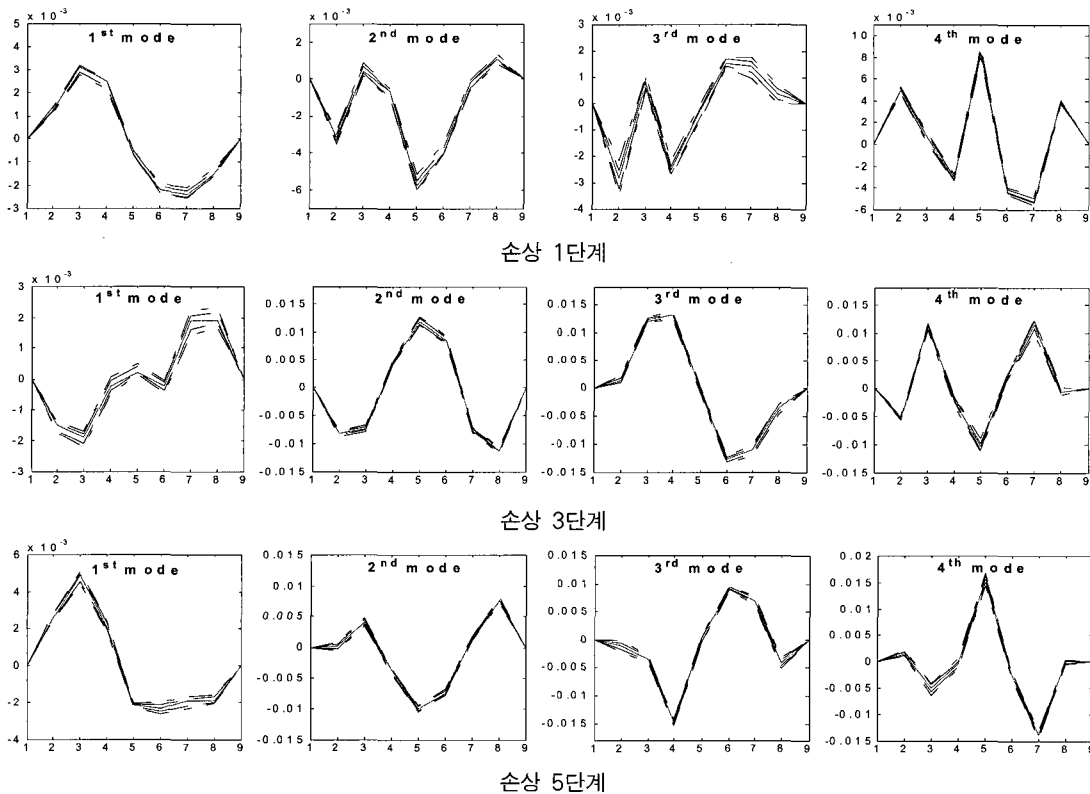



그림 6 모델오차의 유무에 따른 모드형상의 차

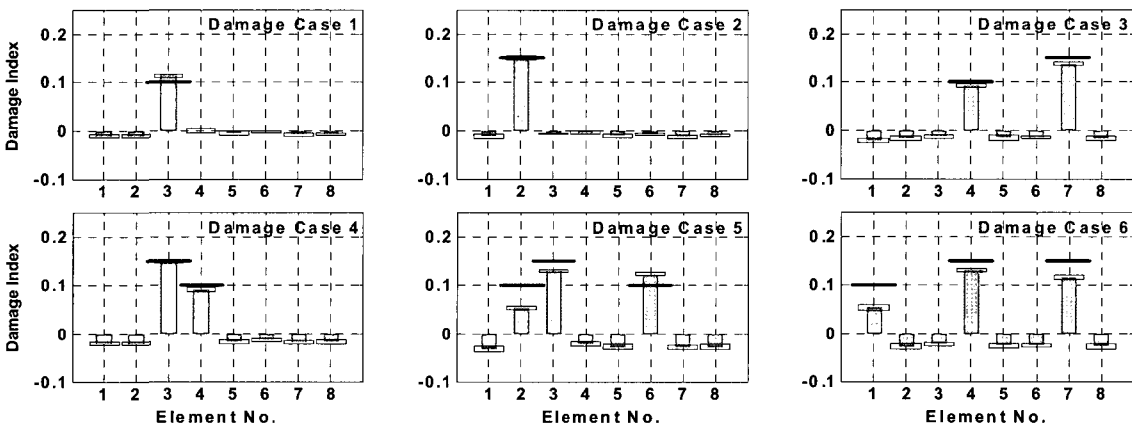
본 연구에서 제안한 식 (6a)가 합리적으로 사용될 수 있음을 단순보에 대한 수치모의실험을 통하여 확인하였다.

그림 7과 8에서는 100개의 경우에 대한 손상추정 결과의 평균값과 표준편차를 정확한 값과 함께 나타내었다. 모드형


상의 차와 모드형상의 비를 사용한 경우에는 평균값이 실제 도입된 손상지수와 유사하고, 작은 표준편차를 나타내었다. 따라서 모든 경우에 있어서 손상이 매우 성공적으로 추정되었음을 알 수 있다. 반면 모드형상 자체를 신경망의 입력으



(a) Using mode shapes




(b) Using mode shape differences




(c) Using mode shape ratios

(— Assumed exact, ■ : Mean, □: Mean ± σ)


그림 7 단순보 예제의 손상추정결과 : 5% modeling error



(a) Using mode shapes



(b) Using mode shape differences



(c) Using mode shape ratios

(— Assumed exact, ■ : Mean, □ : Mean ± σ)

그림 8 단순보 예제의 손상추정결과 : 10% modeling error

로 사용한 경우에는 평균값은 합리적으로 추정된 것으로 보이나, 표준편차는 모든 부재에 있어서 매우 크게 나타남을 알 수 있다. 이는 100개의 랜덤한 모델오차에 대한 영향이 평균값에서는 상쇄되는 결과이고, 각각의 추정결과를 살펴보

면 큰 표준편차에서 알 수 있는 바와 같이 손상추정이 잘 이루어지지 않았음을 알 수 있다. 이러한 결과로부터, 기저유한요소 모델에서의 모델오차의 영향을 줄이기 위하여 손상 전·후의 모드형상의 차나 모드형상의 비가 신경망의 입력자

료로 효과적으로 활용될 수 있음을 알 수 있다.

3.2 다주형교량 예제

좀더 복잡한 검증예제를 통하여, 본 연구에서 제시한 기법의 실제 적용성을 검토하였다. 예제교량은 그림 9와 같이 5개의 주형, 가로보, 콘크리트 슬라브를 가지고 있는 단순교이다. 실제 구조물에서 계측을 통하여 신뢰성 있게 추정가능한 모드의 개수는 저차 몇 개의 모드에 불과하다. 따라서 본 연구에서는 저차 3개의 모드를 손상추정을 위한 자료로 활용하였다. 그림 10 및 표 3에서는 상용프로그램인 SAP2000을 사용하여 구한 저차 3개 모드를 나타내었다. 각각의 주형은 8개의 프레임요소로 모델링하였으며, 상판은 쉘요소로 모델링 하였다. 모델오차는 앞 절의 단순보의 예제에서와 같이 주형의 휨강성을 RMS레벨로 10%, 20% 교란시킨 두가지 경우를 고려하였으며, 각각의 모델오차를 가지는 다양한 기

저모델에 대하여 해석을 수행하였다. 본 절에서는 10%, 20% 모델오차를 가지는 다양한 기저모델 중 하나에 대한 해석내용을 설명하기로 한다. 다른 기저모델들에 대한 결과들도 설명하는 해석결과와 유사하게 나타났다. 손상은 표 4에 나타낸 바와 같이 임의로 정한 프레임 요소의 휨강성을 감소시켜서 나타냈으며, 손상의 위치를 늘려가며 손상경우 6가지에 대해서 손상추정을 수행하였다. 손상추정을 위한 입력자료는 비교를 위하여 모드형상, 모드형상의 차, 모드형상의 비를 각각 이용하였으며, 주파수 정보는 제외하였다.

표 3 다주형교량 모델의 고유주파수 (건전상태)

Modes	True	with 10% modeling error	with 20% modeling error
1	18.03	17.86	17.68
2	20.04	19.88	19.81
3	52.89	52.82	52.82





그림 9 다주형교량 모델 및 요소번호




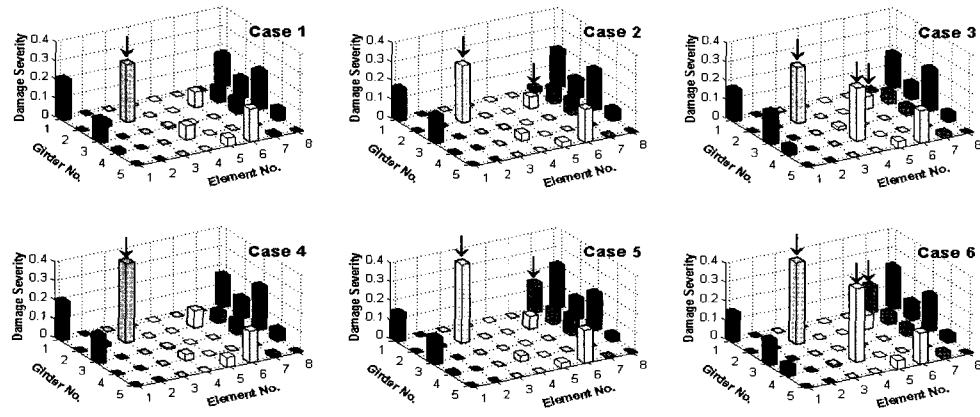
그림 10 다주형교량 모델의 저차 3개 모드

표 4 다주형교량 모델의 손상시나리오 (힘강성의 감소)

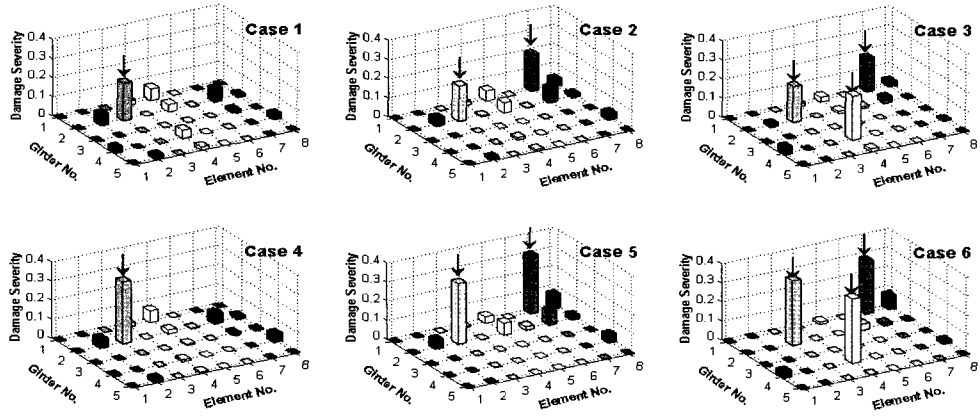
El. No.	Case 1	Case 2	Case 3	Case 4	Case 5	Case 6
7	-	20%	20%	-	30%	30%
11	20%	20%	20%	30%	30%	30%
28	-	-	20%	-	-	30%

손상추정의 결과를 그림 11, 12에 나타내었다. 모드형상 자체를 신경망의 입력으로 사용한 경우에는 모델오차의 크기

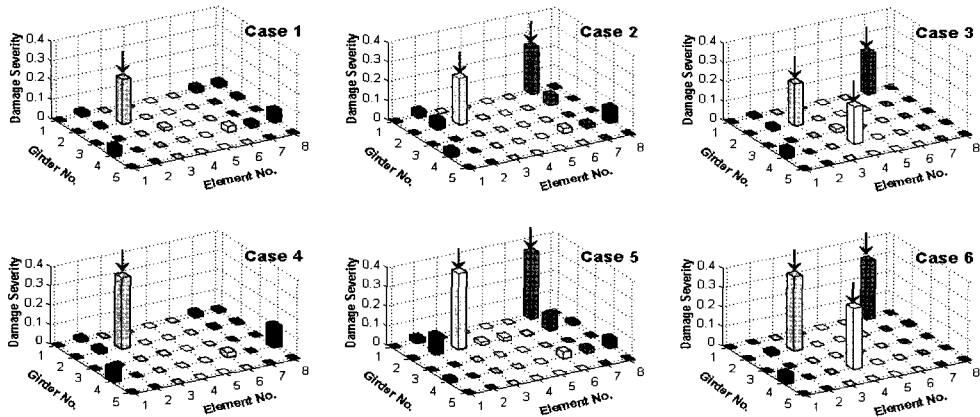
가 비교적 작은 10% 모델 오차의 경우에도 손상추정이 과도한 경우가 많이 나타났으며, 모델오차가 20%인 경우에는 손상추정 결과가 매우 나쁘게 나타났다. 반면, 본 연구에서 제시한 손상 전·후의 모드형상의 차나 모드형상의 비를 사용한 경우에는 지점부근에서 약간의 오경보가 있기는 하나 실제 손상부재에서 추정된 손상지수 값에 비추어 볼 때, 모든 손상시나리오에 대해서 손상의 위치 및 정도의 추정이 성



(a) Using mode shapes

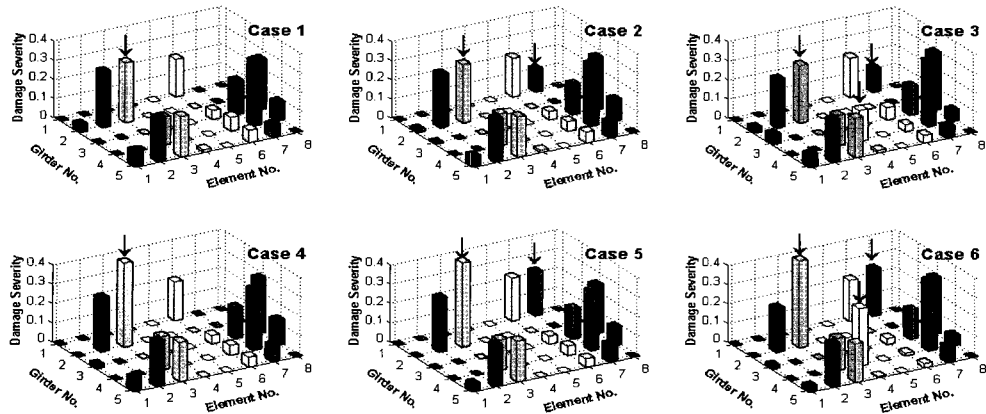


(b) Using mode shape differences

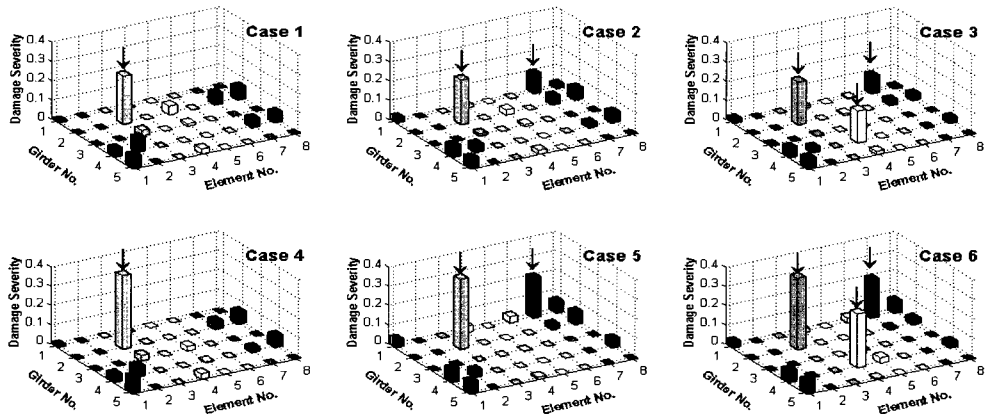


(c) Using mode shape ratios

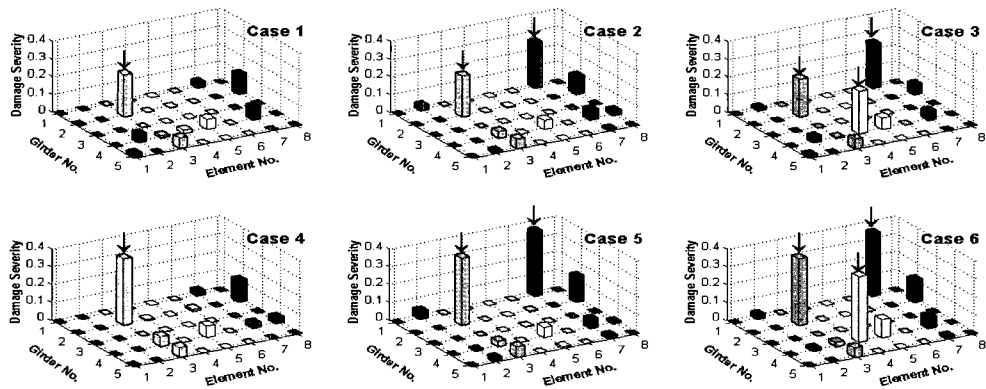
그림 11 다주형교량 예제의 손상추정결과 : 10% modeling error (손상위치↓)



(a) Using mode shapes



(b) Using mode shape differences



(c) Using mode shape ratios

그림 12 다주형교량 예제의 손상추정결과 : 20% modeling error (손상위치↓)

공적으로 수행되었음을 알 수 있다. 이로부터 본 연구에서 제시한 손상추정기법이 복잡한 구조물의 경우에도 효과적으로 모델오차의 영향을 줄일 수 있음을 검증하였다.

4. 결 론

본 연구에서는 신경망기법을 활용한 손상추정에서 해석모

델의 불확실성을 효과적으로 고려할 수 있는 기법을 제안하였다. 손상 전·후의 모드형상의 차 또는 모드형상의 비를 신경망의 입력자료로 활용함으로써, 기저모델의 모델오차를 효과적으로 줄일 수 있음을 보였다. 모델오차가 없는 구조계와 모델오차가 있는 구조계에서의 손상 전·후에 대한 모드방정식으로부터 모드형상의 차 또는 모드형상의 비가 모델오차에 민감하지 않음을 보이고, 이를 단순보 및 다주형 교량

에 대한 수치모의실험을 통하여 검증하였다.

단순보에 대한 모의실험에서는 각 보요소의 휨 강성을 RMS 레벨로 5%와 10% 교란시킨 100개의 모델오차를 가지는 기저모델에 대하여 손상추정을 수행하였다. 손상추정결과, 모드형상 자체를 사용한 경우에는, 추정된 손상지수의 평균값은 랜덤한 모델오차의 영향이 평균과정에서 상쇄되는 효과로 인해 합리적으로 보이거나, 큰 표준편차를 보이므로 개개의 손상추정은 실패하였음을 알 수 있다. 반면, 손상 전·후의 모드형상의 차와 모드형상의 비를 사용한 경우에는 평균값이 실제 도입된 손상지수와 유사하면서도 작은 표준편차를 나타내었다. 따라서 개개의 경우에 있어서도 손상이 매우 성공적으로 추정되었음을 알 수 있다. 이러한 결과로부터, 기저유한요소 모델에서의 모델오차의 영향을 줄이기 위하여 손상 전·후의 모드형상의 차나 모드형상의 비가 신경망의 입력자료로 효과적으로 활용될 수 있음을 검증하였다.

기저모델의 모델오차를 고려한 손상추정기법의 실제 적용성을 검토하기 위하여, 5개의 주형을 가지는 다주형 예제교량에 대한 모의실험을 수행하였다. 10%, 20% 모델오차를 가지는 두가지의 특정 경우에 대하여 손상추정을 수행한 결과, 단순보에 대한 모의실험의 결과와 마찬가지로 모드형상 자체를 사용한 경우는 손상추정이 실패하였으나, 모드형상의 비를 사용한 경우에는 손상의 위치 및 정도의 추정이 성공적으로 수행되었다. 이로부터 본 연구에서 제안한 기법이 복잡한 구조물의 경우에도 효과적으로 적용될 수 있음을 검증하였다.

본 연구에서는 휨강성의 감소를 손상시나리오로 사용하였으므로, 휨거동이 지배적인 구조물에 적용성이 큰 기법이라 볼 수 있으며, 추후 다양한 손상시나리오에 대한 연구가 검토가 필요하다고 생각된다. 또한, 본 연구에서는 이론적 전개상 모델오차의 정도와 손상에 의한 강성의 변화가 작다고 가정하였다. 따라서 모델오차가 큰 경우에는 그에 따른 손상 추정 오차도 커지게 되므로, 사용자 측면에서는 구조물의 거동을 잘 나타낼 수 있는 정확한 기저모델을 구현 하려는 노력이 선행되어야 하며, 그 이후에 본 연구에서 제안한 기법을 통하여 해석 모델에 존재하는 모델오차의 영향을 줄이는 것이 타당하다.

감사의 글

본 연구는 과학기술부·한국과학재단 지정 한국과학기술원 스마트사회기반시설 연구센터의 연구비 지원에 의한 결과로써, 저자들은 이의 지원에 감사한다.

참 고 문 헌

- 김정태, 류연선, 조현만(2002) 고유진동수 이용 손상추정법과 모드형상 이용 손상추정법에 의한 PSC 보의 비파괴 손상검색, 한국전산구조공학회논문집, 15(1), pp. 1229~3059.
- 박승희, 윤정방, 노용래(2004) 강 구조물의 손상 검색을 위한 램 웨이브와 웨이브렛 계수의 효율적인 사용, 한국전산구조공학회 학술발표논문집, pp.429~436.
- 윤정방, 장신애, 심성한, 이종재(2002) Hilbert-Huang Transform을 이용한 교량구조물의 손상추정기법, 한국전산구조공학회 가을 학술발표회 논문집, pp.453~458.
- Chase, S.B., Aktan, A.E. (eds.)(2001) Health Monitoring and Management of Civil Infrastructure Systems, SPIE Vol. 4337
- Chou, J. H., Ghaboussi, J.(2001) Genetic Algorithm in Structural Damage Detection, *Computers and Structures*,79, pp.1335~1353.
- Doebling, S. W., Farrar, C. R., Prime, M. B. (1998) A Summary Review of Vibration-Based Damage Identification Methods, the Shock and Vibration, Digest, 30(2), pp.91~105.
- Gawronski, W., Sawicki, J. T.(2000) Structural Damage Detection Using Modal Norms, *Journal of Sound and Vibration*, 229(1), pp.194~198.
- Ko, J. M., Chak, K. K., Wang, J. Y., Ni, Y. Q., Chen, T.H.T.(2003) Formulation of an uncertainty model relating modal parameters and environmental factors by using long-term monitoring data, Smart Systems and Nondestructive Evaluation for Civil Infrastructures, S.-C. Liu (ed.), SPIE Vol. 5057.
- Lee, J. W., Kim, J. D., Yun, C. B., Yi, J. H., Shim, J. M.(2002) Health-Monitoring Method for Bridges under Ordinary Traffic Loadings, *Journal of Sound and Vibration*, 257(2), pp.247~264.
- Masri, S. F., Smyth, A. W., Chassiakos, A. G., Nakamura, M., Caughey, T. K.(1999) Training Neural Networks by Adaptive Random Search Techniques, *Journal of Engineering Mechanics*, 125(5), pp.123~132.
- Matsuoka, K.(1992) Noise injection into inputs in back-propagation learning, *IEEE Transaction of Systems, Man, and Cybernetics*, 22(3), pp.436~440.
- Ni, Y. Q., Wang, B. S., Ko, J. M.(2002) Constructing input vectors to neural networks for structural

- damage identification, *Smart Materials and Structures*, 11, pp.825~833.
- Ni, Y. Q., Zhou, X. T., Ko, J. M., Wang, B. S. (2000) Vibration-based damage localization in Ting Kau Bridge using probabilistic neural network, *Advances in Structural Dynamics*, J.M. Ko and Y.L. Xu (eds.), Elsevier Science Ltd., Oxford, UK, Vol. II, pp.1069~1076.
- Quek, S. T., Wang, Q., Zhang, L., Ong, K. H. (2001) Practical Issues in the Detection of Damage in Beams Using Wavelets, *Smart Materials and Structures*, 10, pp.1009~1017.
- Sampaio, R. P. C., Maia, N. M. M., Silva, J. M. M.(1999) Damage Detection Using The Frequency Response-Function Curvature Method, *Journal of Sound and Vibration*, 226(5), pp.1029~1042.
- Szewczyk, Z. P., Hajela, P.(1994) Damage detection in structures based on feature-sensitive neural networks, *Journal of Computing in Civil Engineering*, ASCE, 8(2), pp.163~178.
- Wu, X., Ghaboussi, J., Garret, J.H., Jr.(1992) Use of neural networks in detection of structural damage, *Computers and Structures*, 42(4), pp.649~659.
- Yun, C. B., Bahng, E. Y.(2000) Substructural identification using neural networks, *Computers and Structures*, 77(1), pp.41~52.
- Yun, C. B., Yi, J. H., Bahng, E. Y.(2001) Joint Damage Assessment of Framed Structures Using Neural Networks Technique, *Engineering Structures*, 23(5), pp.425~435.
- Zou, J., Chen, J., Pu, Y. P., Zhong, P.(2002) On the wavelet time-frequency analysis algorithm in identification of a cracked rotor, *Journal of Strain Analysis*, 37(3), pp.239~246.
- Zou, Y., Tong, L., Steven, G. P.(2000) Vibration-Based Model-Dependent Damage (Delamination) Identification and Health Monitoring For Composite Structures - A Review, *Journal of Sound and Vibration*, 230(2), pp.357~378.