

깊은 신경망을 이용한 구조물의 유한요소모델 업데이트

공 명* · 박원석**

Gong, Ming*, Park, Wonsuk**

Finite Element Model Updating of Structures Using Deep Neural Network

ABSTRACT

The finite element model updating can be defined as the problem of finding the parameters of the finite element model which gives the closest response to the actual response of the structure by measurement. In the previous researches, optimization based methods have been developed to minimize the error of the response of the actual structure and the analytical model. In this study, we propose an inverse eigenvalue problem that can directly obtain the parameters of the finite element model from the target mode information. Deep Neural Networks are constructed to solve the inverse eigenvalue problem quickly and accurately. As an application example of the developed method, the dynamic finite element model update of a suspension bridge is presented in which the deep neural network simulating the inverse eigenvalue function is utilized. The analysis results show that the proposed method can find the finite element model parameters corresponding to the target modes with very high accuracy.

Key words : Finite element model updating, Deep neural networks, Inverse eigenvalue problem, Suspension bridge

초 록

유한요소모델 업데이트는 측정에 의한 구조물의 실제 응답과 가장 가까운 응답을 내는 유한요소모델의 매개변수를 찾는 문제로 정의할 수 있다. 기존 연구에서는 실 구조물과 해석 모델의 응답의 오차를 최소화하는 최적화에 기반 한 방법이 개발되었다. 이 연구에서는 목표 모드 정보로부터 유한요소 모델의 매개변수를 직접 얻을 수 있는 역 고유치 문제를 구성하고 역 고유치 문제를 빠르고 정확하게 풀기 위한 깊은 신경망(Deep Neural Network)을 구성하는 방법을 제안한다. 개발한 방법의 적용 예로서 현수교의 역 고유치 함수를 모사하는 신경망을 이용한 동적 유한요소 모델 업데이트를 보인다. 해석 결과 제시한 방법은 매우 높은 정확도로 목표 모드에 대응하는 매개변수를 찾아낼 수 있음을 보였다.

검색어 : 유한요소모델 업데이트, 깊은 신경망, 역 고유치 해석, 현수교

1. 서론

교량 등 대형구조물의 유지 보수 및 성능 평가의 중요성이 커짐에 따라 정확한 모델을 개발할 필요성이 커지고 있다. 특히 구조 건전도 모니터링(Structural Health Monitoring, SHM)이 도입되면서 구조물의 안전성과 내구성을 확보하는 상태평가와 함께 실시간 거동계측에 의한 유지관리의 중요성이 부각되고 있다(Sohn et al., 2003). 이를 위한 주요 도구로서 유한요소모델이 사용된다. 유한요소모델은 구조계의 기하학적, 역학적, 물리적 특성을 가장 잘 나타낼 수 있는 표현법으로 유지관리단계에서도 부재력 산정, 손상 진단, 내하력 평가 등에 광범위하게 적용되고 있다.

* 목포대학교 대학원 토목공학과 석사 (Mokpo National University · gm6048067@mokpo.ac.kr)

** 정희원 · 교신저자 · 목포대학교 토목공학과 조교수, 공학박사 (Corresponding Author · Mokpo National University · wonsuk@mokpo.ac.kr)

Received November 22, 2018/ revised January 5, 2019/ accepted January 7, 2019

그러나 일반적으로 구조물의 건설 전 사전 구축된 조건을 기반으로 하는 설계 유한요소 해석 모델은 시공 이후 현재 상태의 구조물을 정확하게 나타내지 않는다고 할 수 있다. 예를 들어 설계 모델의 강성은 종종 비 구조적 부재를 무시함으로써 과소 평가되고, 채포장 등 유지관리 작업에 따른 질량의 변화 등도 적절히 반영되지 않는다. 또한 제작 오차 및 시공 오차에 의해 구조계의 응답에 영향을 주는 추가 불확실성이 도입된다. 시간 경과에 따른 손상 및 성능 저하 역시 일반적으로 설계 모델에 반영되지 않는다. 따라서 교량 등 구조물의 완공 후 현재 사용 상태를 가장 잘 표현할 수 있는 유한요소모델 업데이트 방법이 구조물의 성능 평가를 위해 널리 수용되어왔다(Brownjohn et al., 2000; Zhang et al., 2001; Kim et al., 2011; Park et al., 2012; Harms et al., 2010).

유한요소모델 업데이트는 기계 및 항공우주 분야에서 널리 사용되어 왔지만 교량 등 토목 구조물에 적용할 때의 차별성이나 독특한 점도 여러 연구를 통해 밝혀지고 있다. 예를 들어 변위 및 변형률과 같은 정적 응답을 고려하는 것이 응력 평가에 중요할 수 있고(Zhu et al., 2014), 하중, 계측, 물성 등 많은 불확실성을 다룰 필요가 있으며(Park et al., 2015; Simoen et al., 2015; Kontoroupi and Smyth, 2017), 또한 대형 구조체로 인한 모델의 크기 증가와 많은 수의 업데이트 변수를 다룰 필요가 있는 것 등이다. 이러한 큰 모델과 많은 수의 유한요소모델 매개변수를 다루는 것은 기존의 최적화 방법에 기반한 유한요소모델 업데이트 방법이 효율적이지 않을 수 있는 요인이 된다. 특히, 화재, 충돌 등 불시에 발생하는 극단사건 상황과 관련하여 최근 중요성이 증가하고 있는 실시간 대응체계에서 유한요소모델이 현재 상태를 실시간에 가깝게 반영해야 할 필요성이 있을 때 기존의 최적화 기반 유한요소모델 업데이트 방법은 정확도 및 신속성 측면에서 비효율적일 수 있다.

이 연구에서는 전통적인 최적화 기법이 아닌 새로운 접근법을 제안한다. 전통적인 최적화 기반 모델 업데이트가 계측과 모델 응답간 오차를 최소화 하는 유한요소모델 매개변수를 찾는 것인 반면, 제안하는 방법은 목표 모드 정보로부터 유한요소 모델의 매개변수를 직접 얻을 수 있는 역 고유치 문제를 구성하고 역 고유치 문제를 빠르고 정확하게 풀기 위한 깊은 신경망(Deep Neural Network)을 이용한다. 2장에서 제안하는 역 고유치 문제로 정식화 방법을 기술하고 3장에 깊은 신경망을 이용한 업데이트 방법을 간단한 3자유도 구조계 예를 통해 소개한다. 4장에서는 개발한 방법의 적용 예로서 실구조물인 자정식 현수교의 3차원 유한요소모델에 대한 역 고유치 함수를 묘사하는 깊은 신경망 구성 및 이를 이용한 동적 유한요소모델 업데이트를 보인다. 5장 결론에서는 제시하는 방법의 효율성 및 한계점, 향후 연구방향에 대하여 토의한다.

2. 유한요소모델 업데이트 문제 정식화

유한요소모델 업데이트는 계측한 실 구조물의 동, 정적 응답과 가장 가까운 응답을 낼 수 있는 유한요소 모델을 찾는 문제이다. 이 장에서는 먼저 현재 가장 많이 사용되고 있는 오차 최소화 관점에서의 유한요소모델 업데이트 문제 정식화를 소개하고, 이어서 이 연구에서 새롭게 제시하는 역 고유치 문제 관점의 정식화를 기술한다.

2.1 최적화 문제로의 유한요소모델 업데이트 문제 정식화

일반적으로 구조물의 정·동적 해석을 위한 유한요소모델은 질량, 감쇠, 강성 행렬로 표현된다. 따라서 모델 업데이트는 이러한 행렬을 업데이트 하는 문제로 나타낼 수 있으며 정적 모델에서는 강성 행렬이, 동적 모델에서는 주로 질량과 강성 행렬이 업데이트의 대상이 된다. Friswell and Mottershed(2013)는 유한요소모델 행렬을 업데이트하는 방법을 직접법(direct methods)과 반복법(iterative methods)로 구분하였는데, 직접법은 닫힌 형태 해(closed form solution)인 업데이트 방정식(update equation)으로 나타나는 해석적 최적해에 의해 업데이트된 질량, 강성 행렬을 직접 구하는 방법이고, 반복법은 질량, 강성 행렬을 구성하는 모델 매개변수를 반복적 최적화 과정을 통해 구하는 방법이다. 직접법은 해석적 최적해를 얻을 수 있으나 질량 행렬과 강성 행렬의 구조가 유지 되지 않아 업데이트한 행렬의 물리적 특성을 파악하기 어렵다. 반면, 반복법에 사용하는 유한요소모델의 매개변수는 구조물의 기하학적 형상과 재료의 물성치 등 물리적인 특성과 직접적으로 연관된 변수로 선정하는 것이 일반적이므로, 업데이트 결과의 해석이 용이한 반면 수치적 최적화 과정을 거치는 것이 보통이다. 일반적으로 모델 자체 보다 모델의 응답과 실구조물의 응답을 일치시키는 것에 주안점이 있는 경우에는 직접법을 이용한 업데이트를, 실구조물의 주요 물리적 변수를 추적하고, 원 모델의 행렬 구조를 유지할 필요가 있을 경우에는 반복법을 사용한다. 이 연구에서는 교량 등 토목구조물의 모델 업데이트에 주로 사용되고 있는 다음과 같은 동적 유한요소모델 업데이트 문제를 고려한다.

실제 구조물의 계측 응답으로부터 구한 고유진동수벡터 및 고유벡터행렬을 각각 λ_m, Φ_m 이라 하자. 유한요소모델의 매개변수벡터 θ 에 의해 결정되는 질량 및 강성행렬을 각각 $M(\theta), K(\theta)$ 라고 하면 이들 행렬에 의해 유한요소모델의 고유진동수벡터 $\lambda_a(\theta)$ 및 고유벡터행렬 $\Phi_a(\theta)$ 를 구할 수 있다. 이제 계측응답에 의한 λ_m, Φ_m 과 유한요소모델의 $\lambda_a(\theta), \Phi_a(\theta)$ 와의 오차를 나타내는 목적함수 $J(\theta)$ 를 적절히 정의하면, 모델 업데이트 문제는 매개변수벡터 θ 를 설계변수로 하는 목적함수 $J(\theta)$ 의 최소화 문제로 다음 Eq. (1)과 같이 정식화 할 수 있다.

$$\min_{\theta} \mathcal{J}(\lambda_m, \phi_m, \lambda_a(\theta), \phi_a(\theta), \theta) \text{ subject to } \mathbf{g}(\theta) \leq \mathbf{0} \quad (1)$$

여기서, $\mathbf{g}(\theta)$ 는 매개변수의 제한조건 등을 나타낼 수 있는 제한조건 함수이다. Eq. (1)의 최적화 문제 목적함수 $\mathcal{J}(\theta)$ 는 여러 가지 방법으로 정의할 수 있으나 계측 모드 정보와 유한요소 모델의 모드 사이의 오차를 나타낼 수 있는 값으로 정의하는 방법이 주로 사용되고 있다. 예를 들어 Costa et al.(2016)은 다음과 같이 각 모드별 진동수의 오차 합과 모드벡터의 오차 합을 나타내는 목적함수를 구성하여 아치교의 유한요소모델을 업데이트 하였다.

$$\mathcal{J}(\theta) = a \sum_{i=1}^n \frac{|\lambda_m^i - \lambda_a^i(\theta)|}{\lambda_m^i} + b \sum_{i=1}^n |MAC(\phi_m^i, \phi_a^i(\theta)) - 1| \quad (2)$$

Eq. (2)에서 MAC (Modal Assurance Criteria)은 0과 1사이의 값을 가지며 두 모드 벡터가 직교할 때 0, 일치할 때(상수 배의 관계일 때) 1의 값을 가지도록 정의된다(Allemang, 2013).

이와 같이 오차 최소화 문제로 정식화 되는 유한요소모델 업데이트 문제는 정식화 과정이 직관적이고 명료하며, 매우 다양한 최적화 방법을 이용하여 최적 업데이트 매개변수 θ 를 구할 수 있기 때문에 가장 널리 사용되는 방법 중 하나라고 할 수 있다.

2.2 역 고유치 문제로의 유한요소모델 업데이트 문제 정식화

Eq. (1)과 같이 표현한 최적화 문제로의 정식화는 해를 찾기 위해 비선형 최적화 문제를 풀어야 하므로 일반적인 최적화 문제 풀이 과정의 어려움을 그대로 가진다. 즉, 목적함수를 계산하는데 소요되는 시간, 최적화 알고리즘에 따른 반복 계산 시간, 수렴성, 전역해와 지역해, 매개변수 수 증가에 따른 문제, 해의 존재성과 유일성 등이 그것이다. 이 연구에서는 최적화 과정에서 나타나는 고유치 문제에 착안하여 새로운 유한요소모델 업데이트 정식화 방법을 제안함으로써 최적화 문제 풀이 과정의 일부 어려움을 극복하고자 하였다. 최적화 과정의 고유치 문제는 다음과 같이 설명할 수 있다.

Eq. (1)의 업데이트 문제는 최적화 과정에서 반복적으로 개선되어 가는 매개변수에 대하여 유한요소모델의 행렬을 재구성하고 이로부터 고유치 해석을 통하여 그 매개변수에 해당하는 모델의 고유치와 모드행렬을 구하는 과정을 반복하게 된다. 즉, 이 최적화 과정에서는 매개변수벡터 θ 에서 고유값벡터 $\lambda_a(\theta)$, 모드행렬 $\phi_a(\theta)$ 를 계산하는 고유치 문제를 반복해서 계산하게 된다. 최적화 과정을 통해 얻은 최적해 θ^* 는 계측으로부터 얻은 목표 고유값 λ_m, ϕ_m 과 가장 오차가 작은 최적 고유값 λ_m^*, ϕ_m^* 을 갖는 질량

및 강성 행렬을 만들어 낼 수 있으며, 이를 고유치 문제 함수 f 를 써서 나타내면 다음과 같다.

$$f: \theta^* \rightarrow \lambda_m^*, \phi_m^* \text{ or } [\lambda_m^*, \phi_m^*] = f(\theta^*; \mathbf{M}(\theta^*), \mathbf{K}(\theta^*)) \quad (3)$$

Eq. (3)으로부터 착안하여 제안하는 방법은 고유치 함수 f 의 역함수인 역 고유치 함수 f^{-1} 를 이용한다. 최적 유한요소모델 파라미터 θ^* 를 역 고유치 함수로부터 직접 구하는 문제로 유한요소 모델 업데이트 문제를 정식화한다. 다음 Eq. (4)와 같이 정의할 수 있다.

$$f^{-1}: \lambda_m, \phi_m \rightarrow \theta^* \text{ or } \theta^* = f^{-1}(\lambda_m, \phi_m) \quad (4)$$

즉, 계측으로부터 구한 목표 고유진동수 벡터 λ_m 과 고유벡터행렬 ϕ_m 이 주어지면, 그에 해당하는 유한요소 모델의 최적 매개변수 벡터 θ^* 를 역 고유치 함수 계산으로 결정할 수 있다. 그러나, 역 고유치 문제를 푸는 해석적 방법에 대해서는 특수한 경우를 제외하고 일반적인 방법이 알려져 있지 않다. 또한 고유값에 대응하는 질량 및 강성행렬을 찾는 문제가 아닌 행렬을 구성하는 매개변수를 결정하는 역 고유치 문제의 해법에 대해서도 연구 결과를 찾기 어렵다(Chu, 1998). 따라서 이 연구에서는 깊은 신경망(Deep Neural Network)을 이용하여 Eq. (4)의 역 고유치 함수를 구성하는 방법을 제안하였다.

3. 역 고유치 함수 모사 깊은 신경망을 이용한 유한요소모델 업데이트

신경망 모델은 잘 알려진 바와 같이 임의의 비선형, 불연속, 복잡한 함수 관계, 입출력 관계를 효과적으로 모델링할 수 있는 도구이다. 신경망이 입출력 관계를 잘 표현하기 위해서는 일반적으로 많은 입출력 데이터가 필요하고 데이터가 많아질수록 최적망 구성 또는 학습에 시간이 많이 소요된다. 그러나 일단 구성된 신경망에 대해서는 매우 빠르게 출력 값을 얻을 수 있어 실시간으로 함수 값을 계산할 경우에 활용성이 높다.

이 연구에서는 Eq. (4)의 역 고유치 함수 관계를 모사하기 위해 깊은 신경망 모델을 사용하였다. 이 연구에서 사용한 용어인 깊은 신경망은 Goodfellow et al.(2016)이 제시한 분류에 따른 것으로 은닉층(hidden layer) 수가 1개 이상인 다층 신경망(Multilayer Neural Network)을 지칭한다. 유한요소모델 업데이트를 위한 역 고유치 문제에 적합한 깊은 신경망 모델을 구축하기 위해서는 입력 및 출력 데이터의 구조와 수, 입력층 및 출력층 구조, 은닉층의 개수와 층별 노드 수, 각 층 노드의 활성화 함수(activation function)

와 같은 깊은 신경망 모델 구조를 결정해야 한다. 그러나 이러한 깊은 신경망 모델의 구조는 모사하고자 하는 함수 관계에 따라 달라지므로 각 문제의 특성에 맞는 최적 구조는 일반적으로 시행착오법 등에 의한 반복 설계를 통해 결정한다.

제시한 방법의 구현 예를 보이기 위해 Fig. 1과 같은 3자유도 전단빌딩의 유한요소모델 업데이트를 고려한다. 이 유한요소모델의 질량 및 강성행렬은 다음과 같고 업데이트할 매개변수 벡터는 각 층의 질량 및 층강성 $\theta = \{m_1, m_2, m_3, k_1, k_2, k_3\}^T$ 로 한다.

$$M = \begin{bmatrix} m_1 & 0 & 0 \\ 0 & m_2 & 0 \\ 0 & 0 & m_3 \end{bmatrix}, K = \begin{bmatrix} k_1 & -k_1 & 0 \\ -k_1 & k_1 + k_2 & -k_2 \\ 0 & -k_2 & k_2 + k_3 \end{bmatrix} \quad (5)$$

역 고유치 함수를 구성하는 깊은 신경망 학습을 위한 데이터 집합을 생성하기 위해 Table 1과 같이 기준 값으로부터 질량은 20%, 강성은 10%의 변동 폭을 갖는 매개변수 벡터 θ 를 임의 생성하고, 각 매개변수에 대한 고유진동수 벡터 $\lambda_a \in R^{3 \times 1}$ 와 모드 행렬 $\Phi_a \in R^{3 \times 3}$ 를 Eq. (5)의 행렬로부터 고유치 해석을 통해 추출하였다. 샘플링은 LHS (Latin Hypercube Sampling) 방법을 사용하였다.

학습을 위한 배치 크기(batch size)는 1000개로 하였고 이중 시험 및 검증용으로 300개를 사용하였다. 최대 에포크는 10만,




Fig. 1. Three Story Shear Building Model

Table 1. Parameter Variations of the Shear Building Model for the Data Set Generation

	Nominal	Min.	Max.
m_1 (ton)	10	8	12
m_2 (ton)	10	8	12
m_3 (ton)	10	8	12
k_1 (kN/m)	200	180	220
k_2 (kN/m)	200	180	220
k_3 (kN/m)	200	180	220

별도의 드롭 아웃은 사용하지 않았다. 이 문제를 위해 구성된 신경망 구조를 Fig. 2에 나타내었다. 입력 층은 고유진동수 $\lambda_1, \lambda_2, \lambda_3$ 3개, 3×1 고유벡터 Φ_1, Φ_2, Φ_3 3개의 총 12개 노드로 구성하고, 출력 층은 매개변수 벡터 θ 의 원소인 각층 질량 3개, 각층 강성 3개에 대한 공칭 값과의 비율을 나타낸 총 6개 노드로 구성하였다. 최적 구조를 찾기 위해 은닉 층 개수와 각 은닉 층의 노드 개수를 변화시켜 가며 성능을 조사하였다. 은닉 층 개수는 1개부터 4개까지 변화시키고, 은닉 층 노드 개수는 30개-200개 까지 변화시켜 가며 최적 구조를 찾고자 하였다.

은닉 층 개수 및 노드 개수를 변화시켜 가며 학습시킨 결과를 Fig. 3에 나타내었다. 신경망 구조의 변화에 따른 학습 시간 및 목표 값과 신경망 출력 값 사이의 평균제곱오차(MSE)값을 도시하여 학습 성능을 파악하였으며, 그림에 나타난 비와 같이 일반적으로 은닉층 수를 늘려갈수록, 은닉층의 노드 개수를 늘려갈수록 학습이 잘 이루어지는 것을 확인할 수 있었다. 학습 결과 MSE값은 층당 200개의 노드 수와 은닉층 수 4개를 쓴 가장 큰 구조에서 2.7×10^{-5} 까지 줄일 수 있었고, 이 때 학습에 소요된 시간은 2.4 GHz intel CPU를 사용한 PC환경에서 약 1시간 정도 였다. 전단빌딩 모델의 고유치 생성 및 신경망 학습은 모두 MATLAB을 사용하여 프로그래밍 하였다.

학습한 역 고유치 함수 깊은 신경망이 목표 고유치와 모드벡터에 대한 업데이트 매개변수를 잘 찾을 수 있는지 확인하기 위해 학습에 이용한 데이터 집합이 아닌 가상의 계측 모드 데이터를 이용하여 신경망의 출력을 만들어 비교하였다. Fig. 4에 이 가상의 계측모드 데이터에 대한 유한요소모델 매개변수 값 정해와 두 가지 서로 다른 구조로 학습한 깊은 신경망인 DNN A와 DNN B의 출력 값을 비교한 결과를 나타내었다. DNN A는 은닉층 수 2개, 층당 뉴런 개수 30개의 구조이며, DNN B는 은닉층 수 4개, 층당 뉴런 개수 200개의 구조이다. 학습 결과 DNN A는 MSE 3.44, 매개변수

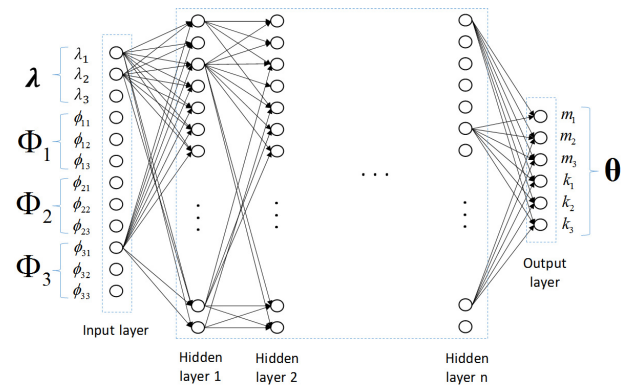


Fig. 2. Deep Neural Network Structure for an Inverse Eigenvalue Function Representation of the Finite Element Model of the Three Story Shear Building




Fig. 3. Learning Time (Left) and Mean Square Error (Right) with Respect to the Number of Nodes and Hidden Layers of the Deep Neural Network for the Inverse Eigenvalue Problem of the Three Story Shear Building Model

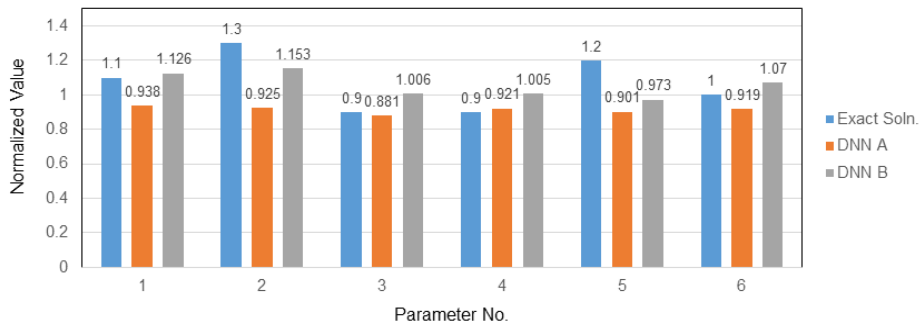


Fig. 4. Comparison of the Updated Parameters




Fig. 5. The Self-Anchored Suspension Bridge for Finite Element Model Updating

값 출력의 정해와의 오차 합이 질량 45.5 %, 강성 30.6 %로 정해와 큰 차이를 보이지만, MSE 2.7×10^{-5} 인 DNN B는 질량 2.92 %, 강성 0.25 %의 오차 합을 보여 정해와 매우 유사한 매개변수를 얻을 수 있었다. 이를 통해 잘 학습된 깊은 신경망은 구조물 유한요소 모델의 역 고유치 문제를 모사할 수 있는 것으로 판단하였다.

4. 현수교 3차원 유한요소모델 업데이트

제시한 방법의 적용성을 검증하기 위하여 실 교량 구조물에 대한 유한요소모델 업데이트를 수행하였다. 이 장에서는 대상 교량

에 대한 제원 및 업데이트할 유한요소모델에 대하여 기술하고, 이어 깊은 신경망을 이용한 모델 업데이트 결과를 기술한다.

4.1 대상 교량 및 유한요소모델

대상 교량으로 Fig. 5과 같은 모노케이블 자정식 현수교를 고려한다. 두 개의 다이아몬드형 콘크리트 주탑과 2차선 강박스거더 보강형으로 중앙 경간 250 m, 양 측 경간 110 m로 구성되어 있다. 대상 교량의 유한요소모델은 설계 당시의 정보에 기반하여 작성되었다. 거더와 주탑은 750개의 뼈대요소로, 주 케이블 및 현수체는 69개의 트러스 요소로 모델링 하였으며, 이 유한요소모델

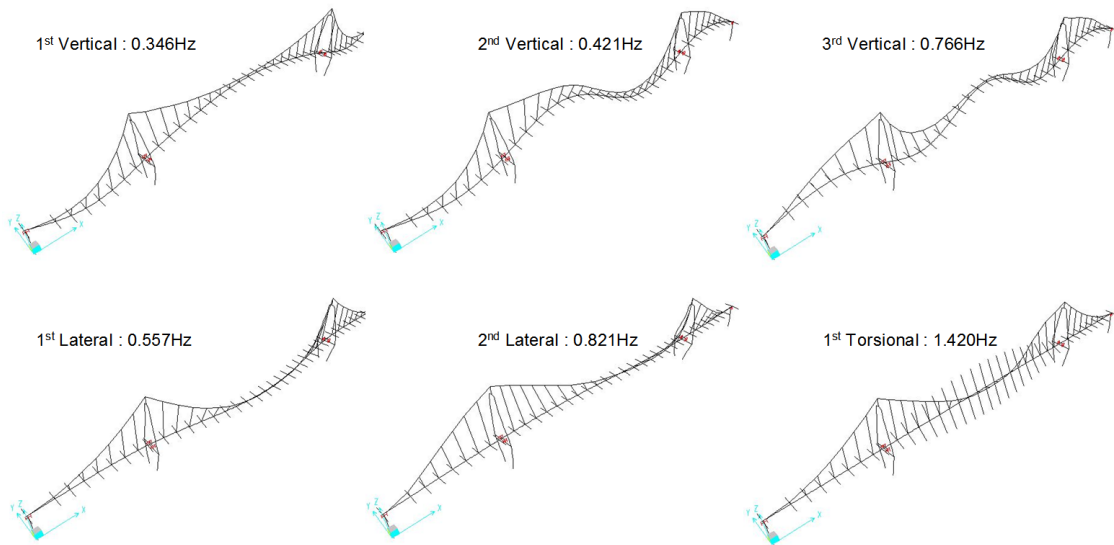


Fig. 6. Modal Frequencies and Mode Shapes of the Finite Element Model

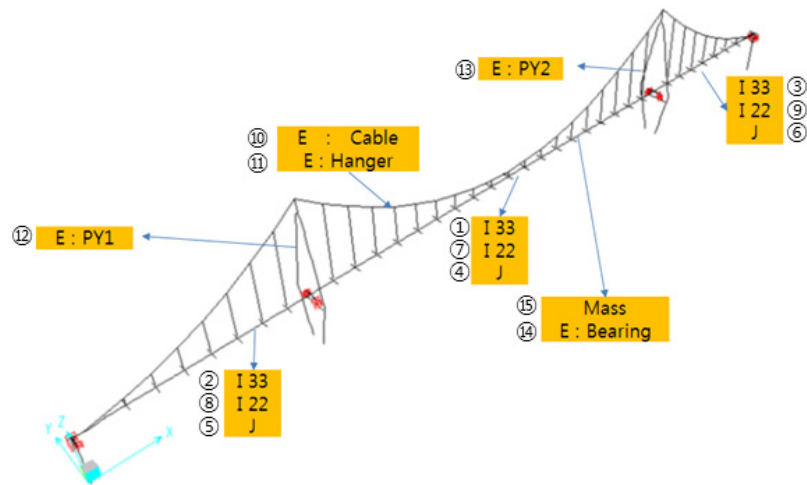


Fig. 7. Updating Parameters of the Finite Element Model for the Suspension Bridge

의 고유치 해석 결과 주요 모드 고유진동수 및 모드 형상은 Fig. 6에 나타내었다.

4.2 깊은 신경망을 이용한 유한요소모델 업데이트

대상교량의 유한요소모델 업데이트를 위한 매개변수 벡터를 Fig. 7에 정리하였다. 모두 15개의 매개변수를 선정하였으며, 이 매개변수 들은 주요 모드에 기여할 수 있는 강성 및 질량을 고려한 결과이다.

이 유한요소모델 및 매개변수벡터에 대하여 역 고유치 함수를 구성하기 위한 깊은 신경망은 다음과 같이 구성하였다. 출력 층은 앞서 정의한 15개의 유한요소모델 매개변수를 가지도록 하였다. 모드 정보로 구성되는 입력 층은 20개의 모드 정보를 고려하도록

구성하였다. 고유진동수로 20개의 노드를 할당하고, 모드벡터행렬을 위해 각 주탑에 9개, 거더에 26개의 절점 출력을 선정하였다. 각 절점 당 회전변위를 제외한 x, y, z 세 방향의 병진 변위를 고려하여 $44 \times 3 \times 20 = 2640$ 개의 입력 노드를 가지도록 하였다. 따라서 입력 노드는 모두 2660개의 노드를 가지도록 구성하였다. 은닉층 수는 2개에서 10개까지 변화시켜 가면서 조사 하였고, 은닉층의 뉴런 노드 개수는 200개에서 900개 까지 변화시켜 가며 조사하였다. 활성화 함수로는 tangent sigmoid, log sigmoid, linear 함수를 모두 고려하였다.

학습을 위한 입출력 데이터는 15개 매개변수에 대하여 초기 기준 값으로부터 변동폭 20%로 하여 1000개의 매개변수벡터를 LHS 방법으로 샘플링하고, 각각에 대한 고유치 해석을 수행하여




Fig. 8. Updated Parameters of the Finite Element Model for the Virtual True Solution: Case 1 (Left) and Case 2 (Right)

모드정보를 구축하였다.

학습을 위한 배치크기는 1000개로 하였고 이중 시험 및 검증에 30 %를 사용하였다. 학습 시 최대 에포크는 10만 번으로 하고 별도의 드롭 아웃은 사용하지 않았다. 학습결과 은닉층 수 4개 이하, 층당 노드 수는 200에서 300개 정도의 구성으로 MSE 10^{-8} 이하의 좋은 학습 결과를 얻을 수 있었다. 학습에 소요된 시간은 2.4 GHz intel CPU를 사용한 PC환경에서 최대 4시간 정도였으며, MATLAB을 이용하여 프로그래밍 하였다.

학습된 역 고유치 함수의 성능을 확인하기 위하여 학습에 이용되지 않은 가상의 계측 모드 데이터를 이용하여 역 고유치 함수 깊은 신경망이 정해를 도출할 수 있는지 확인하였다. Fig. 8에 Case 1 및 Case 2의 서로 다른 두 개의 신경망 출력값을 비교한 결과를 나타내었다. 각각 정규화된 15개의 매개변수에 대한 가상 정해 값과 깊은 신경망 출력값을 비교한 결과를 나타내었다. 정규화된 정해 매개변수 성분과 깊은 신경망의 출력 값을 비교한 결과 두 가지 Case 모두 모든 매개변수성분의 오차 합이 0.1 % 이내로 매우 정확한 업데이트 결과를 얻을 수 있었다. 이러한 결과는 제시한 방법이 실제 교량 규모의 유한요소모델에 대한 업데이트에 충분히 적용 가능한 것임을 보이는 사례로 판단된다.

5. 결론

이 연구에서는 구조물의 동적 유한요소모델 업데이트를 위한, 역 고유치 함수를 모사하는 깊은 신경망을 사용한 모델 업데이트 방법을 제안하였다. 제안하는 방법은 계측 모드와 일치하는 유한요소 모델 매개변수를 역 고유치 함수를 통해 결정하는 것으로, 유한요소 모델의 역 고유치 함수를 구하기 위해 깊은 신경망을 적용하였다. 간단한 3자유도 구조계와 복잡한 실구조 현상 유한요소 모델에 대하여 제안한 방법을 적용하고 검토한 결과, 목표 모드를 만들기

위한 유한요소모델 매개변수를 매우 높은 정확도로 찾을 수 있는 신경망을 구할 수 있었다. 이 연구에서 제안한 유한요소모델 업데이트를 위한 신경망 구조는 뼈대 요소 개수 800여개 정도 규모의 케이블 교량 유한요소 모델에 대하여 은닉층 수 4개, 층당 노드 수 200개 정도의 깊은 신경망 규모에서 충분히 학습이 가능한 것으로 파악 되었다. 또한 동 규모의 신경망 학습에 필요한 데이터의 생성 및 학습 시간도 PC 환경에서 수 시간 정도로 가능하여 실 구조물에 대한 적용성이 충분한 것으로 판단된다. 특히 이 연구에서 제안하는 유한요소모델 업데이트는 신경망의 적용으로 인해 기존의 최적화 방법으로는 적용이 어려웠던 실시간 모델 업데이트에 적용성이 높을 것으로 보인다. 즉, 학습에 걸리는 시간은 어느 정도 필요하나 학습된 신경망은 실시간으로 변하는 진동수 및 모드형상에 대한 유한요소모델 매개변수를 즉각적으로 출력할 수 있으므로 실시간으로 변하는 매개변수를 생산, 추적할 수 있다.

이 논문에서 제안한 연구 내용의 한계점 및 향후 연구가 필요한 내용은 다음과 같다. 우선 실제 계측 데이터를 사용한 모델 업데이트를 위한 추후 연구가 필요하다. 실 계측에서는 몇 가지 주요 모드에 대한 정보만 취득 가능하며 제한된 절점 개수만 계측할 수 있으므로 이를 고려하여 업데이트를 할 수 있는 신경망 구축이 필요하다. 또한 이렇게 생성된 유한요소 모델의 매개변수와 기존 최적화 방법 등으로 업데이트된 매개변수와의 비교 검토도 요구된다. 이 연구에서는 신경망의 최적 구조 결정을 위해 시행착오에 의한 반복법을 사용하였으나, 이를 자동화하여 보다 효율적으로 최적의 신경망 구조를 찾을 수 있는 방법을 개발하는 것도 좋은 연구가 될 것으로 보인다.

제안하는 방법의 효율성 및 한계점과는 별개로 이 방법 역시 유한요소모델 업데이트 체계가 가지고 있는 근본적인 한계점을 지닌다는 점도 인지해야 한다. 즉, 계측 오차, 유한요소 모델의 이산화에 의한 오차 및 한계, 해의 유일성과 존재성 문제 등 근본적인

한계점을 극복하고 있지는 않으며, 구한 해의 타당성에 대해서는 구조물에 대한 전문적인 이해와 판단이 여전히 매우 중요하다.

감사의 글

이 연구는 국토교통부 건설기술연구사업(18SCIP-B119952-03)에 의하여 수행되었습니다. 연구 지원에 감사드립니다.

본 논문은 2018 CONVENTION 논문을 수정·보완하여 작성되었습니다.

References

- Allemand, R. J. (2003). "The modal assurance criterion—twenty years of use and abuse." *Sound and vibration*, Vol. 37, No. 8, pp. 14-23.
- Brownjohn, J. M. and Xia, P.-Q. (2000). "Dynamic assessment of curved cable-stayed bridge by model updating." *Journal of Structural Engineering*, Vol. 126, No. 2, pp. 252-260.
- Chu, M. T. (1998). "Inverse eigenvalue problems." *SIAM review*, Vol. 40, No. 1, pp. 1-39.
- Friswell, M. and Mottershead, J. E. (2013). *Finite element model updating in structural dynamics*, Springer Science & Business Media.
- Goodfellow, I., Bengio, Y., Courville, A. and Bengio, Y. (2016). *Deep learning* (Vol. 1), Cambridge: MIT press.
- Harms, T., Sedigh, S. and Bastianini, F. (2010). "Structural health monitoring of bridges using wireless sensor networks." *IEEE Instrumentation & Measurement Magazine*, Vol. 13, No. 6.
- Kim, H. K., Kim, N. S., Jang, J. H. and Kim, Y. H. (2011). "Analysis model verification of a suspension bridge exploiting configuration survey and field-measured data." *Journal of Bridge Engineering*, Vol. 17, No. 5, pp. 794-803.
- Kontoroupi, T. and Smyth, A. W. (2017). "Online bayesian model assessment using nonlinear filters." *Structural Control and Health Monitoring*, Vol. 24, No. 3, p. e1880.
- Park, W., Kim, H. K. and Park, J. (2012). "Finite element model updating for a cable-stayed bridge using manual tuning and sensitivity-based optimization." *Structural Engineering International*, Vol. 22, No. 1, pp. 14-19.
- Park, W., Park, J. and Kim, H. K. (2015). "Candidate model construction of a cable-stayed bridge using parameterised sensitivity-based finite element model updating." *Structure and Infrastructure Engineering*, Vol. 11, No. 9, pp. 1163-1177.
- Simoen, E., De Roeck, G. and Lombaert, G. (2015). "Dealing with uncertainty in model updating for damage assessment: A review." *Mechanical Systems and Signal Processing*, Vol. 56, pp. 123-149.
- Siringoringo, D. M. and Fujino, Y. (2008). "System identification of suspension bridge from ambient vibration response." *Engineering Structures*, Vol. 30, No. 2, pp. 462-477.
- Sohn, H., Farrar, C. R., Hemez, F. M., Shunk, D. D., Stinemates, D. W., Nadler, B. R. and Czarnecki, J. J. (2003). "A review of structural health monitoring literature: 1996-2001." *Los Alamos National Laboratory, USA*.
- Zhang, Q., Chang, T.-YP. and Chang, C. C. (2001). "Finite-element model updating for the Kap Shui Mun cable-stayed bridge." *Journal of Bridge Engineering*, Vol. 6, No. 4, pp. 285-293.
- Zhu, Q., Xu, Y. and Xiao, X. (2014). "Multiscale modeling and model updating of a cable-stayed bridge. I: Modeling and influence line analysis." *Journal of Bridge Engineering*, Vol. 20, No. 10, pp. 04014112.