

재킷식 해상풍력터빈 지지구조물의 손상추정기법

이종원

남서울대학교 건축공학과

Damage Estimation Method for Jacket-type Support Structure of Offshore Wind Turbine

Jong-Won Lee

Department of Architectural Engineering, Namseoul University

요약 본 연구에서는 재킷식 해상풍력터빈 지지구조물의 효과적인 건전성 모니터링을 위하여, 손상에 의한 구조물의 모드 특성 변화 및 군집신경망기법을 이용한 손상추정기법을 제안한다. 실용적 적용을 위하여 제한된 계측자료를 활용하고, 구조적으로 중요하며 손상이 발생될 확률이 큰 것으로 판단되는 중요부재를 대상으로 손상을 추정한다. 즉, 재킷식 지지구조물은 부재 개수가 많기 때문에, 모든 부재를 적절히 식별하기 위해서는 이에 상당하는 많은 수의 계측 데이터 채널 및 센서를 설치해야 한다. 이는 건전성 모니터링의 경제적 및 실용적인 측면에서 적절치 않다고 판단되며, 본 연구에서는 중요 구조부재에 대하여 제한된 계측자료를 활용하여 집중적으로 손상추정을 수행하기 위한 연구를 수행한다. 5 MW 해상풍력터빈에 적용될 수 있는 재킷식 해상풍력터빈 지지구조물을 모델링한 후, 수치 시뮬레이션을 수행하여 신경망의 훈련패턴을 생성한다. 이후, 군집신경망기법을 이용하여 중요부재에 대한 손상위치 및 손상정도를 20가지 손상경우에 대하여 추정한 결과, 모든 손상 경우에 대하여 성공적으로 손상을 판정할 수 있었으며, 군집신경망기법을 적용함으로써 추정결과의 정확성이 향상됨을 알 수 있었다. 또한 실험연구를 통하여 기법을 검증하였는데, 3가지 손상경우에 대하여 손상을 추정한 결과 합리적으로 손상을 추정할 수 있었다.

Abstract A damage estimation method is presented for jacket-type support structure of offshore wind turbine using a change of modal properties due to damage and committee of neural networks for effective structural health monitoring. For more practical monitoring, it is necessary to monitor the critical and prospective damaged members with a limited number of measurement locations. That is, many data channels and sensors are needed to identify all the members appropriately because the jacket-type support structure has many members. This is inappropriate considering economical and practical health monitoring. Therefore, intensive damage estimation for the critical members using a limited number of the measurement locations is carried out in this study. An analytical model for a jacket-type support structure which can be applied for a 5 MW offshore wind turbine is established, and a training pattern is generated using the numerical simulations. Twenty damage cases are estimated using the proposed method. The identified damage locations and severities agree reasonably well with the exact values and the accuracy of the estimation can be improved by applying the committee of neural networks. A verification experiment is carried out, and the damage arising in 3 damage cases is reasonably identified.

Keywords : Committee of neural networks, Critical members, Damage estimation, Jacket-type support structure, Modal property

이 논문은 2017년 대한민국 미래창조과학부와 한국연구재단의 중견연구자지원사업의 지원을 받아 수행된 연구임 (NRF-2017R1A2B4006722).

*Corresponding Author : Jong-Won Lee(Namseoul Univ.)

Tel: +82-41-580-2761 email: jwlee@nsu.ac.kr

Received May 30, 2017

Revised June 26, 2017

Accepted August 17, 2017

Published August 31, 2017

1. 서 론

최근 협소한 국토 및 민원문제 등으로 인한 육상풍력 발전의 한계점들을 극복하고 해상의 고품질 풍력자원을 이용하기 위하여 해상풍력발전에 대한 개발이 더욱 요구되고 있다. 해상풍력터빈 지지구조물은 나셀과 블레이드를 포함한 발전기 구조물을 지지하는 역할을 하는 중요한 구조물이며, 지지구조물의 손상 및 붕괴는 풍력발전기 운용을 중단시켜 막대한 비용손실을 초래하고 안전상의 문제도 야기할 수 있다. 해상풍력터빈의 지지구조물은 바람, 파도, 조류, 해저지질조건 등 다양한 해상환경 조건에 노출되기 때문에 이러한 요인들을 모두 고려한 설계기술 및 유지관리기술 개발이 필요하다. 특히, 해양 구조물의 접근성 제약, 열악한 환경, 고비용 보수 등의 요인으로 인해 구조물 건전성 모니터링 시스템 구축을 통한 효과적인 유지관리가 더욱 요구된다. 즉, 해상풍력터빈 지지구조물의 구조적 안전성 확보 및 지속적 운전을 위한 효과적인 유지관리를 위해서는 구조물의 현 상태를 항상 모니터링하고 장기간에 걸쳐 누적되는 구조물의 노후화 정도 및 손상을 항상 감시할 필요가 있다.

해상풍력터빈의 지지구조물은 크게 고정식과 부유식으로 분류할 수 있으며, 고정식 중 하나인 재킷식 (jacket-type) 지지구조물은 시공 시 효율성, 안전성 및 경제성을 고려하여 널리 활용되고 있다. 본 연구에서는 재킷식 해상풍력터빈 지지구조물의 효과적인 구조물 건전성 모니터링을 위한 손상추정기법을 개발하고자 한다. 재킷식 해양구조물의 손상추정기법에 대한 연구동향은 다음과 같다.

제한되고 공간적으로 불완전한 모드특성 측정치를 이용하여 개별 부재 손상을 추정하기 위하여 cross-model cross-mode 기법이 개발되었고[1], 운용 중 계측된 응답으로부터 random decrement 신호를 구한 후 이를 신경망의 입력으로 이용하여 손상을 추정할 수 있는 연구가 수행되었다[2]. 모드변형에너지 산정 시 강성보정계수를 도입하여 재킷식 해상풍력터빈 지지구조물의 손상위치를 식별할 수 있는 연구가 진행되었고[3], 구조물의 고유주파수와 모드형상을 이용하여 유전자 알고리즘으로 유한요소모델을 개선함으로써 손상을 추정할 수 있는 연구가 수행되었다[4]. 또한, 소수의 모드형상 계측 데이터를 이용하여 재킷식 구조물에 존재하는 손상의 위치와 크기를 추정할 수 있는 알고리즘이 연구되었고[5], 광섬유 브

래그 격자 센서를 이용하고 계측된 데이터로부터 여러 환경요인을 제거하여 보다 손상에 민감한 특성을 파악하기 위한 주성분 분석기법을 적용하여 구조물의 손상을 탐지할 수 있는 기법을 개발하였다 [6].

본 연구에서는 제한된 계측자료를 활용하여 재킷식 해상풍력터빈 지지구조물의 손상위치와 손상정도를 효과적으로 추정하기 위하여, 중요부재를 대상으로 군집신경망기법[7]을 적용한다. 재킷식 지지구조물은 부재 개수가 많기 때문에 부재 1개의 손상이 전체 구조물의 모드특성 변화에 미치는 영향이 적을 것으로 판단된다. 또한 전체 부재를 대상으로 하는 부재단위의 손상추정방법을 적용할 수 있으나, 손상추정의 관점에서는 추정하고자 하는 미지수가 많아지게 된다. 따라서 모든 부재를 적절히 식별하기 위해서는 이에 상당하는 계측 데이터 채널 및 센서를 설치해야 한다. 이는 경제적 및 실용적인 측면에서 적절치 않다고 판단되며, 본 연구에서는 재킷식 구조물에서 구조적으로 중요하고 손상이 예상되는 부재를 대상으로, 제한된 계측자료를 활용하여 집중적으로 손상추정을 수행하기 위한 연구를 수행한다. 한편, 기술의 실적용을 위하여 지반으로 관입되는 기초부에 대한 모델링을 포함하여 손상추정을 수행한다. 이를 위하여, 프로토타입 재킷식 해상풍력터빈 지지구조물을 모델링한 후, 손상에 의한 구조물의 모드특성 변화와 군집신경망기법을 이용하여 손상위치 및 손상정도를 추정하고, 실험연구를 통하여 제안된 방법을 검증한다.

2. 군집신경망기법

최근 구조물에 대한 시스템인식 및 손상추정 문제에 신경망기법을 적용하기 위하여 많은 연구가 수행되어 왔다. 신경망기법 기반 시스템인식 및 손상추정의 과정은 패턴인식의 문제로 정의될 수 있으며, 신경망기법은 이러한 패턴인식의 문제에 매우 효과적인 기법이다. 그러나 신경망기법 적용 시 국소 최저치 문제, 노이즈 및 제한된 계측자료 등으로 인한 신경망기법의 비유일성 문제 등이 존재한다. 이를 해결하기 위한 방법 중 하나로, 통계적 접근 방법인 군집신경망(committee of neural networks)을 적용할 수 있는데, 이 방법에서는 신경망의 출력을 함수 공간에서 평균하여 처리한다.

군집신경망기법에서는 Fig. 1과 같이 여러 개의 개별

신경망을 독립적으로 훈련시키며 이때 각 개별 신경망들의 초기 연결강도, 구조 및 훈련패턴 등을 동일하게 또는 달리 적용할 수 있다. Fig. 1에서 \mathbf{x}_i 는 i 번째 신경망의 입력벡터이고 \mathbf{y}_i 는 i 번째 신경망에 대한 변환함수 (mapping function) $f_i(\mathbf{x}_i)$ 에 의해 계산되는 출력벡터이다. 군집변환함수는 다음 식으로 나타낼 수 있다.

$$f_{COM}(\mathbf{X}) = \sum_{i=1}^N \alpha_i f_i \quad (1)$$

여기서 $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)$ 이고 N 은 개별 신경망의 총 개수이며, α_i 는 i 번째 신경망에 대한 가중치이며 $\sum_{i=1}^N \alpha_i = 1$ 이다. 따라서 군집출력(committee output)은 다음 식으로 계산될 수 있다.

$$\mathbf{y}_{COM} = \sum_{i=1}^N \alpha_i \mathbf{y}_i \quad (2)$$

위 식을 이용하여 개별 신경망들의 출력을 단순 평균할 수 있고, 가중치를 설정하여 평균할 수도 있다.

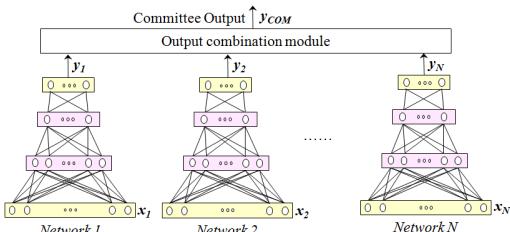


Fig. 1. Illustration of committee of neural networks

3. 재킷식 지지구조물 모델링

본 연구에서 대상으로 하는 프로토타입 재킷식 지지구조물의 전체적인 형상을 Fig. 2에 보였는데, 5 MW 풍력터빈용으로서 해저면에서 평균해수면까지 16.8 m, 평균해수면에서 타워 최상단까지 100.2 m이고 기초부는 해저면에서 지반으로 56 m 관입되어 있다. 한편, 타워 상부(블레이드, 허브, 나셀)의 질량은 359,528 kg이고 지지구조물(해저면 상부)의 질량은 749,002 kg이다.



Fig. 2. Layout of jacket-type support structure

본 연구에서는 효율적인 손상추정을 위하여, 3차원의 재킷식 구조물을 2차원 구조로 유한요소 모델링 하였다. 즉, 2차원 유한요소해석용 in-house 프로그램을 사용하여 손상추정을 위한 모드해석을 수행하였다. 향후, 보다 정밀한 손상추정을 위해서는 3차원 모델링을 통한 손상추정기법 연구가 요구된다. 그러나 바람 주방향에 대한 2차원 구조를 대상으로 하는 손상추정기법 또한 집중적인 구조물 견전성 모니터링에 유용할 것으로 판단된다. 한편, 유한요소 모델링 시 구조부재의 2차원 등가 단면 특성을 설정하였으며, 타워 상부 구조물은 집중질량으로 처리하였다.

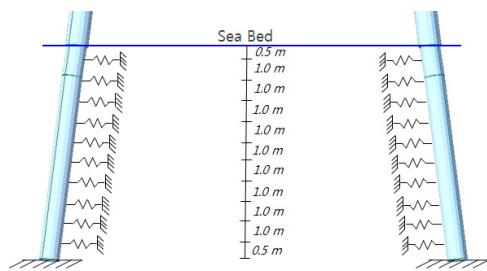


Fig. 3. Distributed spring model

한편, 해양구조물에서는 해저면에서 지반으로 관입되는 기초부에 대한 적절한 모델링이 요구된다. 대부분의 해상풍력터빈 해석 프로그램들에서는 지반 p-y 모델의 비선형성 및 깊이에 따른 특성변화를 고려한 지반-파일 상호작용을 구체적으로 반영하지 못하고 있고, 동적해석에 적합한 단순화된 선형 모델을 적용하고 있으며, 다음 3가지의 선형 모델이 제안되고 있다[8]. 첫째, 기초부 파일의 특성과 길이를 변경하여 전체 파일을 캔틸레버 보로 이상화하는 유효고정길이 모델(effective fixity length

model) 둘째, 기초부를 횡방향 및 회전 자유도를 동시에 가지는 스프링으로 모델링하는 연성 스프링 모델 (coupled spring model) 셋째, 기초부 파일을 지반 깊이 방향으로 분포되는 횡방향 스프링을 가지는 보로 이상화 하는 분포 스프링 모델(distributed spring model)이다. 위 세 가지 방법 중 분포 스프링 모델이 실제 파일의 형태를 가장 근사하게 모델링할 수 있으며, 가장 정확한 모드특성을 계산할 수 있는 것으로 보고되었다[9]. 본 연구에서는 Fig. 3과 같이 분포 스프링 모델을 적용하여 지지구조물의 모드특성을 구하였으며, 이때 p-y 모델은 실지반조사 결과를 이용하여 구한 값을 사용하였다. 즉, Fig. 3에 보인 바와 같이 십도 9.5 m까지의 p-y 모델을 기반으로, 지지구조물의 기초부에 1 m 간격으로 각각 10개씩의 단순 선형 스프링으로 지반을 모델링하여 지지구조물의 모드특성을 구하였다.

4. 수치해석에 의한 손상추정

재킷식 지지구조물은 해양 환경에 노출되어 있으므로 부식결함이 발생할 수 있고, 반복하중을 받으므로 피로에 의한 균열결함이 발생할 가능성이 있다. 부식은 결국 부재 단면적을 감소시키는 효과가 있으며 이로 인하여 부재의 강성이 저하된다. 피로균열도 균열발생 위치에서 부재의 강성저하를 야기하므로, 재킷식 지지구조물에서 발생할 수 있는 대표적인 결합형태인 부식과 균열손상은 손상전후 강성비율을 활용하여 추정할 수 있을 것으로 판단된다. 따라서 본 연구에서는 손상전후 강성의 비율을 나타낼 수 있도록 다음과 같이 강성지수(α_j) 및 손상정도(d_j)를 정의하였다.

$$\alpha_j = \frac{(EI)_j^d}{(EI)_j^o} \text{ and } d_j = 1 - \alpha_j \quad (3)$$

여기서 j 는 부재 위치, ‘o’와 ‘d’는 각각 전전상태와 손상상태를 의미한다. 또한 E 는 영계수이고 I 는 단면이차모멘트이다.

앞에서 언급되었듯이 본 연구에서는 재킷식 구조물에서 구조적으로 중요하고 손상이 예상되는 부재를 대상으로 집중적인 손상추정을 수행하기 위한 연구를 수행한다. 즉, Fig. 4에 나타낸 재킷식 구조물의 하부 기둥 6개

(Col. 1 ~ Col. 6)에 대하여 손상에 의한 모드특성 변화 및 군집신경망기법을 이용한 손상추정을 수행한다. 지지구조물의 횡방향 진동은 주로 바람하중 및 파랑하중에 의해 발생되고, 횡방향 하중을 받는 구조물에서 대부분의 파괴 또는 손상은 구조물 하부에 집중된다고 판단된다. 즉, 재킷식 지지구조물에서 하부 기둥들의 건전성은 다른 부재들보다 전체 구조물의 구조적 안전성 측면에서 중요하며, 손상이 발생될 확률이 큰 것으로 판단된다. 따라서 본 연구에서는 6개의 하부 기둥 휨강성을 신경망의 출력으로 이용하였다.

한편, 그림 Fig. 4에 보인 바와 같이 대상 하부 기둥의 중앙 및 절점 8 곳에서 가속도를 계측하는 것으로 가정하였다. 즉, 가속도 계측장비의 최소 계측 채널 단위가 8 챇널인 경우가 많으며, 경제적인 구조물 건전성 모니터링을 위하여 8채널의 제한된 계측자료를 취득하는 것으로 가정하였다. 또한, 효과적인 손상추정을 위하여 6개의 대상 기둥 및 2개의 절점에서 가속도를 계측하는 것으로 가정하였는데, 향후 최적 계측위치 설정기법 연구가 수반되면 더욱 효율적인 손상추정이 가능할 것으로 판단된다.

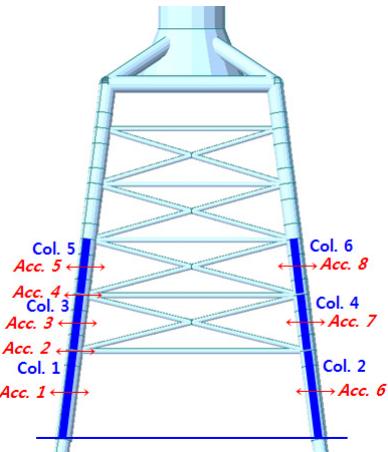


Fig. 4. Input and output to neural networks

군집신경망을 적용하여 손상을 추정하기 위하여, 대상 지지구조물에 대하여 손상위치 및 손상정도를 무작위로 샘플링한 후 이에 대한 지지구조물의 고유주파수와 모드형상을 각각 구하였다. 각각의 손상경우에 대하여 변화된 1차, 2차, 3차, 및 4차 고유주파수 및 모드형상을 구하였다. 즉, 각각의 훈련패턴은 4개의 손상전후 고유주파수, 32개의 모드형상 성분 및 이에 해당하는 손상위

치와 손상정도로 구성된다. 따라서 신경망 입력자료는 36개로써 1차, 2차, 3차 및 4차 고유주파수 및 모드형상이고, 출력층은 6개 하부 기둥의 강성지수로 구성하였다. 생성된 훈련패턴을 이용하여 신경망을 학습시켰으며 이때, 안정된 추정오차를 위하여 훈련패턴의 순서를 무작위로 하여 100회의 반복학습을 수행하였다.

군집신경망을 구성하기 위하여 위와 동일한 구조의 신경망을 20개 작성한 후, 동일한 훈련패턴으로 단일 신경망들을 독립적으로 학습시켰다. 이때 단일 신경망들의 초기 연결강도를 랜덤하게 설정하여 각각 다른 초기 연결강도를 가지고 학습시켰다.

Table 1. Damage cases

Damage Cases	Loss of bending rigidity (%)					
	Col. 1	Col. 2	Col. 3	Col. 4	Col. 5	Col. 6
1	3	0	0	0	0	0
2	0	5	0	0	0	0
3	0	10	0	0	0	0
4	5	0	5	0	0	0
5	10	0	5	0	0	0
6	10	0	10	0	0	0
7	5	5	0	0	0	5
8	5	0	0	5	0	0
9	5	0	0	0	0	5
10	10	0	0	10	0	0
11	10	0	0	0	0	10
12	15	0	20	0	0	0
13	15	0	0	10	10	0
14	0	0	15	10	10	0
15	5	5	5	5	0	0
16	5	5	5	0	0	5
17	15	10	15	10	0	0
18	15	10	15	0	0	10
19	0	10	15	15	10	0
20	20	15	0	0	15	20

Table 2. Results of damage estimation

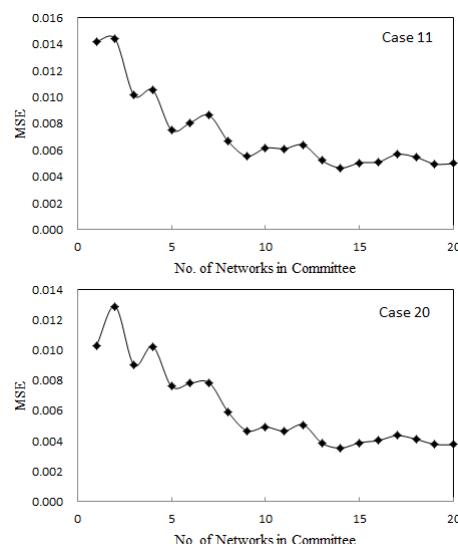
Damage Cases	Loss of bending rigidity (%)					
	Col. 1	Col. 2	Col. 3	Col. 4	Col. 5	Col. 6
1	3.1	-0.2	0.3	-0.3	-0.2	0.0
2	0.3	4.8	0.1	0.0	-0.1	0.2
3	0.2	9.8	0.3	-0.2	-0.2	0.0
4	5.2	0.0	5.2	0.1	0.2	0.0
5	10.1	0.0	5.1	0.1	-0.2	-0.1
6	10.2	0.0	10.2	-0.3	0.3	0.3
7	5.2	5.0	0.0	-0.3	-0.1	5.0
8	5.1	0.0	0.2	4.8	0.0	0.3
9	5.1	0.0	0.0	-0.2	-0.3	4.9
10	10.1	0.0	0.1	9.8	-0.2	0.1
11	10.1	0.0	0.2	0.1	0.0	10.1
12	15.2	-0.1	20.2	-0.2	0.5	0.5
13	15.0	-0.2	0.3	9.6	10.0	0.1
14	0.4	0.0	15.1	9.8	10.2	0.5
15	5.0	5.0	5.1	4.9	0.0	0.2

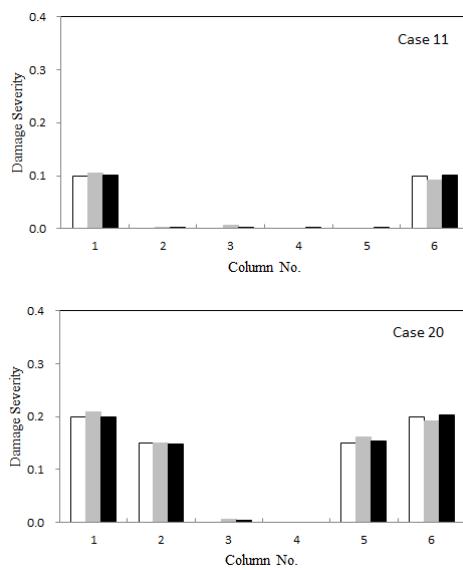
16	5.1	5.0	4.9	0.2	-0.1	4.9
17	15.1	9.9	15.1	9.6	0.0	0.1
18	15.0	10.0	15.1	0.1	0.4	10.2
19	0.3	9.9	15.0	14.8	10.1	0.2
20	20.0	14.9	0.3	-0.4	15.4	20.3

20개의 단일 신경망에 대한 학습이 종료된 후, Table 1에서 보인 20가지 손상 경우에 대한 고유주파수 및 모드형상을 단일 신경망들에 입력하여 손상위치 및 손상정도를 각각 추정하였다. 이때 손상정도는 식 (3)에서 정의되었으며, 단일 신경망들에 의하여 계산된 결과와 식 (2)를 이용하여 군집출력을 계산하였는데, 단순 평균 방법을 적용하여 추정치를 구하였다.

손상추정결과를 Table 2에 나타내었는데, 모든 손상경우에 대하여 손상위치와 손상정도를 합리적으로 추정할 수 있었다. 가속도 측정위치가 좌측(Fig. 4의 Col. 1, 3, 5)에 다소 편중되었으나, 우측 기둥들(Fig. 4의 Col. 2, 4, 6)의 손상도 성공적으로 추정하였으며, 복수 부재 손상의 경우도 손상추정결과가 정확해와 잘 일치함으로 알 수 있다.

한편, Fig. 5와 6에서는 손상 경우 11과 20에 대한 군집신경망 적용 결과를 대표적으로 나타내었다. Fig. 5에는 군집신경망을 위하여 적용된 단일 신경망의 개수에 따른 평균 제곱 오차(mean square error: MSE)의 변화를 나타내었는데, 단일 신경망의 개수가 증가하면서 오차가 감소함을 알 수 있다.

**Fig. 5.** Change of MSE

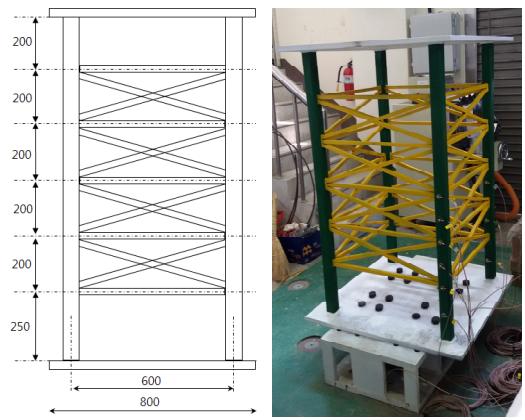
**Fig. 6.** Results of damage estimation

□ : Exact; ■ : Estimated (1st network);
■ : Estimated (committee).

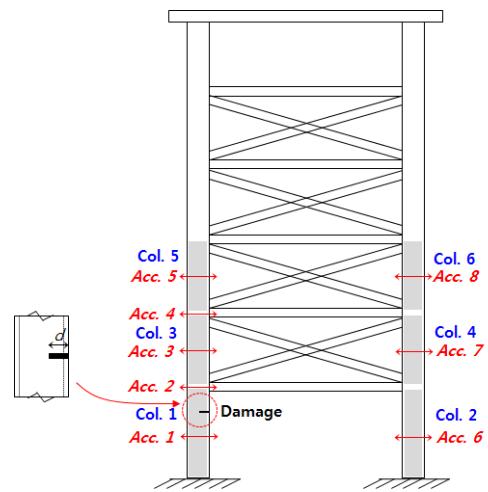
한편 Fig. 6의 x축은 Fig. 4에 나타낸 Col. 번호이고 y축은 식 (3)에서 설명된 손상정도이다. 하얀색 막대는 Table 1에서 설정한 손상정도이고 회색 막대는 첫 번째 단일 신경망을 적용하여 추정한 손상정도이며, 검정색 막대는 Table 2에 보인, 20개의 단일 신경망들로 구성된 군집신경망을 적용하여 추정한 손상정도이다. 첫 번째 단일 신경망의 결과도 비교적 정확하게 추정되었으나 군집신경망기법을 적용함으로써 손상위치 및 손상정도의 추정결과가 향상됨을 알 수 있었고, 이러한 경향은 모든 손상경우에 대하여 동일한 것으로 확인되었다. 20개의 단일 신경망들이 동일한 구조와 훈련패턴으로 학습되었지만 서로 다른 초기 연결강도를 가지고 훈련되었기 때문에, 신경망의 초기 연결강도에 민감한 국소 최저치 문제가 완화되어 결과가 향상된 것으로 판단된다.

5. 실험연구

개발된 알고리즘을 검증하기 위한 손상실험을 수행하기 위하여 재킷식 실험체를 Fig. 7과 같이 제작하였다. 수평재 및 사재의 접합 편의성을 위하여 기둥을 각형 강관으로 제작하였으며, 수평재 및 사재는 기둥에 용접으로 접합하였다.

**Fig. 7.** Jacket-type specimen (lengths in mm)

앞에서 언급되었듯이, 재킷식 실험체에서 구조적으로 중요하고 손상이 예상되는, Fig. 8에 보인 하부 기둥 6개에 대하여 모드특성 변화를 이용한 손상추정을 수행하였다. 즉, 6개의 하부 기둥 휨강성을 신경망의 출력으로 이용하였다. 한편, Fig. 8에 보인 바와 같이 대상 하부 기둥의 중앙 및 절점 8 곳에서 가속도계를 부착한 후 인위적으로 손상을 발생시키며 자유진동실험을 수행하였다. 즉, 손상추정 대상 기둥 및 계측위치는 4장의 경우와 동일하게 설정하였다.

**Fig. 8.** Input and output to neural networks (experiment)

Col. 1의 고정단에서 약 188 mm인 지점에 Fig. 8에 보인 손상정도(d)를 단계적으로 크게 발생시키면서 실험을 수행하였다. 이때, 2차원 손상추정을 위하여 반대 측 기둥에도 동일위치에 동일손상을 발생시켰다. 손상정도

를 15, 20, 25 mm가 되도록 순차적으로 손상을 크게 발생시켰으며, 각 손상 단계별로 10회의 자유진동실험을 수행하여 결과를 평균하였다. 인위적으로 발생시킨 손상의 형상은 Fig. 9에 나타내었으며, 단계별 손상경우를 Table 3에 정리하였다.



Fig. 9. Inflicted damage (Case 2)

Table 3. Damage cases (experiment)

Damage Cases	Damage location, Col. no	Damage severity, d (mm)
1	1	15
2	1	20
3	1	25

대상 실험체에 대하여 유한요소법을 이용한 해석 모델을 수립하여, 손상위치 및 손상정도를 무작위로 샘플링한 후 이에 대한 실험체의 고유주파수와 모드형상을 각각 구하였다. 즉, 각각의 손상경우에 대하여 변화된 1차, 2차 및 3차 고유주파수 및 모드형상을 구하였는데, 각각의 훈련패턴은 3개의 손상전후 고유주파수, Fig. 8에 보인 8개 측정위치에서의 3차까지 모드형상 성분 24개 및 이에 해당하는 손상위치와 손상정도로 구성된다. 따라서 신경망 입력자료는 27개로써 1차, 2차 및 3차 고유주파수 및 모드형상이고, 출력층은 6개 하부 기둥의 강성지수로 구성하였다. 생성된 훈련패턴을 이용하여 신경망을 학습시켰으며 이때, 안정된 추정오차를 위하여 훈련패턴의 순서를 무작위로 하여 100회의 반복학습을 수행하였다. 한편 계측 데이터에 포함된 노이즈의 영향을 감소하기 위하여 노이즈 첨가학습(noise injection learning)을 적용할 수 있다. 즉, 훈련패턴에 인위적으로

일정 정도의 노이즈를 첨가시킨 후 학습을 수행함으로써, 신경망의 일반화 성능을 향상시켜 추정결과의 정확성을 개선시킬 수 있다. 노이즈 첨가학습을 위하여 신경망의 훈련패턴에 5% RMS 수준의 노이즈를 첨가하여 신경망을 훈련시켰다. 학습이 종료된 후 Table 3에 보인 3가지 손상경우에 대하여, 실험을 통하여 추정된 고유주파수 및 모드형상을 신경망에 입력하여 손상위치 및 크기를 각각 추정하였다.

이후, 4장에서 설명된 바와 동일한 과정으로 군집신경망기법을 적용하여 손상을 추정한 결과를 Fig. 10에 나타내었는데, 3가지 손상경우에 대하여 손상을 가한 Col. 1에서 손상이 추정됨을 알 수 있다. 한편, 인위적으로 가한 손상형태에 의한 기둥의 휨강성 감소정도를 정량적으로 결정하기 어려워 손상정도 추정치를 정확해와 비교하지는 못하였지만, 실제 손상정도가 커질수록 손상정도 추정치도 증가하는 추세임을 알 수 있다.

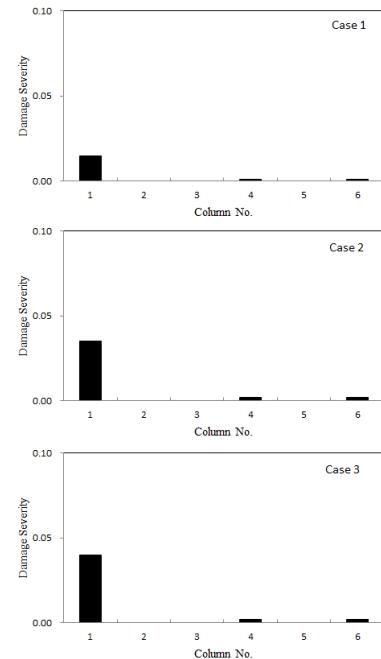


Fig. 10. Results of damage estimation (experiment)

6. 결 론

본 연구에서는 재킷식 해상풍력터빈 지지구조물에 대한 손상추정기법을 제안하였다. 제한된 계측자료를 활용

하기 위하여 중요부재를 대상으로 하였으며, 손상에 의한 지지구조물의 고유진동수 및 모드형상의 변화를 이용하였고, 손상위치 및 손상정도를 판정하기 위하여 군집신경망기법을 사용하였다.

프로토타입 재킷식 해상풍력터빈 지지구조물을 기반으로 관입되는 기초부를 포함하여 모델링한 후, 제한된 계측자료를 이용하여 중요부재에 대한 손상위치 및 손상정도를 추정하였다. 20가지 손상경우에 대하여 손상위치 및 손상정도를 추정한 결과, 모든 손상 경우에 대하여 성공적으로 손상위치와 손상정도를 판정할 수 있었으며, 군집신경망기법을 적용함으로써 추정결과의 정확성이 향상됨을 알 수 있었다. 또한 실험연구를 통하여 기법을 검증한 결과, 합리적으로 손상위치와 손상정도를 추정할 수 있었다.

중요부재 선정 및 이에 대한 최적 계측위치 선정 결과에 따라 제안된 기법의 정확성 및 적용성이 달라질 수 있으므로 이에 대한 추가연구가 필요한 것으로 판단되며 또한, 3차원 손상추정기법을 개발한 후 본 연구에서 제안된 기법을 적용하면, 재킷식 해상풍력터빈 지지구조물의 보다 효과적인 건전성 모니터링에 활용이 가능할 것으로 사료된다.

References

- [1] H. Li, J. Wang, S. J. Hu, "Using Incomplete Modal Data for Damage Detection in Offshore Jacket Structures", *Ocean Engineering*, vol. 35, pp. 1793-1799, 2008.
DOI: <https://doi.org/10.1016/j.oceaneng.2008.08.020>
- [2] A. A. Elshafey, M.R. Haddara, and H. Marzouk, "Damage Detection in Offshore Structures Using Neural Networks", *Marine Structures*, vol. 23, pp. 131-145, 2010.
DOI: <https://doi.org/10.1016/j.marstruc.2010.01.005>
- [3] F. Liu, H. Li, W. Li, and B. Wang, "Experimental Study Of Improved Modal Strain Energy Method for Damage Localisation in Jacket-Type Offshore Wind Turbines", *Renewable Energy*, vol. 72, pp. 174-181, 2014.
DOI: <https://doi.org/10.1016/j.renene.2014.07.007>
- [4] H. Malekzehtab, A. A. Golafshani, "Damage Detection in an Offshore Jacket Platform Using Genetic Algorithm Based Finite Element Model Updating with Noisy Modal Data", *Procedia Engineering*, vol. 54, pp. 480-490, 2013.
DOI: <https://doi.org/10.1016/j.proeng.2013.03.044>
- [5] J. T. Kim, N. Stubbs, "Damage Detection on Jacket-type Offshore Structures from Few Mode Shapes", *Transactions of the Korean Society of Ocean Engineers*, vol. 8, pp. 144-153, 1994.
- [6] H. J. Park, K. Y. Koo, J. H. Yi, C. B. Yun, "Development of a Damage Monitoring Technique for Jacket-type Offshore Structures Using Fiber Bragg Grating Sensors", *Transactions of the Korean Society of Civil Engineers*, vol. 31, pp. 399-408, 2011.
- [7] M. P. Perrone, "General Averaging Results for Convex Optimization", *Proceedings of Connectionist Models Summer School*, Hillsdale, pp. 364-371, 1993.
- [8] J. Jonkman, S. Butterfield, P. Passon, T. Larsen, T. Camp, J. Nichols, J. Azcona, and A. Martinez, *Offshore Code Comparison Collaboration within IEA Wind Annex XXIII: Phase II Results Regarding Monopile Foundation Modeling*, NREL/CP-500-42471, National Renewable Energy Laboratory, 2008.
- [9] G. Bir, J. Jonkman, *Modal Dynamics of Large Wind Turbines with Different Support Structures*, NREL/CP-500-43045, National Renewable Energy Laboratory, 2008.

이 종 원(Jong-Won Lee)

[정회원]



- 1991년 2월 : 연세대학교 대학원 건축공학과 (공학석사)
- 2003년 2월 : KAIST 대학원 건설및환경공학과 (공학박사)
- 1991년 3월 ~ 2008년 8월 : 한국 기계연구원 책임연구원
- 2008년 9월 ~ 현재 : 남서울대학교 건축공학과 교수

<관심분야>

구조물 건전성 모니터링, 손상추정, 스마트센서 기술