

군집 신경망기법을 이용한 해상풍력발전기 지지구조물의 건전성 모니터링 기법

Health Monitoring Method for Monopile Support Structure of Offshore Wind Turbine Using Committee of Neural Networks

이 종 원†·김 상 렬*·김 봉 기*·이 준 신**

Jong Won Lee, Sang Ryul Kim, Bong Ki Kim and Jun Shin Lee

(Received January 21, 2013 ; Revised March 18, 2013 ; Accepted March 18, 2013)

Key Words : Damage Estimation(손상추정), Support Structure(지지구조물), Offshore Wind Turbine(해상풍력발전기), Committee of Neural Networks(군집 신경망), Structural Health Monitoring(구조물 건전성 모니터링)

ABSTRACT

A damage estimation method for monopile support structure of offshore wind turbine using modal properties and committee of neural networks is presented for effective structural health monitoring. An analytical model for a monopile support structure is established, and the natural frequencies, mode shapes, and mode shape slopes for the support structure are calculated considering soil condition and added mass. The input to the neural networks consists of the modal properties and the output is composed of the stiffness indices of the support structure. Multiple neural networks are constructed and each individual network is trained independently with different initial synaptic weights. Then, the estimated stiffness indices from different neural networks are averaged. Ten damage cases are estimated using the proposed method, and the identified damage locations and severities agree reasonably well with the exact values. The accuracy of the estimation can be improved by applying the committee of neural networks which is a statistical approach averaging the damage indices in the functional space.

1. 서 론

협소한 국토 및 민원문제 등으로 인한 육상풍력 발전의 한계점들을 극복하고 해상 고품질 풍력자원을 이용하기 위하여 해상풍력발전기에 대한 개발이 활발히 진행되고 있다. 한편, 건설비용 절감을 위한 구조물 및 기계요소들의 대형화 및 접근성 제약

으로 인하여 효과적 유지관리 및 신뢰성 확보를 위한 기술개발의 필요성이 대두되고 있다. 이에 따라 상태 모니터링 시스템(condition monitoring system) 적용을 통한 효과적인 유지관리기술 개발의 중요성이 증가하고 있다.

육상풍력발전기와는 달리 해상풍력발전기의 경우 지지구조물의 제작 및 시공비용이 상당부분 차지하며, 이의 유지관리 및 건전성 모니터링에 대한 관심

† Corresponding Author ; Member, Namseoul University
E-mail : jwlee@nsu.ac.kr
Tel : +82-41-580-2761, Fax : +82-41-580-2929

* Member, Korea Institute of Machinery and Materials

** Member, Korea Electric Power Research Institute

‡ Recommended by Editor Hyung-Jo Jung

© The Korean Society for Noise and Vibration Engineering

이 고조되고 있다. 해상풍력발전기의 지지구조물은 타워, 하부구조물 및 기초로 구분할 수 있는데, 이는 나셀과 블레이드를 포함한 발전기 구조물을 지지하는 역할을 하는 중요한 구조물이며, 지지구조물의 손상 및 붕괴는 풍력발전기 운용을 중단시켜 막대한 비용손실을 초래하고 안전상의 문제도 야기한다. 또한 지지구조물은 다양한 해상환경조건에 노출되기 때문에 이를 고려한 설계기술 및 유지관리기술 개발이 필수적이다. 지지구조물의 효과적 유지관리를 위해서는 구조물에 대한 건전성 모니터링(structural health monitoring) 기술의 개발 및 적용이 필요하다. 즉, 해상풍력발전기 지지구조물의 구조적 안전성 확보 및 지속적 운전을 위한 효과적인 유지관리를 위해서는 구조물의 현 상태를 항상 모니터링하고 장기간에 걸쳐 누적되는 구조물의 노후화 정도 감시하며, 손상이 발생하는 경우 이를 추정할 수 있는 기법을 적용할 필요가 있다.

최근 구조물에 대한 시스템인식 및 손상추정 문제에 신경망기법(neural networks technique)을 적용하기 위하여 많은 연구가 수행되어 왔다. 신경망기법 기반 시스템인식 및 손상추정의 과정은 패턴인식의 문제로 정의될 수 있으며, 신경망기법은 이러한 패턴인식의 문제에 매우 효과적인 기법이다. 또한 신경망기법은 다양한 종류의 입력 및 출력자료를 다룰 수 있으며, 훈련이 완료된 신경망을 이용하여 운용 중의 구조물에 대한 손상추정을 수행하므로 신속한 평가가 가능하다. 그러나 신경망기법 적용 시 국소 최저치(local minima) 문제, 노이즈 및 제한된 계측자료 등으로 인한 비유일성(non-uniqueness) 문제 등이 존재한다. 이를 해결하기 위한 방법 중 하나로, 통계적 접근 방법인 군집 신경망(committee of neural networks) 기법을 적용할 수 있는데, 이 방법에서는 신경망들의 출력을 함수 공간에서 평균하여 처리한다.

군집 신경망기법은 페론⁽¹⁾ 및 페론과 쿠퍼⁽²⁾에 의하여 소개된 이후로 음성 및 시각 분야의 패턴 인식에 널리 활용되어 왔다. 군집 신경망에 포함되어 있는 단일 신경망들의 오차들 간 상관관계가 없을 때, 군집 신경망은 단일 신경망들 중 가장 우수한 신경망 보다 정확한 결과를 출력한다⁽²⁾. 진동 데이터를 이용한 구조물 결함판정에 군집 신경망 적용의 가능성이 제안되었으며^(2,3), 주파수 응답함수와 모달 데

이터를 각각 단일 신경망의 입력자료로 사용한 후 군집 신경망을 구성하여 구조물의 결함을 탐지하는 연구가 수행되었다^(4,5). 국소 최저치 문제는 신경망의 초기 연결강도(initial synaptic weight)에 민감하며, 일반적인 군집 신경망 구성의 방법은 단일 신경망을 초기 연결강도를 달리 하고 동일한 훈련패턴(training pattern)을 이용하여 독립적으로 훈련시키는 것이다. 즉, 군집 신경망에 포함되어 있는 단일 신경망들의 훈련이 종료되면 이들의 연결강도는 서로 다르게 된다. 이러한 형태의 군집 신경망을 이용하여, 회귀분석 및 분류태스크 분야에서 단일 신경망의 성능을 개선한 연구가 보고 되었다^(6,7). 이와 관련하여, 단일 신경망들의 구조와 훈련패턴을 동일하게 혹은 달리 구성하는 4가지 군집 신경망 방법을 이용하여 빌딩 구조와 모형교량의 손상을 추정한 결과, 군집 신경망 적용에 의하여 추정결과가 개선되었으며, 개선효과는 주로 초기 연결강도에 민감한 신경망의 국소 최저치 문제 완화에 기인한 것으로 보고되었다⁽⁸⁾. 한편, 군집 신경망기법은 구조물 손상 추정 문제를 포함하여 다양한 분야에 적용되어지고 있다. 즉, 신속한 도로 이동시간 예측을 위하여 확률 신경망의 군집 신경망을 적용하여 예측 결과를 개선하였으며⁽⁹⁾, 정확한 전력 부하 예측을 위하여 과거의 전력 부하 및 온도 데이터를 이용하여 훈련시킨 군집 신경망을 적용한 연구가 수행되었고⁽¹⁰⁾, 부직포의 시각적 특성 인식을 일반적인 패턴인식의 문제로 고려하여 웨이블릿 에너지 신호와 군집 신경망을 함께 사용하여 특성을 평가하였다⁽¹¹⁾.

이 연구에서는 해상풍력발전기 지지구조물의 효과적인 건전성 모니터링을 위하여, 모노파일 형식 지지구조물을 대상으로 모드특성 및 군집 신경망기법을 이용한 손상추정기법을 제안한다. 이를 위하여 해저지질조건과 부가수질량을 고려하여 모노파일 형식 지지구조물의 고유주파수, 모드형상 및 모드형상 곡률을 해석적으로 추정한다. 선행 연구⁽¹²⁾에서는 동일한 모노파일 형식 지지구조물에 대하여 9 계측점에서 계산되는 고유주파수 및 모드형상을 이용하고, 단일 신경망을 적용하여 손상을 추정하였다. 이 연구는 위 선행 연구의 후속 연구로서, 계측점을 축소하기 위하여 5 계측점을 적용하고 모드형상 곡률을 추가로 이용하였으며, 손상추정 결과의 정확성을 개선하기 위하여 군집 신경망을 적용하였다. 건전성

모니터링을 위한 계측 데이터 채널 및 센서 개수의 축소는 비용절감의 측면에서 실용적인 방법으로 판단된다.

2. 군집 신경망 기법

다중 퍼셉트론 신경망(multi-layer perception neural networks)은 다수의 입력과 출력의 관계를 표현하는 일종의 선형 또는 비선형함수로 볼 수 있으며, 이 때 입출력 관계는 인접한 두 층에 존재하는 뉴런(neuron)간의 관계를 설정하는 연결강도(synaptic weight)에 의해 결정된다. 따라서, 연결강도가 변화하면 입출력 관계도 함께 변화한다. 이러한 연결강도를 주어진 패턴으로 훈련시켜 개선시키는 과정을 학습(training or learning algorithm)이라 하며, 보편적으로 역전파(back-propagation) 학습방법이 적용된다.

군집 신경망기법에서는 Fig. 1과 같이 여러 개의 단일 신경망들을 독립적으로 훈련시키며 이때 각 단일 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.

군집 변환함수(committee mapping function)는 다음 식으로 나타낼 수 있다.

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

여기서 $\mathbf{X}=(\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)$ 이고 N 은 단일 신경망의 총 개수이며, α_i 는 i 번째 신경망에 대한 가중치이고

$\sum_{i=1}^N \alpha_i = 1$ 이다. 따라서 군집 출력(committee output)은 다음 식으로 계산될 수 있다.

$$y_{COM} = \sum_{i=1}^N \alpha_i y_i \tag{2}$$

식 (2)를 이용하여 단일 신경망들의 출력을 단순 평균할 수 있고, 가중치를 설정하여 평균할 수도 있다. 신경망의 초기 연결강도에 민감한 국소 최저치 문제, 노이즈 및 제한된 계측자료 등으로 인한 비유일성 문제 등을, 단일 신경망들의 출력을 함수 공간에서 평균하여 처리하는 군집 신경망기법을 적용하여 일정 정도 해결할 수 있을 것으로 판단된다. 즉, 다중 퍼셉트론 신경망에서 다수의 입력과 출력의 관계에 대한 매개변수는 연결강도로 구성되고, 이 연결강도는 일반적으로 많은 국소 최저치를 내포하며 이는 초기 연결강도에 민감하다. 이러한 국소 최저치 문제를 해결하기 위해서는 많은 수의 표본 신경망을 적용하여 이 중 가장 우수한 성능의 신경망을 이용해야하지만 이는 매우 비효율적이라고 판단된다. 이러한 비효율성을 해결하기 위하여 매개변수 공간이 아닌 함수 공간에서 평균 처리하는 군집 신경망기법이 효과적이라고 판단된다. 군집 신경망을 구성하는 방법은 여러 가지가 있으나, 선행연구⁽⁸⁾에서 단일 신경망들의 구조와 훈련패턴을 동일하게 혹은 달리 구성하는 4가지 군집 신경망 방법을 이용하여 구조물 손상을 추정한 결과, 개선효과는 주로 초기 연결강도에 민감한 신경망의 국소 최저치 문제 완화에 기인한 것으로 보고되었다. 따라서 이 연구에서는 동일한 훈련패턴으로 단일 신경망들을 독립

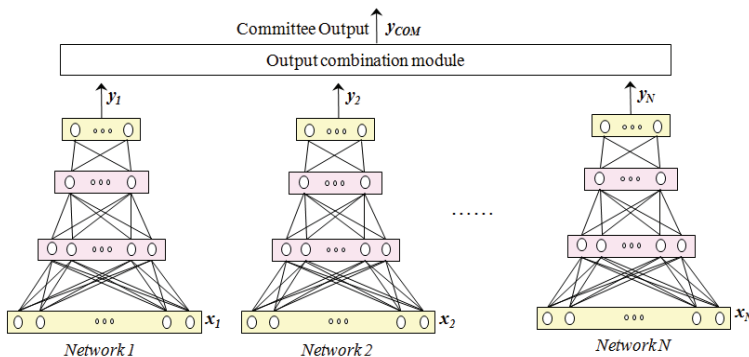


Fig. 1 Illustration of committee of neural networks

적으로 학습시켰으며 이때 단일 신경망들의 초기 연결강도를 랜덤하게 설정하여 각각 다른 초기 연결강도를 가지고 학습시켰다.

3. 모노파일 형식 지지구조물

이 연구에서는 손상추정을 위하여 선행 연구⁽¹²⁾와 동일한 모노파일 형식 지지구조물을 적용하였다. 이

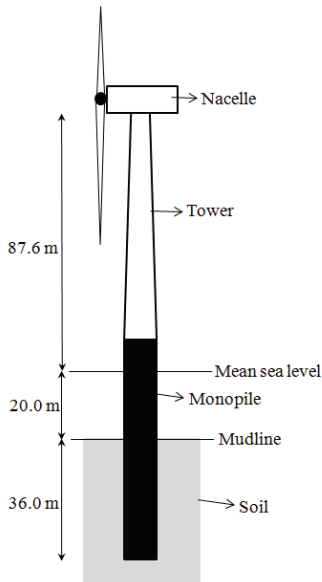


Fig. 2 Configuration of support structure

Table 1 Section properties of support structure

Section no.	Location	Mass per unit length(kg/m)	Stiffness (N·m ²)
1	0.00000	9517.14	1037.13E9
2	0.27881	9517.14	1037.13E9
3	0.27882	4306.51	474.49E9
4	0.35094	4030.44	413.08E9
5	0.42306	3763.45	357.83E9
6	0.49517	3505.52	308.30E9
7	0.56729	3256.66	264.08E9
8	0.63941	3016.86	224.80E9
9	0.71153	2786.13	190.06E9
10	0.78365	2564.46	159.49E9
11	0.85576	2351.87	132.77E9
12	0.92788	2148.34	109.54E9
13	1.00000	1953.87	89.49E9

장에서는 해당 지지구조물의 모델링 및 모드특성 추정에 대하여 선행 연구의 내용을 간략히 요약하였으며 자세한 사항은 위 선행 연구를 참조할 수 있다.

손상추정에 사용된 지지구조물은 5 MW NREL Reference 모델⁽¹³⁾에 적용할 수 있는 구조물로 설정하였다. 모노파일은 외경 6 m, 두께 60 mm의 강관이며, Fig. 2에 보인 바와 같이 머드라인(mudline)부터의 높이는 30 m이고 평균해수면(mean sea level)까지의 높이는 20 m이며, 머드라인부터 지반으로 36 m 관입되어있다. 해석대상 지지구조물(타워 포함)의 높이는 머드라인으로부터 107.6 m이며 높이에 따라 단면이 변화하고 위치에 따른 지지구조물 단면의 주요 특성을 Table 1에 나타내었다. Table 1에서 위치는 타워 최상부가 1, 머드라인 부가 0이고 그 사이의 위치는 0과 1사이의 수로 치환하여 나타내었다. Table 1 위치에서의 강성을 계산한 후 중간값을 보간하여 구한다.

해저 지반의 조건은 존크만 등⁽¹⁴⁾에서 사용된 조건을 사용하였으며, Fig. 3과 같이 분포 스프링 모델을 적용하여 지반을 모델링한 후 지지구조물의 모드특성을 구하였고, 깊이에 따른 지반 스프링 상수는 비르와 존크만⁽¹⁵⁾에서 사용된 값을 이용하였다. 한편, 모노파일의 흡수효과에 의한 부가수질량을 고려




Fig. 3 Simplified model of monopile foundation

Table 2 Natural frequencies of support structure(Hz)

Mode no.	Fixed		Distributed spring	
	No added mass	Added mass	No added mass	Added mass
1	0.285	0.284	0.244	0.243
2	1.873	1.847	1.523	1.377
3	3.880	3.629	3.230	2.730

하여 지지구조물의 모드특성을 구하였다.

Fig. 2에 보인 대상 지지구조물의 고유주파수, 모드형상 및 모드형상 곡률을 BModes 프로그램⁽¹⁶⁾을 이용하여 구하였다. 기초부가 머드라인에서 고정되어 있는 경우와 분포 스프링 모델을 적용한 경우에 대하여 각각 부가수질량을 고려하지 않은 경우와 고려한 경우의 바람방향 고유주파수를 Table 2에 비교하였으며, 손상추정을 위한 지지구조물 모드특성 추정에서는 부가수질량을 고려하고 분포 스프링 모델을 적용하였다.

4. 지지구조물의 손상추정

모노파일에서 발생할 수 있는 대표적인 결함형태인 부식과 균열손상은 손상전후 강성비율을 활용하여 추정할 수 있을 것으로 판단된다. 따라서, 이 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 Table 1의 지지구조물 단면 위치, ‘o’와 ‘d’는 각각 건전상태와 손상상태를 의미한다. 또한 E 는 영계수, I 는 단면이차모멘트이며 EI 는 휨강성이다.

대상 지지구조물에 대하여 우선 16,000셋의 손상 위치 및 손상정도를 무작위로 샘플링한 후 이에 대

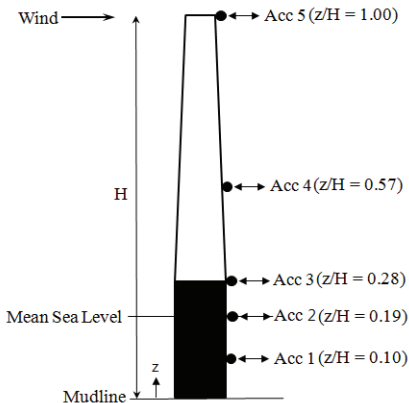


Fig. 4 Measurement locations

한 지지구조물의 고유주파수, 모드형상 및 모드형상 곡률을 BModes 프로그램을 이용하여 각각 구하였다. 이때 모드형상 및 모드형상 곡률은 Fig. 4에 보인 5개 위치에서 가속도를 측정하는 것으로 가정하여 구하였다.

각각의 손상경우에 대하여 변화된 1차, 2차 및 3차 고유진동수, 모드형상 및 모드형상 곡률을 구하였다. 즉, 각각의 훈련패턴은 3개의 손상전후 고유진동수 비율, 15개의 모드형상 성분, 15개의 모드형상 곡률 성분 및 이에 해당하는 손상위치와 손상정도로 구성된다. 따라서 신경망 입력자료는 33개로써 1차, 2차 및 3차 고유진동수, 모드형상 및 모드형상 곡률이고, 출력층은 13개 위치(Table 1 참조)에서의 강성지수(α_j)로 구성하였다. 대상 지지구조물은 단순한 구조형상이지만 높이에 따라 단면의 특성이 변화하고 특히, 모노파일과 타워의 접합부에서는 단면 특성이 급격히 변화하며, 보다 정밀한 손상추정을 위하여 13개 위치에서의 강성지수를 신경망의 출력자료로 활용하였으므로 안정된 계산을 위하여 충분히 많은 모드형상 관련 자료를 이용하였다. 한편, 25개 및 20개의 노드를 가지는 2개의 은닉층을 구성하였다. 손상위치 및 정도 추정을 위한 신경망의 구조를 Fig. 5에 나타내었다. 생성된 훈련패턴을 이용하여 신경망을 학습시켰으며 이때, 안정된 추정오차를 위하여 훈련패턴의 순서를 무작위로 하여 100회의 반복학습을 수행하였다.

군집 신경망을 구성하기 위하여 위와 동일한 구조의 신경망을 20개 작성한 후, 동일한 훈련패턴으로 단일 신경망들을 독립적으로 학습시켰다. 이때 단일

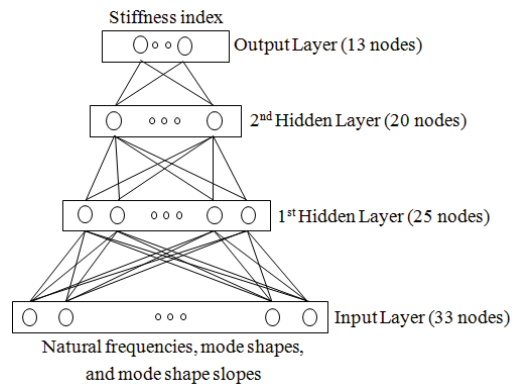


Fig. 5 Structure of neural networks

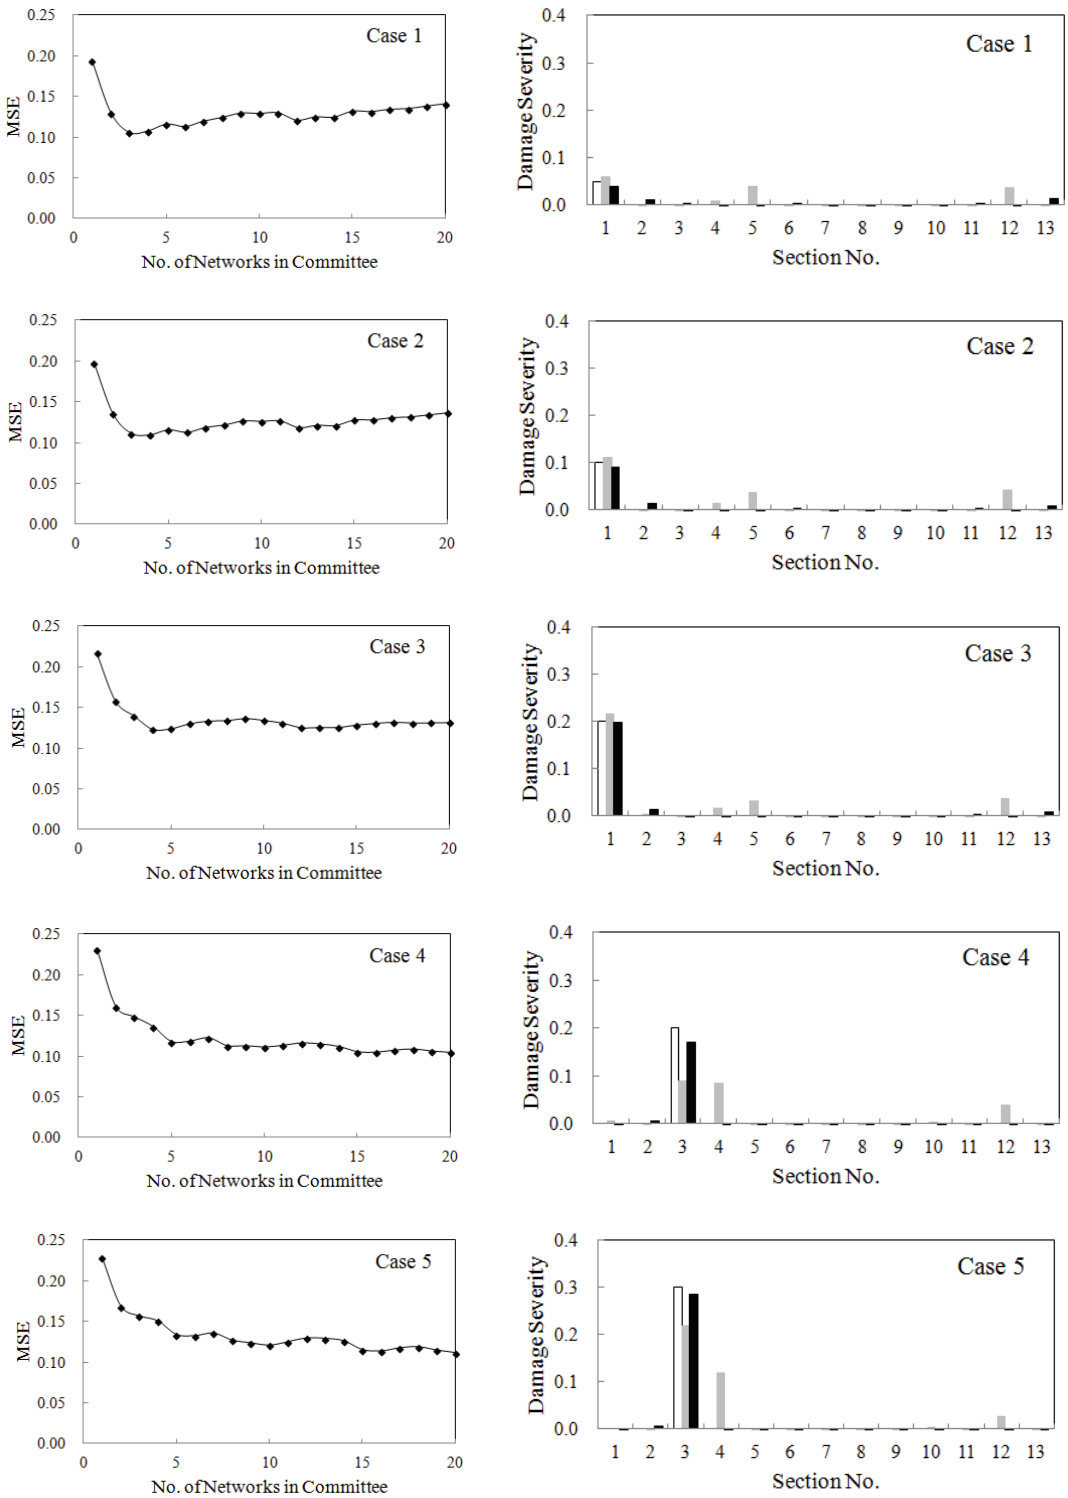


Fig. 6 Results of damage estimation

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

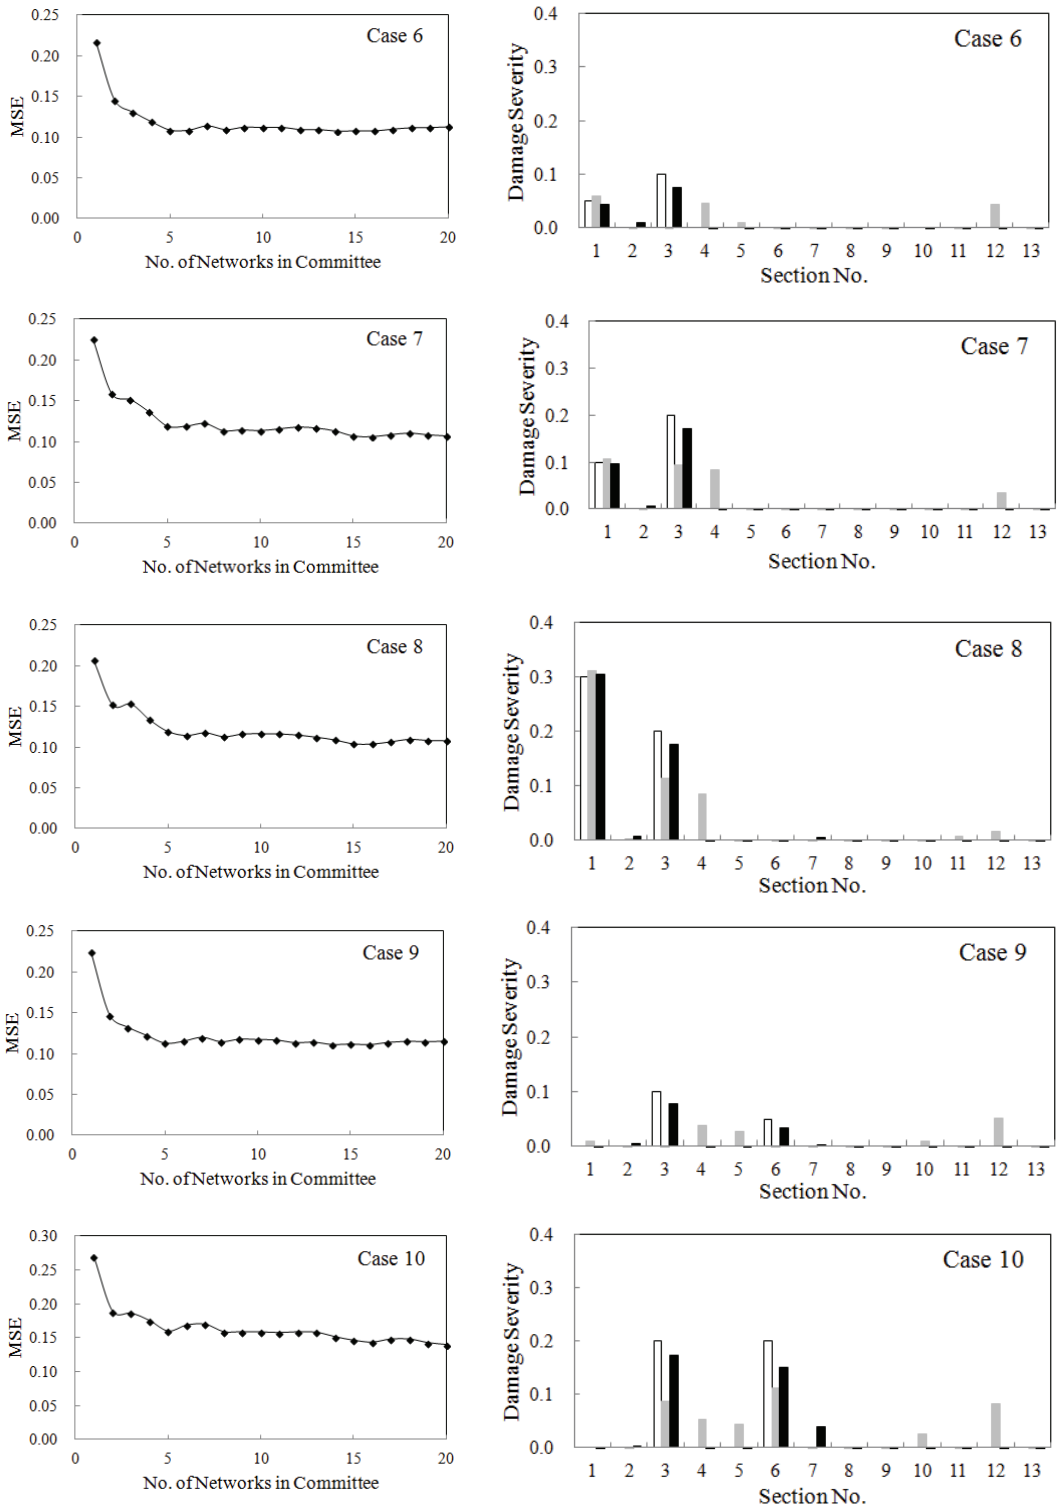


Fig. 6 Results of damage estimation(continued)

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

Table 3 Damage cases

Damage case	Damage severity(%)		
	0.000 (location)	0.279 (location)	0.495 (location)
1	5	-	-
2	10	-	-
3	20	-	-
4	-	20	-
5	-	30	-
6	5	10	-
7	10	20	-
8	30	20	-
9	-	10	5
10	-	20	20

신경망들의 초기 연결강도를 랜덤하게 설정하여 각각 다른 초기 연결강도를 가지고 학습시켰다.

20개의 단일 신경망에 대한 학습이 종료된 후, Table 3에 보인 10가지 손상경우에 대한 고유주파수, 모드형상 및 모드형상 곡률을 단일 신경망들에 입력하여 손상위치 및 손상정도를 각각 추정하였다. 이때 Table 3에서의 위치는 Table 1에서 강성이 정의된 위치이며 손상정도는 식 (3)에서 정의되었다. 단일 신경망들에 의하여 계산된 결과와 식 (2)를 이용하여 군집 출력을 계산하였는데 이때 단순 평균 방법을 적용하였다.

손상추정결과를 Fig. 6에 나타내었다. Fig. 6의 좌측 그래프에는 군집 신경망을 위하여 적용된 단일 신경망의 개수에 따른 평균 제곱 오차(mean square error)의 변화를 손상경우별로 나타내었으며, 단일 신경망의 개수가 증가하면서 오차가 감소함을 알 수 있다. 여기서, 군집 신경망에 적용되는 20개의 단일 신경망들의 순서를 인위적으로 조절하지 않았으며, 단일 신경망들의 순서에 따라 수렴하는 양상이 달리 나타날 수 있는 것으로 판단된다. 이 연구의 결과에서는 단일신경망의 수가 5개 부근에서 성능이 향상되었으나, 충분한 수렴을 위하여 20개의 단일 신경망을 이용하였다. 한편 Fig. 6 우측 그래프의 x축은 Table 1에서 설명된 단면 번호이고 y축은 식 (3)에서 설명된 손상정도이다. 하얀색 막대는 Table 3에서 설정한 손상정도(정확해)이고 회색 막대는 첫 번째 단일 신경망을 적용하여 추정한 손상정도(추정

치)이며 검정색 막대는 20개의 단일 신경망들로 구성된 군집 신경망을 적용하여 추정한 손상정도(추정치)이다. 군집 신경망기법을 적용하지 않는다면 첫 번째 단일 신경망의 결과가 손상추정 결과가 되지만 군집 신경망기법을 적용함으로써 손상위치 및 손상정도의 추정결과가 향상됨을 알 수 있다. 또한, 20개의 단일 신경망들이 동일한 구조와 훈련패턴으로 학습되었지만 서로 다른 초기 연결강도를 가지고 훈련되었기 때문에, 군집 신경망의 주요 효과 중 하나는 초기 연결강도에 민감한 국소 최저치 문제 완화인 것으로 판단된다.

5. 결 론

이 연구에서는 모노파일 형식의 해상풍력발전기 지지구조물에 대한 손상추정기법을 제안하였다. 손상에 의한 지지구조물의 고유진동수, 모드형상 및 모드형상 곡률의 변화를 이용하였으며, 손상위치 및 손상정도를 판정하기 위하여 군집 신경망기법을 사용하였다. 선행 연구에서의 계측점 개수를 축소하기 위하여 모드형상 곡률을 추가로 이용하였고, 단일 신경망에 의한 추정결과와 정확성을 향상시키기 위하여 군집 신경망기법을 적용하였다. 즉, 신경망의 초기 연결강도에 민감한 국소 최저치 문제, 노이즈 및 제한된 계측자료 등으로 인한 비유일성 문제 등을 함수 공간에서 평균하여 결과를 처리하는 군집 신경망기법을 적용하여 추정결과를 개선하였다. 10가지 손상경우에 대하여 손상위치 및 손상정도를 추정한 결과, 모든 손상 경우에 대하여 비교적 정확하게 손상위치와 손상정도를 판정할 수 있었으며 군집 신경망기법을 적용함으로써 추정결과와 정확성이 향상됨을 알 수 있었다.

향후, 지지구조물의 모드특성 이외의 계측 자료를 함께 활용함으로써 손상추정결과와 정확성을 좀 더 향상시킬 수 있을 것으로 판단되며, 다른 형식의 해상풍력발전기 지지구조물의 건전성 모니터링에 제안된 기법을 활용할 수 있을 것으로 사료된다.

후 기

이 연구는 지식경제부 신재생에너지기술개발사업(융합원천)인 “서남해 2.5GW 해상풍력을 위한 실증

단계 연구”과제의 세부연구 일부 내용임을 밝히는 바이며, 연구수행에 지원해 주신 관계자 여러분께 감사드립니다.

참 고 문 헌

(1) Perrone, M. P., 1993, General Averaging Results for Convex Optimization, Proceedings of Connectionist Models Summer School, Hillsdale, pp. 364~371.

(2) Perrone, M. P. and Cooper, L. N., 1993, When Networks Disagree: Ensemble Methods for Hybrid Neural Networks, Artificial Neural Networks for Speech and Vision, Chapman & Hall, London, pp. 126~142.

(3) Marwala, T. and Heyns, P. S., 1998, Multiple-criterion Method for Determining Structural Damage, American Institute of Aeronautics and Astronautics Journal, Vol. 36, No. 8, pp. 1494~1501.

(4) Marwala, T. and Hunt, H. E. M., 1999, Fault Identification Using Finite Element Models and Neural Networks, Mechanical Systems and Signal Processing, Vol. 13, No. 3, pp. 475~490.

(5) Marwala, T., 2001, Probabilistic Fault Identification Using a Committee of Neural Networks and Vibration Data, Journal of Aircraft, Vol. 38, No. 1, pp. 138~146.

(6) Hashem, S., 1994, Optimal Linear Combinations of Neural Networks, PhD Thesis, Purdue University, IN, USA.

(7) Parmanto, B., Munro, P. W., Doyle, H. R., Doria, C., Aldrighetti, L., Marino, I. R., Mitchel, S. and Fung, J. J., 1994, Neural Network Classifier for Hepatoma Detection, Proceeding of the World Congress of Neural Networks, San Diego, USA.

(8) Lee J. W., Yi, J. H., Kim, J. D. and Yun, C. H., 2004, Health Monitoring Method Using Committee of Neural Networks, Key Engineering Materials, Vols. 270-273, pp. 1983~1988.

(9) Hinsbergen, C. P. IJ., van Lint, J. W. C. and van Zuylen, H. J., 2009, Bayesian Committee of Neural Networks to Predict Travel Time with Confidence Intervals, Transportation Research Part C, Vol. 17, No. 5, pp. 498~509.

(10) Abdel-Aal, R. E., 2005, Improving Electric Load Forecasts Using Network Committees, Electric Power System Research, Vol. 74, No. 1, pp. 83~94.

(11) Liu, J., Zuo, B., Zeng, X., Vroman, P. and Rabenasolo, B., 2011, Wavelet Energy Signature and Robust Bayesian Neural Network for Visual Quality Recognition of Nonwovens, Expert Systems with Application, Vol. 38, No. 7, pp. 8497~8508.

(12) Kim, S., R., Lee, J. W., Kim, B. K. and Lee, J. S., 2012, Damage Estimation Method for Monopile Support Structure of Offshore Wind Turbine, Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 22, No. 7, pp. 667~675.

(13) Jonkman, J., Butterfield, S., Musial, W. and Scott, G., 2009, Definition of a 5-MW Reference Wind Turbine for Offshore System Development, Technical Report, NREL/TP-500-38060, National Renewable Energy Laboratory.

(14) Jonkman, J., Butterfield, S., Passon, P., Larsen, T., Camp, T., Nichols, J., Azcona, J. and Martinez, A., 2008, Offshore Code Comparison Collaboration within IEA Wind Annex XXIII: Phase II Results Regarding Monopile Foundation Modeling, Conference Paper, NREL/CP-500-42471, National Renewable Energy Laboratory.

(15) Bir, G. and Jonkman, J., 2008, Modal Dynamics of Large Wind Turbines with Different Support Structures, Conference Paper, NREL/CP-500-43045, National Renewable Energy Laboratory.

(16) Bir, G. S., 2007, Users Guide to BModes (Software for Computing Rotating Beam Coupled Modes), National Renewable Energy Laboratory.



Jong Won Lee received his PhD from the Civil and Environmental Engineering Department at Korea Advanced Institute of Science and Technology in 2003. He worked at Korea Institute of Machinery and Materials. His research interests include structural health monitoring, damage identification, and smart sensor technique.