

회전 블레이드의 결함진단 확률제고를 위한 가진 모멘트 적용

김종수* · 최찬규* · 유흥희*†

* 한양대학교 기계공학부

Application of Excitation Moment for Enhancing Fault Diagnosis Probability of Rotating Blade

Jong Su Kim*, Chan Kyu Choi* and Hong Hee Yoo*†

* Dept. of Mechanical Engineering, Hanyang Univ.

(Received November 26, 2013 ; Revised December 10, 2013 ; Accepted December 12, 2013)

Key Words: Hidden Markov Model(HMM; 은닉 마르코프 모델), Artificial Neural Network(ANN; 인공 신경망), Fault Diagnosis(결함 진단), Feature Vector(특징벡터), Vector Quantization(벡터 양자화)

초록: 기계시스템의 결함을 진단하기 위한 방법으로 패턴인식 기법이 널리 사용되고 있다. 진동신호의 변화를 감지하여 기계시스템의 건전성을 판단하는 방법이 패턴인식 기법이다. 대표적 패턴 인식기법으로 최근 은닉 마르코프 모델과 인공신경망이 여러 분야에서 사용되고 있다. 본 연구에서는 결함진단에 은닉 마르코프 모델과 인공신경망을 혼합한 방법이 제시되었으며 결함진단 대상 구조물로는 크랙을 가진 회전하는 풍력터빈 블레이드가 선정되었다. 본 연구에서는 크랙발생 여부뿐만 아니라 그 위치 및 크기도 동시에 진단하고자 하였다. 아울러서 본 연구에서는 일정 주파수들을 갖는 모멘트를 대상 구조물에 가함으로써 외부 잡음에도 불구하고 높은 결함진단 확률을 가질 수 있도록 하였다.

Abstract: Recently, pattern recognition methods have been widely used by researchers for fault diagnoses of mechanical systems. A pattern recognition method determines the soundness of a mechanical system by detecting variations in the system's vibration characteristics. Hidden Markov models (HMMs) and artificial neural networks (ANNs) have recently been used as pattern recognition methods in various fields. In this study, a HMM-ANN hybrid method for the fault diagnosis of a mechanical system is introduced, and a rotating wind turbine blade with a crack is selected for fault diagnosis. The existence, location, and depth of said crack are identified in this research. For improving the diagnostic accuracy of the method in spite of the presence of noise, a moment with a few specific frequencies is applied to the structure.

1. 서 론

기계시스템에 발생하는 결함의 진단을 위해서는 다음의 두 가지 사항이 요구된다. 첫째는 발생된 결함을 신속하게 발견할 수 있어야 하는 것이고, 둘째는 작동 중인 기계시스템을 멈추지 않고서도 결함 발생여부를 판단할 수 있어야 하는 것이다. 첫째 사항인 결함발견 신속성은 결함이 진전되어 파손에 이르는 것을 막아야 하기 때문에 중요하며 둘째 사항인 작동 중인 기계시스템을 멈추지 않고

결함발생 여부를 진단해야 하는 것은 작동중단에 따른 경제적 손실을 줄인다는 점에서 중요하다. 과거 기계시스템의 일반적 정비방식은 일정 시간 간격으로 정비를 수행하는 방식이었다. 이 경우는 기계시스템에 결함이 없이 정상적으로 작동하는 경우도 무조건 작동을 멈추고서 정비를 수행해야 하기 때문에 상당한 시간적 경제적 손실이 뒤따라 매우 비효율적이다. 그러므로 최근 들어서는 기계시스템의 작동 중 실시간 신호를 이용해 상태를 진단하는 방법들이⁽¹⁾ 개발되어 왔다.

최근에는 기계시스템의 결함 진단에 기기 동작 중 발생하는 신호를 이용해 실시간으로 결함 발생 유무를 판단하는 상태기반정비(CBM: condition based maintenance)⁽²⁾ 형태를 주로 이용하고 있다. 상태기반

† Corresponding Author, hhyoo@hanyang.ac.kr

© 2014 The Korean Society of Mechanical Engineers

정비는 진단 대상 기계시스템의 동작 중 발생하는 진동, 온도, 압력 등과 같은 출력 신호를 이용하여 실시간으로 기기 상태를 파악할 수 있게 해준다. 따라서 주기적으로 정비를 수행하는 기존 정비 방법에 비해 시간과 경제적인 면에서 매우 효율적이다.

상태기반정비는 신호들의 차이를 패턴 인식(pattern recognition) 기법을 이용하여 분류하고 그 분류된 결과를 가지고 기계시스템의 상태를 판단하는 것이다. 기계시스템에 발생하는 결함의 종류 혹은 결함의 발생 위치에 따른 진동신호는 다르기 때문에 패턴 인식 기법으로 진동 신호를 분류할 수 있다. 최근 많이 쓰이는 패턴 인식기법으로는 은닉 마르코프 모델(HMM: hidden Markov model)과 인공신경망(ANN: artificial neural network) 등이 있다.

은닉 마르코프 모델과 인공신경망에 관한 기존 연구들을 살펴보면, 1983년에 Rabiner^(3,4) 등이 은닉 마르코프 모델을 음성인식과 문자인식에 사용하는 연구를 하면서 패턴 인식 기법으로 널리 사용되기 시작하였다. 이후 응용분야가 넓어져 2000년에 Bunk⁽⁵⁾에 의해 은닉 마르코프 모델을 이용한 기계시스템의 상태진단 연구가 진행되었다. Lee⁽⁶⁾ 등은 2003년에 회전하는 기기의 출력 신호를 이용하여 기기 결함을 진단하는데 은닉 마르코프 모델을 이용하였다. 인공신경망 역시 패턴 인식 분야에 널리 사용되는데, 1998년에는 Rowley⁽⁷⁾ 등이 얼굴 인식기법에 인공신경망을 사용하였다. 2003년에는 Samanta⁽⁸⁾ 등이 회전하는 베어링의 결함 진단에 인공신경망을 사용하였다.

본 논문에서는 은닉 마르코프 모델과 인공신경망을 함께 이용한 기계시스템 결함진단 알고리즘을 제안하였다. 기존 결함진단 연구에서는 하나의 패턴 인식 기법만을 사용하였는데, 본 연구에서는 은닉 마르코프 모델과 인공신경망을 함께 이용해 결함 진단의 정확도를 높이고자 하였다. 아울러 기존 연구들과는 달리 결함 발생여부를 판단하는 것에서 더 나아가 그 결함의 발생 위치와 크기를 동시에 찾는 방법을 제안하였다. 제안한 결함 진단 기법이 효과적인 진단 결과를 내는지 확인하기 위해 크랙을 가진 풍력 터빈 블레이드를 대상으로 진단을 수행하였다. 해석 모델로부터 진동신호인 변위 값을 추출하여 크랙의 발생 여부와 크랙의 발생 위치 및 크기를 동시에 찾는 진단을 수행하였다. 이와 아울러서 신호 속에 주어지는 외부 잡음에도 불구하고 진단의 확률을 높이기 위해서 특정 주파수들을 갖는 모멘트를 대상물에 가하는 방법을 제안하고 그 효용성을 검증하였다.

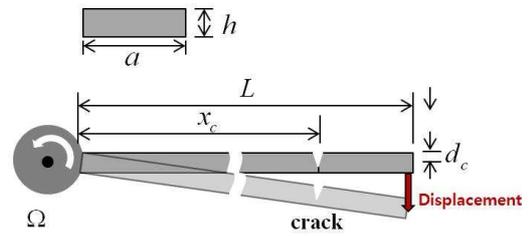


Fig. 1 Geometry of a rotating blade having a crack

2. 특징벡터 추출

2.1 결함 진단 대상 모델

본 연구에서는 결함을 진단할 대상 기계시스템으로 풍력터빈 블레이드를 선정하였다. 풍력터빈 블레이드를 Fig. 1 과 같이 하나의 크랙을 포함한 보로 모델링 하여⁽⁹⁾ 크랙 발생여부와 그 위치 및 깊이를 진단하고자 하였다. Fig. 1 은 길이가 L 이고, 단면의 가로 및 세로 길이가 a 와 h 인 보 형상을 보여 준다. 고정단으로부터 임의 위치 x_c 에 깊이 d_c 의 크랙이 존재 하고, 보의 고정 단은 각속도 Ω 로 회전을 한다. 이때 시간에 따른 변위를 출력신호로 사용하여 은닉 마르코프 모델과 인공신경망에 적용시킨다. 보 끝단의 처짐을 구하는 과정은 참고문헌 (9)에 제시되어 있다.

2.2 FFT 를 이용한 특징벡터 추출

보 해석 모델로부터 얻은 출력 신호인 시계열 데이터는 은닉 마르코프 모델에 직접 사용할 수 없고 특징벡터(feature vector)를 추출하는 과정과 특징벡터를 기호로 바꾸는 벡터 양자화(vector quantization)과정을 거쳐야 한다.^(10,11) 먼저 보의 해석 모델에 식 (1)과 같은 형태의 입력운동을 가한다.⁽¹²⁾

$$\Omega = \Omega_s + A \sin(2\pi ft) \quad (1)$$

다음으로 보 해석 모델로부터 학습 데이터(training data)를 얻는다. Fig. 2 에서 보듯이 크랙 진단영역을 크랙의 위치 방향과 깊이 방향으로 각각 8 개로 나누어 64 개 영역으로 만든다. 크랙이 각 영역에 존재할 때 추출한 출력 신호들을 학습데이터로 사용한다. 이때 크랙의 위치와 깊이가 다를 경우 해당 출력 신호들간에 차이가 발생한다.

다음 과정으로 잡음(noise)의 영향을 고려하기 위하여 출력신호에 백색 잡음을 (white Gaussian

noise) 더해 준다. 출력신호에 대한 잡음의 상대적 크기를 알기 위하여 식 (2)와 같이 SNR(signal to noise ratio)값을 정의 하였다. 이 식에서 P 는 power, A 는 변위진폭의 평균제곱근(root mean square)을 뜻한다.

$$\text{SNR}_{\text{dB}} = 10 \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) = 10 \log_{10} \left(\frac{A_{\text{signal}}}{A_{\text{noise}}} \right)^2 \quad (2)$$

이 같이 얻은 학습데이터는 특징벡터 추출과정과 양자화 과정을 거치는데 이것을 전처리 과정(preprocessing)이라 한다. 먼저 특징벡터 추출 과정으로 앞에서 구한 학습 데이터를 주파수영역으로

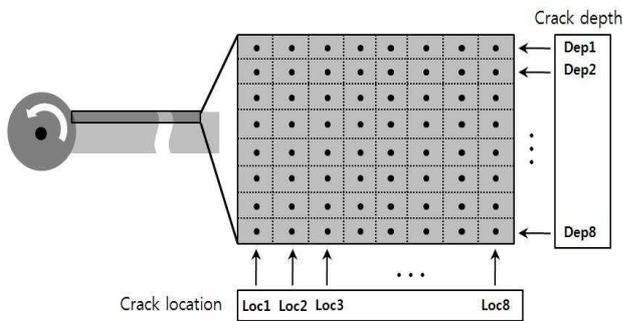


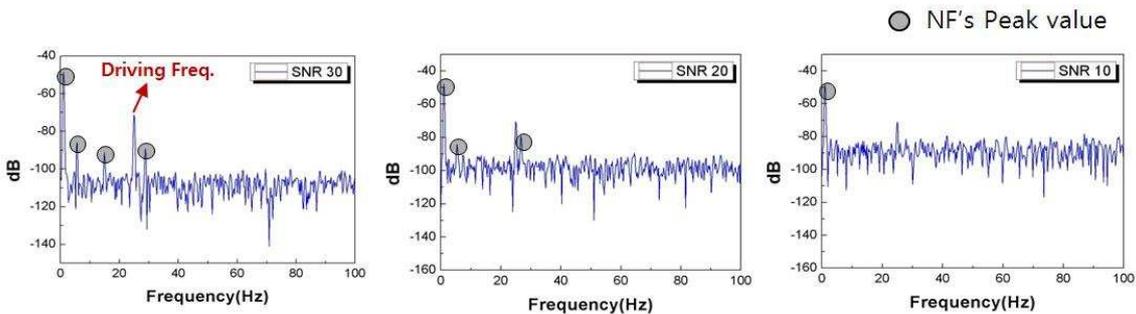
Fig. 2 Crack diagnostic area and the location of training data point

변환하여 준다. 그러면 Fig. 3 과 같은 그래프와, 1~5 차 고유진동수의 피크 값이 나타남을 알 수 있다. 이 5 개의 고유진동수 피크 값을 특징벡터로 사용한다. 이때 크랙 위치 및 크기에 따라서 이 고유진동수들의 피크 값이 다르므로 특징벡터로 사용하기에 적합하다. Fig. 3(a)는 SNR 값이 비교적 작을 때, 즉 잡음의 세기가 클 때의 고유진동수 피크 값들을 나타낸 것이다. 그래프를 보면 SNR 값이 작아질수록 고유진동수 피크 값들이 잡음에 묻히는 것을 알 수 있다. 이 문제점을 해결하기 위해 보에 식 (3)과 같은 조화함수 조합 모멘트를 가한다. 조화함수 주파수들은 각각 보의 2~5 차 고유진동수 값들을 사용하며, 그 이유는 이 가진 모멘트에 의해 보의 2~5 차 고유진동수 피크 값들을 상승시켜 잡음에 묻히지 않도록 하기 위함이다.

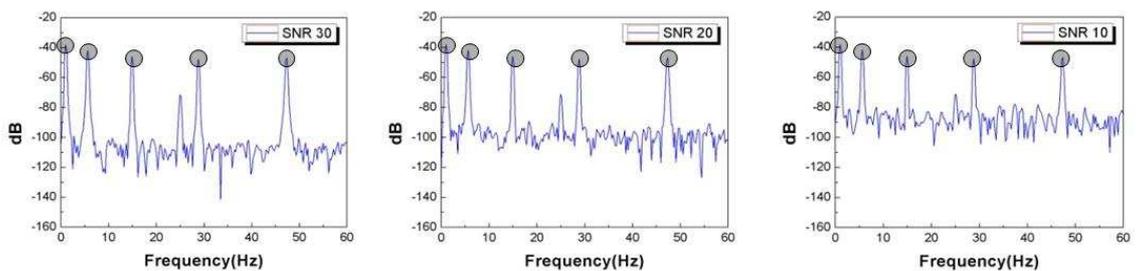
$$M_e = A_1 \sin(2\pi f_1 t) + A_2 \sin(2\pi f_2 t) + A_3 \sin(2\pi f_3 t) + A_4 \sin(2\pi f_4 t) \quad (3)$$

Fig. 3(b)는 보에 모멘트를 가한 뒤 출력 신호를 FFT 한 그래프를 나타낸 것이다. 보의 1~5 차 고유진동수들이 잘 나타나는 것을 알 수 있다.

마지막 과정은 앞에서 구한 특징 벡터를 기호로 변환하는 벡터양자화과정이다. 코드북(codebook)을 이용하여 특징벡터를 기호열로 변환⁽⁶⁾한다.



(a) FFT of output signal according to SNR (no excitation)



(b) FFT of output signal according to SNR (excitation)

Fig. 3 Feature vector obtained from output signal of the beam

3. 진단 알고리즘의 개요

3.1 HMM 과 ANN 을 이용한 복합 모델

이 연구에서는 크랙 진단 정확도를 높이기 위해 은닉 마르코프 모델과 인공신경망을 동시에 이용하였다. 해석 모델로부터 구한 특징벡터를 인공신경망을 이용하여 먼저 패턴 분류를 시행⁽¹³⁾하고, 그 결과 값의 정보를 은닉 마르코프 모델 학습 시 이용하는 것이다. 은닉 마르코프 모델만을 사용한 진단 결과와 은닉 마르코프 모델과 인공신경망을 함께 사용한 진단 결과의 비교는 참고문헌 (12)를 통해 확인할 수 있다.

Fig. 4는 은닉 마르코프 모델과 인공신경망을 이용한 복합 모델(hybrid model)을 만드는 과정을 보여준다. 대상 기계시스템에서 얻은 출력 신호를 FFT 하여 1~5차 고유진동수에서의 피크 값을 구한다. 이 값들이 특징벡터가 된다. 다음은 5개 특징벡터 요소를 인공신경망을 이용하여 패턴 분류를 한다. 패턴 분류해 나온 결과값 2개를 앞서 얻었던 5개의 특징벡터 요소에 더하여 총 7개 값을 가지고 Baum-Welch algorithm⁽⁴⁾을 이용하여 은닉 마르코프 모델을 구성한다. 이 경우 인공신경망으로 진단한 결과의 정보를 은닉 마르코프 모델 구성 시 특징벡터로 사용하기 때문에 단일 은닉 마르코프 모델을 이용하는 경우에 비해 진단 정확도가 높아진다.⁽¹²⁾

3.2 복합 모델 적용 알고리즘

앞 과정에서 만든 복합모델을 이용하여 크랙 발생 여부와 크랙의 위치 및 크기를 찾는 진단과정 (diagnosis process)이 이루어진다. 복합모델의 형태는 식 (4)와 같이 은닉 마르코프 모델과 같다.^(4,12) Fig. 5에 나오는 빔의 각 영역 내 숫자들은 해당 영역에 크랙이 존재할 때 추출한 출력신호로 만든 복합모델을 나타낸다. 총 126개의 복합모델을 가지고 6단계에 걸쳐 크랙의 위치와 크기를 찾는다. 먼저 첫 번째 단계에서는 임의의 위치와 크기의 크랙을 갖는 빔으로부터 얻은 관측 기호열이 1번 영역과 2번 영역에 해당하는 복합모델 λ_1 과 λ_2 에서 발견될 확률 $\log(P[O|\lambda_1])$ 과 $\log(P[O|\lambda_2])$ 를 각각 구한다. 그 다음 두 확률 값을 비교하여 큰 쪽에 해당하는 영역을 크랙이 있는 영역으로 택한다. 두 번째 단계는 첫 번째 단계에서 택한 영역을 반으로 나눈 다음 첫 번째 단계와 마찬가지로 두 확률 값 $\log(P[O|\lambda_3])$ 과 $\log(P[O|\lambda_6])$ 를 각각

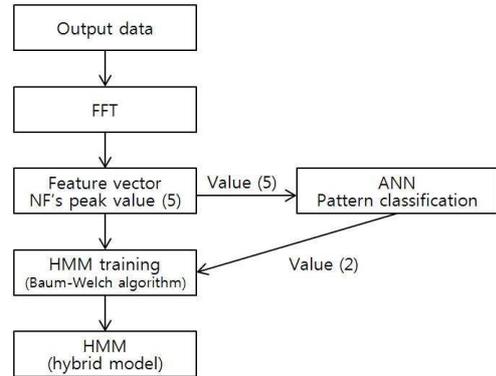


Fig. 4 Procedure of building the HMM/ANN hybrid model

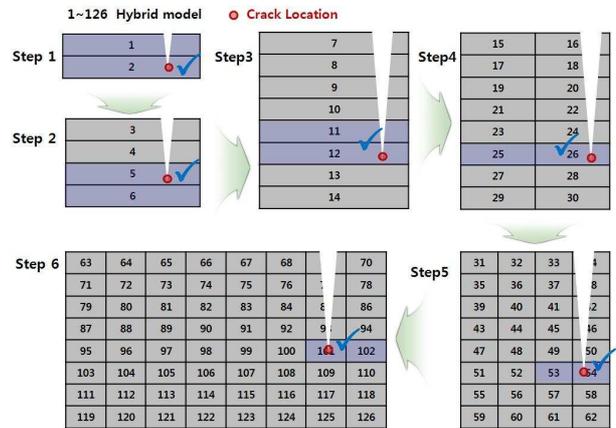


Fig. 5 Process of crack diagnosis using a hybrid model

구하여 비교한다. 이와 같은 방법으로 총 6단계를 거치면 최후의 크랙 위치와 크기를 찾게 된다. 이때 임의의 관측 기호열이 복합모델 즉 HMM 에서 발견될 확률 값 $\log(P[O|\lambda_i])$ 은 로그 우도(log-likelihood)라고 한다.⁽⁴⁾

$$\lambda = (\pi, A, B) \tag{4}$$

4. 진단 결과

4.1 크랙 발생 여부 진단 결과

Fig. 6은 각 영역에 크랙이 존재할 때 복합모델이 크랙이 존재한다고 판단할 확률을 나타낸 것이다. 각 영역내의 숫자는 총 10번 진단을 하여 옳게 판단한 횟수를 나타낸다. 참고문헌 (12)의 결과와 비교했을 때 크랙 크기가 작을 경우 진단확률

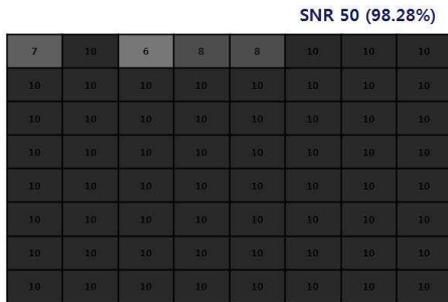


Fig. 6 Diagnostic probability at each sub-domain

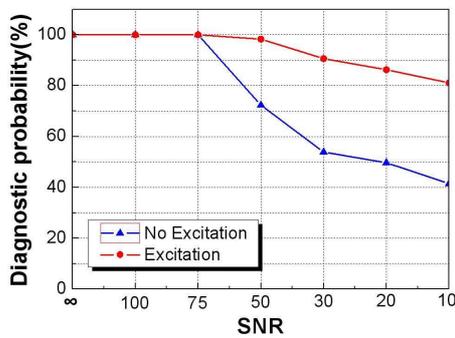


Fig. 7 Diagnostic probability versus SNR

이 상승한 것을 알 수 있다. 이것은 가진 모멘트를 가했을 때 좀 더 정확한 진단이 가능하다는 것을 말한다. Fig. 7 은 64 개 진단 영역의 총 진단확률을 잡음 세기, 즉 SNR 값에 따라 나타낸 것이다. 이 결과 역시 가진 모멘트를 가했을 때 진단확률이 상승한 것을 알 수 있고 SNR 값이 작아질수록 진단확률이 감소함을 알 수 있다.

4.2 크랙 위치 및 크기의 진단 결과

Fig. 8 은 각 영역 별로 크랙이 존재 할 때, 복합 모델로 진단 시 크랙 위치와 크기를 정확히 찾을 확률을 보여준다. 그 음영이 진할수록 진단확률이 높은 것이다. 이 결과 역시 참고문헌 (12)와 비교해보면 크랙 크기가 작은 곳에서 진단확률이 상승하였음을 알 수 있다.

Fig. 9 는 SNR 값에 따른 전체 진단영역에서의 총 진단 확률을 나타낸 것이다. 이 결과를 보면 가진 모멘트를 가했을 경우 가하지 않은 경우보다 진단확률이 크게 상승함을 알 수 있다. 그럼에도 불구하고 SNR 값이 작아질수록 진단확률이 감소하는 결과는 여전히 나타났다.

Fig. 10 은 크랙의 위치에 따른 진단 확률을 SNR 값 별로 나타낸 것이다. 그래프를 보면 SNR 값에 따라 전체적으로 진단확률이 감소 혹은 증가하는

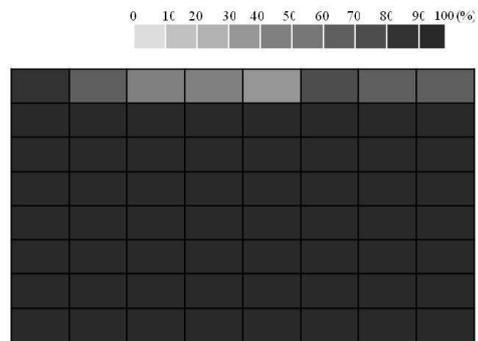


Fig. 8 Diagnostic probability 95.63% (SNR 50)

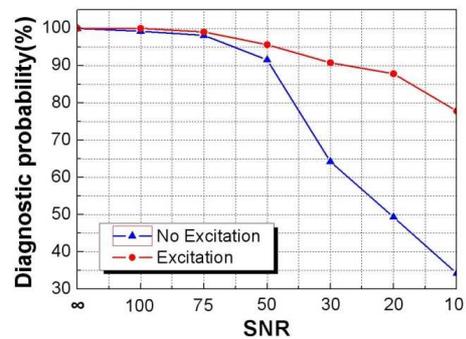


Fig. 9 Diagnostic probability versus SNR

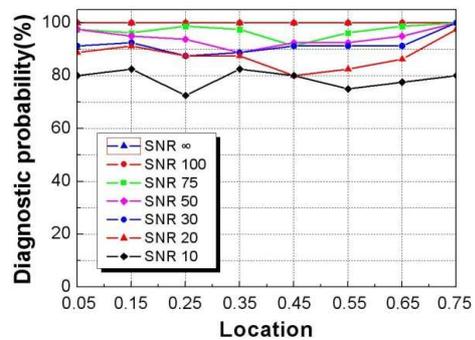


Fig. 10 Diagnostic probability versus crack location

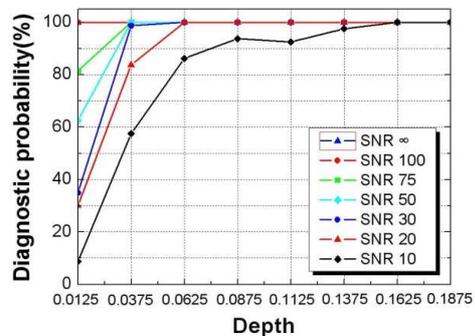


Fig. 11 Diagnostic probability versus crack size

경향이 있지만, 일정한 SNR 값에서 크랙 위치에 따른 진단확률에는 큰 차이가 없음을 알 수 있다.

이 결과를 통해 블레이드 내에 크랙 위치는 진단 확률에 큰 영향을 미치지 않음을 잘 알 수 있다. 이와 달리 Fig. 11 은 크랙 크기에 따른 진단확률을 SNR 값 별로 나타낸 것이다. 결과를 보면 이 역시 SNR 값에 따라서는 전체적으로 진단확률이 증가하거나 감소하는 경향을 보이지만, Fig. 10 결과와 달리 크랙 크기에 따른 진단확률에는 큰 변화가 발생하는 것을 알 수 있다. 크랙 크기가 클 때는 진단확률이 높고 크기가 작아질수록 진단확률이 감소한다. 이 결과는 크랙의 크기가 진단확률에 미치는 영향이 크다는 것을 보여준다.

5. 결 론

이 논문에서는 은닉 마르코프 모델과 인공신경망을 함께 이용하여 기계시스템의 결함을 진단 하고자 하였다. 기존의 연구들과는 달리 결함발생 여부뿐만 아니라 결함발생 위치 및 크기를 동시에 찾는 알고리즘을 제안하였고, 이러한 결함 진단 방법이 실제 우수한 진단결과를 내는지 확인하기 위해 크랙을 갖는 회전하는 풍력터빈 블레이드를 보 모델로 하여 크랙 발생여부 및 크기와 위치를 진단하였다. 보 해석모델로부터 얻은 출력신호에 백색 잡음을 더해 실제 상황을 재현하고자 하였다. 출력신호에 대한 잡음의 비율을 SNR 값으로 나타내어 이 값에 따른 진단확률을 조사하였다. 진단 결과 잡음세기가 아주 미미 할 땐 크랙의 위치와 크기를 정확히 찾았고, 잡음의 세기가 증가할수록 진단확률이 떨어지는 것을 알 수 있었다. 잡음의 세기가 증가함에 따른 진단확률 하락 문제를 해결하기 위해 보 해석모델에 모멘트를 가하는 방법을 제안하였다. 가진 모멘트를 특정 주파수들을 갖는 조화함수의 조합형태로 하였을 경우 잡음에 묻혀 나타나지 않았던 특징벡터 요소들이 뚜렷이 나타나게 되었다. 그 결과 진단확률이 크게 상승하는 것을 알 수 있었다.

후 기

이 연구는 2011 년도 지식경제부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제 입니다(No. 2011T100200116).

참고문헌

(1) Martin, K. F., 1994, "A Review by Discussion of

- Monitoring and Fault-diagnosis in Machine-tools," *International Journal of Machine Tools and Manufacture*, Vol. 34, No. 4, pp. 527~551.
- (2) Jardine, A. K. S., Lin, D. and Banjevic, D., 2006, "A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance," *Mechanical Systems and Signal Processing*, Vol. 20, pp. 1483~1510.
- (3) Rabiner, L. R., Levinson, S. E. and Sondhi, M. M., 1983, "On the Application of Vector Quantization and Hidden Markov Models to Speaker-Independent Isolated Word Recognition," *AT&T The System Technical Journal*, Vol. 62, No. 4, pp. 1075~1105.
- (4) Rabiner, L. R., 1989, "A Tutorial on Hidden Markov Models and Selected Application in Speech Recognition," *Proc. IEEE*, Vol. 77, No. 2, pp. 257~286.
- (5) Bunks, C., McCarthy, D. and Al-Ani, T., 2000, "Condition-based Maintenance of Machines Using Hidden Markov Models," *Mechanical System and Signal Processing*, Vol. 14, No. 4, pp. 597~612.
- (6) Lee, J. M., Kim, S. J., Hwang, Y. H. and Song, C. S., 2003, "Pattern Recognition of Rotor Fault Signal Using Hidden Markov Model," *Trans. Korean Soc. Mech. Eng. A*, Vol. 27, No. 11, pp.1864~1872.
- (7) Rowley, H. A., Baluja, S. and Kanade, T., 1998, "Neural Network-based Face Detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 20, No. 1, pp. 23~38.
- (8) Samanta, B. and Al-Balushi, K. R, 2003, "Artificial Neural Network Based Fault Diagnostics of Rolling Element Bearings Using Time-domain Features," *Mechanical Systems and Signal Processing*, Vol. 17, No. 2, pp. 317~328.
- (9) Kim, M. K. and Yoo, H. H., 2009, "Vibration Analysis of a Cracked Beam with a Concentrated Mass Undergoing Rotational Motion," *Trans. of the KSNVE*, Vol. 10, No. 1, pp. 10~16.
- (10) Robert, M. G., 1984, "Vector Quantization," *IEEE ASSP Magazine*, pp. 4~28.
- (11) Liu, Z., Yin, X, Zhang, Z., Chen, D. and Chen, W., 2004, "Online Rotor Mixed Fault Diagnosis Way Based on Spectrum Analysis of Instantaneous Power in Squirrel Cage Induction Motor," *IEEE Transactions on Energy Conversion*, Vol. 19, No. 3, pp. 485~490.
- (12) Kim, J. S. and Yoo, H. H., 2013, "Fault Diagnosis of a Rotating Blade using HMM/ANN Hybrid Model," *Trans. of the KSNVE*, Vol. 23, No. 9, pp. 814~822.
- (13) MATLAB Product Help Manual; Neural Network Tool Box.