

웨이블릿 변환과 인공신경망을 이용한 결함분류 프로그램 개발과 용접부 결함 AE 신호에의 적용 연구

Development of Defect Classification Program by Wavelet Transform and Neural Network and Its Application to AE Signal Due to Welding Defect

김성훈*, 이강용**

Seong-Hoon Kim* and Kang-Yong Lee**

초 록 웨이블릿 변환과 인공신경망을 이용하여 AE 신호를 분류하는 소프트웨어 패키지를 개발하였다. 웨이블릿 변환으로는 연속 웨이블릿 변환과 이산 웨이블릿 변환을 모두 고려하였으며, 인공신경망의 모델로는 오류 역전파 인공신경망을 사용하였다. 분류에 사용된 AE 신호는 용접부에 인공결함을 가진 시편의 3점 굽힘시험에서 발생한 신호이다. 개발된 소프트웨어 패키지를 이용하여 이 신호를 웨이블릿 변환시켜 생성된 시간-주파수 평면상에서 특징값을 추출하고 이를 인공신경망에 학습하여 인공신경망 분류기를 설계하고 검증하였다. 본 연구에서 개발된 소프트웨어 패키지를 이용한 AE 신호 분류법이 유용함을 보이고, 또한 연속 웨이블릿 변환과 이산 웨이블릿 변환에 의한 분류 결과를 비교하였다.

주요용어: 웨이블릿 변환, 음향방출, 인공신경망, 특징값 추출, 신호 분류

Abstract A software package to classify acoustic emission (AE) signals using the wavelet transform and the neural network was developed. Both of the continuous and the discrete wavelet transforms are considered, and the error back-propagation neural network is adopted as an artificial neural network algorithm. The signals acquired during the 3-point bending test of specimens which have artificial defects on weld zone are used for the classification of the defects. Features are extracted from the time-frequency plane which is the result of the wavelet transform of signals, and the neural network classifier is trained using the extracted features to classify the signals. It has been shown that the developed software package is useful to classify AE signals. The difference between the classification results by the continuous and the discrete wavelet transforms is also discussed.

Keywords: wavelet transform, acoustic emission, artificial neural network, feature extraction, signal classification

1. 서 론

음향 방출 신호의 처리에서 일반적인 문제는 물리적인 파라미터가 시간과 주파수 모두에 관련될 때, 물리적인 파라미터를 어떻게 추출하느냐하는 것이다. 따라서 시간과 주파수 모두를 고려하는 시간-주파수 해석이 고려의

대상이 되었다.

시간-주파수 해석에는 단시간 푸리에 변환(Short Time Fourier Transform), Wigner-Ville 분포 등이 사용되어 왔다. 그러나, 단시간 푸리에 변환은 시간-주파수 분해능이 일정하기 때문에 광범위한 주파수에 대한 해석에는 불편하고, 또, Wigner-Ville 분포는 적절한 시간-주

파수분포를 얻기 위해서는 부가적인 처리가 필요하는 등, 종래의 시간-주파수해석법에는 단점이 있었다. 그래서 최근에 등장한 웨이블릿 변환(Wavelet Transform)이 각광을 받고 있다.

Serrano와 Fabio[1]는 음향 방출 신호의 분석에 웨이블릿 변환이 사용될 수 있음을 보였고, Qi 등[2]은 복합재의 인장 시험에서 발생하는 음향 방출 신호의 해석에 이산 웨이블릿 변환[3,4]을 사용하여 웨이블릿 변환의 결과와 음향 방출 신호의 이벤트와의 관계를 찾았다. 또한 Qi와 Barhorst[5]는 이산 웨이블릿 변환에 기초한 음향 방출 신호의 해석이 복합재의 파괴 거동을 예측하는데 있어 기존의 방법보다 우수함을 보인 바 있다. Suzuki 등[6]은 연속 웨이블릿 변환[4,7]을 이용하여 GFRP 복합재의 인장시험에서 발생하는 음향방출 신호를 분석하여 시간-주파수 평면에 도시한 결과, 여러 가지 파괴의 상태에 따른 신호들을 쉽게 분류 할 수 있음을 보였다. 그러나 Suzuki 등의 연구는 결합의 종류에 따라 신호를 분류하는데 웨이블릿 변환이 유효함을 보이고 있지만, 웨이블릿 변환의 결과를 시간-주파수 평면상에 도시하고 육안에 의해 분류하는 것에 그치고 있다. Abbate 등[8]은 초음파 신호에 연속 웨이블릿 변환을 적용한 잡음 억제 기법을 사용하여 신호에 포함된 잡음을 제거하여 원 신호를 복원하는데 웨이블릿 변환이 효과적임을 보이고 있다. 또한 Robini 등[9]은 초음파 신호의 B-scan 영상에 대하여 이산 웨이블릿 변환의 일종인 웨이블릿 패킷 변환을 이용한 영상 처리를 수행함으로써 결합의 위치를 2차원 영상으로 나타내는데 성공하였다. 또 Wang과 McFadden[10]은 연속 웨이블릿 변환을 이용하여 기어 박스에서 발생하는 진동 신호를 해석하여 결합을 추적하고 있다. 이상의 연구들은 연속 웨이블릿 변환이나 이산 웨이블릿 변환 중의 하나만을 다루고 있으며, 웨이블릿 변환의 결과로 얻어지는 시간-주파수 분포를 해석하는 부분은 관찰에 의존하고 있다.

본 논문에서는 연속 웨이블릿 변환과 이산 웨이블릿 변환을 모두 사용하여 음향 방출 신호를 해석하고, 그 결과로 얻어지는 시간-주파수 평면에 나타난 분포의 특징값을 이용하여 인공지능망[11] 분류기를 설계하는 소프트웨어 패키지를 개발하여 신호의 분류를 자동화하였고, 연속 웨이블릿 변환과 이산 웨이블릿 변환의 두 가지 경우에 대하여 각각 설계된 분류기의 분류 성능을 검증 및 비교해 보았다.

본 연구에 사용된 신호 데이터는 스테인레스 강의 용접부 인공 결합에 의해 얻어진 음향 방출 신호[12]이다.

웨이블릿 변환은 그 방법에 따라 연속 웨이블릿 변환과 이산 웨이블릿 변환으로 나뉘어진다.

2. 웨이블릿 변환

2.1. 연속 웨이블릿 변환(CWT: continuous wavelet transformation)

연속 웨이블릿 변환은 웨이블릿의 샘플 데이터의 전 영역에 걸쳐 모든 데이터 포인트에 대해 shifting을 행하는 과정으로, 그 결과 매우 부드럽고 해상도가 높은 결과를 얻을 수 있다. 또한 scaling에서도 해상도를 높일 수 있다. 그러나, 해상도가 높은 반면에, 계산에 소요되는 시간이 길고 메모리의 소비량이 높은 경향이 있다.

시간 t 의 함수 $f(t)$ 의 웨이블릿 변환 [WT]은 다음 식으로 정의 된다.

$$[WT](a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (1)$$

식 (1)에서 보는 바와 같이 웨이블릿 변환의 결과인 웨이블릿 계수는 a, b 의 함수이며, a 는 주파수와 관련된 scaling으로 $a > 0$ 이고, b 는 시간 축에서의 shifting을 나타내며, $\overline{\psi}$ 는 기본 웨이블릿 ψ 의 복소공액을 나타낸다.

본 연구에서는 기본 웨이블릿으로서 다음 식과 같은 Gabor 함수를 사용한다.

$$\psi(t) = \frac{1}{\pi^{1/4}} \sqrt{\frac{\omega_0}{\gamma}} \exp\left(-\frac{(\omega_0/\gamma)^2}{2} t^2\right) \exp(i\omega_0 t) \quad (2)$$

여기에서 ω_0 는 기본 웨이블릿의 중심 주파수를 나타낸다.

Gabor 함수는 엄밀하게 말하면 기본 웨이블릿이 될 수 없지만, $\gamma = \pi\sqrt{2/\ln 2} \approx 5.336$ 으로 하여 근사적인 기본 웨이블릿으로 많이 사용된다.

2.2. 이산 웨이블릿 변환(DWT: discrete wavelet transformation)

이산 웨이블릿 변환은 원래의 신호로부터 높은 주파수 대역의 신호를 분리해내는 하이-패스 필터 (high-pass filter)와 낮은 주파수 대역의 신호를 분리해내는 로우-패

스 필터(low-pass filter)의 집합인 필터 बैं크(filter bank)로 구성된다. 필터 बैं크는 트리 구조(tree structure)를 가지며 로우-패스 필터를 통과한 신호가 다시 웨이블릿 변환되는 형식으로 구성된다.

일반적으로 신호의 특성을 결정짓고 신호를 다른 신호와 구별되게 하는 특징은 낮은 주파수 쪽에 있으므로 로우-패스 필터를 통과한 신호는 신호의 대체적인 특징을 나타내주는 근사신호(approximation)가 되며, 하이-패스 필터를 통과한 신호는 신호의 세부사항을 나타내는 세부신호(detail)가 된다.

본 연구에서는 이산 웨이블릿 변환을 위한 필터로서 Daubechies 16 필터[3]를 사용하였다.

한 단계(level)의 이산 웨이블릿 변환에서 입력신호로 2N개의 샘플 포인트를 가지는 신호를 입력하면, 그 출력은 N개의 샘플 포인트를 가지는 근사신호와 세부신호로 나뉘게 된다. 이러한 과정을 반복하게 되므로 단계가 높아질수록(주파수가 낮아질수록) 해상도가 낮아지게 된다. 이것은 해상도가 주파수에 무관하게 일정한 연속 웨이블릿 변환과의 차이점이며, 이러한 해상도의 차이 때문에 연속 웨이블릿 변환보다 계산량과 메모리 소비가 적다.

3. 실험방법

3.1. Artificial Neurons

인공 뉴런은 생물학적인 뉴런의 매우 간략화된 모델로서 개발된 것으로, 다른 뉴런들이나 외부환경으로부터 입력을 받는다. 뉴런을 연결하는 경로는 연결의 강도를 나타내는 가변량과 관계된다. 각각의 뉴런에는 문턱값과 활성화함수가 있다. 활성화함수는 입력의 합과 문턱값의 비교에 사용된다. 입력의 합이 문턱값을 넘게 되면 뉴런의 출력은 고위상태가 된다. 이 활성화함수에는 여러 가지가 있다. 가장 널리 쓰이는 오류역전파 인공신경망에서는 연속이고 미분가능한 함수가 필요하므로 시그모이드(sigmoid) 활성화함수가 사용된다.

주어진 입력에 대한 뉴런의 출력은 연결강도와 문턱값을 조정함으로써 제어될 수 있다. 인공신경망(ANN)은 이들 인공 뉴런들이 여러 가지 다양한 방법으로 연결된 것이며, 일반적으로는 feedforward network 알고리즘이 많이 사용된다.

3.2. Feedforward Networks

피드포워드 네트워크에서 신경단위(neural unit)들은 몇

개의 층(layer)로 나뉘어진다. 네트워크는 하나의 입력층(input layer), 하나 또는 그 이상의 은닉층(hidden layer), 하나의 출력층(output layer)으로 이루어진다. 하나의 층에 속한 뉴런들의 각각은 이웃한 층의 뉴런들의 각각과 완전히 연결되어야 하지만, 같은 층에 속한 뉴런이나 이웃하지 않은 층의 뉴런들과 연결되어서는 안 된다.

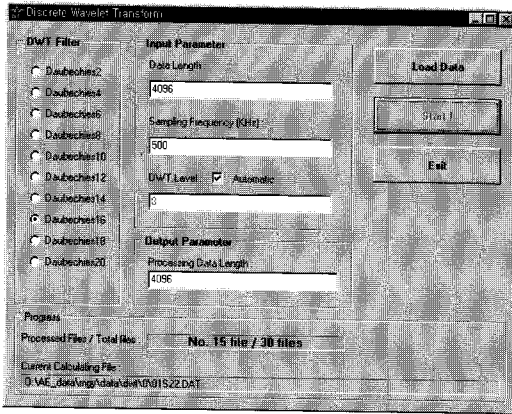
입력층에서 받아들인 입력정보는 은닉층을 거쳐 출력층으로 전달되며 정보는 연결강도와 문턱값의 형태로 분산화되어 저장된다. 처음에는 이 연결강도와 문턱값은 임의로 주어진다.

네트워크를 특정한 정보에 대해 학습시키려면 학습 예제(training example)를 준비하여야 한다. 학습예제는 입력 뉴런에 입력될 값과 그에 상응해 출력 뉴런에 배당될 값(입력에 대한 기대값)의 집합이다. 학습의 초기에는 연결강도와 문턱값이 임의로 배정되므로 학습예제의 입력을 네트워크에 입력하였을 때의 출력값과 기대값 사이에는 오차가 발생하며, 학습 알고리즘에 의해 연결강도와 문턱값을 조정함으로써 오차를 줄이는 것이 학습의 과정이다. 본 연구에서는 학습 알고리즘으로 오류역전파(error-backpropagation) 알고리즘을 사용하였다.

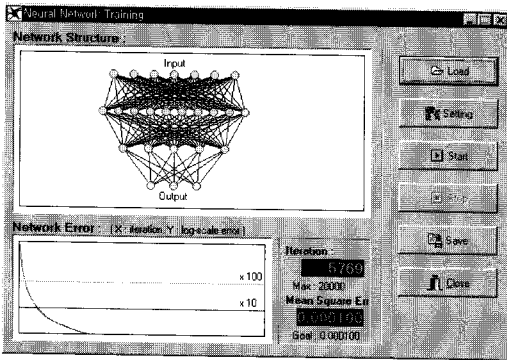
4. 응용 소프트웨어의 개발

본 연구를 위하여 실험에 의하여 얻어진 음향 방출 신호에 웨이블릿 변환을 적용하여 시간-주파수 분포를 구하고, 그로부터 추출된 특징값으로 인공 신경망을 학습하여 분류기를 설계하고 신호를 분류하는 일련의 작업을 수행하는 소프트웨어 패키지를 개발하였다. 이 소프트웨어 패키지는 MS-Windows 운영체제를 사용하는 환경에서 동작하며, GUI (graphic user interface) 방식으로 사용하기에 편리하도록 개발되었다. Fig. 1에 본 패키지의 핵심적인 두 부분의 작동 화면을 나타내었다. Fig. 1 (a)는 이산 웨이블릿 변환, Fig. 1 (b)는 인공 신경망을 학습하는 화면이다.

프로그램은 크게 5 부분으로 구성되어 있다. 첫 번째는, 웨이블릿 변환을 수행하는 부분으로 연속 웨이블릿 변환에는 Gabor wavelet을, 이산 웨이블릿 변환에는 Daubechies filter family를 사용하도록 프로그램하였다. 두 번째는 웨이블릿 변환의 결과인 시간-주파수 분포로부터 특징값을 추출하는 부분으로, 특징값은 시간-주파수 평면상에 도식한 웨이블릿 계수의 분포에 대한 기하학적 정보를 비롯하여 에너지 분포가 최대인 중심 주파수 대역에서의 시간 영역에 대한 파형 특성, 그리고 에너



(a) wavelet transform(discrete)



(b) neural network training

Fig. 1 Screens of developed software package

지 분포가 최대인 시간에서 주파수 영역에 대한 파형 특성 등을 고려하여 추출하였다. 이를 Table 1에 간략하게 정리하였다. 세 번째 부분은 추출된 특징값들 중에서 신호를 잘 분류할 수 있는 특징값을 선택하고 인공 신경망 학습을 위한 학습 예제를 생성하는 기능을 하며, Fisher's criterion, class mean scatter criterion, probability density plot, feature-feature plot, eigenvector analysis [13], 2-D criterion[14] 등 여러 가지 특징값 선택 방법을 사용할 수 있도록 하였다. 네 번째는 실제로 인공 신경망을 학습시켜 분류기를 설계하는 부분, 그리고 다섯 번째는 학습이 끝난 인공 신경망 분류기를 이용하여 신호를 분류하는 부분이다. Fig. 2에 그 개략적인 흐름을 도시하였다.

5. 실험

서로 다른 인공 결함으로부터 발생하는 AE 신호를 구

Table 1 Brief list of features

feature no.	features
1 - 18	geometric information of time-frequency distribution : location of peak, distance between peaks, average of intensity and variance of intensity etc.
19 - 36	time-related features at frequency : average, variance, skewness and kurtosis etc.
37 - 52	frequency-related features at time : frequency bandwidth, rise-slope and decay-slope etc

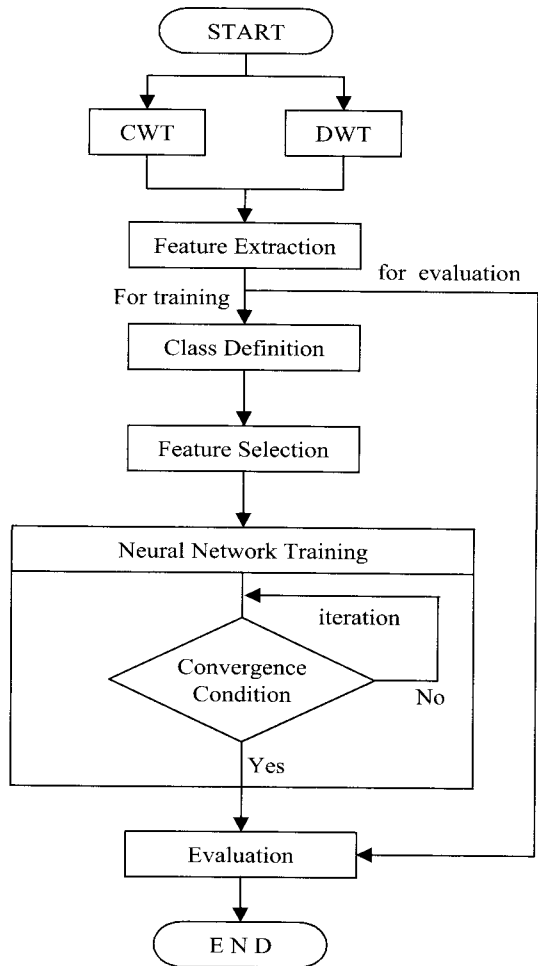


Fig. 2 Flowchart of classification using wavelet transform and neural network

분하기 위한 시편에 사용한 재료는 오스테나이트 계열의 SUS304이다. 이 재료에 아크 용접법을 사용하여 용접 시편을 제작하였는데, 용접이 이루어진 후 연삭기를 이용하여 양쪽 면을 약 2mm씩 잘라 내어 균일한 용접면을 이루도록 하였다. 또한 중앙 결합 부분에 집중 하중이 가해질 수 있도록 양쪽을 반지름 7.5mm로 모따기 하였다. 그 후 방전 가공을 이용하여 인공 결함의 종류에 따라 무결합 시편 1개, 구멍이 있는 용접 시편 1개, 노치가 있는 용접 시편 1개씩 모두 3개의 시편을 제작하였다. 이런 작업 후에 얻은 최종 인공 결함 시편의 형상은 Fig. 3 (a)~(c)에 나타나 있다. 제작된 시편은 만능 재료 시험기 (INSTRON, Model 1350, 10 ton)의 변위 제어방식으로 3점 굽힘 실험을 하였다. 3점 굽힘 실험 시 스패의 길이는 130mm로 하였고 인공 결함이 존재하는 부분이 아래의 중앙에 위치하도록 주의하였다. 센서는 용접부 결합의 위치에서 40mm 떨어진 부분에 센서의 중앙 부분이 위치하게 하였다. 최대변위의 2% 정도(1mm)로 변위를 제어하였다. 센서는 광대역 센서(broadband sensor, AET사의 FC 500, 200kHz~2MHz)를 사용하였다. 센서를 부착시킬 때에는 센서 부착 부위를 사포로 다듬고 커플러نت(couplant)를 칠한 다음 센서 고정용 스프링을 사용해 센서를 시편에 고정시켰다. 센서를 통해 나온 신호는






Fig. 3 Welding specimen with an artificial defect (a) no defect, (b) hole and (c) notch

30KHz ~ 2MHz 의 밴드 패스 필터(band pass filter)가 내장된 선 증폭기(pre-amplifier)에서 40dB 증폭된 후 주 증폭기(main amplifier)가 내장된 AET5500에서 다시 10%증폭된 후 디지털 오실로스코프로 들어가게 된다. 샘플링 주파수(sampling frequency) 500KHz로 신호당 4096개의 데이터를 받았으며, trigger level은 1.30V로 하고 5%의 pre-triggering을 취하였다.


각 시편으로부터 30개의 신호를 검출하였고 20개의 신호는 분류기 설계에, 나머지 10개 신호는 검증용으로 사용하였다.



(a) no defect



(b) hole



(c) notch


Fig. 4 Waveform of original signal

6. 실험결과 및 고찰


실험으로부터 얻어진 신호(Fig. 4)를 웨이블릿 변환하여 얻어진 시간-주파수 분포의 예를 Fig. 5 와 Fig. 6 에 나타내었다. Fig. 5는 연속 웨이블릿 변환에 의해 얻어진 시간-주파수 분포로, sampling point축은 시간축, scaling은 대수로 표현된 주파수축에 해당한다. 그림에서 보듯이 Gabor wavelet에 의한 연속 웨이블릿 변환의 결과는 항상 양의 값을 가진다. Fig. 6는 이산 웨이블릿 변환에 의한 시간-주파수 분포이며, level은 웨이블릿 변환의 단계를 나타내고 역시 주파수축을 의미한다. 이 경우, 연속

웨이블릿 변환과는 달리 양의 값만을 가지지는 않으며, 따라서 연속 웨이블릿 변환에서와 같은 에너지의 분포로 만들어 주기 위하여 제곱을 취하였다. 또한, 앞서 언급한 것처럼 연속 웨이블릿 변환의 경우가 훨씬 해상도가 높음을 알 수 있다.


이와 같은 웨이블릿 변환의 결과로부터 특징값을 추출하였으며, 추출된 특징값중에서 분류에 사용될 특징값을 선정하는데는 eigenvector analysis와 2-D criterion을 사용하였다. Eigenvector analysis에서는, Table 1에서 언급한 52 개의 특징값을 모두 사용하여, 이 52개의 특징값으로 이루어진 특징값 벡터에 대하여 eigenvector analysis



(a) no defect




(b) hole




(c) notch


Fig. 5 3-D view of time-frequency distribution of a signal by CWT (a) no defect (b) hole and (c) notch



(a) no defect



(b) hole



(c) notch

Fig. 6 3-D view of time-frequency distribution of a signal by DWT (a) no defect (b) hole and (c) notch

를 행하여 분류도가 좋은 순위에 따라 배열된 새로운 52개의 특징값 벡터를 만들어낸 후, 이 벡터로부터 상위 7개를 선정하였다. 그리고 2-D criterion에서는 2-D criterion을 적용하여 얻은 특징값의 순위로부터 상위 7개를 선정하였다.

이렇게 하여 선정된 특징값을 취합하고 각각의 특징값을 0에서 1사이로 정규화하여 인공신경망의 학습 예제로 하였다. 세 가지 종류의 각 결함에 대해 20개씩의 신호에서 추출한 특징값을 학습 예제로 하여 인공신경망 분류기를 설계하였다. 인공신경망은 7개의 입력층 단위, 2개의 은닉층에 각각 10개와 5개의 단위, 3개의 출력층 단위를 가지는 구조로 하였다. 입력층의 7개의 단위는 정규화된 특징값이 배당되며 출력층의 3 단위는 각각의 결함의 종류를 나타내는 것으로 결함의 분류군에 속하면 1, 속하지 않으면 0의 값을 가지도록 하였다. 수렴 조건은 평균 제곱오차(mean square error)가 0.0001 이하가 될 때로 하였고, 이 값에 수렴하지 않는 경우에는 iteration이 20000회를 넘어서는 경우로 하였다. 인공 신경망의 학습률은 0.1, momentum은 0.7로 하였다.

학습이 끝난 신경망의 성능을 평가하기 위하여, 각 결함 당 10개의 미학습 신호로부터 추출한 특징값을 입력하여 인공 신경망 분류기를 검증하였다. 이 결과를 Table 2, 3에 나타내었다. 연속 웨이블릿 변환에 기초한

인공 신경망 분류기는 eigenvector analysis의 경우에는 1개의 무결함 신호를 notch로 분류한 것을 제외하고 다른 모든 결함은 정확하게 분류하여 96.7%의 인식률을 보이고 있고, 2-D criterion을 적용한 경우에는 90%의 인식률을 보였다. 이산 웨이블릿 변환에 기초한 분류기는 eigenvector analysis와 2-D criterion의 경우 모두 73.3%의 인식률을 보였다.

연속 웨이블릿 변환에 의한 시간-주파수 평면상의 분포는 이산 웨이블릿 변환에 의한 것보다 훨씬 해상도가 높으므로 연속 웨이블릿 변환에 기초한 인공 신경망 분류기의 성능이 더 나은 것으로 나타났다. 비용적인 측면에서 계산시간을 고려해보면, 200MHz CPU와 64Mbyte RAM을 가진 PC에서 하나의 신호에 대해 웨이블릿 변환을 계산할 때, 연속 웨이블릿 변환에는 약 10분 정도가 소요되었으나, 이산 웨이블릿 변환에서는 약 2초 정도의 시간이 소요되어 시간, 비용적인 측면에서는 이산 웨이블릿 변환이 유리한 것으로 나타났다. 그러나 전체적인 성능면에서 보아 인공 신경망을 이용한 신호의 분류를 위한 시간-주파수 해석 도구로는 연속 웨이블릿 변환이 적합하다고 볼 수 있다. 또, eigenvector analysis 와 2-D criterion을 비교해 보면 eigenvector analysis에 의해 특징값을 선택하는 것이 인공 신경망 분류기의 성능이 더 좋을 수 있다.

Table 2 Evaluation result of CWT-based classifier for untrained data

	Estimated as			Recognition Rate	
	no defect	hole	notch		
no defect	9	0	1	9/10	96.7 %
hole	0	10	0	10/10	
notch	0	0	10	10/10	

(a) eigenvector analysis

Table 3 Evaluation result of DWT-based classifier for untrained data

	Estimated as			Recognition Rate	
	no defect	hole	notch		
no defect	9	0	1	9/10	73.3 %
hole	0	7	3	7/10	
notch	0	4	6	6/10	

(a) eigenvector analysis

	Estimated as			Recognition Rate	
	no defect	hole	notch		
no defect	9	0	1	9/10	90.0 %
hole	1	8	1	8/10	
notch	0	0	10	10/10	

(b) 2-D criterion

	Estimated as			Recognition Rate	
	no defect	hole	notch		
no defect	9	0	1	9/10	73.3 %
hole	0	7	3	8/10	
notch	1	3	6	10/10	

(b) 2-D criterion

7. 결 론

본 연구에서는 연속 및 이산 웨이블릿 변환을 이용한 시간-주파수 해석과 인공 신경망을 이용해 음향 방출 신호를 분류하는 소프트웨어 패키지를 개발하였다. 이 소프트웨어를 이용하여 용접부에 인공 결함을 가진 시편으로부터 검출한 음향 방출 신호를 분류해 본 결과, 다음과 같은 결론을 얻었다.

1. 연속 및 이산 웨이블릿 변환과 인공신경망을 이용한 신호 분류 소프트웨어 패키지를 이용하여 용접부 결함으로부터 검출된 신호를 그 결함의 종류에 따라 분류할 수 있었다.

2. 연속 웨이블릿 변환과 이산 웨이블릿 변환에 의한 분류 결과를 비교하였을 때, 인공 신경망을 이용한 음향 방출 신호의 분류에는 연속 웨이블릿 변환이 적합함을 알 수 있었다.

3. 특징값 선택에 있어 eigen vector analysis 방법과 2-D criterion 방법의 비교를 통해 웨이블릿 변환과 인공 신경망을 이용한 음향 방출 신호 분류에 있어서 eigen-vector analysis 방법이 2-D criterion 방법보다 좋은 결과를 주는 것을 알 수 있었다.

참고문헌

- [1] E. P. Serrano and M. A. Fabio, "Application of the Wavelet Transform to Acoustic Emission Signals Processing," *IEEE Transaction on Signal Processing*, Vol. 44, No. 5, pp. 1270-1275, (1996)
- [2] Gang Qi, Alan Barhorst, Javad Hashemi and Girish Kamala, "Discrete Wavelet Decomposition of Acoustic Emission Signals from Carbon-Fiber-Reinforced Composites," *Composite Science and Technology*, Vol. 57, pp. 389-403, (1997)
- [3] Mladen Victor Wickerhauser, *Adapted Wavelet Analysis from Theory to Software*, A K Peters, Ltd. (1994)
- [4] Raghuvver M. Rao and Ajit S. Bopardikar, *Wavelet Transforms*, Addison-Wesley Longman, Inc. (1998)
- [5] Gang Qi and Alan A. Barhorst, "On Predicting the Fracture Behavior of CFR and GFR Composites Using Wavelet-Based AE Techniques," *Engineering Fracture Mechanics*, Vol. 58, No. 4, pp. 363-385, (1997)
- [6] Hiroaki Suzuki, Tetsuo Kinjo, Yasuhisa Hayashi, Mikio Takemoto and Kanji Ono, "Wavelet Transform of Acoustic Emission Signals," *Journal of Acoustic Emission*, Vol. 14, No. 2, pp. 69-84, (1996)
- [7] Charles K. Chui, *An Introduction to Wavelets*, Academic Press, Inc. (1991)
- [8] Agostino Abbate, Jeff Koay, Julius Frankel, Stephan C. Schroeder and Pankaj Das, "Signal Detection and Noise Suppression Using a Wavelet Transform Signal Processor: Application to Ultrasonic Flaw Detection," *IEEE Transaction on Ultrasonics, Ferroelectrics, and Frequency Control*, Vol. 44, No. 1, pp. 14-25, (1997)
- [9] Marc C. Robini, Isabelle E. Magnin, Hugues Benoit-Cattin and Atilla Baskurt, "Two-Dimensional Ultrasonic Flaw Detection Based on the Wavelet Packet Transform," *IEEE Transaction on Ultrasonics, Ferroelectrics, and Frequency Control*, Vol. 44, No. 6, pp. 1382-1394, (1997)
- [10] W. J. Wang and P. D. McFadden, "Application of Wavelets to Gearbox Vibration Signals for Fault Detection," *Journal of Sound and Vibration*, Vol. 192, No. 5, pp. 927-939, (1996)
- [11] Granino A. Korn, *Neural Network Experiments on Personal Computers and Workstations*, A Bradford Book (1991)
- [12] 이강용, 임장묵, 김준섭, "적응형 신호형상 인식프로그램의 개발과 AE법에 의한 용접부결함 분류에 관한 적용 연구", *비파괴검사학회지*, 제 16 권, 제 1호, pp. 34-45, (1996)
- [13] Christopher Chatfield and Alexander J. Collins, *Introduction to Multivariate Analysis*, Chapman and Hall (1980)
- [14] 이강용, 황인범, "신경망 AE신호 신호형상 인식법을 위한 특징값 선택법의 개발과 용접부 및 회전체 결함 분류에의 적용 연구", *비파괴검사학회지*, 제 21 권 제 1 호, pp. 46-53, (2001)