

구조물의 품질 결함 변별력 증대를 위한 수직 에너지 기반의 웨이블릿 Feature 생성

김준석* · 정 육**†

* 세종대학교 경영학과

** 동국대학교 경영학과

Structural Quality Defect Discrimination Enhancement using Vertical Energy-based Wavelet Feature Generation

Joon-Seok Kim* · Uk Jung**†

* Department of Business Administration, School of Business, Sejong University

** Department of Management, School of Business, Dongguk University

Key Words : Class separability, Damage detection, Feature generation, Fourier transform, Wavelet transform

Abstract

In this paper a novel feature extraction and selection is carried out in order to improve the discriminating capability between healthy and damaged structure using vibration signals. Although many feature extraction and selection algorithms have been proposed for vibration signals, most proposed approaches don't consider the discriminating ability of features since they are usually in unsupervised manner. We proposed a novel feature extraction and selection algorithm selecting few wavelet coefficients with higher class discriminating capability for damage detection and class visualization. We applied three class separability measures to evaluate the features, i.e. T test statistics, divergence, and Bhattacharyya distance. Experiments with vibration signals from truss structure demonstrate that class separabilities are significantly enhanced using our proposed algorithm compared to other two algorithms with original time-based features and Fourier-based ones.

1. 서 론

장기간의 수명을 가진 우수한 품질의 공학 구조물(예를 들면 교량, 건물, 기계 등등)에 대한 시대적 요구와 함께 구조물의 결함여부를 측정하는 것은 지난 수십 년 간 매우 중요한 연구의 주제가 되어왔다. 대부분의 공학 구조물들은 그들의 정상적인 운용 환경 속에서 예기치 않은 파로누적에 의한 균열, 온도의 변화, 충격, 과도한 하중, 그리고 침식 등의 내, 외부 결함요인들에 쉽게

노출되어 진다. 과도하게 손상당한 사회기반 구조물의 수리 및 운용 정지 시간에 소요되는 과도한 관리비용은 구조물 결함여부의 조기 탐지 및 진단의 중요성을 크게 인식시켜 왔다. 그러나 가장 오래되고 기본적인 결함여부의 탐지 방식인 직접 가시조사(visual inspection) 방식은 인간이 직접 접근할 수 있는 영역에만 국한되었고 이마저도 특정한 상황(예를 들면 우주정거장이나 위험한 환경에서의 구조물 등)에서는 사용이 매우 제한된 방식이었다. 이러한 이유로 인해 구조물의 진동 특성(vibration characteristics) 측정을 이용한 구조물의 모니터링 시스템들이 최근 주의를 끌기 시작 했다[11][12].

많은 진동 기반의 결함 탐지 방법들은 주로 구조물의

† 교신저자 ukjung@dongguk.edu

※ 본 연구는 2006년도 동국대학교 신임교원 정착연구비 지원으로 이루어졌음.

강도(stiffness)나 질량의 변화에 기인한 주파수와 같은 모우드 모수(modal parameter)의 동적 특성 변화를 활용하고 이를 통해 인간의 물리적 접근 없이 원격 혹은 간접적으로 구조물의 강건함을 측정한다. 그러나 진동 기반 방법론에서의 주요 난관은 시그널의 특성상 관찰해야하는 변수의 수가 너무 많고 작은 크기의 구조적 결합에 대해 모우드 속성 변화의 민감도가 떨어진다는 것이다[13]. 구조물의 손상이 심각한 상황에 이르기까지는 결합에 의한 모우드 속성의 변동을 잘 구분해내는 것은 어려운 일이다.

본 연구의 목적은 분석 대상인 변수의 수를 줄이고 모우드 속성 변화에 민감한 feature들을 찾아내는 것이다. Feature는 일종의 확률변수로 취급된다. Feature의 추출과 선택(우리는 본 연구에서 이들을 ‘feature 생성’이라고 부른다.)은 의사결정 단계에서 사용되는 속성이나 차원의 수를 감소시키는 매우 중요한 단계이다. Feature 생성은 패턴인식, 통계학, 그리고 데이터마이닝 분야의 매우 활발한 연구 분야로 자리 잡아 왔다. Feature 생성의 주된 아이디어는 원형의 데이터를 다른 형태의 feature들로 변환시키고 예측을 위한 정보력이 떨어지는 feature들을 제거함으로써 투입변수의 부분집합을 선택하는 것이다[3][6]. 이는 분류기(classifier) 모델의 가해성(comprehensibility)을 향상시키고 발견되지 않은 데이터에 대해 보다 일반화된 모델을 구축하는데 도움을 준다. 예측을 위한 정보와 관련이 깊은 feature들은 분류문제에 도움을 주는 반면 그렇지 않은 feature들은 분류기의 성능을 저해할 수 있다. 보다 많은 feature들을 사용할수록 보다 많은 훈련 데이터(training data)를 필요로 하게 됨으로 예측정보와 관련이 깊은 feature들을 선택하는 것은 분류문제에서 매우 중요한 단계이다[4]. 이것은 feature의 수가 샘플 시그널들의 수보다 월등히 많은 구조물 결합 진단문제에서의 진동 반응치를 구분하는 과제에서는 특히 강조된다. 시그널 분류문제에서의 예측 정보와 관련이 깊은 feature라 함은 각각의 시그널의 독특한 특성들을 추출하여 특성이 다른 군집들 간의 변별력이 높은 feature들을 의미한다.

결합 탐지문제에 사용되는 대부분의 방법들은 푸리에 변환(Fourier transform[1], FT)의 활용에 기반을 두고 있다. FT는 하나의 시그널을 여러 다른 주파수를 지닌 사인곡선들의 조합으로 분해하는 것을 말한다. 결국 FT는 시간 도메인에서 표현된 하나의 시그널을 주파수 도메인에서의 표현방식으로 변환시키는 것으로

그 변환과정에서 시간의 정보를 소실하여 언제 특정 사건(시그널의 변화)이 발생했는지를 알 수 없게 만드는 단점을 가지고 있다. 이러한 단점을 어느 정도 보완하기 위하여 short-time Fourier transform(STFT)로 발전된 창 기법(windowing technique)의 활용을 사용하기도 하나 이는 여전히 시간과 주파수에 대한 정보가 창의 크기에 의해 제한된 정밀도를 가질 수밖에 없다는 스스로의 한계점을 가지고 있다. 최근 대안으로 떠오른 방식이 웨이블릿(wavelet)을 활용하는 것이다[10]. 웨이블릿 분석은 시간 도메인의 한 시그널을 시간-주파수 도메인으로 옮기는 것으로 STFT의 단점을 보완하여 고주파 영역에서는 시간 정보의 정밀함을, 저주파 영역에서는 주파수 정보의 정밀함을 추구하는 방법이다. 웨이블릿 활용의 주된 장점은 시그널의 돌출(spike)과 같은 지협적인 정보의 분석이 가능하고 유한한 간격에서 표현될 수 있다는 것이다. 그러므로 이는 불연속점들(discontinuities)을 포함한 시그널을 표현하고 근사시키는 데 적합하다. 이 특성은 특히 진동 시그널에서의 결합탐지 응용문제에 매우 중요한 속성이다. 게다가 고속변환이 가능하여 시그널의 변환에 소요되는 계산 노력을 감소시켜 준다. 이러한 장점들로 인하여 웨이블릿 변환은 결합탐지 및 모니터링을 위한 매우 강력한 도구로 최근 인식되고 있다. 진동 시그널에서의 결합 관련 속성들과 시간-주파수 특징들을 보여주는 웨이블릿 기반의 연구들을 Law[7], Li[8], 그리고 Li, Deng, and Dai[9]등에서 찾아볼 수 있다.

대부분의 웨이블릿을 활용한 feature 생성 알고리즘들은 훈련 데이터가 가지는 정보를 활용하지 않는 unsupervised 방식으로 구분될 수 있다. 분류 문제에서 훈련 데이터로부터의 정보를 활용하는 supervised feature 생성은 unsupervised feature 생성에 비해 보다 나은 성능을 가져온다고 보는 것이 일반적이다. 본 연구에서 우리는 군집간의 변별력이 높은 소수의 웨이블릿 계수들을 선택하는 새로운 feature 생성 방식을 제안한다. 이를 위해 시그널 내에 포함된 측정 잡음(noise)을 제거하고 다수 시그널들의 현저한 특징들을 잘 나타내는 공통의 feature를 선택하기 위해 수직에너지 임계법(vertical-energy based thresholding, VET) [5]을 사용하여 선택된 웨이블릿 계수들을 feature로 정의한다. 그리고 각 feature들의 군집 간 변별력 측정을 위해 T test statistics, divergence, 그리고 Bhattacharyya distance의 세 가지 기준을 사용한다. 결국 우리는 가장 높은 군집 변별력을 가지는 소수의

웨이블릿 계수들을 선택하게 된다. 그리고 본 연구에서 제안된 방식이 군집간의 현저한 변별력의 증가를 가져옴을 기준의 다른 방법들과의 비교를 통해 제시한다.

본 연구의 구성은 다음과 같다. 먼저 제 2절에서 웨이블릿 변환과 수직 에너지 임계법(VET)에 대해 간략히 요약하고 기준의 방식과의 비교를 위한 퓨리에 변환(FT)에 대해서도 요약한다. 제 3절에서는 군집 간 변별력 구분의 여러 기준들에 대해 논하고 본 연구에서 제시하는 feature 생성 알고리즘을 소개한다. 제 4절에서는 트러스 구조물(truss structure)의 결합 탐지 실험의 소개와 결과, 그리고 논의 사항들에 대해 설명한다. 마지막으로 제 5절을 통해 본 연구의 주요 학문적 기여 및 향후 연구방향에 대해 논의하면서 본 논문을 마무리 한다.

2. 진동 시그널의 feature 추출을 위한 웨이블릿 변환과 퓨리에 변환

2.1 이산형 웨이블릿 변환과 수직에너지 임계법

2.1.1 이산형 웨이블릿 변환

이 장에서는 웨이블릿 변환[10]의 이론적인 배경을 간략하게 소개한다. 이산형 웨이블릿 변환(discrete wavelet transform, DWT)은 시간 영역에서 표현된 한 시그널을 시간-주파수 영역으로 변환시킨다. DWT는 여러 주파수의 해상도를 가진 다양한 레벨에서 수행되고 각 레벨의 변환은 수행됨에 따라 시간의 해상도는 감소하고 이에 상응하여 주파수의 해상도는 증가하게 된다. 제곱적분 가능한 실함수의 공간 L_2 에서 정의되는 시간 영역의 시그널 $f(t)$ 를 위한 DWT는 전이 가능한 스케일링 함수(scaling function) $\phi(t)$ 와 전이 및 팽창 가능한 모웨이블릿 함수(mother wavelet function) $\psi(t)$ 로 아래와 같이 표현된다.

$$f(t) = \sum_{k \in Z} c_{L,k} \phi_{L,k}(t) + \sum_{j \geq L} \sum_{k \in Z} d_{j,k} \psi_{j,k}(t)$$

여기서 $d_{j,k}$ 는 웨이블릿 계수를, $c_{L,k}$, $L < J$ 는 스케일링 계수를 나타낸다. 이들 계수들은 $c_{L,k} = \langle f(t), \phi_{L,k}(t) \rangle$ 그리고 $d_{j,k} = \langle f(t), \psi_{j,k} \rangle$ 와 같은 L_2 에서의 내적(inner product)으로 계산된다.

여기서 $\phi_{L,k}(t) = 2^{L/2} \phi(2^L t - k)$; $k \in Z$ 는 스케일링

함수의 집합체(family)이고 $\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k)$; $j \geq L$, $k \in Z$ 는 웨이블릿 함수의 집합체로서 이들 모함수들의 올바른 선택은 이들 집합체가 시그널 공간을 위한 직교정규(orthogonal basis)를 구성하도록 한다.

등 간격을 이루고 $i = 1, 2, \dots, M$ 및 양의 정수인 J 로 표현되는 $N = 2^J$ 개의 요소들로 이루어진 벡터 $y_i = [y_{i1}, y_{i2}, \dots, y_{iN}]$ 를 정의하자. 그리고 어깨글자(superscript) T 를 transpose operator를 나타낸다고 할 때 $\mathbf{Y} = [y_1, y_2, \dots, y_M]^T$ 는 M 개의 다수 시그널들을 나타내는 행렬이 된다. 이산형 웨이블릿 변환(DWT) \mathbf{W} 가 행렬 $\mathbf{Y} = [y_1, y_2, \dots, y_M]^T$ 에 적용될 때 이 변환을 통해 얻어지는 웨이블릿 계수의 행렬은 $\mathbf{D} = \mathbf{WY}$ 가 된다. 여기서 \mathbf{D} 는 $\mathbf{D} = [d_1, d_2, \dots, d_M]^T$, $d_i = [d_{i1}, d_{i2}, \dots, d_{iN}]$ 로 표현되며 d_{im} 는 i 번째 시그널을 위한 m 번째 웨이블릿 위치에서의 웨이블릿 계수를 의미한다.

2.1.2 수직 에너지 임계법

이미 서론에서 언급한 것과 같이 적절히 선택된 feature들은 분류기의 가해성을 높이고 추가적인 데이터들에 대해 보다 나은 일반화된 모델을 생성하는데 도움을 준다. 이러한 목적을 달성하기 위해 우리는 먼저 데이터의 수정된 혹은 변형된 feature들의 적절한 부분집합을 선택해야 한다; 즉 좋은 부분집합은 어떤 분류기 모형이 사용되는지에 상관없이 데이터의 특성들과 상관관계가 높아야 하고 반면 이들 feature들끼리는 가능하면 서로간의 상관관계가 낮아야 한다. 이러한 특화된 몇몇 feature들을 선택하는 것은 데이터의 차원을 감소시키고 이로 인해 후속 분석과정에서의 계산 비용을 낮추게 되며 데이터에 포함되어 있는 잡음을 감소시키게 된다. 이것이 우리가 웨이블릿 변환을 본 연구에서 고려하는 이유이다.

본 연구에서는 feature 추출의 수단으로 수직 에너지 임계법(vertical-energy based thresholding, VET) [5]을 사용한다. 대부분의 다른 웨이블릿 분석에서의 임계법들은 단순히 단일 시그널만을 다루고 있다. 그러므로 그들은 각각의 단일 시그널의 독립적 패턴에 의해 결정되는 선택된 웨이블릿 계수들을 얻게 되고 다수의 시그널을 대표하는 공통된 웨이블릿 계수를 선택하는 데 문제가 생긴다. 웨이블릿 분석에서의 임계법에 대한 보다 자세한 내용은 Antoniadis et al.[2]의 연구를 참조하기 바란다.

이 문제와 관련하여 VET feature 추출은 다수 시그

널들을 동시에 다루기 위해 아래와 같은 수직 에너지 측정치를 사용한다.

$$\|\mathbf{d}_m^v\|^2 = d_{1m}^2 + d_{2m}^2 + \cdots + d_{Nm}^2, \quad m = 1, 2, \dots, N$$

즉 수직 에너지 측정치는 m 번째에 위치한 모든 다수 시그널들의 웨이블릿 계수들의 제곱합을 의미한다. 결국 VET feature 추출은 다음과 같은 임계값 λ_{NM} 보다 큰 수직 에너지를 가지는 i 번째 웨이블릿 계수들을 선택하게 된다.

$$\lambda_{NM} = \sum_{m=1}^N E(\|\mathbf{d}_m^v\|^2) / N.$$

이 VET feature 추출은 데이터 축소의 효율과 시그널 복원시의 에러율을 함께 고려한 다수 시그널을 위한 방식으로 다수 시그널의 대표적 패턴을 잘 유지하면서 시그널들의 잡음을 제거하는데 효율적인 방식이다. VET에 관한 보다 자세한 사항 및 증명은 Jung et al[5]를 참고하기 바란다. 이렇게 선택된 소수의 웨이블릿 계수들은 추후 의사 결정 과정에서의 축소된 데이터로서 사용된다. 이들 축소된 웨이블릿 계수들은 제 3절에서의 feature 선택 과정에서 투입 feature로서 사용된다.

2.2 고속 푸리에 변환과 Power Spectrum Analysis

본 연구에서 제시된 방법과의 비교를 위해 이 절에서는 푸리에 변환(Fourier Transform, FT)에 대한 간략히 소개한다. 현대 계산 기술의 발전과 함께 푸리에 변환의 수행은 매우 널리 사용되고 있으며 대부분 고속 푸리에 변환(Fast Fourier Transform, FFT)[1]의 형식을 다루고 있다. FT는 많은 진동 시그널의 분석을 위한 기본적인 도구로 사용되고 있다.

시간 영역에서의 함수 $f(t)$ 의 FT는

$$G(w) = \int_{-\infty}^{\infty} f(t) e^{-iwt} dt$$

로 정의되고 그 역함수는

$$f(t) = \frac{1}{2\phi} \int_{-\infty}^{\infty} G(w) e^{-iwt} dw$$

이다. 그리고 FFT는 이산형 푸리에 변환(DFT)의 고속

알고리즘으로

$$X(k) = \sum_{j=1}^N x(j) w_N^{(j-1)(k-1)}$$

로 표현되며 여기서 $w_N = e^{(-2\pi i)/N}$ 는 N th root of unity이다.

FFT는 시간 영역에서의 시그널을 주파수 영역의 시그널로 변환시키기 때문에 N 은 표면 주파수 단위의 개수를 나타낸다.

본 연구에서는 $N=512$ 개의 주파수 단위 개수를 사용하고 power spectrum, 즉, 각 주파수에서의 power의 측정치, 를 사용한다.

이 power spectrum은 다음과 같이 표현된다.

$$P_{yy} = X(k) * \text{conj}(X(k)) / N.$$

이들 각 주파수 단위에서의 power가 제 3절에서의 feature 선택 단계에서 투입 feature로 사용되고 제 4절에서 본 연구의 제안 방법과 비교 분석 될 것이다.

3. 제안 알고리즘과 다양한 군집 변별력 측정치

제 2절에서 생성된 투입 feature들은 여러 측정 기준을 통하여 군집간 변별력의 관점에서 평가된다. 군집간 변별능력이 있는 소수의 웨이블릿 계수들을 선택하는 웨이블릿 VET 기반의 feature 생성 알고리즘이 Algorithm 1에 묘사되어 있다.

알고리즘의 투입변수로는 다수 진동 시그널의 집합 $\mathbf{Y} = \{\mathbf{y}_1, \dots, \mathbf{y}_M\}^T$, 정상/비정상 구조물 소속 인덱스 $I = \{I_1, \dots, I_M\}$ (여기서 $I_i = \{0, 1\}$; 정상 구조물일 경우는 0, 결함이 있는 구조물인 경우는 1), 그리고 희망하는 feature의 차원 수 k 가 된다. 먼저 알고리즘은 웨이블릿 변환 $\mathbf{D} = \{\mathbf{d}_1, \dots, \mathbf{d}_M\}^T$, $\mathbf{d}_i = \{d_{i1}, \dots, d_{iN}\}$ 를 계산하여 수직 웨이블릿 계수 행렬 $\mathbf{D}^v = \{\mathbf{d}_1^v, \dots, \mathbf{d}_N^v\}^T$, $\mathbf{d}_i^v = \{d_{i1}, \dots, d_{iN}\}^T$ 를 형성한다. 그리하여 수직 에너지 측정치가 λ_{NM} 보다 큰 \mathbf{d}_i^v 들을 선택하여 축소된 크기의 웨이블릿 계수의 집합인 S 를 구성하고 군집 간 변별력 측정치인 $M^{(i)}$ 를 기준으로 선택된 웨이블릿 feature들을 S 안에서 정렬한다.

본 논문에서는 $M^{(i)}$ 을 위해 T test statistics, di-

vergence, 그리고 Bhattacharyya distance의 세 가지 측정치를 사용한다. 그리하여 S 로부터 가장 높은 $M^{(i)}$ 를 가지는 k 개의 \mathbf{d}_i^v 들을 선택하여 최종 선택된 feature로서 사용하게 된다. 이제까지 설명된 feature 생성 알고리즘을 pseudo-code 형식으로 Algorithm 1에 요약하였다.

Algorithm 1. Wavelet VET-based feature generation algorithm

```

Input: a set of vibration signals  $\mathbf{Y} = \{\mathbf{y}_1, \dots, \mathbf{y}_M\}^T$ ,
       a set of membership index  $I = \{I_1, \dots, I_M\}$  where
        $I_i = \{0, 1\}$ ; 0 for healthy and 1 for damaged
       structure, and the desired feature dimension-
       ality  $k$ .
Compute the wavelet transform  $\mathbf{D} = \{\mathbf{d}_1, \dots, \mathbf{d}_M\}^T$ 
       where  $\mathbf{d}_i = \{d_{i1}, \dots, d_{in}\}$ ;
Set the vertical wavelet coefficient feature ma-
       trix  $\mathbf{D}^v = \{\mathbf{d}_1^v, \dots, \mathbf{d}_N^v\}$  where  $\mathbf{d}_i^v = \{d_{1i}, \dots, d_{Mi}\}^T$ ;
 $\forall \mathbf{d}_i^v \in \mathbf{D}^v$ , compute the wavelet vertical energy
 $\|\mathbf{d}_i^v\|^2 = d_{1i}^2 + d_{2i}^2 + \dots + d_{Mi}^2$ ;
Compute  $\lambda_{NM} = \sum_{m=1}^N E(\|\mathbf{d}_m^v\|^2) / N$ ;
 $S \leftarrow \text{Empty}$ ;
for  $i = 1$  to  $N$  do
  if  $\|\mathbf{d}_i^v\|^2 \geq \lambda_{NM}$  then
     $S \leftarrow S \cup \mathbf{d}_i^v$ 
  end if
end for
 $\forall \mathbf{d}_i^v \in S$ , compute the class separability measure
 $M^{(i)}$ ;
Sort  $S$  with respect to  $M^{(i)}$  in descendent order;
 $F \leftarrow \text{Empty}$ ;
for  $i = 1$  to  $k$  do
   $F \leftarrow F \cup \mathbf{d}_i^v$ 
end for
Output: the feature set  $F$ .

```

다음은 군집 간 변별력 측정의 세 가지의 다른 기준인 T 검정량, divergence, 그리고 Bhattacharyya distance에 대한 간단한 소개이다.

3.1 T 검정량 (T test statistics)

통계적 가설 검정은 개별 feature들의 변별력을 측정하는 가장 흔한 기법 중 하나로서 두 가설이 형성된다. 즉 “군집 간 feature들의 값들이 유의하게 다르지 않다”를 의미하는 귀무가설 H_0 와 “군집 간 feature들의 값들이 유의하게 다르다”를 의미하는 대립가설 H_1 가 그것이다. 이러한 가설들은 샘플들로부터 가용한 통계적 정보를 활용하는 실험적 증거들을 통해 검정되는데 이때 결론은 통계적 에러의 유의수준에 의해 결정된다.

확률변수 x 의 측정치가 샘플을 통해 주어져 있을 때 미지의 모수 θ 를 포함한 확률밀도함수가 알려져 있다고 가정하자. 가설 검정 과정은 다음과 같은 두 가설을 구성하는 것으로부터 시작된다.

$$H_0 : \theta = \theta_0, \quad H_1 : \theta \neq \theta_0$$

통계량으로 사용될 함수 $g(\cdot)$ 가 선택되면 모든 가용한 측정치의 벡터 x_1, x_2, \dots, x_n 들을 사용하여 $g(\cdot)$ 을 추정한다.

$$M_q = g(x_1, x_2, \dots, x_n)$$

이렇게 구해진 확률변수 M_q 는 검정량(test statistics)로 사용된다. 함수 $g(\cdot)$ 는 검정량의 확률밀도 함수 $f_{M_q}(M_q; \theta)$ 가 미지의 모수 θ 에 의해 쉽게 모수화(parameterization)되도록 선택되어진다. 대부분의 경우 한 feature의 평균과 분산이 다른 군집들의 구분을 위해 검정된다. 대립가설의 기각은 해당 feature가 어떤 변별력도 가지고 있지 않아 이로 인해 분류과정에서 생략될 수 있다는 것을 의미한다. (H_0 가 군집 간 구분이 되지 않는다는 것을 의미함을 상기하라.) 각 샘플이 군집 A 혹은 B 에 소속되어 있다고 가정하면 이때 검정량 M_q 는 다음과 같이 주어진다.

$$M_q = \frac{|\mu_A - \mu_B|}{\sqrt{\frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}}}$$

여기서 n_i 는 군집 I 에 속한 샘플들의 개수를 의미한다. 결국 검정량 M_q 가 가장 큰 값을 가지는 feature들이 가장 변별력이 있는 feature들로 인식되어 진다.

3.2 Divergence

두 군집 A 과 B 를 구분하는 분류문제를 고려하자. 이 경우 두 군집 간 변별력의 측정치는 두 확률밀도함수의 비율로 표현된 다음식과 관련이 있다.

$$\ln \frac{f(x|A)}{f(x|B)}$$

그러면 군집 A 에 대한 위 비율의 기댓값은

$$D_{AB} = \int_{-\infty}^{\infty} f(x|A) \ln \frac{f(x|A)}{f(x|B)} dx$$

로 정의되며 유사하게 군집 A 에 대한 군집 B 의 변별정보는

$$D_{BA} = \int_{-\infty}^{\infty} f(x|B) \ln \frac{f(x|B)}{f(x|A)} dx$$

로 정의된다.

$\ln(1) = 0$ 이므로, 두 군집 A 와 B 가 완전히 중첩되었을 때 위 적분 값들은 영의 값을 갖는다. D_{AB} 와 D_{BA} 의 합은 divergence로 알려진 아래와 같은 두 군집 A 와 B 간의 변별 측도를 생성한다.

$$M_d = D_{AB} + D_{BA} = \int_{-\infty}^{\infty} (f(x|A) - f(x|B)) \ln \frac{f(x|A)}{f(x|B)} dx$$

그러므로 divergence M_d 가 가장 큰 값을 갖는 feature들이 이 기준상의 가장 변별력이 높은 feature들이 된다.

3.3 Bhattacharyya distance

또 다른 군집 간 변별 측도는 Bhattacharyya distance가 있다. 이는 일반적인 다변량 형식으로는

$$Bhat = \frac{1}{8} (\mu_A - \mu_B)^T \left(\frac{\Sigma_A + \Sigma_B}{2} \right)^{-1} (\mu_A - \mu_B) + \frac{1}{2} \ln \frac{|\Sigma_A + \Sigma_B|}{\sqrt{|\Sigma_A||\Sigma_B|}}$$

로 표현되며 일변량 공간상에서 두 군집간의 거리는 각 군집의 평균과 분산을 이용하여 다음과 같은 M_b 의 형

식으로 표현된다.

$$M_b = \frac{1}{4} \left\{ \frac{(\mu_A - \mu_B)^2}{\sigma_A^2 + \sigma_B^2} \right\} + \frac{1}{4} \ln \left\{ \frac{1}{4} \left(\frac{\sigma_A^2}{\sigma_B^2} + \frac{\sigma_B^2}{\sigma_A^2} + 2 \right) \right\}$$

이 경우 역시 Bhattacharyya distance M_b 가 가장 큰 값을 가지는 feature들이 가장 변별력이 있는 feature들로 인식된다.

이상 소개된 군집 간 변별력 측정의 세 가지의 다른 기준에 대한 보다 자세한 사항은 Duda[3]를 참고하기 바란다.

4. 트러스 구조물에서의 결합여부 탐지 실험사례

본 장에서는 제안된 feature 생성 방법의 결과를 검증하기 위한 실험인 트러스 구조물의 수리적 모델과 시뮬레이션 데이터의 특성을 설명한다. 본 연구에서 제안된 방법은 트러스 구조물의 강도 손상 여부를 파악하는데 초점을 맞춘다.

본 연구에서 사용된 구조물 시스템은 <Figure 1>에서 묘사된 8-bay 평면골조 트러스 구조물이다. 이 구조물은 2개의 횡가새(cross-brace)를 가진 4m 길이의 알루미늄 구조물로서 지주(strut)는 2cm의 직경을, 각 bay의 길이는 0.5m이다. 그럼에서와 같이 한쪽 끝이 벽면에 고정된 횡날개 구조를 지닌 이 트러스 구조물의 A 지점에 가우시안 랜덤 노이즈(Gaussian random noise)를 가진 진동 자극을 가하고 구조물 시스템의 반응으로써 S 지점에서 화살표 방향의 시간에 따른 변위를 측정하였다. <Figure 1>은 또한 본 연구에서 제안하는 방법에 의해 탐지될 결합의 위치(E1과 E2)를 표시하였다. 결합의 정도를 시뮬레이션 함에 있어 E1과 E2 지점에 각각 50%의 강도를 기준으로 가우시안 분포를 따르는 10%의 랜덤한 강도 파라메터의 변동과 SNR 비율(signal to noise ratio)=3을 가진 측정 잡음을 매 각각의 결합 지점에 대하여 70회의 시뮬레이션마다 입력하였다. 이와 같은 시뮬레이션을 통해 약 8초 동안 1000Hz의 비율로 샘플 데이터를 생성하였다. 이러한 조치는 결합 정도의 불확실성에 대한 강건함을 살펴보기 위한 것이다.

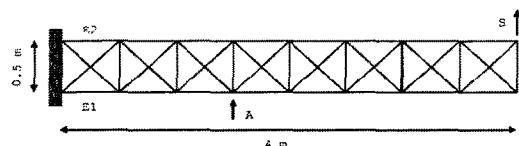
<Figure 2>는 세 다른 속성의 구조물, 즉, 정상, type 1(E1 지점의 결함), 그리고 type 2 (E2 지점의 결함)에서의 대표적 샘플 진동 시그널의 예를 보여주고 있다.

본 연구에서 제안된 방법의 성능을 평가하기 위하여 다음과 같은 세 다른 종류의 실험을 설계하였다.

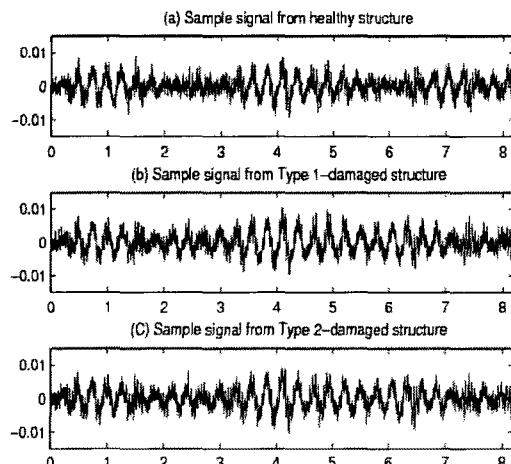
Case 1: type 1 결함 시그널과 정상 시그널간의 구분

Case 2: type 2 결함 시그널과 정상 시그널간의 구분

Case 3: 모든 종류(type 1 and 2)의 결함 시그널과 정상 시그널간의 구분



<Figure 1> Schematics of 8-bay planar truss structure



<Figure 2> Time-history response from sensor(S) in the truss structure; (a) healthy condition, (b) damage type 1, (c) damage type 2

결국 본 실험에서 제안된 feature 생성 방법은 시그널들의 정상/비정상 여부를 구분하기 위하여, 그리고 이차원 공간상에서 군집들을 변별력 있게 가시화(visualization)시키기 위해 가장 정보력이 높은 두 feature를 변형과 선택과정을 통해 찾아내어야 한다.

<Table 1>, <Table 2>, 그리고 <Table 3>은 정상/비정상 군집 간의 2D 평면에서의 가시화에 사용된 두 개의 feature들을 원형 시간 기반, FFT power spectrum 기반, 그리고 웨이블릿 VET 기반의 feature들을

통해 찾아내고 그들의 변별력 측정치들을 각각 나태내고 있다.

본 실험의 결과는 웨이블릿 기반의 feature들이 다른 두 기반의 feature들에 비해 트러스 구조물의 정상/비정상 여부를 구분하는데 보다 우수한 역할을 하고 있음을 보여준다.

<Table 1>을 보면 Case 1의 경우 divergence M_q 의 값이 원형 시간 기반 feature들의 경우에는 13.7772와 13.7704, FFT power spectrum의 경우에는 3.9044와 3.4091, 그리고 웨이블릿 VET 기반의 경우에는 81.8929와 70.8515의 값을 가져 웨이블릿 VET 기반의 feature들이 훨씬 변별력이 크다는 것을 알 수 있다. 또한 주시할 점은 FFT power spectrum 기반의 feature들이 원형 시간 기반의 경우보다 훨씬 작은 값을 나타내고 있다는 것이다. 이는 FFT가 주파수 영역으로 시그널을 변환시키면서 주파수의 변화가 일어나는 시간에 대한 정보를 소실함으로 인해 생기는 것으로 주파수가 시간에 따라 변화하는 non-stationary 한 시그널들을 다루는데 부적절하다는 것을 보여준다. 웨이블릿 기반의 feature들의 우수함과 FFT 기반의 feature들의 문제점들은 다른 경우들(Case 2와 Case 3)에서도 비슷한 양상을 보였다.

이차원 공간상으로의 시그널들의 가시화의 대표적인 결과로 <Figure 3>, <Figure 4>, 그리고 <Figure 5>를 볼 수 있다. 이들은 Case 3의 샘플 진동 시그널들을 각각의 다른 feature 기반에서의 Bhattacharyya distance를 고려하여 가장 군집 간 변별력이 높은 두 fea-

<Table 1> Discrimination performance comparison on T test statistics (M_q)

Feature Base	Case	Damage Locations	M_q of 1st feature	M_q of 2nd feature
Original	1	Type-1	13.7772	13.7704
	2	Type-2	13.8680	13.7197
	3	Type-1 & 2	15.2440	14.7279
FFT Power Spectrum	1	Type-1	3.9044	3.4091
	2	Type-2	3.4872	3.8361
	3	Type-1 & 2	4.1534	3.3850
Wavelet VET	1	Type-1	81.8929	70.8515
	2	Type-2	89.2155	78.1899
	3	Type-1 & 2	99.8860	89.3009

ture들을 이용해 나타낸 것들이다. 웨이블릿 VET 기반의 <Figure 5>는 다른 두 기반의 <Figure 3>과 <Figure 4>에 비해 두 군집을 가장 잘 구분하고 있음을 보여주어 <Table 3>의 결과에 의한 것처럼 가장 효과적인 feature 기반임을 보여준다. 다른 두 변별력 측정 기준들(T test statistics과 divergence)의 경우도 Bhattacharyya distance의 경우와 유사한 수준의 2D 가시화의 결과를 보여주어 그림의 중복 표현을 피하기 위해 본 논문에서 제외시켰다.

이상과 같은 실험 결과로부터 우리는 세 가지의 다른 군집 간 변별력 측정기준의 관점들에서 공통적으로 웨이블릿 VET 기반의 feature들이 다른 두 기준의 방식들에 비해 우수한 정상/비정상 구조물의 변별력이 있음

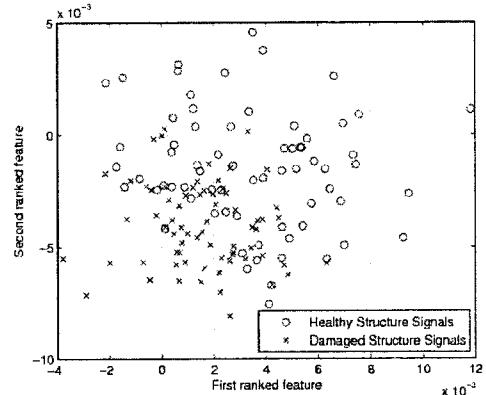
<Table 2> Discrimination performance comparison on Divergence (M_d)

Feature Base	Case	Damage Locations	M_d of 1st feature	M_d of 2nd feature
Original	1	Type-1	5.4999	5.4234
	2	Type-2	5.7092	5.5045
	3	Type-1 & 2	5.0790	4.6503
FFT Power Spectrum	1	Type-1	1.5196	0.6677
	2	Type-2	0.9371	0.9312
	3	Type-1 & 2	0.7198	0.5685
Wavelet VET	1	Type-1	195.5871	165.3469
	2	Type-2	227.4257	191.7963
	3	Type-1 & 2	209.4389	174.1544

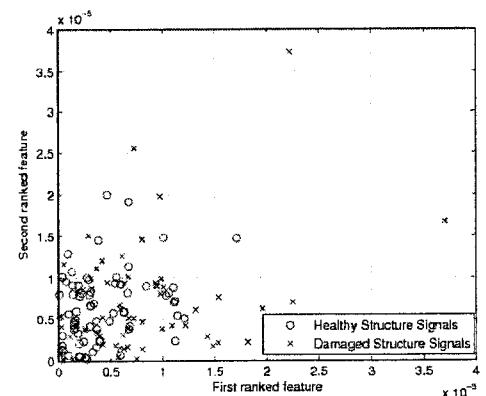
<Table 3> Discrimination performance comparison on Bhattacharyya distance (M_b)

Feature Base	Case	Damage Locations	M_b of 1st feature	M_b of 2nd feature
Original	1	Type-1	0.0145	0.0136
	2	Type-2	0.0123	0.0116
	3	Type-1 & 2	0.0116	0.0098
FFT Power Spectrum	1	Type-1	0.0282	0.0226
	2	Type-2	0.0318	0.0286
	3	Type-1 & 2	0.0217	0.0201
Wavelet VET	1	Type-1	0.0799	0.0721
	2	Type-2	0.0813	0.0766
	3	Type-1 & 2	0.0858	0.0742

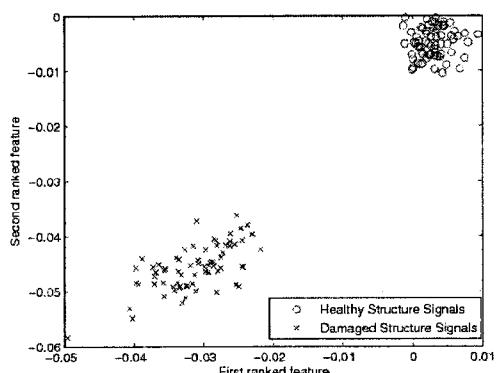
을 확인하였다. 이 실험은 트러스 구조물의 결합 여부를 파악하는데 있어 제안된 feature 생성 방식이 성능의 향상을 가져오고 있음을 보여주고 있다.



<Figure 3> Signal visualization using original time-based features considering Bhattacharyya distance



<Figure 4> Signal visualization using FFT power spectrum-based features considering Bhattacharyya distance



<Figure 5> Signal visualization using Wavelet VET-based features considering Bhattacharyya distance

5. 결론 및 향후 연구방향

본 연구에서는 진동 시그널을 이용하여 공학 구조물의 품질상태, 특히 정상/비정상 구조물간의 구분 능력을 향상시키기 위한 새로운 feature 생성 방식을 제안하였다. 많은 feature 추출과 선택 알고리즘들이 제안되어 왔으나 대부분 unsupervised 형식에 머물렀기 때문에 각 feature들의 군집 간 구분 능력을 고려하지 않았다. 우리는 결합 여부의 탐지 및 정상/비정상 군집들의 효과적 가시화를 위해 군집 간 변별력이 우수한 소수의 웨이블릿 계수들을 생성하는 방법을 제안하였다. 이 과정에서 우리는 세 가지의 다른 변별력 측정 기준 (T test statistics, divergence, 그리고 Bhattacharyya distance)을 사용하여 각 feature들을 평가하였다. 트러스 구조물의 진동 시그널을 이용한 결합 여부 구분 실험에서 본 연구에서 제안된 알고리즘이 기존의 두 방식(원형 시간 기반과 FFT power spectrum)에 비해 훨씬 우수한 정상/비정상 군집 간 변별력을 가져오는 것을 볼 수 있었다.

향후의 연구 과제로는 두 군집 간의 구분 문제를 확장하여 다수의 군집에 대한 구분을 통해 결합의 위치를 찾아내는 보다 일반화된 문제에 접근하는 것이다. 이는 분류기에 투입된 진동 시그널만으로 정확한 수리 및 보수의 필요 위치를 알아내는 매우 효율적인 결합 여부 모니터링 시스템에 크게 기여할 것이다.

References

- [1] Ambardar, A. (1995), *Analog and Digital Signal Processing*, PWS Publishing Company, Boston.
- [2] Antoniadis, A., Gijbels, I., and Gregoire, G. (1997), Model selection using wavelet decomposition and applications, *Biometrika*, vol. 42, no. 4, pp. 751-763
- [3] Duda, R. O., Hart,P.E. and Stork, D.G. (2001), *Pattern Classification*, 2nd edn., Wiley, New York, NY.
- [4] Guyon, I. and Elissee, A. (2003), An introduction to variable and feature selection, *Journal of Machine Learning Research*, 3, 1157-1182.
- [5] Jung, U., Jeong, M. K. and Lu, J. C. (2006), A vertical-energy-thresholding procedure for data reduction with multiple complex curves, *IEEE Transactions on Systems, Man, and Cybernetics-Part B*, 36(5), 1128-1138.
- [6] Lie, J.S., Zhang, J.L., Palumbo, M.J. and Lawrence, C.E. (2003), Bayesian clustering with variable and transformation selection, *Bayesian Statistics*, 7, 249-275.
- [7] Law,S.S., Li,X.Y., Zhu,X.Q., and Chan,S.L. (2005), Structural damage detection from wavelet packet sensitivity, *Engineering Structures*, 27, 1339-1348.
- [8] Li,Z., Xia,S., Wang,J. and Su,X.(2006), Damage detection of cracked beams based on wavelet transform, *International Journal of Impact Engineering*, 32, 1190-1200.
- [9] Li,H., Deng,X., and Dai,H. (2007), Structural damage detection using the combination method of EMD and wavelet analysis, *Mechanical Systems and Signal Processing*, 21, 298-306.
- [10] Mallat, S. G. (1989), *A Wavelet Tour of Signal Processing*, Academic Press, San Diago.
- [11] Palacz, M., and Krawczuk, M. (2002), Vibration parameters for damage detection in structures, *Journal of Sound and Vibration*, Vol.249, No.5, 999-1010.
- [12] Sohn, H., Farrar, C.R., Hemez, F.M., Shunk, D.D., Stinemates, D.W., and Nadler, B.R. (2003), A review of structural health monitoring literature: 1996~2001, *Technical Reports LA-13976-MS*, Los Alamos National Laboratory.
- [13] Swamidas, A.S.J. and Chen, Y. (1995), Monitoring crack growth through change of modal parameters, *Journal of Sound and Vibration*, Vol.186, No.2, 325-343.