

논문 2009-46SP-3-16

음향방출을 이용한 금속의 피로 균열성장 패턴인식 기법

(A Pattern Recognition Method of Fatigue Crack Growth on Metal using Acoustic Emission)

이 수 일*, 이 종 석**, 민 황 기*, 박 철 훈**

(Soo Ill Lee, Jong-Seok Lee, Hwang-Ki Min, and Cheol Hoon Park)

요 약

음향방출 기법은 작동중인 상태에서 기계 설비를 비파괴 검사할 수 있는 기법이며, 균열성장 같은 장애의 신뢰성 있는 감시를 위해서 순간적인 균열신호뿐만 아니라 동특성을 이용하는 것이 중요하다. 균열성장을 검출하기 위해 널리 사용되는 물리적 파괴 3단계는 음향방출 현상이 시간에 따라 서로 겹치는 문제점이 있어 정확한 균열성장 시간을 추정하기 어렵다. 제안한 패턴인식 기법은 오경보와 미탐지를 최소화하기 위해서 음향방출 동특성을 입력으로 사용하고, 균열성장 시간을 정확히 추정하기 위해 시간에 따른 클러스터링 기법을 사용한다. 실험결과는 제안한 패턴인식 기법이 압력의 변화에 의한 음향방출의 변화의 장인함 때문에 실용화에 효율적임을 보여준다.

Abstract

Acoustic emission-based techniques are being used for the nondestructive inspection of mechanical systems used in service. For reliable fault monitoring related to the crack growth, it is important to identify the dynamical characteristics as well as transient crack-related signals. Widely used methods which are based on physical phenomena of the three damage stages for detecting the crack growth have a problem that crack-related acoustic emission activities overlap in time, therefore it is insufficient to estimate the exact crack growth time. The proposed pattern recognition method uses the dynamical characteristics of acoustic emission as inputs for minimizing false alarms and miss alarms and performs the temporal clustering to estimate the crack growth time accurately. Experimental results show that the proposed method is effective for practical use because of its robustness to changes of acoustic emission caused by changes of pressure levels.

Keywords : acoustic emission, fatigue crack growth, neural network, Gaussian mixture model, temporal clustering

I. 서 론

음향방출(Acoustic Emission, AE) 기법은 구조물이나 재료 내부 결함의 발생과 성장 등의 상태정보를 서비스 중에 연속적으로 모니터링이 가능하며, 결함을 검출하여 막대한 위험과 사고를 예방할 수 있는 비파괴 검사기법이다. 이러한 음향방출 신호를 이용하여 균열(crack)의 발생과 성장, 구조의 질적 저하 등을 검출할

수 있으며 재료에 의존하는 음향방출 특성을 상태와 연관지어 모델링 할 수 있다^[1~3]. 따라서 음향방출 기법은 산업계 전반에 사용되는데 각종 압력용기(pressure vessel), 탱크(tanks), 금속파이프 등의 결함과 누설을 검사하는데 효과적으로 사용되며, 특히 원자력발전소 주요기기에도 사용되고 있다.

일반적으로 균열이 성장할 때 균열 크기는 부드러운 곡선 형태로 증가하지만 음향방출 에너지 활동은 시간 축에서 급격한 상승기와 잠복기를 갖는 비선형 특성을 갖는다. 실험실 환경에서 짧은 시간의 인장(tensile)과 같은 외부압력에 의해 만들어진 균열성장 신호를 실제

* 학생회원, ** 정회원, 한국과학기술원 전자전산학부
(School of Electrical Engineering and Computer Science, KAIST)

접수일자: 2008년8월29일, 수정완료일: 2009년4월14일

환경에 사용하기 위해서는 음향방출 신호간의 상관관계 등을 이용한 불변하는 특징 추출과 압력, 온도 등의 변화에 대한 보정 과정이 반드시 필요하며, 균열성장 신호는 누설(leakage)이나 외부 타격에 의한 음향방출 신호보다 상당히 미약하기 때문에 실제 환경의 기계적, 전기적 잡음을 제거하는 과정 또한 고려되어야 한다. 이러한 문제점 때문에 시간에 따른 패턴인식 문제에서는 시간에 따라 음향방출 신호 패턴의 변화와 재료의 상태를 연관짓고, 패턴 자체의 경향이나 동특성(dynamical characteristics)을 이용하여 많은 정보량과 정확성을 얻는 것이 중요하다.

음향방출 신호는 결함의 존재가 아닌 결합의 동적인 상태변화에 의해 발생하므로 그 변화량과 에너지는 비례관계이지만 시간적인 발생간격을 예측하기는 어렵다. 균열성장을 검출하기 위해 일반적으로 재료의 물리적인 현상, 즉 균열성장 시 음향방출의 원인인 전위 이동(dislocation movement), 균열 시작(crack initiation), 균열 성장(crack growth)의 3단계로 나누어 클러스터링 하는 기법이 많이 사용된다^[2, 4]. 이러한 세 단계에서 주로 발생하는 음향방출 현상을 패턴인식의 입력으로 사용하는 기법은 음향방출 현상이 시간영역에서 정확히 나뉘지 않고 중복될 경우 정확한 시간추정이 어려운 문제점이 있다.

본 연구에서는 음향방출 신호의 동특성을 입력으로 사용하여 오경보(false alarm)와 미탐지(miss alarm)를 최소화하는 잡음에 강인한 패턴인식기법을 제안한다. 기존의 균열성장 신호 검출기법은 현재 시간의 정보만을 사용하기 때문에^[2, 4~5] 잡음에 민감한 문제점이 있으나, 제안하는 기법에서는 시간적인 클러스터링 기법을 통해 균열성장의 정확한 시간추정이 가능하다. 또한 금속에 가해지는 여러 압력레벨에 의한 음향방출의 변화에 강인한 특징추출 기법과 정규화(normalization) 기법을 포함하여, 실용화에 효율적임을 보인다. 제안하는 기법은 균열발생 단계에서 미탐지를 없애고, 균열 성장 시 가장 위험한 마지막 단계에서는 오경보를 없앰으로써 전체시간 구간에서 정확한 인식이 가능하다. 본 연구를 원자력발전소에 적용하기 위해 원자로와 연결되는 냉각재 배관(coolant pipe)의 금속재료인 탄소강(SA-508 CL.1a)에 대한 실험을 통해 제안하는 기법이 유용함을 보인다.

다음 장에서는 기존의 음향방출 기법, 신호해석 및 클러스터링 그리고 균열성장 신호의 패턴인식 기법에

대한 연구를 소개하고, III장에서는 금속의 균열성장을 시간에 따라 클러스터링 하기 위해 제안하는 전체 패턴인식 기법에 대한 과정을 보여주며, 주파수와 시간영역의 특징추출 과정과 패턴인식 기법에 사용된 패턴인식 기와 균열에 대한 통합 결정규칙을 기술한다. IV장에서는 실험을 통해 제안하는 인식기법의 성능을 보이며, 마지막으로 V장에서 결론으로 논문을 맺는다.

II. 기존의 균열성장 패턴인식 기법

음향방출은 고체 내부구조의 변화에 의해 내부 응력(stress)의 재분배가 이루어질 때 고체 내부에 국부적으로 형성되었던 변형에너지가 급격히 방출되면서 탄성파가 발생하는 현상으로, 부식이나 균열성장과 같은 변형 또는 파괴과정에서 저장되어 있던 에너지의 급격한 방출에 의해 일시적인 방출파가 생기게 된다. 재료의 입장 실험 시 여러 단계의 음향방출 활동을 볼 수 있는데 음향방출 카운트 비율(AE count rate)은 과거의 모든 음향방출 이벤트에 대한 카운트수의 합인 누적 음향방출 카운트 수(cumulative AE counts)의 미분 값이며, 이는 균열성장 비율(crack growth rate)과 비례하므로^[6] 일반적으로 재료의 균열성장을 해석하기 위해서 누적 음향방출 카운트 수가 주로 사용된다. 그림 1은 일반적인 균열성장 과정에서의 누적 음향방출 카운트 수의 변화를 나타내는데, 비균열 단계인 소성변형(plastic deformation) 이후 균열성장 3단계를 볼 수 있다. 본 연구에서는 균열성장 3단계로의 진입을 균열발생 그리고 세 단계의 진행과정을 균열성장이라고 정의한다.

균열의 발생 및 성장을 검출하기 위해서는 시간에 따른 재료의 균열특성을 현상학적으로 분류하거나 균열성장 시간에 따라 분류하는 기법으로 해석할 수 있다^[7]. 대부분의 현상학적 인식기법은 단계1과 단계3에서 주로 발생하는 파형 분석을 통해서 균열성장을 검출하는데, 파형 변수를 이용하여 코호넨 지도(Kohonen's map)과 k-평균기법(k-means)를 이용하여 다른 형태의 신호파형 클래스를 구분하였고^[2], 각 단계에서 주로 발생하는 파형신호를 참조 데이터와의 공분산 행렬(covariance matrix)을 이용하여 판별하였다^[4, 8].

균열신호를 외부충격 신호와 분류하기 위해 시간과 주파수 영역 특징을 통합하여 다층퍼셉트론(Multi Layer Perceptron, MLP), 방사기저함수(Radial Basis Function, RBF), Support Vector Machine(SVM)을 이

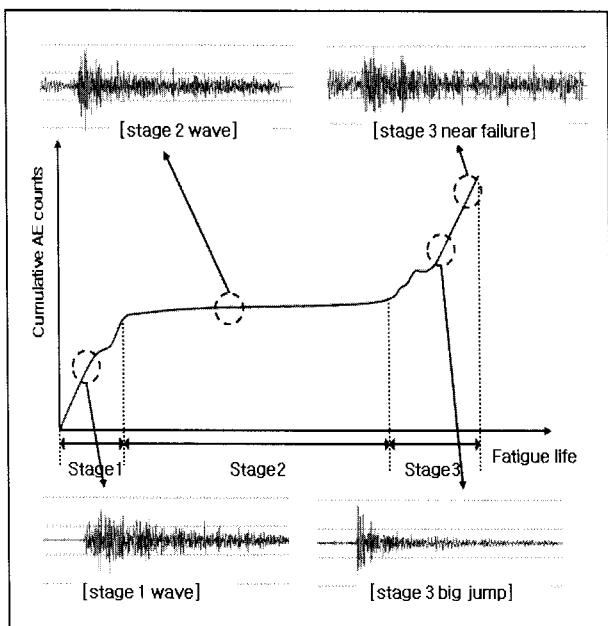


그림 1. 일반적인 균열성장 단계별 음향방출 파형
Fig. 1. General acoustic emission waves at each crack growth stage.

용하였으며^[9], 잡음과 거리에 따라 취득된 균열신호를 주성분 분석(Principal Component Analysis, PCA), MLP를 이용하여 분류, 해석하였다^[5]. 다른 음향방출 발생원을 코호넨 지도를 이용하여 인식하거나^[10] 주파수 영역에서 방출원에 따른 특징을 PCA 등을 통해 추출하는 방법이 연구되었다^[8~9, 11]. 또한 음향방출 이벤트에 대해 통계적인 추정기법이나 신경회로망(neural network) 등을 통하여 클러스터링 하는 기법 등이 제안되었다^[2, 9, 11]. 실제 응용사례를 볼 때, 원자력발전소의 균열성장을 탐지하기 위해서 도파관 음향방출 감지기를 설치하는 방법이 사용되었다^[12].

그림 1은 일반적인 인장 실험 시 균열 발생과 성장의 각 단계에서 나타나는 대표적인 파형을 보여주는데 해당 단계에서 반드시 같은 형태의 파형만 발생하지는 않는다. 단계1과 단계2의 신호는 구별이 어려우므로 일반적인 파형분석 기법에서는 주로 단계1과 단계3의 신호 파형을 구분한다^[3~4].

III. 제안하는 균열성장 패턴인식 기법

1. 제안하는 균열성장 패턴인식 기법

균열성장을 참조 파형과의 비교기법^[4] 등으로 현상에 따라 클러스터링 하는 방법은 특정 음향방출 파형의 발생 시점을 알 수 있다. 하지만 현재시간의 현상에만

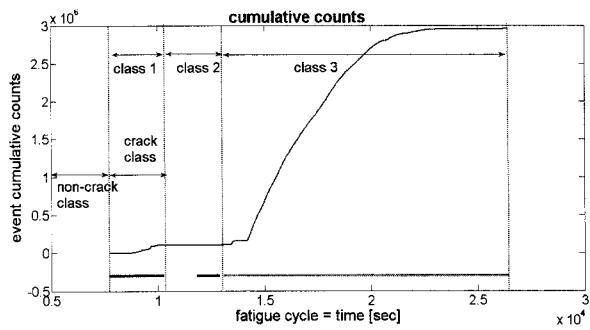


그림 2. 제안하는 인식기법을 위한 균열발생 및 성장의 시간적인 구분
Fig. 2. Temporal clustering of crack initiation and growth for the proposed recognition method.

의존한 이 기법은 균열이 성장하는 시간과 완벽히 일치하지 않는다. 즉, 그림 1의 단계1의 파형은 단계2, 단계3에도 모두 존재하고 있으며, 단계2의 파형도 단계3에 존재하여 시간 축에 서로 겹쳐있게 되고^[7], 단계3 big jump 파형도 발생시점을 정확히 추정할 수 없으며, 단계3 구간 중 특히 누적 음향방출 카운트수의 기울기가 크지 않은 경우는 big jump 파형이 나타나지 않는다. 여기서 big jump 파형은 에너지의 급격한 방출에 의해 음향방출 빈도가 갑자기 증가할 때 나타나는 파형을 의미한다. 따라서 현상에 따른 클러스터링은 균열이 성장하는 시간을 정확히 추정하기 어렵고, 음향방출 신호의 시간에 대한 경향 정보와 동특성이 포함될 수 없다. 따라서 본 연구에서는 금속의 균열 성장에 따른 음향방출 정보를 시간에 따라 클러스터링 하고 이를 인식하는 패턴인식 기법을 제안한다. 클래스 구분을 위해 물리적 폐카니즘에서 규정한 단계1,2,3을 클래스1,2,3으로 바로 변환하여 시간에 따른 단계를 구분하는 문제로 바꾸기로 한다.

그림 2는 실험에 사용된 균열성장 신호를 시간에 따라 클래스의 구분을 한 예를 보여주고 있다. 이와 같은 시간에 따른 클래스 구분 방법은 순차적으로 발생하는 균열성장 단계를 알게 되므로^[7] 재료의 균열성장 시간을 추정할 수 있게 한다.

그림 3은 제안하는 인식 기법을 보인다. 연속적으로 발생하는 음향방출 신호와 잡음신호 중에서 문턱값(threshold)을 넘어서는 신호만 무빙윈도우(moving window)로 분할(segmentation)하여 제안된 인식기의 입력으로 사용된다. 그림 3에서 특징추출 과정은 주로 시간영역에서 적합한 특징을 추출하는 파형 파라미터 취득(Wave Parameter Acquisition) 단계와 주파수 영

역 특징을 추출하는 과정 특징추출(Wave Feature Extraction)의 두 가지로 나뉜다. 실제 압력환경에 가깝게 다른 인장력을 가해도 불변하는 강인한 특징추출과 정규화가 이뤄진다. 시간영역의 과형변수 중 가장 클래스 분별능력이 우수한 특징을 선택하였고, 주파수 영역의 특징 추출을 위해서는 두 개의 필터뱅크(filterbank)를 사용한다. 하나는 비균열/균열 신호간 주파수특징 추출에 사용되고, 다른 하나는 균열성장 과정에서 각 클래스별 대표신호를 가장 잘 분별할 수 있도록 설계한다. 본 인식기는 크게 균열발생을 감지하는 인식기와 균열의 성장 과정을 분류하는 인식기의 두 부분으로 구성되어 있다. 균열발생 패턴 인식기는 MLP를 사용하여 소성변형과 전기적인 스파이크 잡음 신호 등을 포함한 비균열 신호에서 클래스1에 해당하는 균열 발생 신호를 검출하는 것이 목적이다. 균열발생 패턴 인식기에서 균열발생 신호가 검출되면 균열성장 패턴 인식기가 동작을 시작하여 균열성장의 각 단계인 세 개의 클래스를 구분, 인식하게 된다. 균열성장 패턴 인식기는 MLP와 가우시안 혼합모델(Gaussian Mixture Model, GMM) 및 이들을 통합하는 결정규칙 모듈로 구성되어 있다.

균열성장 패턴 인식기가 동작을 시작하면 GMM은 클래스1에서 확률분포함수를 만들기 위해 학습되고, 클래스2, 3에서는 데이터의 확률 값을 검사하게 되며, 경계선(threshold value) 보다 낮은 경우 클래스3로 인식하게 된다. 균열발생과 균열성장 문제를 분리하여 별도의 MLP를 사용하는 것은 학습의 복잡도를 감소시켜 정확성을 향상시키는 역할을 한다. 하지만 균열성장 과

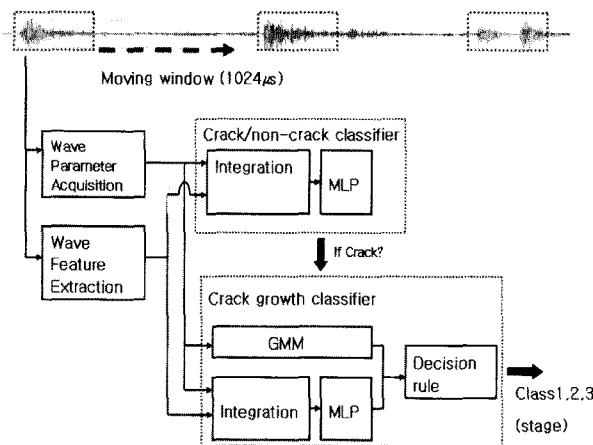


그림 3. 균열성장 검출을 위한 전체 인식기법
Fig. 3. Overall recognition method for detecting the crack growth.

형이 시간 축에서 정확히 분류되지 않고 서로 겹쳐 있으므로 MLP에서는 많은 오경보가 발생하며, 에너지 값의 확률분포를 이용하는 GMM의 영향으로 이러한 오경보를 방지하는 역할을 한다. MLP와 GMM의 결과를 결합하기 위한 결정규칙은 클래스3에 대한 오경보를 방지하며 4프레임의 과거 값에 대한 정보를 함께 고려하여 간헐적으로 발생하는 유사 클래스3 신호의 오인식을 방지하는 역할을 한다. 또한 GMM의 영향으로 균열성장 패턴 인식기에는 시간에 따른 에너지 분포와 같은 동특성이 포함된다.

2. 특징추출 과정

가. 주파수영역 특징추출

그림 4는 과형 특징추출을 위한 과정을 나타낸다. 먼저 시간영역에서 직류성분을 제거하고, 5,120개의 샘플 길이($1024\mu sec$)의 무빙윈도우를 사용하여 문턱 값을 넘는 경우 신호를 분할한다.

그림 5는 비균열/균열 신호의 대표적인 주파수 스펙

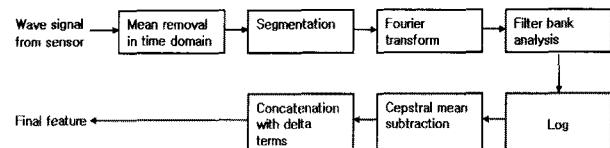


그림 4. 과형특징의 추출 과정

Fig. 4. Procedure of wave feature extraction.

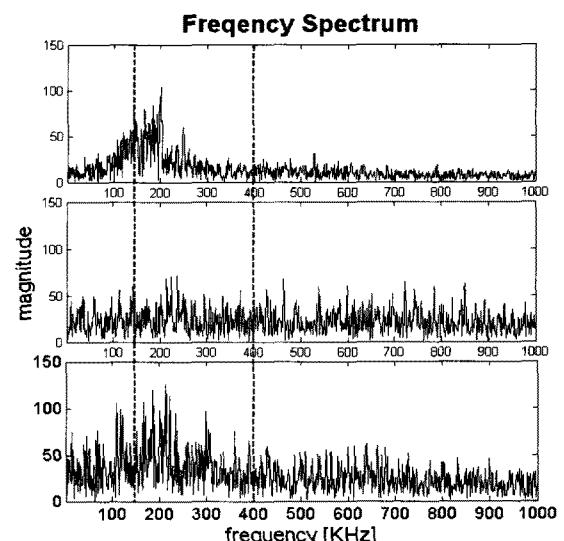


그림 5. 균열발생에 대한 음향신호의 주파수 분석
Fig. 5. Spectral analysis of the acoustic signal for crack initiation.

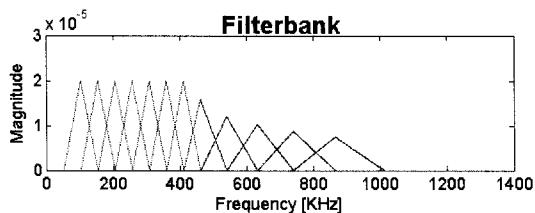


그림 6. 균열발생 단계 분류를 위한 특징 추출에 사용되는 필터뱅크

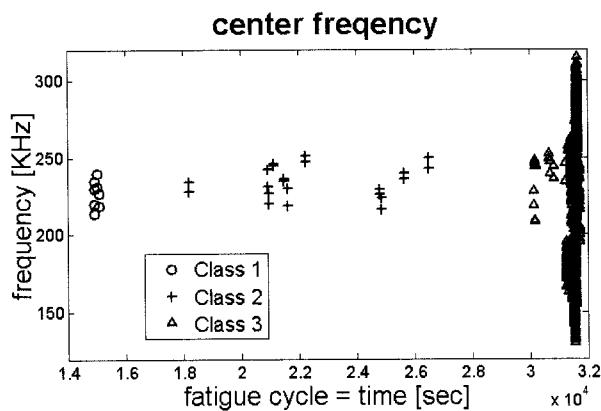
Fig. 6. Configuration of the filterbank for the crack initiation classification.

트럼을 보여준다. 맨 위의 스펙트럼은 비균열 클래스의 대표적인 파형이고, 아래 두개는 균열 클래스의 대표적인 파형이다. 비균열 신호는 소성변형에 의한 연속형 음향방출 신호, 상승시간과 지속시간이 매우 짧게 나타나는 전기적인 스파이크 잡음, 기타 피로인장실험에서 발생한 잡음신호 등이며, 균열신호는 전위 이동에 의한 연속형 신호와 균열과 관련된 돌발형 신호로 구성되어 있다.

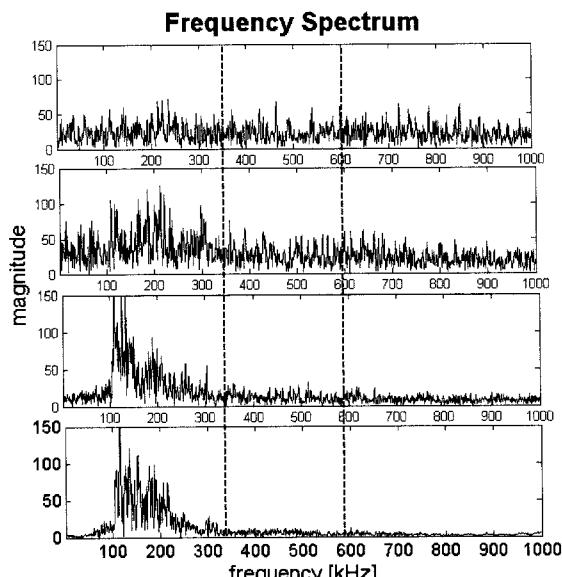
필터뱅크 설계 시는 고려된 총 주파수 대역, 필터뱅크 대역 수, 필터뱅크 대역의 넓이 등을 주로 고려하는데, 먼저 의미 있는 총 주파수 대역을 결정하고, 정보량에 따른 대역 넓이를 결정하였으며, 대역 수에 의해 결정되는 패턴의 차수는 시스템의 복잡도를 증가시키므로 본 논문에서는 실험적으로 결정하였다. 그림 6은 균열발생의 검출을 위한 특징을 추출하는데 쓰이는 필터뱅크의 주파수 응답을 나타낸다. 총 주파수 대역은 50kHz~1MHz로 결정하였으며, 50kHz 이하의 대역에 대해서는 잡음을 제거하기 위해서, 1MHz 이상의 대역은 많은 정보량이 없으므로 완전히 제거하였다. 그림 5에서 맨 위의 비균열 신호와 두 번째 그림의 균열신호는 150kHz~250kHz에서 쉽게 분별이 되고, 세 번째 그림의 균열신호와는 250kHz~400kHz에서 분별이 되는 것을 알 수 있다. 따라서 설계된 필터뱅크는 정보량이 많은 150kHz~400kHz 구간을 위해 중심주파수가 100kHz부터 400kHz까지 동일한 간격으로 구성된 7개의 삼각형 필터를 정의하였고, 대역 수를 고려하여 450kHz 이상의 고주파수 대역에 로그스케일로 증가하는 5개의 삼각형 필터를 정의하였다. 필터뱅크를 구성하는 총 12대역의 삼각형 필터 중심 주파수는 식 (1)과 같다.

$$f_c(i) = \begin{cases} 100 + 50 \times (i-1) & 1 \leq i \leq 7 \\ 450 \times 1.17^{i-7} & 8 \leq i \leq 12 \end{cases} \quad (1)$$

그림 7은 균열성장 시 음향방출 파의 중심주파수 분포와 대표적인 파형의 주파수 스펙트럼을 보여준다. 그림 7.(a)에서 클래스3 신호는 200kHz ~ 260kHz 대역의 중심주파수이외에도 많은 신호가 존재함을 알 수 있다. 그림 7.(b)에서 위의 두개의 스펙트럼은 클래스1의 대표적인 파형이고, 아래 두개는 클래스3의 대표적인 파형이다. 총 주파수 대역은 100kHz~1MHz로 결정하였으며, 100kHz 이하의 대역은 잡음을 제거하기 위해서, 1MHz 이상의 대역은 많은 정보량이 없으므로 완전히 제거하였다. 클래스 1과 3을 가장 쉽게 구분 짓는 주파수 영역은 350kHz~600kHz이며, 100kHz 영역은 모든 형태의 신호가 가장 큰 값을 가짐을 볼 수 있다. 이러한 특성을 이용하여 그림 8과 같은 주파수 응답을 보이는



(a) 균열성장의 음향 방출 파 중심주파수 분포



(b) 클래스1과 클래스3의 대표적인 주파수 스펙트럼

그림 7. 균열성장 과정에 대한 음향신호의 주파수 분석
Fig. 7. Spectral analysis of the acoustic signal for crack growth.

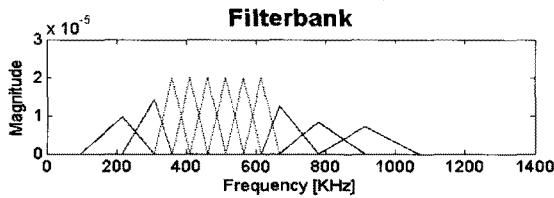


그림 8. 균열성장 단계 분류를 위한 특징 추출에 사용되는 필터뱅크

Fig. 8. Configuration of the filterbank for the crack growth classification.

필터뱅크를 설계하여 균열성장의 검출을 위한 특징 추출에 사용한다. 설계된 필터뱅크는 정보량이 많은 350kHz~600kHz 구간을 위해 중심주파수가 350kHz부터 600kHz까지 동일한 간격으로 구성된 6개의 삼각형 필터와 대역수를 고려하여 650kHz 이상의 고주파수 대역에 로그스케일로 증가하는 3개의 삼각형 필터와 300kHz 이하의 주파수 대역에 역으로 로그스케일로 증가하는 2개의 삼각형 필터를 정의하였다. 필터 뱅크를 구성하는 총 11대역의 삼각형 필터 중심 주파수는 식(2)와 같다.

$$f_c(i) = \begin{cases} 2 \times 300 - (300 \times 1.3^{3-i}) & 1 \leq i \leq 2 \\ 300 + 50 \times (i-2) & 3 \leq i \leq 8 \\ 650 + 1.17^{i-8} & 9 \leq i \leq 11 \end{cases} \quad (2)$$

균열성장과 균열발생 필터 뱅크의 출력 값에 대해 이를 적용하여 캡스트럼 특징을 얻었는데, 이러한 캡스 트럼 특징은 많은 패턴 인식 문제에 대하여 우수한 성능을 보이며 특히 잡음에 강인한 기법으로 알려져 있다 [13]. 캡스트럼 평균 차감(Cepstral Mean Subtraction, CMS)[14] 단계까지 거치게 되면 균열성장의 경우 총 11 개, 균열발생의 경우 총 12개의 특징들이 추출된다. 즉 하나의 프레임 데이터가 11 또는 12차원의 특징 벡터로 변환되는데 이는 현재 작업하고 있는 프레임 정보만을 고려한 것으로, 프레임과 프레임 간의 상관관계 정보는 전혀 고려되지 않는다. 프레임의 길이를 넘어서는 비교적 긴 시간 동안에 걸쳐 일어나는 사건의 정보를 고려하고 음향방출의 경향 정보를 나타내기 위해서 다음과 같은 델타 특징을 함께 이용한다[15].

$$\Delta \mathbf{x}(t) = \frac{\sum_{k=1}^2 (\mathbf{x}(t+k) - \mathbf{x}(t-k)) \cdot k}{2 \cdot \sum_{k=1}^2 k^2} \quad (3)$$

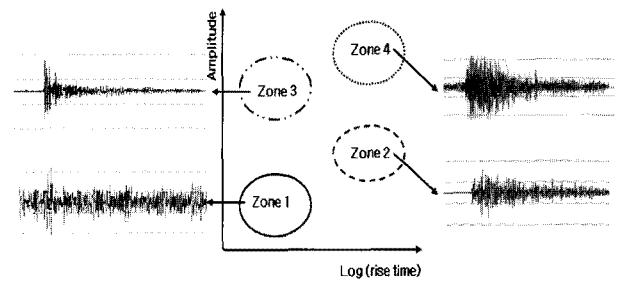
여기서 $\mathbf{x}(t)$ 는 시간 t 에서의 특징 벡터를 의미한다.

클래스1과 클래스3은 짧은 시간에 많은 빈도수의 이벤트가 발생하고 같은 형태의 파형이 계속 발생하는 경우가 많으므로 델타 특징을 이용하여 경향 정보를 나타낼 수 있다.

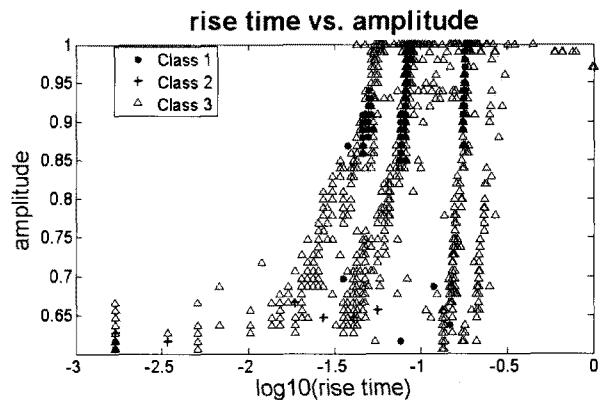
나. 시간영역 특징추출

그림 1에서 보는 것과 같이 클래스1과 클래스3의 대표적인 음향방출파의 시간영역에 대한 차이점은 상승시간이 다르다는 점이며 이 때문에 많은 연구에서 상승시간을 이용한 균열신호의 성장과 음향신호 방출원을 검출해왔다. 또한 클래스3의 기울기가 큰 영역에서 급격한 에너지방출에 의해 상대적으로 클래스1보다 높은 진폭의 신호가 발생함을 알 수 있다[2, 9].

그림 9는 균열성장 시 발생하는 음향방출 파를 파형에 따라 진폭, 상승시간에 따라 그 분포를 나타낸 것이고 그림 9.(a)는 파형에 따라, 그림 9.(b)는 시간에 따른 클래스를 구분하여 그 분포를 나타낸 것이다. 그림 9.(a)에서 볼 수 있듯이 일반적인 음향방출 파형은 시간 영역에서 상승시간, 진폭, 지속시간 등으로 구분이 가능



(a) 균열성장 시 음향방출 파형에 따른 파라미터 분포



(b) 제안된 알고리즘을 위한 시간에 따른 균열성장 시 음향방출 파라미터의 실제 분포

그림 9. 균열성장 단계별 시간영역 특징분포

Fig. 9. Distribution of time-domain features for crack growth.

하다. Zone 1은 전기적인 스파이크 잡음으로 상승시간, 지속시간, 진폭이 모두 작게 되며, 균열신호가 아니며 어느 단계에서든 발생할 수 있다. Zone 2의 음향방출 파형은 전형적인 클래스1의 파형이지만 역시 클래스 1,2,3 어디에서도 발생할 수 있다. Zone 3과 4는 전형적인 클래스3의 파형이지만 그림 9.(b)에서 볼 수 있듯이 클래스1의 신호와 쉽게 구분될 수 없음을 알 수 있다. 또한 Zone 3과 4는 구분을 위한 상승시간의 분포 폭이 작으므로 실제 문제에 쉽게 적용될 수 없다. 따라서 균열성장의 시간에 따른 클러스터링을 위해서 균열성장 단계에서 분별능력이 가장 큰 특징의 선택과정이 필요하다.

파형 파라미터 취득을 위해서 피로인장실험 중 16가지(time, rise time, counts to peak, counts, energy, duration, amplitude, average signal level, average frequency, RMS, reverberation frequency, initial frequency, signal strength, absolute energy, frequency centroid, peak frequency)의 파라미터를 저장하였는데, 이 중에서 분별능력이 우수한 특징을 선택하였다. 이러한 특징선택 과정은 많은 후보 특징 중에서 패턴인식에 필요한 입력의 차원을 줄여 복잡도를 낮게 할 수 있으며 인식 정확도를 향상시킬 수 있다^[16]. 이 과정은 각 변수의 분별능력을 계산하여 그 값이 큰 것들을 선택함으로써 가능하며, 분별능력 J 는 식 (4)와 같다.

$$J = \frac{|m_1 - m_2|^2}{s_1^2 + s_2^2} \quad (4)$$

m_1, m_2 는 각 클래스에 대한 평균값, s_1^2, s_2^2 은 각 클래스에 대한 분산이다. 따라서 각 클래스의 평균값이 서로 멀수록, 분산 값은 각각 작을수록 J 가 크게 나타남을 알 수 있다. 균열성장과 균열발생 데이터에 대해 J 에 대한 순차적인 특징 순위가 매겼는데, 여러 특징이 상호 작용을 통해 클래스 분별능력을 향상시킬 수 있으므로^[16] 실험을 통해 패턴 인식률이 높은 특징을 선택, 사용하였다. 균열성장의 경우 진폭, 상승시간, 지속시간, 신호강도, 에너지 순으로 큰 J 를 가지는데, 이중 진폭, 상승시간, 에너지의 3개의 입력만을 사용했을 때 가장 우수한 성능을 보였다. 균열발생의 경우는 지속시간, 진폭, 초기주파수, 반사주파수, 신호강도, 에너지 순으로 큰 J 를 가지며, 가장 우수한 성능을 보이는 진폭, 에너지 값을 선택하고, 그림 9.(a)의 전기적인 스파이크 잡

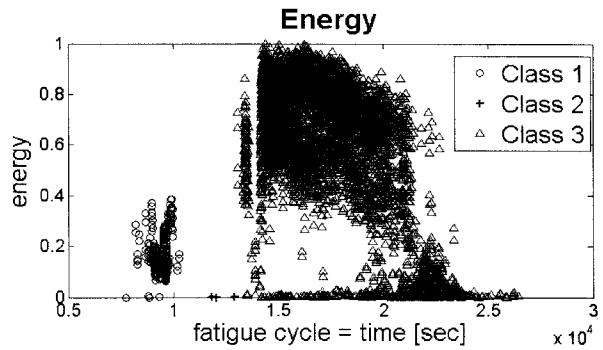


그림 10. 균열성장 시 에너지 분포

Fig. 10. Distribution of the energy during crack growth.

음을 제거하기 위해 상승시간과 count to peak를 추가하여 4개의 입력을 사용하였다.

시간영역의 파라미터를 특징을 실제 문제에 사용하기 위해서는 정규화에 대한 대책 또한 필요하다. 에너지 값의 경우 그 크기가 금속에 가해지는 압력레벨에 따라 크게 변화한다. 그림 10은 균열성장 시 각 클래스 별 에너지 분포를 나타낸다. 모든 피로인장실험에서 클래스3의 에너지 최대 값이 클래스1의 에너지 최대 값의 약2.5배 정도인 것으로 나타났다. 따라서 클래스1의 에너지 최대 값의 2.5배를 실시간으로 나누어 정규화를 하였다. 이런 방법으로 변하는 압력레벨이 가해지는 실제 환경에서도 에너지 값을 정규화 할 수 있다.

3. 패턴인식기와 통합 결정규칙

그림 3과 같이 본 패턴인식기는 균열발생, 균열성장의 두개의 패턴인식기로 구성되어 있다. 균열발생은 인식 기법으로 MLP를 사용하고, 균열성장은 GMM과 MLP를 사용하여 통합 결정규칙을 적용하였다. 균열성장 패턴인식기의 GMM은 클래스1 기간에 학습을 수행하고, 클래스2부터는 테스트를 시행하여 낮은 확률 발생시 클래스3 진입을 인식하며, 클래스1과 클래스3을 분류하는 MLP의 인식결과와 통합되어 상호보완적으로 균열성장을 인식한다.

GMM은 균열 성장 검출만을 목적으로 사용되며, 우선 균열발생 패턴 인식기로부터 균열을 통보받은 후 GMM은 클래스1에서 학습을 시작한다. 클래스1 신호들의 에너지 값의 확률 분포를 학습하고 나면, 그 모델을 기반으로 새로운 신호에 대하여 클래스2에서 클래스3까지 균열이 성장했는지 여부를 판단할 수 있게 된다. 새로운 신호가 들어왔을 때 그 신호에 대한 확률 분포 모델의 확률 값을 읽을 수 있는데, 이 값이 클수록 이미

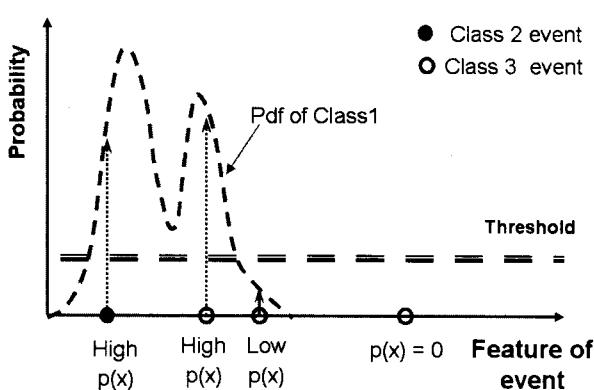


그림 11. 균열성장 시 확률분포의 예

Fig. 11. Example of probability distribution during crack growth,

학습된 클래스1 신호에 가깝다는 것을 의미하고 값이 작을수록 학습된 클래스1과 다른 신호, 즉 클래스3의 균열이 발생했다는 것을 의미한다. 여기서 클래스3의 사건을 구분하는 확률 값의 경계선(threshold value)을 사용자가 설정해 주어야 하며 제안된 알고리즘에서는 클래스2에서 오경보를 없애기 위해 클래스1을 학습 후 가장 작은 확률 값보다 작게 설정하였다.

클래스3의 신호가 클래스1의 신호와 유사한 신호를 상당수 포함하고 있으므로 미탐지가 순간적으로 발생하지만 음향방출 신호의 시간빈도수가 다른 클래스보다 높으므로 클래스3에서의 미탐지의 시간간격은 매우 짧으며, 균열성장의 특성상 클래스3 신호가 발생한 후의 미탐지는 의미가 없는 것이며 클래스3 신호를 얼마나 빨리 인식할 수 있는지가 중요한 것이다. 그림 11은 확률분포 모델을 이용하여 클래스3을 인식하는 예를 보여준다.

신경회로망을 이용하여 구분하는 것은 클래스1과 클래스3이다. 이는 클래스2의 경우 클래스1과 클래스3에 비해 상당히 적은 수의 음향방출 이벤트가 발생하므로 신경회로망이 클래스2를 제대로 학습하지 못하기 때문이다.

균열성장 분류를 위해 제안하는 통합기법에서는 균열발생시 미탐지 감소에 효과적인 MLP와 클래스3에서 오경보 감소에 효과적인 GMM을 함께 사용함으로써 균열성장 전체구간에 대한 오경보와 미탐지를 모두 줄일 수 있다. 특히 클래스3에서 여러 가지 특징이 함께 존재하는 형태이므로 미탐지가 발생할 수 있는데 이를 줄이기 위해 과거의 몇 개 이벤트에 대한 정보를 현재 값에 반영하여 사용하고, 이는 클래스2에서 클래스3 신

호에 대한 오경보를 줄이는 역할도 한다.

따라서 GMM과 MLP의 통합은 과거 4프레임과 현재 프레임의 인식결과에 바탕을 두는 식 (5)와 같은 결정 규칙에 의해 이루어지며 오경보를 줄이는 것을 강조하기위해 실험적으로 GMM의 결과를 2배하는 가중치를 결정하였다. 가중치가 작을 수록 오경보 발생율이 높게 되며 유사 클래스3 신호에 민감하게 된다.

$$Y(i) = \sum_{j=i-4}^i (2 \times P(j) + M(j)) \quad (5)$$

여기서 $P(j)$ 는 GMM의 출력 값이고, $M(j)$ 는 MLP의 출력 값이며, $P(j)$, $M(j)$ 는 클래스3 일 경우 +1의 값을, 클래스3로 인식하지 않은 경우 -1의 값을 갖는다. 따라서 $Y(i)$ 가 0보다 크거나 같은 경우는 클래스3로 인식하고, 0보다 작은 경우는 클래스3로 인식되지 않는다.

IV. 실 험

제안하는 기법의 성능을 실험으로 알아본다. 데이터 수집을 위한 피로인장실험과 균열의 발생 및 성장에 대한 패턴인식 실험을 설명한다.

1. 피로인장실험

본 연구에서 사용된 냉각재 배관(coolant pipe)과 동일한 금속재료(탄소강, SA-508 CL.1a)는 원자로에서 발생한 고온의 열을 열교환기인 증기발생기에 전달하는 설비이며 높은 에너지의 중성자 조사를 받으며, 고온, 고압의 냉각재와 접촉해야 하는 등 원자력 특유의 환경에 처해있고, 수명기간 중 재료의 건전성과 안전성이 요구되는 설비이다.

피로 인장실험의 구성은 그림 12.(a)와 같다. 재료 인장실험기는 MTS810을 사용하였고, 센서는 PAC사의 광 대역 센서인 WD모델을 사용하였으며, 프리앰프는 PAC사의 1220A를 사용하였다. 또한 음향방출 계측장비로는 PAC사의 Disp-24 장비를 사용하여 음향방출 신호를 취득, 처리하였다. SA508 CL.1a 시험편은 ASTM E647-05를^[17] 참고로 규격을 결정하였으며, 세부규격과 센서 설치위치는 그림 12.(b)와 같다. 센서는 새김 눈(notch) 주변에 대칭으로 설치되어 각각 메인센서와 가드센서의 역할을 수행하여 인장실험기의 그림

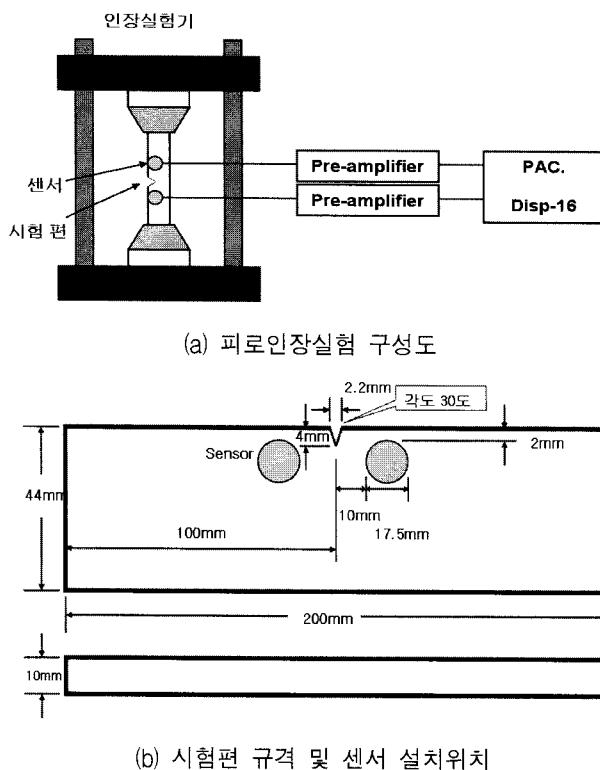


그림 12. 피로인장실험 구성도 및 시험편 규격
Fig. 12. Organization of the fatigue tensile test and the specification of specimen.

표 1. 음향방출 계측장치 설정치
Table 1. Setting of the acoustic emission equipment.

Analog filter[Hz]	Sampling rate	Pre-trigger	Length
10k ~ 2M	5MSPS	128	5k

(grip)에 의해 발생하는 마찰잡음과 반사잡음을 제거하였다. 센서1과 센서2에서 측득된 신호의 도착시간의 차이가 $40 \mu\text{sec}$ 이하로 나는 경우는 그립이 아닌 notch에서 발생한 신호로 판단하여 실험에 사용하였다.

프리앰프는 40dB로 설정하였고, 음향방출 계측장치의 공통 요소는 표 1과 같이 설정하였다. $10\text{kHz} \sim 2\text{MHz}$ 의 신호를 5 MSPS(Mega Samples Per Second)로 샘플링 했으며 음향방출 파형의 저장 길이를 5k로 설정하여 각 이벤트 발생시 5,120개의 샘플길이의 음향방출 파형이 저장되도록 하였고, pre-trigger를 사용하여 문턱 값을 넘기 전의 파형도 640개의 샘플 길이로 저장되도록 설정하였다.

피로인장실험은 표 2와 같은 조건으로 실험하였으며 실제 환경을 모델링하기 위해 다른 응력을 가해서 실험데이터를 수집하였고, 문턱 값은 잡음수준보다 3dB 높게 설정하였다. 인장력(force)을 50KN, 70KN으로 변

표 2. 피로인장실험 변수 설정

Table 2. Parameters for the fatigue tensile test.

실험 No.	Force [KN]	Stress ratio (R)	Stress Interval [MPa]	Stress cycle (sine)	Threshold	회수
1	50	0.1	12.5~125	10Hz	60	5
2	70	0.1	17.5~175	10Hz	70	2

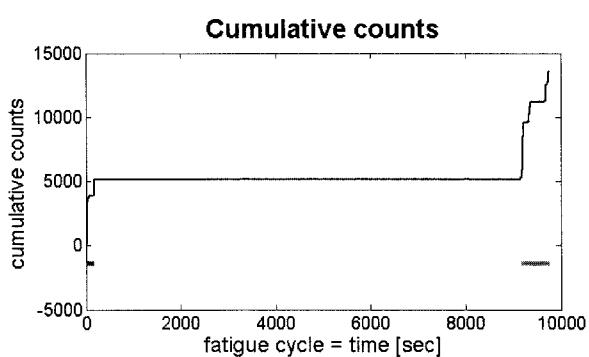
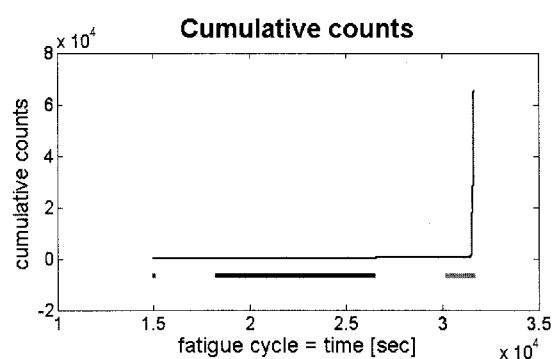


그림 13. 실험 조건에 따른 누적카운트 수의 분포
Fig. 13. Distribution of cumulative counts for each experimental condition.

화시켰으며 각 실험 조건별 음향방출 특성의 예를 그림 13에 보였다. 클래스1의 시작시간과 클래스1, 3 구간의 누적 카운트 수의 기울기가 다르므로 정규화 과정이 필요하다.

2. 균열 발생 및 성장의 패턴인식 실험

피로인장실험에서 얻어진 데이터를 표 3과 같이 다섯 가지 형태로 나누어 실험하였다. 표 내부의 숫자는 실험에 사용된 피로인장실험에서 각각 얻어진 데이터 집합의 개수이다. 이러한 실험을 통해 압력조건이 달라지는 실제 환경에서도 제안하는 기법이 강인하게 동작하는지 테스트 한다. 데이터 형태 1, 2는 학습과 테스트의 조건이 같은 경우, 3, 4는 조건이 다른 경우, 5는 조건이 섞여있는 경우에 대한 실험이다.

표 3. 모의실험을 위한 데이터 구성 형태
Table 3. Configuration of data for simulation.

Pressure Condition	Test Condition No.	Train		Test	
		50KN R=0.1	70KN R=0.1	50KN R=0.1	70KN R=0.1
same pressure	1	3	0	2	0
	2	0	1	0	1
different pressure	3	5	0	0	2
	4	0	2	0	5
mixed pressure	5	3	1	2	1

비균열/균열 발생 패턴 분류를 위해 2층 구조 MLP의 은닉 뉴런 수는 20개를 사용하였고, 학습 알고리즘으로 Levenberg-Marquardt(LM)^[18] 알고리즘을 사용하였으며, 초기 가중치 값은 [-0.05, 0.05]에서 랜덤하게 선택한다. 은닉 뉴런의 수는 주어진 문제를 LM 알고리즘으로 90% 이상의 성공률을 보이며 충분히 학습이 가능한 최소의 개수를 선택한 것이다. 학습 종료조건으로는 RMSE(root mean squared error)를 0.01로 설정하였고 최대 반복회수(epoch)는 5,000번으로 하였다. 과형 특징추출 단계에서 출력으로 나온 24차원의 특징과 변수 파라미터로 상승시간, count to peak, 에너지, 진폭의 4개 특징을 사용함으로써, 총 28차원의 입력을 사용하였다.

균열 성장 패턴 분류를 위해서는 2층 구조 MLP의 은닉 뉴런 수는 25개로 하였으며, 학습 종료조건으로는 RMSE를 0.1로 설정하였고 최대 반복회수는 5,000번으로 하였다. 과형 특징추출 단계에서 출력으로 나온 22 차원의 특징과 변수 파라미터로 상승시간, 에너지, 진폭의 3개 특징을 사용함으로써, 총 25차원의 입력을 사용하였다. 비균열/균열, 균열성장 패턴분류에서 표 3의 각 실험 데이터 구성형태에 대해 신경회로망의 초기 가중치를 바꿔서 50회씩 반복 실험하였다. GMM은 입력으로 에너지만을 사용하였고 3개의 가우시안 함수를 사용하였으며 Expectation-Maximization(EM) 알고리즘을 사용하여 학습하였다. 최대 반복회수는 10^6 으로 하였다.

표 4는 여러 가지 압력조건의 데이터에 대해 특징추출 과정을 변화시키면서 균열발생 클래스에 대한 패턴인식 정확도와 미탐지율(miss alarm rate)을 보여주며, 그림 14는 균열발생 패턴인식 결과의 예를 보여준다. 제안된 특징추출 과정을 통해 얻어진 최종 특징정보가 다른 압력조건에서 얻어진 실제 환경에 가까운 데이터

표 4. 균열발생 패턴인식 정확도

Table 4. Recognition accuracy of crack initiation.

Test Cond. No.	Without CMS+DELTA		With CMS		With CMS+DELTA	
	Test accuracy [%]	Miss alarm rate [%]	Test accuracy [%]	Miss alarm rate [%]	Test accuracy [%]	Miss alarm rate [%]
1	100 (best) 80.2(mean) 34.1(worst)	14.5	98.0 (best) 77.2(mean) 33.7(worst)	9.9	98.2 (best) 78.8(mean) 33.8(worst)	10.3
2	92.3 (best) 83.5(mean) 71.8(worst)	12.5	80.6 (best) 77.1(mean) 72.1(worst)	11.2	92.3 (best) 85.2(mean) 78.1(worst)	9.4
3	72.3 (best) 57.1(mean) 38.1(worst)	50.2	90.2 (best) 83.3(mean) 76.7(worst)	12.6	90.6 (best) 86.9(mean) 76.1(worst)	8.4
4	77.4 (best) 59.0(mean) 45.9(worst)	36.9	81.1 (best) 78.1(mean) 74.3(worst)	23.2	81.4 (best) 79.9(mean) 77.8(worst)	18.1
5	95.2 (best) 86.2(mean) 61.2(worst)	11.7	93.1 (best) 63.7(mean) 41.2(worst)	7.7	92.2 (best) 85.1(mean) 61.2(worst)	7.7

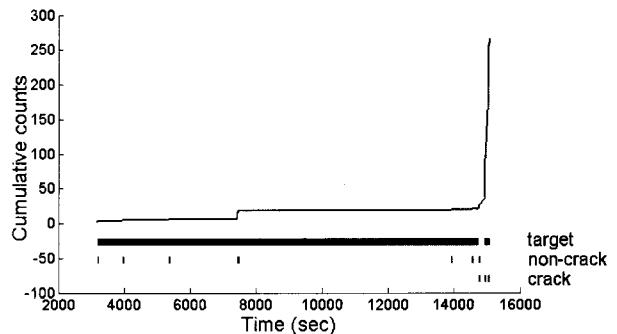


그림 14. 균열발생 패턴인식(with CMS+DELTA) 결과의 예

Fig. 14. Recognition result of crack initiation (with CMS+DELTA).

에 대해 좋은 테스트 성능을 나타낼 수 있다. 표 4에서 보면 CMS 기법이 다른 압력조건 데이터집합을 학습, 테스트 할 때 특히 좋은 성능향상과 미탐지율 감소를 나타낸다. 이는 다른 압력에 의한 물리적인 메커니즘의 변화가 다른 채널특성으로 나타나는데 CMS 기법을 통해 이러한 왜곡을 제거한 결과이다. 같은 압력 조건인 데이터집합에서는 약간의 성능저하가 보이는데 이는 오경보의 증가로 인한 것이며, 미탐지는 오히려 감소시키는 결과를 보여주었다. 델타특징의 사용은 전체적인 성능향상과 미탐지를 감소시켰다. 비균열 클래스에 있는 잡음을 포함한 음향방출 과형은 시간적으로 간격이 넓고 신호간의 상관성이 적으나, 균열 클래스는 짧은 시간 내에 유사한 특성과 서로 상관되는 특징이 있으므로 델타특징이 특히 미탐지를 감소시키는 역할을

표 5. 균열성장 시 MLP의 패턴인식 정확도
Table 5. Recognition accuracy of the MLP when the crack grows.

Test Cond. No.	Without CMS+DELTA		With CMS		With CMS+DELTA	
	Test accuracy [%]	false alarm rate [%]	Test accuracy [%]	false alarm rate [%]	Test accuracy [%]	false alarm rate [%]
1	84.5 (best) 70.8(mean) 41.6(worst)	14.8	83.4 (best) 72.0(mean) 42.6(worst)	16.9	80.8 (best) 71.6(mean) 40.6(worst)	14.3
	56.4 (best) 50.0(mean) 41.6(worst)	45.8	57.4 (best) 47.5(mean) 42.6(worst)	45.7	50.5 (best) 46.6(mean) 41.2(worst)	46.1
	54.8 (best) 53.4(mean) 51.0(worst)	14.6	54.4 (best) 53.3(mean) 52.6(worst)	4.5	54.7 (best) 54.3(mean) 53.5(worst)	4.3
4	75.1 (best) 67.0(mean) 58.5(worst)	38.2	75.5 (best) 68.7(mean) 52.9(worst)	38.9	74.0 (best) 67.8(mean) 59.5(worst)	34.4
	70.9 (best) 56.2(mean) 46.2(worst)	28.3	69.2 (best) 58.0(mean) 49.6(worst)	28.3	78.1 (best) 61.0(mean) 51.6(worst)	26.7

하였다. 따라서 CMS와 델타특징을 사용한 음향 특징 추출기법에 효과적으로 미탐지를 감소시키고, 전체적인 성능을 향상시킴을 알 수 있다.

표 5에서 특징추출 과정 변화에 의한 균열성장 인식 정확도의 변화를 볼 때 균열신호 발생 인식실험과 달리 뚜렷한 결과의 향상이 나타나지 않는다. 이는 앞서 설명한 균열성장 단계에서 시간에 따라 클러스터링 할 때 음향방출파가 클래스에 중복되어 존재하는 것을 의미한다. CMS 기법은 균열성장 인식에서 압력조건이 다른 경우의 실험에서 오경보를 줄이는 효과를 가지며, 델타 특징은 약간의 성능개선과 오경보를 줄이는 역할을 하고 있는데, 이는 균열성장 단계에서 시간에 따른 균열성장의 동특성을 이용할 경우 성능을 향상시키면서 오경보를 줄일 수 있다는 것을 보여준다.

표 6은 GMM의 오경보율과 미탐지율을 보여준다. 표에서 #1~#7 데이터는 실험에 사용된 각각의 데이터 집합의 번호를 의미한다. 이 실험에서는 오경보율을 0%로 만들 수 있도록 클래스1에서 학습된 확률의 최소 값보다 작게 설정하였다. 따라서 클래스3 신호 중 클래스1에서 한 개라도 존재하는 에너지 값은 미탐지로 처리

표 6. GMM의 오경보율과 미탐지율
Table 6. False alarm rate and miss alarm rate of GMM.

alarm rate	50KN, R=0.1						70KN, R=0.1					
	#1data	#2data	#3data	#4data	#5data	#6data	#7data	#1data	#2data	#3data	#4data	#5data
false	0	0	0	0	0	0	0	0	0	0	0	0
miss	2.2	0	96.7	92.0	88.2	61.9	67.1					

표 7. 통합기법에서 검출된 클래스3 첫 번째 프레임의 백분율
Table 7. Percentage of the first frame detected as class 3 by the combined method.

Test Condition No.	50KN, R=0.1						70KN, R=0.1					
	#1data	#2data	#3data	#4data	#5data	#6data	#7data	#1data	#2data	#3data	#4data	#5data
1	1.0	1.0	1.0	1.0	1.0	—	—	—	—	—	—	—
2	—	—	—	—	—	—	—	1.0	1.0	—	—	—
3	—	—	—	—	—	—	—	1.0	1.0	—	—	—
4	1.0	1.0	7.1	9.6	4.2	—	—	—	—	—	—	—
5	1.0	1.0	6.1	1.4	1.0	4.2	1.0	—	—	—	—	—

하였으므로 미탐지율은 상당히 높은 것을 볼 수 있다. 미탐지로 처리되는 신호는 클래스1에서 학습된 신호로서 실험 데이터에 따라 비율이 다르게 나타나는 것을 볼 수 있으며, 클래스3의 높은 미탐지율을 MLP와의 상호 보상하도록 결정규칙으로 통합하였다. 균열성장의 활동 단계인 클래스3에서는 전체 시간구간의 정확도보다 균열이 클래스3에 진입 후 얼마나 빨리 정확히 인식하는 첫 번째 시작점이 중요하게 작용하므로 표 7과 같은 균열성장 성능평가 방법을 이용하였다.

표 7은 통합기법의 결정규칙에서 클래스3라고 인식된 첫 번째 프레임의 전체 프레임에 대한 백분율을 보여주고 있다. 클래스3라고 인식된 첫 번째 프레임은 GMM, MLP 두 개의 기법에서 일정시간, 동시에 발생하는 시작점을 찾아서 통보한 것이며, 이러한 통합기법에서 결정 규칙은 오경보율을 0%로 만들 수 있고, 클래스3의 전체 프레임 개수 중에서 10% 이내의 빠른 시간에 클래스3을 인식할 수 있음을 보여준다.

그림 15는 균열성장 패턴인식 결과를 보여준다. 누적 카운트 곡선 아래 첫 번째 수평 바는 세 개의 클래스

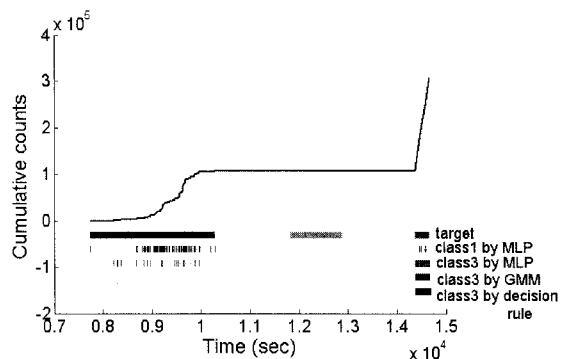


그림 15. 균열성장 패턴인식(with CMS+DELTA) 결과의 예

Fig. 15. Recognition result of crack growth (with CMS+DELTA).

를 구분한 것이고, 두 번째 수평 바는 MLP에 의해 클래스1으로 인식한 결과이며, 세 번째 수평 바는 MLP에 의해 클래스3으로 인식한 결과이다. 네 번째 수평 바는 GMM의 결과를 나타내고, 다섯 번째 수평 바는 MLP와 GMM을 결정규칙에 의해 통합해 클래스3을 인식한 결과이다. 클래스3에서 두 기법이 어느 시간동안 연속된 인식 결과를 가질 때, 이를 통합한 결정규칙에 의해 클래스3이 인식됨을 볼 수 있다.

V. 결 론

본 논문에서는 금속에서 발생하는 균열성장 시간을 정확히 추정하기 위한 패턴인식 기법을 제안하였다. 물리적 균열성장 3단계의 음향방출 현상은 시간에 따라 겹치는 문제점으로 인해 균열성장 시간의 추정을 어렵게 한다. 따라서 균열발생과 성장의 전 시간과정을 고려하는 두개의 패턴인식기를 사용하여 학습의 복잡도를 감소시키고, 음향방출 동특성을 균열성장 인식기법에 적용하여 미탐지, 오경보를 최소화 하였다. 균열성장 시간의 추정이 용이하도록 시간에 따른 클러스터링 기법을 적용하였고, 실제 환경에 가깝게 금속에 가해지는 여러 압력조건에서도 강인하게 동작하는 특징추출 단계가 포함되었다. 구분이 어려운 균열성장의 시간에 따른 클러스터링 문제를 해결하기 위해 확률분포모델인 GMM을 MLP와 통합하여 상호 보상하는 구조를 적용했으며, 특징추출 단계에서는 주파수영역의 특징을 위해 두 개의 필터뱅크를 설계하였고, 시간영역에서는 분별력에 의한 특징선택(feature selection) 단계를 적용하였다.

본 연구에서는 균열발생 클래스 이전의 잡음신호와 압력변화 만을 고려하였는데, 실제 환경에서는 여기서 고려한 것보다 다양한 음향방출 잡음과 주변에서 유입되는 잡음 등이 포함될 수 있으며 이러한 잡음을 제거하는 기법과 강인한 특징 추출에 관한 추후 연구가 필요하다.

참 고 문 헌

- [1] D. Fang and A. Berkovits, "Fatigue design model based on damage mechanisms revealed by acoustic emission measurements," *Journal of Engineering Materials and Technology*, vol. 117, no. 2, pp. 200-208, 1995.
- [2] N. Godin, S. Huguet, and R. Gaertner, "Integration of the Kohonen's self-organising map and k-means algorithm for the segmentation of the AE data collected during tensile tests on cross-ply composites," *NDT&E International*, vol. 38, no. 4, pp. 299-309, 2005.
- [3] Z. Shi, B. Beadle, S. Hurlebaus, J. Jarzynski, and L. Jacobs, "Study of acoustic emission from incipient fatigue failure," *Review of Progress in QNDE*, vol. 18, pp. 295-401, 1999.
- [4] I. M. Daniel, C. G. Sifniotopoulos and J.-J. Luo, "Analysis of acoustic emission output from propagating crack," *Review of Progress in QNDE*, vol. 17, pp. 1331-1338, 1998.
- [5] S. Rippengill, K. Worden, K. M. Holford, and R. Pullin, "Automatic Classification of Acoustic Emission Patterns," *Journal of the British Society for Strain Measurement*, vol. 39, no. 1, pp. 31-41, 2003.
- [6] M. Huang, L. Jiang, P. K. Liaw, C. R. Brooks, T. Seeley, and D. L. Klarstrom, "Using acoustic emission in fatigue and fracture Materials research," *Journal of the Minerals, Metals and Materials Society*, vol. 11, pp. 1-14, 1998.
- [7] C. Ennaceur, A. Laksimi, C. Herve, and M. Cherfaoui, "Monitoring crack growth in pressure vessel steels by the acoustic emission technique and the method of potential difference," *Int. Journal of Pressure Vessels and Piping*, vol. 86, pp. 197-204, 2006.
- [8] C. C. Tan, N. F. Thornhill, and R. M. Belchamber, "Principal component analysis of spectra with application to acoustic emissions from mechanical equipment," *Transactions of Institute of Measurement and Control*, vol. 24, no. 4, pp. 333-353, 2002.
- [9] V. Kappatos and E. Dermatas, "Classification of acoustic emission and drop signals using SVM, MLP and RBF Networks," in *Proc. 5th National Conference on Non-Destructive Testing of the Hellenic Society for NDT*, Athens, Hellas, Nov. 2005.
- [10] S. Hugueta, N. Godin, R. Gaertner, L. Salmon, and D. Villard, "Use of acoustic emission to identify damage modes in glass fibre reinforced polyester," *Composites Science and Technology*, vol. 62, no. 10, pp. 1433-1444, 2002.
- [11] H. K. Min, C. Y. Lee, J.-S. Lee, and C. H. Park, "Abnormal Signal Detection in Gas Pipes Using Neural Networks," in *Proc. IEEE Int. Conf. Industrial Electronics Society*, pp. 2503-2508,

Taipei, Taiwan, Nov. 2007.

- [12] P. H. Hutton, R. J. Kurtz, M. A. Friesel, J. R. Skorpik, and J. F. Dawson, "Acoustic emission/flaw relationships for inservice monitor of LWRs", Pacific Northwest Laboratory, Tech. Rep. NUREG/CR-5645: PNL-7479, Oct. 1991.
- [13] X. Huang, A. Acero, and H. -W. Hon, *Spoken Language Processing: A Guide to Theory, Algorithm, and Systems Development*, Prentice Hall, 2001.
- [14] R. M. Stern, B. Raj, and P. J. Moreno, "Compensation for environmental degradation in automatic speech recognition," in *Proc. ESCA-NATO Tutorial and Research Workshop on Robust Speech Recognition using Unknown Communication Channels*, pp. 33-42, Pont-à-Mousson, France, April, 1997.
- [15] T. H. Applebaum and B. A. Hanson, "Regression features for recognition of speech in quiet and in noise," in *Proc. Int. Conf. Acoustics, Speech, and Signal Processing (ICASSP)*, vol. 2, pp. 985-988, Toronto, Canada, April 1991.
- [16] K. Goebel and W. Yan, "Feature selection for tool wear diagnosis using soft computing techniques," in *Proc. ASME Manufacturing in Engineering Division*, vol. 18, pp. 157-163, 2000.
- [17] Standard test method for measurement of fatigue crack growth rates, ASTM Std. E647-05, July 2005.
- [18] M. T. Hagan and M. B. Menhaj, "Training feedforward networks with the marquardt algorithm," *IEEE Transactions on Neural Networks*, vol. 5, no. 6, pp. 989-993, Nov. 1994.

저 자 소 개



이 수 일(학생회원)
 2003년 동명정보대학교 정보통신
 공학과 학사
 2008년 한국과학기술원 전자전산
 학부 공학석사
 1993년~2001년 한국전력공사
 2001년~현재 한수원(주)
 NETEC 연구원

<주관심분야 : 신경회로망, 고장진단>

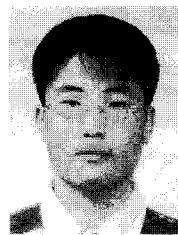


이 종 석(정회원)
 1999년 한국과학기술원 전기및전
 자공학과 학사
 2001년 한국과학기술원 전자전산
 학과 공학석사
 2006년 한국과학기술원 전자전산
 학과 공학박사

2006년~2008년 한국과학기술원 전자전산학부
 연수연구원

2008년~현재 로잔공과대학교 전기공학부
 연수 연구원

<주관심분야 : 시청각 음성인식, 멀티모달 인터
 페이스>



민 홍 기(학생회원)
 2004년 한국과학기술원 전기및전
 자공학과 학사
 2006년 한국과학기술원 전자전산
 학과 공학석사
 2006년~현재 한국과학기술원
 전자전산학부 박사과정

<주관심분야 : 신경회로망, 음성인식>



박 철 훈(정회원)
 1984년 서울대학교 전자공학과
 학사
 1985년 Caltech 전자공학과 공학
 석사
 1990년 Caltech 전자공학과 공학
 박사

1991년~현재 한국과학기술원 전자전산학부 교수
 <주관심분야 : 지능시스템, 신경회로망, 최적화,
 지능제어>