

주성분 분석과 인공신경망을 이용한 피로균열 열림·닫힘 시 음향방출 신호분류

Classification of Acoustic Emission Signals for Fatigue Crack Opening and Closure by Artificial Neural Network Based on Principal Component Analysis

김기복*[†], 윤동진*, 정중채*, 이승석*

Ki-Bok Kim*[†], Dong-Jin Yoon*, Jung-Chae Jeong* and Seung-Seok Lee*

초 록 3가지 종류의 알루미늄 합금강의 피로균열 진전 시 균열 열림 및 닫힘에 따른 음향방출 신호를 분류하기 위하여 주성분 분석 방법과 인공신경망 기법을 적용하였다. 재료의 균열 열림과 닫힘, 마찰 등과 같은 여러 가지 AE 신호를 얻기 위하여 피로시험을 수행하였다. 주성분 분석결과 AE 파라미터의 제 1 및 제 2 주성분만으로도 균열 열림 및 닫힘에 대한 AE 신호의 변이를 94%이상 설명할 수 있는 것으로 분석되어 주성분 분석 기법을 이용한 균열 열림 및 닫힘에 대한 신호해석이 가능한 것으로 나타났다. AE 신호의 주성분들을 입력변수로 사용한 인공신경망을 이용하여 균열 열림 및 닫힘을 분류할 수 있는 분류기를 개발하고 평가한 결과 분류기의 입력 변수로서 2개의 주성분을 이용할 경우 전체 AE 파라미터를 입력변수로 사용한 경우 보다 분류 성능이 향상되었다.

주요용어: 음향방출, 균열 열림 및 닫힘, 주성분 분석, 인공신경망, 알루미늄 합금

Abstract This study was performed to classify the fatigue crack opening and closure for three kinds of aluminum alloy using principal component analysis (PCA). Fatigue cycle loading test was conducted to acquire AE signals which come from different source mechanisms such as crack opening and closure, rubbing, fretting etc. To extract the significant feature from AE signal, correlation analysis was performed. Over 94% of the variance of AE parameters could accounted for the first two principal components. The results of the PCA on AE parameters showed that the first principal component was associated with the size of AE signals and the second principal component was associated with the shape of AE signals. An artificial neural network (ANN) analysis was successfully used to classify AE signals into six classes. The ANN classifier based on PCA appeared to be a promising tool to classify AE signals for fatigue crack opening and closure.

keywords: acoustic emission, crack opening and closure, principal component analysis, artificial neural network, aluminum alloy

1. 서 론

교량 구조물이나 항공기 재료 등과 같은 구조물들은

다양한 크기의 지속적인 반복하중을 받고 있기 때문에 이에 따른 균열발생, 균열진전, 최종 파단으로 전개되는 피로현상을 초래하게 된다. 따라서 이러한 균열발생 및

균열진전을 조기에 검출하는 것은 매우 중요하며 최근 들어 음향방출 기술을 이용하여 구조물의 피로균열을 검출하기 위한 연구들이 수행되고 있다[1-4]. 특히, 피로균열 성장속도(fatigue crack growth rate)가 응력확대계수의 함수로 표현되기 때문에 피로균열진전 시 음향방출 발생특성과 응력확대계수와의 상관관계를 구명하기 위한 연구가 수행되었다[1,2]. 저장도 구조용 강에 대한 피로균열 단합과 AE 특성 사이에 상관성이 있음이 보고되었으며 [3,4] 2024-T3 및 4340 탄소강 시편에 대한 균열 열림 및 단합에 따른 AE 발생특성 구명 연구가 수행되었다[5]. 특히 최근 구조용 알루미늄 2024-T4와 6061-T6 재료에 대한 피로균열 진전 시 발생하는 AE 특성에 대한 결과로서 균열 열림 및 단합 시 재료의 미세조직과 기계적 특성인 인장강도와 항복강도에 따라 AE 특성이 달라질 수 있음이 보고되었다[6].

음향방출 기술을 적용하는데 있어서 가장 큰 기술적인 어려움은 원하지 않는 외부잡음으로부터 의미 있는 신호를 분리하거나 분류하는 문제이다. 이러한 AE신호 분류 기법 및 적용과 관련하여 신호처리 및 형상인식 기법이 많이 연구되어 왔다[7-12]. 분류문제에 있어서 AE신호로부터 특징들을 추출하고 분석하여 분류하기 위한 기법으로서 비교사 학습(unsupervised learning)에 의한 군집분석[10], 선형판별함수 등 비교적 간단한 통계적 분류 기법을 적용한 연구가 수행되었으며[7,11] 여러 가지 분류기들 중 신경회로망을 이용한 분류기의 인식율(recognition rate)이 가장 양호한 결과를 나타내는 것으로 보고되고 있다[7-9,12,13].

재료의 피로균열 거동으로 인한 균열진전 시 측정되는 AE 신호는 비선형 거동 특성뿐만 아니라 여러 가지 파라미터를 포함하는 다변량 데이터의 속성을 나타내게 된다. 피로균열 진전 시 균열선단에서의 microcrack의 성장속, 균열 열림에 의해 AE가 발생할 수 있으며 피로균열의 단합과 균열면 사이의 마찰에 의해서도 AE가 종종 발생하기 때문에 균열진전 특성과 상관없는 AE 신호를 반드시 분류하여야 한다. 또한 피로균열 실험에서 발생하는 많은 양의 방대한 AE 신호로부터 패턴분류를 위한 분석에서 독립변수가 많은 다차원 공간이 아닌 2차원 또는 3차원 공간상에서의 직관적인 관찰이 가능하다면 다차원 데이터의 처리가 매우 용이해질 것이다. 이러한 다차원 데이터에서 정보의 손실을 줄이면서 2차원 또는 3차원의 데이터로 차원을 낮출 수 있는 방법으로 주성분 분석이 많이 이용되고 있다[2,14,15].

본 연구에서는 다변량 데이터 해석에 많이 사용되는 주성분 분석 기법을 이용하여 알루미늄 합금인 2024-T4, 6061-T6, 7075-T6의 피로균열 진전에 따른 균열 열림 및 단합 시 발생하는 AE 특성을 해석하고자 하였다. 또한 주성분 분석 기법과 인공신경망을 조합한 AE 신호 분류기를 개발하고 평가하였다.

2. 주성분 분석 및 AE 신호 분류

2.1. 주성분 분석

주성분 분석을 위하여 먼저 AE 파라미터를 데이터 행렬 X 로 구성하여야 한다. M 개의 AE 파라미터와 각 파라미터에서 N 개의 데이터가 얻어졌다면 X 는 $M \times N$ 의 행렬로 표시할 수 있으며, 열을 기준으로 정규화한 후에 X 의 공분산 행렬을 계산한다. X 의 공분산 행렬은 $M \times M$ 의 XX^T 로 표시된다. 공분산 행렬의 고유값(eigen value)과 고유 벡터(eigen vector)를 계산한 다음 각 고유 벡터와 AE 파라미터의 내적을 구한다. 여기서 고유값이 가장 큰 고유 벡터에 내적한 주성분의 값을 제 1 주성분, 두 번째로 큰 고유값의 고유 벡터에 대한 주성분의 값을 제 2 주성분이라 부른다. 총, 3, 4, ..., M 개의 주성분까지 계산할 수 있으며, 각 고유 벡터의 방향은 데이터 행렬의 M 차원 공간상에서 변이를 각각 직교화된 방향으로 분해한 방향을 의미한다. 따라서 주성분 분석을 통해 각 AE 파라미터 사이에 존재하는 공선성(collinearity)를 제거할 수 있다[15].

2.2. AE 신호 분류를 위한 인공 신경망

신경회로망은 입력과 출력과의 선형/비선형 관계를 모형화할 수 있는 범용 함수로서 각 노드간의 연결로 이루어진 퍼셉트론(perceptron)의 단층 또는 다층 구조로 이루어지며 데이터의 학습을 통해서 각 층의 노드와 연결 강도를 결정하고 연결 강도를 통해서 입력과 출력 관계를 기억하게 된다. AE 신호 분류문제에 이러한 신경회로망 기법이 많이 적용되어 왔다[8,9,12].

신경회로망은 크게 목표 값의 존재 유무에 따라 교사 학습(supervised learning)과 비교사 학습(unsupervised learning)이 있다. 교사 학습에서는 신경회로망을 학습시킬 때 목표 값을 제시하고 이들 목표 값에 근사하도록 학습을 시키는 기법으로서 대표적인 학습 방법으로 다층

퍼셉트론에 의한 역전파 알고리즘이 많이 사용된다. 비교사 학습은 데이터에 대한 출력 값이 정해져 있지 않고, 입력 데이터의 특성에 따라 데이터를 여러 집단으로 분류화하여 군집화(clustering)시키는 학습 방법으로서, 경쟁 학습(competitive learning)과 자기 조직화 지도(self organizing maps) 등이 있다[16].

본 연구에서는 균열 열림과 닫힘에 따른 AE 신호의 분류가 가능한 분류기를 개발하기 위하여 신경회로망을 이용하였으며 역전파 알고리즘에 의한 교사 학습을 적용하였다.

3. 실험장치 및 방법

3.1. 시편

본 연구에서 사용된 시편은 항공기 구조용 재료에 많이 사용되는 Al2024-T4, Al6061-T6, Al7075-T6의 3가지 종류의 알루미늄 합금을 대상으로 하였다. 피로균열 진전 시 균열 열림 및 닫힘에 대한 실험을 위해 소형인장(CT) 시편에 대하여 균열이 시편 중심부에서 발생하여 진전되도록 노치(notch)의 중심에 5mm 길이의 웨브론(chevron) 노치를 가공한 후 예비균열을 만들었다. 제작된 CT시편에 대한 실험조건 및 각 재료에 대한 물성값들은 Table 1과 같다.

Table 1 Specimens, mechanical properties, and test conditions.

Material	Al2024-T4	Al6061-T6	Al7075-T6
Tensile Strength (MPa)	540	315	532
Yield Strength (MPa)	412	286	554
Elongation (%)	14	14.6	9.25
Rolling Direction	L-T		
Fatigue Cycle	1 Hz		

3.2. 피로 실험 및 AE 측정

피로 실험은 기계식 재료시험기 Instron (Model 8652)을 사용하였으며 1 Hz의 피로 사이클에 대해 일정한 진폭의 하중을 주면서 실험을 수행하였으며 모든 실험에 대해 응력비 (stress ratio; R)은 0.1로 하였다.

AE 신호는 다채널 상용 AE 시스템인 MISTRAS 2001 (PAC)과 디지털 오실로스코프(LeCroy 9354A)를 사용하

여 측정하였다. AE 센서는 100~1,000 kHz 범위의 광대역형 센서(WD, by PAC)의 2 종류를 사용하였다.

AE 장비로부터 측정된 AE 신호로부터 Table 2에서 보는 바와 같은 10개의 AE 파라미터를 도출하여 분석에 사용하였다.

Table 2 AE parameters extracted from AE signals

AE parameter	Meaning
RT	rise time
RC	ring-down count
EN	energy
ED	event duration
PA	peak amplitude
CP	count to peak
RF	reverberation frequency
IF	initiation frequency
SS	signal strength
BE	absolute energy

3.3. AE와 균열 열림 및 닫힘과의 관계

본 연구에서 피로 실험 시 발생하는 AE 와 피로균열의 열림 및 닫힘 거동과의 관계를 규명하기 위한 개념은 Fig. 1에서 보는바와 같다[6]. 일정한 주기로 반복되는 하중변화는 Fig. 1(a)에서와 같이 정현적(sinusoidal)인 sine 파로 표시되며 각 cycle에서의 첨두값을 최대의 균열 열림 및 닫힘 거동에 대응시켰다. 따라서 Fig. 1(b)와 같이 하중이 0° 에서 360° 까지 변할 때 균열의 열림과 닫힘이 반복된다. 위상각 변화 0°~180° 범위는 균열이 열리는 구간으로서 180°에서 열림이 최대가 되며(Fig. 1(c)), 180°~360° 범위는 균열이 닫히는 구간으로서 360°에서 Fig. 1(d)와 같이 균열이 완전히 닫히게 된다.

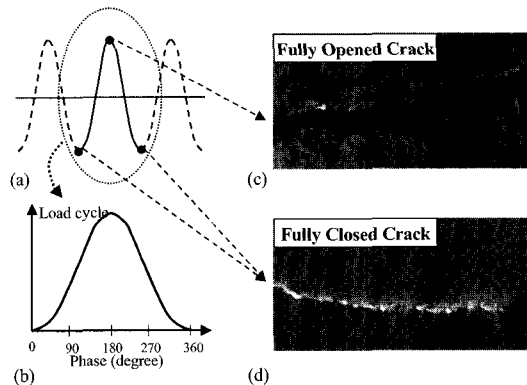


Fig. 1 A concept of crack opening and closure

4. 결과 및 고찰

4.1. 피로 사이클에 따른 누적 AE 발생 수

임의의 피로 사이클 구간에서 약 300초 동안의 사이클 동안에 발생한 AE의 누적값을 Fig. 2에 나타내었다. 일정한 하중 진폭에서 1 Hz의 피로사이클 주파수 변화에 따른 누적 AE hits는 거의 직선적으로 증가하였는데 이러한 경향은 기존의 연구결과와 거의 유사한 결과를 나타내는 것으로 분석되었다[6,17].




Fig. 2 Cumulative AE hits versus number of fatigue cycle

4.2. AE 신호 분류를 위한 파라미터 선택

분류기 설계에서 신호 또는 형상 분류를 위하여 분류에 유용한 특징 또는 파라미터를 선택해야 한다. 일반적으로 특징변수들 간에 선형종속적인 관계가 있을 경우 즉, 어떤 특징변수가 다른 특징변수들의 선형결합으로 표현되는 다중공선성이 있을 경우 적어도 한 개의 특징변수는 다른 특징변수들로 설명될 수 있으므로 특징변수로서의 역할을 할 수 없게 된다. 따라서 이러한 다중공선성 문제를 고려하지 않을 경우 통계적 결과가 매우 불안정하게 된다. 이러한 분류 및 판별분석에서 유의한 특징변수들을 선정하기 위하여 여러 가지 특징값 선택방법들이 적용되고 있다[8-9,13,18]. 본 연구에서는 분석하고자 하는 AE 파라미터의 수가 10개로서 그 수가 비교적 작기 때문에 각 AE 파라미터들 간의 상관분석을 통하여 적절한 파라미터를 선택하고자 하였다[18]. 즉, 상관계수의 절대값이 1에 가까울수록 두 변수 사이의 상호 의존성이 매우 높으며 공선성이 존재함을 의미한다. Table 3에서의

분석결과를 근거로 상관계수 0.8 이상의 매우 강한 상관관계를 나타내는 EN, SS, BE를 제외한 7개의 AE 파라미터들을 특징변수로 선택하였다.

Table 3 Correlation analysis results between AE parameters

	RT	RC	EN	ED	PA	CP	RF	IF	SS
RC	0.11	1							
EN	0.09		1						
ED	0.26	0.78		1					
PA	0.02	0.74	0.70	0.53	1				
CP	0.40	0.54	0.41	0.54	0.31	1			
RF	0.30	0.17	0.10	0.18	0.13	0.08	1		
IF	0.05	0.29	0.20	0.36	0.11	0.34	0.29	1	
SS	0.09				0.70	0.42	0.10	0.20	1
BE	0.02			0.75	0.71	0.30	0.06	0.11	

4.3. 주성분 분석을 통한 균열 열림·닫힘 고찰

균열 열림·닫힘 거동을 분석하기 위하여 주성분 분석을 실시하였다. 분석은 개별시편이 아닌 전체 시편을 대상으로 하였으며 결과는 Table 4에서 보는 바와 같다. 전체 7개의 주성분에서 첫 번째 및 두 번째 주성분이 전체 데이터 변이의 94%이상을 차지하는 것으로 나타났다. 즉, 제 1 주성분 및 제 2 주성분만으로도 균열 열림 및 닫힘을 설명할 수 있음을 의미한다.

Table 4 Eigenvalues of principal components and percentage proportion

Principal component	Eigen value	Percentage proportion
1	7.5185	85.49
2	0.7664	8.71
3	0.4409	5.01
4	0.0522	0.59
5	0.0091	0.10
6	0.0071	0.08
7	0.0003	0.02

또한 고유벡터와 AE 파라미터를 이용하여 다음 식 (1), (2)와 같이 제 1 주성분과 제 2 주성분을 표시할 수 있다.

$$PC1 = 0.049RT + 0.096RC + 0.970ED \\ + 0.050PA + 0.005CP + 0.097RF + 0.186IF \\ \dots (1)$$

$$PC2 = 0.056RT - 0.009RC - 0.217ED \\ + 0.102PA + 0.012CP + 0.401RF + 0.882IF \\ \dots (2)$$

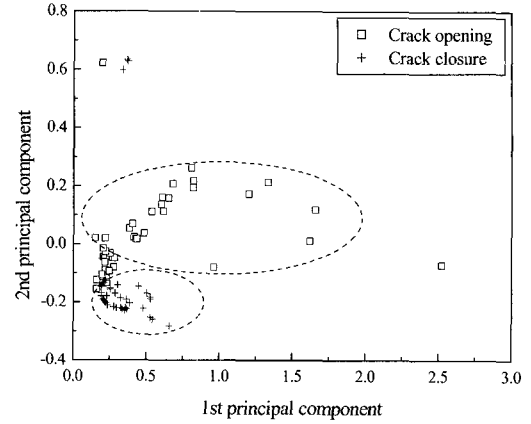
여기서, PC1은 제 1 주성분, PC2는 제 2 주성분을 각각 나타낸다.

상기 식 (1)과 (2)를 이용하여 다차원 데이터인 AE 특징값들이 제 1 주성분 및 제 2 주성분이라는 새로운 특징값을 가지는 2차원으로 차원이 축소될 수 있다. 따라서 제 1 주성분과 제 2 주성분을 이용하여 특징값-특징값 선도를 작성하여 균열 열림 및 닫힘 시 AE 신호의 분류 가능성을 검토하였다.

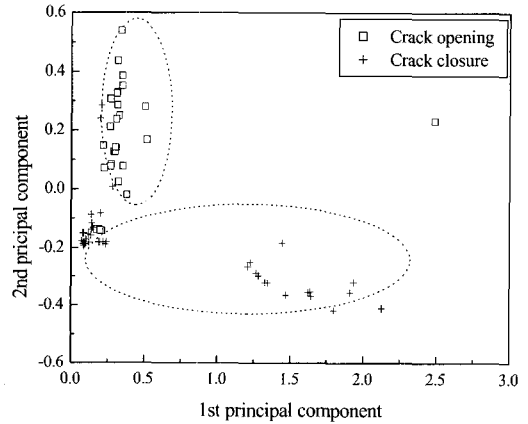
제 1 주성분 식 (1)에서 각 파라미터의 계수들이 모두 양의 값을 가지고, 특히 RC, ED, RF, IF의 계수가 다른 AE 파라미터의 계수보다 비교적 큼을 알 수 있다. 이것은 제 1 주성분에서 이들 AE 파라미터의 영향이 큰 것을 의미한다. 따라서 제 1 주성분에서 각 파라미터의 계수가 모두 양이므로 이들의 물리적 의미를 고려해 볼 때 제 1 주성분은 AE 신호의 발생 및 크기에 관계됨을 유추할 수 있다. 한편 제 2 주성분 식 (2)의 경우 RC 및 ED의 계수가 음의 값을 나타내고 있는데 이것은 AE 신호의 특성에 따라 즉, RC 및 ED와 다른 파라미터들간의 상대적인 크기에 따라 제 2 주성분이 양 및 음의 값을 나타낼 수 있다는 것을 의미한다. 즉, 균열 열림 혹은 닫힘 시의 AE의 waveform 형태나 모양 등에 관계될 것으로 생각될 수 있다.

Fig. 3에서의 특징값-특징값 선도에서 균열 열림의 경우 제 2 주성분은 양의 값을 나타내며 균열 닫힘의 경우 음의 값을 나타내었다. 전체적으로 균열이 열릴 때 제 2 주성분의 값이 양의 값을 나타내는 것은 상대적으로 ringing이 작으며 지속시간이 짧지만 피크값이 큰 신호가 많이 발생함을 의미한다. 반면, 균열이 닫힐 경우를 고찰해보면 상대적으로 ringing이 많고 지속시간이 길면서 피크값이 비교적 작은 신호가 발생하기 때문에 제 2 주성분의 값이 음의 값을 나타내는 것으로 판단된다.

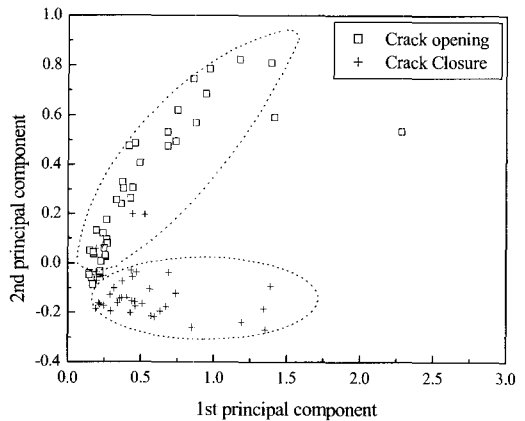
따라서 Fig. 3의 결과로부터 주성분 분석 결과를 이용할 경우 균열 열림 및 닫힘 시 AE 신호의 분류가 가능할 것으로 판단된다.



(a) AI2024-T4



(b) AI6061-T6



(c) AI7075-T6

Fig. 3 Feature-feature plot for (a) AI2024-T4 (b) AI6061-T6 and (c) AI7075-T6 specimen by the first two principal components

4.4. 인공신경망을 이용한 AE 신호 분류

균열 열림 및 닫힘 시 발생한 AE 신호를 분류하기 위한 인공신경망의 구성은 학습 회수 및 속도, 수렴속도, 출력결과 등을 고려하여 은닉층이 하나인 구조로 하였으며 은닉층의 노드수는 8개로 하였다. 입력층의 입력패턴으로서 7개의 AE 파라미터를 모두 이용하는 방법과 2개의 주성분을 이용하는 2가지 방법을 이용하여 각각의 경우에서 분류기의 성능을 비교하였다. 한편, 출력층의 노드수는 본 연구에서의 시편이 3종류이고 각 시편에서 균열 열림 및 닫힘의 2가지로 분류해야 하므로 총 6개의 출력노드를 가지게 된다. 신경망 학습시 학습회수는 50,000번, 오차의 목표값은 10e-5, 학습율은 0.1, 모멘텀은 0.95, 각 층간의 전달함수는 sigmoid 함수를 사용하였으며 MATLAB 소프트웨어를 이용하여 분류기를 구현하였다.

분류해야할 패턴으로서 AI2024-T4 시편의 경우 균열 열림을 A2O, 균열 닫힘을 A2C, AI6061-T6 시편의 경우 균열 열림을 A6O, 균열 닫힘을 A6C, AI7075-T6 시편의 경우 균열 열림을 A7O, 균열 닫힘을 A7C로 하여 각각 6개의 분류군으로 설정하였다.

인공신경망 분류기로서 전체 AE 파라미터를 모두 입력변수로 사용하는 경우와 AE 파라미터에 대한 2개 주성분을 입력변수로 사용하는 2개의 분류기를 구성하여 각 분류기의 분류성능을 비교하였다. 각 인공신경망 분류기에 대한 학습 및 검증결과는 Table 5 및 Table 6에서 보는바와 같다. 전체 AE 파라미터를 분류기의 입력으로 사용하였을 경우 학습에 의한 평균 분류율은 92%, 학습에 사용되지 않은 데이터로 검증한 결과 분류율은 83%를 나타내었다. 반면, AE 파라미터에 대한 2개 주성분을 입력으로 할 경우 Table 6에서 보는바와 같이 학습에 의한 평균 분류율은 98%, 미학습 데이터로 검증한 결과는 90%로 나타나 전반적으로 전체 AE 파라미터를 입력변수로 사용했을 경우 보다 양호한 분류성능을 나타내었다.

이상의 결과로 미루어볼 때 인공신경망의 입력변수로서 개별 특징변수들을 모두 사용하는 것보다 서로 직교하게 되는 주성분으로 차원을 축소하여 입력하는 것이 바람직할 것으로 판단된다. 즉, 분류를 위한 변수선택절차에 의해 적절한 특징변수들을 선택한다 하더라도 AE 신호의 경우 이러한 특징변수들이 모두 동일한 하나의 waveform에서 얻어지게 되므로 정도의 차이는 있지만 변수들 간에 선형종속적인 관계가 여전히 존재할 가능성을 높을 것으로 사료된다. 이러한 경우 주성분 분석을 함으

로써 변수들 간에 내재해 있는 다중공선성의 영향을 감소시킬 수 있는 서로 직교하는 입력변수들로 변환된다. 따라서 통계적으로 완전히 독립적인 새로운 특징변수들이 인공신경망 분류기에 입력되게 되므로 분류성능이 향상되는 것으로 판단된다.

Table 5 Results of classification analysis between crack opening and closure by ANN classifier using whole AE parameters (values in parenthesis are for validation)

Class	A2O	A2C	A6O	A6C	A7O	A7C	R.R.
A2O		0(0)	0(0)	1(1)	0(1)	0(4)	93(85)
A2C	0(1)		0(0)	0(0)	0(0)	0(1)	100(95)
A6C	0(0)	0(1)		0(0)	1(0)	0(1)	97(94)
A6C	0(2)	9(14)	3(0)		0(2)	3(4)	63(45)
A7O	0(0)	0(0)	0(3)	0(0)		0(0)	100(93)
A7C	2(4)	0(2)	0(0)	0(0)	1(0)		93(85)
Total recognition rate (%)							

Table 6 Results of classification analysis between crack opening and closure by ANN classifier using the first two principal components (values in parenthesis are for validation)

Class	A2O	A2C	A6O	A6C	A7O	A7C	R.R.
A2O		0(1)	0(0)	1(0)	0(0)	0(2)	100(93)
A2C	0(0)		0(0)	0(0)	0(0)	0(1)	100(98)
A6C	0(1)	0(1)		0(0)	0(0)	0(1)	100(91)
A6C	0(2)	0(1)	0(1)		1(2)	0(4)	98(75)
A7O	0(0)	0(0)	0(1)	0(0)		0(0)	100(98)
A7C	2(2)	0(4)	2(1)	0(0)	0(0)		90(83)
Total recognition rate (%)							

5. 요약 및 결론

알루미늄 합금강에 대한 피로시험 시 발생하는 AE 신호를 이용하여 피로균열 열림 및 닫힘을 해석하고 분류하기 위하여 주성분 분석과 신경회로망 기법을 적용하였다. 주요 연구결과를 요약하면 다음과 같다.

1. 주성분 분석결과 AE 파라미터의 제 1 및 제 2 주성분만으로도 균열 열림 및 닫힘에 대한 AE 신호의 변

이를 94%이상 설명할 수 있는 것으로 분석되었다.

2. 제 1 주성분과 제 2 주성분을 이용하여 특징값-특징값 선도를 분석한 결과 균열이 열릴 때의 제 2 주성분 값은 대체적으로 양의 값을 나타내었으며 균열이 닫힐 때는 음의 값을 나타내어 주성분 분석 기법을 이용한 균열 열림 및 닫힘에 대한 신호해석이 가능한 것으로 나타났다.
3. 인공신경망을 이용하여 균열 열림 및 닫힘을 분류할 수 있는 분류기를 개발하고 평가한 결과 분류기의 입력 변수로서 2개의 주성분을 이용할 경우 전체 AE 파라미터를 입력변수로 사용한 경우보다 분류 성능이 향상되었다.

참고문헌

- [1] 윤동진, 정중채, 박휘립, 김기복, 이승석, “응력확대계수와 음향방출 변수를 이용한 피로균열 거동 연구”, 비파괴검사학회지, Vol. 20, No. 5, pp. 412-423, (2000)
- [2] 김기복, 윤동진, 정중채, 박휘립, 이승석, “주성분 회귀 분석 및 인공신경망을 이용한 AE 변수와 응력확대계수와의 상관관계 해석”, 비파괴검사학회지, Vol. 21, No. 1, pp. 80-90, (2001)
- [3] Z. F. Wang, J. Li, W. Ke, Y. S. Zheng, Z. Zhu, and Z. G. Wang, “Acoustic Emission Monitoring of Fatigue Crack Closure,” *Scripta Metallurgica*, Vol. 27, No. 12, pp. 1691-1694, (1992)
- [4] Z. F. Wang, J. Li, W. Ke, and Z. Zhu, “Characteristics of Acoustic Emission for A537 Structural Steel During Fatigue Crack Propagation,” *Scripta Metallurgica*, 27(5), pp. 641-646, (1992)
- [5] I. M. Daniel, J. J. Luo, C. G. Sifniotopoulos, and H. J. Chun, “Acoustic Emission Monitoring of Fatigue Damage in Metals,” *Nondestructive Testing and Evaluation*, Vol. 14, pp. 71-87, (1998)
- [6] 정중채, 윤동진, 박휘립, 김기복, 이승석, “구조용 알루미늄 합금에서의 피로균열 열림 및 닫힘 시 AE 발생 특성 연구”, 비파괴검사학회지, Vol. 22, No. 2, pp. 155-169, (2002)
- [7] 주영상, 정현규, 심철무, 임형택, “형상인식법을 이용한 음향방출신호의 분류”, 비파괴검사학회지, Vol. 10, No. 2, pp. 23-31, (1990)
- [8] 이강용, 임장묵, 김준섭, “적용형 신호형상 인식프로그램의 개발과 AE법에 의한 용접부 결함분류에 관한 연구”, 비파괴검사학회지, Vol. 16, No. 1, pp. 34-45, (1996)
- [9] 이강용, 황인범, “신경망 AE 신호 형상인식을 위한 특징값 선택법의 개발과 용접부 및 회전체 결함 분류에의 적용 연구”, 비파괴검사학회지, Vol. 21, No. 1, pp. 46-53, (2001)
- [10] A. A. Anastasopoulos and T. P. Philippidis, “Clustering Methodology for the Evaluation of Acoustic Emission from Composites”, *Journal of Acoustic Emission*, Vol. 13, No. 1/2, pp. 11-22, (1995)
- [11] O. Y. Kwon and K. Ono, “Acoustic Emission Characterization of the Deformation and Fracture of an SiC-Reinforced, Aluminum Matrix Composite”, *Journal of Acoustic Emission*, Vol. 9, No. 2, pp. 123-129, (1990)
- [12] K. Ono and J. Wu, “Pattern Recognition Analysis of Acoustic Emission from Fatigue of 2024-T4 Aluminum”, *Progress in Acoustic Emission*, pp. 237-242, (1996)
- [13] 송성진, “용접 결함 분류를 위한 초음파 형상 인식 기법”, 비파괴검사학회지, Vol. 15, No. 2, pp. 395-405, (1995)
- [14] A. Chichibu, T. Kikuchi and T. Kishishita, “Principal Component Analysis of AE Waveform Parameters for Investigating an Instability of Geotechnical Structures,” *Journal of Acoustic Emission*, Vol. 11, No. 4, pp. S47-S56, (1993)
- [15] M. A. Sharaf, D. L. Illman and B. R. Kowalski, “Chemometrics”, John Wiley & Sons, New York, (1986)
- [16] J. Hertz, A. Krogh, and R. G. Palmer, “Introduction to the theory of neural computation,” Addison-Wesley Publishing Company, USA, (1991)
- [17] D. O. Harris and H. L. Dunegan, “Continuous Monitoring of Fatigue Crack Growth by Acoustic Emission”, *Experimental Mechanics*, Feb. pp.71-81, (1973)
- [18] SAS Institute, SAS/STAT Guide for Personal Computer, Version 6 Edition, SAS Institute, Cary, NC (1987)