

주성분 회귀분석 및 인공신경망을 이용한 AE 변수와 응력확대계수와의 상관관계 해석

Analysis on Correlation between AE Parameters and Stress Intensity Factor using Principal Component Regression and Artificial Neural Network

김기복*, 윤동진*, 정중채*, 박휘립*, 이승석*

Ki-Bok Kim*, Dong-Jin Yoon*, Jung-Chae Jeong*, Philip Park* and Seung-Seok Lee*

초 록 AE 신호와 재료의 기계적 물성과의 관계를 정량적으로 제시할 수 있는 방법을 개발하였다. 재료의 여러 가지 기계적 성질들 중 피로균열 거동에 관련된 응력확대계수를 중심으로 AE 신호와 같은 다변량 데이터의 처리에 많이 사용되고 있는 주성분 회귀분석과 비선형적 문제 해결에 적합한 신경회로망 기법을 이용하였다. 이를 위하여 강 교량 부재인 SWS490B 강에 대한 피로균열진전과 실험을 수행하였으며 표준 CT 시편에 대한 피로균열진전 시 발생하는 AE 신호의 각 변수와 응력확대계수와의 관계를 고찰하였다. 통계분석 방법인 변수선택법을 적용한 결과 AE 카운트(RC), 에너지(EN), 신호지속시간(ED)의 각각에 대한 유의성이 높은 것으로 나타났으나 전반적으로 전체 AE 변수를 모두 이용할 경우 통계적 유의성이 높은 것으로 나타났다. 부재의 반복하중 시 발생하는 피로균열진전을 정량적으로 도출할 수 있는 응력확대계수 추정모델을 개발하고 평가하였다. 미지 시료에 대하여 개발된 모델의 응력확대계수 예측 성능을 분석한 결과 주성분 회귀모델과 인공신경망 모델 모두 우수한 예측성능을 나타내었으나 전반적으로 인공신경망 모델이 주성분 회귀모델보다 다소 양호한 것으로 분석되었다.

주요 용어: 음향방출, 피로균열, 응력확대계수, 주성분 회귀분석, 인공신경망

Abstract The aim of this study is to develop the methodology which enables to identify the mechanical properties of element such as stress intensity factor by using the AE parameters. Considering the multivariate and nonlinear properties of AE parameters such as ringdown count, rise time, energy, event duration and peak amplitude from fatigue cracks of machine element, the principal component regression(PCR) and artificial neural network(ANN) models for the estimation of stress intensity factor were developed and validated. The AE parameters were found to be very significant to estimate the stress intensity factor. Since the statistical values including correlation coefficients, standard error of calibration, standard error of prediction and bias were stable, the PCR and ANN models for stress intensity factor were very robust. The performance of ANN model for unknown data of stress intensity factor was better than that of PCR model.

Keywords: acoustic emission, multivariate statistical analysis, principal component regression model, artificial neural network, stress intensity factor, fatigue crack

1. 서론

음향방출(AE) 기술은 비파괴 시험법의 하나로서 재료의

물성 및 거동에 대한 연구를 비롯하여 소재의 특성 평가, 물리적인 현상 규명 등의 학술적인 분야에서의 연구와

더불어 산업 설비에서의 구조물 안전 진단, 생산 공정 및 공구류 감시, 토목 건축에의 적용, 전자산업, 의료분야 등에 활발히 적용되고 있다.

음향방출을 이용하여 재료 또는 구조물의 특성이나 현상을 규명하기 위해서는 재료나 구조물 내부로부터 전달된 파동을 측정하고 해석해야 하는데 재료 내에서 발생된 AE 신호의 전파 및 감지는 재료의 내부 상태에 크게 영향을 받는다. 따라서 감지되는 AE 신호는 재료의 물성, 기하학적 특성, 주위 환경조건 및 측정조건에 따라 큰 영향을 받기 때문에 이러한 신호로부터 재료의 내부 상태를 정량적으로 추정하는 것은 일반적으로 매우 힘든 작업이다. 음향방출 기법은 초음파 탐상법과는 달리 passive한 검사방법이기 때문에 AE 신호의 해석과정은 재료내부의 상태를 추정(estimate)하기 위한 과정일 뿐이다. 즉, 기계 구조물의 변형 및 파괴 시에 발생하는 AE를 분석할 경우 재료의 변형과 손상의 정도를 추정할 수는 있지만 AE 신호와의 정량적 상관성 도출은 AE 신호의 특성상 어려울 것으로 판단된다.

비파괴 평가기술로서 AE는 부재의 균열 개시 및 진전 뿐만 아니라 재료내의 미시적인 거동을 파악할 수 있는 고감도 기술이며 재료의 물성 연구에 아주 유용한 방법이다. 재료의 피로균열 거동으로 인한 균열진전은 일반적인 해석적 방법으로 설명되기 곤란한 비선형적 요소를 많이 포함하고 있으며, 균열진전시 측정되는 대표적인 AE 신호는 응력확대계수와 같은 하나의 종속변수와 여러 개의 독립변수 즉, 신호의 상승시간(RT; rise time), ringdown count(RC), 신호지속 기간(KED; event duration), 에너지(EN; energy), 최대 진폭(PA; Peak amplitude) 등과 같은 여러 개의 반응변수를 가지는 다변량 데이터의 속성을 지닐 것으로 사료된다. 관련 연구를 살펴보면 음향방출 기술을 이용한 피로균열 측정이 가능함이 보고되었으며 [2-6] Wang[3-4] 등은 구조용 강 시편에 대한 피로균열 실험결과 응력확대계수와 음향방출 카운트 사이에 상관성이 있음을 확인하였다. 지금까지의 연구들은 주로 AE 신호와 피로균열간의 관계 고찰 및 피로균열 모니터링 연구[2-6]와 AE 신호의 패턴분류[1, 7-9] 등이 주로 이루어져 왔다. 최근의 연구로서 응력확대계수와 음향방출 관계를 이용하여 균열 길이 및 균열 검출 능력을 평가하기 위한 연구가 수행되었으며[20] AE 신호를 이용한 기계적 특성들에 대한 정량화 연구는 거의 없는 것으로 조사되었다.

본 연구는 AE 신호와 재료의 기계적 성질과의 관계를 정량적으로 제시 할 수 있는 방법을 개발하기 위하

여 수행되었다. 구조용 용접강에 대하여 피로균열 거동에 관련된 응력확대계수를 중심으로, AE 신호와 같은 다변량 데이터의 처리에 많이 사용되고 있는 주성분 분석 방법과 비선형적 문제 해결에 적합한 신경회로망 기법을 이용하여 부재의 반복하중 시 발생하는 피로 균열진전을 정량적으로 도출할 수 있는 예측 모델을 개발하고 평가하였다.

2. 주성분 회귀분석 및 인공 신경망

AE 파라미터와 같은 여러 개의 반응변수를 이용하여 균열 진전속도나 응력확대계수 등을 설명하기 위한 방법으로서, AE 변수의 다변량적인 속성으로 인하여 여러 개의 반응변수(AE 파라미터)들 중 단일 파라미터만을 이용하여 종속변수(응력확대계수 등)를 해석하는 방법은 적합하지 않을 것으로 사료된다. 따라서 이러한 재료의 기계적 특성을 해석하기 위해서는 관련된 정보인 다변량 데이터를 종합적으로 이용하여야 할 것으로 사료된다. 이러한 방법으로서 다변량 통계해석 방법인 다중 선형회귀(MLR; multi linear regression), 주성분회귀(PCR; principal component regression), 부분최소자승회귀(PLS; partial least squared regression), 인공신경망(ANN; artificial neural network) 등이 주로 이용되고 있다[10-12].

다중 선형회귀 방법은 회귀분석 모델에 포함되는 변수의 수가 비교적 적기 때문에 회귀모델의 구성이 간단한 장점이 있으나 AE 파라미터와 같이 반응변수가 많은 변수집단에서 응력확대계수의 설명에 적합한 반응변수를 찾아내는 것은 쉽지 않은 것으로 생각된다. 또한 일반적으로 변수들 상호간에 높은 상관관계가 있는 경우 회귀모델의 개발 과정에서 다중 공선성(Multicollinearity)의 문제점이 발생하는 경우가 많다[12]. 따라서 본 연구에서는 여러 개의 반응변수를 가지는 스펙트럼 데이터 등의 분석에서, 포함되는 변수의 설명력이 강함과 동시에 비교적 안정적인 결과를 나타내는 것으로 알려진 PCR 기법을 적용하여 응력확대계수를 추정하고 예측할 수 있는 통계적 모델을 개발하였다. 또한 AE 파라미터와 같은 비선형 문제 해결에 적합한 인공신경망 기법을 이용하여 응력확대계수를 추정하고 예측할 수 있는 모델을 개발하여 PCR 방법과 비교·분석하였다.

이를 위하여 먼저 응력확대계수 추정모델에 포함될 최적 반응변수의 개수를 결정하고 응력확대계수에 유의한 반응변수를 선정하기 위하여 통계적인 기법중의 하나인 변수선택법을 적용하였다[13].

2.1. 주성분 분석 및 회귀모델

주성분 분석 및 회귀 모델은 음향 방출 데이터와 같은 여러 개의 반응변수에 대하여 얻어진 다변량 데이터 즉, 다차원적인 변수들을 축소 및 요약한 다음 차원을 단순화시켜 서로 상관되어 있는 반응변수들 예를 들어 RT, RC, ED, EN, PA 등의 상호간의 복잡한 구조를 서로 상관되지 않은, 혹은 독립적인 주성분이라고 불리는 새로운 변수로 유도한다. PCR 모델은 높은 상관관계를 가지고 있는 많은 다변량 데이터를 고유벡터 집합과 스코어로 분해하여 주성분이라는 소수의 상호 독립적인 새로운 변량으로 변환함으로써 다중 선형회귀모델의 단점인 다중 공선성(multicollinearity)을 제거함과 동시에 소수의 독립적인 주성분을 구성함으로써 다변량 데이터의 변이를 최대한 감소시키기 위한 통계기법이다[11, 15]. 즉, PCR 모델은 다중선형회귀 분석모델의 독립변수로서 소수의 특정한 변수만을 이용하는 것이 아니라 모든 측정된 AE 파라미터들을 종합적으로 해석하는 방법으로서 많은 수의 데이터를 소수의 주성분으로 축소한 다음 이러한 주성분의 분석을 통해 AE 파라미터를 해석한다.

본 연구에서 적용된 PCR 알고리즘은 다음과 같다. 먼저, AE 신호로부터 얻어지는 여러 개의 반응변수를 선형 조합하여 응력확대계수를 설명하기 위한 첫 번째 주성분 t_1 을 다음과 같이 구성한다.

$$t_1 = w_{11}x_1 + w_{12}x_2 + \dots + w_{1p}x_p \quad (1)$$

$$w_{1j} = \frac{\text{cov}(x_j, y)}{\sqrt{\sum_{k=1}^p \text{cov}^2(x_k, y)}}$$

여기서, t_1 = 제 1 주성분

x_p = 제 1 주성분 선형 조합의 p번째 반응변수 (독립변수, AE 각 파라미터)

w_{1p} = 제 1 주성분의 x_p 에 대한 기중치 계수

$\text{cov}(x, y)$ = x 와 y 의 공분산

$j = 1, 2, \dots, p$

p = 변수의 개수

상기 식(1)의 선형조합을 하나의 독립변수로 하여 종속변수(응력확대계수)를 설명할 수 있는 다음과 같은 단순 선형 회귀식을 구성한 후 회귀분석을 수행한다.

$$y = c_1 t_1 + y_1 \quad (2)$$

여기서, y = 종속변수(응력확대계수)

c_1 = 제 1 주성분에 대한 회귀계수

y_1 = 잔차벡터(또는 오차벡터)

상기 회귀식(2)에서 종속변수 y 에 대한 설명력이 너무 약할 경우 즉, 잔차 y_1 이 너무 클 경우 첫 번째 주성분과 서로 상관되지 않으면서 잔차 y_1 을 설명할 수 있는 두 번째 주성분, t_2 를 식 (1)과 같은 방법으로 구성된 다음 잔차 y_1 을 종속변수, 두 번째 주성분, t_2 를 독립변수로 하여 식 (2)와 같은 방법으로 단순 선형 회귀분석을 반복적으로 수행한다. 따라서 주성분 회귀분석은 변수들이 선형 조합된 각 주성분을 독립변수로 하여 개발된 회귀식의 잔차(또는 오차)들을 최소화하는 iterative한 방법으로서 MATLAB 소프트웨어를 이용하여 주성분 회귀분석 알고리즘을 구현하였다. 본 연구에서는 PCR 회귀모델 개발을 위해 NIPALS(nonlinear iterative partial least squares) 알고리즘을 적용하였으며[16], 모델의 최적 주성분 개수를 결정하기 위하여 교차검증(cross validation) 방법을 적용하였다[11]. 즉, PRESS(prediction residual error sum of squares)의 변화를 관찰하여 잔차(오차)의 값이 최소가 될 때의 주성분 개수가 최적 주성분 개수로 결정되며 이때 PCR 알고리즘이 종료된다.

2.2. 인공 신경망

현재 가장 널리 쓰이는 신경회로망의 구조는 다층 인식자 구조로서 학습 방법으로 오류역전파(BP, back propagation) 알고리즘이 주로 사용된다. BP 학습방법은 입력층(input layer)으로 입력된 신호는 각 층간의 전달 함수를 통하여 은닉층(hidden layer), 출력층(output layer)으로 전달된다. 이렇게 전달된 신호와 원하는 신호의 비교에 의해서 최종 출력층에서 목표값과 학습값 사이의 오차(error)가 결정되고, 이 오차가 다시 역방향으로 전달된 다음 일반화된 델타법(GDR, generalized delta rule) 또는 최급강하법(greatest descent method)을 이용하여 각 층의 기중치들을 갱신한다[17]. 이러한 BP학습 방법은 일반적으로 학습이 상당히 느리게 진행되며 지역적 최소치(local minima)에 빠져 더 이상 학습이 진행되지 않는 경우가 발생하기도 한다. 느린 학습 속도는 학습율을 크게 하면 개선이 될 수 있지만, 학습이 진행되면서 학습 데이터에 따라, 기중치들의 변화가 상당히 민감해져 학습 오차가 진동을 하는 경우가 발생할 수 있다. 따라서 일반적인 BP에서는 학습율을 임의로 크게 할 수 없으며 지역적 최소치에 빠지는 것도 일반적인 BP학습의 문제

점으로 지적되고 있다. 따라서 본 연구에서는 이러한 문제점을 해결하기 위하여 가중치를 갱신하기 위한 모넨텀 개념을 도입한 수정된 오류역전과 알고리즘을 이용하여 응력확대계수를 추정할 수 있는 인공신경망을 구성하였으며 MATLAB 소프트웨어를 이용하여 구현하였다[18].

2.3. 응력확대계수 추정모델의 평가방법

응력확대계수를 추정하기 위한 주성분회귀 모델과 신경망 모델의 개발 및 성능 평가는 형상인식법으로 널리 사용되는 supervised pattern recognition 방법[19]과 같이 AE 파라미터들을 훈련표본(training set)과 시험표본(test set)으로 나눈 다음 훈련표본을 이용하여 응력확대계수 추정모델을 개발한 다음 나머지 시험표본을 개발된 모델에 적용하여 그 성능을 평가하였다. 이를 위하여 먼저 각 모델의 개발에 사용된 훈련표본을 다시 모델에 적용하여 예측되는 응력확대계수 값과 실제 측정된 값이 일치하는지를 조사하였다. 즉, 예측 정밀도를 나타내는 예측표준오차(SEC, standard error of calibration)와 상관계수(R, correlation coefficient)를 검토하였다. 그 다음 각 모델에 미지의 새로운 AE 파라미터 즉, 모델의 개발에 사용되지 않은 시험표본을 적용하여 예측되는 응력확대계수 값과 실제 측정된 값을 비교하여 검증표준오차(SEP, standard error of prediction), Bias, 상관계수를 각각 구하였다. 이때 Bias와 SEP는 모델에 의한 예측값과 실제 측정값의 차이에 대한 평균과 표준편차를 각각 의미한다. 따라서 Bias와 SEP는 각각 시스템의 오차와 랜덤오차를 나타내게 되며, Bias는 대상 재료, 측정조건, 측정 장치의 변동 등에 따라 달라진다[11].

$$SEC = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{n - p - 1}} \tag{3}$$

$$Bias = \frac{\sum_{i=1}^n (y_i - \bar{y}_i)}{n} \tag{4}$$

$$SEP = \sqrt{\frac{\sum_{i=1}^n [(y_i - \bar{y}_i) - Bias]^2}{n - 1}} \tag{5}$$

여기서, y_i = 실제 측정된 i 번째 응력확대계수
 \bar{y}_i = 모델에 의해 예측된 i 번째 응력확대계수
 n = 데이터 개수
 p = 변수의 개수

3. AE 신호 분석 및 응력확대계수 추정 모델개발

3.1. AE 실험

본 연구에 사용된 시편과 장비는 본 연구의 선행 연구 [20]에서 사용되었던 시편과 장비를 그대로 사용하였다. 구조용 용접강(SWS490B)를 이용하여 두께가 9, 12.5, 20mm인 서로 다른 3종류의 표준 CT시편(L-T시편)을 제작한 다음 균열이 시편 중심부부터 발생하여 진전되도록 노치(notch)의 중심에 5mm 길이의 웨브론(chevron) 노치를 가공한 후 예비균열을 만들었다. 제작된 CT시편에 대한 실험조건 및 명칭은 Table 1과 같다.

피로시험을 위한 실험장치는 Fig. 1에서 보는바와 같다. 유압식 MTS를 이용하여 피로 사이클(cycle)을 각각 1, 2, 4 Hz의 3 가지로 하였으며 정확한 균열진전 속도 및 균열길이를 측정하기 위하여 CT 시편 한쪽 표면을 경면 처리한 다음 1mm 간격의 표시선을 그은 후 마이크로 줌 렌즈가 부착된 CCD 카메라로 표면 균열진전속도와 길이를 100 μ m 단위로 정밀하게 측정하였다. 실험에 사용된 AE 센서는 300 kHz의 공진형 센서(R30, PAC)와 100~1,000 kHz 범위의 광대역형 센서(WD, PAC)을 사용하였다. 피로 균열 진전시 발생하는 AE 신호는 다채널(multi-channel) 상용 AE 시스템인 MISTRAS 2001 (PAC)과 디지털 오실로스코프 (LeCroy 9354A)를 이용하여 측정하였다. 이때 AE 시스템의 문턱값은 32~48dB 범위에서 설정하였으며 발생하는 AE 신호는 프리엠프에서 60dB로 증폭된 후 AE 시스템과 디지털 오실로스코프에 각각 입력되어 분석되었다.

Table 1 Specimen and test conditions

| Name of Specimen | Rolling direction | Fatigue cycle | Thickness |
|--|-------------------|----------------------|-----------|
| LT-9/1 Hz LT-9/2 Hz LT-9/4 Hz | L-T | 1 Hz 2 Hz 4 Hz | 9 mm |
| LT-12/1 Hz LT-12/2 Hz LT-12/4 Hz | L-T | 1 Hz 2 Hz 4 Hz | 12.5 mm |
| LT-20/1 Hz LT-20/2 Hz LT-20/4 Hz | L-T | 1 Hz 2 Hz 4 Hz | 20 mm |

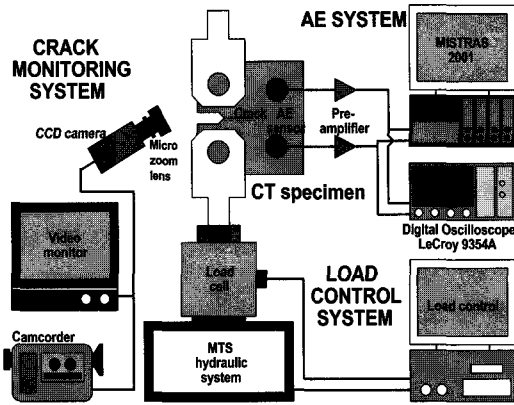


Fig. 1 Schematic diagram of experimental setup

3.2. 시편의 응력확대계수 및 AE 신호 처리

본 연구의 피로시험에서 하중 재하 사이클동안 발생하는 균열성장애 따른 응력확대계수는 순간적이고 연속적으로 변하는 값이므로 이를 정량화하기는 매우 어려울 뿐만아니라 임의 순간에서 발생한 AE 신호들을 응력확대계수에 일대일 대응시키는 것은 불가능할 것으로 생각된다. 따라서 Fig. 2에서 보는바와 같이 시편의 균열길이 100 μm 단위로 측정되므로 균열진전 측정구간인 100 μm 사이의 각 구간에서 균열이 진전됨에 따라 발생하는 각각의 AE 신호들에 대하여 RT, RC, EN, ED, PA 들을 구한 다음 구간 내 발생 신호들의 평균값들을 계산하여 응력확대계수에 대응하도록 하였다. 즉, 임의 균열 간격 끝에서의 응력확대계수에 이 구간 내에 발생한 모든 AE

신호들에 대한 AE 파라미터의 평균값들이 대응된다.

측정된 균열진전 길이로부터 CT 인장 표준시험편 (ASTM 규격 E-399-78)에 적용되는 다음 식을 이용하여 응력확대계수를 산출하였다[13].

$$K_I = \sigma \sqrt{\pi a} F(a/W) \tag{6}$$

여기서, K_I = 응력확대계수

σ = 시편의 공칭응력(kPa)

a = 균열의 길이

W = 시편의 핀홀 중심에서 시편 끝단까지의 거리

$F(a/W)$ = 시편의 기하학적 함수

기하학적 함수 $F(a/W)$ 는 다음과 같이 표시된다.

$$F(a/W) \approx 29.6 - 185.5(a/W) + 655.7(a/W)^2 - 1017.0(a/W)^3 + 638.9(a/W)^4 \tag{7}$$

3.3. 변수선택법을 이용한 반응변수 선정

각각의 AE 파라미터와 응력확대계수와의 관계를 고찰하기 위하여 각 응력확대계수에 따른 AE 파라미터를 분석한 결과 Fig. 3에서 보는바와 같이 RC, EN, ED의 경우 응력확대계수가 증가함에 따라 증가하는 경향을 나타내었다. 그러나 PA 및 RT의 경우 응력확대계수와의 상관관계가 낮은 것으로 나타났다. 이러한 기본적인 특성을 파악한 후 AE 각 파라미터들과 응력확대계수와의 상관관계를 구명하고 적절한 인자를 도출하기 위하여 통계분석을 실시하였다. 즉 목적값(응력확대계수)과 종속변수를 가장 잘 설명할 수 있는 변수들을 선택하는 알고리즘으로서 통계분석 도구인 SAS(statistical analysis system) version 6.02의 RSQUARE Procedure를 이용하였다[14]. RSQUARE 분석은 모든 가능한 회귀 방법을 수행하는 통계적 방법으로서 반응변수에 영향을 미칠 가능성이 있는 변수가 k 개 있을 때 2^k 개의 선형회귀모델에 적합시키면서 적절한 설명변수를 선택할 수 있게 해준다. 따라서 전체 9개 시편 각각에 대하여 총 288개의 모델에 대한 분석을 실시하게 되므로 본 연구에서는 이들 분석결과를 이용하여 Fig. 3에서의 결과를 확인함과 동시에 적절한 모델의 입력변수를 선정하고자 하였다. 분석결과 Fig. 3에서의 결과와 유사한 분석 결과를 나타내었는데 전반적으로 본 연구에서 측정된 전체 AE 파라미터가 모




Fig. 2 Explanation for each average value of AE parameter matching to stress intensity factor

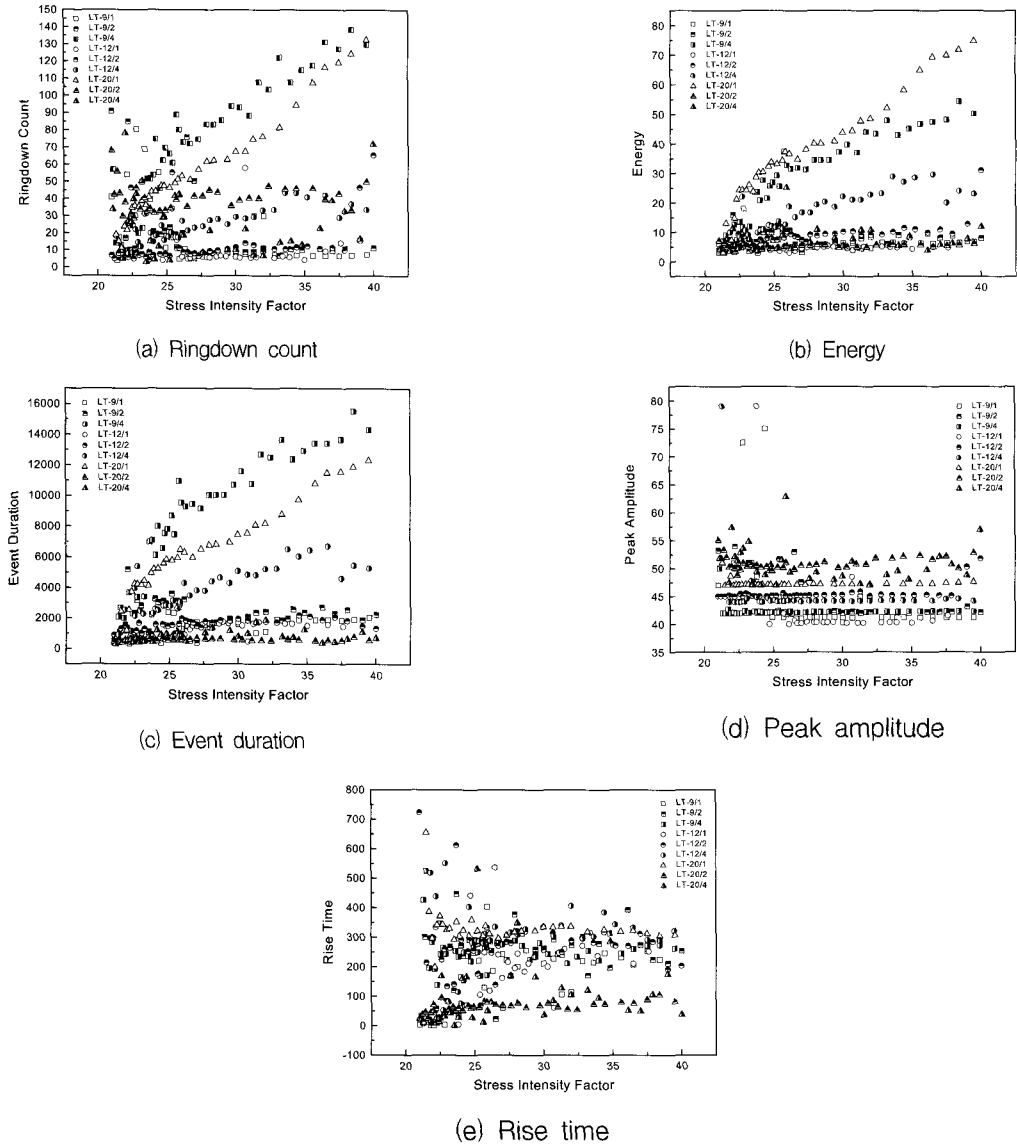


Fig. 3 AE parameters vs. stress intensity factor according to each specimen and load cycle conditions
 (a) ringdown count, (b) energy, (c) event duration, (d) peak amplitude and (e) rise time

델의 입력변수로 모두 포함될 경우 모델의 적합도를 나타내는 결정계수가 다소 높게 나타났다. 따라서 본 연구에서는 AE 파라미터인 RC, RT, EN, ED, PA의 5개 변수를 모두 입력변수로 사용하여 응력확대계수 추정모델을 개발하고 평가하였다.

한편, 본 연구에서의 응력확대계수 추정모델은 시편의 크기, 두께, 종류, 하중 재하 사이클 등에 상관없이

입력의 AE 파라미터에 대하여 신뢰성이 있는 응력확대계수를 제시할 수 있는 모델이 바람직할 것으로 사료된다. 그러나 예비분석결과 Fig. 3에서 나타난 바와 같이 각 시편별 및 하중 재하 속도별로 AE 각 파라미터들의 특성들이 다르게 나타나기 때문에 이러한 종합적인 추정모델을 개발하기는 어려울 것으로 판단된다. 따라서 응력확대계수를 추정하기 위한 모델은 본 연구

의 실험에 사용된 전체 9개 시편 각각에 대한 개별적 모델로 한정하였다.

3.4. 응력확대계수 추정을 위한 주성분회귀모델

응력확대계수 추정을 위한 PCR 모델을 개발하기에 앞서 각각의 시편별로 주성분 분석을 실시하였다. Table 2와 3은 전체 분석 결과 중 시편 두께 20mm, 1Hz의 하중 재하 속도일 때의 주성분 분석결과를 나타낸다. 전체 5개의 주성분 중 응력확대계수에 유의한 3개의 주성분을 선정한 결과를 나타내며 제 1 주성분이 전체 5개의 주성분에서 차지하는 비율이 0.999255로서 제 1 주성분이 응력확대계수를 설명하는 데 가장 유의성이 높은 성분인 것으로 분석되었다. Table 3은 각각의 주성분에 대하여 AE 각 파라미터의 개별적인 기여율을 나타낸다. Fig. 3과 변수선택법의 결과에서 확인되었듯이 제 1 주성분을 볼 때 RT와 PA의 기여율이 상대적으로 매우 낮음을 알 수 있다.

Table 4는 전체 측정 시편에 대한 주성분 회귀분석 및

검증 결과로서 대체적으로 분석에 사용된 주성분들과 응력 확대계수와의 상관관계가 양호한 것으로 분석되었으나 LT-20/4 시편의 경우 상관계수가 아주 낮게 나타났다. 이러한 문제점을 검토한 결과 LT-20/4 시편의 경우 응력 확대계수 계산을 위한 균열길이 측정에서 실험 데이터가 몇몇 구간에서 일부 확보되지 못한 것으로 지적되었다.

앞서 언급한 바와 같이 응력확대계수 추정모델을 개발한 후 모델의 개발에 사용되지 않은 미지의 데이터(시험 표본)를 이용하여 개발된 모델을 검증한 결과 대체적으로 모델의 개발과 관련한 통계량(상관계수, SEC)과 거의 비슷한 값으로서 안정적인 결과를 나타내었다. 한편 그림 4에 시험표본을 이용하여 개발된 주성분 모델을 검증한 결과를 LT-9/4, LT-12/2, LT-20/1에 대하여 나타내었으며 이들 시편에 대한 응력확대계수를 추정하기 위해 개발된 주성분 회귀방정식은 다음 식 (8)-(10)과 같이 표시된다. 따라서 Table 4와 Fig. 4의 결과로 미루어 볼 때 AE 신호에 대하여 주성분 회귀분석 기법을 적용할 경우 시편의 응력확대계수의 추정이 가능할 것으로 사료된다.

Table 2 Proportions of each principal component at LT-20/1

| Principal component | Proportion |
|---------------------|------------|
| 1 | 0.999255 |
| 2 | 0.000742 |
| 3 | 0.000003 |
| 4 | 0 |
| 5 | 0 |

Table 3 Principal component score at each AE parameter at LT-20/1

| AE Parameter | 1st principal component | 2nd principal component |
|--------------|-------------------------|-------------------------|
| RT | 0.14276 | -0.90812 |
| RC | 0.96492 | 0.23741 |
| EN | 0.99267 | 0.11717 |
| ED | 0.99445 | 0.09382 |
| PA | -0.36850 | 0.83869 |


Table 4 Results of analysis on principal component regression for estimation of stress intensity factor

| Item \ Specimen | | LT-9 | | | LT-12 | | | LT-20 | | |
|-----------------|-------------|--------|-------|--------|--------|-------|--------|--------|--------|-------|
| | | 1Hz | 2Hz | 4Hz | 1Hz | 2Hz | 4Hz | 1Hz | 2Hz | 4Hz |
| Calibration | R | 0.540 | 0.857 | 0.961 | 0.514 | 0.809 | 0.777 | 0.987 | 0.685 | 0.229 |
| | SEC | 10.234 | 3.041 | 1.542 | 3.488 | 3.323 | 6.339 | 0.931 | 4.186 | 5.993 |
| | Factor No.* | 2 | 5 | 5 | 5 | 5 | 2 | 3 | 5 | 5 |
| Validation | R | 0.505 | 0.872 | 0.962 | 0.438 | 0.557 | 0.576 | 0.982 | 0.857 | 0.213 |
| | SEP | 9.648 | 8.679 | 1.168 | 4.145 | 4.953 | 6.702 | 1.140 | 3.259 | 6.061 |
| | Bias | -2.493 | 1.550 | -0.352 | -3.170 | 0.964 | -0.256 | -0.108 | -0.393 | 0.694 |

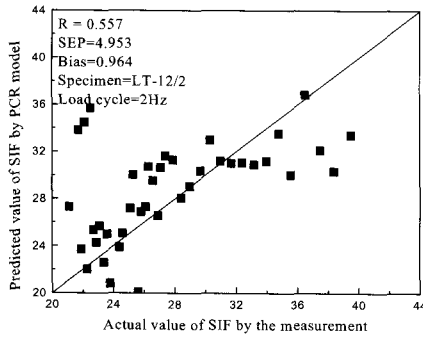
* Factor No. corresponds to the number of principal component

[LT-9/4 시편에 대한 응력확대계수 예측 회귀방정식]

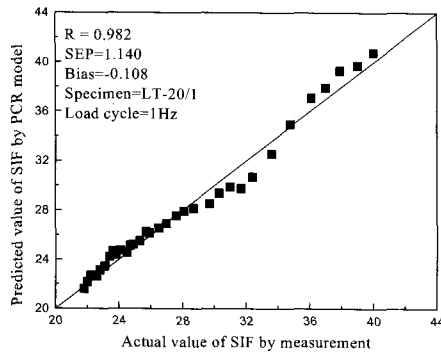
$$\begin{aligned} \text{SIF} = & 0.0026 \cdot \text{RT} - 0.1590 \cdot \text{RC} \\ & + 4.9637 \cdot \text{EN} - 0.0148 \cdot \text{ED} + 0.4408 \cdot \text{PA} \end{aligned} \quad (8)$$



(a) LT-9/4



(b) LT-12/2



(c) LT-20/1

Fig. 4 Validation results of principal component regression model between actual value and predicted value of SIF (a) LT-9/4, (b) LT-12/2 and (c) LT-20/1

[LT-12/2 시편에 대한 응력확대계수 예측 회귀방정식]

$$\begin{aligned} \text{SIF} = & 0.0023 \cdot \text{RT} + 0.0448 \cdot \text{RC} \\ & + 0.4988 \cdot \text{EN} + 0.0080 \cdot \text{ED} + 0.2155 \cdot \text{PA} \end{aligned} \quad (9)$$

[LT-20/1 시편에 대한 응력확대계수 예측 회귀방정식]

$$\begin{aligned} \text{SIF} = & 0.0049 \cdot \text{RT} + 0.0389 \cdot \text{RC} \\ & + 1.6505 \cdot \text{EN} - 0.0087 \cdot \text{ED} + 0.3639 \cdot \text{PA} \end{aligned} \quad (10)$$

3.5. 응력확대계수 추정을 위한 인공신경망

응력확대계수 추정을 위한 인공신경망에서 적절한 은닉층의 개수를 결정하기 위하여 먼저 몇 가지 기본 데이터를 이용하여 은닉층의 개수를 변화시켜 가면서 출력결과를 비교하여 가장 양호한 출력결과를 나타내는 은닉층의 개수를 결정하였다. 또한 각 은닉층의 노드수는 2에서 16까지 2씩 증가시키면서 가장 양호한 학습 결과를 나타내는 노드를 결정하였다. 개발된 망의 구조는 1→10→6→1의 구조로서 1개의 입력층과 2개의 은닉층 그리고 1개의 출력층으로 구성하였다. 신경망의 입력 패턴으로서 각 유닛에 AE 파라미터인 RT, RC, EN, ED, PA를 입력하고 출력층에는 입력되는 AE 파라미터에 대응되는 응력확대계수가 학습 목표값이 되도록 설정한 후 신경망의 학습을 수행하였다. 학습 수행시 오차의 목표값은 $10e^{-5}$, 학습율은 0.1, 모멘텀은 0.95로 하였으며 학습회수는 오차의 목표값 이하가 될 때까지로 하였다. 본 연구에서 구성된 인공신경망은 Fig. 5에서 보는바와 같으며 첫 번째 은닉층의 전달함수는 tangent sigmoid 함수를, 두 번째 은닉층에서 출력층까지의 전달함수는 pure linear 함수를 사용하였다[18].

주성분 회귀분석과 마찬가지로 각 시편에 대하여 훈련 표본을 이용하여 인공신경망을 학습시킨 후 학습에 사용되지 않은 시험표본을 이용하여 개발된 인공신경망의 예측 성능을 검증하였다. Table 5는 개발된 인공신경망 모델의 결과로서 전반적으로 주성분 회귀모델 보다 향상된 성능을 나타내는 것으로 나타났다.

또한, Fig. 6에서 보는바와 같이 개발된 인공신경망 모델을 시험표본으로 검증한 결과를 LT-9/4, LT-12/2, LT-20/1에 대하여 나타내었으며 본 연구에서 개발된 인공신경망을 이용할 경우 AE 신호로부터 매우 신뢰할 만한 응력확대계수의 추정이 가능할 것으로 판단되었다.

이상의 분석으로부터 일반적인 피로시험 또는 연속적인 반복하중을 받는 부재에 대한 비파괴 시험결과 자료를 분석하기 위한 방법으로서 자료의 다변량 속성 및 비

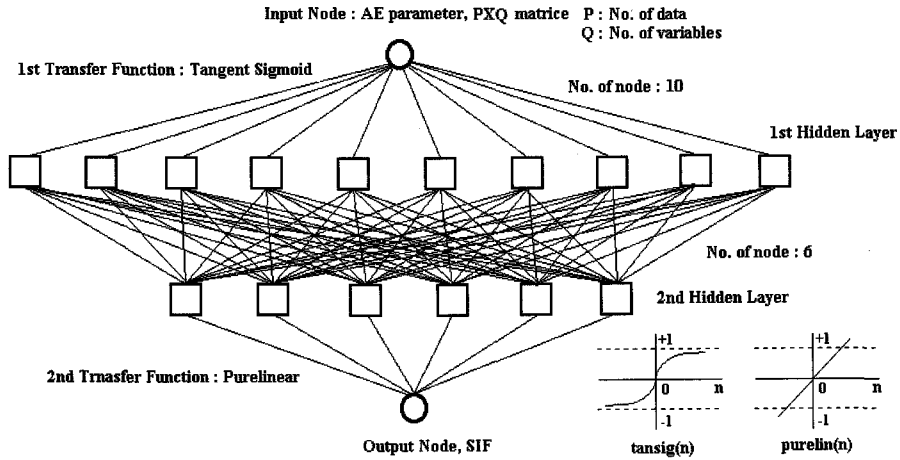


Fig. 5 Structure of artificial neural network model for prediction of stress intensity factor

Table 5 ANN learning results between stress intensity factor and AE parameters

| Specimen | Load Cycle | Structure of ANN | Calibration | | Validation | | |
|----------|------------|--|-------------|-------|------------|--------|--------|
| | | | R | SEC | R | SEP | Bias |
| Lt-9 | 1Hz | 1 → 6 → 10 → 1 Input layer 1st hidden layer 2nd hidden layer Output layer | 0.906 | 3.874 | 0.905 | 2.854 | 0.343 |
| | 2Hz | | 0.937 | 2.948 | 0.930 | 3.509 | 1.180 |
| | 4Hz | | 0.980 | 0.769 | 0.979 | 1.186 | -0.215 |
| Lt-12 | 1Hz | | 0.902 | 2.325 | 0.903 | 3.099 | 1.281 |
| | 2Hz | | 0.892 | 3.403 | 0.892 | 4.187 | 1.461 |
| | 4Hz | | 0.953 | 2.903 | 0.945 | 3.815 | 1.635 |
| Lt-20 | 1Hz | | 0.994 | 0.636 | 0.993 | 0.771 | 0.231 |
| | 2Hz | | 0.898 | 3.447 | 0.897 | 3.471 | -0.327 |
| | 4Hz | | 0.613 | 8.582 | 0.616 | 10.138 | -2.951 |

선형 특성을 고려할 때 주성분 분석 방법과 신경회로망 기법이 유용할 것으로 판단된다.

4. 결 론

구조용 용접강(SWS490B)에 대한 피로시험시 발생하는 AE 신호를 이용하여 응력확대계수를 정량화 할 수 있는 방법에 대한 논의로서 AE 신호와 같은 다변량 데이터의 처리에 많이 사용되고 있는 주성분 회귀분석 방법과 비선형적 문제 해결에 적합한 신경회로망 기법을 이용하여 응력확대계수 추정 모델을 개발하고 평가한 결과 다음과 같은 결론을 얻었다.

1. 응력확대계수 추정모델에 포함되는 AE 신호의 유의


한 반응변수를 검토한 결과 대체적으로 RC, EN, ED가 유의성이 높은 것으로 나타났으며 전반적으로 측정된 전체 AE 파라미터를 모델의 입력변수로 사용할 경우 모델의 적합도를 나타내는 결정계수가 다소 높게 나타났다.

2. 주성분 회귀모델을 개발하고 분석한 결과 측정 데이터가 불안한 일부 시편에 대한 결과를 제외하고는 본 연구에서 개발된 주성분 회귀모델을 이용할 경우 미지 시편의 응력확대계수 추정이 가능할 것으로 분석되었다.

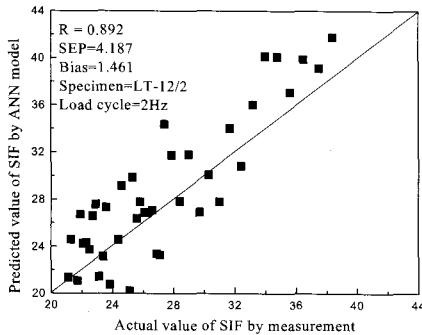
3. 모멘텀 개념을 도입한 수정된 오류 역전파 알고리즘을 이용한 인공신경망을 개발하여 미지의 시료에 대하여 응력확대계수를 추정한 결과 매우 양호한 예측 성능을 나타내었으며 주성분 회귀모델 보다 예측 성능이 다소 양호한 것으로 분석되었다.

4. 차후 AE 신호와 응력확대계수의 관계에 대한 신뢰성 있는 많은 데이터를 수집한다면 임의 부재나 시편에 대한 종합적인 분석 모델의 개발이 가능할 것으로 사료된다.


참고문헌



(a) LT-9/4



(b) LT-12/2



(c) LT-20/1

Fig. 6 Validation results of artificial neural network model between actual value and predicted value of SIF (a) LT-9/4, (b) LT-12/2 and (c) LT-20/1

- [1] 이강용 임장목, 김준석, "적응형 신호 형상 인식 프로그램 개발과 AE법에 의한 용접부 결함 분류에 관한 적용 연구", 비파괴검사학회지, Vol. 16, No. 1, pp. 520-530, (1996)
- [2] D. O. Harris and H. L. Dunegan, Continuous Monitoring of Fatigue Crack Growth by Acoustic Emission, *Experimental Mechanics*, February, pp. 71-81, (1974)
- [3] 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)
- [4] 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*, 27(12), pp. 1691-1694, (1992)
- [5] A. Berkovits and D. Fang, Study of Fatigue Crack Characteristics by Acoustic Emission, *Engineering Fracture Mechanics*, 51(3), pp. 401-416, (1995)
- [6] T. C. Lindley, I. G. Palmer, and C. E. Richards, Acoustic Emission Monitoring of Fatigue Crack Growth, *Materials Science and Engineering*, 32, pp. 1-15, (1978)
- [7] 주영상, 정현규, 심철무, 임형택, "형상인식법을 이용한 음향방출신호의 분류", 비파괴검사학회지, Vol. 10, No. 2, pp. 23-31, (1990)
- [8] H. Yuki and K. Homma, "Analysis of Artificial Acoustic Emission Waveforms Using a Neural Network," *J. of Acoustic Emission*, Vol. 10, No.3/4, pp. 35-41, (1992)
- [9] 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)
- [10] H. Martens and T. Naes, *Multivariate Calibration*, Wiley: Chichester, (1989)
- [11] M. a. Sharaf, D. L. Illman and B. R. Kowalski, *Chemometrics*, John Wiley & Sons, New York, (1986)
- [12] N. Draper and H. Smith, *Applied Regression*

- Analysis*, 2nd Ed., John Wiley & Sons, New York, (1981)
- [13] 김상철, 파괴역학, 민음사, (1985)
- [14] SAS Institute, *SAS/STAT Guide for Personal Computers*, Version 6 Edition, SAS Institute, Cary, NC (1987)
- [15] A. Chichibu, T. Kikuchi and T. Kishishita, "Principal Component Analysis of AE Waveform Parameters for Investigating an Instability of Geotechnical Structures, *J. of Acoustic Emission*, Vol. 11. No. 4, pp. S47-56, (1993)
- [16] Kramer, L., *Toolbox for use with MATLABTM : Chemometrics*, The Mathworks Inc.,(1993)
- [17] J. A. Freeman and D. M. Skapura, "Neural Networks-Algorithm, Applications and Programming Technique", Addison Wesley, pp.89-125, (1991)
- [18] D. Howard and B. Mark, *Neural Network Toolbox for Use with MATLAB*, The MathWorks Inc., (1992)
- [19] 송성진, "형상인식기법을 이용한 비파괴적 결함 종류 판별", 비파괴검사학회지, Vol. 19, No. 5, pp. 378-391, (1999)
- [20] 윤동진, 정중채, 박휘립, 김기복, 이승석, "응력확대 계수와 음향방출 변수를 이용한 피로균열 거동 연구", 비파괴검사학회지, Vol. 20, No. 5, pp. 412-423, (2000)