

신경회로망을 이용한 AI 2024-T3합금의 피로손상모델에 관한 연구

최우성^{*}(동아대 대학원), 홍순혁^{*}(동아대 대학원), 이동우^{*}(동아대 대학원),
조석수^{**}(삼척대 자동차공학과), 주원식^{***}(동아대 기계공학과)

A Study on Fatigue Damage Model using Neural Networks in 2024-T3 aluminium alloy

Woo-Sung Choi*, Soon-Hyeok Hong*, Dong-Woo Lee*,
Seok-Swoo Cho**, Won-Sik Joo***

Abstract

To estimate crack growth rate and cycle ratio uniquely, many investigators have developed various kinds of mechanical parameters and theories. But, these have produced local solution space through single parameter. Neural Networks can perform pattern classification using several input and output parameters. Fatigue damage model by neural networks was used to recognize the relation between da/dN , N/N_f , and half-value breadth ratio B/B_o , fractal dimension D_f and fracture mechanical parameters in 2024-T3 aluminium alloy. Learned neural networks has ability to predict both crack growth rate da/dN and cycle ratio N/N_f within engineering estimated mean error (5%).

1. 서 론

반복 하중을 받는 부재의 피로손상은 주로 균열성장속도와 피로수명비를 파괴역학 파라미터로 평가하여 실험조건에 영향을 받지 않는 수학적 모델을 기초로 평가하여 왔다.¹⁾ 또한 초음파나 음향 방출등과 같은 비파괴적 파라미터를 이용하여 피로 손상을 평가하려는 노력도 많이 수행되고 있다. 이러한 모델은 균열선단근방의 복잡한 파괴기구를 구멍 하지 못하여 상당한 평가 오차를 발생시키고 있다.

Paris²⁾등은 균열성장속도를 부하와 제하시의 응력 확대계수 차이인 ΔK 로 평가한 이래로 많은 연구자들³⁾이 응력진폭, 최대응력확대계수, 파괴인성, 응력비, 균열닫힘, 가혹한 환경, 실험재료등에 의하여 균열성장거동이 영향을 받음에도 불구하고 함수 근사법으로 평가하고 있다. 또한 비파괴적 파리미터를 이용하여 피로수명비를 평가하는 경우에도 상술의 방법이 그대로 적용되고 있다. 그러나 균열성장속도와 피로수명비는 피로손상을 나타내는 역학적 파라미터로 상술의 파괴역학적 및 비파괴적 파라미터로 평가하는 경우 대부분 실험조건에 영향을 받아 일의적으로 평가할 수 없다.

또한 다양한 재료손상을 단일 역학적 파라미터를 이용하여 평가하고 있으나 손상의 진행정도와 평가 파라미터사이에 상당한 오차가 발생하고 있다. 따라서 다양한 환경의 파라미터를 동시에 사용하여 부재의 균열성장속도나 피로수명비를 평가한다면 손상의 진행 정도를 비교적 정확하게 예측할 수 있을 것이다.

주⁴⁾등은 고온 저사이클 피로균열성장거동을 다양한 탄소성파괴역학 파라미터를 이용하여 평가한 뒤 신경회로망에 의한 균열성장모델링을 수행하였다. 각 실험데이터를 두점 표현방식에 의하여 처리 하므로서 미학습데이터에 대하여 균열성장속도를 5%이내에서 예측하였다. 또한 Yagawa⁵⁾등은 고온 재료의 응력-변형률 선도를 신경회로망을 이용하여 모델링하였다. 입력층과 출력층의 유니트를 각각 소성변형률 ε_p , 배응력 Y 와 항응력 R 및 소

성변형률에 대한 배응력 Y 와 항응력 R 의 기울기로 설정하여 학습시킨 뒤 미학습데이터에 대한 응력-변형률 선도를 예측한 결과 $\pm 3\%$ 이내의 추정평균오차가 발생되었다. 그러나 상술의 모델링 방법은 실험데이터를 평가하는 파라미터를 다양하게 사용하지 못하고 모델링하려는 곡선 기울기를 이용하고 있기 때문에 실시간적으로 손상을 평가할 수 없다.

따라서 본 연구에서는 인간의 신경세포를 모델화한 역전파 신경회로망(backpropagation neural networks)을 기초로 X선 반가폭비 B/B_0 , 프랙탈 차원 D_f , 파괴역학 파라미터를 학습데이터로 처리 하므로서 상술의 모델링이 커브 피팅(curve fitting)에 주력하는데 국한되므로써 오는 평가 방법의 한계를 극복하고자 한다. 즉, 피로실험에서 얻는 균열성장속도와 피로수명비를 단일 파괴역학 및 비파괴파라미터로 평가하는 것이 아니라 상술의 파라미터를 동시에 사용하므로서 피로손상을 종합적으로 평가할 수 있는 피로손상모델을 구축하고자 한다.

2. 신경회로망에 관한 이론적 배경

Fig. 1은 역전파 신경회로망의 층상구조를 나타내고 있다.⁶⁾ 그림에서 하나의 원은 신경회로망에서 사용되는 가장 기본 단위인 뉴런을 나타내

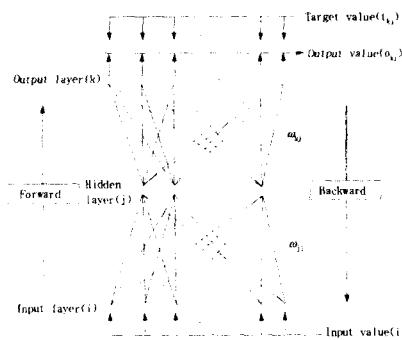


Fig. 1 Block of backpropagation neural networks

고 있고, 이러한 뉴런들을 모은 최소 단위가 하

나의 층(layer)을 구성하게 된다. 신경회로망은 이러한 층을 종방향으로 적층하여 입력층 유니트와 은닉층 유니트 사이를 결합계수 w_{ji} 로, 은닉층 유니트와 출력층 유니트 사이에는 w_{kj} 로 각각 연결시키므로서 정보처리 시스템을 구축하게 된다.

일반적인 역전파 신경회로망의 학습은 입력 층의 각 유니트에 입력 데이터를 제시하면 이 신호는 각 유니트에서 변환되어 은닉층에 전달되고 최종적으로 출력층으로 나오게 된다. 신경회로망의 학습은 이러한 출력값과 목표값을 비교하여 그 차이를 감소시키는 방향으로 결합계수를 조절하는 것이다. 또한, 이러한 결합계수 행렬에 학습되지 않은 입력층 데이터를 열 벡터(column vector)의 형태로 신경회로망에 대입하면 새로운 출력 데이터를 구할 수 있고, 만약 이러한 출력 데이터가 목표값에 수렴된다면 신경회로망은 일반화 능력을 가지고 있다고 말한다.

입력된 패턴 p 의 목표 출력값과 실제 출력값의 오차 함수 E_p 는 다음 식 (1)과 같이 나타낸다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2 \quad (1)$$

여기서,

E_p : 데이터 패턴 P 에 대한 오차의 제곱

t_{pj} : n번째층의 j번째 유니트의 목표값

o_{pj} : n번째층의 j번째 유니트의 출력값

본 논문에서 사용하는 일반화된 델타규칙(generalized delta rule)의 결합계수 변화량은 다음 식 (2)와 같다.

$$\Delta_p w_{ji} (n+1) = \eta \delta_{pj} o_{pj} + \alpha \Delta_p w_{ji} (n) \quad (2)$$

여기서, n : 반복 학습 횟수

η : 학습 계수 (learning rate)

α : 모우멘트 계수 (momentum rate)

3. 실험 결과와 고찰

3.1 $(\Delta\sigma/\sigma_{ys})^m a^n$ 에 의한 da/dN 의 평가

본 연구에서 수행한 실험은 Al 2024-T3 합금을 이용하여 양진굽힘하중형태로 수행되어졌으며 생크형(schenk type) 평면굽힘피로시험기(mori te

-sting machine co., Model 5171)를 이용하였다.⁷⁾

Fig. 2는 각각의 응력진폭 $\Delta\sigma$ 에 따른 표면피로균열길이 a 와 균열성장속도 da/dN 의 관계를 나타낸 것이다. 표면피로균열길이 a 는 균열성장속도 da/dN 에 대하여 선형적 관계가 성립한다. 그럼에서 직선의 기울기는 응력진폭 $\Delta\sigma$ 가 303MPa

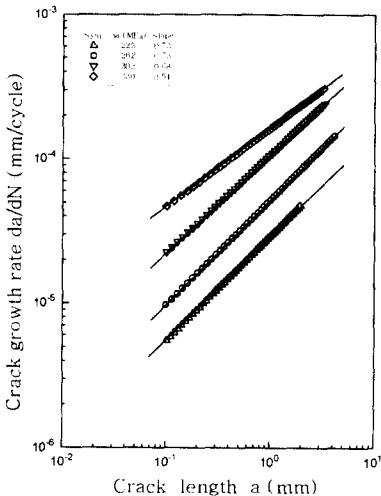


Fig. 2 Relation between crack growth rate da/dN and crack length a

까지는 $\Delta\sigma$ 에 크게 영향을 받지 않고 약 0.7에 근접하나, 고응력 330MPa에서는 0.54로 감소하고 평균기울기 값은 0.67이다. 또한 응력진폭 $\Delta\sigma$ 가 증가할수록 표면피로균열길이 a 에 따른 균열성장속도 da/dN 가 현저히 빨라짐을 알 수 있다.

Fig. 3은 각각의 표면피로균열길이 a 에 따른 균열성장속도 da/dN 과 응력진폭 $\Delta\sigma$ 의 관계를 나타낸 것이다. 본 선도의 데이터는 표면피로균열길이 a 를 0.1에서 2mm까지 설정한 뒤 그 간격을 0.4mm로 하여 점증시켜 사용한다. 응력진폭 $\Delta\sigma$ 에 대하여 균열성장속도 da/dN 는 직선관계가 성립하고 있으며 직선의 기울기는 균열길이가 증가할수록 5.47에서 4.19로 감소하고 그 평균기울기 값은 4.64이다. 또한 균열성장속도 da/dN 는 표면피로균열길이 a 와 응력진폭 $\Delta\sigma$ 가 증가할수록 급속히 증가하고 있다. 따라서 Fig. 2와 3

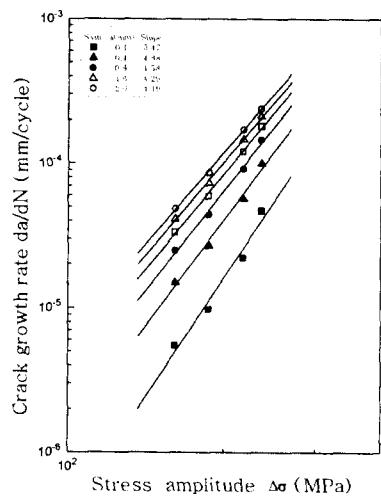


Fig. 3 Relation between crack growth rate da/dN and stress amplitude $\Delta\sigma$

의 결과를 종합하면 균열성장속도 da/dN 는 응력진폭 $\Delta\sigma$ 와 표면피로균열길이 a 에 대하여 지수적 관계를 가지고 있음을 알 수 있다.

Fig. 4는 응력진폭 $\Delta\sigma$ 를 Al 2024-T3 합금의 항복응력 σ_{ys} 로 나누어 무차원시킨 $\Delta\sigma/\sigma_{ys}$ 와 표면피로균열길이 a 를 이용한 파괴역학 파라미터 $(\Delta\sigma/\sigma_{ys})^m a^n$ 로 균열성장속도 da/dN 를 평가한 것이다. 그럼에서 m 과 n 은 Fig. 2와 Fig. 3의 기울기 m 과 n 의 값 중에서 $(\Delta\sigma/\sigma_{ys})^m a^n$ 에 대한 균열성장속도 da/dN 의 회귀식에 대한 표준편차가 가장 적은 평균값인 4.64와 0.67로 설정한다.⁸⁾ $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 에 따른 균열성장속도 da/dN 는 응력진폭 $\Delta\sigma$ 에 크게 영향을 받지 않고 하나의 벤드를 형성하고 있으며 각 응력진폭 $\Delta\sigma$ 에 대한 평균 기울기는 1로서 균열성장속도 da/dN 는 $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 에 대하여 선형적 관계가 성립하고 있다. 따라서, 표면피로균열을 고려한 균열성장속도 da/dN 과 파괴역학적 파라미터 $(\Delta\sigma/\sigma_{ys})^m a^n$ 에 대한 관계식은 다음과 같이 표시된다.

Fig. 6은 표면피로균열 길이의 프랙탈 차원 $D_f^{10)}$ 을 각 응력진폭의 피로수명비 N/N_f 에 대하여 나타낸 것이다.

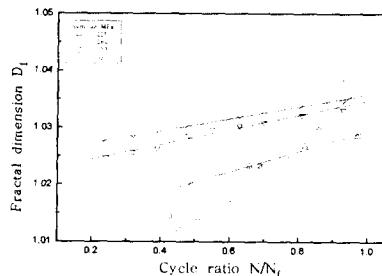


Fig. 6 Relation between fractal dimension D_f and cycle ratio N/N_f

피로수명비 N/N_f 의 증가에 따라 그 프랙탈 차원 D_f 도 증가하고 있다. 그리고 응력진폭 $\Delta\sigma$ 가 증가함에 따라 전체적인 프랙탈 차원 D_f 도 증가하고 있으나 응력진폭 $\Delta\sigma=262\text{MPa}$ 인 경우 피로수명초기에 각 응력진폭 $\Delta\sigma$ 에서 가장 낮은 프랙탈 차원 D_f 를 보이다가 후기에 가장 높은 프랙탈 차원 D_f 를 보여 큰 직선의 기울기를 나타내고 있다. 즉, 파단에 이르게 하는 표면피로균열은 균열간의 합체에 의하여 균열형상이 갑작스럽게 변화하는데, 저응력의 경우 균열간의 합체가 서서히 이루어지므로 프랙탈 차원 D_f 의 증가도 서서히 증가하고, 고응력의 경우 균열간의 합체가 초기부터 급진적으로 이루어지므로 전체적인 프랙탈 차원 D_f 도 그 증가량이 완만하다. 그러나 응력진폭 $\Delta\sigma=262\text{MPa}$ 의 중응력에서는 파단을 일으키는 표면피로균열의 프랙탈 차원 D_f 가 표면미소균열간의 합체가 일어나기 이전까지는 피로수명비 N/N_f 와 프랙탈 차원 D_f 간에 완만한 증가를 보이나 미소균열간의 합체가 발생되면 균열형상이 갑작히 변하므로 프랙탈 차원 D_f 도 동시에 급격히 증가하게 된다. 따라서 균열형상에 의한 프랙탈 차원 D_f 는 피로수명비에 따라 점진적으로 증가하고 있으나 초기균형상과 재료조

직 및 응력진폭에 강하게 의존하고 있어 단독 파라미터에 의하여 피로손상을 평가할 수 없음을 알 수 있다.

4. 신경회로망에 의한 피로손상의 평가

4.1 신경회로망을 이용한 피로손상모델의 구성

Fig. 7은 신경회로망을 이용하여 피로손상을 예측하기 위한 흐름도를 나타낸 것이다.

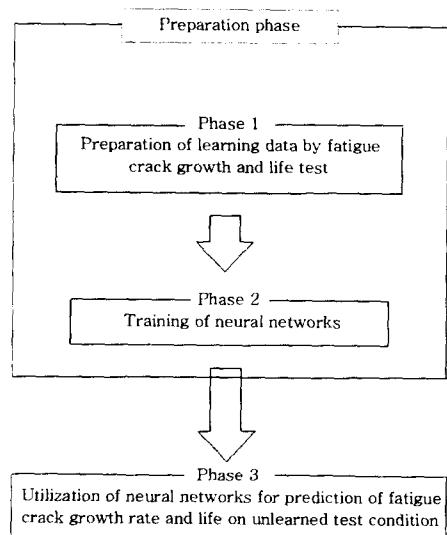


Fig. 7 Prediction of fatigue crack growth rate and life by neural networks

제1단계에서는 균열성장속도 da/dN , 피로수명비 N/N_f , X선 반가폭비 B/B_0 , 프랙탈차원 D_f 등의 피로손상을 나타내는 실험데이터를 신경회로망에 적합하도록 구성하고 제2단계에서는 입력층 유니트를 응력진폭 $\Delta\sigma$, X선 반가폭비 B/B_0 , $(\Delta\sigma/\sigma_{ys})^m a^n$, 프랙탈 차원 D_f , 표면피로균열길이 a 로, 출력층 유니트를 균열성장속도 da/dN , 피로수명비 N/N_f 로 설정하여 신경회로망을 학습시키고, 마지막 3단계에서는 학습된 신경회로망의 결합계수행렬을 이용하여 미학습데이터에 대한 균열성장속도 da/dN 과 피로수명비 N/N_f 를 예측한다.¹¹⁾ 이상의 신경회로망 구조를 Fig. 8에 나타내었으며 이를 기초로 최적조건의 신경회로망을 피로손상모델에 미치는 각종 인

자를 이용하여 구한 뒤 피로손상을 예측하고자 한다.

피로손상모델에 사용한 신경회로망의 학습과 일반화능력은 신경회로망의 출력값과 목표값의 차이인 추정평균오차를 기초로 평가하였으며 추정평균오차의 정의는 다음과 같다.

$$\phi = \frac{1}{r} \sum_{p=1}^r \frac{|\psi_{\text{neuro}}(p) - \psi(p)|}{|\psi(p)|} \quad (5)$$

여기서, $\psi(p)$: 입력층 유니트에 대한 목표값

r : 학습과 일반화에 사용한 데이터 수

$\psi_{\text{neuro}}(p)$: ψ 에 대한 신경회로망의 출력값

또한 추정평균오차가 0.05이내로 접근될 때, 피로손상모델이 공학적 오차 범위내에서 수렴한 것으로 가정하여 이 범위를 한계오차 범위로 설정한다.

Fig. 8은 신경회로망의 입력층을 응력진폭 $\Delta\sigma$, X선 반가폭비 B/B_0 , $(\Delta\sigma/\sigma_{ys})^{m}a^n$, 프랙탈 차원 D_f , 균열길이 a 로 설정하고 신경회로망의 출력층을 균열성장속도 da/dN , 피로수명비 N/N_f 으로 설정한 피로손상모델이다.

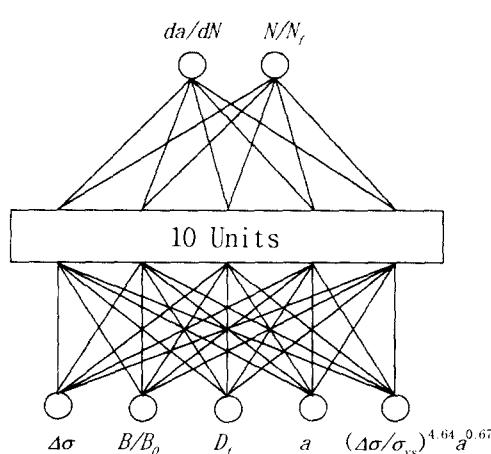


Fig. 8 Neural networks for fatigue damage model

4.2 신경회로망의 초기학습조건을 이용한 피로 손상의 평가

Table 1은 신경회로망의 초기학습조건을 임의로 설정한 것이고 Table 2는 Table 1에서 설정한 초기학습조건 중 다른 학습 파라미터는 고

정시키고 은닉층 수와 데이터 수 및 학습반복횟수를 각각 단독으로 변화시켰을 때의 추정평균오차 중 가장 적은 값을 나타내는 값을 각각 나타낸 것이다. Table 2에서 균열성장속도와 피로수명비에 대한 추정평균오차는 공학적 오차범위내에 수렴되고 있다.

Table 1 Initial conditions for learning of neural networks

number of hidden layer	number of hidden units	learning rate	momentum rate	number of data	number of epochs
1	10	0.1	0.9	51	100000

Table 2 Optimal conditions and estimated mean error for learning of neural networks

parameter	number of hidden units	data	epoch
optimal condition	6	51	2000000
estimated mean error (ϕ)	da/dN 0.0243 N/N_f 0.0100	0.0243 0.0100	0.0140 0.0049

Table 3은 Table 2의 학습조건을 이용하여 최적화시킨 신경회로망을 기초로 AI 2024-T3 합금의 피로손상과정을 학습 및 일반화한 결과를 나타낸 것이다. 신경회로망의 학습에 따른 추정평균오차는 da/dN 가 0.014, N/N_f 가 0.0049로서 공학적 오차가 0.05이므로 상당히 낮은 오차이지만 일반화를 수행하면 da/dN 는 0.151, N/N_f 는 0.2785으로써 공학적 한계오차 범위를 상당히 벗어나고 있다. 이러한 결과는 학습데이터 중에서 반가폭비 B/B_0 와 프랙탈 차원 D_f 를 신경회로망에서 사용할 수 있는 값으로 스케일링한 범위가 각각 0.93376~1, 0.97182~1이므로 비록 학습이 충분히 수행되었다 하더라도 일반화를 수행하면 국소 최적해(local optima)에 빠지기 때문이다. 따

라서 다음절에서는 인식성이 열악한 데이터를 개선하기 위하여 데이터를 인공적으로 조절하는 데이터 변환법을 제안한다.

Table 3 Generalization and learning by initial optimal conditions of neural networks

estimated mean error ϕ	learning	generalization
da/dN	0.014	0.151
N/N_f	0.0049	0.2785

4.3 데이터 변환법을 이용한 피로손상의 평가

입력층 유니트 중에서 스케일링된 값의 범위가 극히 적은 데이터는 반가폭비 B/B_0 와 프랙탈 차원 D_f 으로서 피로수명비 N/N_f 에 대하여 대단히 민감하게 반응한다. 따라서 상술의 데이터는 다음 식에 의하여 최대값과 최소값사이의 범위를 다른 데이터의 분포에 맞도록 변환되는 것이 필요하다.

$$B/B'_0 = 10(N/N_f) + B/B_0$$

$$D'_f = 10(N/N_f) + D_f \quad (6)$$

여기서, B/B'_0 : B/B_0 의 변환된 값

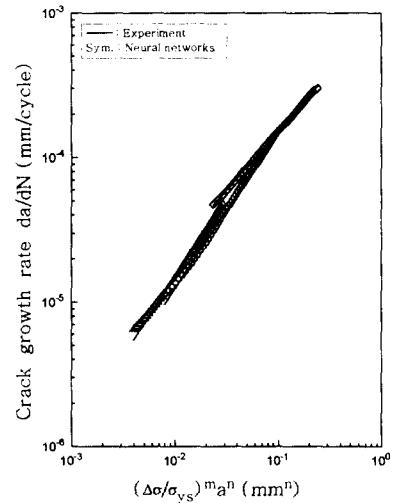
D'_f : D_f 의 변환된 값

식 (6)에 의해 변환된 데이터의 값의 범위는 B/B'_0 가 0.62063~1, D'_f 가 0.27769~1로서 최대값과 최소값사이의 범위가 데이터 변환 전보다 훨씬 증가하였다.

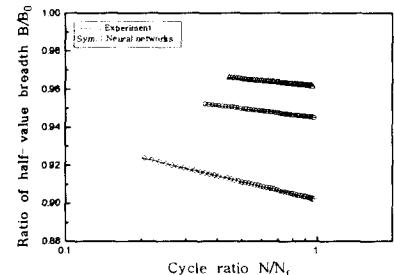
Fig. 9와 10은 반가폭 B/B_0 와 프랙탈 차원 D_f 를 식 (6)으로 수정한 데이터와 Table 2의 학습방법으로 균열성장속도 da/dN 와 피로수명비 N/N_f 를 학습하고 예측한 것이다. 데이터를 변환하기전의 초기 조건인 Table 3과 비교하면 학습추정평균오차는 감소하고, 일반화추정평균오차도 da/dN 의 경우 약 1/2로 감소되어 공학적 오차범위 이내로 수렴된다. 따라서 반가폭 B/B_0 와 프랙탈 차원 D_f 의 데이터의 범위를 넓힌 데이터 변환법은 학습과 일반화에 상당한 영향을 미침을 알

수 있다.

Fig. 11은 Fig. 4의 $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 에 대한 균열성장속도 da/dN 의 실험결과에 의해 회귀된



(a) Unit da/dN at output layer

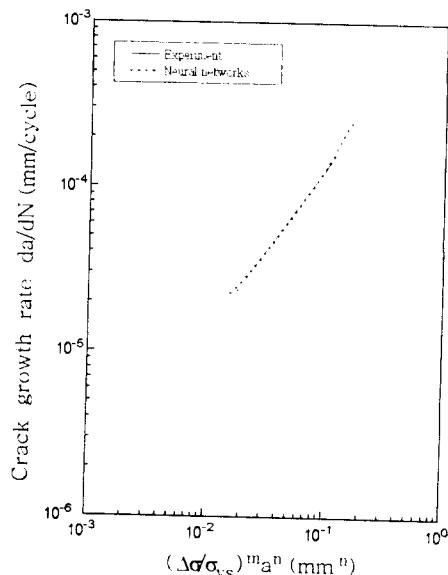


(b) Unit N/N_f at output layer

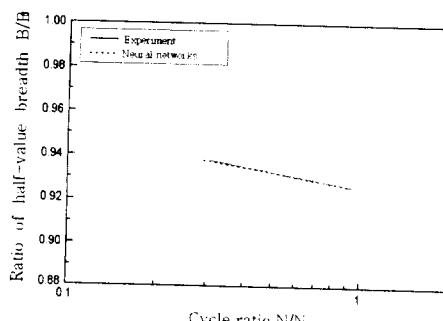
Fig. 9 Fatigue crack growth rate da/dN and cycle ratio N/N_f learned by neural networks

식 (4)를 기초로 예측한 피로수명비 N/N_f 와 X 선 반가폭비 B/B_0 와 프랙탈 차원 D_f 및 다양한 파괴역학 파라미터를 입력층 유니트로 하는 신경회로망을 이용하여 예측한 피로수명비 N/N_f 를 비교한 그림이다. 그림에서 알 수 있는 것처럼 균열성장법칙을 이용하여 구한 파단피로수명비는 0.67인 것에 대하여 다양한 파라미터에 의하여

신경회로망으로 구한 파단파로수명비는 0.963으로 예측된다. 따라서 신경회로망으로 기존의 파로파손 및 파괴과정을 학습하여 최적화시킨 결합계수행렬을 이용하여 미지의 실험조건에 대한



(a) Unit da/dN at output layer



(b) Unit N/N_f at output layer

Fig. 10 Fatigue crack growth rate da/dN and cycle ratio N/N_f predicted by neural networks

파로손상을 예측한다면 공학적 한계오차 범위내에서 수렴되고 있으므로 기존의 단일 파라미터중에서 $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 나 프랙탈 차원 D_f 로 파로수명비 N/N_f 를 평가할 때 발생되는 오차를 충분히 극복할 수 있다고 생각된다.

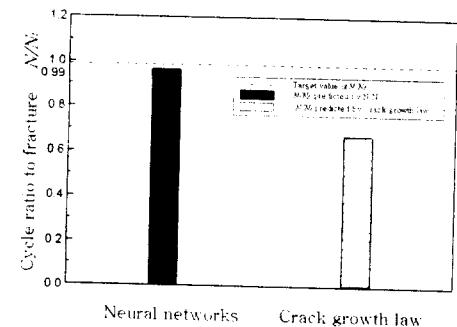


Fig. 11 Prediction of cycle ratio to fracture N/N_f by neural networks and crack growth law

5. 결 론

본 연구에서는 X선 반가폭비 B/B_0 와 프랙탈 차원 D_f 및 다양한 역학적 파라미터를 입력층 유니트로 하는 신경회로망을 기초로 파로손상을 예측하여 다음과 같은 결론을 얻었다.

- 초기학습조건을 이용하여 최적화시킨 신경회로망은 학습추정평균오차는 공학적 오차범위에 상당히 접근하고 있으나 일반화추정평균오차는 그 범위를 벗어나고 있다.
- 신경회로망의 학습과 일반화능력은 원시 데이터를 데이터의 최대값으로 스케일링하여 사용하는 것 보다 데이터의 인식성을 높여 주는 방향으로 스케일링하는 것이 훨씬 더 향상되었다.
- 비파괴 및 다양한 파괴역학 파라미터를 기초로 미지의 실험조건에 대하여 파로손상을 예측할 수 있는 신경회로망을 구축함으로서 $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 와 프랙탈 차원 D_f 로 파로수명비 N/N_f 를 평가할 때 발생되는 추정평균오차를 극복할 수 있다.

참 고 문 헌

- 日本材料學會, 疲勞部門委員會, “金屬疲勞の研究の歴史”, pp. 61~78, 1988.

-----참고문헌 이하 생략-----