

역전파신경회로망을 이용한 피로손상모델링에 관한 연구

A Study on Fatigue Damage Modelling Using Back-propagation Neural Networks

조석수*, 장득열**, 주원식***
Seokswoo Cho, Deukyul Jang, Wonsik Joo

ABSTRACT

It is important to evaluate fatigue damage of in-service material in respect to assure safety and remaining fatigue life in structure and mechanical components under cyclic load. Fatigue damage is represented by mathematical modelling with crack growth rate da/dN and cycle ratio N/N_f and is detected by X-ray diffraction and ultrasonic wave method etc. But This is estimated generally by single parameter but influenced by many test conditions. The characteristics of it indicates fatigue damage has complex fracture mechanism. Therefore, in this study we propose that back-propagation neural networks on the basis of ratio of X-ray half-value breadth B/B_0 , fractal dimension D_f and fracture mechanical parameters can construct artificial intelligent networks estimating crack growth rate da/dN and cycle ratio N/N_f without regard to stress amplitude $\Delta \sigma$.

주요기술용어 : Fatigue Damage Modelling (피로손상모델링), Ratio of X-ray Half-value Breadth (X선 반가폭비), Fractal Dimension (프랙탈 차원), Crack Growth Rate (균열성장속도), Cycle Ratio (피로 수명비), Back-propagation Neural Networks (역전파신경회로망)

1. 서 론

반복하중을 받는 부재의 피로손상은 주로 균열

성장속도 da/dN 과 피로수명비 N/N_f 를 파괴역학 파라미터로 평가하여 실험조건에 영향을 받지 않는 수학적 모델링을 기초로 평가하여 왔다.¹⁾ 또한 초음파²⁾나 X선 회절³⁾등과 같은 비파괴적 파라미터를 이용하여 피로손상을 평가하려는 노력도 많이 수행되고 있다. 이러한 모델은 균열선 단근방의 복잡한 파괴기구를 구명하여 피로손상

* 정회원, 삼척대학교 자동차공학과

** 정회원, 삼척대학교 기계공학과

*** 정회원, 동아대학교 기계공학과

을 평가하려는 방법을 제안하고 있으나 실험데이터를 주로 최소자승법과 같은 함수근사법으로 처리하고 있다.

한편, Paris⁴⁾등은 균열성장속도 da/dN 를 부하와 제하시의 응력확대계수 차이인 ΔK 를 적용한 아래로 많은 연구자들이 응력진폭, 최대응력확대계수, 파괴인성, 응력비, 균열닫힘, 열악한환경, 실험 재료등에 의하여 균열성장거동이 영향을 받음에도 불구하고 함수 근사법에 의한 평가법을 유지해 왔다.⁵⁾ 또한 비파괴적 파라미터를 이용하여 피로수명비 N/N_f 를 평가하는 경우에도 상술의 방법이 그대로 적용되어 왔다. 그러나 균열성장속도 da/dN 과 피로수명비 N/N_f 는 피로손상을 나타내는 역학적 파라미터로서 상술의 파괴역학적 및 비파괴적 파라미터로 평가하는 경우 대부분 실험조건에 영향을 받으므로 일관성 있게 평가하기 어렵다.

또한, 다양한 재료손상을 단일 역학적 파라미터를 이용하여 평가하고 있으나 손상의 진행정도와 평가 파라미터사이에 상당한 오차가 발생하고 있다. 따라서 다양한 환경의 파라미터를 동시에 사용하여 부재의 균열성장속도 da/dN 과 피로수명비 N/N_f 를 평가한다면 손상의 진행 정도를 비교적 정확하게 예측할 수 있을 것이다.

주⁶⁾등은 고온 저사이클 피로균열성장거동을 다양한 탄소성파괴역학 파라미터를 이용하여 평가한 뒤 신경회로망에 의한 균열성장모델링을 수행하였다. 각 실험데이터를 두점과 세점표현방식(two point and three point representation scheme)에 의하여 처리하므로써 결합계수행렬을 구성하지 않았던 미학습데이터에 대하여 균열성장속도 da/dN 를 5%이내에서 예측하였다. 한편, 고온용 재료의 반복 응력-변형률선도는 재료의 경화성 때문에 응력을 변형률 항으로 표현하기 어려워 소성 변형률 ε_p 와 인장응력을 기초로 하는 배응력 Y 와 인장응력의 변동폭을 기초로 하는 항응력 R 의 합수로 나타내고 있다. Yagawa⁷⁾등은 상술의 개념을 이용하여 반복 응력-변형

률 선도를 신경회로망으로 모델링하였다. 즉, 입력층과 출력층 유니트를 각각 소성변형률 ε_p , 배응력 Y 와 항응력 R 및 소성변형률 ε_p 에 대한 배응력 Y 와 항응력 R 의 기울기로 설정하여 학습시킨 뒤 미학습데이터에 대한 응력-변형률 선도를 예측한 결과 $\pm 3\%$ 이내의 추정평균오차가 발생되었다. 또한 Wu⁸⁾등은 반복압축하중을 받는 콘크리트의 반복응력-변형률 관계를 삼점표현방식(three point representation scheme)으로 표현하고 그 데이터를 학습 데이터로 하는 신경회로망을 기초로 제하과정(unloading process)을 일반화하여 6 사이클째의 응력-변형률 관계를 공학적 오차범위내에서 예측하므로써 신경회로망이 재료의 역학적 거동을 쉽게 모델링할 수 있음을 보였다. 그러나 상술의 모델링 방법은 재료 손상을 평가하는 파라미터를 다양하게 사용하지 못하고 모델링하려는 곡선의 기울기를 이용하고 있기 때문에 실시간적으로 손상을 평가할 수 없다.

따라서 본 연구에서는 인간의 신경세포를 모델화한 역전파 신경회로망(back-propagation neural networks)을 기초로 X선 반가폭비 B/B_0 , 프랙탈 차원 D_f , 파괴역학 파라미터를 학습데이터로 처리하므로써 기존의 모델링이 커브핏팅(curve fitting)에 주력하는데 국한되므로써 오는 평가 방법의 한계를 극복하고자 한다. 즉, 피로실험에서 얻는 균열성장속도 da/dN 과 피로수명비 N/N_f 를 단일 파괴역학 및 비파괴 파라미터로 평가하는 것이 아니라 상술의 파라미터를 동시에 사용하므로써 피로손상을 종합적으로 진단할 수 있는 인공지능형 네트워크(artificial intelligent networks)를 구축하고자 한다.

2. 신경회로망과 피로손상모델링

2.1. 역전파신경회로망의 특징과 학습

Fig. 1은 본 연구에서 사용하는 역전파 신경회로망⁹⁾의 기본적 구조를 나타낸 것이다. 그럼에서 역전파 신경회로망은 입력층과 은닉층 및 출력층

으로 구성된 계층형 구조를 가지고 있으며 각층은 복수개의 유니트로 이루어져 있다.

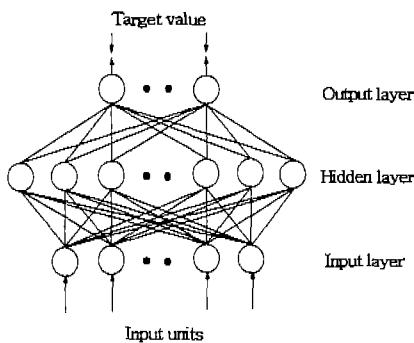


Fig. 1 Structure of back-propagation neural networks

각 유니트는 신경세포인 뉴런(neuron)의 수학적 모델로서 다입력, 단출력의 처리 소자(processing element)이다. 역전파 신경회로망은 다음 식 (1)에 표시하는 목표값과 출력값의 차이인 오차의 제곱이 최소가 되도록 유니트간의 결합계수와 유니트 옵셋(offset)을 출력층과 중간층 및 중간층과 입력층의 순서로 조절하여 나가는 오차역전파학습법(error back-propagation learning)을 취하고 있다.

$$E = \sum_p E_p = \sum_p \sum_{k=1}^n \frac{1}{2} (T_{pk} - O_{pk})^2 \quad (1)$$

단, E_p : p 번째 학습 데이터에 대한 오차제곱

T_{pk} : p 번째 학습 데이터에서 k 번째 출력 층 유니트에 대한 목표값

O_{pk} : p 번째 학습 데이터에서 k 번째 출력 층 유니트에 대한 출력값

n : 출력층 유니트 수

또한, 신경회로망의 학습에 사용되는 학습계수와 모우멘트계수는 결합계수행렬에 가중치를 부여하여 국소 최적해(local minima)에 빠지는 것을 방지한다. 한편, 재료거동모델링에 사용되는 역전파 신경회로망은 다음과 같은 특징을 가지고 있다.

(1) 이산적 입출력 관계를 가지는 데이터를 이용하여 임의의 연속 맵핑을 수행하는 네트워크를 구축할 수 있다.

(2) 학습에 사용하지 않았던 미학습 데이터를 기초로 임의의 경계조건에 대한 내삽값 또는 외삽값을 출력하므로서 각 시뮬레이션 및 실험조건에 대한 결과를 예측할 수 있다.

(3) 학습이 완료된 역전파 신경회로망의 입력층 유니트에 미학습 데이터를 대입하면 몇 셀과 몇 셀의 간단한 연산에 의하여 출력값을 단시간에 구할 수 있다.

2.2. 역전파 신경회로망과 계산역학을 이용한 재료거동모델링

본 절은 신경회로망을 이용한 피로손상모델링을 수행하기 전에 관찰 데이터 ψ 에서 재료거동파라미터 $\omega = (\omega_1, \omega_2, \dots, \omega_n)$ 를 동정(identification)하는 문제를 계산역학적 관점에서 어떻게 처리하는지를 알아보고자 한다. 기존의 최적화 방법과 계산역학을 결합시킨 재료거동모델링은 다음 식 (2)의 잔여 제곱합(residual square sum) $R(\omega)$ 를 최소화하는 ω 를 구하는 문제이다.

$$R(\omega) = \frac{1}{n} \sum_{j=1}^n \frac{1}{2} (\psi_j^{out}(\omega) - \psi_j^{tar})^2 \quad (2)$$

단, ψ_j^{out} : 재료거동파라미터가 ω 일 때 관찰시

점 j 에 대한 관찰 데이터 ψ 의 출력값

ψ_j^{tar} : 재료거동파라미터가 ω 일 때 관찰시

점 j 에 대한 관찰 데이터 ψ 의 목표값

n : 관찰 데이터 수

잔여는 다양한 최적화 방법에 의하여 최소화되고 있으나 재료거동모델링과 같은 역문제해석(inverse problem analysis)에서는 최적화 방법에 의하여 재료거동파라미터 ω 가 변화됨에 따라 $\psi_j^{out}(\omega)$ 를 구하는 계산역학 시뮬레이션이 필요하다. 따라서 최적해를 구할 때까지 많은 반복횟수와 그에 따른 큰 계산부하가 걸린다.

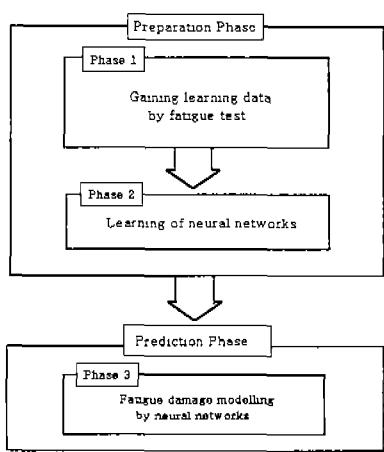


Fig. 2 Procedure of fatigue damage modelling using neural networks

Fig. 2는 신경회로망을 기초로 역문제해석에 의한 재료거동모델링 과정을 도식적으로 나타낸 것이다. 제1단계에서는 계산역학 시뮬레이션이나 실험에 의하여 재료거동파라미터 ω 에 대한 관찰 데이터 ϕ_i 를 구한다. 제2단계에서는 제1단계에서 구한 데이터에 의하여 신경회로망을 학습시키는 과정으로 관찰 데이터 ϕ_i 를 신경회로망의 입력층에 대입하여 출력되는 재료거동파라미터의 값과 목표값의 차이를 최소화시킨다. 제3단계는 제2단계에서 학습한 신경회로망에 미학습 관찰 데이터 Φ 를 입력하게 되면 간단한 덧셈과 곱셈과정을 통하여 재료거동파라미터 ϕ_i 가 출력된다.

기존의 재료거동모델링에 사용하였던 최적화 방법은 상술의 제2단계에서 사용하고 있으나 신경회로망을 이용하게 되면 모델링을 위한 반복계산이 불필요하고 간단한 연산만 수행하므로 계산시간이 짧아지며 학습공간에 설정된 해 공간내의 임의의 재료거동도 신경회로망의 일반화능력을 이용하면 적절한 해를 구할 수 있다.

2.3. 피로손상모델링

본 연구에서 수행하는 피로손상모델링은 역전

파신경회로망을 이용하여 다음의 3단계를 통하여 이루어진다. 제1단계는 A1 2024-T3합금의 피로시험을 수행하여 파괴역학 및 비파괴역학적 파라미터에 의하여 피로손상을 평가하므로서 피로손상파라미터에 대한 피로손상 데이터를 마련한다. 제2단계는 제1단계에서 축적한 데이터를 기초로 피로손상파라미터를 입력층 파라미터로, 피로손상을 출력층 파라미터로 설정하여 신경회로망을 학습시킨다. 마지막으로 제3단계는 학습이 완료된 신경회로망의 결합계수행렬을 이용하여 피로손상파라미터에 대한 미학습데이터를 입력층에 대입하여 출력층에서 피로손상을 예측한다.

이러한 신경회로망의 학습과 미학습 데이터에 대한 예측 능력은 신경회로망의 출력값에 대한 출력값과 목표값의 차이인 다음 식 (3)의 추정평균오차 E 로서 나타낸다.

$$E(W, \Theta, NT, \Phi) = \sum_p E^p(W, \Theta, NT, \Phi) = \\ \frac{1}{n} \sum_{i=1}^n \frac{|\phi_i^{tar}(W, \Theta, NT, \Phi^p) - \phi_i^{out}|}{|\phi_i^{tar}|} \quad (3)$$

단, W : 신경회로망 유니트사이의 결합계수

W_{ij}

Θ : 신경회로망 유니트의 음셋 Θ ;

NT : 신경회로망의 구조

Φ : 관찰 데이터

ϕ_i^{out} : 재료거동파라미터의 출력값

p : 학습패턴

n : 학습 데이터 수

본 논문의 경우 신경회로망의 출력값이 목표값에 대하여 추정평균오차가 0.05이내일 때 공학적 오차범위내에 수렴한다고 정의한다.

3. 신경회로망을 이용한 피로손상 모델링

3.1. 파괴와 비파괴적 파라미터를 이용한 피로손상의 평가

본 연구에서 사용하는 데이터는 저자들이 A1

2024-T3합금을 이용하여 실험한 결과를 기초로 하고 있다.^{12~14)} 즉, 피로실험은 Schenck형 평면 굽힘피로시험기를 이용하였으며 시험편의 관찰영역은 꼭률반경 R이 59mm가 되도록 설정하였다. 또한 실험하중은 265MPa에서 330MPa까지 4단계로 설정하였으며 응력비 R이 -1이 되도록 하였다. 이상의 실험 결과를 이용하여 피로손상을 다음과 같은 파괴와 비파괴적 파라미터로 평가하였다.

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

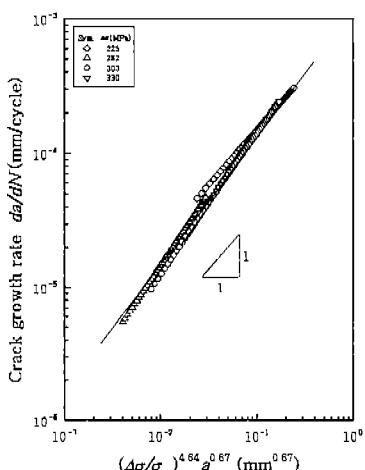


Fig. 3 Relation between crack growth rate da/dN and $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$

Fig. 3은 Nishitani 등¹²⁾이 제안한 $(\Delta\sigma/\sigma_{ys})^m a^n$ 을 이용하여 도출한 파괴역학 파라미터 $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 로 균열성장속도 da/dN 을 평가한 것이다. $(\Delta\sigma/\sigma_{ys})^{4.64} a^{0.67}$ 에 따른 균열성장속도 da/dN 는 응력진폭 $\Delta\sigma$ 에 크게 영향을 받지 않고 하나의 밴드를 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 일의적 관계가 성립하고 있다.

3.1.2. X선 반가폭비 B/B_0 에 의한 피로수명비 N/N_f 의 평가

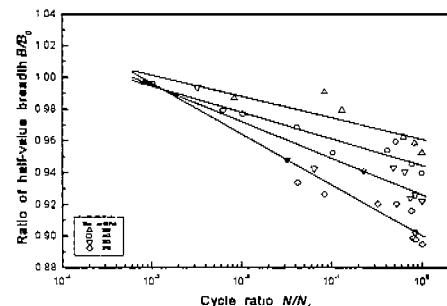


Fig. 4 Relation between ratio of half-value breadth B/B_0 and cycle ratio N/N_f

Fig. 4는 Al 2024-T3합금의 피로수명비 N/N_f 의 변화에 따른 X선 반가폭비¹³⁾ B/B_0 의 변화를 나타낸 것이다. 피로수명 초기에 반가폭비 B/B_0 가 급격히 감소하나 그 영역은 수 반복수에 해당되므로 그 데이터는 직선회귀 데이터에 포함시키지 않아 본 그림에서는 생략하였다. 피로수명 초기를 제외한 영역에서의 반가폭비 B/B_0 는 피로수명비 N/N_f 가 증가함에 따라 완만하게 감소하다가 말기에 피로수명 초기에서와 같이 급격히 감소하고 있다. 그림에서 직선은 각 응력진폭에 대한 데이터를 최소자승법으로 직선회귀시켜 구한 것으로 직선의 기울기는 각 응력진폭에 따라 다르고 응력진폭이 크면 기울기도 커지고 있다. 따라서 피로수명비 N/N_f 에 대한 반가폭비 B/B_0 의 변화에 대한 응력진폭 $\Delta\sigma$ 의 의존성이 나타나고 있으며, 응력진폭 $\Delta\sigma$ 가 증가할수록 반가폭비 B/B_0 의 변화량이 증가됨을 알 수 있다.

3.1.3. 프랙탈 차원 D_f 에 의한 피로수명비 N/N_f 의 평가

Fig. 5는 피로균열길이 a 의 프랙탈 차원¹⁴⁾ D_f 을 각 응력진폭의 피로수명비 N/N_f 에 대하여 나타낸 것이다. 피로수명비 N/N_f 의 증가에 따라 프렉탈 차원 D_f 도 증가하고 있다. 그리고 응력진폭 $\Delta\sigma$ 가 증가함에 따라 전체적인 프렉탈 차원 D_f 도 증가하고 있으나 응력진폭 $\Delta\sigma=262$ MPa인 경우 피로수명 초기에 각 응력진폭 $\Delta\sigma$ 에서 가

장 낮은 프랙탈 차원 D_f 를 보이다가 후기에 가장 높은 프랙탈 차원 D_f 를 보여 큰 직선의 기울기를 나타내고 있다.

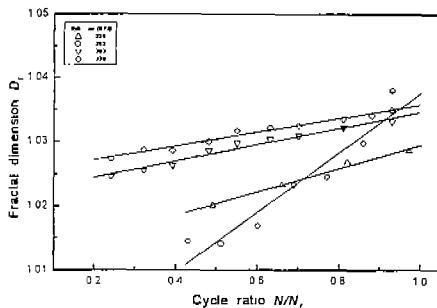


Fig. 5 Relation between fractal dimension D_f and cycle ratio N/N_f

즉, 파단에 이로게 하는 피로균열은 균열간 합체에 의하여 균열형상이 갑작스럽게 변화하는데, 응력진폭 $\Delta\sigma=225 \text{ MPa}$ 의 경우 균열간의 합체가 서서히 이루어지므로 프랙탈 차원 D_f 의 증가도 서서히 증가하고, 응력진폭 $\Delta\sigma=330 \text{ MPa}$ 의 경우는 균열간의 합체가 초기부터 급진적으로 이루어지므로 전체적인 프랙탈 차원 D_f 도 그 증가량이 완만하다. 그러나 응력진폭 $\Delta\sigma=262 \text{ MPa}$ 에서는 파단을 일으키는 피로균열의 프랙탈 차원 D_f 가 미소균열간의 합체가 일어나기 이전까지 피로수명비 N/N_f 에 대하여 프랙탈 차원 D_f 가 완만하게 증가하나 미소균열간의 합체가 발생하면 균열형상이 갑자기 변하므로 프랙탈 차원 D_f 도 동시에 급격히 증가하게 된다. 따라서 균열형상에 의한 프랙탈 차원 D_f 는 피로수명비 N/N_f 에 따라 겹진적으로 증가하나 초기균열형상과 재료조직 및 응력진폭에 강하게 의존하고 있어 단독 파라미터에 의하여 피로손상을 평가할 수 없음을 알 수 있다.

3.2. 신경회로망 학습에 미치는 각 파라미터의 영향

3.2.1. 데이터 패턴의 영향

Table 1은 피로손상모델링의 학습에 미치는 데이터 패턴의 영향을 평가하기 위한 신경회로망의 초기조건이다. 테이블에서 역전파신경회로망

의 은닉층 수를 한 개로 설정한 것은 역전파신경회로망이 3층의 계층구조에서도 임의의 비선형연속맵핑(nonlinear continuous mapping)을 표현할 수 있는 능력이 충분히 있는 것으로 증명되었기 때문이다.¹⁵⁾ 또한 은닉층 유닛 개수는 10개로 하였으며, 학습계수와 모우멘트계수는 각각 0.1과 0.9로, 각 응력진폭 $\Delta\sigma$ 에 대한 데이터 수는 51개, 반복학습횟수는 100,000회로 각각 설정하였다.

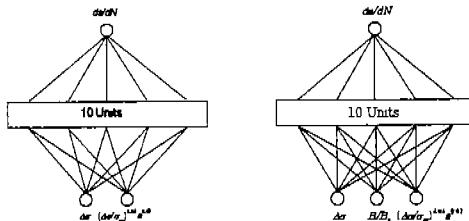
Table 1 Initial conditions for learning of neural networks

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

Fig. 6, 7은 신경회로망의 출력층 유닛리를 균열성장속도 da/dN 로 설정한 경우의 데이터 패턴 구조와 이에 따른 학습결과를 나타낸 것으로 실선은 피로균열성장시험의 실험결과를, 심벌은 신경회로망의 학습결과를 표시한 것이다. 신경회로망이 고응력진폭의 경우 데이터 패턴의 종류에 관계없이 학습을 양호하게 수행하나 저응력진폭의 경우 균열성장속도가 과대평가되어져 학습이 정확히 이루어지지 않고 있음을 알 수 있다.

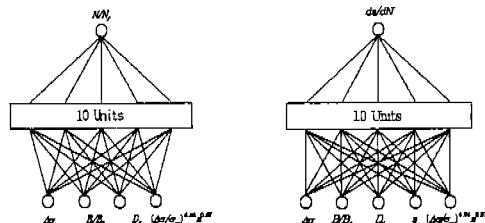
또한, Fig. 8, 9는 신경회로망의 출력층 유닛리를 피로수명비 N/N_f 로, Fig. 10, 11, 12는 신경회로망의 출력층 유닛리를 균열성장속도 da/dN 과 피로수명비 N/N_f 를 동시에 설정한 경우의 데이터 패턴 구조와 이에 따른 학습구조를 나타낸 것이다. 전자의 경우 신경회로망이 대부분의 데이터 패턴에서 좋은 학습을 수행 하나 2 데이터 패턴의 경우 거의 학습이 제대로 수행되지 못하고 있음을 알 수 있다. 또한 후자의 경우 신경회로망의 출력층 유닛인 균열성장속도 da/dN 과 피로수명비 N/N_f 에 대한 학습에서도 출력층 유닛리를 단독으로 설정한 경우와 비슷한 학습결과를 보이나 Fig. 9의 2 데이터 패턴에서 보였던 학습거동을 보이지 않는다. 즉, 신경회로망은 입

력증 유니트 수에 큰 영향을 받지만 출력층 유니트 수에도 큰 영향을 받고 있음을 알 수 있다.



(a) 2 data patterns

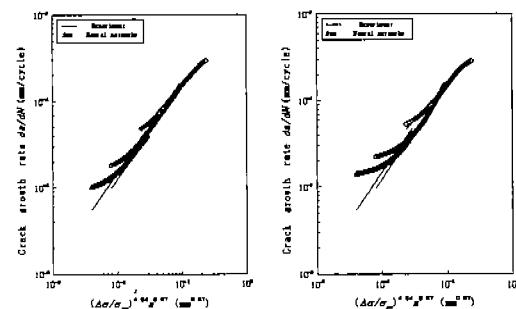
(b) 3 data patterns



(c) 4 data patterns

(d) 5 data patterns

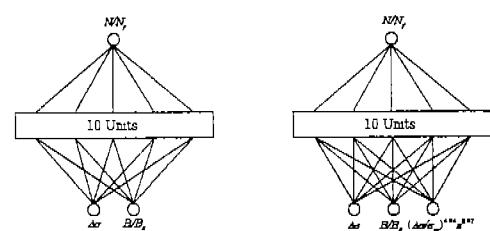
Fig. 6 Architecture of neural networks in fatigue crack growth modelling on output unit da/dN



(c) 4 data patterns

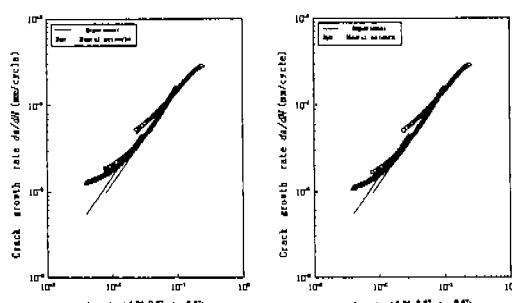
(d) 5 data patterns

Fig. 7 Fatigue crack growth modelling at specific learning pattern on output unit da/dN



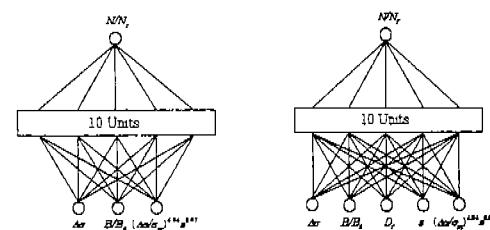
(a) 2 data patterns

(b) 3 data patterns



(a) 2 data patterns

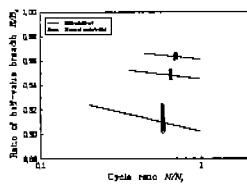
(b) 3 data patterns



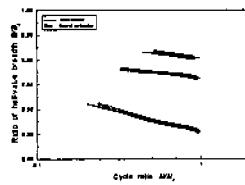
(c) 4 data patterns

(d) 5 data patterns

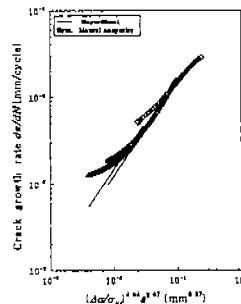
Fig. 8 Architecture of neural networks in fatigue life modelling on output unit NN_f



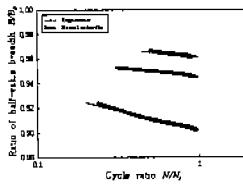
(a) 2 data patterns



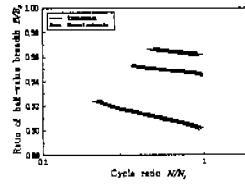
(b) 3 data patterns



(a) 3 data patterns

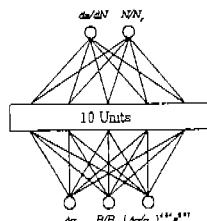


(c) 4 data patterns

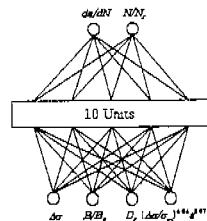


(d) 5 data patterns

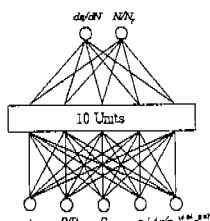
Fig. 9 Fatigue life modelling at specific learning pattern on output unit N/N_f



(a) 3 data patterns

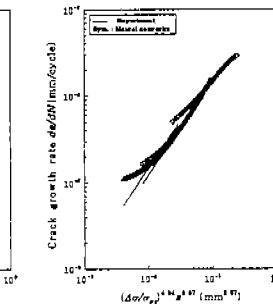


(b) 4 data patterns

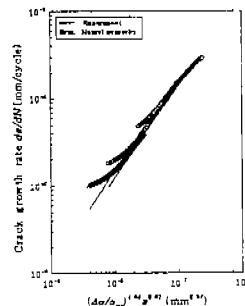


(c) 5 data patterns

Fig. 10 Architecture of neural networks in fatigue damage modelling on output unit da/dN and N/N_f



(b) 4 data patterns



(c) 5 data patterns

Fig. 11 Fatigue crack growth modelling at specific learning pattern on output unit da/dN and N/N_f

피로수명초기에 균열성장속도 N/N_f 는 과대하게 예측하고 있으나 균열성장속도 da/dN 는 과소하게 평가되고 있다. 그러나 피로수명말기에는 균열성장속도 da/dN 나 피로수명비 N/N_f 모두 목표값에 근접하고 있다.

또한 신경회로망의 입력층 유니트를 $\Delta \sigma$, $(\Delta \sigma / \sigma_{ys})^M a^n$, B/B_o , D_f , a 로 설정하고 출력층 유니트를 균열성장속도 da/dN 과 피로수명비 N/N_f 을 동시에 설정하여 학습하면 추정평균오차가 각각 0.111, 0.026로 나타나 데이터 패턴중 가장 우수한 학습결과를 보이고 있어 본 구조를 신경회로망의 최적의 데이터 패턴구조로 설정하였다.

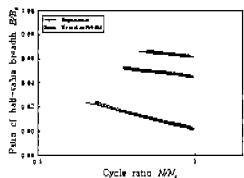
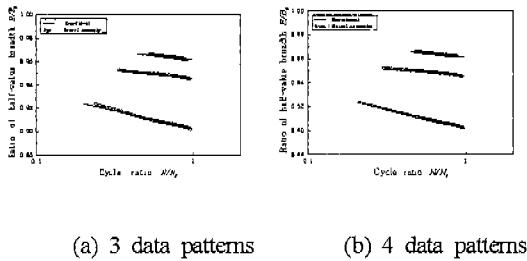


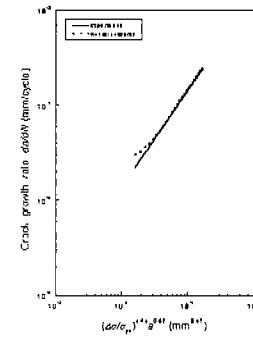
Fig. 12 Fatigue life modelling at specific learning pattern on output unit da/dN and N/N_f

3.2.2. 최적 데이터 패턴에 따른 피로 손상의 예측

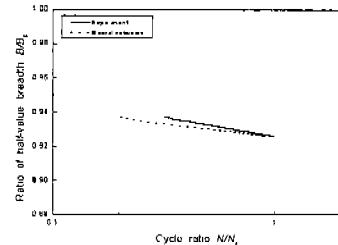
Fig. 13은 선질에서 학습 결과가 가장 우수한 Fig. 10의 (c) 신경회로망의 결합계수행렬을 이용하여 피로손상을 예측한 것이다. 피로수명초기에 균열성장속도 da/dN 를 과도하게 예측하고 있으나 피로수명비 N/N_f 는 과소하게 평가되고 있다. 그러나 피로수명말기에는 균열성장속도 da/dN 나 피로수명비 N/N_f 모두 목표값에 거의 근접하고 있다. 따라서 Fig. 11과 Fig. 12에서 학습된 신경회로망의 일반화 추정평균오차는 균열성장속도 da/dN 의 경우 0.0599, 피로수명비 N/N_f 의 경우 0.2275로서 공학적 한계오차 범위 0.05에서 벗어나고 있으며 피로수명비 N/N_f 가 균열성장속도 da/dN 에 비하여 약 3.8배 정도의 추정평균오차를 더 발생시키고 있다. 이러한 결과는 신경회로망의 학습에 사용하였던 데이터 중 N/N_f 와 프랙탈 차원 D_f 사이의 강한 비선형성이 일반화에도 큰 영향을 미쳐 피로손상을 예측하는 데 상당한 장애를 일으킨 것으로 생각된다.

3.2.3. 모델링 파라미터의 최적화

신경회로망 학습에 미치는 모델링 파라미터의 영향을 검토하기 위하여 Table 1의 학습조건을 모두 고정시킨 상태에서 검토 파라미터만 점진적으로 변화시키고 다른 파라미터는 고정시켜 학습 추정평균오차가 가장 적은 파라미터의 값을 모델링 파라미터의 최적값으로 정의하였다.



(a) Unit da/dN in output layer



(b) Unit N/N_f in output layer

Fig. 13 Crack growth rate da/dN and cycle ratio N/N_f predicted by neural networks with optimal data pattern

Table 2 Optimal 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	6	0.9	0.9	51	2,000,000

또한 이와 같은 파라미터 변화에 따른 학습 결과를 이용하여 최적화된 파라미터 값을 나타낸 것이 Table 2이다. 테이블에서 초기의 학습조건에 비하여 학습계수는 0.1에서 0.9로, 은닉층 유니트 수는 10개에서 6개로 각각 변경되었다. 특히, 은닉층 유니트의 경우 각 문제에 적합한 학습 패턴에 따라 적절한 값이 존재하고 있으며 본 피로균열성장모델링문제의 경우 초기 은닉층 유니트보다 감소하고 있어 적은 개수의 은닉층이라도 맵핑에는 커다란 문제가 없음을 알 수 있다.

3.2.4. 계수연동법에 의한 피로손상 예측

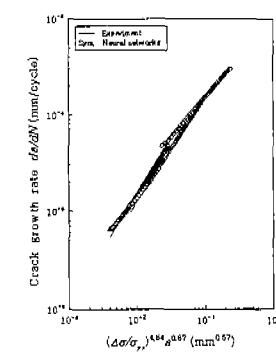
Table 3 Change of momentum and learning rate with number of epochs

		20000	40000	60000	80000	100000
case 1	learning rate	0.9	0.7	0.5	0.3	0.1
	momentum rate	0.9	0.7	0.5	0.3	0.1
case 2	learning rate	0.1	0.3	0.5	0.7	0.9
	momentum rate	0.1	0.3	0.5	0.7	0.9
case 3	learning rate	0.9	0.7	0.5	0.3	0.1
	momentum rate	0.1	0.3	0.5	0.7	0.9
case 4	learning rate	0.1	0.3	0.5	0.7	0.9
	momentum rate	0.9	0.7	0.5	0.3	0.1
case 5	learning rate	0.9	0.9	0.9	0.9	0.9
	momentum rate	0.9	0.9	0.9	0.9	0.9

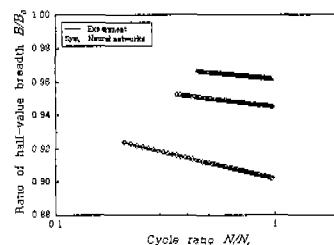
Table 3은 학습과 모우멘트계수가 학습횟수에 따라 연동적으로 변화되는 방법과 0.9로 고정되는 방법을 각각 나타내고 있다. 특히, 전자에서 제안하는 계수연동법은 학습 및 모우멘트 계수를 학습횟수에 따라 0.2씩 증가 또는 감소시켰으며 가능한 모든 경우를 나열하고 있다.

Fig. 14, 15는 학습추정평균오차가 계수선택법 중에서 다른 계수선택법에 비하여 크지만 일반화 추정평균오차가 가장 적은 case 4의 학습과 모우멘트계수를 기초로 신경회로망을 학습시킨 결과와 일반화에 의하여 피로손상을 예측한 결과를 각각 나타낸 것이다. 추정평균오차는 균열성장속

도 da/dN 의 경우 0.0488, 피로수명비 N/N_f 는 0.0321로서 공학적 한계오차 범위 0.05이내에 있음을 알 수 있다. 또한 전결의 데이터 패턴과 모델링 파라미터를 최적화시킨 학습 및 일반화와 본 절의 학습 및 일반화 결과에서 신경회로망의 초기학습조건을 결정하기 위한 신경회로망 구조와 본 절의 신경회로망 구조에 큰 차이가 있음을 알 수 있다. 따라서 신경회로망의 구조를 최적화시키기 위해서는 학습반복횟수에 따라 계수를 고정시키는 방법보다 계수를 변화시키는 계수연동법이 신경회로망의 구조를 인식하는 연결강도를 달라지게 하는 데 유효함을 알 수 있다.



(a) Unit da/dN in output layer



(b) Unit N/N_f in output layer

Fig. 14 Crack growth rate da/dN and cycle ratio N/N_f learned by neural networks with floating rate method

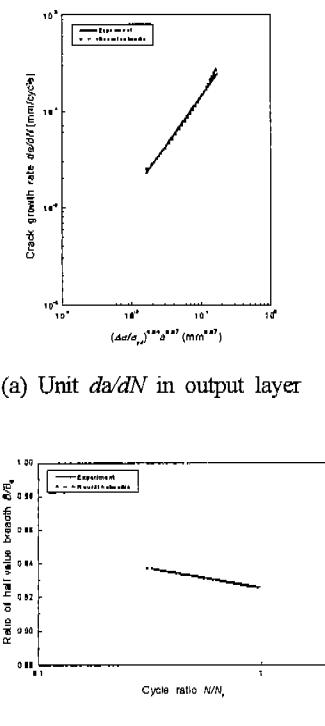


Fig. 15 Crack growth rate da/dN and cycle ratio N/N_f predicted by neural networks with floating rate method

4. 결 론

Al 2024-T3 합금을 이용한 피로와 비파괴실험을 수행하여 그에 따른 데이터를 기초로 역전파신경회로망을 이용한 피로손상모델링을 수행한 결과 다음과 같은 결론을 얻었다.

- Al 2024-T3 합금의 균열성장속도 da/dN 는 항복응력에 대한 응력진폭의 비 ($\Delta\sigma/\sigma_{ys}$)와 균열길이 a 를 기초로 만든 파괴역학 파라미터 $(\Delta\sigma/\sigma_{ys})^{4.64}a^{0.67}$ 를 이용하여 일관성 있게 평가할 수 있다.

- X선 반가폭비 B/B_0 와 프랙탈 차원 D_f 으로 피로수명비 N/N_f 를 평가하는 경우 응력진폭 Δ

σ 와 재료의 미소조직에 강하게 의존하고 있으므로 일관성 있는 평가를 수행할 수 없다.

- 신경회로망에 의한 피로손상모델링에서 테이터 패턴 수가 증가함에 따라 학습은 양호해지나 일반화에 의한 피로손상을 예측하게 되면 피로수명초기에는 균열성장속도 da/dN 는 과대평가되나 피로수명비 N/N_f 는 과소평가되어진다.

- 신경회로망에 사용하는 학습과 모우메트 계수를 0.9로 고정시키는 계수고정법보다 학습반복횟수에 따라 0.2씩 변화시키는 계수연동법이 학습과 일반화에 의한 피로손상을 공학적 오차범위내에서 예측할 수 있다.

- 후 기 -

본 연구는 98년도 동아대학교 학술연구조성비에 의하여 지원되었으며 이에 감사드립니다.

참 고 문 헌

- 日本材料學會, 疲労部門委員會, “金屬疲労の研究の歴史”, pp. 61~78, 1988.
- 大石, 山田, 吉村, 失川, 永井, 松田, “ニューラルネットワークと計算力學を用いた超音波缺陷同定法(レーザ超音波實驗による精度検證), 日本機械學會論文集(A編), 第64卷, 第619號, pp. 810~818, 1998.
- Thomas F. Perrone, “Principles of Radiographic Film Interpretation of Pipeline Welds”, Journal of the American Society for Nondestructive Testing, Vol. 50, No. 11, pp. 1268~1273, 1992.
- P. C. Paris, F. Erdogan, "A Critical Analysis of Crack Propagation Laws", Trans. ASME,

- Basic Eng., Vol. 85, pp. 528, 1963.
5. 中澤一, 本間寛臣, “金属の疲労强度”, 養賢堂, pp. 98~126, 1982.
 6. 주 원식, 조 석수, “신경회로망을 이용한 고온 저사이클 피로균열성장 모델링에 관한 연구”, 대한기계학회논문집 (A), Vol. 20, No. 9, pp. 2752~2759, 1996.
 7. 奥田洋司, 宮崎博, 矢川元基, “ニューラルネットワークを用いた非弾性応答のモデリング”, 日本機械學會論文集 (A編), 第62卷, 第597號, pp. 1284~1290, 1996.
 8. X-Wu, J. Ghabousi, “Modeling The Cyclic Behavior of Concrete Using Adaptive Neural Network”, Computational Mechanics Vol. 1, pp. 1319~1329, 1993.
 9. 박 민용, 최항식, “뉴로컴퓨터”, 대영사, pp. 28~37, 1991.
 10. 大石篤哉, 山田勝稔, 吉村忍, 矢川元基, “ニューラルネットワークと計算力学に基づく定量的超音波非破壊検査(斜め缺陷の同定とロバスト性の検証)”, 日本機械學會論文集 (A編), 第62卷, 第6202號, pp. 2350~2356, 1996.
 11. 조 석수, “STS 304鋼의 高溫疲労龜裂成長特性과 龜裂成長모델링에 의한 強度評價에 관한 研究”, 동아대학교 박사학위논문, pp. 33~34, 1996.
 12. 西谷弘信, 後藤眞宏, “微少き裂伝ば則と部材の疲労壽命との關係”, 日本機械學會論文集 (A編), 第51卷, 第462號, pp. 332~341, 1985.
 13. 平修二, 本田和男, 松木健次, “X線による金屬材料疲労破壊に関する研究(X線回折半價幅, 残留應力およびかたさの諸化について)”, 日本機械學會論文集 (A編), 第28卷, 第194號, pp. 1335~1343, 1962.
 14. 沼田眞一, 片平和俊, 鈴木秀人, “複合組織形TiAl合金に發生する分布疲労き裂のフラクタルモデルと余壽命評価”, 日本機械學會論文集 (A編), 第64卷 第619號, pp. 597~602, 1998.
 15. Laurene Fausett, “Fundamentals of Neural Networks”, Prentice Hall Int., pp. 320~330, 1994.