

신경회로망을 이용한 Al 2024-T3 합금의 피로손상예측에 관한 연구

조석수*, 장득열**, 주원식***

A Study on the Prediction of Fatigue Damage in 2024-T3 Aluminium Alloy Using Neural Networks

Seok Swoo Cho*, Deuk Yul Jang**, Won Sik Joo***

ABSTRACT

Fatigue damage is the phenomena which is accumulated gradually with loading cycle in material. It is represented by fatigue crack growth rate da/dN and fatigue life ratio N/N_f . Fracture mechanical parameters estimating large crack growth behavior can calculate quantitative amount of fatigue crack growth resistance in engineering material. But fatigue damage has influence on various load, material and environment. Therefore, In this study, we propose that artificial intelligent fatigue damage model can predicts fatigue crack growth rate da/dN and fatigue life ratio N/N_f simultaneously using fracture mechanical and nondestructive parameters.

Key words : Fatigue damage (피로손상), Artificial intelligent fatigue damage model (인공지능형 피로손상모델), Fatigue crack growth rate (피로균열성장속도), Fatigue cycle ratio (피로수명비), Estimated mean error (추정평균오차)

1. 서론

현대사회는 고도의 산업화 사회로 급속히 발달됨에 따라 기계 또는 구조물의 각종 효율이 빠른 속도로 높아지고 있다. 이러한 기계 중 수송기계는 연료의 부존자원이 고갈됨에 따라 기관의 연비를 향상시키기 위하여 기존의 철강 재료를 고강도 알루미늄 합금 등과 같은 경량화 재료로 대체함과 동시에 현재의 과도한 안전율을 공학적 수준으로 내리기 위하여 파괴역학적 개념에 입각한 설계강도를 요구하고 있다. 그러나 이러한 역학적 환경에

사용되는 재료의 경우 손상 패턴에 대한 정확한 평가방법의 확립이 부재의 안전성을 확보한다는 측면에서 대단히 중요하다.¹⁾

그러한 손상중 피로손상은 반복수에 따라 점진적으로 재료내부에 축적되는 현상으로 피로균열성장속도 da/dN 과 피로수명비 N/N_f 가 대표적인 손상파라미터이다. 그러나 상술의 파라미터는 다양한 하중과 환경 및 재료적 특성에 영향을 받고 있다. 특히, 반복하중을 받는 균열선단근방의 소성역을 파괴역학적으로 정확하게 해석하지 못하는 파라미터인 응력확대계수 K 나 J 직분등으로 피로수명을

* 삼척대학교 자동차공학과

** 삼척대학교 기계공학과

*** 동아대학교 기계공학과

예측하는 경우 상당한 평가 오차를 초래하고 있다. 또한 표면에 노치가 없는 평활재의 피로손상은 미시적 조직영향을 강하게 받기 때문에 거시균열의 평가방법을 그대로 적용할 수 없다. 따라서 거시균열성장거동을 평가하는 데 사용하는 파괴역학적 파라미터는 각 재료간의 피로균열성장저항성을 비교 평가하는 데는 상당히 유용하나 다양한 역학적 환경에 대하여 일관성 있게 평가할 수 있는 파라미터는 아니다.²⁾ 따라서 다수의 역학적 및 비역학적 파라미터를 동시에 사용하여 부재의 균열성장속도 da/dN 과 피로수명비 N/N_f 를 평가한다면 손상의 진행 정도를 비교적 정확하게 예측할 수 있을 것이다.

주³⁾등은 고온 저사이클 피로균열성장거동을 다양한 탄소성파괴역학 파라미터를 이용하여 평가한 뒤 신경회로망에 의한 균열성장모델링을 수행하였다. 각 실험데이터를 두점과 세점 표현방식(two and three point representation scheme)에 의하여 처리하므로써 미학습데이터에 대하여 균열성장속도 da/dN 를 5%이내에서 예측하였으며, Yagawa⁴⁾등은 재료표면에 존재하는 인공 결함을 초음파로 동정(identification)하는 문제를 신경회로망으로 모델링하였다. 입력층 유니트는 결함이 있을 때와 없을 때의 에코 파형 차이를, 출력층 유니트는 결함이 존재하는 재료 표면의 x-y 좌표로 설정하여 학습시킨 뒤 미학습데이터에 대한 표면의 x-y 좌표를 예측한 결과 초음파의 측정점이 증가할수록 일반화 정밀도는 향상되었다. 또한 Wu⁵⁾등은 반복압축하중을 받는 콘크리트의 반복응력-변형률 관계를 삼점 표현방식(three point representation scheme)으로 표현하고 그 데이터를 학습 데이터로 하는 신경회로망을 기초로 제하과정(unloading process)을 일반화 하여 6사이클째의 응력-변형률 관계를 공학적 오차 범위내에서 예측하므로써 신경회로망이 재료의 역학적 거동을 쉽게 모델링할 수 있음을 보였다. 그러나 상술의 모델링 방법은 재료 손상을 평가하는 파라미터를 다양하게 사용하지 못하고 모델링려는 곡선의 기울기를 이용하고 있기 때문에 실시간적으로 손상을 평가할 수 없다.

따라서 본 연구에서는 인간의 신경세포를 모델화한 역전파 신경회로망(back-propagation neural networks)⁶⁾을 이용하여 X선 반가폭비 B/B_0 , 프랙탈 차원 D_f , 파괴역학 파라미터들을 입력층 유니트로, 피로균열성장속도 da/dN 과 피로수명비 N/N_f 를 출력

층 유니트로 학습하므로써 AI 2024-T3합금의 피로 실험에서 얻은 균열성장속도 da/dN 과 피로수명비 N/N_f 를 단일 파괴역학 및 비파괴 파라미터로 평가하는 것이 아니라 피로손상인 균열성장속도 da/dN 과 피로수명비 N/N_f 를 동시에 평가할 수 있는 인공지능형 피로손상모델(artificial intelligent fatigue damage model)을 제안하고자 한다.

2. 신경회로망에 관한 기초적 연구

2.1 신경회로망의 유니트 구조

신경회로망의 유니트는 인간의 신경세포를 공학적으로 모델화한 것이며 이러한 유니트는 신경회로망의 정보처리요소(information processing element)이기 때문에 셀(cell)이라고도 한다.

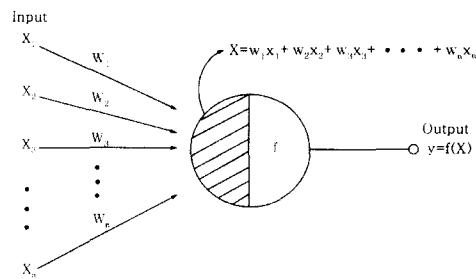


Fig.1 Structure of artificial neuron with activation function

Fig. 1은 본 연구에서 사용한 다입력 단출력형의 신경회로망 유니트를 표시하고 있다. 활성화 함수(activation function) f 는 1계미분이 본래의 함수로서 표현할 수 있으며 출력값이 [0, 1]구간에서 연속적으로 변화하는 시그모이드 함수(sigmoidal function)를 사용했다. 신경회로망에 들어오는 입력값은 결합함수(combining function)의 형태로서 그 유니트와 관계되는 출력값과 그 연결상의 결합계수와의 곱의 합이 들어오며 이를 식(1)로, 나가는 출력값은 입력값에 의한 활성화 함수값으로 식(2)로 나타낸다.

$$net_{pj} = \sum_i w_{ji} o_{pi} \quad (1)$$

$$o_{pj} = f_j(net_{pj}) \quad (2)$$

$$f(net_{pj}) = \frac{1}{1 + \exp(-\frac{2net_{pj}}{net_0})} \quad (3)$$

여기서, o_{pj} : n 번째층의 j 번째 유니트 출력값
 σ_{pj} : $n-1$ 번째층의 i 번째 유니트 출력값
 net_{pj} : n 번째층의 j 번째 유니트의 내부 포텐셜
 $f(net_{pj})$: 유니트의 활성화 함수
 net_0 : 시그모이드 함수의 온도
 w_{ji} : $n-1$ 번째층의 i 번째 유니트와 n 번째층의 j 번째 유니트 사이의 결합계수

2.2 역전파 신경회로망의 학습 알고리즘

역전파 신경회로망은 각 출력층 유니트에 대하여 원하는 목표값(target value)을 나타내기 위하여 신경회로망에 입력된 패턴에 대한 목표값과의 제곱 오차를 최소화시키는 방법이다.

학습방법은 순방향과 역방향으로 처리를 수행하며 전자는 입력벡터에 대하여 입력층에서 출력층으로의 유니트 상태를 계산하여 가고, 후자는 출력층에 접속되어 있는 결합계수로부터 시작하여 입력층의 방향으로 수정하여 간다. 이 두 가지 처리를 오차가 수렴할 때까지 반복하므로서 학습이 진행되는 것이다.

입력된 패턴 p 의 출력값과 목표값의 오차 함수 E_p 는 다음 식(4)와 같이 나타낸다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2 \quad (4)$$

여기서, E_p : 데이터 패턴 p 에 대한 오차의 제곱
 t_{pj} : n 번째층의 j 번째 유니트의 목표값
 o_{pj} : n 번째층의 j 번째 유니트의 출력값

본 논문에서 사용하는 결합계수 변화량은 일반화된 델타규칙(generalized delta rule)을 기초로 다음 식 (5)와 같이 된다.

$$\Delta_p w_{ji} (n+1) = \eta \delta_{pj} o_{pj} + \alpha \Delta_p w_{ji} (n) \quad (5)$$

여기서, n : 반복학습횟수

η : 학습계수 (learning rate)
 α : 모멘트계수 (momentum rate)

3. 신경회로망을 이용한 피로손상모델링

3.1 파괴와 비파괴적 파라미터를 이용한 피로 손상의 평가

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

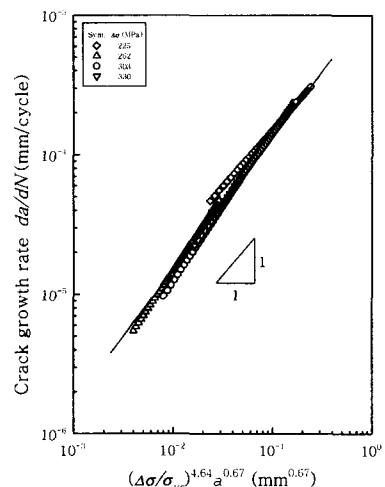


Fig. 2 Relation between crack growth rate da/dN and $(\Delta\sigma / \sigma_{ys})^{4.64} a^{0.67}$

Fig. 2는 응력진폭 $\Delta\sigma$ 를 Al 2024-T3합금의 항복 응력 σ_{ys} 로 나누어 무차원화시킨 $\Delta\sigma/\sigma_{ys}$ 와 피로균열길이 a 를 이용한 파괴역학 파라미터 $(\Delta\sigma / \sigma_{ys})^{4.64} a^{0.67}$ 로⁷⁾ 균열성장속도 da/dN 를 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 선형적 관계가 성립하고 있다.

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

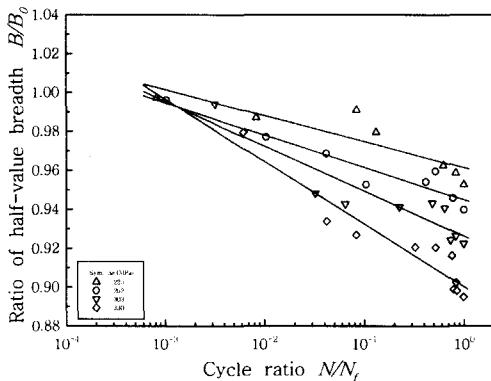


Fig. 3 Relation between ratio of half-value breadth B/B_0 and cycle ratio N/N_f

Fig. 3은 AI 2024-T3합금의 피로수명비 N/N_f 의 변화에 따른 X선 회절선의 반가폭비⁸⁾ 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 말기에는 피로수명 초기에서와 같이 급격히 감소하고 있다. 또한 그림에서 직선은 각 응력진폭에 대한 데이터를 최소자승법으로 직선회귀 시켜 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. 4는 피로균열길이 a 의 프랙탈 차원 D_f ⁹⁾를 각 응력진폭의 피로수명비 N/N_f 에 대하여 나타낸 것이다. 피로수명비 N/N_f 의 증가에 따라 그 프렉탈 차원 D_f 도 증가하고 있다. 그리고 응력진폭 $\Delta\sigma$ 가 증가함에 따라 전체적인 프렉탈 차원 D_f 도 증가하

고 있으나 응력진폭 $\Delta\sigma = 262 \text{ MPa}$ 인 경우 피로수명

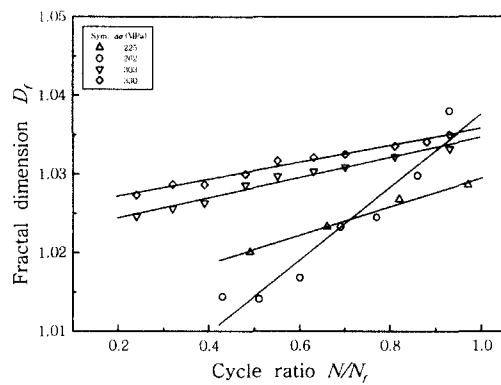


Fig. 4 Relation between fractal dimension D_f and cycle ratio N/N_f

초기에 각 응력진폭 $\Delta\sigma$ 에서 가장 낮은 프렉탈 차원 D_f 를 보이다가 후기에 가장 높은 프렉탈 차원 D_f 를 보여 큰 직선의 기울기를 나타내고 있다. 따라서 프렉탈 차원 D_f 는 피로수명비 N/N_f 에 따라 점진적으로 증가하는 경향을 보이고 있으나 초기균열형상과 재료조직 및 응력진폭에 강한 의존성을 보이고 있으므로 피로수명비 N/N_f 를 일관성 있게 평가할 수 없음을 알 수 있다.

3.2 피로손상모델링과 신경회로망 구조

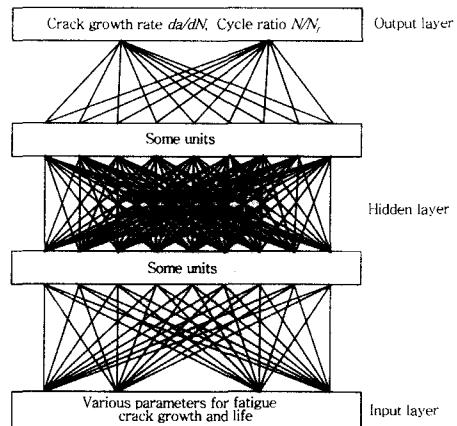


Fig. 5 Architecture of neural networks with various parameters for fatigue crack growth and life

Fig. 5는 피로손상모델링을 수행하기 위한 신경회로망의 구조를 나타낸 것이다. 신경회로망의 입력층 유니트를 응력진폭 $\Delta\sigma$, X선 반가폭비 B/B_0 , 프랙탈 차원 D_f , 파괴역학 파라미터 ($\Delta\sigma / \sigma_{ys}$)^{4.64} $a^{0.67}$, 피로균열길이 a 로, 출력층 유니트를 균열성장속도 da/dN 과 피로수명비 N/N_c 로 설정하였다.

피로손상모델링을 수행할 때 신경회로망의 학습과 일반화능력은 신경회로망의 출력값과 목표값의 차이인 추정평균오차를 기초로 평가하였으며 추정평균오차의 정의는 다음과 같다.

$$\psi = \frac{1}{r} \sum_{p=1}^r \frac{|\psi_{neuro}(p) - \psi(p)|}{|\psi(p)|} \quad (6)$$

여기서, $\psi(p)$: 입력층 유니트에 대한 목표값
 r : 학습과 일반화에 사용한 학습데이터수
 $\psi_{neuro}(p)$: ψ 에 대한 신경회로망의 출력값

또한, 추정평균오차가 0.1이내로 접근될 때, 피로손상모델링이 공학적 오차범위내에서 수렴한 것으로 가정하여 이 범위를 한계오차 범위로 설정한다

4. 신경회로망 학습에 미치는 모델링 파라미터의 영향

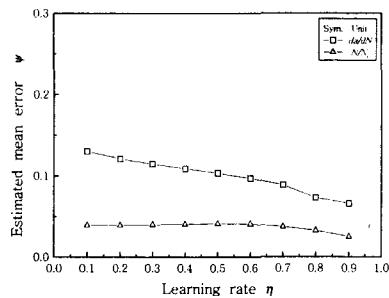
4.1 학습계수와 모멘트계수의 영향

Table 1은 피로손상모델링의 학습에 미치는 각 파라미터의 영향을 평가하기 위한 신경회로망의 초기조건이다.

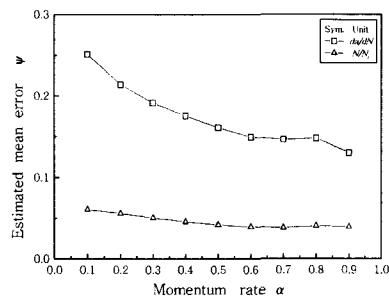
Table 1 Initial conditions for learning of neural networks

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

은닉층 수는 1개이고 그 유니트 수는 10개로 하였으며, 학습과 모멘트계수는 각각 0.1과 0.9로, 각 응력진폭 $\Delta\sigma$ 에 대한 데이터 수는 51개, 반복학습 횟수는 100,000회로 각각 설정하였다.



(a) Constant $\alpha = 0.9$



(b) Constant $\eta = 0.1$

Fig. 6 Relation between estimated mean error and learning rate and momentum rate

Fig. 6의 (a)는 신경회로망의 구조를 최적화시키기 위하여 모멘트계수 α 를 0.9로 고정시킨 후 학습계수 η 의 변화에 따른 학습추정평균오차를 나타낸 것이고, (b)는 학습계수 η 를 0.1로 고정시킨 후 모멘트계수 α 의 변화에 따른 학습추정평균오차를 나타낸 것이다. 학습추정평균오차는 각 계수가 증가함에 따라 (a), (b)의 두 경우 모두 감소하고 있으며 0.9에서 최소값을 보이고 있다. 이러한 결과는 학습초기에 출력값과 목표값사이의 오차 ($t_i - o_i$)가 크므로 오차에 비례하는 큰 값의 학습계수 η 를 도입시키므로 수렴을 용이하게 하고 모멘트계수 α 도 학습 초기에 큰 값으로 설정하여 국부 최적해 (local optima)에 빠지는 것을 방지함으로서 오차의 진동을 감소시켜 학습능력을 향상시켰기 때문이라고 생각된다.¹⁰⁾ 그러나 상술의 계수고정법은 학습 횟수에 관계없이 학습과 모멘트계수 η , α 가 고정

되어 있으므로 각층의 유니트사이의 결합계수 수정량을 조절하는데 한계가 있다. 따라서 계수선택을 일반화하기 위해서 전 학습과정중에 계수들을 고정시키는 방법이 아닌 두 계수를 반복학습횟수동안 연동적으로 변화시키는 방법으로 학습할 필요가 있다.

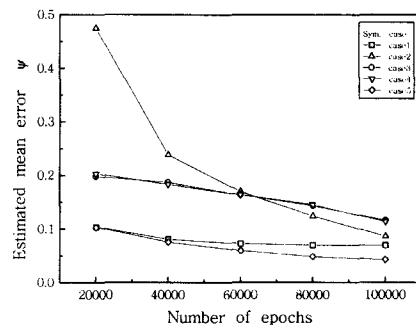
Table 2 Change of learning and momentum rate with number of epochs

		epoch	20000	40000	60000	80000	100000
case	rate						
case1	learning rate	0.9	0.7	0.5	0.3	0.1	
	momentum rate	0.9	0.7	0.5	0.3	0.1	
case2	learning rate	0.1	0.3	0.5	0.7	0.9	
	momentum rate	0.1	0.3	0.5	0.7	0.9	
case3	learning rate	0.9	0.7	0.5	0.3	0.1	
	momentum rate	0.1	0.3	0.5	0.7	0.9	
case4	learning rate	0.1	0.3	0.5	0.7	0.9	
	momentum rate	0.9	0.7	0.5	0.3	0.1	
case5	learning rate	0.9	0.9	0.9	0.9	0.9	
	momentum rate	0.9	0.9	0.9	0.9	0.9	

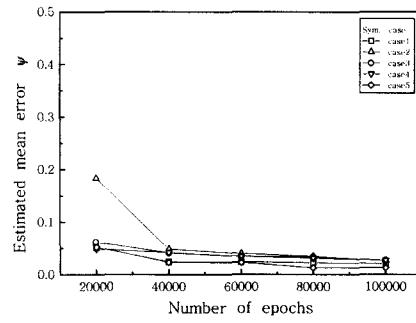
Table 2는 전술의 신경회로망의 학습조건을 나타낸 것으로 학습과 모멘트계수 α 가 학습횟수에 따라 연동적으로 변화되는 방법과 0.9로 고정되는 방법을 각각 나타내고 있다.

Fig. 7은 Table 2의 각 학습방법에 따른 신경회로망의 학습결과를 나타낸 것이다. 그럼에서 반복학습횟수가 20,000회 되는 학습초기를 보면 학습과 모멘트계수가 모두 0.9인 case 1과 case 5의 추정평균오차는 학습과 모멘트계수가 모두 0.1인 case 2와 비교하여 적음을 알 수 있다. 이러한 결과는 입력층과 은닉층 및 출력층사이의 결합계수 변화량을 크게 하기 위하여 각 계수를 크게 하는 것이 초기 학습에 유효함을 알 수 있다. 그리고 추정평균오차는 학습과 모멘트계수를 연동적으로 변화시키는 경우보다 0.9로 고정시킨 case 5가 최소 균열성장속도 da/dN 의 경우 0.0134, 피로수명비 N/N_f 의 경우 0.0039만큼 더 작게 나타나고 있다. 따라서 균열성장속도 da/dN 과 피로수명비 N/N_f 를 동시에 모델링하기 위한 신경회로망의 학습은 계수연동법보다 계수고정법이 훨씬 더 우수한 것으로 나타나고 있어

주³⁾등이 수행한 고온저사이클 피로균열성장모델링과 상반된 결과를 나타내고 있다. 즉, 피로손상을 모델링하기 위한 방법이 전자의 경우 한점표현방식(one point representation scheme)에 기초를 두고 있지만 후자의 경우 세점표현방식(three point representation scheme)에 기초를 두고 있기 때문에 모델링에 따른 상이한 학습인식구조가 계수선택방법에 따른 학습에 큰 영향을 미쳤던 것으로 생각된다.



(a) Unit da/dN in output layer



(b) Unit N/N_f in output layer

Fig. 7 Relation between estimated mean error and floating rate methods

4.2 은닉층 유니트 수의 영향

전절까지 데이터 패턴과 학습 및 모멘트계수를 결정하기 위해 초기학습조건을 1개의 은닉층과 10개의 유니트로 설정하였다. 본 절에서는 학습에 미치는 유니트 수의 영향을 알아보기 위해 각 응력진

폭에 대한 데이터 수 51개에 대하여 은닉층 유니트 수를 2개에서 100개까지 순차적으로 바꾸어 학습 시킨 후 추정평균오차가 가장 적은 유니트 수를 은닉층의 최적 유니트 수로 선택한다.

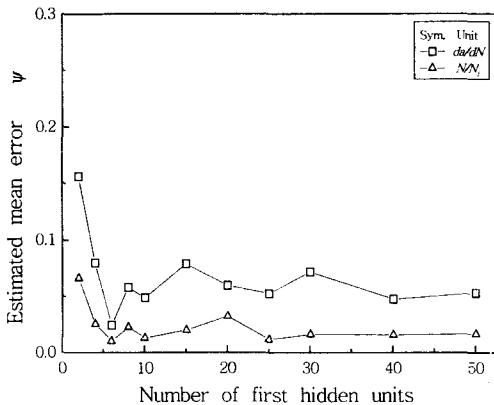


Fig. 8 Relation between estimated mean error and number of first hidden units

Fig. 8은 신경회로망의 특정 은닉층 유니트 수에 대한 출력층 유니트 균열성장속도 da/dN 과 피로수명비 N/N 의 학습결과를 나타낸 것으로 추정평균오차가 유니트 수 6개까지는 두 출력층 유니트 모두에 대하여 급격히 감소하다가 유니트 6개 이상에서는 증가와 감소를 반복하면서 진동한다. 일반적으로 신경회로망의 은닉층 유니트 수를 증가시켜 그 구조를 복잡하게 하면 학습패턴에 대한 맵핑은 잘 수행되지만 미학습데이터에 대한 일반화능력은 오히려 떨어지는 것으로 알려져 있다.¹¹⁾ 이러한 문제점은 네트워크의 자유도를 작게 하므로 해결할 수 있다. 따라서 본 연구에서 사용하는 신경회로망의 은닉층 유니트는 6개가 가장 적당한 것으로 생각되므로 최적의 은닉층 유니트 수를 6개로 설정한다.

4.3 은닉층 수의 영향

Fig. 9는 전절에서 결정된 1층의 은닉층 유니트 수를 6개로 한 신경회로망의 은닉층 구조에 다른 1층의 은닉층을 추가시켜, 이 층의 유니트에 대한 균열성장속도 da/dN 과 피로수명비 N/N 의 추정평균오차를 나타낸 것이다. 두 개의 출력층 유니트에 대

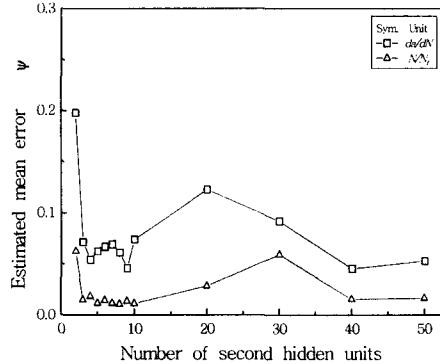


Fig. 9 Relation between estimated mean error and number of second hidden units

한 추정평균오차는 유니트가 10개까지 급격히 감소하나 10개이상에서는 증가와 감소를 반복하면서 진동한다. 또한 은닉층을 2층으로 설정한 경우가 은닉층을 1층으로 설정한 경우보다 추정평균오차는 최소 균열성장속도 da/dN 의 경우가 0.021, 피로수명비 N/N 가 0.0052만큼 더 크다. 따라서 입력층 데이터에서 출력층 데이터로의 연속 맵핑은 하나의 은닉층으로 가능하며¹²⁾ 2층 이상의 은닉층을 사용할 경우 단지 신경회로망의 학습시간만 길게 하므로써 비효율적인 연산처리구조가 됨을 알 수 있다.

4.4 학습데이터 크기의 영향

신경회로망으로 피로손상거동을 표현하기 위한 학습데이터의 크기를 최적화시킬 수 있다면 모델링에 필요한 시간적, 경제적 손실을 충분히 줄일 수 있을 것이다. 따라서 학습데이터의 크기를 점진적으로 증가시키는 점증학습방식을 이용하여 최적학습데이터의 크기를 결정하고자 한다.

Fig. 10은 신경회로망의 학습에 이용했던 데이터 수와 10만회 학습에 대한 추정평균오차의 관계를 나타낸 것이다. 학습데이터 수가 증가함에 따라 뚜렷한 경향성을 나타내지 않고 다만 지금까지 초기조건으로 설정했던 51개의 데이터 수일 때가 가장 적은 추정평균오차값을 보이고 있다. 따라서 과도한 학습데이터 수가 신경회로망에 주어질 때 학습에 상당한 시간이 걸린다는 것과 각각의 신경회로망 구조에 적합한 학습데이터 크기가 존재함을 알 수 있다. 이러한 결과는 신경회로망의 결합계수

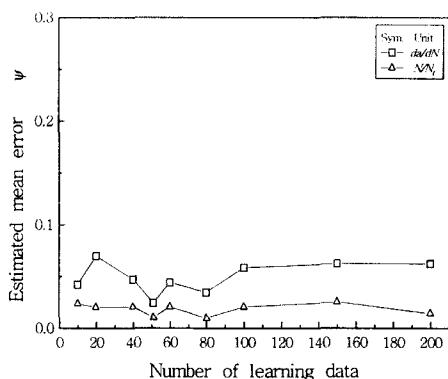


Fig. 10 Relation between estimated mean error and number of learning data

행렬이 초기의 학습조건으로 설정하였던 51개의 데이터 수를 기준으로 형성되어지기 때문에 추정평균오차도 이 부근의 데이터 수에서 가장 적은 값을 보이는 것으로 생각된다.

4.5 반복학습횟수의 영향

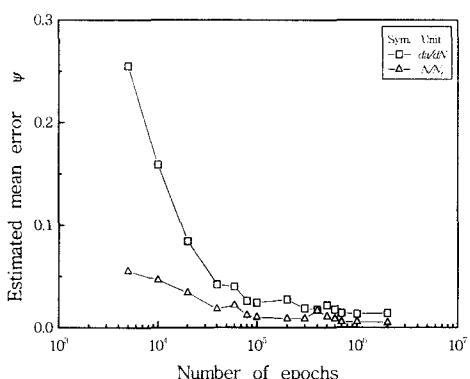


Fig. 11 Relation between estimated mean error and number of epochs

Fig. 11은 반복학습횟수에 대한 출력층 유닛 균열성장속도 da/dN 과 피로수명비 N/N_f 의 추정평균오차를 나타낸 것이다. 그림에서 반복학습횟수가 증가함에 따라 대체로 그 추정평균오차도 감소하고

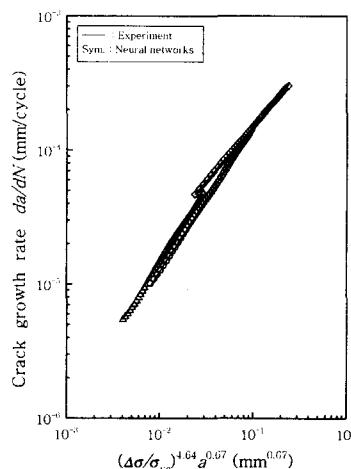
70만회 이상부터 균열성장속도 N/N_f 과 피로수명비 N/N_f 는 각각 0.014, 0.005 근처로 수렴하고 있다. 이러한 결과는 어느 정도의 반복학습횟수까지는 입력층 데이터에서 출력층 데이터로의 연속 맵핑에 상당한 영향을 주다가 그 이상의 반복학습횟수에서는 더 이상 영향을 주지 못하고 수렴해 버리기 때문이라 생각된다.

Table 3은 상술의 각 과정을 통하여 신경회로망의 각 파라미터를 최적화시킨 결과를 나타낸 것으로 신경회로망의 초기조건을 이용하여 각 파라미터를 단독으로 변화시킨 경우에 대한 추정평균오차의 최소값과 그 때의 파라미터를 각각 나타낸 것이다.

Table 3 Optimal conditions and estimated mean error for learning of neural networks

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

4.6 최적학습조건에 의한 피로손상의 예측



(a) Unit da/dN in output layer

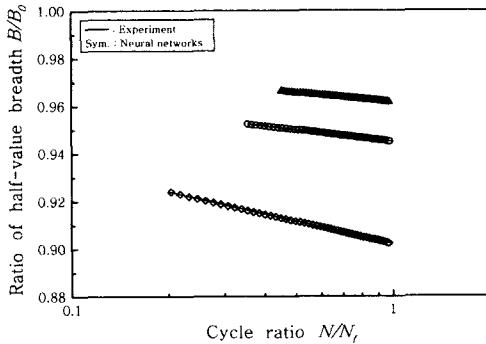
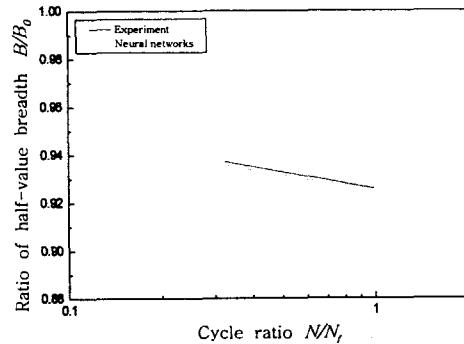
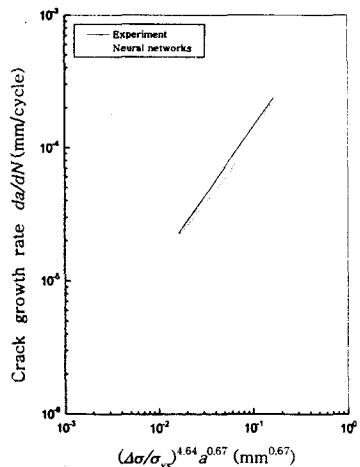
(b) Unit N/N_f in output layerFig. 12 Crack growth rate da/dN and cycle ratio N/N_f learned by neural networks with optimal learning conditions(b) Unit N/N_f in output layerFig. 13 Crack growth rate da/dN and cycle ratio N/N_f predicted by neural networks with optimal learning conditions

Fig. 12, 13은 Table 3의 최적학습조건을 이용하여 학습시킨 신경회로망을 기초로 AI 2024-T3 합금의 파로손상과정을 학습 및 일반화한 결과를 나타낸 것이다. 신경회로망의 학습에 따른 추정평균오차는 균열성장속도 da/dN 는 0.014, 피로수명비 N/N_f 는 0.0049로서 균열성장속도 da/dN 는 공학적 오차 범위 0.1를 초과하나 피로수명비 N/N_f 는 매우 낮은 평가 오차를 보이고 있다. 또한 응력진폭 $\Delta\sigma=303$ MPa에 대한 균열성장속도 da/dN 와 피로수명비 N/N_f

(a) Unit da/dN in output layer

를 학습된 신경회로망의 결합계수행렬로 예측하면 추정평균오차가 각각 0.1, 0.09로 충분한 공학적 오차한계범위에 들어온을 알 수 있다. 따라서 초기의 학습조건을 이용하여 각 파라미터를 단독으로 변화시켜 학습조건을 최적화하는 방법이 파로손상을 모델링하는 데 상당히 유효함을 알 수 있다.

5. 결론

본 연구에서는 AI 2024-T3 합금의 파로시험 데이터를 이용하여 신경회로망을 학습시킨 후 미지의 파괴역학과 비파괴파라미터를 입력층유니트에 대입하여 균열성장속도 da/dN 과 피로수명비 N/N_f 를 동시에 예측하는 네트워크를 구성한 결과 다음과 같은 결론을 얻었다.

1. 신경회로망에 사용하는 학습과 모멘트 계수를 고정시키는 계수고정법이 연동적으로 바꾸는 계수연동법보다 학습추정평균오차가 적게 나타내고 있다.
2. 은닉층 유니트 수를 증가시키면 추정평균오차는 6개까지는 현저히 감소하나 그 이상에서는 진동만 한다.
3. 학습 데이터 수가 증가에 따른 학습추정평균오차는 일정한 경향은 보이지 않으나 초기조건으로

설정하였던 51개의 데이터 수가 가장 적은 학습추정평균오차를 나타낸다.

4. 미지의 피로시험조건에 대한 파괴역학과 비파괴파라미터를 최적학습조건에 의한 신경회로망의 입력층 유니트에 대입하여 균열성장속도 da/dN 과 파로수명비 N/N_f 를 동시에 예측한 결과 일반화 추정평균오차는 각각 0.1, 0.09이다.

후기

본 연구는 99년도 삼척대학교 학술연구조성비에 의하여 수행되었으며 관계자 여러분께 감사드립니다.

참 고 문 헌

1. 川田雄一, "機械要素の疲労と設計," 日刊工業新聞社, pp. 1~63, 1967.
2. 趙石守, "STS304鋼의 高溫疲勞龜裂成長特性과 龜裂成長모델링에 의한 強度評價에 관한 研究," 東亞大學校 博士學位論文, pp.1~6, 1996.
3. 주원식, 조석수, "신경회로망을 이용한 고온 저사이클 피로균열성장 모델링에 관한 연구," 대한기계학회논문집 (A), Vol. 20, No.9, pp. 2752~2759, 1996.
4. 大石, 山田, 吉村, 失川, 永井, 松田, "ニューラル ネットワークを計算力学を用いた超音波缺陷同定法(レーザ超音波実験による精度検證)," 日本機械學會論文集 (A), 第64卷, 第619號, pp.810~818, 1998.
5. X. Wu, J. Ghabousi, "Modeling The Cyclic Behavior of Concrete Using Adaptive Neural Network," Computational Mechanics Vol. 1, pp.1319~1329, (1993).
6. 방승양, "뉴로컴퓨터," 尚湖社, pp.117~146, 1998.
7. 西谷弘信, 後藤眞宏, "微少き裂ば則と部材の疲労壽命との關係," 日本機械學會論文集 (A), Vol. 51, No. 462, pp. 332~341, 1985.
8. 西谷弘信, 藤村顯世, 福田幸雄, 福田孝之, "炭素鋼の疲労過程における疲労被害とX線半價幅の關係," 日本機械學會論文集, Vol. 55, No. 510, pp. 192~197, 1989.
9. 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," 日本機械學會論文集 (A), Vol.64, No. 619, pp. 597~602, 1998.
10. J.M. Zurada, "Introduction to artifical neural system," West Publishing Co., 1992.
11. Laurene Fausett, "Fundamentals of Neural Networks," Prentice Hall, inc., pp. 3~5, 1994.
12. Mehrotra, K.G, K.Kohan, S.Ranka, "Bounds on The Number of Samples Needed for Neural Network," IEEE Transaction on Neural Networks 2(6), pp. 548~558, 1991.