

● 論 文

역전파 신경회로망을 이용한 피로 균열성장 모델링에 관한 연구

주 원 식* · 조 석 수**

(95년 7월 31일 접수)

A Study on Fatigue Crack Growth Modelling
by Back Propagation Neural Networks

Won-Sik Joo* · Seok-Swoo Cho**

Key Words : Fatigue crack growth modelling(피로균열성장 모델링), Back propagation neural networks(역전파 신경회로망), Function mapping(함수 사상), Modified J integral(수정 J적분), Learning(학습), Generalization(일반화)

Abstract

Up to now, the existing crack growth modelling has used a mathematical approximation but an assumed function have a great influence on this method. Especially, crack growth behavior that shows very strong nonlinearity needed complicated function which has difficulty in setting parameter of it. The main characteristics of neural network modelling to engineering field are simple calculations and absence of assumed function. In this paper, after discussing learning and generalization of neural networks, we performed crack growth modelling on the basis of above learning algorithms. $J' - da/dt$ relation predicted by neural networks shows that test condition with unlearned data is simulated well within estimated mean error(5%).

1. 서 론

균열성장 구동력과 균열성장 속도 사이의 관계를 나타내는 균열성장 모델링은 피로균열성장 실험결과에 의한 수학적 근사화 방법에 기초하고 있다. 그러나 해결하고자 하는 균열성장 문제에 비선형 특성이 많이 포함되어 있거나 피할 수 없는 실험

오차가 있을 경우 기존의 모델로는 균열성장 거동을 표현하기가 매우 어렵다. 특히, 고온 저사이클 피로균열 성장 거동은 역학적, 환경적 그리고 재료적 변수에 매우 복잡하게 연관되어 있으므로 균열성장 거동의 동적 특성을 모델링하는 데 많은 어려움이 있다. 이러한 균열성장 속도를 평가하기 위한 상술의 함수 근사화 방법에 의한 수학적 근사

* 동아대학교 공과대학 기계공학과

** 동아대학교 대학원

해가 일부 유도되었으나, 이러한 근사해는 상술의 모든 파라미터를 포함하는 경우 상당한 오차를 포함하게 된다.^{1),2)} 또한, 균열성장 모델에 관한 해석적 접근 방법³⁾은 유한 요소법과 경계 요소법등과 같은 컴퓨터에 기초한 수치 해석 방법의 진보에 따라 각종 기계 구조물에 관한 정밀한 응력해석을 통하여 균열성장 거동을 표현할 수 있었다. 이러한 수치해석에 기초한 균열성장 거동의 유용성은 주로 해석에 사용된 역학적 가정에 의하여 결정되므로 재료의 이방성을 고려하지 않고 단순한 역학적 가정에 기초를 둔 균열성장모델을 사용하여 실제 구조물의 균열성장 속도를 측정할 경우 해석치와 실험치 사이에 상당한 차이를 보일 것으로 생각된다. 따라서 실험 조건의 전반적 영역에 걸쳐 잘 들어 맞는 균열성장모델의 적절한 파괴역학 파라미터를 찾기 힘들 뿐만 아니라, 실험조건이 달라지면 이러한 파라미터의 재조정이 필요하므로 기존의 균열성장 모델링이 부적절한 것으로 생각된다.

현재까지 피로에 종사하는 대부분의 연구자들은 주로 균열 성장 지배 파라미터를 구하는 문제에 초점을 맞추고 있기 때문에 함수 근사화 및 해석적 방법에 기초를 둔 연구가 주류였으나, 신경회로망과 같이 공학적 문제에 대하여 그것의 성격을 완전히 알지 못하더라도 입력층에서 출력층으로의 함수를 근사화시킬 수 있는 정보처리시스템을 사용하여 이러한 균열성장 속도를 공학적 오차범위내에서 평가할 수 있다면, 부재의 안전성 및 경제성의 관점에서 대단히 유용할 것이라 생각된다. 따라서 본 논문에서는 이러한 신경회로망을 균열성장 모델링에 적용하기 위하여 먼저, 임의 함수의 데이터를 기초로 역전파 신경회로망(Back propagation neural network)의 함수 사상(function mapping) 능력을 검토하고 나서 균열성장 구동력인 각종의 J적분을 신경회로망의 입력층 데이터로, 균열성장 속도를 출력층 데이터로 하여 균열성장 거동을 모델링하였다.

2. 역전파 신경회로망의 구조 및 학습 알고리즘

역전파 신경회로망에서 사용되는 유니트⁴⁾는 다

입력 다출력 형태로서 총상으로 그룹화되어 있으며 이를 Fig. 1에 나타내었다. 그림에서 데이터의 흐름은 입력층에서 출력층으로 또는 역방향으로

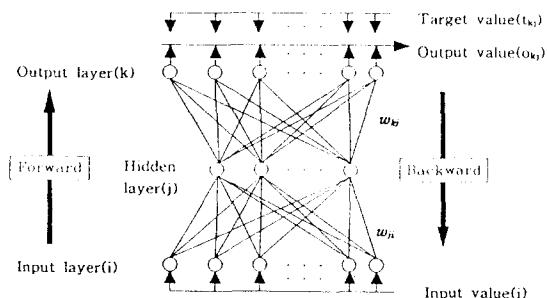


Fig. 1 Block of back propagation neural networks

전달되고 층내에서의 데이터 흐름은 이루어지지 않는다. 또한, 이러한 신경회로망의 학습은 목표값과 출력값의 평균이승오차를 나타내는 식(1)의 E_p 가 최소가 되도록 최급하강법을 이용하여 출력층과 은닉층 사이, 은닉층과 입력층 사이의 결합계수를 순차적으로 수정해 나가므로써 최적의 결합계수 수행렬을 구하는 것이다.

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

단, t_{pj} : 입력층 데이터의 목표값

o_{pj} : 신경회로망의 출력값

3. 신경회로망을 이용한 균열성장 모델링

균열성장 모델링에 수학적 근사법이 사용된다면 다음 식의 반복법을 이용한 미정계수법으로 계수 C_0 와 C_i 를 찾기 위한 계산을 해야 하며, 사용되는 파라미터 상호간에 물리적 의미를 충분히 가지고 있어야 한다.

$$\frac{da}{dt} = C_0 + \sum_i C_i \phi_i(\Delta J_i, J', v, \dots) \quad (2)$$

$j : f, c, t$

ϕ_i : nonlinear polynominal function

이러한 방법은 가정 함수의 설정이 중요하며 상관

관계가 복잡해 질수록 고차 함수가 필요하고 이에 따른 내개 변수의 계산이 어려워 진다. 따라서 본 논문에서는 가정 함수의 설정이 필요없고 간단한 연산을 행하는 것 만으로 모델링을 수행할 수 있는 신경회로망 이론을 기초로 이러한 난점을 해결하고자 한다.

신경회로망을 이용한 균열성장 모델링은 균열성장 구동력이라는 입력총 데이터와 균열성장 속도라는 출력총 데이터를 대응시키는 정량적 사상(Quantitative mapping)문제라고 말할 수 있다.^{5),6)} 따라서 신경회로망을 학습시킨다는 것은 다음 관계식의 함수 f 를 결정하는 것이며 이러한 경우 함수 f 는 신경회로망에 해당된다.

$$\frac{da}{dt} = f(\Delta J_b, J', \nu, \dots) \quad (3)$$

$j : f, c, t$

한편, 입력총 데이터와 출력총 데이터사이에 물리적 의미를 가지고 있지 않고 단지 대응관계가 있는 데이터를 함수 f 에 해당하는 신경회로망으로 학습시켜 그들 사이의 비선형 또는 연속적 사상관계를 신경회로망내에다 구축시켜 놓으면 그들의 일반화 능력에 의하여 미학습자료에 대한 균열성장 속도를 합리적으로 예측할 수 있을 것이다. 따라서 학습이 완료되어 일반화 단계에서 $\Delta J_{fb} = \Delta J_f, J_b = J', \nu = \nu'$ 등이 주어지면 함수 f 에 의하여 균열성장 속도 $da/dt_b = da/dt$ 를 얻을 수 있다. 또한 충분히 학습된 신경회로망은 실험 중에 발생된 오차에 대한 복구 능력이 크기 때문에 기존의 수학적 방법에 의하여 균열성장 속도를 예측하는 것 보다 훨씬 더 신뢰성 있게 평가할 수 있을 것으로 생각된다.

Fig. 2는 이상의 신경회로망을 이용하여 균열성장 모델링하는 순서를 나타낸 것이다. 제 1단계에서는 균열성장 구동력과 균열성장 속도등의 균열성장 실험 데이터를 신경회로망에 적합하도록 구성하고 제 2단계에서는 그들 자료를 가지고 신경회로망을 학습시킨다. 마지막 3단계에서는 학습된 신경회로망의 결합계수행렬을 이용하여 균열성장 속도를 예측한다.

균열성장 모델링을 수행할 때 신경회로망의 학습능력은 신경회로망의 출력값과 목표값의 차이인

추정평균오차를 기초로 평가하였으며 추정평균오차의 정의는 다음과 같다.

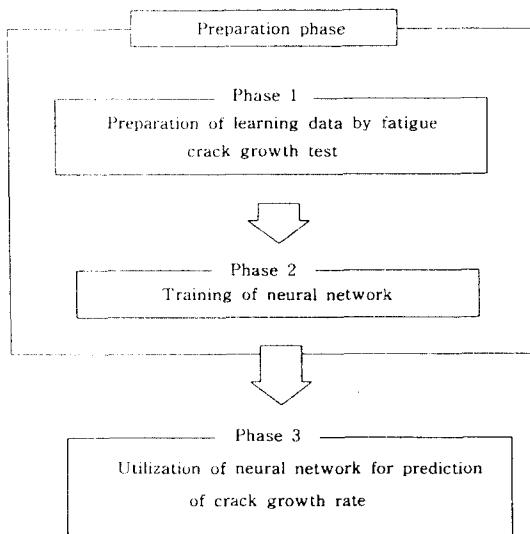


Fig. 2 Procedure of crack growth modelling by neural networks

$$\psi \text{ Mean Error} = \frac{1}{r} \sum_{p=1}^r |\psi_{\text{neuro}}(p) - \psi(p)| \quad (4)$$

여기서 $\psi(P)$: 입력총 데이터에 대한 목표값
 r : 학습과 일반화 검증에 사용한 학습 데이터 수
 $\psi_{\text{neuro}}(P)$: ψ 에 대한 신경회로망의 출력값
 ψ Mean Error : 신경회로망 데이터 $\psi_{\text{neuro}}(P)$ 의 추정평균오차

또한 추정평균오차가 0.05로 접근될 때, 균열성장 모델링이 공학적 오차범위내에서 수렴한 것으로 가정하여 이 범위를 한계오차범위로 설정하였다.

4. 신경회로망의 학습과 일반화 능력에 대한 검토

본 장에서는 균열성장 모델링을 하기 이전에 임의 함수에서 특정 좌표점을 선택하여 그 점을 신경회로망의 학습 데이터로 사용하여 신경회로망의 학습과 일반화 능력에 대하여 검토한다.

4.1 학습 함수의 설정

신경회로망의 학습 데이터로 사용할 학습 함수는 다음 식과 같은 3개의 함수를 임의로 선택하였으며 Table 1은 변수 x, y 와 함수 $\psi_x, \psi_y, \psi_{xy}$ 사이에 가상적으로 존재하는 4가지 경우의 학습 패턴을 나타낸 것이다. 또한 학습에 사용할 데이터

Table 1 Data patterns in function mapping and result of learning

Item Case	Set of input data	Set of output data	Schematic view of output data	Iteration number of learning at the end of learning	Mean error of function mapping
Case 1	(x, y) (ψ_x, ψ_y)			34,024	ψ_x Mean error 0.0418 ψ_y Mean error 0.0458
Case 2	(x, y) (ψ_x, ψ_{xy})			50,001	ψ_x Mean error 0.0155 ψ_{xy} Mean error 0.2049
Case 3	(y, x) (ψ_y, ψ_{xy})			50,001	ψ_y Mean error 0.0174 ψ_{xy} Mean error 0.1987
Case 4	(x, y) ($\psi_x, \psi_y, \psi_{xy}$)			18,024	ψ_x Mean error 0.0254 ψ_y Mean error 0.0003 ψ_{xy} Mean error 0.0384

는 $x-y$ 좌표평면상에 존재하는 무수한 점 중 임의로 잡았으며 이를 Fig.3에 나타내었다. 그림에서 학습 데이터로서는 ●으로 표시되는 (x, y)와 그것에 대응하는 $\psi_x, \psi_y, \psi_{xy}$ 값을 각각 입력층 데이터와 출력층 데이터로 하는 25개 데이터 패턴을 사용하였다.

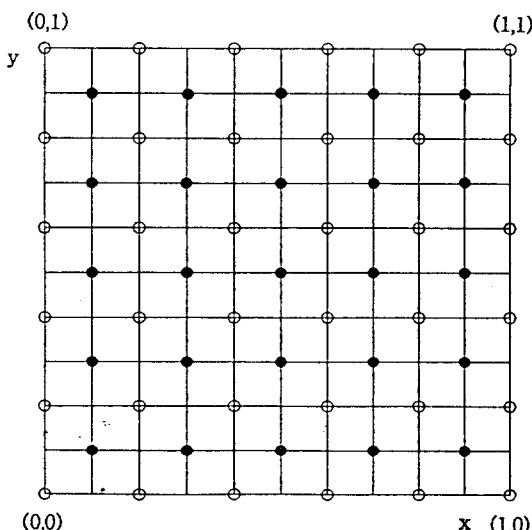


Fig. 3 Learning data in function mapping

$$\psi_x = \psi_x(x, y) = x \quad (5)$$

$$\psi_y = \psi_y(x, y) = y \quad (6)$$

$$\psi_{xy} = \psi_{xy}(x, y) = (x - 0.5)^2 + (y - 0.5)^2 \quad (7)$$

4.2 신경회로망의 구조 및 학습방식

Fig. 4는 본절에서 사용하는 신경화로망의 구조를 나타낸 것으로 경우 1~3에 대해서는 2유니트

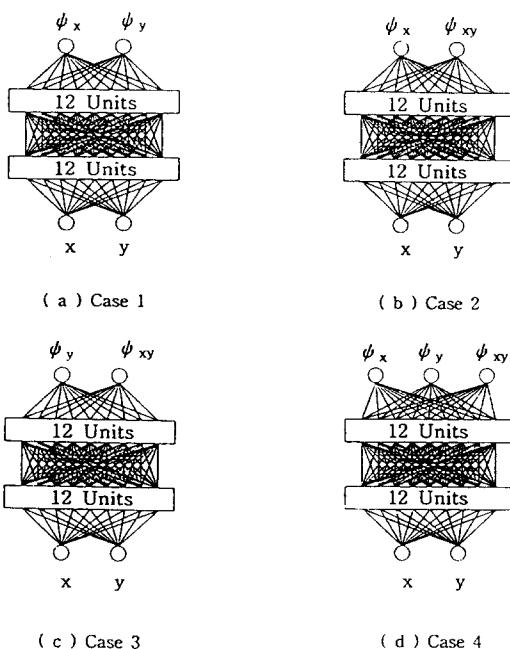


Fig. 4 Architecture of neural networks in function mapping

입력층과 출력층으로 구성하고, 경우 4에 대해서는 출력층만 3유니트로 구성하였으며 그외 두층의 유니트는 경우 1~3과 동일하다. 또한, 2층의 은닉층 갯수는 신경회로망 학습이 가장 어려웠던 case4가 빠르게 학습되는 최소 유니트수로 잡았으며 본절의 경우 12개로 설정하였다. 이에 따른 신경회로망의 학습은 본 논문에서 정의되는 한계오차범위에 접근될 때 완료되는 것으로 가정하였으며, 이러한 한계오차범위에 접근되지 않을 경우 학습횟수가 50000회가 되는 단계에서 신경회로망을 임의로 정지시켰다.

또한 신경회로망이 미학습데이터에 대하여 타당한 출력값을 만들어 낼 수 있느가에 대한 일반화 능력의 검증은 학습과정에서 발생되는 추정평균오차 ψ Mean Error가 최소로 될 때의 결합계수 행렬을 이용하여 평가하였다. 일반화에 사용되는 미학습 데이터는 Fig. 3의 ○으로 표시된 (x, y) 의 값을 입력층 데이터로 잡았다.

4.3 신경회로망의 학습 능력

Table 1은 신경회로망을 이용한 함수 사상(function mapping)에 사용되는 4가지 학습패턴의 학습 결과를 나타낸 것이다. 경우 1, 4의 신경회로망은 추정평균오차 ψ Mean Error가 0.05 이하가 되기 위하여 각각 학습 횟수 34024회와 18024회를 필요로 한다. 그러나 경우 2, 3은 신경회로망이 추정평균오차의 수렴 범위내로 들어오지 않아 결국 학습 한계 횟수인 50000회에서 신경회로망 프로그램을 정지시켰다. 경우 2, 3의 경우 학습 데이터 중 입력 층 x, y 와 출력층 ψ_x, ψ_y 사이에 선형적 사상 관계를 이루고 있지만 출력층이 ψ_{xy} 가 되는 경우 다대일의 비형적 사상관계가 존재하고 있다. 따라서 신경회로망 내부에 두 가지 사상관계가 불완전하게 혼합되어 있기 때문에 신경회로망이 한계 추정평균오차에 접근하지 못하는 것으로 생각된다. 한편. 경우 1, 4의 신경회로망은 모두 한계오차범위에 접근하고는 있으나, 출력층 갯수가 적어 학습이 쉬우리라 생각되는 경우 1이 경우 4보다 학습에 필요한 학습 횟수가 약 2배 정도 많다. 이러한 결과는 ψ_x 와 ψ_y 의 학습 데이터가 분리되는 것 보다 ψ_x, ψ_y 와 ψ_{xy} 의 학습 데이터가 훨씬 더 쉽게 분리되기 때문인 것으로 생각된다.

4.4 신경회로망의 학습과 일반화

Fig. 5는 신경회로망의 학습능력을 평가하기 위하여 특정 좌표 $(0.5, 0.5)$ 에서의 학습결과 및 연속 함수를 동시에 나타내었다. 각 학습에 사용한 좌표 값 모두를 연속적으로 그림에 나타내어 일반화 능력을 고찰하는 것은 (x,y) 좌표가 변화함에 따라 세 종류의 연속함수가 변하게 되므로 위와 같이 특정 좌표에 의한 변화 거동을 검토하는 것이 바람직한

것으로 생각된다.

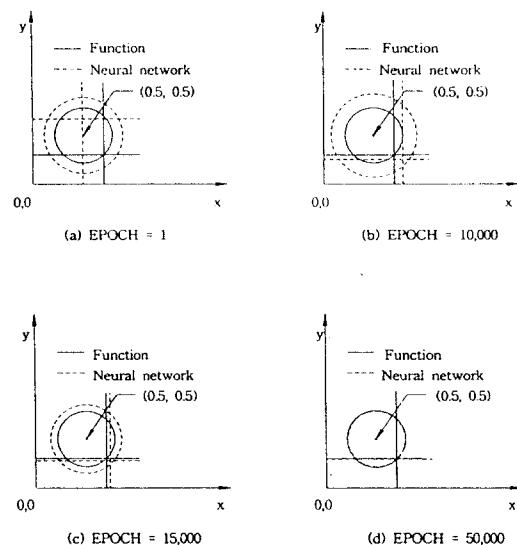


Fig. 5 Learning procedure of neural network

Fig. 5의 (a)는 신경회로망이 학습 초기에 입력 층 데이터가 출력층 데이터에 대하여 어떻게 사상하고 있는가를 보이고 있다. 그림에서 실선은 출력 층 데이터의 목표값이며 점선은 신경회로망에 의하여 학습된 출력값이다. 학습 초기에 출력값과 목표값사이에 상당히 큰 오차를 보이고 있으나, 신경회로망의 학습반복횟수가 증가함에 따라 출력값이 목표값에 접근하고 있고 특히 (d)의 경우 출력값에 따른 원과 선의 위치가 Table 1에 나타낸 위치에 수렴되고 있어 신경회로망의 학습이 거의 완료되었음을 알 수 있다. 이러한 신경회로망은 그 구조내에 학습된 결합계수 행렬을 구축하고 있으므로 신경회로망의 입력층에 미학습 데이터를 대입하면 입력값에 대한 출력값을 예측할 수 있을 것이다. 따라서 Fig. 3의 미학습 데이터를 이용하여 신경회로망의 일반화 능력을 평가하였으며 이를 Fig. 6에 나타내었다. 그림에서 출력값과 목표값사이에 추정평균오차가 0.042정도만 발생되므로 신경회로망은 미학습 데이터에 대하여 충분히 일반화되어, 입력 층 데이터와 출력층 데이터사이에 성공적으로 사

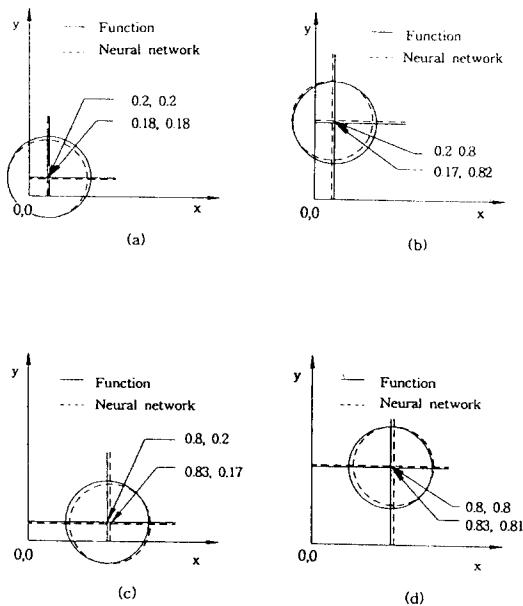


Fig. 6 Generalization of neural network

상이 이루어졌다는 것을 알 수 있다. 따라서 공학 문제에서 데이터를 신경회로망의 입력층과 출력층으로 분류하여 학습시켜 놓으면 미학습 입력값에 대한 적절한 출력값을 얻을 수 있어 예측 모델을 만드는데 신경회로망이 유용할 것으로 기대된다. 다음 장에서는 이러한 사실에 근거를 두고서 신경회로망을 이용한 균열성장 모델링을 통하여 미학습 데이터에 대한 균열성장 속도를 예측해 볼 것이다.

5. 신경 회로망을 이용한 고온 저사 이클 피로균열 성장 모델링

5.1 신경회로망의 기본적 구조

일반적으로 구조물은 다양한 하중상태에 놓이게 되나 균열성장 거동에 기초한 피로설계개념을 이러한 구조물에 응용할 경우, 하중상태를 단순한 일축으로 가정하여 실험하는 것이 일반적이다. 따라서 신경회로망을 이용한 균열성장모델은 周^{7),8)} 등이 수행한 SUS 304강의 일축하중하의 균열성장 거동을 기초로 만들어졌으며 이에 따른 실험조건을 Table 2에 나타내었다. 역전파신경회로망을 학

습시키는 데 필요한 데이터를 얻기 위한 균열성장 실험은 최대응력을 170MPa로 고정하여 다양한 하중반복속도와 예민화온도 및 응력비를 변화시켜 파괴역학적 관점으로 데이터를 정리하였다. 또한, 이러한 데이터는 신경회로망 학습에 시그모이드 활성화 함수를 사용하기 때문에 학습데이터의 최대값과 최소값을 이용하여 모든 실험 데이터를 0에서 1 사이의 선형적 값으로 표준화(Scaling)시켰다.

Table 2 Test condition

Temp.(°C)	R	Freq.(Hz)	Symbol
550	0.5	1.6	△
600			▲
650			▲
700			△
650	0.5	0.0	□
		0.3	■
		0.5	■
		0.7	□
600	0.5	6	○
		1.6	●
		0.08	●
		0.008	○

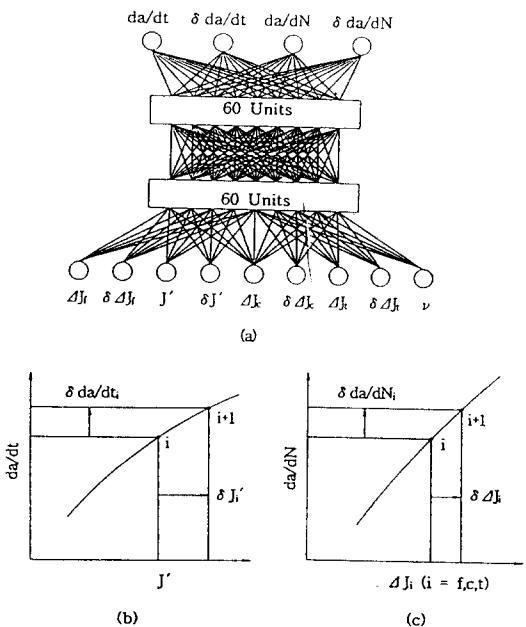


Fig. 7 Representation scheme of data pattern and architecture of neural network in crack growth modelling

신경회로망에 기초를 둔 균열성장모델을 만들기 위해서는 균열성장 거동을 표현하기 위한 입력총과 출력총 유니트에 사용할 파괴역학적 파라미터를 결정해야만 한다. 따라서 균열성장기구의 파괴역학적 관점에서 균열성장 구동력을 입력총 유니트로, 균열성장 속도를 출력총 유니트로 신경회로망을 구성하였고 여기서 사용되는 데이터는 임의 균열에서 측정된 파괴역학량 이외에 그 인접 데이터 사이의 기울기를 함께 사용하였다. 또한, 역전파 신경회로망에서 사용되는 은닉총 수는 학습 효율과 시간을 고려하여 2개로 모두 고정시켰으며 이상의 신경회로망 구조와 데이터 패턴의 표현방식을 Fig. 7에 나타내었다.

5.2 학습에 미치는 학습 계수와 모우멘트 계수의 영향

Table 3은 균열 성장 신경회로망의 최적 구조를 만들기 위하여 신경회로망의 학습반복횟수를 30만회로 잡아 학습계수 μ 를 바꿀 때 학습 계수와 평균 오차와의 관계를 나타낸 것이다.

Table 3 Relation between learning rate and estimated mean error

Learning rate	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Momentum rate	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9	0.9
Estimated mean error	0.202	0.183	0.143	0.143	0.143	0.143	0.146	0.144	0.147

추정평균오차는 학습계수가 0.2이하에서 급격히 증가하다가 0.3과 0.6사이에서 일정한 값 0.143에 수렴하게 되고 0.7이상에서는 추정평균오차가 증가와 감소를 반복하게 된다. 이러한 결과는 학습률이 작은 경우 국부 입력총 데이터에 의해서만 결합계수가 평균 이승 오차 E_p 에 대하여 수정되기 때문에 정말로 옳은 목표값이 무엇인지를 모르기 때문인 것으로 생각된다. 반면에 결합계수가 0.3과 0.6사이의 영역에서는 결합계수 w_{ij} 에 대한 평균이승오차 E_p 의 오차 평면이 평탄함으로 인하여 쉽게 수렴되나 0.7이상에서는 신경회로망의 추정평균오차가 진동하여 수렴이 약간 늦어지는 것으로 사료된다.

Table 4는 학습에 미치는 모우멘트 계수의 영향을 알아보기 위하여 상술의 학습반복회수를 기초로 모우멘트 계수와 추정평균오차와의 관계를 나타낸 것이다. 추정평균오차는 0.7까지 급격히 증가하다가 0.7 이상에서는 오히려 감소하게 된다. 이러한 결과는 모우멘트 계수가 0.7이하에서는 신경회로망이 오차평면의 국부적 최소값으로 들어가기 때문이나 0.7이상에서는 모우멘트 계수에 의한 결합계수의 수정량이 크게되어 국부적 입력 데이터의 변화에 둔감하여져 신경회로망 오차평면의 국부적 최소값을 벗어나기 때문이라 생각된다.

Table 4 Relation between momentum rate and estimated mean error

Learning rate	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1
Momentum rate	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Estimated mean error	0.271	0.272	0.274	0.276	0.278	0.279	0.287	0.223	0.202

따라서 본 논문에서 사용하는 학습계수와 모우멘트 계수는 위의 실험결과를 기초로 $\mu=0.3$, $m=0.9$ 로 고정시켜 사용하였다.

5.3 신경회로망에 의한 균열성장 속도의 예측

균열성장 모델링은 신경회로망에 실험 데이터를 대입하여 그것을 자기 조직화시켜 그것의 결합계수를 수정하므로써 J적분값과 그 증분으로 균열성장 속도와 그 증분값을 예측하고자 하는 것이다.⁹⁾ 이러한 예측 모델에 사용되는 각각의 신경회로망 구조는 각 실험조건에 따라 Fig.8의 입력총 변수중 실험 변수인 주파수, 응력비, 온도만 바꾸어 사용하였다. 먼저 학습할 세가지 실험조건의 데이터를 신경회로망에 대입하여 학습반복회수가 30만회에 도달한 결과를 도식화한 것이 Fig.8~10까지의 (a)이다. 그림에서 실선은 각 실험조건의 실제 균열성장 속도를, 기호는 신경회로망에 의하여 예측된 균열성장 거동을 나타낸 것이다. 실제 균열성장 거동이 비선형거동을 보이고 있음에도 불구하고 신경회로망에 의하여 잘 수렴되고 있음을 알 수 있다. 이와 같이 학습된 결합계수 행렬에 일반화에

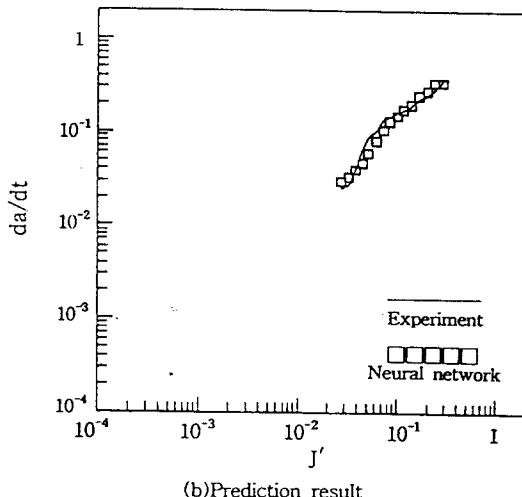
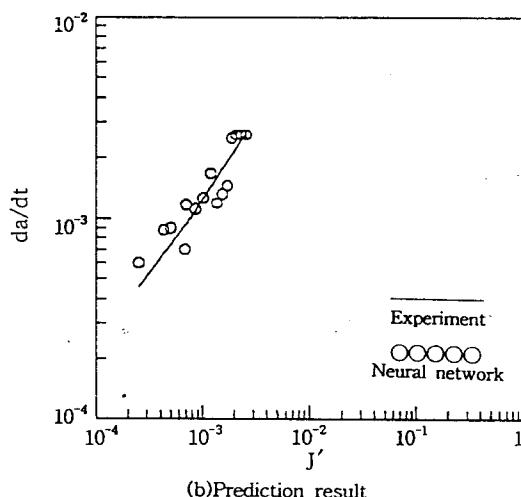
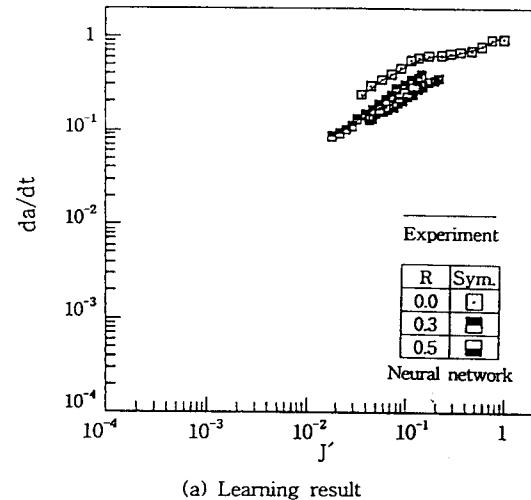
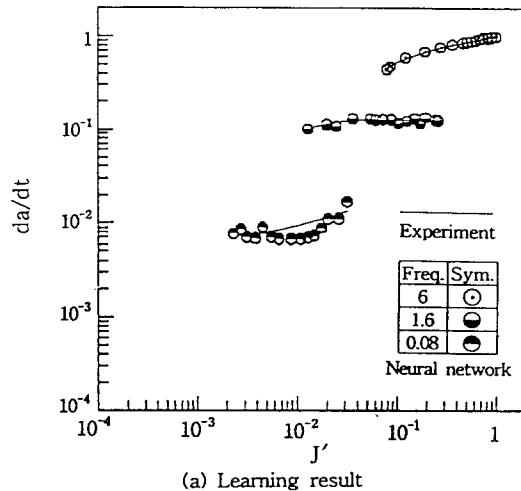


Fig. 8 da/dt - J' relation learned and predicted by neural network on fatigue crack growth test with various frequencies

이용할 데이터를 열 벡터(column vector)에 대입하여 계산하면 신경회로망에 의하여 균열성장 속도를 예측할 수 있다. Fig. 8~10의 (b)는 신경회로망에 의하여 미학습 데이터를 일반화시킨 결과를 나타낸 것이다. 균열성장곡선에서 신경회로망이 J' 적분값에 의하여 학습되지 않았음에도 불구하고 추정평균오차가 0.049이므로 한계오차범위에서 모

Fig. 9 da/dt - J' relation learned and predicted by neural network on fatigue crack growth test with various stress ratis

델링되고 있음을 알 수 있다. 그러나 각 실험조건에 따른 기울기의 변화가 심한 Fig. 9의 경우 신경회로망에 의하여 균열성장 속도를 예측할 때 상당한 오차가 발생됨을 알 수 있다. 이러한 결과는 학습 초기 단계부터 축적된 오차가 다른 실험조건에 비하여 크기 때문인 것으로 생각되며 이러한 오차 축적현상에도 불구하고 신경회로망에 의한 거시적

균열성장 속도를 예측할 수 있다는 것은 학습된 신경회로망이 일반화를 통한 오류복구능력을 가지고 있다는 것을 나타내고 있다.

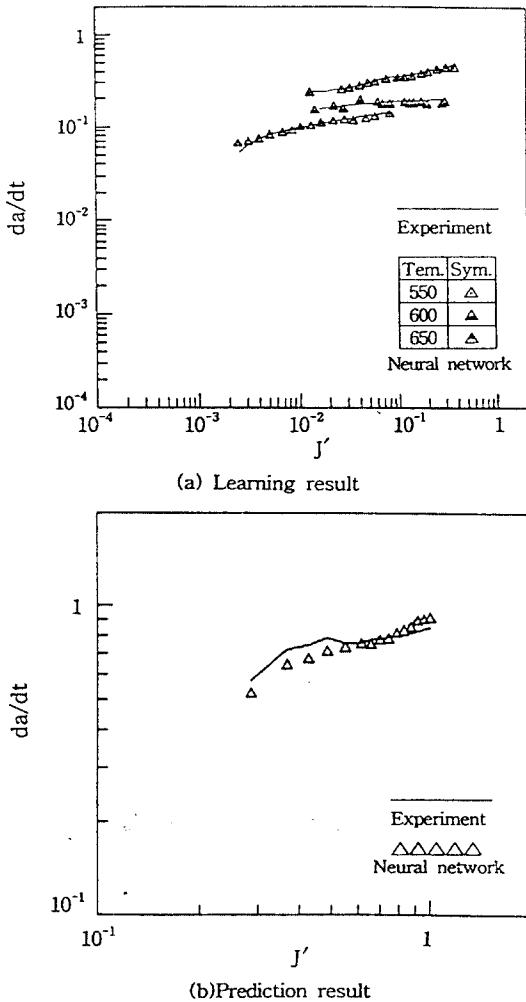


Fig. 10 da/dt - J' relation learned and predicted by neural network on fatigue crack growth test with various temperatures

6. 결 론

기존의 균열성장 모델링에 수학적 근사법이 사용되어 왔으나 이러한 방법은 가정함수의 설정이 중요하며 상관 관계가 복잡해 질수록 고차함수가

필요하고 이에 따른 매개 변수의 계산이 어려워진다. 따라서 본 논문에서는 가정함수의 설정이 필요 없고 간단한 연산을 행하는 것으로 공학문제의 모델링에 유용한 것으로 생각되는 신경회로망의 학습과 일반화 특성을 검토한 후, 이러한 학습 알고리즘을 기초로 균열성장 모델링을 수행하여 다음과 같은 결론을 얻었다.

1. 임의 함수의 데이터를 이용한 신경 회로망의 학습과 일반화로 부터 신경 회로망은 함수 사상 능력을 가지고 있어 공학적 문제로의 모델링에 유용한 것으로 평가된다.
2. 신경 회로망의 학습에 큰 영향을 미치는 학습 계수와 모우멘트 계수는 신경 회로망의 구조에 따라 적절한 값이 존재하고 있다.
3. 역전파 신경회로망으로 고온 저사이클 피로 균열 성장 모델링을 수행하면 균열 선단 균방의 역학적 환경에 관계없이 균열 성장에 관한 거시적 데이터만으로 그러한 거동을 한계오차범위내에서 모델링 할 수 있어 신경회로망이 기존의 경험적 모델링 보다 더 유용한 것으로 평가된다.

7. 참 고 문 헌

1. 大路, 小倉, 久保外 2人, “SUS304鋼を用いたクリープ疲労相互作用下のき裂傳ば実験”, 材料, 第31卷, 第36號, pp. 145~151, 1984
2. Kuntimaddi Sadanada, Paul Shahinian, “Elastic-Plastic Fracture Mechanics for High Temperature Fatigue Crack Growth”, ASTM STP 700, pp. 152~163, 1980
3. 李鳳勳, “有限要素핸드북”, 東和技術, pp. 324~367, 1991
4. Philip D.Wasserman, “Neural Computing”, Van Nostrand Reinhold, p. 14, 1989
5. 오 성현, 주 운표, 김 건중, “다층신경회로망을 이용한 원자력 발전소 가압기 센서 검증”, 대한전기학회논문집, Vol. 142, No. 7, pp. 35~42, 1993
6. 望月義彦, 矢川元基, 吉村忍, “階層型ニューラルネ

- ットワークと計算力学に基づく逆問題解析法 - 學習、推定メカニズムの検討と定量的缺陷同定への適用”, 日本機械學會論文集(A編) 57卷, 540號, pp. 1922~1929
7. 손승우, “SUS304강을 이용한 고온저사이클피로균열 성장 거동에 관한 연구”, 동아대학교 석사학위 논문, p. 24~29, 1994
8. 大路, 久保, 周, 久利, “SUS鋼のクリープ温度領域における正弦波部分片振應力下の時間依存形および繰返し數依存形き裂傳ば”, 日本機械學會論文集, 第51卷, 第467號, pp. 132~145, 1986
9. X-Wu, J. Ghabousi, “Modelling the cyclic behavior of concrete using adaptive neural network”, Computational mechanics Vol. 1, pp. 1319~1329, 1993