

〈논 문〉

신경회로망을 이용한 고온 저사이클 피로균열성장 모델링에 관한 연구

주원식* · 조석수**

(1996년 8월 1일 접수)

A Study on High Temperature Low Cycle Fatigue Crack Growth Modelling by Neural Networks

Won-Sik Joo and Seok-Swoo Cho

Key Words : Crack Growth Modelling(균열성장 모델링), Neural Network(신경회로망), Modified J Integral(수정 J적분), Learning Pattern(학습패턴), Generalization(일반화), Estimated Mean Error(추정평균오차)

Abstract

This paper presents crack growth analysis approach on the basis of neural networks, a branch of cognitive science to high temperature low cycle fatigue that shows strong nonlinearity in material behavior. As the number of data patterns on crack growth increase, pattern classification occurs well and two point representation scheme with gradient of crack growth curve simulates crack growth rate better than one point representation scheme. Optimal number of learning data exists and excessive number of learning data increases estimated mean error with remarkable learning time. 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

고온 저사이클 피로균열성장거동에 관한 실험적 연구는 주로 균열성장의 구동력과 균열성장속도 사이의 관계를 실험조건에 영향을 받지 않는 수학적 모델링을 세우는 데 주력되어 왔다.⁽¹⁾ 이러한 모델은 복잡한 균열성장거동을 지배하는 파괴역학적인 파라미터의 개발과 실험데이터에 의한 함수근사법에 근거하고 있다. 1970년대부터 지금까지 다양한 실험조건하의 균열성장거동에 관한 수학적 모델은 거의 동일한 방법으로 개발되어져 왔으며, 그

모델링 절차는 다음과 같다.

첫째, 피로시험을 실시하여 실험재료의 균열성장 거동을 관찰한다.

둘째, 균열성장거동을 정리하여 평가하기 위한 파괴역학적인 파라미터를 결정한다.

셋째, 실험조건에 따른 균열성장거동을 예측하기 위하여 함수근사법에 근거한 균열성장모델을 세운다.

넷째, 셋째에 의하여 제안된 모델로서 균열성장 거동을 설명할 수 없을 때, 둘째와 셋째의 절차를 반복한다.

이러한 균열성장 모델링 방법에서 주로 사용되는 파괴역학적인 파라미터는 응력확대계수와 J 적분 등이며, 이것들은 인장하중을 받을 때 균열선단에서

*회원, 동아대학교 기계공학과

**동아대학교 대학원

의 응력집중강도 및 포텐셜 에너지해방률어므로 제하과정이 반드시 포함되는 피로균열성장기구에서 위의 파라미터를 적용하는 것은 파라미터의 정의에 위배된다. 그러나 Paris 등⁽²⁾은 균열성장속도평가에 부하때와 제하때의 응력확대계수 차이인 ΔK 를 적용한 이래로 많은 연구자들⁽³⁻⁵⁾은 응력진폭, 최대 응력확대계수, 파괴인성치, 응력비, 균열단합, 열악한 환경, 실험재료 등에 의하여 균열성장거동이 영향을 받는다고 생각하여 물리적 관계가 엄밀하지 않음에도 불구하고 위의 모델링 절차를 통하여 상술의 파라미터를 개조하여 적용하였다. 그러나 실험조건의 전반적 영역에 걸쳐 잘 들어 맞는 균열성장모델의 적절한 파괴역학인 파라미터를 찾기 힘들 뿐만 아니라, 실험조건이 달라지면 이러한 파라미터의 개조정이 필요하므로 기존의 균열성장 모델링이 부적절한 것으로 생각된다.

따라서 본 논문에서는 새로운 학습 알고리즘을 토대로 하는 신경회로망 이론을 사용하여 상술의 수학적 모델링이 시퀀셜(sequential)데이터 처리에 국한됨으로써 오는 기능상의 한계를 극복하고자 한다. 즉, 피로시험에서 얻은 균열성장속도를 파괴역학적인 파라미터로 평가하는 것이 아니라 기존의 파라미터를 이용한 데이터 처리 시스템의 관점에서 균열성장속도를 평가하였다.

2. 신경회로망에 관한 기초적 연구

2.1 신경회로망의 유니트 구조

신경회로망의 유니트는 인간의 신경세포를 인공적으로 모델화한 것이며, 이러한 유니트는 신경회로망의 정보처리요소(information processing element)이기 때문에 셀이(cell)이라고도 한다.⁽⁶⁾ Fig. 1은 본 연구에서 사용한 다입력 단출력형의 신경회로망 유니트를 표시하고 있다. 활성화함수(activation function) f 는 1계 미분이 본래의 함수로서 표현할 수 있고, 출력값이 $[0, 1]$ 구간에서 연속적으로 변화하는 시그모이드함수(sigmoidal function)를 사용했다. Fig. 2는 시그모이드함수를 X-Y 평면상에 나타낸 것으로 S자 형태를 취하고 있다. 신경회로망에 들어오는 입력값은 결합함수(combining function)의 형태로서 그 유니트와 관계되는 출력값과 그 연결상의 결합계수와와의 곱의 합이 들어오며 이를 식 (2.1)로, 나가는 출력값은 입력값에 의한 활성화 함수값으로 식 (2.2)이다.




Fig. 1 Structure of artificial neuron with activation function




Fig. 2 Sigmoidal activation function

$$net_{pj} = \sum_i w_{ji} o_{pi} \quad (2.1)$$

$$o_{pj} = f_j(net_{pj}) \quad (2.2)$$

$$f(net_{pj}) = \frac{1}{1 + \exp\left(-\frac{2net_{pj}}{net_{t0}}\right)} \quad (2.3)$$

- o_{pj} : n 번째층의 j 번째 유니트 출력값
- o_{pi} : $n-1$ 번째층의 i 번째 유니트 출력값
- net_{pj} : n 번째층의 j 번째 유니트의 내부포텐셜
- $f(x)$: 유니트의 활성화함수
- net_{t0} : 시그모이드함수의 온도
- w_{ji} : $n-1$ 번째층의 i 번째 유니트와 n 번째층의 j 번째 유니트사이의 결합계수

2.2 역전파 신경회로망의 층상구조

Fig. 3은 본논문에서 사용하는 역전파 신경회로망의 층상구조를 나타내고 있다.⁽⁷⁾ 그림에서 하나의 원은 신경회로망에서 사용되는 가장 기본단위인 뉴런을 나타내고 있으며, 이러한 뉴런들을 모은 최소 단위가 하나의 층(layer)을 구성하게 된다. 신경회로망은 이러한 층을 종방향(longitudinal direc-




Fig. 3 Block of back propagation neural network

tion)으로 적층하여 입력층 유니트와 은닉층 유니트사이를 결합계수 w_{ji} 로, 은닉층 유니트와 출력층 유니트 사이에는 w_{kj} 로 각각 연결시키므로써 정보 처리시스템을 구축하게 된다.

일반적인 역전파 신경회로망의 학습은 다음과 같다. 입력층의 각 유니트에 입력데이터를 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. 따라서 신경회로망의 학습이 완료되었다는 것은 입력층과 출력층 데이터 사이에 존재하는 패턴인식을 파악하여 결합계수 행렬로 신경회로망내에 저장하게 된다. 이러한 결합계수 행렬에 학습되지 않은 입력층 데이터를 열벡터(column vector)의 형태로 신경회로망에 대입하면 새로운 출력데이터를 구할 수 있고 만약 이러한 출력데이터가 목표값에 수렴된다면 신경회로망은 일반화 능력을 가지고 있다고 말한다.

균열성장 모델링을 수행할 때 신경회로망의 학습과 일반화능력은 신경회로망의 출력값과 목표값의 차이인 추정평균오차를 근거로 평가하였으며 추정평균오차의 정의는 다음과 같다.

$$\phi \text{ Mean Error} = \frac{1}{r} \sum_{p=1}^r \frac{|\phi_{neuro}(p) - \phi(p)|}{|\phi(p)|} \quad (2.4)$$

여기서,

$\phi(p)$: 입력층 데이터에 대한 목표값

r : 학습과 일반화 검증에 사용한 학습데이터 수

$\phi_{neuro}(p)$: ϕ 에 대한 신경회로망의 출력값

ϕ Mean Error : 신경회로망 데이터 $\phi_{neuro}(p)$ 의 추정평균오차

또한 추정평균오차가 0.05로 접근될 때, 균열성

장 모델링이 공학적 오차범위내에서 수렴한 것으로 가정하여 이 범위를 한계 오차범위로 설정하였다.

3. 신경회로망을 이용한 고온 저사이클 피로균열성장 모델링

3.1 신경회로망의 기본적 구조

신경회로망에 근거를 둔 균열성장모델을 만들기

Table 1 Test condition

Tem. (°C)	R	ν (Hz)	Symbol
600	0.5	6	⊙
		1.6	●
		0.08	◐
		0.008	○




Fig. 4 Architecture of neural network in crack growth modelling Output layer Hidden layer Input layer

위해서는 균열성장거동을 표현하기 위한 입력층과 출력층 유니트에 사용할 파괴역학적 파라미터를 결정해야만 한다. 따라서 균열성장기구의 파괴역학적 관점에서 균열성장의 구동력을 입력층 유니트로, 균열성장속도를 출력층 유니트로 신경회로망을 구성하였다. 또한, 신경회로망의 학습에 사용되는 데이터는 孫 등⁽⁸⁾이 수행한 SUS 304 스테인레스 강 of 고온 저사이클 피로균열성장거동을 근거로 만들어졌으며 이에 따른 실험조건을 Table 1에 나타내었다. 그러나 역전파 신경회로망은 시그모이드 활

성화함수(sigmoidal activation function)를 사용하기 때문에 상술의 데이터를 그대로 신경회로망의 학습에 사용할 수 없다. 따라서 원래의 실험데이터를 시그모이드 활성화함수의 범위인 0과 1사이의 값으로 표준화시켰다.

한편 신경회로망의 학습에 미치는 은닉층 수에 관한 Mehrotra 등⁽⁹⁾의 이론해석결과에 의하면, 입력층 데이터에서 출력층 데이터로의 연속매핑(continuous mapping)은 하나의 은닉층으로도 가능하며 2층 이상의 은닉층을 사용할 경우 단지 신




Fig. 5 One point representation scheme and architecture of neural network at various learning pattern in crack growth modelling

경회로망의 학습을 용이하게 할 뿐이었다. 따라서 본 논문에서 사용되는 신경회로망의 은닉층은 학습 효율과 시간을 고려하여 2층의 은닉층으로 모두 고정시켰다. 그리고 신경회로망이 한계 오차범위로 접근하는 속도를 빠르게 하기 위하여 입력층과 은닉층에 결합계수 1인 바이어스 유닛(bias unit)을 첨가시킴으로써 활성화함수의 원점을 오프셋(offset)시켜 퍼셉터론(Perceptron)의 하한계를 조

절하는 것 같은 효과를 내게 하였다.⁽¹⁰⁾ 이상의 신경회로망 구조를 Fig. 4에 나타내었으며 이를 근거로 다음 절에서는 균열성장 모델링에 미치는 각종 인자에 대하여 검토하고 이에 따른 최적 조건의 신경회로망을 이용하여 균열성장속도를 예측하였다.

3.2 학습에 미치는 데이터 패턴의 영향

균열성장 모델링에 미치는 데이터 패턴의 영향을

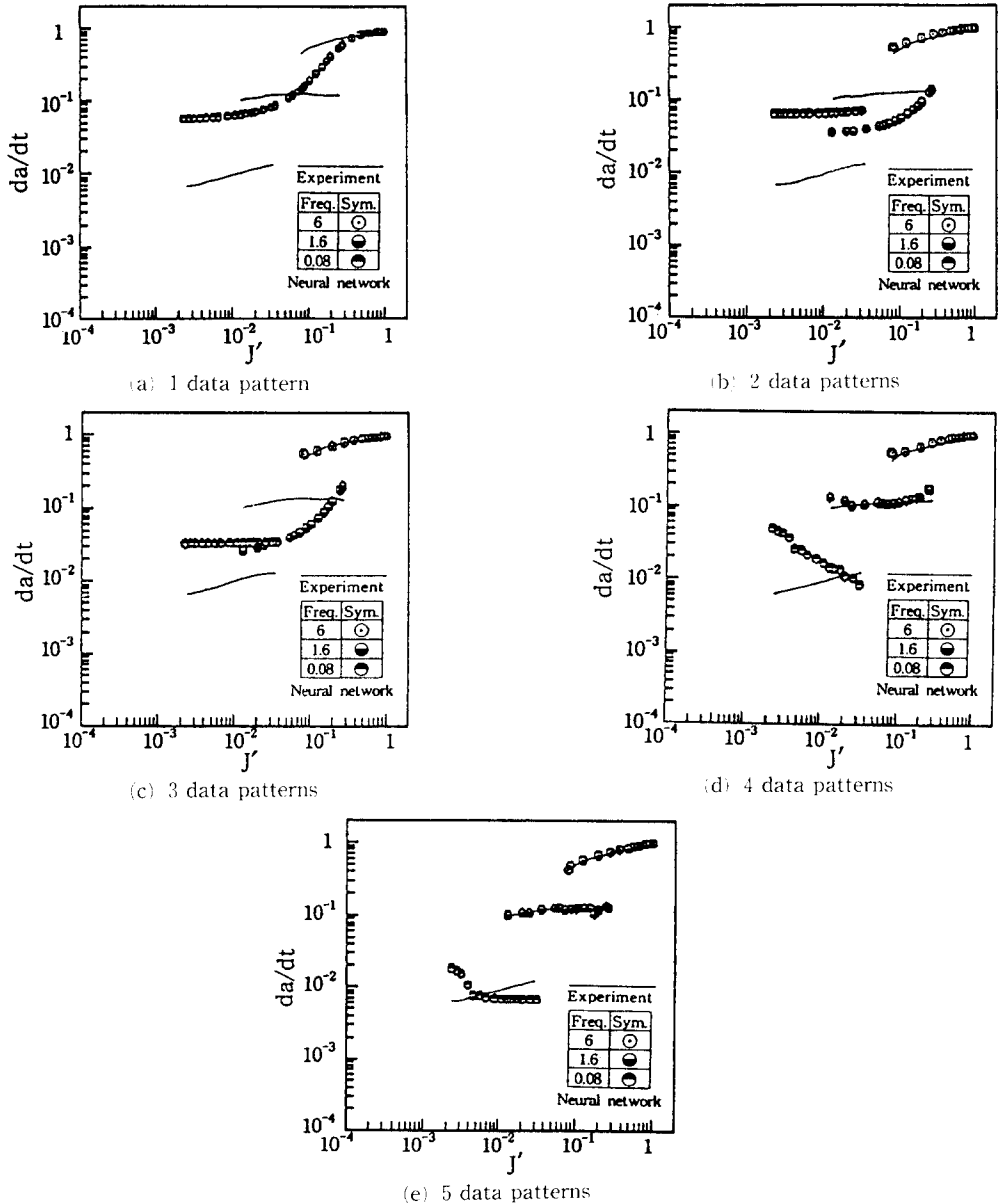


Fig. 6 Crack growth modelling at specific learning pattern




Fig. 7 Relation between estimated mean error and learning pattern




Fig. 9 da/dt - J' relation learned by neural network




Fig. 8 Two point representation scheme and architecture of neural network in crack growth modelling

평가하기 위하여 특정 데이터 패턴에 따른 신경회로망의 구조와 모델링 결과 및 추정평균오차를 Figs. 5, 6, 7에 각각 나타내었다. 데이터 패턴 수가 증가할 수록 각각의 실험조건에 따른 패턴이 잘 분류되고 있고, 이에 따른 추정평균오차가 현저히 감소하고 있다. 이러한 결과는 본 실험의 균열성장영역이 크리프-피로 상호작용하에 있어 크리프와 피로에 관한 각각의 균열성장 지배파라미터가 필요하기 때문에, 신경회로망의 학습에서도 단일 J' 적분값

을 이용한 신경회로망으로 균열성장거동을 모델링하는 것 보다는 피로와 크리프 균열성장 지배파라미터를 다 함께 포함하는 신경회로망으로 모델링하는 것이 훨씬 더 학습효과가 크다는 것을 나타내고 있다. 그러나 이러한 데이터 패턴으로 학습할 경우 추정평균오차가 0.1로서 한계 추정평균오차 범위 0.05를 벗어나고 있으며 특히 0.08 Hz의 실험조건은 균열성장곡선 경로를 잘 따라가지 못하고 있어 추정평균오차의 대부분을 차지하고 있다. 따라서 이러한 경로 의존성을 극복하기 위하여, 균열성장곡선의 기울기를 나타내는 J' 적분증분과 이에 대응하는 균열성장속도증분을 신경회로망의 학습데이터로 채용하였으며 Figs. 8, 9에 이러한 데이터 패턴과 신경회로망 구조 및 학습된 출력값과 목표값을 각각 나타내었다. 앞의 데이터 패턴에 비하여 추정평균오차 범위가 현저히 줄어들어 균열성장곡선 경로를 잘 따라가고 있다. 이러한 결과는 고온 저사이클 피로균열성장과 같이 비선형거동을 강하게 보이는 경우, 곡선상의 한점만으로 이러한 거동을 표현하기 어렵다는 것을 나타낸다. 즉, 신경회로망이 이러한 거동을 정확히 나타내기 위해서는 더 많은 종류의 데이터를 필요로 하며 이에 대한 대책으로 균열성장곡선상의 한 점과 그 다음 점에 관한 데이터를 표현하기 위한 두 점사이의 기울기가 신경회로망 학습에 유효함을 알 수 있다.

3.3 신경회로망의 학습에 미치는 데이터 크기의 영향

신경회로망으로 균열성장거동을 표현하기 위한

데이터 패턴의 크기를 최적화시킬 수 있다면 모델링에 필요한 시간적, 경제적 손실을 충분히 줄일 수 있을 것이다. 따라서 본 논문에서는 학습데이터

의 크기를 점진적으로 증가시키는 점증학습방식을 이용하여 최적 학습데이터의 크기를 결정하고자 한다.


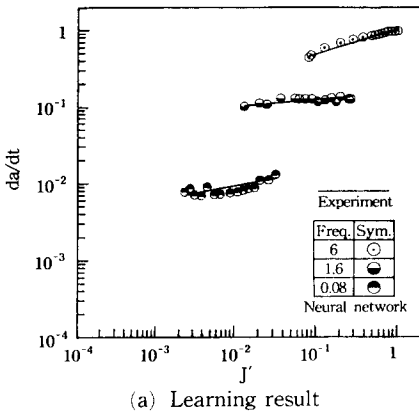
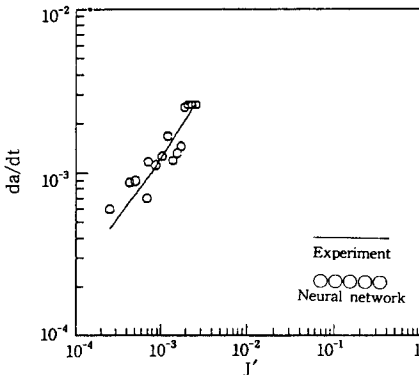


Fig. 10 Relation between estimated mean error and number of learning data



(a) Learning result



(b) Prediction result

Fig. 11 da/dt - J' relation learned and predicted by neural network on fatigue crack growth with various frequencies

최적 학습데이터의 크기를 결정하기 위한 학습데이터의 갯수는 3.4절의 균열성장거동을 예측하기 위한 학습데이터인 $\nu=0.008$ Hz의 실험조건을 제외한 나머지 실험조건에 대한 45개이다. 첫번째 신경회로망을 학습시킬 때의 데이터는 $\nu=6, 1.6, 0.08$ Hz의 각 실험조건중에서 하나씩 선택하므로써 3개가 되고 나머지 42개는 신경회로망이 미지의 실험조건에 얼마나 잘 적응하는가를 평가하기 위한 학습시키지 않은 일반화 데이터이다. 두번째 이후의 신경회로망을 학습할 때는 그 이전의 신경회로망에 이용하였던 데이터 갯수를 근거로 3개씩 점진적으로 증가시키고 일반화에 이용되었던 데이터 갯수는 역으로 3개씩 감소시켰다. 따라서 이전의 일반화에 사용한 데이터는 그 다음 단계의 학습 데이터로 첨가되었다. Fig. 10은 신경회로망의 학습에 이용했던 데이터 갯수와 30만회 학습을 수행하여 일반화시킨 데이터 출력값의 추정평균오차 및 학습시간을 동시에 나타내고 있다. 학습데이터가 증가함에 따라 일반화의 추정평균오차가 감소하고 있으나 15개 이상의 데이터를 기준으로 더 이상 학습이 개선되지 않았다. 즉, 과도한 학습데이터의 크기는 일반화의 추정평균오차를 증가시키고 동시에 학습시간을 비선형적으로 증가시키고 있다. 따라서 과도한 학습데이터가 신경회로망에 주어질 때 학습에 상당한 시간이 걸린다는 것과 각각의 신경회로망 구조에 적합한 학습 데이터의 크기가 존재함을 알 수 있다.

3.4 신경회로망에 의한 균열성장속도의 예측

균열성장 모델링은 신경회로망에 실험데이터를 대입하여 그것을 자기 조직화시키거나 그것의 결합계수를 수정하여 J' 적분값과 그 증분으로 균열성장속도와 그 증분값을 예측하고자 하는 것이다.⁽⁹⁾ 먼저 학습할 실험데이터를 신경회로망에 대입하여 반복학습회수가 30만회에 도달한 결과를 도식화한 것이 Fig. 11의 (a)이다. 그림에서 실선은 각 실험조건에 실제 균열성장속도를, 기호는 신경회로망에 의하여 예측된 균열성장거동을 나타낸 것이다. 실제 균열성장거동이 비선형거동을 보이고 있음에도 불구하고 신경회로망에 의하여 잘 수렴되고 있음을 알 수 있다. 이와 같이 신경회로망은 입력층 데이

터에서 출력층 데이터로의 맵핑에 의하여 학습이 이루어지고 가장 최적화된 신경회로망의 결합계수 행렬에 $\nu=0.008$ Hz의 실험데이터를 열벡터(column vector)의 형태로 대입하여 계산하면 신경회로망에 의하여 균열성장속도를 예측할 수 있을 것이다. Fig. 11의 (b)는 신경회로망에 의한 상술의 예측결과를 나타낸 것이다. 균열성장곡선에서 신경회로망이 J적분값에 의하여 학습되지 않았음에도 불구하고, 추정평균오차가 0.05이고 이러한 오차는 한계 오차 범위 5%이내에 포함되어 있으므로 충분한 신뢰성을 가지고 있음을 알 수 있다.

4. 결 론

고온용 부재의 안전성 평가를 위하여 균열성장거동에 관한 파괴역학적 평가는 대단히 중요하나 각 실험조건의 전반적 영역에 걸쳐 잘 들어 맞는 균열성장모델의 적절한 파괴역학적인 파라미터는 현존하지 않는다. 따라서 본 논문에서는 이러한 균열성장속도를 일관성있게 평가하기 위한 방법으로써 인지 과학적 접근방법중의 하나인 신경회로망을 이용한 균열성장 모델링을 수행하여 다음과 같은 결론을 얻었다.

- (1) 균열성장에 관한 데이터 패턴수가 많아질수록 패턴 분리가 잘 일어나며, 한점 표현방식보다는 균열성장곡선의 기울기를 이용하는 두 점 표현방식이 훨씬 더 정확하게 균열성장모델링을 하고 있다.
- (2) 균열성장모델링에 쓰이는 학습데이터 갯수는 최적의 크기가 존재하고 있으며 과도한 학습데이터 크기는 추정평균오차와 학습시간을 동시에 증가시켰다.
- (3) 학습된 신경회로망을 이용하여 균열성장속도를 예측한 결과, 미학습데이터에 대한 모델링이 추정평균오차 범위내에서 정확하게 수행되므로 신경

회로망이 균열성장 모델링에 유용한 것으로 평가된다.

참고문헌

- (1) 日本材料學會, 1988, "金屬疲勞の研究の歴史," 疲勞部門委員會, pp. 61~78.
- (2) Paris, P. C. and Erdogan, F., 1963, *Trans. ASME, Ser., D*, 85, p. 529.
- (3) 中澤一, 本間寛臣, 1982, "金屬の疲勞強度," 養賢堂, 東京, pp. 98~126.
- (4) 大路, 小倉, 久保外 2名, 1984, "SUS304鋼を用いたクリ-フ疲勞相互作用下のき裂傳ば實驗," 材料, 第31卷, 第36號, pp. 145~151.
- (5) Kuntimaddi Sadanada and Paul Shahinian, 1980, "Elastic-Plastic Fracture Mechanics for High Temperature Fatigue Crack Growth," *ASTM STP 700*, pp. 152~163.
- (6) Laurene Fausett, 1994, *Fundamentals of Neural Networks*, Prentice Hall, inc., London, pp. 3~5.
- (7) 김대수, 1989, "Neural Networks"-Theory and Application," 하이테크 정보, 서울, pp. 97~144.
- (8) 손승우, 1994, "SUS304강을 이용한 고온 저사이클 피로균열성장거동에 관한 연구," 석사학위논문, 동아대학교, 부산, pp. 24~29.
- (9) Mehrotra, K., Kohan, G. K. and Ranka, S., 1991, "Bounds on the Number of Samples Needed for Neural Network," *IEEE Transaction on Neural Networks* 2(6), pp. 548~558.
- (10) Philip D. Wasserman, 1989, *Neural Computing*, Van Nostrand Reinhold, New York, pp. 53~54.