

역전파신경망을 이용한 구멍뚫기법의 편심 오차 예측

김 철[†] · 양원호^{*} · 허성필^{**} · 정기현^{***}
(2001년 3월 26일 접수, 2002년 1월 2일 심사완료)

Prediction for the Error due to Hole Eccentricity in Hole-drilling Method Using Backpropagation Neural Network

Cheol Kim, Won-Ho Yang, Sung-Pil Heo and Ki-Hyun Chung

Key Words: Hole-drilling Method(구멍뚫기법), Hole Eccentricity(구멍편심), Residual Stress(잔류응력), Backpropagation Neural Network(역전파신경망), Finite Element Analysis(유한요소해석)

Abstract

The measurement of residual stresses by the hole-drilling method has been commonly used to evaluate residual stresses in structural members. In this method, eccentricity can usually occur between the hole center and rosette gage center. In this study, the error due to the hole eccentricity is predicted using the artificial neural network. The neural network has trained training examples of stress ratio, normalized eccentricity, off-centered direction and stress error using backpropagation learning process. The prediction results of the error using the trained neural network are good agreement with FE analyzed ones.

1. 서 론

잔류응력이란 기계구조물이나 재료가 주위 환경과 열적 평형상태에 있으면서 외부 하중에 관계없이 내재하는 감금된 응력(locked-in stress)을 말한다. 이러한 잔류응력의 측정법에는 X-선 회절법, 초음파법, 절단법, 구멍뚫기법 등이 있는데, 원리가 비교적 간단하면서 정확하게 측정할 수 있는 구멍뚫기법이 널리 사용되고 있다. 구멍뚫기법(hole-drilling method; HDM)은 잔류응력이 존재하는 금속표면에 작은 구멍을 뚫어 이때 이완되는 응력을 스트레인게이지로 측정하는 방법이다. 이 방법은 1934년 Mathar⁽¹⁾가 처음으로 제안

하였으며, 이후 Soete⁽²⁾에 의해 3개의 로제트 스트레인 게이지를 사용하는 방법이 제안되었다. 현재 이 방법은 ASTM E837-92⁽³⁾에 그 적용범위, 절차, 조건, 잔류응력 계산법 등에 대하여 규정되어 있으며, 이 시험규격에 따라 측정하였을 때 측정치의 오차는 $\pm 10\%$ 이내라고 설명하고 있다. 구멍뚫기법을 이용하여 잔류응력을 측정하기 위해서는 정확한 구멍뚫기 작업이 필요한데 이를 위하여 RS-200과 같은 드릴과 헌미경이 부착된 측정기구가 많이 사용된다. 그러나 ASTM에서 규정하고 있는 구멍의 최대 편심 허용값이 0.025mm로서 매우 작기 때문에 전용 측정기구를 이용하여도 규정된 편심 허용값을 만족하기는 쉽지 않으며, 실제로 편심 허용값을 어느 정도 초과하여도 무시하고 사용하는 경우도 있다. 따라서 구멍이 편심된 경우, 오차의 크기가 어느 정도인지 파악하는 것은 매우 중요하다.

구멍뚫기법에서 구멍 편심의 영향에 대한 지금 까지의 연구는 Ajovalasit⁽⁴⁾가 이론적인 방법으로 연구를 수행하였으며, Wang⁽⁵⁾은 수치해석 기법으로 이완상수를 수정하는 방법을 제시하였다. 또

[†] 책임저자, 회원, 성균관대학교 대학원 기계설계학과
E-mail : chlkim@nature.skku.ac.kr

TEL : (031)290-7496 FAX : (031)290-5849

* 회원, 성균관대학교 기계공학부

** 회원, 한국원자력연구소

*** 회원, 성균관대학교 대학원 기계설계학과

한, 저자 등⁽⁶⁾은 유한요소해석과 수치해석 기법을 이용하여 1축 잔류응력장의 경우에 구멍 편심오차의 예측과 오차 보정식을 제안한 바 있다. 그러나 지금까지의 연구에 있어서, 이론적인 방법의 연구들은 관통구멍(through hole)을 뚫은 경우인 Kirsch 해⁽⁷⁾를 기본으로 하여 유도된 식으로서 막힌구멍(blind hole)을 뚫을 경우에 대한 구멍편심의 영향에 대해서는 경계조건 설정 등의 어려움으로 인하여 아직까지 정확한 이론해를 제시하지 못하고 있다. 또한, 유한요소해석이나 수치해석적 방법의 연구들은 대부분 1축 잔류응력장의 경우로 문제를 단순화시켜서 연구를 수행하였다.

일반적인 2축 잔류응력장에서 구멍뚫기법을 적용할 경우 구멍이 편심되면 측정되는 잔류응력값에는 오차가 포함되는데, 이 오차의 크기는 응력비, 편심크기, 편심방향 등에 의해 결정되는 다변수 문제에 해당된다. 현재 이러한 다변수 문제의 결과 예측을 위한 다양한 알고리즘들이 개발되고 있으며, 특히 인공신경망(*artificial neural network*)을 이용한 결과 예측에 관한 연구가 활발히 수행되고 있다.^(8~10) 정확하면서 충분한 양의 학습 데이터를 확보할 수 있는 경우 인공신경망을 이용하면 임의의 입력 변수에 대한 결과를 효과적으로 예측할 수 있다.

따라서, 본 연구에서는 2축 잔류응력장 모델을 설정하고 유한요소해석을 통하여 구멍 편심에 따른 잔류응력 오차를 구한 후, 이를 인공신경망을 이용해 학습시킴으로써 임의의 2축 잔류응력장에서 구멍편심에 따른 오차의 크기를 예측하고자 한다.

2. 인공신경망의 구조와 학습 알고리듬

인공신경망⁽¹¹⁾은 인간의 두뇌구조 및 학습양식을 모방하여 컴퓨터에 적용한 모델로서 두뇌의 학습방식과 유사한 신경망학습(*neural network training*)을 통하여 기존의 데이터를 일반화하는 기능이 있다. Fig. 1은 인공신경망의 일반화 과정을 도식적으로 나타낸 것으로서 일반화를 하기 위해서는 먼저 문제에 대한 학습 데이터들(*training examples*)을 신경망의 입력패턴으로 제시하고 이들 입력패턴을 신경망에 반복적으로 학습시키면 신경망은 입력패턴에 맞게 학습된다. 학습이 성공적으로 완료되면 시험 예들(*testing examples*)을 학습된 신경

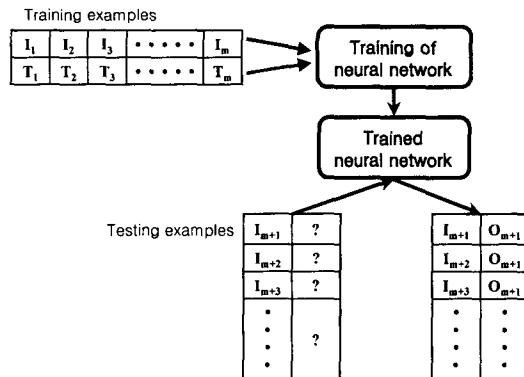


Fig. 1 Generalization procedure of neural network

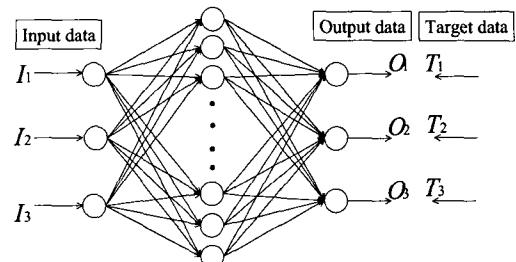


Fig. 2 Neural network model with one hidden layer

망에 대입하며, 신경망은 이들에 대한 적절한 예측 결과를 제시한다.

역전파 신경망(*backpropagation neural network*)은 Rumelhart 등⁽¹²⁾에 의해 제시된 신경망 모델로서 현재 가장 많이 사용되고 있는 학습모델 중 하나이다. 이 모델은 입력층(*input layer*), 은닉층(*hidden layer*) 및 출력층(*output layer*)으로 구성되어 있으며 필요에 따라 여러 개의 은닉층을 사용할 수 있으나 1개의 은닉층만으로도 충분하다고 알려져 있다. 각 층은 다수의 유닛들로 구성되어 있으며 각 층 사이의 유닛과 유닛들은 연결강도(*weight*)로 연결되어 있다. 역전파 신경망의 학습 알고리듬은 두 단계의 순서에 의하여 이루어진다고 볼 수 있다. 첫 번째 단계에서 입력을 네트워크에 제시하면 이것이 네트워크의 전방향으로 전파되어 출력을 내고, 이 출력과 목표값과의 차이에 미분계수를 곱하여 출력 유닛에 대한 오차를 계산한다. 두 번째 단계에서는 오차신호가 네트워크의 역방향으로 전파되어 이것을 바탕으로 연결강도를 수정한다. 이러한 네트워크를 도식적으로 나타낸 것이 Fig. 2이며, 식 (1)은 연결강도의 조절규칙을 수식으로 나타낸 것이다.

$$w_{jk}(\text{new}) = w_{jk}(\text{old}) + \alpha \delta_k z_j + \mu \Delta w_{jk}(\text{old}) \quad (1)$$

$$\text{여기서, } \delta_k = (T_k - O_k) f'(O_{\text{in}_k})$$

식 (1)에서 w_{jk} 는 j 번재 유닛에서 k 번재 유닛으로의 연결강도이며 Δw_{jk} 는 연결강도의 변화량이다. z_j 는 j 번재 은닉층 유닛의 출력이고 T_k , O_k 는 각각 k 번재 유닛의 목표값과 출력값이며 O_{in_k} 는 k 번재 출력층 유닛의 입력값이다. $f'(O_{\text{in}_k})$ 는 k 번재 유닛에서 활성함수(activation function)의 미분값으로서, 본 연구에서는 활성함수로 식 (2)와 같이 표현되는 시그모이드 함수(sigmoid function)를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

또한, 학습률(learning rate) α 는 신경망의 학습속도를 조절하며, 모멘텀 계수(momentum parameter) μ 는 신경망 학습이 지역최소점(local minimum)에 빠지는 것을 방지한다. 한편, 각 유닛에 대한 목표값과 출력값의 차이는 학습오차 $E(w)$ 로 정의되며 식 (3)과 같이 표현된다.

$$E(w) = \frac{1}{2} \sum_{k=1}^m (T_k - O_k)^2 \quad (3)$$

결과적으로 신경망의 학습은 식 (3)의 학습오차를 최소화하는 방향으로 연결강도를 조절하는 것으로서 이를 위하여 급강하 경사법(steepest gradient descent method)을 이용하며, 출력값이 목표값에 근사하게 되어 학습오차가 규정치 보다 작아지면 학습이 종료된다.

3. 구멍 편심에 대한 유한요소해석

3.1 해석모델 및 방법

실험적인 방법으로 오차를 해석하는데는 측정값 자체에 이미 오차가 포함될 수 있으므로 정확한 오차를 파악하는데 한계가 있다. 이러한 경우 유한요소법을 이용하면 알고 있는 응력장을 정확히 설정할 수 있으므로 오차를 해석하는데 효과적이다.

따라서, 본 연구에서는 Fig. 3과 같은 2축 응력상태에 있는 평판 중앙에 구멍뚫기법용 스트레인게이지를 부착한 경우에 대한 유한요소해석 모델을 설정하였다. 스트레인게이지 부분의 형상은 현재 널리 사용되고 있는 Micro Measurement사의

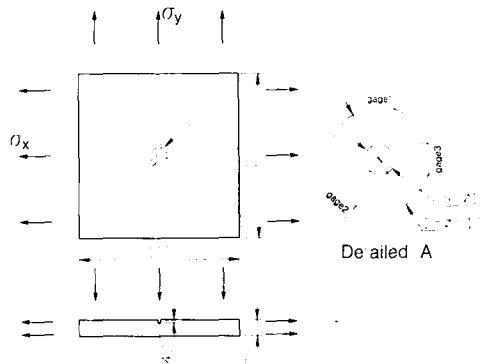


Fig. 3 Model configuration

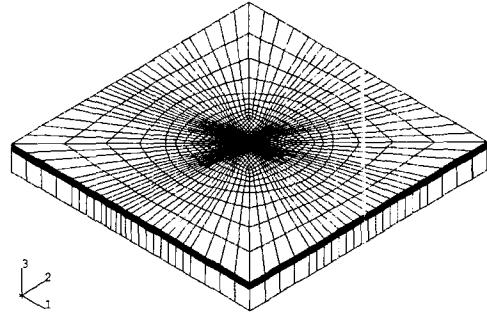
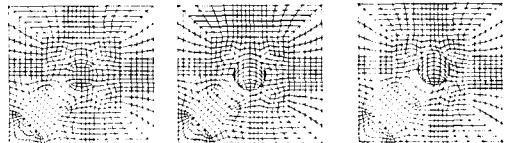


Fig. 4 3-Dimensional finite element model



(a) Before drilling (b) Centered drilling (c) Off-centered drilling

Fig. 5 Strain gage and hole part

TEA-XX-062RK-120 모델을 기준으로 설정하여, 구멍직경 d 는 $\phi 1.57\text{mm}$, 스트레인게이지 직경 D 는 $\phi 5.13\text{mm}$ 로 하였다. 유한요소망은 실제 측정모델과 일치시키기 위하여 3차원으로 구성하였으며, 총 7개의 층으로 나누어서 깊이 방향으로 구멍부 요소를 제거해 갈 수 있도록 하였다. 재료 물성치로 탄성계수 E 는 205GPa , 푸아송 비 ν 는 0.3을 적용하였다.

Fig. 4는 본 연구에 사용된 유한요소망을 나타낸 것이다, Fig. 5는 구멍을 뚫기 전과 수직 구멍뚫기 및 편심 구멍뚫기를 한 경우의 스트레인게이지 부분을 나타낸 것이다. 특히, 1개의 스트레인게이지를 48개 요소로 구성하여 이를 요소에서의 평균 변형률을 계산하여 각 스트레인게이지

Table 1 Verification result for FE model

Applied residual stress (MPa)		HDM analysis result (MPa, deg)			Stress error (%)
σ_x	σ_y	σ_1	σ_2	β	
100	0	99.95	0.0	0.07	0.05
100	100	99.43	99.43	0.01	0.57
100	-100	100.09	-100.04	0.01	0.09

위치의 변형률로 하였다. 요소로는 8절점 솔리드 요소(solid element)를 14210개 적용하였고 절점 수는 16648개이다. 본 연구에 사용한 프로그램으로는 상용 유한요소해석 프로그램인 ABAQUS를 사용하였다.

이와 같은 모델을 이용하여 신경망 학습 데이터를 구하기 위한 구멍 편심오차를 해석하였는데, 응력비 σ_y/σ_x 는 -5에서 5까지 10단계로, 편심크기 e 는 ASTM 편심 허용치인 0.025mm부터 구멍 반지름 r 의 약 0.5배인 0.375mm까지 4단계로 나누었으며, 편심방향은 1번 스트레인게이지에서 시계방향으로 30°씩 12단계로 나누어서 해석을 수행하여 총 480개의 신경망 학습 데이터를 구하였다.

3.2 해석모델 검증

본 연구에서는 구멍뚫기법에 대한 유한요소해석의 타당성을 검증하기 위하여 먼저 구멍이 편심되지 않은 경우에 대한 해석을 수행하였다. 각 스트레인게이지 위치에서의 평균 변형률을 구멍을 뚫기 전후에 각각 계산하여 그 변화량을 구하고, 식 (4)에 이 값들을 대입하여 주응력과 그 방향을 계산하였다. 식 (4)에서 이완상수(calibration coefficients) \bar{A} , \bar{B} 는 ASTM E 837에 제시된 방법으로 유한요소해석을 수행하여 구하였으며, \bar{A} 는 -3.0225×10^{-7} , \bar{B} 는 -6.5565×10^{-7} 으로 계산되었다.

$$\begin{aligned} \sigma_1, \sigma_2 &= \frac{\varepsilon_3 + \varepsilon_1}{4\bar{A}} \pm \frac{\sqrt{(\varepsilon_3 - \varepsilon_1)^2 + (\varepsilon_3 + \varepsilon_1 - 2\varepsilon_2)^2}}{4\bar{B}} \\ \beta &= \frac{1}{2} \tan^{-1} \left(\frac{\varepsilon_3 + \varepsilon_1 - 2\varepsilon_2}{\varepsilon_3 - \varepsilon_1} \right) \end{aligned} \quad (4)$$

구멍을 뚫기 전부터 응력을 가한 상태(잔류응력이 있는 상태로 가정)에서 구멍을 뚫었을 때의

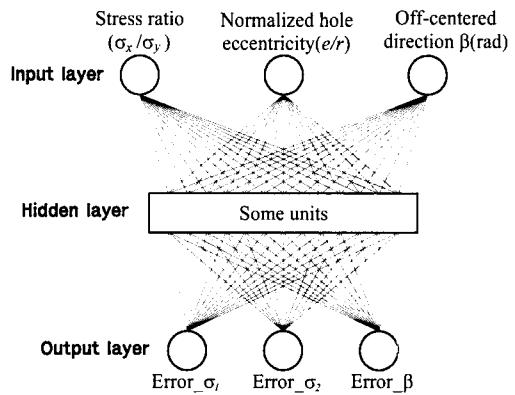


Fig. 6 Architecture of neural network for error prediction due to hole eccentricity in HDM

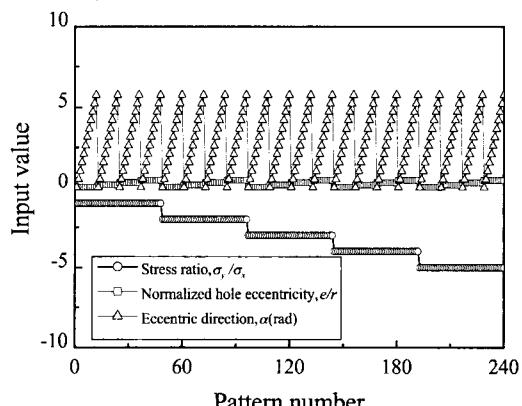


Fig. 7 Input value for minus stress ratio

이완변형률(relieved strain)을 구한 후, 주응력의 크기와 방향을 계산하여 가한 응력과 비교하였는데, Table 1은 임의의 세 가지 잔류응력장에서 이와 같은 구멍뚫기법의 해석 결과를 정리한 것이다. 표에서 설정한 잔류응력이 1% 이내로 잘 일치하는 바, 본 연구에서의 구멍뚫기법에 대한 유한요소해석 모델 및 방법의 타당성을 입증할 수 있다.

4. 신경망 학습

구멍뚫기법에서 구멍 편심에 따른 잔류응력 오차의 예측을 위한 신경망 모델을 Fig. 6과 같이 구성하였다. 입력층은 응력비(stress ratio, σ_y/σ_x), 무차원 편심크기(normalized hole eccentricity, e/r) 및 편심방향(eccentric direction, α)의 3개 유닛을

Table 2 Epoch number with momentum parameter in case of minus stress ratio

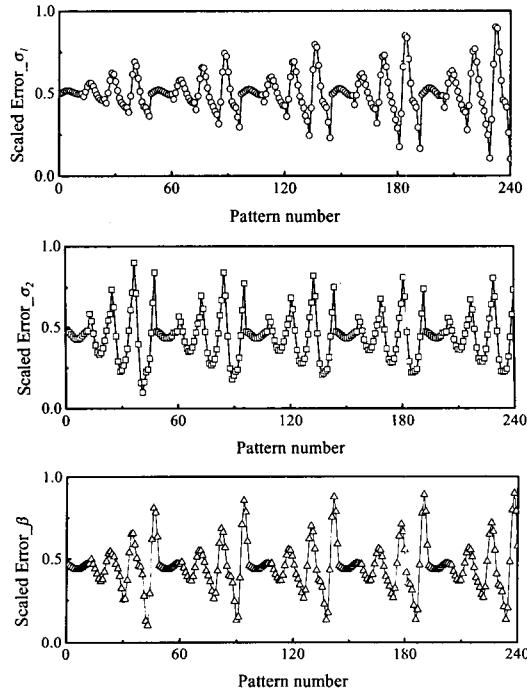
Momentum parameter	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Epoch number	53,037	40,963	53,271	37,571	25,777	27,146	22,482	17,662	18,855

Table 3 Epoch number with learning rate in case of minus stress ratio

Learning rate	0.05	0.1	0.15	0.2	0.25	0.3	0.35	0.4	0.5
Epoch number	30,630	17,662	10,520	6,810	12,186	7,681	45,010	74,694	100,000 (SSE=0.12)

Table 4 Epoch number with hidden unit in case of minus stress ratio

Hidden unit	10	20	30	40	50	60	70	80	90	100
Epoch number	100,000 (SSE=0.39)	6,810	3,389	3,670	4,107	2,080	1,896	1,450	1,755	1,771

**Fig. 8** Scaled target value for minus stress ratio

사용하였으며, 출력층은 식 (5)와 같이 계산되는 구멍 편심으로 인한 주응력 σ_1 과 σ_2 의 %오차와 주응력 방향 오차 $Error_\beta$ 의 3개 유닛을 사용하였다.

$$Error_{\sigma_i} = \frac{\sigma'_i - \sigma_i}{\sigma_i} \times 100 \quad (5)$$

여기서, $Error_{\sigma_i}$ 는 퍼센트 응력오차(% stress error, $i=1, 2$)이고, σ'_i 는 편심구멍일 때의 주응력이며

σ_i 는 편심되지 않았을 때(centered drilling)의 주응력이다.

이러한 신경망 모델을 이용한 신경망 학습은 응력비가 음수인 경우와 양수인 경우로 각각 나누어서 수행하였다.

4.1 응력비가 음수인 경우

4.1.1 신경망 학습 절차

응력비가 음수인 경우에 신경망 학습을 위한 패턴 수는 240개를 사용하였으며, Fig. 7에 학습 데이터의 입력값을 나타내었다. Fig. 8은 응력비가 음수인 경우의 목표값인 $Error_{\sigma_1}$, $Error_{\sigma_2}$ 및 $Error_\beta$ 를 시그모이드 함수의 선형 구간인 0.1~0.9로 각각 스케일링하여 나타낸 것이다.

본 연구에서는 저자 등이 FORTRAN90으로 작성한 모멘텀 역전파 신경망 프로그램을 이용하여 신경망 학습을 수행하였으며 세부적인 수행절차는 다음과 같다.

Step 1 : 학습률은 0.1, 은닉층 유닛은 20개, 최대 반복회수는 10만회로 고정하고 모멘텀 계수를 0.1에서 0.9까지 변화시키면서 식 (6)의 오차제곱합(sum squared error; SSE)이 0.1에 도달할 때까지 신경망 학습을 수행하였으며, 그 결과를 Table 2에 나타내었다.

$$SSE = \sum_{k=1}^m (T_k - O_k)^2 \quad (6)$$

Table 2에서 모멘텀 계수가 0.8일 때 가장 작은 반복회수에서 목표 오차에 도달한 것을 알 수 있다.

Table 5 Epoch number with momentum parameter in case of plus stress ratio

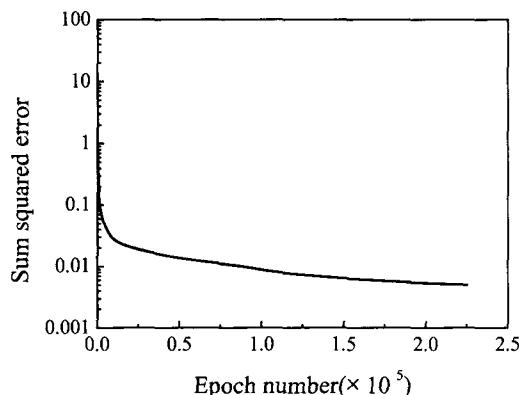
Momentum parameter	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
Epoch number	46,091	48,408	56,860	96,491	29,831	20,164	22,085	14,628	100,000 (SSE=0.55)

Table 6 Epoch number with learning rate in case of plus stress ratio

Learning rate	0.05	0.1	0.15	0.2	0.25	0.3	0.4
Epoch number	24,616	8,085	59,761	14,628	12,650	100,000 (SSE=0.55)	100,000 (SSE=0.72)

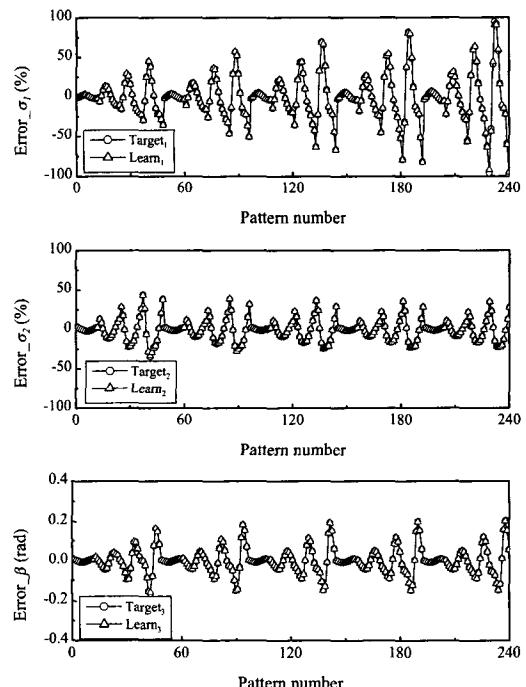
Table 7 Epoch number with hidden unit in case of plus stress ratio

Hidden unit	10	20	30	40	50	60	70	80	90	100
Epoch number	100,000 (SSE=0.84)	100,000 (SSE=0.42)	100,000 (SSE=0.12)	31,651	31,703	22,499	22,737	17,317	24,439	21,522

**Fig. 9** Sum squared error versus epoch number for minus stress ratio

Step 2 : Step 1에서 결정한 모멘텀 계수 0.8과 은닉층 유닛은 20개, 최대 반복회수는 10만회로 고정하고 학습률을 0.05에서 0.5까지 변화시키면서 오차제곱합이 0.1에 도달할 때까지 신경망 학습을 수행하였으며, 그 결과를 Table 3에 나타내었다. Table 3에서 학습률이 0.5 이상이 되면 10만회의 반복회수에도 목표 오차에 도달하지 못하므로 이에 대한 학습은 생략하였다. 한편, 표에서 오차제곱합(SSE)은 10만회의 반복회수에서의 오차의 크기를 나타낸 것이다. Table 3에서 학습률이 0.2일 때 가장 작은 반복회수에서 목표 오차에 도달하였다.

Step 3 : Step 1과 Step 2에서 결정한 모멘텀 계수와 학습률을 각각 0.8과 0.2로 고정하고, 최대 반복회수는 10만회로 설정한 후 은닉층 유닛 개

**Fig. 10** Comparison network output value with target one for minus stress ratio

수를 10부터 100까지 변화시키면서 신경망 학습을 수행하여 그 결과를 Table 4에 나타내었다. Table 4에서 은닉층 유닛이 80개일 때 가장 작은 반복회수에서 목표 오차 0.1에 도달하였음을 알 수 있다.

이와 같은 세 단계를 거쳐서 모멘텀 계수 0.8, 학습률 0.2, 은닉층 유닛 80개로 신경망 학습조건

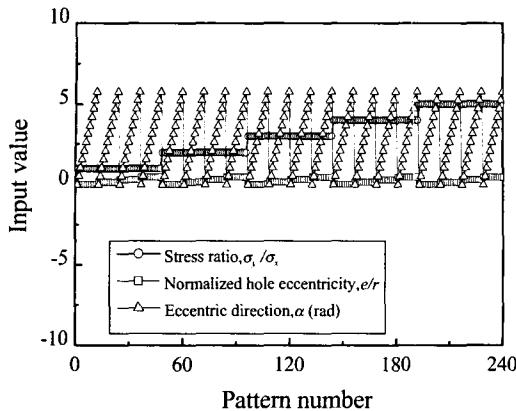


Fig. 11 Input value for plus stress ratio

을 결정하였다.

4.1.2 신경망 학습 결과

본 연구에서는 신경망의 일반화 능력을 목표값과 출력값의 오차제곱합을 기초로 하여 평가하였다. 이에 따라 최종 신경망 학습은 앞에서 결정한 신경망 학습조건을 적용하여 오차제곱합이 0.005에 도달할 때까지 학습을 수행하였다. 여기서 오차제곱합의 기준치 0.005는 스케일링한 목표값과 출력값의 차가 충분히 작을 때, 즉 식(7)을 만족할 때의 전체 학습 데이터에 대한 오차제곱합으로서 이 조건을 만족하면 학습이 잘 수행된 것으로 가정하고 오차의 한계로 결정하였다.

$$|\text{scaled } T_k - \text{scaled } O_k| \approx 0.005 \quad (7)$$

Fig. 9는 학습회수에 따른 오차제곱합을 나타낸 것으로서 약 23만회의 반복학습 후 목표 오차인 0.005에 도달하였다.

신경망 학습의 성공여부는 신경망 출력층에서 각 유닛의 출력값과 목표값의 차이를 비교하여 판단할 수 있다. Fig. 10은 신경망 출력값을 목표값과 같이 나타낸 것으로서 세 개의 출력값이 모두 목표값과 잘 일치하고 있는 바, 신경망 학습이 성공적으로 이루어졌음을 알 수 있다.

4.2 응력비가 양수인 경우

응력비가 양수인 경우에 있어서도 응력비가 음수인 경우와 동일한 방법으로 신경망 학습을 수행하였다. 입력 패턴은 240개를 사용하였으며, 학습 데이터의 입력값과 0.1~0.9로 스케일링한 목표값을 Fig. 11과 Fig. 12에 각각 나타내었다.

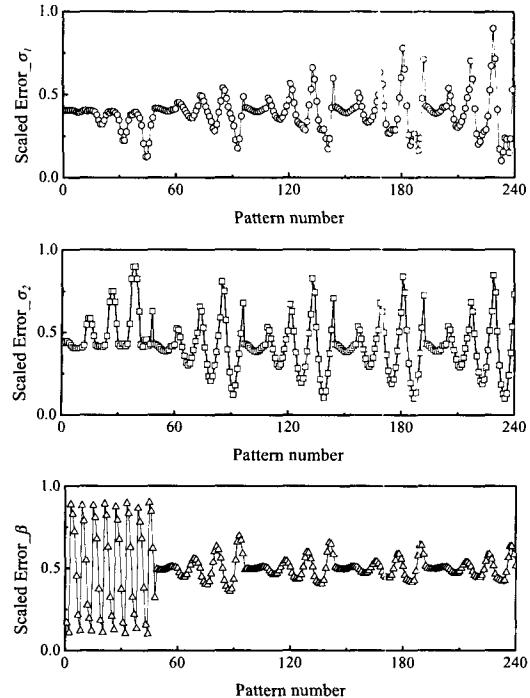


Fig. 12 Scaled target value for plus stress ratio

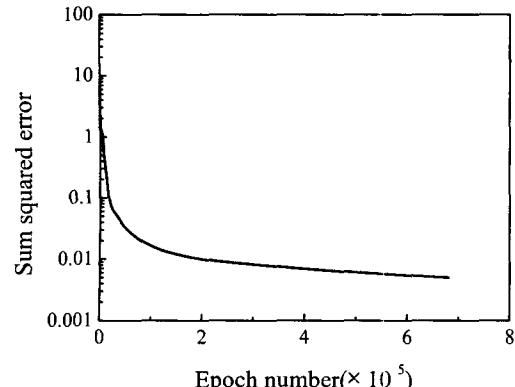


Fig. 13 Sum squared error versus epoch number for plus stress ratio

신경망 학습조건은 응력비가 음수인 경우와 동일한 방법으로 세 단계를 거쳐서 결정하였다. 한편, 응력비가 음수인 경우에 비하여 상대적으로 학습 속도가 늦어 모멘텀 계수와 학습률을 결정하는 단계에서는 목표 오차를 0.5로 하였으며, 은닉층 유닛 개수를 결정할 때는 목표 오차를 0.1로 설정하여 신경망 학습조건을 구하였다. Tables 5~7에 각각의 조건에 따른 학습결과를 정리하였다.

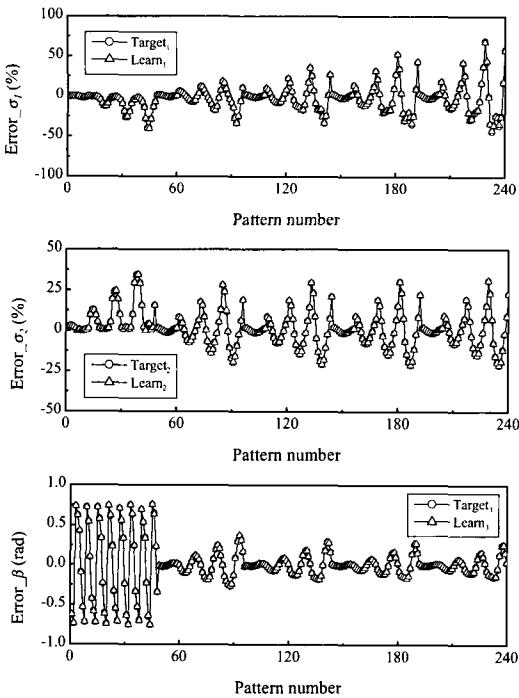


Fig. 14 Comparison network output value with target one for plus stress ratio

으며 이로부터 응력비가 양수인 경우에는 모멘트 계수 0.8, 학습률 0.1, 은닉층 유닛 80개로 신경망 학습조건을 결정하였다.

최종 신경망 학습은 오차제곱합이 0.005에 도달할 때까지 수행하였는데, 약 68만회의 반복학습 후에 목표 오차에 도달하였으며, 이때의 반복 회수에 따른 오차제곱합을 Fig. 13에 나타내었다. Fig. 14는 응력비가 양수인 경우의 신경망 출력값을 목표값과 같이 나타낸 것으로서 세 개의 출력값 모두 목표값과 잘 일치하였다.

5. 구멍 편심오차 예측

인공신경망에서는 신경망 학습이 성공적으로 완료된 후 임의의 입력값을 학습된 신경망에 대입하면 신경망은 이에 대한 적절한 예측 결과를 제시한다. 본 연구에서는 학습된 신경망에 임의의 응력비, 편심크기 및 편심방향에 대한 입력값을 제시하여 이때의 오차의 크기를 예측하였다.

Tables 8~9는 유한요소해석으로 구한 오차와 신경망으로 예측한 오차 결과를 비교하여 나타낸 것으로 응력비가 음수인 경우를 Table 8에, 응력

Table 8 Predicted results for minus stress ratio

(a) Case 1

Input value	Output value (error due to off-center)		
		FE analysis	Neural network
Stress ratio (σ_y / σ_x)	-5.83	σ_1 (%)	31.76
Normalized hole eccentricity(e/r)	0.191	σ_2 (%)	-1.42
Off-centered direction(rad)	1.396	β (rad)	-0.0408

(b) Case 2

Input value	Output value (error due to off-center)		
		FE analysis	Neural network
Stress ratio (σ_y / σ_x)	-1.4	σ_1 (%)	11.89
Normalized hole eccentricity(e/r)	0.2548	σ_2 (%)	-16.23
Off-centered direction(rad)	2.793	β (rad)	-0.0706

Table 9 Predicted results for plus stress ratio

(a) Case 1

Input value	Output value (error due to off-center)		
		FE analysis	Neural network
Stress ratio (σ_y / σ_x)	1.5	σ_1 (%)	7.86
Normalized hole eccentricity(e/r)	0.3185	σ_2 (%)	13.97
Off-centered direction(rad)	0.785	β (rad)	-0.268

(b) Case 2

Input value	Output value (error due to off-center)		
		FE analysis	Neural network
Stress ratio (σ_y / σ_x)	6.0	σ_1 (%)	-38.63
Normalized hole eccentricity(e/r)	0.3312	σ_2 (%)	-13.21
Off-centered direction(rad)	2.356	β (rad)	-0.0987

비가 양수인 경우를 Table 9에 정리하였다. 각각 두 가지씩의 임의의 입력값에 대한 신경망 예측값과 유한요소해석 결과를 비교하였는데, 1개 네이터에서 상대 오차가 공학적 오차범위를 초과하였으나 절대 오차의 측면에서는 충분히 작은 값인 바, 신경망 예측값은 유한요소해석 결과와 전반적으로 일치하는 결과를 얻었다.

따라서, 본 연구에서 학습된 신경망을 이용하면 별도의 유한요소해석 등의 과정을 수행하지 않아도 구멍 편심에 따른 오차의 크기를 효과적으로 예측할 수 있을 것으로 판단된다.

6. 결 론

본 연구에서는 구멍뚫기법으로 잔류응력을 측정할 경우 구멍 편심에 따른 측정오차를 예측하기 위하여 응력비, 편심크기 및 편심방향에 따른 잔류응력 오차를 유한요소해석을 이용하여 구하고, 인공신경망 학습을 통해 일반화하였다.

응력비가 음수인 경우와 양수인 경우로 나누어서 각각의 신경망 학습조건을 결정하여 최종 신경망 학습을 수행하였으며, 신경망 학습 후 출력값은 목표값과 잘 일치하였다. 학습된 신경망을 이용하여 임의의 응력장, 편심크기 및 편심방향에 따른 잔류응력의 오차를 예측한 결과 유한요소해석 결과와 전반적으로 잘 일치한 바, 본 연구결과를 이용하여 효과적으로 구멍뚫기법에서의 편심 오차를 예측할 수 있다.

참고문헌

- (1) Mathar, J., 1934, "Determination of Initial Stresses by Measuring the Deformation Around Drilled Holes," *Trans. ASME, Iron & Steel*, Vol 56, pp. 249~254.
- (2) Soete, W., Vancrombrugge, R., 1950, "An Industrial Method for the Determination of Residual Stresses," *Proceedings of the Society for Experimental Stress Analysis*, Vol VIII, No. 1, pp. 17~28.
- (3) "Standard Test Method for Determining Residual Stresses by the Hole-Drilling Strain-Gage Method," 1992, ASTM E 837-92.
- (4) Ajovalasit, A., 1979, "Measurement of Residual Stresses by the Hole-drilling Method : Influence of Hole Eccentricity," *Journal of Strain Analysis*, Vol. 14, No. 4, pp. 171~178.
- (5) Wang Jia-Yong, 1990, "Refined Analysis of the Relieved Strain Coefficients for the Off-center Hole-drilling Case," *Experimental Mechanics*, pp. 367~371.
- (6) 김 철, 석창성, 양원호, 2000, "구멍뚫기법을 이용한 잔류응력 측정시 구멍 편심의 영향," *대한기계학회논문집(A)*, 제24권, 제3호, pp. 2059~2064.
- (7) Kobayasi, A. S., 1993, *Handbook on Experimental Mechanics*, 2nd ed, SEM, pp. 785~790.
- (8) 주원식, 조석수, 1996, "신경회로망을 이용한 고온 저사이클 피로균열성장 모델링에 관한 연구," *대한기계학회논문집(A)*, 제20권, 제9호, pp. 2752~2759.
- (9) 조석수, 주원식, 2000, "역전파신경회로망을 이용한 피로균열성장과 수명 모델링에 관한 연구," *대한기계학회논문집(A)*, 제24권, 제3호, pp. 634~644.
- (10) Inamdar, M. V., Data, P. P. and Desai, U. B., 2000, "Studies on the Prediction of Springback in Air Vee Bending of Metallic Sheets Using an Artificial Neural Network", *Journal of Materials Processing Technology*, Vol. 108, pp. 45~54.
- (11) Fausett, L., 1994, *Fundamentals of Neural Network : Architectures, Algorithms and Applications*, Prentice Hall, pp. 3~37.
- (12) Rumelhart, D. E., Hinton, G. E., Williams, R. J., 1986, "Learning Internal Representations by Error Propagation : in Parallel Distributed Processing," The MIT Press, Vol. 1, pp. 675~695.