

신경망 기법을 이용한 구멍뚫기법에서의 구멍 편심오차 보정

김 철* · 양원호** · 조명래*** · 허성필****

Correction of Error due to Hole Eccentricity in Hole-drilling Method Using Neural Network

Cheol Kim, Won-Ho Yang, Myoung-Rae Cho and Sung-Pil Heo

Key Words : Hole-drilling Method(구멍뚫기법), Hole Eccentricity(구멍편심), Residual Stress(잔류응력), Neural Network(신경망), 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 corrected using the neural network. The neural network has trained training examples of normalized eccentricity, eccentric direction and direction of maximum stress at eccentric case using backpropagation learning process. The trained neural network could corrected the error of measured residual stress in experiments with hole eccentricity. The proposed neural network is very useful for correction of the error due to hole eccentricity in hole-drilling method.

1. 서론

잔류응력의 측정법은 크게 파괴적인 방법, 비파괴적인 방법 그리고 준 비파괴적인 방법의 3가지로 나눌 수 있다. 절단법으로 대표되는 파괴적인 방법은 측정 대상을 파괴시켜서 측정하기 때문에 효율적이지 못하며 경우에 따라서는 측정이 불가능할 때도 있다. 비파괴적인 방법에는 X선 회절법, 초음파법, 자기장법 등이 있는데, 비파괴적으로 측정할 수 있다는 장점이 있는 반면, 정확한 측정이 어려우며 측정장비가 고가라는 단점이 있다. 이들 방법에 비하여 준 비파괴적인 방법인 구멍뚫기법(hole-drilling method; HDM)은 측

정 대상에 최소의 손상을 일으키는 것만으로 측정이 가능하며 측정품의 크기나 기하학적 형상에 거의 제한 받지 않는다. 또한 지금까지 알려진 여러 가지 잔류응력 측정법 중 원리와 측정 과정이 간단하면서도 비교적 정확하게 측정할 수 있는 장점이 있다.

구멍뚫기법은 잔류응력이 존재하는 금속 표면에 작은 구멍을 뚫어 이때 구멍 주위에서 이완되는 응력을 스트레인 게이지로 측정하는 방법으로서 1934년 Mathar⁽¹⁾가 처음으로 제안하였으며, 이후 Soete⁽²⁾에 의해 3개의 로제트 스트레인 게이지를 사용하는 방법이 제안되었다. 현재 이 방법은 ASTM E 837⁽³⁾에 그 적용범위, 절차, 조건, 잔류응력 계산법 등에 대하여 규정되어 있으며, 이 시험규격에 따라 측정하였을 때 측정치의 오차는 $\pm 10\%$ 이내라고 설명하고 있다.

구멍뚫기법에서는 구멍의 위치에 따라 이완되는 응력의 차이가 발생하기 때문에 정확한 구멍뚫기 작업을 위하여 Micro Measurements사의 RS200 밀링 가이드와 같은 드릴과 현미경이 부착된 측정기구를 많이 사용한다. 그러나 ASTM에

* 회원, 성균관대학교 대학원

** 회원, 성균관대학교 기계공학부

*** 회원, 인덕대학 컴퓨터응용기계계열

**** 회원, 성균관대학교 대학원

서 규정하고 있는 구멍의 최대 편심 허용치가 0.025mm로서 매우 작기 때문에 전용 측정기구를 이용하여도 규정된 편심 허용치를 만족하기는 쉽지 않다. 따라서 구멍이 편심된 경우 오차를 보정해 줄 수 있는 방법이 요구된다. 더우기 구멍 뚫기법의 특성상 동일 위치에서 다시 측정하는 것은 불가능하기 때문에 구멍이 편심 허용치를 상당히 벗어났더라도 측정치를 보정해서 사용할 수 있는 방법이 필요하다.

구멍뚫기법에서 구멍 편심의 영향에 대한 연구로 Ajovalast⁽⁴⁾가 이론적인 방법으로 연구를 수행하였으며, Wang⁽⁵⁾은 수치해석 기법으로 이완상수를 수정하는 방법을 제시한 바 있다. 그러나 지금까지의 연구들은 대부분 관통구멍(through hole)을 뚫은 경우인 Kirsch 해⁽⁶⁾를 기본으로 하여 유도된 식으로서 막힌 구멍(blind hole)을 뚫을 경우에 대한 구멍 편심의 영향에 대해서는 경계조건 등의 어려움으로 인하여 아직까지 정확한 이론해를 제시하지 못하고 있다.

따라서, 본 연구에서는 1축 잔류응력장 모델을 설정하고 유한요소해석을 통하여 구멍 편심에 따른 오차의 크기를 구하였으며, 역전파 신경망 알고리즘을 이용하여 구멍의 편심 크기 및 방향에 따른 오차 보정 방법을 제시하였다. 또한 구멍뚫기법의 실험을 통하여 제시한 오차 보정 방법의 효용성을 검토하였다.

2. 신경망 학습 알고리즘

인공신경망⁽⁷⁾은 인간의 두뇌구조 및 학습양식을 모방하여 컴퓨터에 적용한 모델로서 두뇌의 학습 방식과 유사한 신경망 학습(neural network training)을 통하여 기존의 데이터를 일반화(generalization)하는 기능이 있다. Fig. 1은 인공신경망의 일반화 과정을 도식적으로 나타낸 것으로서 일반화를 하기 위해서는 먼저 문제에 대한 학습 데이터(training examples)들을 신경망의 입력패턴으로 제시하고 이들 입력패턴을 신경망에 반복적으로 학습시키면 신경망은 입력패턴에 맞게 학습된다. 학습이 성공적으로 완료되면 시험 예(testing examples)들을 학습된 신경망에 대입하며, 신경망은 이들에 대한 적절한 예측 결과를 제시한다.

역전파 신경망(backpropagation neural network)은

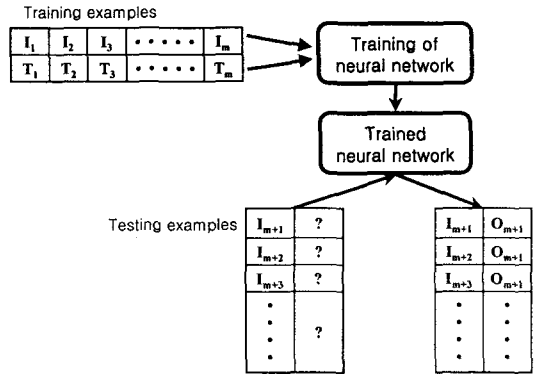


Fig. 1 Generalization procedure of neural network

Rumelhart 등⁽⁸⁾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 알고리즘은 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. 식 (1)은 이러한 연결강도의 조절규칙을 수식으로 나타낸 것이다.

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

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

식 (1)에서 w_{jk} 는 j 번째 유닛에서 k 번째 유닛으로의 연결강도이며 Δw_{jk} 는 연결강도의 변화량이다. z_j 는 j 번째 은닉층 유닛의 출력이고 T_k , O_k 는 각각 k 번째 유닛의 목표값과 출력값이며 O_{in_k} 는 k 번째 출력층 유닛의 입력값이다. $f'(O_{in_k})$ 는 k 번째 유닛에서 활성화함수(activation function)의 미분값으로서, 본 연구에서는 활성화함수로 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 방지하고 학습 속도를 향상시킨다. 한편, 각 유닛에 대한 목표값과 출력값의 차이는 학습오차 $E(w)$ 로 정의되며 식 (3)과 같이 표현된다.

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

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

3. 구멍 편심에 대한 유한요소해석

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. 2와 같은 1축 응력 상태에 있는 평판 중앙에 구멍뚫기범용 스트레인 게이지를 부착한 경우에 대한 유한요소해석 모델을 설정하였다. 스트레인 게이지 부분의 형상은 현재 널리 사용되고 있는 Micro Measurements사의 TEA-06-062-RK-120 모델을 기준으로 설정하여, 구멍직경 d 는 1.57mm, 스트레인 게이지 직경 D 는




Fig. 2 Model configuration





Fig. 3 3-Dimensional finite element model



(a)Before drilling (b)Centered drilling (c)Eccentric drilling

Fig. 4 Strain gage and hole part

5.13mm로 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. 3은 본 연구에 사용된 유한요소망을 나타낸 것이며, Fig. 4는 구멍을 뚫기 전후 및 편심 구멍뚫기를 한 경우의 스트레인 게이지 부분을 나타낸 것이다. 특히, 1개의 스트레인 게이지를 48개 요소로 구성하여 이들 요소에서의 평균 변형률을 계산하여 각 스트레인 게이지 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, 편심 크기 e 는 ASTM의 편심 허용치인 0.025mm부터 구멍 반지름 r 의 약 0.5배인 0.375mm까지 4단계로 나누었으며, 편심 방향은 1번 스트레인 게이지에서 시계방향으로 30°씩 12단계로 나누어서 해석을 수행하였다.

또한, 실제 잔류응력을 측정할 경우에 측정자는 최대응력 방향을 알지 못하고 있기 때문에, 본 연




Fig. 5 Architecture of neural network for correction due to hole eccentricity in HDM

구에서 설정한 해석 모델과 다른 방향으로 스트레인 게이지를 부착하여 측정할 것이다. 이러한 임의 방향으로 스트레인 게이지를 부착한 경우를 고려하기 위하여, x 축과 3번 스트레인 게이지의 방향이 일치하고 있는 Fig. 3과 같은 모델에서 스트레인 게이지를 시계방향으로 30° 씩 회전시켜 가면서 각각의 경우에 대하여 편심 크기 및 방향에 따른 오차를 구하였다.

결과적으로 스트레인 게이지 회전 모델 6가지, 편심 크기 4가지, 편심 방향 12가지에 대해 각각 유한요소해석을 수행하여 총 288개의 신경망 학습 데이터를 구하였다.

4. 편심오차 보정을 위한 신경망 학습

4.1 신경망 모델

구멍이 편심되어 뚫어졌을 경우 측정된 이완 변형률로부터 계산된 최대응력과 방향에는 오차가 포함되어 있다. 결과적으로 측정자는 구멍의 편심 크기 및 방향 그리고 오차가 포함된 최대응력의 크기 및 방향을 알 수 있다. 따라서, 이들 측정값으로부터 오차의 크기를 구하기 위한 신경망 모델을 Fig. 5와 같이 구성하였다.

입력층은 무차원 편심크기 e/r , 편심 방향 $\alpha(\text{deg})$ 및 편심 구멍일 때의 최대응력 방향 $\beta'(\text{deg})$ 의 3개 유닛을 사용하였으며, 출력층은 식 (4)와 같이 계산되는 구멍 편심으로 인한 최대응력의 %오차 $\%Error_{\sigma_{\max}}$ 와 최대응력 방향 오차 $Error_{\beta}$ 의 2개 유닛을 사용하였다.

$$\%Error_{\sigma_{\max}} = \frac{\sigma'_{\max} - \sigma_{\max}}{\sigma_{\max}} \times 100 \quad (4)$$






Fig. 6 Input value for network training





Fig. 7 Target value for network training

식 (4)에서 σ'_{\max} 는 오차가 포함된 최대응력이고, σ_{\max} 는 구멍이 편심되지 않았을 때 측정되는 잔류응력 참값이다. Fig. 6은 유한요소해석으로 구한 288개의 신경망 학습 패턴에서 입력값을 나타낸 것이며, Fig. 7은 목표값인 $\%Error_{\sigma_{\max}}$ 및 $Error_{\beta}$ 를 각각 보인 것이다.

본 연구에서는 저자 등이 Visual FORTRAN으로 작성한 역전파 신경망 프로그램을 이용하여 신경망 학습을 수행하였으며 은닉층 유닛은 120

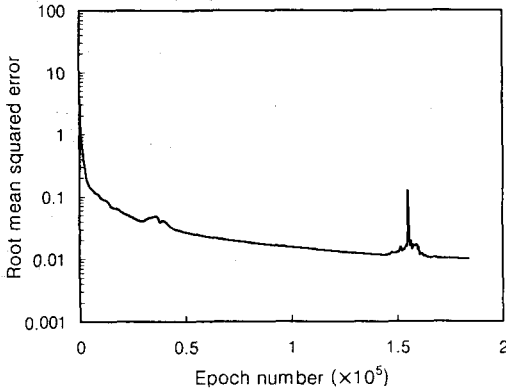


Fig. 8 Root mean squared error versus epoch number

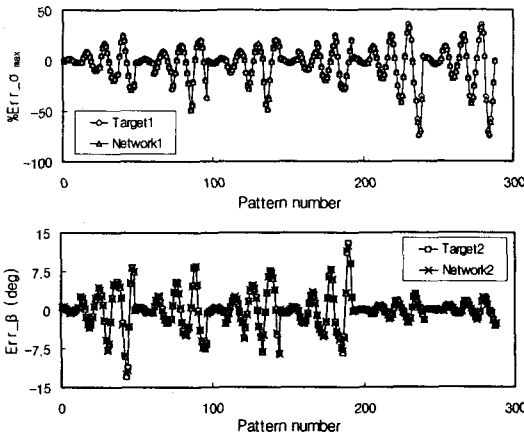


Fig. 9 Comparison network output value with target one

개, 학습률은 0.05, 모멘텀 계수는 0.8로 하였다. 또한, 식 (5)로 계산되는 평균오차(root mean squared error)가 0.01에 도달하거나 반복회수가 30만회에 도달하면 학습을 종료하도록 하였다.

$$RMS = \sqrt{\frac{\sum_{k=1}^N (T_k - O_k)^2}{N}} \quad (5)$$

4.2 신경망 학습 결과

Fig. 8은 신경망 학습 종료 후 학습 회수에 따른 평균오차를 나타낸 것으로서 약 18만회의 반복학습 후 목표 오차인 0.01에 도달하였다. 신경망 학습의 성공여부는 신경망 출력층에서 각 유닛의 출력값과 목표값의 차이를 비교하여 판단할 수 있다. Fig. 9는 신경망 출력값을 목표값과 같이 나타낸 것으로서 두 개의 출력값이 모두 목표




Fig. 10 Schematics of uniaxial stress test




Fig. 11 Photograph of hole-drilling method in uniaxial stress field

값과 잘 일치하고 있는 바, 신경망 학습이 성공적으로 이루어졌음을 알 수 있다.

5. 잔류응력 측정

5.1 측정장치 및 절차

신경망 학습 결과의 효용성을 확인하기 위하여 편심 구멍뚫기로 잔류응력 측정 실험을 수행하였다. 보정된 오차의 정확성을 판단하기 위해서는 알고 있는 응력장을 설정해야 하므로 Fig. 10과 같이 시편에 1축 응력을 부가할 수 있는 실험 장치를 구성하였다. 부하용 나사를 돌리면 시편과 로드셀(load cell)을 인장, 압축시키며 이때 가한 하중을 인디케이터를 이용하여 계측할 수 있도록 하였다.

시편은 SM45C 재질로서 풀림 처리를 실시하여 초기 잔류응력의 영향을 줄였으며, 폭 60mm, 길이 300mm, 두께 10mm로서 스트레인 게이지 크기를 고려하여 ASTM에서 제시한 자유표면의 영향을 무시할 수 있는 시편 크기에 맞게 제작하였다.⁽³⁾ 이와 같은 실험 장치를 이용하여 1축 응력을 가한 상태에서 시편 중앙에 부착한 스트레인 게이지에 구멍을 뚫었을 때 이완되는 변형률을

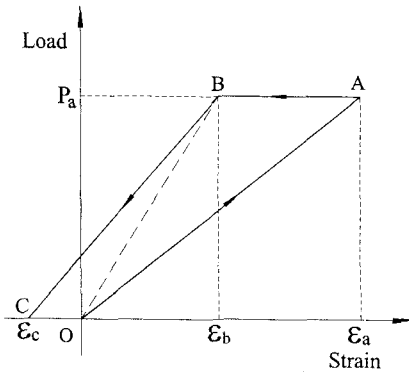


Fig. 12 Process of loading and measurements for removing initial stresses in specimen

측정하였으며, Fig. 11에 측정 사진을 나타내었다. 스트레인 게이지는 유한요소해석에서 설정한 모델과 같은 TEA-06-062RK-120을 사용하였으며, 구멍뚫기 작업은 RS200 밀링 가이드의 고속 공기 터빈(high speed air turbine)을 사용하였다.

한편, 시편에 풀림 처리를 함으로써 잔류응력을 제거시켰으나 가공 등의 이유로 잔류응력이 남아있을 수 있으므로 이의 영향을 최소화하기 위하여 Fig. 12와 같은 측정 과정을 수행하였다.^(9,10) 시편에 하중을 가하면 OA를 따라서 변형률이 증가하고 이 상태에서 구멍을 뚫으면 변형률은 AB만큼 감소할 것이다. 다시 하중을 제거시켰을 때 O점으로 돌아오면 $\epsilon_{ba} = \epsilon_b - \epsilon_a$ 가 이완된 변형률이라고 할 수 있다. 그러나 하중을 제거하였을 때 C점(ϵ_c)으로 돌아왔다면 재료에 존재하였던 잔류응력으로 인하여 변형률이 더 이완되었음을 의미한다. 따라서 가해진 하중에 의해 순수하게 이완된 변형률은 $\epsilon_{ba} - \epsilon_c$ 라고 할 수 있다.

5.2 측정 결과

세 가지의 각기 다른 경우에 대하여 구멍뚫기법을 적용하였다. 스트레인 게이지 직경의 0.4배인 2.05mm 깊이까지 구멍을 뚫었을 때의 이완 변형률을 측정하고, 식 (6)에 대입하여 최대응력과 그 방향을 계산하였다. 이 때 이완상수 \bar{A} , \bar{B} 는 ASTM E 837에 제시된 방법으로 유한요소해석을 수행하여 구하였다.

Table 1 Measured results with hole eccentricity

No.	Applied stress (MPa)	Measured stress (MPa)	Direction of σ_{max} (deg)	Hole eccentricity (mm)	Direction of eccentricity (deg)
Case1	30	25.6	84.7	0.192	270
Case2	50	40.6	62.3	0.3	45
Case3	50	60.2	85.2	0.28	60




Fig. 13 Enlarged drilled hole at eccentric case

$$\sigma_{min}, \sigma_{max} = \frac{\epsilon_3 + \epsilon_1}{4\bar{A}} \pm \frac{\sqrt{(\epsilon_3 - \epsilon_1)^2 + (\epsilon_3 + \epsilon_1 - 2\epsilon_2)^2}}{4\bar{B}} \quad (6)$$

$$\beta = \frac{1}{2} \tan^{-1} \left(\frac{\epsilon_3 + \epsilon_1 - 2\epsilon_2}{\epsilon_3 - \epsilon_1} \right)$$

구멍을 뚫은 후 구멍 편심 크기와 방향은 현미경과 Fig. 13과 같은 구멍부 확대 사진을 이용하여 측정하였다. 측정 결과 구멍의 편심 크기에 따라 최대응력의 오차는 최대 23%까지 측정되었으며 세부적인 결과를 Table 1에 정리하였다.

6. 구멍 편심오차 보정

인공신경망에서는 학습이 성공적으로 완료된 후 임의의 입력값을 학습된 신경망에 대입하면 신경망은 이에 대한 적절한 예측 결과를 제시한다. 따라서, 본 연구에서는 학습된 신경망에 편심 구멍뚫기에 의해 측정된 값을 제시하여 오차의 크기를 구하였으며, 이로부터 측정치에서 오차를 보정해 주었다.

Table 2는 세 가지의 실험 결과를 학습된 신경망에 적용하여 구한 값으로서 각각의 경우에 입력값과 출력값을 정리하여 나타낸 것이다. 따라서, Table 2의 신경망 출력값인 측정 오차만큼 잔류응력 측정치를 보정하여 구멍이 편심되어 측정된 경우에도 최대응력과 그 방향의 참값을 식 (7)과 같이 구할 수 있겠다.

$$\sigma_{max} = \sigma'_{max} - \sigma'_{max} \times \frac{\%Error_{\sigma_{max}}}{100} \quad (7)$$

$$\beta = \beta' - Error_{\beta}$$

Table 2 Neural network result using the HDM testing data

No.	Network input			Network output	
	e/r	α (deg)	β' (deg)	%Err- σ_{max}	Err- β
Case 1	0.245	270	84.7	-14.3	-1.0
Case 2	0.588	45	62.3	-27.6	2.6
Case 3	0.357	60	85.2	13.2	6.2

Table 3 Stress result before and after correction

Applied stress (MPa)	Before correction		After correction	
	Max. stress (MPa)	Error (%)	Max. stress (MPa)	Error (%)
30	25.6	14.7	29.3	2.3
50	38.7	22.6	51.9	3.8
50	60.2	20.4	52.1	4.2

Table 3은 Table 2의 신경망 출력값을 식 (7)에 대입하여 측정 오차를 보정해 준 결과이다. 3회 의 편심 구멍뚫기에 의한 잔류응력 측정에서 최대응력의 오차가 23%까지 포함되었으나, 본 연구 결과를 이용하여 보정한 후에는 5% 이내의 오차를 포함하는 결과를 얻을 수 있었다.

따라서, 본 연구 결과를 이용한 구멍 편심오차의 보정은 효과적임을 알 수 있으며, 학습된 신경망을 이용하여 비교적 간단한 방법으로 임의의 1축 잔류응력장에서의 구멍 편심오차를 보정해 줄 수 있겠다.

7. 결론

본 연구에서는 유한요소해석과 역전파 신경망 기법을 이용하여 1축 잔류응력장에서 구멍뚫기법의 구멍 편심오차를 보정해 주기 위한 방법을 제시하였다. 널리 사용되고 있는 스트레인 게이지 모델을 설정하고 편심 크기 및 방향 그리고 스트레인 게이지의 부착 방향을 고려하여 유한요소해석을 수행하였으며, 개발한 역전파 신경망 프로그램을 이용하여 신경망 학습을 수행하였다.

편심 구멍뚫기로 측정한 잔류응력 측정치에 대해 학습된 신경망을 적용하여 오차를 보정한 결과 5% 이내로 측정 오차를 줄일 수 있었다. 이와 같은 방법은 임의의 1축 잔류응력장에서 구멍뚫기법에 의한 잔류응력 측정에 손쉽게 적용될 수 있을 것이다.

후 기

본 논문은 한국과학재단 산하 성균관대학교 산업설비 안전성평가 연구센터의 연구비 지원으로 이루어진 것으로서, 이에 관계자 여러분들께 감사 드립니다.

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) Ajovalast, 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) Kobayasi, A. S., 1993, *Handbook on Experimental Mechanics*, 2nd ed, SEM, pp. 785~790.
- (7) Fausett, L., 1994, *Fundamentals of Neural Network : Architectures, Algorithms and Applications*, Prentice Hall, pp. 3~37.
- (8) 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.
- (9) Rendler, N. J. and Vigness, I., 1966, "Hole-drilling Strain Gage Method of Measuring Residual Stresses," *Experimental Mechanics*, Vol. 6, No. 12, pp. 577~586.
- (10) 주진원, 박찬기, 1998, "구멍뚫기법을 이용한 깊이방향으로 변하는 잔류응력 측정방법," 대한기계학회논문집(A), 제22권, 제2호, pp. 268~277.