

신경회로망을 이용한 원공 결함 패턴 인식에 관한 연구

이동우*, 홍순혁**, 조석수***, 주원식****

A Study on the Pattern Recognition of Hole Defect using Neural Networks

Dong Woo Lee*, Soon Hyeok Hong**, Seok Swoo Cho*** and Won Sik Joo****

ABSTRACT

Ultrasonic inspection of defects has been focused on the existence of defect in structural material and need has much time and expenses in inspecting all the coordinates (x, y) on material surface. Neural networks can have an application to coordinates (x, y) of defects by multi-point inspection method. Ultrasonic inspection modeling is optimized by neural networks Neural networks has trained training example of absolute and relative coordinate of defects, and defect pattern. This method can predict coordinates (x, y) of defects within engineering estimated mean error ψ .

Key Words : Multiple Defect(복수 결함), Ultrasonic Inspection Modelling(초음파 탐상 모델링), Multi-position Inspection Method(다점 탐상법), Backpropagation Neural Networks(역전파신경회로망), Data Transformation(데이터 변환), Estimated Mean Error(추정 평균오차)

1. 서론

과학기술의 급속한 발달에 따라 항공기, 고속철도, 원자력 발전소등의 대형 시스템의 건설이 증가하고 있다. 그러나 이러한 시스템에 결함이나 균열로 인하여 예기치 못한 사고가 발생하게 되면 엄청난 경제적 및 사회적 손실이 일어나게 된다. 따라서 이러한 구조물에 대한 안전성을 평가하기 위한 비파괴 방법이 요구되어 초음파, 방사선, 음향방출⁽¹⁾등이 제안되어져 상당한 효과를 거두고 있다. 이러한 방법 중 초음파 탐상은 다른 방법에 비하여 투과능력이 뛰어나며 미소 결함에 대한 감도가 높고 내부결함의 위치와 크기 및 방향성을 대체적으

로 정밀도 있게 결정할 수 있다. 또한 방사선 투과 시험에 비하여 이동성이 양호하고 시험방법이 안전할 뿐만 아니라 간편하기 때문에 널리 사용되는 비파괴 시험법이다. 또한 기존의 비파괴 검사는 연속 탐상법(Continuous inspection method)으로 모든 시험체 표면을 탐상해야만 균열이나 내부 결함의 크기나 위치를 찾을 수 있다. 이러한 방법은 탐상영역의 확대에 의하여 탐상시간과 비용이 증가하게 되어 탐상 방법의 개선이 요구되고 있다.

한편, 결함탐상모델링은 초음파의 관측결과에서 경계조건인 결함 파라미터를 구하는 역문제(Inverse problem)로 순문제에 비하여 수학적으로 취급하는 것이 상당히 어렵다⁽²⁾. 최적화 방법을 결

2002년 6월 11일 접수

* 동아대학교 기계공학과 대학원

** 부경대학교 공과대학 CAD/CAM Lab.

*** 삼척대학교 기계·정밀기계·자동차공학부

**** 동아대학교 기계·산업시스템공학부

합탐상문제로 적용한 예는 다수 있으나 국소 최적해에 잘 빠지므로 전역적 최적해를 구하기가 어렵다. 이러한 결점을 극복하기 위하여 유전자 알고리즘을 이용한 방법이 제안되어져 전역적 최적해를 구할 수 있었으나 모델링할 때 계산량이 방대하므로 현장에서 신속한 검사를 수행할 수 없다⁽³⁾. 한편, 구조물의 내부 균열이나 결함의 존재 여부와 그 위치 및 형상을 정량적으로 파악하기 위하여 비파괴 결함탐상법과 인공지능을 동시에 사용하는 최적화방법을 적용한 연구는 점차적으로 증가되고 있으며 그 대표적 예는 다음과 같다.

Oishi⁽⁴⁾ 등은 결함을 가지는 물체에 투과한 초음파를 유한요소법으로 시뮬레이션 한 뒤 각 측정점에 대한 변위 변동 데이터를 이용하여 단일 결함의 위치를 신경회로망으로 모델링하였다. 또한 이^(5,6) 등은 초음파의 에코 신호를 프랙탈로 해석하여 용접부에서 발생하는 단일결함의 종류를 신경회로망으로 분류하였다. Yagawa⁽⁷⁾ 등은 관통 균열과 평판중에 존재하는 반타원 표면균열의 전기포텐셜을 이용하여 그 균열의 위치와 크기를 개층형 신경회로망으로 모델링 하였다. 특히, 3차원 균열의 x, y 좌표와 균열 길이 및 균열 깊이의 다양한 파라미터를 신경회로망으로 학습하여 일반화한 결과 최대 추정평균오차가 0.081로 상당히 적은 오차범위로 수렴되었다.

그러나 상술의 연구는 단일 결함과 균열의 종류 및 그 존재여부에 큰 관심을 가지고 있으므로 재료 내부에 존재하는 복수결함의 위치와 종류를 분류하는데 큰 노력이 기울여지지 못했을 뿐만 아니라 탐상 방법의 개선을 통한 효율성 있는 탐상 방법을 확립하지 못하였다. 이러한 관점에서 결함 위치와 패턴을 기존의 연속 탐상법으로 찾는 것이 아니라 2차원 탐상 영역을 정사각형 셀로 나누어 각 셀의 꼭지점에서만 탐상하는 다점 탐상법(Multi-position inspection method)을 이용하고자 한다. 즉, 시험체중에서 균열이나 결함이 존재할 확률이 높은 위험영역의 전 표면을 초음파로 탐상하지 않고 그 영역을 적당한 정사각형 셀로 나누어 그 꼭지점 중 측정점으로 선택된 점에서만 탐상한다. 따라서 본 연구에서는 각 측정점에 대한 결함 에코 높이와 저면 에코 높이 및 탐촉자 종류를 신경회로망의 입력 데이터로 하고 절대적 결함위치, 결함패턴 및 상대적 결함위치를 출력층 데이터로 하여 신경회로망에 대한 학습 파라미터를 최적화시

킨 후 미학습데이터에 대하여 일반화를 수행함으로써 초음파 탐상방법을 개선함과 동시에 신경회로망으로 결함 파라미터를 예측하고자 한다.

2. 실험장치 및 방법

2.1 재료 및 시험편

본 실험에 사용한 재료는 고온용 부재로 널리 사용되는 오스테나이트계 스테인리스강인 STS 316 강을 사용하였으며 Fig. 1은 시험편의 형상 및 치수를, Table 1은 시험편 재료의 화학적 성분을 각각 나타내었다.




Fig. 1 Geometry and dimension of specimen for ultrasonic inspection

Table 1 Chemical compositions of the STS 316 steel (wt. %)

Material	C	Si	Mn	P	S
STS 316	0.026	0.34	1.30	0.029	0.009

Fig. 1은 초음파 탐상에 사용할 직경이 120mm인 환봉으로서 탐상면은 밀링 머신을 이용하여 압출방향에 대하여 수직방향으로 가공하였으며 탐상면의 표면 거칠기는 탐상오차를 최소화하기 위하여 10 점 평균 거칠기를 0.25mm이내의 범위에 수렴하도록 연삭가공(NICCO, Type : NSG 550B)을 하였다. 또한 인공결함은 직경 2mm인 드릴을 사용하여 깊이 12mm의 90%인 10.8mm로 1차 가공한 뒤 엔드밀을 이용하여 나머지 깊이 1.2mm를 평저공이 되도록 가공하였다.

2.2 실험장치와 방법

본 실험에서는 초음파 탐상 장치(Ultracac II)를

사용하였으며 탐상방법은 수침법(Immersion method)을 이용하였다. 또한 Fig. 2는 초음파를 이용한 탐상방법을 나타낸 것으로 격자 간격은 초음파의 지향각을 고려하여 2mm로 설정하였고 탐촉자의 탐상 위치는 다섯 장소로 셋팅하였다. 또한 ● 는 초음파 탐상에서 사용한 임의의 결합 위치를 나타낸 것이다.

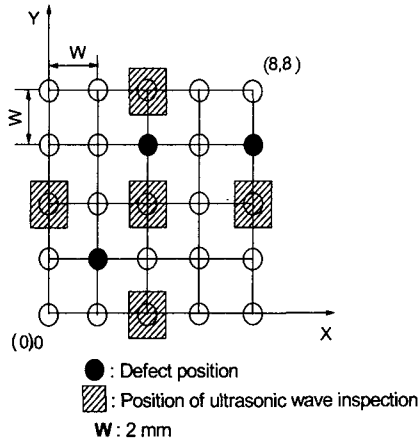


Fig. 2 Ultrasonic inspection method and defect position

3. 역전파 신경회로망의 학습 알고리즘

역전파 신경회로망은 신경망을 학습할 때 신경망 출력층의 각 유니트에 대하여 원하는 출력(Target)을 주기 위해 신경망에 입력된 패턴에 대한 실제의 출력치와의 평균자승오차값을 최소화시키는 방법이다. 다음 식 (1)은 역전파 신경회로망에서 학습패턴에 대한 자승오차 E_p 를 나타내고 있다.

$$E_p = \sum_{j=1}^n \frac{1}{2} (T_{pj} - O_{pj})^2 \quad (1)$$

여기서,

- n : 출력층 유니트수
- E_p : p번째 학습패턴에 대한 자승오차
- T_{pj} : p번째 학습패턴에 대한 k번째 출력층 유니트의 목표값
- O_{pj} : p번째 학습패턴에 대한 k번째 출력층 유니트의 출력값

또한 E_p 에 관한 최급강하(steepest descent)를 하기 위해서 일반적인 델타규칙(delta's rule)과 같이 다음 식(2)를 이용하여 결합계수를 변화시킨다.

$$\Delta_p w_{ji} = \eta \delta_{pj} O_{pi} \quad (2)$$

여기서,

$\Delta_p w_{ji}$: n-1번째 층의 i번째 유니트와 n번째 층의 j번째 유니트 사이의 결합계수 변화량

δ_{pj} : n번째 층의 j번째 유니트의 오차신호

η : 학습계수(learning rate)

그리고 일반적으로 학습계수 η 를 작은 값으로 설정하기 때문에 각 학습단계에서 결합계수 변화량은 상대적으로 줄어들게 되므로 학습이 느려지는 현상이 나타난다. 따라서 학습단계에서 결합계수를 변화시킬 때 이전 학습단계의 결합계수 변화량을 보조적으로 활용하여 학습의 고속화에 이용하는 모우멘트 계수는 다음 식(3)을 이용하여 결합계수를 변화시킨다.

$$\Delta_p w_{ji}(n+1) = \eta \delta_{pj} O_{pi} + \alpha \Delta_p w_{ji}(n) \quad (3)$$

여기서,

n : 반복학습 회수

η : 학습계수(learning rate)

α : 모우멘트 계수(momentum rate)

또한 신경회로망의 학습과 일반화능력은 신경회로망의 출력값과 목표값의 차이인 추정평균오차를 기초로 평가하였으며 추정평균오차의 정의는 다음 식(4)와 같다.

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

여기서,

r : 학습과 일반화에 사용한 학습 데이터 수

$\psi(p)$: 입력층 유니트에 대한 목표값

$\psi_{neuro}(p)$: 입력층 유니트에 대한 출력값

또한, 추정평균오차가 0.05이내로 접근될 때 공학 적 오차범위 내에서 수렴되는 것으로 가정하여 이 범위를 공학적 한계 오차범위로 설정한다.

4. 초음파를 이용한 결함 탐상 모델링

Table 2 Initial conditions for learning of neural networks

Hidden layer	Hidden units	Learning rate	Momentum rate	Learning data	Epochs
1	10	0.1	0.9	87	100000

4.1 결함 탐상 모델링에 미치는 학습 파라미터의 영향

4.1.1 데이터 패턴의 영향

본 연구에 적합한 신경회로망의 데이터 패턴을 결정하기 위하여 출력층 유니트를 절대적 결합위치 (x, y)와 결합패턴 k 및 상대적 결합위치 (r_x, r_y)의 각각의 독립적 데이터 패턴으로 설정한 경우와 각각의 데이터 패턴을 통합하여 설정한 경우로 나눈 뒤 입력층 유니트를 3개, 5개, 7개, 9개, 11개 등으로 변화시킨다. 입력층 유니트가 증가할수록 각각의 데이터 패턴 크기에 관계없이 신경회로망의 학습에 따른 추정평균오차는 감소되므로 Table 3은 11개의 입력층 유니트를 기초로 각 데이터 패턴에 따른 신경회로망의 학습결과를 나타낸 것이다. 출력층 데이터를 각 데이터 패턴별로 독립적으로 설정한 경우, 절대적 결합위치 (x, y)와 상대적 결합위치 (r_x, r_y)가 0.84에서 1.01까지의 상당히 큰 학습 추정평균오차를 보이나 결합패턴 k 는 0.25정도의 학습추정평균오차를 보여 결합패턴이 결합위치보다는 패턴 분리가 잘 일어남을 알 수 있다. 이러한 결과는 결합위치가 결합패턴에 비하여 초음파 에코 신호에 미치는 영향이 훨씬 더 복잡하기 때문이라 생각된다.

한편, 신경회로망의 출력층 유니트를 각 데이터 패턴을 통합적으로 설정한 경우 독립적으로 설정한 경우에 비하여 학습 추정평균오차는 최소 2.7배정도 감소되고 있으므로 통합된 데이터 패턴이 훨씬 더 우수함을 알 수 있다. 이러한 결과는 출력층 유니트의 데이터 패턴이 증가됨에 따라 신경회로망의


Table 3 Learning result for data pattern

Output	Estimated mean error Ψ				
	x		y		
x, y	1.00		0.86		
	0.25				
k	r _x		r _y		
	1.01		0.84		
x, y, k, r _x , r _y	x	y	k	r _x	r _y
	0.31	0.30	0.15	0.31	0.31


입력층에서 출력층으로의 인식 구조가 훨씬 더 정확하게 설정되고 있으므로 절대적 결합 위치에 대한 보조 자료로 활용되고 있는 결합 패턴과 상대적 결합 위치가 유용함을 알 수 있다. 따라서 본 연구에서 사용하는 신경회로망의 입출력층 구조는 입력층 유니트를 각 측정점에 대한 결합 에코 높이와 저면 에코 높이 및 탐촉자의 종류의 총 11개를, 출력층 유니트를 절대적 결합위치와 결합패턴 및 상대적 결합위치의 총 11개로 각각 설정한다.

4.1.2 학습계수와 모우멘트계수의 영향

Fig. 3의 (a)는 신경회로망에 사용되는 파라미터를 최적화시키기 위하여 모우멘트 계수를 0.9로 고정시킨 후 학습계수 η 의 변화에 따른 추정평균오차를, (b)는 학습계수를 0.1로 고정시킨 후 모우멘트 계수 α 의 변화에 따른 추정평균오차를 나타낸 것이다. (a)에서 학습에 따른 각 출력층 유니트의 추정평균오차는 전 학습계수에 걸쳐서 그 차이가 적지만 0.7에서 가장 적은 값을 보이고 있다. 또한 (b)에서 각 출력층 유니트의 추정평균오차는 작은 모우멘트 계수에서 다소 높지만 모우멘트 계수가 증가할수록 낮아지는 경향을 보인다. 그 중 학습 결과가 가장 우수한 모우멘트 계수인 0.6의 경우 추정평균오차는 0.10에서 0.20으로 공학적 한계오차 범위를 상당히 벗어나고 있다. 이상의 결과를 기초로 신경회로망의 학습 계수와 모우멘트 계수는 각각 0.7과 0.6으로 설정한다.



(a) Constant $\alpha = 0.9$



(b) Constant $\eta = 0.1$

Fig. 3 Relation between estimated mean error and learning rate and momentum rate

Table 4 Optimal conditions and estimated mean error for learning of neural networks


Parameter		Number of hidden units	Data	Epoch
Optimal condition		200	87	1000000
Estimated mean error (ψ)	(x, y)	x	y	
		0.05	0.05	
	k	0.03		
	(r _x , r _y)	r _x	r _y	
0.05		0.05		

4.2 각 최적화방법에 의한 결함 파라미터의 예측


Table 4는 4.1절의 초기학습조건에 의하여 최적화된 신경회로망 파라미터와 출력층 유니트의 추정 평균오차를 각각 나타낸 것이다. 데이터 패턴에 따른 학습추정평균오차는 4.1.1항의 결과와 동일한 경향을 나타내고 있으나 모든 출력층 유니트의 추정 평균오차는 공학적 한계 오차범위인 0.05이내로

수렴되고 있다.


그리고 Fig. 4는 Table 4의 학습조건을 이용하여 최적화시킨 신경회로망을 기초로 절대적 결함위치 (x, y)와 결함패턴 k 및 상대적 결함위치(r_x, r_y)의 결과를 추정평균오차와 시험편의 절대좌표로서 나타낸 것으로 절대결함위치 x₃, r_{x3}을 제외하고는 공학적 한계 오차범위인 0.05 이내로 학습하고 있다.



(a) Unit x, y



(b) Unit k



(c) Unit r_x, r_y


Fig. 4 Defect parameters learned by neural networks with initial learning conditions

4.2.1 초기학습조건의 최적화에 의한 결합 파라미터의 예측


Fig. 5는 Fig. 4의 학습된 신경회로망의 결합계 수행렬에 각 결합패턴에 따른 미학습데이터 1개씩을 대입하여 일반화시킨 결과를 나타낸 것이다. 그림에서 절대적 결합위치 x_1, y_1, y_3 와 상대적 결합위치 r_{x1}, r_{y1}, r_{y3} 는 공학적 한계 오차범위로 수렴되거나 나머지 결합 파라미터의 추정평균오차는 0.07에서 0.21의 범위에 있으므로 공학적 한계 오차범위를 최대 4.2배정도 초과하므로 신경회로망 구조를 새로이 최적화시킬 필요가 있을 것으로 생각된다.

4.2.2 데이터 변환법을 이용한 결합 파라미터 예측


기존의 학습 데이터 중 결합 위치는 결합패턴에 따라 출력층 유니트에 그 값이 존재하지 못하는 경우가 있다. 특히, 결합이 하나인 1 결합패턴이나 결합이 2 개인 2 결합패턴의 경우 출력층 유니트의 1 개내지 2개가 데이터화되지 못하게 된다. 따라서 본 연구에서는 이러한 문제를 해결하기 위하여 출력층 중 그 값이 존재하지 않는 결합위치 유니트에 대하여 결합위치의 데이터 범위를 벗어난 0.05에서 0.2로 강제적으로 할당하여 학습시켰다. 그 중 학습 과정에서 가장 적은 추정평균오차를 보이는 0.05를 전절까지의 학습과 일반화에 사용하였다. 그러나 이와 같은 데이터 분포로는 학습 추정 평균오차가 한계 오차범위 내에 들어오지만 일반화 추정 평균오차는 공학적 한계오차범위를 훨씬 초과하므로 일반화는 상당히 열악함을 알 수 있다. 따라서 본 절에서는 신경회로망의 출력층 중 데이터가 존재하지 않는 결합위치 유니트에 대한 학습과 일반화 데이터로서 각 데이터 패턴에 존재하는 결합위치를 그대로 사용하는 방법을 제안한다. Fig. 6과 7은 위의 데이터 구조를 기초로 4.1절의 방법을 통해 신경회로망 파라미터를 최적화시킨 후 학습과 일반화를 수행한 결과를 나타낸 것이다. 그림에서 학습에 따른 추정평균오차의 경향은 거의 차이가 없으나 일반화에서는 공학적 오차 한계범위내로 수렴됨으로서 본 데이터 표현방법이 국부 최적해에 빠진 신경회로망을 전역적 최적해로 유도한다는 것을 알 수 있다.



(a) Unit x, y




(b) Unit k




(c) Unit r_x, r_y


Fig. 5 Defect parameters predicted by neural networks with initial learning conditions




(a) Unit x, y




(a) Unit x, y




(b) Unit k



(b) Unit k



(c) Unit r_x, r_y



(c) Unit r_x, r_y

Fig. 6 Defect parameters learned by neural networks with initial learning conditions

Fig. 7 Defect parameters predicted by neural networks with initial learning conditions

5. 결론

본 연구에서는 초음파를 이용하여 시험편 내부의 복수 결함에 대한 절대적 결함 위치를 탐상하기 위하여 신경회로망을 도입한 결과 다음과 같은 결

론을 얻었다.

1) 초기학습조건을 이용하여 신경회로망의 구조를 최적화시킨 경우 결함위치의 데이터 분포로 인하여 학습에서는 우수한 결과를 보이나 일반화에

서는 공학적 한계 오차범위 0.05를 벗어나고 있다.

2) 결합 패턴과 상대적 결합위치는 절대적 결합 위치를 찾아내는 데 상당한 역할을 수행함으로써 적은 학습 데이터 수를 가지는 신경회로망의 결점을 극복할 수 있다.

3) 출력층 유니트 중 그 데이터를 확보하지 못하는 결합위치 유니트를 그 결합패턴에 존재하는 결합위치로 설정하는 경우 임의로 설정한 경우와 비교하여 학습 추정평균오차는 비슷하나 일반화 추정평균오차는 훨씬 더 우수하여 공학적 오차한계범위 0.05에 수렴된다.

참고문헌

1. 이강용, 백충현, “음향 방출법에 의한 파괴 인성치 측정 및 파괴 안정성 평가를 위한 연구,” 대한기계학회논문집, 제13권, 제1호, pp. 96-104, 1989.
2. 大石篤哉, 山田勝稔, 吉村忍, 失川元基, “ニューラルネットワークと計算力学に基づく缺陷同正,” 日本機械學會論文集 (A), Vol. 60, No. 569, pp. 264-271, 1994.
3. 기타노 히로아키, “유전자 알고리즘,” 대청, pp. 12-72, 1996.
4. 大石篤哉, 山田勝稔, 吉村忍, 失川元基, “ニューラルネットワークと計算力学に基づく超音波缺陷同正,” 日本機械學會論文集 (A), Vol. 62, No. 598, pp. 1479-1487, 1996.
5. 이원, 윤인식, 정성관, 김정기, “프랙탈 해석을 고려한 용접 결합의 초음파 형상 인식 최적화에 관한 연구,” 대한기계학회 춘계학술대회논문집 (A), pp. 288-293, 1998.
6. 윤인식, 이원, 이병채, “카오스 특징 추출에 의한 용접 결합의 초음파 형상 인식,” 한국정밀공학회지, 제15권, 제6호, pp. 167-174, 1998.
7. 失川元基, 吉村忍, 大石隆寛, “階層形ニューラルネットワークと計算力学による三次元き裂の形状同正,” 日本機械學會論文集 (A), Vol. 59, No. 559, pp. 30-38, 1993.