

인공신경회로망을 이용한 최적용접조건 선정에 관한 평가

차용훈*, 김일수**, 이연신***, 김덕중****, 성백섭*****

* 조선대학교 공과대학 · ** 목포대학교 공과대학 · *** 송원대학 자동차과
**** 동아인재대학 자동차과 · ***** 조선대학교 대학원

A Study on the Selection of Optimum Welding Conditions using Artificial Neural Network

Yonghoon Cha, ilsoo Kim, Younsin Lee, Duckjoong Kim, Backsub Sung

ABSTRACT

The objective of the study is the development of the system for effective prediction of residual stresses using the backpropagation algorithm from the neural network.

To achieve this goal, the series experiment were carried out and measured the residual stresses using the sectional method. Using the experimental results, the optional control algorithms using a neural network should be developed in order to reduce the effect of the external disturbances on during GMA welding processes.

Then the results obtained from this study were compared between the measured and calculated results, the neural network based on backpropagation algorithm might be controlled weld quality. This system can not only help to understand the interaction between the process parameters and residual stress, but also improve the quantity control for welded structures.

Key Word : Backpropagation(백프로퍼케이션), Residual stress(잔류응력), Hidden layer(은닉층), Target value(목표값)

용접이음은 영구적으로 금속부재를 접합하기 위한 가장 경제적이고 효율적인 방법으로 이음효율 상승, 중량경감, 공정수 감소 및 유밀성·기밀성 등의 장점이 있어 구조물, 차량, 조선, 압력용기, 항공기, 수송기계 및 산업분야 등의 수리와 생산공장에서 광범위하게 사용되고 있다. 이러한 각종 구조물에 있어서 파괴나 손상의 대부분은 용접이음의 원인에 의해서 발생되고, 특히 대형 구조물이나 위험한 재료를 저장하고 수송하는데 사용되는 구조물은 좌굴저항을 향상시키기 위하여 여러 방법으로 용접을 수행하고 있다^{1~4)}.

국내에서는 인공신경회로망을 이용한 용접 이음재의 측정에 관한 해석은 국내의 여건 및 기술적인 면에서 미진한 상태이며 단지 용접분야에 신경회로망을 적용할 수 있는지 가능성을 점검하였다. 현재까지 잔류응력과 공정변수들 사이의 관계에 관한 연구의 최적조건의 정립화는 전무한 상태이다^{6~10)}.

따라서 본 연구에서는 용접공정에서 용접중 발생하는 여러가지 외란의 영향에 의한 잔류응력 최소화 기술을 신경회로망을 이용하여 최적의 제어 알고리즘을 개발하고, 추가적인 실험을 통하여 측정된 잔류응력 실험치와 비교하여 나온 데이터를 인공신경회로망을 도입, 최적의 용접 공정변수를 평가하고자 한다.

1. 서 론

2. 실 험

실험에 사용된 재료는 고장력강 판재로서 두께 12mm인 BV-AH32강 (KR - RA32, ABS - AH32)으로 현재 선박구조물에 주로 사용되고있다. 시험편을 압연방향으로 채취한 후 시험편 규격 KS B 0801 13A로 인장시험편을 제작하고 실험을 실시 하였다. 기계적 성질은 Table 1과 같다.

Table 1 Mechanical properties of BV-AH32 steel

Yield Strength (kg/mm ²)	Tensile Strength (kg/mm ²)	Elongation (%)	Young's Modulus (kg/mm ²)
41.02	57.35	20	21,740

용접시 용접부의 역학적 조건 및 시험편이 수축, 팽창의 영향을 받지 않는(무한평판의 역학적 조건) 최소크기로 선정하였으며, 시험편 판재를 절단한 후 절단면 및 개선각을 밀링가공 하였으며, 12×150×200(mm)인 두 개의 판을 맞대기 용접하여 시험편을 제작하였다.

용접봉은고려용접봉(주) 고장력강용인 Solid-SM-70 6type이고, 직경 1.2mm를 사용하였다. 용접방법은 GMA용접을 하고 보호가스를 Ar 80%, CO₂ 20%를 사용하였으며 팁 높이는 15mm, 토치 각도는 90 °로 하였다.

또한 용접을 하기 전에 시험편의 밑면에 가접인 Sealing bead를 140(A)×20(V)×22 cm/min로 하였다. Fig. 1은 용접시험편의 층수를 보여주는 그림이고, Table 2과 같이 용접조건에 따른 시험편의 종류를 제작하였다.

인공신경회로망을 이용한 용접부 잔류응력의 예측방법은 크게 학습단계와 생산단계로 나뉘어진다. 학습단계에서는 일련의 입출력 관계가 공급되고 이에 따라 인공신경회로망에서 함수관계가 규명된다.

주어진 입력변수에서 출력변수가 계산된 후 실제 주어진 출력값과 오차에 따라 각각의 함수의 가중치(weight)가 학습 알고리즘(training algorithm)에 의해 조절되며 학습이 계속된다.

오차가 허용범위 내에 들어오면 학습이 종료

되고 인공신경회로망은 현재의 입출력사이의 함수관계를 기억한다.

Fig. 1 Welding specimen of pass number




Table 2 Welding condition of butt welding

Welding condition (A×V)	Welding speed (cm/min)	Weaving		Pass	Layer	Number of test specimen
		Width (mm)	Number (n/min)			
220×26	25			1	2	1
	25	11	45	2		
	25			1		
	17	13	45	2	3	2
	30	2	120	1		
	30	7	100	2		
	30	11	60	3	4	3
	30	2	120	1		
	30	7	100	2		
	23	13	45	3	5	4
	35	3	120	1		
	35	7	100	2		
	40	3	120	3	6	5
	40	3	120	4		
	35	3	120	1		
	35	7	100	2	6	6
	32	5	80	3		
	32	5	80	4		

Fig. 2는 4개의 공정변수들로부터 다층 신경회로망을 이용하여 용접부의 잔류응력 지수들을 예측하는 방법을 도식적으로 나타낸것이다. 먼저 신경회로망을 이용한 잔류응력 크기를 실제 예측에 사용하기에 앞서, 이러한 목적에 적합한 잔류응력 크기의 예측기를 구축하기 위해 신경회로망을 학습시킨다. 이는 학습법칙에 의해 신경회로망 내부의 매개변수를 조절함으로써 이루어진다. 4개의 공정변수들로부터 측정되고 실제로 형성된 잔류응력 크기 지수들이 신경회로망의 출력측에

목표값으로 주어진다. 신경회로망의 입력으로는 4개의 공정변수들에 관한 정보가 제공되고, 이로부터 신경회로 예측기는 잔류응력 크기의 지수들의 예측값을 계산하게 된다. 이는 실제 측정된 잔류응력 크기 지수들과 비교된다. 예측값이 실제 측정값과 차이가 있으면, 학습법칙에 의해 신경회로망 내부의 매개변수들을 조절하여 오차가 줄어들도록 학습시킨다. 학습의 초기에는 신경회로 예측기가 완전하게 구축되지 않았으므로 이들의 오차가 크다. 따라서, 학습법칙에 의해 오차가 줄어들도록 신경회로망 내부의 매개변수의 교정값이 계산되며, 이를 이용하여 매개변수는 수정되며, 새로운 매개변수에 잔류응력 크기의 예측값이 다시 계산되어 실제 크기와 비교된다. 이러한 반복적인 학습에 의해, 잔류응력 크기 지수들의 예측값과 실제 실험된 값과의 차이는 줄어들게 되며, 이들의 차이가 충분히 줄어들 때까지 계속된다.




Fig.2 Block diagram of the training and estimation procedures for residual stresses using a neural network estimator

학습이 끝나면, 신경회로망의 내부에는 4개의

공정변수들과 잔류응력 크기의 지수들과의 관계가 구현되고, 이는 실제 잔류응력 크기 지수의 예측에 이용된다. 실제 용접중 시스템으로부터 4개의 공정변수값들이 측정되면 이로부터 신경회로망을 이용하여 잔류응력 크기 지수들을 예측할 수 있다. 이때 측정된 공정변수들은 신경회로망 예측기의 학습시에 사용된 값들과 일치할 필요는 없으며, 이는 신경회로망이 보간기능을 갖추고 있기 때문이다.

일반적으로 신경회로망은 두 가지 모드로 작동된다. 먼저, 학습단계에서는 다수의 입-출력 (input - output)쌍이 주어지고 이 입-출력 쌍의 관계를 잘 나타내도록 가중치와 bias들이 조정된다. 초기에 임의의 가중치와 bias들을 주면 공정변수들에 대해 잔류응력 크기의 예측값을 계산하여 이를 목표값과 비교한다. 오차가 줄어들도록 가중치와 bias값들을 조절하기위해 학습률 (training algorithm)을 사용하며, 이러한 가중치와 bias의 조절과정은 오차가 원하는 범위 이내로 줄어들거나, 학습반복 횟수가 주어진 횟수에 도달할 때까지 반복되게 한다. 이러한 조절과정이 끝나면, 신경회로망은 입-출력 쌍의 관계를 잘 표현해 주는 가중치들을 얻게된다. 그후 산출 단계에서 새로운 입력들이 주어지면, 학습과정에서 신경회로망 내부에 형성된 입-출력쌍의 연관 관계에 적합한 출력들이 계산되게 된다.

이상의 과정을 거쳐서 학습단계가 종료되면 인공신경회로망에 저장된 가중치에 용접조건을 단순히 통과시킴으로서 용접부의 잔류응력 추정이 가능해 진다.

3. 실험결과 및 고찰

3.1 단면법에 의한 용접잔류응력 측정

단면법에 의한 용접잔류응력 측정을 위하여 맞대기 용접부의 폭 방향으로 용접 안정구간인 중앙을 선택하여 측정하였다.

Figs. 3~8은 각각의 데이터를 표시한 그림이며, 데이터 분석결과 용접공정변수(용접속도, 전류, 전압, 층수)에 변화가 있어도 용접잔류응력의 분포 형태는 동일한 형태임을 알 수 있었으나,

용접잔류응력의 크기는 σ_x 및 σ_y 성분 모두 용접속도가 느릴수록 다소 크게 나타났다. 더욱이 용접선 길이방향으로 용접잔류응력의 분포양상을 보면, 용접 시단부와 종단부의 미소영역에서 용접잔류응력 성분(σ_x, σ_y) 모두 응력이 크게 측정되었으며, 그 외의 영역에서는 일정한 양상을 보이고 있다.

이러한 측정결과를 나타내는 세일 큰 이유는 용접이 시작되는 지점과 끝나는 지점의 일정영역을 제외하고는 동일한 열적 특성을 받기 때문이라고 사료된다. 또한, 용접잔류응력이 최대값을 보이고 있는 지점이 열영향부 및 그 근방임을 알 수 있었다. 전류, 전압이 높은 경우 용접잔류응력이 크게 측정되었으며, 속도변화에 따른 결과는 미소한 차이를 나타냈으며, 속도에 따라 비이드 폭이 달라지는 경우에 대해 분석한 결과 비이드 폭이 클수록 용접잔류응력 데이터 값이 크게 측정되었다.

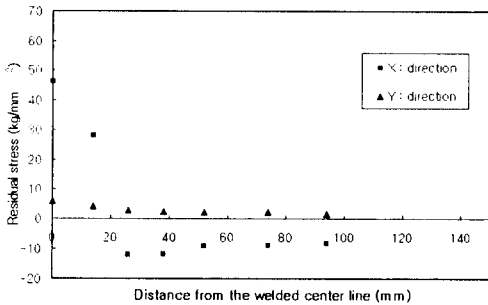


Fig. 3 Distribution of welded residual stress for SPE-1




Fig. 4 Distribution of welded residual stress for SPE-2




Fig. 5 Distribution of welded residual stress for SPE-3

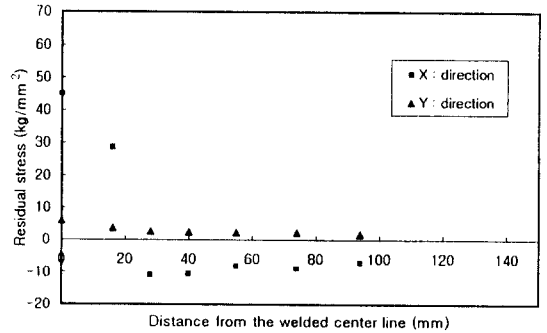


Fig. 6 Distribution of welded residual stress for SPE-4




Fig. 7 Distribution of welded residual stress for SPE-4




Fig. 8 Distribution of welded residual stress for SPE-4

3. 2 인공신경회로망에 의한 잔류응력 예측 및 결과 분석

다양한 용접조건으로 행한 실험에서 입력변수는 전류, 전압, 용접속도 및 용접층수로 선정하였고, 출력변수는 유한요소법으로 검증한 단면법에 의한 잔류응력 데이터를 종방향 응력과 횡방향 응력으로 각각 7개씩 측정하여 선정하였다. 앞에서 개발한 알고리즘을 기초로 용접잔류응력을 인공신경회로망 예측기에 학습시켰다. 본 연구에서 위하여 은닉층은 1층이며, node수는 40개로 설정하였다. 또한 학습률(learning rate)은 0.5, 관성률(momentum rate)은 0.7이며 최대 학습 반복 횟수는 120,000번으로 하였다. 학습단계에서는 학습시 기억되는 가중치를 이용하여 용접 후 용접부의 잔류응력 분포도를 추정하였다.

신경회로망을 이용하여 예측된 용접잔류응력의 신뢰성을 평가하기 위하여 신경회로망에 학습시킨 데이터 중 무작위로 시험편을 선정하여 예측기를 이용하여 예측한 값들을 실험에서 측정된 데이터와 비교한 결과 잘 일치함을 알 수 있었다. 신경회로망을 이용하여 용접잔류응력 값을 예측하는데 있어서 그 성능을 평가하기 위하여 다음과 같은 퍼센트 예측 오차가 사용되었다.

$$\eta = \frac{\beta - \alpha}{\beta} \times 100 (\%)$$

여기서, η : percentage error

α : the calculated error

β : the measured error

여기서 R_m 과 R_n 는 각각 실험에서 얻은 용접

잔류응력 데이터와 예측한 데이터 값이다. 위에서 산출한 데이터의 에러값은 퍼센트 예측오차의 범위분포가 $\pm 3\%$ 의 이내로 예측 오차를 나타냈다. 이러한 에러검증 결과 용접잔류응력을 예측하기 위해 만든 프로그램이 매우 우수한 성능을 발휘했음을 알 수 있다.

인공신경회로망 프로그램의 신뢰성을 검증하여 매우 우수함을 입증하여 Table 3과 같이 3 종류의 전류×전압과 이것을 기본으로 각각 2-PASS, 3-PASS, 4-PASS 형태로 총 3개를 만들어 실험을 실시 하였다. 인공신경회로망에서 예측하고자 하는 측정시험편의 실행조건 및 방법은 앞에서 행한 조건과 동일한 조건으로 실험을 실시하였다.

Table 3 Welding condition of Prosecution Test specimen

Welding condition (A×V)	Welding speed (cm/min)	Weaving		Pass	Layer	Number of test specimen
		Width (mm)	Number (n/min)			
270×26	25			1	2	1
	21	12	45	2		
	30	2	120	1	3	2
	30	7	100	2		
	27	12	50	3		
	35	3	120	1	4	3
	35	7	100	2		
	36	4	100	3		
	36	4	100	4		

Figs. 9~11은 인공신경회로망을 이용하여 예측한 데이터의 결과에 대하여 나타낸 것이다. 인공신경회로망에서 예측한 결과와 단면법으로 측정된 잔류응력값을 비교 분석한 결과 다소 미소한 데이터 변화가 있었으나 전반적으로 잘 일치하는 양상을 보였다.




Fig. 9 Residual stresses predictive distribution using artificial neural network for NEU-1




Fig. 10 Residual stresses predictive distribution using artificial neural network for NEU-2




Fig. 11 Residual stresses predictive distribution using artificial neural network for NEU-3

3. 3 용접잔류응력을 감소하기 위한 최적의 모델 선정

Figs. 10~12는 최적의 용접조건 선정을 위해 인공신경회로망을 이용하여 신경회로망에 학습시킨 뒤에 전류, 전압, 용접속도, 층수에 따른 공정 변수를 변화시키면서 인공신경회로망에서 예측한 결과와 이론적인 방법인 수치해석 분석 데이터 및 실험적인 방법으로 구한 데이터들을 비교분석하기 위하여 도식한 것이다. 실험적방법인 단면법과 이론적인 수치해석인 유한요소법과의 용접 잔류응력의 비교한 결과 맞대기 용접시험편에서의 용접잔류응력을 예측한 결과와 같은 양상으로 나타났다. 그림에서 알 수 있듯이 용접잔류응력 값은 전류, 전압이 높은 쪽에서 용접잔류응력이 높게 나왔으며, 속도가 빠를수록 용접잔류응력 데이터 값이 작게 나옴을 알 수 있었다. 본 연구에서 사용한 고장력강(BV-AH32)은 용접부에서

인장잔류응력값이 45~53 kg/mm² 정도 나왔으며, 용접부에서 멀어질수록 선형적으로 급속히 떨어짐을 알 수 있었다. 또한 σ_x 방향의 잔류응력 값은 용접 비이드 끝단부의 열영향부를 끝으로 인장잔류응력이 압축잔류응력으로 급속히 변화하였으며, σ_y 방향의 잔류응력값은 모두 인장압축잔류응력으로 측정 되었으며, 그 차이는 매우 미소함을 알 수 있었다. 이것은 맞대기 용접부에서는 σ_x 방향의 용접잔류응력 값의 영향을 지배적으로 받음을 알 수 있다.




Fig. 12 Distribution of optimized welded residual stress for OUT-1




Fig. 13 Distribution of optimized welded residual stress for OUT-2




Fig. 14 Distribution of optimized welded residual stress for OUT-3

4. 결론

1. 다양한 수치해석 결과와 실험치를 비교하여 백프로퍼케이션 학습 알고리즘인 인공신경회로망을 통하여 용접잔류응력 예측한 결과를 비교 분석 검토한 결과 신뢰성이 있음을 알 수 있었다.

2. 인공신경회로망에 실험데이터 및 유한요소법의 잔류응력값을 학습시킨 결과 오차가 3%이내의 용접잔류응력을 예측할 수 있었으며, 예측한 데이터를 실제 시험편을 제작하여 이와 유사한 조건에서 단면법에 의한 용접잔류응력을 비교한 결과 인공신경회로망이 최적의 용접조건을 선정할 값과 일치함을 알 수 있었다.

3. 더욱 신뢰성 있는 인공신경회로망을 이용한 최적 용접조건 선정을 위한 프로그램을 위해 새로운 학습법 개발 및 학습할 데이터의 양을 늘리고 이것을 데이터 베이스화 할 경우 최적의 용접잔류응력 예측시스템 개발은 더욱 신뢰성을 높일 수 있을 것으로 사료되며 이는 앞으로 꾸준한 연구가 진행되어야 할 것으로 사료된다.

참고문헌

1. Y. W. Shi and B. Y. Chen. "Effects of Welding Residual Stresses on Fatigue Crack Growth Behaviour in Butt Welds of a Pipeline Steel." Engineering Fracture Mechanics. Vol. 36, No. 6: pp.893-902, 1990.
2. V. Ramamurti and S. Suresh. "Residual

Stress Analysis in Weldments." Engineering Fracture Mechanics. Vol. 38, No. 6: pp.385-391, 1991.

3. S. Nair, R. C. Dix. "Residual Stress Generation and Relaxation in Butt-Welded Pipes." Transactions of the ASME. Vol. 104: pp.188-192, 1982.

4. K. Masubuchi. "Analysis of Welded Structure." International Series on Materials Science and Technology. Vol. 33: pp.518-576, 1980.

5. T. S. wilkinson, D. A. Mighell, and J. W. Goodman, "Back propagation and its application to handwritten signature verification." IEEE Conference on Neural Information Procession Systems Natural and Synthetic: pp. 487~496, 1989.

6. D. O. Hebb, "The Organization of Behavior." Wiley, pp.73~82, 1949.

7. F. Rosenblatt, The Perceptron. "A Probabilistic model for information storage and organization in the brain." Psychologic Review 65: pp.386~408, 1958.

8. M. Minsky and S. Papert. "Perceptrons." Cambridge, MA, MIT Press: 1969.

9. T. K. Kohonen. "The neural phonetic typewriter." IEEE Computer, Vol. 1, No. 3: pp.11~22, 1978.

10. J. J. Hopfield. "Neurons with graded responds have collective computational properties like those of two-state neurons." Proc. of the National Academy Science 81: pp.3088~3092, 1984.