

研究論文

인공신경회로망을 이용한 탄산가스 아크 용접의 잔류응력 예측에 관한 연구

조용준* · 이세현** · 엄기원**

A Study of Predicting Method of Residual Stress Using Artificial Neural Network in CO₂ Arc Welding

Yong-joon Cho*, Se-hun Rhee** and Ki-woan Um**

Key Words : Co₂ Arc Welding, Residual Stress, Artificial Neural Network, Heat Input, FEM, Thermo-elastic-plastic Analysis, Current, Voltage Predicting Method

Abstract

A prediction method for determining the welding residual stress by artificial neural network is proposed. A three-dimensional transient thermomechanical analysis has been performed for the CO₂ arc welding using the finite element method. The first part of numerical analysis performs a three-dimensional transient heat transfer analysis, and the second part then uses the results of the first part and performs a three-dimensional transient thermo-elastic-plastic analysis to compute transient and residual stresses in the weld. Data from the finite element method are used to train a backpropagation neural network to predict the residual stress. Architecturally, the fully interconnected network consists of an input layer for the voltage and current, a hidden layer to accommodate the failure mechanism mapping, and an output layer for the residual stress. The trained network is then applied to the prediction of residual stress in the four specimens. It is concluded that the accuracy of the neural network predicting method is fully comparable with the accuracy achieved by the traditional predicting method.

1. 서 론

구조물을 아크 용접함에 있어서 용접부 부근은

아크열에 의해 국부적으로 가열되고, 이로 인한 불균일한 온도 분포는 과도 열응력과 비탄성적인 변형을 발생시킨다. 이러한 변형에 의해 용접 후 냉각 수축의 과정을 거친 용접부 부근에는 복잡한 구조에 의한 응력이 잔류하게 된다. 이러한 응력들은 취성, 파괴강도, 피로강도, 진동특성, 부식저항등에 영향을

* 학생회원, 한양대학교 정밀기계공학과 대학원

** 정회원, 한양대학교 정밀기계공학과

주게 된다. 위와 같은 현상은 대부분의 용접공정이 공통적으로 지닌 문제점으로 이 분야에 대해 그동안 많은 연구가 수행되어져 왔다^{1, 2)}.

이러한 용접 잔류응력 문제를 해결하기 위해서 우선적으로는 용접부위의 잔류응력 분포를 정확히 이해하고 해석하며 더 나아가 보다 신뢰성과 경제성 있는 새로운 예측법이 요구된다.

본 연구에서는 잔류응력의 효과적인 예측방법을 제안하기 위하여 학습 능력을 지닌 error back propagation 알고리즘에 의한 multilayer perceptron 인공 신경회로망을 도입하여 용접부의 잔류응력 예측에 응용하고자 하였으며, 범용 유한요소 해석 패키지인 ANSYS 4.4A를 이용한 컴퓨터 시뮬레이션을 수행하여 인공 신경회로망의 학습에 필요한 데이터를 산출하였다. 또한, 재질이 연강인 시편에 탄산가스 아크 V형 맞대기 용접을 수행한 후, 기존의 실험 방법중 스트레스 이완법의 가장 대표적인 방법인 hole-drilling 방법을 이용하여 앞에서 얻어진 수치 해석 결과의 타당성을 검증하여 인공신경회로망에 학습된 데이터가 신뢰성있는 것임을 입증 하였다.

이상의 방법을 사용하여 기존의 방법보다 더욱 정확하고 신속하게 잔류응력을 예측하고자 하였다. 이러한 연구는 복잡한 용접 현상에 의한 잔류응력 발생의 정확한 이해에 큰 도움을 줄 수 있을 뿐더러, 용접 부위의 잔류응력에 대한 실시간 출력을 얻어 내어 용접공정에 응용함으로써 공정 제어시 용접 구조물의 품질 관리 및 향상에 큰 도움을 줄 수 있으리라 예상된다.

2. 인공신경회로망의 적용

2.1 적용 배경

용접 구조물에서 잔류응력은 피할 수 없는 문제이며, 용접 잔류응력이 용접 구조물의 성능이나 안전성에 중요한 영향을 미친다는 것은 잘 알려진 사실이다. 용접 잔류응력에 대한 가장 큰 문제는 그것이 일반적으로 쉽게 측정되지 않는다는 것이다. 그러므로 잔류 응력의 영향을 조사하기 위해 용접 잔류응력의 크기나 분포를 정확하게 예측하는 것은 매우 중요한 일이다.

잔류응력은 대상 구조물에 대한 일반적인 실험적 절차에 의해서는 측정되기 힘들다. 왜냐하면, 센서가

응력 제거에 의한 변형을 변화를 감지하기 위해서 잔류응력이 센서 부착 상태에서 어떤 형식으로는 노출되어야만 하는데, 이를 위해서는 부재를 파괴하여야 하기 때문이다. 이러한 단점을 보완하기 하기 위해서 수치해석 기법이 도입될 수도 있지만, 이 방법 역시 계산 시간에 의한 시간 지연 요소를 지니고 있기 때문에 실제적인 용접공정 응용에는 어느 정도 한계점을 지니고 있다.

이러한 이유에서 파괴에 의한 실험적 방법의 단점과 시간 지연에 의한 수치해석 방법의 단점을 모두 보완해 주면서, 정확도에 있어 두 방법과 큰 차이가 없는 새로운 잔류응력 예측법이 필요하다. 본 연구에서는 기존의 단점들을 보완하고 장점을 살리기 위하여, 이미 몇몇 연구자들에 의해 용접 분야에 적용되기 시작한 인공신경회로망을 잔류응력 예측법에 적용하였다.

2.2 신경회로망의 구조 및 특성

신경회로망이란 생명체의 신경조직을 모방하여 모델화한 정보처리 시스템으로 단순 소자들의 병렬, 분산 연결구조를 가지고 있으며, 외부로부터 들어오는 입력에 의하여 dynamic state response을 일으킴으로써 필요한 출력을 생성시키는 것이다. 이는 코드화된 알고리즘에 의하여 기억장치에 저장된 정보를 순차적으로 연산하여 그 결과를 다시 기억하는 기존의 노이만식 디지털 컴퓨터의 sequential연산의 기능상 한계를 극복하기 위한 또다른 시도로서 PDP (Parallel Distributed Processing) 시스템 혹은 neuromorphic 시스템이라는 의미를 지니고 있기도 하다³⁾.

일반적으로 신경망회로는 데이터를 병렬 분산 처리하는 방식을 사용하고 있고 내용의 일부 또는 관련된 암시를 가지고 전체를 찾아내는 CAM(Content Adressable Memory)방식의 연상 기억 능력과 고장 극복(fault-tolerance)이 있고 학습에 의해 자극과 응답에 대한 한정적 경험을 일반화함으로써 차후에 필요에 따라 적절한 해를 구할 수 있는 학습 능력을 지니고 있다.

이러한 신경망회로는 최근 들어 컴퓨터 분야는 물론이고 공학, 자연과학, 의학 등 매우 다양한 분야에서 심도 있게 연구되고 있다. 용접 시스템등과 같이 많은 변수를 포함하고 있는 복잡한 시스템의 경우 모든 변수에 대한 적절한 법칙을 추출해 내는

것은 매우 어려운 일이므로, 본 연구에서는 소자의 대단위 병렬성에 의한 용이한 하드웨어 구현능력과 이로 인한 빠른 처리속도에 의거하여, 용접공정의 실시간 제어등에 응용될 수 있는 신경회로망을 이용하여 용접 전류, 전압과 잔류 응력과의 비선형 함수를 구하였다. 이들 관계는 인공 신경회로망이 지니고 있는 weight 값에 의해 결정되고 입력 전류, 전압에 따른 그때의 결과를 사용하여 용접공정의 잔류응력 해석에 사용하였다.

2.3 신경회로망의 구현 원리

인공신경회로망은 neuron과 synapse로 구성된 생체의 신경 조직을 단순화시켜 모방한 모델을 기본으로 하고 있다. 한 절점에서의 뉴런은 인접한 많은 뉴런으로부터 입력신호를 받아서 하나의 결론을 출력하게 되고 시냅스는 뉴런의 출력을 받아서 weight를 곱한 후 다른 뉴런으로 보내게 된다.

이러한 기본 소자들은 입 출력층과 은닉층(hidden layer)으로 나뉘어져 전체 신경망을 구성한다. 간단한 계산 능력만을 지닌 기본 소자들이 서로 유기적으로 연결되어 입 출력사이의 복잡한 함수 관계(mapping)를 구현하며 이러한 함수 관계는 비선형성이 매우 심한 경우 상당히 효과적으로 적용될 수 있다.




Fig. 1 Schematic Diagram of Neural Network

인공신경 회로망을 이루는 기본 모델은 Fig.1에 나타내었다.

3. 유한요소법에 의한 학습 데이터의 산출

3.1 유한요소법 적용 용접

공정의 수치해석에 관한 기초 이론은 앞서 말한 바와 같이 Rosenthal⁴⁾ 등에 의해 이미 1940년대에 완성되기 시작하였다. 이들 방법들은 이상화된 여러 조건들을 사용하였기 때문에 정확한 해를 구하기에는 부적합하였으나, 용접 공정의 비선형성을 적절히 설명하고 있어 이후의 수치 해석 방법에 토대를 마련하였다. 1970년대 이후, 컴퓨터와 유한요소법의 도움으로 많은 연구자들에 의해 복잡한 형태의 과도 열전달 문제와 미분방정식이 효과적으로 처리할 수 있게 되었으며, 이에 따라 각종 용접 공정의 보다 정확한 시뮬레이션이 가능하게 되었다.

Hibbitt과 Marcal⁵⁾은 그의 논문에서 유한요소법을 이용하여 용접 잔류응력을 예측하는 방법의 새로운 장을 열었는데, 그들은 이 연구에서 경계 조건과 재료의 비선형성을 효과적으로 처리한 열전달 해석을 수행하였고 이에 따른 결과를 열응력 해석에 사용하였다. 이때, 온도 의존성 물성치에 의한 탄·소성 거동과 시간 의존성 creep 효과를 고려하여 잔류응력 값을 예측하였다. 그럼에도 불구하고 전체적인 결과는 실험치와 다소간의 차이점을 나타내었다. Friedman⁶⁾은 용접 공정에 의한 과도 및 잔류응력과, 변형 형태에 따른 영구 변형을 고려하여 좀 더 정확한 소성변형율을 계산하여 잔류응력을 예측하였다. 1980년대에 접어들면서, 앞선 연구 결과를 바탕으로 본격적인 상업용 유한요소 패키지가 개발됨에 따라, Tekriwal과 Mazumda⁷⁾는 ABAQUS를 이용하여 GTA 용접의 3차원 열전달 문제를 효과적으로 계산해 내었다. 이들은 또, 이를 바탕으로 용접이 진행됨에 따라 점진적으로 element가 첨가되는 기술을 사용하여 GMA 용접을 해석하였다.⁸⁾ 1991년에는 Tekriwal 등⁹⁾이 앞에 언급한 연구의 연장선으로 GMA 용접의 과도 및 잔류응력에 대한 해석을 시도하였으나, 시편 크기에 의한 구속을 고려함에 있어서 다소의 문제점을 보이고 있다.

본 연구에서는 이상의 연구를 바탕으로 이들을 보완하여 탄산가스 아크 용접의 열전달 해석 및 잔

류응력 해석을 수행하였다. 여기서, 탄산가스 아크 용접의 해석은 기존에 발표된 GMA용접 해석과 같은 맥락에서 취급되어질 수 있었다.

본 연구에서는 결과의 정확성과 경제성을 고려하여 thermal analysis와 stress analysis를 분리하여 순차적으로 해석하는 방법을 사용하였다. 이 방법은 열 해석에서 얻어진 결과를 응력해석에 적용함으로써 이루어질 수 있었다.

3.2 용접 공정의 분석 및 가정

탄산가스 아크 용접 공정을 해석하기 위하여 용접의 진행에 따른 메카니즘을 살펴보면, 분포 열원을 갖는 용접 아크가 용접될 두 평판 위를 x 방향으로 v 의 속도로 Fig. 2와 같이 움직인다. 용접 토치로부터 나오는 일정한 흐름을 갖는 활성 피복 가스가 대기 오염으로부터 용접부를 보호하기 위하여 사용되며, 아크열에 의해 와이어가 용융되고 입열량의 나머지 부분들은 평판에 흡수된다. 결국, heat flow가 모든 3차원 방향으로 흐르면서, 용융된 와이어와 함께 두 평판을 용융시켜 결합시킨다. 이 과정은 아크의 입열




Fig. 2 CO₂ Arc Welding Procedure with Coordinate System

형태가 용접 중심선에 대하여 대칭이 되는 Gaussian 분포라고 가정하여 두 평판의 한쪽면만을 분석하였다.

용접이 완료된 후 용접부의 부근에는 급격한 온도상승으로 인한 팽창과 냉각에 의한 수축이 일어난다. 이러한 온도변화의 과정에서 이음의 부근에는 복잡한 구속에 의한 탄성 소성적 응력변화가 발생하며, 냉각 후에 응력이 잔류하게 된다. 이러한 응력의 변화는 열 응력 해석에서 얻어진 결과를 이용해서

Table 1. Material Properties of Mild Steel for FEM

Ambient Temperature :	293K				
Solidus Temperature :	1700 K				
Liquidus Temperature :	1755 K				
Latent Heat of Fusion :	273790 J/kg				
Density of Mild Steel :	7870 kg/m ³				
Poisson Ratio :	0.3				
	Thermal Conductivity of Mild Steel	Specific Heat of Mild Steel	Thermal Expansion Coefficient	Young's Modulus	Yield Strength
T[K]	K[W/m/K]	C _p [J/kg/K]	[m/m/k]	[kgf/mm ²]	[kgf/mm ²]
293	73	675	1.2 E-5	2.1E4	27
750	59	675	1.35E-5	2.0E4	24
1000	52	675	1.42E-5	1.0E4	0.12
1250	45	675	—	—	—
1500	38	675	1.51E-5	1.0E-3	0.001
1600	36	675	—	—	—
1699	42	657	—	—	—
1700	48	5668	—	—	—
1755	48	5668	—	—	—
1756	61	695	—	—	—
2000	61	695	1.51E-5	1.0E-3	0.001

해석될 수 있었다.

이상의 과정은 기존 논문에 따라 몇가지 가정을 이용하여 이상화시켜 해석하였다.

이때, 해석에 사용된 연강의 물성치는 Table 1과 같다.

3.3 해석 과정

3.3.1 아크 입열 모델

아크 입열은 온도 분포와 그에 따른 냉각속도 그리고 용융부와 열영향부의 크기에 직접적으로 영향을 주기 때문에 이를 모델링하는 작업은 매우 중요하다. 용접조건, 즉, 피복가스, 노즐거리, 홈의 형상 등은 아크 효율에 중요한 영향을 미치지만 본 해석에서는 이 값들의 변화는 무시하고 일정한 값, 67%를 아크 효율로 사용했다. 열전도율과 비열은 온도에 따라 값이 변하는 비선형 데이터를 사용하였으며 특히 비열 값에는 잠열을 고려할 수 있는 데이터를 사용했다. 용적의 온도로는 2300 K를 적용했고, 아크의 온도는 각 조건의 전류, 전압 조건 아래에서 아크가 와이어를 녹이는데 필요한 열량을 고려하여 적용했다. 평판에 대한 아크 입열은 모든 시간 동안 대칭적인 Gaussian 분포라고 가정했다. 이 분포는 식 (1)과 같은 모델을 사용하였다.

$$q(x,y,t) = \frac{3\eta_{eff}VI}{\pi \gamma_b^2} \exp\left[-\frac{3}{\gamma_b^2} [(x-vt)^2 + y^2]\right] \quad (1)$$

3.3.2 표면 열손실

자연대류열전달은 $y=0$ 인 대칭면을 제외된 모든 평판의 표면에서 일어난다. 과거의 모델들에 기초하여, $h=10 W/m^2K$ 가 피복가스에 영향을 받지 않는 모든 표면에 사용되었으며, 식 (2)의 실험식이 용접 토치 노즐 아래 표면부의 강제대류 계수로 사용되었다.

$$h = 13 Re^{1/2} Pr^{1/3} k_{gas}/D \quad (2)$$

탄산가스의 특성에 기초하여 Re와 Pr을 계산하고, 열원이 용접 방향으로 이동함에 따라 속도를 고려하여 적절한 heat flux가 각 time-step의 nodal point에 가해지고, 새로운 mesh가 형성됨에 따라 새로운 경계 조건이 결정된다. 경계 조건은 일정한 h 값이 노즐

주위의 모든 점에서 사용되었으며, h 의 반경 방향 변화는 없는 것으로 하였다. 이상의 방법으로 입열 부분의 heat flux, 열 전달 계수를 구하여 해석에 사용하였다.

3.3.3 mesh 생성

mesh 생성은 수치 해석 결과의 정확도와 경제성에 결정적인 역할을 한다. 용접 중심선 근처에서는 고온이 급격히 변하므로 더 세밀한 element가 필요하다. 탄산 가스 아크 용접의 해석시 1300여개의 node와 800여개의 element가 사용되었다. 용접선 근처의 세밀한 크기의 element는 수치해석의 정확도를 보장하지만 경제성을 고려하여야 하므로 용접 중심선으로부터 멀어질수록 element의 크기가 커지도록 mesh를 만들어, 보다 경제적인 수치해석을 가능하게 하였다.

탄산가스 아크 용접의 경우 용접이 완료되기 전에 금속의 첨가가 계속적으로 가해지므로 보다 정확한 해를 얻기 위해서는 계속적인 mesh의 생성이 필요하다. V형 홈을 모델링할 경우에는 더욱 많은 node가 필요하지만 연구 목적상 V홈 내에 195개의 질점을 배치하였다. 용접공정의 묘사는 150 mm를 64부분으로 나누어 32 단계로 해석하였으며 각 단계마다 4.68 mm의 요소를 더해 나갔다. 해석은 첫 번째 패스가 완전히 완료된 후, 대기 중에서 30분간의 냉각 과정을 거친 다음 두 번째 패스가 진행되도록 하였다. 이상의 모델은 Fig.3에 나타내었다.




Fig. 3 CO₂ Arc Welding FEM Mesh Model

3.3.4 냉각

용접이 종료되면 더 이상의 입열은 주어지지 않으며 그 순간부터 냉각이 시작된다. 이때, 냉각 속도는 공정이 완료된 시편의 성질을 결정하는 매우 중요한 요인이다. 냉각과정은 sub-routine COOL을 만들어 상온(293K)을 주위 온도로 설정하고, $y=0$ 인 면을 제외한 모든 면에 새로운 경계조건을 부여해 대기 중에서 냉각시켰다. 용접이 끝난 직후의 time-step은 작게 하여 급격한 온도 변화에 민감하게 하였으며, 시간이 경과함에 따라 time-step을 증가시켜 경제성을 고려했다. 각 load-step의 반복 계산시 ramp형태의 load를 적용함으로써 step 사이의 온도 차이에서 오는 오차를 줄였다. 반복 계산은 time step의 크기에 따라 반복 간격을 적절한 크기로 나누어주는 time-step 최적화 기법을 사용하였다. mesh의 형태와 함께 냉각 time-step의 크기는 해석의 정확성과 경제성 사이의 중요한 문제이지만 신뢰성 있는 결과를 위해서는 어느 정도의 미세한 분할이 필요했다. 냉각은 60 time-step으로 나뉘어 17200 sec까지 진행되었다.

3.3.5 잔류응력 계산

냉각을 포함한 모든 공정이 끝난 후에 앞에서 얻은 결과를 이용하여 시편 내부의 잔류응력을 계산하기 위해서는 열해석 과정들이 응력해석 모듈에서 변형, 반복되어야 한다. 열해석 단계에서 생성된 mesh를 이용하여, 응력해석에 적당한 8-node isoparametric element로 구성된 새로운 mesh를 형성하여 응력해석을 가능하게 하였다. 시편의 재질은 등방성, 균일 질로 가정하였고 용착 금속 부분도 같은 재질로 간주하여 해석하였다.

시편의 냉각 온도에 따라 kinematic hardening model에 의한 bilinear 형태의 각기 다른 소성 비율을 적용하여, 매 온도마다 Bausinger effect를 포함한 적절한 소성 변형을 고려하였다. 시편의 구속은 $y=0$ 인 면에서 모든 방향의 변위를 구속하였고 그 밖의 node들은 변형에 자유롭게 하였다.

이상의 조건에 따라, 각 step의 thermal 해석 결과를 이용하여 90 단계의 stress 해석을 수행하였다. 이 과정은 thermal 해석 결과를 이용하여 수행됨으로 큰 기억장치 용량과 많은 처리 시간이 요구되었다.

3.4 해석 결과 및 고찰

앞의 해석과정에 의해 탄산 가스 아크 V형 맞대기 용접을 시뮬레이션하였다. Fig.4는 두 번째 패스의 진행을 묘사하고 있다. 나중에 스트레인 게이지에 의한 실험에서 얻어진 데이터와의 비교를 위하여 용접방향에서 중앙인 부분, 즉, $x=75\text{ mm}$ 인 면을 축으로 하여 시편 표면($z=6\text{ mm}$) 부위의 각 node에 대한 응력 분포를 관찰하였으며, 두께에 대한 응력값의 차이는 미소하므로 고려 대상에서 제외시켰다. 이 결과는 Fig. 5와 Fig. 6에 나타내었다. 용접 방향의 응력은 용접 중심선을 중심으로 인장응력이 차츰 감소하게 되며 끝단 부분에서는 압축응력이 작용됨을 볼 수 있다. 인장응력의 최대값은 항복응력을 약간 넘는 정도의 값을 나타내었다. 횡방향 응력은 종방향 응력에 비해 상대적으로 작은 값을 나타냈으며 역시 용접 중심선 부근이 최대 인장응력을 받고 있었다. 사용된 시편의 두께(6 mm)효과를 생각하여 두께 방향의 응력은 고려 대상에서 제외시켰다.

용접 입열이 증가할 수록 최대 인장 응력을 받고 있는 부분이 중심선에서 멀어지고, 끝단의 압축 응력도 점점 증가함을 알 수 있었다. 횡방향의 응력도 입열량이 증가할 수록 증가됨을 알 수 있었는데, 이는 높은 진류, 전압에서의 용접 시공이 잔류응력에 더욱 취약함을 보여주는 좋은 예가 될 것이다. 사용된 시편의 크기 효과에 따라 끝단으로 갈수록 압축응력의




Fig. 4 The 2nd Pass of Welding Procedure




Fig. 5 Longitudinal Residual Stress Distribution




Fig. 6 Transverse Residual Stress Distribution

크기가 증가됨을 볼 수 있으며, 상대적으로 폭이 넓은 시편에서 발생하는 응력의 현상과는 반대의 형태를 보이고 있다.

계산된 10가지 용접 조건에 대한 수치해석의 결과 중에서, 대표적인 4가지 조건에 대한 결과가 종방향 잔류응력과 횡방향 잔류응력으로 나뉘어 Fig. 5와 Fig. 6에 표시되었으며, 그 밖의 결과들은 5장에서 다루었다.

이들 결과들은 실험적 방법으로 타당성을 검증한 후 인공신경회로망의 학습 데이터로 사용될 것이다.

4. Hole-Drilling 방법에 의한 학습 데이터의 검증

4.1 Hole-Drilling 방법의 적용

앞에서 계산된 용접 잔류응력을 신경회로망에 학습시키기 전에 이들 해석 결과의 타당성 및 신뢰성이 요구되므로, 실험적 방법으로 이를 검증하기 위하여 hole-drilling 방법을 사용하였다.

무척 작은 구멍을 잔류응력이 존재하는 물체에 뚫으면, 자유 표면의 응력이 '0'이 되어야 한다는 이유에서 그 부분의 응력이 노출되게 되는데, 이 때에 구멍 면에 존재했던 반경 방향 응력(radial stress)의 제거는 구멍 근방의 응력을 변화시키고, 그에 따라 측정 물체의 표면에서는 구부 응력이 변화하게 된다. 여기서, 구멍 주위의 변형률의 변화를 측정함으로써 물체가 원래 가지고 있었던 잔류응력을 계산해 낼 수 있다.

실제 적용에 있어서, 구멍은 관통 구멍(through-hole)이 아니라, 깊이는 대략 구멍 지름과 같고 측정 물체의 두께에 비해 작은 비관통구멍(blind-hole)을 사용하였다. 비관통구멍은 관통 구멍에 비하여 구조가 복잡하기 때문에 측정된 변형률로부터 잔류응력을 계산하기 위해 탄성이론을 직접 이용하기는 어려우므로, 해를 얻기가 쉬운 관통 구멍에 hole-drilling법을 적용시켜 이론적 근거를 얻어내고, ASTM 규격에 따라 비관통구멍에 확장시켜 적용하였다¹¹⁾.

4.2 실험 시편 제작

용접 구조물의 잔류응력을 측정함에 있어서 용접 시편의 크기는 실제 구조물에 존재하는 정도의 잔류응력을 포함할 수 있도록 충분한 크기를 갖고 있어야 한다.

본 논문에서는 위에서 고려한 용접구조물의 길이 및 너비효과를 감안하여 다음과 같이 용접 시편을 제작하였다. 용접모재는 일반 용접 구조물로 가장 많이 사용하는 SS41을 사용하였다. 너비 100mm, 길이 150mm, 두께 6mm의 시편을 전류와 전압을 변화 여가며, 토치 간격 15mm의 탄산가스 V형 맞대기 2단 용접하였다. 첫 번째 패스는 용접 속도, 9 mm/sec로 220A, 27V의 조건에서 용접을 수행하였고, 두 번째

패스는 용접 속도, 9.4mm/sec 로 전류 $250\sim 285\text{A}$, 전압 $30\sim 35\text{V}$ 를 적절히 조정하여 가며 용접을 수행하여 4개의 시편을 제작하였다. 용접은 현대 중공업 주식회사의 용접 로봇과 조흥 전기 산업 주식회사의 탄산가스 아크 용접기를 사용하여 수행하였으며 이때 shielding gas로는 15 l/min 유량의 탄산가스만을 사용하였다.

실험에 사용된 시편은 Fig.7에 묘사되어 있다.




Fig. 7 Schematic Draft of Weldment

4.3 실험 과정 및 결과

앞 절에서 언급한 원리를 바탕으로 위에서 용접된 시편의 잔류응력을 측정함에 있어, 스트레인 게이지, 변형을 측정장치 그리고 구멍 뚫기 작업등은 보다 정확한 실험 결과를 위해 매우 신중히 결정되었다.

중앙을 중심으로 세 개의 서로 다른 스트레인 게이지를 일정한 각도와 거리를 유지하도록 시편에 부착하는 일은 대단히 힘든 일이다. 그러므로 본 연구에서는 세 개의 grid가 한 게이지안에 들어 있는 rosette strain gage를 사용하였다. 변형을 측정장치로는 고정밀도의 digital strain indicator를 사용하였고, switch & balance unit을 사용하여 세 개 이상의 다출력을 동시에 얻음으로써 구멍 뚫기 작업시 한번에 세 개의 변형율을 얻을 수 있었다. 구멍은 드릴의 진동에 관계없이 게이지의 중심에 매우 정밀하게 가공되어야 함으로 milling guide라는 보조장치를 사용하였다¹¹⁾.

Fig.7에 나타난 것과 같이 스트레인 게이지는 시편의

용접 중심선을 기준으로 한쪽 면에 5개를 부착하였으며, 중심에서 멀어질수록 배치 간격을 크게 하여 게이지를 절감하였다. 구멍은 게이지의 특성을 고려하여 드릴 지름을 1.5875mm 로 정했으며, 구멍 깊이 1.5875mm 를 밀링 가이드를 사용하여 10단계로 나누어 뚫었다. 검출된 변형율에 의해 주응력을 계산하고 이를 바탕으로 종방향 잔류응력과 횡방향 잔류응력을 계산하였다. 이와 같은 과정을 4개의 시편에 반복적으로 수행하였다. 잔류응력은 중심선을 중심으로 감소되는 경향을 보였으며, 끝단에 가까워지면 그 크기가 급격히 줄어들고, 그 최대 값은 항복응력보다 약간 큰 수치를 보여주고 있다.

이상에서의 결과를 수치해석의 결과와 비교하여 각각의 용접조건에 대한 실험치와 해석치의 비교를 Fig. 8에 나타내었다. 전반적으로 응력분포의 경향은 일치하였으나 정상적인 문제에서 약간의 오차를 발견할 수 있었다. 이는 실험과정에서 발생한 오류와 해석 조건의 몇몇 가정에서 기인한 것으로 생각된다. 특히 작은 구멍을 정확한 게이지 중심에 정확하게 뚫어야 하는 실험과정은 오차의 발생 요인을 다소 포함하고 있다고 생각할 수 있다.

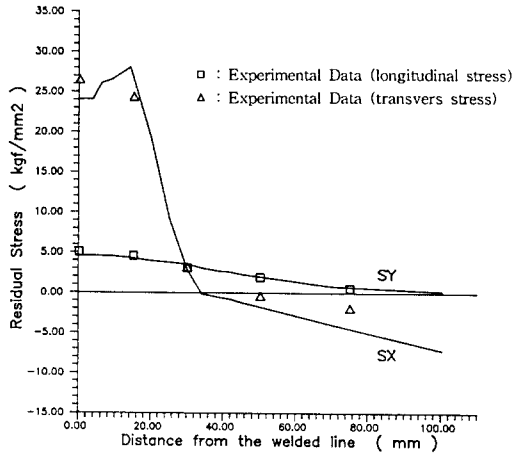
본 연구의 목적상, 해석에 의한 결과값은 실험에 의한 결과 값과 비교해 볼 때, 어느 정도 신뢰성을 지니고 있다고 판단되므로 인공 신경망 회로에 학습시켜 잔류응력을 예측하는데 필요한 적절한 데이터라 할 수 있었다.

5. 인공신경회로망에 의한 잔류응력 예측

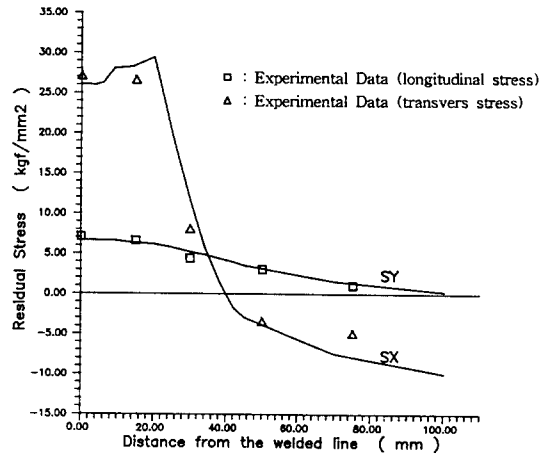
5.1 학습과정 및 데이터 처리

인공신경회로망은 많은 변수들이 매우 심한 비선형성을 나타내는 공정에 효과적으로 사용할 수 있으므로, 이를 탄산가스 아크 용접에 의한 용접 후 잔류응력 예측에 적용하여 기존의 예측방법에 새로운 대안을 제시하였다.

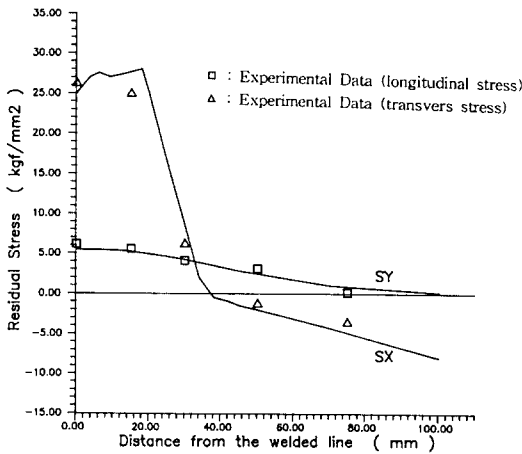
용접은 전류와 전압을 변화 하여가며 수행되었으므로, 입력 변수는 전류와 전압으로 정하였고 활성화 함수로 사용된 sigmoid 함수의 특성상 각각 $0.1\sim 0.9$ 사이의 값으로 표준화(normalize)하여 사용하였다. 출력 변수는 실험적 신뢰성이 입증된 유한요소법에 의한 실험적 결과치, 즉, 종방향 응력과 횡방향 응력을 역시 $0.1\sim 0.9$ 사이의 값으로 표준화하여 적용하였다.




(a) 2nd pass : 250A, 30V



(c) 2nd pass : 270A, 33V



(b) 2nd pass : 260A, 33V



(d) 2nd pass : 285A, 35V

Fig. 8 Comparison of Experimental Data with Analysis Data (1st pass : 220A, 27V)

여기서 각 node와 node 사이의 응력 변화는 거의 선형적이므로 수치해석 모델과 비슷한 비율의 절점 분할을 출력 층에 적용하였다. 표준화는 식 (3)을 사용하였으며, 출력단에 나온 결과는 식 (4)를 이용하여 실제 응력값을 산출하였다.

$$\frac{(0.9-0.1)}{x_{\max}-x_{\min}} \times (x-x_{\min}) + 0.1 \quad (3)$$

$$\frac{x_{\max}-x_{\min}}{(0.9-0.1)} \times (x-0.1) + x_{\min} \quad (4)$$

은닉층을 결정하기 위하여 기존의 연구를 참고하여 node의 수가 각각 10, 20인 단층 perceptron 모델과 10×10, 15×15, 20×20, 25×25인 다층 perceptron 모델을 본 연구에 적용한 결과, 모델에 따라 학습율이 각각, 79.2%, 82.5%, 91.7%, 94.1%, 95.3%, 95.1%를 나타내었다. 이에 따라, 다른 모델보다 학습율이 높고, 오차율이 적은 20×20의 형태의 은닉층을 최종적으로 선택하였다.

학습에 필요한 자료는 전류, 전압이 각각 220~285A, 27~35V로 변화하여 가며 계산된 데이터를 기초로 하였으며, 각 데이터의 잔류응력 분포 변화가 그다지

크지 않으므로 학습에 필요한 입력 node의 수는 14개로 한정시켰다. 또한, 학습율 0.7과 momentum rate 0.9를 신경회로망에 사용하였으며, 최대 반복 횟수를 10000번으로 정하였다.

5.2 잔류응력 예측

이상의 학습 방법에 의해 인공신경회로망을 학습시킨 결과 95.3%의 학습율을 얻을 수 있었고, 학습된 범위 내에서의 잔류응력 결과는 최고 오차 6.7%를

Table 2. Error for the FEM & Neural Network(Longitudinal Residual Stress, 1st pass : 220A, 27V)

Residual Stress of Longitudinal Direction(kgf/mm ²)						
No.	255A			33V		
Node	2nd Pass FEM	Neural	Error %	2nd Pass FEM	Neural	Error %
1	26.17	26.32	0.57	25.04	25.12	0.32
2	27.54	27.58	0.15	27.03	27.31	1.04
3	27.53	27.83	1.09	27.52	27.68	0.58
4	27.16	27.36	0.74	27.19	27.56	1.36
5	29.09	29.11	0.07	27.51	27.60	0.33
6	21.52	21.63	0.51	25.85	25.87	0.08
7	13.19	13.23	0.30	16.50	16.79	1.76
8	5.01	5.12	2.20	8.60	8.71	1.28
9	0.43	0.45	4.65	2.01	2.02	0.50
10	-0.11	-0.11	0.00	-0.51	-0.52	1.96
11	-0.65	-0.63	3.08	-0.98	-0.99	1.02
12	-1.00	-1.01	1.00	-1.58	-1.59	0.63
13	-4.21	-4.23	0.48	-4.31	-4.33	0.46
14	-0.04	-6.09	0.83	-8.03	-8.06	0.37


Table 3. Error for the FEM & Neural Network(Transverse Residual Stress, 1st pass : 220A, 27V)

Residual Stress of Transvers Direction(kgf/mm ²)						
No.	255A			33V		
Node	2nd Pass FEM	Neural	Error %	2nd Pass FEM	Neural	Error %
1	5.01	5.06	1.00	5.40	5.42	0.37
2	4.98	5.01	0.60	5.39	5.41	0.37
3	4.97	5.00	0.60	5.38	5.40	0.37
4	4.94	4.99	1.01	5.35	5.36	0.19
5	4.75	4.93	3.79	5.25	5.27	0.38
6	4.35	4.56	4.83	4.91	4.98	1.43
7	4.11	4.11	0.00	4.60	4.63	0.65
8	3.70	3.71	0.27	4.23	4.25	0.47
9	3.39	3.51	3.54	3.85	3.86	0.26
10	3.05	3.04	0.33	3.51	3.55	1.14
11	2.73	2.77	1.47	3.13	3.17	1.28
12	2.49	2.48	0.40	2.84	2.85	0.35
13	0.75	0.76	1.33	1.05	1.09	3.81
14	0.15	0.14	6.67	0.17	0.17	0.00


넘지 않았다. 이는 임의의 전류, 전압을 신경회로망에 입력했을 때 나오는 출력을 비교하여 알 수 있었으며, 이 결과중 대표적인 예를 longitudinal 방향과 transverse 방향으로 나누어 Table 2와 Table 3에 나타내었다.

10개의 학습 데이터와 같은 입력을, 학습된 예측 프로그램에 적용하였을 경우 결과 값은 학습 데이터와 거의 차이를 못 느낄 정도였고, 학습된 데이터 사이의 값을 입력하여 인공신경망을 이용하였을 경우 출력은 학습된 출력 데이터의 사이에 있는 값을 얻을 수 있었다.

임의의 전류, 전압에 의한 잔류응력 예측 결과를



(a) 2nd pass : 257A, 32V by Neural Nets



(b) 2nd pass : 275A, 34V by Neural Nets

Fig. 9 Verification of Predicted Data (1st pass : 220A, 27V)

Fig. 9에 나타내었다. Fig. 9는 학습으로 얻어진 신경회로망의 종방향 잔류응력 예측결과를 유한요소법에 의해 수치해적인 방법으로 얻어진 데이터를 이용하여 검증한 것이다. (a)는 255×32 Watt의 입열에 대한 수치해와 260×33 Watt의 입열에 대한 수치해를 점선으로, 인공신경회로망에 의해 얻어진 257×32 Watt 입열에 대한 잔류응력을 실선으로 비교한 그래프이며, (b)는 270×33 Watt의 입열에 대한 수치해와 280×34 Watt의 입열에 대한 수치해를 점선으로, 인공신경회로망에 의해 얻어진 275×34 Watt 입열에 대한 잔류응력을 실선으로 비교한 그래프이다. 그림에서 알 수 있듯이 두 수치해 사이의 임의의 입력에 대해, 제안된 예측법은 수치해 범위 안에서 그 예측값을 나타내는 안정성을 보이고 있다. 다만, 용접 중심선 부근의 결과에서 새로운 예측법에 의한 결과가 수치해에서 약간의 벗어남을 볼 수 있는데, 이는 학습에 사용된 데이터의 node 수를 결정함에 있어 14개로 한정하였기 때문에 peak점에 대한 node 값이 고려되지 않은 이유에 기인한 것으로 보인다.

본 연구에서 제시된 잔류응력 예측방법은 기존의 예측방법과 비교하여 볼 때 신뢰성 문제에 있어서 수치해석적 기법과 큰 차이가 없을 뿐 아니라, 경제적인 측면에서도 실험적 방법이나 수치적 계산 방법에 비해 월등히 우수함을 알 수 있었다. 이 방법에 의해 적절한 데이터로 학습된 용접공정의 경우, 매우 신속하고 정확하게 용접 잔류응력을 구할 수 있으므로 산업 현장에 쉽게 응용이 가능하며, 품질 및 생산성 향상에 큰 도움을 줄 수 있으리라 생각된다.

6. 결 론

지금까지 유한요소법과 인공신경회로망을 이용하여 연강의 탄산가스 아크 맞대기 용접의 잔류응력 예측 방법에 관하여 알아보았다. 이상의 연구에서 다음과 같은 결론을 얻었다.

1. 유한요소법을 이용하여 탄산가스 아크 용접의 3차원 열전도 해석을 수행하였으며, 열전도 해석 결과를 응력해석에 적용하여 용접 잔류응력을 해석하였다.
2. 각각 다른 용접조건으로 탄산가스 아크 맞대기 용접을 실시한 후, Hole-Drilling 방법으로 잔류응력을 측정하여 부위에 따른 잔류응력의 분포 및 특성을 알

수 있었다.

3. 다양한 수치해석 결과를 실험치와 비교하여 유한요소법을 이용한 수치해석의 신뢰성을 입증하였다.

4. 수치해석에서 얻은 결과를 인공신경망에 학습시켜 주어진 범위 내의 전류, 전압에 대한 잔류응력을 구할 수 있는 새로운 예측법을 제시하였다.

5. 본 연구에 의한 예측 결과는 신속성과 정확성 면에서 기존의 방법보다 우수함을 알 수 있었다.

참 고 문 헌

1. 엄기원 : 최신 용접공학, 서울, 동명사 (1992)
2. Masubuchi, K : Analysis of Welded Structures, Oxford Pergamon Press(1980)
3. Lippmann, Richard P. : "An Introduction to Computing with Neural Nets.", IEEE Assp Magazine (1987)
4. Rosenthal, D. : "Mathematical Theory of Heat Distribution during Welding and Cutting." Welding Journal, 20(1941)
5. Hibbit, H. D., and P. V. Marcal : "A Neumerical Thermo-Mechanical Model for the Welding and Subsequent Loading of a Fabricated Structure." Computers and Structures, 3(1973)
6. Friedman, E. : "Thermomechanical Analysis of the Welding Process Using the Finite Element Method." ASME Journal of Pressure Vessel Technology, 97(1975)
7. Tekriwal, P., M. Stitt and J. Mazumder : "Finite Element Modeling of Heat Transfer for Gas Tungsten Arc Welding." Metal Construction, 19(1987)
8. Tekriwal, P. and J. Mazumder : "Finite Element Analysis of Three-Dimensional Transient heat Transfer in GMA Welding." Welding Journal, 67(1988)
9. Tekriwal, P and J. Mazumder : "Transient and Residual Thermal Strain-Stress Analysis of GMAW." Transactions of the ASME Journal of Engineering Materials and Technology, 113 (1991)
10. Rendler, N. J. and I. Vigness : "Hole-drilling Strain-gage Method of Measuring Residual Stresses." Experimental Mechanics (1966)
11. "Measurement of Residual Stress by the Hole-Drilling Strain Gage Method." Measurement Group Tech Note TN-503-3(1988)