

**研究論文**

大韓熔接學會誌  
第11卷 第4號 1993年 12月  
Journal of the Korean  
Welding Society  
Vo1.11. No.4, Dec., 1993

## 신경회로망을 이용한 필렛 이음부의 가스메탈 아크용접변수 선정에 관한 연구

문형순\* · 이승영\* · 나석주\*

### **A Study on Selection of Gas Metal Arc Welding Parameters of Fillet Joints Using Neural Network**

H. S. Moon\*, S. Y. Lee\* and S. J. Na\*

**Key Words :** Welding Parameter(용접변수), Leg Length(각장), Fillet Joint(필렛 이음부),  
Penetration(용입), Neural Network(신경회로망)

#### **Abstract**

The arc welding processes are substantially nonlinear, in addition to being highly coupled multivariable systems. Frequently, not all the variables affecting the welding quality are known, nor may they be easily quantified. From this point of view, decoupling between the welding parameters from the welding quality is very difficult, which makes it also difficult to control the welding parameters for obtaining the desired welding quality.

In this study, a neural network based on the backpropagation algorithm was implemented and adopted for the selection of gas metal arc welding parameters of the fillet joint, that is, welding current, arc voltage and welding speed. The performance of the neural network for modeling the relationship between the welding quality and welding parameters was presented and evaluated by using the actual welding data. To obtain the optimal neural network structure, various types of the neural network structures were tested with the experimental data. It was revealed that the neural network can be effectively adopted to select the appropriate gas metal arc welding parameter of fillet joints for a given weld quality.

---

\* 정회원, 한국과학기술원 정밀공학과

## 1. 서 론

수동용접이나 자동용접시 각장(leg length)이나 용입깊이(depth of penetration) 등, 용접품질에 영향을 미치는 인자를 원하는 값으로 얻기위하여 선정해야 할 용접변수—전압, 전류, 용접속도—들은 각각 서로 연관되어 있다. 이와같이 용접품질에 대한 변수들의 관계가 비선형성의 특징을 가지므로 이를 관계에 대한 영향력을 수학적으로 모델링 하는데는 여러가지 어려운 점이 있다.

용접품질에 대한 용접변수를 제어하기 위한 방법으로 와이어 공급속도와 루트 간격(root gap)사이의 관계를 실험적으로 구하거나<sup>1)</sup> 용접속도와 비드(bead) 형상에 대한 정보를 이용하여 용접부를 제어하는 방법<sup>2)</sup>등이 발표되었으나 이들 방법들은 용접변수 전체를 고려하지 않고 용접변수 각각에 대한 용접부의 특성을 실험적으로 구하여 용접부를 제어하고자 하였다. 따라서 용접부의 형상을 결정하는데 있어서 서로 연관된 특성을 가지는 용접변수들에 대해서는 전반적으로 고려되지 않았다.

원하는 용접품질에 대한 적절한 용접변수를 얻기 위해서 열전달에 대한식을 유도하고<sup>3)</sup> 이식을 이용하여 주어진 용접변수에 대해서 용접품질을 예측할 수도 있으나<sup>4)</sup>, 프로그램 수행시간이 오래 걸리고 채택된 물성치에 의해서 그 정확도가 변하는 단점이 있다.

수학적으로 모델링이 어려운 비선형성의 특성을 표현하는 방법으로는 퍼지(fuzzy)이론, 전문가 시스템(expert system), 이 둘의 특성을 살린 퍼지—전문가 시스템(fuzzy—expert system), 그리고 신경회로망등이 있다. 지금까지 이러한 방법들은 많은 분야에 적용되고 있으며 특히 용접공정에 적용된 사례를 들어보면 비선형성의 특성을 갖는 용접공정을 제어하기 위한 퍼지제어기 설계를 행한 예가 있고<sup>5)</sup>, 음향신호(acoustic signals)를 이용한 용접품질 실시간 분류를 위해서 신경회로망을 적용한 경우등이 있다<sup>6)</sup>.

본 연구에서는 신경회로망을 이용해 원하는 필릿 이음부의 용접품질에 대한 용접변수를 보다 쉽게 얻을 수 있는 시스템의 구성방법을 제시하고자 하며 신경회로망에 의한 모델링과 실제 실험한 데이터를 이용하여 학습된 신경회로망에 대한 신뢰성을 시험하였다.

## 2. 신경회로망의 이론적 배경

신경회로망의 독특한 특성은 학습에 의한 추상적인 추론을 할 수 있으며 신호 형태를 인식하는데 있어 오류에 민감하다는 것이다. 이와 같은 이유로 신경회로망은 화상과 신호처리에 기초를 둔 패턴인식등에 점점 많이 이용되고 있다. 신경회로망의 구성은 입출력층과 은닉층(hidden layer)으로 크게 구분할 수 있으며 정보의 흐름은 오직 한 방향으로만 이루어 진다. 이는 각 계산단위가 그 결과를 다음 층에만 보낸다는 의미인데 하나의 중앙처리장치를 가진 컴퓨터 시스템과 비교해보면 이 구조는 많은 수의 계산단위가 동시에 작용함으로서 고 수준의 병렬처리 과정을 나타내는 것이다<sup>7)</sup>.

신경회로망의 특성으로는 여러가지가 있는데 우선 기본 처리단위가 간단하다는 특성을 들 수 있다. 즉 아주 간단한 기능을 가진 프로세서들이 모여서 고도로 복잡한 문제를 해결할 수 있다. 분산표현으로써, 데이터는 전체망 구조에 연결되어 있는 각 연결강도(weight)의 값들에 의해 기억된다. 또한 몇개의 처리단위가 망기져도 전체망의 정확도는 크게 떨어지지 않는다. 신경회로망은 새로운 패턴을 학습하기 위해 스스로 연결강도를 조정할 수 있으며, 입력과 출력 간의 관계를 수학적으로 표현하기 어려운 경우에도 이를 사이의 관계를 연결강도를 이용해서 나타낼 수 있다.

다음은 신경회로망을 구성하는 입출력 및 가중치를 나타내는 표현식이다. 에너지 함수(cost function) J는 다음과 같이 표현될 수 있다.

$$J = (1/2) \sum_p \sum_k (D_k - A_k)^2 \quad (1)$$

여기서,

p : 패턴 개수

D<sub>k</sub> : k번째 노드에서의 원하는 출력

A<sub>k</sub> : k번째 노드에서 나오는 실제 출력

신경회로망을 학습시키는 것은 에너지 함수를 최소화하기 위해 각 연결강도를 최적화시키는 과정이며 이를 위한 알고리즘은 다음과 같다.

$$H_i = S(\sum_i W_{ij} S_j) \quad (2)$$

$$Ak = S(\sum W_{jk} H_j) \quad (3)$$

$$NET = \sum W_{ij} S_i \quad (4)$$

본 연구에서 사용한 활성화 함수(activation function)는 아래 식과 같은 시그모이드(sigmoid) 함수를 사용하였다.

$$S(NET) = 1.0 / (1.0 + \exp(-NET))$$

여기서,

$S_i$  : 각 패턴에 따른 입력

$H_j$  :  $j$ 번째 은닉층(hidden layer)에서의 출력

$W_{ij}, W_{jk}$  : 연결강도

$S(NET)$  : 시그모이드 함수

신경회로망을 학습시키는 방법은 에너지 함수를 최소화하도록 연결강도를 계속 변경시켜 줘야하는데 이에 관한 배경은 다음과 같다. 연결강도들을 변경시켜 주기 위해서 이들을 다음과 같이 정의한다<sup>8)</sup>.

$$W_{ij}(t+1) = W_{ij}(t) - \eta \frac{\partial J}{\partial W_{ij}} \quad (5)$$

$$W_{jk}(t+1) = W_{jk}(t) - \eta \frac{\partial J}{\partial W_{jk}} \quad (6)$$

$$-\eta \frac{\partial J}{\partial W_{jk}} = \eta \sum_p \delta_{kp} H_{jp} \quad (7)$$

$$-\eta \frac{\partial J}{\partial W_{ij}} = \eta \sum_p \delta_{ip} H_{jp} \quad (8)$$

여기서,

$t$  : 반복 횟수(iteration number)

$\eta$  : 학습율(learning rate)

$$\delta_{kp} = S'( \sum_j W_{jk} H_{jp} ) (D_{kp} - A_{kp})$$

$$\delta_{jp} = S' ( \sum_i W_{ij} S_{ip} ) \sum_k W_{jk} \delta_{kp}$$

신경회로망에서 기억이란 각 신경세포간의 연결강도에 대한 크기로 나타내며, 학습이란 연결강도의 크기를 변화시키는 것이다. 따라서 에너지 함수가 최소가 되도록 하는 과정은 학습을 주어진 패턴에 맞게 연결강도를 변경시킨다는 개념이다.

### 3. 신경회로망을 이용한 용접변수 결정

용접공정에서 나타나는 여러가지 용접변수들은 서로 상관관계를 가지므로 용접변수에 대한 용접품질의 관계를 정량화시키는 데는 많은 문제점을 가지고 있다. 따라서 실제 용접공정에서 모재의 두께, 각장, 용입깊이등에 따라 용접변수 – 아크전압, 용접전류, 용접속도 – 를 결정하는데는 여러가지 어려움이 있다. 용접변수와 그에 따른 용입깊이, 비드폭과의 관계를 살펴보면 다음과 같다. 용접전류를 높게하면 용입깊이가 커지고 비드폭은 거의 일정하며 아크전압을 증가시키면 용입깊이는 감소하고 비드폭은 커지게 되고 용접속도를 증가시키면 비드폭은 감소하고 용입깊이는 증가했다가 감소하게 된다<sup>9)</sup>. 이러한 인자들의 관계는 특히 수학적 모델링이 거의 불가능 하므로 실제 현장에서 용접할 때 각 모재의 두께에 따른 적절한 용접조건을 얻기 위해서는 시행착오법에 의한 실험적 데이터에 의존할 수 밖에 없다.

용접변수를 선정할때 시행착오를 많이 거치지 않고 적절한 용접변수를 선정하기 위하여 본 연구에서는 신경회로망을 이용하여 위의 복잡한 문제점을 해결하고자 한다. 이를 위한 신경회로망 구성도를 Fig.1에 나타내었다.

용접방법은 필럿용접이고 실험횟수는 각 모재 두께당 12번의 실험을 하였으며 모재 두께는 4.5mm, 6 mm, 7mm의 연장을 대상으로 하였다. 학습에 대한 예측능력을 시험하기 위하여 학습데이터를 각각 15, 30개에 대하여 신경회로망을 학습시키고 임의의 9개 실험데이터를 이용하여 구성된 신경회로망에 대한 예측능력을 평가하였다. 여기서 각각의 실험데이터를 학습데이터로 사용하기 위해서는 신경회로망의 시그모이드 함수의 특성에 의해 입력데이터를 0 ~ 1 사이의 값을 갖도록 해줘야 하며<sup>10)</sup> 이를 위해서 본 연구에서는 각각의 값들을 (9)식과 같이 0.1~0.9 사이의 정규화된 값이 되도록 변경시켜 주었다.

$$[(0.9 - 0.1) / (\text{Value(max)} - \text{Value(min)})] \cdot (\text{Value} - \text{Value(min)}) + 0.1 \quad (9)$$

여기서  $\text{Value(max)}$ 는 사용하고자 하는 값의 최대값을 의미하며  $\text{Value(min)}$ 은 최소값, 그리고  $\text{Value}$ 는 실제값을 의미한다<sup>11)</sup>. 값들을 0.1~0.9사이로 변경시킨

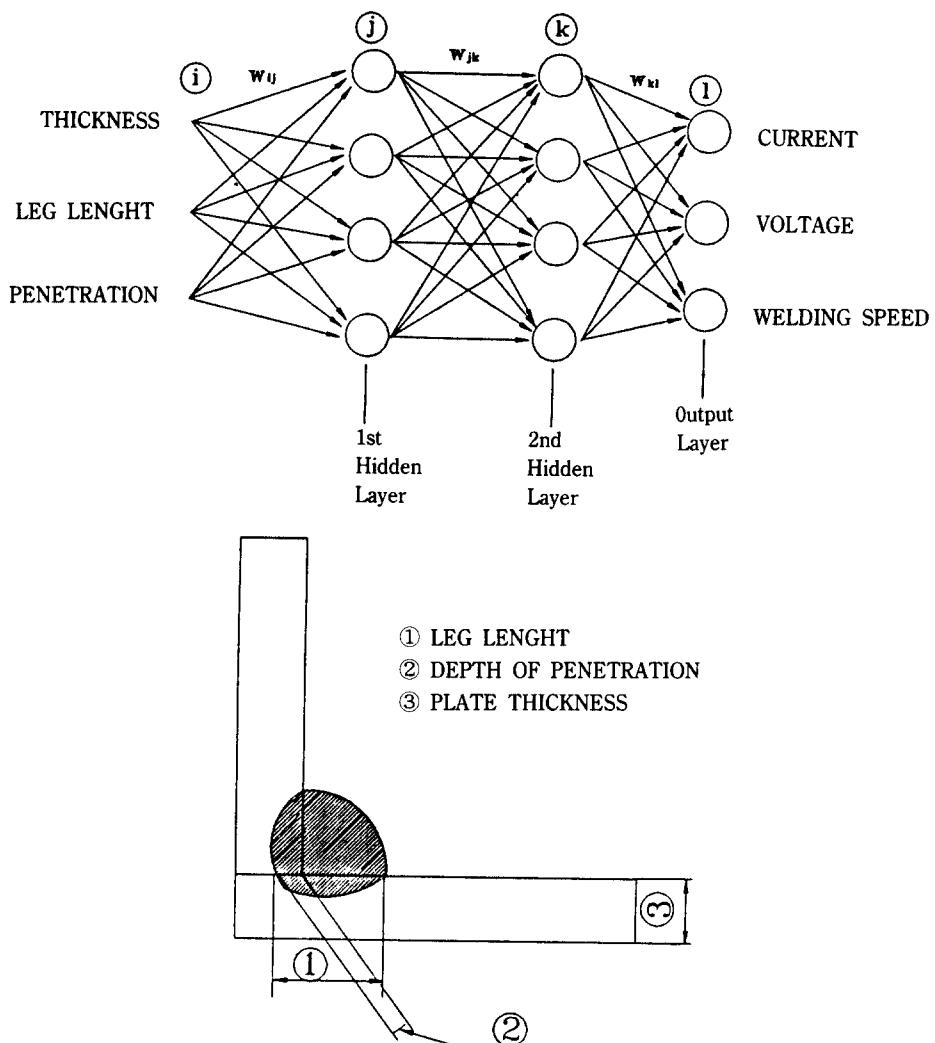
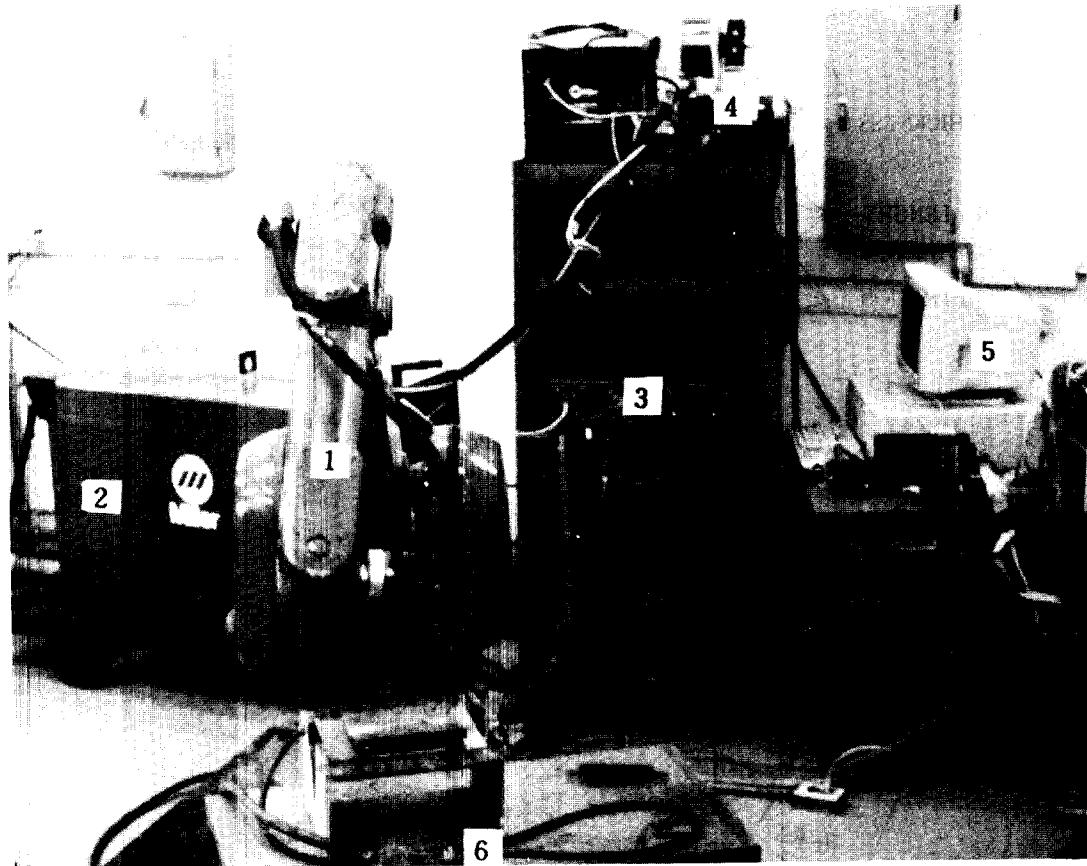


Fig. 1 Neural Network for determining welding parameters and geometry of fillet weldment

이유는 시그모이드 함수의 특성에 의해 0과 1의 값으로 수렴하기가 매우 어려우며 이 때문에 과도한 학습이 일어날 수 있기 때문이다. 신경회로망을 학습시킬 때 에너지 함수값은 계속 감소하게 되고 이 값이 어느 범위에 들면 학습을 중단하게 된다. 그러나 학습률  $\eta$ 가 클 경우 에너지 함수값의 진동(oscillation) 현상이 일어나고 이로 인해 수렴속도가 느려지는 경향이 나타난다. 이러한 경향을 방지하기 위하여 연결강도 조절시 모멘텀(momentum)항을 추가로 사용했으며 반복학습 범위를 주기 위하여 학습시 에러(error)범위를 0.01로 하였다.

#### 4. 실험결과 및 고찰

원하는 용접품질에 대한 용접변수들을 예측하는 신경회로망을 구성하기 위하여 여러 가지 실험 데이터가 필요하며 이에 대한 실험장치를 Fig.2에 나타내었다. 보호가스는 Ar 80%, CO<sub>2</sub> 20%인 혼합가스를 사용하였으며 용접와이어는 직경 1.2mm인 솔리드 와이어(solid wire)인 AWS ER70S-6을 사용하였다. 실험한 시편의 단면도를 Fig. 3-(a), 3-(b), 3-(c), Fig.



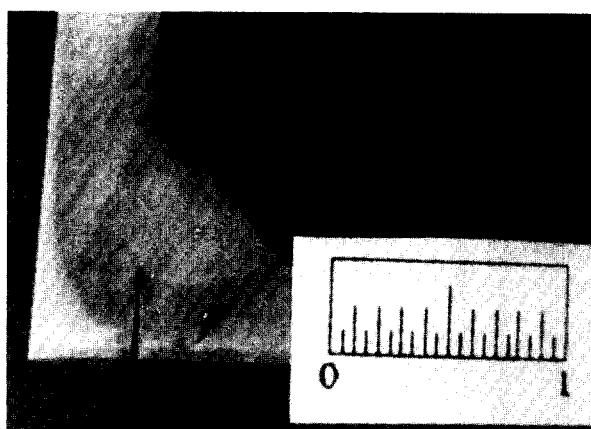
1 : IRB 2000 Industrial Robot  
 2 : Welder  
 3 : Robot Controller-Welder Interface Circuit  
 4 : Wire Feeder  
 5 : 286 Personal Computer  
 6 : Shunt Resistor  
 7 : Robot Controller-Computer Interface Circuit

**Fig. 2** Overview of experimental apparatus

4-(a), 4-(b), Fig. 5-(a), 5-(b)에 나타내었다. Fig. 3에는 모재의 두께, 용접속도가 같을 경우 용접전류 및 아크전압에 따른 각장과 용입깊이의 경향을 나타내었으며 아크전압이 클 수록 아크길이(arc length)가 길어지게 되고 아크 분위기(arc atmosphere)가 넓은 영역에서 형성되므로 각장이 커지게 됨을 알 수 있다. 반면 아크분위기가 넓은 영역에서 형성되므로 입열량(heat input)이 모재의 한 부분에 집중되지 않고 따라서 용입깊이가 작아지게 된다. 용접전류의 경우는 값이 커질 수록 입열량이 증가하고 이로인해 용입깊이 및

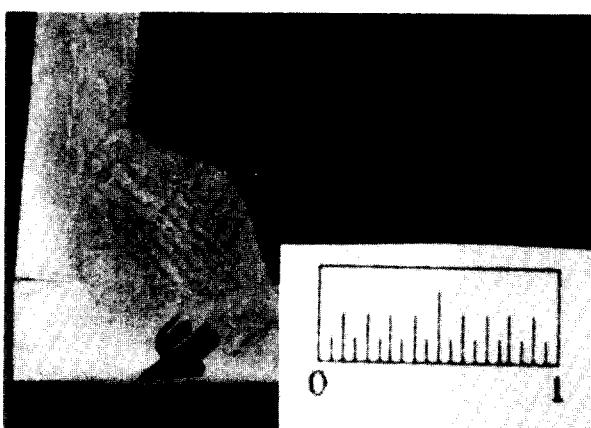
각장이 커지게 된다. 본 실험에서는 아크전압에 의한 용입깊이의 감소보다 용접전류에 의한 용입깊이의 증가율이 크므로 전체적으로 용입깊이와 각장이 증가한 것으로 생각된다.

Fig. 4는 모재의 두께, 용접전류 그리고 아크전압이 같을 경우 용접속도에 따른 각장 및 용입깊이의 경향을 비교하기 위하여 나타내었다. 본 연구에서는 용접속도를 4, 6(mm/sec)의 범위만을 대상으로 실험하였는데 실험적으로 구한 결과는 용접속도가 증가할수록 용입깊이는 증가하였으며 이는 낮은 용접속



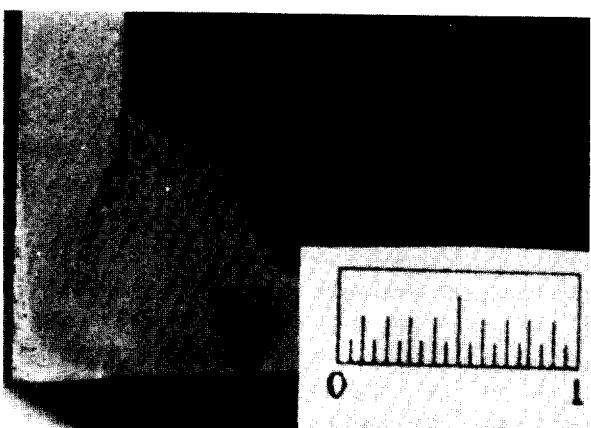
Thickness = 4.5 (mm)  
Voltage = 19 (V)  
Current = 200 (A)  
Welding speed = 4 (mm/sec)

(a)



Thickness = 4.5 (mm)  
Voltage = 21 (V)  
Current = 240 (A)  
Welding speed = 4 (mm/sec)

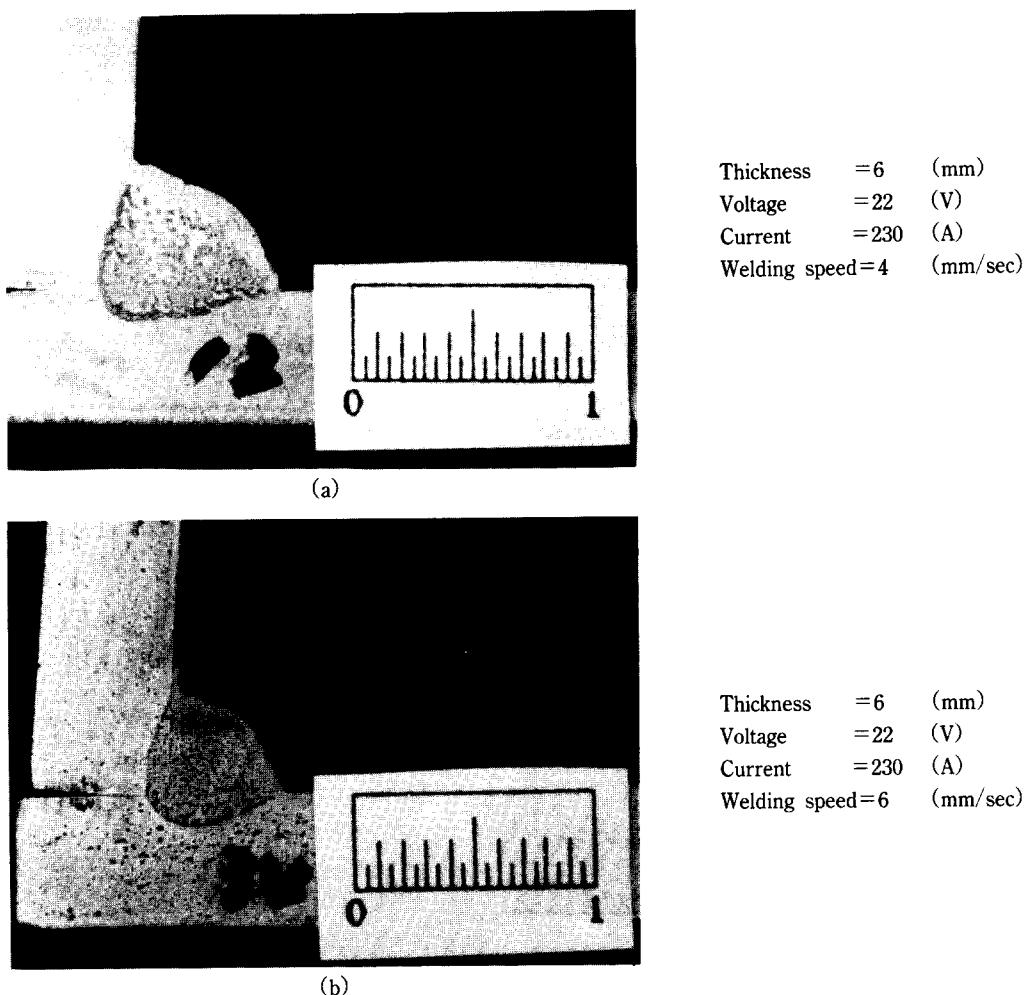
(b)



Thickness = 4.5 (mm)  
Voltage = 23 (V)  
Current = 260 (A)  
Welding speed = 4 (mm/sec)

(c)

**Fig. 3** Change of weld bead shape for various welding conditions



**Fig. 4 Change of weld bead shape for different speeds**

도일 경우 용융 풀(molten pool)이 아크의 영향을 완충하는 역할을 한 결과로 판단된다. 반면 용접속도가 감소할 수록 용착금속은 많아지고 이로인해 각장이 증가하는 경향을 나타내었다.

Fig. 5는 용접전류 및 용접속도를 동일하게 두고 모재의 두께를 달리 했을 때 나타나는 용입깊이 변화를 보이고 있다. 이 결과에서 모재의 두께가 얇을 수록 용입깊이가 깊었는데 이는 열전도가 후판의 경우보다 다소 느린 결과로 판단된다.

위의 실험데이터를 이용하여 용접품질을 입력으로 하고 이를 얻기위한 용접변수들을 출력으로 하는 구조를 다층 신경회로망을 이용하여 구현하였다. 일반적으로 생각하면 학습데이터가 많을 수록 구성된 신

경회로망의 예측능력이 좋을 것으로 판단되나 실제로는 은닉층의 처리단위에 따라서 학습의 정확도가 달라질 수 있다. 따라서 예측성능이 좋은 적절한 신경회로망 구조를 얻기위해서는 다양한 구조의 신경회로망을 통하여 가장 오차가 적은 구조를 시행착오법으로 찾아내야만 한다. 예측능력을 검증하기 위해 모재의 두께, 각장, 용입깊이를 하나의 입력 패턴으로 하고 전압, 전류, 용접속도를 출력 패턴으로 하는 실험데이터를 사용하였다. Table 1에는 학습데이터의 입, 출력 패턴이 15개 검증데이터가 9개인 경우를 Table 2에는 학습데이터의 입, 출력 패턴이 30개 검증데이터가 9개인 경우를 나타내었다. Fig. 6에는 학습데이터가 각각 15, 30개에 대하여 입력노드수가 3개, 첫번째

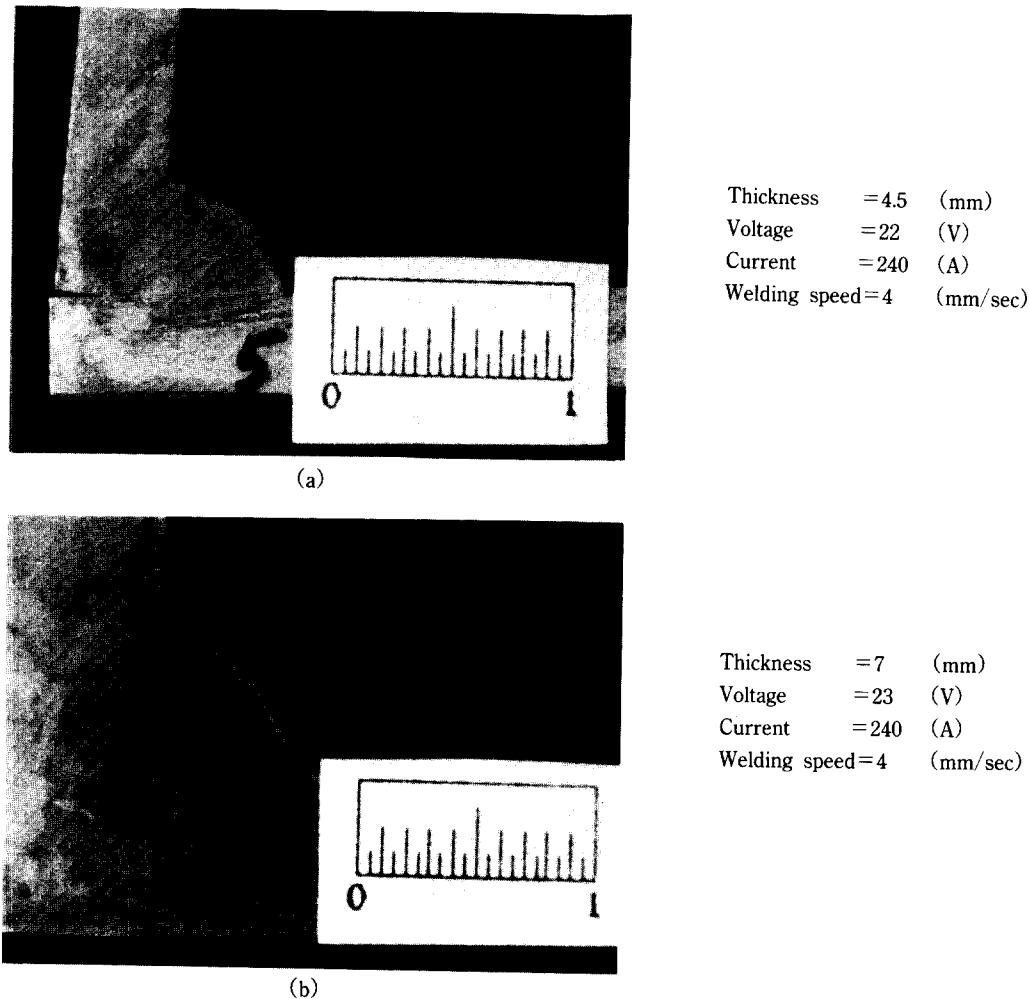


Fig. 5 Change of weld bead shape for different thicknesses

은닉층의 노드(node)수가 7개, 두번쨰 은닉층의 노드수가 7개 그리고 출력노드수가 3개의 구조를 가지는 3-7-7-3의 신경회로망을 통해서 예측된 값들사이의 오차율을 도식적으로 나타내었다. Fig. 6에서 보면 학습데이터의 전체범위 - 학습데이터의 상한 및 하한 - 가 같을 경우 학습데이터 갯수가 30개인 경우에 비해 15개인 경우가 더 큰 오차율을 나타내고 있음을 알 수 있으며 신경회로망 구성시 같은 구조인 경우 학습데이터가 많을 수록 예측된 용접변수들이 실험치과 비슷하며 오차가 적음을 알 수 있다.

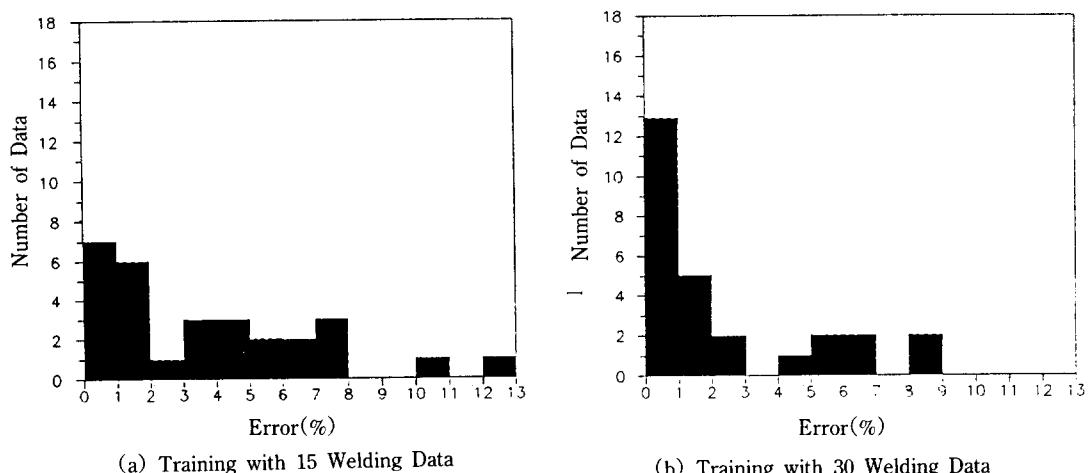
또한 학습데이터가 같을 경우에도 은닉층의 노드수에 따라 신경회로망의 특징이 조금씩 달라질 수 있으므로 한 패턴당 입력갯수가 3개 - 모재의 두께,

각장, 용입깊이 -, 출력갯수가 3개 - 아크전압, 용접전류, 용접속도 -인 구조에 대해 3-7-7-3, 3-8-8-3, 3-9-9-3, 3-10-10-3, 3-11-11-3, 3-12-12-3, 3-6-10-3, 3-11-5-3, 3-12-7-3 등으로 은닉층의 처리단위를 바꿔가며 실험하였으며 Fig. 7에 이들 각각의 구조에 대하여 예측된 값과 실제 실험치와의 오차율을 도식적으로 나타내었다. 여기서 보면 3-7-7-3의 구조가 오차율이 가장 작고 따라서 구성된 신경회로망중 가장 예측능력이 우수함을 알 수 있다.

Fig. 8에는 신경회로망을 이용하여 예측한 값과 실험치 사이의 오차율에 대한 표준편차를 나타내었으며 3-7-7-3의 구조가 표준편차값이 가장 작음을 알

**Table 1** Data sets used for Training(1–15) and Testing(16–24) of Neural Network

Test Number	Thickness of Plate (mm)	Leg Length (mm)	Penetra-tion (mm)	Voltage (V)	Travel Speed (mm/s)	Current (A)
1	4.5	4.7	0.5	19	4	200
2	4.5	4.35	1.125	20	6	200
3	4.5	5.5	1.5	21	4	240
4	4.5	6.65	1.81	24	4	250
5	4.5	5.7	2.0	24	6	260
6	6.0	6.0	1.4	21	4	230
7	6.0	6.5	1.7	23	4	250
8	6.0	5.35	1.82	23	6	250
9	6.0	5.4	1.97	25	6	270
10	6.0	5.8	2.12	26	6	270
11	7.0	6.5	1.25	23	4	240
12	7.0	6.85	1.8	26	4	260
13	7.0	5.1	1.88	25	6	260
14	7.0	7.25	2.32	28	4	280
15	7.0	6.02	2.5	28	6	280
16	4.5	3.8	1.0	19	6	200
17	4.5	4.95	1.8	22	6	240
18	4.5	5.7	1.25	22	4	220
19	6.0	5.1	1.63	22	6	230
20	6.0	6.75	1.85	25	4	270
21	6.0	5.3	1.68	24	6	240
22	7.0	4.9	1.4	23	6	240
23	7.0	6.7	2.25	27	4	280
24	7.0	5.55	2.14	25	6	270

**Fig. 6** Error of neural network for two training data

**Table 2** Data sets used for Training(1–30) and Testing(31–39) of Neural Network

Test Number	Thickness of Plate (mm)	Leg Length (mm)	Penetration (mm)	Voltage (V)	Travel Speed (mm/s)	Current (A)
1	4.5	4.7	0.5	19	4	200
2	4.5	4.9	1.81	20	4	200
3	4.5	4.35	1.125	20	6	200
4	4.5	5.5	1.5	21	4	240
5	4.5	6.25	1.67	22	4	240
6	4.5	4.3	1.75	21	6	240
7	4.5	6.4	1.9	23	4	260
8	4.5	6.65	1.81	24	4	250
9	4.5	5.0	1.94	23	6	260
10	4.5	5.7	2.0	24	6	260
11	6.0	6.0	1.4	21	4	230
12	6.0	6.35	1.53	22	4	230
13	6.0	4.5	1.59	21	6	230
14	6.0	6.5	1.7	23	4	250
15	6.0	6.6	1.75	24	4	250
16	6.0	5.35	1.82	23	6	250
17	6.0	5.7	1.835	24	6	250
18	6.0	6.95	1.9	26	4	270
19	6.0	5.4	1.97	25	6	270
20	6.0	5.8	2.12	26	6	270
21	7.0	6.5	1.25	23	4	240
22	7.0	6.6	1.32	24	4	240
23	7.0	5.6	1.6	24	6	240
24	7.0	6.6	1.69	25	4	260
25	7.0	6.85	1.8	26	4	260
26	7.0	5.1	1.88	25	6	260
27	7.0	5.7	1.93	26	6	260
28	7.0	7.25	2.32	28	4	280
29	7.0	5.45	2.37	27	6	280
30	7.0	6.02	2.5	28	6	280
31	4.5	3.8	1.0	19	6	200
32	4.5	4.95	1.8	22	6	240
33	4.5	5.7	1.25	22	4	220
34	6.0	5.1	1.63	22	6	230
35	6.0	6.75	1.85	25	4	270
36	6.0	5.3	1.68	24	6	240
37	7.0	4.9	1.4	23	6	240
38	7.0	6.7	2.25	27	4	280
39	7.0	5.55	2.14	25	6	270

수 있고 또한 오차율이 가장 작으므로 각각의 용접변수를 예측하는데 있어 실제값과 큰 오차를 가지지 않는 가장 안정된 신경회로망 구조임을 알 수 있다. 3-7-7-3의 구조에 비하여 다른 구조의 신경회로망에서 나타나는 오차율 및 표준편차의 값들은 큰

범위의 수치를 나타내며 이 구조를 가지고 예측된 용접변수의 값들은 신뢰성이 떨어진다고 말할 수 있다. 그러나 3-7-7-3의 구조가 위에서 제시된 여러 가지 신경회로망의 구조에 비하여 용접품질에 대한 용접변수를 선정하는 가장 적절한 구조임에는 틀림

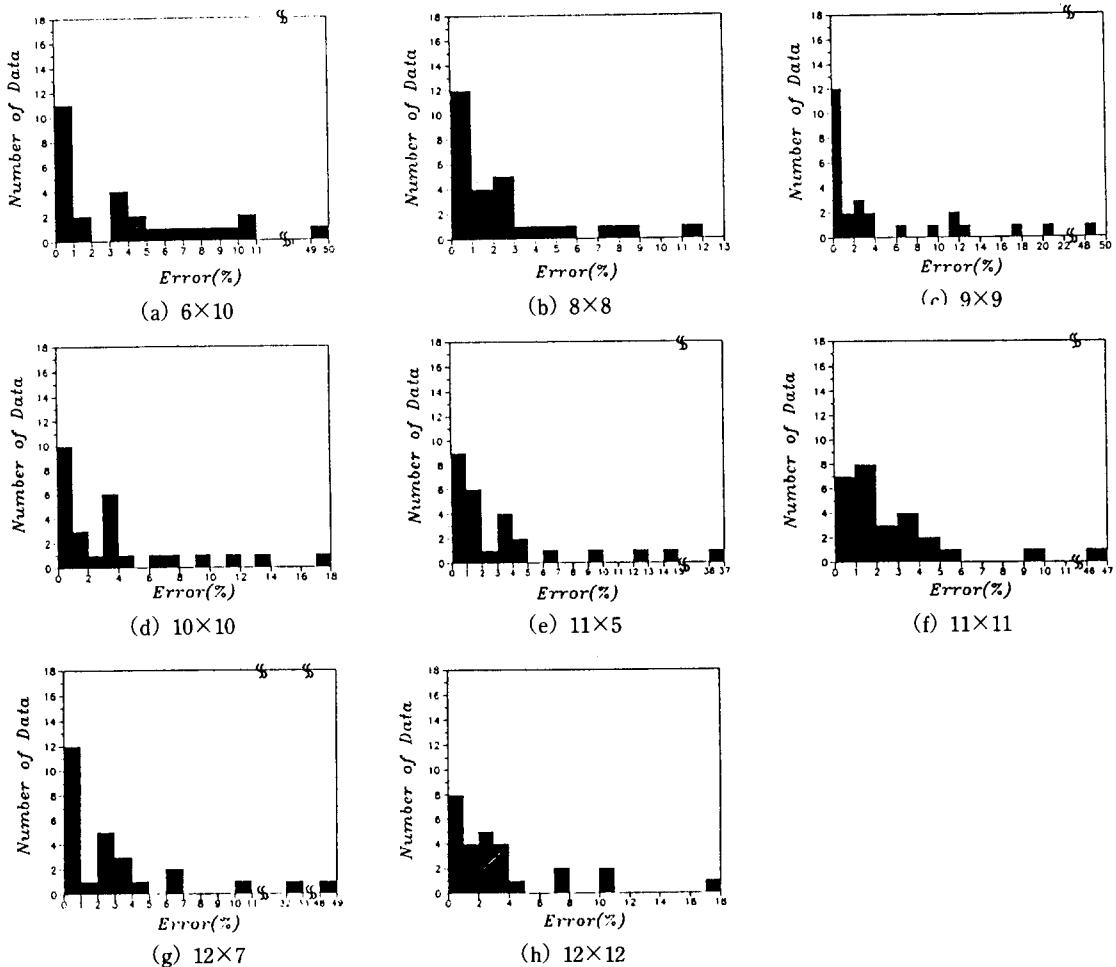


Fig. 7 Error of various nodes of hidden layer for 30 training data

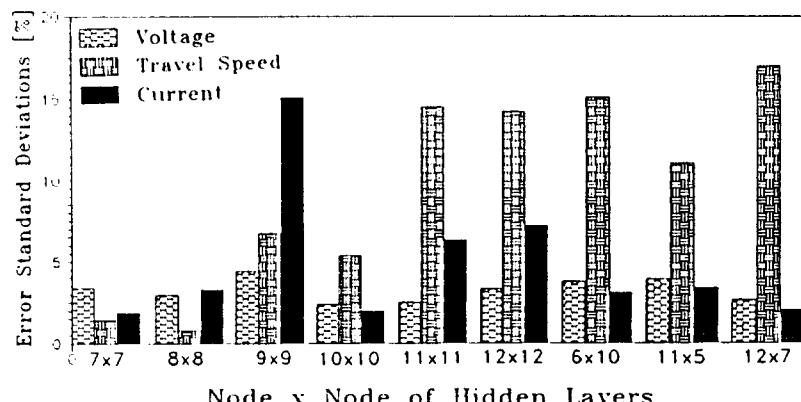


Fig. 8 Standard deviation of error(%) for various nodes of hidden layer

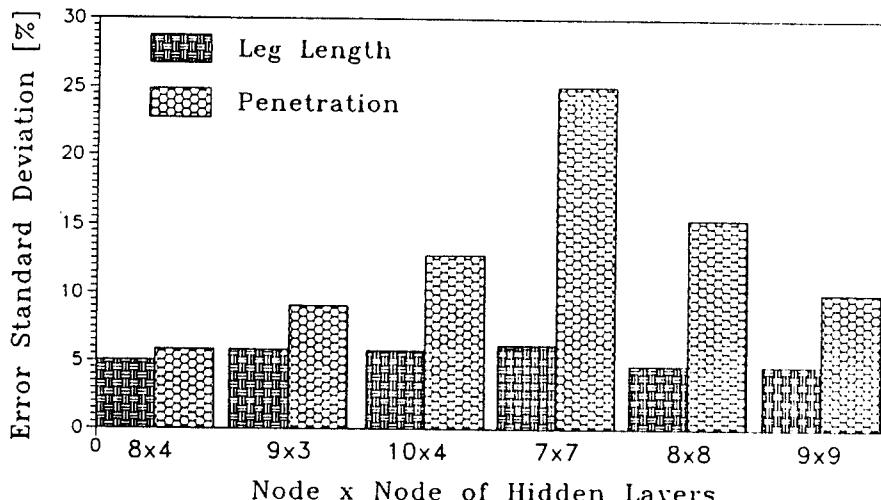


Fig. 9 Standard deviation of error(%) for various nodes of hidden layer

없으나 다른 다양한 은닉층의 처리단위를 갖는 신경회로망에 대하여 실험을 해보면 더욱 적절한 구조의 신경회로망을 얻을 수도 있으리라 생각된다.

모재의 두께, 전류, 전압, 용접속도를 입력 패턴으로 하고 각장, 용입깊이를 출력 패턴으로 하는 구조에 대한 예측특성을 알아보기 위해서 전체 학습 패턴이 30개인 경우의 신경회로망을 구성하여 은닉층의 처리단위를 다양하게 바꿔가며 실험하였다. 4-8-4-2, 4-9-3-2, 4-10-4-2, 4-7-7-2, 4-8-8-2, 4-9-9-2의 구조에 대한 오차율의 표준편차를 Fig.9에 나타내었다. 여기서 4-8-4-2의 구조가 오차율에 대한 표준편차값이 가장 작음을 알 수 있고 따라서 다른 신경회로망보다 각장과 용입깊이를 예측하는데 있어 가장 안정된 구조임을 알 수 있다. 실제값과 예측된 값들 사이의 오차율은 비슷하나 표준편차가 큰 범위를 가지는 신경회로망의 구조나, 표준편차의 범위는 비슷하나 오차율이 큰 경우도 신뢰도가 4-8-8-2구조에 비하여 떨어진다.

## 5. 결 론

본 연구에서는 용접공정에 있어 용접변수 선정을 위한 신경회로망의 적용에 관하여 고찰하였다. 용접공정은 수학적인 모델링이 어려울 뿐만 아니라 공정에 관련되는 각 변수들을 독립적으로 형성시키기 어려우므로 경험에 의한 데이터를 이용하여 예측능력의

특성을 가진 신경회로망 모델을 구성하여 이러한 난점을 해결할 수 있다. 이러한 개념을 이용하여 용접공정에 있어 용접변수 선정시 해석적인 방법에 의하지 않고 신경회로망 모델을 이용하여 변수값들을 예측하고 이 값들을 실제 실험치와 비교하여 가장 적절한 신경회로망 구조를 선택하였다.

신경회로망에 대하여 모의실험한 결과 용접품질에 대한 용접변수를 예측하는 모델로서 실제 실험치에 대한 예측 값들이 큰 오차없이 나타나는 구조를 얻을 수 있었다. 이러한 신경회로망을 여러가지 실제 용접공정에 응용한다면 용접공정설계에 많은 도움이 될 수 있을 것으로 사료되며, 보다 범용적인 신경회로망을 구축하기 위해서는 더 많은 연구가 수행되어야 할 것이다.

## 참 고 문 현

1. H. Nomura, Y. Sugitani, M. Murayama : Development of Automatic Fillet Welding Process with High Speed Rotating Arc, Transaction of the Japan Welding Society, Vol.18, No.2(1987), pp. 116~124
2. H. Nomura, Y. Sugitani, Y. Suzuki : Automation Real-Time Bead Height Control with Arc Sensor in TIG Welding, Transaction of the Japan Welding Society, Vol.18, No.2(1987), pp. 125~132
3. D. Rosenthal : Mathematical Theory of Heat Dist-

- ribution during Welding and Cutting, Welding Journal, Vol.20, No.5(1941), pp. 220~234
4. A.C. Nunes : An Extended Rosenthal Weld Model, Welding Journal, Vol.62, No.6(1983), pp. 165~170
  5. G. Langri, M. Tomizuka : Self-Organizing Fuzzy Linguistic Control with Application to Arc Welding, IEEE Inter.Workshop on Intelligent Robot and System, Tsuchiura, Japan, (1990), pp. 1007~1014
  6. A. Matteson, R. Morris, R Tate : Real-Time GMAW Quality Classification using an Artificial Neural Network with Airborne Acoustic Signal as Input, Proc. of International Conference on Computerization of Welding Information, Orlando, Florida, (1992), pp. 189~197
  7. W. Ameling, J. Borowka, U. Dilthey, L. Kreft, M. Raus and W. Scheller, Aachen : Adaptive Arc Sensor for Varying Joint Geometry - The Use of Artificial Neural Networks, Welding and Cutting, Vol.44, No.2(1992), pp. E24~E25
  8. J. Hertz, A. Krogh, R. G. Palmer : Introduction to the Theory of Neural Computation, Addison-Wesley Publishing Company, (1991), pp. 115~120
  9. J. Weston : Advanced Welding Systems, IFS Ltd, UK, London, (1988), pp. 245~248
  10. P.D. Wasserman : Neural Computing Theory and Practice, Van Nostrand Reinhold International Company Ltd., New York, (1989), pp. 44~47
  11. K. Andersen, G. E. Cook, G. Karssai and K. Ramaswamy : Artificial Neural Networks Applied to Arc Welding Process Modeling and Control, IEEE Transaction on Industry Application, Vol.26, No. 5 (1990), pp. 824~830