

다층 신경회로망을 이용한 GMA 용접 공정에서의 용융지 크기의 예측

임태균 조형석
한국과학기술원 생산공학과

Estimation of Weld Pool Sizes in GMA Welding Processes Using a Multi-layer Neural Net

Tae-Gyun Lim Hyung-Suck Cho

Dept. of Production Engineering

Korea Advanced Institute of Science and Technology

ABSTRACT

This paper describes the design of a neural network estimator to estimate weld pool sizes for on-line use of quality monitoring and control in GMA welding processes. The estimator utilizes surface temperatures measured at various points on the top surface of the weldment as its input. The main task of the neural net is to realize the mapping characteristics from the point temperatures to the weld pool sizes through training. A series of bead-on plate welding experiments were performed to assess the performance of the neural estimator.

1. GMA 용접 공정에 대한 개요

GMA(Gas Metal Arc)용접 공정은 그림.1에서와 같이 전극과 용접할 모재 사이에 고전류를 가할 때 발생하는 전기적인 아크를 열원으로 하여 용접물과 전극을 녹여서 용접물을 접합하는 용접 공정이다. 이때 녹은 금속과 고온의 열영향부가 대기에 노출되어 산소와 반응하여 산화되는 것을 막기 위하여 보호 기체를 용접부에 공급하여 대기와와의 접촉을 차단한다.

GMA에 의해 형성된 용접부의 성능은 일반적으로 용접 비드의 기하학적인 크기로 나타내며, 그림.2에 나타낸 바와 같이, 용접 비드 폭, 용입 깊이 및 이면 비드의 폭으로 구분된다. 이러한 용접 비드의 크기에 영향을 미치는 용접변수들은 용접 전류, 아크 전압, 토치 이동 속도, 전극의 크기와 위치 등이다. 이러한 변수들의 적절한 조합에 의해 접합부에서의 요구되는 용접부가 형성된다.

만일 용접부의 결함이 용접 후의 여러 가지 검사에서 발견되면 그 결함부는 보수되어야 하며, 그 검사와 보수에 드는 비용은 전체 제조공정에 드는 비용의 상당한 부분을 차지할 뿐만 아니라 생산성의 감소를 유발한다. 따라서, 이러한 용접부의 검사와 보수의 양을 줄이기 위한 방법에 대해 많은 연구가 이루어지고 있다. 그 중 하나는 용접부의 결함 발생 가능성을 줄이기 위해 용접 작업의 유연화를 도모하는 것이다. 즉, 용접중 용접질을 대변하는 변수들을 측정하여, 그에 영향을 주는 여러 외란에 의한 영향을 실시간으로 보상해 주는 자동 용접 시스템을 이룩하는 것이다.

2. 용접 공정 변수의 측정

용접과 같은 생산 공정을 제어하기 위해서는, 실제 용접 상황을 대변해 주는 관련 변수들의 측정이 이루어져야 한다. 용접부의 성능은 여러 가지 상황에 의해서 결정되나, 실제의 용접 상황에서 실시간으로 측정가능한 지수는 Dornfeld등[1]이 밝힌 바와 같이 비드의 폭, 표면온도와 표면온도 냉각률, 표면으로부터의 방사 에너지, Acoustic emission등으로 제한된다. 그 중 용접부의 성능에 직접적인 영향을 미치는 지수는 비드의 폭 뿐이고, 나머지 측정 가능한 지수들은 그 측정량에 의해서 용접부의 성능 정도를 예측하는데 사용될 수 있다.

영상 센서를 이용하여 비드 폭을 측정하는 방법[2]의 경우, 실시간 영상 처리를 위해 고가의 장비가 필요하고 그 측정 대상이 용융지의 비드 폭에 한정되며, 용접부의 성능에 보다 직접적인 용접 변수인 용입 깊이 또는 완전 용입에서의 이면 비드 폭은 측정할 수 없다. 용입 깊이의 측정 방법으로는 초음파 측정법[3]이 있는데, 온도에 따른 물성 변화에 의한 부정확성, 초음파 탐침자의 접촉 유지 곤란등의 어려움이 있다. 이면 비드 폭의 측정법으로 이면에서의 방사 에너지를 측정하는 방법[4]에서는 측정 센서가 용접 토치와의 동시성이 항상 유지되어야 한다는 것과 이면에서의 용융금속으로부터 센서를 보호해야 하는 어려운 점이 있다. 따라서 이러한 방법들은 용접질을 나타내는 용융부의 비드 폭, 용입 깊이 및 이면 비드의 폭 전체를 실시간으로 측정하기 힘들다. 따라서 용접물 표면에서의 온도를 측정하여 용융부의 크기를 간접적으로 예측하는 방법이 연구되었다.[5]

용접물 표면 상의 한 점에서 측정된 온도는 용접 조건이 다르더라도 같은 값으로 측정될 수 있다. 그러나, 용접 조건이 다르면 다른 온도 분포가 형성되므로 실제 형성된 용융지의 크기는 다르게 된다. 따라서 표면 온도를 측정하여 용융지의 크기를 예측하고자 할 때, 한 점에서의 온도 측정으로는 다양한 용접 조건에 따른 용융지의 크기를 정확하게 모니터링할 수 없다. 따라서 여러 측정점에서의 표면 온도가 측정되어야 한다. 본 논문에서는 세 점의 표면 온도를 측정하여 용융지의 크기를 예측하였다. 실제 용융지의 형성은 측정점에서의 온도와 온도 구배에 관련되므로, 한 점에서의 온도와 x-축과 y-축 방향으로의 온도차로써 용접물 표면에서의 온도 분포를 나타내어, 용융지의 크기 예측에 사용하였다. 용접물

상의 표면 온도는 적외선 온도 센서를 이용하여 측정되었다. 그림.3에는 세 개의 표면 온도 측정점과 아크와의 상대적인 위치가 나타나 있다.

3. 표면 온도 및 용접 비드 크기의 측정 실험

절대 온도 $0^{\circ}K$ 이상인 모든 물체는 그 온도에 따라서 분자의 운동량이 달라지게 되고 그에 따른 에너지를 방사하게 된다. 여기서의 에너지는 전자기파로서 그 양을 측정함으로써 그 물체의 온도를 알 수 있다. 사용된 표면 온도 측정 센서는 wide band형 적외선 센서이다. 적외선 온도 측정 시스템의 구성은 그림.4와 같이 대물 렌즈, aperture, 적외선 광 센서 및 신호 증폭 회로로 구성되어 있다. 대물렌즈는 용접 모재 표면의 한 점에서 방출되는 적외선 광을 집광하고 이를 aperture를 거쳐서 적외선 센서로 전달한다. 센서는 수광량의 증가에 따라서 그 저항이 감소하는 성질을 갖고 있다. 그러므로 센서의 한 단과 직렬로 연결된 부하 저항의 한 단 사이에 여기 전압(exciting voltage)을 가할 때 수광량에 따라 변하는 센서의 저항에 따라 회로 내의 전류량이 변화하게 된다. 신호 증폭 회로는 그때의 센서 양단 전압을 측정하고 이를 증폭시키는 회로로 구성되어 있다. aperture는 센서 목표 외의 다른 영역에서 반영된 빛을 모두 제거한다.

다양한 용접 조건에서 수행된 실험을 통하여 용접물상의 세 점의 표면 온도들과 이에 의해 형성된 실제 용접 비드의 크기들이 측정되었다. 실험에 사용된 시편은 열간 압연 AISI 1025 강판이며 두께 4 mm에 크기는 200 by 60mm이다. GMA 용접이 시편의 중심선을 따라 수행되었으며 보호 가스로는 Ar 가스가 사용되었다. 사용 전극은 직경 1.2 mm의 연강용 전극이다. 용접 실험은 여러 용접 전압, 용접 전류 및 토치 이동 속도에 대해서 반복적으로 수행되었다. 용접부의 크기는 용접이 완료된 후에 용접부를 절단하고 연마한 후 97% 에탄올과 3% 질산 용해액에 예침한 후에 단면을 검사하여 멘드라이트 조직을 이용하여 구하였다. 사진에는 전체 실험 장치의 실제 모습이 나타나 있다.

그림.5에는 여러 용접 조건에서 표면 온도에 따른 준 정상 상태에서의 용접부의 크기 지수들이 나타나 있다. 용접부의 크기 지수로는 용접부의 비드 폭과 용입 깊이에 이면 비드 폭의 반을 더한 값을 사용하였다. 두번째의 용접부 크기 지수는 부분 용입 용접의 경우 용입 깊이를 나타내며 완전 용입 용접의 경우에는 용접물 두께를 빼면 이면 비드 폭의 크기를 나타낸다. 토치 이동 속도는 4, 6, 8 mm/s로 변화시켰다.

그림.5(a)에는 다양한 용접 조건에서 행한 실험에서 측정된 (-9.7) 점의 표면 온도 T1과 실제 형성된 용접부의 크기 지수들이 나타나 있다. 그림에서 보면 용접부의 비드 폭의 경우 측정 온도의 증가에 따라 거의 선형적으로 증가함을 알 수 있다. 같은 측정 온도에 대해서 용접 속도가 증가할 경우 용접 비드 폭의 크기 역시 증가한다. 이는 용접 속도가 증가할 경우 용접 열입력이 커져 용접 비드 폭의 증가를 가져 오기 때문이다. 반면에, 용입 깊이 및 이면 비드 폭의 경우에는 측정점의 온도에 따라 비선형적으로 변화한다.

그림에서 보면 같은 표면 온도 T1에 대해서도 용접 조건

에 따라 각각 크기 지수가 다른 용융지 형성됨을 알 수 있다. 따라서 한 점의 표면 온도만을 측정하여서는 다양한 용접 조건에 따라 형성된 용융지의 크기 지수들을 예측할 수 없다. 그러므로 용융지의 크기를 정확히 예측하려면 또 다른 표면점의 온도가 추가적으로 측정되어야 한다.

그림.5(b)와 그림.5(c)에는 (-14.7)점의 온도 T2와 (-9.11)점의 온도 T3를 측정하고 T1과의 온도차를 구하여 이에 따른 용접부 크기 지수의 변화를 도시하였다. 그림에서 보면 이러한 온도차와 용융 비드의 크기 지수들은 매우 큰 비선형성을 보여 준다. 이는 용접 조건의 변화에 대해서 표면 온도 T1, T2, T3 사이의 관계가 매우 비선형적이고 또한 용접 조건에 따라서 용접물의 표면에서는 매우 다른 온도 분포를 유발하기 때문이다. 그림에서 보면 알 수 있듯이 용접부의 표면 온도 분포를 나타내는 T1, T1-T2, T1-T3로부터 용접부의 크기 지수들을 예측할 수 있는 해석적인 방법이 없다. 따라서 본 논문에서는 다층 신경회로망을 이용함으로써 이들 사이의 상관관계를 학습하여 구현하고 이를 이용하여 용접부의 크기 지수들을 예측하고자 한다.

4. 다층 신경회로망을 이용한 용융지 크기의 예측

4.1 개요

최근에, 수학적으로 접근하기 어려운 분야에 신경회로망을 적용하는 연구가 활발하게 진행되고 있다. 이러한 연구는 패턴 인식 및 분류[6,7], 적응 필터 및 신호 처리[8]에 많이 적용되고 있고, 또한 최적화[9], 공정 및 플랜트 모델링[10~12], 센서 데이터의 해석[13]과 지능 제어 분야[11]에도 그 적용이 많이 이루어지고 있다. 신경회로망의 기본적인 역할은 입-출력 관계를 black box로 가정하고 그 사상(mapping)을 구현하는 것이다.

그림.6에는 다층 신경회로망[14]을 이용하여 용융지의 크기를 예측하는 방법이 도식적으로 나타나 있다. 먼저 적외선 온도 측정 시스템으로부터 세 점의 온도 T1, T2, T3가 측정되어, 신경회로망의 입력으로 T1, T1-T2, T1-T3가 구해진다. 신경회로망의 출력은 예측된 용융지의 크기 지수들이며 이는 실제 측정된 용융지 크기 지수들과 비교된다. 오차가 생기면 학습 법칙에 의해 신경회로망 내부의 매개 변수를 조절하여 오차가 줄어들도록 한다. 반복 학습에 의해 예측된 용융지 크기 지수들과 실제 측정된 용융지 크기 지수들의 차가 충분히 줄어들면 온도 분포와 용융지의 크기와의 상관 관계의 학습이 끝나게 되며, 신경회로망은 실제 용융지 크기 지수의 예측에 사용될 수 있다. 따라서 온도 측정 시스템에서 세 점의 표면 온도를 측정하여 신경회로망의 입력으로 주면 신경회로망은 이에 의해 형성된 용융지의 크기 지수들을 예측하게 된다. 그림.7은 신경회로 예측기의 구조를 보여 준다.

신경회로망의 학습단계에서, 입력값 벡터 T1, T1-T2, T1-T3가 입력단에 주어지면 신경회로망은 이들을 입력 계층과 첫번째 중간 계층 사이의 가중치에 곱하여 첫번째 중간 계층으로 가는 순입력 net₁를 계산하여 준다. 계산된 순입력들은 신경회로망의 입력 T1, T1-T2, T1-T3에 대해 가중치의 곱에 따라 서로 다른 선형 3차함수가 된다. 이 순입력은 첫번째 중

간 계층의 노드에서 바이어스(bias)와 비선형 활성화 함수를 거쳐 노드의 출력으로 계산된다. 비선형 활성화 함수는 순입력 계산에서 노드 입력에 곱해지는 가중치와 노드에서의 바이어스 값에 따라 그 형태가 달라진다. 따라서 첫번째 중간 계층의 각 노드는 신경회로망의 입력 T1, T1-T2, T1-T3에 대해서 가중치와 바이어스 값에 따라 각각 다른 비선형 함수를 내보낸다. 이 비선형 함수들은 다시 가중치가 곱하여져 다음 계층의 순입력으로 계산되고 다음 계층에 있는 노드의 바이어스 값과 비선형 활성화 함수를 거쳐 더욱 복잡한 비선형 함수로 계산되어 다음 계층으로 가는 출력이 된다. 따라서 최종적으로 계산되는 출력단의 용융지 크기 지수들은 신경회로망의 입력 T1, T1-T2, T1-T3에 대한 복잡한 비선형 함수로 나타난다. 매 반복 학습시에 모든 입-출력 데이터쌍이 한번씩 주어져 각각에 대하여 실제 출력의 계산과 관찰된 값과의 오차에 따른 가중치와 바이어스 값들의 조정량이 계산되며 모든 입-출력 데이터쌍에 대한 조정량을 모두 합하여 가중치와 바이어스 값들을 조정한다. 이러한 반복 학습이 끝나면, 신경회로망의 내부에는 적당한 가중치와 바이어스 값에 의해 입력 T1, T1-T2, T1-T3와 용융지 크기 지수들의 상관 관계가 구현되며 용융지 크기 지수들의 예측에 사용된다.

4.2 용융지 크기의 학습과 예측

다양한 용접조건에서 행한 실험으로부터 72개의 표면 온도 T1, T2, T3와 그에 대응하는 용접 비드의 크기가 측정되었다. 이중 54개의 데이터쌍이 신경회로 예측기의 학습에 사용되었으며, 나머지 18개의 데이터쌍은 예측 성능의 평가를 위하여 실제 용접 비드의 크기 예측에 사용되었다. 신경회로망의 입력 T1, T1-T2, T1-T3에 대해서 그 출력인 용접 비드 폭과 용입 깊이에 이면비드 폭의 반을 합한 지수가 그림.5에서 보는 바와 같이 그 상관 관계가 상이하므로, 신경회로망의 출력 변수로 두가지 크기 지수들을 같이 예측하는 구조와 각각 따로 신경회로망을 구성하는 구조 두 가지 경우에 대하여 학습과 예측을 수행하였다. (그림.8) 그리고 T1, T1-T2, T1-T3와 용접 비드의 크기 지수와의 관계를 잘 표현해 줄 수 있는 신경회로망의 구조를 알아 보기 위해 그 구조를 다양하게 변화시키면서 학습과 예측을 수행하였다. 신경회로망은 앞에서 설명한 바와 같은 방식으로 입-출력 간의 상관 관계를 표현하므로 중간 계층의 갯수와 각 계층에 있는 노드의 수가 설계 변수가 된다. 중간 계층의 갯수와 각 계층에 있는 노드의 수가 많아질수록 신경회로망 내부의 조정할 수 있는 매개 변수인 가중치와 바이어스들이 많아지므로 더욱 복잡한 함수 관계의 표현이 가능하다. 그러나 대부분의 경우 2개의 중간 계층으로 입-출력 간의 상관 관계 표현이 가능하므로[15] 여기서는 2개의 중간 계층의 노드 수를 변화시키면서 용융지 크기의 예측에 적합한 신경회로망의 구조를 선정하였다. 이러한 구조를 선정하는 기준은 평균 제곱 예측 오차(average squared estimation error)를 최소로 하는 구조를 선정하였다. 여기서 학습과 모멘텀 이득은 각각 0.5와 0.3으로 하였다. 이는 앞서 행한 여러 테스트에서 수렴 속도와 학습시에 나타날 수 있는 전체 제곱 오차의 oscillation을 기준으로 선정된 값이다. 학습 반복 횟수는 10000회까지로 하였다. 신

경회로망을 이용하여 용융지의 크기를 예측하는데 있어서 그 성능을 평가하기 위하여 다음과 같은 퍼센트 예측 오차가 사용되었다.

$$\text{percentage error}(\%) = (W_t - W_e) / W_t \quad (1)$$

여기서, W_t 와 W_e 는 각각 실험에서 얻은 실제 용융지의 크기와 예측값이다.

4.3 예측의 결과 및 고찰

그림.9에는 그림.8.(a)의 경우에 대해서 신경회로망의 구조를 여러가지로 변화시키면서 측정 온도로부터 용융지의 크기 지수들을 예측한 결과가 나타나 있다. H.L.-1과 H.L.-2는 각각 첫번째와 두번째 중간 계층의 노드수이고, 전체 데이터 세트에 대한 제곱 오차(squared error)의 평균값이 도시되어 있다. 결과에서 보면 한 개의 중간 계층만 사용할 때나 두개의 중간 계층을 사용할 경우 첫번째 중간 계층에 2개의 노드만 사용할 때, 상대적으로 크고 안정되지 않은 예측 오차를 나타낸다. 이것은, 이러한 구조로는 측정 온도들로부터 용융지 크기와의 사상 관계를 충분히 표현해 줄 수 없음을 보여 준다. 반면에 첫번째 중간 계층의 노드 수가 4개 보다 크거나 같은 경우에는 예측 오차가 많이 줄었으며 구조의 변화에 따라 안정된 예측 오차를 보여 준다. 첫번째 중간 계층의 노드 수가 2개에서 4개를 변화할 때, 예측 오차가 급격히 감소한다. 예측 결과를 보면, 여러가지 구조 중 용융지 비드 폭의 경우 3-4-2-1의 구조가 가장 적은 예측 오차를 보였으며, 용입 깊이에 이면 비드 폭의 반을 합한 지수의 경우 3-4-6-1의 구조가 가장 적합하였다.

그림.10에는 이러한 구조를 이용하여 용융지의 크기를 학습시키고 실제 예측한 결과가 용접 속도 4mm/sec인 데이터 세트에 대해 나타나 있다. 그림에서 보면 예측된 결과는 실제 측정된 용융지 크기의 지수들과 잘 일치한다. 따라서 신경회로망의 입력 T1, T1-T2, T1-T3와 용접 비드 크기 지수들이 매우 큰 비선형적인 상관관계가 있음에도 불구하고 이를 잘 구현하였으며 학습에 사용되지 않은 신경회로망의 입력에 대해서도 정확하게 용융지 크기 지수를 예측함을 보여 준다. 예측값과 실제 측정된 값과의 차이는 표면 비드 폭의 경우 -0.24mm에서 0.24mm에 이르며 용입 깊이에 이면 비드 폭을 합한 지수의 경우 -0.24mm에서 0.41mm에 이른다. 그림.10(b)에는 이들 예측 오차가 x 값으로 나타나 있으며, 용융지의 표면 비드 폭의 경우 $+5x$ 이내의 예측 오차를 나타내었고, 용입 깊이에 이면 비드 폭의 반을 합한 지수의 경우 $+10x$ 이내의 예측 오차를 보여주었다.

그림.11에는, 그림.8.(b)의 경우에 대해서 신경회로망을 여러가지 구조로 변화시키면서 학습과 예측을 수행한 결과가 나타나 있다. 그림에서 보면, 그림.8.(a)의 경우에서와 같이 첫번째 중간 계층의 노드 수가 2개에서 4개로 변할 때 예측 오차는 급격하게 줄어 들며 구조에 따라 안정화된다. 이는 첫번째 중간 계층의 노드 수가 4개 이상일 때, 신경회로망 내부의 매개 변수에 의해서 입-출력간의 관계가 안정되게 표현됨을 보여 준다. 그런데, 두번째 중간 계층의 노드 수가 2개

일 때는 예측 오차가 상대적으로 크다. 이는 두가지 용융지의 크기 지수에 대해 입-출력상의 상관관계가 상이하셔서 이 관계가 신경회로망의 내부에서 잘 구현되지 않았기 때문이다. 그 이유는 그림.8.(b)에서 알 수 있는 바와 같이, 두 용융지 크기 지수들의 상관 관계를 구분 짓는 것은 두번째 계층과 출력 계층사이의 가중치와 바이어스값 뿐이므로 이 부분의 노드 수가 적으면 두 용융지 크기 지수들의 상관 관계를 구분 짓기 힘들어지기 때문이다. 그림.12에는 3-6-6-2의 구조에 대한 퍼센트 오차 분포를 나타내었다. 용융 비드 폭의 경우 +6%의 예측 오차를 보여 주었으며, 용입 깊이에 이르면 비드의 반을 포함한 지수의 경우 +12%의 오차가 나타났다.

5. 결론

GMA 용접 공정에서 용접 비드의 크기를 예측하는데 있어서 신경회로망을 이용하는 방법을 제시하였다. 모니터링 신호로는 용접물 표면상의 세점의 온도들이 사용되었고 비접촉식 적외선 온도 센서에 의해 측정되었다. 다양한 용접 조건에서 행한 실험을 통하여 제안된 방법에 대하여 예측 오차를 평가하였다. 예측결과를 보면 표면 비드폭의 경우 5% 이내, 용입 깊이에 이르면 비드 폭의 반을 포함한 지수의 경우 10% 이내의 예측 오차를 보여 주었다. 용융지 크기의 지수들을 하나의 신경회로망을 이용해 예측하는 경우가 각각의 신경회로망을 이용해 예측하는 경우보다 더 큰 예측 오차를 보였다. 신경회로망의 입력과 출력 사이의 관계가 매우 비선형적이고 이들의 상관 관계를 알아내어 용융지 크기 지수들을 예측할 수 있는 해석적인 방법이 없으나, 이들의 상관 관계를 신경회로망을 통하여 구현함으로써 좋은 예측 성능을 얻었다. 이로써, 수학적으로 모델링하기 어려운 다른 분야에도 다층 신경회로망은 잘 적용될 수 있음을 보여 준다.

References

- [1] D.A.Dornfeld, M.Tomizuka, G.Langari, "Modelling and adaptive control of arc welding processes", Measurement and Control for Batch Manufacturing, ASME WAM, pp.53-64, Nov. 1982.
- [2] R.W.Richardson, D.A.Gutow, R.A.Anderson, D.F. Farson, "Coaxial arc weld pool viewing for process monitoring and control", Welding Journal, pp.43-50, March 1984.
- [3] J.M.Katz, D.E.Hardt, "Ultrasonic measurement of weld penetration", Control of Manufacturing Processes and Robotic Systems, ASME WAM, pp.79-95, Nov. 1983.
- [4] D.E.Hardt, D.A.Garlow, J.B.Weinert, "A model of full penetration arc welding for control system design", Trans. of ASME, J. of Dyn. Syst., Meas., and Contr., Vol.107, pp.40-46, March 1985.
- [5] K.S.Boo, A Study on Analysis and Control of Gas

Metal Arc Welding Process, Ph.D. Thesis, Dept. of Production Engineering, KAIST, 1991.

- [6] K.Fukushima, S.Miyake, T.Itou., "Neocognitron: a neural network model for a mechanism of visual pattern recognition", IEEE Trans. on Syst., Man, and Cyb., Vol.SMC-13, pp.826-834, 1983.
- [7] T.G.Lim, J.H.Kim, H.S.Cho, S.K.Kim, "A neural network method for recognition of part orientation in a programmable bowl feeder", 11th Int. Conf. on Assembly Automation, MS90-832-1-14, Nov. 1990.
- [8] B.Widrow, R.Winter, "Neural nets for adaptive filtering and adaptive pattern recognition", IEEE Computer Magazine, pp.25-39, March 1988.
- [9] H.E.Rauch, T.Winarske, "Neural networks for routing communication traffic", IEEE Control Systems Magazine, pp.26-31, April 1988.
- [10] K.Andersen, G.E.Cook, G.Karsai, K.Ramaswamy, "Artificial neural networks applied to arc welding process modeling and control", IEEE Trans. on Industry Applications, Vol.26, No.5, pp.824-830, Sept./Oct. 1990.
- [11] K.S.Narendra, K.Parthasarathy, "Identification and control of dynamical systems using neural networks", IEEE Trans. on Neural Networks, Vol.1, No.1, pp.4-27, March 1990.
- [12] T.G.Lim, H.S.Cho, H.S.Chang, "Estimation of nugget size in resistance spot welding using a neural network", Proc. 72nd Annual AWS Convention, 1991.
- [13] S.Rangwala, D.Dornfeld, "Sensor integration using neural networks for intelligent tool condition monitoring", ASME J. of Engineering for Industry, Vol.112, pp.219-228, Aug. 1990.
- [14] D.E.Rumelhart, G.E.Hinton, R.J.Williams, "Learning internal representations by error propagation", Parallel Distributed Processing: Explorations in the Microstructures of Cognition, MIT Press, Vol.1, pp.318-362, 1986.
- [15] R.P.Lippman, "An introduction to computing with neural nets", IEEE ASSP Magazine, Vol.4, pp.4-22, 1987.




Fig.1 Schematic description of GMA welding process.




Fig.2 Cross section view of a weld pool.




Fig.3 Coordinates of a weldment.




Fig.4 Schematic diagram of the optical system for measurement of radiation emitted from weldment.




Photo Experimental set-up.

- 1: Welder 2: IBM-AT 3: LAB MASTER
- 4: Signal processing circuit 5: X-Y manipulator
- 6: Wire feeder 7: Pyrometer sensor system
- 8: Weld torch

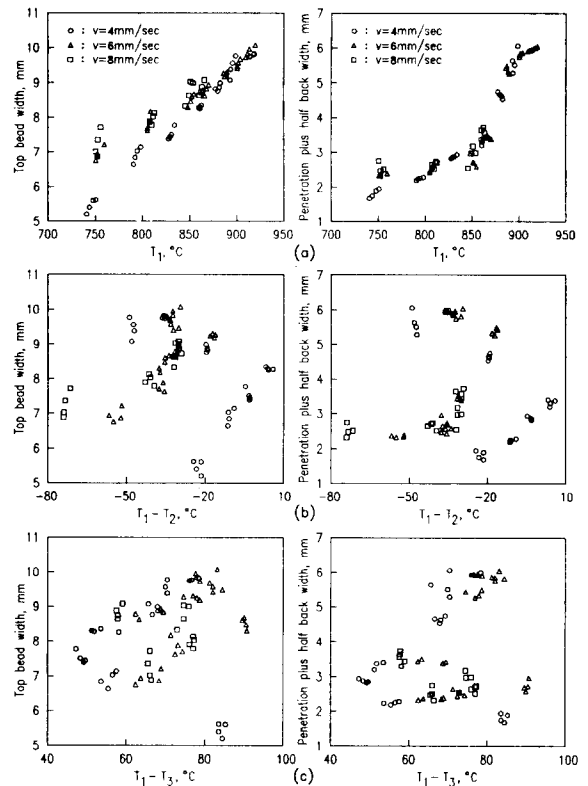


Fig.5 Weld pool size versus surface temperatures for various welding speeds : weldment thickness = 4 mm.

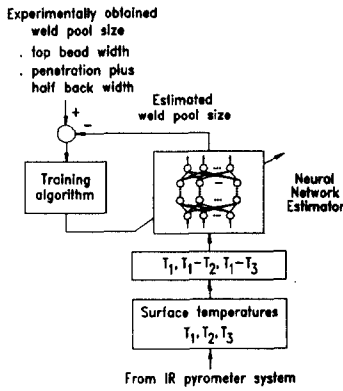


Fig.6 Block diagram of the estimation procedure for weld pool sizes using a neural network.

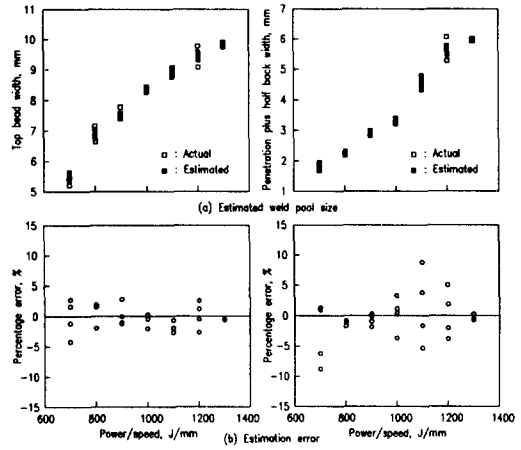


Fig.10 Estimation result of the weld pool sizes using a neural network. : welding speed = 4 mm/sec

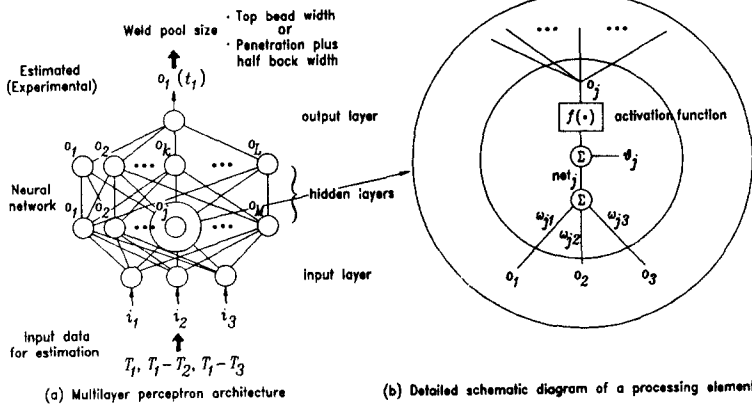


Fig.7 Schematic diagram of the estimation procedure using a neural network.




Fig.11 Total estimation error of the entire data set with various architectures of the neural network estimator.




Fig.8 Two neural network architectures for weld pool size estimation.




Fig.9 Total estimation error of the entire data set with various architectures of the neural network estimator.




Fig.12 Distribution of the estimation errors.