

다층 신경회로망을 이용한 GMA용접 단락이행영역에서의 아크 안정성 평가에 관한 연구

강문진* · 이세현** · 엄기원**

A study of Estimation of the Arc Stability in Short-circuiting Transfer Region of GMA Welding Using Multi-layer Perceptrons

M.J. Kang*, S.H. Rhee** and K.W. Um**

Key Words : CO₂ arc welding(CO₂ 아크 용접), Arc state(아크 상태), Weight of generated spatters(스패터 발생량), Standard deviation(표준편차), Back propagation neural network(오류 역전파 신경회로망), Learning rate(학습율)

Abstract

In GMAW, the spatters are generated according to the variation of the arc. If the arc is stable, Few spatters are generated. But if unstable, too many spatters are generated. So, this means the spatters are dependent on the arc state.

The aim of this study is to accurately estimate the arc state. To do this, the generated spatters were captured under the some welding conditions, and the waveforms of the arc voltage and welding current were collected. From the collected signals, the waveform factors and their standard deviations were extracted. Using these factors as input parameters of multi-layer artificial neural network, the learning for the weight of the generated spatters is performed and the estimation results to the real spatter are assessed. Obtained results are as follow: the linear correlation coefficient between the estimated result and the real spatters was 0.9986. And although the average convergence error was set 0.002, the estimated error to the real spatter was within 0.1 gr/min at each welding condition. In the estimation for the weight of generated spatters, the result with multi-layer neural network was far better than with multiple regression analysis. Especially, even though under the welding condition which the arc state is unstable (the spatter is generated much more), very excellent estimation performance was shown.

1. 서 론

아크 용접에 있어서 스패터의 발생은 용접 생산성과 제품의 품질을 크게 저하시키기 때문에 용접자동화에

있어서 해결해야 되는 문제점의 하나이다. 용접 자동화의 주류를 이루고 있는 GMA용접에 있어서, 스패터 발생량은 용접전원의 특성, 용접조건 및 용접와이어의 종류 및 화학적 조성 등 여러가지 요인의 영향을 받는 것으로 알려지고 있다. 그러나 이러한 요인들은 결국

※ 1999년 7월 19일 접수

* 정희원, 포항산업과학연구원

** 정희원, 한양대학교 정밀기계공학과

강문진 : moonjin@rist.re.kr

아크의 상태를 불안정하게 하거나 또는 큰 변동을 야기시키기 때문에 용접와이어의 용적이 용융지로 이행하지 못하고 스파터가 발생하게 된다. 특히 단락이행 영역에 있어서 스파터는 주로 단락의 순간이나 다시 아크가 발생하는 순간 또는 순간 단락이 일어나는 경우에 주로 발생한다. 이 때 단락 기간 또는 아크 기간이 일정하지 않고 불규칙한 경우 규칙적으로 단락이 이루어지는 경우보다 스파터가 많이 발생하게 된다. 따라서 스파터의 발생량과 아크의 안정성은 밀접한 관계가 있고 아크가 안정하면 스파터 발생량이 적으며, 아크가 불안정하면 스파터 발생량이 많게 된다.

용접품질의 고급화와 용접공정의 자동화를 위해서 아크의 안정성을 평가하거나 예측하고자 하는 많은 시도가 있었다. Arai 등¹⁾은 CO₂ 아크 용접의 단락이행 모드에서 아크시간의 표준편차와 아크 안정성과의 상관관계를 연구하였고, 인간의 경험에 의한 아크 안정성과 아크시간의 표준편차 사이에 밀접한 관계가 있음을 보였다. Lucas²⁾는 아크의 안정성과 단락 최고 전류와 단락주기의 균일성과의 관계를 연구하였는데 단락최고전류와 단락시간 각각의 표준편차와 안정성간에 관계가 있음을 보였다. Ogunbiyi 등³⁾은 용접전류와 아크 전압파형으로부터 파형을 구성하는 몇가지 인자를 사용하여 아크 상태를 예측하는 인덱스를 구성하였고, 이를 이용하여 용적이행모드와 아크 안정성을 평가하였다. Mita⁴⁾는 숙련된 용접사의 경험지식과 용접전압 및 전류파형에서 얻어지는 여러 인자를 고려하여 다중회귀분석에 의한 아크시간, 단락시간, 평균단락전류의 표준편차, 평균아크 전류의 표준편차로 구성되는 아크 안정성 지수를 제시하였다. Shinoda 등⁵⁾은 단락이행모드에 있어서 측정된 용접전류와 아크전압 파형으로부터 아크 안정성을 예측할 수 있는 인덱스를 제안하였다. 한편 아크 안정성을 정량적으로 평가하기 위해서 스파터 발생량과 아크 안정성 사이의 상관성을 해석하기 위한 결과들도 보고되었다. 강봉용 등^{6,7)}은 CO₂ 아크 용접의 단락이행영역과 천이영역에 있어서 용접전류와 아크전압을 구성하는 파형인자가 스파터 발생량에 미치는 영향을 검토하였다. 강성구 등⁸⁾은 용접전류와 전압파형을 구성하는 인자들의 값과 스파터 발생량과의 상관관계를 분석하여 아크 안정성 판단 인덱스를 제안하였다. 강문진 등⁹⁾은 다중회귀분석을 이용하여 CO₂ 아크 용접의 단락이행영역에 있어서 용접전류와 아크전압 파형으로부터 스파터 발생량을 가장 정확하게 예측하는 회귀모델을 제안하였다. 이러한 많은 연구결과들로부터 아크 안정성을 정량적으로 평가할 수 있는 개선된 모델들이 지속적으로 제안되어 왔으나 아직 많은 제한점들이 있고 예측오차가 발생할

수 있는 단점을 내포하고 있다.

본 연구에서는 CO₂ 아크 용접의 단락이행영역에 있어서 다양한 용접조건하에서 용접전류와 아크전압 파형들로부터 이들 파형을 구성하는 특징적인 인자들을 추출하고 추출된 인자들을 인공신경회로망의 입력으로 하여 보다 정확하게 스파터 발생량 또는 아크 안정성을 예측하고자 한다.

2. 실험장치 및 방법

2.1 실험장치

본 연구에 사용된 실험장치의 구성도를 Fig. 1에 나타내었는데, 용접용 로봇과 용접기, 스파터 포집장치 및 용접공정 변수 계측센서, A/D 및 D/A 변환장치 그리고 용접공정변수 해석을 위한 컴퓨터로 구성하였다.




Fig. 1 Configuration of experimental set up

전류와 전압의 설정치를 컴퓨터로부터 D/A변환장치를 통하여 용접기의 외부입력단자에 연결하여 설정하도록 하였다. 또한 용접중 용접전류의 계측은 용접기에서 용접모재를 연결하는 접지선에 설치한 홀 센서를 이용하였고, 아크 전압은 용접전원 출력 단자사이의 전압이 계측되었다. 이렇게 얻은 용접변수 신호들은 200 kHz급 A/D 변환장치를 거쳐 컴퓨터에 입력하였고, 메모리에 저장하였다. 이때 신호에 함께 실린 잡음(noise)은 200Hz의 잡음 제거 주파수(cut-off frequency)를 갖는 디지털 저주파 통과 필터(digital low pass filter)를 사용하여 제거하였다. 필터링된 데이터들은 컴퓨터 상에서 용접파형 해석을 위한 각 파형인자의 해석처리가 수행되었다. 한편 용접 공정은 용접전류용 로봇과 350A급 인버터 제어형 정전압 용접기를 사용하여 수행하였고, 스파터 포집장치는 황동을 사용하여 제작하였다.

2.2 실험방법

스패터 발생량 측정을 위한 용접실험에 있어서, 보호 가스는 100% CO₂ 가스를 사용하여 20 l/min의 유량을 용접부에 공급하였다. 용접와이어는 지름 1.2 mm의 AWS ER70S-6을 사용하였으며, 시험소재는 두께 6 mm의 SS400이었다. 용접속도는 5mm/sec의 고정된 조건으로 하였다. 전극 팁-모재간 거리(contact tip-to-work distance, 이하 CTWD)는 용접전류 조건 150 A와 200 A에서는 15 mm로, 용접전류 225 A와 250 A에서는 20mm로 설정하였다. 용접전압은 용접전류에 따라 19V~28V내에서 약 7V 범위에 걸쳐 적절하게 변화시켰다. 또한 동일 용접 조건에서 6회의 반복실험이 수행되었다. 용접방법은 비드 온 플레이트 용접이 실시되었고, 용접중 데이터 샘플링 속도는 초당 5000개로 하였다. 총 데이터 샘플링량은 용접 시작 후 10초가 경과한 시점에서 20초 동안 수집하였다. 용접중 발생하는 스패터는 Fig. 1에서 보여지는 스패터 포집장치를 이용하였고, 용접 후 발생한 스패터를 모두 모아서 300µm의 눈금을 가진 체로 미세한 가루들을 털어내고 남은 크기의 스패터를 전자저울을 이용하여 그 중량을 측정하였다.

2.3 신호 처리

20초동안 수집된 용접전류 및 전압 파형의 데이터는 1초 간격, 즉 5000개 데이터 단위로 처리 하였다. 또한 전술한 바와 같이, 용접전류 및 전압 데이터는 디지털 저주파 통과 필터를 이용하여 필터링하였다. 이렇게 하여 아크기와 단락기를 구별하기 위한 소정의 임계치(threshold voltage) 이상이 되는 값은 1로, 그렇지 않은 데이터는 전부 0의 값으로 만드는 일종의 영역분할을 실시하였고, 그 다음 최고치를 뽑아내는 최고치 식별 함수를 이용하여 아크기와 단락기를 판별하게 하였다. 이에 의거해 단락의 현상을 묘사하는 1초 동안의 용접 전압과 전류파형의 여러 특성치들의 값과 그들의 표준편차량을 추출하고, 이렇게 추출된 20개의 값들(20초동안 수집)의 평균치를 도출하였다.

3. 오류역전파 다층 신경회로망

3.1 오류역전파 다층 신경회로망

Fig. 2는 본 연구에서 사용된 다입력, 단출력형의 신경회로망 유닛을 나타낸 것이다. 활성화 함수와 같이 여러 개의 입력에 연결된 연결강도(connection

weights), 신경단위의 처리 단위인 노드(node)와 한 개의 출력으로 구성되어 있다. 신경단위에서 출력되는 신호는 식(1)과 같은 관계를 가진다.

$$o = f\left(\sum_{i=1}^n w_i x_i\right) \quad (1)$$

여기서 $f(X)$ 는 활성화함수(activation function)로서 노드에서 연결강도와 입력 값들의 곱의 합을 이용하며, 식(2)의 시그모이드 형태를 사용하였다.

$$f(x) \equiv \frac{2}{1+\exp(-x)} - 1 \quad (2)$$

본 연구에서 사용한 오류 역전파 다층 신경회로망은 Fig. 3과 같이 입력층, 은닉층, 출력층으로 이루어진 층 구조를 가지고 있고, 입력층으로부터 데이터를 입력받아 최종적으로 출력층에 출력치를 생성하는 과정은 전방위적(feed forward)으로 진행된다. 입력층의 출력과 연결강도를 이용하여 은닉층의 출력을 생성하고, 은닉층의 출력과 해당 연결강도를 처리하여 결과층의 출력을 만들어내는 과정을 식(3)~(5)에 나타내었다.

$$y_j = f\left(\sum_{i=1}^I v_{ij} z_i\right) \quad (3)$$

$$x_i = f\left(\sum_{j=1}^J u_{ij} y_j\right) \quad (4)$$

$$o = f\left(\sum_{i=1}^I w_i x_i\right) \quad (5)$$

여기서 z 는 입력층의 입력벡터, y 와 x 및 o 는 각각 은닉층 및 출력층의 출력벡터이고, v 와 u 및 w 는 각 층의 연결강도 배열이고, I 와 J 및 T 는 각각 입력층, 은닉층의 노드수이다.

전술한 순서로 계산된 신경회로망의 출력치로부터 목표치와의 오차를 계산하여 은닉층의 오차 수준을 결정하고 연결강도를 학습패턴에 충실하도록 학습 기억시킬 수 있다. 오차계산에는 식(6)과 같은 최소자승법이 이용되었다.




Fig. 2 General symbol of neuron consisting of node and connection weights




Fig. 3 Multi-layer feedforward neural network

$$E = \frac{1}{2p} \sum_{i=1}^p (d_i - o_i) \quad (6)$$

여기서, p 는 학습 패턴 수이고 d_i 는 목표치(desired value), o_i 는 신경회로망의 출력값이다.

연결강도는 식(7), 식(8), 식(9)와 같이 오차에 기여하는 연결강도의 민감도(sensitivity), 즉 오차변화량 대비 연결강도 미소변화량의 반대방향으로 보정되어, 오차가 감소하는 방향으로 학습이 되며, 그 정도는 학습율(learning rate)에 의해 조절된다.

$$\Delta w_k = -\eta \frac{\partial E}{\partial w_k} \quad (7)$$

$$\Delta u_j = -\eta \frac{\partial E}{\partial u_j} \quad (8)$$

$$\Delta v_{ji} = -\eta \frac{\partial E}{\partial v_{ji}} \quad (9)$$

여기서, η 는 학습율이다. 따라서 학습패턴을 이용하여 오차가 허용수준까지 낮아지도록 반복적으로 연결강도를 보정한다.

3.2 아크 안정성 예측을 위한 신경회로망 입력변수의 선정

단락이행 영역에 있어서 전형적으로 나타나는 용접 전류 및 아크전압 파형을 Fig 4에 나타내었다. 아크 상태와 스파터 발생량에 영향을 미칠 것으로 일반적으로 알려진 파형인자들 및 그들의 표준편차들 13개를 정하였고, 2장의 용접조건에 따라 용접이 실시되었을 때, 계측된 아크 전압과 용접전류 파형으로부터 이들의 값을 추출하였다.

값이 추출된 인자들(factors)은 단락이행 주기(T), 아크 시간(T_a), 단락 시간(T_s), 단락 최고전류(I_p), 단락순간 전류(I_s), 단락이행 평균전류(\bar{I}), 단락 이행주

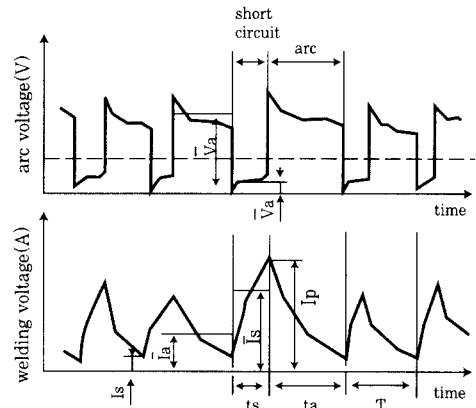


Fig 4. Waveforms of welding voltage and current in short circuit transfer mode

기의 표준편차($s(T)$), 아크 시간의 표준편차($s(T_a)$), 단락시간의 표준편차($s(T_s)$), 평균 아크전류의 표준편차($s(\bar{I}_a)$), 단락 최고전류의 표준편차($s(I_p)$), 단락순간 전류의 표준편차($s(I_s)$), 단락이행 평균 전류의 표준편차($s(\bar{I})$)이었다. 이들 13개의 인자들을 아크 안정성(즉, 스파터 발생량) 학습을 위한 다층 신경회로망의 입력변수로 선정하였다.

3.3 스파터 발생량 예측을 위한 신경회로망의 학습

본 연구에서 사용된 오류역전파 다층 신경회로망은 앞서 서술하였듯이, 2장에서 언급한 단락이행영역의 용접전류와 용접전압조건들 하에서 용접이 실시되었을 때, 용접전류 및 아크전압 파형으로부터 추출된 13개의 인자들을 입력으로 하는 입력층 와 각각 20개의 노드를 갖고 있는 2개의 은닉층 (y, x) 그리고 스파터 발생량을 출력으로 하는 하나의 출력층()으로 하여 학습하였다. 입력층과 은닉층에는 -1의 고정 입력(fixed input)이 첨가되어 각층의 크기는 각각 $I\{13\}$, $J\{20\}$, $T\{20\}$, 1으로 하였다. 입력층과 출력층사이의 연결강도는 각각 V, U, W 로서 $\{J \times I\}$, $\{T \times J\}$, $\{K \times T\}$ 의 크기를 갖는 배열로 표시할 수 있으며, 학습전에 $[-1, 1]$ 사이의 난수(random value)로서 초기화 하였다. 또한 입력벡터 $[I \times 1]$ 는 신경회로망 입력변수로 선정한 13개의 파형인자들 각각의 최소값을 -1로, 최대값을 1로 정규화(normalizing)시켜 $[-1, 1]$ 범위의 값을 가지도록 하였고 또한 신경회로망의 학습에 의해 예측된 스파터 발생량인 출력벡터 $o\{K \times 1\}$ 또한 최소, 최대값에 대해 정규화(normalizing)시켜 $[-1, 1]$ 범위의 값을 가지도록 하였다. 학습율은 0.1로 설

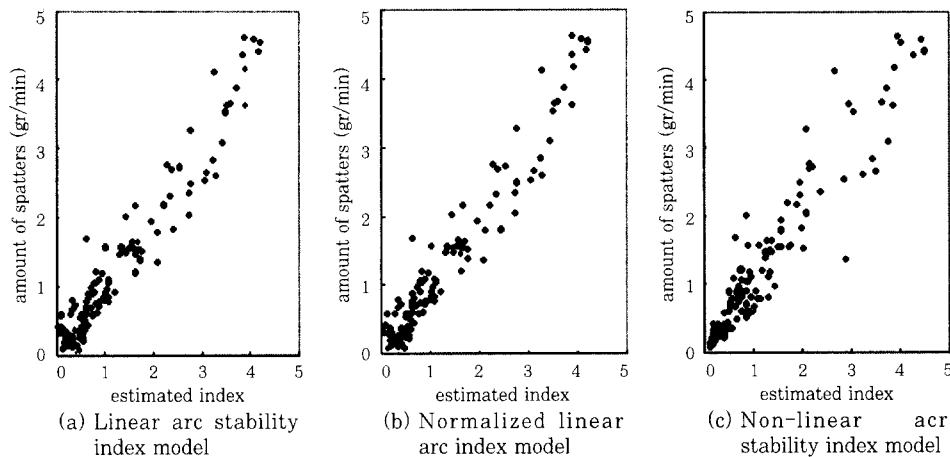


Fig. 5 Relationship between the estimated arc stability index and the weight of spatters for various regression models⁹⁾

정하였고, 수렴오차는 정규화된 출력변수의 예측결과와 정규화된 실제 스패터 발생량의 총 오차량에 대해서 0.002로 하였다.

4. 스패터 발생량에 대한 신경회로망 모델의 예측성능

Fig. 5는 앞서 보고하였던것으로써⁹⁾, 2장에서 언급된 용접조건하에서 상기 13개의 파형 인자들을 사용하여 스패터 발생량을 예측하기 위해서 다중회귀분석에 의해 제안되었던 두개의 선형 예측 모델들과 한 개의 비선형 예측 모델의 성능을 평가한 것을 나타낸 것이다.

그림에서 보면 이들 모델들은 스패터 발생량과 대체로 선형적 관계를 나타내고 있는데, 2개의 선형모델은 비선형 모델에 비해 비교적 좁게 분포하는 특성을 나타냄으로써 전체적으로 스패터 발생량을 예측함에 있어서 보다 좋은 성능을 보이고 있으나 예측값이 1이하의 낮은 값에서는 비선형 모델의 경우가 선형모델들보다 정확하게 묘사하고 있음을 알 수 있다. 특히 비선형 모델의 경우에서 예측값의 증가와 더불어 실제 스패터 발생량과의 오차량이 더욱 커지게 되는 특징을 나타내고 있기 때문에 아크의 상태를 잘못 예측할 수 있음을 알 수 있다.

또한 스패터 발생량의 다중상관계수는 표준화되지 않은 인덱스 모델(Fig. 5(a))이 0.9684로 가장 우수하였다. 한편, 스패터 발생량이 적은 용접조건에 있어서는 비선형 회귀모델의 예측성능이 선형 모델 보다 매우 우수하였다.

Fig. 6은 본 연구에서 실시된 모든 용접전류와 용접전압조건 하에서 용접을 하였을 때 얻어진 13개의 파

형인자들을 입력변수로 하고 스패터 발생량을 출력변수로 하여 인공신경회로망의 학습에 의해 예측된 스패터 발생량과 실제 스패터 발생량을 비교하여 나타낸 것이다. Fig. 6에서 알 수 있듯이, 예측된 스패터 발생량과 실제 스패터 발생량은 거의 직선적인 관계를 나타내었다. 특히 스패터 발생량이 0.5 gr/min 이상인 영역에서는 오차량과 실제 스패터 발생량이 거의 같게 나타났다. 그러나 스패터 발생량이 0.5 gr/min 이하의 영역에서는 예측된 스패터 발생량과 실제 스패터 발생량 사이에 약간의 오차가 발생됨을 보이고 있다. 즉 이 영역에서의 오차비율(오차량/실제 스패터 발생량)이 거의 100% 달할 수 있음을 알 수 있다. 그러나 오차비율이 클지라도 스패터 발생량이 적으며 오차량이 안정한 범위내에 있고, 또한 같은 영역에 있어서 Fig. 5의 다중회귀분석에 의한 예측결과 보다 탁월한 예측결과를 보이고 있음을 알 수 있다. 한편 Table 1에서 알 수 있듯이, 예측된 스패터 발생량과 실제 스패터 발생량 사이의 선형상관계수는 0.9986으로 나타났고, 특히




Fig. 6 Relationship between the weight of the estimated and the real spatter generation using multi-layer artificial neural network

Table 1 Regression characteristics of several estimated models

	Multiple regression analysis			Neural network model
	Linwear model	Normalized linear model	Nonlinear model	
Multiple correlation coefficients	0.9682	0.9682	0.9441	0.9986
Adjusted R ²	0.9345	0.9345	0.9058	0.9965
Standard error	0.2972	0.2972	0.3134	0.0691

표준오차에 있어서 회귀모델에 의한 예측 오차가 약 30 % 인데 반하여 다층 신경회로망에 의한 오차는 6.9 %로 나타나서 우수한 예측성능을 가짐을 알 수 있다.

Fig. 7은 본 연구에서 실시된 모든 용접전류와 전압 조건하에서 신경회로망의 학습에 의해 예측된 스패터 발생량과 실제 스패터 발생량사이의 오차량을 나타낸 것으로써, 스패터 발생량에 대한 최대 오차량은 0.23 gr/min이었다. 이때의 실제 스패터 발생량이 4.62 gr/min이었고 오차비율은 4.978 % 인 점을 생각한다면 매우 정확한 예측결과임을 확인 할 수 있다. 또한 전반적으로 오차량의 범위가 0.1 gr/min 안에 분포하고 있음을 보이고 있다. 따라서 스패터 발생량의 예측에 있어서 다중회귀분석에 의한 회귀모델보다 인공신경회로망에 의한 예측모델이 훨씬 우수한 정확성을 가짐을 알 수 있다.




Fig. 7 Error between the weight of the estimated and the real spatter generation in overall range

Fig. 8은 용접전류를 150A로 설정하였을 때, 용접전압에 따른 실제 스패터 발생량과 다층 신경회로망의 학습에 의해 예측된 스패터 발생량의 적합도를 평가한 것이고, Fig. 9는 학습에 의한 예측 결과와 실제 스패터 발생량 사이의 오차량을 나타낸 것이다. 여기에서 실제 스패터 발생량과 학습결과에 의한 예측값의 비교를 오차비율로 표시하지 않고 오차량으로 표시한 것은

스패터 발생량이 많은 용접의 경우에는 오차비율이 매우 적게 나타나지만, 위에서 언급한 바와 같이, 스패터 발생량이 0.5 g/min 이하인 경우에 있어서는 오차량과 실제 스패터 발생량 모두 적게 나타나서 오차비율이 크게 나타나는 현상(최대 100%이상)이 발생하기 때문이다. 이러한 경우, 예측성능의 평가에 혼동을 발생시킬 우려가 있다.

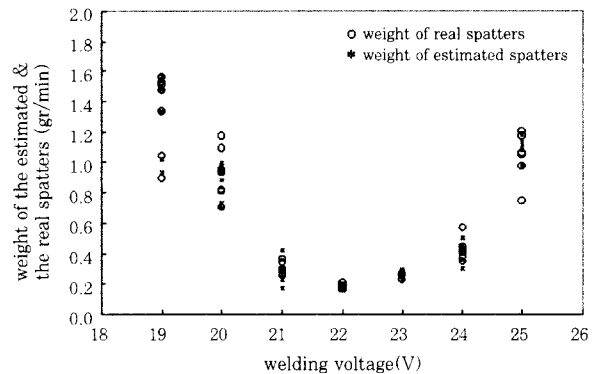


Fig. 8 Comparison between the weight of the estimated and the real spatters at welding current 150A

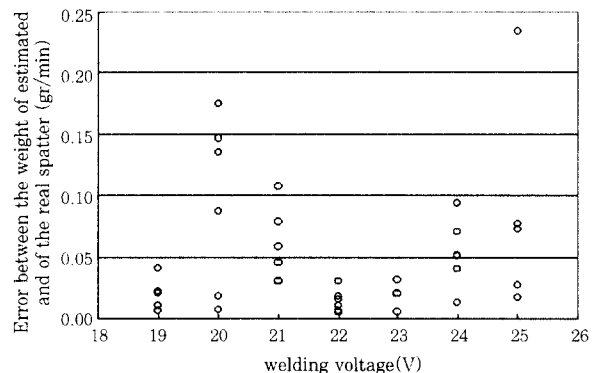


Fig. 9 Error between the weight of the estimated and the real spatters at welding current 150A

Fig. 8과 9를 살펴보면 학습에 의해 예측된 스패터 발생량은 실제 스패터 발생량과 거의 일치하고 있음을 알 수 있다. 특히 아크 상태가 안정한 22 V의 용접조건에서는 예측된 결과와 실제 스패터 발생량의 오차가

0.03 gr/min이내에 있음을 보이고 있다. 그러나 용접 전압 20V의 조건과 25 V의 조건에서 대부분의 경우, 예측된 결과와 실제 스파터 발생량의 오차가 0.1 gr/min이내에 있어서 예측결과가 우수하지만, 0.15 gr/min이상의 예측오차가 발생하는 경우도 있었다.

Fig. 10는 용접전류가 200A로 설정되었을 때 용접 전압의 변화에 따른 실제 스파터 발생량과 다층 신경회로망의 학습에 의해 예측된 스파터 발생량의 적합도를 평가한 것이고, Fig. 11은 학습에 의한 예측 결과와 실제 스파터 발생량 사이의 오차량을 나타낸 것이다.




Fig. 10 Comparison between the weight of the estimated and the real spatters at welding current 200A




Fig. 11 Error between the weight of the estimated and the real spatters at welding current 200A

Fig. 10와 11을 살펴보면, 200A의 모든 용접전압 조건에서 예측된 결과가 실제 스파터 발생량과 매우 일치하고 있음을 볼 수 있다. 즉 예측오차가 대부분의 경우에서 0.1 gr/min이내로 나타나는 결과를 얻을 수 있었다. 특히 아크 상태가 불안정하여 스파터가 많이 발생하는 20V와 26V의 전압조건에서 예측오차가 0.1 gr/min으로 나타난 것은 다층신경회로망에 의한 스파터 발생량 예측성능이 매우 우수함을 반증하는 것이다.

Fig. 12는 용접전류가 225A로 설정되었을 때 용접 전압의 변화에 따른 실제 스파터 발생량과 다층 신경회로망의 학습에 의해 예측된 스파터 발생량의 적합도를 평가한 것이고, Fig. 13은 학습에 의한 예측 결과와 실제 스파터 발생량 사이의 오차량을 나타낸 것이다.




Fig. 12 Comparison between the weight of the estimated and the real spatters at welding current 225A




Fig. 13 Error between the weight of the estimated and the real spatters at welding current 225A

Fig. 12와 13을 살펴보면, Fig. 10과 11의 경우와 마찬가지로 225A의 모든 용접전압조건에서 예측된 결과가 실제 스파터 발생량과 매우 일치하고 있음을 볼 수 있다. 특히, 225A의 용접조건은 CTWD가 20mm로 150A나 200A의 용접조건과 다소 다른 용접조건임에도 불구하고 대부분의 예측오차가 0.1 gr/min이내로 나타나는 결과를 얻을 수 있었다. 특히 아크 상태가 불안정하여 스파터가 많이 발생하는 22V와 28V의 전압조건에서조차 예측 오차가 대부분 0.05 gr/min이내로 나타났다.

Fig. 14는 용접전류가 250A로 설정되었을 때 용접 전압의 변화에 따른 실제 스파터 발생량과 다층 신경회로망의 학습에 의해 예측된 스파터 발생량의 적합도를 평가한 것이고, Fig. 15는 예측 결과와 실제 스파

터 발생량 사이의 오차량을 나타낸 것이다. 250A의 경우 28V 이상의 용접전압조건에서 입상이행(globular transfer)과 단락이행이 불규칙적으로 함께 나타났기 때문에 28V 이상의 전압조건의 결과는 파형인자들의 정보를 추출하는데에 오차가 있으므로 이들 조건에서 다층 신경회로망을 이용하여 아크 안정성을 예측하는데에는 적용될 수 없었다.




Fig. 14 Comparison between the weight of the estimated and the real spatters at welding current 250A




Fig. 15 Error between the weight of the estimated and the real spatters at welding current 250A

Fig. 14와 15를 살펴보면, Fig. 12와 13의 경우와 마찬가지로 대부분의 용접조건에서 예측된 결과가 실제 스파터 발생량과 잘 일치하고 있음을 볼 수 있다. 그러나 아크 상태가 불안정하여 스파터가 많이 발생하는 23V의 전압조건에서 예측오차가 0.01~0.23 gr/min으로 나타났다. 하지만 이 조건에서의 스파터 발생량이 약 4.5 gr/min인 점을 감안한다면 매우 좋은 예측결과를 나타낸 것으로 볼 수 있다.

그러므로 GMA용접의 단락이행영역에 있어서 용접 전류와 아크 전압파형으로부터 추출된 파형인자들을 다층 신경회로망의 입력으로 하여 아크 안정성을 예측한 결과 지금까지 보고된 많은 연구결과보다 우수한

예측성능을 가짐을 확인하였다.

5. 결 론

GMA용접의 단락이행영역의 용접전류 및 용접전압 조건에 있어서, 다층 신경회로망을 사용하여 스파터 발생량을 정량적으로 학습하여 아크 안정성을 예측할 수 있는 모델을 개발하고자 하였다. 이를 위하여 단락 이행모드로 용적이 이행하는 용접조건들에서 용접하였을 때 용접전류와 아크전압 파형을 구성하는 13개의 파형인자들을 추출하였고 이들 13개의 인자들을 다층 신경회로망의 입력변수로 하였다. 이들 13개의 입력변수들의 값은 각각의 최소값을 -1로, 최대값을 1로 정규화(normalizing)시켜 [-1, 1] 범위의 값을 가지도록 하였다. 이렇게 정규화된 입력변수들에 대해서는 은닉층을 2층(20X20), 스파터 발생량을 출력변수로 하고, 학습율을 0.1, 수렴오차를 0.002로 하였을 때 얻어진 학습결과를 바탕으로 다음과 같은 결론을 얻을 수 있었다.

1. 예측된 스파터 발생량과 실제 스파터 발생량의 선형상관계수가 0.9986으로 거의 선형적인 상관관계를 나타내었으며 각각의 용접조건에서의 예측오차량은 대부분 0.1 gr/min이내에 들었다.
2. 스파터 발생량에 대한 다층 신경회로망에 의한 예측결과는 다중회귀분석에 의한 예측결과보다 매우 우수하게 나타났으며, 특히 아크 상태가 불안정한 스파터가 많이 발생하는 용접조건에서조차도 매우 탁월한 예측성능을 보였다.
3. 용접전압의 변화에 따른 다층 신경회로망의 예측성능을 평가한 결과 거의 대부분의 용접조건에서 실제 스파터 발생량을 적합하게 예측하고 있음을 알 수 있었다.
4. 본 연구는 GMA용접의 단락이행영역의 조건에 한하여 아크 안정성을 예측할 수 있는 모델을 개발하고자 하였다. 따라서 250A의 용접전류에 있어서 28V이상의 용접조건에서는 입상이행과 단락이행이 혼재하여 나타나서 이 때의 결과들이 본 연구에 적용될 수 없었다.

참 고 문 헌

1. T. Arai, M. Kobayashi, T. Yamada, M. Rokujo, K. Hirakoso and T. Kaneko : The investigation of arc phenomena by means of a computer, Quarterly Journal of the Japan Welding Society, Vol. 1, No. 3, (1983), pp.15-20.

2. W. Lucas : Microcomputer system, Software and expert system for welding engineering, *Welding Journal*, Vol. 66, No. 4, (1987), pp.19-30.
3. B. Ogunbiyi and J. Norrish : GMAW metal transfer and arc stability assessment using monitoring indices, *Computer Technology in Welding*, Six International Conference, Lanaken, Belgium, 9-12, June, (1996).
4. T. Mita, A. Sakabe and T. Yokoo : Quantitative estimates of arc stability for CO₂ gas shielded arc welding, *Welding International*, No. 2, (1988), pp.152-159.
5. T. Shinoda and H. Nishikawa : Monitoring and signal processing of short circuiting metal transfer of metal active gas welding process, *Proc. of the Int. Conf. On the Joining of Materials*, May 31 - June 2, (1995), pp. 558-565.
6. 김희진, 강봉용, 이강희, 유중돈 : CO₂용접의 단락이행 조건에서 스파터발생과 파형인자의 관계, *대한용접학회*, Vol. 16, No. 3, (1998), pp. 95-101.
7. 강봉용, 이창한, 김희진, 장희석 : CO₂용접의 천이이행 조건에서 스파터발생과 파형인자의 관계, *대한용접학회*, Vol. 16, No. 4, (1998), pp. 39-46.
8. 강성구, 문형순, 나석주 : 스파터 양을 이용한 아크 안정성 판별에 관한 연구, *대한용접학회지*, 제15권, 제6호, (1997), pp. 527-534.
9. 강문진, 이세현, 엄기원 : GMA용접의 단락이행영역에 있어서 아크 상태 평가를 위한 모델 개발, *대한용접학회지*, 제17권, 제4호, (1999), pp. 296-303