

탄산 가스 아크 용접에서 회귀 분석과 인공 신경망을 이용한 아크 센서 모델 개발

김 용 재* · 이 세 현**

*두산중공업 기술연구원 용접기술연구팀

**한양대학교 공과대학 기계공학부

Development of Arc Sensor Model Using Regression Analysis and Artificial Neural Network in CO₂ Arc Welding

Yongjae Kim* and Sehun Rhee**

*Welding Technology Research Team, Doosan Heavy Industries & Construction Co. Ltd., Changwon 641-792, Korea

**School of Mechanical Engineering, Hanyang University, Seoul 133-791, Korea

Abstract

The experimental model of arc sensor in CO₂ arc welding has been individually developed according to welding condition and welding procedure. Therefore, the development of new arc sensor having the features of all conventional arc sensor is important in point of its application to various welding environment. In this study, the arc sensor experimental models comprised of a regression model and noise term were formulated using conventional arc sensing algorithm such as current area difference, current integration difference and weaving end current difference method, and their features were observed. The new regression arc sensor model was suggested using multiple linear regression analysis using current variables as independent variables of regression analysis. The artificial neural network model was also suggested where current variables and offset distance was used input/output variables of input/output node.

(Received February 19, 2002)

Key Words : CO₂ arc welding, Arc sensor, Current area difference, Current integration difference, Weaving end current difference, Linear regression analysis, Artificial neural network

1. 서 론

가스 메탈 아크 용접에서 아크 센서 모델은 크게 수학적 모델과 실험 모델로 구분된다. 수학적 모델은 용접 현상을 수식으로 표현함으로써, 현상을 개념적으로 파악하고 이를 실제 실험과 비교하여 전체적인 실험의 신뢰도를 검증할 수 있는 자료로 사용할 수 있고, 컴퓨터 모의실험을 통해 실제 실험을 대신할 수 있는 장점을 가지고 있다¹⁾. 하지만, 수학적 모델은 용접 현상이 갖는 복잡성을 많은 가정을 통해 단순화시키기 때문에 실제 현상과는 차이를 보이게 되어 실제 시스템에 적용시키는 데 다소 무리가 있었다. 실험 모델은 제어 대상이 구체적인 경우 그 대상에 대한 실험만으로 모델을 구할

수 있어 아크 센서 모델로 주로 사용된다. 이런 실험 모델은 센싱 방법에 따라, 위빙 끝단 사이의 전류 값을 구분하여 적분 비교하는 적분 방식^{2,3)}, 위빙 중간점의 전류 값을 미분하여 부호를 비교하는 미분 방식, 위빙 끝단에서의 전류 값을 비교하는 위빙 끝단 전류 비교 방식⁴⁾, 위빙 끝단과 최저 전류 값을 갖는 점 사이의 시간차를 비교하는 시간 비교 방식, 측정된 아크 신호의 주파수 스펙트럼으로부터 변위를 감지하는 주파수 분석 방식⁵⁾, 위빙 끝단과 중간 점에서의 기준 전류 값과 측정 전류 값을 비교하는 기준치 비교 방식 등이 있다. 그러나 오프셋 거리(offset distance, 용접선에서 토치 위빙 중심선까지 거리)와 센서 신호 사이의 관계를 단순 1차 선형식만으로 나타낸 실험 모델은 실제 현상이 갖고 있는 센서 오차를 나타낼 수 없기 때문에 이를 기

반으로 설계된 제어기는 추적 중 생기는 신호 노이즈에 많은 영향을 받았다.

한편, 이들 각각의 수학 모델 및 실험 모델은 용접 조건과 공정별 특징을 고려하여 개별적으로 개발되었다. 하지만, 이러한 아크 센서 모델 모두는 용접 중 발생하는 오프셀 거리를 효과적으로 인식하여 벗어난 용접선을 추적하는 '용접선 추적'이라는 하나의 목적을 가지고 있다. 따라서 각 방식별 특징을 모두 가지고 있으면서 보다 우수한 용접선 추적 성능을 가지는 아크 센서 방식을 개발한다는 것은 다양한 용접 환경에 적용할 수 있다는 점에서 중요하다고 할 수 있다.

본 연구에서는, 우선 아크 센서 방식으로 가장 많이 사용되는 전류 면적 차이(current area difference, CAD) 방식, 전류 적분 차이(current integration difference, CID) 방식과 위빙 끝단 전류 차이(weaving end current difference, WED) 방식의 각 방식별 아크 센서 회귀 모델을 구하고, 그들의 특성을 살펴보았다. 그 후 각 방식별 변수를 설명 변수(independent variable or regressor)로 하는 회귀 분석(regression analysis)을 통해 새로운 회귀 모델을 유도하였다. 또한 각 방식별 변수를 입력 노드(node)의 입력 변수로, 오프셀 거리를 출력 변수로 하는 인공 신경망(artificial neural network) 모델을 제안하였다.

2. 아크 센서의 원리

용접 토치가 V 그루브 위를 위빙할 때, 심선 송급 속도가 일정할 경우 용접 전류는 팁-모재간 거리(contact tube to work-piece distance, CTWD)에 따라 달라진다. Fig. 1은 시간에 따른 용접 전류의 변화를 나타낸다. 여기서 점선은 용접선과 위빙 중심선이 일치할 경우의 전류 변화이며, 실선은 용접선과 위빙 중심선이 일치하지 않아 오프셀 거리가 존재하는 경우를 나타낸다. 이처럼 오프셀 거리가 존재할 때 전반부 1/2 위빙 주기 동안의 전류 적분 값(CID_{1st half})과 후반부 1/2 위빙 주기 동안의 전류 면적 값(CID_{2nd half})에 차이가 생기게 된다. Fig. 2는 Fig. 1을 토치 위빙 위치에 따른 전류 변화로 나타낸 것이다. 점선은 오프셀 거리가 0일 경우일 때이고, 오프셀 거리가 존재할 때의 전류 변화 모습은 실선과 같다. 용접선과 토치 위빙 중심선이 일치하지 않으면 위빙 양 끝단의 전류 값에 차이가 생기며(WED_{right} - WED_{left}), 전류 면적에도 차이가 생긴다(CAD_{right} - CAD_{left}). 이러한 전류 적분 차이, 위빙 끝단 전류 차이와 전류 면적 차이는 토치 위빙 중심선이 용접선에서 멀리 벗어날수록 큰 값을 가지며, 따라서 토치의 위빙 중심선이 용접선에서 얼마나 치우쳐 있는가의 정보를 가지게 된다

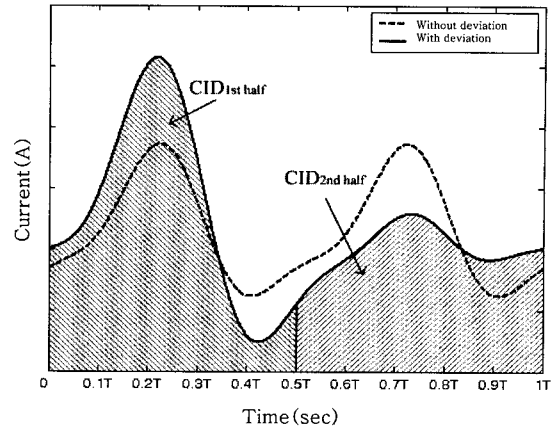


Fig. 1 Welding current variation with time

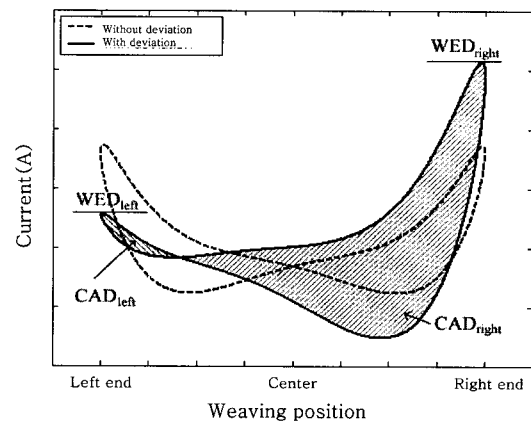


Fig. 2 Welding current variation with weaving position

3. 단순 선형 회귀 분석을 이용한 아크 센서 모델

아크 센서의 수학 모델은 많은 가정을 수반하여 용접 현상이 갖는 비선형성 및 복잡성을 충분히 표현하지 못하는 제약이 있다. 때문에 이를 직접 선형 제어에 사용하였을 때 아크 센서의 추적은 예기치 못한 결과를 가져올 수 있다. 따라서 실제 실험을 통한 실험 모델이 필요하고, 이 모델을 통해 센서의 기본 노이즈라든가 추적 제어에 사용할 아크 센서의 선형성을 파악하여 용접선 추적 전략을 세워야 한다.

우선, 전류 면적 방식, 전류 적분 방식 그리고, 위빙 끝단 전류 비교 방식을 통한 아크 센서 모델을 각각 구하였다. Table 1의 용접 조건에 대해, -3mm 에서 1mm 간격으로 3mm까지의 오프셀 거리에 따라 위빙 하면서 용접을 실시하였다. 한 번 실험에 10회 위빙하면서 각각 4회씩 반복 실험하여 전류 값을 얻었다.

전류 신호는 홀소자(hall sensor)를 사용해 얻어 절단 주파수(cut-off frequency)가 6 Hz인 저역 통과

Table 1 Welding condition for experiment

Variables	Conditions
Wire feed rate	5.5 m/min
Welding speed	4 mm/sec
Welding voltage	24 V
Shielding gas(flow rate)	100% CO ₂ (20 l/min)
Welding wire	1.2 mmφ ER70S-6
Base metal(thickness)	SS400 (9mm)
Groove angle	90°
Center contact tube to workpiece distance	20mm
Weaving width	8mm
Weaving frequency	1 Hz
Metal transfer mode	short-circuit

필터(low pass filter)를 거치게 한 후 2 kHz의 샘플링 속도로 처리하였다. 전류 신호를 통해 각각 좌우 전류 면적 차이, 전류 적분 차이와 위빙 끝단 전류 차이를 계산하고, 이를 저장하였다. 각각의 데이터들은 가중치가 0.5인 이동 평균법(moving average algorithm)을 사용하여 전원 노이즈와 기본 노이즈를 제거하는 디지털 필터링 처리를 하였다.

3.1 전류 면적 차이 모델

설명 변수를 오프셋 거리로, 응답 변수(dependant variable or response variable)를 전류 면적 차이로 하는 단순 선형 회귀 분석(simple linear regression analysis)을 실시하였다. 이 때의 회귀식(regression model)은 식 (1)과 같다. 이 때, 실험을 통해 얻은 평균 잔차(각 수준의 잔차 제곱합 평균의 양의 제곱근 값)인 1.20 A·sec 를 표준 편차가 1인 표준 정규 분포를 갖는 랜덤 노이즈에 곱하여 센서 노이즈($N(0, 1.20^2)$)로 가정하였다⁶⁾. 여기서, x_{offset} 은 오프셋 거리를 나타내며, y_{CAD} 는 전류 면적 차이를 의미한다.

$$y_{CAD} = 0.989x_{offset} + 0.233 + N(0, 1.20^2) \quad (1)$$

일반적으로 회귀식의 적합도를 평가하기 위한 지표로 결정 계수(coefficient of determination, R^2)와 추정 값의 표준 오차(standard error of estimate)를 사용한다. 그리고 단순 회귀 분석에서는 표본의 수가 충분히 크지 않을 때 자유도를 고려하여 수정된 결정 계수(adjusted coefficient of determination, \bar{R}^2)를 사용하게 된다. 이를 식 (2)⁷⁾에 나타냈다.

$$\bar{R}^2 = 1 - \frac{n-1}{n-p-1}(1-R^2) \quad (2)$$

여기서, n 은 표본의 크기이고, p 는 설명 변수의 수이다. 단순 회귀 분석에서 $n=280$ 이고, $p=1$ 이다.

식 (1)에서 수정된 결정계수는 0.731이며, 이 회귀식을 통해 오프셋 거리를 추정할 때의 표준 오차는 1.04mm로 나타났다. 결정 계수는 응답 변수인 전류 면적 차이의 변동을 설명 변수인 오프셋 거리의 변동으로 설명할 수 있는 정도를 나타낸다. 이 값이 클수록 (0.9 이상) 예측 성능이 좋아짐을 고려할 때, 0.731의 값은 상대적으로 작은 값이라고 할 수 있다.

Fig. 3은 식 (1)을 통해 예측한 오프셋 거리를 실제 오프셋 거리에 대해 나타낸 것이다. 그림에서 알 수 있듯이 데이터들은 무거운 꼬리(heavy tailed) 분포를 하고 있다. 이는 오프셋 거리가 작은 경우(-1mm~1mm)에는 작은 추적 오차들이 계속 발생하고, 큰 오프셋 거리가 생겼을 때는 곧바로 용접선을 인식하여 추적할 수 있음을 의미한다. 이 점이 전류 면적 방식의 특징이라고 할 수 있다. 따라서 Kim⁸⁾은 아크 센서 모델을 3차 다항 회귀 모델(third-order polynomial regression model)로 가정하고, 외란에 강한 퍼지 제어를 설계하여 추적 오차를 줄이는 연구를 수행한 바 있다.




Fig. 3 Estimated offset distance using current area difference model

3.2 전류 적분 차이 모델

전류 적분 차이 모델의 경우에 평균 잔차가 1.15 A·sec임을 고려하여 구한 실험 모델은 식 (3)과 같다. 여기서, y_{CID} 는 전류 적분 차이를 의미한다.

$$y_{CID} = 1.61x_{offset} + 0.598 + N(0, 1.15^2) \quad (3)$$

이 때 수정된 결정계수는 0.887로서, 전류 면적 방

식의 0.731보다 큰 값을 가졌다. 이는 해당 회귀식이 오프셋 거리를 예측하는데 전류 면적 방식보다 더 유리하다는 것을 의미하며, 회귀식을 통해 오프셋 거리를 추정할 때의 표준 오차(0.674mm)도 전류 면적 방식의 경우(1.04mm)보다 작은 값의 좋은 결과로 나타났다.

Fig. 4는 식 (3)을 통해 예측한 오프셋 거리를 실제 오프셋 거리에 대해 나타낸 것이다. 예측 값의 흩어진 정도(degree of scattering)도 전류 면적 방식의 경우보다 작음을 알 수 있다. 또한, 데이터들은 가벼운 꼬리(light tailed) 분포를 하고 있다. 따라서 전류 적분 모델은, 오프셋 거리가 작은 경우에는 추적 성능이 우수하지만, 큰 외란이 생겼을 경우에는 용접선으로 용접 토치가 다시 돌아오는데 다소의 시간이 걸릴 가능성이 있다고 판단할 수 있었다.




Fig. 4 Estimated offset distance using current integration difference model

3.3 위빙 끝단 전류 차이 모델

오프셋 거리에 따른 위빙 끝단 전류 차이를 나타내는 회귀 모델은 평균 잔차가 6.78 A임을 고려하여 식 (4)로 나타낼 수 있다. 여기서, y_{WED} 는 위빙 끝단 전류 차이를 의미한다.

$$y_{WED} = 2.45x_{offset} + 4.03 + N(0, 6.78^2) \quad (4)$$

이 때 수정된 결정계수는 0.340으로, 3가지 모델 중 가장 작은 값이었다. 이 회귀식을 통해 오프셋 거리를 추정할 때의 표준 오차는 1.63mm로 나타났다. 이 값은 아크 센서의 일반적인 허용 추적 오차인 1.2mm(실험에 사용한 심선의 직경)를 넘는 값이다. 따라서, 이를 줄이기 위해 위빙 반주기 동안의 데이터를 2차 최소자승법을 통해 커브 핏팅(curve fitting)하여 신호 노이즈를 줄이는 등의 데이터 처리가 필요하게 된다⁹⁾.

Fig. 5는 식 (4)를 통해 예측한 오프셋 거리를 실제 오프셋 거리에 대해 나타낸 것이다.

이상의 아크 센서 방식들 모두는 결정 계수가 0.9 미만의 값으로 나타나 해당 모델을 잘 설명할 수 있는 회귀 모델이라고 말하기 어렵다. 또한, 3가지 모델은 모두 선형 모델을 취하였는데, 이는 용접선 추적 제어기로 선형 제어를 사용하는 이점을 살리고자 한 것이다. 하지만, 선형 모델은 모델을 선형화하는 과정에서 각각의 모델들이 가지고 있는 비선형적 특성을 잃어버리는 단점이 있다.

결론적으로, 이상의 기본 아크 센서 방식의 주된 목적이 용접 중 발생하는 오프셋 거리를 효과적으로 인식하여 벗어난 용접선을 추적하는 것이므로, 각 방식별 특징을 모두 가지고 있으면서 보다 우수한 용접선 추적 성능을 가지는 새로운 아크 센서 방식의 개발이 필요하다고 할 수 있다.




Fig. 5 Estimated offset distance using weaving end current difference model

4. 다중 회귀 분석을 이용한 아크 센서 모델

이 절에서는 기존의 모델을 통합한 새로운 아크 센서 모델을 얻고자, 전류 면적 차이, 전류 적분 차이와 위빙 끝단 전류 차이의 3가지 변수를 설명 변수로, 오프셋 거리를 응답 변수로 하는 다중 선형 회귀 분석(multiple linear regression analysis)을 실시하고 회귀식을 유도하였다

Table 2에 오프셋 거리(Offset)를 응답 변수로 하고, 전류 면적 차이(CAD), 전류 적분 차이(CID)와 위빙 끝단 전류 차이(WED)를 설명 변수로 하는 네 개의 변수간의 상관관계(correlations)를 상관표(correlation table)로 나타내었다.

세가지 설명 변수 모두가 오프셋 거리와 선형 상관관

Table 2 Correlation coefficients between each regressor and offset distance, and between regressors themselves

Model	Offset	CAD	CID	WED
Offset	1.000			
CAD	0.855	1.000		
CID	0.942	0.776	1.000	
WED	0.585	0.540	0.551	1.000

계가 있음을 알 수 있고, 이 중에 CID가 가장 큰 상관 관계를 보였으며, CAD, WED의 순으로 나타났다. 또한 변수들 서로의 상관관계는 그다지 크지 않은 것으로 나타나, 추가적인 설명 변수 선택 과정(variable selection procedures)은 생략하였다.

Table 3은 회귀 모델식의 계수, 이 계수 값을 계수의 표준 오차로 나눈 값인 t 값과 유의 확률(significant probability)을 나타내고 있다. 유의 확률은 3가지 설명 변수 모두 0.05 이하의 값을 가지고 있으므로 이들이 회귀식을 표현하는데 의미가 있는 값들임을 알 수 있다. 또한, F(t²) 검정(F-test)에서 3가지 변수 모두 엄격한 검정 기준인 2 이상의 값을 보이고 있어, 이들이 회귀식을 구성하는데 필요한 변수들임을 확인할 수 있고, t값이 가장 높은 CID가 오프셀을 표현하는데 가장 공헌이 큰 변수임을 알 수 있다. Table 3의 회귀 계수를 통해 얻어진 다중 선형 회귀 모델(multiple linear regression model or MLR model)을 식 (5)에 나타냈다.

$$y = 0.259x_{CAD} + 0.400x_{CID} + 0.0113x_{WED} - 0.345 \quad (5)$$

다중 회귀 분석의 경우에도 결정 계수는 회귀식의 적합도를 평가하기 위한 중요한 지표이다. 하지만, 설명 변수가 많아질수록 결정 계수 값이 커지는 성향을 가지고 있어서, 다중 회귀 분석에서도 결정 계수 대신 수정된 결정 계수를 사용하게 된다.

식 (5)의 경우에 수정된 결정 계수가 0.927로 나타

Table 3 Coefficients of regression model

	Regression coefficients	t	Significant probability
(Constant)	-0.345	-9.459	8.451E-19
CAD	0.259	11.378	1.055E-20
CID	0.400	25.778	1.055E-20
WED	0.0113	2.379	0.804E-02

났다. 이 값은 기존 방식보다 더욱 1에 가까운 값으로서, 이는 MLR 모델이 상당히 정확하게 해당 모델을 나타내고 있다는 것을 의미한다. 추정 값의 표준 오차도 0.542mm로 나타나 MLR모델이 기존 방식보다 우수한 예측 성능을 보임을 알 수 있었다. Fig. 6은 오프셀 거리와 식 (5)를 통해 추정한 오프셀 거리와의 관계를 나타낸다. 오프셀 거리의 대소에 관계없이 어느 구간에서나 일정한 예측 성능을 보임을 볼 수 있고, 각 수준의 잔차 값도 일정하게 나타남을 알 수 있다.




Fig. 6 Estimated offset distance using multiple linear regression model

5. 인공 신경망을 이용한 아크 센서 모델

이 절에서는 전류 면적 차이, 전류 적분 차이와 위빙 끝단 전류 차이의 3가지 인자를 입력 값으로, 오프셀 거리를 출력 값으로 하는 인공 신경망을 구성하고, 이를 통해 새로운 아크 센서 모델을 얻고자 하였다.

인공 신경망 구성에 오류 역전파 알고리즘(error back propagation algorithm)을 사용하였고, 뉴런 모델(neuron model)로는 수렴 속도가 빠르고 안정적인 Levenberg-Marquart 모델¹⁰⁾을 사용하였다. 전형적인 전방위 다층 퍼셉트론(feedforward multilayer perceptron)을 가진 신경망 모델은 입력 층, 은닉 층과 출력 층을 가진다. 본 연구에서는 2개의 은닉 층을 가진 [3×l×m×1]의 신경망 구조를 사용하였다. 이와 같은 뉴런 모델을 Fig. 7에 나타내었다. 여기서, x_i는 입력 층의 입력 벡터, y_j와 z_k 및 o는 각각 은닉 층과 출력 층의 출력 벡터이고, u_{ji}와 v_{ki} 및 w_k는 각 층의 연결 강도 배열이다. l과 m은 은닉 층의 뉴런수로서 본 연구에서는 l=m=N의 같은 수를 사용하여 [3×N×N×1]

의 신경망을 구성하였다. 전달 함수(transfer function or activation function)로는 입력 층과 은닉 층, 은닉 층과 은닉 층 사이에서는 바이폴라 시그모이드(bipolar sigmoid) 함수를 사용하였고, 은닉 층과 출력 층 사이에서는 선형 함수를 사용하였다.

한편, N 값은 신경망 변수 개수가 학습(training)에 사용되는 데이터 개수(280개중 유효성 판정 데이터(validation date) 70개와 시험 데이터(testing date) 70개를 뺀 140개)를 넘지 않도록 9의 정수 값을 사용하였다. N 값이 9인 경우의 총 신경망 변수 개수는 136이 되고, 이 값은 신경망이 가질 수 있는 최대의 변수 개수가 된다. N 값이 너무 작으면 신경망은 언더피팅(underfitting)되어 예측 오차가 커지게 되고, N 값이 9를 넘게 되면 신경망은 오버피팅(overfitting)되어, 학습 데이터에 대한 예측 오차는 매우 작아지지만, 학습에 사용하지 않은 새로운 데이터에 대한 예측 성능은 나빠지는 경향을 가지게 된다¹¹⁾. 따라서 본 연구에서는 학습 오차를 줄일 수 있을 만큼의 충분한 N 값을 가지면서도 신경망의 일반성(generalization)을 유지할 수 있도록 신경망 구성에 개선된 일반화(improving generalization) 방법을 사용하였다. 일반적으로 신경망의 개선된 일반화 방법에, 목적 함수(performance function)에 신경망의 연결 강도항(weights and biases)의 제곱합 평균(mean sum of squares)을 포함시켜 연결 강도값을 작은 값으로 제한하는 수정된 목적 함수(modified performance function) 방법, 필요한 연결 강도값만 사용하는 자동 정규화(automated regularization) 방법과 신경망이 오버피팅 되기 전에 학습을 멈추는 초기 멈춤(early stopping technique) 방법을 사용한다¹⁰⁾. 본 연구에서는 세가지 방법중 가장 빠른 수렴 속도와 우수한 예측 성능을 보인 초기 멈춤 기법을 사용하였다. 이 방법에서는 우선 유효한 데이터를 학습 데이터, 유효성 판정




Fig. 7 Multi layer feed forward neural network

데이터와 시험 데이터의 3부분으로 나눈다. 여기서 시험 데이터의 오차 값은 신경망이 학습되는 동안에 계속 작아지지만, 유효성 판정 데이터의 오차 값은 계속 줄어들다가 신경망이 오버피팅되기 시작하면 다시 커지게 된다. 따라서 이 값이 커지기 시작하는 시점에서 학습을 멈추면 신경망이 오버피팅되는 것을 방지할 수 있다. 또한, 시험 데이터의 오차가 최저가 되는 학습 반복 횟수(iteration number or epoch)와 유효성 판정 데이터의 오차가 최소가 되는 그 때의 반복 횟수를 비교하여 데이터 분할(division)의 적합성을 검증할 수 있다. 즉, 두 값의 차가 심하면, 총 데이터를 다시 나누게 된다.

목적 함수는 오차의 제곱합 평균(mean squared error)을 사용하였고, 학습율(learning rate)은 0.1, 모멘텀 값(momentum coefficient)은 0.7을 사용하였다.

Fig. 8은 학습 과정 중 3가지 데이터의 오차 변화를 나타낸 것이다. 유효성 판정 데이터의 오차가 커지기 시작하는 시점인 23회 반복 학습 후 신경망 학습이 멈추었음을 알 수 있다. 이 때, 학습 데이터의 목적 함수 값은 약 0.015의 값을 가졌다.

위의 학습 과정을 거쳐 구성된 신경망을 사용하여 오프셋 거리를 예측한 결과를 Fig. 9에 나타내었다.

이 때 추정된 오프셋 거리의 표준 오차는 0.375mm로, 이 결과는 기존 방식의 결과는 물론 회귀 모델을 사용한 방식의 결과보다도 더 좋은 결과이다. 이는 인공 신경망 모델이 회귀 모델의 수식으로 표현하기 어려운 좀 더 복잡하고 구체적인 비선형 특성을 나타낼 수 있기 때문인 것으로 생각된다. 결론적으로 용접 현상과 같은 비선형성이 강한 공정에서 아크 센서와 같이 비교적 느린 제어 시스템을 적용할 때 인공 신경망을 사용한 모델이 매우 좋은 제어 성능을 보임을 알 수 있었다.

이상의 결과를 종합적으로 Table 4에 나타내었다. 다중 회귀 분석을 통해 얻은 회귀 모델과 이를 기초로

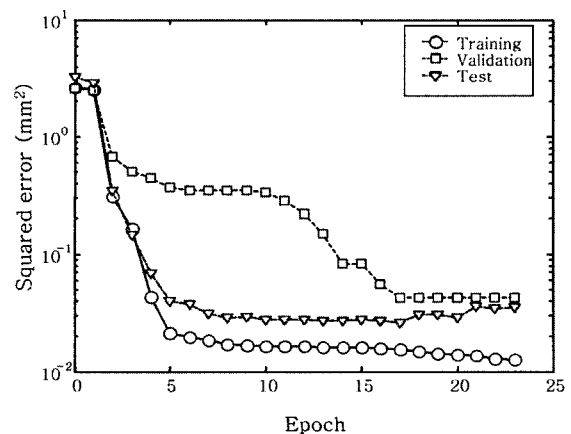


Fig. 8 Three set error variation during training




Fig. 9 Estimated offset distance using neural network model

Table 4 Performance in CAD, CID, WED, MLR and NN model

Model	Adjusted coefficient of determination	Standard error of estimate (mm)
CAD	0.731	1.04
CID	0.887	0.674
WED	0.340	1.63
MLR	0.927	0.542
NN	0.965	0.375

구성된 인공 신경망 모델이 아크 센서 플랫폼을 나타내는 결정 계수 측면에서나, 추정 값의 표준 오차 면에서 기존의 모델보다 우수한 성능을 보이며, 특히 인공 신경망 모델이 더욱 우수한 성능을 가짐을 알 수 있었다.

6. 결 론

1) 단순 선형 회귀 분석을 통해 전류 면적 차이, 전류 적분 차이, 위빙 끝단 전류 차이와 오프셀 거리에 대한 실험 모델을 구하고, 방식별로 특징을 알아 본 결과, 전류 면적 차이를 이용한 경우에는 오프셀 거리가 작은 경우보다 오프셀 거리가 큰 경우에 용접선 정보가 강해지며, 전류 적분 차이를 이용한 모델의 경우에는 오프셀 거리가 비교적 작은 경우에 용접선 정보가 강해지는 경향을 보였다. 위빙 끝단 전류 차이를 이용한 모델의 경우에는 센서 노이즈가 매우 크게 나타나 결정 계수 측면에서나 추정 값의 표준 오차면에서 추적 성능이 떨어지는 특성을 보였다.

2) 전류 면적 차이, 전류 적분 차이와 위빙 끝단 전류 차이를 설명 변수로 하고, 오프셀 거리를 응답 변수로 하는 다중 선형 회귀 분석을 통해 얻은 아크 센서의

실험 모델은 수정된 결정 계수가 0.927, 추정된 표준 오차가 0.542mm로 나타나, 다중 선형 회귀 모델이 용접선을 인식하는데 매우 효과적인 모델임을 알 수 있었다.

3) 전류 면적 차이, 전류 적분 차이와 위빙 끝단 전류 차이를 입력 변수로 사용하고 오프셀 거리를 출력 변수로 사용하며, 일반화 방법으로 early stopping technique을 사용한 인공 신경망 모델의 경우에, 수정된 결정 계수는 0.965, 오프셀 거리를 추정할 때의 표준 오차는 0.375mm로 나타나 5가지 모델 중에 가장 좋은 결과를 보였다.

4) 탄산 가스 아크 용접에서 다중 선형 회귀 모델과 인공 신경망을 사용한 아크 센서 모델이 매우 좋은 용접선 추적 성능을 보임을 알 수 있었다.

참 고 문 헌

1. H. Fujimura, E. Ide and H. Inoue : Robot Welding with Arc Sensing, Sensors and Control Systems in Arc Welding, Chapman and Hall, London (1994), 228-237
2. S. Iwaki : Application of Arc Sensors to Robotic Seam Tracking, Sensors and Control Systems in Arc Welding, Chapman and Hall, London (1994), 209-215
3. Y. Kim, S. Rhee and K. W. Um : A Study of Seam Tracking by Arc Sensor Using Current Area Difference Method, Journal of KWS, 14-6 (1996), 131-139 (in Korean)
4. S. Y. Lee, H. S. Moon, S. J. Na, Y. J. Chang and B. K. Ahn : A Study on Development of Arc Sensor for Arc Welding Robot Using Consumable Electrode, Journal of KWS, 11-3 (1993), 22-33 (in Korean)
5. H. Nomura, Y. Sugitani and N. Tamaoki : Automatic Seam Tracking and Bead Height Control by Arc Sensor, Sensors and Control Systems in Arc Welding, Chapman and Hall, London (1994), 266-278
6. D. C. Montgomery : Design and Analysis of Experiments, John Wiley & Sons, New York (1997)
7. A. Sen and M. Srivastava : Regression Analysis - Theory, Methods, and Applications, Springer-Verlag, New York (1990)
8. Y. Kim and S. Rhee : Development of Arc Sensor Model Using Fuzzy Controller in Gas Metal Arc Welding, Measurement Science and Technology, 12-4 (2001), 534-541
9. J. W. Kim and S. J. Na : A Study on and Arc Sensor for Gas Metal Arc Welding of Horizontal Fillets, Welding Journal, 70-8 (1991), 216s-221s
10. H. B. Demuth and M. H. Beale : Neural Network Toolbox, The MathWorks, Miami (1997)
11. M. T. Hagan, H. B. Demuth and M. H. Beale : Neural Network Design, PWS Publishing Company,