

가스 메탈 아크 용접에서 인공 신경망을 이용한 아크 센서 모델링에 관한 연구

A Study of Arc Sensor Modeling Using Artificial Neural Network in Gas Metal Arc Welding

김용재*, 이세현**

* 한양대학교 정밀기계공학과 대학원

** 한양대학교 기계공학부

1. 서론

아크 센서는, 좌우 토치 위빙 끝단의 전류 값을 비교하는 방식[1], 위빙 반주기마다 전류 값을 적분하여 비교하는 방식[2], 위빙 1/4 주기 별로 전류 값을 적분하여 생기는 전류 면적의 비대칭성을 이용한 방식[3] 등을 사용한 연구가 수행되었다. 이들 각각의 수학 모델 및 실험 모델은 용접 조건과 공정별 특징을 고려하여 개별적으로 발전되어 왔다. 하지만, 결국 이러한 아크 센서 방식들 모두는 용접 중 발생하는 오프셀 거리(토치 중심선이 용접선에서 벗어난 거리)를 효과적으로 인식하여 벗어난 용접선을 추적하는 ‘용접선 추적’이라는 하나의 목적을 가지고 있다. 따라서 각 방식별 특징을 모두 가지며, 보다 나은 용접선 추적 성능을 가진 아크 센서 방식을 개발한다는 것은 다양한 용접 환경에서 범용적으로 적용할 수 있다는 점에서 중요하다고 할 수 있다. 최근에 다중 회귀 분석을 통한 새로운 아크 센서 모델[4]이 제안되기도 하였으나, 용접 현상이 갖는 비선형적 특성을 더욱 잘 표현하는 새로운 모델이 필요하였다.

본 연구에서는, 아크 센서 방식으로 가장 많이 사용되는 위빙 끝단 전류차(WED, Weaving End current Difference), 전류 면적차(CAD, Current Area Difference)와 전류 적분차(CID, Current Integration Difference) 방식을 통합한 새로운 아크 센서 방식을 개발하고자 하였다. 이를 위해, 수학 모델이 필요없고, 비선형 모델을 잘 표현하는 인공 신경망 모델을 도입하였다. 각 방식별 3 가지 인자를 입력 값으로, 오프셀 거리를 출력 값으로 하는 인공 신경망을 구성하여 아크 센서를 모델링하였으며, 새로운 아크 센서 모델의 성능을 가상 용접선 추적 실험을 통해 기존 방식과 비교 분석하였다.

2. 인공 신경망을 이용한 아크 센서 모델링

인공 신경망 구성에 오류 역전파 알고리즘을 사용하였고, 뉴런 모델로는 수렴 속도가 매우 빠른 Levenberg-Marquart 모델을 사용하였다. 입력 변수로는 전류 면적차, 전류 적분차와 위빙 끝단 전류차의 3 가지 인자를 사용하였다. 신경망 구조로는 2 개의 은닉층을 가진 $[3 \times N \times N \times 1]$ 의 구조를 사용하였다. 이 때, N 값은 신경망 변수의 갯수가 학습에 사용되는 데이터 갯수를 넘지 않도록 9의 정수값을 사용하였다. N 값이 너무 작으면 신경망은 언더피팅되어 예측 오차가 커지게 되고, N 값이 9를 넘게 되면 신경망은 오버피팅되어, 학습 데이터에 대한 예측 오차는 매우 작아지지만, 학습에 사용하지 않은 새로운 데이터에 대한 예측 성능은 나빠지는 경향을 가지게 된다[5]. 따라서 본 연구에서는 학습 오차를 줄일 수 있을 만큼의 충분한 N 값을 가지면서도 신경망의 일반성을 유지할 수 있도록 신경망 구성에 초기 멈춤(early stopping) 방법[6]이라는 개선된 일반화 방법을 사용하였다. 이 방법에서는 우선 유효한 데이터를 학습 데이터, 유효성 판정 데이터와 시험 데이터의 3 부분으로 나눈다. Figure 1은 학습 과정 중 3 가지 데이터의 오차를 모니터링한 결과이다. 전달 함수로는 입력층과 은닉층, 은닉층과 은닉층 사이에서는 bipolar sigmoid 함수를 사용하였고, 은닉층과 출력층 사이에서는 선형 함수를 사용하였다. 목적 함수는 오차의 제곱합 평균을 사용하였고, 학습율은 0.1, 모멘텀 값은

0.7를 사용하였다. 학습이 끝난 후, 목적 함수 값은 약 0.015의 값을 가졌다. Figure 2는 이상에서 구성한 신경망 모델을 사용한 경우의, 오프셀 거리와 추정된 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. 이 때의 추정값의 표준 오차는 0.3745(mm)로 나타나 신경망 모델이 기존 방식 뿐만 아니라 다중 회귀 모델의 결과(0.5422)[4]보다 우수한 예측 성능을 보임을 알 수 있었다.

3. 가상 용접선 추적 실험

가상 용접선 추적 실험을 통해 기존 방식과 신경망을 사용한 방식의 용접선 추적 성능을 비교하였다. 25 스텝의 용접선 추적 구간을 가정하고, 오프셀 각도를 5°로, 용접선 총 길이는 100mm, 용접 속도는 4mm/s로 하였다. 센서 노이즈로 정규 분포를 갖는 랜덤 노이즈를 가정하였다. 제어기로는 퍼지 제어기[7]를 사용하였다. 여기서, 평균 추적 오차를 최소로 하는 방식별 최적 계수 인자(scaling factor)를 격자 추적법(grid search method)을 사용하여 구하였다. 이렇게 구한 최적 계수 인자, 평균 추적 오차와 최대 추적 오차를 Table 1에 나타내었다. 신경망 모델을 구성할 때 예측되었던 평균 추적 오차(0.3745mm)가, 최적의 계수 인자를 갖는 퍼지 제어기를 사용함으로써 크게 줄어 들었음(0.2522)을 알 수 있다. 이를 통해, 가상 용접선 추적 실험을 이용하여 구한 퍼지 제어기의 계수 인자가 추적 성능을 개선하는데 큰 역할을 하는 최적의 값을 확인할 수 있었다.

한편, 만약 이렇게 구한 계수 인자 값이 계수 인자의 변화에 대해 시스템이 민감하게 반응하게 하는 값이라면, 제어 시스템의 강인성(robustness)이 떨어지게 된다. 따라서 계수 인자에 대한 제어 시스템의 민감도 분석을 통해 최종적으로 계수 인자의 적합성을 관찰해 볼 필요가 있다. Figure 3(a)는 신경망 모델을 이용한 경우에 있어서, Gde 값이 0.21일 때, Ge와 Gdu의 변화에 따른 목적 함수 값의 변화와 최적점의 위치를 나타낸 것이다. 이 때, 최적점은 안정 한계선인 1.2 윤곽선에 위쪽으로 가까이 위치하고 있다. 이것은 제어기 입력이나 출력에 양(+) 방향의 큰 외란이 발생하면, 시스템이 불안정해지고, 큰 추적 오차가 발생할 수 있음을 의미하는 것이다. 따라서, 보다 안정한 제어기 설계를 위해 새로운 최적 계수 인자를 구하여야 한다. Figure 3(b)는 Gde 값이 0.26일 경우의 새로운 최적점과 목적 함수 값 변화를 보인 것이다. 이 때의 최적 계수 인자와 평균 추적 오차, 평균 최대 추적 오차 값을 Table 2에 나타내었다. 이 때의 평균 최대 추적 오차(1.1393mm)는, Table 1에 나타난 값(1.2080mm)보다 작아졌음을 볼 수 있다. 이것은 안정한 지역의 새로운 계수 인자를 사용함으로써, 비록 평균 추적 오차는 다소 커졌지만, 시스템의 큰 추적 오차 발생 빈도가 줄어들었음을 시사해 준다.

이상에서 구한 최적 계수 인자값들을 사용하여 가상 용접선 추적 실험을 실시하였다. 동일한 형태의 외란에 대한, 3가지 기존 방식, 회귀 모델 그리고 신경망을 사용한 방식의 추적 결과의 한 전형적인 예를 Fig. 4에 비교하여 도시하였다. 신경망(NN) 모델이 가장 우수한 성능을 보였고, 다음으로 다중 선형 회귀(MLR) 모델, 전류 적분 차(CID) 모델이 전체적으로 만족할 만한 결과를 보였다. 결론적으로, 본 연구에서 제안한 신경망 모델을, 최적화된 계수 인자를 갖는 퍼지 제어기와 함께 용접선 추적에 적용한 결과, 평균 추적 오차와 외란에 대한 추적 오차면 모두에서 우수한 성능을 보임을 시각적으로 확인할 수 있었다.

4. 결론

전류 면적 차이, 전류 적분 차이, 위빙 끝단 전류 차이의 3가지 입력 노드와 오프셀 거리를 출력

노드로 하는 인공 신경망을 구축하고, 초기 멈춤 방법을 사용하여 신경망을 최적화, 일반화하였다. 최적화된 인공 신경망 모델이 기존 방식보다 오프셋 거리를 추정하는데 우수한 성능을 보임을 알 수 있었다. 퍼지 제어기 설계에서, 계수 인자를 최적화함으로써 평균 추적 오차가 줄어드는 결과를 얻었고, 따라서 이렇게 구한 계수 인자가 추적 성능을 개선하는데 큰 역할을 하는 최적의 값임을 확인할 수 있었다. 또한, 계수 인자 변화에 따른 제어기 민감도 해석을 통하여 보다 안정한 최적 계수 인자를 결정할 수 있었고, 이를 적용한 퍼지 제어기는 가상 용접선 추적 실험에서 최대 추적 오차가 줄어들음을 보였다. 아울러 평균 추적 오차와 외란에 대한 추적 오차면 모두에서 기존 방식을 사용한 경우보다 우수한 성능을 보임을 확인할 수 있었다. 결국 본 연구에서 제안한 신경망 모델과 퍼지 제어기가, 용접 현상과 같은 비선형성이 강한 공정을 모델링하고, 이 모델을 아크 센서와 같이 비교적 느린 제어 시스템에 적용할 때 매우 좋은 제어 성능을 보임을 알 수 있었다.

참고 문헌

[1] J. W. Kim and S. J. Na : “A Study on and Arc Sensor for Gas Metal Arc Welding of Horizontal Fillets”, *Welding Journal*, Vol. 70, No. 8 (1991), pp.216s-221s.

[2] S. Iwaki : “Application of Arc Sensors to Robotic Seam Tracking”, *Sensors and Control Systems in Arc Welding*, Chapman and Hall, London (1994), pp.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 the Korean Welding Society*, Vol. 14, No. 6 (1996), pp.131-139.

[4] Y. Kim, S. Rhee and M. J. Kang : “A Study of Arc Sensor Modeling using Multiple Regression Analysis in Gas Metal Arc Welding”, *The Spring Conference of The Korean Welding Society in 2001*, (2001), pp.34-39.

[5] M. T. Hagan, H. B. Demuth and M. H. Beale : *Neural Network Design*, PWS Publishing Company, Boston (1996).

[6] H. B. Demuth and M. H. Beale : *Neural Network Toolbox*, The MathWorks, Miami (1997).

[7] Y. Kim, and S. Rhee : “Development of Arc Sensor Model Using Fuzzy Controller in Gas Metal Arc Welding”, *Measurement Science and Technology*, Vol. 12, No. 4 (2001), pp.534-541.




Fig. 1 Three set error variation during training process


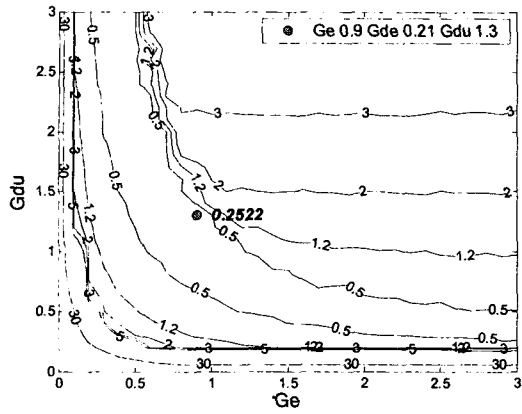



Fig. 2 Estimated offset distance using NN model



(a) Neural network model



(b) Neural network model with new stable scaling factors

Fig. 3 Contour of cost function according to the variation in Ge and Gdu: (a) Neural network model (b) Neural network model with new stable scaling factors

Table 1. Optimal scaling factors in NN model

Model	Ge	Gde	Gdu	Mean error(mm)	Max error(mm)
MLR	2.6	0.15	0.5	0.3679	1.3194
NN	0.9	0.21	1.3	0.2522	1.2080

Table 2. New optimal scaling factors in NN model

Model	Ge	Gde	Gdu	Mean error(mm)	Max error(mm)
New NN	0.8	0.26	1.2	0.2839	1.1393

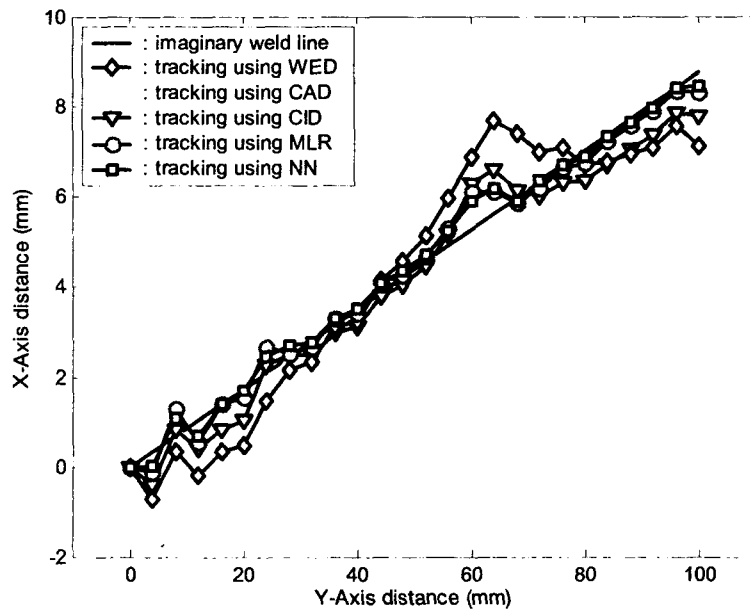


Fig. 4 Results of seam tracking simulation using CAD, CID, WED, MLR and NN model