

## AI 기법을 이용한 용접공정변수 예측 시스템 개발

### Development on a System for Predicting the Welding Parameters Using a AI Technology

김일수\*, 박창언\*, 김학형\*\*, 김인주\*\*, 손준식\*\*

\* 목포대학교 기계공학과, \*\* 목포대학교 대학원 기계공학과

#### 1. 서 론

최근에 신경망을 이용하여 복잡한 시스템의 입력변수 및 출력변수 사이의 상호 관계를 모델링하는 방법이 유용하게 사용되고 있다. 인공지능의 한 부문인 신경망은 생물학적 두뇌를 모방한 초 병렬 컴퓨팅 메커니즘으로 그 안의 많은 상호 연결 가중치(interconnecting weight)에 정보를 저장한다.

Juang<sup>(1)</sup>은 역전파 네트워크와 counter-propagation 네트워크를 연구하여 용접 공정변수와 비드형상 특성 사이의 관계를 규명하고 counter-propagation 네트워크가 역전파 네트워크보다 TIG 용접 공정에서 학습 능력이 더 뛰어나다는 주장하였다. Nagesh와 Datta<sup>(2)</sup>는 최적구조의 신경회로망을 이용하여, 아크용접에서의 비드형상을 예측하는데 역전파 신경망을 이용했다. 이들은 신경망이 비드형상을 예측 및 분석하고 모델링 하는 강력한 수단이라고 발표했다. 또한, Li<sup>(3)</sup>는 SAON(Self Adaptive Offset Network) 신경망을 이용하여 SAW(Submerged Arc Welding) 용접에서 5가지 기하구조 특성과 용접 공정변수 사이의 비선형 관계를 모델로 표현하였다. Tarng<sup>(4)</sup>은 TIG용접 공정을 위한 공정변수와 비드형상 특성 사이의 관계를 연구했고 전역 최적화 알고리즘(global optimization algorithm)을 적용하여 용접 공정변수를 결정하고 역전파 신경망을 이용한 목적함수 기반의 비드형상을 산출해냈다. 신경망을 이용한 용접 공정변수와 비드형상에 대한 많은 연구가 이루어 졌지만 신경망을 이용한 GMA 용접 모델링을 연구한 발표 자료는 많지 않은 실정이다.

본 연구에서는 인공지능 기법을 이용하여 용접 공정 변수예측 시스템 개발하고자 하였으며, 용

접공정을 모델링 하여 용접변수와 비드형상간의 관계를 확인하고, 용접공정 변수를 최적화 하고자 하였다. 이를 위하여 실험 데이터를 기준으로 하여 여러 역전파 알고리즘 및 LM(Levenberg-marguardt) 알고리즘으로 훈련된 신경망을 구성하여 정확도를 검토하여 비드형상의 예측 가능성 을 확인하였다.

#### 2. 장 실험 및 분석

본 연구에서 선택한 공정변수는 패스 수를 기초로 한 용접전압, 용접속도, 아크전류이고 출력 변수는 표면 비드폭, 표면 비드높이, 이면 비드폭, 이면 비드높이이다. 따라서 3가지 레벨의 3개의 공정변수로 인해 9개의 자유도가 발생하므로 L9(34) 직교 배열을 사용하였다.

실험 재료는 화학적 조성이 0.25%C, 0.4%S 및 0.04%P AS1204 연강판을 사용하였다. 모재는 300×200mm로 잘라 먼지와 산화물을 제거하기 위해서 #1200 사포로 양면을 다듬어 제작하였고, 보호 가스는 80%Ar+20%CO<sub>2</sub>로 조성하였다.

목포대학교 자동제어 실험실의 시설을 사용하였고 용접 장비는 GMA 용접 유닛과 로봇 Teach Box를 갖춘 용접용 로봇으로 구성되어 있다. 6 축 로봇의 토크 포지셔닝 및 운동 제어는 용접 토크를 모니터링 함으로써 실험을 실시하였다.

비드형상을 측정하기 위하여 용접부의 중간 지점을 쇠톱으로 잘라 횡단면을 만들고 끝부분은 절삭하였다. 시험편의 단면을 닦은 다음 2.5% 질산 용액으로 부식시켜 비드형상이 드러나게 하여 GMA 용접 공정제어를 위한 시스템의 기본이 되는 비드형상의 출력변수로 선정하였다.

#### 3. 신경망 모델 및 지능시스템 개발

GMA 용접 공정에서의 최적의 비드형상을 예측하기 위하여 비드형상에 대한 용접속도, 용접전류, 아크전압 등 복잡하고 상호작용이 매우 큰 공정변수를 매핑하는 도구로 다중 역전파 네트워크를 이용하였다. 네트워크 설정은 여러 역전파 알고리즘과 LM(Levenberg-Marguardt) 학습 알고리즘을 이용하였다. Fig. 1은 본 연구에서 사용한 다중 신경망 구조를 나타낸다.

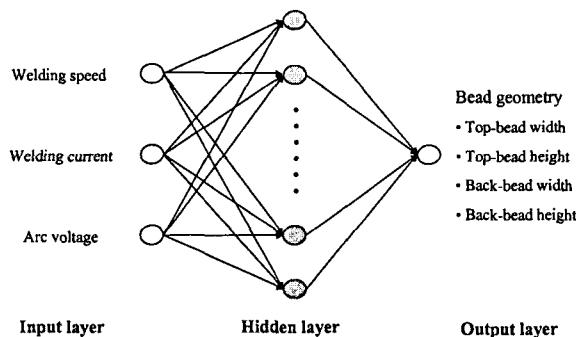


Fig. 1 Optimal neural network architecture for predicting bead geometry

### 3.1 에러 역전파 알고리즘

에러 역전파 알고리즘을 이용한 신경망의 트레이닝이 수행되었고, 개발된 신경망의 정확도는 트레이닝 및 시험의 측정값과 추정값 사이의 평균제곱근(RMS) 오차로 평가하였다. 트레이닝 단계에서 평균 RMS 오차는 약 0.0695까지 줄어들었다. 반복 횟수가 증가해도 RMS 오차는 더 이상 줄어들지 않았다. 이러한 결과를 바탕으로 상이한 네트워크 구조에서 나타난 RMS 오차는 미리 설정된 최고 트레이닝 주기수 500 epoch 안에서 최종 목표 오차값 0.01에 컨버전스 할 수 있도록 하였다. 이 알고리즘을 이용하여 얻은 최저 RMS 오차는 은닉층 뉴런이 4개일 때의 0.0218이었다. 또한 예측의 정확도는 은닉층 뉴런 수가 늘어날수록 떨어졌다. 뉴런의 숫자를 증가시켜도 네트워크의 함수근사 능력은 곧바로 향상되지 않는다는 것을 나타낸다. Table 1에서 보는 바와 같이 트레이닝 표본과 시험 표본의 RMS 오차를 볼 때 하나의 은닉층을 가진 3-4-1 구조에서 최저 RMS 오차가 발생함을 알 수 있다.

Table 1 The result of various network configurations with the error back-

propagation algorithm

Configuration	Training RMS error	Testing RMS error	CPU time(s)
3-2-1	2.3272e-2	0.6404	6.98
3-4-1	2.1782e-2	0.4745	7.00
3-6-1	2.6664e-2	0.5237	7.11
3-8-1	2.7203e-2	0.7768	7.20
3-10-1	2.8318e-2	0.7638	7.24
3-12-1	2.8541e-2	0.4172	7.25
3-14-1	2.8673e-2	0.8236	7.27
3-16-1	3.1151e-2	0.9488	7.40

### 3.2 Levenberg-Marguardt 알고리즘

LM 알고리즘은 네트워크의 정확도를 높이기 위해 사용하였고 가중치와 편향(bias)은 전의 함수에 따라 조정하였다. Table 2는 LM 근사 함수를 이용한 다양한 신경망의 성능을 나타낸다. 트레이닝 공정시의 RMS 오차는 경쟁층의 뉴런 수 증가와 직접적인 관련이 없고, 스칼라 값이 최대 값에 도달하거나 네트워크 구조가 변수로 조정되면 학습 공정은 끝난다. 그러나 시험 세트의 평균 RMS 오차는 트레이닝 세트의 값보다 크다는 것을 알 수 있었다. 이 값을 이용하여 얻은 최소 RMS 오차는 은닉층에 4개의 뉴런과 500 트레이닝 주기에서 0.0000845 였다.

Table 2 The result of various network configurations with the LM algorithm

Configuration	Training RMS error	Testing RMS error	CPU time(s)
3-2-1	3.7405e-3	0.7570	10.70
3-4-1	8.4505e-5	0.0357	11.20
3-6-1	5.6373e-4	0.0401	12.76
3-8-1	1.6977e-4	0.9835	14.84
3-10-1	2.8743e-4	1.7903	17.43
3-12-1	5.6296e-4	1.7822	20.60
3-14-1	6.8854e-4	1.6404	24.03
3-16-1	1.7223e-4	1.7546	30.52

LM 알고리즘 및 에러 역전파 트레이닝 알고리즘을 비교해 볼 때 네트워크 컨버전스는 더 빨라졌고 목표 오차값은 훨씬 낮은 값에서 설정할 수 있었다. 또한 이전의 기법과는 달리 네트워크의 매핑(mapping) 능력은 은닉층 뉴런 수가 증가한다고 해서 반드시 향상되지 않음을 알 수 있었다.

3-4-1 네트워크 구조를 가진 두 알고리즘의 성능을 비교한 결과를 Fig. 2에 나타내었다. LM 알고리즘을 이용하여 얻은 계산값이 여러 역전파 알고리즘을 이용하여 개발된 모델의 계산값보다 더 정확함을 알 수 있다.

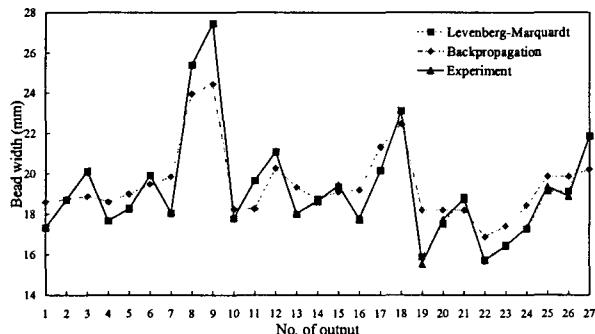


Fig. 2 Performance of the error back-propagation algorithm and the LM approximation algorithm for predicting bead geometry

가장 정확한 신경망을 선택하기 위하여 추가 실험을 실시하여 여러 역전파 알고리즘 및 LM 알고리즘을 이용하여 개발한 신경망 모델과 실험 결과를 비교하였다. 설정된 모델의 예측 및 실험 결과를 통해 나타난 비드형상에 대한 결과는 Fig. 3에 나타내었다. LM 알고리즘을 이용한 신경망 모델이 실험결과에 최적선을 제공하고 여러 역전파 알고리즘보다 비드형상 예측값이 더 정확함을 알 수 있었다.

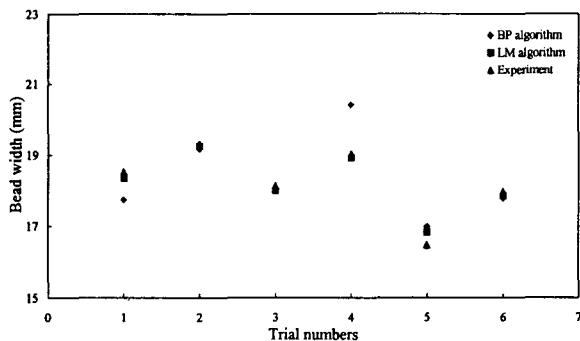


Fig. 3 Comparison of measured and calculated results using two training algorithm

기준으로 BP 신경망 알고리즘과 LM 알고리즘을 사용한 신경망 모델을 구성하여 비교 및 추가 실험을 통한 검증을 통해 신경망 모델의 적합성을 검토하였다.

자동 GMA 용접 공정의 경우 LM 알고리즘을 사용한 신경망 모델이 실제 측정값과 가까운 값을 예측하였고 이를 통해 신경망 모델을 이용한 GMA 용접공정 알고리즘과 최적의 비드형상의 기하학적 구조를 통해 최적 공정변수의 선택에 대한 적합성을 확인할 수 있었다.

## 참고문헌

- Juang, S. C., Tarnng, Y. S. and Lii, H. R., "Comparison between the back-propagation and counter-propagation works in the modeling of the TIG welding process", Journal of Materials Process Technology, 75 (1998), 54-62
- Nagesh, D. S. and Datta, G. L., "Prediction of weld bead geometry and prediction in shield metal-arc welding using artificial neural networks", Journal of Materials Process Technology, 57, (2002), 1-10
- Li, P., Fang, M. T. C. and Lucas, L., "Modeling of submerged arc weld beads using self-adaptive offset neural networks", Journal of Materials Processing Technology, 71 (1997), 88-298
- Tarnng, Y. S., Tsai, H. L. and Yeh, S. S., "Modeling, optimization and classification of weld quality in tungsten inert gas welding", International Journal of Machine Tools and Manufacturing, 39 (1999), 1427-1438

## 4. 결 론

본 연구에서는 용접 공정변수와 비드형상의 기하학적 구조의 관계를 실험에서 결정된 데이터를