

신경망 알고리즘을 이용한 아크 용접부 품질 예측

조 정 호*†

*충북대학교 기계공학부

Prediction of Arc Welding Quality through Artificial Neural Network

Jungho Cho*†

*School of Mechanical Engineering, Chungbuk National University, Chungju 361-763, Korea

†Corresponding author : Junghocho@cbnu.ac.kr

(Received February 19, 2013 ; Revised May 31, 2013 ; Accepted June 25, 2013)

Abstract

Artificial neural network (ANN) model is applied to predict arc welding process window for automotive steel plate. Target weldment was various automotive steel plate combination with lap fillet joint. The accuracy of prediction was evaluated through comparison experimental result to ANN simulation. The effect of ANN variables on the accuracy is investigated such as number of hidden layers, perceptrons and transfer function type. A static back propagation model is established and tested. The result shows comparatively accurate predictability of the suggested ANN model. However, it restricts to use nonlinear transfer function instead of linear type and suggests only one single hidden layer rather than multiple ones to get better accuracy. In addition to this, obvious fact is affirmed again that the more perceptrons guarantee the better accuracy under the precondition that there are enough experimental database to train the neural network.

Key Words : Arc welding, Neural network, Prediction, Automotive, Steel

1. 서 론

용접은 복잡다단한 물리화학적 공정으로 그 결과물인 용접 품질을 예측하는 것은 매우 어려운 일이다. 그럼에도 불구하고, 용접은 금속 관련 최종 제품을 생산하기 위해 반드시 필요한 공정 중 하나이므로 품질에 관한 공정 변수의 최적화는 피할 수 없는 절차이고, 최적화에 따른 품질 예측의 중요성은 두말할 필요가 없다.

용접 공정 변수에 대한 피용접물의 품질 예측에 관한 전통적인 방법은 당연히 경험에 의존하는 것이다. 이는 용접 기술자의 개인적인 경험일 수도 있고, 잘 정리된 보고서일 수도 있다. 수치 해석 기법의 발전에 힘입은 또 다른 품질 평가 방법은 FEM이나 FDM과 같은 유한 요소 해석 결과에 의존하는 것이다. 그러나, 단순화와 가정에 의한 지배 방정식과 경계 조건들로 인해 실제로는 여전히 무시할 수 없는 정도의 오차를 보이고, 적지 않은 시간을 요구하기도 하지만, 물리적인 재료의

추가비용 없이 공정 경향을 파악하고 공정을 설계하는데 많은 도움이 되고 있다.

신경회로망 이론은 용접 공정과 같이 복잡하고 비선형적인 거동을 보이는 시스템의 결과를 예측하는데 적합한 것으로 알려져 있다. 용접 공정과 관련된 신경망 알고리즘의 성공적인 적용 사례¹⁻⁴⁾는 이미 다수 알려져 있고, 지금도 계속 진행 중이다⁵⁾.

본 연구는 다양한 종류의 자동차용 강판 조합에 대한 아크 용접 결과를 예측하기 위해 신경망 알고리즘을 적용하였고, 신경망 알고리즘의 변수가 예측 정확성에 미치는 영향을 분석하여 보다 정확도 높은 신경망을 구성하기 위한 방안을 제시하였다.

2. 네트워크 설계

본 연구는 MATLAB에서 제공하는 모델을 사용하였다. MATLAB 패키지는 기본적인 신경망 모델을 제공하고 있으므로, 퍼셉트론을 정의하고 네트워크로 연결

해주는 기초적인 작업을 별도로 해 줄 필요가 없다.

적용된 모델은 정적 모델로 피드백 전달이 없으며, 역전파 알고리즘으로 최적 계수 값을 결정하고 1개의 출력 값을 갖도록 설계하였다. 은닉 층의 개수와 은닉 층 내의 퍼셉트론 개수를 변수로 줄 수 있도록 하여, 은닉 층과 퍼셉트론 개수가 예측 결과에 미치는 영향을 관찰하고, 이 결과를 바탕으로 네트워크 설정 방향을 제안하였다.

신경망 네트워크의 변수는 앞서 언급한 바와 같이 은닉층의 개수, 퍼셉트론의 개수 외에 전달함수의 종류를 포함해 총 3가지로 설정하였다. 전달함수는 선형이나 다양한 비선형 함수를 적용할 수 있도록 하였고, 각각의 경우에 대해 예측 정확도를 비교하여 적정 전달함수를 제안하였다.

Fig. 1은 MATLAB을 이용해 구성된 신경망 네트워크의 구성 예로 1개의 은닉층에 10개의 퍼셉트론을 갖고 10개의 입력을 받아 1개의 출력을 내는 구성도를 보여주고 있다.

본 연구에 적용한 아크 용접의 대상은 자동차용 강판으로 겹치기 필렛 이음부에 아크 용접을 적용하여 적정 용접 조건에 대한 실험이 선행되었고, 이를 데이터 베이스로 활용하여 신경망을 트레이닝하고, 트레이닝된 신경망을 예측에 적용하였다. 실험 데이터 베이스는 겹치기 이음의 상하판 각각에 대해 강종과 도금 종류를 달리하여 보다 다양한 강판 조합에 대응할 수 있도록 한 것이다. 이에 따라, 신경망 네트워크의 입력 변수도




Fig. 1 Example of neural network design which has single hidden layer with 10 perceptrons and nonlinear transfer function

Table 1 Input variables of neural network

input variables	steel plate and welding condition
1	current (ex. 140(A))
2	welding speed (ex. 0.5(mpm))
3	argon portion in shield gas (ex. 0.95)
4	CO ₂ portion in shield gas (ex. 0.05)
5	top plate surface coat (GA-2, bare-1)
6	top plate strength (ex. 340(MPa))
7	top plate thickness (ex. 1.0(mm))
8	bottom plate surface coat
9	bottom plate strength
10	bottom plate thickness

상하판 각각 지정할 수 있도록 하였고, 각 입력 변수에 해당하는 강판과 용접 조건은 Table 1과 같다.

3. 트레이닝

실험 데이터 베이스는 340MPa, 440MPa 급의 GA (아연도금, galva-annealed), 비도금 강판에 대해 다양한 두께로 총 9가지 조합의 적정 용접 조건을 제시하고 있다. Fig. 2는 데이터베이스가 제시하는 적정 용접 구간에 대한 예를 보여주고 있으며, 이 결과는 인장 실험을 바탕으로 한 결과이다. 이 프로세스 윈도우를 신경망 예측에 적용시키기 위해 Table 2와 같이 변형시키고, 이후로 신경망 예측 결과를 모두 이 같은 형태로 구성해 실험결과와 비교하기로 한다. 표에서 1은 양호한 품질, -1은 용락이나 용입 부족의 불량률을 나타낸다. 굵은 라인의 테두리로 용접 품질이 양호한 영역을 표시하였다. 이 표는 SGARC 340MPa 1.4t 두께의 강판 두 장에 대한 실험 결과로 이 표를 기준으로 신경망 예측 알고리즘의 정확도를 검증할 것이다. 보호가스 조성은 Ar 95% + CO₂ 5%이다.

위의 Table 2와 같은 실험 결과 데이터 베이스 중 총 9가지 강판 조합을 선정해 이중 8가지 조합은 트레이닝을 위해 사용하고, 나머지 한 가지 조합은 트레이닝된 네트워크의 정확도를 평가하기 위해 사용하였다. 트레이닝 실험 셋과 평가용 실험 셋은 Table 3과 같다.

Table 3에서 보듯이 선정된 실험 셋은 동일 강종의 다른 두께, 동일 강도의 도금 유무, 동일 조건의 다른




Fig. 2 Example of process window of arc welding experiment database⁶⁾

Table 2 Welding experiment process window example to apply to neural network training. Bold lined area shows sound bead zone

	100A	150A	200A	250A
0.4 mpm	1	1	-1	-1
0.6 mpm	1	1	-1	-1
0.8 mpm	1	1	1	-1
1.0 mpm	-1	-1	1	1

Table 3 Steel plate combination and shield gas conditions for network training and evaluation

welded steel plates	shield gas	note
SPRC440 1t+1t	Ar 95%+CO ₂ 5%	for training
SPRC440 1.4t+1.4t	Ar 95%+CO ₂ 5%	
SGARC340 1t+1t	Ar 95%+CO ₂ 5%	
SGARC440 1t+1t	Ar 95%+CO ₂ 5%	
SGARC440 1t+1t	Ar 80%+CO ₂ 20%	
SGARC440 1.4t+1.4t	Ar 95%+CO ₂ 5%	
SGARC440 0.7t+0.7t	Ar 95%+CO ₂ 5%	
SGARC440 1t+1t	Ar 100%	for evaluation
SGARC340 1.4t+1.4t	Ar 95%+CO ₂ 5%	

보호 가스 조성 등 용접 조건과 강판 조합이 교차되도록 선택하여 신경망이 보다 다양한 용접 조건 변수 하에서 트레이닝 되도록 설계하였다.

4. 결과 및 고찰

앞서 언급한 바와 같이 이 연구에서는 가장 간단한 형태의 역전파 알고리즘 네트워크를 구성했다. 네트워크를 피드백 입력이 없는 정적 모델이고, 변수로 은닉층의 개수, 퍼셉트론의 개수, 전달 함수의 형태를 선정하고 이 변수들이 예측 정확도의 미치는 영향을 살펴본 후 정확도를 높이기 위한 네트워크 설정 방안을 도출한다.

우선 첫 번째로 기본적인 형태의 10개의 퍼셉트론을 1개의 은닉층으로 갖고, Fig. 3과 같은 형태의 쌍곡선 탄젠트 시그모이드 (hyperbolic tangent sigmoid) 함수를 적용하였고, 그 결과는 Table 4와 같다. 이 결과를 Table 2와 비교하면 알 수 있듯이, 대부분의 용접 조건에서 실험 결과와 일치하지 않음을 알 수 있다.

동일한 신경망 네트워크 설정에서 은닉층의 개수와 전달 함수는 그대로 두고 퍼셉트론의 개수를 10개에서 20개로 증가시킨 결과는 Table 5와 같다. 마찬가지로 Table 2와 비교하면 앞서 10개 퍼셉트론의 경우보다




Fig. 3 Hyperbolic tangent sigmoid function

$$y = \frac{2}{(1 + e^{-2a})} - 1$$

Table 4 Predicted process window by artificial neural network with single hidden layer consisting of 10 perceptrons and hyperbolic tangent sigmoid transfer function

	100A	150A	200A	250A
0.4 mpm	1	0.98	-1	-1
0.6 mpm	-1	-1	-1	-1
0.8 mpm	-1	-1	0.62	-1
1.0 mpm	-1	-1	1	-1

Table 5 Predicted process window by artificial neural network with single hidden layer consisting of 20 perceptrons and hyperbolic tangent sigmoid transfer function

	100A	150A	200A	250A
0.4 mpm	1	0.79	-1	-1
0.6 mpm	1	1	-1	-1
0.8 mpm	-0.44	1	1	-1
1.0 mpm	-1	-1	1	-1

예측 정확도가 상당히 향상되었음을 알 수 있다. 하지만, 여전히 예측이 빗나간 영역이 2개 조건에서 발생하여 신뢰성이 부족함을 보여주고 있다.

Table 4와 Table 5의 비교에서 알 수 있는 한 가지 사실은 퍼셉트론의 개수가 증가할수록 예측 정확도가 높아진다는 사실이다. 이를 바탕으로 퍼셉트론을 30개로 증가시켰을 때의 결과는 Table 6과 같다. 이 결과를 Table 2와 비교해보면 전체 16개 용접조건 중 1개만 제외하고 모두 실험 결과와 일치하는 정확도를 보임을 알 수 있다. 이로써, 앞서 언급한 바와 같이 퍼셉트론의 개수가 증가할수록 예측 정확도가 증가한다는 사실을 재확인할 수 있다.

일반적으로, 신경망의 은닉층이 증가할수록 보다 복잡한 시스템의 특성과 비선형성을 커버할 수 있는 것으로 알려져 있다. 이를 검증하기 위해 본 연구에서도 은닉층을 2개로 증가시키고, 각각에 20개씩, 총 40개의

Table 6 Predicted process window by artificial neural network with single hidden layer consisting of 30 perceptrons and hyperbolic tangent sigmoid transfer function

	100A	150A	200A	250A
0.4 mpm	1	1	-1	-1
0.6 mpm	1	1	-1	-1
0.8 mpm	1	1	1	-1
1.0 mpm	-1	1	1	0.77

Table 7 Predicted process window by artificial neural network with double hidden layer consisting of 20 perceptrons in each and hyperbolic tangent sigmoid function

	100A	150A	200A	250A
0.4 mpm	1	-1	-1	-1
0.6 mpm	1	1	-1	-1
0.8 mpm	-1	1	0.71	-1
1.0 mpm	-1	1	1	-1

Table 8 Predicted process window by artificial neural network with single hidden layer consisting of 10 perceptrons and linear transfer function

	100A	150A	200A	250A
0.4 mpm	3.95	1.41	-5.10	-5.45
0.6 mpm	2.65	3.24	-3.13	-3.74
0.8 mpm	1.14	1.53	4.71	-2.86
1.0 mpm	0.49	-0.04	4.18	-2.33

퍼셉트론을 배치시켰고, 그 결과는 Table 7과 같다. 이를 1개 은닉층 20개 퍼셉트론의 Table 5와 비교해보면, 은닉층을 추가하였음에도 불구하고, 예상과는 다르게 정확도가 그리 향상되지 못했음을 알 수 있다. 위의 일반적인 경향과는 배치되는 것으로, 추가된 은닉층을 커버하기 위한 충분한 트레이닝 셋이 공급되지 못한 것이 그 원인임을 추측해볼 수 있다.

마지막으로 네트워크의 전달 함수를 비선형 함수에서 선형 함수로 변형시켜 적용한 결과는 Table 8과 같다. 트레이닝시킨 실험 셋의 결과는 모두 1과 -1의 값으로 양호/불량을 설정하였으나, 선형 전달 함수로 출력된 결과는 범위가 일정치 않게 출력되었다. 양수를 양호로, 음수를 불량으로 간주하여 실험 결과와 비교하여도 매우 그릇된 예측 결과를 보임을 알 수 있다.

5. 결론 및 향후연구

본 연구는 MATLAB 상용 패키지를 이용해 신경망 회로이론에 입각한 퍼셉트론 네트워크를 구성하고, 자동차용 강판의 아크 용접 품질 예측에 이를 적용하였다. 신경망의 변수를 은닉층의 개수, 은닉층을 구성하는 퍼셉트론의 개수, 최종 전달 함수의 형태로 설정하고, 각 변수가 예측 정확도에 미치는 영향을 살펴보았다.

신경망의 입력은 아크 용접의 상/하판 소재의 종류와 전류, 속도, 보호 가스 조성 등 총 10개의 변수를 설정하였고, 출력 값은 1개 값으로 인장 실험 결과를 근거

로 한 양호/불량에 해당하는 1이나 -1을 내보내도록 설정하였다.

총 9개의 실험 셋 중 8개는 트레이닝에 사용하고, 나머지 1개를 예측 정확도 평가 기준으로 사용하여 다음과 같은 결론에 도달하였다.

1) 신경망의 은닉층을 구성하는 퍼셉트론의 개수가 많을수록 높은 예측 정확도를 기대할 수 있다.

2) 일반적으로 신경망의 은닉층을 증가시킬수록 원래 시스템의 복잡도나 비선형성을 보다 정확하게 커버할 수 있으나, 본 연구에서는 은닉층을 증가시켜도 예측 정확도에 큰 영향이 없음을 확인하였다. 증가된 은닉층을 충분히 트레이닝 키기기 위한 실험 셋의 증가가 없었던 것이 일반적인 경향에 반하는 결과를 보인 것으로 추정된다.

3) 전달 함수를 비선형으로 설정했을 경우가 선형 함수의 경우보다 예측 정확도가 높게 나타났다. 입력 변수가 상대적으로 많고, 실험 결과 역시 비선형적인 양상이므로 비선형 전달 함수가 보다 적합한 전달 함수인 것을 알 수 있다.

4) 본 연구에서는 역전파 알고리즘을 사용하는 1개 은닉층과 30개의 퍼셉트론, 그리고 쌍곡선 탄젠트 시그모이드 전달 함수의 신경망을 적용하였을 때, 단순 계산으로 93.75%(15/16)의 예측 정확도를 보였다.

지금까지의 신경망 예측 결과는 정적 모델에 한한 것으로 향후 본 연구는 동적 모델로 예측 모델을 확장하고, 실험 DB 역시 780MPa, 1.5GPa급 자동차용 강판으로 확대 적용할 예정이다.

후 기

본 연구는 지식경제부 제조기반산업 원천기술개발사업의 자동차 핵심부품 생산기반공정 플랫폼기술과제 지원으로 수행되었습니다.

참 고 문 헌

1. Young-Soo Yang, Truong-Thanh Nguyen and Kang-Yul Bae : Prediction of Heating Line for Plate Forming in Induction Heating Process Using Artificial Neural Network, Journal of the KWJS **28-4** (2010), 1-4 (in Korean)
2. Young Whan Park and Sehun Rhee : Development of Statistical Model and Neural Network Model for Tensile Strength Estimation in Laser Material Processing of Aluminum Alloy, Journal of the Korean Society of Precision Engineering **24-4** (2007), 93-101 (in Korean)
3. Jeong-ick Lee and Byung-kab Koh : Back-bead Prediction and Weldability Estimation Using An Artificial

- Neural Network, Transactions of the Korean society of machine tool engineers **16-4** (2007), 79-86 (in Korean)
4. Chang-Hyun Kim, Hong-Yeon Yu and Sung-Hoon Hong : Adaption of Neural Network Algorithm for Pattern Recognition of Weld Flaws, The Journal of the Korea Contents Association **7-1** (2007), 65-72 (in Korean)
 5. S. W. Campbell, A. M. Galloway and N. A. McPherson : Artificial Neural Network Prediction of Weld Geometry Performed Using GMAW with Alternating Shielding Gases, Welding Journal **91-6** (2012), 174s-181s
 6. <http://www.root-tech.kr>