

신경망 알고리즘을 이용한 차체용 강판 아크 용접 조건 도출

조 정 호^{*,†}

*충북대학교 기계공학부

Proper Arc Welding Condition Derivation of Auto-body Steel by
Artificial Neural NetworkJungho Cho^{*,†}

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

†Corresponding author : junghocho@chungbuk.ac.kr

(Received February 14, 2014 ; Revised April 7, 2014 ; Accepted April 16, 2014)

Abstract

Famous artificial neural network (ANN) is applied to predict proper process window of arc welding. Target weldment is variously combined lap joint fillet welding of automotive steel plates. ANN's system variable such as number of hidden layers, perceptrons and transfer function are carefully selected through case by case test. Input variables are welding condition and steel plate combination, for example, welding machine type, shield gas composition, current, speed and strength, thickness of base material. The number of each input variable referred in welding experiment is counted and provided to make it possible to presume the qualitative precision and limit of prediction. One of experimental process windows is excluded for predictability estimation and the rest are applied for neural network training. As expected from basic ANN theory, experimental condition composed of frequently referred input variables showed relatively more precise prediction while rarely referred set showed poorer result. As conclusion, application of ANN to arc welding process window derivation showed comparatively practical feasibility while it still needs more training for higher precision.

Key Words : Artificial neural network, Arc welding, Automotive, Predictio

1. 서 론

차체용 강판의 아크 용접은 동종 혹은 이종의 박판 합금강 소재를 용융 접합시키는 공정으로 근본적으로 용접 결과를 예측하기란 매우 어려운 일이다. 아울러, 환경 문제로 인한 자동차의 연비 향상 요구에 따라 차체 경량화 소재로 각종 초고강도 강판이 새롭게 도입되어, 아크 용접 품질을 관리하고 예측하는 일은 더욱 더 복잡해 졌다. 새로운 강종이 차체에 적용될 때마다 기존 강판과의 용접 조건이 새로이 설정되어야 하지만, 현실적으로 이 절차는 많은 시간과 비용을 요하므로 부품을 조달하는 협력 업체는 물론 완성차 업체 입장에서도 큰 부담이 되고 있다.

신경망 알고리즘(artificial neural network, ANN)은 인체의 신경 세포인 뉴런 (neuron)을 모방한 가상의 신경 소자, 퍼셉트론(perceptron)을 망(network)으로 연결하여, 입력과 출력을 갖춘 일종의 함수를 만든 것으로 퍼셉트론이 구성하는 복잡한 회로망을 통해 복잡한 비선형 현상을 비교적 간단하게 재현하거나 예측할 수 있는 장점을 가지고 있다. 이에 따라, 신경망 알고리즘을 이용해 복잡한 용접 현상을 예측하려는 시도가 계속 있어왔고, 비교적 성공적인 결과를 보여주었다¹⁻⁵⁾.

본 연구는 신경망 알고리즘을 이용해 440MPa급 차체용 강판의 아크 용접 조건을 도출했던 이전 연구⁶⁾의 계속적인 연구로, 1180MPa급의 초고강도 강판을 추

가하여 현재 차체에 적용되고 있는 340~1180MPa급 강도의 강판 조합에 대해 적절한 용접 조건을 예측할 수 있도록 하였다.

2. 신경망 설정

퍼셉트론은 다수의 입력 변수와 1개의 출력 변수를 갖는 함수로 각각의 입력 변수는 서로 다른 가중치 (weigh factor)가 곱해진 후 모두 더해져 전달 함수 (transfer function)로 넘겨진다. 그리고, 전달 함수를 통한 1개의 출력 변수는 또 다른 퍼셉트론의 입력 변수가 되는 방식으로 망이 형성되는 것이다. 주어진 입력에 대해 일정한 출력값이 나오도록 가중치를 조정해 주는 것을 트레이닝(training) 이라 하고, 실험이나 계측 결과를 신경망에 트레이닝시키면, 이미 결정되어 있는 출력값을 맞추기 위해 잔차 (residual)에 대한 최소 제곱법 등의 방법으로 가중치를 조정하게 된다. 그리고, 이렇게 결정된 가중치의 신경망에 새로운 조건의 입력 변수가 주어지면, 새로운 예측 결과를 출력으로 내보내는 것이다.

신경망은 Fig. 1의 개요도와 같이 입력층, 은닉층, 출력층으로 나뉘는데, 출력층은 1개의 퍼셉트론으로 구성되는 반면, 은닉층은 다수의 퍼셉트론과 다수의 은닉층으로 구성 가능하다. 입력층의 설정 변수는 단순히 입력 변수가 되지만, 은닉층은 은닉층의 개수와 각 층 (layer)의 퍼셉트론 개수가 설정 변수가 되며, 은닉층과 출력층의 사이의 전달 함수 역시 설정 변수이다. 이 연구에서는 테스트를 통해 40개의 퍼셉트론을 갖는 1개의 은닉층과 14개의 입력 변수, 그리고 전달 함수로는 쌍곡선 탄젠트 시그모이드 함수를 적용하여 비교적 우수한 예측 정확도를 확보하였다. 보다 자세한 내용은 선행 연구를 참조하기 바란다⁶⁾. 추가로, 신경망 전체 구성 방식을 정적 모델이나 동적 모델로 설정할 수 있는데, 동적 모델은 정적 모델과 달리 출력 변수가 다시 입력 변수 중 하나로 연결되는 피드백이 있다. 이 설정 역시 선행 연구 결과에 따라 정적 모델로 결정되었다.

신경망의 평가는 주어진 실험 결과로 도출된 용접 조건표 중 일부를 예측 정확도 평가용으로 남겨두고 나머




Fig. 1 Schematic diagram of artificial neural network consists of input, hidden and output layer

Table 1 Selected input variables of arc welding prediction ANN model

input variables	steel plate and welding condition
1	Welding machine type (GMA, CMT)
2	Welding current
3	Welding speed
4	Argon portion in shield gas
5	CO2 portion in shield gas
6	DCEN portion in pulse
7, 8	Steel type (CP, DP, TRIP)
9, 10	Surface coat (GA, GI, bare)
11, 12	Strength
13, 14	Thickness

지를 트레이닝시켜 신경망 예측 결과와 실험 결과를 비교하는 방식으로 진행하였다. 예를 들어 10개의 용접 조건표가 있으면, 9개의 결과를 트레이닝시키고, 남은 1개를 가지고 예측 결과와 실험 결과를 비교해 정확도를 평가하는 것이다.

신경망의 입력 변수는 겹치기 이음 필렛 용접의 상판, 하판의 강종, 강도, 도금, 두께 등의 소재 변수와 용접 전류, 속도, 보호가스 조성, 용접기 종류, DCEN 극성 비율 등 총 14가지로 설정하였다. Table 1은 입력 변수를 정리한 것이다.

3. 트레이닝 및 예측 결과

신경망 알고리즘은 트레이닝을 통해 망의 가중치 변수가 결과에 맞도록 조정되므로 트레이닝 횟수가 많으면 많을수록 신경망의 예측 정확도가 높아진다. 본 연구의 아크 용접 결과 예측도 마찬가지로 강판 조합이 다양할수록, 전류 등의 용접 조건이 다양할수록, 그리고 트레이닝의 회수가 많으면 많을수록 신경망의 예측 정확도는 높아진다. 그러나, 6가지의 강판 강도와 3가지의 도금 종류, 그리고 5개 종류의 두께만 가지고도 90개의 강판 조합이 도출되므로, 현실적으로 주어진 강종과 두께의 모든 조합에 대한 실험 용접조건표를 도출하는 것은 불가능에 가깝다. 본 연구에서는 선택된 입력 변수에서 실험을 위해 확보 가능한 강판 조합에 대해 제한적인 회수의 실험을 통한 용접 조건표를 확보하였고, 이를 신경망에 적용하여 적정 용접 조건을 예측할 수 있는 알고리즘을 완성하였다.

실험 변수 별 실험 회수는 Table 2와 같이 정리하였는데, 이 표에서는 각 변수가 실험에서 적용된 횟수를 괄호 안의 숫자로 제시하였다. 앞서 언급한 바와 같이

Table 2 Selected input variables of arc welding prediction ANN model

Machine	Current(A)	Speed (m/min)	Ar portion	CO ₂ portion	EN(%)	Coat	Strength (MPa)	Thickness (mm)	Steel type
CMT (712EA) GMA (464EA)	50	0.4 0.6 0.8 1 1.2	0 (336EA) 0.8 (184EA) 0.95 (616EA) 1 (40EA)	1 (336EA) 0.2 (184EA) 0.05 (616EA) 0 (40EA)	0 (1020EA) 30 (156EA)	Top plate			
	60					Bare (888EA) GA (504EA) GI (136EA)	340(128EA)	0.7(16EA)	DP(592EA) TRIP(80EA) CP(132EA)
	70						440(224EA)	1.0(629EA)	
	80						590(248EA)	1.2(160EA)	
	90						780(184EA)	1.4(304EA)	
	100						980(208EA)	1.6(40EA)	
	110					Lower plate			
	120					Bare (888EA) GA (504EA) GI (136EA)	340(64EA)	0.7(16EA)	DP(592EA) TRIP(80EA) CP(156EA)
	130						440(288EA)	1.0(544EA)	
	140						590(192EA)	1.2(160EA)	
	150						780(192EA)	1.4(416EA)	
	160						980(232EA)	1.6(40EA)	
	170						1180(208EA)		
	180								
	190								
	200								
	210								
	240								
	250								
	260								

어떤 변수에 대한 실험 회수가 많으면 많을수록 그 변수에 대한 예측 결과는 정확해진다. 따라서, Table 2에 제시된 각 변수의 실험 회수가 많은 조합에 대한 예측 결과는 비교적 정확할 것으로 예상할 수 있고, 상대적으로 회수가 적은 조합의 예측은 부정확할 것이다. 예를 들어 CMT 용접 DCEP-100%에 Ar 95% + CO₂ 5% 보호가스 조성을 사용하고, DP 590GA 1mm 두께 강판을 상하판으로 조합하는 경우 상대적으로 높은 예측 정확도를 기대할 수 있으나, GMA DCEN-30%, Ar 100%에 TRIP1180 1.6mm 두께 강판의 상하판 조합이라면 상대적으로 낮은 예측 정확도를 보일 것으로 추측할 수 있다. 즉, 이 표는 트레이닝 된 신경망의 적정 용접 조건을 예측할 수 있는 범위와 상대적인 정확도를 제시하는 것과 동시에 한계를 보여주고 있는 것이다.

Table 3은 CR 980 DP 강의 실제 용접 실험 결과로 용접 속도와 전류에 따른 적정 용접 조건을 보여주

Table 3 Process window of CR 980 DP 1.0t + 1.0t, CMT, DCEP 100%, Ar 95%, CO₂ 5%

160A	Burn through	Burn through	Proper
130A	Burn through	Proper	Proper
100A	Proper	Proper	Lack of fusion
70A	Proper	Lack of fusion	Lack of fusion
	0.8m/min	1.0m/min	1.2m/min

Table 4 Process window of weld combination same to table 3 predicted by trained ANN

160A	-1	-1	0.99
130A	-1	-1	1
100A	1	1	-0.46
70A	1	-0.99	-1
	0.8m/min	1.0m/min5	1.2m/min

고 있다. Table 4는 동일 조합에 대한 예측 결과로 신경망을 트레이닝할 때, Table 3의 결과만 제외한 나머지 실험 결과를 트레이닝시킨 후 신경망 알고리즘을 통해 도출한 적정 용접 조건이다. 표에서 -1이나 0보다 작은 값은 과용접이나 용입부족 조건을 나타내고, 1이나 0보다 큰 값은 적정 용접 조건을 나타낸다. Table 3과 Table 4의 비교에서 알 수 있듯이, 1가지 용접 조건을 제외하면 나머지 조건에서 예측 결과와 실험 결과가 일치함을 알 수 있다. 그리고, Table 3을 통해 제시되어 있는 용접 조합은 Table 2를 참조하면 알 수 있듯이 상대적으로 실험 회수가 많은 조건으로 예측 정확도가 비교적 우수함에 유의해야 한다.

Table 5와 Table 6은 각각 앞서의 결과와 달리 상대적으로 실험 회수가 적은 변수 조합에 대한 실험 결과와 신경망 예측 결과로, 16개의 용접 조건 중 3개 조건에서 상호 일치하지 않는 것을 확인할 수 있다. 이는 트레이닝 회수와 예측 정확도에 관한 상관 관계에서 언급한 것과 일치하는 결과다.

Table 5 Process window of CR 980 DP 1.0t + 1.0t, CMT, DCEP 100%, Ar 95%, CO2 5%

210A	Burn through	Burn through	Proper
190A	Proper	Proper	Proper
170A	Proper	Proper	Lack of fusion
150A	Proper	Lack of fusion	Lack of fusion
	0.8m/min	1.0m/min	1.2m/min

Table 6 Process window of weld combination same to table 5 predicted by trained ANN

210A	Burn through	Burn through	Proper
190A	Proper	Proper	Proper
170A	Proper	Proper	Lack of fusion
150A	Proper	Lack of fusion	Lack of fusion
	0.8m/min	1.0m/min	1.2m/min

Table 7 Process window of CR 590 DP 1.0t + GA 1180 CP 1.0t, CMT, DCEP 100% and CO₂ 100% weld combination predicted by trained ANN

300A	-1	-1	1	1
230A	-1	1	1	1
160A	1	1	1	1
90A	1	1	1	-1
	0.5m/min	0.7m/min	0.9m/min	1.1 m/min

신경망 알고리즘을 이용해 아크 용접 결과를 예측하는 가장 큰 목적은 실험으로 도출 불가능한 용접 조합에 대한 적정 용접 조건을 도출하는 데 있다. Table 7은 이러한 목적에 부합하는 예로 재료 조달 및 일정문제 때문에 실험으로 도출이 불가능했던 590MPa급 고장력강과 1180MPa급 초고장력강 조합에 대한 적정 용접 조건을 트레이닝된 신경망을 통해 예측한 것이다. 이 예측 결과가 정확한 것인가에 대한 의문이 들 수도 있으나, 이 의문에 대한 실험적인 검증은 앞서의 Table 4와 5과 같은 수 백개 조건의 트레이닝 후 실험된 결과 검증에 단지 하나를 추가하는 것에 지나지 않기 때문에 반드시 필요한 것은 아니다.

4. 고찰 및 결론

본 연구는 인공 신경망 알고리즘을 도입하여 차체용 강판의 겹치기 필렛 이음부에 대한 적정 아크 용접 조건을 도출하였다. 은닉층의 수, 은닉층의 퍼셉트론 수 및 전달 함수의 종류 등과 같은 신경망의 설정 변수는 선행 연구를 따라 개별 테스트를 통해 예측 정확도가 가장 우수한 변수로 결정되었다. 입력 변수는 아크 용접기 종류, 보호 가스 조성, 용접 전류와 속도, 상하판의 강종과 강도 등 14개를 선정하였고, 이에 대해 적정 용접 조건에 대해서는 1을, 과용접이나 용입 부족 조건에 대해서는 -1을 출력하도록 설정하였다.

340MPa 급에서부터 1180MPa 급에 이르는 강판 조합에 대해 다양한 용접 조건에서 용접 실험을 통해 용접조건표가 도출되었고, 적정 용접 품질은 인장 강도 테스트를 통해 결정되었다. 설정된 인공 신경망의 예측 정확도 평가를 위해 실험 용접조건표 중 1개를 제외한 나머지가 신경망의 트레이닝에 사용되고, 제외된 1개 용접조건표에 대해 신경망 예측 결과와 실험 결과를 비교하는 방법으로 평가가 이루어졌다.

실험에 적용된 모든 용접 조건과 개별 입력 변수의 실험 회수가 표로 정리되어 품질 예측이 가능한 용접 조합의 범위와 예측 정확도를 정성적으로 추측할 수 있도록 하였다. 실험 회수가 높은 변수의 용접 조합은 트레이닝 회수가 많으므로 예측 정확도가 높고, 빈도 수가 적은 조합은 상대적으로 정확도가 낮을 수 밖에 없다. 그리고, 이러한 결과는 신경망 예측 결과와 실험 결과를 직접 비교함으로써 입증하였다.

본 연구는 실험 회수가 높은 변수 조합에 대해 비교적 정확도가 높은 예측 결과를 제시함으로써 신경망 알고리즘을 이용한 적정 아크 용접 조건 도출에 대한 신뢰성을 검증하였고, 실험으로 도출할 수 없었던 강판 조합에 대한 적정 용접 조건표를 제시하여 아크 용접 품질 예측에 있어서 신경망 알고리즘의 효용성과 가능성을 보여 주었다.

후 기

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

Reference

1. Y. S. Yang, T. T. Nguyen and K. Y. 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. Y. W. Park and S. 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. J. I. Lee and B. K. 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. C. H. Kim, H. Y. Yu and S. H. 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. J. Cho : Prediction of Arc Welding Quality through Artificial Neural Network, Journal of KWJS **31-3** (2013), 44-48 (in Korean)