

GTA 용접에서 DNN 알고리즘을 이용한 실시간 비드폭 예측에 대한 연구

오원빈* · 김일수*[†] · 윤태종* · 이보람* · 이충우* · 박기영** · 진병주** · 이유헌***

*목포대학교 기계공학과

**고등기술연구원 지능기계시스템센터

***(주)클래드코리아 원주

A Study on the Prediction of Real-Time Bead Width Using a DNN Algorithm in GTA Welding

Won-Bin Oh*, Ill-Soo Kim*[†], Tae-Jong Yun*, Bo-Ram Lee*, Chung-Woo Lee*,
Ki-Young Park**, Byeong-Ju Jin** and Yu-Cheol Lee***

*Mokpo National University, Mokpo, 58554, Korea

**AI & Mechanical System Center, Institute for Advanced Engineering, Youngin, 17180, Korea

***CladKorea, Wonju, 26365, Korea

[†]Corresponding author : ilsookim@mokpo.ac.kr

(Received July 27, 2020 ; Revised September 7, 2020 ; Accepted November 30, 2020)

Abstract

As the pipes used in the shipbuilding industry are expensive of the materials themselves and require excellent welds performance, the latest high-performance welding methods and automation are urgently needed, the level of demand for pipe welding equipment products is increased, and the cost reduction for securing competitiveness in overseas markets is being developed. In pipe welding, the worker's proficiency has a great influence on the quality and productivity of the welds, and the demand for the welding process continues to increase as the number of skilled workers decreases. Recently, the welding industry has been involved in the Fourth Industrial Revolution, and several studies are being conducted to establish the smart factory and the high quality demand of products in the field of actual production and manufacturing. Deep learning, one of the artificial intelligence techniques, shows outstanding performance in recent areas such as object recognition, natural language processing and image classification through the development of computer computation processing speed. Therefore, in this study, 3D Scanner was used to obtain current voltage data through GTA welding using SA516-70 material and to identify the dimensions of bead width according to current voltage data. In addition, real-time current and voltage data and data obtained through 3D Scanner developed a DNN model to predict bead width.

Key Words : GTAW, 3D scanner, DNN model, Welding monitoring

1. 서 론

조선산업의 성장과 더불어 용접기술은 많은 발전을 하여왔으나 현재 조선업 용접은 3D 업종으로 분류되어서 작업자를 확보에 어려움이 있으며, 특히 용접 관련

전문인력이 부족한 실정이다. 수동용접 공정 중에 용접 품질은 오직 용접 전문인력의 기량에 좌우되는 관계로 전문인력을 확보하지 못한 대다수의 용접 관련 업체에서는 부정확하고 비효율적인 용접시공법을 적용함으로써, 용접 불량, 용접결함으로 인한 불량증가 및 원가상승 등의 경제적인 문제점에 당면해 있다.

부정확한 용접조건 선정으로 인하여 발생하는 용접공정의 문제점 중 하나는 용접변형인데 이러한 용접변형은 외관상 미흡, 이음 강도감소 및 치수 부정확성 등과 같이 용접된 구조물의 품질에 악영향을 미친다. 또한 다양한 외부 요인으로 인해 이상 상황이 발생할 수 있으며 이로 인해 정상적인 용접이 이루어지지 않는 문제가 발생한다. 특히 용접기에서 이러한 이상 상황을 감지하지 못하는 경우가 많기 때문에 작업자가 이를 인식하지 못하여 용접품질 관리에 많은 어려움이 발생한다.

현재까지 이러한 문제점을 해결하기 위하여 고효율, 고생산성 용접기술을 통하여 수작업으로만 이루어지던 용접공정을 자동화하기 위한 많은 연구가 수행되고 있는데 완전한 용접 자동화 과정을 위해서는 아직도 해결하여야 하는 많은 문제점을 가지고 있다¹⁾. 이러한 문제점 중에서 가장 중요한 요인은 최적의 용접품질을 미리 예측하고 적정한 용접조건을 선정하는데 있다. 용접공정의 최적화는 지금까지 다양한 방법으로 연구가 진행되었다.

1990년대에는 용접품질 최적화를 위하여 시뮬레이션 기법을 이용한 연구가 시작되었다.

Lee²⁾는 유한요소법을 이용하여 용접변수의 민감도 해석을 통하여 용접 최적화를 연구하였다. Park³⁾은 수치해석을 통하여 Pipe 보수 용접조건을 최적화하였다. Lee⁴⁾는 GTA(Gas Tungsten Arc) 용접에 대하여 전극봉 각, 아크길이 및 용접전류 등이 용접부에 미치는 영향을 수치해석을 사용하여 연구하였다.

2000년대에는 용접품질에 영향을 미치는 공정변수와 용접부의 비드형상과의 상관관계를 통해 최적 용접변수 선정을 위한 수학적 모델개발에 집중되었다⁵⁾. Park⁶⁾은 GTA 아래보기 자세 다층용접부의 비드형상 예측에 관한 실험적 연구를 통하여 공정변수와 비드형상간의 상관관계 분석 및 개발된 회귀 모델의 정확도를 분석하였다. Kim⁷⁾은 2차 회귀 모델을 이용하여 GMA 용접부의 비드형상을 예측을 위한 수학적 모델에 관한 실험적 연구를 통하여 공정변수와 비드 상관관계 분석하였다. Son⁸⁾은 GMA 용접에서 유전자 알고리즘을 이용하여 2차방정식 모델과 3차방정식 모델을 개발하였으며, 기존 회귀 모델과 개발한 모델을 비교·분석함으로써 용접품질을 향상 방안을 제시하였다. Jung⁹⁾은 GA 알고리즘을 이용하여 탄뎀 가스메탈아크 용접 비드형상 예측 공정 최적화에 관하여 연구하였다.

2010년대부터 현재까지는 신경망을 이용하여 복잡한 시스템의 입력변수 및 출력변수 사이의 상호 관계를 모델링하는 방법으로 사용되었다¹⁰⁾. 4차산업혁명과 관련하여 연계된 AI(Artificial Intelligence) 기법 중 하

나로 딥 러닝(Deep learning) 기법을 이용한 공정변수 제어를 위한 연구가 수행중이다. Kim¹¹⁾은 딥 러닝을 이용하여 GMA 용접에서 이면비드 생성 유무 판단 알고리즘에 관한 연구를 하였으며, 심층 신경망을 사용하여 이면비드가 생성된 용접인지 여부를 판단하는 시스템을 제안하였다. Cho¹²⁾는 신경망 알고리즘을 이용하여 용접부 품질예측을 하였다. Park¹³⁾은 딥 러닝의 일종인 CNN(Convolutional Neural Network)기법을 이용한 스폿용접 품질분류에 관한 연구를 통하여 두 알고리즘 모델의 분류 정확도를 비교·분석하였다. Cho¹⁴⁾는 인공 신경망 알고리즘을 도입하여 차체용 강판의 겹치기 필렛 이음부에 대한 적정 아크 용접조건을 도출하였다.

위에서 언급한 대부분의 연구가 현재까지 최적의 용접변수 결정과 예측모델 개발에 관련된 분야와 용접공정 전 변형량을 예측하고, 이를 최소화하기 위한 기술적 방법들이 제시에 제한적으로 연구가 집중되었다. 하지만 AI 기법인 딥 러닝기술을 이용하여 최적의 용접조건 선정 및 용접부 결합여부 확인을 위한 알고리즘 개발 및 실시간으로 비드폭을 예측 할 수 있는 연구는 전무한 실정이다.

따라서 본 연구에서는 GTA 용접의 용접 모니터링 시스템을 이용하여 실시간으로 전류 및 전압 데이터를 획득하고, GTA 용접부의 미용접 및 기공과 같은 결함 발생 여부나 결함의 위치를 실시간으로 판단하는 알고리즘 개발을 수행하고자 한다. 또한 용접품질은 실제 용접부 비드에서의 결함 발생여부와 결함 위치를 3D Scanner를 통하여 확인하였다. 그리고 DNN(Deep Neural Network) 알고리즘을 이용하여 최적의 비드폭을 예측하고 실시간으로 결함을 예측할 수 있는 연구를 하였다.

2. GTA 용접실험

2.1 용접실험 구성 및 방법

SA516-70(ASME SA516-Grade70 Steel) 파이프의 용접공정의 비드폭을 예측하기 위하여 용접실험을 실시하였고 파이프 용접 시 작업자가 요구하는 다양한 비드폭을 선정하기 위해 가장 효율적이고 널리 사용되는 GTA(Gas Tungsten Arc) 용접법을 선정하였다. 따라서 본 연구에서는 파이프 용접의 예측모델을 개발하기 위해 GTA 용접을 이용하여 SA516-70의 용접을 수행하였다. SA516-70의 용접부의 품질을 확인하고 최적의 공정변수를 개발하기 위하여 MIYACHI 모델




Fig. 1 The apparatus for welding experimentation employed




Fig. 2 Bead height deviation




Fig. 3 A schematic diagram for GTA weld process

Maxstar 700이 사용되었고 Fig. 1에 용접실험을 위한 전체 시스템 구성을 나타내고 있다. 용접실험은 파이프 용접 대신에 평판 실험이 수행되었다. 파이프에 직접 용접을 하여 최적의 조건을 선택하려면 고가의 장비가 필요하며, 많은 비용과 인력이 필요하다. Fig. 2에서 알 수 있듯이, 250mm 직경 파이프가 2° 회전으로 용접되는 경우 비드높이 편차 (δ)는 약 0.0381mm이다. 따라서 위와 같은 이유로 평판 시험편에 대해 용접실험을 수행하였다. 또한 연구에서 수행된 실험은 평평한 위치에서 비드 형상(Bead geometry)에 필요한 기본 용접조건을 선택하여 용접실험을 수행하였다.

Fig. 3은 실험을 위하여 시험편 재질은 SA516-70을 사용하였으며, 400×500×5mm (400mm×500mm×5T) 규격으로 제철용접 실험을 진행하였다. 비드용접(Bead-on-plate)으로 용접이 수행되기 때문에 시험편 옆면에

Table 1 Mechanical properties of base metal

Material	C	Si	Mn	P	S	Cu	Ni	Cu	V
SA516-70	0.186	0.369	1.089	0.018	0.004	0.03	0.01	0.014	0.013

Table 2 GTA welding parameters and their levels

Welding parameter		Unit	Level		
Control factor	A	B	-1	0	1
	Welding current	Amp	150	160	170
	Arc voltage	Volt	17	18	19
Fixed variable	<ul style="list-style-type: none"> Shielding gas : Ar 100 % Torch angle : 90° Welding speed : 7 cm/min 				

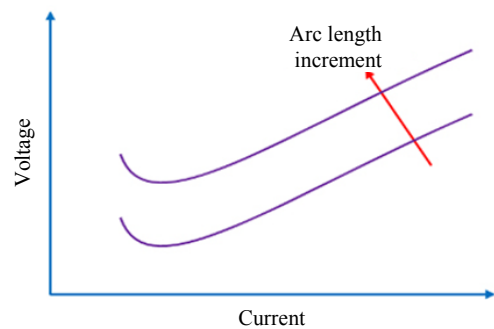


Fig. 4 Voltage characteristics with variation of arc length

개선각도 및 루트면은 설정하지 않았다. 또한 실험에 사용된 시험편의 화학적 조성은 Table 1에 나타내었다.

본 용접실험에의 공정변수는 용접성에 가장 큰 영향을 미치는 용접전류, 아크전압으로 선정하였으며, 이에 따른 출력변수로는 비드폭으로 선정하였다. 실험계획법은 입력변수 변화에 따른 출력변수 반응의 비선형적인 변화에도 민감하게 대응할 수 있고 실험횟수의 최적화를 고려하기 위하여 완전요인설계(Full factorial design)를 선정하였다. 9개의 용접실험조건을 이용하여 실험을 실시하였으며, 입력변수의 실험변수 및 수준은 Table 2에 나타내었다. 용접속도는 상수로 선정하여 실험을 진행하였다.

Fig. 4에 아크전압은 아크길이에 의하여 결정되며, 아크길이가 증가하면 아크전압은 선형적으로 증가한다. 아크전압이 증가하면 입열량이 증가하므로 모재의 용융량도 증가하지만, 아크길이가 길어짐에 따라 아크가 주위로 퍼지므로 아크열이 분산되어 비드폭은 증가하지만 용입이 감소한다.

본 연구에서는 실시간으로 데이터를 수집 및 예측모델에 활용하기 때문에 용접변수로 아크길이 보다는 TIG 용접 전용 모니터링 시스템으로 측정할 수 있는 아크전압을 사용하였다.




Fig. 5 GTA welding monitoring system employed

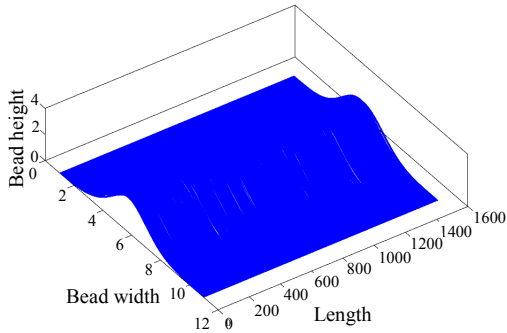


Fig. 6 Measured bead geometry using a 3D scanner

2.2 데이터 수집 및 비드폭 측정

GTA 용접의 체계적인 실험 결과 분석을 위하여 출력되는 용접전류 및 아크전압 값의 정확한 계측은 아크 시작 시 발생하는 고주파의 영향을 고려하여 TIG 용접 전용 모니터링 시스템을 이용하여 용접전류와 아크전압을 측정하였다. 용접실험 결과 데이터 및 예측모델 개발에 사용된 용접전류 및 아크전압 값은 이를 통하여 실시간으로 계측된 데이터 값을 사용하였다. Fig. 5는 모니터링 장치를 통해 계측된 용접 중의 용접전류 및 아크전압 파형을 나타낸다. 이렇게 실시간으로 측정된 용접전류 및 아크전압의 데이터들은 예측모델 개발에 사용하였다.

전류·전압 모니터링과 실시간 품질을 확인하기 위하여 3D Scanner를 사용하여 용접시작 지점과 끝 지점에서 각각 200mm를 제외한 가운데 50mm의 비드폭을 측정하고 비드폭으로부터 측정된 20만개의 데이터들을 최적화 모델 개발에 사용하였다. Fig. 6은 3D scanner를 이용하여 측정된 비드형상을 모델링한 결과를 나타낸다.

2.3 실험결과

용접실험결과 전반적으로 아크가 안정적이고 양호한 비드폭을 형성함으로써 외관상 결함을 나타내지 않았으며, 용접조건에 따라 용융부의 형상에 미치는 영향을 판별하기 위해 광학 현미경 시스템을 이용하여 단면형

Table 3 Design of experiment conditions for experiment using a FFD

Case no.	Welding current (A)	Arc voltage (V)	Bead width(mm)	
			Bead width	Bead geometry
1	150	17	11.25	
2	150	18	11.52	
3	150	19	11.86	
4	160	17	12.54	
5	160	18	12.72	
6	160	19	12.93	
7	170	17	13.61	
8	170	18	13.82	
9	170	19	13.90	

상(Macro)을 촬영하여 특성을 분석하였고 측정된 결과인 비드형상을 Table 3에 나타내었다.

3. 결과 및 고찰

3.1 GTA 용접공정 DNN 알고리즘 개발

GTA 용접공정에서의 비드폭 예측이 가능한 심층 신경망(Deep Neural Network, DNN) 알고리즘을 개발하고자 한다. DNN은 딥 러닝은 기존 인공신경망에서 지속적으로 발전되어 온 기계학습법 중에 하나로써 인공신경망보다 더 깊고(Deep) 넓은(Wide) 구조를 가지고 있다. 기존 인공신경망의 역전파 알고리즘(Back propagation algorithm)의 한계를 극복하고 복잡한 구조를 풀 수 있도록 하였다. 심층 신경망은 입력층(Input layer)과 출력층(Output layer) 사이에 여러 개의 은닉층(Hidden layer)들로 이뤄진 인공신경망(Artificial

Neural Network, ANN)이다.

심층 신경망은 일반적인 인공신경망과 마찬가지로 복잡한 비선형 관계(Non-linear relationship)들을 모델링할 수 있다. 예를 들어, 사물 식별 모델을 위한 심층 신경망 구조에서는 각 객체가 이미지 기본 요소들의 계층적 구성으로 표현될 수 있다. 이때, 추가 계층들은 점진적으로 모여진 하위 계층들의 특징들을 규합시킬 수 있다. 심층 신경망의 이러한 특징은, 비슷하게 수행된 인공신경망에 비해 더 적은 수의 유닛(Unit, Node)들 만으로도 복잡한 데이터를 모델링할 수 있게 해준다. 심층 신경망은 표준 오류역전파 알고리즘으로 학습될 수 있다. 이때, 가중치(Weight)들은 아래의 등식을 이용한 확률적 경사 하강법(Stochastic gradient descent)을 통하여 갱신될 수 있다.

$$\Delta w_{ij}(t+1) = \Delta w_{ij}(t) + \eta \frac{\partial C}{\partial w_{ij}} \quad (1)$$

여기서, η 는 학습률(Learning rate)을 의미하며, C 는 비용함수(Cost function)를 의미한다. 비용함수의 선택은 학습의 형태(지도 학습, 자율 학습(기계 학습), 강화 학습 등)와 활성화함수(Activation function)같은 요인들에 의해서 결정된다. 예를 들면, 다중 클래스 분류 문제(Multiclass classification problem)에 지도 학습을 수행할 때, 일반적으로 활성화함수와 비용함수는 각각 Softmax 함수와 교차 엔트로피 함수(Cross entropy function)로 결정된다.

Softmax 함수는

$$P_j = \frac{\exp(x_j)}{\sum_k \exp(x_k)} \quad (2)$$

로 정의된다. 이때, P_j 는 클래스 확률(Class probability)을 나타내며, x_j 와 x_k 는 각각 유닛 j 로의 전체 입력(Total input)과 유닛 k 로의 전체 입력을 나타낸다. 교차 엔트로피는

$$C = - \sum_j d_j \log(p_j) \quad (3)$$

로 정의된다. 이때, d_j 는 출력 유닛 j 에 대한 목표 확률(Target probability)을 나타내며, p_j 는 해당 활성화함수를 적용한 이후의 j 에 대한 확률 출력(Probability output)이다.

기존 인공 신경망의 경우에는 XOR 문제 등 다소 간단한 데이터를 구별해 낼 수 있었지만 은닉층(Hidden layer)의 층수가 증가했을 때 기울기가 사라지는 문제(Vanishing gradient problem)나 오버피팅(Over-




Fig. 7 Structure of on-line learning neural network




Fig. 8 The flowchart of DNN procedure

fitting) 문제를 해결하지 못했다. 은닉층에서의 층의 개수에 따라 모델의 복잡도가 결정되고, 2개 이상의 은닉층을 가진 경우를 DNN 알고리즘이라 하며 Fig. 7과 같이 다중의 은닉층을 이용하면 다양한 비선형적 관계를 나타낼 수 있다. 인공신경망과 심층 신경망의 가장 큰 차이점은 은닉층의 수이다.

위와 같은 방법으로 인공신경망이 가지고 있던 은닉층의 수를 증가시키며 더 정밀한 분류가 가능해지도록 발전하였다. DNN의 은닉층 뉴런 수는 시행착오 방식으로 결정되었다. 신경망의 전반적인 정확도를 향상시키고자 하였으며, 학습은 목표 오차값에 도달하거나 최대 Epoch 수가 끝날 때 또는 μ 가 최대값에 도달할 때까지 계속되었다. Fig. 8은 DNN의 Flowchart를 나타내었다¹⁵⁾.

3.2 GTA 비드폭에 대한 DNN 알고리즘 개발

은닉층 사이즈 선택은 신경망 설계에서 가장 중요하게 고려해야 할 요소 중 하나이며, 이 분야에 대해 집중적인 연구가 진행되고 있지만 아직까지 결정적인 솔루션이 없는 상태이다. 이러한 문제는 신경망 매핑이 복잡하고 성공적으로 끝난 많은 트레이닝 절차가 특성

상 비결정적이기 때문에 정확하게 분석하는 것은 상당히 어려운 일이다.

따라서 학습 데이터는 용접실험을 통해 획득한 데이터들의 평균값을 이용하였고, 시행착오 방식을 통하여 은닉층의 뉴런수는 3~10개로 설정하여 오차가 최소화 되도록 학습하였다. Fig. 9는 은닉층의 뉴런수에 따른 비드폭의 실측값과 예측값의 비교·분석한 결과를 보여주고 있는데 상관 관계는 1에 가까울수록 강한 상관관

계이고 0에 가까울수록 관계가 없다. 은닉층의 뉴런수가 7개일 경우 상관계수 R이 1에 가장 가까운 0.98612로 은닉층의 뉴런수가 3개일 경우 보다 정확한 비드폭을 예측함을 확인할 수 있었다.

3.3 MSE를 통한 오차

MSE(Mean Squared Error)는 실험 또는 해석을 수행하지 않은 예측점에 불확실성을 정량적으로 제공하는 값으로써 모델의 구성을 위해 선택된 실험점에서 멀어질수록 예측오차의 값이 증가하는 특징을 갖는다. MSE는 Cost function인데 MSE function은 모델의 예측값(Prediction) \hat{Y} 과 실제 타겟값(True target value) Y 의 차이를 제곱해서 모두 더한 값들의 평균으로 정의된다.

통계에서 추정값의 평균 제곱 오차 또는 평균 제곱 편차는 오차의 제곱 평균, 즉 추정값과 실제 값 간의 평균 제곱 차를 측정한다. 손실함수는 정답에 대한 오류를 숫자로 나타내는 것으로 오답에 가까울수록 큰 값이 나오고 반대로 정답에 가까울수록 작은 값이 나온다. 식 (4)의 Y_i 는 실제값, \hat{Y}_i 는 예측값, n 은 예측값의 수를 의미한다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (4)$$

Table 4에 은닉층의 뉴런수를 찾기 위한 네트워크 구조를 재구성하여 학습한 신경회로망 결과를 나타내었으며, 은닉층의 뉴런수가 7개일 경우 시험의 MSE 0.1247과 학습의 MSE 0.1425로 오차가 최소로 은닉층의 뉴런수가 3개일 경우 보다 정확한 비드폭을 예측함을 확인할 수 있었다. Fig. 10은 신경회로망을 이용하여 얻은 시험과 학습에 대한 MSE 오차를 나타내고 있다.

Table 4 R²-value for the artificial neural-network configuration with a number of between 3 and 10 neurons in the hidden layer

Hidden layer	Epochs	Training time (sec)	Training error (MSE)	Testing error (MSE)
3	144	00:00:49	0.3241	0.2145
4	42	00:00:03	0.4191	0.2612
5	606	00:00:36	0.2728	0.1847
6	110	00:00:04	0.5367	0.3475
7	1000	00:01:17	0.1247	0.1145
8	1000	00:01:12	0.2141	0.1275
9	241	00:00:24	0.6124	0.4997
10	101	00:00:10	0.7815	0.6814

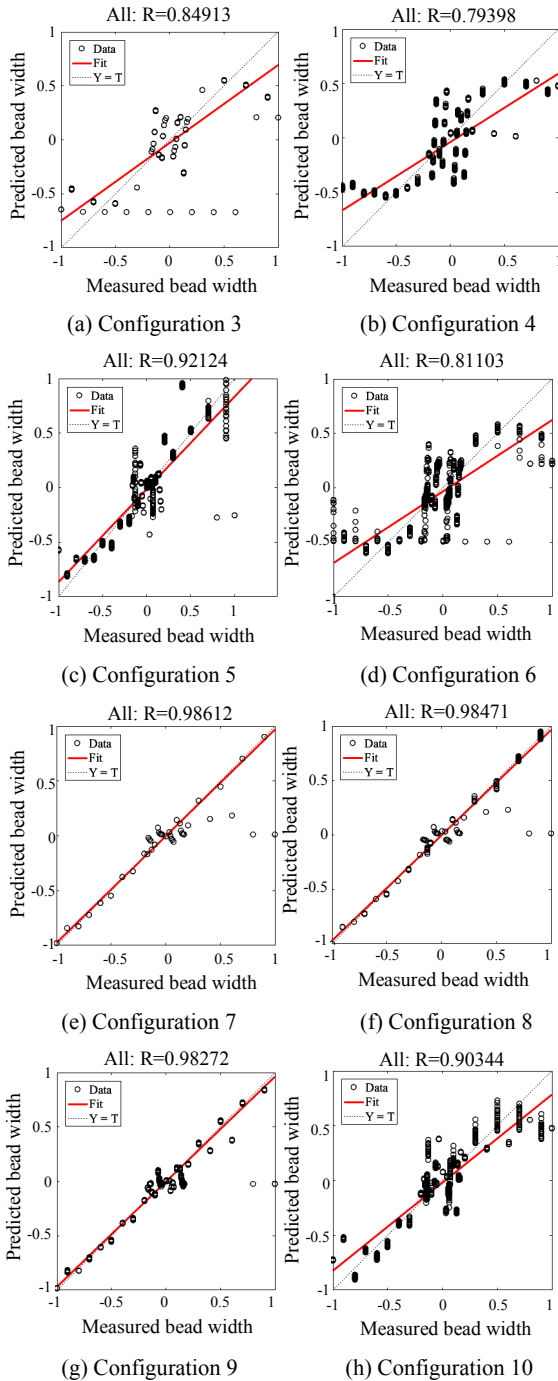


Fig. 9 R²-value for the neural-network configuration for bead width

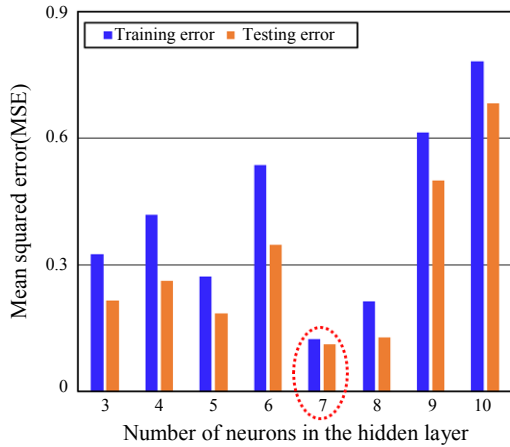


Fig. 10 Training and testing subset MSE value for the artificial neural-network configuration with a number of between 3 and 10 neurons in the hidden layer

Table 5 Performance of the developed DNN algorithm for bead width

Bead geometry	PAM (%)
Bead width	100

3.4 PAM 분석을 통한 검증

GTA 용접 비드폭을 예측하기 위한 DNN 알고리즘의 보다 정확한 비드폭 예측성능을 비교·분석하기 위하여 아래의 식 (5)와 같이 Poliak¹⁶⁾이 정의한 PAM (Predictive Ability of Model)을 이용하여 정확도를 평가하였다.

$$PAM = \frac{N_{PAM}}{N} \tag{5}$$

여기서, N_{PAM} 은 $-0.1 \leq \frac{B_M - B_P}{B_M} \leq 0.1$ 범위의 예측치의 수를 나타내며, N 은 전체 예측치 수를 나타낸다. 그리고 B_M 은 실측치 비드폭이며, B_P 는 계산된 비드폭을 의미한다. PAM은 오차범위 10% 이내에 예측을 정확한 예측으로 간주하여 모델의 정확도를 나타내며, 표준편차는 모델의 분포를 확인함으로써 측정치 비드폭에 얼마나 근접하게 예측하는지를 나타낸다.

개발된 DNN 알고리즘의 PAM분석 결과를 Table 5에 나타냈으며, 예측능력 확인을 위해 각 실험조건별 측정된 비드폭과 예측된 비드폭을 Fig. 11에 나타냈다. PAM 분석 결과 100%의 높은 PAM의 예측능력을 가지고 있다. 이는 정확한 비드폭을 예측함을 확인할 수 있다.



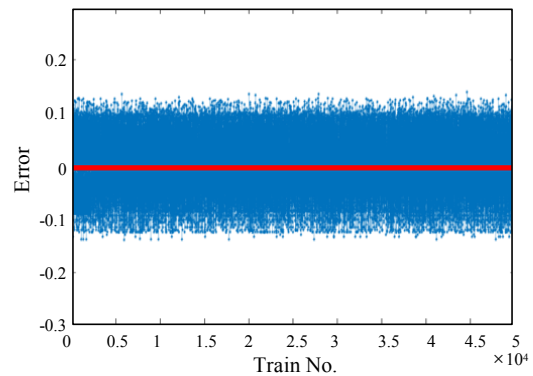


Fig. 11 Comparison between measured and predicted bead width from the developed DNN algorithm



(a) Predicted bead widths



(b) Error distributions

Fig. 12 Model 1 for bead width

3.5 DNN 알고리즘을 통한 오차 예측

개발된 DNN 알고리즘을 사용하여 비드폭을 예측하였으며 평균 오차는 1% 미만으로 나타났다. Fig. 12는 입력값(용접전류 및 아크전압)으로 출력값(비드폭)을 예측하고 오차를 나타낸다.

Table 6 Error rate by case

Bead width(mm)	
Case	Average error
1	0.05
2	0.03
3	0.02
4	0.01
5	0.02
6	0.01
7	0.04
8	0.03
9	0.03

4. 결 론

본 연구에서는 GTA 용접공정의 비드폭 예측모델 개발을 위하여 SA516-70 평판의 제살용접 실험을 실시하고, 이를 통하여 획득한 데이터를 활용하여 실시간으로 공정변수와 비드폭간의 상관관계 분석 및 비드폭 예측모델 개발을 수행함으로써 다음과 같은 결론을 얻을 수 있었다.

1) 완전요인실험방법에 따라 용접조건별로 총 27회의 GTA용접실험을 실시하였으며, 용접실험 시 용접 모니터링 시스템을 이용하여 실시간으로 전류·전압 데이터를 추출하였다. 추출한 데이터를 기반으로 용접품질을 실시간으로 확인하였으며, 전류전압 데이터에 따른 비드폭의 경향을 확인하기 위해 3D Scanner를 사용하였다. 또한 실시간 전류·전압 데이터와 3D Scanner를 통하여 획득한 데이터들은 최적화 모델 개발하였다.

2) 용접실험에서 측정된 실험결과를 기초로 신경회로망을 이용하여 DNN 알고리즘을 개발하기 위하여, 신경회로망 구조를 이용하여 숨겨진 은닉층의 뉴런수를 결정하였고 은닉층의 뉴런수 7개의 구조를 가진 최적화된 DNN 알고리즘을 개발하였다.

3) DNN 알고리즘의 신뢰성을 검증하기 위하여 실제 용접실험에서 얻은 비드폭과 상호 비교·분석하였으며, PAM을 이용하여 정확도를 평가하였다. 그 결과 DNN 알고리즘의 비드폭이 100%의 예측성능을 확인함으로써 DNN 알고리즘을 사용할 경우 정확한 비드폭을 예측함을 확인할 수 있었다.

후 기

This work was supported by the Project of Technology Development for Industry Core (No.20004100, Package

Concept of Pipe Spools, Platform as a Service, Digital Twin, Big Data) funded By the Ministry of Trade, Industry & Energy (MOTIE, Korea)

ORCID: Won-Bin Oh: <https://orcid.org/0000-0003-2032-1031>

ORCID: Tae-Jong Yun: <https://orcid.org/0000-0002-3827-5857>

ORCID: Bo-Ram Lee: <https://orcid.org/0000-0002-0201-6335>

ORCID: Ill-Soo Kim: <https://orcid.org/0000-0002-9936-6760>

ORCID: Ki-Young Park: <https://orcid.org/0000-0002-7641-8249>

ORCID: Byeong-Ju Jin: <http://orcid.org/0000-0001-7829-7949>

References

1. J. S. Son, I. S. Kim and H. H. Kim, A Study on Real-time Prediction of Bead Width on GMA Welding, *J. Korean Weld. Join. Soc.* 25(2) (2007) 64-70. <https://doi.org/10.5781/KWJS.2007.25.6.064>
2. S. H. Lee and Y. S. Yang, A study on the sensitivity analysis of welding process parameters on weld bead geometry, *J. Korean Soc. Manuf. Technol. Eng.* (1998) 274-280.
3. S. C. Park, Optimization of repair welding conditions using experimental and numerical analyses, *J. Korean Weld. Join. Soc.* (1999) 245-246.
4. S. Y. Lee and S. J. Na, In the fixed TIG welding, the numerical analysis of the geometric welding parameters affecting the melt One study, *J. Korean Weld. Join.* (1994) 100-104.
5. I. S. Kim, M. H. Park, H. H. Kim, J. P. Lee, C. K. Park and J. Y. Shim, An Experimental Study on Mathematical Model to Predict Bead Width in GMA Weldment, *J. Korean Soc. Precis. Eng.* 32(2) (2015) 209-217. <https://doi.org/10.7736/KSPE.2015.32.2.209>
6. M. H. Park, I. S. Kim, J. H. Lee, J. P. Lee, Y. S. Kim and S. O. Na, An Experimental Study on Prediction of Bead Geometry for GTA Multi-pass Welding in Under-head Position, *J. Weld. Join.* 32(1) (2014) 53-60. <https://doi.org/10.5781/JWJ.2014.32.1.53>
7. I. S. Kim, M. H. Park, H. H. Kim, J. P. Lee, C. K. Park and J. Y. Shim, An Experimental Study on Mathematical Model to Predict Bead Width in GMA Weldment, *J. Korean Soc. Precis. Eng.* 32(2) (2015) 209-217. <https://doi.org/10.7736/KSPE.2015.32.2.209>
8. J. S. Son, I. S. Kim, K. C. Jang and D. G. Lee, A Study on Development of Predicted Model for Bead Height Using Genetic Algorithm in GMA Welding, *J. Korean Soc. Manuf. Technol. Eng.* (2006) 292-297.
9. S. M. Jung, I. S. Kim, J. H. Lee, J. P. Lee, Y. S. Kim and M. H. Park, Experimental study on prediction of optimum Tandem GMA welding bead geometry, *Korean Welding and Joining Society 2012 Fall Conference*, (2012) 185.
10. J. H. Kim, M.H. Ko and N. K. Ku, A Study on Resis-

- tance Spot Welding Failure Detection Using Deep Learning Technology, *J. Comput. Des. Eng.* 24(2) (2019) 161-168.
<https://doi.org/10.7315/CDE.2019.161>
11. M. S. Kim, S. M. Shin, D. H. Kim, S. H. Rhee, A Study on the Algorithm for Determining Back Bead Generation in GMA Welding Using Deep Learning, *J. Weld. Join.* 36(2) (2018) 74-81.
<https://doi.org/10.5781/JWJ.2018.36.2.11>
 12. J. H. Cho, Prediction of Arc Welding Quality through Artificial Neural Network, *J. Korean Weld. Join. Soc.* 31(3) (2013) 44-48.
<https://doi.org/10.5781/KWJS.2013.31.3.44>
 13. D. J. Park, D. H. Kim, S. S. Jeon and S. H. Rhee, A study on the Quality Classification of Spot Welding Using Deep Learning (Convolutional Neural Network), *J. Weld. Join.* (2018) 112.
 14. J. H. Cho, Proper Arc Welding Condition Derivation of Auto-body Steel by Artificial Neural Network, *J. Weld. Join.* 32(2) (2014) 43-47.
<https://doi.org/10.5781/JWJ.2014.32.2.43>
 15. H. W. Wang, G. Yang, C. C. Pan and Q. Gong, Prediction of Hot Metal Silicon Content in Blast Furnace based on EMD and DNN, *34th Chinese Control Conference (CCC)*, Hangzhou, (2015) 8214-8218.
 16. Poliak, Parallel ANOVA Processing, *MIT Press, Cambridge, MA*, (1986) 318-362.