

딥러닝(Deep Learning)을 이용한 GMA 용접에서 이면비드 생성 유무 판단 알고리즘에 관한 연구

김민석* · 신승민* · 김동현* · 이세현*[†]

*한양대학교 대학원 기계공학과

A Study on the Algorithm for Determining Back Bead Generation in GMA Welding Using Deep Learning

Min Seok Kim*, Seung Min Shin*, Dong Hyun Kim*, and Sehun Rhee*[†]

*School of Mechanical Engineering, Hanyang University, Seoul, 04763, Korea

[†]Corresponding author : srhee@hanyang.ac.kr

(Received February 26, 2018 ; Revised March 27, 2018 ; Accepted April 4, 2018)

Abstract

In arc welding, the generation of back bead is considered as one of the main factors that determine the mechanical characteristics of the welded structure. The existence or shape of the beads can be observed by destructive inspection, which cuts the cross section, or non-destructive inspection, which uses visual or ultrasonic waves. In recent manufacturing processes, the demands of high quality and factory automation are continuously presented, and the importance of research on a more efficient real time diagnosis system that can reduce the time and cost for the detection of structural defects of welds is becoming higher. In this study, an algorithm is developed to determine the back bead generation in real time by using current and voltage signals measured in real time by applying deep learning which is one of artificial intelligence techniques. The result proposes a system to determine whether back bead is generated or not, using deep neural network, a type of deep learning.

Key Words : Gas metal arc welding, Back bead, Machine learning, Deep learning, Deep neural network, Artificial neural network, Time series data

1. 서 론

불활성가스 아크용접(gas metal arc welding; GMAW)은 소모성 전극과 모재 간의 아크를 생성해 용융 및 결합을 일으키는 용접법 중 하나이다. 소모성 전극인 용접 와이어가 아크의 열에 의해 용융되어 용접부에 공급되며, 가스노즐을 통해 공급되는 보호 가스에 의해 아크와 용접부가 보호된다¹⁾.

이면 비드(back bead)란 맞대기 아크용접에서 아크가 열면의 반대면(후면)에 생성되는 비드를 의미한다²⁾. 이면 비드가 생성됨으로써 원페스 용접으로 전면과 후면을 동시에 용접하는 효과를 주게 된다. 특히 배관 및

선박 용접에서 이면 비드의 유무와 형상은 정적 체결강도 및 피로강도에 영향을 미치는 매우 중요한 요소 중의 하나로 인식되고 있다. 이면 비드 용접은 용접을 시행하는 사람의 자세나 용접 조건에 따라 매우 다양한 형태로 나타나며 간혹 이면 비드가 생기지 않는 경우도 발생하게 된다.

기존에 이면 비드의 생성 유무를 판단하기 위한 방법으로는 용접부를 파괴하여 확인하는 방법 또는 용접부를 파괴하지 않는 비파괴검사방법이 있다. 특히 선박용접에서 용접 부위를 파괴하지 않는 비파괴검사방법으로는 초음파탐상검사(UT), 자분탐상검사(MT) 등이 있다. 이러한 방법들은 모두 실험적으로만 의미가 있다는 한계점과 상대적으로 비용이 많이 드는 단점을 가지고 있다.

한편 비드 형상을 예측하는 예로 용접 조건 및 고정된 용접 자세에 대한 입력변수를 통계적으로 계산하는 방법이 제시되었다³⁾. 또한 인공신경망을 이용하여 용접 조건들에 대한 입력변수들을 설정하여 비드 형상을 예측하는 방법이 제시되었다⁴⁾. 이러한 방법들은 모두 용접의 조건이 고정된 환경에서 형상을 알아낼 수 있는 방법들이다.

최근 생산과 제조의 과정에서 높은 품질의 요구와 공장 자동화의 양상들이 지속적으로 제시되고 있으며, 용접부의 구조적 결함의 검출을 위해 시간적, 경제적인 손실을 줄일 수 있는 보다 효율적인 실시간 진단 시스템에 관한 연구의 중요성이 더욱 높아 가고 있다. 이러한 필요성에 따라 공작기계의 결함 검출 및 기계 상태의 진단 분야에서 실시간으로 평가 및 검사가 가능한 기계 학습(machine learning) 기법을 적용한 결함 검출 방법에 관해 최근 여러 연구가 진행되고있다⁵⁾.

본 연구에서는 용접이 수행되고 있는 동안 계측된 전류와 전압 신호를 이용해 실시간으로 이면 비드의 생성 유무를 판단할 수 있는 알고리즘을 개발하여 실제 용접에 대입해 실험적으로 검증하였다. 시스템의 기계학습 기법으로 최근 신뢰성이 높게 평가되고 있는 딥러닝(deep learning)기법을 사용하였으며, 입력 변수들은 해당 전류 및 전압신호의 특징을 추출하여 구성하였다. 또한 딥러닝의 성능을 기존 인공신경망과 비교하여 성능을 검증하였다.

2. 딥 러닝

2.1 심층 신경망(Deep Neural Network)

딥러닝은 기존 인공신경망에서 지속적으로 발전되어 온 기계학습법 중에 하나로써 인공신경망보다 더 깊고(deep) 넓은(wide) 구조를 가지고 있다. 심층 신경망(deep neural network; DNN)은 딥러닝의 하나이며 기존 인공신경망의 역전파 알고리즘(back propagation algorithm)의 한계를 극복하고 복잡한 구조를 풀 수 있도록 하였다. 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(overfitting) 문제를 해결하지 못했다⁶⁾.

이후 여러 인공신경망에 대한 연구로 신경망의 가중치를 계산하는 방법, 다양한 활성화 함수 등의 발전으로 심층 신경망의 학습이 가능하게 되었다. 또한 많은 수의 연산을 그래픽 처리 장치(graphic processing unit;

GPU)를 통해 계산하여 기존 CPU 대비 빠른 학습이 가능하게 되었다.

역전파 계산법으로 해당 구조의 가중치(w)와 편향값(b)을 구하기 위해서는 오차함수(E)의 기울기를 계산해야한다. 학습에서 가중치를 수정 할 때 다음과 같은 규칙이 적용된다.

$$w_i \leftarrow w_i + \Delta w_i \tag{1}$$

$$\Delta w_i = -\eta \frac{\partial E_d}{\partial w_i}$$

여기서 η 는 학습율(learning rate)이며 보통 0.001~0.01의 값을 사용한다. 오차를 가중치에 대하여 미분하면 다음과 같은 식을 얻을 수 있다.

$$\frac{\partial E}{\partial w_i} = \frac{\partial E}{\partial f} \cdot \frac{\partial f}{\partial s} \cdot \frac{\partial s}{\partial w_i} \tag{2}$$

위에서 오차는 활성화함수의 출력값(f)에 의존하고 활성화함수는 다시 입력총값(s)에 의존하므로 연쇄법칙을 적용하여 전개하였다. 이 때 활성화 함수로 시그모이드(sigmoid)를 사용할 시 출력값과 입력총값의 미분식은 다음과 같다.

$$\frac{\partial f}{\partial s} = f(1-f) \tag{3}$$

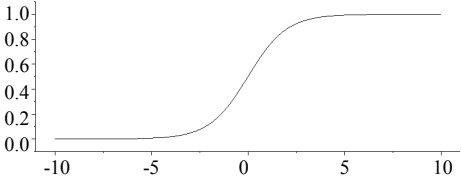
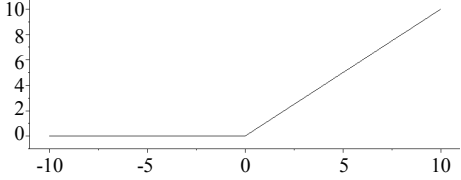
$$\frac{\partial s}{\partial w_i} = \frac{\partial}{\partial w_i} \sum w_j x_j = x_i \tag{4}$$

식 (3)에서 지역의 최대값은 0.25이며 가중치의 값 또한 항상 1보다 작은 값이기 때문에 은닉층의 수가 증가할수록 새로운 가중치를 재추정 하는데 미미한 변화만을 이르게 재추정이 거의 이루어지지 않는 기울기가 사라지는 문제가 발생한다.

본 연구에서는 심층 신경망 구조에 Table 1에 제시된 렐루(rectifier liner unit; ReLU) 함수를 활성화 함수로 적용하여 가중치 재추정이 더욱 용이하게 만들었다. 렐루 함수는 음수에서 출력값이 0으로 활성이 되지 않으며 양수에서는 기울기가 항상 1로 일정하기 때문에 시그모이드 함수에서 발생하는 기울기가 사라지는 문제를 해결하게 된다.

또한 기울기 하강법을 사용하는 가장 기본적인 방법인 식(1)에서 제시되었는데 심층 신경망의 경우 기본형태에서 변형된 식을 사용한다. 본 연구에서는 전체 데이터 대신 일부 조그마한 데이터의 모음(mini-batch)에 대해서만 오차함수를 계산하는 확률적 기울기 하강(stochastic gradient descent)의 방법 중 하나인 아담 옵티마이저

Table 1 Activation functions used in the neural network structure

Structure	Activation function	f(x)	Graph
ANN	Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	
DNN	ReLu	$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$	

(adam optimizer)를 사용하였다⁷⁾. 아담 옵티마이저는 기울기의 지수평균과 기울기의 제곱값의 지수평균을 저장하며 가중치를 업데이트한다.

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla_w E(w) \quad (5)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \nabla_w E(w)^2 \quad (6)$$

$$w \leftarrow w - \frac{\eta}{\sqrt{(v_t + \epsilon)}} m_t \quad (7)$$

β_1 과 β_2 는 보정계수로 각각 0.9, 0.999를 사용하며 ϵ 은 분모가 0이 되는 것을 방지하기 위해 약 10^{-8} 정도의 아주 작은 값을 사용한다. 식 (5)는 가중치 재추정시 관성을 주는 의미로 최적화 과정에서 진동(oscillation)으로 인해 추정이 느려질 때 더 빠르게 추정할 수 있도록 만들어주며 식 (6)은 미니배치 사용시 각각 변수마다 업데이트 횟수에 따라 단계 크기(step size)를 다르게 적용하여 더 빠르게 최적값을 추정할 수 있도록 만들어준다.

일반적인 인공신경망(artificial neural network: ANN)과 심층 신경망의 가장 큰 차이점은 은닉층의 수이다. 위와 같은 방법으로 인공신경망이 가지고 있던 은닉층의 수를 증가시키며 더 정밀한 분류가 가능해지도록 발전하였다. 특히 심층 신경망의 구조를 다양하게 변화시키며 여러 형태의 딥러닝이 존재하는데 대표적인 경우로 순환 신경망(recurrent neural network)과 합성곱 신경망(convolutional neural network)이 있다.

2.2 심층 신경망 기반 이면 비드 생성 판단

본 연구에서는 딥러닝기법 중 하나인 심층 신경망을 사용하여 GMAW의 전류, 전압 신호를 학습하여 다른 테스트 신호들에서 이면 비드 생성 유무를 판단하는 시스템을 구성하였다. Fig. 1과 같은 알고리즘을 제안하

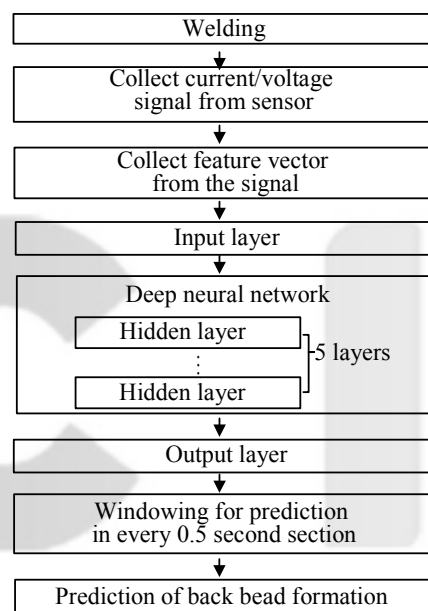


Fig. 1 Process of back bead detection




Fig. 2 Structure of DNN layer used for learning and testing

였으며 최종적으로 0.5초의 용접 구간에서 이면 비드가 생성되었는지 유무를 판단한다.

학습과 시험을 위해 사용된 DNN구조는 Fig. 2에서 나타낸 것과 같다. 입력층 노드(input node)는 전류, 전압에서 추출된 12개의 변수로 이루어지며 출력층 노드(output node)는 이면 비드가 생성되었을 시 1을 출력하고 생성되지 않았을 시에는 0이 출력되게 했으며 출력층 노드 수는 1개이다. 은닉층은 5개의 층으로 구성하였으며 각 층은 23개의 노드로 구성하였다. 학습율은 0.001이며 100,000번 반복하여 학습을 진행하였다.

각 층에서의 활성화 함수로 렐루 함수를 사용하였으며 이는 인공신경망에서 사용되는 시그모이드 함수보다 역전파 계산시 기울기의 크기 영역이 더 크게 나타난다. 또한 각 노드의 가중치를 계산하기 위해 아담 옵티마이저를 사용하였다. 이러한 방법론은 기존의 인공신경망이 가지고 있던 기울기가 사라지는 문제나 오버피팅을 해결하며 DNN이 구현 가능하도록 만들어 준다. 해당 내용을 비교하기 위해 사용한 기존 인공신경망은 은닉층이 2개로 이루어져있고 활성화 함수와 옵티마이저로 각각 시그모이드 함수와 배치 그래디언트 디센트 옵티마이저(batch gradient descent optimizer)를 사용하여 같은 내용의 입력값을 학습하고 시험하였다.

3. 전류·전압 신호기반 이면 비드 생성 판단 기법

3.1 GMAW 실험 방법

본 연구에서 사용한 시편은 Fig. 3에 나타낸 것과 같이 길이 180 mm, 폭 150 mm, 두께 2.6 mm의 아연이 도금된 SGAFH 590FB판재이며 이면 비드 실험을 위하여 맞대기 이음을 사용하였다.

용접실험에 적용한 조건은 Table 2에 나타낸 것과 같다. 용접속도는 600 mm/min으로 진행하였으며, 용접 전류와 전압은 각각 232 A, 20.4 V이며 이는 와이어 송급속도를 7 m/min으로 진행했을때 GMA 용접의 최적 조건이다.

아크 용접기는 Fronius사의 TPS-4000모델을 사용하였다. 용접 비드를 보호하기 위한 보호가스로는 Ar-90%, CO₂-10%의 혼합가스를 사용하였으며, 금속이행은 정전압모드에서 단락이행모드로 시행하였다. 본 실험에서는 이면 비드의 유무를 판단하기 위하여 임의로 두 시편 사이에 갭을 주지 않은 경우와 0.2 mm 갭을 준 경우로 나누어 실험하였다.

Fig. 4에 나타낸 것과 같이 갭을 준 경우에는 아크로 인한 입열이 시험편의 아랫면까지 잘 전달되어 이면 비




Fig. 3 Specification of weld specimen

Table 2 GMA welding conditions for experiment

Variable	Value
CTWD	15 mm
WFR	7 m/min
Welding speed	600 mm/min
Arc current	232 A
Arc voltage	20.4 V




Fig. 4 Bead shapes with 0.2mm gap




Fig. 5 Bead shapes with no gap

드가 생성되는 반면에 갭을 주지 않은 경우에는 Fig. 5와 같이 이면 비드가 생성되지 않았다. 같은 전류, 전압의 조건으로 단락이행모드를 제어했음에도 불구하고

두 용접에 큰 차이가 발생하였고 이 때 생성되는 아크의 모양이 계속되는 신호에 영향을 줄 것으로 예상하였다.

3.2 용접 전류·전압 모니터링 시스템

용접을 수행하는 동안 전류신호와 전압신호를 실시간으로 초당 10000개의 데이터를 20초 동안 획득하여 저장하였다. Fig. 6와 같이 20초간 계측된 전류와 전압 신호를 구간별로 p1부터 p8까지 8개의 구간을 학습 데이터(train data)로 사용하였고 Test p1과 Test p2 구간을 시험 데이터(test data)로 사용하였다. 지도 학습(supervised learning)을 진행할 때에는 입력값뿐만 아니라 출력값도 함께 지정해 주어야 하는데 이 때 p1부터 p4구간과 p5부터 p8구간을 교차 배치하여 학습에 더욱 용이하도록 만들었다.

Fig. 6의 전류, 전압 신호를 계측한 용접에 해당하는 상면 비드와 이면 비드 형상을 Fig. 7에 나타내었다. 학습 데이터로 사용된 구간은 전체 측정기간 20초 중에서 불완전한 영역인 시작 부분과 종료 부분인 4초를 제외한 구간의 데이터를 사용하였으며 학습을 위해 16초 동안 진행된 용접 구간을 p1부터 p8으로 구별하여 수행하였다. 시험 데이터로 사용된 구간은 8초 동안 진행된 용접 구간이며 Test p1의 4초와 Test p2의 4초이다.

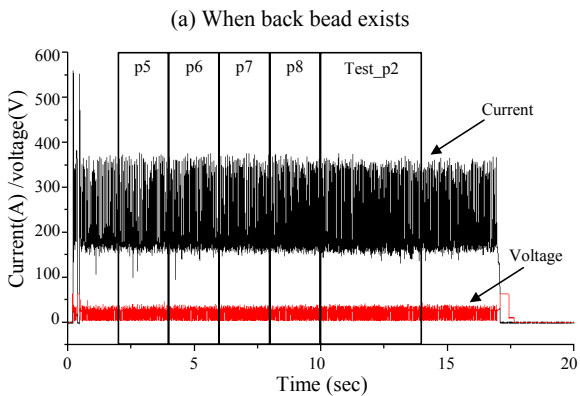





Fig. 6 Measured current and voltage signals for train or test



(a) When back bead exists



(b) When back bead does not exist

Fig. 7 Image of the welding zone corresponding to the signal

3.3 특징벡터 추출

Fig. 5에서의 계측한 데이터를 0.2초의 프레임에서 특징 벡터들을 추출하였다. 학습데이터가 16초간 진행되었을 때 더 많은 특징 벡터를 추출하기 위해 90%씩 중첩하며 프레임을 설정하였다. Fig. 8에 나타낸 것 같이 4가지 종류의 카테고리에서 특징 벡터들을 추출하였다. 각 카테고리는 한 프레임 내에 아크의 상태와 관련된 변수들이며 특징들(features)은 그 변수들의 평균, 표준편차, 최대값, 개수 따위로 이루어진다. 두 개의 카테고리는 전압과 관련된 변수이며 0.2초 윈도우 내에 단락시간(short circuit time)과 아크시간(arc time)과 관련된 특징들로 이루어진다. 다른 두 카테고리는 전류와 관련된 변수들이다. 전류의 피크(peak)값과 관련된 특징들과 피크값들 사이의 시간과 관련된 특징들이 이를 이룬다.

0.2초 프레임 내에 관찰된 모든 단락시간과 아크시간 각각의 평균, 표준편차, 최대값을 추출하였고 전류의 피

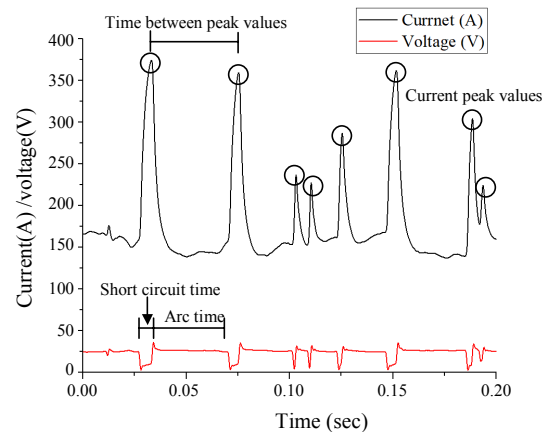


Fig. 8 Categories used for feature extracting in 0.2 second window

Table 3 Features from the categories of the signal

Category	Features
Short circuit time	Average, Standard deviation, Maximum
Arc time	Average, Standard deviation, Maximum
Current peak values	Average, Standard deviation, Number of peaks
Time interval between peak values	Average, Standard deviation, Maximum

크값들의 평균, 표준편차, 피크의 개수를 추출하였으며, 마지막으로 피크 사이의 시간값들의 평균, 표준편차, 최대값을 추출하였다. 총 12개의 특징 벡터들을 추출하였으며 Table 3에 정리하였다.

추출된 특징들은 중 일부는 서로 상호작용하는 관계에 있다. 가령 전압에서의 단락시간과 아크시간을 더하면 이론상 전류에서 피크값 사이의 시간이 된다. 시간과 관련된 값들이 중첩적으로 사용되어 노드의 수로써 가중치를 더 부여해주는 의미를 가지고 있다.


3.4 시험 결과

3.4.1 심층 신경망 시험결과


추출된 12차원의 벡터를 입력값으로 하는 712개의 데이터를 Fig. 2와 같은 심층 신경망 구조에 학습하였고, 학습된 심층 신경망 구조를 통하여 356개의 데이터를 시험하였다. 학습을 모두 진행한 결과 학습데이터에 대한 정확도는 94.52%이다. Fig. 6에서 제시한 Test p1과 Test p2 구간을 시험하였으며 Test p1의 경우는 이면 비드가 생성된 경우로써 출력값이 1이 되어야 알맞게 예측했다고 볼 수 있다. 반대로 Test p2 구간의 경우는 이면 비드가 생성되지 않았고 출력값이 0이어야 한다.

Fig. 9은 0.2초 윈도우를 적용한 심층 신경망 결과값을 나타낸 것이다. 정확도 79.21%로 산출되었으며 이 출력값은 4초구간의 데이터를 0.2초 단위로 90%중첩하여 계산하였으므로 간헐적으로 정상적인 값으로 예측하지 못한다고 할지라도 중첩되는 구간이 함께 고려되었을 때 결과값이 다르게 나타날 수 있다.

이 점을 고려하여 본 시스템의 최종적인 판단은 0.5초 구간, 즉 심층 신경망 구조에서 연속된 9개 출력값을 사용하여 계산하였다. 연속되는 9개의 출력값의 평균이 0.5이상일 경우 비드가 생성된 구간이라고 보고 0.5미만일 경우 비드가 생성되지 않았다고 판단하였다. 그 결과 324개의 결과값을 도출했으며 Fig. 10과 같이




(a) Back bead region




(b) Non-back bead region

Fig. 9 Output from the deep neural network



(a) Back bead region



(b) Non-back bead region

Fig. 10 Final prediction after 0.5 second windowing in DNN

96.91 %의 정확도로 계산되었다.

3.4.2 인공 신경망 시험결과

심층 신경망에서의 실험 과정을 인공 신경망 구조에서 동일하게 적용하여 비교해 보았다. Fig. 11은 일차적으로 인공 신경망 구조를 거친 결과값이다. 정확도 68.26%로 해당값이 앞서 제시된 심층 신경망의 결과값보다 10.95% 저조한 것을 관찰할 수 있다.

최종적인 판단 결과는 Fig. 12에서 볼 수 있다. 71.91%의 정확도로 이면 비드의 생성 유무를 예측하였으며 심층 신경망 결과에 비해 정확도가 현저히 낮은 수준이라고 여겨진다.

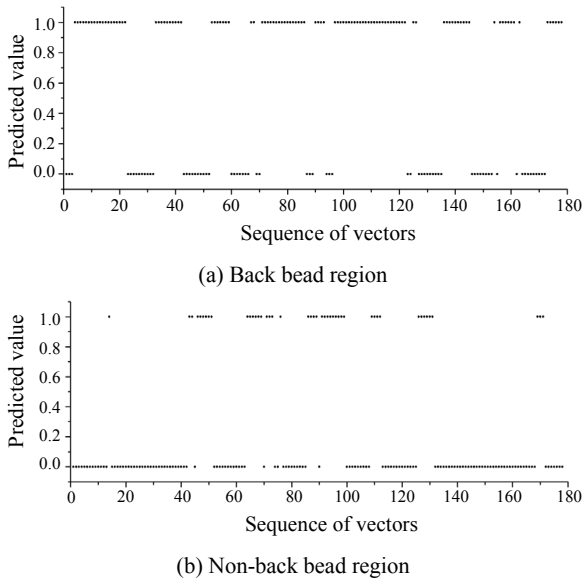


Fig. 11 Output from the artificial neural network

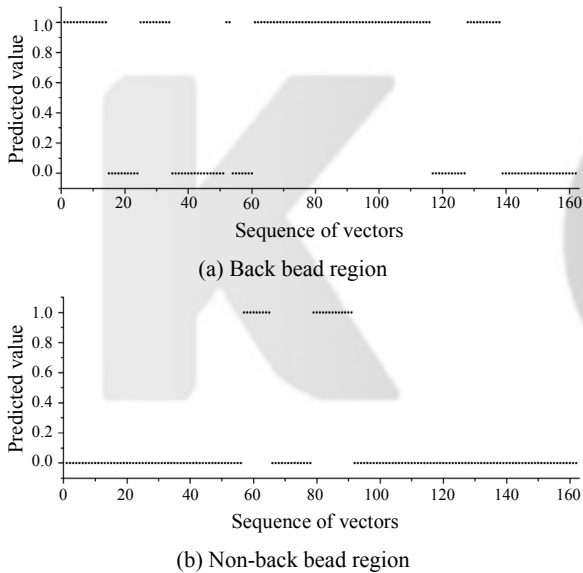


Fig. 12 Final prediction after 0.5 second windowing in ANN

3.4.3 결과 비교 및 분석

본 연구에 사용된 심층 신경망 구조는 용접 시행시 발생하는 전류와 전압의 신호에서 특징벡터를 추출하여 입

력값으로 설정하였고 출력값은 1과 0으로 이면 비드가 생성되었는지의 여부를 나타내도록 학습하고 시험하였다.

Table 4는 최종적인 결과치를 심층 신경망과 인공 신경망을 비교하며 나타낸 것이다. 인공 신경망의 경우 71.91%의 정확도로 테스트 데이터를 예측하였으며 심층 신경망의 경우 그보다 약 25% 상승한 96.91%의 정확도로 이면 비드 생성을 판단하였다. 특히 심층 신경망의 경우 이면 비드가 생성되지 않을 시에 더 높은 정확도로 판단하였다.

비드 생성에 따라 용접의 전류, 전압값의 차이를 이용하였다. 이 때 전류의 피크값의 크기는 용접의 조건마다 달라지기 때문에 시스템이 보편적으로 사용되기 어려운 한계점을 지닌다. 그렇지만 이 외에 시간을 활용한 파라미터들은 용접 조건, 즉 전류와 전압의 크기와 상관없이 사용될 수 있다. 전류의 피크값 또한 정규화 과정 이후 크기에 상관없이 사용될 수 있을 것으로 사료된다.

4. 결 론

기계 학습법 중 딥러닝의 한 종류인 심층 신경망(DNN)을 사용하여 이면 비드가 생성된 용접인지 여부를 판단하는 시스템을 제안하였다. 이연도금 강판의 맞대기 용접을 GMAW으로 진행할 때 발생하는 전류와 전압을 계속하여 특징추출 후 심층 신경망으로 학습하였다. 특징벡터로는 전압과 관련된 변수 6개 전류와 관련된 변수 6개, 총 12개를 사용하였다. 학습한 신호를 기반으로 학습에 사용되지 않은 신호를 시험하였고 결과값으로 출력되는 예측값을 다시 0.5초 구간으로 묶어 이면 비드가 생성되었는지 판단하였다. 그 결과 심층 신경망 구조의 Hidden layer가 5층, 23노드일때 가장 높은 약 96.91%의 정확도로 이면 비드의 생성 유무를 판단하였으며 인공 신경망 구조로 학습 후 시험했을 때보다 약 25% 증가했다.

Acknowledgement

This work was supported by the Industrial technology

Table 4 Test data result

Structure	Variable	Number of measured	Estimated	Error	Acc.
DNN	Back bead	162	152	10	96.91%
	Non-back bead	162	162	0	
ANN	Back bead	162	93	69	71.91%
	Non-back bead	162	140	22	

Innovation Program (No. 10063421, 'Development of the in-line welds quality estimation system and network-based quality control technology in arc and spot welds of ultra high strength steels for automotive parts assembly') funded By the Ministry of Trade, industry & Energy(MI, Korea).

This research was respectfully supported by Engineering Development Research Center (EDRC) funded by the Ministry of Trade, Industry & Energy (MOTIE). (No. N0000990)

ORCID: Min Seok Kim: <https://orcid.org/0000-0001-6921-4216>

ORCID: Seung Min Shin: <https://orcid.org/0000-0002-8348-3671>

ORCID: Dong Hyun Kim: <http://orcid.org/0000-0003-0532-3725>

ORCID: Sehun Rhee: <https://orcid.org/0000-0002-0039-5650>

References

1. The Korean Welding and Joining Society, *Welding and Joining handbook (III Process and heat processing)*, (2007), 45-46
2. The Korean Welding and Joining Society, *Welding and Joining Dictionary*, (2001), 87
3. Ji-sun Kim, Ill-Soo Kim, Hyun-Ho Na, Ji-Hye Lee, An Experimental Study on Prediction of Back-bead Geometry in Pipeline Using the GMA Welding Process, *Korean Society of Manufacturing Technology Engineers*, 20(1), (2011), 74-80
4. Jeong-ick, 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
5. Minjae Kang, *A Study on Monitoring System of Arc Welding Fault Detection Using Machine Learning Algorithm*, Hanyang University, (2017), master's thesis
6. Kitae Kim, Bomi Lee, Jong Woo Kim, Feasibility of Deep Learning Algorithms for Binary Classification Problems, *Journal of Intelligence and Information Systems*, 23(1), (2017), 95-108
<https://dx.doi.org/10.13088/jiis.2017.23.1.095>
7. Diederik P. Kingma, Jimmy Lei Ba, ADAM : a Method for Stochastic Optimization, *Published as a conference paper at the 3rd International Conference for Learning Representations*, San Diego, (2015), 1-15
8. Jeong-Ung Park, Gyu-Baek An, Fracture Toughness of Thick Steel Plate for Ship Building, *International Journal of Korean Welding Society*, 25(4), (2007) 353-357
9. L. Deng, G. Hinton and B. Kingsbury, New types of deep neural network learning for speech recognition and related applications: an overview, *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, Vancouver, BC, (2013), 8599-8603
10. Dongho Jung, Seunghyub Oh, A Study on the Flow Influence in Piping Welding Joint Back Bead, *Proceedings of the Society of CAD/CAM Conference*, (2013), 568-571
11. Dongcheol Kim, Sehun Rhee, Hyunsung Park, Modelling and optimization of a GMA welding process by genetic algorithm and response surface methodology, *International Journal of Production Research*, 40(7) (2002), 1699-1711
<https://doi.org/10.1080/00207540110119964>
12. Yongjoon Cho, Sehun Rhee, Quality Estimation of Resistance Spot Welding by Using Pattern Recognition With Neural Networks, *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 53(2) (2004), 330- 334
<https://doi.org/10.1109/TIM.2003.822713>