

딥 러닝 기반의 이미지학습을 통한 저항 용접품질 검증

강지훈·구남국[†]
동의대학교 조선해양공학과

Verification of Resistance Welding Quality Based on Deep Learning

Ji-Hun Kang·Namkug Ku[†]
Dept. of Naval Architecture and Ocean Engineering, Dong-Eui University

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Welding is one of the most popular joining methods and most welding quality estimation methods are executed using joined material. This paper propose welding quality estimation methods using dynamic current, voltage and resistance which are obtained during welding in real time. There are many kinds of welding method. Among them, we focused on the projection welding and gathered dynamic characteristics from two different types of projection welding. For image learning, graphs are drawn using obtained current, voltage and resistance, and the graphs are converted to images. The images are labeled with two sub-categories – normal and defect. For deep learning of images obtained from welding, Convolutional Neural Network (CNN) is applied, and Tensorflow was used as a framework for deep learning. With two resistance welding test datasets, we conclude that the Convolutional Neural Network helps in predicting the welding quality.

Keywords : Resistance welding(저항 용접), Quality verification(품질 검증), Deep learning(딥 러닝), Tensorflow(텐서플로우)

1. 서 론

선박, 해양구조물, 자동차 및 항공기 등 높은 부가가치를 창출할 수 있는 산업에서 높은 생산성의 확보는 필수적이다. 그리고 이러한 생산성의 향상은 제작공정에서의 용접의 품질과도 직결되어 있다.

조선소에서는 조립단계 및 선종에 따라 다양한 용접법이 적용되고 있으며 그 중 많이 적용되고 있는 용접공정을 살펴보면 플럭스 코어 아크 용접(Flux Cored Arc Welding), 서브머지드 아크용접(Submerged Arc Welding, SAW), 피복 아크용접(Shield Metal Arc Welding, SMAW), 중력식 아크 용접(Gravity Arc Welding) 등이 있다.

이렇게 다양한 용접을 실시하고 있는 조선소의 경우 생산 공정 중 용접이 상당 부분을 차지하고 있으며 용접부 외관검사 및 비파괴 검사를 실시하여 용접부 품질을 확인하여야 한다. 주로 방사선 검사(radiography testing), 초음파 검사(ultrasonics testing), 자분 검사(magnetic particles), 액체침투검사(liquid penetrants testing), 누설검사(leak testing)등의 비파괴 검사를 실시하고 있다. 그러나 상기 방법들로는 생산공정에서 실시간적

인 적용이 어려울 뿐만 아니라, 상대적으로 많은 비용이 소모된다는 단점이 있다. 따라서 객관적이고 실시간적인 평가가 가능한 신뢰성 있는 검사방법을 개발하기 위해 각 개별 용접공정에 대한 용접데이터를 분석하는 기술 개발이 필요하다.

이에 따라서 본 연구에서는 용접시 실시간으로 얻어지는 데이터를 활용하여 저렴한 비용으로 용접 품질을 검증할 수 있는 기술을 제안하고자 한다. 다만, 본 연구에서는 제안한 기술을 앞서 설명한 플럭스 코어 아크 용접이나 서브머지드 아크용접 등에 적용하기 위한 전단계로서 실험 데이터를 생성하기에 용이한 저항용접에 먼저 적용해 봄으로써 제안한 기술의 타당성을 먼저 검토해 보았다.

Hwang et. al(2017)의 연구에서는 역전파(back propagation)를 기반으로 학습되는 인공신경망(artificial neural network) 알고리즘을 이용하여 저항 점 용접 시 발생하는 3가지의 불량 용접 상태를 예측할 수 있는 알고리즘을 제안하였다. 용접 시 소재조합 정보, 가압력, 용접신호를 사용하여 평균 90%이상의 예측정확도를 나타내었으나 심층신경망(deep neural network)를 사용하지 않았다. Cho et. al(1998)의 연구에서는 정전류 제어 방식의 저항 점 용접 시 검출되는 전압 등의 용접변수와 용접부의 인장전단강도와 너깃 생성여부 등의 용접 품질과의 관계를

규명할 수 있는 퍼지 알고리즘을 제안하였다. 오목자국 등의 결함과 전단 및 인장강도의 실시간적인 품질예측이 가능한 결과를 보여주었다. Yoon(2017)의 연구에서는 Adaptive Resonance Theory I Neural Network를 사용하여 인라인에서 수집 가능한 전류 및 전압 신호를 이용하여 저항 점 용접부의 인장강도나 파단 형상을 예측할 수 있는 모델을 개발하였다. Woo & Rhee(2014)의 연구에서는 가압력과 전류의 세기를 주요인자로 설정하여 저항 점 용접시 방출되는 음향 신호를 주파수 영역으로 변환하여 역전파 신경망에 학습시키고, 음향 신호의 진폭과 중심주파수가 용접성과의 상관관계가 있음을 밝힘으로서 실시간 비파괴적인 용접품질평가에 대한 가능성을 보여주었다.

현재 모니텍에서는 저항용접의 용접성에 대해 실시간적인 판단으로 불량률 판별하는 특허를 가지고 있으며(Hwang & Gho, 2012; Monitec Co., 2018), 이 특허는 동저항 및 평균동저항을 이용한 알고리즘으로 구성된다. 다만, 이 알고리즘은 순서도를 활용한 기준 값의 단순 비교로 이루어져 있으며, 약 80%의 정확도로 불량 판별이 가능하다.

앞서 살펴본 바와 같이 지금까지 산업에서의 용접의 중요성 때문에 용접의 용접성에 대한 평가에 대한 연구가 많이 되어왔지만 용접 공정변수 데이터의 패턴을 이미지화하여 인공지능망에 학습시켜 용접성을 평가한 연구는 이루어지지 않았다.

본 연구에서는 인공지능망을 사용하여 보다 정확도 높은 용접결합 평가 모델을 만들 수 있는 방법에 관해 연구하고자 한다.

본 연구에서는 인공지능망(artificial neural network) 기술을 용접의 동특성에 적용하여 너트 프로젝션 용접, End plug 업셋(Upset) 용접 등 저항 용접 프로세스의 불량판별 기법 개발에 대해 순차적으로 기술하고자 한다. 우선, python을 이용하여 용접 데이터를 시각화 시킬 수 있도록 Matplotlib 라이브러리(Matplotlib development team, 2019)를 활용하여 용접 공정 중 발생된 데이터를 이미지화하여 저장할 수 있는 플랫폼을 구축하였다. 또한 Google의 오픈소스 기반 인공지능망의 일종인 Inception v3모델(Inception, 2019)로 구성된 컨볼루션 신경망(Convolutional Neural Network; CNN)을 이용하여 저항 용접시 얻을 수 있는 전압, 용접 전류, 가압력 등의 용접 공정변수 데이터를 학습시켜 용접성을 예측할 수 있도록 구성하였다. 인공지능망 구성을 위해 Tensorflow(TensorFlow 2.0 Beta, 2019)를 기반으로 구현된 GoogLeNet모델(Inception, 2019)을 활용하였으며, 용접 공정변수에 대한 전이 학습(transfer learning)을 수행하였다. 그리고 예측된 결과를 기반으로 신경망 모델의 성능에 대해 논의하였다.

본 논문의 구성은 다음과 같다. 2절에서는 저항용접의 동특성 데이터의 특성에 대해 살펴보고 용접성 분석을 위해 고려해야 될 공정변수에 관하여 기술하였다. 3절에서는 오픈소스 기반의 TensorFlow를 이용하여 신경망을 구성하는 방법과 저항 용접시 발생하는 저항 및 전류 등의 데이터를 정제하고 분석하는 절차를 설명한다. 4절에서는 몇 가지 저항용접의 품질과 관련된 공정변수 데이터패턴의 인공지능망 학습 결과에 대해 서술하였다. 마지막으로 5절에서 결론을 맺는다.

2. 용접 특성 및 공정 변수

2.1 저항용접

저항용접은 저항열을 이용하여 모재를 녹여 접합시키는 용접 방법이다. Fig. 1은 저항용접의 개념도를 보여주고 있으며, 저항 용접의 순서는 다음과 같다.

- 1) 용접 대상물(workpiece)을 겹쳐 고정한다.
- 2) 용접 대상물의 상하에 전극(electrode)을 닿도록 배치한다.
- 3) 전극을 통해 용접 대상물에 전류(current)를 흘려보내는 동시에 압력(pressure)을 가한다.
- 4) 용접 대상물 사이의 저항 때문에 열이 발생하고 가장 큰 저항이 발생하는 접합면이 용융된다.
- 5) 용융된 부분은 너깃(nugget)이 되고 용접이 마무리 된다.

- 전류: 동일한 조건에서 전류를 증가시켜 용접하게 될 경우 용융부의 크기 증가와 기계적 강도의 증가 등의 효과를 기대할 수 있다. 따라서 일반적으로 높은 용접전류를 인가하여 시간대비 생산성을 높일 수 있으나, 과도하게 높은 전류는 용접부의 과열에 의해 스패터의 발생을 유발하여 용접에 쓸 금속이 손실되는 결과를 초래할 수 있다. 더불어 낮은 용접전류 역시 너깃의 충분한 성장을 보장하지 못하여 용접부의 기계적 강도 등이 부족할 수 있다.

- 통전시간: 위 3)번에서 전류를 흘려보내는 시간을 통전시간이라고 한다. 전류가 동일한 조건에서 통전시간을 증가시키면 너깃직경이 증가하지만 일정 시간이상이 되면 더 이상 너깃 직경은 증가하지 않고 오목자국 등의 문제가 발생하게 된다. 또한 저전류를 사용하여 통전시간을 길게 하면 전극과 용접재료 등의 다른 부분으로 열이 전달되어 열손실과 함께 통전 중 냉각 작용이 발생하여 인장 전단강도가 저하되는 원인이 될 수 있다(Lee, 2013).

저항용접은 일반적으로 열에 의한 용접모재의 변형이나 잔류응력이 작아 3mm 이하의 박판재를 이용한 용접 제품의 대량생산 등에 적합하다. 하지만 용접재의 재질 및 두께에 따라 전류의 세기나, 통전시간, 가압력(pressure)등의 공정변수를 조절하여 적절한 용접조건을 선정할 필요가 있다. 공정변수를 적절하게 제어하지 않을 경우 용접부의 스패터(spatter) 발생 및 충분하지 않은 너깃(nugget)두께 등의 문제가 있을 수 있다. 본 연구에서는 용접조건에 관련된 공정변수 중 실시간으로 측정이 용이한 전류(current), 전압(voltage)을 활용하여 용접 품질을 예측하고자 하였다. 이를 위해서 측정한 전류와 전압을 활용하여 동저항(dynamic resistance)을 계산하였다. 여기서, 동저항은 글자 그대로 전압을 전류로 나누어 구한 저항값을 의미 하는데, 전류나 전압이 용접을 하는 도중 실시간으로 변하기 때문에 저항도 실시간으로 변하게 되며, 이를 동저항이라고 부른다. 일반적으로 동저항은 용접의 진행과정에 대한 다양한 정보를 담고 있기 때문에, 본 연구에서는 이 동저항을 인공지능망 학습에 활용하였다.




Fig. 1 Resistance Welding

통상의 용접공정의 품질관리를 위해 모니터와 같이 실시간 용접 품질 평가 시스템에서 도출된 용접 데이터의 평균 값을 이용할 경우 관리는 가능하나 각각의 개별 용접에 대한 품질관리는 어려운 점이 있다.(Monitec Co., Ltd, 2018) 따라서 용접공정이 끝남과 동시에 용접공정 중 발생된 실시간 데이터를 이용하여 즉각적으로 용접성을 판단할 수 있게 된다면 생산성 향상뿐만 아니라 품질 관리 측면에서도 긍정적인 효과를 기대할 수 있다.

2.2 프로젝션 용접

프로젝션 용접은 용접 모재에 전류를 인가할 때 모재의 저항에 의해 유발된 열에너지를 활용하여 접합하므로 점 용접(spot welding)과 유사한 특성이 있다. 용접 실시 전 용접모재에 돌기(projection)를 가공하고, 가공된 돌기를 통해 전류를 집중시킴으로써 작은 크기의 너깃으로 용접이 가능하고 열 변형이 적다는 장점이 있다. 또한 여러 개의 돌기를 생성하여 여러 점을 동시에 용접할 수 있으므로 높은 생산성을 유지할 수 있기 때문에 산업 전반에 걸쳐 널리 이용되고 있는 방법이다.

프로젝션 용접은 용접재를 서로 밀착시켜 저항열을 이용하여 용접하는 방법이므로 접촉면의 상태와 면적은 용접 품질에 영향을 줄 수 있다. 예를 들면 Fig. 2의 오른쪽 가장 위 그림에서 보는 바와 같이 너트가 바르게(normal nut) 놓여 있는 경우에는 정상적으로 용접이 되지만, 중간 그림과 같이 너트가 뒤집혀 놓여있는 경우(inverted nut)나 혹은 아래 그림과 같이 공정상의 불량이나 너트의 재사용 등으로 인하여 돌기의 형상이 정상적이지




Fig. 2 Failure of nut projection welding

않을 때(bad projection) 용접 불량이 발생한다. 이러한 용접의 경우 동저항과 전극 변위를 계속하면 용접 품질을 추정할 수 있다.

2.3 업셋 용접

업셋(Upset)용접은 서로 다른 용접모재의 단면을 가볍게 접촉시킨 후 대전류를 흘려 접촉면에 용접재료를 가열하고, 용접면이 용융된 상태에서 큰 힘으로 압력을 주어 접합시키는 방식의 용접법이다. 초기 가열 과정에서 접합에서는 가압력이 낮으나 대전류가 흐르기 시작하면 Fig. 3에서 보는 바와 같이 높은 압력으로 업셋(Upset)하여 용융부를 외부로 배출시키게 된다. 업셋 용접은 표면의 불순물이나 산화막을 업셋 과정에서 용접부 외부로 배출할 수 있다. 따라서 용접 전 접합면의 상태에 크게 영향 받지 않으며, 접합강도와 신뢰성이 높은 용접법이다.




Fig. 3 Upset welding process

3. 심층 신경망

인공신경망은 생물학에서의 신경망, 특히 인간이나 동물들의 중추신경계인 뇌를 모델로 한다. 중추신경계는 신경세포(neuron)의 시냅스 결합을 통해 신호를 전달하게 되는데, 이러한 신호전달과정을 수학적으로 모델화하여 인공뉴런을 통해 정보를 전달하는 것을 인공신경망이라 정의할 수 있다. 딥러닝은 기존의 인공신경망에서 더 나아가 신경망의 계층수와 은닉층의 노드 수를 늘린 보다 깊고 넓은 신경망 구조를 가지고 있다. 이러한 구조를 심층신경망(Deep neural network; DNN)으로 정의할 수 있으며 기존의 인공신경망이 풀지 못하였던 복잡한 문제나 비선형 문제를 다룰 수 있다. 본 연구에서는 이미지 학습을 위하여 기존의 심층 신경망 기술을 활용하였으며, 이 장에서는 본 연구에서 활용한 심층신경망 기술을 설명한다.

3.1 딥러닝 프레임워크

현재까지 MXNet, Keras, Caffe, Torch 등의 다양한 프레임워크가 개발되어 있으며 Python이나 C++등의 프로그래밍 언어를 통해 신경망을 보다 쉽게 구축하고 대량의 데이터를 처리 할 수 있도록 보조해 주고 있다. 본 연구에서는 구글에서 공개한 오픈소스 기반의 기계학습(Machine Learning) 소프트웨어 라이브러리인 Tensorflow를 딥러닝 프레임워크로 사용하여 신경망을 구성하였다.

3.2 컨볼루션 신경망(CNN)

컨볼루션 신경망은 이미지의 선이나 색 테두리 등의 시각적 특징이나 특성을 감지하는 것을 주요 목적으로 한다. CNN은 합성곱(convolution)을 이용하여 동작하며 특정 패턴을 가진 규칙적인 곱 연산을 수행한다. 이를 통해 이미지를 이해하고 높은 수준으로 추상화된 정보를 추출 할 수 있어 영상인식, 컴퓨터 비전 등의 다양한 분야에 활용되고 있다.

CNN은 Fig. 4 에서 보는 바와 같이 컨볼루션 계층과 풀링 계층으로 구성되어 있으며 이 두 계층을 어떠한 방식으로 얼마나 연결하느냐에 따라 성능이 차이날 수 있고 해결 할 수 있는 문제도 달라질 수 있다. 여기서 컨볼루션 계층은 합성곱 연산으로 이미지를 변환시키는 역할을 하며, 풀링 계층은 Fig. 5 에 나타난 방식과 같이 2차원 평면 행렬에서 지정된 영역의 입력 이미지를 구획을 나누어 필터 크기만큼의 영역에서 최대값 혹은 평균값을 추출하여 하나의 대푯값으로 압축하는 과정을 거쳐 다음 노드의 입력값으로 넘겨주게 된다. 또한 하나의 값으로 압축하는 과정에서 가중치와 편향을 적용하게 된다. 컨볼루션 과정과 풀링 과정을 거친 이미지는 마지막으로 Fully connection 계층을 거쳐 소프트맥스(Softmax)함수를 통해 각각의 이미지의 분류를 판별하게 된다.




Fig. 4 Basic structure of CNN




Fig. 5 Pooling method

3.3 Inception V3을 이용한 CNN 구축

딥러닝은 이미 훈련과정을 거친 학습된 모델을 재사용하여 다른 영역의 데이터를 추가로 학습시키는 전이학습이 가능하다.(Esteva et. al, 2017) 매번 새로운 유형의 데이터를 처음부터 학습시켜 신경망의 가중치와 편향을 조정하는 것보다 전이 학습을 통해 기존의 모델의 구조와 파라미터를 사용하면 학습 속도가 빨라질 수 있고 최종 모델의 성능이 높아질 수 있다. 본 연구에서는 ILSVRC(ImageNet Large Scale Visual Recognition Competition)를 위해 ImageNet이 보유한 1,000여 종류의 이미지를 구분 할 수 있도록 학습된 Pre-trained Inception V3으로 구성된 GoogLeNet모델을 사용하였다. 따라서 마지막 분류 레이어의 전이학습을 통해 모델을 새로이 구축하여 사전 학습된 신경망에 역전파(backpropagation)를 통해 가중치와 편향을 미세조정(fine-tuning)할 수 있도록 하였다. 따라서 기존 Inception 모델의 마지막 1,000개의 분류 레이어를 전이학습을 통해 정상과 결함으로 나뉜 2개의 출력을 가지는 레이어로 구성함으로써 용접의 정상/불량을 구분 할 수 있는 모델로 재구축하였다.

GoogLeNet은 컨볼루션 계층과 풀링 계층으로 구성된 Fig. 6의 Inception 모듈을 무수히 쌓아 구성된 신경망으로 동일한 Inception 모듈 내부의 레이어에서 서로 다른 크기를 가진 컨볼루션 계층을 적용하여 다른 크기의 배열을 가지는 Feature map을 생성하도록 구성되었다. 또한 1x1 컨볼루션을 사용하여 데이터의 차원을 줄여 Inception 모듈이 연결되었을 때 늘어나는 연산량을 줄일 수 있도록 하였다.(Szegedy et. al, 2015)




Fig. 6 Inception module

또한 인공 신경망 학습을 위해 GoogLeNet모델의 Bottleneck 텐서 크기를 2048, 학습 속도를 0.01로 설정하였다. 이 과정에서 이미지의 좌우 반전 또는 임의의 크롭과 같은 변형은 수행하지 않았다.

3.4 Tensorboard를 활용한 매개변수 조정

Tensorflow는 학습과정에서 일정시간마다 텐서 값과 계산 로그를 그래프로 시각화하여 보여주는 도구인 Tensorboard를 지원한다. 이를 통해 학습의 진행에 따라 오차와 정답률의 시각화된 경향을 자세히 확인 할 수 있으므로 매개변수를 조절하여 신경망을 튜닝하거나 학습결과를 검토 할 수 있다. 따라서 본 연구

에서도 신경망 학습과정 중 Tensorboard를 확인하며 반복 학습 횟수(training step) 및 학습속도(learning rate) 등의 매개변수를 조정하며 학습 데이터를 어떻게 가공 할 것인지 참고하였다.

3.5 손실 함수

예상값과 실제 출력 값 사이의 오차를 계산하기 위한 방법에는 평균제곱오차(Mean Square Error; MSE)나 유클리드 제곱거리 등의 방법을 사용하고 있으나 인공지능망 모델링을 활용한 분야에서는 이러한 차이를 손실함수(cost function)로 정의하고 있다. 본 연구에서는 이러한 손실함수로 교차 엔트로피(cross entropy)를 사용하였다. 교차 엔트로피는 식 1과 같이 계산 될 수 있다.

$$-\sum_i y_i' \log(y_i) \quad (1)$$

여기서 y_i 는 분류를 위한 라벨값으로 one-hot vector로 주어진다. y_i' 는 라벨을 추가한 학습시킨 학습 데이터 셋으로부터 얻은 신경망 학습결과를 의미한다. 일반적으로 분류문제에서 평균 제곱 오차의 경우 단순히 분류가 틀린 개수에 대한 결과 값만을 나타낼 뿐 학습데이터에 부여된 라벨과 비교하여 얼마나 잘못 예측했는지, 분류결과를 얼마나 신뢰 할 수 있는지에 대한 정보를 제공하진 않는다. 교차 엔트로피는 신경망이 출력한 분류문제의 오차에 신경망이 추정한 분류결과 신뢰성(confidence)을 고려하여 종합적 관점에서 신경망의 학습결과를 평가 할 수 있다.

4. 데이터 가공과 신경망 학습

4.1 학습 데이터 가공

우선 용접공정 중 전압 센서, 전류 센서 및 압력 센서를 사용하여 전압, 전류, 가압력의 데이터를 얻었으며, 동저항은 공급 전력의 1주기 동안 센서의 샘플링주기에 따라 전압의 전류 및 순간 값을 음의 법칙에 따라 연산함으로써 계산되었다.

상기의 측정과정을 통해 너트 프로젝션 용접의 경우 총 66개의 용접 데이터를 획득하였으며, 이 중 정상 용접데이터는 30개, 불량 용접데이터는 36개로 구성되어 있다. 취득한 데이터는 일반적으로 학습을 위한 데이터셋과 학습 결과를 검증하기 위한 테스트셋으로 분류하여 사용 된다. 본 논문에서는 학습 데이터셋으로서 80%인 53개를 지정하고 나머지 20%인 13개를 테스트 데이터셋으로 구성하였다. 또한 End plug 업셋 용접의 경우 총 258개의 용접데이터를 확보하였다. 이 중 정상 용접데이터는 31개, 불량 용접데이터는 227개로 앞선 프로젝션 용접과 마찬가지로 20%를 테스트셋으로 남겨두기 위해 학습 데이터셋으로 202개, 테스트셋 56개로 구성하였으며 두 가지 용접 데이터에 대한 특징을 Table 1에 정리하였다.

본 연구에서는 저항용접의 공정변수 전압과 전류를 실시간으로

측정 하였으며, 전압과 전류를 이용하여 동저항을 계산 하였다. 일반적으로 저항용접의 경우 용접의 진행 과정 분석을 위해서 전압이나 전류보다는 동저항의 변화를 참고 한다. 따라서 본 연구에서는

Table 1 Comparison of weld data

	Projection	Upset
Object	Nut	Tube, End plug
Sampling rate	3,000Hz	48,000Hz
Cycle	60ms	16.6ms
Data points	9,504	180,600
Training data	53	202
Testing data	13	56




Fig. 7 Current, voltage and dynamic resistance of nut projection welding




Fig. 8 Current, voltage and dynamic resistance of upset welding

동저항 계산 결과를 python의 matplotlib 라이브러리를 활용하여 그래프 이미지로 시각화 하였다. 그리고 각 이미지에 정상과 결함으로 라벨을 지정해 주어 신경망이 이미지의 패턴을 인식 할 수 있도록 하였다. Fig. 7과 Fig. 8은 각각 너트 프로젝션 용접과 업셋 용접시 측정한 전압 과 전류, 그리고 이를 이용하여 계산한 동저항의 패턴을 보여주고 있다.

앞서 설명한 바와 같이 이미지학습을 위해서 동저항을 계산하여 이미지로 변환하고, 정상과 결함으로 라벨을 지정 하였다. Fig. 9는 너트 프로젝션 용접의 이미지 학습용 데이터 중 일부를, Fig. 10은 업셋용접의 이미지 학습용 데이터 중 일부를 보여주고 있다.




Fig. 9 Patterns of dynamic resistance of nut projection welding for image learning




Fig. 10 Patterns of dynamic resistance of upset welding for image learning

4.2 신경망 학습 및 예측 결과

우선 너트 프로젝션 용접에 대해서 학습 데이터셋을 이용하여 학습을 진행 하였다. Fig. 11을 보면 테스트셋에 대한 용접 품질 예측 정확도가 0.9 근처에서 수렴하는 것을 알 수 있다. 또한 Fig. 12과 같이 학습이 진행됨에도 불구하고 손실함수값이 교차 엔트로피가 0.45이하로 줄어들지 않았다. 반면 업셋 용접의 경우에는 학습 데이터셋에 대한 정확도가 Fig. 13에 나타난 바와 같이 0.98 부근까지 지속적으로 증가하면서 신경망이 데이터셋을 제대로 학습하고 있는 것을 볼 수 있다. 그리고 Fig. 14에 나타난 바와 같이 교차 엔트로피 값이 약 0.1까지 낮아졌다.

결과적으로 너트 프로젝션 용접은 800회 이상 학습을 수행할 경우 과적합 현상이 나타났으며 예측 정확도는 최대 약 0.9 부근에서 정지 하였다. 업셋 용접에서는 10,000회까지 안정적으로 학습을 수행하여 예측 정확도가 98%로 수렴 하였으며, 과적합이 발생하지 않았다.




Fig. 11 Training set accuracy of projection welding




Fig. 12 Validation cross entropy of projection welding




Fig. 13 Training set accuracy of upset welding




Fig. 14 Validation cross entropy of upset welding

5. 결 론

본 연구에서는 프로젝션 용접과 업셋 용접에서 발생하는 용접 전압 전류를 계측한 뒤, 이를 동저항 패턴으로 변경하고 해당 패턴을 컨볼루션 신경망에 학습 시켜 용접의 정상/불량을 판별할 수 있는 방법론을 제시 하였다. 프로젝션 용접의 경우에는 총 66세트의 동저항 패턴을 학습하는데 사용 하였으며, 약 90%의 정확도로 정상/불량 용접을 판별하였다. 업셋 용접의 경우에는 총 258세트의 동저항 패턴을 학습하는데 사용 하였으며, 98%의 정확도로 정상/불량 용접을 판별하였다. 본 연구를 통해 인공 신경망의 이미지 인식 기술을 적용하면 용접 데이터의 이미지 속 패턴을 활용해 용접성을 예측하는 것이 가능하다는 결과를 확인할 수 있었다.

다만 본 연구에서는 최대 98%의 정확도로 불량을 판별 할 수 있었으나, 이는 실험실 수준에서 확보한 데이터에 대한 판별 정확도이며 현장에서 실제 계측되는 데이터를 적용하면 정확도는 이보다 떨어질 것으로 예상된다. 그리고 98% 수준의 정확도로는 현장에 적용하여 실제 업무에 활용하기에는 무리가 있다.

위의 한계를 극복하기 위해서는 다음과 같은 추가 연구가 필요하다.

- 보다 많은 수의 동저항 데이터의 확보 및 분석
- 신경망 학습 시 동저항 뿐 아니라 가압력, 통전시간 등 용접에서 발생하는 다른 용접 변수에 대한 고려
- 실험 데이터 이외에 현장에서 발생하는 데이터의 확보 및 테스트

또한 향후에는 신경망 모델을 활용하여 저항용접 뿐만 아니라 조선분야에 사용되고 있는 다양한 용접 프로세스에 대해 장기간에 걸쳐 수집된 용접 데이터를 확보하여 분석할 예정이다.

후 기

본 논문은 해양수산부 해양장비개발 및 인프라 구축사업인 “해양플랜트 플리트오버 및 복수크레인 설치설계 핵심기술개발” 과제의 연구결과 중 일부임을 밝힙니다.

References

- Cho, Y., Rhee, S., & Um, K.W., 1998. A study of real-time weldability estimation of resistance spot welding using fuzzy algorithm. *Journal of Welding and Joining*, 16(5), pp.76–84.
- Esteva, A., Kuprel, B., Novoa, B.A., Ko, J., Swetter, S.M., Blau, H.M. & Thrun, S., 2017. *Nature*, 542, pp.115–118.
- Hwang, D.S. & Gho, M.H., 2012. Development and application of realtime weld quality monitoring system. *Journal of Welding and Joining*, 30(1), pp.44–50.
- Hwang, I.S., Yoon, H.S., Kim, Y.M., Kim, D.C., Kang, M.J., 2017, Prediction of irregular condition of resistance spot welding process using artificial neural network, *Proceedings of 2017 Fall Conference of Society for The Korean Welding & Joining Society*, November 2017.
- Inception, 2019, <https://github.com/google/inception> [Accessed 04 January 2019].
- Kim, G.C., 2008, Welding and joining manual. *Journal of Welding and Joining*.
- Lee, J.H., 2013, *Materials and Welding*, The 21st Century History of Book Publishing.
- Matplotlib development team, 2019, <https://matplotlib.org/> [Accessed 04 January 2019].
- Monitec. Co. Ltd, 2018, Weld Quality Monitoring System, URL: <http://www.monitech.co.kr> [Accessed 04 January 2019].
- Szegedy, C., Liu, S., Jia Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. & Rabinovich, A., 2015, *Going deeper with convolutions*, Institute of Electrical and Electronics Engineers Conference on Computer Vision and Pattern Recognition, Boston, MA, pp.1–9.
- TensorFlow 2.0 Beta, 2019, <https://www.tensorflow.org/hub> [Accessed 04 January 2019].
- Woo, C.K. & Rhee, Z.K., 2014. Quality assurance of the resistance spot-welding using acoustic emission raw signals classification. *Journal of Korean Society of Mechanical Technology*, 16(2), pp.1357–1363.
- Yoon, H.S., 2017. *Quality estimation of resistance spot welding using adaptive resonance theory Artificial neural network*. Master's Degree Dissertation, Inha University of Engineering.



강 지 훈

구 남 국