

Copper Filter Dryer 품질보증을 위한 결함 검출 및 원인 분석⁺

(Defect Detection and Cause Analysis for Copper Filter Dryer Quality Assurance)

오 석 민¹⁾, 박 진 제²⁾, 다 어 반 권³⁾, 장 병 호⁴⁾, 김 흥 재⁵⁾, 김 창 순^{6)*}

(SeokMin Oh, JinJe Park, Van-Quan Dao, ByungHo Jang, HeungJae Kim, and ChangSoon Kim)

요 약 Copper Filter Dryer(CFD)는 냉동 및 냉방 시스템에서 냉매의 순환 시 불순물을 제거하여 깨끗한 냉매를 유지하는 역할을 하며, CFD의 결함은 냉동 및 냉방 시스템의 누수, 수명 저하 등 제품의 결함으로 이어질 수 있어 품질보증이 필수적이다. 기존에는 품질 검사 단계에서 작업자가 검사하고 결함을 판단하는 방법이 주로 사용되었으나, 이러한 방법은 주관적으로 판단하기 때문에 정확하지 못하다. 본 논문에서는 CFD 축관 및 용접 공정 과정에서 발생하는 결함을 검출하고 기존의 품질 검사를 대체하기 위해 YOLOv7 객체 감지 알고리즘을 사용하여 결함을 검출했고, F1-Score 0.954, 0.895의 검출 성능을 확인하였다. 또한, 결함 이미지의 Timestamp에 해당하는 센서 데이터 분석을 통해 용접 과정 중 발생하는 결함의 원인을 분석하였다. 본 논문은 CFD 공정 중 발생하는 결함을 검출하고 원인을 분석함으로써 제조 품질보증과 개선 방안을 제시한다.

핵심주제어: 딥러닝, 컴퓨터 비전, YOLOv7, 데이터 분석

Abstract Copper Filter Dryer (CFD) are responsible for removing impurities from the circulation of refrigerant in refrigeration and cooling systems to maintain clean refrigerant, and defects in CFD can lead to product defects such as leakage and reduced lifespan in refrigeration and cooling systems, making quality assurance essential. In the quality inspection stage, human inspection and defect judgment methods are traditionally used, but these methods are subjective and inaccurate. In this paper, YOLOv7 object detection algorithm was used to detect defects occurring during the CFD Shaft pipe and welding process to replace the existing quality inspection, and the detection performance of F1-Score 0.954 and 0.895 was confirmed. In addition, the cause of defects occurring during the welding process was analyzed by analyzing the sensor data corresponding to the Timestamp of the defect image. This paper proposes a method for manufacturing quality assurance and improvement by detecting defects that occur during CFD process and analyzing their causes.

Keywords: Deep Learning, Computer Vision, YOLOv7, Data Analysis

* Corresponding Author: ee.cskim@big-ai.kr

+ 이 논문은 2023년 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(재단 과제관리번호: 2021RIS-003)

Manuscript received January 23, 2024 / revised February 05, 2024 / accepted February 07, 2024

1) ㈜빅아이 빅데이터개발팀, 제1저자

2) ㈜빅아이 기업부설연구소, 제2저자

3) ㈜빅아이 기업부설연구소, 제2저자

4) ㈜빅아이, 제2저자

5) ㈜에스디이엔티 기업부설연구소, 제2저자

6) ㈜빅아이 기업부설연구소, 교신저자

1. 서론

Cooper Filter Dryer(CFD)는 냉동 및 냉방 시스템에서 냉매의 순환 시 습기, 먼지 및 기타 불순물을 제거하여 시스템 내의 깨끗한 냉매 유지를 도와주는 역할을 한다. 이를 통해 냉동 및 냉방 시스템의 성능과 효율성을 향상하며, 시스템의 수명을 연장할 수 있다.

CFD 제조 공정은 Fig. 1과 같이 1차 축관 공정, 2차 축관 공정, 용접 공정 순으로 진행된다. 축관 공정에서는 원재료인 구리관을 절단 및 용접하여 축관을 형성하고 축관의 표면을 정밀하게 가공한다. CFD 형상은 Fig. 2와 같다. 용접 공정에서 Filter Dryer의 냉매 순환을 위한 구리관 용접을 수행한다. 이러한 3단계로 구성된 공정을 거치면서 축관 결함, 과용접, 부족용접과 같은 다양한 결함이 발생한다. 이러한 결함은 단순한 표면적 문제뿐만 아니라 냉동 및 에어컨 등 전자제품의 결함으로 이어질 수 있다 (Campbell, F. C., 2013).




Fig. 1 Process of the CFD manufacturing




Fig. 2 CFD Shape

따라서, CFD 제조 공정 단계에서 생산된 부품에 대한 품질보증은 필수적이다. 기존에는 작업자가 육안으로 직접 검사하고 판단하는 방법이 주로 사용되었지만, 이러한 방법은 공정 중 제품에 발생한 미세한 결함을 작업자의 주관적 판단으로 검출함으로써 판단의 오류가 발생할 가능성이 있다. 또한, 결함의 복잡성이 증가함에

따라 검사의 정확도는 감소한다(See, J. E., 2015; Sundaram, Sarvesh, and Abe Zeid., 2023).

본 논문에서는 CFD 공정 과정에서 발생하는 결함을 검출하기 위해 합성곱 신경망 기반 대표적인 객체 감지 알고리즘인 YOLOv7(You Only Look Once Version 7)을 활용한다. YOLO 알고리즘은 대표적인 One-stage detector 모델로써, 2단계로 감지하는 Two-stage detector 모델 대비 정확도는 낮지만, 빠른 속도를 보여준다.

YOLOv7 객체 감지 모델 학습을 위해 축관 공정과 용접 공정에서 수집된 이미지를 회전하는 Rotation 기법을 사용하여 데이터 증강하였고, 밝기와 대비를 일정하게 조정하는 Gray scaling 기법을 사용하여 이미지 데이터를 정규화하여 데이터 세트를 구축하여 모델 학습하였다.

축관 공정 학습 모델은 F1-Score 0.967와 0.956의 mAP@0.5를 달성했고, 용접 공정 학습 모델은 F1-Score 0.921, 0.985의 mAP@0.5로 높은 모델 학습 성능 결과를 달성했다. 또한, 축관과 용접 공정에서의 실제 정상 및 결함 검출과 분류에 있어 축관 공정은 F1-Score 0.954의 검출 성능을 달성했고, 용접 공정 F1-Score 0.895의 검출 성능을 달성하였으며, 이미지 데이터 한 건을 검출하고 처리되는 시간은 평균 4.598 초로 빠르게 정상과 결함을 검출 및 분류하고 품질 검사를 진행함을 확인하였다. 이를 통해 CFD 제조 공정 과정에서 발생하는 결함을 검출 및 분류하여 정확하고 효율적인 품질 검사 시스템 방안을 제시한다.

공정 과정에서 발생하는 외관 결함에 대한 검출이 품질 검사 및 검수 시스템에 있어 큰 도움이 되지만 공정의 근본적인 문제나 결함의 원인이 되는 인자들을 알 수 없어 품질 개선이 힘들다. 이 논문에서는 결함 검출 결과와 통합하여 공정에서 수집되고 있는 센서 데이터를 이용하여 가장 높은 빈도로 발생하는 과용접, 부족용접 결함과 전류, 전압 데이터의 상관관계 분석을 통해 공정 단계에서 결함이 발생하는 원인을 밝혀내고 공정 생산성 향상과 품질 개선을 위한 방안을 함께 제시한다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 CFD 결함 검출에 사용한 객체 감지 알고리

증인 YOLOv7 구조와 설명, 선정 이유를 설명한다. 3장에서는 데이터 증강 및 전처리를 포함한 데이터 세트 구축, 4장에서는 모델 학습 및 성능 평가 내용을 기술하였다. 5장에서는 축관 및 용접 공정에서의 결함 검출과 검출 성능에 대해 기술하였으며, 6장에서는 센서 데이터를 통한 상관관계 분석과 결함 원인 분석에 대해 기술하였다. 마지막으로 7장에서는 결론과 향후 연구 방향을 제시하였다. 이미지 수집 및 가공, 모델 학습 후 실제 결함 검출 시스템 구축과 결함 원인 분석을 위한 본 연구의 전체적인 순서도와 프로세스를 Fig. 3에 나타내었다.

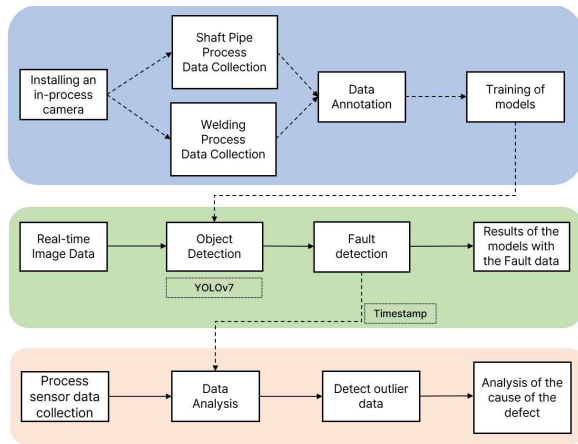


Fig. 3 In This Study Design Process

2. 결함 검출 알고리즘 설계

2.1 객체 감지 알고리즘 구조

공정 과정에서 CFD의 축관 및 용접 시 발생하는 다양한 유형의 결함을 감지하기 위해 convolution neural network (CNN) 기반 알고리즘인 YOLO를 사용했다. YOLO 알고리즘은 ‘You Only Look Once’의 약자로 대표적인 One-stage detector 모델이다. 이미지를 한 번만 보고 convolution 층의 grid cell 별로 물체가 있을 확률과 해당 grid cell이 어떤 클래스일지 확률 계산하며 객체를 감지하는 방법이다 (Moon-Seok Jeon., et al., 2023).

YOLO는 2016년 YOLOv1이 처음 출시된 이후 YOLOv8까지 8개의 버전이 출시되었고, 그 중 Fig. 4와 같이 정확도와 성능이 우위에 있는 YOLOv7 알고리즘을 활용하였다. YOLOv7 네트워크 아키텍처 구조는 Backbone, Neck, Head로 구성된다. Backbone은 이미지에서 객체의 특징을 추출하는 역할을 하고, Neck은 Backbone에서 추출한 특징을 이미지의 다양한 크기의 객체를 감지할 수 있도록 조정하는 역할을 한다. Head는 Neck에서 조정된 특징을 사용하여 객체의 위치와 클래스를 예측하는 역할을 한다. YOLOv7 알고리즘은 ResNet50을 Backbone으로 사용하여 풍부한 특징을 추출하고, FPN과 BiFPN을 사용하여 객체의 위치와 클래스를 정교하게 예측하여 높은 정확도를 보여준다. 전체적인 네트워크 아키텍처 구조는 Fig. 5와 같다(Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M., 2023).




Fig. 4 Comparison of YOLO-v7 and other object detectors (Hussain, 2023)

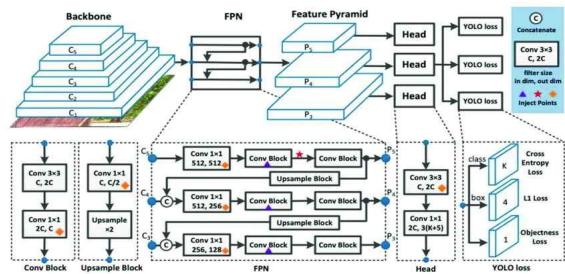


Fig. 5 YOLOv7 network architecture(Kaya, Ömer et al., 2023)

2.2 알고리즘 비교

One-stage detector 대표 모델인 YOLO는 Faster R-CNN, Mask R-CNN 등 2단계로 감지하는 Two-stage detector 대비 정확도는 낮지만, 빠른 속도를 보여준다(P. Soviany and R. T. Ionescu, 2018). 실제 공정 데이터 세트를 사용하여 YOLO 모델과 Two-stage detector 대표 모델인 Faster R-CNN 모델을 동일한 환경(RTX 3060 Ti)에서 비교하였고, 그 결과는 Table 1과 같다. YOLOv7 모델은 mAP 0.956, FPS 45로 높은 정확도와 초당 45 프레임을 처리하는 빠른 처리 속도를 확인했다. Faster R-CNN은 mAP 0.959, FPS 13으로 정확도는 YOLOv7 모델과 비슷하였으나, 처리 속도 성능에서 큰 차이가 나는 것을 확인했다. CFD 제조 공정은 자동화 공정으로써 빠른 공정 속도를 가지고 있으며, 공정이 완료된 후 품질 검사 단계에서 허용되는 최대 소요 시간은 11초 이내이다. 그러므로 결함 검출을 정확하게 하는 것도 중요하지만, 빠르게 검출할 수 있어야 한다. 이런 이유로 실시간 객체 감지와 빠른 처리가 가능하고 높은 속도와 효율성을 가져 실제 생산 공정에 적용하기 적합한 대표적인 객체 감지 알고리즘인 YOLO를 사용한다.

Table 1 Trade-off between YOLOv7 and Faster R-CNN performance

model	mAP@0.5	FPS
YOLOv7	0.956	45
Faster R-CNN	0.959	13

3. Data set

3.1 데이터 증강 및 전처리

축관 공정에서 발생하는 결함은 주로 균열, 부식, 기포 등이고 용접 공정에서 주로 발생하는 결함은 과용접, 부족용접으로 공정 과정에서

결함이 발생하는 특성이 달라 따로 분류하여 검출해야 한다. 축관과 용접 각 공정 완료 지점에 비전 카메라를 설치하여 이미지 데이터를 수집하였고, 이 과정에서 다양한 유형의 결함 이미지 데이터를 확보하여 YOLOv7 모델 학습을 위한 데이터 세트를 구축하였다.

데이터 증강은 일반적으로 학습 데이터 세트의 크기와 다양성을 보장하기 위해 사용된다. 데이터 세트가 제한적이거나 불균형한 경우, 데이터 증강을 사용하면 모델의 학습 안정화와 성능을 향상할 수 있다(K., Nanthini. et al., 2023). 정상 이미지 데이터에 비해 결함 이미지 데이터의 수량이 적어 생기는 데이터 불균형 문제를 방지하기 위해 이미지를 회전하는 Rotation 기법을 사용하여 데이터 증강하였다. 수집된 원본 이미지의 color 3채널(RGB) 이미지를 사용하고 각 채널을 정규화하여 실험하였으나, 분류의 정확도는 크게 향상되지 않았지만, 처리 속도는 상당히 감소하였다. 데이터 세트의 이미지에서 색상 정보가 분류에 중요한 역할을 하지 않는 것을 확인하였고, 이런 이유로 실시간 처리 속도를 향상하기 위해 밝기와 대비를 일정하게 조정하는 Gray scaling 기법을 사용하여 이미지 데이터를 정규화하였다. 이미지 라벨링 툴을 사용하여 정상과 결함을 Bounding Boxing 방식으로 라벨링 하였다(Jiyeon Yim et al., 2021). 축관 공정은 시료 없음(Empty), 정상(Normal), 결함(Error)으로 Fig. 6과 같이 데이터 세트를 구축하였고, 용접 공정은 정상(Normal), 시료 없음(Empty), 과용접(Over), 부족용접(Under)으로 4



Fig. 6 Dataset of the shaft pipe process




Fig. 7 Dataset of the welding process

가지 classes로 설정하여 Fig. 7과 같이 학습 데이터 세트를 구축하였다.

데이터 정규화를 포함한 증강 과정을 거친 후 data split을 위해 Python 머신러닝 라이브러리인 Scikit-learn을 사용하여 training set:validation set:testing set을 8:1:1 비율로 분할하였다. 모델을 학습할 때 주어진 데이터 시트를 사용하여 학습하기 때문에 data split을 하지 않으면 새로운 데이터에 대해서는 제대로 예측하지 못하는 문제가 발생할 수 있으므로, 모델의 성능을 객관적으로 평가하기 위해 data split 후 모델 학습에 사용하였다. 학습에 사용한 축관 공정 데이터 세트는 총 2,580건으로 Table 2에 나타낸 바와 같고, 용접 공정 데이터 세트는 총 4,000건으로 Table 3에 나타낸 바와 같다. 데이터의 양보다 품질이 뛰어난 라벨링 데이터로 데이터 세트를 구성하였고, 클래스별 데이터 세트의 균형 유지를 위해 학습용 데이터 세트 개수를 선정하였다.

Table 2 Dataset structure of the shaft pipe process

	Normal	Empty	Error	Total
Train	688	688	688	2,064
Validation	86	86	86	258
Test	86	86	86	258
Total	860	860	860	2,580

Table 3 Dataset structure of the welding process

	Normal	Empty	Over	Under	Total
Train	800	800	800	800	3,200
Validation	100	100	100	100	400
Test	100	100	100	100	400
Total	1,000	1,000	1,000	1,000	4,000

4. 모델 학습

4.1 학습 하이퍼파라미터

모델 학습 과정에서는 Table 4에 나타낸 바

와 같이 학습 하이퍼파라미터를 조정 하였으며, 학습에 사용한 환경은 'GTX 3060 Ti'로 GPU 메모리 문제를 방지하기 위해 Batch size를 다음과 같이 설정하였다.

Table 4 Hyperparameters of the trained models

	Batch size	Epoch	learning -rate start	learning -rate end
Shaft pipe process Dataset	2	300	0.01	0.1
Welding process Dataset	2	300	0.01	0.1

4.2 모델 학습 결과

학습된 모델의 성능은 정밀도(precision), 재현율(recall), F1 점수(F1-Score), 평균정밀도(mAP, mean Average Precision)를 사용하여 평가했다. 정밀도는 모델이 수행한 감지 횟수 대비 검출 비율을 계산하게 된다. 계산식은 (1)과 같으며, 정밀도 값이 높을수록 객체 감지 시 오탐률이 낮아지고 정확도가 높아진다. 재현율은 모델이 이미지에서 객체의 모든 객체를 감지하는 능력을 측정한다. 계산식은 (2)와 같으며, 재현율 값이 높을수록 모델이 객체를 놓치지 않고 모두 검출할 수 있다는 것을 의미한다. F1 Score는 정밀도와 재현율의 조화 평균으로, 값이 높을수록 모델의 정확성이 높음을 뜻한다. 평균 정밀도는 각 클래스의 평균 정밀도를 계산하여 얻는 지표이고, mAP@0.5는 IoU(Intersection over Union) 값이 0.5 이상인 경우의 평균 정밀도를 의미하므로, 모델이 실제 객체를 잘 검출할 뿐만 아니라, 검출한 객체의 위치도 정확하게 예측할 수 있는지 평가하는 지표라고 할 수 있다. 계산식은 (4)에 나타내었다. 이러한 지표들은 모델의 정확도, 감지율 등 다양한 조건에서 객체 감지를 할 수 있는 능력을 평가한다(Z. Haimer et al., 2023).

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1-Score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

축관 공정 데이터 세트의 학습 결과 Table 5에 나타낸 바와 같이 정밀도 0.953, 재현율 0.981로 F1-Score 0.967의 높은 성능을 달성하였고, mAP@0.5 역시 0.956로 전체적으로 높은 학습 성능을 확인하였다. 용접 공정 데이터 세트의 학습 결과는 Table 6에 나타내었으며, 정밀도 0.985, 재현율 0.866, F1-Score 0.921, mAP@0.5는 0.985로 높은 학습 정확도를 확인하였다.

Table 5 Training performance of Shaft pipe Dataset

Indices	Values
Precision	0.953
Recall	0.981
F1-Score	0.967
mAP@0.5	0.956

Table 6 Training performance of Welding Dataset

Indices	Values
Precision	0.985
Recall	0.866
F1-Score	0.921
mAP@0.5	0.985

5. 결함 검출

5.1 결함 검출 결과

본 연구에서 제안한 결함 검출 시스템의 주요 목적은 제조사에서 작업자의 육안으로 검사 및 판단하는 품질 검사 방법을 대체하는 것이며, 이를 위해선 결함 검출 모델의 전체적인 정확도가 높아야 한다. 이런 이유로 모델을 주요 성능 지표인 F1-Score 사용하여 평가하였다. 축관 공정에서 발생하는 정상과 시료 없음, 균열이나 부식 등 축관 결함 이미지 데이터 30건씩 총 90건의 테스트 이미지를 사용했고 F1-Score 95.4%의 검출 정확도를 달성하였다. 용접 공정에서는 정상 이미지 데이터, 시료 없음 이미지 데이터, 과용접 이미지 데이터, 부족용접 이미지 데이터 각각 25건씩 총 100건 테스트 이미지를 사용하여 측정 결과 F1-Score 89.5%의 검출 정확도 달성하였다. 검출 예측 정확도에 대한 성능 측정 결과는 Table 7에 나타내었다.

용접 공정의 검출 정확도는 축관 공정보다 상대적으로 낮은 이유는 용접 공정에서 발생하는 결함은 Fig. 8과 같이 외관적으로 다른 복잡한 형태를 가지고 있으며, 종종 복합적으로 발생하기 때문에 이러한 다양한 유형의 결함을 데이터 세트에 반영하지 못한 것이 검출 정확도가 낮은 원인으로 보인다. 특히, 재현율이 낮은 것은 모델이 편향적이거나 불균형함을 의미한다. 이는 향후 연구에서 축관과 용접 공정에서 다양한 결함을 포함하는 확장된 데이터 세트를 구축 및 학습하고 모델 학습 전략 및 아키텍처를 개선하거나 미세 조정(fine-tuning)함으로써 용접 공정의 검출 정확도를 향상할 수 있을 것으로 판단되며, 축관 공정의 경우 높은 검출 성능을 달성하였으며 검출이 되지 않은 일부 이미지 데이터를 분석한 결과, 미세한 결함의 경우 정확도가 낮아 검출하지 못함을 확인하였다. 데이터 세트가 크지 않기 때문에 추후 지속적인 데이터 세트 확장을 통해 더 높은 검출 정확도를 확보할 수 있을 것으로 판단된다.

품질 검사 속도 측면에서 이미지 데이터 한 건을 검출하고 처리 소요 시간은 평균 4.598초

로 최대 5초를 넘지 않았으며, 빠르게 정상과 결함을 검출 및 분류하고 품질 검사를 진행함을 확인하였다.

Table 7 Evaluate Fault Detection Performance

	Precision	Recall	F1-Score
Shaft pipe process	0.941	0.968	0.954
Welding process	0.909	0.882	0.895




Fig. 8 Complex weld defects

6. 결함 원인 분석

6.1 결함 원인 파악을 위한 설비 데이터 분석 방안

CFD 생산 공정 단계에서 빈번하게 발생하는 과용접과 부족용접 결함은 용접 공정 단계에서 전류, 전압의 공급이 높거나 낮을 때 발생한다. 앞서 제시한 이미지 데이터 기반 결함 검출 방안은 결함의 존재 여부를 판단하는 데에는 효과적이지만, 결함의 근본적인 원인을 파악하기에 한계가 있다. 결함의 발생원인 파악을 통해 결함 발생을 예방하거나 최소화하기 위한 조치를 취할 수 있어 품질 개선에 도움을 준다. 이러한 이유로 결함으로 판정된 부품의 이미지 데이터 기반 공정 설비의 센서 데이터 분석 및 결함의 원인 인자 분석을 통한 품질 개선 방안을 제시한다.

앞서 제시한 이미지 데이터 기반 결함 검출 모델을 통해 결함으로 검출된 부품 이미지의 Timestamp 활용하여 해당 생산 시간대의 공정 설비 센서 데이터를 수집한다. Timestamp는 이미지가 촬영된 시간 정보를 나타내는 값이다. 이러한 접근은 공정 시 수집된 설비의 전체 센서 데이터를 분석하는 것이 아닌 결함이 발생한 시간대의 데이터를 추출하여 확인함으로써 데이터를 효율적으로 분석할 수 있다.

용접 공정에서 수집하고 있는 설비 센서 데이터는 전류, 전압 데이터를 포함한 총 14개의 feature로 구성되어 있다. 데이터 상관관계 분석을 통해 변수 간의 선형 상관관계를 측정하여 상관계수가 높은 전류 설정값 데이터, 전압 설정값 데이터와 전류 실제값 데이터, 전류 실제값 데이터를 핵심 feature로 선정하였다. 전압, 전류 설정값 데이터는 용접 공정 설비에서 공정 단계에 필요한 전압, 전류의 값을 설정하는 데이터이고 전압, 전류 실제값 데이터는 용접 공정 설비에서 발생한 실제의 값 데이터이다.

6.2 설비 데이터 분석 결과

이미지 데이터 기반 결함 검출 모델을 통해 용접 공정에서 부족용접 결함이 ‘2024-01-09, 08:52:01’에 발생하였음을 확인하였고, 해당 시간대의 설비 센서 데이터를 확인하여 분석하였다. Fig. 8에 나타낸 바와 같이 공정 단계에서 요구하는 설비의 전류 설정값과 실제로 투입된 전류의 값은 63A로 동일하였으나, 전압 설정값 데이터와 전압 실제값 데이터가 큰 차이를 보이는 것을 확인하였다. 전압 설정값은 약 250V로 일반적인 공정 진행 상태와 같은 정상적인 수치인 반면, 전압 실제값은 약 120V로 설비에서 설정한 값보다 적게 들어왔음을 확인하였다.

동일하게 결함 검출 모델을 통해 과용접 결함이 ‘2024-01-09, 08:47:16’에 발생하였음을 확인하고 해당 시간대의 데이터를 분석하였다. Fig. 9와 전압 설정값은 250V, 전압 실제값은 246V로 큰 차이를 보이지 않는 일반적인 공정 진행 상황과 같은 데이터를 보였다. 전류의 설정값은 64A이지만 실제 투입된 전류의 값은

104A로 설정 전류 데이터보다 실제 전류가 과다하게 투입되었음을 확인하였다. 이는 전류 공급 장치의 오작동이나 오류로 인해 전류 출력량이 증가한 것이 결함의 원인이라고 판단된다.

위의 분석 결과를 통해 부족용접 결함의 경우 용접 공정 설비의 설정값보다 전압이 적게 들어오는 경우 발생함을 확인하였고, 과용접 결함의 경우 전류와 전압 설정값보다 전류가 과다하게 투입되는 경우 발생함을 확인하였다. 현장 공정 과정에서 발생한 결함 이미지 데이터와 수집된 센서 데이터를 활용하여 결함의 원인을 분석하였고, 현재 수집된 데이터에서 부족용접 결함에서 전류값에 따른 영향이나, 과용접 결함과 전압값의 상관관계는 확인되지 않았으나 지속적인 결함 데이터와 센서 데이터 수집 및 분석으로 추가적인 연구가 필요할 것으로 판단된다.

향후 연구에서는 다양한 결함에 대한 분석을 위해 결함의 종류에 따라 설비 데이터 분석 방법을 개발하여 결함의 발생 원인을 구체화하여 공정 생산성 향상과 CFD 제조 공정 과정의 품질 개선을 기대할 수 있을 것이다.

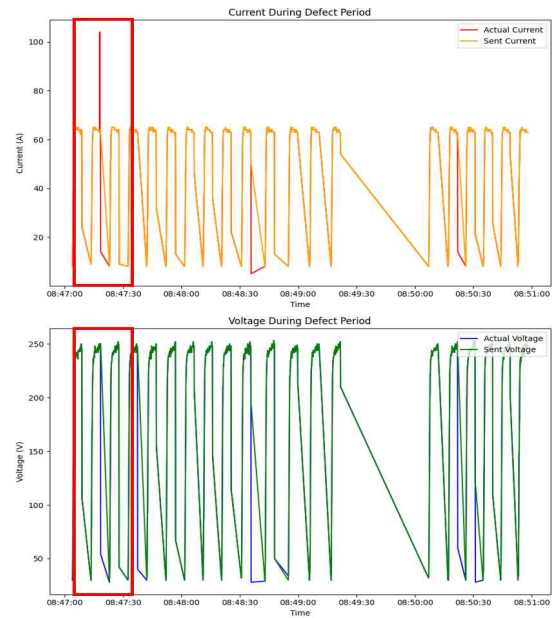


Fig. 10 Compare Current, Voltage Setpoint and Actual Value Data for Underweld Defects

7. 결론

본 논문에서는 CFD 제조 공정 과정에서 발생하는 외관 결함을 검출하고 원인을 분석하여 품질을 보증하는 방안을 제시하였다. 합성곱 신경망 기반 YOLOv7 객체 감지 모델을 사용하여 축관 및 용접 공정 간 정상과 결함 이미지 데이터를 학습하고 다양한 유형의 축관 결함과 용접 결함을 검출하고 분류하였다. 축관 공정에서는 F-1 Score 95%, 용접 공정에서는 F-1 Score 89%의 높은 검출 정확도를 확보하였다. 또한, 결함 검출 이미지의 Timestamp 정보를 통해 해당 시간대의 센서 데이터를 분석하였고 이를 통해 부족용접의 경우 용접 공정 설비의 설정값보다 전압이 적게 들어오는 경우 발생하고, 과용접 결함의 경우 전류 설정값보다 전류가 과다하게 투입되는 경우 발생함을 확인하였다.

이러한 연구 결과는 CFD 제조 공정 과정에서 발생하는 외관 결함을 효과적으로 검출하고 결함의 원인을 분석함으로써 제조 품질을 보증하는 데 기여할 것으로 기대된다.




Fig. 9 Compare current, voltage Setpoint and actual value data for Overweld defects

향후 연구에서는 다양한 크기와 유형의 이미지 데이터 세트를 확보하고 결합의 크기에 따라 모델의 receptive field를 조정하거나, 결합의 위치에 따라 모델의 attention mechanism을 적용하는 등의 방법을 통해 결합 검출 정확도를 향상하는 방안을 고려할 수 있을 것이다.


References

- Campbell, F. C. (Ed.). (2013). *Inspection of metals: understanding the basics*. ASM International.
- Hussain, M. (2023). YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. *Machines*, 677. <https://doi.org/10.3390/machines11070677>
- Jiyeon Yim, Seong-Oak Lee, Kyoung-Pyo Kim, & Yonggyun Yu. (2021). Application of object detection algorithm for psychological analysis of children's drawing. *Journal of Korea Society of Industrial Information Systems*, 26(5), 1-9.
- Kaya, Ömer & Çodur, Muhammed & Mustafaraj, Enea. (2023). Automatic Detection of Pedestrian Crosswalk with Faster R-CNN and YOLOv7. *Buildings*, 13, 1070. <https://doi.org/10.3390/buildings13041070>.
- K., Nanthini., D., Sivabalaselvamani., K., Chitra., S., Kavinkumar. (2023). A Survey on Data Augmentation Techniques. 913-920.
- Moon-Seok Jeon, Yeongtae Kim, Yuseok Jeong, Hyojun Bae, Chaewon Lee, Song Lim Kim, & Inchan Choi (2023). A Study on the Artificial Intelligence-Based Soybean Growth Analysis Method. *Journal of Korea Society of Industrial Information Systems*, 28(5), 1-14.
- P. Soviany and R. T. Ionescu. (2018). "Optimizing the Trade-Off between Single-Stage and Two-Stage Deep Object Detectors using Image Difficulty Prediction," 2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC), Timisoara, Romania, pp. 209-214.
- See, J. E. (2015). Visual Inspection Reliability for Precision Manufactured Parts. *Human Factors*, 57(8), 1427-1442. <https://doi.org/10.1177/0018720815602389>
- Sundaram, Sarvesh, and Abe Zeid. (2023). "Artificial Intelligence-Based Smart Quality Inspection for Manufacturing" *Micromachines* 14, no. 3: 570. <https://doi.org/10.3390/mi14030570>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2023). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*
- Z. Haimer, K. Mateur, Y. Farhan and A. A. Madi., (2023). "YOLO Algorithms Performance Comparison for Object Detection in Adverse Weather Conditions," 2023 3rd International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET), Mohammedia, Morocco, pp. 1-7.



오 석 민 (SeokMin Oh)

- 정회원
- (주)빅아이 빅데이터개발팀 선임연구원
- 관심분야: 딥러닝, 컴퓨터 비전, 데이터 분석



박 진 제 (JinJe Park)

- (주)빅아이 기업부설연구소 책임연구원
- 관심분야: 인공지능, 스마트 팩토리, 유지 보수



다 어 반 권 (Van-Quan Dao)

- (주)빅아이 기업부설연구소
수석연구원
- 관심분야: 인공지능, 스마트
팩토리, 에너지 관리 시스템



장 병 호 (ByungHo Jang)

- (주)빅아이 대표이사
- 관심분야: 인공지능, 스마트
팩토리, 에너지 관리 시스템



김 흥 재 (HeungJae Kim)

- (주)에스디이엔티 기업부설연
구소 연구소장
- 관심분야: 인공지능, 공정 지
능화, 제조 품질 관리



김 창 순 (ChangSoon Kim)

- 정회원
- (주)빅아이 기업부설연구소
연구소장
- 관심분야: 인공지능, 스마트
팩토리, 에너지 관리 시스템