

Camouflaged Object Detection 모델을 활용한 용접물 검출 성능 향상 연구

이지화^{1□}, 김혜원^{1□}, 이다현¹, 고병진², 윤종완^{3*}, 박태준^{4*}

¹한양대학교 일반대학원 인공지능융합학과, ²한양대학교 공학대학 스마트융합공학부 로봇융합전공,

³한양대학교 공학대학 지능형로봇학과, ⁴한양대학교 공학대학 로봇공학과

jongwanyoon@hanyang.ac.kr, taejoon@hanyang.ac.kr

Improving Performance of Weld Object Detection Using the Camouflaged Object Detection Model

Jihwa Lee, Dahyeon Lee, Hyewon Kim, Jong-Wan Yoon, Byungjin Ko, Taejoon Park

Hanyang Univ.

요약

제조 산업에서 용접 공정의 수요가 증가함에 따라 공정 자동화 연구가 활발히 진행되고 있으며, 작업대로부터 용접물을 분리하는 과정이 필수적이다. 본 논문은 Camouflaged Object Detection (COD) 모델을 활용해, 용접 환경에서 작업대와 유사한 얇은 plate 용접물을 효과적으로 검출하는 방법을 제안한다. 특히 용접물의 크기에 따라 ZoomNet 모델의 보조 스케일 값 조절을 통해 성능 향상을 보여줌으로써 보조 스케일 조절에 대한 가이드라인을 제시하였다. 이 연구는 COD 모델을 용접물 검출 분야에 적용하여 정확도를 높이는 동시에, 다양한 크기의 데이터 셋에 ZoomNet을 최적화할 수 있는 유용한 가이드라인을 제공한다.

I. 서론

건설, 기계, 자동차 등 다양한 분야의 제조업 및 산업 환경에서 알루미늄, 철과 같은 금속을 용접하는 작업이 필수적이다. 그러나 높은 열, 유해한 연기, 화상 등의 다양한 위험 요소로 인해 작업자의 안전을 위협할 수 있다. 이러한 환경에 자동화 시스템을 도입하면, 인력 부족 문제를 해결하고, 작업자의 안전을 보장하면서도 안정적인 생산을 유지할 수 있다.

이처럼 제조 산업에서 필수적인 용접 공정은 지속적으로 수요가 증가하고 있으며, 기술의 발전과 작업 효율을 위해 센서와 인공지능을 활용한 용접 공정의 자동화 연구가 활발하다. 특히, 비전 센서를 통해 용접할 부분을 검출하여 경로를 생성하는 연구가 많은 관심을 끌고 있다. 해당 연구에서는 비전 센서로 취득한 데이터 중 학습에 방해되는 배경을 제거하여 용접물에 해당하는 부분만을 활용하기 위해 작업대로부터 용접물을 분리하는 과정이 필요하다.

일반적인 사물을 검출할 때와 달리, 용접 환경에서 용접물과 작업대가 유사한 시각적 특징을 가지고 있는 경우에 용접물을 구분하기 어렵다. 특히, 얇은 plate 용접물과 같이 작업대와 높이 차이가 거의 없는 상황에서 고가의 고정밀 스캐너가 아닌 일반 RGB-D 센서를 사용한다면 센서 자체의 성능적 한계로 인해 3차원 정보를 활용한 구분 방식에 한계가 있다.

따라서 본 논문에서는 이미지 정보만으로, 배경과 유사한 객체를 식별하고 탐지하는 작업에 특화된 Camouflaged Object Detection (COD) 모델을 활용하여 얇은 plate를 검출하고자 한다. 특히 객체의 크기에 따른 보조 스케일 구성을 확인하고자 한다.

II. 본론

용접물과 용접 작업대의 표면의 색상과 질감이 유사한 경우, 이미지 상에서 용접물과 작업대를 명확히 구분하기 어려운 문제가 발생한다. 이는 특히 정확한 용접물의 위치를 파악해야 하는 용접 환경에서 큰 도전 과제이

다. 이러한 문제를 해결하기 위해, 배경과 유사한 객체를 효과적으로 식별할 수 있는 Segmentation 모델의 적용이 필요하다.

본 논문에서는 이와 같은 작업 환경에 특화된 Segmentation 모델인 COD 모델을 적용하여 작업대로부터 식별이 어려운 얇은 plate를 구분하는 것을 목표로 한다. 먼저 COD 모델을 사용하는 것이 적절한지 확인하기 위해 일반적인 Segmentation 모델과 COD 모델의 성능을 비교하였다. 그 중 가장 높은 성능을 보인 ZoomNet[1]을 기반으로 용접 작업물과 유사한 작업대를 가진 용접 환경에서 용접 작업물의 구분 성능을 높이하고자 한다.

ZoomNet은 원본 이미지와 함께 확대된 이미지와 축소된 이미지를 입력으로 사용하여 encoder에서 저수준(low-level) 및 고수준(high-level) 특징을 각각 추출한다. 각 스케일에서 추출된 특징은 하나로 통합되어 decoder를 통해 고해상도로 복원된다. 이러한 구조적 특징은 배경과 유사한 색상이나 질감을 가진 다양한 크기의 객체를 잘 탐지할 수 있게 해준다.

따라서, 이미지의 스케일에 따라 감지할 수 있는 객체의 크기가 달라진다는 점을 고려하여, 감지 대상 객체의 크기에 적합한 보조 스케일 값을 찾아내는 것이 중요하다. 이를 통해, 용접 환경에서 용접물의 위치에 상관없이 높은 정확도로 용접물을 검출할 수 있는 ZoomNet의 보조 스케일 구성을 제시하고자 한다.

III. 실험

실험에 사용한 데이터 셋은 배경과 유사한 용접물을 검출하기 위해 직접 구성된 데이터 셋으로, 데이터 수집에 사용한 카메라는 Realsense L515로 로봇 팔 엔드 이펙트 부근에 고정하여 취득하였다. 취득한 이미지의 해상도는 1280x720이다. 데이터 취득 시나리오는 크게 2가지이다. 첫 번째는 용접물과 동일한 재질이지만 중간중간 경계가 있어 용접물과 배경의 경계

를 찾기 어려운 분할 판재 배경 시나리오, 두 번째는 경계가 없는 철판 위에 용접물이 올려져 있는 단일 판재 배경 시나리오이다. 각 시나리오마다 용접물의 크기는 작은 것(150*50*3mm)과 큰 것(400*50*3 mm) 2가지로, 데이터 수는 동일한 비율로 구성했다. 데이터 셋은 총 680장으로 학습 데이터는 480장, 테스트 데이터는 200장을 사용했다. plate 크기 별 모델 최적화 학습 시에는 각각 학습 데이터는 240장, 테스트 데이터는 100장을 사용했다.




그림 1 분할 판재 배경에 큰 용접물이 올려진 경우(왼), 단일 판재 배경에 작은 용접물이 올려진 경우(오)

실험 과정에서 성능 지표로는 mean Intersection over Union (mIoU)를 사용했다. 각 실험에서 모델이나 조건에 따라 3회 반복 학습을 진행하였으며, 3회 결과값의 평균을 최종 결과값으로 도출하였다.

먼저 일반적인 Segmentation 모델과 COD 모델의 성능을 비교하였다. 일반 Segmentation 모델로는 Unet3+[2], DeepLabv3+[3], YOLOv8-seg[4], COD 모델로는 HitNet[5], PUENet-V[6], ZoomNet 모델로 실험하였다. 학습 데이터 셋으로 2가지 크기의 용접물의 데이터를 모두 사용하였다. 표 1을 통해 용접물 검출에서 일반 Segmentation 모델의 성능과 COD 모델의 성능이 명확한 차이가 있음을 확인할 수 있다. 이를 통해 용접 작업대와 용접물이 유사한 경우, 일반 Segmentation 모델이 아닌 COD 모델을 적용하는 것이 적합하다는 것을 확인하였다.

	Unet3+	DeepLabv3+	YOLOv8-seg	HitNet	PUENet-V	ZoomNet
mIoU	0.638	0.793	0.795	0.917	0.900	0.936

표 1 일반 Segmentation 모델과 COD 모델 성능 비교

추가적으로 위 실험에서 가장 높은 성능을 보인 모델인 ZoomNet을 이용하여, 검출 대상의 크기에 따른 최적의 모델 구성을 찾아보고자 하였다. ZoomNet의 경우 다양한 차원의 특성을 다루기 위해 Triplet Feature Encoder를 제안하였는데, Encoder에서 사용하는 2개의 보조 스케일을 검출 대상의 크기에 따라 조정하여 성능을 확인해 보았다. ZoomNet 저자가 제안한 보조 스케일의 기본값은 0.5와 1.5이다.

먼저 큰 크기의 용접물의 경우, 메인 스케일의 기본값인 1과 보조 스케일 중 큰 스케일에 해당하는 값인 1.5를 고정하고 작은 스케일 0.5를 0.15, 0.25로 변경하여 성능을 확인해 봤다. 표 2를 살펴보면, 0.25일 때 mIoU가 가장 높은 것을 알 수 있다.

다음으로 작은 스케일을 0.25로 고정하고 큰 스케일을 1.25, 1.75로 변경하여 성능을 확인해 봤다. 표 3에 제시한 실험 결과를 통해, 1.25가 가장 높고 1.5, 1.75 순으로 성능이 낮아지는 것을 확인했다. 이를 통해 검출 대상이 큰 경우 보조 스케일을 작게 설정하는 것이 성능 향상에 도움이 된다는 것을 확인하였다. 이에 추가적으로 원본보다 작은 보조 스케일 2개의 조합으로 학습을 진행해봤다. 0.3, 0.6으로 실험한 결과, 원본 스케일보다 작은 값을 보조 스케일로 사용하였을 때 성능이 0.933으로 확연히 높아지는 것을 확인했다.

작은 스케일	0.15	0.25	0.5
큰 스케일		1.5	
mIoU	0.825	0.881	0.873

표 2 큰 용접물 데이터로 ZoomNet의 보조 스케일 중 작은 스케일을 변경한 실험 결과

작은 스케일	0.25			0.3
큰 스케일	1.25	1.5	1.75	0.6
mIoU	0.902	0.881	0.875	0.933

표 3 큰 용접물 데이터로 ZoomNet의 보조 스케일 중 큰 스케일을 변경한 실험 결과

크기가 작은 용접물의 경우 보조 스케일 중 큰 스케일인 1.5를 1.25, 1.75로 변경하여 성능을 확인해 봤다. 표 4를 살펴보면, 1.25로 설정하였을 때 성능이 가장 높게 나타난 것을 확인할 수 있다. 추가로 큰 스케일을 1.25로 설정하고 작은 스케일을 0.75로 변경해봤지만, 기본값인 0.5의 결과와 차이가 0.003으로 미비하게 하락했다. 앞선 결과를 모두 살펴보았을 때, 큰 스케일이 1.5와 1.25인 경우에 작은 스케일의 값에 관계없이 모델의 성능이 높게 나타난 것을 확인할 수 있다. 이를 통해 검출 대상이 작은 경우 보조 스케일을 크게 설정하는 것이 성능 향상에 도움이 된다는 것을 확인하였다. 따라서 작은 스케일 없이 큰 스케일로만 구성하여 실험해 보았다. 1.25, 1.5로 실험한 결과, 가장 높은 성능인 0.925를 달성했다.

작은 스케일	0.5		
큰 스케일	1.25	1.5	1.75
mIoU	0.912	0.902	0.889

표 4 작은 용접물 데이터로 ZoomNet의 보조 스케일 중 큰 스케일을 변경한 실험한 결과

작은 스케일	0.5	0.75	1.25
큰 스케일	1.25		1.5
mIoU	0.912	0.909	0.925

표 5 작은 용접물 데이터로 ZoomNet의 보조 스케일 중 작은 스케일을 변경한 실험 결과

마지막으로 큰 용접물과 작은 용접물이 모두 포함된 전체 학습 데이터 셋에서는 어떤 보조 스케일 조합으로 설정하였을 때 가장 좋은 성능을 보이는지 확인하였다. 표 6과 같이, ZoomNet에서 제시한 보조 스케일의 기본값인 0.5, 1.5의 경우 가장 높은 성능을 보였다.

작은 스케일	0.25			0.5		
큰 스케일	1.25	1.5	1.75	1.25	1.5	1.75
mIoU	0.920	0.890	0.901	0.930	0.936	0.926

표 6 전체 학습 데이터로 ZoomNet의 보조 스케일을 변경한 실험 결과

앞선 실험 결과, 본 논문에서 사용한 데이터 셋 기준으로 큰 용접물의 경우 ZoomNet의 보조 스케일을 0.3, 0.6으로 설정하는 것이 가장 높은 성능을 보여주었고, 작은 용접물의 경우 보조 스케일을 1.25, 1.5로 설정하는 것이 가장 높은 성능을 보여주었다. 그리고 큰 용접물과 작은 용접물 데이터를 함께 학습 데이터로 사용하였을 때, 0.5와 1.5로 설정한 경우에 가장 높은 성능을 보여주었다. 이를 통해 ZoomNet의 보조 스케일 값을 용접물의 크기에 따라 적절하게 설정하는 것이 모델 성능 향상에 도움이 된다는 것을 확인하였다.

IV. 결론

본 논문에서는 COD 모델을 용접 자동화 분야 중 용접물 검출에 적용해 일반적인 Segmentation 모델을 사용하였을 때보다 성능을 향상시켰다. 이러한 용접물 검출 성능 향상을 통해, 향후 용접 산업에서 용접물에 대한 특징 분석을 기반으로 한 용접 경로를 생성하는데 기여할 것으로 기대된다.

또한, 객체의 크기에 따라 최적의 보조 스케일 값이 달라짐을 확인할 수 있었다. 여러 실험을 통해 검출 대상의 크기가 큰 경우 보조 스케일의 값이 0.3, 0.6일 때, 검출 대상의 크기가 작은 경우 보조 스케일의 값이 1.25, 1.5일 때 가장 좋은 성능을 보임을 알 수 있었다. 따라서 작은 객체 검출에는 보조 스케일 값을 크게 하는 것이 유리하고, 큰 객체 검출에는 보조 스케일의 값을 작게 하는 것이 유리하다. 이를 바탕으로 이 논문이 다른 데

이더 셋에 ZoomNet을 적용할 때 보조 스케일 선정에 참고할 수 있는 가이드라인이 될 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 과학기술정보통신부(과기정통부)의 재원으로 정보통신기획평가원(IITP)의 지원을 받아 수행된 지역지능화혁신인재양성사업의 결과물임(IITP-2024-RS-2020-II201741, 100%).

참 고 문 헌

- [1] Pang, Youwei, et al. "Zoom in and out: A mixed-scale triplet network for camouflaged object detection." Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition. 2022.
- [2] Huang, Huimin, et al. "Unet 3+: A full-scale connected unet for medical image segmentation." ICASSP 2020-2020 IEEE international conference on acoustics, speech and signal processing (ICASSP). IEEE, 2020.
- [3] Chen, Liang-Chieh, et al. "Encoder-decoder with atrous separable convolution for semantic image segmentation." Proceedings of the European conference on computer vision (ECCV). 2018.
- [4] Redmon, Joseph, et al. "You only look once: Unified, real-time object detection." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [5] Hu, Xiaobin, et al. "High-resolution iterative feedback network for camouflaged object detection." Proceedings of the AAAI Conference on Artificial Intelligence. Vol. 37. No. 1. 2023.
- [6] Zhang, Yi, et al. "Predictive uncertainty estimation for camouflaged object detection." IEEE Transactions on Image Processing 32 (2023): 3580-3591.