

비드 폭 이상 감지를 위한 전이학습 기반 실시간 용접 이미지 분할에 관한 연구

김현수
울산과학기술대학교 기계공학부

A Study on Real-Time Weld Image Segmentation Based on Transfer Learning for Detecting Abnormalities in Weld Bead Width

Hyun Soo Kim
School of Mechanical Engineering, Ulsan College

요약 본 논문에서는 용접 비드 이미지 분석을 위한 전이 학습 기반의 딥러닝 세그멘테이션 모델 적용에 관해 다룬다. 기존의 이미지 처리 방법들은 용접 과정에서 발생하는 그을음, 스패터와 같은 노이즈 및 불규칙한 명암 분포에 취약함을 보였으나, 본 연구는 ResNet34 백본을 활용한 전이 학습을 통해 이러한 문제들을 극복하고 적은 양의 데이터로도 뛰어난 성능을 달성할 수 있는 방법을 제시하였다. 이 방법은 특히 데이터가 부족한 산업 현장에서도 우수한 결과를 나타냈다. 이 연구에서는 ResNet34, ResNet50, VGG16, VGG19, EfficientNet_B0, EfficientNet_B3를 백본으로 한 6가지 맞춤형 UNet 아키텍처를 개발하여 각 모델의 세그멘테이션 성능을 평가하였다. 실험 결과, UNet + ResNet34 모델은 다른 모델들과 비교하여 가장 낮은 평균 손실값(0.023)과 가장 높은 다이스 계수(0.956)를 기록함으로써 우수한 세그멘테이션 성능을 보였다. 이는 특히 불분명한 용접 비드 경계를 갖는 복잡한 이미지 조건에서도 비드 영역의 정확한 탐지가 가능함을 나타내며, 실제 산업 현장에서의 활용 가능성을 입증하였다. 실제 산업 현장에서 직접 수집한 용접 비드의 이미지 데이터셋을 수집하여 공개하였고, 이 데이터를 이용해 전이 학습 기반의 세그멘테이션 모델을 평가하였다. 이를 통해 모델의 실용성과 적용 가능성을 검증하고, 최적화 방법을 개발함으로써, 용접 비드 검사의 정확성과 효율성을 크게 향상시켰다. 본 연구는 딥러닝 기술과 전이 학습의 효과적인 결합을 통해 산업 현장에서의 복잡한 문제들을 해결할 수 있는 새로운 가능성을 제시하며, 향후 연구와 기술 개발에 중요한 기여를 할 것으로 기대된다.

Abstract This paper discusses the application of a transfer learning-based deep learning segmentation model for welding bead image analysis. Traditional image processing methods are vulnerable to noise, such as soot and spatter, and irregular light distribution during welding. This study presents a method that overcomes these issues using a ResNet34 backbone through transfer learning, achieving superior performance even with limited data, particularly in industrial environments with scarce data. This study developed six custom UNet architectures using ResNet34, ResNet50, VGG16, VGG19, EfficientNet_B0, and EfficientNet_B3 as backbones to evaluate the segmentation performance of each model. The experimental results showed that the UNet + ResNet34 model recorded the lowest average loss value (0.023) and the highest Dice coefficient (0.956), demonstrating superior segmentation performance compared to the other models. This indicates that accurate detection of bead areas in images with unclear welding bead boundaries is possible, even under complex conditions, proving its practical applicability in real industrial settings. The research also involved collecting and releasing a dataset of welding bead images from industrial sites, which were used to evaluate the transfer learning-based segmentation model. This validated the practicality and applicability of the model and significantly enhanced the accuracy and efficiency of welding bead inspections through the development of optimization methods. This study presents new possibilities for solving complex problems in industrial settings through the effective integration of deep learning technology and transfer learning, expecting to make significant contributions to future research and technology development.

Keywords : Weld Inspection, Deep Penetration Welding, Image Segmentation, Deep Learning, Transfer Learning

본 논문은 울산과학기술대학교 교비 연구과제로 수행되었음.

*Corresponding Author : Hyun Soo Kim(Ulsan College)

email: hskim3@uc.ac.kr

Received June 11, 2024

Accepted August 2, 2024

Revised July 8, 2024

Published August 31, 2024

1. 서론

용접 비드 결합 검사는 제품의 안전성과 신뢰성을 보장하는 데 필수적이다. 기존의 용접 검사 방법으로는 파괴 검사와 비파괴 검사가 주로 사용된다. 파괴 검사는 제품을 실제로 파괴하여 내부 결합을 확인하는 방법으로, 샘플 테스트에 주로 사용한다. 반면, 비파괴 검사는 초음파 검사, X-레이 검사 등을 통해 제품을 손상시키지 않고 결합을 찾아내지만, 이 방법들은 시간이 많이 걸리고, 고비용이며, 전문적인 운용 기술을 요구한다. 따라서 최근에는 비접촉식이며 실시간으로 결합을 판단할 수 있는 비전 검사의 필요성이 증가하고 있다. 비전 검사는 카메라와 컴퓨터 비전 기술을 활용하여 빠르고 정확하게 결합을 감지하며, 제품 생산 라인에서 전수 검사를 실시하기에 매우 적합하다.

본 연구는 비전 검사를 활용하여 용접 비드의 결합을 자동으로 탐지하고 분류하는 데 초점을 맞추고 있다. 용접 비드의 세그멘테이션은 용접 표면 결합 검사에서 매우 중요한 역할을 수행한다. 이는 용접 품질을 평가하고, 안전성과 구조적 무결성을 보장하는 데 필수적인 정보를 제공하기 때문이다. 정확한 결합 위치를 식별할 수 있게 하고, 다양한 결합 유형을 효과적으로 구분할 수 있게 한다. 또한, 용접 품질 평가에 있어 비드 형상을 분석하고, 특정 산업 표준에 따른 용접 품질을 확인하는 데 필수적이다. 자동화된 검사 시스템을 구축하고, 실시간 모니터링을 통해 생산성을 향상시킨다.

특히, 이 연구에서는 복잡한 결합에 의해 비전 검사의 정확도가 저하될 수 있는 문제를 해결하기 위해 새로운 접근 방식을 제안한다. 전통적인 이미지 프로세싱 방법은 이러한 복잡한 결합을 효과적으로 분류하고 탐지하는 데 한계가 있다. 따라서, 본 연구는 딥러닝 기반의 세그멘테이션 기술을 사용하여 이러한 한계를 극복하고자 한다. 딥러닝 모델은 이미지에서 직접적으로 결합을 탐지하고 분류할 수 있는 능력을 제공함으로써, 전통적 방법보다 우수한 성능을 발휘한다. 이 연구를 통해 제안된 방법은 제품의 안전성과 신뢰성을 향상시키고, 제품 생산 라인에서 결합 검출의 효율성과 정확성을 현저히 개선할 것으로 기대한다.

Fig. 1은 레이저 심층 용접(Laser Deep Penetration Welding) 과정에서 검출된 다양한 용접 비드 결합을 보여준다. 이 과정은 두 개의 금속판을 볼트 체결 대신 용접으로 고정하는 방식을 채택하고 있으며, 특히 2차전지 배터리팩 조립 공정에 적용 가능성을 테스트하였다. 레

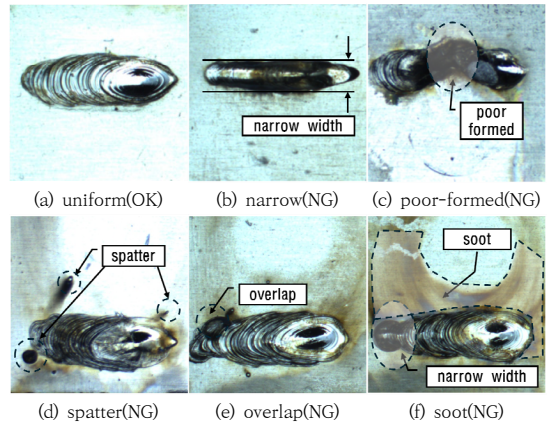


Fig. 1. Various defect shapes encountered during the inspection of weld bead quality

이저 심층 용접은 깊이 있는 용접이 가능하며, 용접부의 기계적 강도를 높이고 열영향부(HAZ)를 최소화하는 장점을 가진다.

이 그림에서 나타나는 결합 유형은 다음과 같다:

- Uniform(OK): 결합이 없는 균일한 용접 비드로, 용접 품질이 양호한 상태를 나타낸다.
- Narrow(NG): 용접 깊이가 얇아져 용접 강도가 저하된 경우로, 용접 실패의 원인이 된다.
- Poor-formed(NG): 비드 폭이 일정하지 않거나 레이저 주사 경로를 크게 벗어나 용접 강도 저하 및 외관 불량을 초래한다.
- Spatter(NG): 용접 중 발생하는 스패터로, 용접 품질을 저하시키며 추가적인 후처리 작업을 필요로 한다.
- Overlap(NG): 비드가 과용출되어 용접부에 과도한 물질이 쌓이는 결합으로, 기계적 강도 약화 및 외관 불량을 유발한다.
- Soot(NG): 용접 중 발생하는 그을음으로 인해 비드 경계 추출이 어렵고, 자동화 비전 검사 시 오류를 발생시켜 이미지 프로세싱 적용에 어려움을 준다.

이러한 결합들은 용접 품질에 큰 영향을 미치며, 레이저 심층 용접 공정에서 철저한 검사와 관리를 요구한다. 결합 유형별로 특징을 명확히 파악하고, 적절한 조치를 취하는 것이 필요하다. 이 과정에서 발견된 결합들은 용접 품질의 평가 및 개선에 중요한 정보를 제공한다.

Fig. 2는 깨끗한 용접 비드 영상을 보여주며, 수작업으로 추출한 비드와 비교할 때, 전통적인 이미지 프로세싱 방법을 사용하여도 정확한 세그멘테이션 마스크를 생

성할 수 있음을 보여준다. 반면, Fig. 3은 그을음이 발생한 용접 비드를 예로 들어, 이미지 프로세싱의 단계적 구성(이진화, 모폴로지 연산, 세그멘테이션) 및 파라미터 선정에 따라 결과가 달라지는 문제를 시각적으로 설명한다. 이는 특히 Fig. 1(f)와 같이 복잡한 결함을 가진 경우, 정확한 비드 추출이 어렵다는 전통적 이미지 프로세싱 방법의 한계를 드러낸다.




Fig. 2. A segmentation mask result using traditional image processing techniques for a clean weld bead




Fig. 3. An example of segmentation mask errors using traditional image processing on weld bead with heavy soot

이 연구는 전통적인 이미지 프로세싱 방법의 한계를 극복하고자 딥러닝 기반의 세그멘테이션 기술, 특히 전이 학습을 활용한 효과적인 용접 비드 추출 방법을 제안한다. 이 방법은 전통적인 방법에서 발생하는 문제들을 해결하고, 정확한 세그멘테이션 마스크 생성을 보장한다. 특히, Fig. 1과 Fig. 3에서 논의된 그을음과 같은 복잡한 결함이 있을 때 파라미터 선택과 이미지 프로세싱 단계에 따라 결과가 크게 달라질 수 있어, 이를 해결하기 위한 정확한 세그멘테이션 마스크 생성이 필수적이다. 제안된 방법은 제품의 안전성과 신뢰성을 향상시키는 데 중요한 기여를 하며, 제품 생산라인에서 결함 검출의 효율성과 정확성을 현저히 개선하는 핵심적인 개선안으로 작용할 것이다. 이는 실제 제조 공정에 적용될 경우, 검사 시간과 비용을 줄이는 동시에 더 높은 품질의 제품 생산을 가능하게 한다.

본 논문은 딥러닝 기술을 적용하여 용접 비드의 세그멘테이션 문제를 해결하기 위한 연구로, 특히 용접 강도 확보를 위한 불균일한 용접 비드 폭 감지에 초점을 맞추고 있다. 이 연구는 용접 공정 중 발생할 수 있는 불균일한 비드 폭을 효과적으로 탐지하고 분류하기 위한 방법론을 제시하며, 이를 통해 용접 품질의 향상 및 생산 효율성을 증가시키는 것을 목표로 한다. 연구 방법론으로는, ResNet34, ResNet50, VGG16, VGG19, EfficientNet_B0, EfficientNet_B3를 백본으로 하는 6가지 맞춤형 UNet 아키텍처를 개발하였으며, 이들 모델의 세그멘테이션 성능을 다양한 실험을 통해 비교하고 평가한다. 이 과정에서 얻어진 결과를 바탕으로 각 모델의 장단점을 분석하고, 가장 효과적인 모델 구성을 도출한다. 이러한 접근을 통해, 본 연구는 실제 적용 가능하고 효율적인 용접 비드 폭 감지 방법을 개발하고자 한다.

2. 관련 연구

용접품질검사 분야에서 자동화된 시각적 인식과 이미지 처리 기술의 발전은 높은 정확도와 신뢰성을 제공한다. Muravyov와 Nguyen[1]은 Canny 엣지 검출기와 간격 융합을 결합하여 용접 결함을 정확히 인식하는 방법을 제안하였다. Zhang 외[2]는 로봇 GMA 용접 과정에서 비드 형상을 감지하는 이미지 처리 알고리즘을 개발하여 실험적으로 검증하였다. AJMI 외[3]는 Hough 변환과 Canny 검출기를 사용하여 방사선 이미지를 통한 용접 결함 감지 방법을 제시하였으며, Wang 외[4]는 다양한 이미지 처리 알고리즘을 비교하여 레이저 라인을 기반으로 한 용접 풀 모니터링의 최적 접근법을 연구하였다. 이러한 연구들은 용접품질검사의 자동화와 정확성 향상에 기여하며, 다양한 환경에서의 적용 가능성을 보여준다.

딥러닝 기반 이미지 세그멘테이션 기술은 의료 이미지부터 일반 시각적 작업에 이르기까지 다양한 응용 분야에서 중요한 발전을 이루고 있다. Ronneberger 외[5]의 UNet은 특히 생체 의학 이미지 세분화에서 우수한 성능을 보여주며, 데이터 증강을 통해 제한된 훈련 데이터에서도 효과적으로 학습한다. Long 외[6]는 CRF를 통합하여 세분화의 정확성을 향상시켰다. Chen 외[7], Sun 외[8], 그리고 Zhang 외[9]의 연구는 다양한 네트워크 백본이 세그멘테이션 성능에 미치는 영향을 비교함으로써, 최적의 네트워크 구조를 선택하는 데 중요한 정보를 제

공하였다. 이러한 연구들은 의료 이미지뿐만 아니라 일반적인 이미지에서도 세그멘테이션의 정확도를 향상시키는 데 크게 기여하고 있다.

전이학습은 이미 학습된 모델을 새로운, 관련된 문제에 적용하여 학습 시간을 단축하고 성능을 향상시키는 기법이다. 이 기법은 용접 품질 검사와 같은 작은 데이터셋 문제에 적용될 때, 이미 충분히 학습된 모델을 기반으로 특정 도메인의 미세 조정을 통해 더 빠르고 효율적인 성능 향상을 도모할 수 있다. 특히 UNet 기반의 용접품질 검사 분야는 딥러닝 기술을 통해 자동화와 정확성을 크게 향상시키고 있다. Li 외[10]의 연구는 클라우드와 엣지 컴퓨팅을 통합한 로봇 비전 시스템으로 용접 결함을 자동으로 감지하는 혁신을 선보였다. Jin 외[11]와 Natan 외[12]는 각각 UNet 기반 기술을 사용하여 방사선 이미지와 용접 점의 세분화를 통해 용접 비드와 결함을 더 정확하게 식별하고 분류할 수 있는 방법을 개발하였다. Yu 외[13]의 연구는 실시간으로 용접 풀을 인식하고 분석할 수 있는 시스템을 제시함으로써 용접 공정 모니터링의 신속성과 정확성을 제공한다. Wang 외[14]는 세그멘테이션 네트워크를 통해 용접 과정에서 발생할 수 있는 다양한 결함을 효과적으로 감지할 수 있는 방법을 개발하여 용접 품질 관리의 자동화에 기여하였다. 이러한 기술들은 용접 결함의 자동 감지뿐만 아니라 전체적인 용접 공정의 효율을 크게 향상시킬 수 있는 가능성을 보인다.

전통적인 용접품질 검사 방법은 대부분 시간이 많이 소요되고 주관적인 판단에 의존했다. 하지만 최근에는 딥러닝과 같은 고급 알고리즘을 활용하여 이러한 문제들을 해결하고 있다. Whang 외[15]는 클라우드 기반 데이터 처리를 통해 용접 결함을 자동으로 감지하는 로봇 비전 시스템을 개발하였으며, Kim 외[16]의 연구는 YOLO 알고리즘을 통해 빠르고 정확한 결함 감지가 가능함을 보여준다. 또한, Kang 외[17]는 이미지 처리 기술을 사용하여 용접 과정을 실시간으로 모니터링하고 분석함으로써 용접 품질을 효과적으로 관리할 수 있는 방법을 개발하였다. 이러한 기술들은 용접 결함의 자동 감지뿐만 아니라 전체적인 용접 공정의 효율을 크게 향상시킬 수 있는 가능성을 보인다.

실제 백본을 사용한 딥러닝 네트워크 깊이에 따른 성능을 비교분석한 연구들[18-20]을 살펴보면, 깊은 네트워크가 항상 더 나은 성능을 보장하지 않으며, 특정 상황에서는 더 적은 계산 자원을 사용하는 ResNet34가 더 깊은 ResNet50보다 더 나은 성능을 보여주었다는 것을

입증하였다. 따라서 깊이가 다른 백본에 대한 철저한 분석과 평가는 실제 애플리케이션 개발에서 중요한 고려사항이 되어야 한다.

본 연구는 선행 연구들과 차별화되는 몇 가지 주요한 관점을 제공한다.

첫째, 연구의 실용성과 적용 가능성을 높이기 위해 산업 현장에서 직접 획득한 실제 이미지와 마스크 셋을 사용하고 다른 연구에 기여하기 위해 이를 제공하였다[21]. 이 데이터셋은 용접 비드의 세밀한 특성을 정확하게 파악하고 분석할 수 있는 기회를 제공한다.

둘째, 전통적인 이미지 처리 방법들이 가진 여러 한계를 개선하기 위해 전이 학습 기법과 다양한 백본 아키텍처를 통합하였다. 이 접근법은 특히 그늘음 정도가 급격히 변화하는 생산 환경에서 용접 비드를 효과적으로 검출할 수 있도록 하며, 기존 방법들이 해결하기 어려운 문제에 대해 우수한 모델 성능을 입증한다.

마지막으로, 실시간 처리가 요구되는 산업 현장에서 처리 속도와 정확성의 균형을 최적화하는 방법을 제시한다. 이는 산업 현장의 요구 사항을 충족시키며, 실제 운영 환경에서의 효율성을 대폭 향상시키는 결과를 가져온다.

이러한 접근은 본 연구를 기존 연구들과 차별화시키며, 용접 비드 품질 검사 기술의 발전에 중요한 기여를 할 것으로 판단한다.

3. 연구 방법

Fig. 4는 본 논문에서 제안하는 ResNet34 백본을 사용한 맞춤형 UNet 아키텍처를 설명한다. 이 구조는 용접 비드 이미지의 정밀한 세그멘테이션을 수행하기 위해 다음과 같은 세부 단계를 포함한다:

인코더는 224x224 픽셀 크기의 입력 이미지를 처리하여 컨볼루션 레이어를 통해 이미지의 특징을 추출하고, 배치 정규화 및 ReLU 활성화 함수를 사용하여 비선형 변환을 수행한다. 맥스 풀링을 통해 특징 맵의 차원을 줄이는 과정을 거치며, 브릿지는 네트워크의 가장 깊은 곳에서 추가된 컨볼루션 레이어로 더 깊은 특징을 추출하고, 이를 디코더로 전달한다. 디코더는 업샘플링과 픽셀 셔플 기술로 이미지의 디테일을 복원하며, 스킵 연결을 통해 세밀한 정보를 유지한다. 이 과정은 세그멘테이션의 정확도를 높이는 데 기여하며, 본 논문에서 제안된 ResNet34 백본을 가진 맞춤형 UNet 아키텍처를 통해 용접 비드 세그멘테이션을 효과적으로 수행한다.

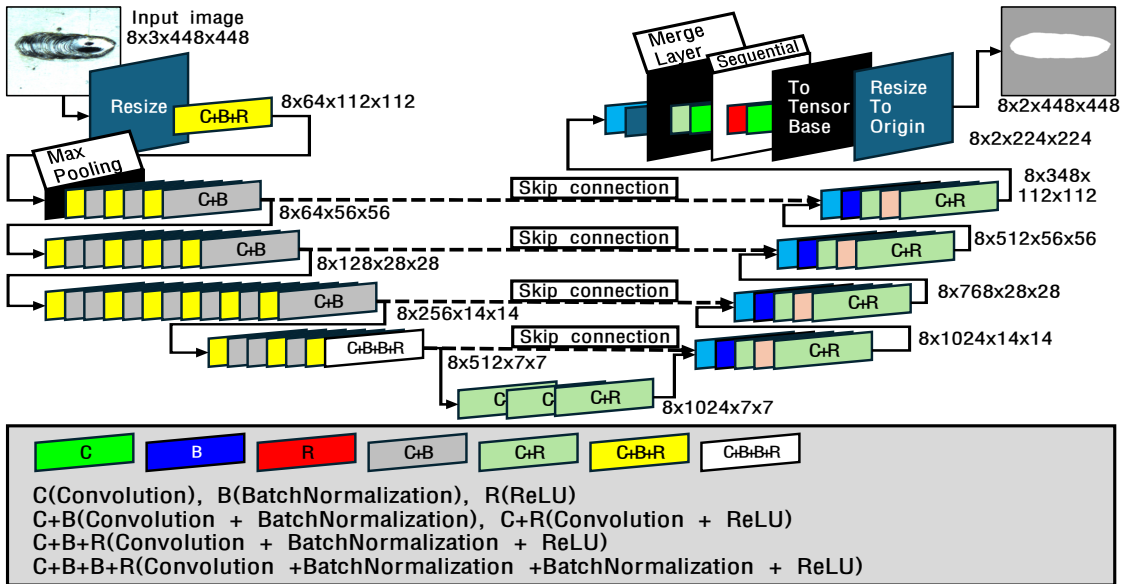


Fig. 4. The custom UNet architecture with a ResNet34 backbone proposed in this paper for weld bead segmentation

이러한 접근 방식은 용접 비드의 복잡한 특징을 정확하게 포착하고 세밀하게 세그멘테이션하는 데 중요하다. 본 연구에서 직접 획득한 데이터셋에 대해 6가지 백본 모델에 대해 맞춤형 UNet의 성능을 평가한 결과로 ResNet34 백본이 용접 비드 세그멘테이션에 가장 적합함을 실험으로 입증하였다.

논문에서는 복잡한 딥러닝 연산과 대규모 데이터 처리를 위해 Table 1의 컴퓨팅 리소스를 활용하였다. 이 훈련 환경에서는 성능평가에 사용한 6가지 모델을 모두 훈련할 수 있었으나, EfficientNet b7과 같은 대형 백본은 GPU 메모리의 부족으로 훈련할 수 없어 EfficientNet은 기본 모델인 b0와 중간 크기인 b4만 훈련을 할 수 있었으며, VGG나 ResNet 계열의 백본은 정상적인 훈련이 가능하였다.

본 논문에서 사용된 용접 비드 데이터셋은 총 1394개의 이미지를 훈련 데이터셋, 검증 데이터셋, 테스트 데이터셋으로 분할하였다. 훈련 데이터셋은 전체 데이터의 60%에 해당하는 836개의 이미지로, 검증 데이터셋과 테스트 데이터셋은 각각 전체 데이터의 20%, 즉 279개의 이미지로 구성되어 있다. 이렇게 분할된 데이터셋을 통해 모델의 성능을 평가하고 검증하였다.

훈련 과정에서는 훈련 데이터셋과 검증 데이터셋을 활용하여 모델의 학습과 성능 조정을 진행하였다. 이 두 데이터셋을 통해 모델의 하이퍼파라미터를 최적화하고 과

적합을 방지하기 위한 검증 절차를 수행하였다. 최종적으로, 학습된 모델은 테스트 데이터셋을 사용하여 추론을 수행하였다. 이를 통해 실제 생산라인 시운전 환경에서의 모델 성능을 평가하였다. 연구에서는 총 6가지 다른 훈련 모델을 비교 분석하였으며, 용접 비드 결함 탐지에 가장 효과적인 모델을 식별하였다. 이러한 접근 방식은 모델의 일반화 능력을 평가하였다.

본 연구에서 데이터 전처리 및 증강을 배제하고 데이터셋의 원본(raw) 영상으로 훈련을 진행하였다. 이러한 방식은 원본 데이터의 자연스러운 특성을 유지하고 과적합을 방지하여 모델이 실제 환경에서 더 견고하게 동작하도록 돕는다. 또한, 이 접근법은 계산 효율성을 높이고, 모델의 단순성을 보장하며, 평가의 명확성을 향상시키는 등의 장점을 제공한다. 이는 모델 설계 및 실험 단계를 간소화하고, 신뢰성과 투명성을 높이는 데 기여하여, 실제 산업 현장에 적합한 최적의 솔루션을 제공할 수 있다.

Table 1. Experimental setup

CPU	Ryzen Threadripper PRO 5955WX 16-Cores
RAM	128 GB
GPU	NVIDIA GeForce RTX 4090
GPU Driver	535.171.04
CUDA Ver.	12.1
Python Ver.	3.12.3

Table 2. Dataset split

Dataset	number of images	ratio(%)
train dataset	836	60
validation dataset	279	20
test dataset	279	20
total	1,394	100

Table 3. Test UNet-based transfer learning model (The batch size for all models was set to 8, with the Adam optimizer and cross-entropy loss function being used)

Model (UNet + backbone)	Learning rate	Average train and validation time per 1-epoch(sec)	Best model file size (Mbyte)
UNet + VGG16	1.91E-04	28	352
UNet + VGG19	1.48E-04	29	414
UNet + ResNet34	5.25E-05	9	483
UNet + ResNet50	2.51E-05	32	3,974
UNet + EffiNet_b0	3.63E-05	111	1,163
UNet + EffiNet_b4	5.25E-05	369	2,392

본 연구에서 사용한 작은 데이터셋이나 과적합의 우려가 있는 상황에서 VGG, EfficientNet 등의 백본을 포함한 다양한 모델을 실험적으로 비교 분석하는 것은 각 모델이 특정 데이터와 작업에 어떻게 성능을 발휘하는지 이해하는 데 중요하다. 이를 통해, 데이터 크기와 모델의 복잡성에 따라 어떤 모델이 더 적합한지 판단할 수 있다. 세그멘테이션으로 사용한 UNet은 비교적 오래된 구조임에도 불구하고, 다양한 의료 영상 처리 및 산업용 이미지 분석에서 높은 정확도와 신뢰성을 입증하였다. UNet의 인코더-디코더 구조는 세부적인 경계 검출 및 픽셀 단위의 정밀한 분할에 강점을 가지고 있으며, 이는 용접 비드 결함 검출과 같은 특정 문제에 매우 적합하다. 또한, 최신 SOTA 모델들이 높은 성능을 제공하지만 복잡성과 연산 비용이 크게 증가하는 반면, UNet은 상대적으로 가벼우면서도 성능이 검증된 모델이기 때문에 실시간 처리와 효율적인 연산이 중요한 산업 현장에 더 적합할 수 있다. 따라서, UNet을 기반으로 다양한 백본 모델을 사용하여 용접 비드 결함 검출 성능을 최적화하고자 하는 것은 연구 목표를 달성하는 데 적합한 접근 방식으로 판단하였다.

논문에서는 다양한 UNet 기반 모델을 훈련시킨 결과, 훈련 소요 시간과 베스트 모델의 파일 크기를 비교 분석하였다. 가장 빠른 모델인 UNet + ResNet34는 30 에

폭 기준으로 평균 9초가 소요되어 총 270초 (4분 30초)가 걸렸으며, 가장 느린 모델인 UNet + EffiNet_b4는 평균 369초가 소요되어 총 11,070초 (약 3시간 4분)가 걸렸다. 파일 크기는 UNet + VGG16이 352MB, UNet + VGG19가 414MB, UNet + ResNet34가 483MB, UNet + ResNet50가 3,974MB, UNet + EffiNet_b0가 1,163MB, UNet + EffiNet_b4가 2,392MB로 다양하다. 이러한 결과는 각 모델의 구조적 특성과 학습 효율성을 반영하며, 모델 선택 시 중요한 고려 사항이 된다. 특히, 속도가 빠른 모델 선택은 실험의 수를 늘리고 더 나은 하이퍼파라미터 조합을 빠르게 찾아내는 데 유리하며, 실시간 데이터 처리가 필요한 생산 라인에 이상적이다.

실험에서는 6개 모델의 세그멘테이션 성능을 비교하기 위해 다음 세 가지 메트릭을 사용하였다:

- Dice 계수(Dice Coefficient): 이 메트릭은 두 샘플 간의 유사도를 측정하는 데 사용되며 다음과 같이 표현한다

$$Dice = \frac{2 \times |X \cap Y|}{|X| + |Y|} \quad (1)$$

X, Y 는 각각 예측된 세그멘테이션과 실제 세그멘테이션 영역을 나타낸다. 이 계수는 0과 1 사이의 값을 가지며, 1에 가까울수록 두 세그멘테이션 간의 오버랩이 많음을 의미한다.

- 픽셀 정확도(Pixel Accuracy): 이 메트릭은 전체 픽셀 중 올바르게 분류된 픽셀의 비율을 측정하면 다음과 같이 정의한다.

$$Accuracy = \frac{Number\ of\ classified\ pixels}{Total\ number\ of\ pixels} \quad (2)$$

픽셀 정확도는 간단하면서도 직관적인 성능 측정 방법으로, 전체 이미지에서 모델이 얼마나 잘 작동하는지를 보여준다.

- F2 점수(F2 Score): 이 메트릭은 precision과 recall의 조화 평균을 바탕으로 계산되며, recall을 더 중시하는 성능 측정 기준이다.

$$F_2 = \frac{(1 + 2^2) \times Precision \times Recall}{(2^2 \times Precision) + Recall} \quad (3)$$

여기서 Precision은 정밀도, Recall은 재현율을 의미한다. F2 점수는 특히 불균형한 데이터 세트에서 유용하며, 미세한 세그멘테이션 오류에 민감하다. 이 메트릭들은 각 모델의 세그멘테이션 성능을 정량적으로 평가하는 데 사용되었다.

4. 결과 분석

Fig. 5에서 다양한 UNet 기반 모델의 훈련 소요 시간, 파일 크기 및 베스트 모델의 성능을 비교 분석하였다. ResNet 계열이 훈련 및 검증 손실과 다이스 계수에 서 전반적으로 우수한 성능을 보여준 반면, VGG 계열은 다소 낮은 다이스 계수를 기록하며 중간 수준의 성능을 나타내었다. 특히, ResNet34는 낮은 훈련 및 검증 손실과 높은 다이스 계수로 가장 우수한 성능을 보였다. 반면, 더 깊은 ResNet50과 EfficientNet 계열은 예상과

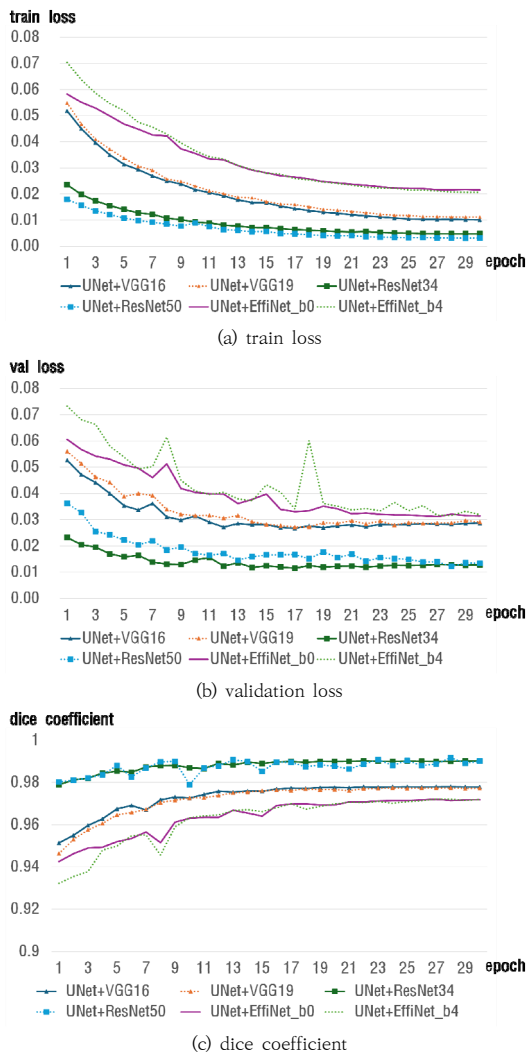


Fig. 5. Loss metrics and Dice coefficient for each model across training and validation datasets(dice coefficient graphs are presented only for the validation dataset)

달리 높은 손실 값과 낮은 다이스 계수를 보여주며, 파라미터가 많은 깊은 네트워크는 적은 데이터셋에 대해 항상 더 나은 성능을 보장하지 않음을 시사한다. 이는 용접 비드 데이터셋의 특성과 깊은 네트워크의 경계 추출 민감도가 관련이 있을 수 있음을 나타내며, 데이터셋에 최적화된 모델 선택의 중요성을 강조한다. 이러한 결과는 실시간 용접 비드 검사와 같은 응용 분야에서 효과적인 모델을 선택하는 데 있어 중요한 가이드라인을 제공할 수 있다.

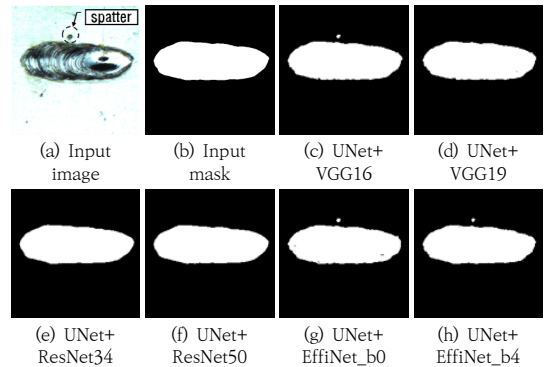


Fig. 6. Comparison of segmentation masks inferred by each model for a clean weld bead

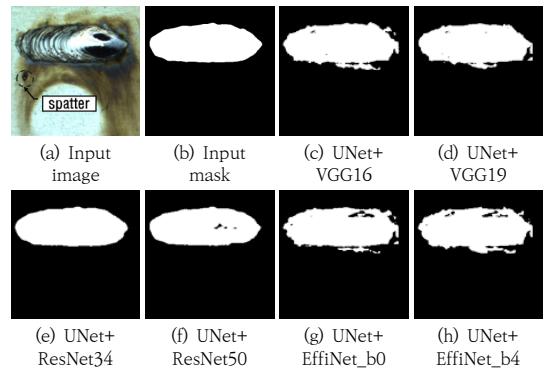


Fig. 7. Comparison of segmentation masks inferred by each model for a weld bead with heavy soot

Fig. 6과 7은 각각 깨끗한 비드 표면과 그늘음이나 스파터가 있는 비드 표면의 분할 결과를 보여준다. Fig. 6에서 훈련된 모든 모델은 깨끗한 비드 표면에서 뛰어난 분할 결과를 제공하며 이는 기존 이미지 처리 방법도 적절하게 수행할 수 있음을 나타낸다. 그러나 Fig. 7에서는 그늘음이나 스파터가 있는 복잡한 이미지 조건에서 모델 간의 성능 차이가 눈에 띄게 나타난다. 특히 ResNet 시

리츠 모델은 이러한 까다로운 조건에서도 높은 견고성을 보여주고 있으며, 이는 ResNet34 모델이 복잡한 표면 이미지에서 비드 폭 이상을 감지하는 데 더 적합하다는 것을 보여준다. 이러한 결과를 바탕으로 본 연구에서는 복잡한 영상 조건에서도 안정적인 성능을 유지하는 ResNet34 모델이 특히 실시간 용접 비드 검사에 적합하다고 판단한다.

Fig. 7의 결과에 따르면, UNet + VGG16과 UNet + VGG19는 그늘음과 스패터가 포함된 복잡한 조건에서 오버피팅과 세밀한 구분의 어려움을 보이며, 더 깊은 층을 사용하는 UNet + VGG19는 더 많은 세부적인 오류를 발생시킨다. 반면, UNet + ResNet34 및 ResNet50 모델은 높은 강건성을 보이며 안정적인 세그멘테이션 결과를 제공한다. 그러나 ResNet50은 때때로 불필요한 세부 사항을 포착하는 경향이 있는 반면, UNet + ResNet34는 비드 폭 이상을 더 정확하게 감지한다. UNet + EfficientNet_b0과 UNet + EfficientNet_b4는 효율적인 구조로 계산 자원을 적게 사용하지만 그늘음에 민감하여 비드 외 영역을 비드로 인식하는 오류가 증가한다. 이러한 분석을 통해 ResNet 계열 모델, 특히 ResNet34가 비드 영상 데이터셋 조건에서 가장 우수한 성능을 보임을 확인할 수 있다.

Table 4. Overview of the inference outcomes for the best models evaluated on the test dataset(279 images)

Model (UNet + backbone)	Dice coefficient	Pixel accuracy	F2 Score
UNet + VGG16	0.969	0.986	0.961
UNet + VGG19	0.967	0.985	0.957
UNet + ResNet34	0.981	0.992	0.973
UNet + ResNet50	0.976	0.990	0.963
UNet + EffiNet_b0	0.964	0.984	0.953
UNet + EffiNet_b4	0.964	0.984	0.954

Table 5. Analysis of real-time inference efficiency among the best models tested on the test dataset(279 images)

Model (UNet + backbone)	Computation time(ms)	frame per sec.	weight file size(Mbyte)
UNet + VGG16	23.80	42.02	352
UNet + VGG19	23.58	42.40	414
UNet + ResNet34	16.99	58.86	483
UNet + ResNet50	29.71	33.66	3,974
UNet + EffiNet_b0	65.05	15.37	1,163
UNet + EffiNet_b4	110.75	9.03	2,392

Table 4에서 UNet + ResNet34는 모든 훈련 모델 중 가장 뛰어난 성능을 보여 다이스 계수 0.981, 픽셀 정확도 0.992, F2 점수 0.973을 기록했다. UNet + ResNet50, VGG16, VGG19, 그리고 EfficientNet 기반의 UNet + EffiNet_b0와 EffiNet_b4도 각각 우수한 성능을 보였으나, 특히 ResNet34는 빠른 처리 속도 (16.99ms, 58.86fps)로 실시간 이미지 처리에 매우 적합하다. Table 5에 따르면, VGG 계열은 처리 시간과 초당 프레임 수가 안정적이나, EfficientNet 계열은 높은 계산 부하로 실시간 처리에 제한적일 수 있음을 보여준다. 이 결과는 산업 현장에서 빠른 속도의 용접 비드 검사에 UNet + ResNet34가 실시간 검사에 가장 효과적이며, 반면 UNet + EffiNet_b4는 처리 시간이 길어 생산 효율성이 저하될 위험이 크다.

실험 결과를 종합적으로 분석한 결과, ResNet34를 백본으로 하는 UNet 모델이 용접 비드 데이터셋에서 비드 폭 이상 감지에 최적임을 확인할 수 있었다. UNet + ResNet34는 훈련과 검증 과정에서 낮은 손실 값을 기록하며 높은 다이스 계수를 달성하였고, 깨끗한 비드와 복잡한 비드(그늘음, 스패터 포함)에서 모두 우수한 세그멘테이션 결과를 보였다. 특히 그늘음과 스패터가 있는 복잡한 조건에서도 강건한 성능을 보여, 이는 산업 현장에서 이미지 경계가 불분명하거나 스패터를 포함한 조건에서도 효과적인 비드 폭 이상 감지가 가능함을 의미한다. 실시간 이미지 처리에서도 16.99ms의 낮은 계산 시간과 58.86fps의 높은 프레임 속도로 매우 효과적인 성능을 보임으로써, ResNet34가 복잡도, 정확성, 처리 속도를 모두 고려할 때 산업 현장에서의 실시간 용접 비드 검사에 매우 적합하다는 결론에 이르렀다. 이에 본 연구는 UNet 기반 ResNet34 백본의 훈련 모델을 최종 검사 모델로 선정하였다.

5. 결론

본 연구에서 개발된 ResNet34 백본을 사용한 맞춤형 UNet 아키텍처는 용접 비드 폭 이상감지를 위해 비드 영역의 단일 세그멘테이션에 초점을 맞추고 있다. 이는 전이 학습을 통해 이미 훈련된 모델을 적용함으로써, 복잡한 용접 이미지에서 비드 폭 이상을 효과적으로 탐지하고 분류할 수 있는 방법을 제공한다. 이 접근법은 제한적인 데이터를 가진 산업 환경에서도 높은 성능을 달성하는 이점을 지니며, 인코더의 다양한 컨볼루션 레이어

와 맥스 풀링을 통해 특징을 추출하고, 브릿지와 디코더의 세밀한 업샘플링과 스킵 연결을 통해 정밀한 세그멘테이션을 수행한다. 이로써 본 연구는 산업 현장에서 빠르고 정확한 비드 폭 이상감지를 가능하게 한다.

결론적으로, UNet + ResNet34 모델은 현재 비드 폭 이상감지를 위한 단일 클래스 세그멘테이션에서 우수한 성능을 보였으며, 향후 연구에서는 이 모델을 다양한 불량 형상을 포함하는 멀티클래스 세그멘테이션으로 확장할 계획이다. 이러한 확장은 모델의 적용 범위를 넓히고, 다양한 용접 방식과 재료에 대한 세그멘테이션 능력을 향상시키며, 산업 응용 분야에서의 활용도를 더욱 증대시킬 것이다.

References

- [1] S. V. Muravyov, D. C. Nguyen, "Weld Defects Automatic Visual Recognition by Combined Application of Canny Edge Detector and Interval Fusion with Preference Aggregation", *International Conference on Information, Control, and Communication Technologies (ICCT)*, IEEE, pp. 1-4, 2022.
DOI: <https://doi.org/10.1109/icct56057.2022.9976559>
- [2] G. Zhang, T. J. Yun, W. B. Oh, B. R. Lee, B. Lim, I. S. Kim, "A Study on the Bead Geometry with Offset based on Image Processing Algorithm", *Proceedings of the 5th World Congress on Mechanical, Chemical, and Material Engineering (MCM'19)*, Lisbon, Portugal - August, Paper No. MMME 138, 2019.
DOI: <https://doi.org/10.11159/mmme19.138>
- [3] C. Ajmi, S. E. Ferchichi, A. Zaafour, K. Laabidi, "Automatic detection of weld defects based on hough transform", *In 2019 International Conference on Signal, Control and Communication (SCC)*, IEEE, pp. 1-6, Dec. 2019.
DOI: <http://dx.doi.org/10.1109/SCC47175.2019.9116162>
- [4] Z. Wang, C. Zhang, Z. Pan, Z. Wang, L. Liu, X. Qi, S. Mao, J. Pan, "Image segmentation approaches for weld pool monitoring during robotic arc welding", *Applied Sciences*, Vol. 8, No. 12, 2445, 2018.
DOI: <https://doi.org/10.3390/app8122445>
- [5] O. Ronneberger, P. Fischer, T. Brox, "U-net: Convolutional networks for biomedical image segmentation", *In Medical image computing and computer-assisted intervention -MICCAI 2015: 18th international conference Munich Germany*, proceedings, part III 18, pp. 234-241, Oct. 2015.
DOI: https://doi.org/10.1007/978-3-319-24574-4_28
- [6] J. Long, E. Shelhamer, T. Darrell, "Fully convolutional networks for semantic segmentation", *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440, 2015.
DOI: <http://dx.doi.org/10.1109/CVPR.2015.7298965>
- [7] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, A. L. Yuille, "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs", *IEEE transactions on pattern analysis and machine intelligence*, Vol. 40, No. 4, pp. 834-848, 2017.
DOI: <http://dx.doi.org/10.1109/TPAMI.2017.2699184>
- [8] K. Sun, Y. Zhao, B. Jiang, T. Cheng, B. Xiao, D. Liu, Y. Mu, X. Wang, W. Liu, J. Wang, "High-resolution representations for labeling pixels and regions", *arXiv preprint arXiv:1904.04514*, 2019.
DOI: <https://doi.org/10.48550/arXiv.1904.04514>
- [9] R. Zhang, L. Du1, Q. Xiao, J. Liu, "Comparison of backbones for semantic segmentation network", *Journal of Physics: Conference Series*, Vol. 1544, No. 1, 012196, 2020.
DOI: <http://dx.doi.org/10.1088/1742-6596/1544/1/012196>
- [10] H. Li, X. Wang, Y. Liu, G. Liu, Z. Zhai, X. Yan, H. Wang, Y. Zhang, "A Novel Robotic-Vision-Based Defect Inspection System for Bracket Weldments in a Cloud-Edge Coordination Environment. Sustainability", *Sustainability*, Vol. 15, No. 14, 10783, 2023.
DOI: <http://dx.doi.org/10.3390/su151410783>
- [11] G. Jin, S. Oh, Y. Lee, S. Shin, "Extracting Weld bead shapes from radiographic testing images with U-net", *Applied Sciences*, Vol. 11, No. 24, 12051, 2021.
DOI: <http://dx.doi.org/10.3390/app112412051>
- [12] O. Natan, D. U. K. Putri, A. Dharmawan, "Deep learning-based weld spot segmentation using modified UNet with various convolutional blocks", *ICIC Exp. Lett. Part B: Appl.* Vol. 12, No. 12, pp. 1169-1176, 2021.
DOI: <http://doi.org/10.24507/icicelb.12.12.1169>
- [13] R. Yu1, J. Kershaw, P. Wang, Y. Zhang, "Real-time recognition of arc weld pool using image segmentation network", *Journal of Manufacturing Processes*, Vol. 72, pp. 159-167, 2021.
DOI: <https://doi.org/10.1016/j.jmapro.2021.10.019>
- [14] B. Wang, F. Li, R. Lu, X. Ni, W. Zhu, "Weld feature extraction based on semantic segmentation network", *Sensors*, Vol. 22, No. 11, 4130, 2022.
DOI: <http://dx.doi.org/10.3390/s22114130>
- [15] H. G. Hwang, B. S. Kim, Y. T. Woo, Y. W. Yoon, S. C. Shin, S. J. Oh, "A development of welding information Management and Defect Inspection Platform based on artificial intelligent for shipbuilding and maritime industry", *Journal of the Korea Institute of Information & Communication Engineering*, Vo. 25, No. 2, pp. 193-201, Feb. 2021.
DOI: <http://doi.org/10.6109/ikiice.2021.25.2.193>
- [16] I. S. Kim, M. G. Lee, Y. Jeon, "Comparative Analysis of Defect Detection Using YOLO of Deep Learning", *Journal of the Korean Society of Manufacturing Technology Engineers*, Vol. 30, No. 6, pp. 514-519, 2021.
DOI: <https://doi.org/10.7735/ksmte.2021.30.6.513>

- [17] J. H. Kang, N. Ku, "Verification of Resistance Welding Quality Based on Deep Learning", *Journal of the Society of Naval Architects of Korea*, Vol. 56, No. 6, pp. 473-479, 2019.
DOI: <https://doi.org/10.3744/SNAK.2019.56.6.473>
- [18] Y. Heryadi, E. Irwansyah, E. Miranda, H. Soeparno, K. Hashimoto, K. "The effect of resnet model as feature extractor network to performance of DeepLabV3 model for semantic satellite image segmentation", *In 2020 IEEE Asia-Pacific Conference on Geoscience, Electronics and Remote Sensing Technology*, pp. 74-77, Dec. 2020.
DOI: <https://doi.org/10.1109/AGERS51788.2020.9452768>
- [19] N. Sambyal, P. Saini, R. Syal, V. Gupta, "Modified residual networks for severity stage classification of diabetic retinopathy", *Evolving Systems*, Vol. 14, No. 1, pp. 17-35, 2023.
DOI: <https://doi.org/10.1007/s12530-022-09427-3>
- [20] F. M. Talaat, S. El-Sappagh, K. Alnowaiser, E. Hassan, "Improved prostate cancer diagnosis using a modified ResNet50-based deep learning architecture", *BMC Medical Informatics and Decision Making*, Vol. 24, No. 1, 2024.
DOI: <https://doi.org/10.1186/s12911-024-02419-0>
- [21] H. S. Kim, "Weld bead images and masks", <https://figshare.com>, Jun. 2024.
DOI: <https://doi.org/10.6084/m9.figshare.25904014>

김 현 수(Hyun Soo Kim)

[중신회원]



- 2002년 2월 : GIST 기전공학과 (공학석사)
- 2009년 2월 : GIST 기전공학과 (공학박사)
- 2009년 3월 ~ 2010년 8월 : GIST 기전공학과 (Post Doc.)
- 2010년 9월 ~ 2014년 2월 : 삼성 SDI 중앙연구소 책임연구원
- 2014년 3월 ~ 현재 : 울산과학기술대학교 기계공학부 부교수

<관심분야>

빅데이터, 인공지능, 생산자동화, CAD, 그래픽스