



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

2022년 2월

석사학위논문

강철 표면 결함 분류를 위한 Segmentation 모델 비교

조선대학교 대학원

컴퓨터공학과

황 석 민

강철 표면 결함 분류를 위한 Segmentation 모델 비교

Steel surface segmentation models for defect detection

2022년 2월 25일

조선대학교 대학원

컴퓨터공학과

황 석 민

강철 표면 결함 분류를 위한 Segmentation 모델 비교

지도교수 정 호 엽

이 논문을 공학 석사학위신청 논문으로 제출함.

2021년 10월

조선대학교 대학원

컴퓨터공학과

황 석 민

황석민의 석사학위 논문을 인준함

위원장 조선대학교 교수 김 판 구 (인)

위 원 조선대학교 교수 정 호 엽 (인)

위 원 조선대학교 교수 전 찬 준 (인)

2021년 12월

조선대학교 대 학 원

목 차

LIST OF TABLES iii

LIST OF FIGURES iv

ABSTRACT v

제 1 장 서 론 01

제 1 절 연구 배경 01

제 2 절 연구 목적 04

제 2 장 이론적 배경 관련 연구 05

제 1 절 Segmentation과 표면결함 05

1. Segmentation 05

2. 금속의 표면결함 판별 07

제 3 장 실험 방법 09

제 1 절 데이터 셋 구축 09

1. Severstal Steel Defects Data 09
2. Data labeling 11

제 2 절 각 모델별 특징 13

1. FCN 14
2. Resnet 15
3. U-Net 17
4. ResUnet 19

제 4 장 결과 및 분석 21

제 1 절 각 모델별 결과 21

제 2 절 각 모델별 결과와 Ground Truth 비교 검증 22

제 5 장 결론 및 향후연구 24

참 고 문 헌 25

LIST OF TABLES

Table 2.1 U-Net의 예측 값과 기존 판별에 사용되는 Image J 비교 평가, Ground Truth와 가까운 값이 더 높은 정확도를 갖음	8
Table 3.1 공통 하이퍼 파라미터	13
Table 4.1 Dice Coefficient, IoU 결과 비교	21
Table 4.2 Dice Coefficient, Dice loss의 결과, 이미지 전체 사이즈에 차지하는 Pixel 비율을 측정한 결과 값	22
Table 4.3 IoU, focal loss의 결과, 이미지 전체 사이즈에 차지하는 Pixel 비율을 측정한 결과 값	23

LIST OF FIGURES

Fig 1.1 Severstal Steel defects 각 Class별 예시	3
Fig 2.1 본 연구의 이미지 데이터로 나타낸 Semantic Segmentation 예시	6
Fig 2.2 결함을 포함한 이미지 & 결함을 포함하지 않는 이미지	10
Fig 2.3 Severstal Steel defects data	10
Fig 3.1 좌측 Severstal Steel data 기존 데이터, 우측 수정 보완한 Label	12
Fig 3.2 본 연구 데이터로 Image Augmentation 예시	12
Fig 3.3 (a) FCN에서 convolution layer 사용하여 위치정보 유지, (b) 기존 네트워크에서 Fc layer를 사용해, 위치정보 사라짐의 예시	14
Fig 3.4 (a) identity block, (b) convolution block	16
Fig 3.5 (a) 기존 Resnet50, (b) Segmentation을 위해 decoder 부분, U-Net의 decoder으로 교체	16
Fig 3.6 본 연구에 사용된 U-Net 구조	18
Fig 3.6 ResUnet의 아키텍처	20

Abstract

Steel surface segmentation models for defect detection

Seok Min Hwang

Advisor: Prof. Ho Yub Jung, Ph. D.

Dept. of Computer Engineering

Graduate School of Chosun University

This study attempts to determine steel defects after the rolling process. Steel is one of the most widely used materials in various industries, which is made by controlling carbon and various components in the iron ore. In the process of producing steel, rollers are used to shape steels into the thickness required by the customer. If the defects are not identified after rolling and the next process is carried out, it can lead to deterioration of the product quality and even facility accidents. For that reason, the inspection of defects in steel is the most important step in quality control. Therefore, this study intends to segment surface defects during the steel production process using deep learning techniques over the steel surface images.

In the defect inspection stage, two types of tests are usually performed: manual discriminatory inspection and automated surface deflection detection (SDD) inspection. The manual discriminant inspection, however, involves time consuming subjective intervention. In this paper, in order to address the problems of objectivity and time in defect steel inspection, we evaluate various different deep segmentation models on Severstal steel defects data set. The labeled areas were more precisely relabeled and data balanced. The classi

fication and size of defects measures are compared with various segmentation models with the aforementioned set. The accurate defect segmentation can aid in identifying each type of defect as well as determining the cause.

제 1 장 서론

1절 연구 배경

철강 제조업은 현대 산업에서 필수적이며 대체하기 어려운 기초 산업이며 철강 제품은 자동차, 전자제품, 가구, 무기, 가정용 자재, 기계, 조선 등과 같이 다방면으로 필요시 되는 산업 분야이다[1].

철강 제조업에서 강철의 품질관리는 제조업에서 최종 제품 품질에 영향을 미치기 때문에 매우 중요하다. 강철의 결함이 생산과정 및 성형 공정에서 다양하게 발생되는데 발생한 결함들은 제품 특징 및 수명을 단축시킬 수 있어 품질관리가 필요하다. 또한 강철의 결함이 불량률을 증가시키며 상당한 경제적 손실을 초래할 수 있기 때문에 더욱 그러하다[2].

강철의 표면 결함의 대표적인 예로 Fig1.1과 같이 pitted, crazing, scratch, patches 4가지가 있다. 이러한 결함을 검출 및 판별하는 검사는 검사자가 직접 육안으로 판별하는 수동 판별 검사와 SDD(surface defect detector) 두 가지 방법이 있다. 하지만 이 방법들 역시 낮은 성능과 검사자의 개입으로 지속적인 성능 개선이 요구된다.

이 두 가지 검사 방법 중 수동 판별 검사는 두 가지 단점이 있다. 첫 번째로 검사자가 영상 전체를 세밀하게 확인해야 하므로 검사시간이 오래 걸려 제조 공정의 지연으로 이어질 수 있다[1]. 두 번째는 검사자의 경험에 따라 결과가 달라진다는 점이다. 이는 검사자의 주관성이 들어가 검사 결과가 달라지는데 것인데, Fig1.1과 같이 작은 차이점 때문에 검사 결과가 달라질 수 있다는 점을 잘 보여주는 예시이다. 따라서 수동 판별 검사는 철강 결함 판별에 있어 품질 보증이 어렵다.

결함 판별 검사 중 SDD 결함 판별 검사는 지속적인 성능 향상이 진행 중이다. 검사자의 육안에 의한 수동 결함 판별 검사 시 분류 정확도가 70~80%인데 반해, SDD 결함 판별 검사는 아직 85%의 정확도를 나타내고 있다. 또한 SDD 결함 판별 검사는 수동 판별 검사보다는 빠르지만, 아직은 낮은 정확도를 보이고 분류 후 검사자가 한번 더 검사해야 한다는 단점이 있다.

강철의 제조 공정 중 발생하는 표면 결함은 검출-분류-평점산출을 거쳐 품질 기준을 만족 여부에 따라 정품 또는 불량으로 최종 판별된다. 결함의 종류, 크기,

위치 등에 품질 기준 점수에 산출되기 때문에 결함 검출뿐만 아니라 종류와 크기 탐지도 중요하다. 이와 관련하여 SDD 검사의 단점은 검출과 분류까지만 가능하다는 점이다. 또한 마지막 단계에서 검사자가 정품, 불량 판별을 위한 개입이 필요로 한다는 점이다.

본 연구에서는 수동 판별 검사로 인한 생산율이 감소하고 제품 불량률이 증가하는 단점들을 파악하고, SDD 판별 검사에서는 어려운 결함의 크기 또한 파악하는 방법을 다루어보고자 한다. 위와 같은 문제를 해결하기 위하여 본 연구에서는 severstal steel defect 데이터 셋을 사용하였다. 결함 판별과 크기 측정을 위해서 딥러닝 기법 중 Segmentation을 사용하고자 한다[17]. 금속의 표면 결함을 분류와 크기를 측정하기 위하여 Segmentation을 사용한다면, 2가지 측면이 개선될 것으로 보인다.

먼저 검사 시간 감소가 될 것이다. 수동 판별 검사와 SDD는 불량 판별을 위해선 검사자의 개입이 필요해 시간이 오래 걸렸지만 Segmentation을 사용한다면 자동으로 강철의 표면 결함을 판별, 크기를 측정하여 불량 판별과 원인 도출 시간을 단축시킬 수 있다. 다음으로는 검사자의 경험에 따른 주관성이 아닌 객관성을 갖고, 판별 검사를 할 수 있다는 점에서 개선될 것으로 기대된다. 객관성을 가진 검사 방법은 신뢰도 향상에 도움을 줄 수 있을 것으로 생각된다.

Steel defect

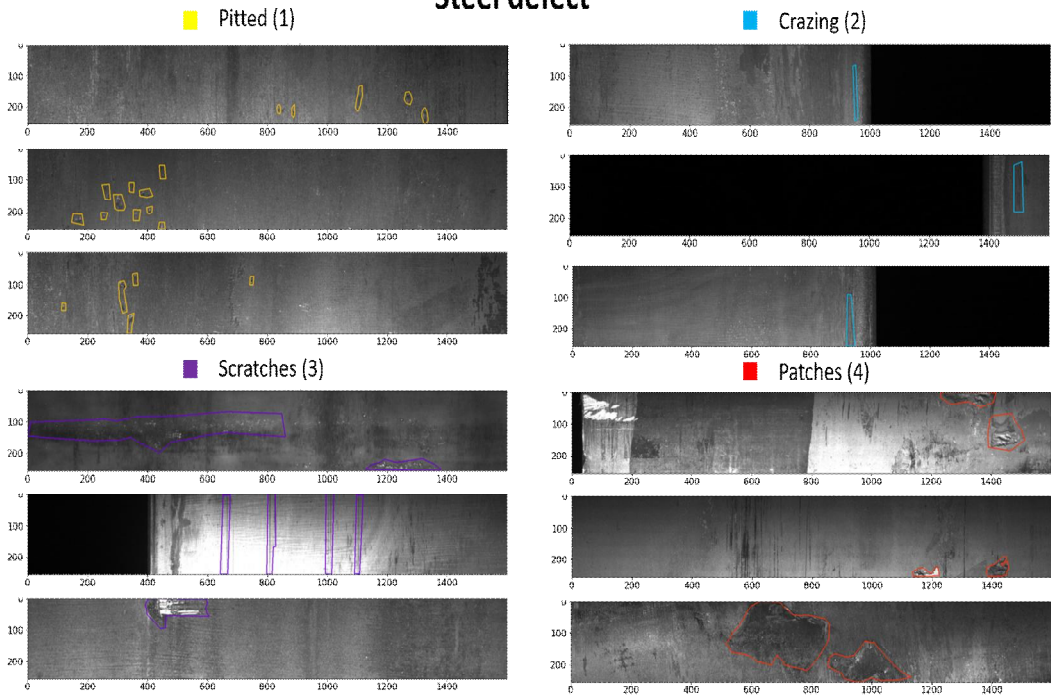


Fig 1.1 Severstal Steel defects 각 Class별 예시

2절. 연구 목적

결함 판별 검사는 많은 변수가 있다. 금속의 표면 재질의 특성과 검사를 실행하는 곳에 따라 조도가 다르며, 가공 과정에서 발생하는 불균일한 표면과 같은 변수들이 존재하기 때문에 결함 영역을 판별하는 것은 매우 어렵다[3]. 또한 산업에서 표면 결함 검사는 빠르고 높은 정확도를 필요로 하며 결함의 유무 외에 결함의 위치 정보와 크기 등이 필요한 경우도 있다. 난이도가 높은 결함 검사에는 필터 또는 검사자의 객관성에서 한계를 보이고 있다. 미세한 결함을 해상도가 높은 영상에서 발견해야 하는 경우 또한 있다.

본 연구에서는 Deep Learning CNN 기법 중 Segmentation을 활용하여 금속의 표면 영상에서 결함을 분류하고 크기를 측정하고자 한다. kaggle에서 공개데이터인 Severstal steel defects data를 사용하여 측정할 것이다. Severstal steel defects data의 표면 결함은 pitted, crazing, scratch, patches 등을 포함 하는데, 데이터 불균형 문제가 있으며, 몇몇 데이터는 영역 외 부분까지 labeling되어 있어 labeling을 다시 하여 Segmentation을 하고자 한다. 연구에 사용될 Segmentation 모델로는 VGG16, U-Net FCN, Resnet, ResUnet 등 CNN기반 모델들을 사용할 것이다. 최종적으로는 CNN기법 중 Segmentation(영상 분할)을 다양한 모델에 접목하여 각 모델 별 비교 분석을 할 것이다. 이를 통해 모델별 정확도를 확인하고, 생산과정 및 표면 결함 분석 실험 단계에서 결함의 종류 및 크기 분석을 용이하게 하고자 한다. 또한 표면 결함 분석에서의 객관성과 정확성을 증진시켜, 실험 및 공정에서의 결함을 감소시키고자 한다.

제 2 장 이론적 배경과 관련 연구

제 1 절 Segmentation과 표면결함

1. Segmentation

컴퓨터 비전은 이미지에서 객체의 의미 있는 정보를 수학적 알고리즘을 통해 추출하는 학문이다[8]. 컴퓨터 비전에서 Segmentation은 이미지 영상에서 이미지 내 있는 객체들을 분할하는 작업이다. Segmentation은 자율주행 자동차, 의료 영상 등 다양한 분야에서 중요한 기술로 소개되고 있다[19].

금속의 표면 이미지를 분석하면 물리적, 화학적 성질과 같은 정보를 알아 낼 수 있다. 최근 금속의 표면 이미지 분석과 딥러닝 기법 중 CNN을 접목하여 분석하는 연구가 활발하게 진행되고 있다[5]. 기존 금속의 표면 이미지 관찰에는 현미경을 통해서 사람이 직접 관찰하거나, 다소 단순하게 설계된 프로그램을 사용해왔다. 최근 CNN기법을 활용한 연구가 활발하게 진행되고 있다. CNN기법 중 Segmentation을 활용하여, 금속의 미세조직 이미지에서 미세조직을 분석하는 연구 분야가 있다[5]. SEM(투과 전자 현미경, Scanning Electron Microscope)을 사용하여 강철의 미세조직 상(Phase) 촬영한 MECS 데이터를 판별하는 연구다[5]. MECS 데이터의 미세조직 판별하는 방법으로 MVFCN을 사용되었다. MVFCN은 픽셀단위 영상 분할(pixel-wise segmentation) 방식으로 통하여 학습한다. 입력 데이터의 크기를 직접 조정하여, 차별성을 두었다. 학습에서 특징추출과 분류 단계를 분리하지 않고 end-to-end 방식으로 사용됐다. 다른 모델들과 분류 정확도 비교했을 때, CIFAR-NET은 57.03%, VGG16은 66.50%의 분류 정확도가 나왔다. 이에 반하여 MVFCN을 사용할시 93.94%의 분류 정확도를 보였다. 이 실험은 강철 실험 중 어떤 강철인지, 어떤 성질을 가지고 있는지 등 다양한 정보를 예측할 수 있다. 기존 실험처럼 금속의 영상 데이터와 딥러닝의 접목은 활발하게 연구, 발전되고 있다.

본 연구에서는 Semantic Segmentation을 사용하여 강철의 결함을 판별 및 측정하였다. Semantic Segmentation은 Fig2.1과 같이 영상에서 해당하는 객체의 Pixel을 Pixel 단위로 물체를 구분한 뒤, 해당 Pixel이 어떤 Class인지 예측하는 것이

다[6]. Segmentation을 사용하여 본 연구에서는 금속의 표면결함을 판별하고자 한다.

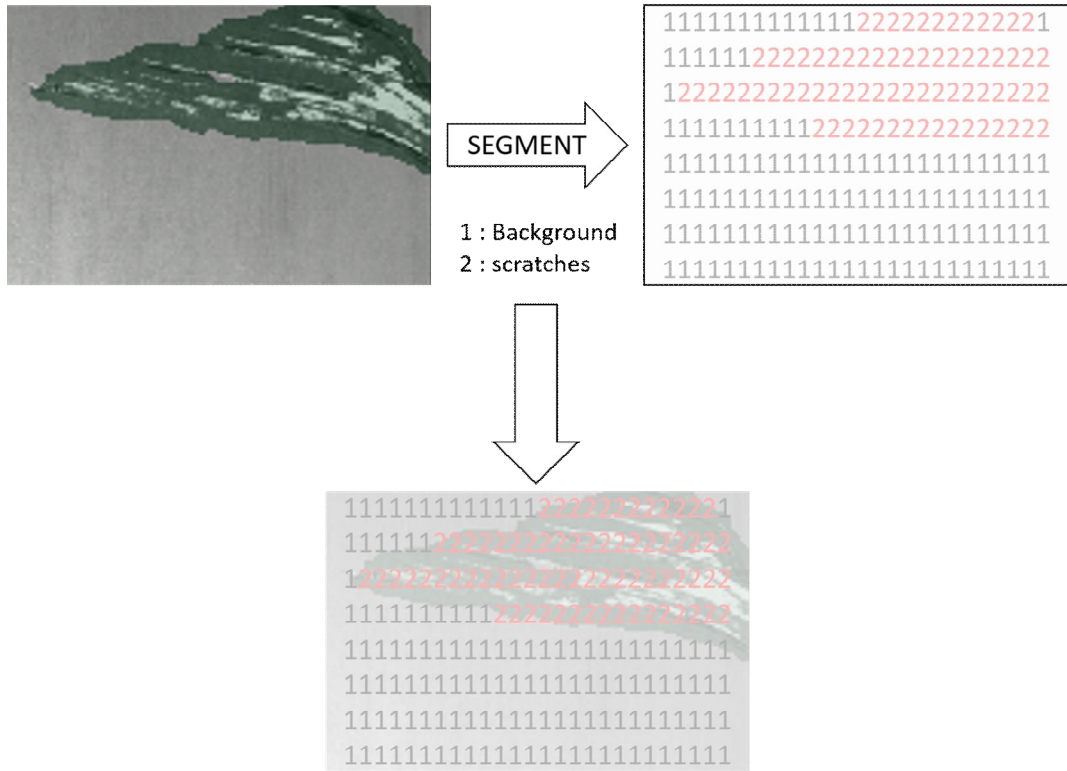


Fig 2.1 본 연구의 이미지 데이터로 나타낸 Semantic Segmentation 예시

2. 금속의 표면 결함 판별

금속의 표면 이미지를 통하여 많은 정보를 얻을 수 있다. 앞선 Segmentation 연구에서는 구상 흑연 주철 이미지 내 구상 흑연을 판별 연구를 하였다. 미세조직 이미지에서 구상 흑연을 Segmentation하여, 크기와 분율을 계산하였다[7]. 또한 색상, 형태적 유사성을 갖는 다른 흑연들까지 인식되던 이전 판별 방식을 개선하였다[19]. Table 2.1과 같이 기존 연구에서는 개선된 방식에서 계산된 크기와 분율로 구상 흑연 주철 연구의 간소화와 성능평가에서 조금 더 높은 객관성을 확보할 수 있다.

강철 표면 결함 종류는 pitted, crazing, scratch, patches등을 포함된다. 표면 결함은 제조공정 중 발생되는데, 검출, 분류, 평점 산출 3가지 과정을 거쳐 품질 기준 만족 여부에 따라 정품과, 불량으로 판정된다. 평점 산출은 결함의 종류 크기 위치에 따라 평점이 산출되며, 결함 생성의 인과관계를 파악할 수 있다.

결함 판별 방식은 크게 두 가지 방법이 있다. 사람이 직접 결함을 판별하는 방법과 SDD(surface steel defects)이 있다.

2가지 방법 중 검사자가 직접 판별하는 방식은 2가지 단점이 있다. 첫 번째로 사람이 직접 판별하기엔 미세한 차이가 있어, 높은 숙련도가 필요하다. 두 번째로 수동 작업으로 검사 시간이 많이 소요된다.

SDD(surface defect detector)기법을 사용한 판별 검사가 있다. SDD는 열간 압연 후 표면에서 결함을 판별한다. 앞에서 설명한 검출, 분류, 평점 산출 3가지 과정 중 SDD는 검출과 분류 두 가지를 할 수 있다. 이후 마지막 평점 산출은 검사자가 산출한다. 평점 산출 단계에서 공정 지연으로 이어진다.

본 연구에서는 Segmentation을 사용하여, 기존 SDD에서 평점 산출이 되지 않는 점을 보완하고자 한다. 보완하기 위해서 다양한 Segmentation 모델들을 사용하여 각 모델 별 판별 정확도와 크기를 측정하여 비교하였다.

Table 2.1 U-Net의 예측 값과 기존 판별에 사용되는 ImageJ[21] 비교 평가, Ground Truth와 가까운 값이 더 높은 정확도를 갖음

	구상 흑연 Ground Truth 분율 (픽셀의 수)	U-net Predicted 분율 (픽셀의 수)	ImageJ ^[18] 분율 (픽셀의 수)
Img1	16.6% (10,917)	16.4% (10,781)	16.9% (11,075)
Img2	2.4% (1,591)	2.2% (1,441)	2.8% (1,836)
Img3	11.3% (7,408)	11.0% (7,208)	11.4% (7,471)
Img4	13.5% (8,869)	13.4% (8,847)	14.9% (9,764)
Img5	14.1% (9,278)	14.2% (9,301)	14.5% (9,511)
Img6	15.4% (10,115)	15.2% (9,981)	15.4% (10,151)
Img7	10.5% (6,915)	10.5% (6,882)	10.3% (6,782)
Img8	3.6% (2,378)	3.5% (2,329)	3.8% (2,517)

제 3 장 실험 방법

제 1 절 데이터 셋 구축

1. Severstal Steel Defects Data

강철의 표면 결함 판별을 위한 Segmentation 데이터로는 Severstal steel defects 데이터를 사용하였다. 압연 공정은 철강 소재를 두 개의 롤러 사이에 통과시켜 가공하는 공정이다[9]. 압연공정 후 결함을 판별을 한다. 판별에 사용되는 영상 이미지가 Severstal Steel Defects다. 빠른 속도로 진행 중인 표면에서의 결함을 검출하지 못하게 된다면, 후 공정에서 품질 악화, 설비 사고로 이어질 수 있다. 때문에 표면 결함은 빠르고 정확하게 판별하는 것이 중요하다.

Severstal Steel defects 데이터 셋은 총 12,568개의 이미지가 있으며, 그 중 5,902개의 정상 이미지, 6,666개의 결함 이미지가 포함되어 있다. Fig2.2는 결함이 있는 표면과 정상 표면의 예시이다. 결함이 있는 6666개 이미지는 Fig2.3와 같이 4가지로 분류된다.




Fig 2.2 결함을 포함한 이미지 & 결함을 포함하지 않는 이미지




Fig 2.3 Severstal Steel defects data

2. Data labeling

본 연구에서 사용된, Severstal steel defects는 결함이 포함된 이미지는 두 가지 문제점이 있다. 심각한 데이터 불균형 문제와 몇몇 이미지에서 실제 결함 이외의 배경부분까지 Labeling이 되어있다. 데이터 불균형 문제에서는, Fig2.3과 같이 4가지 Class중 Scratches는 5150개, 가장 적은 Craziing은 247개를 차지한다. 약 20배 차이가 나는 데이터 불균형 문제는 비중이 큰 데이터에서 정확도가 높아지고, 비중이 작은 데이터에서는 정확도가 낮아지는 문제가 생긴다. 다음으로 Fig 3.1에서와 같이 실제 결함 이외에 배경영역까지 Labeling된 이미지들이 있다.

본 연구에서는 이러한 두 가지 문제 중 Class 불균형을 해결하기 위해 Class별 각 250여장 씩 down sampling을 진행하였다. 다음으로는 Labeling이 결함 이외의 배경영역까지 된 이미지들은 Labeling을 직접 다시 진행 하였다. 진행된 Labeling은 Fig3.1에서 우측 Custom label과 같이 배경 부분을 최소화하였다. 충분한 학습을 위해 Labeling된 이미지 데이터를 data augmentation을 통해 데이터의 양을 늘렸다[18]. data augmentation을 진행하기 위해, Fig3.2와 같이 albumentation을 사용했다[10]. 그 중 vertical flip, horizontal Flip, rotate(180, 330), contrast(1.5, 2.0) 총 6가지 방법을 사용했다. 마지막으로 256X1600 Pixel 사이즈의 이미지를 128X512 Pixel로 Cropping하여 18,000여장으로 데이터 셋을 구성했다. 구성된 데이터를 사용하여, Segmentation을 진행하였다.




Fig 3.1 좌측 Severstal Steel data 기존 데이터, 우측 수정 보완한 Label

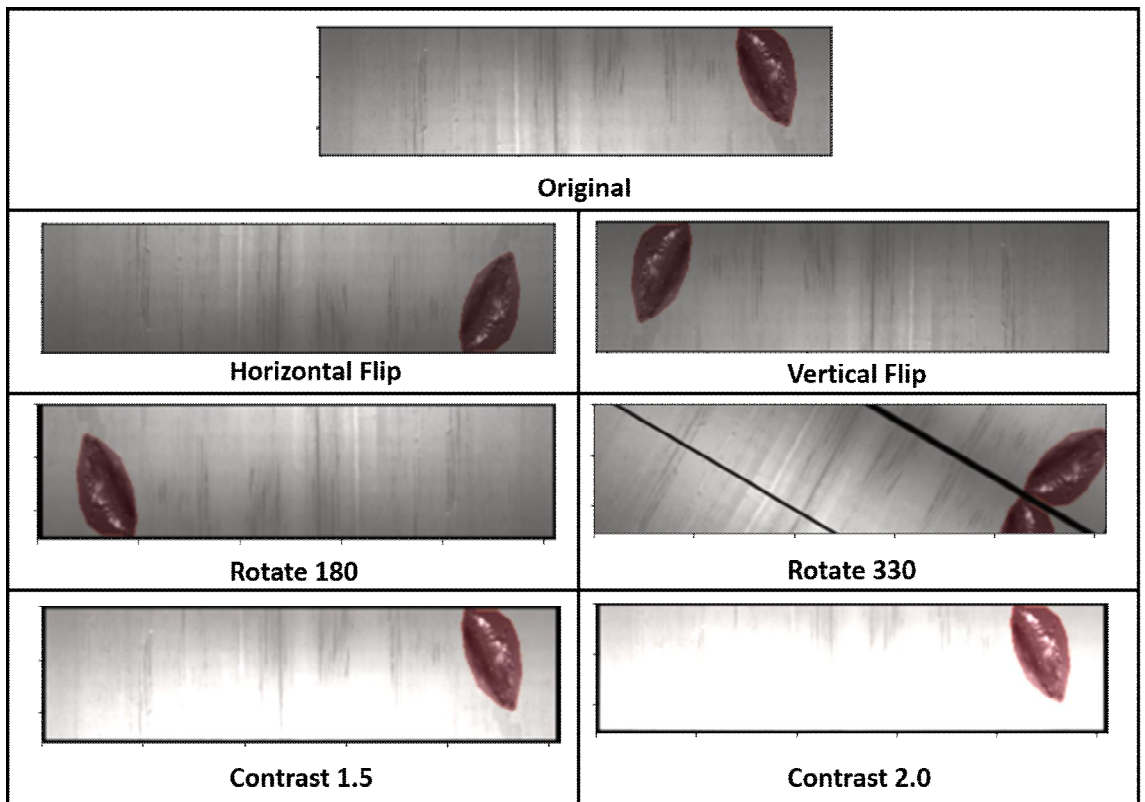


Fig 3.2 본 연구 데이터로 Image Augmentation 예시

제 2 절 모델별 특징

학습에는 Labeling 데이터를 사용하였다. 학습을 위한 10,800장, 검증을 위한 3,600장, 테스트를 위한 3,600장의 이미지로 구성했다. 네트워크는 FCN, Resnet, U-Net, ResUnet를 비교 평가했다. 실험 환경은 Tensorflow2.0 진행했으며, Table 3.1과 같이 하이퍼 파라미터는 공통되게 진행했다. input size는 128*512로 고정하였다. 평가지표로 Segmentation에서 많이 쓰이는 Dice Coefficient와 IoU를 사용하였고, loss함수는 Dice loss와 focal loss를 사용하였다[14]. Learning rate는 ReduceLR0nPlateau을 사용하였다. 모델의 개선이 없을 경우에 Learning Rate를 조절해 모델의 개선을 유도한 것이다. 모델의 개선 효과를 기대할 수 있다.

Table 3.1 공통 하이퍼 파라미터

input image	128*512
learning rate	ReduceLR0nPlateau
metrics	dice coefficient, IoU
loss	dice loss, focal loss

1. FCN (Fully Convolutional Networks)

FCN은 2015년 CVPR에 Semantic Segmentation을 위해서 제안된 네트워크다[6]. 기존 이미지 분류에서 강한 성능을 보인 AlexNet, VGG16, GoogLeNet을 목적에 맞게 변형시킨 것이다. 기존 네트워크들은 Fig 3.3의 (b)와 같이 Fc layer(Fully-connected layer)를 사용해, 1차원 벡터로 변환된 레이어를 하나의 벡터로 연결하여, 활성화 함수를 통해 가장 확률이 높은 Class를 output으로 분류한다. FCN은 Fc layer를 Fig 3.3의 (a)와 같은 컨볼루션 레이어로 대체 후, Upsampling을 거쳐 input image와 같은 사이즈의 특징맵을 만든다. 만들어진 특징맵은 위치정보를 가지고 있으며, 특징맵을 분류하여 나온 결과 값을 통해, 픽셀을 분류하여 Segmentation을 한다.

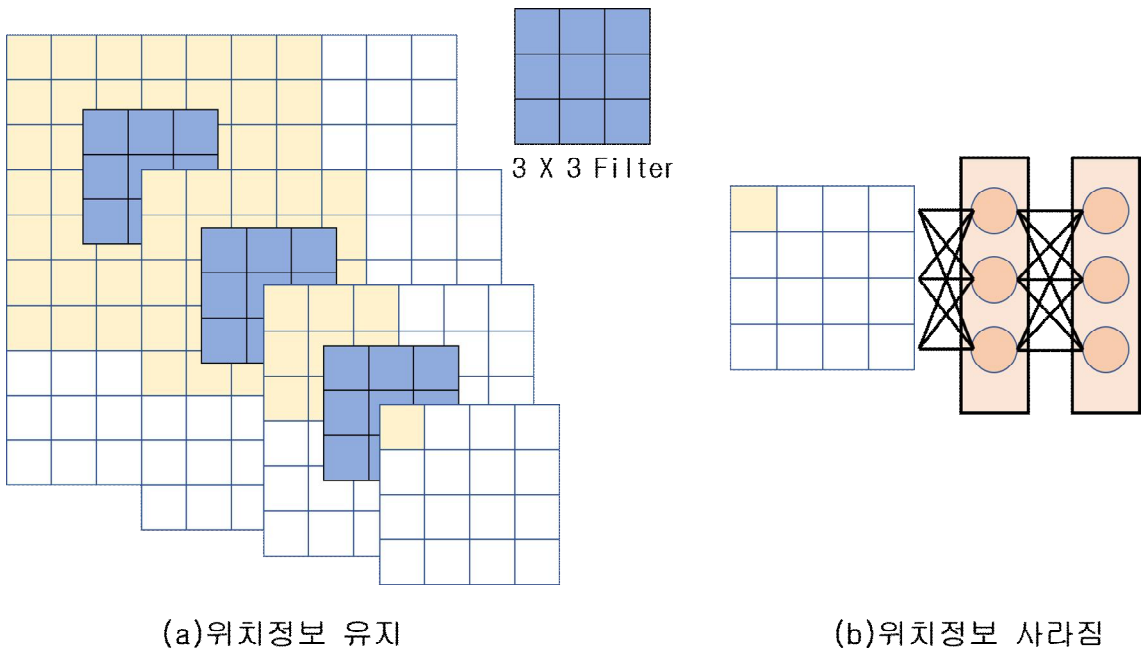


Fig 3.3 (a) FCN에서 convolution layer 사용하여 위치정보 유지, (b) 기존 네트워크에서 Fc layer를 사용해, 위치정보 사라짐의 예시

2. Resnet

Resnet은 학습에서 layer가 깊어짐에 따라 보이는 기울기 소실(gradient vanishing)문제를 해결하기 위해 고안된 네트워크이다[11]. 문제점을 해결하기 위해 제안된 방법이 residual learning이다[20]. 기존 네트워크에서 입력 값 x 가 layer를 거쳐 $H(x)$ 를 출력하는데, residual learning은 출력 값과 입력 값의 차이인 $F(x) = H(x) - x$ 를 구해, $H(x) = F(x) + x$ 를 최소화 시켜 출력 값과 입력 값의 차이를 줄이는 것이다. $F(x) = 0$ 이 되도록 학습하여 $H(x) = 0 + x$ 가 되도록 한다. 더해진 x 가 1이 되어 미분을 했을 때, 기울기 소실 문제가 해결된다. Resnet은 Identity block, convolution block으로 구성된다. Identity block은 Fig 3.4의 shortcut connection으로 만든 Identity block이다. 앞서 설명한 네트워크의 출력 값에 x 를 더하는 것이다. 다음으로 convolution block은 convolution연산 후 $F(x)$ 에 x 를 더한다.

Fig 3.5 (a)의 구조처럼 Resnet은 분류를 위한 네트워크다. 본래의 Resnet은 classification을 목적을 두고 제안된 모델이다. Fig 3.5 (b)처럼 Segmentation을 위해서는 Decoder 부분을 변경해 주어야 한다. 본 연구에서는 U-Net의 decoder를 사용하여 진행했다.

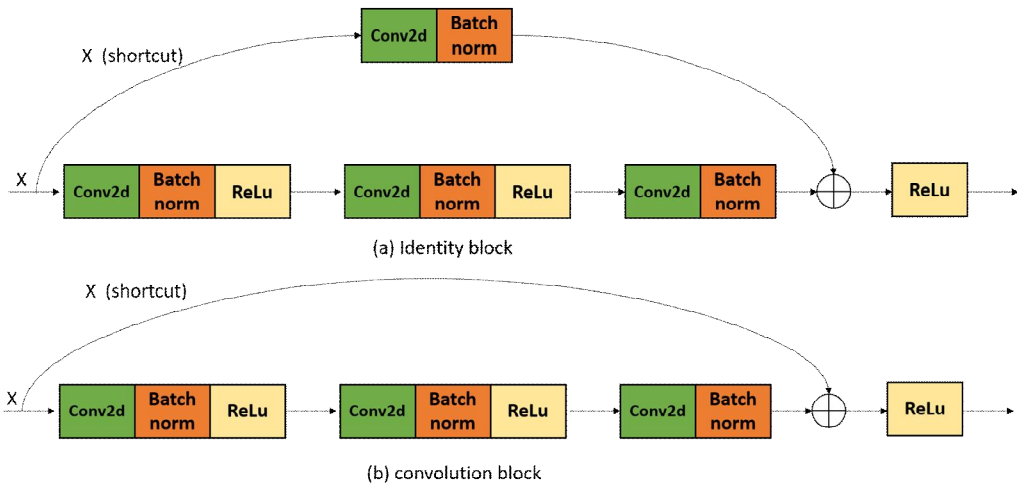


Fig 3.4 (a) identity block, (b) convolution block

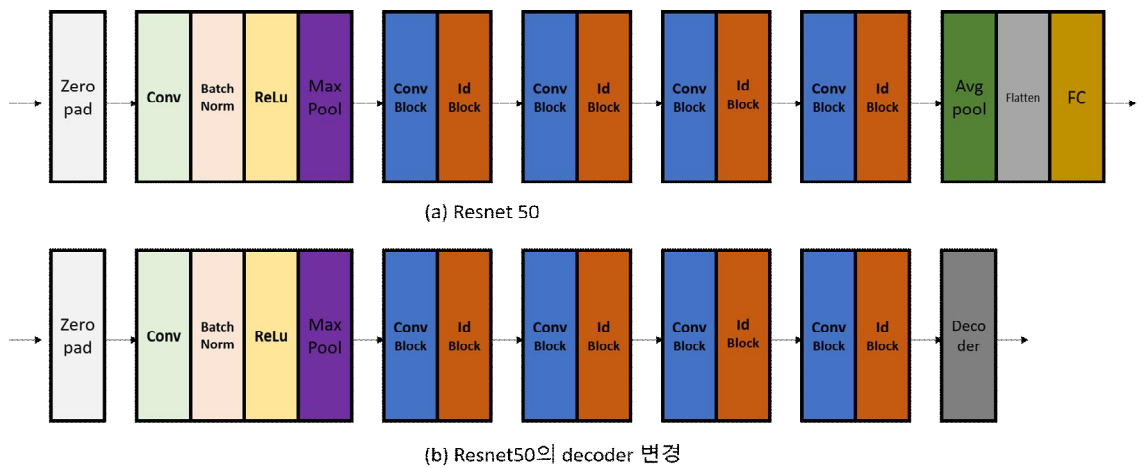


Fig 3.5 (a) 기존 Resnet50, (b) Segmentation을 위해 decoder 부분, U-Net의 decoder으로 교체

3. U-Net

U-Net의 구조는 Fig 3.6과 같이 U 형태를 가지고 있어 U-Net이라 불린다. FCN 기반 모델로 의료 영상 분야에서 Segmentation 목적을 두고 제안되었다[12]. Fig 3.6과 같이 앞부분의 Contracting path와 뒷부분의 Expanding Path로 이루어져 있다[10]. 앞부분의 Contracting path는 Input data의 Context포착을 위한 목적으로 구성되어 있으며, 뒷부분은 Expanding Path로 localization을 위한 구성이다. Skip architecture 개념을 사용해 Contracting path에서 나온 특징맵과 각 Expanding 스텝 마다 결합하는 방식이다[13]. 이는 Contracting path의 최종 특징맵으로 부터 보다 높은 해상도의 결과를 얻기 위해 행해진다[19].




Fig 3.6 본 연구에 사용된 U-Net 구조

4. ResUnet

ResUnet은 Deep Residual U-Net을 나타낸다. 더 적은 수의 매개변수로 성능을 향상 시키도록 설계된 Fully convolution 신경망이다[13]. ResUnet은 기존 U-Net 구조를 Residual learning을 활용하여 개선된 모델이다[21]. Resnet의 특징처럼 깊은 네트워크를 구축하는데 도움을 주며, gradient를 개선하는 데 도움이 된다. ResUnet은 U-Net과 마찬가지로 인코딩 네트워크, 디코딩 네트워크 및 이 두 네트워크를 연결하는 브리지로 구성된다. U-Net은 2개의 3 x 3 컨볼루션을 사용하며 각각 뒤에 ReLU 활성화 함수가 온다. ResUnet의 경우 이러한 계층은 사전 활성화된 잔여 블록으로 대체된다[16].

제 4 장 결과 및 분석

제 1 절 각 모델별 결과

다양한 결과 비교를 위해서 평가 함수 Dice Coefficient와 IoU를, loss 함수는 Dice loss와 focal loss를 사용했다. Dice Coefficient와 IoU는 영상, 이미지 등에서 ground truth와 예측된 영역과의 차이를 알기 위해서 사용되며, Ground Truth와 예측된 영역이 일치할수록 1에 가까워진다[15].

Table 4.1은 Dice Coefficient, IoU 비교결과를 확인할 수 있다. Dice Coefficient는 Dice loss, IoU에서는 focal loss를 사용했다. ResUnet, Resnet, U-Net, FCN 순서로 높은 결과가 도출되었다.

Table 4.1 Dice Coefficient, IoU 결과 비교

Method	Dice Coefficient (Dice loss) (test)	IoU (Focal loss) (test)
FCN	0.7154	0.7284
Resnet	0.9229	0.9104
U-Net	0.9080	0.9027
ResUnet	0.9387	0.9419
SDD	80~85% 검출	

제 2 절 각 모델별 결과와 Ground Truth와 비교 검증

품질 기준 점수는 표면 결함의 종류, 크기, 위치를 사용해 산출된다. 그 중 크기 측정을 위해서 테스트 이미지 8장의 픽셀 개수를 측정했다. Pixel의 개수가 Ground Truth와 예측 값 간의 차이가 적은 값들이 정확하며, 비교를 위해서 측정값을 이미지 전체 사이즈에 차지하는 비율로 표기했다.

Table 4.2과 Table 4.3에서 Ground Truth와 4가지 모델 예측 결과의 비교 측정을 확인 할 수 있다. Table 4.1과 같이 FCN의 예측 결과가 Ground Truth와 가장 큰 차이를 보였으며, ResUnet의 예측 결과가 가장 차이가 적게 나타나, 가장 의미 있는 결과를 도출했다.

Table 4.2 Dice Coefficient, Dice loss의 결과, 이미지 전체 사이즈에 차지하는 Pixel 비율을 측정한 결과 값

	Ground Truth (Pixel count)	ResUnet (Pixel count)	Resnet (Pixel count)	Unet (Pixel count)	FCN (Pixel count)
img 1	1.94%	2.12%	2.15%	2.36%	2.87%
img 2	3.78%	3.94%	4.07%	3.80%	4.71%
img 3	2.72%	3.04%	2.75%	3.11%	4.09%
img 4	1.16%	1.48%	1.52%	1.91%	2.20%
img 5	1.68%	2.03%	2.25%	2.20%	2.57%
img 6	3.31%	3.68%	2.86%	4.25%	4.84%
img 7	1.75%	2.12%	2.28%	2.39%	2.56%
img 8	1.44%	1.70%	1.84%	2.10%	0.92%

Table 4.3 IoU, focal loss의 결과, 이미지 전체 사이즈에 차지하는 Pixel 비율을 측정한 결과 값

	Ground Truth (Pixel count)	ResUnet (Pixel count)	Resnet (Pixel count)	Unet (Pixel count)	FCN (Pixel count)
img 9	2.49%	2.74%	2.89%	2.92%	3.19%
img 10	3.99%	4.25%	4.32%	4.58%	4.90%
img 11	1.95%	2.11%	2.13%	2.41%	2.73%
img 12	1.58%	1.78%	1.66%	1.98%	2.16%
img 13	2.22%	2.43%	2.30%	2.48%	2.89%
img 14	4.36%	4.57%	4.25%	4.47%	5.02%
img 15	2.52%	2.72%	2.86%	2.92%	3.35%
img 16	2.64%	2.88%	2.92%	2.91%	3.50%

제 5 장 결론 및 향후연구

본 논문에서 강철의 표면 결함 분류를 위해 4가지 Segmentation 모델비교를 했다. 기존 판별 방법인, 사람이 직접 판별 방식과, SDD방식에서의 낮은 정확도, 공정지연을 보완을 목적으로 두었다.

Severstal steel defects 데이터는 두 가지 문제가 있었다. 데이터의 불균형과 데이터에서 labeling 영역이 배경 영역까지 지정되어있어, 이를 해결하기 위해 labeling을 직접 다시 학습데이터를 제작하였다.

예측 결과는 FCN에서 결과가 가장 부정확하게 나왔으며, ResUnet의 결과가 제일 정확하게 측정되었다. 기존 SDD에서는 검출과 분류까지만 되었는데, SDD보다 약 8~10% 향상된 결과다.

예측된 결과의 픽셀 개수를 통해 크기를 측정하여, 기존 검사자가 진행하였던 평정산출을 자동으로 할 수 있어, 결함 판별 시간이 단축되었다.

본 연구의 실험 결과를 통해, 연구의 개선이 세 가지 가능할 것으로 보인다. 먼저 첫 번째로 강철 결함 이미지의 다양성을 높이는 것이다. 결함 데이터는 조도와 같은 검사장의 환경에 따라 달라진다. 다양한 환경에서 생성된 데이터를 사용하면, 다양한 환경에서 사용가능한 모델을 학습시킬 수 있다.

두 번째로 현재 학습에 들어가는 이미지 데이터는 결함 데이터 Scratches가 대부분인 데이터로서, 데이터 불균형이 있다. 이후 실험에서는 다른 결함들도 균등하고, 다양하게 가지고 실험한다면, 조금 더 높은 결과를 가질 수 있을 것으로 보인다.

본 연구에서는 Segmentation기법 중 Semantic Segmentation으로 진행 하여 강철의 결함을 분류 및 측정하였는데, 마지막 세 번째 개선 방향으로는 Segmentation 기법 중 Instance Segmentation으로 진행하는 것이다. Instance Segmentation은 이미지 내 같은 객체라도 서로 다른 instance로 구분해주는 것이다. 각 강철의 결함 하나씩을 객체로 두어 개수를 측정한다면, 분류된 결함 이미지에서의 크기, 개수, 위치 정보를 이용하여 결함 생성 원인 도출과 공정 속도 또한 빨라질 것으로 보인다.

참 고 문 헌

- [1] 이민기, 서기성, "금속 표면의 결함 검출을 위한 영역 기반 CNN 기법 비교", 전기학회 논문지 67권, 7호, 865-670쪽, 2018년 07월
- [2] 장지원, 안효준, 이종한, 신수봉, "블레이드의 표면 결함 검출을 위한 Faster R-CNN 딥러닝 모델 구축", " Journal of the Korea Institute for Structural Maintenance and Inspection Vol. 23, No. 7 pp.80-86 2019년 12월
- [3] Pauly, Seyed Majid Azimi, Dominik Britz, Michael Engstler, Mario Fritz & Frank Mücklich, "Advanced Steel Microstructural Classification by Deep Learning Methods", Scientific Reports, volume 8-1, pp.1-14, 01 February 2018
- [4] 이한규, 유철환, 신용구, 임세호, 고성제, "CNN을 활용한 Sementic segmentation 기반의 패션 아이템 검출", 2017년도 대한전자공학회 정기총회 및 추계학술대회, 512-515 쪽, 한국, 2019년 8월
- [5] Seyed Majid Azimi, Dominik Britz, Michael Engstler, Mario Fritz & Frank Mücklich, "Advanced Steel Microstructural Classification by Deep Learning Methods", nature Scientific Reports, volume 8-1, pp.1-14, 01 February 2018
- [6] Jonathan Long, Evan Shelhamer, Trevor Darrell "Fully Convolutional Networks for Semantic Segmentation" Computer Vision and Pattern Recognition volume 2 08 mar 2015
- [7] 방현식, 김선중, "고용강화 페라이트계 구상흑연주철의 미세조직 및 기계적 성질에 미치는 합금원소의 영향" 학위논문(석사)-조선대학교 대학원 : 첨단소재공학과 2021년 2월
- [8] 김영광, 김진술, "자율주행 환경에서 이미지 객체 분할을 위한 강화된 DFCN알고리즘 성능연구", 스마트미디어 저널 9권 4호, pp9~16, 2020년 12월

- [9] 김영환, "실시간 압연하중 및 압연동력 예측 모델의 개선", Proceedings of the Korean Society for Technology of Plasticity Conference (한국소성가공학회:학술대회논문집), pp.52-55, 2000년 04월
- [10] Alexander Buslaev 1,Vladimir I. Iglovikov 2ORCID,Eugene Khvedchenya 3ORCID,Alex Parinov 4,Mikhail Druzhinin 5ORCID andAlexandr A. Kalinin 6,7,*ORCID, "Albumentations: Fast and Flexible Image Augmentations", MDPI, volume 11 issue 2, 20 Feb 2020
- [11] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, "Deep Residual Learning for Image Recognition", Computer Vision and Pattern Recognition, 10 Dec 2015
- [12] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", Computer Vision and Pattern Recognition, 18 may 2015
- [13] Foivos I. Diakogiannis, François Waldner, Peter Caccetta, Chen Wu, "ResUNet-a: a deep learning framework for semantic segmentation of remotely sensed data", Computer Vision and Pattern Recognition, 1 Apr 2019
- [14] Hamid Rezatofighi, Nathan Tsoi, JunYoung Gwak, Amir Sadeghian, Ian Reid, Silvio Savarese, "Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression", Computer Vision and Pattern Recognition, 25 Feb 2019
- [15] Reuben R Shamir, Yuval Duchin, Jinyoung Kim, Guillermo Sapiro, Noam Harel, "Continuous Dice Coefficient: a Method for Evaluating Probabilistic Segmentations", Computer Vision and Pattern Recognition, 26 Jun 2019
- [16] Zhengxin Zhang, Qingjie Liu, "Road Extraction by Deep Residual U-Net", IEEE

GEOSCIENCE AND REMOTE SENSING LETTERS, pp749~753, Vol.15 No5, May 2018

- [17] Mohammadreza Yazdchi ,Mehran Yazdi, Arash Golibagh Mahyari, "Steel Surface Defect Detection Using Texture Segmentation Based on Multifractal Dimension", 2009 International Conference on Digital Image Processing, pp346~350, August 2009
- [18] Abol Basher, Byeong C Kim, kun ho Lee, ho yub jung, "Automatic Localization and Discrete Volume Measurements of Hippocampi From MRI Data Using a Convolutional Neural Network" , IEEE Access PP(99):1-1, January 2020
- [19] 전우태, 장원석, 김종찬, "자율주행 자동차 객체 인지 시스템의 스케줄 최적화" , 한국 자동차공학회 추계학술대회 및 전시회, 891-892쪽, 경주화백컨벤션센터(경상북도 경주시), 한국, 2019년 11월
- [20] 김운기, 조성원, Fatemeh Dehghan, "Vehicle License Plate Recognition, Deep Learning, SSD-MobileNet, ResNet" , 스마트미디어저널, 9 권 2 호, pp 92 ~ 98 2019년 06월
- [21] Abramoff, M.D.; Magalhães, Paulo J.; Ram, Sunanda J. "Image processing with ImageJ" Biophotonics international, (2004) volume 11, issue 7, pp. 36 - 42 (Article)