ISSN 1975-8359(Print) / ISSN 2287-4364(Online)
The Transactions of the Korean Institute of Electrical Engineers Vol. 67, No. 7, pp. 865~870, 2018
http://doi.org/10.5370/KIEE.2018.67.7.865

# 금속 표면의 결함 검출을 위한 영역 기반 CNN 기법 비교

## Comparison of Region-based CNN Methods for Defects Detection on Metal Surface

이 민 기* · 서 기 성†
(Minki Lee · Kisung Seo)

**Abstract** - A machine vision based industrial inspection includes defects detection and classification. Fast inspection is a fundamental problem for many applications of real-time vision systems. It requires little computation time and localizing defects robustly with high accuracy. Deep learning technique have been known not to be suitable for real-time applications. Recently a couple of fast region-based CNN algorithms for object detection are introduced, such as Faster R-CNN, and YOLOv2. We apply these methods for an industrial inspection problem. Three CNN based detection algorithms, VOV based CNN, Faster R-CNN, and YOLOv2, are experimented for defect detection on metal surface. The results for inspection time and various performance indices are compared and analysed.

**Key Words** : Defects detection, Metal surface, Convolution neural network, Faster R-CNN, YOLOv2

## 1. 서 론

제품의 표면 결함은 긁힘, 갈라짐, 찍힘, 패임, 얼룩 등을 포함한다. 표면 재질의 특성에 따라 조명 반사가 심하거나, 가공과정에서 발생하는 불균일한 무늬 등이 존재하기 때문에 정상 영역과 결함 영역의 구별이 매우 어렵다. 산업용 표면 결함 검사는 높은 정확도와 빠른 처리가 필요하며, 결함의 유무 외에 검출 위치에 대한 표시가 필요한 경우가 많다.

한편, 적용 기법의 측면을 보면 전통적인 필터 기반의 접근법[1], 필터와 SVM등의 기계학습을 결합한 접근법[2], 그리고 CNN(Convolutional Neural Network)[3] 등을 이용한 딥러닝 접근법이 있다. 난이도가 높은 결함 검사에는 필터 또는 검출자 기반의 접근이 성능의 한계를 보이고 있다. 조명의 불균일한 반사나 표면이 균일하지 않은 경우, 결함과 주변의 구분이 명확치 않기 때문에 결함을 검출하기가 더욱 어렵다. 또한 해상도가 높은 영상에서 작은 결함을 발견을 해야 하는 경우도 종종 있다.

따라서 이러한 문제를 해결하기 위하여 최근 물체 인식에 탁월한 성능을 보이고 있고 계속적인 발전이 이루어지고 있는 딥러닝 기법을 결함 검사에 적용하는 연구들이 늘고 있다[4-6]. 특히, CNN은 자동적인 특징 추출 기능이 강력하여, 특징 추출을 위한 전처리 필터가 필요하지 않다고 알려져 있다. 기존의 딥러닝 접근법들은 주로 물체에 대한 검출 시도가 대부분이기 때문에, 결함에 대해서 적용 시 객체와의 특성 차이를 분석하고 이를 알고리즘에 반영하는 것이 필요하다.

선행 연구에서 VOV[7] 필터와 CNN을 결합하여 표면 결함에 대한 검출을 시도하였다[6]. 이 방법은 ROI의 수가 비교적 적어서 처리 속도 면에서 장점을 가지나, 검출성능이 만족스럽지 않았다. 후속 연구로 R-CNN[8,9] 기반 접근법 중 가장 최신 방법인 Faster R-CNN[10]을 사용하여 검출 성능과 속도를 향상시켰다[11]. 또한, YOLOv2[12] 기법을 적용하여 Faster R-CNN 접근법과 비교한 연구도 수행하였다[13]. 본 논문에서는 이러한 사전 연구를 확장하여, 산업용 결함 검사 데이터에 대해서 CNN 기반의 상기의 검출 기법들간의 비교 실험을 수행하고 성능을 분석한다.

## 2. 결함 검사 구분 및 위치검출

### 2.1 결함 검출 문제의 특성

산업용 부품 등에서 표면 결함의 종류는 크랙, 스크래치, 흠집 등을 포함한다. 표면이 균일하지 않거나 매끄럽지 않은 경우, 표면 배경과 결함의 구별이 매우 어렵다. 그림 1은 관련 금속 부품의 표면 예이다. 조명의 불균일로 인한 주변의 배경 영상이 결함과 잘 구별되지 않는 경우가 많다. 재질 특성과 가공 과정에서 포함되는 배경 무늬들과 조명의 결합은 결함의 검출을 더욱 어렵게 한다.

### 2.2 결함의 분류 및 위치 검출

산업용 부품에 대한 결함 검사는 결함 위치가 고정되어 있고, 결함의 여부나 종류만을 판단하는 결함 분류의 문제와 결함의 위치까지 판별해야 하는 결함 검출 문제로 나눌 수 있다. 더욱이

† Corresponding Author : Dept. of Electronics Engineering, Seokyeong University, Korea.
E-mail : ksseo@skuniv.ac.kr
* Dept. of Electronics Engineering, Seokyeong University, Korea.
Received : May 5, 2018; Accepted : May 22, 2018

Copyright ⓒ The Korean Institute of Electrical Engineers

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.

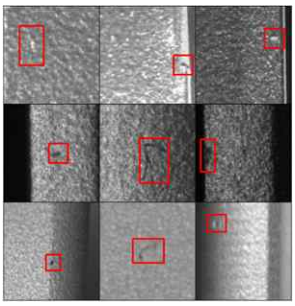

그림 1 표면 결함의 예
Fig. 1 Exmaples of surface defects

대상 부품이 평면이 아닌 경우, 캠이나 부품을 이동시켜 다수의 영상을 얻어야하기 때문에 이 과정에서 조명의 난반사 초점의 흐림 현상이 나타나 검출 조건을 어렵게 만들 수 있다. 본 논문에서는 후자를 다룬다. 아래 그림 2는 검사 대상 부품을 고해상도 캠을 이동시키며 금속 부품의 표면을 촬영하고 결함을 검출하는 시스템의 개념도이다.

## 3. CNN 기반 결함 검출 기법

### 3.1 CNN(Convolutional Neural Network)

CNN[3]은 1989년 LeCun이 발표한 기법으로, 영상인식에 주로 사용되는 딥러닝 기법이다. 기존의 전통적 물체 분류 알고리즘보다 10%이상 좋은 성능을 보이면서 ILSVRC-2012[8]부터 주류 알고리즘으로 사용되고 있다.

CNN은 특징들을 사전에 추출하지 않고, 입력 층에 영상 데이터를 입력하여 특징이 자동 추출되는 특징을 가지고 있다. 이미지를 입력받아 특징을 자동으로 추출한다.

컨볼루션(convolution) 층과 풀링(pooling) 층이 교대로 반복되는 구조를 이룬다. 컨볼루션(합성곱) 연산은 이미지를 흐릿하게 하거나 모서리나 선을 강조하는 효과를 준다. 풀링 연산은 이미지 내 특징의 작은 위치변화에 대한 불변성을 부여한다. 이 두 가지 층을 교대로 거치면서 이미지의 특징을 추출하여 최종적으로 특징 맵을 만들고, 이를 완전연결(Fully connected) 층에 전달하여 이미지를 분류한다. 그림 3은 사전 연구 [6]에서 사용된 CNN 모델 구조의 예이며, 맵과 커널의 크기는 결함에 적합하게 설정되어 있다.

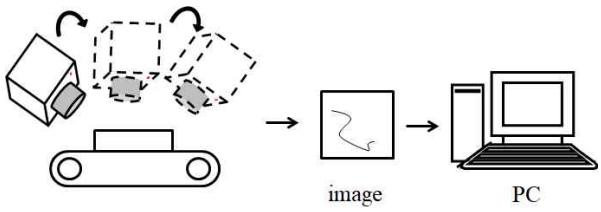


그림 2 검사 시스템 구성도
Fig. 2 Construction of inspection system

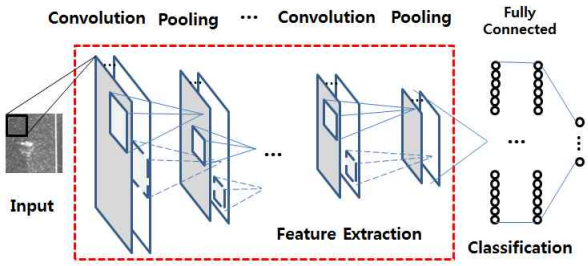


그림 3 CNN 모델 구조
Fig. 3 CNN model structure

CNN으로 직접 학습만을 수행하는 방법은 사람, 고양이, 배등의 물체 인식에 많이 쓰이고, 뛰어난 인식률을 보이고 있다. 그 이유는 대상 물체의 특징이 일관되고, 다른 물체와 구별될 수 있으며, 비교적 크기도 커서 전처리 없이 학습이 가능하기 때문이다. 그러나 산업용 부품에 대한 결함의 경우는 형태에 대한 일관된 특징이 없고, 크기도 작은 경우가 많아서 학습만으로 특징을 자동추출하기가 어렵다.

또한, 결함의 위치를 표시해야 하는 경우, CNN 만의 학습으로는 어려우며, R-CNN과 같이 선택적 탐색을 통해 후보영역 군들을 검출할 수 있어야 가능하다. 그러나, 영상 당 수백 개에서 수천 개의 후보 영역들을 검출하므로 부가적인 연산량이 증가되는 문제가 발생한다.

### 3.2 Faster R-CNN

Faster R-CNN은 CNN을 확장한 기법으로 이미지 내의 물체 검출 시간의 단축 및 검출 성능 향상을 이루었다. 물체 검출은 객체의 클래스 분류 뿐 아니라 이미지 상에서 물체의 위치, 넓이 및 폭을 경계상자로 나타낸다. CNN 기반의 물체 검출 알고리즘은 R-CNN, Fast R-CNN을 거치며 검출 속도와 성능이 개선되어 왔다[8,9]. Fast R-CNN은 Selective Search 알고리즘을 사용하여 후보 영역(ROI)을 제안하고 이를 경계상자(bounding box) 회귀(regressors)로 학습시켰는데, Faster R-CNN[10]에서는 이를 보다 체계화하여, 다양한 크기의 앵커(anchor)를 적용한 RPN(Region Proposal Network)을 제안하였다.

Faster R-CNN 내의 컨볼루션 네트워크는 일반적인 CNN과 같이 컨볼루션 층과 풀링 층으로 이루어져 있고, 여기서 출력되

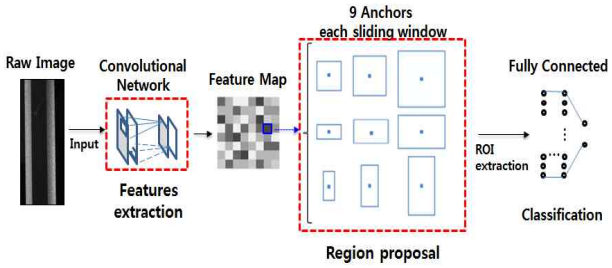


그림 4 Faster R-CNN 구조
Fig. 4 Faster R-CNN structure

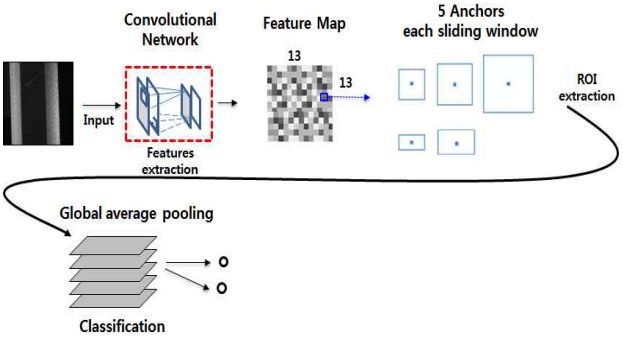


그림 5 YOLOv2 구조
Fig. 5 YOLOv2 structure

는 특징맵은 RPN과 완전연결 층으로 연결된다. RPN은 특징맵에 슬라이딩 윈도우 방식으로 앵커(anchor) 박스를 적용한다. 앵커 박스는 크기와 비율을 변화시킨 다양한 크기로 구성되어 있고, 이들을 적용시켜 검출하고자 하는 객체가 존재할 만한 다양한 영역을 제안한다. 제안된 영역 중 IOU를 계산하여 일정 수치(예로 0.7) 이상을 최종 검출 영역으로 결정한다. 그림 4는 Faster R-CNN의 구조이다.

### 3.3 YOLO v2

YOLOv2[14]는 실시간 객체 검출을 목표로 하는 학습 및 검출 알고리즘으로 기존의 YOLO[12] 알고리즘을 개선한 기법이다. YOLOv2는 입력 이미지를 $S \times S$의 그리드 셀로 나눈 후 각 그리드 셀마다 5개의 앵커 박스를 적용하여 그리드 셀 내 객체의 존재 확률, 객체에 대한 클래스의 확률, 객체의 중심좌표와 객체의 너비 및 높이를 추정한다. Faster R-CNN이 RPN으로 객체의 영역을 제안하는 것과 달리, YOLOv2는 간단한 그리드 셀을 바탕으로 객체의 영역을 제안한다. 완전연결계층 대신 전역평균풀링(global average pooling)을 사용하여 클래스를 분류하기 때문에 Faster R-CNN기법에 비해 빠른 검출이 가능하다. Faster R-CNN이 9개의 앵커를 사용하는 비해 YOLOv2는 5개를 사용하는 점도 작용한다.

YOLOv2는 다중 스케일에 강인하게 대처하기 위해 마지막 풀링층을 거치기 전의 특징맵(feature map)에서도 bbox를 추출하여 사용한다. 앞쪽 특징 맵에서 추출된 bbox는 작은 물체, 풀링 연산후의 특징 맵에서 추출된 bbox는 보다 큰 물체의 특징을 포함한다. 또한 학습할 때 일정 배치마다 입력 이미지의 크기를 랜덤한 사이즈로 조정하여 학습한다. 그림 5에 YOLOv2의 구조가 나와 있다.

## 4. 실험 및 결과 분석

본 논문에서는 금속으로 된 금속 부품의 표면에 대해 Faster R-CNN과 YOLO v2 기반의 결함 검출 방법을 실험하고 비교한다. 더불어 사전 연구 결과인 VOV 필터와 CNN을 결합한 검출 방법의 결과도 함께 정리한다.

실험에 사용한 금속 부품 표면의 결함 종류는 갈라짐, 긁힘, 찍힘, 오염 등을 포함한다. 표면의 질감이 약간 오톨도톨하거나 불균일한 느낌이 있어서 촬영 시 불균일한 무늬가 나타난다. 이러한 배경 무늬가 결함과 유사하여 정상 영역과 결함 영역의 구별을 어렵게 한다.

또한, 촬영 때 생긴 조명 반사가 결함을 왜곡하거나, 정상 영역도 밝기에 따라 결함과 유사하게 보이는 경우도 있다. 또한 제품의 굴곡진 부분으로 인하여 생기는 초점이 맞지 않는 부분과 먼지 등 잡음으로 인해 결함과 혼동될 수 있어 결함 검출을 어렵게 한다. 이러한 요인들이 결함 검출을 더욱 어렵게 한다. 또한, 검사 대상 제품의 위치가 균일하지 않아서, 검사 영역이 전후좌우로 이동되기 때문에 고정된 슬라이딩 윈도우 방식의 검사 방식은 적합하지 않으며 본 논문의 특징맵 방식의 접근이 효율적이다.

실험에 사용된 데이터는 표 1과 같다. VOV+CNN 방법은 학습 시 분류 가능한 부분적인 조각 이미지 데이터를 사용하였고, Faster R-CNN, YOLOv2에서는 전체 이미지를 사용하였다. 또한 위치 검출이 필요하기 때문에 결함이 있는 데이터만을 사용해야 학습이 가능하다. 따라서 비결함 데이터는 학습에 사용하지 않았다. 테스트에는 3가지 방법 모두 같은 데이터를 사용하였고, VOV+CNN 방법은 전체 이미지에 대해서 윈도우를 이동하면서 검출을 시도하였다.

표 1 학습과 테스트 데이터
Table 1 Training and test data

| | No. of Training data (VOV+CNN) | No. of Training data (Faster R-CNN, YOLOv2) | No. of Test data |
|---|---|---|---|
| Defects | 56,000 | 2,600 | 800 |
| Non-defects | 56,000 | - | 2,300 |

VOV와 CNN을 결합한 검출 방법은 금속 부품의 큰 이미지를 슬라이딩 윈도우 방식으로 잘라서 작은 크기의 ROI 이미지를 생성한다. 생성된 ROI 이미지에 VOV 필터를 적용해 결함 후보영역을 추출하고, 이를 CNN에 입력으로 주어 학습한다. Faster R-CNN 및 YOLOv2에서의 검출은위 방법과는 달리 ROI 이미지 대신에 큰 이미지를 학습에 사용한다. 큰 이미지에서 결함이 있는 좌표를 데이터화 한 후, 큰 이미지와 결함 좌표 데이터를 입력으로 사용해 학습한다. 평가시, Faster R-CNN은 결함영역의 좌측 상단 좌표, YOLOv2는 결함영역의 중심 좌표를 출력한다. YOLOv2는 상대적인 좌표(좌표/전체 해상도)를 사용한다.

VOV+CNN 기반 결함 검출 실험은 Epoch 300, 학습률 $10^{-5}$ 수행되었으며, Faster R-CNN 학습은 4 세부 단계로 구성되며 각 단계당 100세대(epoch)씩, 학습률 $10^{-5}$로 수행되었다. YOLOv2 학습은 세부단계 없이 전체 300세대 만큼 수행하며, 학습률은 0.001부터 시작하여 $10^{-5}$까지 단계적으로 감소한다. 실험에 사용된 네트워크의 구조는 그림 5에 나와 있다.

YOLOv2 알고리즘의 적용 시 앵커 박스의 수는 전체 데이터

에 대한 k-means 클러스터링을 통해 결정한다. 참고문헌[14]과 동일한 방법으로 결함 데이터에 대해 수행한 결과 $k=5$에서 평균 IOU(Intersection over Union)가 0.61로서 k가 더 증가되어도 IOU의 향상이 둔화되므로, 알고리즘 수행의 복잡도도 줄일 겸, 5개의 앵커 박스를 사용한다.

실험에서 계산하는 성능 지표는 크게 두 종류이다. 첫째는 미검출율(FNR), 과검출율(FPR), 오류율(Error Rate)로서 산업체 현장에서 많이 쓰이며 직관적 이해가 쉽다. 둘째는 재현율(Recall), 정밀도(Precision), 정확도(Accuracy)로서 연구 논문에서 많이 쓰이는 지표들이다. 표 2에 이들 성능 지표에 대한 비교가 정리되어 있다.

금속 부품의 표면 결함에 대한 검출 실험 결과가 표 3과 그림 7에 나와 있다. 표 3에서 Faster R-CNN 기반 결함 검출 방법이 VOV+CNN 방법에 비해 미검출율이(FNR) 약 1.1% 감소, 과검출율이(FPR) 약 56.1% 감소, 오류율이(Error Rate) 약 42.2% 감소하여 우수한 성능을 보였다. 검사시간 측면에서도 Faster R-CNN이 더 적게 걸림을 알 수 있다. YOLOv2 방법이 Faster R-CNN 기반 방법보다 미검출율은 3.3% 증가했으나, 과검출율과 오류율은 각각 13.2% 및 8.3% 감소하였다. 특히, 검사 시간과 초당 처리 프레임 수는 3가지 방법 중 현격한 차이로 가장 우수하였다. 검사시간 측정에 사용된 그래픽카드는 GTX 960이다. 코드 구현은 VOV+CNN, Faster R-CNN는 Matlab을 사용하였고, YOLOv2는 darknet19 기반의 C/C++를 사용하였다. Faster R-CNN과 YOLOv2 수행 속도의 차이가 기존의 참고문헌[14]의 결과와 유사하게 나왔다.

그림 7은 3가지 방법에 대한 재현율(Recall), 정밀도(Precision), 정확도(Accuracy) 성능을 그래프로 나타낸 것이다. 정확도와 정밀도는 YOLOv2 방법이 가장 우수하고, 재현율에서는 Faster R-CNN 방법이 가장 우수하게 나왔다.

그림 8에는 Faster R-CNN과 YOLOv2의 결함 검출 예가 나와 있다. 두 방법 간에 결함 표시 사각형의 개수 및 형태의 차이가 나타남을 알 수 있다. Faster R-CNN 검출은 같은 결함에 대해 9개의 앵커 중 일부가 사용되어 중복된 검출이 사각형으로 표시되는데, 같은 결함을 포함하고 있다면 하나의 영역으로 간주하여 실험 결과에 반영하였다. YOLOv2에서는 결함 검출 수가 적게 나왔고, 이를 통해 과검출 지표가 감소하였음을 유추할 수

표 2 성능 지표 정리

Table 2 Summary of perfomrnce indexes

| | | | |
|---|---|---|---|
| 미검출율 (FNR) | $\frac{FN}{P}=\frac{FN}{TP+FN}$ | 재현율 (Recall) | $\frac{TP}{P}=\frac{TP}{TP+FN}$ |
| 과검출율 (FPR) | $\frac{FP}{N}=\frac{FP}{TN+FP}$ | 정밀도 (Precision) | $\frac{TP}{TP+FP}$ |
| 오류율 (Error Rate) | $1-\frac{TP+TN}{P+N}$ | 정확도 (Accuracy) | $\frac{TP+TN}{P+N}$ |

표 3 금속 부품 표면의 결함 검출 실험 결과 1

Table 3 Experimental results 1 of defect detection for metal parts

| | VOV+CNN | Faster R-CNN | YOLO V2 |
|---|---|---|---|
| False Negative Rate (FNR) | 2 % | 0.9 % | 4.2 % |
| False Positive Rate (FPR) | 79.1 % | 23 % | 9.8 % |
| Error Rate | 59.6 % | 17.4 % | 9.1 % |
| Inspection time (100 images) | 18.9 sec | 16.8 sec | 3.4 sec |
| fps(frame per second) | 5.2 | 5.9 | 29.4 |

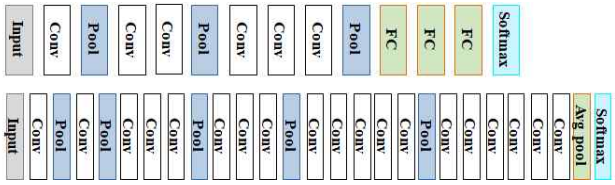


그림 6 네트워크 구조-위) VOV+CNN, Faster R-CNN, 아래) YOLOv2

Fig. 6 Network structure-top) VOV+CNN, Faster R-CNN, bottom) YOLOv2

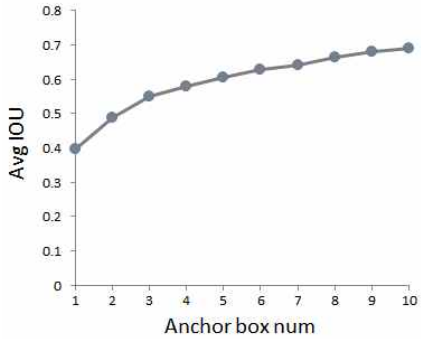


그림 7 결함 데이터의 k-means clustering 결과

Fig. 7 K-means clustering results for defect data

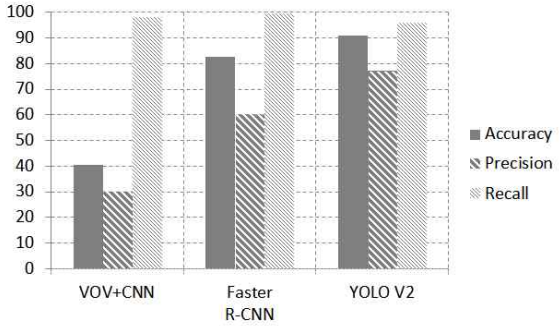


그림 8 금속 부품 표면의 결함 검출 실험 결과 2

Fig. 8 Experimental results 2 of defect detection for metal parts

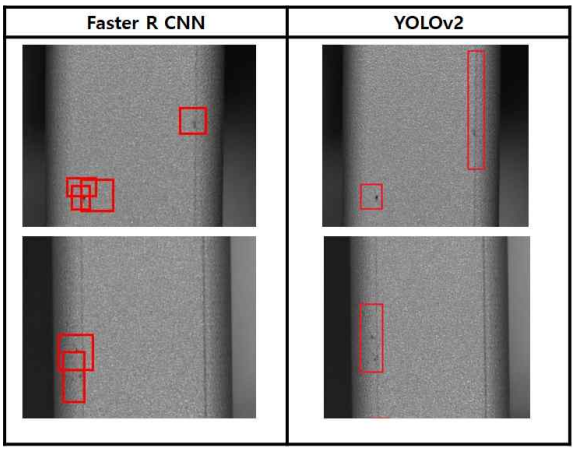


그림 9 결함 검출 예 - Faster R-CNN, YOLOv2
Fig. 9 Detection results of defects for for metal parts - Faster R-CNN and YOLOv2

있다. 대신, 우측 상단에서 길이가 긴 사각형으로 검출이 표시되었는데, 결함을 포함해 세로로 나타나 있는 선은 결함이 아니지만 스크래치와 같은 결함으로 인식되어 실제보다 넓은 영역으로 표시된 것이다.

## 5. 결 론

산업용 금속 부품의 표면 결함 검사에 CNN 기반의 3가지 검출 기법을 적용하여 실험하였다. 사전에 연구된 VOV+CNN 검출 방법 외에 Faster R-CNN과 YOLOv2 기법을 중심으로 검출 성능과 속도 측면에서 비교하였다. 미검출율은 Faster R-CNN이 가장 우수했고, 그 다음으로 VOV+CNN, YOLOv2 순이었다. 과검출과 오류율은 YOLOv2가 가장 우수했고, 그 다음으로 Faster R-CNN, VOV+CNN 순으로 나타났다. 또한, 검출 속도면에서도 YOLOv2 기법이 다른 두 방법보다 월등한 성능을 보였다. 물체 검출을 위주로 연구가 되고 있는 Faster R-CNN과 YOLOv2 알고리즘을 난이도가 높은 금속 부품의 표면 결함 검출에 적용하여 만족할 만한 성능을 얻은 것이 의의라고 볼 수 있다.

향후, 네트워크 구조의 최적화와 학습 알고리즘의 개선을 통해 검출 성능과 처리 시간에 대한 추가적인 향상이 필요하다.

## References

[1] Y. Park, and I. S. Kweon, “Ambiguous Surface Defect Image Classification of AMOLED Displays in Smartphones,” *IEEE Trans. on Industrial Informatics*, vol. 12, no. 2, pp. 597-607, 2016

[2] S. Ghorai, A. Mukherjee, M. Gangadaran, P. K. Dutta, “Automatic Defect Detection on Hot-Rolled Flat Steel Products,” *IEEE Trans. on Instrumentation and Measurement*, vol. 62, Iss. 3, pp. 612-621, 2013.

[3] LeCun, Yann, et al. “Gradient based learning applied to document recognition,” *Proceedings of the IEEE*, pp. 2278-2324, 1998

[4] J-K. Park, N. Kwon, J-H. and D. Kang, “Machine Learning-Based Imaging System for Surface Defect Inspection," *International Journal of Precision Engineering and Manufacturing-Green Technology*, vol. 3, no. 3, pp. 303-310, 2016

[5] H. Choi and K. Seo, “CNN Based Detection of Surface Defects for Electronic Parts,” *Journal of Korean Institute of Intelligent Systems*, vol. 27, no. 3, pp. 195-200, 2017.

[6] H. Choi and K. Seo, “Comparison of CNN Structures for Detection of Surface Defects,” *The Transactions of the Korean Institute of Electrical Engineers*, vol. 66, no. 7, pp. 1100-1104, 2017

[7] B.-K Kwon, J.-S. Won, D.-J. Kang. “Fast defect detection for various types of surfaces using random forest with VOV features,” *International Journal of Precision Engineering and Manufacturing*, vol. 16, no. 5, pp. 965-970, 2015

[8] R. Girshick, J. Donahue, T. Darrell, J. Malik, “Region-Based Convolutional Networks for Accurate Object Detection and Segmentation,” *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 38, no. 1. pp. 142-158. 2016

[9] R. Girshick, “Fast R-CNN,” *ICCV 2015*, pp. 1440-1448. 2015

[10] Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun, “Faster r-cnn: Towards real-time object detection with region proposal networks,” *Advances in neural information processing systems*, pp. 91-99, 2015

[11] M. Lee, K, Seo, “Using Deep Learning Based Machine Vision for Defects Detection,” *Proceedings of Information and Control Symposium CICS'2017*, pp. 54-55, 2017.

[12] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016

[13] M. Lee, K, Seo, “Comparison of CNN Methods for Defects Detection,” *Proceedings of Information and Control Symposium ICS'2018*, pp. 101-102, 2018.

[14] Joseph Redmon, Ali Farhadi, “YOLO9000: better, faster, stronger,” arXiv:1612.08242, 2017.

# 저 자 소 개

**이 민 기 (Minki Lee)**

2017년 서경대학교 전자공학과 졸업(학사). 2017년~현재 서경대학교 대학원 전자컴퓨터공학과 석사과정.
〈관심분야〉 딥러닝, 영상인식, 머신비전

**서 기 성 (Kisung Seo)**

1993년 연세대학교 대학원 전기공학과 졸업(박사). 1999~2003년 Michigan State University, Genetic Algorithms Research and Applications Group, Research Associate, 2002~2003년 Michigan State University, Electrical & Computer Engineering, Visiting Assistant Professor, 2011~2012년 Michigan State University, BEACON (Bio/ computational Evolution in Action CONsortium) Center, Visiting Scholar, 1993년~현재 서경대학교 전자공학과 교수.
〈관심분야〉 진화연산, 딥러닝, 영상인식, 머신비전, 기상예측, 지능로봇