

# A Study on Tire Surface Defect Detection Method Using Depth Image

Hyun Suk Kim<sup>†</sup> · Dong Beom Ko<sup>††</sup> · Won Gok Lee<sup>†††</sup> · You Suk Bae<sup>††††</sup>

## ABSTRACT

Recently, research on smart factories triggered by the 4th industrial revolution is being actively conducted. Accordingly, the manufacturing industry is conducting various studies to improve productivity and quality based on deep learning technology with robust performance. This paper is a study on the method of detecting tire surface defects in the visual inspection stage of the tire manufacturing process, and introduces a tire surface defect detection method using a depth image acquired through a 3D camera. The tire surface depth image dealt with in this study has the problem of low contrast caused by the shallow depth of the tire surface and the difference in the reference depth value due to the data acquisition environment. And due to the nature of the manufacturing industry, algorithms with performance that can be processed in real time along with detection performance is required. Therefore, in this paper, we studied a method to normalize the depth image through relatively simple methods so that the tire surface defect detection algorithm does not consist of a complex algorithm pipeline. and conducted a comparative experiment between the general normalization method and the normalization method suggested in this paper using YOLO V3, which could satisfy both detection performance and speed. As a result of the experiment, it is confirmed that the normalization method proposed in this paper improved performance by about 7% based on mAP 0.5, and the method proposed in this paper is effective.

Keywords : Tire Defect Detection, Depth Image, Deep Learning, Computer Vision, Image Processing

## 깊이 이미지를 이용한 타이어 표면 결함 검출 방법에 관한 연구

김 현 석<sup>†</sup> · 고 동 범<sup>††</sup> · 이 원 곡<sup>†††</sup> · 배 유 석<sup>††††</sup>

## 요 약

최근 4차 산업혁명으로 촉발된 스마트공장에 관한 연구가 활발히 진행되고 있다. 이에 따라 제조업에서는 강건한 성능의 딥러닝 기술을 바탕으로 생산성 향상과 품질 향상을 위해 다양한 연구를 진행 중이다. 본 논문은 타이어 제조공정의 육안검사 단계에서 타이어 표면 결함을 검출하는 방법에 관한 연구로서 3D 카메라를 통해 취득한 깊이 이미지를 이용한 타이어 표면 결함 검출 방법을 소개한다. 본 연구에서 다루는 타이어 표면 깊이 이미지는 타이어 표면의 얇은 깊이로 인해 발생하는 낮은 깊이 대비와 데이터 취득 환경으로 인해 기준 깊이 값의 차이가 발생하는 문제가 있다. 그리고 제조업의 특성상 검출 성능과 함께 실시간으로 처리될 수 있는 성능을 지닌 알고리즘이 요구된다. 따라서, 본 논문에서는 타이어 표면 결함 검출 알고리즘이 복잡한 알고리즘 파이프라인으로 구성되지 않도록 상대적으로 단순한 방법들을 통해 깊이 이미지를 정규화하는 방법을 연구하였으며 검출 성능과 속도를 모두 만족할 수 있는 딥러닝 방법인 YOLO V3를 이용하여 일반적인 정규화 방법과 본 논문에서 제안하는 정규화 방법의 비교 실험을 진행하였다. 실험의 결과로 본 논문에서 제안한 정규화 방법으로 mAP 0.5 기준 약 7% 성능이 향상된 것을 확인하였으며 본 논문에서 제시한 방법이 효과적임을 보였다.

키워드 : 타이어 결함 검출, 깊이 이미지, 딥러닝, 컴퓨터비전, 영상처리

## 1. 서 론

최근 수년 동안 제조업에서는 노동 생산성 증가를 하락과 맞춤형 소규모 생산 요구에 대응하기 위해 2011년 발표된 독

일의 인터스트리 4.0을 기점으로 촉발된 4차 산업혁명을 향한 연구를 활발히 진행 중이다. 일찍이 미국, 독일을 비롯한 주요 선진국들은 제조업의 중요성을 인식하여 제조업의 리쇼어링, 관련 예산의 편성을 통해 제조업 관련 전략적 정책을 추진 중에 있다. 국내 또한 제조 중소기업의 50% 스마트화 달성을 위해 2018년 중소기업 스마트 제조 혁신전략을 발표해 추진하였으며 2020년 인공지능·데이터 중심의 스마트 제조 공급기업 육성을 위해 AI·데이터 기반 중소기업 제조혁신 고도화 전략을 발표하여 추진하는 등 제조업 스마트화 전략에 지원을 아끼지 않고 있다[1,2].

스마트공장은 제조와 ICT(Information and Communications

※ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 Grand ICT연구센터지원사업의 연구결과로 수행되었음(IITP-2020-0-101741).

† 준 회 원 : 한국산업기술대학교 스마트팩토리융합과 박사

†† 비 회 원 : 한국전자통신연구원 차세대시스템SW 박사후 연구원

††† 비 회 원 : 한국산업기술대학교 인공지능기술사업화연구소 연구교수

†††† 비 회 원 : 한국산업기술대학교 컴퓨터공학과 교수

Manuscript Received : October 1, 2021

First Revision : November 10, 2021

Accepted : December 6, 2021

\* Corresponding Author : You Suk Bae(ysbae@kpu.ac.kr)

Technology)의 결합을 의미하는 것으로 주문, 발주를 시작으로 생산까지 ERP(Enterprise Resource Planning), MES (Manufacturing Execution System)에 의해 통합 관리되고 더 나아가 공장에서 발생하는 생산 데이터 기반으로 인공지능 기술에 기반하여 통제, 운영하는 것을 말한다.

빅데이터, CPS(Cyber Physical System), 에너지 절감, 인공지능과 같은 스마트공장의 핵심 기술 들은 공장에서 수집되는 다양한 생산 데이터를 기반으로 처리·분석되고 최적화 된다. 이처럼 스마트공장의 핵심 기술의 기반이 되는 데이터는 스마트공장의 중요 요소라 할 수 있다. 예를 들어, 이상 징후 감지를 통한 무인 자동화와 같은 기술은 스마트공장에서 발생하는 데이터의 활용을 통해 이루어진다.

특히 영상 데이터를 활용하는 제조공정에서는 전문가의 경험치에 의존하여 사용되고 있는 기존의 단순 처리 시스템에서 벗어나 인공지능 기술의 강력한 성능을 기반으로 시스템 성능을 개선하기 위한 연구를 진행 중에 있다. 특히 제조 공정의 최종 단계라 할 수 있는 육안 검사 단계에서 인공지능 기술 적용은 작업의 능률을 크게 향상 시킬 수 있을 뿐만 아니라 작업자 개인마다 서로 상이 할 수 있는 결합 기준을 표준화시킬 수 있는 장점을 가질 수 있다.

본 논문은 자동차용 타이어 제조 공정 중, 최종 검사 단계에서 육안 검사를 대체하기 위해 타이어 표면 결합을 검출하는 방법에 관한 연구로서 3D 카메라를 통해 취득한 깊이 이미지를 이용한다. 얇은 깊이를 지닌 타이어 표면의 정밀한 정규화 이미지를 얻기 위해 Otsu's Threshold, 투영 히스토그램 방법을 통해 타이어 영역을 검출하는 과정을 거쳐 정규화 처리를 하며 타이어 표면 결합 검출을 위해 강력한 성능과 빠른 속도가 장점인 YOLO V3를 사용한다. 성능 검증을 위해 타이어 표면 결합 중 깊이 정보가 필요한 타이어 표면 Vent spews 데이터를 이용한다.

본 논문에서 제안하는 결합 검출 방법은 검출 성능과 더불어 실제 제조업에서 요구하는 검출 속도를 만족시키는 것을 목적으로 한다. 이를 위해 전처리 과정인 이미지 정규화 과정에서 상대적으로 단순한 구조와 적은 계산량으로 처리될 수 있도록 하며 학습과 인식 과정 또한 상대적으로 학습 및 검출 속도가 빠른 Detector를 이용한다.

본 논문은 구성은 다음과 같다. 2장 연구 배경에서 타이어 표면 결합과 깊이 이미지 특징, 선행 연구 분석을 통해 연구 목표를 제시하고 3장에서 본 연구에서 제안하는 깊이 이미지 처리 방법과 타이어 결합 표면 검출 방법을 살펴본다. 4장에서 제안하는 타이어 표면 결합 검출 방법의 실험과 결과 분석을 통해 성능을 검증하고 5장 결론 및 향후 과제에서 연구 결론과 향후 연구 과제를 논의 후 본 논문을 마무리한다.

## 2. 연구 배경

### 2.1 타이어 결합 정보

자동차 타이어 제조 공정은 타이어 출하 전 최종 검사 단




Fig. 1. Tire Vent Spews

계에서 다양한 테스트를 거친다. 제품의 최종 검사는 X-Ray, 초음파 등의 방법으로 제품 내부를 촬영하여 검사하는 내부 검사와 자외선, 육안을 이용하여 제품 외부를 검사하는 표면 검사로 나눌 수 있다. 타이어 표면 결합은 타이어 생산 과정에서 발생할 수 있는 물리적 충격 또는 성형 불량에 따른 타이어 표면 손상, 기포 발생, 이물질 섞임으로 분류할 수 있으며 이는 타이어 고유 색상과 패턴을 훼손하는 형태로 나타난다. 보통의 경우 RGB 이미지를 이용하여 결합 검출이 가능하나 예외적으로 타이어 3D 정보를 필요로 하는 결합의 경우 깊이 이미지를 이용한 결합 검출이 필요하다. 예를 들어 타이어 결합 중 하나인 Vent Spews는 타이어 Tread와 Side Wall 영역에서 발생하는 결합 패턴으로 타이어 생산 시 가류 공정에서 공기가 빠져나올 수 있는 미세한 구멍으로 고무가 흘러나와 발생한다. 이는 타이어 표면에서 흔히 발생할 수 있으나 Vent Spews가 기준 길이 이상일 경우 결합으로 취급된다. Fig. 1은 타이어 표면에서 발생한 Vent spews를 보여준다. 또한 Vent Spews 외에 RGB 이미지에 표현되지 못하는 작은 크기의 스크래치나 패턴 왜곡, 기포와 같은 결합 또한 깊이 이미지 사용이 필요한 경우이다.

### 2.2 타이어 표면 깊이 이미지

타이어 표면 깊이 이미지는 Fig. 2와 같이 타이어를 정반 위에 정렬 후 회전시켜 고정 설치된 3D-Line Scan 카메라를 이용하여 타이어 표면을 촬영하여 취득한다.

타이어 깊이 이미지 촬영에 사용된 카메라 모델은 Automation Technology 사의 C5-2040CS30-330 모델로서 상세 사양은 Table 1과 같다.

촬영된 타이어 표면 깊이 이미지는 타이어의 둘레에 비례하여 가변적인 해상도로 취득된다.

일반적으로 사용되는 RGB 이미지가 8 bit 정보를 담고 있는데 반해 촬영된 깊이 이미지는 현재 사용하는 3D-Line Scan 카메라 기준으로 Height resolution 5 $\mu$ m, Z-Range




Fig. 2. Depth Data Acquisition Environment

Table 1. C5-2040CS30-330 Specification[3]

	Values
FOV(mm)	330
Z-Range(mm)	300
Working Distance(mm)	400
Lateral Resolution(μm)	161
Height Resolution(μm)	5.0
Point per Profile	2048




Fig. 3. Tire Surface Depth Image (Tread)




Fig. 4. Depth Information Change According to Tire Size




Fig. 5. Tire Surface Depth Image Histogram

300mm을 이용하여 계산 시 깊이 Level을 표현하기 위해 16 bit 정보를 담고 있다.

타이어 표면 깊이 이미지는 고정된 3D-Line Scan 카메라의 Z-Range 내에서 타이어와의 거리 정보를 취득한다. 따라서 크기가 다른 타이어의 표면 깊이 이미지를 취득할 때 카메라와 타이어 표면의 거리 정보가 반영되어 타이어 표면의 실제 깊이 정보가 아닌 서로 다른 범위 값을 가지게 된다.

또한 타이어 표면에서 가장 낮은 지점과 높은 지점의 깊이 차이가 작기 때문에 촬영된 깊이 이미지가 표현하는 높이 정보인 16bit(0~65,535)로 표현할 수 있는 깊이 범위 중 극히 좁은 범위를 사용하는 문제를 가진다. Fig. 5는 촬영된 타이어 표면 깊이 이미지의 값을 히스토그램으로 나타낸 그래프이다.

따라서 타이어 표면 깊이 이미지를 활용함에 있어 전처리 과정을 위한 이미지 정규화 시 타이어 표면 내의 상대적인 깊이 정보를 잃지 않으면서 값의 차이를 극명하게 하도록 정규화 범위를 최대한 활용하게 하는 방법이 필요하다.

### 2.3 선행 연구

최근 타이어의 결함 유무를 검출하기 위해 이미지를 이용한 연구가 활발하게 이루어지고 있다. RGB 이미지를 이용하여 타이어 마모도 측정과 손상 부위 검출을 한 연구가 있다 [4]. Hye-Jin Park은 Instance segmentation인 Mask R-CNN[5]과 어텐션 기법을 통해 마모도 분류와 손상 부위 검출 방법을 제시하였다. 해당 연구는 타이어의 손상을 인식하고 검출한다는 점에서 본 연구에서와 유사하나 RGB 이미지를 이용할 경우 타이어 표면에서 발생하는 일부 작은 크기의 결함 정보를 표현할 수 없다는 한계점이 존재한다. 또 다른 관련 연구로 X-ray 이미지를 사용하여 타이어 내부 결함을 검출한 연구가 있다[6]. REN WANG은 X-Ray 이미지를 사용하여 Semantic segmentation[7]인 FCN(Fully Convolution Network)[8]을 이용한 타이어 내부 결함 검출 방법을 제시하였다. 해당 연구와 앞선 연구 모두 타이어 결함 검출을 위해 Segmentation 방법을 이용하였기에 픽셀 단위의 정밀한 객체 검출이 가능하나 이는 학습 시 Segmentation 방법의 특성 상 많은 계산량이 필요하여 상대적으로 학습과 검출 시간이 크게 증가하는 문제점을 가진다. 제조업의 특성상 새로운 제품이 주기적으로 개발되고 새로운 형태의 결함이 계속적으로 발생하기 때문에 잦은 재학습이 필요하다. 또한 자동 결함 검사 시스템의 타이어 삽입, 정렬, 촬영, 배출하는 과정의 시간 내에 검출을 가능토록 하는 점이 요구된다. 이에 따라 타이어 표면 검출 방법 연구 시 결함 검출 성능과 더불어 고려되어야 할 중요 요소는 빠른 학습 시간과 검출 속도이다. 타이어 표면 결함 검출의 목적은 타이어의 정상, 결함 여부를 판단하기 위한 것으로 픽셀 단위의 세밀한 결함 위치 인식은 불필요하다. 이러한 점이 결함 검출 알고리즘 선정 시 고려되어야 한다.

### 3. 깊이 이미지를 이용한 타이어 표면 결함 검출 방법

본 논문에서 제안하는 타이어 표면 결함 검출 방법은 Fig. 6과 같이 타이어 표면 깊이 이미지 정규화, 타이어 표면 깊이 이미지




Fig. 6. Overall System Process




Fig. 7. Tire Tread Surface Depth Image




Fig. 8. Otsu's Threshold Result Image

학습, 타이어 표면 결함 검출 3 단계 프로세스로 나누어진다.

### 3.1 타이어 표면 깊이 이미지 정규화

타이어 표면 깊이 이미지의 정규화는 Equation (1)과 같이 최소-최대 정규화 방법을 이용한다.

$$X_{new} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (1)$$

Fig. 7은 타이어 Tread의 깊이 이미지로서 촬영 시 빨간색으로 표시된 점선과 같이 타이어 표면을 벗어난 영역도 함께 촬영되어 이미지에 Equation (1)을 그대로 적용할 경우 타이어 표면의 정밀한 깊이 정규화 데이터를 얻을 수 없다. 따라서 타이어 표면 영역에서의 최소, 최대 값을 찾을 수 있도록 타이어 영역을 찾는 과정이 선행되어야 한다.

타이어 영역을 찾는 과정에서 정밀한 위치를 찾을수록 더욱 정확한 정규화 이미지를 얻을 수 있으나 전처리 과정인 정규화를 위해 따로 인공지능망 같은 학습과 인식하는 과정을 거치거나 혹은 많은 계산량을 필요케 하는 방법은 연구 시 중요 고려 요소인 빠른 학습, 인식 속도를 위해선 적합한 접근 방법이 아니다. 또한 전체 알고리즘 파이프라인을 지나치게 복잡하게 만들 수 있다. 따라서 낮은 연산으로 근사된 타이어 영역을 찾는 것이 필요하다.

깊이 이미지에서 분할 대상 객체는 타이어 표면 단일 객체이다. 이를 낮은 계산량으로 효과적으로 찾기 위해 Threshold 값을 통해 타이어 표면 영역을 분할하는 방법이 적합하다. 그러나 크기가 다른 타이어로 인해 서로 다른 깊이 범위를 가지는 깊이 이미지 내에서 특정 Threshold 값을 선택할 수 없다. 따라서 이미지 분석을 통해 최적의 Threshold 값을 찾아주는 방법이 필요하다. 최적의 Threshold 값을 찾아주는 대표적인 방법으로 Otsu's Threshold와 Adaptive threshold 방법이 있다. Otsu's Threshold는 임계값  $T$ 를 기준으로 두 화소 집합으로 나누었을 때 명암의 균일성을 크게 하는  $T$ 를 찾기 위해 두 집합의 분산이 가장 작은  $T$ 를 선택하는 방법이다. Adaptive threshold는 이미지를 작은 영역으로 분할하여 Thresholding을 하는 방법으로  $T$  선택 시 주변 영역의 평균 또는 GAUSSIAN 윈도우에서 보정 상수  $C$ 를 뺀 값을  $T$ 로 선택하는 방법이다[9,10]. Adaptive threshold 방법은 영역 별로  $T$ 를 선택하기 때문에 조명에 영향으로 이미지 전체 영역을 하나의  $T$ 로 분할 할 수 없는 문제를 해결할 수 있




Fig. 9. Erosion Process Results

는 장점을 가진다. 그러나 깊이 이미지는 조명의 영향을 받지 않고 단일 객체인 타이어 표면을 분할하기 위해 영역별로  $T$ 를 선택할 필요는 없다. 따라서 두 방법 중 전체 이미지 영역에서 최적의  $T$ 를 찾을 수 있는 Otsu's Threshold를 이용하여 타이어 표면 영역을 분할하였다.

Otsu's Threshold의 수식은 Equation (2)와 같다[10,11].

$$T = \underset{t \in \{0,1,\dots,L-1\}}{\operatorname{argmin}} v_{\text{within}}(t)$$

$$v_{\text{within}}(t) = w_0(t)v_0(t) + w_1(t)v_1(t)$$

$$w_0(t) = \sum_{i=0}^t \hat{h}(i), \quad w_1(t) = \sum_{i=t+1}^{L-1} \hat{h}(i)$$

$$\mu_0(t) = \frac{1}{w_0(t)} \sum_{i=0}^t i \hat{h}(i), \quad (2)$$

$$\mu_1(t) = \frac{1}{w_1(t)} \sum_{i=t+1}^{L-1} i \hat{h}(i)$$

$$v_0(t) = \frac{1}{w_0(t)} \sum_{i=0}^t \hat{h}(i)(i - \mu_0(t))^2,$$

$$v_1(t) = \frac{1}{w_1(t)} \sum_{i=t+1}^{L-1} \hat{h}(i)(i - \mu_1(t))^2$$

Fig. 8은 원본 데이터에 Otsu's Threshold를 적용한 결과 이미지로서 타이어에 근사된 영역이 Threshold 처리된 것을 확인할 수 있다.

처리된 Threshold 이미지는 타이어가 정렬되는 정반으로 인해 발생 될 수 있는 하단 노이즈와 타이어 상단 표면에 발생하는 Vent spews 영역이 포함될 수 있다. 본 논문에서는 이를 제거하기 위해서 침식 연산을 수행하였다.

Fig. 9는 Threshold 이미지에서 침식 처리된 이미지로서 노이즈가 제거되어 목표로 하는 타이어 영역만이 남겨진 것을 확인할 수 있다.

침식 처리된 이미지에서 검출 대상 객체는 타이어 단일 영역이며 타이어 패턴 내의 패인 홈으로 인해 타이어 영역의 각 픽셀은 완전 연결된 형태를 가지지 않는다. 본 논문에서는 이러한 특징에 가장 적합한 위치 검출 방법인 투영 히스토그램을 사용한다. 투영 히스토그램 방법은 Threshold 처리된 이미지




Fig. 10. Tire Area Detection using Projection Histogram




Fig. 11. Detected Tire Area




Fig. 12. Min-Max Normalized Tire Surface Depth Image

내에서 객체 위치를 찾기 위해 흔히 사용되는 Connected component labeling 방법과 비교 시 낮은 계산량으로 빠르게 이미지 내에서 단일 객체를 찾을 수 있다. 또한 객체의 각 픽셀이 완전 연결되어 있지 않더라도 이를 연결시키기 위한 침식 후 팽창과 같은 별도의 과정이 필요하지 않다. Fig. 10은 수평 투영 히스토그램을 계산하여 타이어 영역의 위치를 검출하는 것을 보여준다.

Fig. 11은 투영 히스토그램을 이용하여 타이어 영역의 위치를 검출한 결과로서 원본 타이어 표면 깊이 이미지에 초록색 선 영역으로 타이어 영역을 검출한 결과를 나타낸다.

검출된 타이어 영역 내에서 수식 (1) 최소-최대 정규화를 적용하여 원본 타이어 표면 깊이 이미지를 정규화한 타이어 표면 깊이 이미지는 Fig. 12와 같다.

Fig. 13은 타이어 표면 깊이 이미지를 각기 다른 방법으로 최소-최대 정규화한 깊이 값 히스토그램 그래프를 비교한 것이다. 첫 번째 히스토그램은 최소 값 0, 최대 값 65,536(16 bit)을 이용한 정규화 결과이며 두 번째 히스토그램은 이미지 전체 영역 내의 최소, 최대 값을 이용한 정규화 결과이고 세 번째 히스토그램은 타이어 영역을 검출 후 타이어 영역 내의 최소, 최대 값을 이용하여 정규화된 결과이다. Fig. 13에서 비교한 히스토그램에서 보이는 것처럼 타이어 영역을 검출하여 정규화된 결과는 다른 정규화 방법 결과와 비교 시 타이어 표면에서의 최소, 최대 값을 이용하기 때문에 실제 타이어 표면 내에서의 상대적인 깊이 정보를 유지한 채 정규화 범위를 최대한 활용하는 것을 확인할 수 있다.

### 3.2 타이어 표면 깊이 이미지 학습

#### 1) 학습 데이터 구성

타이어 표면 결함 학습에 사용되는 깊이 이미지는 작은 크




Fig. 13. Depth Information Histogram According to Processing Method




Fig. 14. Create Training & Test Data

기의 결함 정보를 포함할 수 있도록 고해상도 이미지로 얻어진다. 제한된 메모리 환경에서 학습을 위해 이미지 크기를 줄이면 작은 크기의 결함이 사라질 수 있으며 보간으로 인해 깊이 값이 변형되는 결과가 발생할 수 있다. 따라서 학습에 사용되는 이미지를 일정한 배치 크기를 구성할 수 있는 크기로 잘라내어 학습 데이터를 구성하였다. Fig. 14는 학습 데이터를 구성하기 위해 타이어 표면 깊이 이미지를 잘라낸 것을 보여준다.

#### 2) 타이어 표면 깊이 이미지 학습

육안검사를 대체하여 타이어의 결함 영역을 검출하는 것에 중요한 요인은 검출 성능과 함께 학습, 검출 속도 또한 중요한 요인으로 포함된다. 작은 크기의 결함까지 검출해야 하는 타이어 표면 깊이 이미지 특성상 일반적으로 다루는 이미지와 비교 시 높은 해상도를 가지며 이는 학습과 검출 시 많은 계산량과 시간이 요구된다. 본 연구에서는 다양한 딥러닝 방법 중 검출과 속도 성능 요인을 모두 충족할 수 YOLO Detector를 사용하였다.

YOLO는 객체 검출을 위한 딥러닝 모델로서 학습과 검출 과정에서 복잡한 알고리즘 파이프라인 구조 대신 Fig. 15와 같이 하나의 신경망 구조로 이루어져 있어 높은 정확도와 빠른 속도 두 가지를 모두 충족시킬 수 있는 객체 검출 방법이다. 본 논문에서는 타이어 표면 결함 검출을 위해 YOLO V3




Fig. 15. YOLO Network Architecture[12]

를 사용한다. YOLO V3는 YOLO와 YOLO V2에서 성능이 개선된 방법으로 주요 개선내용은 아래와 같다[13-15].

- Residual을 적용한 Backbone Darknet-53으로 빠른 속도를 유지한 채 검출 성능 향상
- Upsampled features에서 Meaningful semantic information과 이전 Feature map의 Finer-grained information을 얻기 위해 3개의 다른 Scale을 이용하여 3-D tensor encoding bounding box를 예측하는 구조로 Multi scale 성능을 강화
- Class 예측을 위해 softmax 대신 binary cross-entropy loss를 사용함으로써 Multilabel classification을 적용

타이어 표면 결함은 작은 크기의 결함이 존재하며 이에 검출 성능, 속도와 별개로 작은 크기 객체 검출이 가능한지 또한 고려되어야 한다. YOLO V3는 Meaningful semantic information과 이전 Feature map의 Finer-grained information을 함께 사용함으로써 Multi scale 성능을 강화함과 동시에 기존 YOLO의 단점인 작은 객체 검출의 어려움을 해결하였다.

Fig. 16은 학습에 사용한 타이어 표면 깊이 이미지 데이터와 YOLO V3 구조를 보여준다.

4. 실험 및 결과 분석

4.1 실험 데이터

타이어 표면 결함 중 깊이 정보가 필요한 Vent spews 데이터를 사용하여 실험하였다. Vent spews의 길이는 mm 단위로 깊이 값의 차이가 발생하는 만큼 정규화 방법에 따른 성




Fig. 16. Tire Surface Depth Image Data and YOLO V3 Structure[14,16]

능 차이를 확인할 수 있으며 타이어 표면 면적과 비교 시 크기가 아주 작기 때문에 YOLO V3에서 미세한 크기의 객체 검출 가능 여부 또한 함께 실험할 수 있다. 또한, 타이어 표면에서 흔히 발생하여 다른 결함 종류와 비교 시 다수의 결함 데이터를 확보할 수 있으며, 이에 따라 다양한 형태가 포함될 수 있어 실험의 신뢰도를 높일 수 있다.

4.2 실험 환경

본 실험에서는 서로 다른 표면 패턴의 타이어 표면 깊이 이미지 16개를 사용하였다. 각 이미지는 일정 크기의 이상의 Batch Size를 구성하도록 512X512 크기로 잘라내어 학습 데이터 605개, 테스트 데이터 260개로 구성하였다. 실험에 사용된 하드웨어 및 소프트웨어 환경은 Table 2와 같다.

학습 데이터는 동일 이미지 셋을 서로 다른 방법으로 정규화한 3가지 데이터 셋을 구성하여 실험하였다.

- Data #1 : 최소 값 0, 최대 값 65 536(16 bit)로 정규화
- Data #2 : 이미지 전체 영역에서 최소, 최대 값을 이용한 정규화
- Data #3 : 타이어 영역을 검출 후 타이어 영역 내에서 최소, 최대 값을 이용한 정규화

학습에 사용한 YOLO V3의 대표 파라미터는 Table 3과 같으며 3가지 데이터 셋 모두 동일 파라미터로 테스트하였다.

4.3 평가 지표

평가 지표는 Precision과 Recall을 사용하였으며 수식은 Equation (3), (4)와 같다.

$$Precision = \frac{TP}{TP + FP} \tag{3}$$

$$Recall = \frac{TP}{TP + FN} \tag{4}$$

또한 mAP(Mean Average Precision) 0.5와 mAP 0.5:0.95를 사용하였다. mAP 0.5는 Pascal VOC 평가 방식으로 IoU(Intersection over Union) 0.5를 기준으로 이상인 경우 Positive, 그렇지 못할 시 Negative로 하여 이를 기반으로 구한 Precision-Recall 곡선의 아래 영역인 AP(Average Precision)의 클래스 평균이다. mAP 0.5:0.95는 MS COCO Dataset 평가 방식으로 IoU 0.5, 0.55, ..., 0.95 기준으로 계산한 mAP의 평균이다.

4.4 실험 및 결과 분석

Fig. 17~20은 테스트 데이터의 Precision, Recall, mAP

Table 2. Algorithm Experiment Environment

	Test environment
OS	Windows 10
CPU	AMD Ryzen 7 3700X
Memory	64 GB
GPU	NVIDIA Geforce RTX 3090
Library	Pytorch 1.8. OpenCV 4.5.2

Table 3. YOLO V3 Training Parameters

Parameter	Values
Learning rate	0.001
Momentum	0.9
weight decay	0.0005
Activation function	Leaky Relu
Learning epochs	200
Batch Size	35




Fig. 17. Precision (Epoch 200)




Fig. 18. Recall (Epoch 200)

0.5, mAP 0.5:0.95를 나타낸 그래프이다. 각 그래프에 Data #1은 파란색, Data #2는 주황색, Data #3는 회색으로 표기하였다.

Data #1의 경우 학습 진행 시 평가 지표 모두에서 일정 값 이상으로 성능이 향상되지 못하는 결과를 보였다.

Data #2는 Epoch 80을 기점으로 Data #1보다 평가 지표 모두에서 더 높은 값으로 수렴하는 결과를 보여주었으며, Data #3는 Data #2와 마찬가지로 비슷한 Epoch에서 상승, 수렴하는 결과를 보여주나 Data #1과 비교 시 큰 성능 차이




Fig. 19. mAP 0.5 (Epoch 200)




Fig. 20. mAP 0.5:0.95 (Epoch 200)

Table 4. Best Precision & Recall

	Precision	Recall
Data #1	81.13	52.46
Data #2	87.65	79.34
Data #3	90.01	83.09

Table 5. Best mAP

	mAP 0.5	mAP 0.5:0.95
Data #1	48.62	17.75
Data #2	78.74	32.84
Data #3	85.17	35.38




Fig. 21. Tire Vent Spews Detection Result (Upside : Label Data, Downside : Prediction Results)

를 보이며 Data #2와 비교 시에도 평가 지표 모두에서 높은 성능을 보이는 것을 확인할 수 있다.

Table 4, 5는 전체 Epoch 중 Best 결과를 나타내는 Table로서 Data #3가 Precision, Recall, mAP 0.5, mAP 0.5:0.95 모두에서 가장 좋은 성능을 보여주는 것을 확인할 수 있다.

Fig. 21은 Vent Spews Label 데이터(상단)와 Data #3를 이용하여 학습된 YOLO V3 Detector를 통해 Vent Spews를 예측한 결과 데이터(하단)로서 빨간색으로 라벨, 예측 Vent Spews 영역을 표시하였다.

실험 결과를 살펴보면 본 논문에서 제시한 정규화 방법을 통해 학습한 결과가 모든 평가 지표에서 가장 높은 성능을 보이거나 특정 값에서 향상되지 않고 수렴하는 것을 확인할 수 있다. 이는 육안으로 형태를 확인하기 힘든 깊이 이미지 특성상, 학습을 위한 라벨 데이터 생성 시 발생할 수 있는 Human Error로

인한 영향으로 판단되며 해당 문제는 학습 데이터의 증가와 데이터 선별 작업을 통해 개선할 수 있을 것으로 보여진다.

### 5. 결론 및 향후 과제

제조공정에서는 실시간 생산 정보가 발생하고 있으며 생산 정보를 데이터화 하여 수집, 활용하는 문제는 공장의 스마트화에 있어서 필연적으로 추진해야 할 부분이다. 이 중 카메라를 통해 수집되는 영상 데이터는 개발 기술의 난이도와는 별도로 작업자의 육안을 대체할 수 있다는 점에서 활용할 수 있는 목표가 분명하다. 영상 데이터의 활용으로 높은 작업 난이도를 필요로 하는 공정의 경우 작업자를 대체하여 생산성을 증가시킬 수 있으며 Human Error로 인한 오류를 해결하여 생산 품질을 향상시킬 수 있다.



본 논문에서는 타이어 육안검사 공정의 스마트화를 목표로 타이어 표면에서 발생하는 결함 검출을 위해 타이어의 표면을 3D 카메라로 촬영한 타이어 표면 깊이 이미지의 낮은 대비와 기준 깊이 값의 차이 문제를 해결하기 위해 타이어 영역을 검출 후, 깊이 이미지를 정규화하고 YOLO V3 Detector를 통해 결함 영역을 검출하는 방법을 제시하였다. 실험을 위해 타이어 표면 결함 데이터 중 Vent spews를 이용하여 서로 다른 정규화 방법으로 데이터를 생성 후 비교를 거쳐 본 알고리즘이 효과적임을 보였다.

본 연구는 깊이 이미지를 이용한 타이어 표면의 결함 검출을 위한 선행 연구이다. 검출된 Vent spews 영역을 검사하여 Vent spews의 결함(기준 길이 초과)을 판단하는 것을 목표로 추가 연구를 계획 중이며 다른 타이어 표면 결함 또한 안정적으로 검출하는 것을 목표로 연구를 진행할 예정이다.

**References**

[1] Ministry of Culture, Sports and Tourism, Smart Factory (Intelligent Factory) [Internet], <https://www.korea.kr/special/policyCurationView.do?newsId=148866604>.

[2] Y. J. Cho, "The strategy for Smart Factory of Korea in the era of the Industry 4.0," *Communications of the Korean Institute of Information Scientists and Engineers*, Vol.35, No.6, pp.40-48, Jun. 2017.

[3] Automation Technology, 3D Laser Sensors for Measurements by Means of Laser-Triangulation [Internet], <https://www.automationtechnology.de/cms/en/3d-laser-sensors-for-measurements-by-means-of-laser-triangulation>.

[4] H. J. Park, Y. W. Lee and B. G. Kim, "Efficient tire wear and defect detection algorithm based on deep learnin," *Journal of Korea Multimedia Society*, Vol.24, No.8, pp.1026-1034, Aug. 2021.

[5] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask R-CNN," in *Proceedings of the IEEE International Conference on Computer Vision*, pp.2961-2969, 2017.

[6] R. Wang, Q. Guo, S. Lu, and C. Zhang, "Tire defect detection using fully convolutional network," *IEEE Access*, Vol.7, pp.43502-43510, Jan. 2019.

[7] P. Wang, P. Chen, Y. Yuan, D. Liu, Z. Huang, X. Hou, and G. Cottrell, "Understanding convolution for semantic segmentation," in *Proceeding of the IEEE Winter Conference on Applications of Computer Vision*, Jun. 2018.

[8] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," in *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, Mar. 2015.

[9] H. Y. Chan, F. K. Lam, and H. Zhu, "Adaptive thresholding by variational method," *IEEE Transactions on Image Processing*, Vol.7, No.3, Mar. 1998.

[10] P. Roy, G. Dey, S. Dutta, S. Chakraborty, N. Dey, and R. Ray, "Adaptive thresholding: A comparative study," in *Proceeding of the International Conference on Control, Instrumentation, Communication and Computational Technologies*, Jul. 2014.

[11] I. S. Oh, "Binary image," in *Computer Vision*, 3rd ed, Hanbit Academy.Inc, pp.68-71, 2018.

[12] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.779-788, 2016.

[13] J. Redmon and A. Farhadi "YOLO9000: Better, faster, stronger," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.7263-7271, 2017.

[14] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," *arXiv preprint arXiv:1804.02767*, Apr. 2018.

[15] Y. H. Lee and Y. S. Kim, "Comparison of CNN and YOLO for object detection," *Journal of the Semiconductor & Display Technology*, Vol.19, No.1. Mar. 2020.

[16] N. S. Punn, S. K. Sonbhadra, S. Agarwal, and G. Rai, "Monitoring COVID-19 social distancing with person detection and tracking via fine-tuned YOLO v3 and Deepsort techniques," *arXiv preprint arXiv:2005.01385*, Apr. 2021.



**김 현 석**

<https://orcid.org/0000-0002-0256-5844>

e-mail : ultrayo@naver.com

2015년 한국산업기술대학교 컴퓨터공학과 (학사)

2017년 한국산업기술대학교 컴퓨터공학과 (석사)

2022년 한국산업기술대학교 스마트팩토리융합과(박사)

관심분야 : Artificial intelligence, Computer Vision, Image processing



**고 동 범**

<https://orcid.org/0000-0002-6488-7291>

e-mail : dbko112@etri.re.kr

2021년 한국산업기술대학교

스마트팩토리융합과(박사)

2021년 ~ 현 재 한국전자통신연구원

차세대시스템SW 박사후 연구원

관심분야 : Smart Factory, Artificial intelligence, Cyber Physical System



**이 원 곡**

<https://orcid.org/0000-0001-7546-6559>  
e-mail : wongok99@kpu.ac.kr  
2012년 한국산업기술대학교 컴퓨터공학과  
(박사)  
2020년 ~ 현 재 한국산업기술대학교  
인공지능기술사업화연구소  
연구교수

관심분야 : Embedded System, RTOS, ESS, PV



**배 유 석**

<https://orcid.org/0000-0003-4629-4801>  
e-mail : ysbae@kpu.ac.kr  
2000년 한국과학기술원 전기및전자공학과  
(박사)  
1999년 ~ 2000년 NIST(National  
Institute of Standards and  
Technology) 연구원

2000년 ~ 2002년 삼성전자 디지털미디어연구소 책임연구원  
2002년 ~ 2003년 휴노테크놀로지 연구소 연구소장  
2003년 ~ 현 재 한국산업기술대학교 컴퓨터공학과 교수  
관심분야 : Artificial intelligence, Pattern classification,  
biometrics, Optical information processing