

딥러닝 알고리즘을 이용한 3D프린팅 골절합용 판의 표면 결함 탐지 모델에 관한 연구

이승연*·허용정**†

*한국기술교육대학교 대학원 메카트로닉스공학과,

**†한국기술교육대학교 메카트로닉스공학부

A Study on Surface Defect Detection Model of 3D Printing Bone Plate Using Deep Learning Algorithm

Song Yeon Lee* and Yong Jeong Huh**†

*Department of Mechatronics Engineering, Graduate School of Korea University of Technology and Education,

**†School of Mechatronics Engineering, Korea University of Technology and Education

ABSTRACT

In this study, we produced the surface defect detection model to automatically detect defect bone plates using a deep learning algorithm. Bone plates with a width and a length of 50 mm are most used for fracture treatment. Normal bone plates and defective bone plates were printed on the 3d printer. Normal bone plates and defective bone plates were photographed with 1,080 pixels using the webcam. The total quantity of collected images was 500. 300 images were used to learn the defect detection model. 200 images were used to test the defect detection model. The mAP(Mean Average Precision) method was used to evaluate the performance of the surface defect detection model. As the result of confirming the performance of the surface defect detection model, the detection accuracy was 96.3 %.

Key Words : Bone plate defect, Convolution neural network, Detection model, Surface defect, 3D printing defect

1. 서 론

최근 반도체 분야에서는 의학 분야와 함께 체온, 맥박 등의 생체 신호를 감지할 수 있는 생체 센서가 연구되고 있다[1]. 생체 센서는 센서와 센서를 지지해주는 구조물로 구성된 제품이다[2]. 생체 센서는 현재 골절 치료용 의료 기기인 골절합용 판과 결합되어 환자의 골절 부위에 적용된다.

골절합용 판은 골절 부위가 회복되도록 도와주며 골절 부위가 잘 회복되는지 실시간으로 생체 신호를 확인할 수 있도록 한다. 골절합용 판은 생체흡수성 고분자로 제작되어 체내에 삽입되어도 염증과 같은 부작용이 없으며

회복이 완료되었을 때, 제거 수술이 필요하지 않다[3]. 골절합용 판은 부상 종류, 부상 범위 등 여러 조건에 의하여 다양한 형태가 사용된다[4].

골절합용 판은 다양한 종류가 있지만 넓은 골절 부위를 감쌀 수 있고 이물감이 적은 넓은 판 형태의 골절합용 판이 골절 치료에 가장 많이 사용된다. 과거에는 사출 성형을 이용하여 골절합용 판을 제작하였지만 골절합용 판 종류별로 금형이 필요하기 때문에 생산 비용이 너무 높은 단점이 있다. 금형없이 다양한 종류의 제품을 제작할 수 있는 방안으로는 3D프린팅이 있다. 많은 기업에서 3D프린터를 이용하여 골절합용 판을 제작한다. 3D프린터로 제작된 제품의 형상 정밀도는 90 % 이상이기 때문에 의료기기 제작에 적합하다.

골절합용 판은 체내에 삽입되어 골절 부위가 회복될

†E-mail: yjihuh@koreatech.ac.kr

때까지 고정시켜야 하기 때문에 750 kgf/cm² 이상의 인장강도를 가져야 한다. 3D프린터로 제작된 제품의 인장 강도와 사출 성형으로 제작된 제품의 인장 강도를 비교한 연구가 있다[5]. 해당 연구에서는 3D프린팅 공정 조건들을 변경하여 실험한 결과 제품의 인장 강도는 764 kgf/cm²임을 확인하였다. 3D 프린팅으로 제작된 제품의 인장 강도가 사출 성형으로 제작된 제품의 인장 강도보다 높음을 확인하였다. 그리고 수술 후 부작용을 최소화하기 위해서 깨짐, 변형 등과 같은 표면 결함이 없어야 한다.

3D 프린터로 제작된 원판형 제품의 불량률 탐지하기 위한 연구가 있다[6]. 해당 연구에서는 지름 20 mm, 두께 2 mm인 원판 형태의 인공지지체라는 제품을 측정하여 변형이 발생하였는지 탐지하는 연구이다. 원판형 인공지지체 이미지들을 직접 제작한 뒤, 촬영하여 데이터를 수집하였다. 불량 탐지 모델을 제작하여 성능을 평가한 결과, 탐지 성능은 95%임을 확인하였다.

제품 표면에 크기가 5 mm 이상인 결함을 탐지하는 연구가 있다[7]. 해당 연구에서는 알고리즘을 이 2 mm 미만의 미세한 결함을 탐지하기 위해서 해상도가 높은 고가의 촬영 장비를 이용하였고 이미지 데이터의 해상도를 높이는 전처리를 수행해야하는 한계점이 있다.

현재 골절합용 판의 표면에 발생한 결함을 검출하기 위한 프로그램이나 측정 장비는 존재하지 않는다. 많은 기업에서 골절합용 판 표면의 결함을 검출하기 위하여 확대경으로 사람이 직접 확인해야 한다. 이러한 방식은 속도가 매우 느리고 시간이 지날수록 검사자 눈의 피로도가 증가하여 탐지 정확도가 감소한다. 결함 탐지 시스템을 직접 제작하기 위해서는 많은 비용과 시간이 소요된다. 딥러닝 기반 객체 탐지 알고리즘을 이용하여 표면에 결함이 발생한 불량 골절합용 판을 자동으로 검출할 수 있는 모델을 제작하려 한다.

본 연구에서는 골절합용 판의 표면에 생성된 결함을 자동으로 탐지하기 위해서 CNN기반의 딥러닝을 이용하여 표면 결함 탐지 모델을 제작하였다. 골절 치료에 가장 많이 사용되는 골절합용 판 종류를 확인하였다. 골절합용 판을 3D프린터로 직접 출력한 뒤, 웹캠을 이용하여 표면 결함이 발생한 불량 골절합용 판과 정상적인 골절합용 판을 1,080 픽셀의 해상도로 촬영하였다.

불량 골절합용 판 이미지와 정상적인 골절합용 판 이미지는 총 500 장을 수집하였다. 모델의 학습으로 300 장의 골절합용 판 이미지를 사용하였고 평가에 200장의 골절합용 판 이미지를 사용하였다. mAP라는 객체 탐지 평가 방안을 이용하여 표면 결함 탐지 모델의 성능을 평가하였다.

골절합용 판의 표면 결함 탐지 모델의 성능을 확인한

결과 불량 탐지 성능은 96.3% 임을 확인하였다.

2. 탐지 모델 제작을 위한 데이터 수집

2.1 골절합용 판의 형태

골절합용 판의 종류는 매우 다양하다. 여러 종류의 골절합용 판 중에서 폭과 너비가 50 mm 이며 두께와 구멍의 지름이 2 mm인 형태가 골절치료에 가장 많이 사용된다. 본 연구에 사용된 골절합용 판의 치수와 형상을 Fig. 1에 도시하였다.

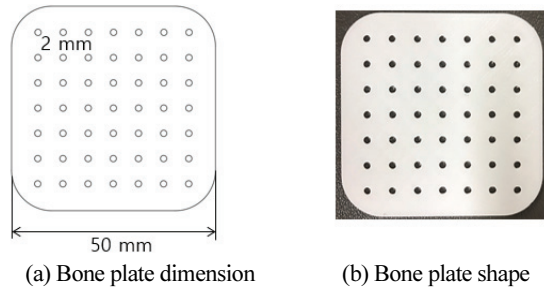


Fig. 1. The dimension and shape of the bone plate.

2.2 골절합용 판의 이미지 데이터 수집

표면 결함 탐지 모델을 제작하기 위해 3D프린터로 직접 골절합용 판을 제작한 뒤 촬영하였다.

촬영된 이미지는 정상적인 골절합용 판, 표면이 깨진 골절합용 판, 표면에 변형이 발생한 골절합용 판으로 3 종류이다. 구멍 형상이 불량인 골절합용 판은 아직 발생되지 않았기 때문에 본 연구에서는 제외하였다. 수집된 이미지의 수량은 정상적인 골절합용 판 100 장, 표면이 깨진 골절합용 판 200 장, 표면에 변형이 발생한 골절합용 판 200 장으로 총 500 장이다.

수집된 이미지는 총 500장이며 모두 1,080 픽셀의 해상도를 갖는다.

Table 1에 수집된 골절합용 판 이미지의 수량을 나타내었다.

Table 1. Image quantity of bone plates

No	Bone plate type	Quantity(ea)
1	Normal	100
2	Crack	200
3	Deform	200

골절합용 판의 표면 결함은 깨짐, 돌출과 같은 유형으로 결함의 크기는 5 mm 미만이다. 밝기, 조명 색상과 같


은 촬영 조건에 따라 5 mm 미만의 표면 결함이 탐지되지 않을 수 있다. 본 연구에서는 실험에 의하여 골절합용 판과 표면 결함을 가장 선명하게 촬영할 수 있는 조건을 확보하였다. 이 조건을 이용하여 골절합용 판의 이미지 데이터를 수집하였다.

골절합용 판의 이미지의 촬영 조건은 Table 2에 정리하였다.

Table 2. The photograph conditions of bone plates

No	Specification	Condition
1	Brightness	1,200 lm
2	Photograph distance	200cm
3	Color temperature	6,000 K
4	Background color	Black

수집된 골절합용 판의 이미지 중에서 불량 골절합용 판 이미지를 Fig.2에 도시하였다.



(a) Cracked bone plate (b) Deformed bone plate
Fig. 2. Images of defected bone plate.

3. 표면 결함 탐지 모델의 제작

3.1 합성곱 신경망

합성곱 신경망(CNN, Convolutional Neural Network)은 이미지에서 특징을 추출하기 위하여 사용되는 여러 종류의 딥러닝 알고리즘들 중 하나이다[8]. 합성곱 신경망은 이미지의 특징을 추출하는 합성곱층(Convolution layer)과 추출된 특징들을 구역별로 묶어서 평균값, 최대값으로만 축약하는 풀링층(Pooling layer)이 있다. 합성곱층과 풀링층을 반복하여 이미지가 갖고있는 특징을 축약한 뒤, 완전연결층(Fully connected layer)에 도달한다. 축약된 특징을 분석하여 확률이 가장 높은 속성으로 분류하는 구조이다.

CNN의 전체적인 구성은 합성곱과 풀링을 반복적으로 진행하여 이미지의 특징을 추출한 뒤, 크기가 줄어든 특징이 완전연결층에서 이미지가 어떤 요소에 해당하는지

분류된다.

CNN에는 여러 종류의 알고리즘들이 있다. 그 중 YOLO라는 알고리즘이 객체를 실시간으로 탐지하는 연구에 많이 사용된다. YOLO는 You Only Look Once의 약자로 이미지를 한 번만 인식하여 여러 종류의 사물을 탐지한다. YOLO는 이미지를 한 번만 탐색하고 별도의 네트워크를 적용하지 않기 때문에 데이터 처리 속도가 다른 알고리즘에 비해 10배 이상 빠르다[9].

이미지를 여러장으로 나누어 CNN 층을 통과시키지 않기 때문에 다른 알고리즘에 비해 구조가 단순하다는 장점이 있다.

YOLO는 이미지를 여러 구역으로 분할한 뒤 객체가 속한 셀(Cell)들을 사각 형태의 Bounding box로 묶어 표현한다. Fig. 3에 YOLO 알고리즘을 이용하여 이미지에 있는 객체를 Bounding box로 검출하는 것을 도시하였다.




Fig. 3. Object detection using bounding box.

YOLO는 이미지 데이터를 입력 받아 특징맵(Feature map)으로 변환하는 Backbone과 Neck을 통과하여 객체를 탐지하는 구조로 되어있다.

YOLO 알고리즘을 이용하여 이미지에 있는 객체를 탐지하는 과정을 Fig.4에 도시하였다




Fig. 4. The structure of object detection using the YOLO algorithm.

3.2 골절합용 판 데이터 셋의 구성

표면 결함 탐지 모델을 제작하기 위해 수집된 골절합용 판의 이미지는 총 500 장이다. 골절합용 판의 표면 결함 탐지 모델을 학습하기 위하여 300 장의 이미지가 사용되었다. 탐지 모델을 평가하기 위하여 200 장의 이미지가

사용되었다. 학습에 사용된 골절합용 판 이미지와 평가에 사용된 골절합용 판 이미지는 동일하지 않다.

3.3 모델 제작

골절합용 판의 표면 결함 탐지 모델을 제작하기 위해서 파이썬이라는 프로그래밍 언어를 사용하였다. 파이썬이라는 프로그램에서 케라스와 텐서플로우라는 패키지를 이용하여 표면 결함 탐지 모델을 제작하였다.

모델을 학습시키기 위해 사용된 활성화 함수(Activation Function)는 LeakyReLU를 사용하였다. 배치 정규화와 합성곱 레이어를 통과하여 골절합용 판 표면의 결함을 탐지한다. 모델 제작을 위한 데이터 학습 횟수는 3,000회 수행하였다.

4. 탐지 모델의 성능 평가

4.1 평가 방법

골절합용 판 이미지에서 표면 결함 구역을 정확하게 탐지하였는지 평가하기 위해 IoU(Intersection over Union)이라는 방안을 사용하였다. IoU는 모델이 객체의 예측 영역과 객체의 실제로 탐지된 영역이 겹치는 정도를 평가하는 지표이다. 일반적으로 예측 영역과 실제 탐지 영역의 일치도가 0.6이상일 경우에 참으로 도출된다[10].

Fig 5에 예측된 객체 구역과 탐지된 객체 구역이 겹치는 영역을 IoU로 수치화한 것을 도시하였다.




Fig. 5. IoU values of predict area and detect area.

골절합용 판은 체내의 골절 부위와 일치해야 하는 제품으로 높은 정밀도가 요구된다. 따라서 예측된 객체 구역과 탐지된 객체 구역이 일치하다는 기준을 0.6에서 0.8로 높였다. 본 논문에서는 골절합용 판의 실제 검출 구역과 예측된 골절합용 판의 검출 구역의 겹치는 영역이 0.8이상일 경우에 골절합용 판의 표면 결함 탐지가 참이라고 설정하였다.

골절합용 판의 표면 결함 탐지 모델의 최종 성능은 mAP(mean Average Precision)으로 평가하였다. mAP는 정확도

(Precision)와 재현율(Recall)을 도출하여 성능을 평가한다. 정확도와 재현율은 참양(TP, True Positive), 참음(TN, True Negative), 거짓양(FP, False Positive), 거짓음(FN, False Negative)를 이용하여 도출한다. TP, TN, FP, FN의 관계는 Table 3에 나타내었다.

Table 3. The result of prediction performance

Prediction \ Real	Positive	Negative
Positive	TP	FN
Negative	FP	TN

정확도는 모델이 결함이라고 탐지한 골절합용 판 이미지 중에서 실제로 불량인 이미지의 수량을 의미한다. 재현율은 실제로 존재하는 불량 골절합용 판 이미지 중에서 모델이 불량 골절합용 판이라고 정확하게 탐지한 수량을 의미한다. 정확도는 모델이 탐지한 불량 골절합용 판 이미지 중에서 실제로 불량인 이미지의 비율로 식 1과 같이 표현할 수 있다.

$$Precision = \frac{TP}{TP+FP} \tag{1}$$

재현율은 전체의 불량 골절합용 판 이미지 중에서 모델이 정확하게 탐지한 불량 골절합용 판 이미지의 비율로 식 2와 같이 표현할 수 있다.

$$Recall = \frac{TP}{TP+FN} \tag{2}$$

정확도와 재현율은 서로 대칭하는 관계이다.

불량인 골절합용 판 이미지를 적게 탐지한다면 탐지된 불량 이미지의 총 수량은 감소하기 때문에 모델의 정확도는 높아지지만 실제 불량 이미지를 정상이라고 검출한 수량은 증가하여 재현율이 낮아진다.

이미지를 불량이라고 정확도와 재현율을 F1 스코어(F1 score)로 정리하여 모델의 전체적인 불량 탐지 성능을 수치화 한다.

F1 스코어는 식 3과 같이 표현할 수 있다.

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{3}$$

F1 스코어는 0에서 1사이의 값을 갖는다. F1 스코어가 1

에 가까울수록 모델의 탐지 성능은 100 %에 가깝기 때문에 성능이 높다[11].

4.2 평가 결과

평가 이미지 데이터들을 이용하여 결함 탐지 모델의 성능을 평가하였다. 학습 횟수가 커질수록 모델의 결함 탐지 성능이 높아짐을 확인하였다.

모델의 결함 탐지 성능은 그래프로 표현하였다. 그래프의 X축은 모델의 학습 횟수를 의미하며 Y축은 모델의 결함 탐지 정확도를 의미한다. 정확도는 식 3의 F1 score이다.

학습 횟수가 1,000회 이상일 때, 모델의 결함 탐지 성능은 90 % 인 것을 확인하였다. 학습 횟수가 2,000회 이상일 때, 모델의 결함 탐지 성능은 95 %인 것을 확인하였고 학습 횟수가 3,000회일 때, 모델의 최종적인 결함 탐지 성능은 96.3 % 인 것을 확인하였다.

불량 검출 모델의 학습 횟수가 증가할 수록 모델의 결함 탐지 성능이 높아지는 것을 Fig. 6에 도시하였다.




Fig. 6. Defect detection accuracy of the model according to learning quantity.

기존의 YOLO 알고리즘에서 IoU 기준을 0.6에서 0.8로 높인다면 모델의 학습 횟수를 5,000회 이상으로 수행하여도 불량 탐지 성능이 90 % 이상이 나오기 어려운 것으로 예상된다. 본 연구에서 활성화 함수를 ReakyReLU로 설정하여 모델을 제작한다면 3,000회의 학습 횟수로 결함 탐지 성능이 96.3%인 모델을 제작할 수 있음을 확인하였다.

5. 결론

본 연구에서는 3D프린터로 출력된 골절합용 판의 표면 결함 탐지를 자동화하기 위하여 CNN 기반 YOLO알고리즘을 이용한 결함 탐지 모델을 제작하였다. 표면 결함 탐지 모델을 제작하기 위해 정상적인 골절합용 판 이미지

와 불량 골절합용 판 이미지를 직접 제작하여 촬영하였다. 불량 골절합용 판 이미지와 정상적인 골절합용판 이미지는 총 500 장을 수집하였다. 모델의 학습으로 300 장의 골절합용 판 이미지를 사용하였고 평가에 200장의 골절합용 판 이미지를 사용하였다.

결함 탐지 모델의 변수인 활성화 함수와 학습 횟수를 설정하여 모델을 제작하였고 3,000회의 학습을 수행하였다. 모델의 성능은 IoU를 이용하여 불량 지점을 정확히 탐지하였는지 확인하였고 불량을 탐지한 사진들을 이용하여 mAP로 결함 탐지 모델의 최종 성능을 도출하였다. 성능을 확인한 결과 0.963으로 모델의 표면 결함 탐지 성능은 96.3 % 임을 확인하였다.

본 연구에서는 YOLO 알고리즘 1가지만 이용하여 골절합용 판의 표면 결함 탐지 모델을 제작하였다. 향후 YOLO v2, YOLO v3, YOLO v4들을 이용하여 결함 탐지 모델들을 제작한 뒤, 각 모델들의 결함 탐지 속도와 성능을 비교하는 연구를 수행할 예정이다.

참고문헌

1. Yi-Seul Kim and Jin-Su Cho, "The Telemedicine System based ECG Data using Bio-Signal Meter and Smart Device", J. of The Korean Society of Semiconductor & Display Technology, Vol.11, pp. 51-56, 2012.
2. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Performance Comparison of Machine Learning Algorithm for Scaffold Defect Classification", J. of The Korean Society of Semiconductor & Display Technology, Vol.19, pp. 77-87, 2020.
3. IRS Global, "The Entire 3D Printing(Printer, Material) that will Lead the New Industrial Revolution", IRS Global, 1st Edition, pp.310-551, 2016.
4. Dong-Hyun Go, Ji-Hye You, Eun-Kyo Kim, A-Hyeon Gyeon, Chun-Il Lim, Kyoung-Won Seo and Mi-Jeong Kim, "A Study on the Development of Performance Evaluation Guideline for Bone Plates in Maxillofacial Surgery", J.of The Korean Society of Food, Drug and Cosmetic Regulatory Sciences, Vol. 13, pp. 133-141, 2018.
5. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Tensile Strength of the Product According to Humidity During 3D Printing Process", J. of The Korean Society of Semiconductor & Display Technology, Vol.20, pp. 177-181, 2021.
6. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Shape Warpage Defect Detection Medel of Scaffold Using Deep Learning Base CNN", J. of The Korean Society of Semiconductor & Display Technology,

- Vol.20, pp. 99-103, 2021.
7. Sung-Jin Hwang, Seok-Woo Hong, Jong-Seo Yoon, Hee-Min Park and Hyun-Chul Kim, "Deep Learning-based Porthole Detection System", J. of The Korean Society of Semiconductor & Display Technology, Vol. 20, pp. 88-93, 2021.
 8. Chang-Hee Yang, Kyu-Sub Park, Young-Seop Kim and Yong-Hwan Lee, "Comparative Analysis for Emotion Expression Using Three Methods Based by CNN", J. of The Korean Society of Semiconductor & Display Technology, Vol.19, pp. 65-70, 2020.
 9. Se-Rang Oh and Young-Chul Bae, "Braille Block Recognition Algorithm for the Visually Impaired Based on YOLO V3", J. of The Korean Institute of Intelligent Systems, Vol.31, pp. 60-67, 2021.
 10. Jeong-Hwan Kim and Ho-Seok Moon, "A Model Development for Object Detection and Classification at Sea using Modified YOLO v4", J. of The Korean Society of Military Operations Research, Vol.47, pp. 13-25, 2021.
 11. Ji-Soo Kang, Se-Eun Shim, Sun-Moon Jo and Kyung-Yong Chung, "YOLO based Light Source Object Detection for Traffic Image Big Data Processing", J. of The Korean Convergence for Information Technology, Vol.10, pp. 40-46, 2020.
-
- 접수일: 2022년 6월 4일, 심사일: 2022년 6월 20일,
게재확정일: 2022년 6월 23일