

CNN 기반 딥러닝을 이용한 인공지능체의 외형 변형 불량 검출 모델에 관한 연구

이승연*·허용정**†

*한국기술교육대학교대학원 메카트로닉스공학과,

**한국기술교육대학교 메카트로닉스공학부

A Study on Shape Warpage Defect Detection Model of Scaffold Using Deep Learning Based CNN

Song-Yeon Lee* and Yong Jeong Huh**†

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

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

ABSTRACT

Warpage defect detecting of scaffold is very important in biosensor production. Because warped scaffold cause problem in cell culture. Currently, there is no detection equipment to warped scaffold. In this paper, we produced detection model for shape warpage detection using deep learning based CNN. We confirmed the shape of the scaffold that is widely used in cell culture. We produced scaffold specimens, which are widely used in biosensor fabrications. Then, the scaffold specimens were photographed to collect image data necessary for model manufacturing. We produced the detecting model of scaffold warpage defect using Densenet among CNN models. We evaluated the accuracy of the defect detection model with mAP, which evaluates the detection accuracy of deep learning. As a result of model evaluating, it was confirmed that the defect detection accuracy of the scaffold was more than 95%.

Key Words : 3D Printing Scaffold, CNN, Deep Learning, Defect Detection Model, Scaffold Warpage

1. 서 론

현재의 반도체 분야는 조직공학 분야와 같이 생체 신호를 감지할 수 있는 생체 적합성 센서를 개발하고 있다[1].

생체 적합성 센서는 심장, 혈관 등의 조직에서 산소포화도, 혈압 등의 생체 신호를 감지한다. 따라서 체내에서 안전한 물질로 제작되어야 한다. 생체 적합성 센서는 생체 신호를 감지할 수 있는 센서와 센서 주변에 세포가 배양되기까지 외형을 지지해주는 인공지능체를 나눌 수 있다[2].

생체 적합성 센서는 삽입될 조직에 따라 목표하는 기계적 강도가 다르다. 서로 다른 목표의 기계적 강도를 맞

춰야 하기 때문에 다양한 원료를 사용하여 목표한 기계적 강도에 맞는 인공지능체를 제작할 수 있어야 한다.

세포배양 실험에는 많은 수량의 인공지능체를 사용하기 때문에 생산 속도가 높아야 한다.

이러한 조건의 인공지능체는 고분자 원료의 필라멘트(Filament)로 이용할 수 있는 FDM 방식의 3D프린터로 제작하기에 적합하다[3].

FDM 방식의 3D프린터를 사용하여 제품을 출력할 경우 인공지능체를 측면에서 확인할 때, 인공지능체가 베드(Bed)와의 접촉면에서 변형되는 불량이 발생할 수 있다. 변형된 인공지능체는 체내에 삽입되었을 때 삽입 부위에 완벽히 일치하지 않아 센서 주위로 세포가 배양되지 않는 문제가 발생한다. 따라서 인공지능체는 변형이 발생하

†E-mail: yjhuh@koreatech.ac.kr

면 안 된다[4].

Fig. 1(a)에 FDM 방식의 3D프린터를 사용하여 인공지지체를 출력하였을 때, 측면에서 바라본 인공지지체의 변형된 외형을 도시했다. 그리고 Fig. 1(b)에 FDM 방식의 3D프린터를 사용하여 인공지지체를 출력하였을 때, 측면에서 바라본 인공지지체의 변형되지 않은 정상적인 외형을 도시했다.




Fig. 1(a). Measured warped scaffold shape.



Fig. 1(b). Measured normal scaffold shape.

외형이 변형된 인공지지체를 검출하기 위한 프로그램이나 측정 장비는 존재하지 않는다. 따라서 변형된 인공지지체를 검출하기 위하여 촬영한 뒤, 사람이 직접 육안으로 확인해야 한다. 이러한 인공지지체 불량 검출 방식은 속도가 매우 느리다. 그리고 시간이 지날수록 눈의 피로도가 증가하여 불량 검출의 정확도가 감소할 수 있다. 이러한 딥러닝 기술을 이용하여 측면이 변형된 인공지지체의 검출이 가능한 모델을 제작하려 한다.

현재 다양한 분야에서 불량 제품의 검출 시스템은 CNN(Convolution Neural Network)기반의 딥러닝(Deep Learning)을 이용하여 연구되고 있다.

본 논문에서는 변형된 인공지지체를 측정할 때 속도가 느리고 정확도가 떨어지는 문제를 CNN기반의 딥러닝을 이용하여 불량검출 모델을 제작했다. 세포배양연구에 자주 사용되는 인공지지체의 형태를 확인한 결과 정사각형 모양의 인공지지체가 많이 사용된 것을 확인하였고 직접 3D프린터로 출력한 뒤, 웹캠을 이용하여 여러 형태로 변형된 인공지지체와 정상적인 인공지지체를 1,080 pixel의 이미지로 촬영했다.

변형된 인공지지체의 이미지와 정상적인 인공지지체의 이미지 1,000 ea 중에서 학습 데이터로 700 ea의 인공지지체 이미지를 사용해 인공지지체의 외형 변형 불량 검출모델을 제작하였고 mAP라는 딥러닝 이미지 평가 방안을 이용하여 모델의 성능을 평가했다.

인공지지체 외형 불량 검출 모델의 성능을 확인한 결과 외형 변형 불량 검출 정확도가 95% 이상인 것을 확인했다.

2. 모델 제작을 위한 데이터 수집

2.1 인공지지체 시편

가로, 세로 20mm, 높이 2 mm의 사각형 인공지지체를 시편으로 선정했다. 사각형의 인공지지체는 1개만 사용할 수 있고 필요에 따라 여러 개를 붙여서 사용 가능하여 세포배양 연구에 많이 사용되기 때문이다. Fig. 3에 가로, 세로 20mm, 높이 2 mm인 사각형 인공지지체를 도시했다.




Fig. 3. Square type scaffold widely used in cell culture.

2.2 모델 제작에 사용된 인공지지체 이미지

FDM 방식의 3D프린터를 사용하여 제품을 출력할 경우 인공지지체를 측면에서 확인할 때, 인공지지체가 베드(Bed)와의 접착면에서 변형되는 불량이 발생할 수 있다.

인공지지체의 외형 변형 불량은 3가지로 나뉜다. Fig. 4에 측면에서 측정한 인공지지체의 변형 유형별 실제 이미지를 도시했다.

(a)는 좌측 하단만 변형된 인공지지체의 실제 이미지이고 (b)는 우측 하단만 변형된 인공지지체의 실제 이미지이다.

(c)는 양쪽 하단 모두가 변형된 인공지지체의 실제 이미지이고 (d)는 변형되지 않은 정상적인 인공지지체의 실제 이미지이다.




Fig. 4. Scaffold warpage of various types.

2.3 인공지능체 촬영에 사용된 장비

촬영하려는 인공지능체들은 가로, 세로 20mm, 높이 2 mm의 크기이다. 따라서 인공지능체의 변형을 촬영하기 위해서는 카메라의 해상도가 1,000 pixel 이상이어야 한다.

인공지능체를 촬영하기 위하여 청연엠에스에서 제작한 NV50-HD100이라는 제품을 사용했다.

NV50-HD100은 1,000 pixel 이상이면서 인공지능체를 촬영하기 위하여 자유로운 각도조절이 하다. 따라서 NV50-HD100을 인공지능체 촬영을 위한 웹캠으로 선정했다.

Fig 5에 인공지능체의 외형을 촬영하기 위한 USB형 웹캠을 도시했다.



Fig. 5. Webcam used to warpape photographing of scaffolds.

3. 인공지능체 외형 불량 검출 모델 제작

3.1 CNN

CNN은 필터를 이용하여 입력 이미지에서 특징을 추출하여 이미지를 분류하기 위해 사용되는 방법이다[5].

CNN은 합성곱층(Convolution layer)과 풀링층(Pooling layer), 완전연결층(Fully connected layer)로 구성되어 있다.

합성곱층은 필터를 이용하여 이미지의 특징을 추출하는 층이다. 풀링층은 최대값 또는 평균값만 추출하여 이미지의 크기를 축소시키는 층이다.

CNN의 전체적인 구성은 합성곱과 풀링을 반복적으로 진행하여 이미지의 특징을 추출한 뒤, 크기가 줄어든 특징이 완전연결층에서 이미지가 어떤 요소에 해당하는지 분류된다[6].

Fig 6에 합성곱층, 풀링층, 완전연결층으로 구성되어 입력된 이미지의 특징을 추출하고 축소하는 과정을 반복하여 이미지를 분류하는 CNN의 구조를 도시했다.




Fig. 6. CNN structure to detect defects.

3.2 모델 제작에 사용된 신경망

인공지능체의 변형 불량 검출 모델은 Densenet을 기반으로 제작했다.

Densenet은 기울기 소멸(Vanishing gradient) 문제가 완화된다. 그리고 특징 전달이 강력하며 추출된 특징을 재사용하기 때문에 파라미터의 수를 감소시켜 불필요한 학습이 필요가 없다[7].

Fig 7에 인공지능체 외형 변형 불량 검출 모델에 사용된 Densenet의 구조를 도시했다.




Fig. 7. Densenet structure used in detection model of scaffold defect.

본 논문을 위해 제작할 인공지능체의 외형 변형 불량 검출 모델은 복잡한 구조가 아닌 단순한 외형의 인공지능체를 측정하기 때문에 파라미터의 수가 적으며 간단한 모델을 제작하기 위해 Desnet을 사용했다.

3.3 인공지능체 이미지 데이터셋 구성

외형 변형 불량 검출 모델의 제작에 사용된 인공지능체 이미지는 1,000 ea 모두 FDM 방식 3D프린터로 직접 출력한 인공지능체로 사용되었다.

인공지능체 외형 변형 불량 검출 모델 제작을 위한 인공지능체 전체 이미지 수량은 1,000 ea 으로 학습에 사용된 인공지능체 이미지 수량은 700 ea 이다. 나머지 300 ea의 인공지능체 이미지는 평가에 사용되었으며 학습에 사용

된 인공지능지체 이미지와 평가에 사용된 인공지능지체 이미지는 서로 중복되지 않았다.

3.4 모델 제작

외형 변형 불량 검출모델의 제작에 사용된 프로그래밍 언어는 파이썬을 사용했다. 또한 모델 제작을 위한 패키지는 케라스와 텐서플로우를 사용했고 모델 제작에 사용된 프로그램은 파이참을 사용했다.

인공지능지체 외형 변형 불량 검출 모델을 제작하기 위하여 데이터의 학습은 3,000회 진행했다.

모델 제작에 있어서 컴퓨터의 사양은 중요하다. 이미지의 해상도가 1,080 픽셀이기 때문에 용량이 크고 학습해야 할 이미지의 수량이 많기 때문에 고사양의 컴퓨터가 필요하다.

Table 1에 외형 변형 불량 검출모델을 제작하기 위한 컴퓨터 사양을 나타냈다.

Table 1. Production environment of detection model

No	Element	Specification
1	OS	Windows 10
2	CPU	Intel i7 (64 bit)
3	GPU	Geforce RTX 2080 Ti 11GB
4	RAM	64 GB

인공지능지체 외형 변형 불량 검출 모델에 사용된 Densenet 알고리즘은 Dense block과 Transition이 각 4회 반복되는 구조이다. Dense block은 합성곱 4회를 반복 실시한다. Transition은 합성곱과 풀링을 1회씩 실시한다. 모든 과정이 완료되면 풀링하여 불량여부를 검출한다. Densenet은 다른 CNN알고리즘에 비하여 구조가 비교적 간단하기 때문에 활성화함수로 Softmax를 사용했다.

4. 모델 평가

4.1 평가 방법

인공지능지체의 외형 변형 불량 검출 모델의 성능은 mAP(mean Average Precision)으로 평가했다. mAP는 딥러닝 객체 검출 알고리즘에서 주로 사용되는 성능 지표이다. mAP는 IoU(Intersection of Union)을 사용한다. IoU는 이미지에서 사물의 실제 검출 구역과 예측된 검출 구역 사이의 겹치는 영역의 비율을 의미한다[8].

인공지능지체는 체내에 적용되어야 하는 높은 정밀도를 요구하는 제품이다. 일반적으로 사물의 검출영역이 0.6이

상일 경우에 참인 연구와는 달리 높은 정밀도를 요구하는 모델이다. 따라서 본 논문에서는 인공지능지체의 실제 검출 구역과 예측된 인공지능지체의 검출 구역의 겹치는 영역이 0.8이상일 경우에 인공지능지체의 외형 변형 불량 검출이 참이라고 설정했다.

4.2 평가 결과

평가 데이터들을 이용하여 학습 횟수에 따라 불량 검출 모델의 성능을 mAP로 평가하였을 때, 학습 횟수가 높아질수록 모델의 불량 검출 성능이 높아지는 것을 확인했다.

Fig 8에 학습횟수에 따른 불량 검출 모델의 성능이 높아지는 것을 그래프로 도시하였다.




Fig. 8. Performance of defect detection model according to number of data learning.

평가 데이터를 이용하여 CNN기반의Densenet알고리즘으로 제작된 불량 검출 모델이 변형된 불량 인공지능지체의 검출을 확인할 수 있었다. Fig 9에 제작된 불량 검출 모델이 변형된 불량 인공지능지체를 검출하는 모습을 도시했다.




Fig. 9. Detection of defect scaffolds using defect detection model.

변형 불량 검출 모델의 성능을 평가한 결과 왼쪽 하단만 변형된 인공지능체의 불량 검출 성능은 96.3 %이며, 오른쪽 하단만 변형된 인공지능체의 불량 검출 성능은 95.9 %이다. 그리고 양쪽 모두 변형된 인공지능체의 불량 검출 성능은 95.3 %로 3가지 검출 성능의 평균은 95.8 %임을 확인할 수 있다.

Table 2에 인공지능체의 변형 조건별 불량 검출 모델의 성능을 나타내었다.

Table 2. Performance of scaffold warpage detection

No	Defect part	Detection performance
1	Left bottom	96.3 %
2	Right bottom	95.9 %
3	Both bottom	95.3 %
Average		95.8 %

5. 결 론

본 연구에서 FDM 방식의 3D프린터로 출력된 인공지능체를 사람이 일일이 측정하여 속도가 느린 문제를 확인할 수 있었다. 이러한 문제를 CNN(Convolution Neural Network)기반의 딥러닝(Deep Learning) 방법인 Densenet을 이용하여 인공지능체의 외형 변형 불량을 검출할 수 있는 모델을 제작할 수 있었다. USB현미경을 이용하여 인공지능체의 측면 이미지를 수집하고 특징을 추출할 수 있었다. 딥러닝 기반의 CNN방안중에서 Densenet을 이용하여 인공지능체 외형 변형 불량 검출 모델을 제작할 수 있었다. Densenet의 구조를 확인한 뒤, 활성화 함수를 선택할 수 있었다. 인공지능체 외형 변형 불량 검출 모델의 성능을 이미지 처리의 평가 방법인 mAP로 평가할 수 있었다. 검출 구역과 예측 구역의 겹치는 영역이 0.8이상일 경우를 확인한 결과 검출 정확도가 95.8 % 임을 정량적으로 확인할 수 있었다.

참고문헌

1. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Prediction Model of Scaffold Pore Size Using Machine Learning", J. of The Korean Society of Semiconductor & Display Technology, Vol.18, pp. 46-50, 2019.
2. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Square Pore Shape Discrimination Model of Scaffold Using Machine Learning Based Multiple Linear Regression", J. of The Korean Society of Semiconductor & Display Technology, Vol.19, pp. 59-64, 2020.
3. Sang-Ho Park, Joo-Hyeong Lee and Jung-Min Kim, "Development of Heating System for Ensuring Accuracy of Output for Open 3D Printer", J. of The Korean Society of Mechanical Engineers, Vol.41, pp. 477-482, 2017.
4. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Prediction Model Performance of Scaffold Pore Size Using Machine Learning Regression Method", J. of The Korean Society of Semiconductor & Display Technology, Vol.19, pp. 36-41, 2020.
5. Yong-Hwan Lee and Heung-Jun Kim, "Implementation of Fish Detection Based on Convolution Neural Networks" J. of The Korea Society of Semiconductor & Display Technology, Vol.19, pp.124-129, 2020.
6. Chang-Hee Yang, Kyu-Sub Park, Young-Sub Kim and Yong-Hwan Lee, "Comparative Analysis for Emotion Expression Using Three Methods Based by CNN" J. of The Korea Society of Semiconductor & Display Technology, Vol.19, pp.65-70, 2020.
7. Soo-Hyeon Lee, Dong-Hyun Kim and Hae-Yeoun Lee, "Camera Model Identification Using Modified DenseNet and HPF", J. of Korean Institute of Information Technology, Vol.17, pp. 11-19, 2019.
8. Ho-Yeon Ahn and Jong-Taek Lee, "Classification of vehicles Based on Faster R-CNN Suitable for Use in Actual Road Environments" J. of The Korea Institute of Intelligent Systems, Vol.28, pp.210-218, 2018.

접수일: 2021년 3월 12일, 심사일: 2021년 3월 17일,
게재확정일: 2021년 3월 19일