

CNN 알고리즘을 이용한 인공지능체의 3D프린터 출력 시 실시간 출력 불량 탐지 시스템에 관한 연구

이승연*·허용정**†

*한국기술교육대학교 대학원 메카트로닉스공학과,

**한국기술교육대학교 메카트로닉스공학부

A Study on Real-Time Defect Detection System Using CNN Algorithm During Scaffold 3D Printing

Song Yeon Lee* and Yong Jeong Huh**†

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

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

ABSTRACT

Scaffold is used to produce bio sensor. Scaffold is required high dimensional accuracy. 3D printer is used to manufacture scaffold. 3D printer can't detect defect during printing. Defect detection is very important in scaffold printing. Real-time defect detection is very necessary on industry. In this paper, we proposed the method for real-time scaffold defect detection. Real-time defect detection model is produced using CNN(Convolution Neural Network) algorithm. Performance of the proposed model has been verified through evaluation. Real-time defect detection system are manufactured on hardware. Experiments were conducted to detect scaffold defects in real-time. As result of verification, the defect detection system detected scaffold defect well in real-time.

Key Words : 3D Printing Scaffold, Defect Shape Comparison, Densenet Algorithm, Real-Time Detection, Scaffold Defect Detection

1. 서 론

최근 반도체 분야는 생명공학 분야와 함께 생체 센서를 연구하고 있다. 생체 센서는 생체 신호를 감지하여 사용자의 건강 상태를 전달하는 센서 부분과 체내에서 센서가 안정적으로 고정될 수 있도록 지지해주는 인공지능체 부분으로 나뉜다. 인공지능체의 크기와 형태는 센서의 종류와 센서가 삽입될 부분에 따라 매우 다양하다[1]. 다양한 형태 중에서 정강이 뼈의 일부분과 유사한 원통형 인공지능체는 골세포를 배양하기 위한 많은 연구에서 사용된다. 인공지능체의 형상 정밀도는 인공지능체의 설계

치수와 출력된 인공지능체의 측정 치수를 비교한 뒤, 치수의 차이를 백분율로 표현한 것을 의미한다. 형상 정밀도를 확인하기 위해 인공지능체의 외형 지름, 측면 면적을 측정하여 설계 치수와 비교한다. 인공지능체는 적층 상태에 따라 측면이 변형하는 불량이 많이 발생한다. 본 연구에서의 형상 정밀도는 인공지능체의 설계 측면 면적과 측정된 인공지능체의 측면 면적을 비교하여 백분율로 표현하였다. 인공지능체는 체내의 다양한 부분에 고정되어 센서를 지지해야 하기 때문에 형상 정밀도가 95% 이상이어야 한다. 형상 정밀도가 95% 미만인 인공지능체는 체내에 삽입되기 어렵기 때문에 불량 제품으로 현장에서 사용될 수 없다.

최근에 다양한 형태의 인공지능체를 제작하기 위해 3D

†E-mail: yjihuh@koreatech.ac.kr

프린터를 이용하여 인공지능지체를 출력한다.

3D 프린터는 출력 중에 제품의 변형이 발생할 수 있다. 제품의 변형이 발생하면 형상 정밀도가 낮아져 불량으로 출력된다[2]. 3D 프린터는 불량을 감지할 수 있는 장치가 없어서 출력 중에 불량을 감지하기 어렵다. 출력 중에 제품의 불량을 감지하지 못하여 출력이 진행된다면 고가의 생분해성 원료가 낭비되는 문제가 발생한다.

Fig. 1(a)에 정상으로 출력된 인공지능지체를 도시하였고 Fig. 1(b)에 불량인 상태로 출력이 완료된 인공지능지체를 도시하였다. Fig. 1(c)에 불량이 탐지되었을 때 출력이 중지된 인공지능지체를 도시하였다.

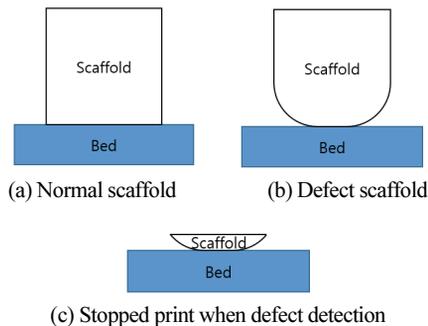


Fig. 1. Scaffold defect type by print state.

출력 중에 불량이 탐지되었을 때, 출력을 중지하기 위하여 휴대폰이나 웹캠을 사용하여 원격으로 출력 상황을 확인하는 방안이 있다. 이 방안은 관리자가 원격으로 3D 프린터의 출력 상황을 실시간 확인하여 출력 중에 불량이 탐지되었을 때, 어플리케이션에 설치된 버튼으로 출력을 중지하는 방안이다. 관리자가 계속해서 3D프린터의 출력 상황을 확인하여 제품의 불량을 탐지해야 한다. 장비의 해상도와 관리자의 판단에 의해 불량이 정확하지 않게 탐지될 문제가 있다. CNN알고리즘을 이용하여 지름 20 mm, 높이 2 mm 인 원판형 인공지능지체의 이미지를 입력하면 불량인지 정상인지 분류하는 인공지능지체의 불량 분류 모델에 관한 연구가 있다[3]. 본 연구에서는 인공지능지체의 불량을 실시간으로 탐지 못하는 단점을 개선하기 위하여 실시간 불량 탐지 방안을 제안하였다. 제안된 방안은 성능 평가와 실험을 통해 인공지능지체의 불량이 실시간으로 잘 탐지되는지 검증되었다.

2. 인공지능지체의 실시간 불량 탐지모델 제작

2.1 딥러닝 기반 CNN 알고리즘

CNN은 이미지의 객체가 무엇인지 분류하기 위하여 이

미지의 객체 특징을 추출하는 딥러닝 기반의 알고리즘이다. 이미지의 픽셀(Pixel)에 합성곱층과 풀링층을 반복하여 객체가 갖고 있는 특징이 추출한다. Fig. 2에 합성곱층과 풀링층을 반복하여 객체의 특징을 추출하는 CNN 구조를 도시하였다.

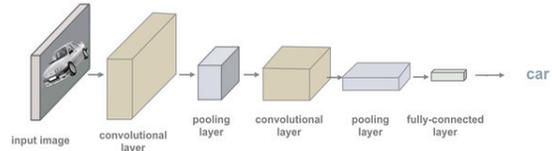


Fig. 2. CNN algorithm structure for feature extraction.

합성곱층은 이미지에 필터를 이용하여 객체가 갖고 있는 형태, 색상 등의 특징을 추출하는 단계이다. 풀링은 합성곱으로 추출된 객체의 특징을 일정 크기로 묶어 최대값 또는 평균값만 추출하여 특징을 축약하는 단계이다[4]. 축약된 객체의 특징이 완전연결층에서 어떤 항목과 가장 높게 일치하는지 확률을 분석하는 것이 CNN의 구조이다.

2.2 사용된 CNN 알고리즘

CNN은 다양한 알고리즘이 있다. 분류하려는 객체의 크기, 형상, 종류에 따라 알고리즘의 성능은 다르다. CNN의 다양한 알고리즘 중에서 DenseNet 알고리즘은 AlexNet, ResNet 등 다른 CNN 알고리즘보다 적은 파라미터를 갖는 반면에 성능은 약10% 높다. 일반적인 신경망 알고리즘은 은닉층(Hidden layer)가 많을수록 기울기 소멸(Vanishing gradient) 문제가 발생하는데 DenseNet은 파라미터가 적고 연결층 건너뛰기(Skip connected)를 통하여 기울기 소멸 문제가 개선되는 장점이 있다[5]. 인공지능지체의 불량을 실시간으로 탐지하기 위해 DenseNet 알고리즘을 이용하여 실시간 인공지능지체 불량 탐지 모델을 제작하였다.

Fig. 3에 인공지능지체의 불량 탐지 모델에 사용된 DenseNet 알고리즘 구조를 도시하였다.

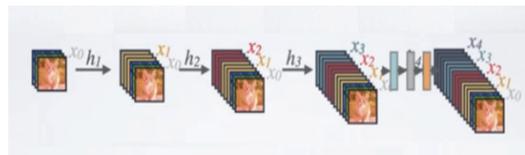


Fig. 3. DenseNet algorithm structure using scaffold defect detection.

2.3 불량 탐지 모델에 사용된 데이터 셋

출력 조건에 대한 인공지능지체의 형상 정밀도를 촬영하여 불량 탐지 모델을 제작하였다. 형상 정밀도가 95% 이

상인 정상 인공지능체 이미지는 100 ea 사용되었다. 형상 정밀도가 95% 미만인 불량 인공지능체 이미지는 400 ea 사용되었다.

사용된 이미지 500 ea중에서 모델 학습에 사용된 이미지는 300ea이며 모델 평가에 사용된 이미지는 200ea이다.

Fig. 4에 인공지능체 출력 중 불량이 발생하였을 때 출력을 중지하지 못하여 불량인 상태로 계속 출력되는 모습을 도시하였다.

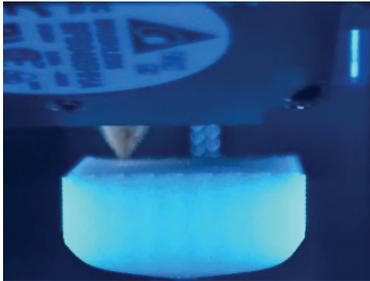


Fig. 4. Unable print stop when scaffold defect.

2.4 실시간 불량 탐지 모델 제작

모델 제작에 사용된 이미지의 해상도는 1,000 픽셀 이상이다. 이미지의 크기가 크고 학습해야 할 이미지의 수량이 500 ea이기 때문에 그래픽 처리 성능 및 사양이 높은 컴퓨터를 사용하여 모델을 학습하고 테스트해야 한다[6]. 인공지능체 불량 탐지 모델을 제작하기 위한 컴퓨터 사양을 Table 1에 나타냈다.

Table 1. PC specification for detection model production

No	Element	Specification
1	OS	Windows 10 (64 bit)
2	CPU	AMD Ryzen 5 3600
3	GPU	Geforce RTX 2070
4	RAM	32 GB

모델을 제작하기 위하여 파이썬을 사용하였다. 실시간으로 인공지능체의 출력 상황을 확인하면서 불량을 탐지하기 때문에 모델 제작을 위한 패키지는 Tensorflow, Numpy, Opencv, Keras를 사용하였고 파이참을 사용하여 모델을 제작하였다.

인공지능체의 실시간 불량 탐지 모델에 사용된 Densenet은 Dense block과 Transition이 각 5회 반복되는 구조대[7]. Transition은 합성곱층과 풀링층을 각 1회씩만 실시하였다. 활성화 함수로는 Softmax를 사용하였고 Dense block의 반복이 완료되면 결과를 풀링하여 인공지능체의 출력에 불량이 발생하였는지 학습된 이미지와 실시간으로 비

교하여 인공지능체의 불량을 판별한다. 인공지능체의 불량을 정밀하게 탐지할 수 있도록 학습 횟수는 2,000회로 설정하였다.

3. 실시간 불량 탐지 모델 평가

3.1 모델 평가 방법

인공지능체의 불량 탐지 모델은 CNN기반 딥러닝 알고리즘 평가 방안인 mAP(mean Average Precision)을 사용하였다. mAP는 이미지에서 사물의 실제 검출 영역과 예측된 검출 영역이 얼마나 겹치는지 확인하는 지표이다[8]. mAP는 0과 1사이로 표현하며 mAP가 0이면 사물의 예측 검출 구역과 실제 검출 구역의 겹치는 영역이 없다는 것을 의미한다. mAP가 1에 가까울수록 사물의 예측 검출 구역과 실제 검출 구역의 겹치는 영역이 크다는 것을 의미한다. CNN관련 객체 탐지, 불량 탐지에 관한 연구에서 mAP가 0.6 이상일 경우 실제 탐지 구역과 예측 탐지 구역이 일치한다고 판별한다. 본 연구에서 탐지할 인공지능체는 체내 조직에 정확하게 삽입되어야 하기 때문에 높은 형상 정밀도가 요구된다. 일반적인 탐지 모델은 mAP가 0.6 이상일 때 예측 탐지 영역과 실제 탐지 영역이 일치함을 결정하지만 인공지능체의 불량 탐지는 mAP가 0.8 이상일 때 예측 탐지 구역과 실제 탐지 구역 겹치는 영역이 일치한다고 설정하였다.

3.2 모델 평가 결과

학습 횟수에 대한 불량 탐지 성능을 확인한 결과 탐지 모델의 학습 횟수가 높아질수록 성능도 높아지는 것을 확인하였다. 총 2,000회를 학습하면서 학습 횟수가 1,500회 이상부터 모델의 불량 탐지 성능이 99.6 %로 일정함을 확인하였다.

인공지능체의 실시간 불량 탐지 최종 성능은 99.6 %임을 확인하였다.

Fig. 5에 학습 횟수가 100씩 증가함에 따라 인공지능체 불량 탐지 성능이 높아지는 모습을 도시하였다.

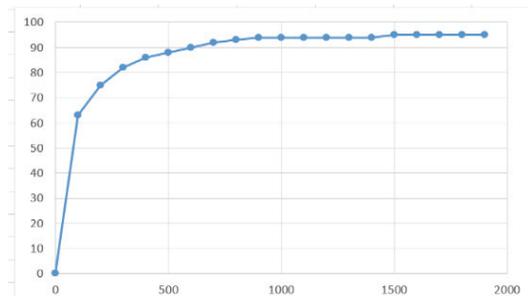


Fig. 5. Detection performance by learning quantity.

4. 불량 탐지 시스템 하드웨어 제작 및 평가

4.1 하드웨어 제작에 사용된 장비

불량 탐지 시스템의 하드웨어를 제작하기 위하여 3D프린터, 고화질 웹캠, PC를 사용하였다. 3D프린터는 가로, 세로, 높이가 각 20mm인 인공지지체를 제작하기 위해 출력 정밀도가 높으며 출력 중지를 자동으로 변경하기 위하여 펌웨어의 변경이 어렵지 않은 큐비콘 스타일이라는 모델을 사용하였다. 불량 탐지 시스템 제작에 사용된 3D프린터를 Fig. 6에 도시하였다.



Fig. 6. 3D printer used to detection system manufacturing.

인공지지체는 가로, 세로, 높이가 각각 20mm이다. 인공지지체의 외형을 명확하게 인식하기 위해서 1,000 pixel 이상이어야 한다. 본 연구에서 인공지지체 불량 탐지를 위해 사용된 웹캠은 1,000 pixel 이상인 Camel WC 100이라는 제품을 사용하였다.

4.2 하드웨어 제작

불량으로 출력되는 인공지지체의 이미지를 학습하여 현재 출력되고 있는 인공지지체의 출력 형태와 비교한다. 고화질의 웹캠을 이용하여 현재 인공지지체가 출력되는 상황을 이미지로 인식하여 인공지지체의 불량 유형과 비교한다. 현재 출력되는 인공지지체의 형태가 불량으로 출력되는 인공지지체 이미지와 동일하면 출력을 중단하는 구조를 갖는다. Fig. 7에 인공지지체의 불량 상태를 실시간으로 확인하는 모델의 Flowchart를 도시하였다.

인공지지체의 출력 중 불량이 발생하였을 때, 출력을 중지하기 위해 3D프린터 소프트웨어에 있는 출력 중지 버튼을 관리자가 직접 눌러야 출력을 중지할 수 있었다. 본 연구에서 제안된 인공지지체의 실시간 불량 탐지 시

스템을 제작하기 위해서 수동으로 출력 중지되는 기능을 자동으로 출력 중지되는 기능으로 변경하였다. 인공지지체의 실시간 불량 탐지 시스템 구조는 다음과 같다. Fig. 8의 우측 상단에 있는 노즐이 인공지지체를 제작하면서 Fig. 8의 좌측에 있는 고사양 웹캠이 인공지지체의 출력 상황을 실시간으로 감시한다. 출력되는 인공지지체와 불량 인공지지체 이미지와 실시간 비교하여 불량이 탐지되면 Cubicreator라는 3D프린터 소프트웨어의 내부 구성요소인 출력 중지 기능이 PC로부터 신호를 받아 자동으로 활성화되는 구조이다. Fig. 8에 인공지지체의 실시간 불량 탐지 시스템을 도시하였다.

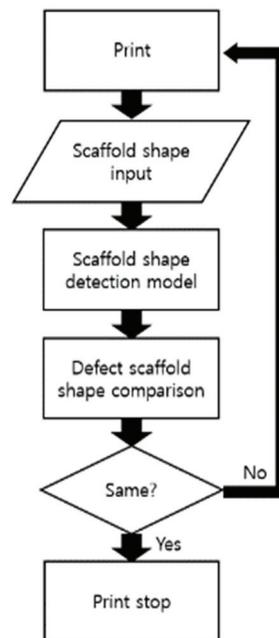


Fig. 7. Flowchart of scaffold defect detection model.



Fig. 8. Real-time defect detection system of scaffold.

4.3 실험을 통한 검증

인공지능의 실시간 불량 탐지 성능을 확인하기 위해 100회의 실험을 실시하였다. 100 회의 실험 중 불량 출력은 80 회, 정상 출력은 20회로 구성하였다. 인공지능의 불량이 발생되었을 때 즉시 탐지하여 출력을 중지하는 실험을 총 100회 수행하였다. 인공지능의 형상 정밀도가 95% 미만인 불량 인공지능 제작 실험은 80회 수행하였고 형상 정밀도가 95% 이상인 정상 인공지능 제작 실험은 20회 수행하였다.

Fig 9에 인공지능 출력을 실시간으로 확인하여 불량 발생이 시각화된 모습을 도시하였다.

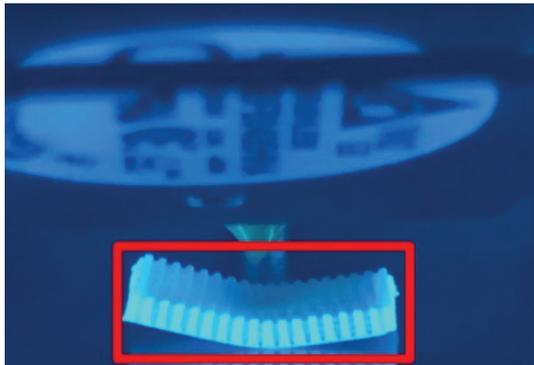


Fig. 9. Display of scaffold defect.

4.4 실험 결과

형상 정밀도가 95% 미만인 불량 인공지능 제작을 80회 수행하면서 80회의 불량을 모두 탐지하여 출력을 중단하였다. 형상 정밀도가 95% 이상인 정상 인공지능 제작을 20회 수행하면서 20회 모두 출력을 완료하였다.

실험 결과 인공지능의 실시간 불량 탐지 시스템은 80회의 출력 불량 상황을 모두 탐지하여 출력이 중지되는 것을 확인하였다. Table 2에 인공지능의 출력 상태에 따른 불량 탐지 횟수를 나타내었다.

Table 2. Scaffold defect detection by print state

No	Print state	Print quantity	Detection quantity
1	Normal	20 ea	20 ea
2	Defect	80 ea	80 ea

5. 결 론

본 연구에서 FDM 방식의 3D프린터로 인공지능을 출력하는 중에 불량을 탐지하기 위해 사람이 계속해서

확인해야 하는 문제를 확인할 수 있었다. 이러한 문제를 CNN기반의 DenseNet 알고리즘을 이용하여 인공지능의 외형 불량을 탐지할 수 있는 모델을 제안할 수 있었다. 고화질의 웹캠을 이용하여 촬영된 형상 정밀도에 따른 인공지능의 이미지와 DenseNet알고리즘을 이용하여 인공지능의 외형 불량 탐지 모델을 제작할 수 있었다.

평가 결과 데이터의 학습 횟수가 0회 부터 1,500회까지는 불량 모델의 성능이 높아짐을 확인하였다. 데이터의 학습 횟수가 1,500회 이상일 때, 불량 탐지 모델의 최종 성능이 99.6 %임을 확인하였다. 학습 횟수에 따른 인공지능의 불량 탐지 성능을 확인할 수 있었다. 3D프린터와 웹캠, PC를 이용하여 출력 중 인공지능의 불량이 탐지되었을 때, 자동으로 출력이 중지되는 시스템을 제작할 수 있었다. 형상 정밀도가 95% 미만인 불량 인공지능 제작을 80회 수행하면서 80회의 불량을 모두 탐지하여 출력을 중단하였다. 형상 정밀도가 95% 이상인 정상 인공지능 제작을 20회 수행하면서 20회 모두 출력을 완료함을 확인하여 제작된 시스템이 인공지능의 불량을 실시간으로 잘 탐지함을 확인할 수 있었다.

참고문헌

1. hang-Hee Lee, Min-Woo Sa, Seung-Hyuk Choi and Jong-Young Kim, "Development of a Novel Laser Sintering Deposition System for Fabrication of 3D Bio-Ceramic Scaffold", J. of The Korean Society of Mechanical Engineers, Vol.43, pp. 513-520, 2019.
2. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Shape Warpage Defect Detection Model of Scaffold Using Deep Learning Based on CNN", J. of The Korean Society of Semiconductor & Display Technology, Vol.20, pp. 99-103, 2021.
3. Song-Yeon Lee and Yong-Jeong Huh, "A Comparative Study on Deep Learning Models for Scaffold Defect Detection", J. of The Korean Society of Semiconductor & Display Technology, Vol.20, pp. 109-114, 2021.
4. Jung-Hee Han and Sung-Soo Hong "Semiconductor Process Inspection Using Mask R-CNN", J. of The Korean Society of Semiconductor & Display Technology, Vol.19, pp. 12-14, 2020.
5. 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
6. Shin-Young Ahn, Eun-Ji Lim and Wan Choi, "Trends on Distributed Frameworks for Deep Learning"

- Electronics and Telecommunications Trends, Vol.31, pp.131-141, 201.
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. Yong-Hwan Lee and Young-Sub Kim, "Comparison of CNN and YOLO for Object Detection" J. of The Korea Society of Semiconductor & Display Technology, Vol.19, pp.85-92, 2020.
-
- 접수일: 2021년 9월 3일, 심사일: 2021년 9월 13일,
게재확정일: 2021년 9월 16일