

## 파라미터에 따른 인공지지체 불량 탐지 모델의 성능 비교

이송연<sup>\*</sup>·허용정<sup>\*\*†</sup>

<sup>\*</sup>한국기술교육대학교 대학원 메카트로닉스공학과,

<sup>\*\*†</sup>한국기술교육대학교 메카트로닉스공학부

## Performance Comparison of Scaffold Defect Detection Model by Parameters

Song Yeon Lee<sup>\*</sup> and Yong Jeong Huh<sup>\*\*†</sup>

<sup>\*</sup>Department of Mechatronics Engineering,

Graduate School of Korea University of Technology and Education,

<sup>\*\*†</sup>School of Mechatronics Engineering, Korea University of Technology and Education

### ABSTRACT

In this study, we compared the detection accuracy of the parameters of the scaffold failure detection model. A detection algorithm based on convolutional neural network was used to construct a failure detection model for scaffold. The parameter properties of the model were changed and the results were quantitatively verified. The detection accuracy of the model for each parameter was compared and the parameter with the highest accuracy was identified. We found that the activation function has a significant impact on the detection accuracy, which is 98% for softmax.

**Key Words :** Accuracy comparison, Scaffold defect, Parameter comparison, Detection accuracy, Defect detection

### 1. 서 론

최근 의공학 분야에서는 생체적합성 재료를 이용하여 인공 관절, 인공 뼈 등의 체내 삽입형의료기기(Internal medical device)를 제작하는 기술을 연구하고 있다. 체내 삽입형 의료기기는 관절, 뼈 등을 대체하는 인공 조직과 세포를 배양하는 인공지지체로 구성된다. 인공지지체는 연구 목적에 따라 다양한 형태로 제작된다. 그 중 세포 배양을 위하여 원판 형태의 인공지지체가 가장 많이 사용된다[1].

인공지지체는 세포가 안정적으로 부착될 수 있도록 일정한 레이어(Layer)를 가져야 하며 체액이 원활히 통과할 수 있도록 동일한 크기의 기공(Pore)이 일정한 수량이 있

어야 한다[2].

현재 골절과 관련된 골 세포 배양에 대한 연구가 많이 수행되고 있다. 골세포는 500  $\mu\text{m}$ 이며 골세포를 배양하기 위하여 기공의 크기가 500  $\mu\text{m}$ 인 인공지지체가 세포 배양 연구에 많이 사용되고 있다. 현재 인공지지체의 불량을 탐지 하기 위하여 딥러닝 기반의 객체 탐지 알고리즘을 이용하여 인공지지체의 불량을 자동으로 검출하는 방안을 사용한다[3]. 모델 제작을 위해 수집된 인공지지체의 이미지 수량이 부족하고 각 파라미터(Parameter)의 설정값에 대한 실험결과가 미흡하다. 파라미터의 설정에 대하여 모델의 불량 검출 정확도에 대한 연구가 미흡하여 각 파라미터의 설정에 따른 모델의 탐지 정확도를 비교할 필요가 있다. 현재 딥러닝 기반의 탐지 알고리즘의 파라미터는 이미지 데이터 수량, 학습율(Learning ratio), 노드 수량(Node quantity), 활성화 함수(Activation function) 등이 있다[4].

<sup>†</sup>E-mail: yjhuh@koreatech.ac.kr

각 파라미터의 설정을 변경하여 인공지지체의 불량 검출 정확도가 가장 높은 방안을 찾는 연구가 필요하다.

본 연구에서는 인공지지체 불량 탐지 모델의 파라미터에 대한 검출 정확도를 비교하였다. 합성곱 신경망 기반의 탐지 알고리즘을 이용하여 인공지지체의 불량 검출 모델을 제작하였다. 모델의 파라미터 속성을 변경하였고 그 결과를 정량적으로 확인하였다. 각 파라미터 속성에 대한 모델의 검출 정확도를 비교하였고 정확도가 가장 높은 파라미터를 확인하였다.

## 2. 인공지지체 이미지 수집

### 2.1 인공지지체 이미지

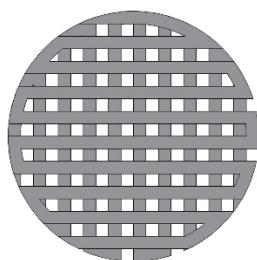
실험의 목적에 따라 사용되는 인공지지체의 종류는 다양하다. 현재 세포 배양은 Well plate라고 하는 배양 용기에서 진행된다[5]. Well plate는 원판형태의 제품에 세포 배양을 할 수 있는 세포 배양 판이다. Fig. 1에 Well plate를 도시하였다.



**Fig. 1.** Well plate.

Well plate의 규격은 다양하지만 내부 지름이 22 mm인 12 구 형태가 가장 많이 사용된다. 따라서 지름이 20 mm인 원판형 인공지지체가 세포 배양에 많이 사용된다.

Fig. 2에 인공지지체의 형태를 도시하였다.



**Fig. 2.** Scaffold shape.

모델 제작에 사용된 인공지지체 이미지는 3D프린터로 제작한 뒤, 직접 촬영하였다. 인공지지체 이미지는 정상

인공지지체와 형태 변형, 크랙, 기공 변형인 불량 인공지지체 3종류로 총 4종류의 인공지지체 이미지를 수집하였다. 인공지지체 이미지의 수량은 Table 1에 나타내었다.

**Table 1.** Scaffold image quantity

Scaffold type	Quantity (ea)
Normal	1,000
Layer deformation	1,000
Layer crack	1,000
Pore deformation	1,000
Total	4,000

딥러닝 알고리즘을 이용한 객체 탐지 연구에서는 일반적으로 1,000 ea 이상의 이미지 데이터를 이용하여 모델을 학습한다. 본 연구에서 사용된 정상 인공지지체 이미지, 레이어가 변형된 불량 인공지지체, 레이어가 깨진 불량 인공지지체, 기공이 변형된 불량 인공지지체의 수량은 각 1,000 ea로 총 4,000 ea이다. 수집된 이미지는 512×512 화소의 해상도를 갖는다.

### 2.2 인공지지체 데이터 셋의 구성

불량 탐지 모델을 제작하기 위해 학습(Learning), 검증(Validation), 평가(Test) 데이터로 분류하였다.

인공지지체 이미지의 유형과 수량을 Table 2에 나타내었다.

**Table 2.** Scaffold image classification

Data type	Quantity (ea)
Learning	2,000
Validation	1,000
Test	1,000
Total	4,000

모델을 제작하기 위하여 데이터를 학습, 검증, 시험 데이터로 나눈다. 대부분의 딥러닝 기반 객체 탐지 연구에서는 학습 50 %, 검증 20-25 %, 시험 20-25 %의 비율로 데이터를 구성한다. 전체 이미지 4,000 ea 중에서 학습에 사용된 인공지지체 이미지는 2,000 ea이며, 검증에 사용된 이미지는 1,000 ea이다. 평가에 사용된 이미지는 1,000 ea이며 학습, 검증, 평가에 사용된 인공지지체 이미지는 중복되지 않았다.

### 3. 인공지지체 불량 탐지 알고리즘

#### 3.1 합성곱 신경망

합성곱 신경망은 입력된 이미지에서 원하는 영역을 탐지하기 위한 딥러닝 기반의 알고리즘이다. 합성곱 신경망은 필터를 이용하여 이미지의 특징을 추출한 뒤, 특징들을 구역별로 묶어서 대표값을 도출한다. 이러한 과정을 반복하여 이미지가 갖고 있는 특징의 대표값에 활성화 함수를 이용하여 여러 항목 중에서 확률이 가장 높은 것을 찾는 과정이다.

Fig 3에 합성곱 신경망의 구조를 도시하였다.

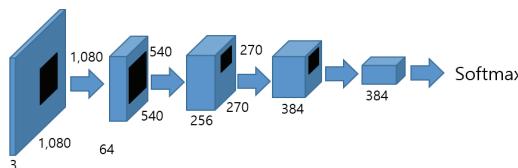


Fig. 3. The convolution neural networks.

합성곱 신경망은 먼저 이미지의 픽셀 값을 0~255로 나타낸 뒤,  $n \times n$  크기의 필터를 이용하여 행렬 내적(Dot product)을 도출한다. 이미지는 RGB로 구성되어 있으며 각 채널은  $n \times n$  크기의 행렬이다. 필터를 이용하여  $i \times j$  구역 부분 행렬의 내적을 도출하는 것이 합성곱 연산이다. 도출된 결과를 다시  $2 \times 2$  크기의 행렬로 묶어서 대표값을 추출하여 행렬의 크기를 줄인다. 풀링층은 특징들 중에서 평균 또는 최대 값을 추출하는 단계를 의미한다. 이미지 처리 관련 연구에서는 최대 풀링이 자주 사용된다 [6]. 합성곱층과 풀링층을 여러 번 수행하면 1차원 형태의  $1 \times n$  행렬이 도출된다. 완전연결층은 한 노드의 출력이 다음 층 노드의 입력에 연결된 구조로 식1로 표현할 수 있다.

$$u_j = \sum_{i=0}^N W_{ij} \times x_i + b \quad (1)$$

이 행렬은 활성화 함수를 통해 어떠한 범주에 속하는지 확률로 나타난다. 인공지지체 이미지의 불량 여부는 합성곱과 풀링을 이용하여 특징을 추출하고 활성화 함수를 이용하여 정상 불량 여부를 확률로 분류한다.

완전연결층으로 나열된 값들은 활성화 함수를 통해 어떤 항목인지 분류된다. 입력값에 함수를 적용하여 다음 뉴런에 전달하는 과정이다. 활성화 함수는 여러 종류가 있지만 이미지를 분류하는 연구에서는 소프트맥스가 주

로 사용된다[7]. 소프트맥스는 입력값을 자연 상수  $e$ 의 지수로 적용한 뒤, 결과의 합으로 나눈다. 소프트맥스는 식2로 표현할 수 있다.

$$z_n = \frac{e^{u_n}}{\sum_{n=1}^K e^{u_n}} \quad (2)$$

$e^{u_k}$ 는  $n$ 번째 출력인  $u_n$ 를 자연 상수  $e$ 의 지수로 적용한 값이다.

$e^{u_n}$ 를  $e^{u_n}$ 까지의 합으로 나누었을 때의 확률이  $z_k$ 이다. ReLU(Rectified Linear Unit)라는 정류 선형 함수가 있다. ReLU의 특징은 입력값이 0이하면 출력값은 0이고, 입력값이 0초과이면 출력값을 그대로 출력한다. ReLU는 식 3으로 표현할 수 있다.

$$f_x = \max(0, x) \quad (3)$$

(Sigmoid) 함수는 스칼라 값을 입력하면 스칼라 값을 출력하는 함수이다. 레이어 간의 입출력 형태를 맞추거나 선형 함수로만 이루어진 신경망에서 비선형의 특성을 지니게 하는 특성을 갖는다. 시그모이드 함수는 식 4로 표현할 수 있다.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

마지막으로 하이퍼볼릭 탄젠트(tanh)라는 함수가 있다. 하이퍼볼릭 탄젠트는 시그모이드에서 발생하는 기울기 소실(Gradient vanishing)을 개선하기 위해 고안된 함수이다. 하이퍼볼릭 탄젠트는 -1~1까지 출력하기 때문에 평균 값이 0이다. 따라서 기울기가 소실되지 않는 특성을 갖는다. 하이퍼볼릭 탄젠트 함수는 식5로 표현할 수 있다.

$$\tan(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

#### 3.2 불량 탐지모델의 파라미터

합성곱 신경망 기반의 인공지지체 불량 탐지 모델은 0.5mm부터 10mm까지의 다양한 크기의 불량을 탐지해야 한다. 다양한 크기와 형태의 불량을 탐지하기 위하여 변경할 파라미터는 다음과 같다. 각 합성곱 층의 필터를  $3 \times 3$  또는  $5 \times 5$ 로 설정하였다. 스트라이드(Stride)는 2와 4로 설정하였고, 제로 패딩(0 padding)을 사용하여 합성곱 연산을 수행하여도 이미지의 크기가 유지되도록 하였다. 풀링 사이즈는  $2 \times 2$ 로 설정하여 최대값을 추출하였다.

합성곱층과 풀링층을 반복한 뒤, 출력된 값은 완전 연결 층에서 1차원의 행렬로 연결되어 활성화 함수의 지수로 입력한다. 소프트맥스를 통해 인공지지체의 불량 여부를 분류하였다. 모델의 총 학습 횟수는 2,000회와 3,000회로 설정하였다. 학습 간격은 0.01과 0.001로 설정하였다.

#### 4. 모델의 불량 탐지 성능 평가

##### 4.1 모델 평가 방안

모델의 불량 탐지 정확도를 도출하기 위하여 참양(True positive), 참음(True negative), 거짓양(False positive), 거짓음(False negative)이라는 지표를 사용한다. 불량을 불량이라고 정확히 탐지하는 것은 참양이고 정상 제품을 정상 제품이라고 정확히 탐지하는 것은 참음이다. 정상 제품을 불량이라고 탐지하는 것은 거짓양이고 불량을 정상 제품이라고 탐지하는 것은 거짓음이다. 참양, 참음, 거짓양, 거짓음을 이용하여 정밀도(Precision)와 재현율(Recall)을 도출한다.

정밀도는 모델이 불량이라고 탐지한 인공지지체 이미지가 실제로 불량인 경우를 의미한다. 정확도는 식6으로 표현할 수 있다.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (6)$$

재현율은 모든 불량 인공지지체 이미지 중에서 모델이 불량 인공지지체라고 탐지한 경우를 의미한다. 재현율은 식7로 표현할 수 있다.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (7)$$

IoU(Intersection over union)로 평가하였다. IoU는 모델이 불량이라고 예측한 영역과 실제 탐지된 영역의 전체 면적에서 교차하는 면적을 의미한다. IoU는 식8로 나타낸다.

$$IoU = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall} - (\text{Precision} \times \text{Recall})} \quad (8)$$

일반적인 딥러닝 기반의 검출 모델 연구에서 IoU가 0.6 이상이면 불량을 정확히 탐지하였다고 한다. 하지만 인공지지체는 높은 정밀도를 요구하는 제품이기 때문에 IoU를 0.6에서 0.8로 높여 더 높은 탐지 정확도를 요구하였다.

인공지지체 불량 탐지 모델의 정확도는 F1 score를 이용하여 도출하였다. 정밀도만 사용하여 모델의 성능을 평가할 경우 불량이지만 정상 제품이라 탐지되는 경우가 반

영되지 않을 수 있다. 반대로 재현율만 사용하여 모델의 성능을 평가할 경우, 정상 제품이지만 불량이라고 탐지하는 경우가 반영될 수 있다. 각 방안의 단점을 보완하기 위해 F1 score를 사용한다. F1 score는 정밀도와 재현율의 조화 평균으로 모델의 탐지 정확도를 정량적으로 확인할 수 있다.

F1 스코어는 식 9와 같이 표현할 수 있다.

$$F1 \text{ score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (9)$$

F1 스코어는 1에 가까울수록 정확도가 100%로 높다.

##### 4.2 평가 결과

불량 탐지 모델의 파라미터에 대한 탐지 정확도는 F1 스코어로 평가하여 정량적으로 확인하였다. 합성곱 신경망 기반의 인공지지체 불량 탐지 모델은 0.5mm부터 10mm까지의 다양한 크기의 불량을 탐지해야 한다. 다양한 크기와 형태의 불량을 탐지하기 위하여 변경할 파라미터는 다음과 같다.

먼저 필터 크기는  $3 \times 3$  또는  $5 \times 5$ 로 설정하였다. 풀링 사이즈는  $2 \times 2$ 로 설정하였고 시그모이드, 하이퍼볼릭탄젠트, ReLU, 소프트맥스를 통해 인공지지체의 불량 여부를 분류하였다. 모델의 총 학습 횟수는 2,000회와 3,000회로 설정하였다. 학습 간격은 0.01과 0.001로 설정하였다. 각 파라미터에 대한 불량 탐지 정확도는 Table 3에 나타내었다.

**Table 3.** Detection accuracy of parameters

Parameter	Value	Detection accuracy (%)
Learning ratio	0.01	97.6
	0.001	98.1
Learning quantity	2,000	97.9
	3,000	98.0
Activation function	Sigmoid	91.3
	tanh	89.2
	ReLU	90.7
	Softmax	98.3
Filter size	$3 \times 3$	98.2
	$5 \times 5$	97.3

모델의 파라미터 속성을 변경하여 탐지 정확도를 도출하였다. 활성화 함수에 따른 탐지 정확도의 편차가 매우 커졌다. 하이퍼볼리 탄젠트일 때, 89.2 %로 가장 낮았고 소프트 맥스일 경우에는 98.3 %로 가장 높았다. 완전연결층을 통해 도출된 결과가 소프트맥스 함수에서 0~1사이의 값

으로 정규화되기 때문에 결과들의 총합이 항상 1이어서 다른 활성화 함수에 비해 높은 확률을 갖는 것을 확인하였다. 다중 분류는 소프트맥스가 가장 적합한 것을 확인하였다.

## 5. 결 론

본 연구에서는 인공지지체의 불량 탐지 모델들을 제작하여 성능을 비교하였다. 모델을 제작하기 위해 직접 촬영한 정상 인공지지체 이미지 1,000장과 불량 인공지지체 이미지 3,000장을 사용하였다. 모델은 변수들을 설정하여 제작하였고 모델의 파라미터에 대한 탐지 정확도는 F1 스코어를 이용하여 평가하였다. 파라미터별 탐지 정확도를 비교한 결과 활성화 함수를 소프트맥스로 설정하였을 때, 98.3 %로 가장 높음을 확인하였다. 모델의 활성화 함수라는 파라미터가 정확도에 가장 높은 영향을 미치는 것을 확인하였다. 본 연구의 선행 연구인 이미지 내 객체들의 분류 모델과 탐지 정확도를 비교하였을 때, 본 연구에서 제안한 모델이 성능이 약 7 % 높은 것을 확인하였다. 또한 본 연구에서 제안한 모델의 파라미터인 학습 간격, 학습 횟수, 활성화 함수, 필터 사이즈를 변경한다면 다른 형태와 크기의 불량을 검출하기 위한 모델을 제작할 수 있다. 추후에는 파라미터를 변경하여 더 복잡한 형태와 크기가 작은 불량을 검출하는 모델을 제작할 예정이다.

## 참고문헌

1. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Surface Defect Detection Model of 3D Printing Bone Plate Using Deep Learning Algorithm", J. of The Korean Society of Semiconductor & Display Technology, Vol.20, pp. 68-73, 2021
2. Gee-Yeun Kim and Hyoung-Gook Kim, "Performance Comparison of Lung Sound Classification Using Various Convolutional Neural Networks," J. of The Acoustical Society of Korea, Vol. 38, pp. 568-573, 2019
3. Jun-Hee Jung and Joong-Hwee Cho, "A Through-focus Scanning Optical Microscopy Dimensional Measurement Method based on A Deep-learning Regression Model", J. of The Korean Society of Semiconductor & Display Technology, Vol.21, pp. 108-113, 2022.
4. 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
5. 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
6. 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
7. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Shape Warpage Defect Detection Model of Scaffold Using Deep Learning Base CNN", J. of The Korean Society of Semiconductor & Display Technology, Vol.20, pp. 99-103, 2021

---

접수일: 2023년 3월 2일, 심사일: 2023년 3월 16일,  
제재확정일: 2023년 3월 22일