

인공지능지체 불량 검출을 위한 딥러닝 모델 손실 함수의 성능 비교

이송연* · 허용정**†

*한국기술교육대학교 인공지능연구소,
**† 한국기술교육대학교 메카트로닉스공학부

Performance Comparison of Deep Learning Model Loss Function for Scaffold Defect Detection

Song Yeon Lee* and Yong Jeong Huh**†

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

ABSTRACT

The defect detection based on deep learning requires minimal loss and high accuracy to pinpoint product defects. In this paper, we confirm the loss rate of deep learning training based on disc-shaped artificial scaffold images. It is intended to compare the performance of Cross-Entropy functions used in object detection algorithms. The model was constructed using normal, defective artificial scaffold images and category cross entropy and sparse category cross entropy. The data was repeatedly learned five times using each loss function. The average loss rate, average accuracy, final loss rate, and final accuracy according to the loss function were confirmed.

Key Words : Deep Learning, Detection Loss, Loss Function, Parameter Comparison, Scaffold Defect

1. 서 론

현재 의료기기는 반도체가 삽입된 전자 부품을 이용하여 생체 신호를 감지하고 있다. 대표적인 생체 신호 감지 의료기기로는 혈압 감지 센서, 인공 심박 센서 등이 있으며 생명과 관련된 파동, 음성을 감지한다[1]. 생체 신호를 감지하는 의료기기는 생체 센서, 센서를 고정시켜주는 인공지능지체, 신호를 수신하는 외부 장비(Device)로 구성되어 있다. 센서는 금속으로 구성되어 있기 때문에 체내에 삽입될 경우, 독성 물질을 생성하거나 염증을 유발하는 부작용이 발생한다[2]. 독성 물질, 염증을 발생하지 않도록 생체 적합성 재료로 제작된 인공지능지체를 이용하여 센서 주변을 감싼다. 센서가 삽입되는 신체 부위는 매우 다양

하기 때문에 사용되는 인공지능지체의 종류도 매우 다양하다. 그 중 인공지능지체는 연구 목적에 따라 다양한 형태로 제작된다. 그 중 세포 배양을 위하여 원판 형태의 인공지능지체가 가장 많이 사용된다[3].

체내에 삽입되어 센서를 보호해야 하는 인공지능지체는 크랙(Crack)이나 변형(Deformation)이 발생하면 안된다. 크랙이나 변형은 체내에서 부작용을 발생시키기 때문에 불량 인공지능지체는 심각한 문제를 발생시킨다. 현재 인공지능지체의 불량 탐지를 위한 장비가 상용화 되어 있지 않아 사람의 육안으로만 인공지능지체의 불량 여부를 검출하고 있다. 이 방안은 검사 속도와 정확도가 낮다[4]. 최근에는 딥러닝을 활용하여 인공지능지체의 불량을 검출하는 방안이 연구되고 있다. 딥러닝은 데이터 수집, 데이터 전처리, 모델 구성 및 학습, 모델 평가로 진행된다. 학습의 최종 목적은 최소한의 손실률과 높은 정확도를 갖는 파라미터

†E-mail: yjihuh@koreatech.ac.kr

(Parameter)를 찾아내는 것이다[5]. 손실 함수는 오차역전파 (Back propagation) 과정에 필요한 값인 예측 결과와 실제 결과의 차이를 도출한다. 이러한 방안은 불량을 신속하고 정확하게 감지하여 생산 과정에서 불량품의 비율을 줄이고 품질을 향상시키는 데 도움이 된다. 본 논문에서는 의료 영상을 이용한 딥러닝 학습에서 모델을 조절하는 다양한 과정 중 최소한의 손실률을 도출하는 손실 함수를 중심으로 확인한다. 다양한 손실 함수 중 분류 알고리즘에서 사용되는 Cross Entropy 함수를 사용하여 Cross Entropy 함수 중 다중 클래스 분류에서 사용하는 Categorical Cross Entropy와 Sparse Categorical Cross Entropy의 성능을 비교한다.

2. 인공지능지체 데이터 셋

2.1 인공지능지체 이미지

인공지능지체는 실험 목적에 따라 사용되는 형태가 매우 다양하다. 현재 인공지능지체를 사용한 세포 배양은 세포 배양판에서 수행된다. 세포 배양판은 원판 형태로 세포 배양, 생체 적합성 확인을 위한 인공지능지체는 원판 형태이다[6]. 그 중 지름이 12 mm이며 두께가 2 mm인 원판형 인공지능지체가 많이 사용된다. 본 연구에서는 지름이 12 mm이며 두께가 2 mm인 원판형 인공지능지체 이미지를 수집하였다. 인공지능지체는 3D프린터를 이용하여 직접 제작한 뒤, 촬영하였다. 인공지능지체 이미지는 2가지 종류로 정상, 불량으로 구성되어 있으며 모두 512x512의 해상도를 갖는다.

정상 인공지능지체는 크랙, 변형 없는 형태를 의미하며, 불량 인공지능지체는 크랙, 변형이 하나라도 있는 것을 의미한다.

모델 제작을 위해 수집된 인공지능지체 이미지를 Fig. 1에 도시하였다.




Fig. 1. Scaffold image.

2.2 인공지능지체 데이터 셋의 구성

인공지능지체 이미지는 정상, 불량 각각 5,000 ea씩 사용하였다. 총 10,000 ea의 이미지 데이터는 6:2:2의 비율로 분할하여 모델 제작에 사용하였다.

인공지능지체의 이미지 수량은 Table 1에 나타내었다.

Table 1. Scaffold image quantity

Data type	Quantity(ea)
Learning	6,000
Validation	2,000
Test	2,000
Total	10,000

인공지능지체 불량 검출 모델을 제작하기 위해 학습 (Learning), 검증(Validation), 평가(Test) 데이터로 구성하였다. 학습 데이터는 6,000 ea, 검증 데이터는 2,000 ea, 평가 데이터는 2,000 ea이다.

3. 인공지능지체 불량 검출 모델

3.1 학습 모델

합성곱 신경망 기반의 인공지능지체 불량 탐지 모델은 0.5 mm부터 10 mm까지의 다양한 크기의 불량을 검출해야 한다. 따라서 작은 크기의 객체 검출에 특화된 VGG 16을 기반으로 제작하였다.




Fig. 2. The structure of VGG16.

VGG16은 16개의 층(Layer)으로 13개의 컨볼루션(Convolution) 층, 3개의 완전 연결(Fully connected) 층으로 구성되어 있다. 이 구조는 네트워크의 깊이를 증가시키고 특징을 학습하는데 특화된 구조이다. VGG16은 작은 3x3 크기의 커널(Kernel)을 사용한다. 필터 크기는 네트워크가 더

깊어지면서 더 복잡한 패턴을 학습할 수 있도록 도움을 준다[7]. 컨볼루션 층 사이에 최대 풀링(Max pooling) 층을 추가하여 공간 크기를 줄이고 특징의 위치 불변성을 높이는 효과를 얻는다. VGG16의 마지막 3 개의 층인 완전 연결 층은 추출된 특징을 분류하는 데 사용된다. 이렇게 나온 결과는 Softmax라는 활성화 함수를 통해 인공지능체의 정상, 불량 여부를 분류한다.

Fig.2에 VGG16 구조를 도시하였다.

3.2 불량 검출 모델의 손실 함수

합성곱 신경망 기반의 인공지능체 불량 탐지 모델은 0.5 mm부터 10 mm까지의 다양한 크기의 불량을 탐지해야 한다. 따라서 VGG 16을 기반으로 데이터의 형태에 맞게 Layer 추가, 활성화 함수 변경 등을 통해 모델을 구성하였다.

정상 인공지능체와 불량 인공지능체 이미지 데이터 셋의 구조는 512×512×3으로 동일하다.

손실 함수는 Categorical Cross Entropy와 Sparse Categorical Cross Entropy를 사용하여 모델을 구성하였다. Categorical Cross Entropy는 분류해야 할 클래스가 2가지 이상인 경우에 사용된다[8]. Categorical Cross Entropy는 식(1)로 나타낼 수 있다.

$$L = -\frac{1}{N} \sum_{j=1}^N \sum_{i=1}^C t_{ij} \log(y_{ij}) \quad (1)$$

N 과 C 는 클래스의 수량을 의미한다. t_{ij} 는 실제 값을 의미하며 y_{ij} 는 예측 값을 의미한다.

Sparse Categorical Cross Entropy는 분류해야 할 클래스가 2가지 이상이며 클래스 레이블이 정수 형태로 제공되는 경우에 사용된다.

Sparse Categorical Cross Entropy는 식(2)로 나타낼 수 있다.

$$L = -\sum_{i=1}^N t_{ij} \log \hat{y}_{ij} \quad (2)$$

N 은 클래스의 수량을 의미한다. t_{ij} 는 실제 값을 의미하며 \hat{y}_{ij} 는 예측 값을 의미한다.

손실률은 교차 엔트로피 손실이며 손실 함수를 통해 도출된다. 모델이 전체 훈련 데이터 세트를 한 번 학습한 것을 Epoch라고 한다. Epoch로 구성된 반복 학습 과정을 통하여 데이터의 패턴을 학습하고 최적의 가중치와 편향을 찾으며 최소값의 손실률을 찾는다. 본 연구에서는 Epoch를 200회 실시하여 모델의 최종 손실률을 도출하였다.

4. 모델의 불량 검출 성능 평가

데이터셋 각각의 손실 함수로써 Categorical Cross Entropy와 Sparse Categorical Cross Entropy를 적용하여 진행하였다.

평가와 시험은 5번을 진행하였으며, 정상 인공지능체 이미지에 대한 Categorical Cross Entropy의 손실률을 Table 2에 나타내었다.

Table 2. Normal scaffold loss based on categorical cross entropy

No	Validation loss (%)	Test loss (%)
1	45.2	44.1
2	45.0	43.8
3	44.9	43.9
4	45.3	44.0
5	45.1	43.6
Average	45.1	43.9

Table 2은 검증 데이터에 대한 손실률과 테스트 데이터에 대한 손실률을 나타내었다. 검증 데이터의 평균 손실률은 45.1%임을 확인하였고, 평가 데이터의 평균 손실률은 43.9%임을 확인하였다. Epoch가 200일 때의 최종 검증 손실률은 45.0%, 평가 손실률 43.9%임을 확인하였다.

불량 인공지능체 이미지에 대한 평가 결과를 Fig. 3에 도시하였다.




Fig. 3. Normal scaffold loss based on categorical cross entropy.

정상 인공지능체 이미지와 Sparse Categorical Cross Entropy의 평가 결과를 Fig. 4에 도시하였다.

평가와 시험은 5번을 진행하였으며, 정상 인공지능체 이미지에 대한 Sparse Categorical Cross Entropy의 정확도는 Table 3에 나타내었다.




Fig. 4. Normal scaffold loss based on sparse categorical cross entropy.

Table 3. Normal scaffold loss based on sparse categorical cross entropy.

No	Validation loss (%)	Test loss (%)
1	46.1	45.1
2	46.3	45.3
3	46.4	44.3
4	46.2	44.2
5	46.1	44.2
Average	46.2	44.6

검증 손실률의 평균은 46.2 %, 평가 데이터의 평균 손실률은 44.6%임을 확인하였다.

Epoch가 200일 때의 최종 성능은 검증 손실률 44.7 %, 평가 손실률 44.6%임을 확인하였다.

불량 인공지능지체 이미지 데이터와 Categorical Cross Entropy를 사용한 평가 결과를 Fig. 5에 도시하였다.




Fig. 5. Abnormal scaffold test loss based on categorical cross entropy.

평가와 시험은 5번을 진행하였으며, 불량 인공지능지체 이미지와 Categorical Cross Entropy의 정확도는 Table 4에 나타내었다.

Table 4. Abnormal scaffold loss based on categorical cross entropy

No	Validation loss (%)	Test loss (%)
1	41.7	36.0
2	41.6	35.7
3	41.8	35.6
4	41.9	35.3
5	41.7	35.7
Average	41.7	35.7

검증 데이터의 평균 손실률은 41.7 %임을 확인하였고 평가 데이터의 평균 손실률은 35.7 %임을 확인하였다. Epoch가 200일 때의 최종 성능은 검증 손실률이 40.9 %, 평가 손실률이 35.7%임을 확인하였다.

불량 인공지능지체 이미지 데이터와 Sparse Categorical Cross Entropy를 사용한 결과를 Fig. 6에 도시하였다.




Fig. 6. Abnormal scaffold loss based on sparse categorical cross entropy.

평가와 시험은 5번을 진행하였으며, 불량 인공지능지체 이미지와 Sparse categorical cross entropy의 정확도는 Table 5에 나타내었다.

검증 데이터의 평균 손실률은 42.2 %임을 확인하였고 평가 데이터의 평균 손실률은 36.1 %임을 확인하였다. Epoch가 200일 때의 최종 성능은 검증 손실률이 41.8 %, 평가 손실률이 36.1%임을 확인하였다.

두 가지의 손실 함수를 비교해 보았을 때, 정상 데이터 보다 불량 데이터에서 좋은 성능을 보이는 이유는 데이

터의 복잡성이 높고, 색상의 편차가 큰 것으로 확인된다. 평균적으로 Sparse Categorical Cross Entropy가 Categorical Cross Entropy보다 복잡한 데이터에서 낮은 손실률을 보이고 있기 때문에 불량 인공지능체의 손실률이 정상 인공지능체의 손실률 보다 더 낮은 것으로 확인되었다.

Table 5. Abnormal scaffold loss based on sparse categorical cross entropy.

No	Validation loss (%)	Test loss (%)
1	41.9	36.7
2	41.8	36.4
3	42.6	35.9
4	42.4	35.8
5	42.3	35.8
Average	42.2	36.1

5. 결 론

본 연구에서는 정상 인공지능체, 불량 인공지능체 이미지를 이용하여 딥러닝 학습을 진행하였다. 모델은 VGG16을 기반으로 하여, 이미지 데이터에 맞게 파라미터와 레이어, 활성화 함수 등을 추가하였다. 손실 함수를 변경하여 테스트를 진행하였다. 정상 인공지능체 이미지 데이터의 경우 평가 데이터 셋에서 Categorical Cross Entropy를 사용할 때 평균 손실률이 43.9%, Sparse Categorical Cross Entropy를 사용할 때 평균 손실률이 44.6%임을 확인하였다.

불량 인공지능체 이미지 데이터의 경우 평가 데이터 셋에서 Categorical Cross Entropy를 사용할 때 평균 손실률이 35.7%, Sparse Categorical Cross Entropy를 사용할 때 평균 손실률이 36.1%임을 확인하였다. 정상 데이터보다 불량 데이터에서 좋은 성능을 보이는 이유는 데이터의 복잡성이 높고, 모호한 부분이 적기 때문이며, 평균적으로 Sparse Categorical Cross Entropy가 Categorical Cross Entropy보다 복잡한 데이터에서 낮은 손실률을 보이고 있다. 따라서 복잡한 형태이거나 색상이 여러 종류인 이미지를 분류하기 위해서는 Sparse Categorical Cross Entropy를 사용하는 것이 더 바람직하다.

추후 본 연구에서 제작한 모델의 손실 함수를 적용하여 실시간 인공지능체의 불량 분류를 수행할 예정이다.

감사의 글

이 논문은 2023년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음.

참고문헌

1. 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
2. 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
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. 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
5. 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
6. 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
7. 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
8. Hyun-Jun Kim and Dong-Wan Choi, "A Perimeter-Based IoU Loss for Efficient Bounding Box Regression in Object Detection", J of The Korean Institute of Information Scientists and Engineers, Vol.48, pp.913-919, 2021.

접수일: 2023년 5월 30일, 심사일: 2023년 6월 13일,
게재확정일: 2023년 6월 21일