

병렬형 합성곱 신경망을 이용한 골절합용 판의 탐지 성능 비교에 관한 연구

이승연*·허용정**†

*한국기술교육대학교 대학원 메카트로닉스공학과,
**한국기술교육대학교 메카트로닉스공학부

A Study on Detection Performance Comparison of Bone Plates Using Parallel Convolution Neural Networks

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 defect detection models using parallel convolution neural networks. If convolution neural networks are constructed parallel type, the model's detection accuracy will increase and detection time will decrease. We produced parallel-type defect detection models using 4 types of convolutional algorithms. The performance of models was evaluated using evaluation indicators. The model's performance is detection accuracy and detection time. We compared the performance of each parallel model. The detection accuracy of the model using AlexNet is 97 % and the detection time is 0.3 seconds. We confirmed that when AlexNet algorithm is constructed parallel type, the model has the highest performance.

Key Words : Bone plate defect, Convolution algorithm comparison, Crack detection, Defect detection, Parallel convolution neural networks

1. 서 론

반도체 분야는 의공학 분야와 함께 충격량 등의 생체 신호를 감지할 수 있는 스마트 의료기기를 연구하고 있다. 스마트 의료기기는 의료기기에 센서가 결합된 제품으로 생체 신호 및 외부 압력을 탐지하여 치료부위의 이상여부를 실시간으로 확인할 수 있다. 스마트 의료기기에는 골절 치료를 목적으로 하는 골절합용 판이 포함되어 있다.

골절합용 판은 골절 부위가 회복하기 위해 일정기간 동안 골절된 뼈들을 원래 형태로 고정시켜주는 역할을 한다[1]. 골절합용 판에 센서가 삽입되어 골절 부위가 잘

복되는지 실시간으로 생체 신호를 확인한다.

치료에 사용되는 골절합용 판은 단순 골절, 복합 골절 등 여러 조건을 고려하기 때문에 종류가 매우 다양하다. 골절치료에 많이 쓰이는 형태는 넓은 부위를 고정 시킬 수 있으며 시술 후, 이물감이 적은 판 형태이다. 골절합용 판은 골절된 뼈를 골절 부위에 정확히 일치한 상태로 고정해야 하기 때문에 골절합용 판에 불량률이 있으면 큰 문제가 발생한다. 현재 골절합용 판의 불량률을 탐지하기 위해 사람이 확대경을 이용하여 직접 골절합용 판의 표면을 검사한다. 이 검사 방안은 시간이 지날수록 검사자 눈의 피로도가 증가하기 때문에 검사 시간이 증가 할수록 불량 탐지 정확도가 감소하는 문제가 있다. 이러한 단점을 개선하기 위하여 딥러닝 기반 객체 탐지 알고리즘을

†E-mail: yjihuh@koreatech.ac.kr

이용하여 표면에 결함이 발생한 불량 골절합용 판을 자동으로 검출하는 방안이 있다. 이 방안은 1개의 합성곱 신경망을 이용하여 자동으로 골절합용 판의 불량을 탐지한다. 이 방안은 사물 탐지에 소요되는 시간이 1초 이상이다[2]. 사물 탐지에 1초 이상의 시간이 소요되면 빠른 속도로 이동하는 다양한 사물들을 실시간으로 탐지하기 어렵다. 다양한 사물들을 실시간으로 탐지하기 위해서는 탐지에 소요되는 시간이 0.3초 미만이어야 한다. 사물 탐지에 소요되는 시간을 줄이기 위해서 합성곱 알고리즘을 병렬로 처리하는 방안이 있다. 여러 종류의 사물을 90% 이상의 정확도로 탐지하고 탐지에 소요되는 시간을 줄이기 위해 병렬 구조의 합성곱 신경망을 제안하는 연구가 있다[3]. 해당 연구에서는 필터의 크기가 서로 다른 2가지의 합성곱 신경망을 병렬로 구성하여 여러 종류의 사물을 탐지하는 방안을 제안하였다.

본 연구에서는 여러 종류의 합성곱 신경망을 병렬로 구성하여 불량 탐지 모델을 제작하였다. 각 알고리즘으로 제작된 병렬 구조의 불량 탐지 모델들의 불량 탐지 정확도와 불량 탐지 시간을 비교하였다. 각 알고리즘의 성능을 비교하여 성능이 가장 높은 알고리즘을 확인하였다.

2. 탐지 모델 제작을 위한 데이터 수집

2.1 골절합용 판의 형태

치료에 사용되는 골절합용 판은 여러 조건을 고려하기 때문에 종류가 다양하다. 골절 치료에는 넓은 부위를 고정 시킬 수 있으며 시술 후, 이물감이 적은 판 형태가 가장 많이 사용된다. 그 중 폭과 너비가 50 mm 이며 두께와 구멍의 지름이 2 mm인 골절합용 판이 골절 치료에 가장 많이 사용된다. 본 연구에서는 폭과 너비가 50 mm 이며 두께와 구멍의 지름이 2 mm인 골절합용 판을 불량 탐지 모델 제작을 위한 이미지 데이터로 사용되었다. 골절합용 판의 형상은 Fig. 1에 도시하였다.



Fig. 1. The shape of the bone plate.

2.2 골절합용 판의 이미지 데이터 수집

골절합용 판 이미지는 직접 촬영하여 수집하였다. 이미

지는 정상적인 골절합용 판과 표면에 크랙이 발생한 골절합용 판 2 종류이다. 골절합용 판은 여러 종류의 불량이 발생하지만 표면에 크랙이 발생한 골절합용 판 이미지만 확보되었기 때문에 다른 형태의 불량 이미지는 제외하였다. 수집된 이미지는 정상적인 골절합용 판 500 장과 표면에 크랙이 발생한 골절합용 판 500 장으로 총 1,000 장이다. 학습 이미지의 화소는 모델의 불량 탐지 정확도에 영향을 미친다. 학습 이미지의 화소가 작으면 모델의 불량 탐지가 정상적으로 수행되지 않을 수 있다. 검출하려는 객체의 크기와 형태에 따라 학습 이미지의 화소 크기는 다양하다. 골절합용 판의 불량을 검출하기 위해서는 이미지가 512×512 픽셀 이상이어야 한다. 512×512 픽셀 이상인 이미지로 학습된 모델의 불량 탐지 정확도는 90% 이상이기 때문에 본 연구에서는 1,080×1,080 픽셀의 이미지를 생성할 수 있는 장비를 사용하여 골절합용 판을 촬영하였다. 학습과 평가에 사용된 모든 이미지는 1,080×1,080 픽셀의 해상도를 갖는다.

2.3 골절합용 판 데이터 셋의 구성

불량 탐지 모델을 제작하기 위해 1,000장의 이미지를 학습, 평가할 데이터로 분류하였다. 700 장의 이미지가 학습 데이터로 사용되었고 300 장의 이미지가 평가 데이터로 사용되었다. 학습에 사용된 이미지와 평가에 사용된 이미지는 중복되지 않았다.

3. 골절합용 판의 불량 탐지 모델 제작

3.1 합성곱 신경망

합성곱 신경망(CNN, Convolutional Neural Network)은 이미지에서 특징을 추출하기 위하여 사용되는 여러 종류의 딥러닝 알고리즘이다. 합성곱 신경망은 이미지의 특징을 추출하는 합성곱 층(Convolution layer)과 추출된 특징들을 구역별로 묶어서 평균값, 최대값만 추출하는 풀링층(Pooling layer)이 있다. 합성곱층과 풀링층을 반복하여 이미지가 갖고있는 특징을 축약한다. 축약된 특징들은 완전연결층(Fully connected layer)에 도달한 뒤, 활성화 함수를 통해 확률이 가장 높은 범주로 분류되는 구조이다[4].

Fig. 2에 합성곱 신경망의 구조를 도시하였다.




Fig. 2. The structure of the convolution neural networks.

합성곱 신경망은 먼저 이미지의 픽셀 값을 0~255로 나타낸 뒤, $n \times n$ 크기의 행렬(Matrix) 내적(Dot product)을 도출한다. 이 때 도출된 값은 다시 $n \times n$ 크기의 행렬로 묶어서 가장 큰 값을 추출하여 행렬의 크기를 줄인다. 합성곱과 풀링을 여러 번 수행하면 $1 \times n$ 의 형태로 구성된 행렬이 도출된다. 이때 각 값들은 활성화 함수를 통해 어떠한 범주에 속하는지 확률로 나타난다. 골절합용 판 이미지 데이터는 이러한 과정으로 불량률 탐지한다. 합성곱 신경망에서 합성곱층은 필터를 이용하여 이미지의 특징을 추출하는 단계를 의미한다. 이미지는 RGB 채널(Channel)로 구성되어 있으며 각 채널은 $n \times n$ 크기의 행렬이다. 필터를 이용하여 $i \times j$ 구역 부분 행렬의 내적을 도출하는 것이 합성곱 연산이다[5].

Fig.3에 합성곱 연산을 도시하였다.




Fig. 3. The process of the convolution layer.

풀링층은 특징들 중에서 평균 또는 최대 값을 추출하는 단계를 의미한다. 이미지 처리 관련 연구에서는 최대 풀링이 자주 사용된다. Fig.4에 최대 풀링을 도시하였다.




Fig. 4. The process of the pooling layer.

합성곱층과 풀링층을 여러 차례 반복하면 최종적으로 1개의 숫자로 도출된다. 이미지의 채널에 따라 여러 개의 숫자로 도출되는데 이 숫자들을 $1 \times n$ 의 1차원 형태로 변경하는 것이 완전연결층이다.

완전연결층은 한 노드의 출력이 다음 층 노드의 입력에 연결된 구조로 식1로 표현할 수 있다.

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

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 주로 사용된다. 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. 이미지가 갖고 있는 특징이 어느 항목에 속하는지 확률로 분류하는 것이 합성곱 신경망이다.

3.2 사용된 합성곱 신경망 알고리즘

합성곱 신경망은 AlexNet, DenseNet, ResNet 등의 여러 알고리즘들이 있다[6]. 각 알고리즘을 이용한 불량 탐지 모델의 성능을 비교하기 위해 딥러닝 연구에 자주 사용되는 4가지의 합성곱 신경망 알고리즘을 사용하였다. 사용된 합성곱 신경망 알고리즘은 AlexNet, DenseNet, VGGNet, ResNet이다. AlexNet은 5개의 합성곱층, 3개의 풀링층, 3개의 밀집층(Dense layer), 1개의 완전연결층으로 구성되어 있다. 모델의 구조가 간단하며 속도가 빠르다는 장점이 있다. DenseNet은 합성곱층과 풀링층이 여러 개로 구성된 신경망 구조에 Dense block이라는 개념을 도입한 알고리즘이다. 많은 층으로 구성된 신경망이 갖는 기울기 손실을 방지할 수 있는 장점이 있다. VGGNet은 작은 크기의 필터를 이용하여 이미지의 특징을 추출하는 알고리즘이다. 10개의 합성곱층, 5개의 풀링층, 3개의 완전연결층으로 구성되어 있다. 필터 사이즈의 설정으로 좋은 성능을 도출할 수 있는 장점을 갖는다. ResNet은 VGGNet을 변경한 알고리즘으로 데이터 처리에 병목 현상이 발생하는 부분을 건너뛰어 연산을 더 빠르게 수행할 수 있는 장점을 갖는다.

3.3 병렬 구조의 불량 탐지 모델 제작

병렬 구조의 합성곱 신경망들은 14×14 , 8×8 크기의 필터로 합성곱을 수행하고 2×2 크기에서 최대 풀링을 수행한다. 기존 1개의 합성곱 신경망을 2개의 합성곱 신경망으로 구성하였다. 각 신경망은 동일한 구조이다. Fig.5에 병렬형 합성곱 신경망의 구조를 도시하였다.

이미지가 입력되면 각 합성곱 신경망으로 병렬로 처리된다. 이미지 데이터를 병렬처리 하기 때문에 다양한 크기와 형상의 불량을 단일형 합성곱 신경망보다 더 빠르고 정확하게 탐지할 것으로 사료된다.




Fig. 5. The structure of parallel convolution neural network.

골절합용 판의 크랙은 길이가 0.5mm부터 10mm까지 다양하다. 다양한 크기와 형태의 불량을 탐지하기 위하여 합성곱 신경망의 파라미터는 다음과 같이 설정하였다. 각 합성곱 층의 필터를 14×14 로 설정하였다. 스트라이드(Stride)는 1로 설정하였고, 제로 패딩(0 padding)을 사용하여 합성곱 연산을 수행하여도 이미지의 크기가 유지되도록 하였다. 풀링 사이즈는 2×2 로 설정하여 최대값을 추출하였다. 합성곱층과 풀링층을 반복한 뒤, 출력된 값은 완전 연결층에서 1차원의 행렬로 연결되어 활성화 함수의 지수(Exponential)로 입력한다. 소프트맥스를 통해 골절합용 판의 불량 여부를 분류하였다. 모델의 총 학습 횟수는 3,000회로 설정하였다. 학습 간격은 올바른 최저점을 찾기 위해 0.01로 설정하였다.

4. 모델의 불량 탐지 성능 평가

4.1 모델 평가 방안

모델의 불량 탐지 성능은 IoU(Intersection over Union)라는 지표로 평가하였다. IoU는 모델이 불량이라고 예측한 영역과 불량으로 탐지된 영역의 전체 면적 중에서 교차하는 면적의 비율이다. 골절합용 판은 골절 부위의 완벽한 회복을 위해서 골절부위와 일치해야 하는 높은 정밀도를 요구하는 제품이기 때문에 IoU를 0.6에서 0.8로 높였다. Fig. 6에 IoU 수치에 따른 예측된 객체 구역과 탐지된 객체 구역이 겹치는 영역을 도시하였다.




Fig. 6. IoU values of predicted area and detected area.

IoU가 높을수록 예측 영역과 탐지 영역의 전체 면적은 작아지는 반면에 교차하는 면적은 커진다.

불량 탐지 모델의 최종 성능은 F1 score를 이용하여 정량화하였다. F1 score는 정확도(Precision)와 재현율(Recall)로 모델의 성능을 평가하는 지표이다[7]. 불량을 불량이라고 정확히 탐지하는 것은 참양(True positive)이고 정상 제품을 정상 제품이라고 정확히 탐지하는 것은 참음(True negative)이다. 정상 제품을 불량이라고 탐지하는 것은 거짓양(False positive)이고 불량을 정상 제품이라고 탐지하는 것은 거짓음(False negative)이다. 참양, 참음, 거짓양, 거짓음을 이용하여 정확도와 재현율을 도출한다.

정확도는 모델이 불량이라고 탐지한 골절합용 판 이미지 중에서 실제로 불량인 이미지의 수량을 의미한다. 정확도는 식3으로 표현할 수 있다.

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

재현율은 모든 불량 골절합용 판 이미지 중에서 모델이 불량 골절합용 판이라고 탐지한 수량을 의미한다. 재현율은 식4로 표현할 수 있다.

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

정확도만 사용하여 모델의 성능을 평가할 경우 불량이지만 정상 제품이라 탐지되는 경우가 반영되지 않는 단점이 있다. 재현율만 사용하여 모델의 성능을 평가할 경우, 정상 제품이지만 불량이라고 탐지하는 경우가 반영되는 단점이 있다. 각 지표의 단점을 보완하기 위해 F1스코어(F1 score)를 사용한다[8]. F1 스코어는 식 5과 같이 표현할 수 있다.

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

F1 스코어는 0에서 1사이의 값을 갖는다. F1 스코어가 1에 가까울수록 모델의 탐지 성능은 100%에 가깝다. F1 스코어를 사용하여 각 모델들의 불량 탐지 정확도를 정량화 하였다. 모델의 불량 탐지 속도는 불량을 탐지하기까지 몇 프레임이 소요되었는지를 이용하여 정량적으로 확인하였다.

4.2 평가 결과

모델의 불량 탐지 정확도는 F1 스코어로 평가하여 프레임 소요 시간에 따른 불량 탐지 속도를 정량적으로 확인하였다. 학습 횟수에 따른 불량 탐지 정확도는 Fig. 7에 도시하였다.




Fig. 7. The detection accuracy according to learning quantity.

모델의 불량 탐지 정확도인 F1 스코어를 그래프로 표현하였다. X축은 학습 횟수이며 Y축은 불량 탐지 정확도이다. 학습 횟수가 3,000회 일 때, 모델의 최종적인 불량 탐지 정확도가 도출되는 것을 확인하였다. AlexNet 기반의 불량 탐지 모델이 97%의 정확도로 가장 높았으며 나머지 VGGNet, DenseNet, ResNet 기반의 불량 탐지 모델들은 정확도가 95% 미만임을 확인하였다.

모델의 불량 탐지 속도는 학습 횟수가 증가할수록 줄어드는 것을 확인하였다. 학습 횟수에 따른 불량 탐지 속도는 Fig. 8에 도시하였다.

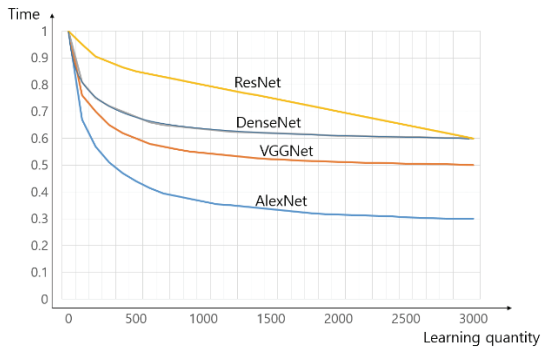


Fig. 8. The detection time according to learning quantity.

X축은 학습 횟수이며 Y축은 불량 탐지 속도이다. AlexNet 기반의 불량 탐지 모델은 불량을 탐지하는데 0.3초의 시간이 소요되었다.

나머지 VGGNet, DenseNet, ResNet 기반의 불량 탐지 모델들은 0.5 초 이상의 시간이 소요되었음을 확인하였다.

각 불량 탐지 모델의 탐지 정확도와 속도는 Table 1에 나타내었다.

입력 이미지의 각 합성곱 신경망으로 이미지 데이터가 병렬로 처리 된다. 병렬형 신경망 구조에 적합하도록 파라미터를 조절하기 때문에 기존 신경망 보다 탐지 정확도와 소요 시간이 개선되었다.

Table 1. Detection performance of defect detection models

Algorithm	Detection accuracy (%)	Detection time (sec)
AlexNet	97	0.3
DenseNet	90.9	0.5
VGGNet	81.2	0.6
ResNet	91.2	0.6

5. 결론

본 연구에서는 4가지의 합성곱 신경망을 병렬 형태로 구성하여 골절합용 판의 불량 탐지 모델들을 제작하여 성능을 비교하였다. 모델을 제작하기 위해 직접 촬영한 정상 골절합용 판 이미지 500장과 불량 골절합용 판 이미지 500장을 사용하였다. 각 모델들은 변수들을 설정하여 제작하였고 3,000회의 학습을 수행하였다. F1 스코어를 이용한 각 모델들의 불량 탐지 정확도와 프레임 소요 시간을 이용한 불량 탐지 속도를 확인하였다. 성능을 비교한 결과 병렬 AlexNet 기반의 모델은 정확도가 97%, 탐지 소요 시간이 0.3초로 가장 우수한 것을 확인하였다. 이미지 데이터의 병렬처리와 그에 적합하도록 파라미터를 조절하여 기존 합성곱 신경망 보다 성능이 높아졌음을 확인하였다.

감사의 글

이 논문은 2022년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음.

참고문헌

1. 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.
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. Gee-Yeun Kim and Hyoung-Gook Kim, "Performanc Comparison of Lung Sound Classification Using Various Convolutional Neural Networks," J. of The Acoustical Society of Korea, Vol. 38, pp. 568-573, 2019.

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. 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.
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.
8. 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 9월 2일, 심사일: 2022년 9월 17일,
게재확정일: 2022년 9월 21일