



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.


다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공 학 석 사 학 위 논 문

인공신경망을 사용하는 치아 및 치석 인식



2022년 2월

부 경 대 학 교 대 학 원

인 공 지 능 융 합 학 과

박 사 론

공 학 석 사 학 위 논 문

인공신경망을 사용하는 치아 및 치석 인식

지도교수 장 원 두

이 논문을 공학석사 학위논문으로 제출함.

2022년 2월

부 경 대 학 교 대 학 원

인 공 지 능 융 합 학 과

박 사 론

박사론의 공학석사 학위논문을 인준함.

2022년 2월 25일



위 원 장 공학박사 한 영 선 (인)

위 원 공학박사 신 인 철 (인)

위 원 공학박사 장 원 두 (인)

목 차

목 차	i
그림목차	iii
표 목 차	iv
국문요약	v
영문요약	vi
I. 서 론	1
1.1. 연구의 배경 및 목적	1
1.2. 연구의 내용 및 범위	3
II. 이론적 배경	5
2.1. 합성곱 신경망	5
2.2. 고속 객체 인식 모델: You Only Look Once	6
2.3. 전이학습	8
2.4. 관련 연구	10
III. 연구 방법	12
3.1. 치아 인식 모델	12
3.1.1 데이터 수집 및 전처리	12
3.1.2 치아 인식 모델 구조	15
3.2. 치아 건강 판단 모델	20
3.2.1 데이터 전처리	20
3.2.2 치아 건강 판단 모델 구조	23
3.3. 학습된 딥러닝 모델 사용 방안 연구	26

IV. 연구 결과	30
4.1. 치아 인식 모델 결과	30
4.2. 치아 건강 판단 모델 결과	31
4.3. 학습된 모델 추가 검증	35
V. 결론	43
참고문헌	45



그 립 목 차

그림. 1. CNN의 구조 및 데이터 학습 과정	5
그림. 2. YOLO 모델의 객체 인식 과정	7
그림. 3. Residual의 개념, 입력 데이터 x 가 한 층을 건너뛰어서 $F(x)$ 와 함께 다음 층의 입력 데이터로 들어가는 모습	9
그림. 4. 치아 데이터의 예시	12
그림. 5. 치아 데이터 레이블 영역의 예시	13
그림. 6. Resize 처리된 학습 데이터 예시	14
그림. 7. 치아 영역 인식 결과 예시	14
그림. 8. 치아 인식 모델 중 CNN + Classification 모델의 구조	17
그림. 9. 치아 인식 모델 중 Resnet152 + Classification 모델의 구조	19
그림. 10. 치아 데이터에 치석 이미지 편집 예시	20
그림. 11. 치아 데이터 20등분 및 Resize 예시	21
그림. 12. 밝기 증강 데이터의 예시	21
그림. 13. 회전 증강 데이터의 예시	22
그림. 14. 치아 건강 판단 모델 중 CNN + Classification 모델의 구조	24
그림. 15. 치아 건강 판단 모델 중 Resnet152 + Classification 모델의 구조	25
그림. 16. 딥러닝 모델 사용을 위한 구조 및 데이터 흐름도	27
그림. 17. Index.html 파일에 구현된 웹 페이지 화면 예시	28
그림. 18. 전처리 및 모델 입·출력에 의한 입력 데이터의 변화 예시	29
그림. 19. 테스트에 사용된 전체 이미지 데이터	38
그림. 20. 건강한 치아 데이터 중 19, 20번 데이터의 테스트 결과	39
그림. 21. 편집된 치석을 포함하는 데이터 중 19, 20번 데이터 테스트 결과	40
그림. 22. 연예인 치아 데이터 중 3, 18번 데이터 테스트 결과	41
그림. 23. 실제 치석 포함 데이터 중 1, 17번 데이터 테스트 결과	42

표 목 차

표 1. 전이학습을 사용한 치아 인식에 관한 연구 정리	12
표 2. 치아 인식 모델에서 CNN 모델과 전이학습 모델의 결과 비교	30
표 3. ResNet 모델의 층의 깊이에 따른 치아 건강 판단 모델 정확도의 변화	32
표 4. 데이터 증강에 따른 Accuracy의 변화	33
표 5. 치아 건강 판단 모델에서 CNN 모델과 전이학습 모델의 결과 비교	34
표 6. 치아 건강 점수 비교	37



인공신경망을 사용하는 치아 및 치석 인식

박 사 론

부 경 대 학 교 대 학 원 인 공 지 능 융 합 학 과

요 약

정보화 기술과 인공지능 기술의 발달로 인하여 인공지능을 헬스케어에 접목한 여러 시도가 이뤄지고 있다. 그중에서 인공지능을 이용한 치아 인식 분야의 연구도 활발한데, 대부분은 치아의 번호를 판단하여 진료를 보조하는 딥러닝 모델에 관한 연구이며, 치석 등 치아의 건강 상태를 추정하는 연구는 시도되지 않았다. 본 연구에서는 치아의 건강 상태를 알 수 있는 치아 인식 및 치아 건강 판단 모델을 제안한다. 제안 모델은 합성곱 신경망(Convolutional Neural Network: CNN)을 직접 설계한 모델과 ResNet 모델을 전이학습 시킨 모델을 비교함으로써 최적의 치아 인식 및 치아 건강 판단 모델을 학습하는 방법을 연구하였다. 또한, ResNet 전이학습 모델의 층의 깊이에 따른 모델 성능의 변화, 데이터 증강을 통한 딥러닝 모델의 성능 향상을 확인하는 방향으로 연구를 진행했다. 결과적으로 치아 인식 모델에서 직접 설계한 CNN 모델은 0.00010 Loss, ResNet 전이학습 모델은 0.00022 Loss로 직접 설계한 CNN 모델의 성능이 더 좋은 것을 확인했다. 그리고 치아 건강 판단 모델에서 ResNet 모델의 층이 깊어짐에 따라 모델의 성능이 향상되는 것을 확인하였고, 데이터 증강은 원본 데이터를 20등분하고, 밝기에 대해 증강하였을 때 가장 성능이 좋았음을 확인하였다. 또한, 치아 건강 판단 모델에서 직접 설계한 CNN 모델은 정확도가 87.45%이고, ResNet 전이학습 모델은 정확도가 91.9%이므로 ResNet 전이학습 모델의 성능이 더 좋은 것을 확인했다. 그리고 학습된 치아 인식 모델과 치아 건강 판단 모델은 클라우드 서버에 학습된 모델 파일을 탑재하고, 웹 페이지를 통해 사용자가 모델에 접근하는 방식의 사용법을 연구하였다. 이때 위와 같은 사용법으로 학습된 모델에 대해 각각 20개의 테스트 이미지의 평균 점수를 구한 결과, 학습 데이터와 유사한 데이터 중 건강한 치아 데이터는 평균 90.42점, 편집된 치석이 포함된 데이터는 평균 57.99점, 학습 데이터와 유사하지 않은 데이터 중 연예인 치아 데이터는 평균 96.21점, 실제 치석이 포함된 데이터는 평균 77.23점으로 구강 건강 점수가 나타났다. 이는 치아 건강 모델이 본 연구에서 의도한 수준의 치아 건강 점수를 찾은 것을 의미한다.

Recognition of tooth and tartar using artificial neural network

Sa Ron Park

Department of Artificial Intelligence Convergence, The Graduate School,
Pukyong National University

Abstract

Due to the development of information technology and artificial intelligence technology, various attempts are being made to graft artificial intelligence into healthcare. Among them, research in the field of tooth recognition using artificial intelligence is also active, but most of them are studies on a deep learning model that assists in treatment by judging tooth numbers, and the health status of teeth is unknown. This study proposes a tooth recognition and dental health judgment model that can know the health of teeth. First, a method for learning the optimal tooth recognition and dental health judgment model was studied by comparing a model directly designed with a Convolutional Neural Network (CNN) and a model obtained by transfer learning of a ResNet model. In addition, the study was conducted in the direction of confirming the change in model performance according to the layer depth of the ResNet transfer learning model and the improvement of the performance of the deep learning model through data augmentation. As a result, it was confirmed that the CNN model directly designed from the tooth recognition model performed better with 0.00010 Loss and the ResNet transfer learning model with 0.00022 Loss. And in the dental health judgment model, it was confirmed that the performance of the model improved as the layer of the ResNet model became deeper, and it was confirmed that the data augmentation performed best when the original data was divided into 20 equal parts and the brightness augmentation was formed.

In addition, since the CNN model designed directly from the dental health judgment model has an accuracy of 87.45% and the ResNet transfer learning model has an accuracy of 91.9%, it is confirmed that the performance of the ResNet transfer learning model is better. And the learned tooth recognition model and health judgment model loaded the learned model file on the cloud server and studied how the user accesses the model through a web page. At this time, as a result of verifying the model trained using the above method with 20 test images, the average of 90.42 points for healthy tooth data, 57.99 points for data including edited calculus among data similar to the training data, and the average of 96.21 points for celebrity dental data, 77.23 points for data that included actual calculus not similar to the training data, indicating oral health scores. This means that the dental health model found the intended level of dental health score in this study.



I. 서론

1.1. 연구의 배경 및 목적

최근 인공지능 기술의 발달로 인해 인공지능을 활용한 다양한 정보화 산업들이 생겼다[1]. 또한, 인간의 평균 수명의 연장과 COVID-19와 같은 전염병의 확산에 대한 두려움 등으로 인해 인공지능을 활용한 헬스케어에 대한 연구도 활발하다[2]. 인공지능 기술 중에서 딥러닝 기술이 많이 사용되는데, 딥러닝 기술은 헬스케어 영역에서 이점이 많고 잠재력이 뛰어나다는 평가를 받는다[3, 4, 5].

그중에서 치아 건강 관리 분야의 연구도 활발한데, 현재까지 대부분의 연구는 치아 파노라마 사진(Dental Panoramic Radiography: DPR)을 학습 데이터로 하여 치아 번호를 확인하고, 의사의 진료를 보조하는 모델을 연구했다[6]. 그러나 치아의 질병 유무, 치아의 건강 상태 등을 종합적이고 객관적으로 판단하는 인공지능 모델에 관한 연구는 거의 존재하지 않았다.

하지만, 딥러닝 기술은 치아 번호 인식뿐만 아니라 치아의 건강을 직접 판단하는 용도로 충분히 사용할 수 있다. 치아의 건강을 관리한다는 것은 정기적으로 치아의 건강 점수를 확인함으로써, 치아 질병에 대한 민감도를 높이는 것이다. 치아와 관련된 질병은 다른 신체의 질병에 비하여 빠른 속도로 병이 진행되고, 한번 치아가 망가지면 다시 복구하는데 큰 비용과 노력이 필요하므로 정기적인 관리가 필요하다. 그러나 대부분 사람이 치아 질병에 대하여 민감도가 낮으므로 치료의 적기를 놓친다[7].

이때, 딥러닝 기술은 치아의 건강을 관리 부분에서 객관적이고 종합적인 판단을 내리고[8], 웹 페이지 혹은 앱 등을 통해 정기적으로 치아 건강 점수를 확인할 수 있는 이점을 가진 기술이다. 따라서 딥러닝 기술로 치아

건강 관리를 받는 사람은 치아 질병에 대한 민감도를 높이고, 전문 의료기
관의 도움을 받는 것에 관한 판단을 더욱 빠르게 할 수 있다. 본 논문은
이와 같은 목적을 갖는 치아 건강 관리를 위한 딥러닝 모델을 연구하였다.

본 논문의 구성은 2장에서 연구의 배경 지식인 CNN 모델, YOLO, 전이
학습과 치아 인식 관련된 연구들을 살펴보고, 3장에서 치아 인식 모델과
치아 건강 판단 모델을 학습하는 방법과 학습된 모델의 사용법을 설명한
다. 4장에서는 치아 인식 모델과 치아 건강 판단 모델의 성능 평가 및 결
과를 검증하고, 5장에서는 결론 및 향후 연구 방향을 제시하였다.



1.2. 연구의 내용 및 범위

본 논문의 연구는 치아 이미지 인식 모델을 개발하는 것, 치아 건강 판단 모델을 개발하는 것, 학습된 딥러닝 모델들을 클라우드 서비스를 통해 실제로 사용하는 것, 이렇게 3가지로 진행되었다.

치아 이미지 인식 모델의 연구는 잘 알려진 이미지 인식 모델인 You Only Look Once(YOLO) 논문을 참고하여 진행하였다. YOLO는 전통적인 객체검출 모델을 따라 하지 않고, 단 한 번의 회귀로 바운딩 박스의 위치, 클래스 확률을 구하기 등의 일련의 절차를 수행하는 모델이다[9]. 데이터 전처리 방식과 데이터의 입·출력 방식은 모두 YOLO를 참조하여 구현하였다. 데이터는 치아 파노라마 이미지(DPR)가 아닌, 인터넷에서 수집한 200개의 치아 정면 이미지로 연구하였다.

또한, 치아 이미지 인식 모델의 연구는 CNN + Classification 구조와 Transfer Layer + Classification 구조를 비교하며 진행하였다. 전이학습 층에 사용된 모델은 ResNet 모델인데, ResNet 모델의 기본 구조 또한 CNN이지만 이미 학습된 모델이라는 점에서 직접 설계한 CNN 모델과 차이가 있다[10].

치아 건강 판단 모델은 건강한 치아 이미지와 건강하지 않은 치아 이미지로 이진 분류하는 모델이다. 이미지 인식 모델처럼 2가지 구조를 비교하는 것으로 연구를 진행했지만, 데이터 전처리, 출력 데이터 형태 등은 이미지 인식 모델과 차이가 있다.

치아 건강 판단 모델의 연구는 치석의 유무만으로 치아 건강을 판단하는 방향으로 진행하였다. 그 이유는 원하는 치아 데이터를 충분히 수집하는데 어려움이 있었기 때문이다. 종합적인 기준으로 건강 점수를 판단하는 딥러닝 모델 학습을 위해서는 질병 유무, 치열 상태, 치석 유무, 연령대 등

이 정확하게 나타나는 양질의 이미지 데이터가 종류별로 충분하게 필요하다[11]. 그러나 치아 데이터의 경우 여러 기준에 적합한 데이터들을 보유할 수 없었다.

또한, 병원에서 많이 보유하고 있는 치아 파노라마 데이터(DPR)는 실생활에서 접할 수 없는 데이터이기 때문에, 실생활의 이미지를 판단할 치아 건강 판단 모델의 학습 이미지로 적합하지 않았다. 따라서 인터넷에서 수집한 치아 정면 이미지 100개 데이터와 그 데이터에 치석을 편집한 데이터 100개를 치아 건강 판단 모델의 학습 데이터로 선정하였다.

마지막으로 본 논문은 학습된 딥러닝 모델들을 사용하는 방법에 관하여 연구했는데, 클라우드 서비스를 이용하여 딥러닝 모델을 서버에 탑재하고, 간단한 웹 사이트와 연동하여 데이터를 전송하게 하였다. 이때, 개인은 휴대용 단말기로 딥러닝 서버에서 제공하는 웹 사이트에 접속하여, 학습된 모델들을 사용하는 방식으로 연구를 진행했다.

II. 이론적 배경

2.1. 합성곱 신경망

합성곱 신경망(Convolutional Neural Network: CNN)은 인공지능의 종류 중 하나인데, 주로 시각적 영상 혹은 이미지의 특징을 추출하는 데 사용되는 층이다[12]. CNN의 기본적인 원리는, 먼저 입력 이미지를 특정한 필터로 필터링하여 특징을 추출한다. 추출된 특징을 특징 맵이라고 하는데, 이것을 다음 층의 입력 데이터로 넘긴다. 그렇게 마지막 층까지 가게 되면 결국 최초의 입력 이미지에 대한 핵심적인 특징들만 남고, 이것으로 분류 층에서 어떤 이미지인지 추측을 한다. 즉, CNN에서의 학습은 이미지의 특징을 추출하는 필터의 가중치를 학습시키는 것이다.

이러한 특징 때문에 CNN은 주로 이미지 혹은 영상 시계열 데이터 같은 2차원의 데이터를 분류하고 예측하는 데 사용되며, 이번 연구의 주요 모델로 사용하게 되었다. 치아 이미지 인식 모델과 치아 건강 판단 모델 모두 직접 설계한 CNN 모델과 이미 학습되어있는 전이학습 모델을 비교하며 연구를 진행했는데, 전이학습 모델 또한 기본 구조는 CNN 구조인 것을 선택하였다.




그림 1. CNN의 구조 및 데이터 학습 과정[12]

2.2. 고속 객체 인식 모델: You Only Look Once

CNN의 개념은 간단하지만, 그 용도에 따라서 CNN 구조가 사용되는 모습이 다양하다. 따라서 특정한 종류의 물체 인식을 하기 위해서는 해당 물체 인식에 최적화된 CNN 모델을 찾을 필요가 있다. 따라서 이미지 인식의 대표적 모델인 고속 객체 인식 모델(You Only Look Once: YOLO)의 개념을 사용하여 치아 이미지 인식 모델을 설계했다. 그리고 이미지 데이터에서 객체 인식을 하는 방법 또한 YOLO 방식에 알맞게 설정하였다.

YOLO에서 이미지 데이터의 객체 인식을 하는 방법은 다음과 같다. 먼저 입력 이미지를 $S \times S$ 크기의 그리드(Grid)로 나누고 그리드마다 예측하고자 하는 바운딩 박스의 개수를 B 로, 분류할 클래스의 개수는 C 라고 한다. 이때, YOLO는 이미지를 입력으로 받고, $S \times S \times (B \times 5 + C)$ 크기의 텐서를 출력으로 나타내는 네트워크 모델인데[9], 이 출력값으로 객체가 존재할 그리드의 위치를 예측한다.

출력값은 바운딩 박스를 찾는데 필요한 5가지 정보를 포함한다. 그 정보는 바운딩 박스의 센터의 x, y 좌표, 바운딩 박스의 너비, 높이, 해당 그리드가 어떤 객체를 포함하는지에 대한 신뢰도(Confidence) 값을 나타낸다. 또한, 해당 그리드에서 나타난 객체가 어느 클래스에 속할지에 대한 확률값을 나타내는 C 값도 존재한다. 만약 해당 그리드에서 신뢰도가 기준(Threshold)값 이상으로 나타나면, C 에서 가장 큰 값이 해당 그리드에서 찾은 객체이다.

치아 이미지 인식 모델은 치아 입력 이미지를 5×5 그리드로 설정하고, 치아 영역만 클래스로 설정하기 때문에 B 와 C 값 모두 1로 설정했다. 따라서 치아 이미지 인식 모델의 출력 텐서는 $5 \times 5 \times (1 \times 5 + 1)$ 이므로 150이다.




그림 2. YOLO 모델의 객체 인식 과정[9]



2.3. 전이학습

전이학습은 특정 분야에서 이미 학습된 신경망을 유사하거나 새로운 분야에서 사용되는 신경망의 학습에 이용하는 것을 의미한다. 전이학습을 사용하는 경우는 학습 데이터가 적은 경우와 학습을 진행하는 연산 장치의 성능이 좋지 못할 경우로 크게 2가지이다. 딥러닝 학습에서 학습 데이터가 적으면 학습이 잘되지 않는 어려움이 자주 나타나는데, 이때 미리 학습된 모델을 사용하는 게 모델의 성능을 높이는 방법이 된다. 그러나 학습에 충분한 데이터가 있더라도 연산 장치의 성능이 좋지 못하면 학습에 어려움이 나타난다. 이때 미리 학습된 신경망은 학습 속도 면에서 도움준다[14].

이미지 인식 모델의 전이학습에 널리 사용되는 신경망은 ResNet, GoogLeNet, VGG 등이 있는데, 이 신경망들은 CNN 층과 완전 연결층의 조합으로 구성되어 있다. 전이학습은 이 중 이미 학습된 CNN 영역의 네트워크와 새롭게 구성되는 네트워크를 연결하여 전체 구조를 구성하는 것이다[13].

이 중 ResNet 모델은 2015년 ILSVRC에서 우승을 차지한 이미지 분류 모델이다[10]. ResNet 모델은 Residual Learning 기법을 사용했는데, 이 기법은 정보 전달이 한 층을 뛰어넘게(shortcut) 함으로써 오차 역전파 시에 기울기가 쉽게 전파되도록 한다. 따라서 CNN 층이 깊어질수록 나타나던 Gradient Vanishing 문제를 보완하였고, ResNet 연구는 152층까지 층이 깊어질수록 모델의 성능이 좋아지는 것을 확인하였다. 본 논문에서 연구한 치아 이미지 인식 모델과 치아 건강 판단 모델은 ResNet152 모델을 전이 학습 모델로 사용하였다.




그림 3. Residual의 개념, 입력 데이터 x 가 한 층을 건너뛰어서 $\mathcal{F}(x)$ 와 함께 다음 층의 입력 데이터로 들어가는 모습[10]

2.4. 관련 연구

앞서 언급했듯, 치아 이미지의 건강을 관리하는 딥러닝 모델의 연구를 위해서는 양질의 이미지 데이터가 종류별로 충분하게 필요하다. 그런 이미지를 쉽게 수집할 수 있는 기관은 병원인데, 대부분의 병원에서는 진료를 목적으로 찍은 치아 파노라마 사진(DPR)만을 가지고 있다. 즉, 치아 건강 관리를 위한 딥러닝 학습에 필요한 치아 이미지 데이터는 거의 없다.

이러한 이유로 인해 딥러닝 기술을 이용하여 직접 치아 건강 상태를 진단하는 모델에 관한 연구는 거의 존재하지 않았다. 다만, 2017년 IEEE에서 발표한 한 논문에서 질병이 있는 치아 파노라마 사진을 학습 데이터로 하여 치아 질병을 Dental Caries, Periapical Infection, Periodontitis 3가지로 분류하는 연구를 진행한 사례가 있었다[15]. 해당 연구는 치아의 건강 상태에 따라 치아 파노라마 이미지의 차이가 발생할 때, 이미지 인식 모델로 치아 질병 여부를 판단할 수 있다는 사실을 보여주었다. 하지만 이 연구는 이미지에 나타나는 질병을 분류하는 딥러닝 모델을 연구한 것이지, 치아 건강 상태를 판단하는 모델을 연구한 것은 아니었다.

이외에도 치아 건강 상태를 판단하는 모델에 관한 연구는 아니지만, 전이학습 모델을 사용하여 치아 파노라마 사진을 학습하고 치아의 번호를 인식하는 딥러닝 모델 연구는 여러 차례 진행되었고, 대부분의 연구에서 성능이 높게 나오는 것을 확인할 수 있었다[6]. 이것은 딥러닝 모델이 치아 이미지 인식에도 탁월한 성능을 보이는 것을 나타내지만, 치아 번호 인식 모델들 역시 의사의 진료를 보조하는 용도였기에 치아 건강 상태를 직접 판단하는 것과는 거리가 있었다. 그래도 이 연구들은 꽤 활발하게 진행되어서 2017부터 최근까지 이어지고 있으며, 이 내용을 Table 1.에 정리하였다. Outcomes 항목 안의 Acc는 정확도(Accuracy), Pre는 정밀도

(Precision), Sen은 재현도(sensitivity), F1은 F1 score를 나타낸다.

표 1. 전이학습을 사용한 치아 인식에 관한 연구 정리

<i>Reference</i>	<i>Year</i>	<i>Image type</i>	<i>Data set Size</i>	<i>CNN architecture</i>	<i>Outcomes (%)</i>
[16]	2017	CBCT	52	AlexNet	Acc 91.0
[17]	2017	Panoramic	100	AlexNet	Acc 94.32
[18]	2018	Periapical	1000	VGG16	Pre 95.8
[19]	2019	Periapical	1250	ResNet	Pre 90
[20]	2018	Panoramic	1574	VGG16	Pre 0.9945
[21]	2019	Panoramic	100	DetectNet GoogLeNet ResNet	Sen 96.4
[22]	2020	Panoramic	303	RCNN + Heuristics	Sen 96.7
[23]	2020	Bitewing	1125	GoogLeNet Inception v2	Pre 0.9293
[24]	2021	Panoramic	421	GoogLeNet Inception v2	F1 0.9686
[5]	2021	Periapical	1686	GoogLeNet Inception v3	F1 0.8720

Ⅲ. 연구 방법

3.1. 치아 인식 모델

3.1.1. 데이터 수집 및 전처리

이미지 인식 모델이 처리할 데이터의 범위를 정면 치아 이미지로 국한했다. 이는 정면 데이터가 아닌 치아 데이터의 수집은 쉽지 않았고, 정면 데이터가 아니면 치석을 제대로 분별하기 쉽지 않았기 때문이다. 따라서 200개의 치아 정면 이미지 데이터를 이미지 인식 모델의 학습 데이터로 사용하였다.



그림 4. 치아 데이터의 예시

치아 이미지 인식 모델의 학습을 위해 수집된 이미지 데이터 레이블링, 이미지 데이터 Resize, 출력 데이터의 텐서 구성, 이처럼 3가지의 이미지 전처리 작업을 진행하였다. 먼저 'ImgLabel'이라는 파이썬의 라이브러리를 사용하여 치아 영역을 레이블링하였는데, 잇몸은 최소한으로 포함되도록 하였다.




그림 5. 치아 데이터 레이블 영역의 예시

다음으로 딥러닝 모델에서 학습할 때는 이미지의 크기가 일정해야 하므로 모든 이미지 데이터를 (256, 256, 3) 크기로 통일했고, 처리하는 과정에서 이미지의 기존 비율을 보존하였다. 또한, 이미지의 여백 부분을 검은색으로 채우고, 기존에 표시된 레이블링 영역 또한 조정하였다.

따라서 입력 데이터는 (256, 256, 3)의 이미지 데이터가 되었으며, 출력 데이터의 텐서는 2.2에서 설명한 $S \times S \times (B \times 5 + C)$ 의 공식이 적용되어서 150이 되었다. 또한, 입력 값을 0~1 사이의 값으로 정규화했는데, 이때 정규화된 입력 값에 따라서 출력 값도 0~1 사이의 값이 나와야 했기 때문에 모델의 출력층의 활성화 함수를 'Sigmoid'로 하였다.

그리고 이 출력 값으로 치아 객체의 존재를 예측하였다. 인식해야 할 객체를 치아 영역만 설정했으므로 출력 데이터에서 바운딩 박스의 신뢰도 값이 기준값보다 크다는 것은 치아 객체가 존재할 확률이 높은 것을 의미한다. 이때, 가장 신뢰도 값이 큰 그리드 1개만을 선택했고, 해당 그리드의 바운딩 박스 정보와 치아 객체일 확률값을 이미지에 표시하도록 하였다.



그림 6. Resize 처리된 학습 데이터 예시



그림 7. 치아 영역 인식 결과 예시

3.1.2. 치아 인식 모델 구조

치아 인식 모델에 대하여 CNN 층과 분류 층으로 구성된 모델과 ResNet 층과 분류 층으로 구성된 전이학습 모델을 설계하여 두 모델을 비교하였다. 두 모델은 모두 (256, 256, 3)의 형태를 가지는 치아 이미지 데이터를 입력 데이터로 설정하였다.

CNN + Classification 구조에서 CNN 층에서는, 먼저 이미지 특징을 추출하는 Convolution 층을 2개씩 쌓았다. 그리고 이전 층에서 출력된 특징 맵을 Z-Score 정규화하는 Batch Normalization(BN) 층을 다음 층에 넣었다. 그리고 특징 맵의 크기를 줄이는 2×2 Max Pooling 층을 넣었다. 이것을 CNN 층을 이루는 기본 단위로 설정하였다. 그리고 위 기본 단위를 토대로 노드의 개수나 층의 개수, 하이퍼 파라미터의 값 등에 변화를 주면서 최적의 모델 구조를 찾았다.

분류 층에서는, 먼저 CNN에서 나온 결과를 1차원 벡터로 바꾸는 Flatten 층을 넣었다. 그리고 완전 연결 층인 Dense 층, Z-Score 정규화 층인 BN 층, 음의 값은 0, 양의 값은 그대로 출력해주는 RELU(Activation) 층, 네트워크의 일부 노드를 생략해서 노드들의 가중치 동조화를 방지하는 Dropout 층까지를 기본 단위가 되는 순서로 설정했다. 그리고 노드의 수, 층의 수 등을 변화시키며 최적화 과정을 거쳤고, 출력층은 출력 텐서가 (150,1) 형태를 가져야 하므로 노드를 150으로 하였고, Sigmoid 활성 함수를 사용했다.

CNN과 분류 층의 기본 단위를 위 순서로 설정한 이유는 모델 구조를 찾는 실험 결과 가장 성능이 좋은 구조였기 때문이다. Fig. 8.은 이 구조에서 가장 최적의 노드 수, 층수 등도 시행착오를 거쳐서 찾아낸 모델이다. CNN 층에서는 3×3 합성곱 층 2개, BN 층 1개, 2×2 Max Pooling 층 1개

인 CNN 층이 총 4번 반복되고, 반복될 때마다 노드의 수가 합성곱 층에서 16, 32, 64, 128로 늘어난다. 분류 층에서는 Dense 층, BN 층, RELU 층, Dropout 층이 총 4번 반복되고, 반복될 때마다 Dense 층에서 노드의 수가 1024, 512, 256, 128로 줄어든다. 현재 구조에서 노드나 층의 수를 더 늘리거나 줄이면 오히려 Validation Loss가 떨어지는 것을 확인하였다.






그림 8. 치아 인식 모델 중 CNN + Classification 모델의 구조

전이학습인 ResNet + Classification 구조에서 ResNet 모델은 ResNet50, ResNet101, ResNet152 이렇게 층의 개수에 따라서 3가지 종류의 모델이 존재한다. 층이 깊어질수록 모델의 성능이 높아진다는 연구 결과가 있었으나, 전이학습의 환경에서도 적용이 되는 것을 확인하기 위하여 ResNet 모델의 층수를 다르게 하여 학습을 하였고, 가장 깊은 층인 ResNet152가 전이학습에서도 가장 좋은 성능을 낸다는 사실을 얻을 수 있었다. 따라서 전이학습 모델은 ResNet152만을 사용하였다.

ResNet152는 7×7 합성곱 층이 우선적으로 존재하고, 3×3 Max Pooling 층이 다음으로 존재하는 구조이다. 이후 합성곱 150개 층이 차례로 존재하는데, 3개 층 단위로 Short-cut Connection이 발생한다. 이 합성곱 150개 층은 기본적으로 Kernel size 1×1 , Kernel size 3×3 , Kernel size 1×1 인 3개 층 단위로 구성되어 있고, 이 구조에서 노드 개수가 (64, 64, 256)인 구조를 3번, (128, 128, 512)인 구조를 8번, (256, 256, 1024)인 구조를 36번, (512, 512, 2048)인 구조를 3번 반복하는 구조로 되어있다.

ResNet152 층은 이미 학습이 되어있으므로, 가중치가 변하지 않도록 고정했고, 분류 층에서만 노드의 수, 층의 수, 하이퍼 파라미터의 값 등을 조정하면서 최적의 모델을 찾았다. 분류 층의 전체적인 구조는 CNN + Classification 모델에서 분류 층과 같다.




그림 9. 치아 인식 모델 중 ResNet152 + Classification 모델의 구조

3.2. 치아 건강 판단 모델

3.2.1. 데이터 전처리

치아 건강 판단 모델은 건강한 치아와 건강하지 않은 치아를 분류하는 딥러닝 모델이고, 그 분류 기준은 치석의 유무로 하였다. 데이터는 모델 학습에 쓰일 100개의 건강한 치아 데이터를 인터넷에서 수집하였고, 수집한 이미지에 치석 이미지를 편집한 100개의 건강하지 않은 데이터를 직접 만들었다. 따라서 총 데이터는 200개이고, 편집 과정에서 치석의 색깔은 실제 치석 색깔을 측정한 RGB(223, 178, 112)로 하였다.



그림 10. 치아 데이터에 치석 이미지 편집 예시

그러나 200개의 치아 데이터로는 학습이 잘되지 않았는데, 충분하지 않은 데이터 수를 주요 원인으로 예상하였다. 그리고 치석의 유무보다 치열, 치아의 형태, 이미지의 밝기 등 다른 요인들이 더 크게 작용한 것도 원인으로 예상하였다.

따라서 모델의 정확도를 높이기 위해 학습 데이터를 늘렸다. 먼저 데이터를 건강하지 않은 치아 100개로 한정하고, 이미지를 횡 방향으로 2등분, 종 방향으로 10등분, 총 20등분을 하였다. 그리고 등분된 각 이미지를

(256, 256, 3)의 크기로 Resize 했는데, 이렇게 만든 각각의 이미지를 하나의 입력 데이터로 하면, 학습 데이터가 총 2000개의 데이터로 늘어난다.




그림 11. 치아 데이터 20등분 및 Resize 예시

더 나아가, 밝기 증강 데이터(Brightness Augmentation)를 만들어주었다. 밝기의 수준을 흑백 이미지를 0, 원본 이미지를 1, 백색 이미지를 2라고 할 때, 0.5~1.5 범위 안에서 랜덤하게 발생시켰는데, 기존 데이터에서 증강 데이터를 4배 발생시켜서 전체 데이터는 총 10000개다. 이에 따라 학습할 때 데이터의 밝기에 따른 영향을 덜 받게 되었고, 분류 모델 성능이 좀 더 좋아졌다.




그림 12. 밝기 증강 데이터의 예시

그리고 더 나아가, 회전 증강(Rotation Augmentation)을 만들었을 때 결

과가 더 좋게 나올 수 있는지 확인했다. 10000개 데이터 각각에 임의의 90도 미만의 회전 증강 데이터를 4배 더 발생시켰고, 전체 데이터는 총 50000개로 분류 모델의 성능을 확인하였으나, 이전보다 더 좋지 않았음을 확인했다.




그림 13. 회전 증강 데이터의 예시

3.2.2. 치아 건강 판단 모델 구조

치아 건강 판단 모델을 학습할 때, 20등분 된 치아의 이미지 각각이 레이블값이 필요하므로, 직접 데이터를 확인하며 레이블링해주었다. 학습된 모델로 테스트할 때, 20등분 된 치아 이미지가 입력값으로 들어가고, 출력값으로 20등분 된 이미지 데이터 각각에 대해 건강한 치아 혹은 건강하지 않은 치아에 속할 확률값이 출력된다. 따라서 20개 출력값의 산술평균값을 건강 점수로 설정하였다.

치아 건강 판단 모델의 구조 역시 치아 이미지 인식 모델과 마찬가지로 직접 설계한 CNN 모델과 전이학습 모델에 대하여 최적의 모델 구조를 찾고 결과를 비교하였다. 또한, 입력 데이터의 형태도 (256, 256, 3) 형태의 이미지 데이터로 치아 인식 모델과 같다. 다만, 출력 데이터에 차이가 있는데, 치아 건강 판단 모델은 이진 분류 모델이므로 출력 텐서가 2이고, 출력 함수도 'Softmax'로 하였다. 또한, 최적화 과정에서 조정하는 노드 수, 하이퍼 파라미터 등의 값도 다르게 나타났다.

치아 건강 판단 모델에서 직접 설계한 CNN 모델의 구조는 다음과 같다. 3×3 합성곱 층 2개, Dropout 층 1개, 2×2 Max Pooling 층 1개 순서로 총 4번 반복되고, 반복될 때마다 합성곱 층의 노드 수만 4, 8, 16, 32로 증가한다. 분류 층에서는 Dense 층, BN 층, RELU 층, Dropout 층이 총 4번 반복되고, 반복될 때마다 Dense 층의 노드의 수만 128, 64, 32, 16으로 감소한다.

전이학습 모델의 ResNet152 층의 구조는 치아 인식 모델의 구조와 같고, 분류 층의 구조도 치아 인식 모델 중 전이학습 모델에서 사용된 분류 층의 구조와 같다.




그림 14. 치아 건강 판단 모델 중 CNN + Classification 모델의 구조




그림 15. 치아 건강 판단 모델 중 ResNet152 + Classification 모델의 구조

3.3. 학습된 딥러닝 모델의 사용 방안 연구

치아 이미지 인식 모델과 치아 건강 판단 모델의 최적 모델을 찾고, 두 모델을 사용할 수 있는 방안에 관하여 연구를 했다. 이미 학습된 모델들은 파일 형식으로 저장할 수 있기에, 학습된 모델을 클라우드 서버에 탑재하게 되면 웹 페이지에서 간단하게 딥러닝 모델을 사용할 수 있게 된다.

학습된 모델을 탑재하기 위한 클라우드 서비스는 AWS의 'EC2'를 사용했고, 개발 환경은 OS 환경은 리눅스 20.04, 가상 CPU 2개, RAM 8기가를 선택했다. Python 버전은 3.8.10, Tensorflow는 2.5.0, Keras는 2.3.0으로 하였고, 서버로서 기능을 위한 라이브러리들을 설치해주었다.

특별히 웹 페이지와 파일 간의 데이터 전송 및 연관성 설정을 위해 Python 라이브러리인 'Flask'를 사용했다. 어떤 파일에서 Flask를 불러오면, 그 파일은 Flask로 개방한 특정 포트와 서버에서 할당한 공인 IP를 사용하여 사용자가 특정 웹 페이지로 접속할 수 있게 만든다. 웹 페이지에서 사용자와 서버는 데이터를 주고받을 수 있는데, 사용자는 웹 페이지에서 치아 건강을 확인하고 싶은 이미지의 'URL 주소'를 입력하도록 설정했고, 웹 페이지에서는 데이터를 'GET 방식'으로 Flask를 불러온 파일에 넘겨주게 된다.

Flask를 불러온 파일은 메인 파일인데, 메인 파일은 URL 주소에서 이미지 데이터를 추출하고, 학습된 모델들을 호출한다. 호출된 치아 이미지 인식 모델은 이미지 인식을 위해 이미지를 전처리하고, 치아 데이터에서 치아 영역을 찾아낸 후, 그 영역만 잘라내서 새로 저장한다. 그 후 호출된 치아 건강 판단 모델은 치아 이미지를 전처리하고 건강 점수를 판단한다. 마지막으로 원본 이미지, 치아 인식 결과 이미지, 건강 점수, 이 3가지 결과를 'Json 형식'으로 변환하여 사용자가 접속해있는 웹 페이지로 반환한다.




그림 16. 딥러닝 모델 사용을 위한 구조 및 데이터 흐름도

치아 건강을 측정할 사진의 URL을 입력해주세요

Origin Image

Result Image



Teeth care Score: 40

그림 17. Index.html 파일에 구현된 웹 페이지 화면 예시

위와 같은 방식으로 치아 인식 모델과 치아 건강 판단 모델을 사용하면, 사용자가 웹상에서 간단하게 치아 건강을 확인할 수 있다. 향후 더 향상된 성능의 딥러닝 모델을 개발하더라도, 이미 구축된 클라우드 서버는 딥러닝 모델의 파일만 바꿔주면 된다는 이점이 있다.

데이터 전처리 과정 및 치아 인식 모델, 치아 건강 판단 모델의 입·출력 과정에서 입력 데이터의 변화는 다음과 같다. 입력된 데이터는 치아 인식 모델을 거쳐서 치아를 인식한 부분을 표시하는 이미지를 생성한다. 이후 치아 건강 판단 모델에 사용되기 위해 치아 영역만 남게 되고, 20등분 된다. 그리고 치아 건강 판단 모델을 거쳐서 건강 점수를 생성한다.




그림 18. 전처리 및 모델 입·출력에 의한 입력 데이터의 변화 예시

IV. 연구 결과

4.1. 치아 인식 모델 결과

전통적인 이미지 인식 모델은 이미지 클래스 개수와 관계없이 이미지의 객체를 인식하는 것이다. 따라서 모델을 평가할 때 얼마나 잘 분류했느냐보다, 오차가 얼마나 작은가를 평가한다. 비록 치아 인식 모델의 클래스가 1개지만, 이미지 인식 모델의 특성에 따라서 Loss 값을 모델 평가에 사용했다.

치아 이미지 인식 모델은 CNN + Classification 모델과 ResNet152 + Classification 모델을 각각 설계하여 결과를 비교하였는데, CNN 모델이 전이학습 모델보다 성능이 약간 더 좋았다. 그 이유는 ResNet152 모델 같은 경우 1000개 이상의 이미지 클래스를 학습하는데 최적화되어있으나, 치아 인식 모델의 경우 1개 클래스만 학습하면 되기 때문에 직접 CNN 구조를 설계한 모델이 치아 이미지 학습에는 더 최적화된 것으로 판단된다.

설계 과정에서 컴파일 환경은 두 모델이 같도록 설정했는데, 학습 대 검증 데이터 비율은 9대 1로 하였다. Optimizer는 'Adam'으로 하였고, loss 함수는 'mean square error'로 하였다. 학습률은 0.001, decay는 0.0001, epoch는 500, batch size는 8로 설정했다.

표 2. 치아 인식 모델에서 CNN 모델과 전이학습 모델의 결과 비교

모델종류	Train_Loss	Validation_Loss
CNN + Classification	0.00009	0.00010
ResNet152 + Classification	0.00012	0.00022

4.2. 치아 건강 판단 모델 결과

치아 건강 판단 모델은 이미지를 건강한 치아와 건강하지 않은 치아로 이진 분류하는 모델이다. 따라서 정확도를 모델 평가 기준으로 사용했고, Loss 값은 모델의 과적합을 확인하는 용도로 참조했다. 그리고 전이학습 모델에서 ResNet 모델의 층의 깊이에 변화를 준 결과, 학습 데이터를 증강(Augmentation)하며 데이터 개수에 변화를 준 결과, 그리고 CNN + Classification 모델과 ResNet152 + Classification 모델을 비교한 결과를 실험을 통해 나타냈다.

전이학습 모델인 ResNet 층은 깊어질수록 이미지 인식의 성능이 좋다는 것이 이미 연구를 통해 드러났다[10]. 그러나 ResNet 모델은 이미지 인식을 위한 모델이기 때문에 이미지 분류 모델에서도 연구 결과가 적용되는지 확인이 필요했다. 따라서 ResNet 모델의 층의 깊이를 다르게 한 결과를 확인하였고, 데이터는 회전 증강까지 한 50000개의 데이터로 실험하였다.

ResNet50 모델의 경우 파라미터를 최대한 조정했을 때 Test 정확도가 89%였지만, 같은 조건에서 전이학습 모델만 ResNet101로 바꿨을 때 정확도가 약 1% 더 올랐다. 그리고 ResNet101 모델도 최적의 파라미터를 찾은 상태에서 전이학습 모델만 ResNet 152로 바꿨을 때 정확도가 약 0.3% 더 올랐다. 따라서 이미지 분류 모델에서도 ResNet152가 가장 좋은 모델인 것이 확인되었다. 이후 파라미터를 조정해가며 테스트를 더 진행한 결과 ResNet152 모델의 정확도가 91%까지 오르는 것을 확인했다.

Table 3.에서 언급하는 분류 층의 기본 구조는 Dense, BN, Activation(RELU), Dropout(0.5)이고, Classification 항목의 숫자는 Dense 층의 노드 수를 의미한다. HyperParameter 열의 lr은 학습률, ep는 epoch, d는 Decay를 의미한다. 모델 컴파일 환경은 Optimizer는 'Adam', loss 함

수는 ‘categorical crossentropy’ 함수로 설정되었고, Training과 Validation, Test 데이터 비율은 7대 1대 2로 설정했다.

표 3. ResNet 모델의 층의 깊이에 따른 치아 건강 판단 모델의 정확도 변화

Transfer	Classification (Dense)	HyperParameter		Train_ Acc	Val_ Acc	Test_ Acc
ResNet50	32, 16, 8, 4	lr=0.001, d=0.0001	ep=300,	0.9330	0.9563	0.8924
ResNet50	96, 48, 24, 12	lr=0.00005, d=0.0001	ep=300,	0.9417	0.9427	0.8934
ResNet101	96, 48, 24, 12	lr=0.00005, d=0.0001	ep=300,	0.9566	0.9565	0.9052
ResNet101	128, 64, 32, 16	lr=0.00005, d=0.0001	ep=300,	0.9656	0.9628	0.9040
ResNet152	128, 64, 32, 16	lr=0.00005, d=0.0001	ep=300,	0.9695	0.9653	0.9070
ResNet152	192, 96, 48, 24	lr=0.00005, d=0.0001	ep=300,	0.9820	0.9688	0.9061
ResNet152	64, 32, 16, 8	lr=0.001, d=0.0001	ep=70,	0.9715	0.9747	0.9121
ResNet152	256, 128, 64, 32	lr=0.00001, d=0.0001	ep=400,	0.9193	0.9295	0.9131
ResNet152	512, 256, 128, 64	lr=0.00001, d=0.0001	ep=400,	0.9424	0.9463	0.9134
ResNet152	1024, 512, 256, 128	lr=0.00001, d=0.0001	ep=400,	0.9652	0.9622	0.9124

다음으로 데이터를 증강하며 데이터 개수에 변화를 줬을 때 모델 성능의 변화를 실험하였다. 모델은 Table 3.에서 정확도가 가장 높게 나온 ResNet152 전이학습 모델로 통일하였다. 데이터 증강에 따른 모델 성능의 비교는 학습 데이터의 개수가 다르므로 분류 층의 노드의 수를 다르게 해줘야 과적합이 발생하지 않는다. 따라서 증강 단계에 따라 분류 층의 노드 수를 다르게 한 모델을 적용했는데, 원본 데이터(Original)와 20등분 된 데이터(Divided)의 경우 분류 층의 노드를 (128, 64, 32, 16)으로 설정했고, 밝기 증강 데이터(Brightness Augmentation)와 회전 증강 데이터(Rotation Augmentation)의 경우 (1024, 512, 256, 128)로 설정했다. Table 4.의 Augmentation 열의 괄호 안의 값은 학습에 사용된 데이터의 개수이다.

실험 결과 20등분으로 나눈 데이터는 기존 데이터보다 학습 효과가 더 좋게 나타났고, 밝기 증강을 했을 때는 20등분으로 나눴을 때보다 성능이 더 좋아지는 것을 확인했다. 그러나 회전 증강을 했을 때는 밝기 증강을 했을 때보다 결과가 더 나쁜 것을 확인했다. 이것은 비록 학습 데이터가 더 많아지더라도, 치아 건강 판단 모델의 경우에 회전 증강한 데이터는 오히려 학습에 방해가 된다는 것을 의미한다. 따라서 의미 있는 데이터 증강은 밝기 증강 단계까지임을 확인하였다.

표 4. 데이터 증강에 따른 Accuracy의 변화

Augmentation	Train_Acc	Val_Acc	Test_Acc
Original Data (200)	0.6042	0.5000	0.5750
Divided Data (2000)	0.9772	0.8750	0.9100
Brightness Data (10000)	0.9928	0.9912	0.9190
Rotation Data (50000)	0.9652	0.9622	0.9124

마지막으로 CNN + Classification 모델과 ResNet152 + Classification 모델의 성능을 비교하였는데, 데이터는 가장 좋은 성능을 보였던 밝기 증강 단계의 데이터로 하였다. 설계 과정에서 컴파일 환경은 두 모델이 학습률에서 차이가 있었는데, CNN + Classification 모델은 학습률이 0.00005, ResNet152 + Classification 모델은 학습률이 0.00001이었다. 그러나 나머지 하이퍼 파라미터 및 컴파일 환경은 같았는데, decay는 0.0001, epoch는 400, batch size는 64로 하였고, optimizer는 ‘Adam’, loss 함수는 ‘categorical crossentropy’ 함수로 설정되었고, Training과 Validation, Test 데이터 비율은 7대 1대 2로 설정했다.

실험 결과 CNN + Classification 모델이 ResNet152 + Classification 모델보다 성능이 좋지 않음을 확인했다. 이 결과는 이미 학습된 ResNet152 모델이 이미지 인식이 아닌 이미지 분류에도 높은 성능을 보임을 나타낸다. 또한, CNN 모델은 Gradient Vanishing 문제 때문에 층을 쌓는 데 한계가 있지만, Residual 기법을 적용한 ResNet152 모델은 이러한 문제 없이 152개 층을 사용하는 데에서 이점을 얻는다고 판단된다.

표 5. 치아 건강 판단 모델에서 CNN 모델과 전이학습 모델의 결과 비교

모델 종류	Validation_Acc	Test_Acc
CNN + Classification	0.9962	0.8745
ResNet152 + Classification	0.9912	0.9190

4.3. 학습된 모델의 추가 검증

4.1, 4.2.에서 학습된 모델은 별도의 테스트 데이터셋을 사용하여 추가적으로 검증되었다. 이를 통해 본 연구에서 개발된 모델이 새로운 데이터셋에도 적용 가능한지를 검증하였다. 4.2에서 모델을 검증한 데이터셋을 데이터셋A, 개구기를 착용한 데이터 중 건강한 치아 데이터와 그 데이터에 치석을 편집한 데이터를 데이터셋B, 개구기를 착용하지 않은 데이터 중 건강한 치아 데이터와 실제 치석이 포함된 데이터를 데이터셋C로 지칭하였다. 데이터셋B의 편집한 치석 이미지와 데이터셋C의 실제 치석 이미지의 치석량은 비슷하게 설정했다. 테스트 이미지들은 모두 인터넷에서 20개씩 수집하였고, 이미지 인식 모델과 치아 건강 판단 모델의 학습에 사용되지 않은 이미지를 선정했다.

검증에 사용된 모델 중 이미지 인식 모델은 CNN + Classification 모델을, 치아 건강 판단 모델은 밝기 증강 데이터를 학습한 ResNet152 + Classification 모델을 클라우드 서버 탑재하였고, 데이터셋B와 데이터셋C로 두 모델을 검증했다. 또한, 치아 건강 점수는 100점 만점으로 하였고, 소수점 둘째 자리까지 표기되도록 설정하였다. 테스트 결과는 표 6.에 정리하였다.

테스트 결과를 분석할 때, 데이터셋B의 경우는 건강한 치아 데이터에서 치석 이미지를 편집했기 때문에 건강한 치아 데이터와 편집된 치석 포함 데이터를 비교하는 것이 옳다고 판단된다. 테스트 결과 데이터셋B의 두 집단의 평균 건강 점수는 약 32.43점 차이가 났고, 각각의 표준편차도 10.72, 12.5로 나타났다. 이는 데이터셋B의 경우 연구에서 의도한 수준만큼의 건강 점수로 잘 판단했음을 의미하는데, 그 이유로 데이터셋B가 학습에 사용된 데이터와 유사한 직접 편집한 치석 데이터이기 때문이라고 판단된다.

데이터셋C의 경우는 건강한 치아 데이터와 실제 치석 포함 데이터의 연관 관계가 없기에 각각 비교하였다. 건강한 치아 데이터의 경우 평균 구강 점수 96.21점, 표준편차 6.88로 연구에서 의도했던 구강 점수 수준이 나온 것을 확인했다. 실제 치석 포함 데이터는 평균 구강 점수 77.23점, 표준편차 20.49로 나타났는데, 이는 비슷한 치석량을 갖는 데이터셋B의 편집된 치석 이미지의 결과에 비해 치아 건강 판단이 제대로 이루어지지 않았음을 의미한다. 핵심적인 이유로 여겨지는 것은, 편집된 치석 이미지보다 실제 치석의 색깔 혹은 형태가 더 다양하게 나타났고, 그에 따라 치석 인식률이 떨어졌으로 판단된다. 따라서 향후 치아 건강 모델을 개선한다면, 학습 데이터로 치석 이미지를 편집할 때, 더 다양한 색깔과 형태의 치석으로 편집해서 치아 건강 모델의 성능을 높일 수 있을 것으로 판단된다.




표 6. 치아 건강 점수 비교

	데이터셋 B		데이터셋 C	
	건강한 치아 데이터 (개구기 착용)	편집된 치석 포함 데이터 (개구기 착용)	건강한 치아 데이터 (개구기 미착용)	실제 치석 포함 데이터 (개구기 착용 & 미착용)
	100	90.58	100	96.33
	100	70	100	94.73
	99.99	69.13	100	93.53
	99.99	66.67	100	92.81
	99.91	66.13	100	92.21
	95.33	64.93	100	92.02
	94.99	62.56	100	90.54
	94.94	61.08	100	89.95
	94.33	61.01	100	89.27
	94.24	60	99.99	85.81
	92	55.01	99.98	85.45
	91.74	54.89	99.98	78.3
	90.79	54.68	99.97	77.19
	89.97	54.25	97.07	75.11
	89.51	53.04	95.02	69.91
	86.6	50.05	95.01	68.53
	84.76	49.99	91.93	64.84
	77.16	46.2	85.12	50.96
	76.57	34.85	85.01	30.04
	55.63	34.82	75.14	27.02
평균	90.42	57.99	96.21	77.23
표준편차	± 10.72	± 12.50	± 6.88	± 20.49



그림 19. 테스트에 사용된 전체 이미지 데이터

(위부터 차례로 데이터셋B의 건강한 치아 데이터, 편집된 치석 포함 데이터, 데이터셋C의 건강한 치아 데이터, 실제 치석 포함 데이터 순서)



Teeth care Score: **99.91**



Teeth care Score: **89.97**

그림 20. 건강한 치아 데이터 중 19, 20번 데이터의 테스트 결과



Teeth care Score: **55.01**



Teeth care Score: **62.56**

그림 21. 편집된 치석을 포함하는 데이터 중 19, 20번 데이터 테스트 결과



Teeth care Score: **95.02**




Teeth care Score: **100**

그림 22. 연예인 치아 데이터 중 3, 18번 데이터 테스트 결과



Teeth care Score: **30.04**



Teeth care Score: **68.53**

그림 23. 실제 치석 포함 데이터 중 1, 17번 데이터 테스트 결과

V. 결론

이미지 데이터, 시계열 데이터 처리에 많이 사용되는 CNN 모델, 그 CNN 모델을 사용하여 이미지 인식, 이미지 분류 모델을 만들었다. 이 모델들을 각각 직접 설계한 CNN 모델과 이미 학습된 CNN (ResNet) 모델을 전이학습 한 결과를 비교 분석하는 것을 목적으로 연구를 진행하였다.

전이학습 관련 선행 연구들 때문에[14], 이미지 인식 부분에서도 전이학습 모델이 직접 설계한 CNN 모델보다 성능이 좋을 거라고 예상하였다. 그러나 치아 인식 모델 같은 경우 큰 차이는 아니지만, 직접 설계한 CNN 모델이 ResNet 전이학습 모델보다 0.0001 Loss 정도 뛰어난 성능을 보였다. 이는 전이학습 모델의 경우 1000개 이상의 클래스를 인식하는 것을 학습한 모델이기 때문에, 1개의 클래스를 인식하는 것도 상당 수준의 성능을 보인 것으로 판단된다. 그러나 인식할 클래스가 1개이기 때문에 직접 CNN 구조를 설계한 것이 좀 더 좋은 성능을 낸 것으로 판단된다.

치아 건강 판단 모델 같은 경우, 예상대로 전이학습 모델이 직접 설계한 CNN 모델보다 좋은 성능을 보였다. 이는 이미 학습된 ResNet152 모델이 이미지 인식이 아닌 이미지 분류에도 높은 성능을 나타냈기 때문에 발생한 결과라고 판단된다. 또한, CNN 모델은 Gradient Vanishing 문제로 인해 층을 쌓는 데 한계가 있지만, Residual 기법을 적용한 ResNet 모델은 이러한 문제 없이 152개 층을 사용하는 것이 원인이라고 판단된다.

치아 인식 모델의 경우 YOLO와 같이, 복잡한 이미지 속에서 얼굴 인식을 하고, 얼굴에서 치아 부분을 인식하는 것에 관한 연구가 앞으로 필요하다고 판단된다. 또한, ResNet 뿐만 아닌 VGG, GoogLeNet 등 기존의 이미지 인식 모델들과 비교하며 더 좋은 CNN 모델을 제안할 수 있을 것으로 판단된다.

치아 건강 판단 모델의 경우, 치아 상태, 질병 유무, 연령대 등에 따른 다양한 치아 데이터를 확보하여 종합적인 기준에서 치아 건강 점수를 나타낼 수 있는 모델로 업그레이드하는 연구가 필요하다고 판단된다. 또한, 사람마다 치열도 다르고 치아의 개수도 다르기에, 20등분을 하는 것보다 치아 인식 모델에서 각 치아를 개별적으로 인식하고, 인식한 치아에 대한 건강 점수의 합산을 내는 것이 더 정확한 판단 모델이 될 것으로 판단된다.

모델을 사용하는 관점에서의 경우, 휴대용 단말기 카메라와 서버의 실시간 연동을 통해 이미지 인식과 치아 건강 점수의 실시간 반영에 관한 연구가 필요하다고 판단된다. 또한, 연구 모델의 실용성을 높이기 위해 휴대용 단말기가 아닌 칫솔에 카메라를 탑재하여 사진을 촬영하고, 딥러닝 서버와 연동되도록 하여 건강 점수를 보여주는 방법이 있다고 판단된다.

지금까지 있었던 치아 인식 관련 딥러닝 연구들은, 치아의 위치 인식과 병원 진료 보조를 중점으로 진행되었다. 그러나 치아 이미지를 학습하여 치아의 건강을 스스로 판단하고, 더 나아가 병원의 진료 수준만큼 치아의 질병을 정확하게 판단할 수 있는 잠재력이 딥러닝 모델에 분명히 존재한다. 또한, 학습된 딥러닝 모델을 사용하는 것은 애플리케이션 접근만큼이나 간단하기에, 치아 건강을 비롯한 차세대 헬스케어 기술로서 딥러닝 기술의 잠재력이 실로 크다고 할 수 있다.

참고문헌

- [1] Xu et al. "The Fourth Industrial Revolution: Opportunities and Challenges" in *International Journal of Financial Research*, 2018.
- [2] Park et al. "사물인터넷 기반 헬스케어 서비스 및 플랫폼 동향" in *The Korean Institute of Communications and Information Sciences*, 2014.
- [3] Yu et al. "Artificial intelligence in healthcare" in *Nature Biomedical Engineering*, 2018.
- [4] Jiang et al. "Artificial intelligence in healthcare: past, present and future" in *Stroke and Vascular Neurology*, 2017.
- [5] Shen et al. "An introduction to deep learning in medical physics: advantages, potential, and challenges," in *Physics in Medicine & Biology*, 2020.
- [6] Görürgöz et al. "Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs" in *Dentomaxillofac Radiol*, 2021.
- [7] Kang et al. "구강보건인식, 태도, 행동 및 지식도가 치태관련질환 발생에 미치는 영향" in *대한예방치과·구강보건학회*, 1994.

- [8] LeCun et al. "Deep learning," in *Nature*, 2015.
- [9] Redmon et al. "You Only Look Once: Unified, Real-Time Object Detection" in *CVPR*, 2016.
- [10] He et al. "Deep Residual Learning for Image Recognition" in *CVPR*, 2016.
- [11] Cho et al. "How much data is needed to train a medical image deep learning system to achieve necessary high accuracy?" in *IEEE*, 2016.
- [12] Albawi et al. "Understanding of a Convolutional Neural Network" in *IEEE*, 2017.
- [13] Rezende et al. "Malicious Software Classification Using Transfer Learning of ResNet-50 Deep Neural Network," in *IEEE*, 2017.
- [14] S. J. Pan et al. "A Survey on Transfer Learning," in *IEEE*, 2010.
- [15] Prajapati et al. "Classification of Dental Diseases Using CNN and Transfer Learning" in *IEEE*, 2017.
- [16] Miki et al. "Classification of teeth in cone-beam CT using deep convolutional neural network" in *Comput Biol Med*, 2017.

- [17] Oktay et al. “Tooth detection with Convolutional neural networks” in *Medical Technologies National Congress (TIPTEKNO) IEEE*, 2017.
- [18] Zhang et al. “An effective teeth recognition method using label tree with cascade network structure” in *Comput Med Imaging Graph*, 2018.
- [19] Chen et al. “A deep learning approach to automatic teeth detection and numbering based on object detection in dental periapical films” in *Sci Rep*, 2019.
- [20] Tuzoff et al. “Tooth detection and numbering in panoramic radiographs using convolutional neural networks” in *Dentomaxillofac Radiol*, 2019.
- [21] Muramatsu et al. “Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data” in *Oral Radiol*, 2021.
- [22] Kim et al. “Automatic tooth detection and numbering using a combination of a CNN and heuristic algorithm” in *Applied Sciences*, 2020.
- [23] Yasa et al. “An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs” in *Acta Odontol Scand*, 2021.

[24] Kılıc et al. “Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs” in *Dentomaxillofac Radiol*, 2021.

