

심장 MRI 영상 처리 및 분석 / 진단 인공지능 학습모델 개발



201924506 양준석

201924533 이수빈

201824487 박현수

지도교수 감진규

목 차

1. 서론.....	1
1.1. 연구 배경.....	1
1.2. 기존 문제점	1
1.3. 연구 목표.....	2
2. 연구 배경.....	3
2.1. 배경지식	3
2.2. 데이터 분석	4
2.3. 서버 구성.....	5
3. 연구 내용.....	6
3.1. Segmentation 모델	6
3.1.1. 데이터 전처리	6
3.1.2. 모델 구조.....	7
3.1.3. Segmentation 오버레이 마스킹.....	9
3.1.4. 데이터 후처리	10
3.2. Classification 모델	10
3.2.1. Feature extraction.....	10
3.2.2. 모델 구조.....	12
3.3. 시각화.....	13
3.3.1. 메인 화면.....	13
3.3.2. 업로드 화면.....	14
3.3.3. MRI 시각화 화면	15

4. 연구 결과 분석 및 평가	16
5. 결론 및 향후 연구 방향	21
6. 구성원별 역할 및 개발 일정	22
7. 참고 문헌	25

1. 서론

1.1. 연구 배경

영상의학과 CT와 MRI의 검사량 증가로 인해 데이터 판독에 할애하는 시간이 줄어들고 있다.

“CT의 경우 최근 10년간 급여청구건수는 1.9 배 이상 증가했고, MRI의 경우도 급여확대로 인해 상승 추세가 가파르다.

그러나 실제로 충원되는 전문의는 이에 미치지 못해 현재 MRI, CT 및 초음파 같은 특수 촬영의 경우에도 3분 진료에 아닌 3분 판독이 이뤄지고 있고, 이를 통한 오진의 위험은 환자와 국민에게 전가되고 있는 실정이다.”[1]

임상 워크플로우에 AI를 이식해 환자 진료에 실제로 활용하면 판독 시간을 단축할 수 있음을 보여준 사례도 있다. [2]

MRI는 단면 통해 정적으로 표현되는 반면, 4D cine MRI는 시간에 따른 움직임에 대하여 동적으로 표현된다. 이러한 차이로 인해 영상 분석 및 진단에 할애하는 시간이 더 클 것이라 생각한다.

그래서 우리는 딥 러닝 모델을 활용한 심장 질환 사전 진단을 통해 영상학과 의료관계자들의 진단을 보조하는 서비스를 개발하고자 했다.

1.2. 기존 문제점

기존 MRI 판독 방법은 전문의가 수동으로 각 영역의 윤곽을 그리다 보니 시간이 많이 걸릴 뿐만 아니라 판독자 간 해석의 차이도 발생한다[3][4]. 또한 MRI 특성상 기기의 종류, 찍는 방법, 장소에 따라 얻어지는 데이터의 형태가 다르기 때문에 정형화하기가 어렵다. 따라서 표준화된 완전 자동화 방법이 필요하다 판단했다.

본 주제로 실험을 시작하는 과정에서도 여러 문제점에 직면했다. 일반적으로 의료 데이터에는 쉽게 접근할 수 없다. 때문에 ACDC Dataset처럼 공개된 데이터만 사용 가능하다 보니 적은 양의 데이터로 모델 학습을 진행해야 했다. 또한 데이터의 양은 적었지만, 각 단일 데이터의 크기는 컸기에 로컬에서 모델 학습을 진행하기엔 시간적, 공간적 자원이 부족했다. 이를 극복하고자 적은 데이터로 높은 성능을 낼 수 있는 모델을 만들고, 자원이 풍부한 학과 서버를 통해 학습을 진행했다.

1.3. 연구 목표

우리는 ACDC에서 제공하는 150개의 데이터를 이용해 심장 상태 진단 딥러닝 모델을 개발할 것이다. 이를 위해서는 첫 번째로 딥러닝 모델로 좌심실, 우심실, 좌심실 벽과 그 외 영역을 segmentation해야 한다. 그림 1과 같이 심장 MRI를 short Axis view로 보았을 때 각 영역을 구분해서 볼 수 있기 때문에, short axis로 데이터를 slice한 후 slice별로 segmentation을 해서 분석한다. 또한 시간의 흐름에 따라 심장이 움직이며 영역들의 위치가 변화하기 때문에, 각 frame마다도 segmentation을 진행해야 한다.




그림 1. Cardiac Axis

Segmentation을 성공적으로 마쳤다면, 그 결과에서 박출률, 좌심방 우심방 부피 등 feature를 추출한다. 추출한 feature를 주어진 조건으로 모델을 훈련시켜 5가지 (정상 / 심근경색 / 확장성 심근증 / 비후성 심근병증 / 우심실 경색)의 상태로 classification을 진행한다.

마지막으로 classification까지 마친 학습 모델을 frame 단위로 시각화하여 진단된 상태를 표기할 것이다. 진단 과정에서 사용된 정보를 수치화하여 의사가 활용 가능한 추가적인 정보를 제공할 것이다.

나아가 같은 질병으로 진단한 다른 MRI 데이터를 간편하게 참고할 수 있도록 시스템을 구성하고자 한다. 수치화된 추가적인 정보를 쉽게 활용할 수 있도록 수치를 통한 MRI 검색 기능을 제공할 예정이다.

연구를 진행하여 제작한 segmentation model 과 classification model을 기반으로 제작한 진단 솔루션은 사용자에게 다음과 같은 이점을 제공한다.

- 환자의 병명을 AI model을 통해 1차로 유추함으로써 진단 방향을 제시
- 심장의 좌심실, 우심실, 심벽을 명확하게 표기함으로써 심실의 크기 및 심벽의 두께를 관찰 가능
- AI가 진단한 병명과 같은 병명의 환자들을 나열해 비교 분석이 쉽도록 UI 제공

2. 연구 배경

2.1. 배경지식

4D cine MRI란 기존의 3D MRI에 시간 차원을 추가하여 생체 내부 구조나 기능의 움직임을 시간에 따라 보여주는 영상이다. 그 중 심장 MRI는 심장의 수축과 이완, 혈류의 움직임, 혈관의 팽창 및 수축과 같은 생체 과정을 시각화하여 볼 수 있다. 4D 심장 MRI를 segmentation하면 결과 이미지에서 이러한 특징을 추출할 수 있다. 이를 통해 환자의 상태를 진단할 수 있다.

심장 4D MRI 영상을 총 4개의 영역으로 segmentation을 진행한다. 심장의 좌심실, 우심실, 심벽, 그 외 background로 분리할 것이다. Segmentation의 결과로부터 얻은 특징들을 이용해 환자의 상태를 진단하다 보니 각 영역을 정확하게 분리해야 한다. 이를 위해 입력 이미지를 픽셀 수준에서 분할하고, 각 pixel을 해당하는 객체에 할당해주는 Semantic segmentation을 이용한다. Semantic segmentation의 방식을 사용하면 해당 객체(좌심실, 우심실, 심벽)의 영역과 위치를 보다 정확하게 파악할 수 있다.

좋은 segmentation의 성능을 위해 Fully Convolutional network(FCN)구조 모델을 사용한다. FCN은 기존 CNN를 확장시켜 pixel별 분류를 수행할 수 있도록 설계된 구조이다. 일반적인 CNN 모델에서는 최종 이미지 전체에 대한 클래스를 예측하는 반면, FCN은 입력 이미지의 모든 pixel에 대한 클래스를 예측하므로 사용할 segmentation에 적합한 구조이다. 입력 이미지를 여러 convolution layer를 통해 down-sampling하여 feature를 추출한다. 생성한 feature map의 채널 수는 분리할 객체의 수와 동일하게 변경한 뒤, 다시 up-sampling을 통해 입력 이미지와 같은 크기의 map을 생성한다. 최종적으로 추출한 feature map과 GT의 차이를 이용하여 학습하는 구조이다.

해당 segmentation 진행 과정에서 Regions of interest(ROI)개념을 사용한다. ROI는 말 그대로 관심있는 영역을 찾는 것이다. 특정 영역을 선택하여 처리 혹은 분석을 수행할 때 유용하고, 수행 시 불필요한 정부를 무시할 수 있기 때문에, 들어가는 계산 및 처리 자원을 절약할 수 있다. 그림 2처럼 총 4개의 ROI를 찾고 bounding box 내의 영역을 처리한다. 심장 MRI에서도 ROI(좌심실, 우심실, 심벽)를 설정하여 불필요한 background를 무시하고 진행한다면 효율적으로 이미지 처리를 할 수 있다.




그림 2. ROI 예시 이미지와 환자 101번 심장 이미지 ROI

2.2. 데이터 분석

모델 학습에 있어 사용될 데이터는 ACDC Dataset이다. 해당 데이터는 2017년에 진행된 ACDC Challenge에서 제공한 데이터이며, train data 100개와 test data 50개로 총 150개이다. 데이터의 크기는 $216 \times 256 \times 10 \times 30$ 으로 3D 심장 이미지를 30 frame으로 시간의 흐름에 따라 변화하는 모습을 보여준다. Data format은 다차원 의료 영상 데이터를 지원하는 nifti 파일로 제공된다. 추가적으로 환자의 정보를 담고 있는 텍스트 파일 또한 포함되어 있다. 환자 심장의 최대 이완/최대 수축 시의 frame, 전체 frame 수, 환자의 키, 몸무게, 환자의 상태를 5가지 class로 분류한 정보가 작성되어 있다. 해당 정보와 segmentation을 통해 얻은 이미지의 특징을 이용하여 환자의 상태를 진단하는 classifier 모델을 구축할 수 있다.

Segmentation Classes	Classification Classes
LV(Left Ventricle): 좌심실	NOR(Normal): 정상
RV(Right Ventricle): 우심실	MINF(Myocardial Infarction): 심근경색
MYO(Myocardium): 좌심실 외막	DCM(Dilated Cardiomyopathy): 확장성 심근증
BG(Background): 그 외 모든 영역	HCM(Hypertrophic Cardiomyopathy): 비후성 심근병증
	ARV(Abnormal Right Ventricle): 우심실 이상

표 1. 용어 정리

2.3. 서버 구성

환자의 MRI와 AI model을 통해 도출해낸 예측 결과를 한눈에 보기 쉽도록 웹 사이트의 형식으로 시각화하였다.

시각화 웹 사이트의 프로젝트 구조는 다음과 같다.




그림 3. 웹 사이트 구조

-
- React JS를 사용하여 Frontend를 구성하였으며, niivue 패키지를 사용하여 4D Cardiac MRI Viewer를 제작
 - Spring을 사용하여 Web Server를 제작
 - TensorFlow를 사용하여 Segmentation 모델을 불러온 후 MRI로부터 LV, RV, MYO에 대한 Segmentation 결과와 각 부분의 nifti 일을 생성
 - scikit-learn을 사용하여 Classification 모델을 불러온 후 Segmentation 결과 데이터를 기반으로 병명을 유추함
 - MariaDB를 통해 LV, RV, MYO에 대한 Segmentation 결과와 Classification 결과인 병명을 저장 및 검색

3. 연구 내용

3.1. Segmentation 모델

3.1.1. 데이터 전처리

모든 입력 이미지의 크기를 256x256으로 설정한다. 그 후 ROI를 심장과 주변 구조만 포함하게 설정하여 자릅니다. 해당 ROI를 최소화하여 설정하기 위해 원형 허프 변환(Circular Hough Transform)과 푸리에 해석(Fourier Analysis)을 사용했다. 원형 허프 변환은 이미지에서 원형 패턴을 검출하는데 유용하다. 푸리에 해석 또한 주기성 패턴을 감지하는 데에 유용하다. 아래의 심장 MRI 이미지를 확인해보면 우리가 segmentation을 진행할 부분은 중앙의 원형 패턴임을 확인할 수 있다. 해당 방법을 통해 MRI에서 원하는 영역만 최소화하여 감지할 수 있다.




그림 4. 원형 허프 변환과 푸리에 해석을 통한 ROI 최소화

3.1.2. 모델 구조

이미지 segmentation model의 아키텍처를 설계하기 위해 여러 모델을 비교하는 과정이 있었다. 비교를 위해 학습시킨 모델은 Transformer를 사용한 모델, U-net 기반 모델, FCN 기반 모델이다. 그 중 학습에 소요되는 시간이 적고 성능이 좋은 deep fully convolution network(FCN)기반 아키텍처를 선택했다.

FCN은 semantic segmentation에 좋은 성능을 보이는 반면, 문제점이 존재한다. Feature map을 기존 skip 연결 방법으로 up-sampling을 하게 되면 결과물이 세밀하게 나오지 않는다. 따라서 up-sampling 경로에서 기존 skip 연결에 비해 계산과 메모리 효율이 높으며 feature map explosion을 해결할 수 있는 long skip과 short-cut connection 방법을 도

입했다.

기존의 FCN 기반 구조는 의료 이미지 segmentation에 좋은 성능을 보여 왔으나, 파라미터 수가 많아 구조가 복잡하며 적은 데이터로 훈련 시 일반화하기 어렵다는 문제가 있었다. 이를 극복하기 위해 좋은 성능을 보이는 FCN 구조는 유지하면서 DenseNet구조를 도입하는 [5]의 논문을 참고해 모델 아키텍처를 결정했다. DenseNet은 feature 재사용을 하여 성능을 저하시키지 않으며 파라미터 수를 줄여주므로 훈련 데이터가 적은 현 상황에 알맞다고 판단했다. 또한 여러 scale과 시점의 input 이미지에 대해 병렬로 convolution을 수행함으로써 메모리 효율성을 높였다.

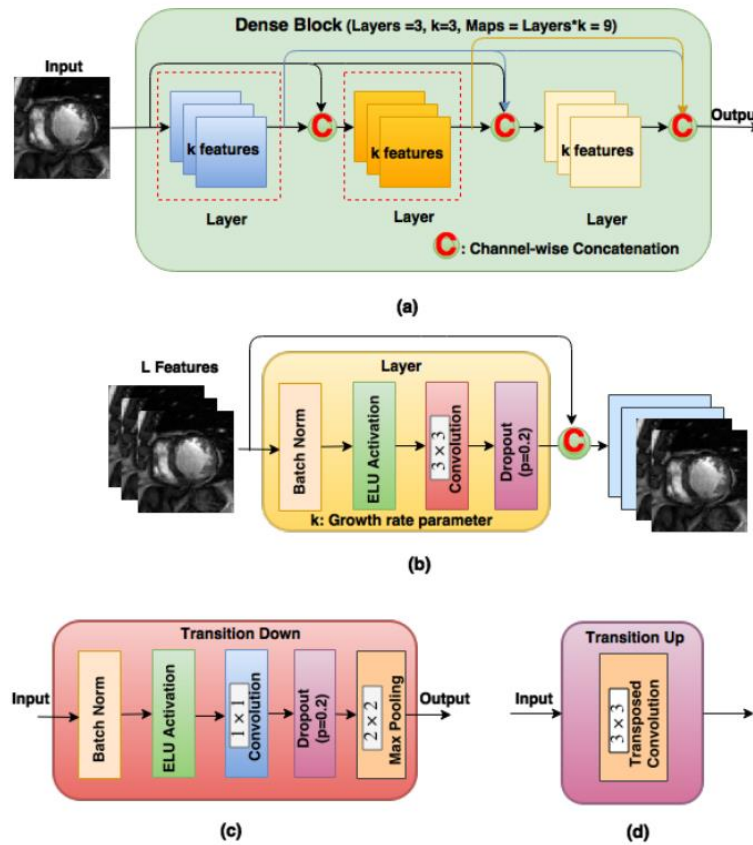


그림 5. 참고한 논문의 구조도

Optimization을 위해서는 이미지 segmentation에 자주 사용되는 dice loss와 voxel 단위 오차를 측정할 수 있는 cross-entropy loss에 각각 가중치를 주고 결합해서 사용했다.

3.1.3. Segmentation 오버레이 마스크

원본 이미지와 segmentation 결과를 합쳐서 볼 수 있도록, 그리고 데이터 후처리를 위해 binary mask를 생성할 수 있도록 segmentation 결과에 대한 overlay mask를 만들어야 했다. 여러 모델 분석을 통해 masking에 유용하게 사용되는 segmentation-overlay-mask 라이브러리를 찾을 수 있었다. 해당 라이브러리의 함수들을 사용하여 masking을 진행하려 하였으나 해당 함수는 2D & 3D Data에 대한 masking만 이루어지기 때문에 nifti 파일을 바로 사용할 수 없었다.

이를 해결하기 위해 각 원본과 segmentation 결과 4D 데이터를 frame별로 slicing하고, 다시 depth별로 slicing하여 여러개의 2D 데이터로 분리했다. 그 후 match하는 두 2D 데이터 masking했다. masking한 output은 png파일로 저장한 후 numpy로 변환하여 하나씩 배열을 쌓았다. 마지막으로 원본 데이터와 같은 크기로 합하여 nifti 파일을 생성할 수 있었다.




그림 6. 101번 환자 데이터의 segmentation masking 결과

코드에서는 class별로 직접 색상을 입혀 masking한 결과를 명확하게 보여줄 수 있지만, nifti 파일로 변환하면 그림 6에서와 같이 흑백으로 표현되었다. 우리가 원하는 것은 segmentation한 결과를 컬러 이미지로 뚜렷하게 분리된 모습이기 때문에 class별로 nifti 파일을 분리해서 각각 다른 색으로 나타냈다.

3.1.4. 데이터 후처리

학습을 시키며 결과 이미지를 랜덤으로 출력해보았을 때 false negative 결과보다 false positive 결과가 더 눈에 띄었고 이 부분이 문제가 될 수 있다고 판단했다. 따라서 false negative 부분과 outlier를 제거하기 위해 데이터 후처리를 진행했다.

False positive를 줄이기 위해서는 segmentation mask에서 연결 되어있는 한 덩어리인 component가 ground truth 이미지와 겹치는 부분이 50%보다 낮으면 제거했다.

Outlier를 없애기 위해서는 각 component가 50 voxel보다 작으면 제거했다. 그리고 남아 있는 component들 사이 구멍을 scipy 라이브러리의 morphology연산 중 binary_fill_holes 함수를 사용해서 메꿨다.

3.2. Classification 모델

3.2.1. Feature extraction

Segmentation을 통해 얻은 결과 이미지에서 필요한 특징들을 추출한다. ACDC Challenge 에서 제시된 기준으로 환자의 상태를 진단한다. 추출할 특징들은 아래와 같다.

- 1) 좌심실, 우심실 부피
- 2) 박출률
- 3) 심벽의 질량
- 4) 신체 표면적(BSA)
- 5) 심벽의 두께

각 영역별 부피를 구하기 위해서는 먼저, segmentation된 image로부터 같은 class로 labeling된 voxel의 개수를 구해야한다. 구한 개수에 해당 nifti 파일의 메타데이터인 voxel의 크기를 곱하여 최종 부피를 측정한다. 이에 대한 수식은 다음과 같다.

$$volume = voxel\ num \times voxel\ size$$

박출률의 계산 방법은 심장 최대 이완시의 부피에서 최소 이완시의 부피를 뺀 값을 구하고, 해당 값에 최대 이완시의 부피를 나누어 구한다.

$$EF = \frac{(ed\ volume - es\ volume)}{ed\ volume}$$

심벽의 질량은 부피에 1.05를 곱하여 계산한다.

$$MYO\ mass = MYO\ volume \times 1.05$$

BSA는 환자의 정보가 들어있는 Info.cfg 파일에서 키와 몸무게를 확인한다. 계산법은 키와 몸무게를 곱한 후, 3600을 나눈 값의 제곱근이다.

$$BSA = \frac{height \times weight}{3600}$$

심벽의 두께는 ED와 ES frame에서 심장의 각 단축 슬라이스에 대해 측정하는데, 심근의 내부 윤곽의 pixel에서 외부 윤곽 pixel까지의 최단 유클리드 거리 측정을 통해 측정한다.




그림 7. Feature Importances of Random Forest Classifier

3.2.2. 모델 구조

추출된 feature들로 classification을 진행했다. 이 때, 여러가지 classification 모델들로 앙상블 기법을 사용했다. 앙상블 기법으로는 soft voting classifier를 사용했다. 사용된 classifier들은 아래와 같다.

- 1) Random forest
- 2) XGB(Extreme Gradient Boosting)
- 3) MLP(Multi Layer Perceptron)
- 4) LR(Logistic Regression)
- 5) GNB(Gaussian Naive Bayes)
- 6) SVM(Support Vector Machine)
- 7) KNN(K-nearest neighbor)

모델을 심플하게 만들기 위해서 성능을 확인한 후 classifier 모델들 중 일부를 선택하여 ensemble classification을 진행했다. 위 classifier중 최종적으로 MLP, GNB, SVM, RF이 선정되어 soft voting에 사용되었다.

3.3. 시각화

3.3.1. 메인 화면




그림 8. 메인 화면의 UI

화면의 기능

- 환자번호 및 예측한 질병명을 통해 해당 환자의 MRI 데이터를 검색
- LV 및 RV의 크기, LV 및 RV의 박출률, MYO의 두께를 기준으로 검색
- 환자의 MRI 및 키, 체중의 정보가 있는 zip 파일을 업로드 하여 분석




그림 9. 검색기능을 사용하여 조건에 해당하는 환자를 나열

3.3.2. 업로드 화면




그림 10. 업로드 화면 UI

화면의 기능

- 메인 화면에서 zip 파일을 업로드 한 경우 나타나는 화면
- 현재 진행 단계인 Uploading, Segmentation, Feature extraction, Classification을 표시

3.3.3. MRI 시각화 화면




그림 11. MRI 시각화 화면 UI

화면의 기능




그림 12. MRI 시각화 화면 세분화

- 환자의 키 체중 정보를 표기
- AI Model 을 통해 도출해낸 심장의 segmentation을 ON / OFF
- 4D cardiac MRI의 frame을 변경하여, 심장의 수축, 이완을 확인하는 기능




그림 13. 1Segmentation 기능을 켜 이후 UI

- Segmentation 기능을 켜 후 RV, LV, MYO의 투명도 조절이 가능




그림 14. 두 환자의 Classification Info UI

- Classification AI가 진단한 진단명과 진단 사유에 대해 기술
- 진단 기준에 비해 괜찮은 수치인 경우 초록색, 진단 기준을 초과한 경우 붉은 색으로 표기

4. 연구 결과 분석 및 평가

Segmentation 모델을 만들 때 여러 구조를 가진 모델을 만들어 비교하고 분석했다. 먼저 Rahman and Marculescu (2023)[6]을 참고해 Transformer와 Attention decoding을 사용한 MERIT 모델의 성능을 확인했다. 또한 Baumgartner et al. (2017)[7]의 논문을 참고해 2D

U-Net을 변형한 모델을 돌려보았다. 그리고 Khened et al. (2019)[5]를 참고해서 DenseNet 구조를 사용한 FCN 변형 모델의 성능을 확인했다. 전체 데이터로 학습한 모델들의 최종 성능은 표 2와 같다.

Model	Avg Dice Score	RV	LV	MYO
MERIT	0.854	0.865	0.911	0.787
Modified 2D U-Net	0.911	0.892	0.948	0.893
FC DenseNet	0.882	0.864	0.918	0.864

표 2. 모델 최종 결과

Segmentation에 대하여 2D U-net 기반 모델의 성능이 제일 높게 나왔으나, 학과 서버에서 학습을 진행한 터라 학과 서버가 닫혔을 때 모델을 가져올 수 없었다. 또한 U-net은 instance segmentation를 사용해 비교적 학습 시간이 오래 걸려서 다시 학습시키기에 시간이 부족했다.

각 class에 한 instance만 존재하기 때문에 여러 instance를 구분하는 instance segmentation가 굳이 필요하지 않았다. 때문에 instance segmentation을 사용하는 U-Net이 아닌 계산 비용이 덜 들어가고 가벼운 semantic segmentation을 사용하는 다른 아키텍처가 더 알맞다고 판단했다. 따라서 두번째로 성능이 우수하고 학습시간 또한 가장 적게 들어 모델을 개선하기 용이한 FC DenseNet을 선택했다.

총 250 epoch를 돌렸고, 학습할수록 loss 값이 줄어드는 것을 확인할 수 있다. 학습 결과 그래프는 TensorBoard를 활용하여 나타내었다.




그림 15. 학습 TensorBoard 결과인 Total loss와 평균 Dice score 그래프. 붉은 선은 train시 log를, 푸른 선은 validation시 log를 의미한다.

그림 15에서 epoch의 증가에 따라 모든 그래프가 수렴함을 볼 수 있었으므로 충분한 epoch를 돌렸다고 판단할 수 있었다.

그림 16과 그림 17에서 육안으로 gt와 prediction을 비교해 보았을 때도 만족할 만한 결과가 나왔다.





그림 16. Case 1의 segmentation 결과



Input Image

GT

Prediction

그림 17. Case 2의 segmentation 결과

Classification 모델의 학습 결과는 Decision tree로 확인했다.




그림 18. classification 모델의 Decision tree. 랜덤으로 샘플링 한 70개 data의 분류 결과이다. 기준 $\text{stdev}(\text{mean}(\text{MWT}[\text{SA}]|\text{LA}))$ 는 Myocardial Wall Thickness(MWT)를 각 Short-Axis(SA) slice 에 대해 평균 낸 값의 Long-Axis(LA) 방향에 대한 표준 편차를 구한 것.

각 클래스 당 14개의 데이터를 랜덤으로 샘플링 했다. 그림 17의 각 노드에 표시된 value 리스트의 각 자리는 순서대로 NOR, MINF, DCM, HCM, RV 클래스의 데이터를 뜻한다. DCM 환자 한 명이 MINF로 분류된 것을 제외한 모든 환자의 데이터가 정상적으로 분류되었다.

ACDC 챌린지 전체에 대한 논문[8]에서 명시한 의학적 진단 기준은 아래 표 3과 같다.

Class	LV 박출률	LV 부피 (ED)	RV 박출률	RV 부피 (ED)	MYO 두께 (ED)
NOR	EF(LV) > 50%	남자 < 90mL/m ² 여자 < 80mL/m ²	EF(RV) > 40%	RV 부피(ED) < 100mL/m ²	MWT(ED) < 12mm
MINF	EF(LV) < 40%	(일부의 경우) 남자 > 90mL/m ² 여자 > 80mL/m ²			
DCM	EF(LV) < 40%	LV 부피(ED) > 100mL/m ²		(일부의 경우) RV 부피(ED) > 100mL/m ²	MWT(ED) < 12mm
HCM	EF(LV) > 50%				MWT(ED) > 15mm
ARV	EF(LV) > 50%	남자 < 90mL/m ² 여자 < 80mL/m ²	EF(RV) < 40%	남자 > 110mL/m ² 여자 > 100mL/m ²	

표 3. 각 클래스에 대한 의학적 진단 기준

의학적 진단 기준은 대부분 ED phase를 기준으로 판단하며, MYO의 최대 두께를 기준으로 판단한다. 반면 추출한 feature와 채택된 모델의 splitting point를 보면 ES phase와 ED phase일 때의 feature들을 모두 사용하고 있었으며, MYO 두께의 표준편차와 같이 더 다

양한 세부 요소들을 사용함을 볼 수 있었다.

또한 LV의 박출률(EF)의 정상 수치는 50% 이상인데, 그림 17의 좌측 하단에 splitting point가 $EF(LV) \leq 0.499$ 충족 기준으로 나뉘는 것을 보아 일부 진단 기준이 일치함을 확인할 수 있었다.

Classification까지 완료한 진단 결과는 test data 50개에 대해 92%의 정확도를 기록했다. 모델 정확도로는 만족할 만한 결과를 얻었다. 92%는 의료진의 진단을 보조 해주기에는 충분한 수치다.




그림 19. test data 진단 결과에 대한 confusion matrix

5. 결론 및 향후 연구 방향

먼저 segmentation모델의 성능은 88.2%로 마무리되었다. 적은 데이터셋이었음에도 불구하고 꽤나 높은 정확도를 보였다. 학습을 진행한 frame들의 형태와 패턴이 유사한 이미지에선 높은 정확도를 보였으나, 종종 MRI를 찍는 각도에 의해 형태를 지나치게 벗어나는 특정 frame들이 정확도를 떨어뜨렸다. 허나 중요한 ED, ES frame에서 좋은 성능을 보인 덕분에 classification에서도 좋은 결과를 얻을 수 있었으므로 만족스러운 결과였다. 다

음 목표인 classification 모델의 성능은 92%로 마무리되었다.

본 과제에선 많지 않은 시간과 데이터로부터 성능을 내다보니, 보다 높은 성능을 내기엔 한계가 있었다. 추후 더 개선된 구조와 많은 데이터들을 통해 학습시킨다면, 더욱 일반화 되고 좋은 성능을 내는 모델을 생성해낼 수 있을 것이다. 나아가 최종적으로 MRI 이미지가 사람의 손을 거치지 않고, 학습 모델을 통해 환자의 상태와 병명을 진단할 수 있는 완전 자동화 시스템이 구축될 수 있을 것으로 기대된다.

Segmentation 및 classification 모델을 사용하여 제작한 진단 자동화 솔루션은 파일 업로드 이후, 병명을 유추해내기까지 약 1분 30초 소요된다. 전문의는 4D cine MRI 특성상 하나의 3D 모델이 아닌 여러 Frame의 3D model을 보고 판단 해야한다. 본 연구를 통해 제작한 솔루션을 발전시켜 AI model의 정확도 및 범용성을 높인다면, 목표로 지향하는 완전 자동화에 다다르지 않더라도, 전문의가 진단을 내리는 방향성을 제시하는 역할을 수행할 것이다. 이를 통해 MRI를 판단하는 시간 단축 및 진료의 정확성 상승을 기대할 수 있다.

6. 구성원별 역할 및 개발 일정

이름	역할
양준석	- 시각화
이수빈	- Fully Convolutional Transformer - Modified 2D U-Net
박현수	- Multi-scale hierarchical vision transformer - FC Multi-scale Residual DenseNets
공통	- 정보 수집 및 논문 분석 - 보고서 작성

표 4. 구성원별 역할

5월		6월				7월				8월				9월			
3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
선행 연구 분석 및 착수 보고서 작성																	
		자료수집 및 논문 분석															
						모델 보완 및 개선, 중간보고서 작성											
										데이터 분석 보충 여부 및 기능 점검							
														최종 보고서 작성 및 발표 준비			

표 5. 딥 러닝 모델 개발 일정

5월		6월				7월				8월				9월			
3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
서버 구축 및 데이터 베이스 설정																	
		심장 MRI 뷰어 연동															
						Segmentation 및 classification 모델 학습											
										학습된 모델을 서버에 적용							
														UI 구성			
														최종테스트			

표 6. Visualizing 일정

7. 참고 문헌

- [1] 조운, “검사량 폭증에 영상의학과 '번아웃' 심각...”의사 1인당 한달 평균 936건 판독해야”, medigatenews, 2023.06.23, Available: <https://medigatenews.com/news/2623890477> (downloaded 2023, Oct. 11)
- [2] 이인복, ““진단 보조 AI 실제 효과 있었다” 판독 시간 대폭 감소”, medcaltimes, 2022.06.15, Available: <https://www.medcaltimes.com/Main/News/NewsView.html?ID=1147887> (downloaded 2023, Oct. 11)
- [3] V. Tavakoli, and A. Amini, “A survey of shaped-based registration and segmentation techniques for cardiac images,” *Journal of Computer Vision and Image Understanding*, Vol. 117, No. 9, pp. 966-989, Sep. 2013.
- [4] A. Suinesiaputra, B. R. Cowan, A. O. Al-Agamy, M. A. Elattar, N. Ayache, A. S. Fahmy, A. M. Khalifa, P. M. Gracia, M. P. Jolly, A. H. Kadish, D. C. Lee, J. Margeta, S. K. Warfield, and A. A. Young, “A collaborative resource to build consensus for automated left ventricular segmentation of cardiac MR images,” *Journal of Medical Image Analysis*, Vol. 18, No. 1, pp. 50-62, Jan. 2014.
- [5] M. Khened, V. A. Kollerathu, and G. Krishnamurthi, “Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers,” *Journal of Medical Image Analysis*, Vol. 51, pp. 21-45, Jan. 2019.
- [6] M. M. Rahman, R. Marculescu, “Multi-scale Hierarchical Vision Transformer with Cascaded Attention Decoding for Medical Image Segmentation,” *Proc. of the IEEE/CVF Winter Conference on Applications of Computer Vision 2023*, pp. 6211-6220, 2023.
- [7] C. F. Baumgartner, L. M. Koch, M. Pollefeys, E. Konukoglu, “An Exploration of 2D and 3D Deep Learning Techniques for Cardiac MR Image Segmentation,” *Proc. of the STACOM 2017*, pp. 111-119, 2018.
- [8] O. Bernard, A. Lalande, C. Zotti, F. Cervenansky, X. Yang, P. -A. Heng, I. Cetin, K. Lekadir, O. Camara, M. A. Gonzalez Ballester, G. Sanroma, S. Napel, S. Petersen, G. Tziritas, E. Grinias, M. Khened, V. A. Kollerathu, G. Krishnamurthi, M. -M. Rohé, X. Pennec, M. Sermesant, F. Isensee, P. Jäger, K. H. Maier-Hein, P. M. Full, I. Wolf, S. Engelhardt, C. F. Baumgartner, L. M. Koch, J. M. Wolterink, I. Išgum, Y. Jang, Y. Hong, J. Patravali, S. Jain, O. Humbert, and P. -M. Jodoin, “Deep Learning Techniques for Automatic MRI Cardiac Multi-Structures Segmentation and Diagnosis: Is the Problem Solved?,” *Journal of IEEE Transactions on Medical Imaging*, Vol. 37, No. 11, pp. 2514-2525, Nov. 2018.