

근감소증 진단을 위한 영상분할 모델 개발 및 적용

노시형¹, 유영주¹, 임동욱¹, 김지언¹, 이충섭¹, 윤권하^{1,2}, 정창원^{1,3}

¹원광대학교 의료융합연구센터

²원광대학교 병원 영상의학과

³원광대학교 병원 스마트사업팀

e-mail : nosij123@wku.ac.kr, yeriel.ryu@gmail.com {medikim3551, cslee99, khy1646, mediblue}@wku.ac.kr

Development of Image Segmentation Model for Sarcopenia Diagnosis and Its application

Si-Hyeong Noh¹, Yeongju Yu¹, Dongwook Lim¹, Ji-Eon Kim¹,
Chungsub Lee¹, Kwon-Ha Yoon^{1,2}, Chang-Won Jeong^{1,3}

¹Medical Convergence Research Center, Wonkwang University

²Department of Radiology, Wonkwang University School of Medicine and Hospital

³Smart Business Team, Wonkwang University Hospital

요 약

의료영상기반의 인공지능 연구는 질환의 조기진단 및 예측 분야에 눈부신 기술발전이 되어왔다. 근감소증 질환은 다양한 기저질환을 기반으로 발생하며, 특히 60대 이상은 30%의 유병율을 갖는다. 해당 질환은 임상적인 진단 방법의 발달과 임상 결과가 알려지면서 관심이 증가하고 있다. 최근 근감소증 진단방법 중의 하나로 CT 또는 MR 의료영상을 통한 진단방법이 제시되었다. 본 논문에서는 인공지능을 기반으로 하여, 근감소증을 진단하기 위해 척추부위 중 Lumbar 3 영역의 근육, 지방 영역의 영상분할 모델을 제시하고자 한다. 이를 위해 인공지능 영상분할 모델을 개발하는 과정과 그 근육과 지방의 영상분할 결과를 보인다. 본 논문에서 제시한 영상분할모델을 통해 근감소증을 빠르게 진단할 수 있을 것으로 기대한다.

1. 서론

근감소증은 근육량과 그 기능의 손실을 포함하는 골격근 장애를 나타낸다. 근감소증은 노인의 12.9~40.4%에서 나타나며, 특히 비만과 근 기능저하와 낙상, 삶의 질 손상 및 사망까지 다양한 영향을 미치고 있다[1]. 근감소증의 정의는 다양한 작업 그룹에 의해 제안되었으며 근육량, 근력 및 신체 수행능력 조합을 포함하며 컷오프 포인트 및 진단 알고리즘이 다양하게 제시되고 있다. 그 중 CT와 MRI는 현대 의학에서 널리 사용되는 영상기법이며, 신체의 근육과 지방량을 정량화하는 표준으로 간주된다[2]. 근감소증 진단에는 다양한 요소가 필요한데, 그중 척추 부위 중 Lumbar 3 영역에서 촬영된 CT 영상의 체성분 분석을 통해 전신 근육과 지방량을 측정할 수 있으며, 이 방법은 근감소증을 평가하는데 널리 사용된다[3-5].

본 논문에서는 근감소증을 진단하기 위한 인공지

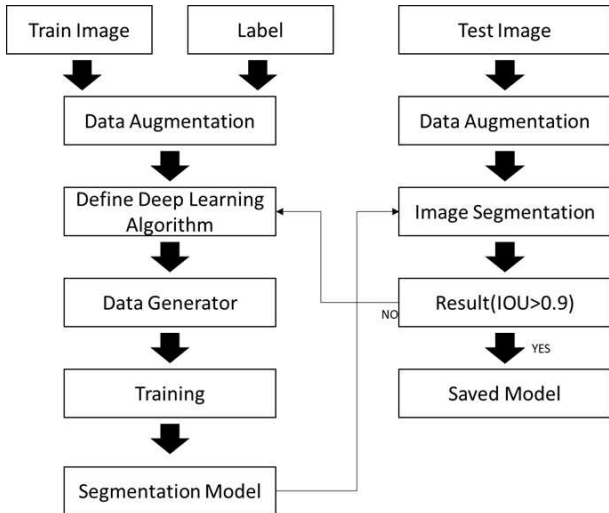
능 분할모델을 개발하는 과정과 그 결과를 통해 생성된 모델을 이용한 영상분할 결과를 보인다. 본 논문의 모델을 통해 복부의 근육량과 지방량을 빠르게 측정하고 그 값을 통해 근감소증을 진단할 수 있을 것으로 기대한다.

2. 근감소증 인공지능 모델 개발

그림 1은 근감소증 인공지능 모델 개발을 위한 개발 프로세스를 나타낸다.

DICOM으로 구성된 Train Data를 Augmentation을 통해 확장하고, 분할을 위한 Deep Learning 알고리즘을 정의한다. 그 다음 Data Generator를 거쳐 Training 후 영상분할 모델을 완성한다. Test Image 역시 데이터를 확장한 후 생성된 모델을 통해 분할을 수행하여 그 결과를 판단하기 위한 IOU의 값이 0.9를 넘는 모델이 생성될때 까지 알고리즘 정의부위의 과정을 반복한다. 원하는 조건 값을 넘어가는

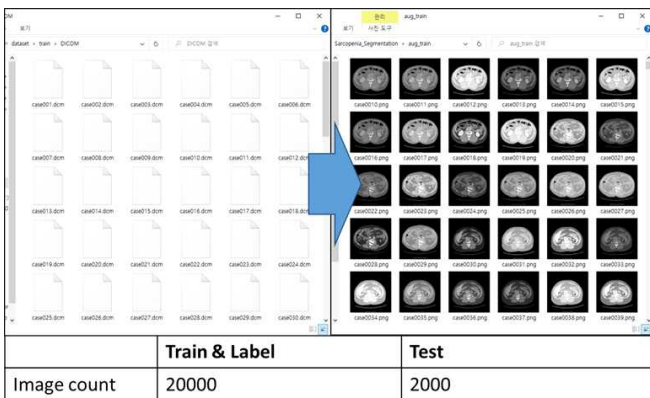
모델이 생성되면 저장한다.



(그림 1) 근감소증 인공지능 모델 개발 프로세스

2.1 데이터 구성

근감소증 진단을 위한 인공지능 모델 개발을 위한 데이터셋의 구성은 그림2와 같다.




(그림 2) 근감소증 인공지능 모델 개발을 위한 데이터셋

먼저 100장의 L3영역의 DICOM을 Windows 값을 Window Level는 -250 ~ 250사이의 랜덤 값, Window Width는 400 ~ 1200 사이의 랜덤 값을 통해 Augmentation하여 20,000장의 데이터셋을 구성하였다. Augmentation을 하는 이유는 복부영상 중 L3영역이라는 한정적인 영역에서 얻어지는 영상만으로는 학습된 결과에 대한 신뢰도에 문제가 있다고 볼 수 있기 때문에 학습에 필요한 데이터를 늘리기 위한 것이다. Window Width란 흑백의 여러 단계인 gray scale로 표현할 수 있는 CT Number들의 범위이므로,작을수록 표시되는 CT No.의 폭이 좁고 클수록 넓어진다. Window Level은 Gray scale의 중앙값으로 농도의 범위를 나타내는데, 낮추면 흡수치가 적은물질(공기)를 잘 나타낼 수 있고, 높일수록 흡수

치가 큰 물질(뼈)를 잘 나타낼 수 있다. 학습용 데이터는 Train, Validation을 각각 18,000장 2,000장으로 구성하고 학습을 진행하였다.

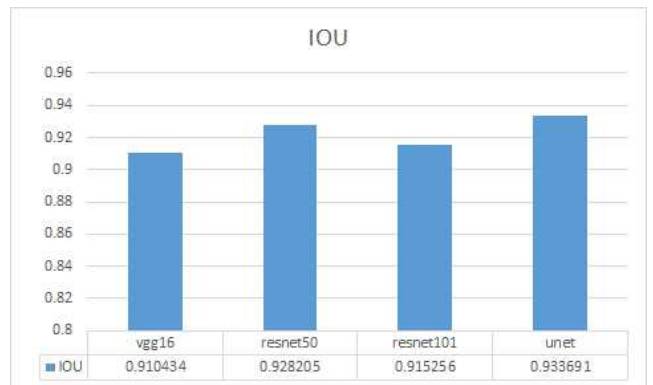
2.2 Deep Learning Model

근감소증 인공지능을 위한 모델은 그림 3와 같다.



(그림 3) 근감소증 인공지능 모델

모델은 영상분할 모델 중 U-Net을 기반으로 하여 만든 모델을 사용하였는데, 모델의 개선을 위하여 Incoder 부분을 Resnet50, Resnet101, Vgg16등을 Augmentation으로 만들어진 동일한 데이터셋을 이용하여 그 성능을 정답과 결과를 비교하여 그 정확도를 비교해 주는 IOU(Intersection over Union)값을 통해 비교한 결과, 그림 4와같이 기본적인 U-Net이 가장 높은 성능을 보여 변화되지 않은 U-Net을 사용한 모델을 만들었다.



(그림 4) 모델 성능평가


학습에 사용된 Loss Function은 Weighted Bce Loss와 Weight Dice loss를 통합한 Weighted Bce Dice Loss를 사용하였다.

2.3 Deep Learning Result

그림 5는 근감소증 영상분할모델을 통해 수행된 영역별 결과를 보인다.

영상분할을 수행하게 되면 피하지방, 내장지방, 근

육의 이미지가 각각 생성되고, 세 영상을 합친 이미지와 DICOM 이미지에 마스킹 이미지를 합친 이미지까지 5개의 영상이 만들어진다. 마스킹 이미지는 학습용 데이터셋으로 분할 모델 개발에 활용된다. 특히, 분할된 이미지를 통해 측정된 근육량은 임상적 진단으로 SMA(Skeletal Muscle Area)/Height² 또는 SMA/Weight 그리고 SMA/BMI으로 근감소증을 진단 또는 예측할 수 있다. 기존 한국표준진단지표로 제시한 cut-off 값의 정량 평가할 계획이다.



(그림 5) 피하지방(a), 근육(b), 내장지방(c), 체성분 분류 이미지(d), DICOM Segmentation Image(e)

3. 결론 및 향후 연구

본 논문에서는 근감소증을 진단하기 위한 인공지능 영상분할 모델을 개발하는 과정과 그 결과를 보였다. 논문의 모델을 통해 근감소증 진단을 위한 체성분 데이터를 손쉽게 획득할 수 있을 것으로 기대한다. 향후 연구로는 해당 모델을 적용한 서비스를 통해 성능을 평가하고 정확도를 높이기 위한 연구를 진행할 계획이다. 그리고 다기관 연구로 국내 지역별 한국인 영상코호트를 수집하여 평가할 계획이다.

Acknowledgement

본 연구는 보건복지부의 재원으로 한국보건산업진흥원의 보건의료기술 연구개발사업(HI18C1216) 그리고 과학정보통신부의 재원으로 한국연구재단(2021R1A5A8029876)(2020R111A1A01074256) 지원에 의하여 이루어진 것임.

참고문헌

- [1] A.J. Cruz-Jentoft, A.A. Sayer, "Sarcopenia", *Lancet*, 393 (2019), pp. 2636-2646
- [2] N. Mitsiopoulos, R.N. Baumgartner, S.B. Heymsfield, W. Lyons, D. Gallagher, R. Ross, "Cadaver validation of skeletal muscle measurement by magnetic resonance imaging and computerized tomography", *J Appl Physiol*, 1998 (85) (1985), pp. 115-122
- [3] Yoon Seong Lee, Namki Hong, Joseph Nathanael Witanto, Ye Ra Choi, Junghoan Park, Pierre Decazes, Florian Eude, Chang Oh Kim, Hyeon Chang Kim, Jin Mo Goo, Yumie Rhee, Soon Ho Yoon, "Deep neural network for automatic volumetric segmentation of whole-body CT images for body composition assessment", *Clinical Nutrition*, Volume 40, Issue 8, 2021, Pages 5038-5046, ISSN 0261-5614
- [4] David Zopfs, Khaled Bousabarah, Simon Lennartz, Daniel Pinto dos Santos, Max Schlaak, Sebastian Theurich, Robert Peter Reimer, David Maintz, Stefan Haneder, Nils Große Hokamp, "Evaluating body composition by combining quantitative spectral detector computed tomography and deep learning-based image segmentation", *European Journal of Radiology*, Volume 130, 2020, 109153, ISSN 0720-048X
- [5] Kim, J, Han, SH, Kim, H-I. "Detection of sarcopenic obesity and prediction of long-term survival in patients with gastric cancer using preoperative computed tomography and machine learning". *J Surg Oncol*. 2021; 1- 9. <https://doi.org/10.1002/jso.26668>