

Development of Cloud-Based Medical Image Labeling System and It's Quantitative Analysis of Sarcopenia

Lee Chung-Sub[†] · Lim Dong-Wook^{††} · Kim Ji-Eon^{†††} · Noh Si-Hyeong^{†††} · Yu Yeong-Ju^{††††} ·
Kim Tae-Hoon^{†††††} · Yoon Kwon-Ha^{†††††} · Jeong Chang-Won^{††††††}

ABSTRACT

Most of the recent AI researches has focused on developing AI models. However, recently, artificial intelligence research has gradually changed from model-centric to data-centric, and the importance of learning data is getting a lot of attention based on this trend. However, it takes a lot of time and effort because the preparation of learning data takes up a significant part of the entire process, and the generation of labeling data also differs depending on the purpose of development. Therefore, it is need to develop a tool with various labeling functions to solve the existing unmetneeds. In this paper, we describe a labeling system for creating precise and fast labeling data of medical images. To implement this, a semi-automatic method using Back Projection, Grabcut techniques and an automatic method predicted through a machine learning model were implemented. We not only showed the advantage of running time for the generation of labeling data of the proposed system, but also showed superiority through comparative evaluation of accuracy. In addition, by analyzing the image data set of about 1,000 patients, meaningful diagnostic indexes were presented for men and women in the diagnosis of sarcopenia.

Keywords : Artificial Intelligence, Medical Image, DICOM, CT, Labeling Data, Sarcopenia

클라우드기반 의료영상 라벨링 시스템 개발 및 근감소증 정량 분석

이 충 섭[†] · 임 동 옥^{††} · 김 지 언^{†††} · 노 시 형^{†††} · 유 영 주^{††††} ·
김 태 훈^{†††††} · 윤 권 하^{†††††} · 정 창 원^{††††††}

요 약

최근 대부분의 인공지능 연구는 AI 모델 개발에 중점을 두고 있다. 하지만 최근 인공지능 연구가 모델 중심에서 데이터 중심으로 점차 변경되고 이런 추세를 바탕으로 학습데이터의 중요성이 크게 주목 받고 있다. 그러나 학습데이터의 준비과정이 전체 과정의 상당 부분을 차지하고 라벨링 데이터 생성 또한 개발 목적에 따라 다르기 때문에 많은 시간과 노력이 필요하다. 따라서 기존의 미충족을 해결하기 위한 다양한 라벨링 기능을 갖는 도구 개발이 필요하다. 본 논문에서는 의료영상의 라벨링 데이터를 정교하고 빠르게 생성하기 위한 라벨링 시스템에 대해서 기술한다. 이를 구현하기 위해서 Back Projection, GrabCut 기법을 이용한 반자동 방식과 기계학습 모델을 통해서 예측한 자동 방식의 라벨링 기능을 구현하였다. 우리는 제안한 시스템의 라벨링 데이터 생성에 대한 수행시간의 장점을 보였을뿐만 아니라 정확성에 대한 비교평가를 통해 우수성을 보였다. 또한 1,000여명의 환자 영상 데이터셋을 분석하여 근감소증 진단에 남성과 여성에 의미있는 진단지표를 제시하였다.

키워드 : 인공지능, 의료 영상, 의료용 디지털 영상 및 통신, 컴퓨터 단층촬영, 라벨링 데이터, 근감소증

※ 본 연구는 보건복지부의 재원으로 한국보건산업진흥원의 보건의료기술 연구개발사업 (HI18C1216), 그리고 한국연구재단(NRF-2021R1A5A8029876) (NRF-2020R1I1A1A01074256)의 지원으로 수행함.

※ 이 논문은 2021년도 한국정보처리학회 ACK 2021에서 "기계학습을 위한 의료영상 라벨링 웹 애플리케이션 구현"의 제목으로 발표된 논문을 확장한 것임.

† 정 회 원 : 원광대학교 의료융합연구소 책임연구원

†† 비 회 원 : 원광대학교 의료융합연구소 연구원

††† 정 회 원 : 원광대학교 의료융합연구소 연구원

†††† 비 회 원 : 세종사이버대학교 소프트웨어공학과 학사과정

††††† 정 회 원 : 원광대학교병원 스마트사업팀 교수

†††††† 비 회 원 : 성균관대학교 삼성창원병원 영상의학과 교수

††††††† 중신회원 : 원광대학교병원 스마트사업팀 교수

Manuscript Received : December 30, 2021

First Revision : February 28, 2022

Accepted : March 29, 2022

* Corresponding Author : Jeong Chang-Won(mediblue@wku.ac.kr)

1. 서 론

인공지능 기술의 발전으로 다양한 분야에서 이를 적용하고 실제 업무에 활용하고자 하는 요구가 크게 증가하고 있다. 최근 몇 년간 가장 주목을 많이 받은 연구는 AI 모델을 개발하는 부분이었다. 글로벌 IT 기업 또는 연구소의 성과로 CNN, U-NET, Vision Transformer, LSTM, BERT 등 다양한 모델의 발전은 있었지만 AI 모델을 훈련시키기 위해 반드시 필요한 데이터의 중요성은 주목받지 못했다[1]. 뛰어난 AI 모델이 있더라도 실제 업무에서 활용 할 때는 데이터의 전처리, 품질, 데이터의 크기 그리고 Train/Validation/Test 셋을 어떻게 구성했는지에 따라 성능에 많은 영향을 준다[2,3]. 이

런 흐름으로 인공지능의 연구가 AI 모델 중심에서 데이터 중심으로 경향이 점차 변경되고 있다[4,5]. 또한 인공지능 프로젝트에서 학습데이터의 준비과정이 전체 과정의 80%를 차지하고 있으며, 향후 이런 데이터의 수요로 학습데이터 제작을 위한 데이터 라벨링 시장이 크게 확대될 것으로 예상하고 있다[6].

학습데이터는 AI 모델을 개발하는 목적에 따라 원천 데이터와 기계학습에 필요한 라벨링된 데이터로 구성된다. 하지만 학습데이터와 라벨링 데이터는 단기간에 대량으로 확보하기 어렵다[7]. 또한 인공지능 연구 방식에 따라 이미지 분류와 이미지 분할을 해야 하며, 이미지 분할은 라벨링된 데이터도 같이 입력하여 학습해야 하는데 원하는 부위에 따라 라벨링 데이터를 새로 생성하기 때문에 인공지능 연구에 많은 시간과 비용이 소비된다. 이러한 문제점을 극복하기 위해서 학습 데이터를 생성하는데 지속적으로 제작하고 공급할 수 있는 솔루션 개발이 필요하다.

본 논문에서는 의료영상의 라벨링 데이터를 빠르고 정교하게 생성하기 위한 의료영상 라벨링 시스템에 대해서 기술한다. 제안하는 시스템은 영상처리 기법을 적용한 반자동 방식과 기계학습 모델을 통해서 도출된 결과에 대한 확인과 간단한 수정으로 효과적이고 빠른 라벨링 데이터 생성이 가능하도록 하였다. 제안한 시스템의 학습 데이터 생성과정을 보이고 기존 개발 소프트웨어와 비교·평가하여 보다 빠르게 라벨링 데이터의 생성과정을 보인다. 그리고 라벨링 데이터의 정량분석을 통해 근감소증 진단을 위한 진단지표로 활용될 가능성을 제시하였다.

2. 관련 연구

2.1 학습 데이터셋 현황

기계학습의 데이터 학습 방법으로 지도학습, 비지도 학습, 강화학습으로 3가지로 분류된다. 의료영상 부분에서 일반적으로 지도학습을 많이 활용하여 딥러닝 모델을 개발하고 있다[8]. 지도학습은 원본 영상과 해당 영상에서 원하는 답을 입력하여 학습하고 비슷한 영상에서 답을 추론하는 방법이다. 지도학습에서 딥러닝 모델의 최적화를 위해 다양한 학습 데이터셋이 필요하다.

공개된 국외의 일반적인 영상인식을 위한 학습 데이터 셋으로는 MNIST[9], CIFAR-50[10], CIFAR-100[10], PASCAL VOC[11], MS COCO[12], ImageNet[13], Google Open Images Dataset[14]이 있다. 공개된 국외의 의료영상 데이터셋으로는 스탠퍼드 AIMI 공유 데이터셋이 있다. AIMI는 100만개 이상의 학습 이미지를 뼈, 가슴, 뇌, 목, 손 등 9개의 카테고리 분류하여 제공하고 있다[15]. 국내의 데이터셋으로는 국가 사업을 주축으로 다양한 분야의 영상 학습데이터를 제공하는 AI Hub[16], 의료영상 데이터셋으로는 PAIP[17], MOAI[18] 등 국가 과제의 일환으로 제공되고 있다. 의료영상 데이터셋에는 의료영상을 학습하는데 정답으로 사용되는 라벨데이터를 포함한다[19]. 하지만 의료영상의 라벨데이터를

만드는 작업에 많은 시간이 소요되기 때문에 인공지능 시스템 개발의 주요 장벽으로 간주되고 있다. 따라서 라벨링을 정교하고 빠르게 작업하기 위한 수동, 반자동, 완전 자동화 방법을 제공하는 다양한 소프트웨어가 개발되고 있다[20,21]. 반자동 방법은 임계값 또는 에지 감지와 같은 이미지 처리 기술을 활용한다. 완전 자동화된 방법은 설계한 알고리즘 또는 인공지능을 기반으로 특정 부분을 라벨링 처리한다.

2.2 준지도학습과 수도라벨링

학습데이터는 많을수록 좋은 성능의 모델을 만들 수 있지만 모든 의료영상의 라벨링 데이터를 생성한다는 것은 어렵다. 이러한 문제점을 해결하기 위한 방법으로 라벨링하지 않은 데이터를 활용하여 학습하는 준지도학습(semi-supervised learning)이 등장하였다. 본 연구에서는 의료영상의 라벨을 생성하기 위해서 준지도학습을 통하여 라벨링 데이터를 생성하였다. 즉, 지도학습을 통해 1차적으로 학습된 모델을 이용하여, 라벨링 하지 않은 일반 의료영상에 대해서 라벨링 예측을 수행하여 대략의 수도 라벨링(pseudo labeling)을 생성한다 [22]. 그리고 약간의 수작업을 거쳐 실제 라벨링 데이터를 생성한다. 이렇게 생성된 라벨 데이터를 이용하여 2차적으로 대량의 의료영상을 학습하여 더 좋은 모델을 개발하는 방법을 채택하였다.

2.3 Wonkwang J

이전 연구에서 우리는 복부 CT 영상에서 근육, 피하지방, 내장지방을 라벨링하기 위해서 Image J라는 오픈소스소프트웨어를 사용하여 라벨링 데이터를 생성하였다. 그러나 메뉴얼 방식으로는 요로결석과 같은 작은 영역의 라벨링 작업은 가능했지만 피하지방, 근육, 내장지방, 척추뼈 등 좀더 넓고 복잡한 라벨링을 진행하기에는 많은 시간이 소모되고 정교하지 못해서 반자동 방식으로 개선하여 Wonkwang J 라는 클라이언트 소프트웨어를 개발하였다[23]. Fig. 1은 Wonkwang J의 전체 UI를 보이고 있다. Wonkwang J는 Windowing 조절, 임계값 조절, 관심영역 추출과 같은 영상처리 과정을 수행하고 최종 얻게되는 라벨링 데이터의 정량분석 기능을 포함하고 있다.

영상처리 과정 중 첫 번째인 Windowing은 영상의 픽셀값 분포 속에 관심 있는 영역만을 보여주는 기능으로 픽셀값(Window Center)을 중심으로 특정한 폭(Window Width)만큼의 픽셀값에 해당하는 영역만을 표시 한다. 두 번째 단계는 임계값 조절로 의료영상의 지방, 근육, 뼈는 일정한 영역의 픽셀값을 갖고 있기 때문에 픽셀값의 임계 구간을 설정하여 사용자가 원하는 부위를 쉽게 선택할 수 있다. 그러나 특정영역에 해당하는 임계값을 설정하면 임계값이 비슷한 경우 동일한 영역으로 레이블링된다. 따라서 세 번째 단계로 임계값 지정 후 관심영역 지정을 통해 피하지방과 내장지방을 분리한다. 이렇게 3 단계를 거쳐서 최종 라벨링 데이터를 생성한다. Table 1은 특정 환자의 복부 CT에서 라벨링한 영역별 정량분석 결과를 보이고 있다.

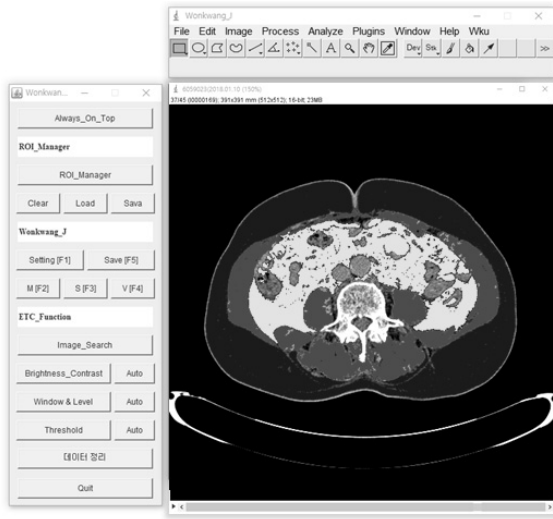


Fig. 1. UI of Wonkwang J

Table 1. Quantitative Analysis Results

	ROI Name	Area	Mean	StdDev
1	Muscle	19696	130.284	19.618
2	Subcutaneous	35616	12.313	10.637
3	Visceral	20182	12.324	12.543

3. 제안 시스템

본 논문에서는 클라우드 기반 의료영상 라벨링 시스템을 제안한다. 기존 라벨링 시스템은 대부분 전문가 애플리케이션으로 독립형으로 설치하여 사용하지만 제안하는 시스템은 Fig. 2와 같이 사용자의 접근성을 높이고 개발 도구의 유지보수 및 관리를 위해 웹기반으로 개발하였다. 웹 서버인 Nginx는 사용자들의 동시접속을 처리하고 부하를 분산시켜주는 역할을 담당한다. React는 사용자가 사용하는 전체 UI를 담당하는데 사용자는 Nginx에 URL 주소를 통하여 Frontend를 요청할 수 있다. 마이크로 웹 프레임워크인 Flask는 파일 업로드, 영상 전처리, 라벨링 기능 요청, 라벨링 파일 저장, 정량분석 등의 다양한 요청에 대한 기능을 분기하고 처리한다. 또한 Flask는 Tensorflow로 개발된 모델을 관리하여 복잡한 라벨링 과정이 요구되는 작업을 모델서빙을 통하여 사용자가 라벨링 과정을 간편하고 빠르게 생성할 수 있도록 지원한다. 전체 시스템은 AWS의 EC2에서 운영되고 있어 기본적인 보안이 적용되어 있고 사용자 증가에 따라 확장 가능하며 최적의 성능을 유지하며 사용할 수 있다.

3.1 라벨링 웹 애플리케이션 UI

본 논문에서 제안하는 의료영상 라벨링 웹 애플리케이션의 전체 UI는 Fig. 3과 같다.

Fig. 3의 (a)는 라벨링 기능을 위한 버튼들이 위치해 있고 (b)는 라벨링을 하기 위한 이미지와 라벨링 결과를 보여주는

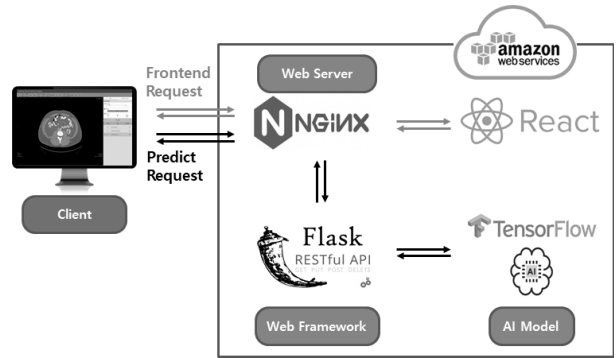


Fig. 2. Overall System Structure




Fig. 3. UI of Medical Image Labeling Web Application

뷰어 영역이다. (c)는 라벨링 툴의 크기와 색상을 지정하는 설정부분이다. (d)는 현재 라벨링된 부분의 HU 값의 Min, Max, Mean 값을 보여준다. (e)는 라벨링 레이어를 추가하거나 제거하기 위한 부분으로 만약 척추뼈 라벨링을 추가하고자 한다면 Add 버튼을 통해 레이어를 추가하고 진행하면 된다. 그리고 Sarcopenia Predict 버튼을 클릭하면 인공지능 모델을 통해서 추론된 근육, 피하지방, 내장지방 3개의 라벨링을 위한 레이어가 자동으로 추가된다. 사용자는 각 라벨링 파일을 선택하고 수정할 수 있다.

3.2 라벨링 웹 애플리케이션 워크플로우

의료영상 라벨링 웹 애플리케이션의 전체 워크플로우는 Fig. 4와 같다.

- (a) File Upload : Open 버튼을 클릭하여 의료영상의 단일 파일 또는 폴더 단위로 선택하여 업로드 한다.
- (b) Series View : 업로드 완료된 전체 파일을 Series 별로 보여주어 실제 라벨링을 원하는 Series를 선택하도록 한다.
- (c) Select Labeling Area : 실제 라벨링 작업할 영역을 선택한다. 현재 그림은 (b)에서 선택된 Axial Series로 전체 Sagittal로 재구성된 척추뼈 영상에서 L3 영역을 지정하고 있다. (b)에서 두 개의 Series가 선택된다면 현재 Select Labeling Area 단계는 생략하고 선택된 전체 Series를 라벨링하도록 (d) 단계로 이동한다.

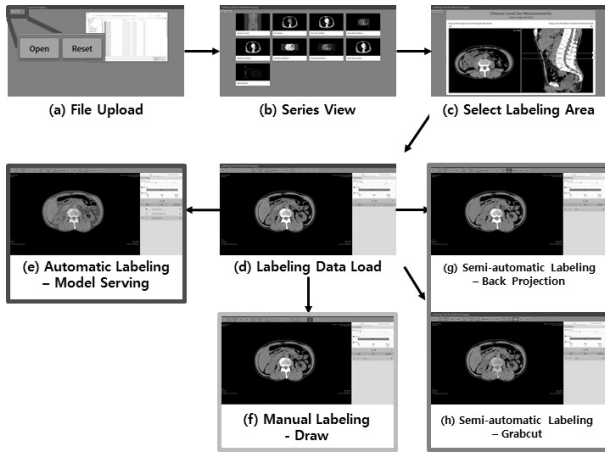


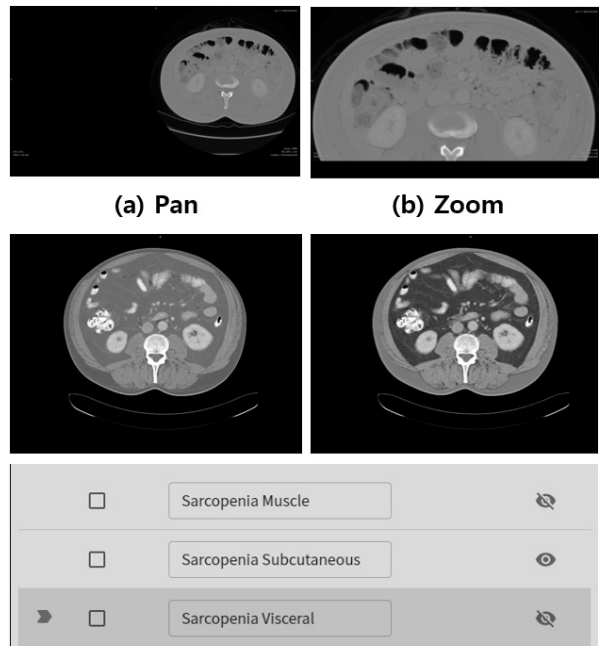
Fig. 4. Workflow for Labeling Web Application

- (d) Labeling Data Load : (c) 단계에서 선택된 파일만 라벨링 도구의 뷰어에 로드 한다. 두 개 이상의 Series 일 경우는 모든 이미지를 로드 한다.
- (e) Automatic Labeling-Model Serving : 완전 자동화된 라벨링 방법으로 기계학습을 통하여 예측된 라벨링 파일을 사용자에게 전달한다. 예측한 라벨링 파일의 수정이 필요한 경우 라벨링 도구에서 약간만 수정하면 된다.
- (f) Manual Labeling-Draw : 사용자가 필요한 부분을 수동으로 그려 라벨링 파일을 생성한다.
- (g) Semi-automatic Labeling-Back Projection : Back Projection 기법[24]은 주어진 이미지에서 히스토그램의 픽셀 분포와 잘 맞는 픽셀을 찾아내는 영상처리 기법으로 의료영상에서 라벨링을 원하는 부위의 일부를 사각형 ROI로 선택하면 비슷한 픽셀을 자동으로 선택해주는 방식으로 라벨링 파일을 생성한다.
- (h) Semi-automatic Labeling-GrabCut : GrabCut 기법[25]은 주어진 이미지에서 전경과 배경을 분리하는 영상처리 기법으로 (h) 이미지를 보면 뼈 부분과 다른 부위의 픽셀값의 차이를 이용하여 원하는 부위를 선택해주는 방식으로 라벨링 파일을 생성한다.

3.3 라벨링 웹 애플리케이션 기능

Fig. 5는 Pan, Zoom, Visible 버튼을 눌렀을 경우에 Display의 변화를 확인할 수 있다.

Pan 버튼은 라벨링 위치에 따라 이미지를 원하는 위치로 이동하는 기능을 활성화 하고 Zoom 버튼은 라벨링 대상의 크기가 요로결석과 같이 3mm이내로 작은 경우 이미지의 원하는 부위를 확대/축소하는 기능을 활성화 한다. 토글 버튼은 생성된 라벨링 정보를 Visible / Invisible로 라벨링이 없는 원본 이미지를 봐야할 경우에 필요한 기능이다. 그리고 뷰어에 로딩된 의료영상에 Zoom, Pan 기능이 적용되었을 때 처음 상태로 되돌리고자 할 때 Reset 버튼을 클릭한다.



(c) Visible, Invisible

Fig. 5. Pan, Zoom, Visible, Invisible Functions

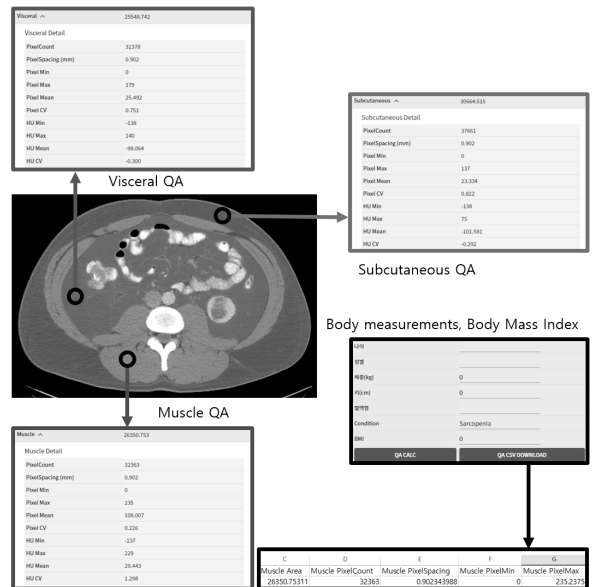


Fig. 6. Results of Quantitative Analysis for the Diagnosis of Sarcopenia

3.4 정량분석 수행

정량분석 탭에서는 모든 부위의 라벨링이 완료된 이후에 버튼 한번으로 라벨링된 전체 부위에 대한 정량분석을 진행한다. Fig. 6은 복부 CT에서 L3영역의 의료영상에서 근감소증 진단을 위해 근육량을 비롯하여 지방량을 라벨링한 결과를 보이고 있다. 라벨링된 영역에 대해서 근육부위, 피하지방부위, 내장지방부위에 따라 정량분석된 수치결과를 얻을 수

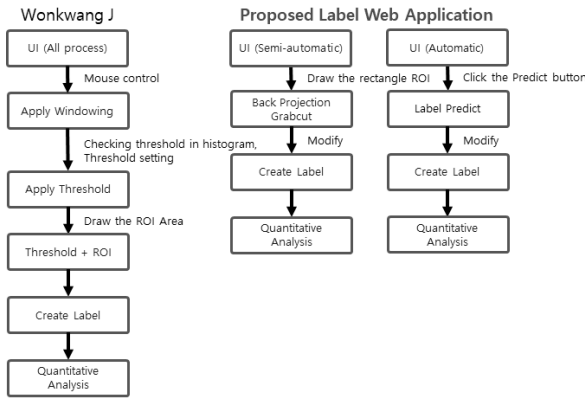


Fig. 7. Comparison of the Labeling Procedure between Wonkwang J and the Proposed Labeling Web Application

있다. 키, 몸무게 결과는 의료영상 태그에서 우선 획득 하지만 없는 경우 수동으로 입력하면 BMI가 자동으로 계산된다. 정량분석 결과는 엑셀파일로 다운로드하여 통계분석에 활용한다.

3.5 Wonkwang J와 라벨링 웹 애플리케이션의 절차비교

1) 절차 비교

라벨링은 다양한 영상처리 기법을 적용하여 정교하고 빠르게 작업하기 위해서 다양한 설정을 위한 다이얼로그와 마우스 컨트롤이 많이 요구된다.

하지만 다이얼로그의 선택과 마우스 컨트롤이 많아질수록 작업 시간이 오래 걸리고 복잡해진다. Fig. 7은 Wonkwang J와 본 논문에서 제안된 라벨링 웹 애플리케이션의 라벨링 절차를 비교한 그림이다. Fig. 7과 같이 Wonkwang J는 절차마다 설정을 위한 다이얼로그 선택과 마우스 조작이 많은 반면 제안된 라벨링 웹 애플리케이션은 반자동화 기능을 제공하여 마우스로 사각형 ROI 지정과 키보드 클릭 그리고 완전 자동화 기능으로 절차가 간소화된 것을 확인할 수 있다. 그리고 반자동화는 라벨 생성을 위해서 약간의 수정 작업이 필요하지만 완전 자동화는 수정없이 라벨링 작업이 가능하다. 실제로 라벨링 작업을 진행해 본 결과 Wonkwang J는 복잡하고 시간이 오래 걸려 진행하기 어렵다는 결과를 얻었고 제안된 라벨링 웹 애플리케이션은 하루에 4시간씩 한달 동안 Patient: 272명, 원본 이미지: 1,786장, 정량분석: 1,786개, 라벨 이미지: 7,144장 의 라벨링을 진행할 수 있었다.

2) 시간 비교

Wonkwang J와 제안된 라벨링 웹 애플리케이션의 라벨링 하는데 걸린 시간을 비교한 표는 Table 2와 같다.

Image J를 사용했을 때 시간은 하나의 영상마다 1,284초가 소요되었으나 Wonkwang J로 분석했을 때 처리 시간은 평균 204초가 소요되었다.

제안된 라벨링 웹 애플리케이션은 평균 32.92초가 소요되

Table 2. Elapsed Time for Each Application

	Image J	Wonkwang J	Proposed Label Web Application
User 1	1290 ± 94	210 ± 31	27.21 ± 13.54
User 2	1260 ± 69	214 ± 24	20.27 ± 8.13
User 3	1266 ± 55	206 ± 11	22.70 ± 13.88
User 4	1344 ± 56	216 ± 23	51.60 ± 23.03
User 5	1268 ± 72	202 ± 21	38.64 ± 18.61
User 6	1196 ± 42	216 ± 11	36.87 ± 18.55
Mean ± SD	1284 ± 71	204 ± 20	32.92 ± 15.96

* Measurement time unit : second




Fig. 8. Example of Label Prediction Result

었다. Image J에 비해서 Wonkwang J가 6배 Wonkwang J보다 제안된 라벨링 웹 애플리케이션이 6배정도 작업시간이 감소하였다. 실제 6명 User의 숙련도에 따라 실제 작업시간의 차이가 있어도 대부분 1장당 60초 이내로 완료됨을 확인하였다. 실제 예측된 결과에서 Fig. 8의 (a) Case 1과 (b) Case 2는 빨간 박스 부분을 수정 후 라벨을 생성해야 하는 경우와 (c) Case 3와 (d) Case 4는 수정이 필요하지 않은 라벨링 데이터 생성이 가능한 경우에 대한 예시를 보이고 있다. 인공지능의 정확도를 높여서 예측 결과의 라벨링이 수정할 부분이 없다면 대량의 라벨링을 손쉽게 할 것으로 기대하고 있다.

3) 정확도 비교

Fig. 9는 Wonkwang J와 제안된 라벨링 웹 애플리케이션의 라벨링 정확도를 비교한 그림이다.

(a)는 Wonkwang J에서 생성한 근육 부분의 라벨링 데이터 결과로 Threshold 값을 설정하여 비슷한 영역을 지정하고 분류하기 위한 영역을 ROI로 설정하면 (a)와 같은 영상을 얻을 수 있다. 이것을 라벨링 데이터로 사용하기엔 부족하다.




Fig. 9. Comparison of Label between Wonkwang J and the Proposed Labeling Web Application

Table 3. Comparison of IOU between Wonkwang J and the Proposed Labeling Web Application

	IOU	M	S	V	MSV	Ratio
1	0.90~1.00%	26	39	14	23	102/200 (51%)
2	0.80~0.89%	15	6	8	20	49/200 (25%)
3	0.70~0.79%	8	2	13	5	28/200 (14%)
4	~0.69%	1	3	15	2	21/200 (10%)

* MSV = Muscle + Subcutaneous + Visceral, M = Muscle, S = Subcutaneous, V = Visceral

빈 공간을 메꾸기 위한 작업이 필요하다. 반면에 제안된 라벨링 웹 애플리케이션은 (b)와 같은 라벨링 데이터를 생성한다. 그리고 약간의 수정만 거치면 인공지능 학습데이터로 사용 가능하다.

자동으로 레이블링된 데이터의 정확도 평가를 위해 Test Dataset 50개의 의료영상으로 예측하여 근육, 피하지방, 내장지방 3개의 영역과 통합된 영역으로 총 4개의 영역으로 분류하고, 각 영역 당 50개씩 200개의 생성된 라벨링과 정답 라벨링으로 계산된 IOU(Intersection over Union)는 다음 Table 3과 같다. 이것의 결과로 수정없이 라벨 데이터로 활용할 수 있는 경우가 50% 이상이 되며, 90% 이하의 정확도로 라벨링 되었다 하더라도 기존 라벨링 도구 보다 빠르게 라벨링할 수 있는 장점을 갖는다.

3.6 근감소증 진단을 위한 정량 분석

우리는 제안한 시스템을 통해 근감소증 진단을 위한 분석방법[23]에 따라 복부 절환 데이터셋을 이용하여 분석하였다. 이를 위해 복부 이미지 1,161장의 라벨링을 진행하였고 정량분석을 통하여 근육량, 피하지방량, 내장지방량을 측정하였다. 측정된 데이터를 기반으로 건강한 젊은 성인의 데이터를 대상으로 T-Score=-0.1과 -0.2의 cutoff 값을 계산하였다. T-Score 값을 기반으로 근감소증의 소견을 보이는 환자를 판별할 수 있다. 레퍼런스 논문[26]의 진단 지표와 비교하여 거의 동일한 오차범위의 값을 보이고 있다. 오차는 대상자의 수 차이로 인하여 발생할 수 있을 것으로 판단하고 있다. Table 4는 각종 지표들에 대한 남성과 여성의 T-Score 값을 보이고 있다.

Table 4. T-Score for Various Indicators

Men	n=83			
	Mean	SD	T-Score=-1.0	T-Score=-2.0
SMA	186.54	32.98	153.56	120.58
SMA/Ht ²	61.64	11.40	50.24	38.83
SMA/Wt	2.24	0.27	1.97	1.70
SMA/BMI	6.80	0.88	5.92	5.03
Women		n=68		
SMA	116.20	24.66	91.53	66.86
SMA/Ht ²	44.67	8.95	35.71	26.76
SMA/Wt	1.93	0.17	1.76	1.59
SMA/BMI	5.02	0.47	4.54	4.07

* SMA:skeletal muscle area, Ht:height, Wt:weight

4. 결론 및 향후 연구

본 논문에서는 의료영상에 대한 라벨링 시스템에 대해 기술하였다. 개발된 시스템을 통해 학습데이터를 생성할때 라벨링 작업을 간편하고 정교하게 할 수 있도록 인공지능 이미지 분할 기술을 도입하여 개선하였다. 향후 연구 내용으로는 현재 데이터베이스 없이 라벨링 기능만을 구현하였기 때문에 업로드된 의료영상 데이터와 생성한 라벨링 데이터의 관리적 문제점과 생성된 데이터를 재사용하는데 문제가 있다. 데이터베이스를 연동하여 향후 데이터에 대한 유지관리가 이루어지도록 할 예정이다. 또한 복잡한 영상의 라벨링을 쉽게 처리하기 위한 영상처리 알고리즘을 연구하여 추가할 계획이다. 그리고 소동물을 위한 정교한 라벨링 기능 또한 추가하여 지원할 계획이다.

References

- [1] Andrew Ng: MLOps: "From Model-centric to Data-centric AI," [Internet], <https://www.deeplearning.ai/wp-content/uploads/2021/06/MLOps-From-Model-centric-to-Data-centric-AI.pdf>.
- [2] Y. Bai, et al., "How important is the train-validation split in meta-learning?" *arXiv preprint arXiv:2010.05843*, 2020.
- [3] A. Rác, D. Bajusz, and K. Héberger, "Effect of dataset size and Train/Test split ratios in QSAR/QSPR multiclass classification," *Molecules*, Vol.26, No.4, pp.1111, 2021.
- [4] M. Motamedi, N. Sakharnykh, and T. Kaldewey, "A data-centric approach for training deep neural networks with less data," *arXiv preprint arXiv:2110.03613*, 2021.
- [5] J. D. Bossér, E. Sörstadius, and M. H. Chehreghani, "Model-centric and data-centric aspects of active learning for neural network models," *arXiv preprint arXiv:2009.10835*, 2020.
- [6] Cognilytica, "Data engineering, preparation, and labeling for AI 2019," [Internet], <https://www.cognilytica.com/2019/03/06/report-data-engineering-preparation-and-labeling-for-ai-2019/>.

- [7] Y. Roh, G. Heo, and S. E. Whang, "A survey on data collection for machine learning: A big data-ai integration perspective," in *IEEE Transactions on Knowledge and Data Engineering*, Vol.33, No.4, pp.1328-1347, 2021, doi: 10.1109/TKDE.2019.2946162.
- [8] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, Vol.521, pp.436-444, 2015.
- [9] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, Vol.86, No.11, pp.2278-2324, 1998.
- [10] A. Krizhevsky, "Learning multiple layers of features from tiny images," [Internet], <https://www.cs.toronto.edu/~kriz/cifar.html>, 2009.
- [11] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, "The PASCAL Visual Object Classes (VOC) Challenge," *International Journal of Computer Vision*, Vol.88, pp.303-338, 2010.
- [12] T. Y. Lin, et al., "Microsoft COCO: Common objects in context," In: Fleet, D., Pajdla, T., Schiele, B., Tuytelaars, T. (eds) *Computer Vision ? ECCV 2014*. Lecture Notes in Computer Science, Vol.8693. Springer, Cham, doi: 10.1007/978-3-319-10602-1_48
- [13] J. Deng, W. Dong, R. Socher, L. J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp.248-255, 2009.
- [14] Google's Open Images V6 + Extensions [Internet], <https://storage.googleapis.com/openimages/web/index.html>.
- [15] Center for Artificial Intelligence in Medicine & Imaging [Internet], <https://aimi.stanford.edu/>.
- [16] AI Hub [Internet], <https://aihub.or.kr/>.
- [17] Pathology AI Platform, [Internet], <http://wiseaip.org/>.
- [18] Morphometry Open AI Innovation [Internet], <http://www.wornoi.org/>.
- [19] A. D. Weston, et al., "Automated abdominal segmentation of CT scans for body composition analysis using deep learning," *Radiology*, Vol.290, No.3, pp.669-679, 2019. doi: 10.1148/radiol.2018181432.
- [20] C. T. Rueden, et al., "ImageJ2: ImageJ for the next generation of scientific image data," *BMC Bioinformatics*, Vol.18, No.529, 2017. doi: 10.1186/s12859-017-1934-z.
- [21] R. Kikinis, S. D. Pieper, and K. G. Vosburgh, "3D Slicer: A platform for subject-specific image analysis, visualization, and clinical support," In: Jolesz, F. (eds.) *Intraoperative Imaging and Image-Guided Therapy*. Springer, New York, NY. doi: 10.1007/978-1-4614-7657-3_19.
- [22] M. N. Rizve, K., Duarte, Y. S., Rawat, and M. Shah, "In defense of pseudo-labeling: An uncertainty-aware pseudo-label selection framework for semi-supervised learning," *arXiv preprint arXiv:2101.06329*, 2021.
- [23] S. Kim, T. H. Kim, C. W. Jeong, C. Lee, S. Noh, J. E. Kim, and K. H. Yoon, "Development of quantification software for evaluating body composition contents and its clinical application in sarcopenic obesity," *Scientific Reports*, Vol.10, No.10452, 2020. doi: 10.1038/s41598-020-67461-0.
- [24] Histogram Backprojection [Internet], https://docs.opencv.org/3.4/dc/df6/tutorial_py_histogram_backprojection.html.
- [25] GrabCut [Internet], https://docs.opencv.org/3.4/d8/d83/tutorial_py_grabcut.html.
- [26] E. H. Kim, et al., "Reference data and t-scores of lumbar skeletal muscle area and its skeletal muscle indices measured by CT scan in a healthy Korean population," *The Journals of Gerontology: Series A*, Vol.76, No.2, pp.265-271, 2021. doi: 10.1093/gerona/glaa065.



이 충 섭

<https://orcid.org/0000-0003-1276-4000>

e-mail : cslee99@wku.ac.kr

2005년 원광대학교 전기전자 및 정보공학부 (학사)

2011년 원광대학교 컴퓨터공학과(석사)

2007년~2014년 인피니트 헬스케어 과장

2014년~2018년 레이언스 책임연구원

2018년~현 재 원광대학교 의료융합연구센터 책임연구원

관심분야 : Medical Imaging, Deep Learning, CDM



임 동 옥

<https://orcid.org/0000-0001-6995-2745>

e-mail : dw316@wku.ac.kr

2018년 원광대학교 컴퓨터공학과(학사)

2019년~2020년 전주대학교

정보통신지원실 직원

2020년~현 재 원광대학교

의료융합연구센터 연구원

관심분야 : Medical Imaging, Deep Learning, CDM, Labeling Tool, Cloud Service



김 지 언

<https://orcid.org/0000-0001-8019-9977>

e-mail : kakasky112@wku.ac.kr

2015년 원광대학교 반도체디스플레이학과 (학사)

2017년 원광대학교 컴퓨터공학과(석사)

2017년~2022년 원광대학교

의료융합연구센터 연구원

관심분야 : Medical Imaging, Machine Learning, Big Data, R_CDM



노 시 형

https://orcid.org/0000-0002-1992-6239
e-mail : nosij123@wku.ac.kr
2015년 원광대학교 전기전자 및
정보공학부(학사)
2017년 원광대학교 컴퓨터공학과(석사)
2017년~현 재 원광대학교
의료융합연구센터 연구원

관심분야: Medical Imaging, Machine Learning, Big Data,
CDM



유 영 주

https://orcid.org/0000-0003-3603-2664
e-mail : yeriel.ryu@gmail.com
2016년 학점은행제 경영학(전문학사)
2020년~2022년 원광대학교
의료융합연구센터 연구원
2021년~현 재 세종사이버대학교
소프트웨어공학과 학사과정

관심분야: Medical Imaging, Big Data, CDM



김 태 훈

https://orcid.org/0000-0002-2552-0665
e-mail : tae_hoonkim@wku.ac.kr
2010년 전남대학교 의공학협동과정(박사)
2006년~2009년 전남대학교
의과학연구소 연구조교
2009년~2014년 전남대학교병원
의생명연구원 연구원

2010년~2013년 전남대학교병원 영상의학연구소 Postdoctoral
Fellow

2010년~2014년 전남대학교 산학협력단 의과대학 연구원

2014년~현 재 원광대학교 의료융합연구센터 연구교수

2020년~현 재 원광대학교병원 스마트사업팀 교수

관심분야: 의료영상 분석, 정량분석 소프트웨어, 영상의학 분야 임상
연구, 빅데이터·공통데이터 모델(CDM) 분석 및 활용



윤 권 하

https://orcid.org/0000-0002-2634-8510
e-mail : khy1646@wku.ac.kr
2002년 전북대학교 의과대학 의학과(박사)
1998년~2022년 원광대학병원 의학과 교수
2001년~2008년 전북테크노파크
방사선영상기술센터 센터장

2012년~2017년 원광대학교병원 병원특성화연구 센터장

2015년~2019년 원광대학교병원 임상의학연구원장

2019년~2022년 원광대학교병원 병원장

2017년~2022년 원광대학교 의료융합연구센터 센터장

2022년~현 재 성균관대학교 삼성창원병원 영상의학과 교수

관심분야: X-ray Imaging, Nano Medicine, Molecular
Imaging, Gastrointestinal Imaging



정 창 원

https://orcid.org/0000-0002-9305-4686
e-mail : mediblue@wku.ac.kr
2003년 원광대학교 컴퓨터공학과(박사)
2004년~2006년 전북대학교 학술연구교수
2006년~2013년 원광대학교 전기전자 및
정보공학부 강사

2013년~현 재 원광대학교 의료융합연구센터 연구교수, 실장

2020년~현 재 원광대학교병원 스마트사업팀 교수

2020년~현 재 원광대학교병원 CDM 기관관리자

관심분야: Bigdata, AI Platform, Medical Data Analysis,
Smart healthcare, Common Data Model for
Medical information, Radiology_CDM