

DEXA에서 딥러닝 기반의 척골 및 요골 자동 분할 모델

김영재[†], 박성진^{**}, 김경래^{***}, 김광기^{****}

Automated Ulna and Radius Segmentation model based on Deep Learning on DEXA

Young Jae Kim[†], Sung Jin Park^{**}, Kyung Rae Kim^{***}, Kwang Gi Kim^{****}

ABSTRACT

The purpose of this study was to train a model for the ulna and radius bone segmentation based on Convolutional Neural Networks and to verify the segmentation model. The data consisted of 840 training data, 210 tuning data, and 200 verification data. The learning model for the ulna and radius bone was based on U-Net (19 convolutional and 8 maximum pooling) and trained with 8 batch sizes, 0.0001 learning rate, and 200 epochs. As a result, the average sensitivity of the training data was 0.998, the specificity was 0.972, the accuracy was 0.979, and the Dice's similarity coefficient was 0.968. In the validation data, the average sensitivity was 0.961, specificity was 0.978, accuracy was 0.972, and Dice's similarity coefficient was 0.961. The performance of deep convolutional neural network based models for the segmentation was good for ulna and radius bone.

Key words: DEXA, Deep Learning, Convolutional Neural Network, U-Net, Segmentation

1. 서 론

골다공증은 전신적인 골격계 질환으로 골밀도(Bone Mineral Density, BMD) 감소와 뼈의 구조적 변형으로 골 강도가 약화되어 골절의 위험성을 증가시키는 질환이다[1,2]. 골다공증은 50세 이상 여성의 21%, 남성의 6%가 겪는 발병률이 높은 질병이지만 골절을 야기하기 전까지는 자각증상이 거의 없어 스스로 골다공증을 인지하기 어렵다[3]. 조기 진단과 예방을

위해 이중 에너지 X-ray 흡수 계측법(Dual Energy X-ray Absorptiometry, DEXA)이 주로 사용되고 있다[4-6].

DEXA 영상은 서로 다른 에너지를 갖는 X 선을 이용하여 두 장의 영상을 얻는다. 단일 X 선을 이용하여 얻은 영상에 비해 DEXA 영상은 두 장의 영상을 통해 생체조직 중첩에 의해 발생한 잡음을 제거할 수 있다는 장점이 있다[7]. DEXA 영상에서 골밀도를 측정하는 방법은 연부조직으로부터 골 영역을 분

※ Corresponding Author: Kwang Gi Kim, Address: (21565) 21 Namdong-daero 774 beon-gil, Namdong-gu, Incheon, Korea, TEL: +82-32-458-2770, FAX: +82-32-460-2361, E-mail: kimkg@gachon.ac.kr

Receipt date: Aug. 20, 2018, Revision date: Oct. 23, 2018
Approval date: Nov. 13, 2018

[†] Dept. of Biomedical Engineering, Gachon University College of Medicine
(E-mail: kimyj10528@gachon.ac.kr)

^{**} Dept. of Biomedical Engineering, Gachon University College of Medicine (E-mail: sungjin9999@naver.com)

^{***} Dept. of Biomedical Engineering, Gachon University College of HealthScience
(E-mail: rlarudfo93@gmail.com)

^{****} Dept. of Biomedical Engineering, Gachon University College of Medicine, Dept. of Biomedical Engineering, Gachon University College of HealthScience

※ This research was supported by Ministry of Trade, Industry and Energy of Korea (10097501)

할한 후 분할된 골 영역에서 골밀도를 측정한다[8]. 따라서 골밀도 측정의 정확성을 높이기 위해서는 연부조직과 골 영역을 정확히 분할할 수 있는 기술 개발이 필요하다. 하지만 아직까지 DEXA 영상에서의 골 영역 분할 연구는 보고된 바가 적으며, 콘 빔(Cone Beam) 방식의 DEXA 장비의 경우, 영상에서 발생하는 gradient로 인해 기존의 영상처리 기법을 통해 정확한 골 영역을 추출하는데 한계가 있으며, 장비나 촬영 환경에 따라 영상이 달라지기 때문에 외부 환경에 강인한 골 영역 추출 알고리즘의 개발이 필요하다.

최근에는 하드웨어 기술이 발전함에 따라 딥러닝 기술을 활용할 수 있는 환경이 갖추어지고 있으며, 이에 따라 다양한 분야에서 딥러닝(Deep Learning) 기술을 적용하고 있다. 특히 딥러닝 기술의 한 종류인 합성곱 신경망(Convolutional Neural Network, CNN)은 다양한 영상 분야에서 활발하게 활용되어지고 있다. 합성곱 신경망은 다수의 비선형 필터를 통해 추출된 다양한 종류의 local 특징들을 반복적으로 적용하면서 global 특징들까지 언어낼 수 있으며, 다양한 종류의 local 및 global 특징들을 통한 학습을 기반으로 위상(Topology) 변화에 무관한 항상성(Invariance)를 얻을 수 있기 때문에 외부 환경에 강인한 분할 결과를 얻을 수 있으며, 기존 영상처리 기법이 가지는 한계에 대한 해결책이 될 수 있다[9,10]. 특히, 기존 영상처리 기법으로는 영상에 gradient가 존재하는 경우 전역적인 문턱치(threshold)를 적용하기 어렵기 때문에 별도의 그래디언트 제거 방법에 대한 추가 연구가 필요하다. 또한 기존 영상처리 기법으로는 영상의 화소값 변동이 적은 부분에서의 분할이 쉽지 않지만 합성곱 신경망에서는 영상의 그래디언트의 영향이나 적은 화소값 변동에도 강인한 분할 결과를 보인다. 이와 같은 합성곱 신경망의 우수한 성능으로 인해 다양한 의료영상 분야에서도 합성곱 신경망을 적용한 연구들이 다수 보고되고 있다.

2018년 Archit Raj 등은 U-Net 모델을 통해 무릎 연골을 분할하고자 하였다. 100개의 MR 볼륨 데이터에 대하여 80개의 볼륨 데이터를 학습에 사용하고, 20개의 볼륨 데이터를 통해 학습된 모델을 검증한 결과, 대퇴부 연골(Femoral Cartilage)에서 0.849의 다이스 계수를 보였고, 정강 연골(Tibial cartilage)에서 0.857의 다이스 계수를 보였다[11]. 2016년 Mohammad Havaei 등은 Cascade CNN 아키텍처를 통

해 뇌 암을 분할하고자 하였으며, BRATS 2013 data를 사용하여 학습 및 검증을 한 결과, 0.84의 다이스 계수를 보였다[12]. 2016년 Alexander Kalinovsky 등은 SegNet 모델을 통해 폐 영역을 분할하고자 하였다. 354장의 X-ray 영상을 사용하여 학습 및 검증을 한 결과, 0.962의 다이스 계수를 보였다[13].

이와 같이 다양한 의료영상 분야에서 딥러닝 기술을 활용하여 병변이나 장기를 분할한 연구 결과들이 보고되고 있으며, 결과 또한 기존 영상처리 기술을 사용하였을 때 보다 높은 성능을 보고하고 있다. 하지만 딥러닝을 이용하여 DEXA 영상에서 골 영역을 분할한 연구는 아직까지 많이 보고되고 있지 않으며, 특히 손목을 촬영한 DEXA 영상에서의 골 영역 분할 연구는 아직까지 보고된바가 없다. 이에 본 논문에서는 손목을 촬영한 DEXA 영상에서 골밀도를 계산할 때 사용되는 척골(Ulna)과 요골(Radius) 분할에 대하여 딥러닝 기술 중 합성곱 신경망(Convolutional Neural Network, CNN)을 활용하고자 하였으며, 이를 기반으로 외부 환경에 강인한 척골 및 요골 분할 기술을 개발하고, 검증하고자 하였다.

2. 재료 및 방법

2.1 개발 환경

본 논문에서는 실험에 사용된 데이터의 전처리 및 후처리에 대한 영상처리를 위해 Microsoft Visual Studio (Ver. 2010, Microsoft, Redmond, WA, USA)와 ITK (Insight Segmentation and Registration Toolkit, Kitware Inc., NY, USA), VTK (Visualization Toolkit, Kitware Inc., NY, USA)를 사용하였다. 딥러닝 학습을 위한 시스템은 4개의 NVIDIA TITAN Xp (NVIDIA, Santa Clara, Calif) 그래픽 처리 장치, Xeon E5-1650 v4 (Intel, Santa Clara, Calif) CPU 및 128 GB RAM으로 구성하였으며, 딥러닝 학습은 Ubuntu 14.04 운영체제에서 Python 2.7.6 및 Keras 2.1.5 (TensorFlow 백엔드 포함) 프레임 워크를 통해 수행되었다.

2.2 데이터

본 논문에서 실험을 위해 척골과 요골이 포함된 손목을 촬영한 DEXA 영상 1,250장을 수집하였다. 수집된 영상은 16비트의 화소값을 가지는 raw 포맷

으로 구성되어 있으며, 가로 784 픽셀, 세로 518 픽셀의 크기를 가진다. 각 영상은 high energy와 low energy 영상이 한 쌍으로 이루어져 있으며, 각 영상의 크기는 가로 784 픽셀, 세로 518 픽셀의 크기를 가진다. High energy 영상과 low energy 영상은 서로 동일한 조건에서 촬영되었기 때문에 동일한 위치를 가진다. 따라서 본 논문에서는 high energy 영상과 low energy 영상 중 뼈와 주변 조직(Tissue)간의 대비가 더 높은 low energy 영상만을 실험에 사용하였다. Fig. 1에서는 손목을 촬영한 DEXA의 high energy와 low energy 영상을 보여준다.

합성곱 신경망을 이용한 딥러닝 학습은 특성상 입력 및 출력 영상의 가로축과 세로축의 크기가 동일해야 한다. 따라서 본 논문에서는 전처리 과정을 통해 영상을 가로 510 픽셀, 세로 510 픽셀로 잘라내어 사용하였다. 학습 데이터를 만들기 위해 수집된 low energy 영상 데이터를 대상으로 전문가가 직접 수동으로 척골과 요골의 영역에 대한 관심영역(Region Of Interest, ROI)을 그려 영상의 마스크 영상을 만들었다. 마스크 영상은 정답 데이터로 사용되어 모델의 학습과 검증에 각각 사용되었다. 관심영역 대상인 척골은 전완을 구성하는 2개의 뼈 중 안쪽에 위치한 뼈로서 팔 아래쪽으로 갈수록 가늘어지는 특징을 가지고 있으며, 요골은 전완의 바깥에 위치하였으며 척골과 반대로 팔 아래쪽으로 갈수록 두꺼워지는 특징을 가지고 있다.

수집된 1,250장의 데이터 중, 840장은 학습 데이터로 사용되었고, 210장은 학습 과정에서 사용하기 위한 튜닝 데이터로 사용되었다. 또한 200장은 최종적인 학습 모델의 검증을 위한 검증 데이터로 사용되었다.

2.3 전처리

수집된 low energy 영상은 좌우에 여백이 위치한다. 이러한 여백은 불필요한 연산을 초래하고, 오검출의 위험성을 높인다. 또한 합성곱 신경망의 특성에 따라 학습에 사용될 영상은 너비와 높이가 동일해야 한다. 따라서 본 논문에서는 영상의 좌우 여백을 제거하고 필요한 영역에 대하여 너비와 높이를 동일하게 잘라내기 위한 전처리 과정을 수행하였다. 우선 수집된 low energy 영상의 크기를 고려하여 학습에 사용할 영상의 크기를 가로 및 세로축 모두 510 픽셀로 결정하였다. 전처리 과정은 영상의 모든 세로축의 좌표들을 대상으로 수평방향에 대한 라인 프로파일(Line Profile)을 설정하고 좌측에서 우측방향으로 검사하여 그레이 값의 기울기가 급격히 높아지는 x축의 위치를 찾았다(Fig. 2). 그리고 찾아진 모든 x축의 위치들 중에서 가장 큰 값을 가지는 위치를 시작으로 510 픽셀 크기의 영역을 잘라내었고, y축은 0 으로부터 510 픽셀 크기의 영역으로 잘라내었다. 또한 잘라낸 영상은 8비트의 픽셀 값(256 그레이 컬러)으로 이산화(Discretization)하여 jpg 포맷의 영상으로 저장하였다.

2.4 합성곱 신경망 모델 학습

본 논문에서 합성곱 신경망은 Fig. 3과 같이 U-Net 모델을 사용하였다. U-Net 모델은 인코딩(Encoding)과 디코딩(Decoding) 단계를 skip connection을 통하여 다시 활용하는 구조로써, 네트워크를 이용하여 영상을 복원할 경우 원본 영상의 세부적인 영역까지 잃지 않고 복원이 가능하여 결과 영상의 품질이 우수한 장점이 있다[14-16]. 학습 환경은 배치 사이

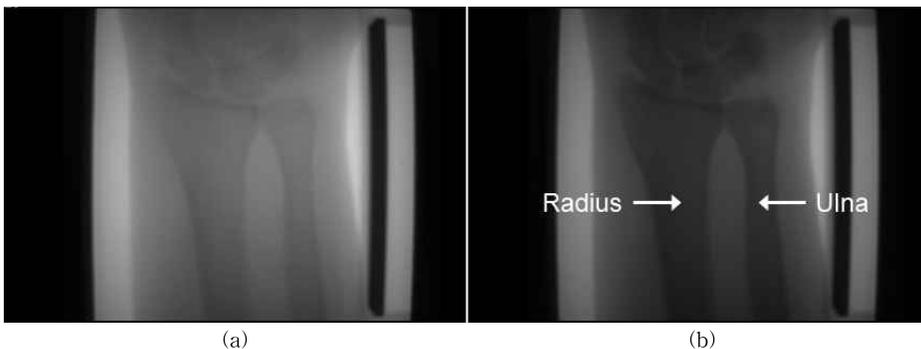


Fig. 1. Example of DEXA image (a) high energy image, (b) low energy image.

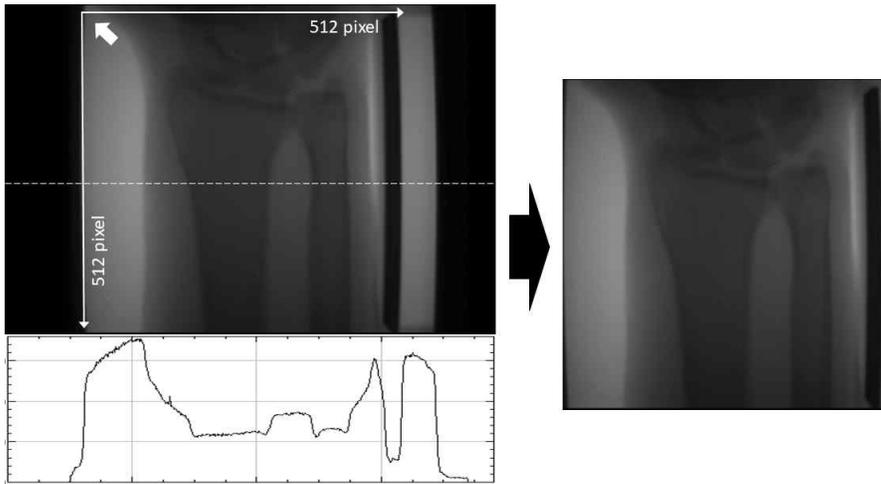


Fig. 2. Pre-processing process in low energy image. The position of the crop area was calculated using the line profile.

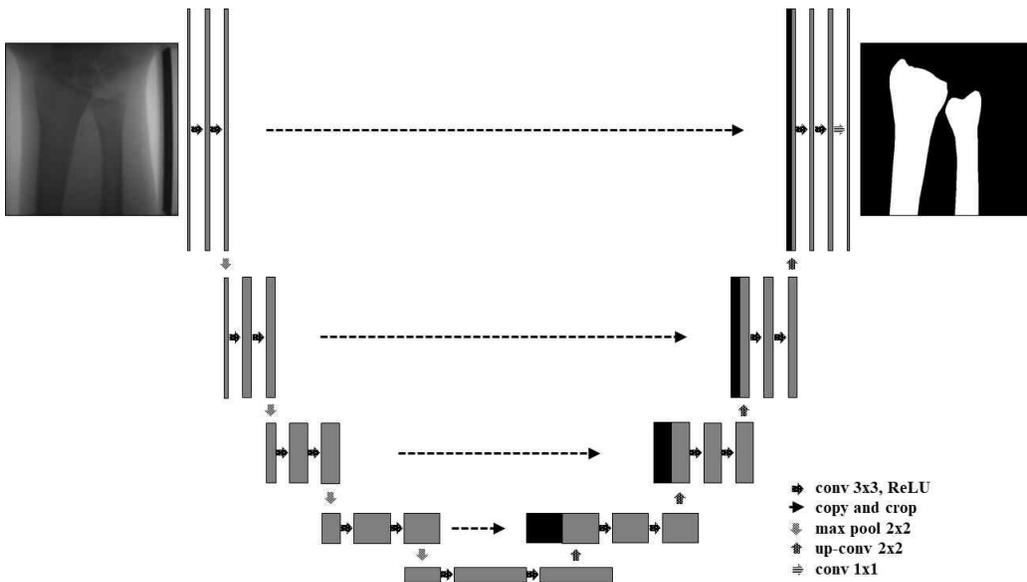


Fig. 3. U-net architecture consisted with convolutional encoding and decoding units.

스(Batch Size)는 8, 에폭(Epochs)은 400 으로 고정하고, 학습률(Learning Rate)은 0.001, 0.0001, 0.00001로 3종류로 다르게 설정하여 학습한 후, 학습 결과를 비교하여 최적의 학습률을 선정하고자 하였다.

2.5 후처리

본 논문에서 학습된 골 영역 분할 모델을 사용할 경우, 학습에 사용된 데이터들과 다른 조건으로 촬영

되거나 속성이 다른 일부 영상들에서는 정확한 검출이 어려울 수 있으며, 오검출된 영역이 발생할 수 있다. 본 논문에서는 합성곱 신경망을 통해 분할된 결과에서 오검출된 영역을 최소화하기 위해 후처리를 수행하였다. 후처리는 영상에서 분할된 각 영역들에 대해 영역 성장 알고리즘(Region Growing Algorithm)을 통해 레이블링(Labeling) 하였다[17]. 그리고 각 레이블들의 크기를 비교하여 전체 영상의 면적

대비 지정된 비율 이하의 크기를 가진 레이블들을 오검출로 판단하고 제거하였다(Fig. 4). 여기서 지정된 비율은 학습 데이터의 일부 영상에서 척골의 면적을 직접 측정하는 실험을 통해 5%로 결정하였다.

3. 결 과

본 논문에서는 합성곱 신경망을 이용하여 DEXA 영상에서 척골 및 요골을 대상으로 추출 모델을 학습

하였다. 학습된 모델의 성능을 검증하기 위해 검증 데이터를 대상으로 학습 모델에 적용하여 추출 결과를 확인하였다. Fig. 5에서는 검증 데이터에서 전문가가 수동으로 추출한 결과와 학습된 모델을 통해 자동으로 추출한 결과를 비교하여 보여준다.

본 논문에서는 학습된 척골 및 요골 추출 모델에 총 200개의 검증 데이터를 적용하고, 그 결과를 전문가가 수동으로 추출한 척골 및 요골의 영역과 비교

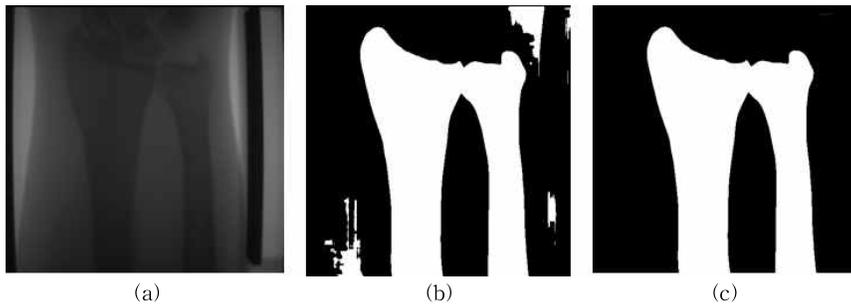


Fig. 4. Result of post-processing algorithm (a) original image, (b) False positive image, (c) Result image with post-processing.

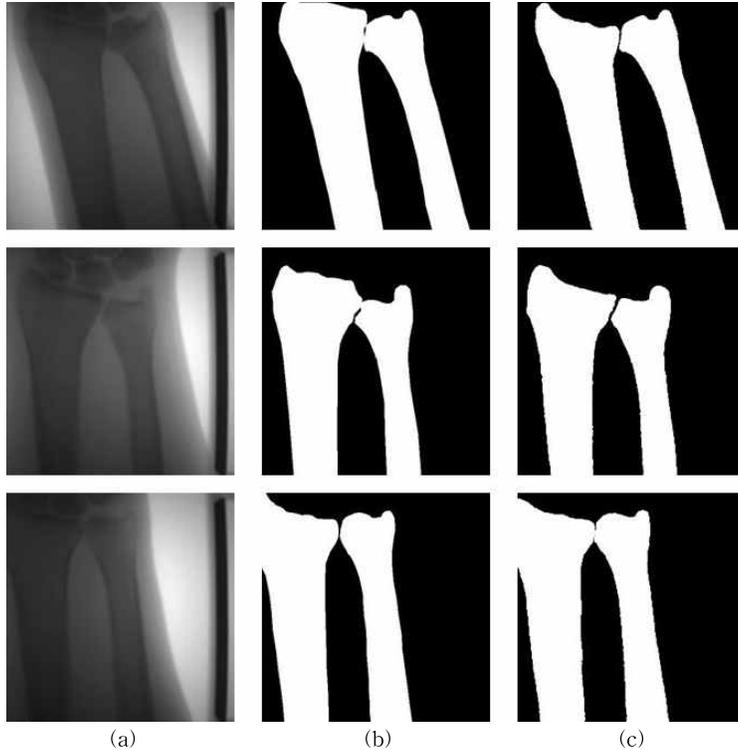


Fig. 5. Comparison of the segmentation results between the deep learning and manual. (a)original images, (b)manual segmentation results, (c)deep learning segmentation results.

및 통계적 분석을 통해 성능을 검증하고자 하였다. 학습 모델에 대한 성능은 민감도(Sensitivity), 특이도(Specificity), 정확도(Accuracy), 다이스 계수(Dice's Similarity Coefficient, DSC)의 4가지 조건부 확률(Conditional Probability)을 통해 검증하였다. 4개의 조건부 확률은 수동 및 딥러닝 방법을 통해 분할된 골 영역의 위치를 pixel by pixel로 비교하여 True Positive (TP), False Positive (FP), True Negative (TN), False Negative (FN)을 각각 산출하고, 아래의 수식에 따라 계산하였다. Table 1은 그 결과를 보여준다.

$$Sensitivity = \frac{TP}{TP + FN} \quad (1)$$

$$Specificity = \frac{TN}{FP + TN} \quad (2)$$

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

$$DSC = 2 \frac{TP}{(TP + FP) + (TP + FN)} \quad (4)$$

검증 데이터를 대상으로 학습 모델을 통해 분할된 결과와 수동 분할 결과 간에 조건부 확률을 계산한

결과, 학습률을 0.0001로 학습하였을 때 민감도는 0.961, 특이도는 0.978, 정확도는 0.972, 다이스계수는 0.961로 가장 우수한 결과를 보였다. 또한 학습 데이터를 대상으로 학습 모델에 적용한 결과에서도 학습률을 0.0001로 학습하였을 때 민감도는 0.998, 특이도는 0.972, 정확도는 0.979, 다이스 계수는 0.961로 가장 우수한 결과를 보였다. 검증 데이터에서 민감도가 학습률 0.001에서 0.976, 학습률 0.00001에서 0.971로 학습률 0.0001에서의 0.961보다 우수한 성능을 보였으나 특이도(학습률 0.001: 0.934, 학습률 0.00001: 0.963), 정확도(학습률 0.001: 0.950, 학습률 0.00001: 0.965), 다이스계수(학습률 0.001: 0.933, 학습률 0.00001: 0.953) 모두에서 학습률 0.0001에서보다 낮은 성능을 보였다.

본 논문에서는 가장 우수한 성능을 보인 학습률 0.0001에서의 결과를 기반으로 수동 분할 결과와 학습 모델을 통해 분할된 결과에 대해 면적을 각각 계산하고, Table 2와 같이 독립표본 t-test와 Bland Altman-plots, Intra-class Correlation Coefficient (ICC)를 통해 각 면적 간에 비교 분석하였다. 학습 데이터에서 수동으로 분할한 면적과 학습 모델로 분

Table 1. Conditional probability results of the trained segmentation model.

	Sensitivity	Specificity	Accuracy	DSC
Learning Rate : 0.001				
Train Data	0.996	0.932	0.952	0.927
Validation Data	0.976	0.934	0.950	0.933
Learning Rate : 0.0001				
Train Data	0.998	0.972	0.979	0.968
Validation Data	0.961	0.978	0.972	0.961
Learning Rate : 0.00001				
Train Data	0.993	0.956	0.967	0.948
Validation Data	0.971	0.963	0.965	0.953

Table 2. Verification and comparison of the deep learning and manual area measurements

		Mean±Stdev	t	p-value*	ICC	p-value**
Train Data	Manual	94248.04±12995.96	0.998	0.972	0.979	0.968
	CNN	94185.24±12828.87				
Validation Data	Manual	80437.96±13674.71	0.961	0.978	0.972	0.961
	CNN	85333.36±13674.76				

* p-value for independent t-test

** p-value for ICC

할한 면적이 각각 평균 94248.04 ± 12995.96 , 94185.24 ± 12828.87 였으며, 검증 데이터에서 수동으로 분할한 면적과 학습 모델로 분할한 면적은 각각 평균 80437.96 ± 13674.71 , 85333.36 ± 13674.76 이었다. 학습 데이터($r=0.981$, $p<0.001$)와 검증 데이터($r=0.975$, $p<0.001$) 모두 측정된 면적에 대하여 유의한 상관관계를 보였다(Fig. 6). 수동으로 분할한 면적과 학습 모델로 분할한 면적간에 차이를 비교하기 위해 수행한 독립표본 t-test 분석에서는 학습 데이터($p=0.752$)와 검증 데이터($p=0.927$) 모두에서 면적 간에 차이를 보이지 않았다. 또한 Bland Altman-plots 분석에서 학습 데이터와 검증 데이터 모두 대부분의 값들이 각 면적 차이의 평균에서 ± 1.96 표준편차 내에 위치하여 좋은 동등성(Comparability)을 보였다(Fig. 7).

ICC는 학습 데이터에서 0.99 (CI: 0.989~0.992, $p<0.001$), 검증 데이터에서 0.987 (CI: 0.983~0.990, $p<0.001$)로 나타나 각각의 측정된 면적들 간에 높은 신뢰도를 보였다.

4. 고 찰

본 논문에서는 DEXA 영상에서 합성곱 신경망을 이용하여 척골 및 요골의 분할을 위한 모델을 학습하고, 수동으로 분할한 결과와 비교 분석을 통해 모델의 성능을 검증하고자 하였다. 그 결과, 육안으로 평가시, 별도의 전처리 과정 없이도 영상에서 발생하는 gradient에 대한 영향을 받지 않았으며, 세밀한 결과를 보였다. pixel by pixel로 비교한 조건부 확률에서도 3종류의 학습률에서 각각 학습하고 그 결과를 비

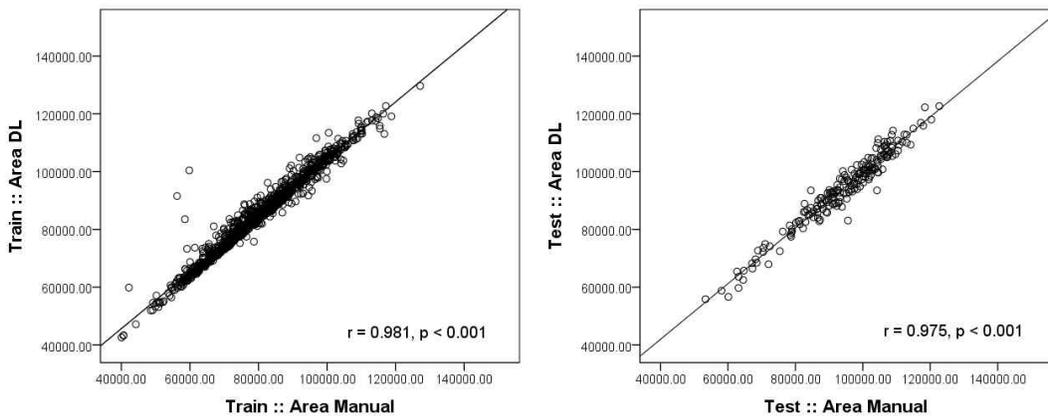


Fig. 6. Scatter plots comparing the manual and the DL area measurements. (a) Manual and Deep Learning in Train data, (b) Manual and Deep Learning in Test data.

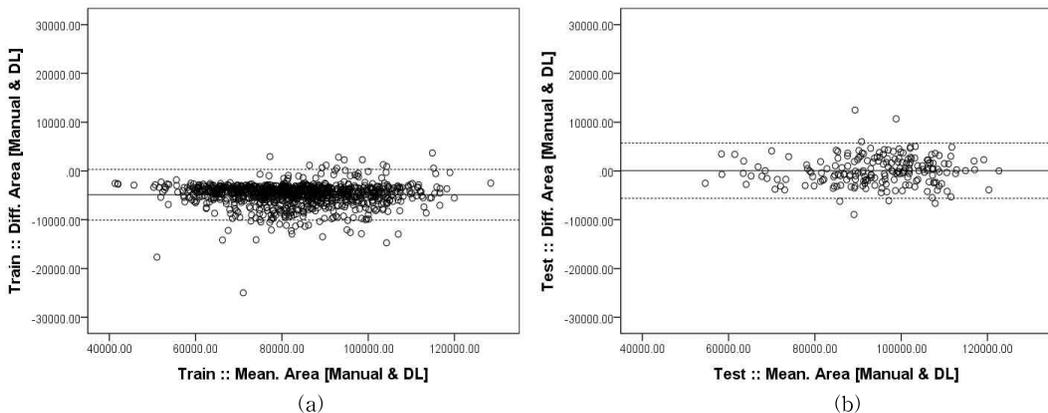


Fig. 7. Bland-Altman plots comparing the manual and the DL area measurements. (a) Manual and Deep Learning in Train data, (b) Manual and Deep Learning in Test data.

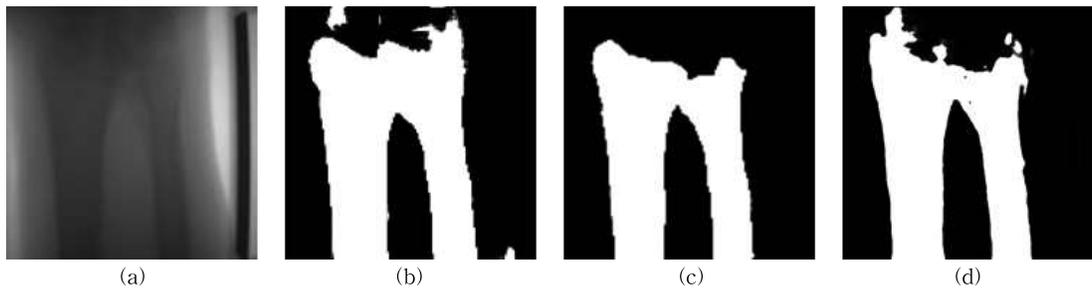


Fig. 8. Comparison of results according to learning rate (a)original image, (b)result by learning rate 0.001, (c)result by learning rate 0.0001, (d)result by learning rate 0.00001

교한 결과, 전체적으로 우수한 성능을 보였다. 그중에서도 학습률 0.0001로 학습한 경우, 검증 데이터에서 0.961의 민감도와 0.961의 디스 계수로 가장 우수한 성능의 분할 결과를 보였다. 비록 학습률 0.001과 0.00001에서 학습하였을 때 민감도가 소폭 향상하기는 하였으나 특이도에서 성능이 떨어졌으며, 이러한 결과는 오검출된 결과가 많다는 것으로 해석할 수 있다. Fig. 8에서는 동일한 데이터에 대하여 각 학습률에서의 결과를 비교하여 보여주고 있으며, 학습률 0.001과 0.00001에서의 결과가 학습률 0.0001에서의 결과와 달리 골 영역 주변에 많은 오검출이 발생한 것을 확인할 수 있다.

또한 가장 우수한 성능을 보인 학습률 0.0001에서의 결과에서 모델에 의한 분할 결과와 수동으로 분할한 결과 각각에서의 면적을 계산하고 독립표본 t -test에 의한 면적의 크기 비교에서도 차이가 없는 것으로 나타났으며, ICC도 0.972로 두 결과가 매우 유사한 것으로 나타났다. 이러한 분석 결과들을 고려하였을 때 딥러닝 기술이 DEXA 영상에서 척골 및 요골을 분할하는데 매우 유용하게 사용될 수 있다는 것을 확인할 수 있었다.

본 논문에서 학습한 분할 모델을 통해 검증한 결과는 대부분 정확하고 세밀한 결과를 보였다. 다만 극소수의 일부 데이터에서 온전한 뼈의 형태를 갖추지 않은 상태에서 분할된 결과를 보였다. 이러한 데이터들은 원본 영상이 대부분의 데이터들과는 촬영 환경이 조금 달랐으나 이에 대한 학습 데이터가 부족했기 때문인 것으로 판단된다. 또한 분할하고자 하는 뼈의 형태가 다소 복잡하지 않은 형태이고 주변 조직들 또한 육안으로도 어렵지 않게 구분이 가능하기 때문에 840장의 다소 적은 데이터로도 좋은 결과를 얻을 수 있었으나 딥러닝 모델을 학습하기에는 충분

치 않은 양으로 판단된다. 따라서 기존보다 다양한 촬영 환경에서 수집된 영상들을 추가적으로 수집하고, 강화학습을 통해 모델을 일반화(Generalization)할 필요가 있다. 또한 현재의 후처리 과정에서는 오검출된 영역만 제거하고 있으나 미검출된 영역까지 보정할 수 있도록 추가적인 연구가 필요하다.

결론적으로, 합성곱 신경망을 통해 학습된 분할 모델을 통해 척골과 요골을 분할하는 모델을 학습하고 검증한 결과, 매우 우수한 분할 결과를 확인하였으며, 향후 분할 모델의 일반화를 위한 추가 학습과 개선을 위한 추가적인 연구가 이루어진다면 더 정확한 분할 결과를 얻을 수 있을 것이며, 골밀도 측정 장비에 분할 모델을 연동시킨다면 골밀도 측정의 정확성과 신뢰성을 높이는 데 많은 도움을 줄 수 있을 것으로 기대된다.

REFERENCE

- [1] J.A. Kanis, "Assessment of Fracture Risk and Its Application to Screening for Postmenopausal Osteoporosis: Synopsis of a WHO Report," *Osteoporosis International*, Vol. 4, No. 6, pp. 368-381, 1994.
- [2] A. Klibanski, L. Adams-campbell, T. Bassford, S.N. Blair, S.D. Boden, K. Dickersin et al., "Osteoporosis Prevention, Diagnosis, and Therapy," *Journal of the American Medical Association*, Vol. 285, No. 6, pp. 785-95, 2001.
- [3] E. Hernlund, A. Svedbom, M. Ivergard, J. Compston, C. Cooper, J. Stenmark, et al., "Osteoporosis in the European Union: Medical Management, Epidemiology and Economic Burden," *Archives of Osteoporos*, Vol. 8, No.

- 1-2, pp. 136, 2013.
- [4] J.W. Kwon, S.I. Cho, Y.B. Ahn, and Y.M. Ro, "Bone Region Extraction by Dual Energy X-ray Absorbption Image Decomposition," *Journal of Korea Multimed Society*, Vol. 12, No. 9, pp. 1233-1241, 2009.
- [5] N.B. Watts, E.M. Lewiecki, P.D. Miller, and S. Baim, "National Osteoporosis Foundation 2008 Clinician's Guide to Prevention and Treatment of Osteoporosis and the World Health Organization Fracture Risk Assessment Tool (FRAX): What They Mean to the Bone Densitometrist and Bone Technologist," *Journal of Clinical Densitometry*, Vol. 11, No. 4, pp. 473-477, 2008.
- [6] R. Michael and M. Clung, "Prevention and Management of Osteoporosis," *Best Practice and Research: Clinical Endocrinology and Metabolism*, Vol. 17, No. 1, pp. 53-71, 2003.
- [7] V. Rebuffel and J. Dinten, "Dual-energy X-ray Imaging?: Benefits and Limits," *Insight-non-destructive Testing and Condition Monitoring*, Vol. 49, No. 10, pp. 589-594, 2006.
- [8] C. Njeh and D. Hans, *The Evaluation of Osteoporosis?: Dual Energy X-ray Absorptiometry and Ultrasound in Clinical Practice*, Martin Dunitz Publishers, London, 1999.
- [9] A. Krizhevsky, I. Sutskever, and G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Proceeding of International Conference on Neural Information Processing Systems*, pp. 1-9, 2012.
- [10] H.C. Shin, H.R. Roth, M. Gao, L. Lu, Z. Xu, I. Nogues, et al., "Deep Convolutional Neural Networks for Computer-aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning," *IEEE Transactions on Medical Imaging*, Vol. 35, No. 5, pp. 1285-1298, 2017.
- [11] A. Raj, S. Vishwanathan, B. Ajani, K. Krishnan, and H. Agarwal, "Automatic Knee Cartilage Segmentation Using Fully Volumetric Convolutional Neural Networks for Evaluation of Osteoarthritis," *Proceeding of IEEE International Symposium on Biomedical Imaging*, pp. 851-854, 2018.
- [12] M. Havaei, A. Davy, D. Warde-farley, A. Biard, A. Courville, Y. Bengio, et al., "Brain Tumor Segmentation with Deep Neural Networks," *Medical Image Analysis*, Vol. 35, pp. 18-31, 2017.
- [13] A. Kalinovsky and V. Kovalev, "Lung Image Segmentation Using Deep Learning Methods and Convolutional Neural Networks Lung Image Segmentation Using Deep Learning Methods and Convolutional Neural Networks," *Proceeding of International Conference on Pattern Recognition and Information Processing*, pp. 21-24, 2016.
- [14] B. Norman, V. Pedoia, and S. Majumdar, "Use of 2D U-net Convolutional Neural Networks for Automated Cartilage and Meniscus Segmentation of Knee MR Imaging Data to Determine Relaxometry and Morphometry," *Radiology*, Vol. 288, No. 1, pp. 177-185, 2018.
- [15] O. Cicek, A. Abdulkadir, S.S. Lienkamp, T. Brox, and O. Ronneberger, "3D U-net: Learning Dense Volumetric Segmentation from Sparse Annotation," *Proceeding of International Conference on Medical Image Computing and Computer-assisted Intervention*, pp. 424-432, 2016.
- [16] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional Networks for Biomedical Image Segmentation," *Proceeding of International Conference on Medical Image Computing and Computer-assisted Intervention*, pp. 1-8, 2015.
- [17] R. Sharma and R. Sharma, "Image Segmentation Using Morphological Operation for Automatic Region Growing," *International Journal of Innovative Research in Computer and Communication Engineering*, Vol. 4, No. 6, pp. 5686-5692, 2014.



김 영 재

2007년 2월 남서울대학교 컴퓨터
학과(학사)
2013년 2월 광운대학교 플라즈마
바이오디스플레이학과
(공학석사)
2018년 2월 광운대학교 플라즈마
바이오디스플레이학과
(공학박사)

2009년 2월~2017년 4월 국립암센터 의공학연구과
2017년 5월~현재 가천대학교 의과대학 의공학교실 연
구교수
관심분야: 의료영상, 인공지능, 3D 디스플레이



박 성 진

2015년 8월 경희대학교 전자전파
공학과(학사)
2018년 1월~현재 가천대학교 의
공학교실
관심분야: 의료영상, 의료정보,
인공지능, 데이터 분석



김 경 래

2013년 3월~현재 가천대학교 의
용생체공학과(학사)
관심분야: 의료영상, 머신러닝,
빅 데이터



김 광 기

1996년 2월 안동대학교 물리학과
(학사)
1998년 2월 포항공과대학교 물리
학과(이학석사)
2005년 2월 서울대학교 의용공학
과(공학박사)

2007년 7월~2017년 1월 국립암센터 의공학연구과
2017년 2월~현재 가천대학교 의용생체공학과 교수
관심분야: 의료영상, 의료정보, 인공지능, 로봇