

손목 관절 단순 방사선 영상에서 딥 러닝을 이용한 전후방 및 측면 영상 분류와 요골 영역 분할

이기표¹ · 김영재^{1,2,3} · 이상림^{4*} · 김광기^{1,2,3,5*}

¹가천대학교 보건과학대학 의용생체공학과, ²가천대학교 의과대학 의공학교실

³가천대학교 길병원 의료기기 R&D센터, ⁴인제대학교 상계백병원 정형외과

⁵가천대학교 융합의학과 대학원

Classification of Anteroposterior/Lateral Images and Segmentation of the Radius Using Deep Learning in Wrist X-rays Images

Gi Pyo Lee¹, Young Jae Kim^{1,2,3}, Sanglim Lee^{4*} and Kwang Gi Kim^{1,2,3,5*}

¹Department of Biomedical Engineering, College of Health Science, Gachon University

²Department of Biomedical Engineering, College of Medicine, Gachon University

³Medical Device R&D Center, Gachon University Gil Hospital

⁴Department of Orthopedic Surgery, Inje University Sanggye Paik Hospital

⁵Department of Health Sciences and Technology, Gachon Advanced Institute for Health Sciences
and Technology (GAIHST), Gachon University

(Manuscript received 29 January 2020 ; revised 13 April 2020 ; accepted 13 April 2020)

Abstract: The purpose of this study was to present the models for classifying the wrist X-ray images by types and for segmenting the radius automatically in each image using deep learning and to verify the learned models. The data were a total of 904 wrist X-rays with the distal radius fracture, consisting of 472 anteroposterior (AP) and 432 lateral images. The learning model was the ResNet50 model for AP/lateral image classification, and the U-Net model for segmentation of the radius. In the model for AP/lateral image classification, 100.0% was showed in precision, recall, and F1 score and area under curve (AUC) was 1.0. The model for segmentation of the radius showed an accuracy of 99.46%, a sensitivity of 89.68%, a specificity of 99.72%, and a Dice similarity coefficient of 90.05% in AP images and an accuracy of 99.37%, a sensitivity of 88.65%, a specificity of 99.69%, and a Dice similarity coefficient of 86.05% in lateral images. The model for AP/lateral classification and the segmentation model of the radius learned through deep learning showed favorable performances to expect clinical application.

Key words: Distal radius fractures, Deep learning, Classification, Segmentation, X-rays

Corresponding Author : Kwang Gi Kim
38-13, Dokjeom-ro 3beon-gil, Namdong-gu, Incheon, Republic
of Korea
Tel: +82-32-458-2770
E-mail: kimkg@gachon.ac.kr
Corresponding Author : Sanglim Lee
1342, Dongil-ro, Nowon-gu, Seoul, Republic of Korea
Tel: +82-2-950-1032, 1027
E-mail: slee4hand@gmail.com

본 연구는 “가천대학교 교내미래혁신 과제(2019-0669)”와 “과학기술
정보통신부 정보통신기획평가원의 대학 ICT연구센터육성지원사업
(IITP-2019-2017-0-01630)”, “한국연구재단(NRF-2016R1A2B1013761)”
의 연구결과로 수행되었음.

I. 서 론

원위 요골 골절은 16세 이하의 소아 및 청소년에서 가장
많이 나타나는 골절이며, 또한 60~70세 사이의 여성에게도
많이 발생한다[1,2]. 건강보험심사평가원에 따르면 국내에서
2016년부터 2018년까지 원위 요골 골절로 치료하는 환자
수가 증가하고 있으며, 2018년에는 총 175,522명의 환자가
발생했다[3].

원위 요골 골절은 관절면 침범이나 분쇄 골절 등에 대한 정확
한 진단을 위해서는 전산화 단층촬영(Computed Tomography,

CT)이 필요하며, 인대 손상이나 동반된 신경의 이상 또는 혈관의 이상을 진단하기 위해서 자기 공명 영상(Magnetic Resonance Imaging, MRI)이 필요할 수도 있으나, 우선적으로 기본적인 진단을 위해서는 전후방(anteroposterior) 및 측면(lateral) 손목 관절 방사선 영상이 필수적이다. 전후방 영상은 환자의 팔꿈치를 90° 만큼 구부리고, 손바닥 면이 바닥에 닿도록 하여 촬영하며, 측면 영상은 환자의 척골(ulna) 면이 바닥에 닿도록 엄지 손가락을 위를 향하게 하여 촬영한다[4].

원위 요골 골절을 판단하는데 있어 단순 방사선 검사는 다중 검출 전산화 단층 촬영(Multidetector CT, MDCT)에서 보다 정확성이 떨어지며[5], 응급의학과 전공의가 원위 요골 골절 유무를 X-ray 검사로 판단한 경우의 정확도는 약 72%로 경험이 적은 임상 의사는 단순 방사선 영상만을 이용하여 원위 요골 골절을 판단하기는 어려울 수 있다[6].

이러한 한계를 극복하기 위해 최근에는 컴퓨터 보조 진단(Computer-Aided Diagnosis, CAD)에 대한 연구가 하드웨어 기술의 발달, 인공지능망 모델의 발달 등으로 활발하게 연구되고 활용되고 있다. 특히 딥 러닝(deep learning) 기술은 1970년대에 소개되었으나 느린 속도, 과적합 문제 등의 문제로 개발의 속도가 늦어지고 임상 적용에 어려움이 있었지만, 그래픽 처리 장치(Graphics Processing Unit, GPU)의 발달과 빅 데이터(big data)의 수집으로 관련 연구들이 활발히 진행되고 있다[7]. 특히, 의료 영상 분야에서 무릎 연골 분할[8], 망막 혈관 분할[9], DEXA에서 척골 및 요골 자동 분할[10] 등의 연구 결과들이 보고되고 있다. 2018년 Raj 등은 U-Net 모델을 이용하여 무릎 연골을 분할하고자 하였다. 그들은 대퇴부 연골(femoral cartilage)은 84.9%, 경골 연골(tibial cartilage)은 83.2%, 슬개 연골(patellar cartilage)은 78.5%의 다이슨 계수를 보였다[8]. 2018년 Kim 등은 U-Net 모델을 통해 DEXA 영상에서 척골 및 요골을 분할하고자 하였다. 그 결과 학습률(learning rate)을 0.0001로 학습하였을 때, 96.1%의 민감도와 96.1%의 다이슨 계수로 가장 우수한 성능의 분할 결과를 보였다[10]. 2017년 Attia 등은 수술 영상에서 수술 도구를 실시간으로 분할하고자 하였다. 그들은 학습 검증을 위해 4개의 15초 비디오, 2개의 60초 비디오 데이터를 사용하여 93.3%의 정확도와 82.7%의 IoU(Intersection over Union)를 나타냈다[11].

원위 요골 골절의 정도를 판단하는 요측 경사각과 전방 경사각을 측정하기 위해서는 전후방 및 측면 영상의 분류가 우선되어야 하며, X-ray 영상에서 요골 영역을 정확하게 분할하는 것이 중요하다. 그러나 X-ray 영상에서 요골의 간부의 피질골은 경계가 뚜렷하게 관찰되지만, 요골 원위로 가는 경우 피질골이 얇아져서 경계가 불분명해지고, 특히 골다공증이 있는 고령의 환자에서 골절이 있는 경우에는 뼈의 경계가

정확하게 구분이 가지 않는 경우가 있다. 또한 측면 영상에서는 요골과 척골이 겹쳐져 나타나기 때문에 요골 영역만 정확히 분할하기가 어렵다. 이로 인해 요측 경사각과 전방 경사각의 측정 결과가 측정한 임상 의에 따라 오차가 존재한다[12-14]. 이러한 오차를 해결하기 위해 영상 처리 기법, 딥 러닝과 같은 컴퓨터 알고리즘을 이용해 요골 영역을 자동으로 분할하는 방법이 필요하지만 X-ray 영상에서의 골 영역 분할 연구들은 대부분 영상 처리 기법을 활용하여 진행하였으며 딥 러닝을 활용한 골 영역 분할은 연구가 많지 않다.

이에 본 연구에서는 딥 러닝을 활용하여 손목 관절 X-ray 영상에서 전후방 및 측면 영상의 종류를 분류하고, 원위 요골 골절을 판단하기 위해 분류된 영상에 따라 자동으로 요골 영역을 분할하고자 하였다.

II. 재료 및 방법

1. 개발환경

본 논문에서는 전처리 과정을 위해 Python(version 3.7.3)을 사용하였다. 딥 러닝 학습을 위한 시스템은 Intel Xeon E5-2630 v4(Intel, Santa Clara, CA, USA), NVIDIA TESLA P40(NVIDIA, Santa Clara, CA, USA), Tensorflow 1.13.1, Keras 2.2.4 with Tensorflow Backend를 사용하였다.

2. 데이터

본 연구에서는 전후방 472장과 측면 432장의 총 904장의 원위 요골 골절이 있는 손목 관절 X-ray 영상을 수집하였다. 전후방/측면 영상 분류 학습의 경우, 579장은 학습 데이터(training data), 145장은 학습 과정에서 성능을 검증하는 검증 데이터(validation data), 180장은 최종적으로 성능을 검증하는 테스트 데이터(test data)로 사용되었다. 요골 영역 분할 학습의 경우, 472장의 전후방 영상과 432장의 측면 영상을 수집하였으며, 수집된 영상에 대해 전문가가 직접 Image J(NIH, Bethesda, MD, USA)를 이용하여[15] 수동으로 요골 영역을 annotation하여 ground truth 이미지를 만들었다(그림 1). Ground truth 이미지는 마스크 이미지로 사용되며, 정답 영상으로써 모델 학습과 검증 과정에 사용되었다. 전후방 영상의 경우 472장 중 301장의 학습 데이터, 76장의 검증 데이터, 95장의 테스트 데이터를 사용했으며, 측면 영상의 경우 432장 중 277장의 학습 데이터, 70장의 검증 데이터, 85장의 테스트 데이터가 사용되었다.

3. 전처리

합성곱 신경망을 이용한 딥 러닝 학습을 위해서는 입력 및 출력 영상의 가로, 세로 크기가 같아야 한다. 따라서 본 연구에서는 원래 영상에 가로, 세로 크기의 차이만큼 원본




그림 1. 요골 영역에 대한 annotation 이미지 a) 원본 이미지, b) ground truth 이미지, c) 오버레이드 이미지
Fig. 1. Annotation image for the radius. a) Original images, b) Ground truth images, c) Overlaid images

이미지에 빈 이미지를 붙여 가로, 세로의 크기가 같아지도록 만든 후, 가로 1024 픽셀, 세로 1024 픽셀로 크기를 조정(resize)하였다.

4. 모델

본 연구에서는 전후방/측면 영상 분류 학습에서는 ResNet50 모델을, 요골 영역 분할 학습에서는 U-Net 모델을 사용하였다.

ResNet50 모델의 층(layer)는 3×3 크기의 필터를 가지며, 동일한 특징 맵(feature map)에서는 동일한 필터 수를 가지고, 특징 맵의 크기가 1/2로 줄어들면 필터의 수는 2배로 증가한다. 이 모델은 잔여 학습 블록(residual learning block)을 이용해 shortcut connection을 만들어 깊은 층을 쌓아 학습할 수 있도록 하였다. Shortcut connection은 하나 이상의 층을 건너뛰는 연결로 추가 파라미터(parameter)나 계산상의 복잡성을 추가하지 않았다[16,17](그림 2). 본 연구에서의 학습 환경은 데이터 증식(data augmentation)은 적용하지

않았고, 옵티마이저(optimizer)는 SGD, 배치 사이즈(batch size)는 4, 학습률(learning rate)은 0.0001, 모멘텀(momentum)은 0.9, 에폭(epoch)은 100으로 설정하여 학습을 진행하였다.

U-Net 모델은 contracting path(왼쪽)와 expansive path(오른쪽)로 구성되어 있다. contracting path에서 각 convolution network에서는 두 번의 3×3 convolution을 사용하며 활성화 함수로는 ReLU가 사용된다. 각 pooling 계층에서는 2×2 max pooling이 사용되어 1/2로 down sampling되며, 채널 수는 2배씩 늘어난다. expansive path에서는 2×2 up-convolution이 사용되고, contracting path의 crop한 데이터와 결합하여 두 번의 3×3 convolution이 사용된다[18](그림 3). 본 연구에서의 학습 환경은 데이터 증식은 적용하지 않았으며, 옵티마이저는 아담(Adam), 배치 사이즈는 4, 학습률은 0.001, 에폭은 100으로 설정하여 학습을 진행하였다.

5. 평가

본 연구에서는 혼동 행렬(confusion matrix)을 이용하여 전후방/측면 영상 분류 학습 모델과 요골 영역 분할 학습 모델의 성능을 검증하였다. 혼동 행렬은 예측 값과 정답 값의 일치 여부를 행렬로 분류하는 평가 기법으로, 정확도(accuracy), 민감도(sensitivity), 특이도(specificity), 정밀도(precision), 재현율(recall), F1 score, 다이스 유사계수(Dice similarity coefficient, DSC) 등의 성능 평가 지표를 이용하여 모델의 성능을 검증한다. 전후방/측면 영상 분류 학습에서는 x축은 1-특이도, y축은 민감도로 하여 이진분류 모델의 예측 정확도를 평가하는 receiver operating characteristic(ROC) 분석과 ROC 커브의 아래 면적을 의미하는 area under curve(AUC)를 사용하였으며, AUC는 1에 가까울수록 모델의 성능이 좋다는 것을 의미한다. 또한 요골 영역 분할 학습에서는 두 가지 방법으로 측정된 값 사이의 유사도를 정량적으로 나타내기 위해, X축은 두 방법으로 측정된 값의 평균을 나타내고, Y축은 두 측정값의 차이를 나타내는 Bland-Altman plot를 사용하였다[19]. Y축 참고선 중 점선은 측정된 값의 평균을 나타내고, 두 개의 실선은 평균에서 표준편차의 1.96%를 곱한 값을 더하고 뺀 값을 나타내며, 두 실선 사이는 95% 신뢰구간이 되며, 이 구간에 값이 위치하면 두 방법으로 측




그림 2. ResNet50 모델의 아키텍처
Fig. 2. The architecture of ResNet50 model




그림 3. U-Net 모델의 아키텍처

Fig. 3. The architecture of U-Net model

정한 값이 서로 유사하다고 할 수 있다.

III. 결 과

전후방/측면 영상 분류 학습의 성능은 95장의 전후방 영상과 85장의 측면 영상으로 구성된 총 180장의 영상으로 이루어진 테스트 데이터로 학습 모델의 성능을 확인하였다. 모델 성능은 혼동 행렬을 이용하였으며, 정밀도, 재현율, F1 score, AUC로 나타났다. 혼동 행렬에서 진양성(true positive, TP)는 전후방 영상을 전후방 영상으로 찾아낸 경우, 위양성(false positive, FP)는 전후방 영상을 측면 영상으로 찾아낸 경우, 위음성(false negative, FN)는 측면 영상을 전후방 영상으로 찾아낸 경우, 진음성(true negative, TN)는 측면 영상을 측면 영상으로 찾아낸 경우를 나타낸다. 정밀도, 재현율, F1 Score는 식 (1)~(3)을 통해 계산하였고, 그 결과는 표 1에 나타났다. 또한 ROC 분석을 통한 AUC는 1.0이었다.

$$\text{Precision} = \frac{TP}{TP+FP} \times 100 \quad (1)$$

$$\text{Recall} = \frac{TP}{TP+FN} \times 100 \quad (2)$$

표 1. 테스트 데이터에서의 전후방/측면 영상 분류 결과

Table 1. Result of classification of anteroposterior/lateral images in test data

	Precision [%]	Recall [%]	F1 Score [%]
Test data	100.0	100.0	100.0

$$\text{F1 Score} = \frac{TP}{TP + \frac{FN+FP}{2}} \times 100 \quad (3)$$

요골 영역 분할의 학습 성능을 검증하기 위해 분류 학습을 통해 분류된 전후방 영상(95장)과 측면 영상(85장)을 학습 모델에 적용하여 결과를 확인하였다. 전후방, 측면 영상에 따라 원본 이미지와 ground truth 이미지, 분할 결과 이미지, 원본 이미지에 분할 결과 이미지를 덮어쓴 오버레이드 이미지(overlayed image)를 각각 그림 4와 그림 5에 나타냈다.

학습 결과는 정확도, 민감도, 특이도, 다이스 유사계수의 4가지 척도로 비교하였다. Ground truth 이미지와 결과 이미지를 픽셀마다 각각 비교하여 혼동 행렬을 이용해 TP, FP, FN, TN를 각각 나타내고, 식 (4)~(7)에 따라 4가지의 척도를 계산하였다. 그 결과는 표 2에 나타났다.

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \times 100 \quad (4)$$

$$\text{Sensitivity} = \frac{TP}{TP+FN} \times 100 \quad (5)$$

$$\text{Specificity} = \frac{TN}{FP+TN} \times 100 \quad (6)$$

$$\text{DSC} = 2 \times \frac{TP}{(TP+TN)+(FP+FN)} \quad (7)$$

테스트 이미지를 대상으로, ground truth 이미지와 분할 학습 결과 이미지를 비교하여 계산한 결과, 전후방 영상을 학습하였을 때는 평균 정확도 99.46%, 평균 민감도 89.68%,




그림 4. 전후방 영상에서의 요골 영역 분할 결과. a) 원본 이미지, b) ground truth 이미지, c) 분할 결과 이미지, d) 오버레이드 이미지
Fig. 4. Result of segmentation of the radius in anteroposterior images. a) Original images, b) Ground truth images, c) Segmentation result images, d) Overlaid images




그림 5. 측면 영상에서의 요골 영역 분할 결과. a) 원본 이미지, b) ground truth 이미지, c) 분할 결과 이미지, d) 오버레이드 이미지
Fig. 5. Result of segmentation of the radius in lateral images. a) Original images, b) Ground truth images, c) Segmentation result images, d) Overlaid images

표 2. 전후방/측면 영상에서의 요골 영역 분할 결과

Table 2. Result of segmentation of the radius in anteroposterior (AP) and lateral images

	Accuracy [%]	Sensitivity [%]	Specificity [%]	DSC [%]
AP images	99.46	89.68	99.72	90.05
Lateral images	99.37	88.65	99.69	86.05

*DSC (Dice similarity coefficient)

평균 특이도 99.72%, 평균 다이스 유사계수 90.05%를 나타냈다. 측면 영상을 학습하였을 때는 평균 정확도 99.37%, 평균 민감도 88.65%, 평균 특이도 99.69%, 평균 다이스 유

사계수 86.05%를 나타냈다. 또한, 수동으로 분할한 영역과 학습 모델을 통해 분할한 영역의 면적을 계산하였으며, 계산한 면적을 비교한 Bland-Altman plot을 그림 6에 나타




그림 6. 수동으로 분할한 영역과 학습 모델을 통해 분할한 영역의 면적을 비교한 Bland-Altman plot 이미지. (a) 전후방 영상, (b) 측면 영상
Fig. 6. Bland-Altman plot comparing the areas of the manually segmented regions with the areas of the segmented regions through the learning model. (a) Anteroposterior (AP) images, (b) Lateral (LAT) images

냈다. 전후방 영상에서 95개 중 91개, 측면 영상에서는 85개 중 80개의 값들이 95% 신뢰구간 사이에 존재하였다. 이를 통해 두 방법으로 측정된 값이 서로 유사함을 알 수 있다.

IV. 고 찰

본 연구에서는 X-ray 영상에서 딥 러닝을 이용하여 전후방 영상과 측면 영상을 분류하고, 영상 종류에 따라 요골 영역 분할을 위한 학습 모델을 개발하였다.

전후방/측면 영상 분류 학습에 사용한 ResNet50 모델은 잔여 학습 블록을 통해 입력 X 가 레이어를 거치며 $F(x)$ 를 찾아내고 이에 입력 X 를 더함으로써 최적의 $F(x)+X$ 를 찾으며, 출력의 차이인 $F(x)$ 에 집중하여 학습한다. 이는 입력 X 에 대한 최적의 Y 값을 찾는 convolutional neural network (CNN)의 Y 값보다 $F(x)$ 의 값이 작아 깊은 레이어에서도 좋은 성능을 나타낸다. 전후방/측면 영상에서의 요골 영역 분할 학습에 사용된 U-Net 모델은 의료 영상 분할에 최적화된 신경망 모델로서 fully connected layer를 사용하지 않기 때문에 학습 속도가 빠르며, up-convolution 과정에서 convolution, max pooling 과정에서 사용된 신경망을 붙여 사용함으로써 차원 축소로 인해 발생하는 공간 정보 손실을 방지한다.

전후방/측면 영상 분류 학습 모델은 총 180장의 영상을 95개의 전후방 영상과 85개의 측면 영상으로 정확히 분류하여 정밀도, 재현율, F1 Score는 모두 100.0%, AUC는 1.0을 나타냈다. 전후방/측면 영상에서의 요골 영역 분할 학습의 결과는 전후방 영상에서 평균 정확도 99.46%, 평균 다이스 유사계수 90.05%로 나타났고, 측면 영상에서는 평균 정확도 99.37%, 평균 다이스 유사계수는 86.05%로 우수한 성능을

보였다.

상대적으로 측면 영상의 요골 영역 분할 학습 결과가 전후방 영상에서의 결과보다 낮은 성능을 보인 이유는 요골과 척골이 뚜렷하게 구별되는 전후방 영상과는 달리, 측면 영상에서는 요골과 척골이 겹쳐져 보이고 육안으로도 정확한 구분을 하기 어렵기 때문에 요골 영역만을 분할하는 것이 어려웠던 것으로 판단된다. 또한 요골 영역 분할 학습에 사용된 영상은 정상 손목 관절 영상이 아닌 원위 요골 골절을 가지고 있는 영상이기 때문에 심한 분쇄나 전위가 있는 영상에서는 요골이 하나의 뼈 형태를 보이지 않고 여러 조각으로 분할되어 있었고, 요골 골절의 근위부는 정확하게 분할했지만 골절 부위를 포함한 원위부를 잘 분할하지 못하거나 일부만 분할한 데이터가 존재하였기 때문이다. 심한 분쇄 골절이나 전위가 심한 경우에는 정상 위치에서 벗어난 위치에 존재하는 뼈 조각이 요골에서 기인한 것이라고 판단하는 것은 어려울 것이다. 이는 더 많은 데이터를 학습하여 이러한 극단적인 영상에 대한 학습이 충분히 이루어지면, 요골 골절 영상에서의 요골 분할 성능이 향상될 수 있을 것으로 판단된다.

본 연구의 제한점은 사용된 학습 데이터 수가 전후방 영상 472장, 측면 영상 432장으로 딥러닝 학습을 하기에는 충분하지 않다는 점이다. 따라서 데이터를 추가로 수집하거나 데이터 증강(data augmentation) 기법을 활용하여 추가 학습을 통해 학습 성능을 향상시키는 연구가 필요하다. 요골 골절을 확인하기 위한 손목 관절 방사선 검사에서는 전후방, 측면 영상뿐만 아니라 사방향(oblique)에서 촬영한 영상도 획득한다. 환자에 따라 골절로 인해 환자의 자세가 정확하지 않아 정확한 전후방, 측면 영상을 얻지 못하는 경우에는 사방향 영상을 통해 골절을 판단하게 된다. 이러한 점을 고려

하여 사방향 영상이나 부정확한 자세에서 촬영한 전후방, 측면 영상을 포함한 여러 상황에서의 불규칙한 영상들을 고려한 연구가 필요하다.

본 연구에서는 딥 러닝을 이용하여 학습된 영상 분류 모델과 요골 영역 분할 모델을 개발하고 학습 모델을 테스트 데이터를 이용하여 우수한 성능을 확인하였다. 향후 다양한 환경에서 촬영한 추가 데이터를 수집하여 추가 학습이 이루어진다면 더 정확한 요골 영역 분할 결과를 얻고, 요골 영역 분할 모델을 이용하여 원위 요골 골절 여부를 판단하는 컴퓨터 보조 진단 시스템을 개발해, 원위 요골 골절의 진단 및 골절의 전위 정도 등을 판단하여 원위 요골 골절의 진단 및 치료에 경험이 적은 임상 의사가 진단 및 치료 방법을 결정하는데 많은 도움을 줄 수 있을 것으로 기대된다.

References

- [1] Brudvik C, Hove LM. Childhood fractures in Bergen, Norway: identifying high-risk groups and activities. *J Pediatr Orthop*. 2003;23:629-34.
- [2] Owen RA, Melton LJ 3rd, Johnson KA, Ilstrup DM, Riggs BL. Incidence of Colles' fracture in a North American community. *Am J Public Health*. 1982;72:605-7.
- [3] http://www.wheelsonline.com/ortho/posterior_anterior_view_of_the_wrist. Accessed on 27 Oct 2019.
- [4] http://www.wheelsonline.com/ortho/posterior_anterior_view_of_the_wrist. Accessed on 27 Oct 2019.
- [5] Kiuru MJ, Haapamäki VV, Koivikko MP, Koskinen SK. Wrist injuries; diagnosis with multidetector CT. *Emerg Radiol*. 2004;10(4):182-5.
- [6] Cho SU, Yang JI, Han KH, Cho YC, Yoo IS, Kim SW, Lee JW, Ryu S, You YH, Han SG, Park SS, Jung WJ, Jung WJ, Lee WS. The Accuracy of a Simple Radiologic Study for Diagnosing Intra-articular Fractures of the Distal Radius. *J Korean Soc Emerg Med*. 2010;21(5):569-74.
- [7] Lee JG, Jun S, Cho YW, Lee H, Kim GB, Seo JB, Kim N. Deep Learning in Medical Imaging: General Overview. *Korean J Radiol*. 2017;18(4):570-84.
- [8] A. Raj, S. Vishwanathan, B. Ajani, K. Krishnan, H. Agarwal. Automatic knee cartilage segmentation using fully volumetric convolutional neural networks for evaluation of osteoarthritis. 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), Washington, DC. 2018; 851-4.
- [9] Kim BS, Lee IH. Retinal Blood Vessel Segmentation using Deep Learning. *Korean Institute of Information Technology*. 2019;17(5):77-82.
- [10] Kim YJ, Park SJ, Kim KR, Kim KG. Automated Ulna and Radius Segmentation model based on Deep Learning on DEXA. *Journal of Korea Multimedia Society*. 2018;21(12):1407-16.
- [11] DiBenedetto MR, Lubbers LM, Ruff ME, Nappi JF, Coleman CR. Quantification of error in measurement of radial inclination angle and radial-carpal distance. *J Hand Surg Am*. 1991;16(3):399-400.
- [12] Jafari D, Najd Mazhar F, Jalili A, Zare S, Hoseini Teshnizi S. The Inter and intraobserver reliability of measurements of the distal radius radiographic indices. *J. Res. Orthop. Sci.*. 2014; 1(2):22-5.
- [13] Hossain, M., Andrew, J.G. Reliability of a digital radiographic system in measuring distal radial fracture displacement parameters. *Eur J Orthop Surg Traumatol*. 2008;18:565-9.
- [14] M. Attia, M. Hossny, S. Nahavandi, and H. Asadi, Surgical tool segmentation using a hybrid deep CNN-RNN auto encoder-decoder. 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Banff, AB. 2017; 3373-78.
- [15] Schneider CA, Rasband WS, and Eliceiri KW. NIH Image to ImageJ: 25 years of image analysis. *Nature methods*. 2012; 9(7):671-5.
- [16] K. He, X. Zhang, S. Ren, J. Sun. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016; 770-8.
- [17] Park SJ, Kim YG, Park DK, Chung JW, Kim KG. Evaluation of Transfer Learning in Gastroscopy Image Classification using Convolutional Neural Network. *Journal of biomedical Engineering Research*. 2018;39(5):213-9.
- [18] O. Ronneberger, P. Fischer, T. Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation. *International Conference on Medical image computing and computer-assisted intervention*. 2015; 234-41.
- [19] D. Giavarina. Understanding Bland Altman analysis. *Biochemia medica*. 2015;25(2):141-51.