

척추의 중심점과 Modified U-Net을 활용한 딥러닝 기반 척추 자동 분할

임성주¹ · 김휘영^{1,2*}

¹연세대학교 의과대학 의생명시스템정보학과
²연세대학교 의과대학 의료영상데이터사이언스센터

Deep Learning-based Spine Segmentation Technique Using the Center Point of the Spine and Modified U-Net

Sungjoo Lim¹ and Hwiyoung Kim^{1,2*}

¹Department of Biomedical Systems Informatics, Yonsei University, Seoul 03722 Korea

²Center for Clinical Imaging Data Science, Yonsei University College of Medicine, Seoul 03722 Korea

(Manuscript received 11 April 2023 ; revised 20 April 2023 ; accepted 21 April 2023)

Abstract: Osteoporosis is a disease in which the risk of bone fractures increases due to a decrease in bone density caused by aging. Osteoporosis is diagnosed by measuring bone density in the total hip, femoral neck, and lumbar spine. To accurately measure bone density in the lumbar spine, the vertebral region must be segmented from the lumbar X-ray image. Deep learning-based automatic spinal segmentation methods can provide fast and precise information about the vertebral region. In this study, we used 695 lumbar spine images as training and test datasets for a deep learning segmentation model. We proposed a lumbar automatic segmentation model, CM-Net, which combines the center point of the spine and the modified U-Net network. As a result, the average Dice Similarity Coefficient(DSC) was 0.974, precision was 0.916, recall was 0.906, accuracy was 0.998, and Area under the Precision-Recall Curve (AUPRC) was 0.912. This study demonstrates a high-performance automatic segmentation model for lumbar X-ray images, which overcomes noise such as spinal fractures and implants. Furthermore, we can perform accurate measurement of bone density on lumbar X-ray images using an automatic segmentation methodology for the spine, which can prevent the risk of compression fractures at an early stage and improve the accuracy and efficiency of osteoporosis diagnosis.

Key words: X-ray image, Osteoporosis, Lumbar spine, Vertebra segmentation, U-Net

I. 서 론

인간의 척추는 크게 경추(cervical vertebrae), 흉추(thoracic vertebrae), 요추(lumbar vertebrae)로 구성된다. 경추는 뇌를 잇는 목 부분에 위치하며 C1부터 C7까지의 명칭으로 구분되어 있다. 흉추는 가슴 부분에 위치하며, T1부터 T12까지

12개의 척추로 이루어져 있다. 요추는 허리 부분에 위치하고 L1부터 L5까지의 명칭으로 구분되어 있다. 척추는 목, 등, 허리, 엉덩이, 그리고 꼬리 부분까지 이어지는 중요한 골격으로, 신체를 지탱하고 평형을 유지하며 척수를 보호한다. 이렇게 몸에서 중요한 역할을 하는 척추는 나이가 들면서 퇴행성 변화를 겪게 된다. 특히 골다공증(osteoporosis)은 고령화로 인해 골의 밀도가 낮아져서 골절 위험이 증가하는 질환이며, 골절로 인한 사망률도 증가하고 있다. 따라서 골다공증을 조기에 발견하고 예방하는 것이 중요하다. 골다공증은 대퇴골 총골, 대퇴골 경부, 요추의 골밀도(bone mineral density)를 측정하여 진단한다[1]. 여기서 요추의 골밀도를 측정하기 위해서는

*Corresponding Author : Hwiyoung Kim
Department of Biomedical Systems Informatics, Yonsei University, Seoul 03722 Korea, Center for Clinical Imaging Data Science, Yonsei University College of Medicine, Seoul 03722 Korea
Tel: +82-2-2228-7397
E-mail: HYKIM82@yuhs.ac

요추 X-ray 영상으로부터 척추 영역을 정확하게 분할해야 한다. 이때, 딥러닝 기반 척추 자동 분할 방법론을 이용한다면 전문가의 노력과 시간을 절약하면서 정확한 분석 결과를 얻을 수 있다.

또한, 척추 X-ray 영상에 대한 자동 분할은 분석적인 측면과 임상적인 측면에서 중요한 역할을 수행한다. 분석적인 측면에서는 딥러닝 기반 자동 분할을 이용하면, 수작업으로 진행되는 세밀한 분석 작업을 자동화할 수 있다. 이는 척추 X-ray 영상에서 중요한 구조물들을 자동으로 식별하고, 해당 구조물의 위치, 크기, 형태 등을 정확하게 추출하는 것을 의미한다. 또한, 수작업으로 X-ray 영상을 분석하는 경우, 사람마다 각각의 경험과 지식이 다르기 때문에, 결과에 대한 일관성이 떨어지거나 오류가 발생할 수 있다. 반면에 딥러닝 기반 자동 분할을 이용하면, 학습된 모델이 일관된 기준에 따라 분석을 수행하기 때문에 정확한 결과를 얻을 수 있다. 더불어, 딥러닝 기반 자동 분할을 이용하면, 대량의 척추 X-ray 영상 데이터셋을 빠르게 분석할 수 있으므로 대규모 연구를 효율적으로 수행할 수 있다. 이를 통해, 척추 질환의 진단, 치료 및 예방 등의 연구에 대한 인사이트를 얻을 수 있다. 다음으로, 임상적인 측면에서는 자동 분할을 통해 척추와 관련된 병변을 정확하게 분석하고 진단하여 환자의 건강 및 치료 계획 수립에 도움이 될 수 있다. 자동화 기술로 얻은 병변 정보를 통해 환자에게 적극적인 조치를 취하고 개인 맞춤형 치료를 제공할 수 있다. 이로써 척추 X-ray 영상에 대한 자동 분할 방법론 연구는 분석적인 측면과 임상적인 측면의 다양한 근거를 통해 필요성을 입증한다.

기존의 연구들을 통해 척추 X-ray 영상 자동 분할 기법에 대한 연구가 이루어졌다. Active Shape Model(ASM)은 이미지에서 객체의 위치와 모양을 추정하는 기술로, 척추 자동 분할 분야에서 활용되고 있다[2]. ASM를 이용하여 먼저 척추의 초기 형태 모델을 만든 다음, 해당 형태 모델과 이미지의 유사성을 기반으로 이미지에서 척추를 분할하는 연구가 있다[3]. 최근에는 딥러닝 기술을 이용한 분할 모델이 개발되었으며, U-Net, SegNet, FCN 등이 주로 사용되고 있다[4-6]. Kim DH 등은 U-Net과 ResNet을 기반으로 한 2개의 딥러닝 모델을 개발하여 분할된 척추 영상을 이용하여 척추 압박 골절 비율을 계산하였고, 이를 통해 Dice Similarity Coefficient(DSC)가 0.929를 기록하였다[7,8]. Kim KC 등은 척추 localization과 딥러닝 기술, Level Set 기술을 결합한 요추의 압박 골절을 평가하기 위한 분할 모델을 제안하였고, 이 방법은 160장의 요추 척추 X-ray 영상이 이용되었으며 평균 DSC는 0.916를 기록하였다[9].

기존 연구들은 일반 영상처리 방법 또는 딥러닝 방법론을 이용하여 척추 X-ray 영상에 대한 자동 분할 방법론을 제시하였다. 하지만 기존 연구들은 골다공증 연구에 대한 정보를

제공하는 데에는 몇 가지 문제점이 존재한다. 우선, 일부 논문에서는 작은 데이터셋으로 실험을 진행하여 일반화 성능이 충분하지 않은 경우가 있다. 또한, 자동 분할 방법론을 통해 예측된 척추 이미지가 골다공증 연구에 이용되기 위해서는 더 높은 정확도를 요구한다. 마지막으로, 척추 X-ray 영상에 존재하는 수술용 임플란트 또는 시멘트로 인해 척추 마디가 가려져 정확도를 저하시키는 문제가 있기 때문에 적절한 데이터셋을 확보하고 수술용 임플란트나 시멘트를 고려한 모델을 개발해야 한다. 이러한 한계점을 극복하기 위해 본 연구는 척추의 중심점과 modified U-Net 네트워크를 결합하는 요추 자동 분할 모델 CM-Net을 제시한다.

II. 본 론

1. 사용 데이터 및 전처리

VERTEX는 2007년부터 2020년까지 서울 세브란스 병원에서 촬영된 척추 측면 X-ray 영상 21,915건을 수집한 데이터셋이다. 그림 1에서 (a)가 흉추를 포함한 영상이고 (b)가 요추를 포함한 영상, (c)가 전체 척추체를 포함한 영상의 예시이다. 이 데이터셋은 압박 골절, 골 시멘트 및 척추 임플란트 등을 포함하고 있다. 본 연구는 세브란스 병원의 윤리심의위원회에서 승인을 받았으며, 의료기록 검토를 위한 서면동의면제(IRB no. 4-2021-0937)가 부여되었다. 요추 영상 분할을 위해 VERTEX 데이터셋의 요추 영상만 학습에 사용하였으며, 내분비학 전문가가 GE 제조사에서 촬영된 695장의 영상에서 L1-L5 척추를 수동으로 레이블링을 진행하였




그림 1. VERTEX 데이터셋 예시
Fig. 1. Example of VERTEX dataset

다. 모델 훈련, 검증 및 테스트 데이터셋은 모두 8:1:1 비율로 나누어 진행되었다.

이미지 전처리 단계에서는 픽셀 값을 0-255 범위 내에서 고르게 분포시키기 위해 히스토그램 평활화를 수행하였다. 또한, 이미지의 크기를 $1,024 \times 512$ 픽셀(높이 \times 너비)로 표준화하면서 종횡비를 유지하였다. 너비가 높이보다 큰 이미지의 경우 너비를 512 픽셀로 설정하고 높이를 이에 맞게 조정하고 이미지 바깥쪽 영역은 0으로 채워져 $1,024$ 픽셀 크기의 공간을 채우는 형식으로 진행하였다. 반대로, 높이가 너비보다 큰 이미지의 경우 높이를 $1,024$ 픽셀로 설정하고 해당 종횡비에 맞게 너비를 조정하였다.

2. 제안 모델

본 연구는 자동 척추 분할 모델의 정확도를 높이기 위해 두 가지의 모듈을 결합한 모델을 개발하였다. 제안된 모델은 의료 영상 분할 모델의 대표적인 네트워크인 U-Net을 베이스로 설계되었다. U-Net은 end-to-end 학습을 통해 전체 이미지를 분할한다. 이를 통해 지역적인 정보와 전체적인 정보를 동시에 학습할 수 있어서 분할 성능을 높일 수 있는 장점이 있다. 또한, U-Net은 이미지의 구조적인 정보를 잘 보존하면서도 분할 정확도가 높다는 장점이 있다.

하지만, 현재 사용하는 척추 데이터셋은 1024×512 픽셀의 크기이므로 네트워크의 깊이가 깊어져 학습이 어려워지는 문제점이 있다. 이러한 문제점을 보완하고자 modified U-Net을 기반으로 학습을 진행하였다[10]. Modified U-Net은 U-Net과 비슷한 구조를 가지지만 modified U-Net은 6개의 레벨을 가진 context pathway와 localization pathway로 이루어져 있다. Context pathway는 입력 이미지의 맥락

(context) 정보를 추출하는 부분으로, 입력 이미지의 주변 부분 정보를 통해 물체의 전반적인 형태나 배경 등의 정보를 파악할 수 있다. 이는 여러 단계로 이루어져 있으며 각 단계마다 이미지의 공간 해상도를 2배씩 감소시켜 전반적인 맥락 정보를 추출할 수 있다. Localization pathway는 context pathway에서 추출된 맥락 정보를 이용하여, 물체의 경계를 정확하게 추출하는 부분이다. Localization pathway도 여러 단계로 이루어져 있으며, 각 단계마다 이미지의 공간 해상도를 2배씩 증가시킨다. 맥락 정보를 이용하여 물체 경계를 더욱 정확하게 파악할 수 있고 각 단계에서 추출된 맥락 정보와 경계 정보를 결합하여 최종적인 분할 결과를 얻게 된다. Modified U-Net의 skip connections은 일반적인 U-Net과 비슷하지만 각 레벨의 context pathway와 localization pathway의 출력을 연결한다. 이러한 구조를 통해 네트워크의 깊이가 깊어져도 입력 이미지의 일부 영역에 대한 정보를 보존하면서 세밀하게 처리할 수 있다. 또한, modified U-Net은 U-Net보다 더 많은 계층을 가지고 있고 그룹 정규화, Leaky ReLU 활성화 및 드롭아웃을 거친다[11-13]. 이를 통해 모델은 더욱 효과적으로 학습할 수 있고 일반화 능력을 향상시킬 수 있다. 이러한 개선점들이 modified U-Net의 성능을 높이고 네트워크의 크기와 깊이에 대한 U-Net의 한계를 극복할 수 있게 하였다.

본 연구는 척추 위치에 대한 정보를 추가하기 위해 modified U-Net 모델의 컨볼루션 레이어의 입력 채널에 척추의 중심점을 추가하는 방법을 사용하였다. 척추의 중심점은 해부학적으로 척추 마디의 무게 중심 지점을 의미하고, 이 중심점 좌표 정보는 세브란스 내분비학과 전문의에 의해 수작업으로 추출되었다. 척추 분할 모델에 이용되는 척추 영상 데이터셋

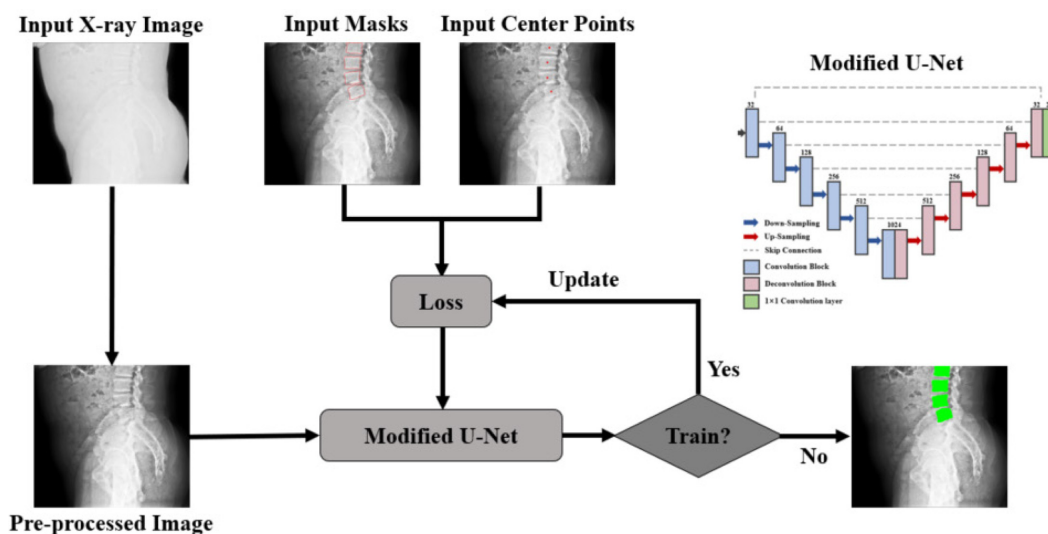


그림 2. 제안된 모델의 전반적인 흐름도

Fig. 2. Overall flowchart of the proposed model




그림 3. Modified U-Net과 척추의 중심점을 결합한 네트워크 구조
 Fig. 3. A network structure that combines modified U-Net and the center point of the spine

142

695장에서 레이블링이 진행되었다. 추출된 척추 중심점을 Modified U-Net에 추가함으로써 모델은 각 척추의 위치 정보를 인식할 수 있게 되어 척추 몸체가 아닌 다른 위치에 척추를 예측하는 가능성을 줄일 수 있다. 이는 분할 모델의 정확도 향상에 기여하며 척추 분할과 같이 정확한 위치 정보가 중요한 작업에서 더욱 효과적이다. 따라서 척추의 중심점을 추가함으로써 U-Net 분할 모델의 성능을 개선할 수 있다. 또한, Ground truth(GT) 마스크와 중심점을 결합한 레이블로 모델을 학습시키면 데이터가 더 풍부해져서 모델의 일반화 성능이 향상된다. 이는 모델이 특정 데이터에 대한 과적합을 방지하고 다른 데이터에서도 잘 작동하도록 만들어준다. 따라서 중심점과 GT 마스크를 결합한 레이블로 모델을 학습시키는 것은 분할 작업에서 성능을 향상시키는 좋은 전략이다.

제안된 모델은 GT 마스크와 척추 중심점의 dice loss를 최소화하는 것을 목표로 한다[14]. 식 (1)과 같이 dice loss는 실제 GT와 예측된 영역의 차이를 계산하는 손실 함수이다. 이때 사용되는 수치 중 TP(True positive)는 모델이 예측한 값이 실제 GT 값이 모두 양성인 경우를 의미하고, FP(False positive)는 GT가 음성인데 모델이 예측한 값이 양성인 경우를 의미한다. 또한, FN(False negative)는 GT가 양성인데 모델이 예측한 값이 음성인 경우를 의미한다. 전체 손실 함수는 분할 GT와 예측된 분할 결과의 overlap을 측정하고 동시에 척추 중심점의 GT와 예측된 중심점의 overlap을 계산하는 구조이며, 식 (2)와 같이 최종 손실값은 두 손실값의 평균으로 계산한다.

$$L_{Dice} = 1 - \frac{2TP}{2TP + FP + FN} \quad (1)$$

$$L_{Total} = \frac{L_{seg} + L_{center}}{2} \quad (2)$$

본 연구는 모델 하이퍼 파라미터 설정에서 dice loss, Adam optimizer을 사용하여 모델을 최적화시켰으며 배치 크기를 10으로 지정하여 100 epochs 만큼 학습시켰다[15]. 그리고 학습률은 2×10^{-5} 로 설정되었다. 이는 모델 학습의 실험적인 과정을 통해 최적의 하이퍼 파라미터가 선정되었다. 모델의 일반화 성능을 향상시키기 위해 학습 데이터의 augmentation 기법을 사용하였고 scaling, rotating, flipping 등이 적용되었다.

III. 결 과

본 연구는 modified U-Net 네트워크와 척추의 중심점을 결합하여 척추 자동 분할 방법론을 제시한다. 척추 분할 모델의 성능 평가는 다양한 방법으로 진행할 수 있는데 본 연구에서는 Dice Similarity Coefficient(DSC)와 정밀도(Precision), 재현율(Recall), 정확도(Accuracy), 정밀도-재현율 곡선 아래의 면적값(AUPRC)가 이용되었다[16,17]. 표 1을 보면, 평가지표를 이용하여 67장의 테스트 데이터셋에 대한 U-Net과 modified U-Net, modified U-Net과 척추의 중심점을 결합한 네트워크(CM-Net)의 성능을 비교하였다. U-Net과 modified U-Net, CM-Net의 평균 DSC가 각각 0.945, 0.965, 0.974이고, CM-Net이 가장 높은 성능을 기록하였다. 또한, 표 2에서 여러 모델에 대한 평균 DSC의 Confidence Interval(CI)를 추정하고, 모델 간의 차이를 검증하기 위해 비모수 상관분석을 이용하였으며 비모수 상관분석 결과로부터 모델 간의 차이가 있음을 입증하였다.

표 1. 여러 분할 모델에 대한 성능 평가 비교

Table 1. Comparison of the result for several segmentation networks

Networks	Metric				
	DSC	Accuracy	Precision	Recall	AUPRC
U-Net	0.945	0.996	0.854	0.892	0.873
Modified U-Net	0.965	0.996	0.895	0.867	0.892
CM-Net	0.974	0.998	0.916	0.906	0.912

표 2. 여러 모델에 대한 평균 DSC의 Confidence Interval(CI) 비교 결과와 모델 간의 비모수 상관분석 결과

Table 2. Comparison of the Confidence Intervals (CI) of the average Dice Similarity Coefficient (DSC) among multiple models and non-parametric correlation analysis between the models

Networks	Mean DSC	p-value
U-Net	0.945 (95% CI, 0.958~0.972)	<0.001
Modified U-Net	0.965 (95% CI, 0.956~0.976)	
CM-Net	0.974 (95% CI, 0.967~0.981)	

정밀도와 재현율을 이용하여 세 모델 간의 차이를 비교하기 위해 정밀도 재현율 곡선을 통해 분석하였다. 그림 4을 보면, 임계값으로부터 CM-Net이 가장 우상향 곡선을 나타내고 있고 가장 좋은 성능을 기록하고 있다는 것을 의미한다. 세 모델의 DSC와 정밀도, 재현율은 모델의 점진적인 개선을 나타내고 있다.

본 연구는 기존 연구들과 제안한 모델에 대한 비교분석을 진행하였고, 척추 위치에 따른 모델의 성능을 비교하였다. 표 3을 보면, 기존 연구들의 모델과 비교했을 때 같은 요추 X-ray 데이터셋에 대해 제안된 모델이 가장 높은 평균 DSC를 기록하였다. 그 외의 평가지표에서 재현율을 제외한 다른 지표들의 결과는 전반적으로 제안된 모델이 가장 높은 성능을 보여주고 있다.

표 3. 척추 위치(Spine View)기반 제안된 모델 및 기존 연구의 성능 비교

Table 3. Comparison of performance between the proposed model and previous studies based on the spine view

Models	Spine View	Metric			
		DSC	Precision	Recall	Accuracy
Pose-net+M-net+Level set [8]	Lumbar spine	0.916	0.846	0.901	-
MDR2-UNet[6]	Lumbar spine	0.929	-	0.937	0.992
CM-Net (Ours)	Lumbar spine	0.974	0.916	0.906	0.998
CM-Net (Ours)	Thoracic spine	0.836	0.912	0.801	0.982

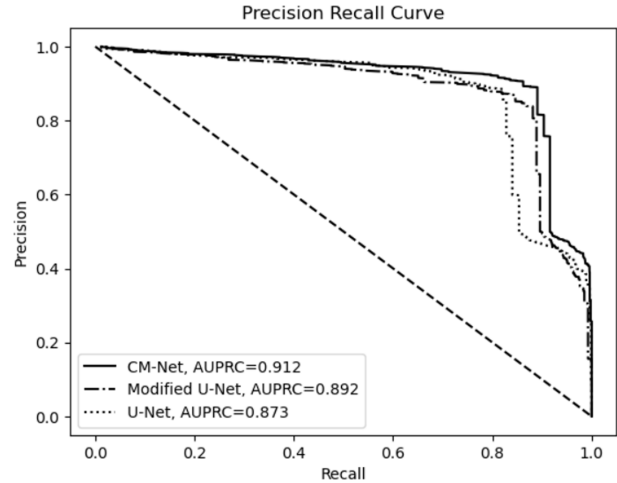


그림 4. 여러 모델에 대한 Precision Recall Curve와 AUPRC 결과 비교

Fig. 4. Comparison of Precision-Recall Curve and AUPRC results for multiple models

IV. 논 의

본 연구에서는 척추 영상 자동 분할을 위해 modified U-Net 모델과 척추 중심점 정보를 결합한 모델을 제안하였다. 실험 결과, 척추 중심점 정보를 결합한 모델이 일반 modified U-Net 모델에 비해 높은 정확도를 보여주었다. 제안된 모델은 척추의 가장자리를 더 정확하게 예측할 수 있는 방법을 분석하였다. 이를 위해 modified U-Net에 척추의 중심점을 추가하여 모델의 입력으로 사용하였다. 이를 통해 모델이 정확한 척추 위치 정보를 제공할 수 있게 되었고, 데이터의 다양성으로




그림 5. CM-Net과 Modified U-Net의 결과 비교
 Fig. 5. Comparison of results between CM-Net and Modified U-Net

일반화 성능을 향상시킬 수 있었다.

제안된 분할 모델을 분석하면서 우리는 모델의 잠재력과 한계를 확인하였다. 그림 5에 modified U-Net와 CM-Net의 예측 마스크를 비교하였는데 (b)가 modified U-Net의 결과이고 (c)에 해당하는 이미지가 CM-Net의 결과이며 (d)는 실제 GT 마스크이다. 예측한 결과를 보면 modified U-Net은 가장 위의 척추 부분과 가장 아래의 척추 부분을 정확히 예측하지 못하는 것을 알 수 있다. 이를 해결하기 위해 modified U-Net에 척추의 중심점을 추가하여 학습한 결과, 모델에 척추의 위치정보를 더해준 것이 이전보다 정확하게 척추의 테두리를 예측하는 효과를 얻을 수 있었다.

또한, 그림 6의 (a), (b), (c)는 각각 척추 임플란트와 압박 골절, 수술용 시멘트가 포함된 X-ray 이미지를 나타낸다. 제안된 모델이 척추 골절과 임플란트가 포함된 데이터셋을 학습하면서 다양한 노이즈를 극복하여 정확한 분할을 달성하는데 있어 높은 잠재력을 보여주고 있다.

하지만, 이 모델은 척추 중심점을 정확하게 추출해야 하므로

척추 중심점 추출의 정확도가 모델 성능에 큰 영향을 미친다는 한계가 있다. 척추 중심점은 전문의에 의해 수작업으로 추출되기 때문에 많은 비용과 시간이 든다. 그리고 정확하게 추출되지 않은 중심점이 모델의 입력에 들어갈 경우에는 모델이 잘못된 중심점 정보를 바탕으로 척추를 분할하게 되므로 분할 결과가 부정확할 가능성이 높다. 따라서, 앞으로의 연구 방향은 추출한 척추의 중심점 정보의 정확성을 검증하고 수작업으로 추출되는 방법을 더욱 개선할 필요가 있다.

더욱이, 객체 검출 작업에서 경추 X-ray 영상의 corner points를 이용하여 딥러닝 기반 객체 검출 모델을 통해 성능 향상을 이룬 연구가 있다[18]. 이와 마찬가지로 분할 작업에서 척추의 중심점을 활용하는 것과 유사한 개념으로 corner points를 분할 모델에 GT 마스크와 함께 학습한다면 척추 뼈의 테두리를 더욱 정확하게 예측하는 데 도움이 될 수 있다. 또한, 전문의에 의해 추출되는 중심점과 다르게 corner points는 자동적으로 정의하기가 비교적 쉽다는 장점이 있다. 하지만 corner points를 추가하는 것은 모델의 복잡도를 높여

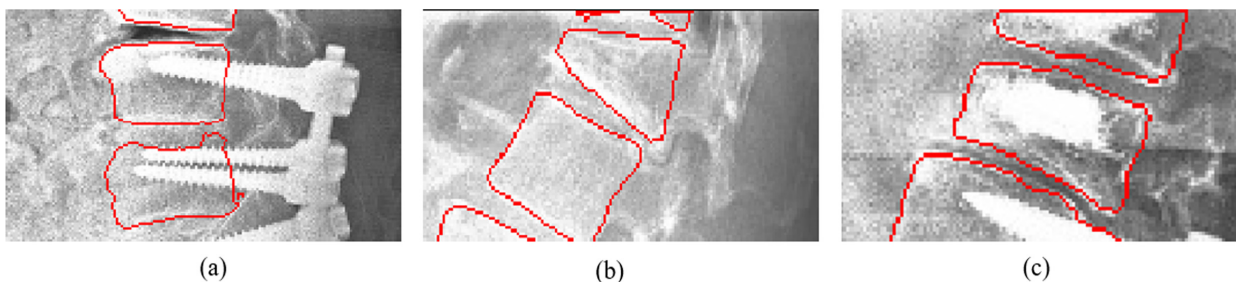


그림 6. 척추 임플란트와 압박 골절, 수술용 시멘트가 포함된 영상에 대한 CM-Net의 예측 마스크
 Fig. 6. Prediction masks of CM-Net for images containing spinal implants, compression fractures, and surgical cement

더 많은 학습 데이터를 필요로 할 수 있고 과적합의 가능성이 증가하기 때문에 데이터와 모델의 적절한 trade-off를 고려하여 활용해야 한다. 수술용 시멘트나 압박 골절을 포함하는 척추 영상일 경우는 척추의 정확한 테두리 정보를 알 수 없기 때문에 전문가의 개입이 필요하다. 따라서, corner points를 추가하여 정확한 테두리를 예측하기 위해서는 모델의 복잡도를 고려하고 자동으로 추출한 corner points 정보의 정확성을 검증해야 한다.

모델의 외부 검증을 위해 흉추 데이터셋 67장을 이용하여 제안된 모델을 평가하였다. 그 결과, 평균 DSC 0.836을 기록하였고 학습된 요추 데이터셋의 결과에 비해 모델의 성능이 감소하였다. 이는 흉추 X-ray 영상에서 흉곽 뼈와 그 아래에 위치한 폐 등 부위의 밀도 차이로 그림자가 형성되어 있어 척추 뼈가 가려지는 현상이 나타나기 때문에 모델이 흉추 부위는 예측하지 못한 것으로 추정된다.

추가로, 기존의 모델은 GE 제조사에서 촬영된 요추 X-ray 영상을 이용하였는데, 다른 제조사에서 촬영된 요추 영상 데이터셋을 이용하여 외부 검증을 시도하였다. Samsung 제조사에서 촬영된 요추 X-ray 영상 50장에 대해 모델을 평가한 결과, 평균 DSC 0.845를 기록하였고 기존 GE 영상들에 비해 성능이 떨어지는 것을 확인하였다. 이는 영상 간의 서로 다른 intensity 분포 차이로 인한 문제이고, 이를 해결하기 위해서는 도메인 적응(Domain adaptation) 방법론을 적용하거나 다른 도메인에 대한 추가 학습이 필요하다.

본 연구는 골다공증 진단에 있어서 자동 분할 기술이 큰 도움이 될 수 있음을 시사한다. 골다공증은 뼈 밀도 감소와 관련된 질병으로, 이를 정확하게 진단하고 치료하기 위해서는 요추의 정확한 분할 정보가 필요하다. 척추의 자동 분할을 통해 정확한 척추 골밀도 측정과 같은 진단이 가능해지면, 환자의 정확한 골다공증 진단과 적절한 치료 계획을 수립할 수 있다. 우리의 연구 결과는 이를 해결하기 위한 유망한 방법을 제시하고 있다. 이는 골다공증으로 인한 골절 등의 합병증을 예방하고, 환자의 삶의 질을 향상시키는 데 큰 도움이 된다. 또한, 이러한 연구는 인공지능 기술의 발전과 의료 분야의 융합을 이루는 좋은 사례로써, 다른 질병의 예방과 치료에도 큰 도움을 줄 수 있을 것으로 기대된다.

V. 결 론

본 연구는 Modified U-Net와 척추 중심점을 결합한 딥러닝 기반 자동 분할 방법론을 제시한다. 이를 통해 요추 X-ray 영상에 대한 자동 분할 모델의 높은 성능을 기록하고, 척추 골절과 임플란트와 같은 노이즈를 극복한 견고한 모델임을 증명하였다. Modified U-Net을 통해 기존 U-Net 네트워크의 단점을 개선하고, 모델에 척추의 중심점을 결합하

여 정확한 척추 위치 정보를 제공할 수 있었으며, 데이터의 다양성 증가로 일반화 성능을 향상시킬 수 있었다. 본 연구는 척추의 자동 분할 방법론을 제시하여 요추 X-ray 영상에 대한 정확한 골밀도 측정을 진행할 수 있으며, 이에 따라 조기에 압박 골절 등의 부작용을 예방할 수 있고 골다공증 진단에 대한 정확성과 효율성을 높일 수 있다. 따라서, 이 연구는 골다공증 진단 분야에서 중요한 의의를 갖는 연구가 될 수 있다.

References

- [1] Fasihi L, Tartibian B, Eslami R, Fasihi H. Artificial intelligence used to diagnose osteoporosis from risk factors in clinical data and proposing sports protocols. *Scientific Reports*. 2022;12(1):18330.
- [2] Cootes TF, Taylor CJ, Cooper DH, Graham J. Active Shape Models-Their Training and Application. *Computer Vision and Image Understanding*. 1995;61(1):38-59.
- [3] Zamora G, Sari-Sarraf H, Long LR. Hierarchical segmentation of vertebrae from x-ray images. *Proc SPIE*. 2003;5032:631-642.
- [4] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Cham, Springer International Publishing.
- [5] Badrinarayanan V, Kendall A, Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017;39(12):2481-2495.
- [6] Long J, Shelhamer E, Darrel T. Fully convolutional networks for semantic segmentation. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [7] Kim DH, Jeong JG, Kim YJ, Kim KG, Jeon JY. Automated Vertebral Segmentation and Measurement of Vertebral Compression Ratio Based on Deep Learning in X-Ray Images. *J Digit Imaging*. 2021;34(4):853-861.
- [8] He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition, in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016;770-778.
- [9] Kim KC, Cho HC, Jang TJ, Choi JM, Seo JK. Automatic detection and segmentation of lumbar vertebrae from X-ray images for compression fracture evaluation. *Computer Methods and Programs in Biomedicine*. 2021;200:105833.
- [10] Abraham N, Khan NM. A Novel Focal Tversky Loss Function With Improved Attention U-Net for Lesion Segmentation. 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019).
- [11] Wu Y, He K. Group Normalization. *CoRR* abs/1803.08494.
- [12] Maas AL. Rectifier Nonlinearities Improve Neural Network Acoustic Models. 2013.
- [13] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: a simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res*. 2014;15(1):1929-1958.
- [14] Zhao R, Qian B, Zhang X, Li Y, Wei R, Liu Y, Pan Y. Rethinking Dice Loss for Medical Image Segmentation. 2020 IEEE

- International Conference on Data Mining (ICDM).
- [15] Kingma DP, Ba J. Adam: A Method for Stochastic Optimization. CoRR abs/1412.6980.
- [16] Bertels J, Eelbode T, Berman M, Vandermeulen D, Maes F, Bisschops R, Blaschko M. Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory & Practice. 2019.
- [17] Davis J, Goadrich M. The relationship between Precision-Recall and ROC curves. Proceedings of the 23rd international conference on Machine learning. Pittsburgh, Pennsylvania, USA, Association for Computing Machinery: 233-240.
- [18] Fard AP, Ferrantelli J, Dupuis A, Mahoor MH. Sagittal Cervical Spine Landmark Point Detection in X-Ray Using Deep Convolutional Neural Networks. IEEE Access. 2022;10:59413-59427.