

논문 2022-17-32

# CT 영상에서 폐 결절 분할을 위한 경계 및 역 어텐션 기법 (Boundary and Reverse Attention Module for Lung Nodule Segmentation in CT Images)

황 경 연, 지 예 원, 윤 학 영, 이 상 준\*

(Gyeongyeon Hwang, Yewon Ji, Hakyoung Yoon, Sang Jun Lee)

Abstract : As the risk of lung cancer has increased, early-stage detection and treatment of cancers have received a lot of attention. Among various medical imaging approaches, computer tomography (CT) has been widely utilized to examine the size and growth rate of lung nodules. However, the process of manual examination is a time-consuming task, and it causes physical and mental fatigue for medical professionals. Recently, many computer-aided diagnostic methods have been proposed to reduce the workload of medical professionals. In recent studies, encoder-decoder architectures have shown reliable performances in medical image segmentation, and it is adopted to predict lesion candidates. However, localizing nodules in lung CT images is a challenging problem due to the extremely small sizes and unstructured shapes of nodules. To solve these problems, we utilize atrous spatial pyramid pooling (ASPP) to minimize the loss of information for a general U-Net baseline model to extract rich representations from various receptive fields. Moreover, we propose mixed-up attention mechanism of reverse, boundary and convolutional block attention module (CBAM) to improve the accuracy of segmentation small scale of various shapes. The performance of the proposed model is compared with several previous attention mechanisms on the LIDC-IDRI dataset, and experimental results demonstrate that reverse, boundary, and CBAM (RB-CBAM) are effective in the segmentation of small nodules.

Keywords : CT image analysis, Lung nodule, Small object detection, Attention mechanism

## 1. 개 요

폐종양은 종양 종류 중에서 가장 많이 발병하는 종양이며 사망률이 매우 높기 때문에, 다른 종양들과 마찬가지로 조기 발견과 치료를 통하여 사망률을 낮추는 것은 중요하다 [1]. 폐 결절은 대부분의 사람들에게서 나타나는 흔한 병변이지만, 임상적으로 악성 결절은 종양 세포로 발전될 가능성이 크다 [2]. 흉부 컴퓨터 단층촬영 (Computer Tomography, CT)을 통하여 폐 결절을 주기적으로 추적 진단하는 것은 암을 조기 치료하는데 중요하며 악성 결절의 경우 수년간 크기 변화가 있거나 석회화가 확인된다면 종양일 가능성이 높다. 이러한 과정은 일반적으로 전문 지식을 가지고 있는 전문의가 CT 영상 또는 X-ray를 통하여 주기적으로 결절의 위치, 부피 변화를 추적 진단할 수 있다. 하지만 이 과정은 시간이 오래 걸리며 전문의의 피로를 초래한다는 문제점이 있다.

최근에는 딥 러닝 기반의 computer-aid diagnosis (CAD)로 의료 영상을 분석함으로써, 병변의 후보 영역을 검출하고 시각화하여 전문의의 업무 부담을 줄이기 위한 연구가 활발

하게 진행되고 있다. CAD는 진단을 하는 전문의의 판단에 보조적인 역할을 하여 오진을 줄여줄 수 있다. CT 영상에서 혈관과 주변 조직이 폐 결절과 비슷한 모양과 밝기를 가지고 있어 구분하기 어려운 경향이 있기 때문에 오진으로 이어질 수 있다. 따라서 정확한 진단을 위해서는 CAD에 적용되는 딥 러닝의 결절 분할 (Segmentation) 성능이 중요하다.

의료 영상 분야에서는 병변 영역의 효율적인 검출을 위하여 end-to-end 방식으로 훈련이 가능한 fully convolutional network (FCN) 기반의 모델들을 주로 사용한다. 특히, U-Net [3]은 의료 영상 분석에서 사용되는 대표적인 모델에 해당된다. 최근 연구에서는 영상 분할의 성능을 높이기 위해 분할하고자 하는 병변 영역에 가중치를 추정하는 attention 기법이나 multi-scale의 정보를 얻을 수 있는 atrous spatial pyramid pooling (ASPP) module [4] 등의 다양한 기법들이 제안되었다.

Attention mechanisms을 여러 응용 분야에서 적용하여 성능을 높이는 연구들이 진행되고 있다 [5]. Channel attention 기법 중에서 squeeze-and-excitation (SE) module [6]은 압축 및 재조정을 통해 채널별 가중치를 계산한 후, feature map에 가중치를 곱하여 중요한 영역을 학습하도록 한다. Spatial attention 기법 중에 U-Net attention 기법은 인코더의 입력 feature map과 이전 층의 decoder 출력에 attention 가중치를 반영한다. 이 후, 계산된 attention feature를 decoder의 출력 feature에 곱하여 다음 층의

\*Corresponding Author (sj.lee@jbnu.ac.kr)

Received: Jul. 10, 2022, Revised: Aug. 9, 2022, Accepted: Oct. 4, 2022.

G. Hwang: Jeonbuk National University. (M.S.)

Y. Ji: Jeonbuk National University. (M.S.)

H. Yoon: Jeonbuk National University (Prof.)

S. J. Lee: Jeonbuk National University (Asst. Prof.)

This work was supported by the National Research Foundation of Korea and funded by a grant from the Korean government (No. 2021R1C1C1006794, 2021R1G1A1A009792).

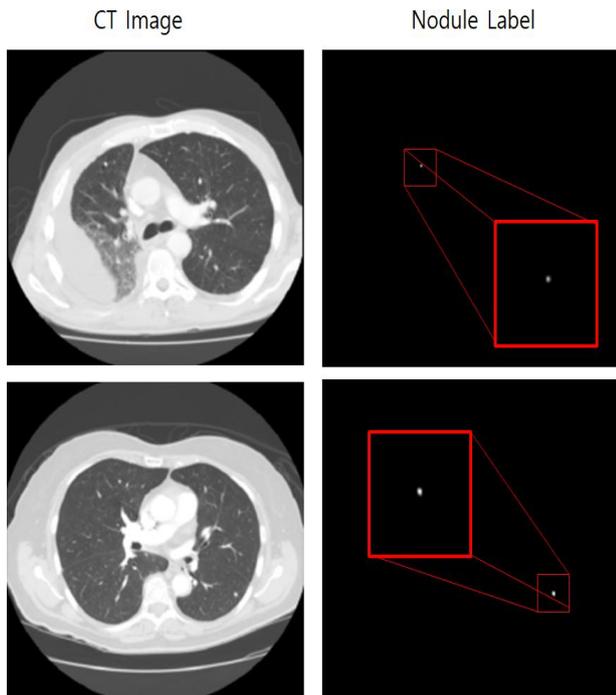


그림 1. 폐 결절의 CT영상 및 label 영상  
Fig. 1. CT and label images of lung nodules

decoder 입력으로 한다. 이러한 convolution 과정은 공간 영역에서 중요한 feature를 갖는 가중치 학습을 가능하게 한다.

Channel과 spatial attention이 결합된 기법 중에는 bottleneck attention module (BAM) [7]과 convolutional block attention module (CBAM) [8]이 있다. BAM은 convolutional neural network (CNN)의 bottleneck 구간마다 attention을 구현한 module이다. Bottleneck에서 spatial pooling을 수행하는 과정을 거치며 feature map의 공간 해상도가 작아져서 feature map의 정보 손실로 이어진다. 이 과정에서 BAM은 입력 feature를 channel 및 spatial attention으로 따로 구한 후, 결합하여 feature map에 곱하는 방법으로, 중요한 부분에 가중치를 집중하여 정보의 손실을 최소화 시킨다. CBAM은 BAM의 후속 연구로, BAM과 다르게 channel attention을 feature map에 계산한 후 spatial attention을 적용한다. 이 방법은 channel과 spatial에서 중요한 feature를 강조하여 이전 연구보다 높은 성능을 보여 준다.

Attention 기법들은 딥 러닝 모델의 성능 개선에 기여하는 경우가 많지만, 의료 영상에서는 분할하고자 하는 병변들에 대하여 환자들의 진료 데이터의 수가 한정되어 있다. 그림 1에서 확인할 수 있는 것처럼, 병변의 크기가 작고 모양이 다양하기 때문에 학습하는데 어려움이 있다. 이를 해결하기 위해, 본 논문에서는 넓은 영역에서의 정보 추출과 작은 크기의 결절 분할의 성능을 높이기 위하여 pretrained U-Net의 skip connection에 ASPP를 적용하였다. 또한 작은 병변들의 spatial feature 정보를 효과적으로 추출하고자, reverse attention [9]과 boundary attention [10, 11]을 기존의 CBAM과 결합한 reverse and boundary attention module (RB-CBAM)을 제안한다. 제안된 방법의 성능을 평가하기

위하여, RB-CBAM을 SE module, BAM, CBAM 비교하였다. 그 결과, 제안하는 방법이 CT 영상에서 폐 결절 분할에 효과적임을 확인할 수 있다.

## II. 본 론

### 1. Architecture

본 논문에서 제안한 전체적인 모델의 구조는 그림 2에서 확인할 수 있다. CT 영상을 전처리하여 모델의 입력으로 사용하였다. Pretrained U-Net을 백본 네트워크로 사용하였고, 정교한 분할을 위하여 skip-connection에 ASPP module을 적용하였고, reverse, boundary attention 그리고 CBAM을 활용한 RB-CBAM을 사용하였다.

### 2. ASPP

일반적으로 U-Net의 encoder의 특성상 low-level의 feature map에서 high-level의 feature map으로 가는 과정에서 convolution과 pooling을 통과하기 때문에 입력 영상의 feature map은 이 과정을 통해 크기가 줄어들어 feature map에 포함된 정보가 손실된다. 크기가 작은 결절의 공간 정보를 보존하기 위해, 본 논문에서는 그림 2와 같이 ASPP module을 이용하였다 [4]. 기존 U-Net의 skip-connection block에서 encoder의 출력 feature map을 서로 다른 dilation를 가지는 kernel을 이용하여 4개의 branch로 나누어 atrous convolution을 적용하였다. 이 때 얻어지는 feature map을 channel 방향으로 결합한 뒤, 1x1 convolution으로 계산한다. 이 과정은 receptive field를 확장시켜 다양한 크기의 feature map을 피라미드 구조를 갖는다. 또한 image 전체 feature map의 정보를 세밀하게 추출하여 주변 혈관과 비슷하게 보이는 결절의 특징을 효과적으로 얻어 작은 크기의 결절 정보를 보존할 수 있다.

### 3. RB-CBAM

ASPP module에서 출력된 feature map은 RB-CBAM의 입력으로 사용된다. 작은 영역에서 attention의 문제점은 경계 부근을 잘 분할하지 못한다는 점이다. 이 문제를 해결하기 위하여, RB-CBAM은 배경을 학습하도록 해주는 reverse attention과 경계 부근을 학습할 수 있도록 해주는 boundary attention을 적용한다. 그 후, CBAM에서 얻어지는 feature와 곱하여 작은 결절의 경계 영역을 잘 학습할 수 있도록 한다.

CBAM은 channel attention module과 spatial attention module로 구성된다. CBAM은  $i$ 번째 층의 ASPP 출력을 벡터화한 feature vector를 입력으로 받는다. Feature map은 channel 방향으로 average pooling과 max pooling으로 병렬적으로 계산된다. 그 다음, 파라미터를 공유하는 multi-layer perceptron (MLP)를 사용하고, 각각의 feature  $F_{avg}^c, F_{Max}^c$ 를 더하고 sigmoid를 통과시켜 channel attention을 얻는다. 계산된 channel attention은 입력 feature map과 곱하여 spatial attention의 입력으로 사용한다.

Channel attention과 다르게 spatial attention module은

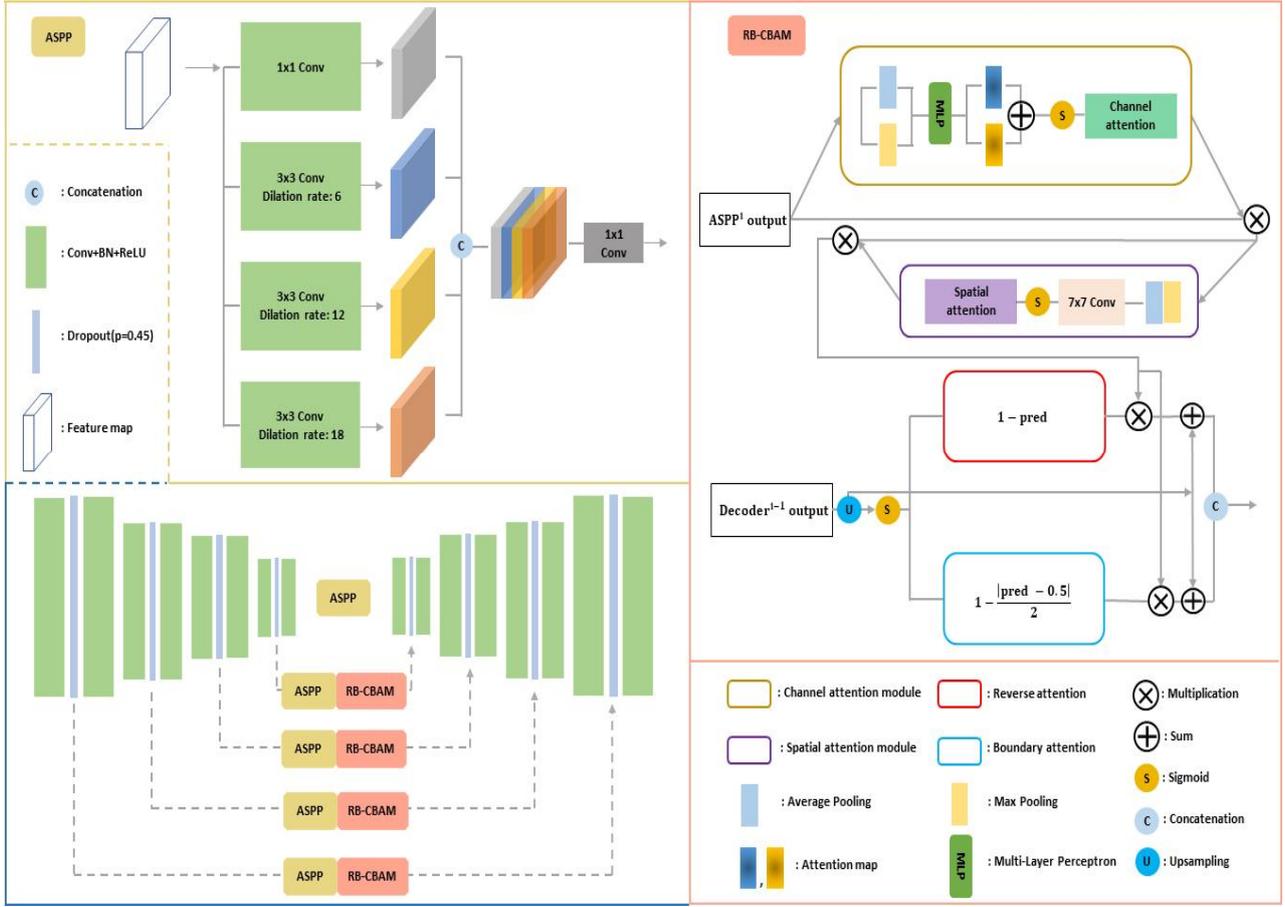


그림 2. ASPP와 RB-CBAM을 이용한 pretrained U-Net 구조  
Fig. 2. Pretrained U-Net architecture using ASPP and RB-CBAM

average pooling과 max pooling을 적용하여 얻어진 각각의 feature  $F_{avg}^s, F_{max}^s$  를 결합한다.  $7 \times 7$  convolution과 sigmoid 함수를 적용하여 최종적으로 얻어지는 attention map은 기존 입력 feature에 곱한다. 이는 다음과 같이 공식화될 수 있다.

$$F' = M_c(F) \otimes F. \quad (1)$$

$F'$ 은 channel attention이 적용된 feature를 의미하며  $M_c(F)$ 는 아래와 같이 나타낼 수 있다.

$$\begin{aligned} M_c(F) &= \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) \\ &= \sigma(W_1(W_0(F_{avg}^C)) + MLP(W_0(W_1(F_{max}^C)))). \end{aligned} \quad (2)$$

$M_c$ 은 channel attention 함수,  $W_0 \in \mathbb{R}^{C/r \times C}$ 과  $W_1 \in \mathbb{R}^{C \times C/r}$ 은 MLP의 가중치,  $\otimes$ 은 요소별 곱셈,  $\sigma$ 는 sigmoid function을 의미한다. Channel attention 이후 spatial attention은 다음과 같이 나타낼 수 있다.

$$F'' = M_s(F') \otimes F'. \quad (3)$$

(3)에서 사용된  $M_s(F)$ 는 spatial attention 함수로서 아래 수식으로 표현할 수 있다.

$$\begin{aligned} M_s(F) &= \sigma(f^{7 \times 7}(AvgPool(F), MaxPool(F))) \\ &= \sigma(f^{7 \times 7}([F_{avg}^s, F_{max}^s])). \end{aligned} \quad (4)$$

[,]는 channel 방향으로 결합을 의미하고,  $f^{7 \times 7}$ 은  $7 \times 7$  filter를 사용한 convolution 함수이다.

Reverse attention은  $i-1$ 번째 층의 decoder의 출력 feature를 upsampling 한 후, sigmoid function을 통해 prediction map을 반전 시켜서 구한다. 이는 다음과 같이 공식화될 수 있다.

$$RA_i = 1 - \sigma(Up(F_{i-1}^D)). \quad (5)$$

$RA_i$ 는  $i$ 번째 층의 reverse attention,  $Up(\cdot)$ 은 upsampling 함수이며,  $F_{i-1}^D$ 는  $i-1$ 번째 decoder의 출력 feature map을 의미한다. 그리고 reverse attention을 적용한 feature map의 수식은 다음과 같이 표현할 수 있다.

$$F_i^{R-CBAM} = Up(F_{i-1}^D) + (RA_i \otimes F_i^{CBAM}). \quad (6)$$

$F_i^{CBAM}$ 는  $i$ 번째 층의 ASPP module의 output을 입력으로 하는 CBAM의 output feature를 의미한다. 또한  $F_i^{R-CBAM}$ 는 CBAM에 reverse attention을 적용한 출력 feature map이다.

Boundary attention은  $i-1$ 번째 층의 decoder 출력 feature를 upsampling 한 후, sigmoid function을 통해 prediction map을 얻는다. 우리는 prediction map에서 결절의 중심에서부터 경계 부근으로 갈수록 확률 값이 작아지는

특성을 이용한다. 이는 아래 수식으로 표현할 수 있다.

$$BA_i = 1 - \frac{|\sigma(U_p(F_{i-1}^D)) - 0.5|}{2}. \quad (7)$$

$BA_i$ 는  $i$ 번째 층의 boundary attention을 의미한다. 그리고 boundary attention을 적용한 feature map은 아래 수식을 통하여 계산할 수 있다.

$$F_i^{B-CBAM} = U_p(F_{i-1}^D) + (BA_i \otimes F_i^{CBAM}). \quad (8)$$

$F_i^{B-CBAM}$ 는 CBAM에 boundary attention을 적용한 feature map이다. 수식 (6)과 (8)에서  $F_i^{R-CBAM}$ 과  $F_i^{B-CBAM}$ 를 얻었으며, 이를 channel 방향으로 결합하는 과정은 아래와 같이 표현할 수 있다.

$$F_i^{RB-CBAM} = [F_i^{R-CBAM}, F_i^{B-CBAM}]. \quad (9)$$

$F_i^{RB-CBAM}$ 은 reverse attention과 boundary attention이 적용된 feature를 의미한다.

#### 4. 손실 함수

Dice coefficient loss는 영역 기반 손실 함수로 의료 영상 분할에서 많이 사용되고 있는 손실 함수이다.

$$D = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} = \frac{2gp+1}{g+p+1}. \quad (10)$$

$D$ 는 dice coefficient 계수 ( $0 \leq D \leq 1$ )이며  $N$ 은 영상 전체의 pixels 및 voxels의 개수이다.  $p_i$ 는 예측한 pixels 및 voxels,  $g_i$ 는 ground-truth의 pixel 및 voxel을 의미한다.  $L_{Dice}$ 는 dice coefficient를 이용하여 다음과 같이 공식화 할 수 있다 [12, 15].

$$L_{Dice} = 1 - \frac{2gp+1}{g+p+1}. \quad (11)$$

Binary cross-entropy loss에 해당하는  $L_{BCE}$  [13]는 두 분포 간의 차이를 측정하는 손실 함수로써 다음과 같이 표현된다.

$$L_{BCE} = \sum_{i=1}^n g_i \log(p(g_i)) + (1-g_i) \log(1-p(g_i)). \quad (12)$$

$g_i$ 는  $i$ 번째 ground truth,  $p(g_i)$ 는  $i$ 번째 ground truth로 예측할 확률이다. 본 논문에서 사용된 손실함수는 영역 기반 손실 함수인  $L_{Dice}$ 와 두 분포간의 차이 기반 손실 함수인  $L_{BCE}$ 를 합쳐서 영역과 분포를 함께 학습할 수 있는  $L_{BCE-Dice}$ 를 사용하였다.

$$L_{BCE-Dice} = L_{BCE} + L_{Dice}. \quad (13)$$

### III. 실험

#### 1. 데이터 세트

본 논문에서 제안한 방법을 실험하기 위하여 1,018 명의 환자의 정보를 포함하는 Lung Image Data Consortium and Image Database Resource Initiative (LIDC-IDRI) 데이터를 사용했다. 각각의 환자 데이터는 표준 DICOM 형식의 임상 흉부 CT 스캔 파일과 결절 위치를 제공한다 [14]. 1,018 명의 환자 중에서 결절이 관찰되는 환자는 총 875 명이고, 이 중 결절의 크기가 직경 3 mm 이상인 결절들만 사용하였다. 실험에 사용된 결절 image는 총 8,230 장이며, 학습에 사용된 데이터는 4,944 장, 검증 및 테스트는 각각 1,236 장, 2,060 장이다.

#### 2. 전처리

LIDC-IDRI 데이터는 표준 DICOM 파일 형식으로 제공된다. DICOM 파일에는 환자 정보 및 pixel 값 등을 포함하는 metadata가 header에 포함되어 있다. DICOM에서 CT 영상의 측정값은 hounsfield unit (HU) [15, 16]으로 표시되며 HU는 물질 방사선 밀도를 의미한다. Pixel array를 HU로 변환하기 위하여 DICOM header의 rescale slope과 rescale intercept 속성 [17]을 아래 수식을 통해 변환할 수 있다.

$$HU = I \times s + b. \quad (14)$$

$I$ 는 pixel array,  $s$ 는 rescale slope,  $b$ 는 resacle intercept를 의미한다. 또한, 환자마다 DICOM metadata의 정보가 다르기 때문에 정규화 과정이 필요하다. 정규화는 pixel spacing을 이용하여 pixel을 voxel로 resampling을 한다 [18]. 본 논문에서는 환자의 평균 pixel spacing값 [0.68 mm, 0.68 mm]과 slice thickness는 2.0 mm로 resampling 하였다. 또한 [19, 20]과 같이 폐 영역을 측정하기 위하여 window width와 window center를 각각 1,500과 -600으로 설정하고 다음과 같이 HU 값을 clip했다.

$$H_{clip}(x, y) = \begin{cases} wc + ww/2 & \text{if } H(x, y) > wc + ww/2 \\ wc - ww/2 & \text{if } H(x, y) < wc - ww/2 \\ H(x, y) & \text{otherwise} \end{cases}. \quad (15)$$

$ww$ ,  $wc$ 는 각각 window width, window center를 의미한다.  $H(x, y)$ 는 HU 값을 가지는 image를,  $H_{clip}(x, y)$ 은 clip된 image이다.

$$H_{normalized} = \frac{H_{clip} - (wc - ww/2)}{(wc + ww/2) - (wc - ww/2)}. \quad (16)$$

위 수식을 통하여 array의 범위를 0~1로 정규화 하였다.

#### 3. 평가 방법

본 논문에서 제안하는 방법을 평가하기 위해서 dice similarity coefficient (DSC) [21]과 recall, precision을 이용하여 평가를 진행하였다. DSC는 다음과 같이 표현할 수 있다.

$$DSC = \frac{2 \times |\text{Pred} \cap \text{GT}|}{|\text{Pred}| + |\text{GT}|} = \frac{2 \times \text{TP}}{(\text{TP} + \text{FP}) + (\text{TP} + \text{FN})}. \quad (17)$$

표 1. Pretrained U-Net기반 attention module 평가 표

Table 1. Pretrained U-Net based attention module evaluation table

	SE module [5]	Attention Unet module [23]	BAM [6]	CBAM [7]	Ours (Proposed)
DSC	0.5716	0.5667	0.5729	0.5519	<b>0.6627</b>
Recall	0.6064	0.5917	0.5569	0.5348	<b>0.6642</b>
Precision	0.5405	0.5437	0.5898	0.5714	<b>0.6870</b>

표 2. ASPP, reverse attention, boundary attention의 유무에 따른 분할 성능 비교

Table 2. Comparison of segmentation performance with and without ASPP, reverse attention, and boundary attention

ASPP	Reverse	Boundary	DSC
			0.3728
	o		0.6201
		o	0.6187
	o	o	0.6259
o			0.5425
o	o		0.5691
o		o	0.6108
o	o	o	0.6627

(17) 에서 pred는 모델이 예측한 분할 영역을 의미하고, GT는 ground truth를 의미한다. 모든 pixel이 겹치게 되면 1의 값을 갖는다. 반대로 가장 낮은 성능은 0이다. TP, TN, FP, FN은 각각 true positive, true negative, false positive, false negative를 의미한다. Precision과 recall은 아래 수식으로 표현할 수 있다.

$$Precision = \frac{TP}{TP+FP}, \tag{18}$$

$$Recall = \frac{TP}{TP+FN}. \tag{19}$$

(18)은 모델이 true라고 예측한 분할 영역 중에서 GT가 true인 것의 비율이고, (19)는 GT가 true인 것 중에서 모델이 true라고 예측한 것의 비율이다.

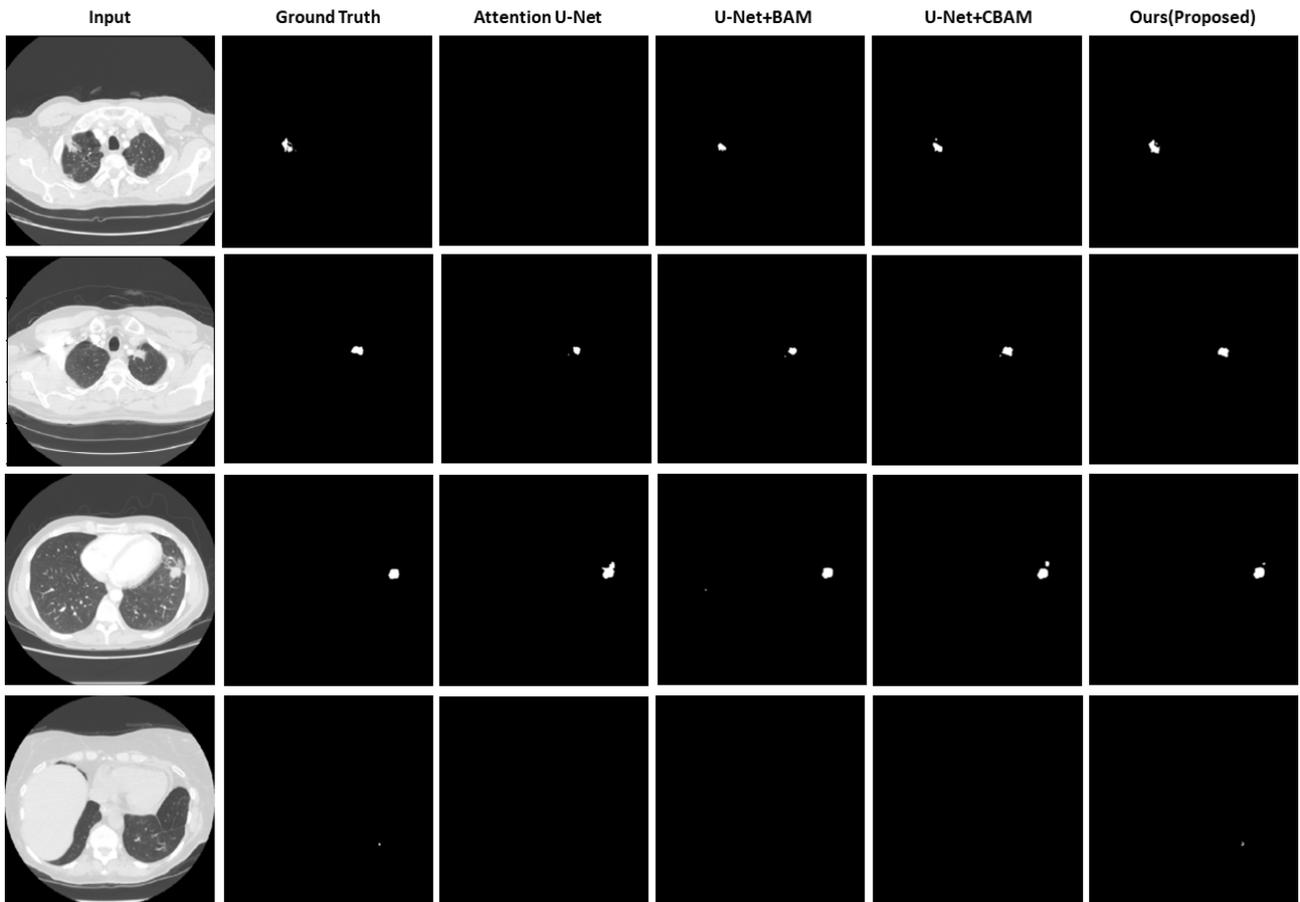


그림 3. SE module, Attention U-Net module, BAM, CBAM, RB-CBAM의 분할 결과  
Fig. 3. Results of segmentation of SE module, Attention U-Net module, BAM, CBAM, and RB-CBAM

#### 4. 실험 결과

본 논문에서는 제안하는 방법을 다른 attention module과 비교하여 평가하였다. 평가에 사용된 attention module은 SE module, Attention U-Net module [23], BAM, CBAM을 pretrained U-Net에 적용하였다. 표 1에서는 세 가지의 평가지표를 이용하여 이전의 attention module과 본 논문에서 제안하는 RB-CBAM의 성능 결과를 보여준다. RB-CBAM의 DSC는 0.6627로 가장 높은 성능을 보인다. 표 2는 RB-CBAM에서 ASPP와 reverse, boundary attention 각각의 사용 여부에 따른 DSC 성능 지표 결과이다. 세 가지 module을 모두 적용한 성능이 0.6627을 달성하여 가장 높은 성능을 보였다. 또한 평가에 사용된 module에 대한 예측된 결절 분할을 그림 3에서 확인할 수 있다.

#### 5. 실험 고찰

표 1에서는 다른 attention module을 적용한 모델과 성능을 비교한 지표이다. 이 표에서, 본 논문에서 제안하는 RB-CBAM을 사용한 모델이 다른 attention module보다 성능이 높다는 것을 확인할 수 있다. 표 2에서는 RB-CBAM에서 적용된 ASPP와 reverse, boundary attention의 유무에 따른 성능을 비교한 표이다. 3가지의 module을 다 적용하지 않았을 때 0.3728로 가장 낮은 성능을 얻었고, ASPP를 사용하지 않고 reverse, boundary attention의 유무의 성능은 두 attention module을 다 사용했을 경우 성능이 reverse와 boundary attention을 하나씩 사용했을 때 보다 성능이 높았다. 마지막으로 ASPP를 사용하면서 reverse, boundary attention 유무의 성능은 두 attention을 모두 사용 하였을 때 0.6627로 가장 높은 성능을 얻었으므로 폐 결절 분할에 있어서 ASPP, reverse, boundary attention을 모두 적용한 RB-CBAM이 효과적임을 실험적으로 보였다.

### IV. 결론

CT 영상에서의 폐 결절은 불규칙한 경계와 다양한 크기를 가진다는 특징이 있다. 그렇기 때문에 이전 연구의 attention module은 폐 결절 데이터에 대해서 학습이 잘 되지 않는다. 이를 해결하기 위하여, 본 논문에서는 RB-CBAM을 소개하였다. RB-CBAM은 ASPP를 적용하여 다양한 scale의 receptive field를 통해 얻어진 feature maps를 피라미드 형식으로 결합하여 공간 정보의 손실을 최소화 하였다. 또한 결절의 경계를 더욱 효과적으로 학습하기 위해 reverse attention과 boundary attention을 CBAM에 결합하였다. 제안된 방법은 이전 연구의 attention module과의 비교를 통하여 실험하였다. 그 결과, 본 논문에서 제안한 방법이 이전 연구의 방법들 보다 효과적임을 실험적으로 보였다.

### References

[1] S. Y. Lee, "컴퓨터도움진단 (Computer-Aided Diagnosis) 기술," 전기의세계, Vol. 60 No. 7, pp. 59-64, 2011.  
 [2] A. McWilliams, M. C. Tammemagi, J. R. Mayo, H.

Roberts, G. Liu, K. Soghrati, K. Yasufuku, S. Martel, F. Laberge, M. Gingras, S. Atkar-Khattra, C. D. Berg, K. Evans, R. Finley, J. Yee, J. English, P. Nasute, J. Goffin, S. Puksa, L. Stewart, S. Tsai, M. R. Johnston, D. Manos, G. Nicholas, G. D. Goss, J. M. Seely, K. Amjadi, A. Tremblay, P. Burrowes, P. MacEachern, R. Bhatia, M. S. Tsao, S. Lam, "Probability of Cancer in Pulmonary Nodules Detected on First Screening CT," *New England Journal of Medicine*, Vol. 369, No. 10, pp. 910-919, 2013.  
 [3] O. Ronneberger, P. Fischer, T. Brox, "U-net: Convolutional Networks for Biomedical Image Segmentation," *Proceedings of International Conference on Medical Image Computing and Computer-assisted Intervention*, pp. 234-241, 2015.  
 [4] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, A. L. Yuille, "Deeplab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected crfs," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 40, No. 4, pp. 834-848, 2017.  
 [5] Z. Niu, G. Zhong, H. Yu, "A Review on the Attention Mechanism of Deep Learning," *Neurocomputing*, Vol. 452, pp. 48-62, 2021.  
 [6] J. Hu, L. Shen, G. Sun, "Squeeze-and-excitation Networks," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 7132-7141, 2018.  
 [7] J. Park, S. Woo, J. Y. Lee, I. S. Kweon, "Bam: Bottleneck Attention Module," *arXiv preprint arXiv:1807.06514*, 2018.  
 [8] S. Woo, J. Park, J. Y. Lee, I. S. Kweon, "Cbam: Convolutional Block Attention Module," *Proceedings of the European Conference on Computer Vision*, pp. 3-19, 2018.  
 [9] S. Chen, X. Tan, B. Wang, X. Hu, "Reverse Attention for Salient Object Detection," *Proceedings of the European Conference on Computer Vision*, pp. 234-250, 2018.  
 [10] J. Y. Sun, S. W. Kim, S. W. Lee, Y. W. Kim, S. J. Ko, "Reverse and Boundary Attention Network for Road Segmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*, 2019.  
 [11] T. C. Nguyen, T. P. Nguyen, G. H. Diep, A. H. Tran-Dinh, T. V. Nguyen, M. T. Tran, "Ccbnet: Cascading Context and Balancing Attention for Polyp Segmentation," *Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 633-643, 2021.  
 [12] S. Jadon, "A Survey of loss Functions for Semantic Segmentation," *Proceedings of IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology*, pp. 1-7, 2020.  
 [13] J. Shore, R. Johnson, "Axiomatic Derivation of the

- Principle of Maximum Entropy and the Principle of Minimum Cross-entropy,” IEEE Transactions on Information Theory, Vol. 26, No. 1, pp. 26-37, 1980.
- [14] S. G. Armato III, G. McLennan, L. Bidaut, M. F. McNitt-Gray, C. R. Meyer, A. P. Reeves, B. Zhao, D. R. Aberle, C. I. Henschke, E. A. Hoffman, E. A. Kazerooni, H. MacMahon, E. J. Van Beeke, D. Yankelevitz, A. M. Biancardi, P. H. Bland, M. S. Brown, R. M. Engelmann, G. E. Laderach, D. Max, R. C. Pais, D. P. Qing, R. Y. Roberts, A. R. Smith, A. Starkey, P. Batrah, P. Caligiuri, A. Farooqi, G. W. Gladish, C. M. Jude, R. F. Munden, I. Petkovska, L. E. Quint, L. H. Schwartz, B. Sundaram, L. E. Dodd, C. Fenimore, D. Gur, N. Petrick, J. Freymann, J. Kirby, B. Hughes, A. V. Castele, S. Gupte, M. Sallamm, M. D. Heath, M. H. Kuhn, E. Dharaiya, R. Burns, D. S. Fryd, M. Salganicoff, V. Anand, U. Shreter, S. Vastagh, B. Y. Croft, “The lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a Completed Reference Database of lung Nodules on CT Scans,” Medical Physics, Vol. 38, No. 2, pp. 915-931, 2011.
- [15] F. Milletari, N. Navab, S. A. Ahmadi, “V-net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation,” Proceedings of International Conference on 3D Vision, pp. 565-571, 2016.
- [16] G. N. Hounsfield, “Computed Medical Imaging,” Science, Vol. 210, No. 4465, pp. 22-28, 1980.
- [17] U. Schneider, E. Pedroni, A. Lomax, “The Calibration of CT Hounsfield Units for Radiotherapy Treatment Planning,” Physics in Medicine & Biology, Vol. 41, No. 1, pp. 111, 1996.
- [18] A. Fajar, R. Sarno, C. Faticah, A. Fahmi, “Reconstructing and Resizing 3D Images from DICOM Files,” Journal of King Saud University-Computer and Information Sciences, 2020.
- [19] R. L. Draelos, D. Dov, M. A. Mazurowski, J. Y. Lo, R. Henao, G. D. Rubin, L. Carin, “Machine-learning-based Multiple Abnormality Prediction with Large-scale Chest Computed Tomography Volumes,” Medical Image Analysis, Vol. 67, No. 101857, 2021.
- [20] E. J. Stern, M. S. Frank, J. D. Godwin, “Chest Computed Tomography Display Preferences. Survey of Thoracic Radiologists,” Investigative Radiology, Vol. 30, No. 9, pp. 517-521, 1995.
- [21] K. H. Zou, S. K. Warfield, A. Bharatha, C. M. Tempany, M. R. Kaus, S. J. Haker, W. M. Wells III, F. A. Jolesz, R. Kikinis, “Statistical Validation of Image Segmentation Quality Based on a Spatial Overlap Index: Scientific Reports,” Academic Radiology, Vol. 11, No. 2, pp. 178-189, 2004.
- [22] J. Davis, M. Goadrich, “The Relationship Between Precision-Recall and ROC Curves,” Proceedings of International Conference on Machine Learning, pp. 233-240, 2006.
- [23] O. Oktay, J. Schlemper, L. L. Folgoc, M. Lee, M. Heinrich, K. Misawa, M. Kensaku, M. D. Steven, Y. H. Nils, K. Bernhard, G. Ben, R. Daniel, “Attention u-net: Learning where to look for the Pancreas” arXiv preprint arXiv:1804.03999, 2018.

### Gyeongyeon Hwang (황 경 연)



2021 Electronic Engineering from Jeonbuk National University (B.S.)

Field of Interests: Medical image analysis, Image processing, Generative learning  
Email: hgy1025@jbnu.ac.kr

### Yewon Ji (지 예 원)



2021 Veterinary Medicine from College of Veterinary Medicine in Jeonbuk National University (B.S.)

Field of Interests: Deep learning, Veterinary diagnostic imaging, Image-guide intervention, Nuclear medicine & Radiation  
Email: jyw2645@naver.com

### Hakyong Yoon (윤 학 영)



2011 Veterinary Medicine from College of Veterinary Medicine in Konkuk University (B.S.)

2016 Veterinary Medical Imaging from College of Veterinary Medicine in Konkuk University (MS & Ph.D)

Career:  
2018~2020 President in Bundang Leaders Animal Medical Center (MRI & CT center)  
2020~ Jeonbuk National University (Assistant Professor)  
Field of interests: Deep learning, Veterinary diagnostic imaging, Image-guided intervention, Nuclear Medicine & Radiation therapy  
Email: knighttt7240@gmail.com

**Sang Jun Lee (이 상 준)**

2011 Electrical Engineering from POSTECH  
(B.S.)

2018 Electrical Engineering from POSTECH  
(M.S. & Ph.D.)

## Career:

2018~2020 Samsung Advanced Institute of Technology  
(Senior Researcher)

2020~ Jeonbuk National University (Assistant Professor)

Field of Interests: Deep learning, Computer vision, Image  
processing, Robotics

Email: sj.lee@jbnu.ac.kr