

흉부 CT 영상에서 심층 감독 및 하이브리드 병변 초점 손실 함수를 활용한 폐암 분할 개선

이민진^{1,0}

오윤선^{1,0}

홍헬렌^{1,*}

¹서울여자대학교 소프트웨어융합학과
(minjin, hjwoys, hlhong)@swu.ac.kr

Enhanced Lung Cancer Segmentation with Deep Supervision and Hybrid Lesion Focal Loss in Chest CT Images

Min Jin Lee^{1,0}

Yoon-Seon Oh^{1,0}

Helen Hong^{1,*}

¹Department of Software Convergence, Seoul Women's University, Seoul, Republic of Korea

요 약

폐암은 크기가 다양하고 유사한 밝기값을 갖는 주변 구조물이 존재하기 때문에 흉부 CT 영상에서 폐암을 정확하게 분할하는 것이 어렵다. 이러한 문제를 해결하기 위해 본 논문에서는 심층 감독을 포함하고 UNet3+를 백본으로 사용하는 폐암 분할 네트워크를 제안한다. 또한, 픽셀 기반, 영역 기반 및 형태 기반의 3가지 구성 요소로 이루어진 하이브리드 병변 초점 손실 함수를 제안한다. 이를 통해 배경에 비해 작은 영역을 차지하는 폐암 부분에 집중하고, 불명확한 경계를 처리하는데 도움이 되는 형태 정보를 고려할 수 있다. 제안 방법을 UNet 및 UNet3+와 비교 실험을 통해 검증하였고, 제안 방법은 모든 폐암 크기에서 DSC 측면에서 가장 우수한 성능을 보였다.

Abstract

Lung cancer segmentation in chest CT images is challenging due to the varying sizes of tumors and the presence of surrounding structures with similar intensity values. To address these issues, we propose a lung cancer segmentation network that incorporates deep supervision and utilizes UNet3+ as the backbone. Additionally, we propose a hybrid lesion focal loss function comprising three components: pixel-based, region-based, and shape-based, which allows us to focus on the smaller tumor regions relative to the background and consider shape information for handling ambiguous boundaries. We validate our proposed method through comparative experiments with UNet and UNet3+ and demonstrate that our proposed method achieves superior performance in terms of Dice Similarity Coefficient (DSC) for tumors of all sizes.

키워드: 폐암 분할, 심층 감독, 하이브리드 병변 초점 손실 함수, UNet3+, CT 영상

Keywords: Lung cancer segmentation, deep supervision, hybrid lesion focal loss, UNet3+, CT image

1. 서론

폐암은 국내 뿐 아니라 전 세계에서 사망률이 가장 높은 암종 중 하나이다[1]. 폐암의 병기 결정, 치료 계획 수립 및 치료 효과 모니터링을 위해 흉부 컴퓨터 단층 촬영(Computed Tomography, CT) 영상이 주로 사용된다. 종양 치료 효과를

평가하기 위한 기준으로 사용되는 RECIST(Response Evaluation Criteria in Solid Tumors) 버전 1.1은 종양 크기 변화를 측정하여 폐암 환자의 치료 결과를 판단하는데 도움을 준다. 이 방법은 종양이 일반적으로 구형이라고 가정하며 종양의 1 차원 최대 지름을 측정한다[2]. 그러나, 폐 종양이 구형이 아닌 불규칙한 모양을 가진 환자의 경우 이 방법은 한계가 있다. 따라서 이러한 환자의 치료 반응을 정확하게 평가하기 위해서는 종양 전체

⁰ These authors contributed equally to this work.

*corresponding author: Helen Hong / Department of Software Convergence, Seoul Women's University(hlhong@swu.ac.kr)

부피를 측정하는 것이 필요하며, 이를 위해 흉부 CT 영상에서 폐암을 자동으로 분할하는 기술이 필요하다.

그림 1 은 흉부 CT 영상에서 나타나는 폐암의 특징을 나타낸다. 폐암은 크기나 형태가 매우 다양하며 위치에 따라 폐실질(Lung parenchyma)에 명확하게 나타나기도 하지만 폐흉벽(Chest wall), 흉강(Chest cavity), 종격동(Mediastinum), 폐혈관 등에 부착되어 있어 주변 구조물과의 경계를 정확하게 구분하기 어렵고, 이로 인해 분할을 자동화하기에 어려움이 있다.

흉부 CT 영상을 활용하여 폐암 분할에 대한 딥 컨볼루션 신경망 연구는 다음과 같다. Hossian[3]은 2 차원 영상에 확장 컨볼루션(Dilated convolution)연산을 수행하여 특징 맵을 생성하고, 이들을 이어 붙여 3 차원 볼륨으로 만들고 3 차원 컨볼루션 연산을 수행하여 3 차원 분할을 수행하는 하이브리드 모델을 제안하였다. 이 모델은 300 명의 NSCLC-radiomics 데이터 중 260 명을 훈련 데이터로, 40 명을 테스트 데이터로 사용하여 65.7%의 다이스 유사계수 (Dice similarity coefficient, DSC) 성능을 보였다. Tuba[4]는 다양한 수용영역(Receptive field)에서 특징을 추출하기 위해 기존 UNet 을 백본(Backbone)으로 하여 연속 확장 컨볼루션 (Consecutive dilated convolution)을 적용하는 방법을 제안하였으며, 이 모델은 335 명의 NSCLC-radiomics 환자 데이터 중 62 명을 테스트 데이터로 사용하여 53.34%의 DSC 성능을 보였다. Zhang[5] 등은 ResNet34 를 기반으로 디코더에서 멀티 스케일 특징 맵을 결합하는 형태로 변형된 ResNet 모델을 적용하였고, 이 모델은 300 명의 NSCLC-radiomics 환자 데이터 중 260 명을 훈련 데이터로, 40 명을 테스트 데이터로 사용하여 73%의 DSC 성능을 보였다. Lee[6]는 주변 구조물과의 관계를 학습하는 캡슐

제안하였으며, 자체 병원에서 얻은 80 명의 폐암 환자 데이터를 사용하여 88.77%의 DSC 성능을 보였다.

본 논문에서는 흉부 CT 영상에서 다양한 크기의 폐암과 주변 구조물과의 경계가 불명확한 문제를 해결하기 위해 UNet3+[8] 네트워크 구조를 백본으로 활용하여, 전체 스케일 스킵 연결(Skip connection) 사용과 심층 감독(Deep supervision)을 통해 네트워크의 안전성을 향상시키고자 한다. 또한 폐암 영역에 더 집중할 수 있도록 하이브리드 병변 초점 손실 함수(Hybrid lesion focal loss: HLF loss) 를 제안한다.

2. 제안방법

2.1 데이터 전처리

흉부 CT 영상은 각 환자마다 다른 촬영 장비와 다양한 프로토콜을 사용하여 획득되므로 영상 간 차이가 발생할 수 있다. 이러한 차이를 최소화하기 위해 흉부 CT 영상에서 정규화(Normalization) 과정이 필요하다. CT 영상은 주로 각 기관을 볼 때 사용하는 다양한 밝기값 윈도우 셋팅을 가지고 있으며, 폐암 영역이나 주변 혈관, 주변 구조물을 잘 표현할 수 있는 폐 윈도우 셋팅을 사용한다. 폐 윈도우 셋팅은 윈도우 폭(Window width)을 1500HU(Hounsfield Unit), 윈도우 레벨(Window level)을 -600H로 설정하여, 영상의 픽셀 밝기값을 -1350HU~150HU 범위 내에서 0~255 밝기값으로 변환한다. 이후에 폐암의 중심 좌표를 기준으로 폐암을 포함하는 영역을 128x128 크기로 잘라 최종 입력 영상을 생성한다.

또한, 데이터 부족으로 인한 학습 시 과적합을 방지하기 위해 데이터 증강(Data augmentation) 기법을 적용한다. 이를

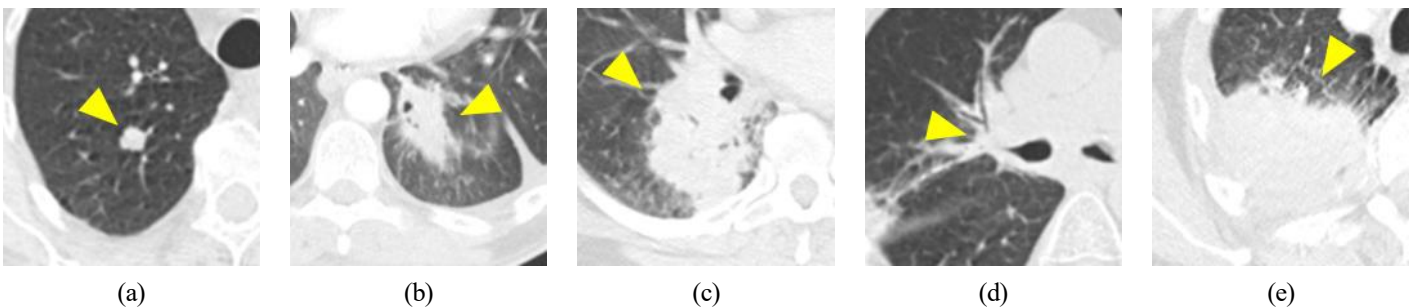


Figure 1. Examples of lung tumors with various sizes, shapes and locations on chest CT images: (a) small-sized lung cancer, (b) medium-sized lung cancer, (c) large-sized lung cancer, (d) mediastinum-attached lung cancer, (e) chest wall-attached lung cancer

네트워크를 사용하여 듀얼-윈도우 앙상블 네트워크를 제안하였으며, 자체 병원에서 얻은 260 명의 폐암 환자 데이터 중 52 명을 테스트 데이터로 사용하여 75.98%의 DSC 성능을 보였다. Jeong[7]은 데이터 불균형 문제를 해결하기 위해 Dice 와 Focal 손실 함수를 결합하여 U-Net 을 기반으로 한 손실 함수를

위해 -20 도에서 20 도 사이의 임의 회전(Random rotation), -20 픽셀에서 20 픽셀 사이의 임의 이동(Random translation), 0.8 배에서 1.2 배 사이의 임의 스케일(Random scaling)을 적용한다. 학습 데이터에 대해 무작위로 3 번의 데이터 증강을 적용하여 학습 데이터를 3 배로 증가시킨다.

2.2 분할 네트워크 구조

일반적으로 의료 영상 분할에 사용되는 UNet[9]은 특징을 추출하는 인코더(Encoder) 부분과 특징의 위치 정보를 파악하는 디코더(Decoder) 부분으로 구성되며, 대칭적인 U자 형태의 구조를 가진다. 이전 디코더 레이어에서 생성된 낮은 수준의 특징 맵과 스킵 연결을 통해 전달된 동일 레이어에서 나온 높은 수준의 특징 맵을 결합하여 디코더를 학습한다. UNet의 이러한 네트워크 구조는 적은 양의 학습 데이터로도 효과적인 학습이 가능하며, 빠른 학습 속도를 제공하는 장점이 있다. 그러나 스킵 연결을 통해 전달되는 정보는 동일한 수준의 인코더 상의 특징 정보 뿐이므로 폐암과 같은 다양한 크기의 종양에 대한 분할 정확도가 저하될 수 있다는 단점이 있다.

UNet의 이러한 한계점을 극복하기 위해 제안된 방법은 그림 2와 같이 UNet3+ 모델을 백본으로 사용하여 전체 스케일에 해당하는 특징 맵을 결합하는 스킵 연결을 수행한다. UNet3+는 각 디코더의 입력으로 이전 디코더에서 얻은 낮은 수준의 특징 맵과 상위 인코더에서 얻은 높은 수준의 특징 맵을

계산한다. 이후 테스트 시에는 마지막 레이어에서 얻은 결과만을 사용하여 최종 결과를 생성한다.

UNet3+는 각 디코더 레이어의 입력으로 상위 레이어의 인코더에서 얻은 높은 수준의 특징 맵과 이전 디코더 레이어에서 얻은 낮은 수준의 특징 맵을 모두 고려함으로써 다양한 스케일의 특징 맵을 효과적으로 활용할 수 있다. 이러한 기능을 통해 다양한 크기를 가진 폐암의 특징을 더 잘 학습할 수 있어서 분할의 성능을 향상시킬 수 있다.

2.3 하이브리드 병변 초점 손실 함수

UNet3+는 다양한 크기의 폐암 정보를 고려할 수 있는 장점을 가지고 있지만, 폐암 영역은 전체 영상에서 매우 적은 픽셀을 차지하며, 주변 기관과 유사한 밝기값을 가지기 때문에 폐암의 경계가 불명확한 경우가 많다. 이를 해결하기 위해 하이브리드 병변 초점 손실 함수를 제안한다.

제안하는 손실함수는 픽셀 기반(Pixel-based), 영역 기반(Regional-based), 형태 기반(Shape-based)의 3가지 방식의 손실함수를 사용한다. 픽셀 기반의 손실함수는 각 픽셀 단위로

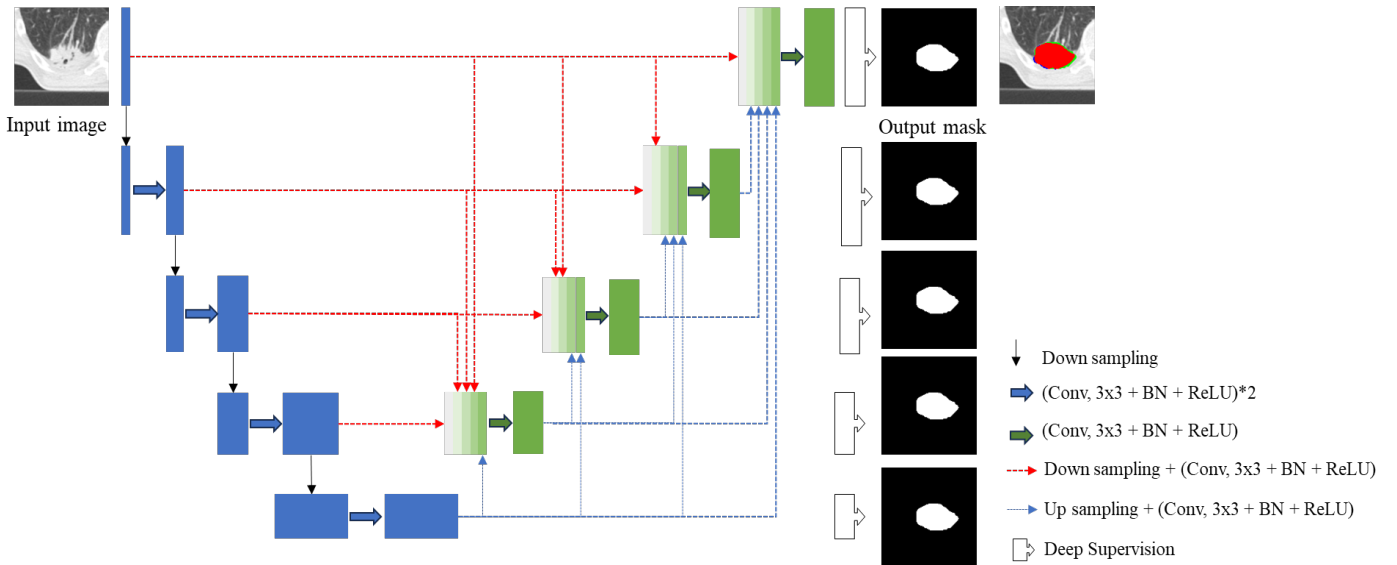


Figure 2. Overview of the proposed method for lung cancer segmentation based on UNet3+

결합하여 디코더의 학습을 수행한다. 이때 각 특징 맵의 크기와 채널 수를 동일하게 맞추기 위해 상위 인코더의 특징 맵은 맥스-풀링을 통해 다운 샘플링 작업과 컨볼루션을 수행하고, 하위 디코더의 특징 맵은 양선형 보간(Bilinear interpolation)을 통한 업 샘플링 작업과 컨볼루션을 수행한다. 또한, 깊은 레이어에서 나오는 특징 맵들을 활용하여 네트워크를 안정화하고 성능을 향상시키기 위해 심층 감독을 적용한다. 심층 감독은 마지막 디코더 레이어에서의 결과만으로 손실 함수를 계산하지 않고, 각 디코더 레이어에서의 결과를 모두 합산하여 손실 함수를

손실을 반영하고자 하는 목적을 가지며, 크로스 엔트로피 손실함수(Cross entropy loss, CE loss)를 변형한 초점 손실 함수(Focal loss)를 사용한다. 초점 손실 함수는 모델이 추정한 확률이 낮은 픽셀에 집중하여 모델을 개선하고자 하는 방식으로 식 (1)과 같이 정의한다. 모델이 추정한 확률이 낮은 픽셀은 주로 폐암의 경계와 같이 분류하기 어려운 픽셀들을 나타내며, 이러한 픽셀들에 더 큰 가중치를 부여한다.

$$\text{Focal loss} = - \sum_{i=1}^n \alpha_i (1 - p_i)^\gamma \log(p_i) \quad (1)$$

이 때, p_i 는 각 클래스에 대한 모델의 추정 확률을 의미하고, $(1 - p_i)^\gamma$ 는 변조인자(Modulating factor)로 확률 값이 클 경우 낮은 가중치를 부여하고 확률 값이 작을 경우 높은 가중치를 부여하여 분류하기 쉬운 픽셀과 어려운 픽셀에 다른 가중치를 부여하는 방식으로 적용되며, α_i 는 배경보다 분류하고자 하는 폐암 클래스에 더 큰 가중치를 부여하기 위해 사용된다. 본 연구에서는 폐암 클래스에 0.7, 배경 클래스에 0.3 의 값을 할당하였으며, γ 값은 2 로 설정한다.

영역 기반의 손실함수는 TP(True Positive), TN(True Negative), FP(False Positive), FN(False Negative)가 차지하는 영역에 대한 비율 정보를 기반으로 손실 함수를 계산하는 방식으로 DSC 의 변형된 형태인 초점 트버스키 손실 함수(Focal tversky loss, FT loss)를 사용한다. 초점 트버스키 손실함수는 식 (2)와 같이 정의하며, 배경에 대한 TN 영역을 제외하고, 폐암 영역에 대하여 올바르게 분할한 TP 영역과 잘못 분할된 FP 와 FN 영역을 고려하여 생성된 함수이다. 또한, 초점 손실함수와 같이 트버스키 손실 값이 작아질 때 손실 함수 값을 더 커질 수 있도록 하여 잘못된 영역이 많아질수록 가중치를 부여한다.

$$FT\ loss = (1 - TL)^\gamma \quad (2)$$

$$TL = \frac{TP}{TP + (1 - \delta)FP + \delta FN} \quad (3)$$

이 때, γ 값은 3/4 로 설정하며, δ 값은 0.3 으로 설정하여 FP 에 민감하도록 높은 가중치를 설정한다.

형태 기반의 손실 함수는 모델 분할 결과와 정답 마스크(Ground truth, GT) 간의 형태를 고려한 구조적 유사성 손실 함수(Structural similarity, SSIM)를 사용한다. 이는 불명확한 경계에서도 결과 마스크 간의 유사성으로 분할의 차이를 줄이도록 하는 방식으로 식 (4)와 같이 정의한다. 이 함수는 구조적으로 유사한 마스크를 생성할 수 있도록 하기 때문에 부정확한 폐암의 경계 영역에서도 유사한 결과를 만들 수 있도록 하는 장점이 있다.

$$SSIM = 1 - \frac{(2\mu_p\mu_g + C_1)(2\sigma_{pg} + C_2)}{(\mu_p^2 + \mu_g^2 + C_1)(\sigma_p^2 + \sigma_g^2 + C_2)} \quad (4)$$

이 때, p 와 g 는 분할 결과 마스크의 패치 영역과 정답 마스크의 패치 영역을 의미하고 $\mu_p, \mu_g, \sigma_p, \sigma_g$ 는 각각 패치 영역에서의 평균값과 분산을 의미하고, σ_{pg} 는 교차 공분산을 의미한다.

3. 결과

실험에 사용한 데이터는 암 영상 아카이브에 공개된 공공 데이터셋으로 NSCLC-Radiomics 데이터셋으로 총 422 명의

폐암 CT 영상으로 구성되어 있다. 422 명의 데이터 중 39 명의 선암(Lung Adenocarcinoma, LUAD) 및 115 명의 편평상피세포암 (Lung Squamous Cell Carcinoma, LUSC) 데이터만을 선별하여 총 154 명의 데이터를 사용하였고, 폐암의 직경은 1.38cm 에서 14.63cm 의 다양한 범위로 분포된다. 모든 데이터는 Siemens Healthineers 사의 Biograph 40, SOMATOM Sensation 10, SOMATOM Sensation 16, SOMATOM Sensation Open 장비와 CMSimaging 사의 XiO 장비를 통해 촬영된 흉부 CT 영상을 사용하였다. 각 데이터의 영상 해상도는 512x512, 픽셀 크기는 0.97mm, 슬라이스 간격은 3mm 이다. 학습과 검증을 위해 랜덤하게 선택하여 각각 111 명과 13 명의 환자 데이터를 사용하였고, 테스트를 위해 30 명의 환자 데이터를 사용하였다.

제안 방법의 폐암 분할 성능을 분석하기 위해 정량적 성능 평가와 정성적 성능 평가를 수행하였고, 기본 UNet 과 UNet3+ 모델과의 비교를 통해 UNet3+ 모델을 백본으로 심층 감독을 수행하고 하이브리드-병변 초점 손실 함수를 사용한 제안 방법의 효과를 분석하였다. 정량적 평가에서는 DSC, 재현율(Recall) 및 정밀도(Precision)의 세가지의 평가지표를 사용하여 제안 방법의 분할 성능을 제시하였으며, 정성적 평가에서는 폐암 분할 결과 영상의 육안 평가를 수행하였다.

본 실험은 CUDA 10.1 과 NVIDIA GeForce GTX 1080 그래픽 카드를 탑재한 서버에서 python 언어를 기반으로 수행되었다. 학습을 위한 하이퍼파라미터로는 배치(Batch) 크기를 8, 학습률(Learning rate)을 1e-5 로 설정하고, 최대 에폭(EPOCH) 수는 300 으로 설정하였으며, 20 에폭 동안 검증 손실이 감소하지 않으면 조기 종료(Early stopping) 하도록 설정하였다.

Table 1 은 전체 폐암에 대한 분할 성능 결과를 보여준다. 하이브리드-병변 초점 손실함수를 사용한 제안 방법이 UNet 과 UNet3+를 적용한 결과에 비해 DSC 측면에서 각각 3.46%와 1.38% 향상되었음을 보인다. UNet3+를 적용한 결과가 제안 방법에 비해 재현율 측면에서 3.01% 높은 결과를 보이지만 정밀도 측면에서는 반대로 4.88% 낮은 결과를 보인다. 이는 UNet3+의 결과가 과대 분할된 결과를 나타내고, 제안 방법에서 정밀도가 더 높은 값을 보이며 과대 분할이 방지된 것을 확인할 수 있다.

Table 1. Performance evaluation of lung tumor segmentation for the entire lung tumors. Mean and standard deviations are provided, with the highest values highlighted in bold.

(%)			
Methods	DSC	Recall	Precision
UNet	68.57 (10.03)	73.93 (14.56)	70.59 (13.58)
UNet3+	70.25 (9.41)	79.22 (14.09)	69.63 (13.42)
UNet3+ + deep supervision + HLF loss (Ours)	72.13 (11.13)	76.27 (16.37)	75.21 (11.94)

Table 2 는 폐암의 크기에 따른 성능 결과를 나타내며, 폐암의 TNM 병기에서의 T-단계와 동일하게 산정한 것으로 Group 1 은 3cm 보다 작은 폐암, Group 2 는 3cm ~ 5cm 크기의 폐암, Group 3 는 5cm 이상의 폐암으로 구분하였다. 크기에 따른 고려가 가장 적은 UNet 의 경우 DSC 수치에서 모두 70% 이하의 낮은 성능을 보였으며, 특히 가장 작은 크기의 폐암인 Group1 에서 가장 낮은 재현율을 보인다. 이는 작은 폐암의 경우 더 분할이 어렵다는 것을 확인할 수 있다. 다중 스케일이 고려된 UNet3+에서는 Group 3 보다 Group 1 과 Group 2 에서 더 큰 향상폭을 보이며, 크기에 상관없이 분할의 성능이 향상됨을 확인할 수 있고, 크기가 큰 Group 2 와 Group 3 에서는 가장 높은 재현율을 보이지만 정밀도는 낮아지거나 유사한 것을 확인할 수 있다. 이는 다중 스케일의 고려와 심층 감독으로 인해 과대 분할이 발생한다는 것을 확인할 수 있다. 이를 해결하기 위해 하이브리드-병변 손실함수를 적용하면 재현율과 정밀도가 균형되게 향상되어 좀더 안정적인 분할 결과를 얻을 수 있다.

Table 2. Performance evaluation of lung tumor segmentation based on lung cancer size group. Mean and standard deviations are provided, with the highest values highlighted in bold.

(%)				
Method	Tumor size group	DSC	Recall	Precision
Unet	Group 1	69.04 (8.11)	68.80 (3.47)	74.89 (14.28)
	Group 2	69.13 (12.31)	79.32 (14.24)	64.76 (14.35)
	Group 3	68.17 (9.56)	73.53 (16.29)	71.48 (12.13)
UNet3+	Group 1	70.23 (9.81)	76.54 (11.87)	68.93 (11.9)
	Group 2	71.03 (10.67)	85.17 (11.61)	64.28 (13.89)
	Group 3	69.93 (8.7)	77.71 (15.03)	72.08 (13.06)
UNet3+ + deep supervision + HLF loss (Ours)	Group 1	72.41 (10.05)	76.79 (10.95)	72.39 (12.96)
	Group 2	73.51 (14.32)	79 (19.55)	73.80 (10.33)
	Group 3	71.46 (9.86)	74.96 (16.39)	76.78 (11.92)

그림 3 은 흉부 CT 영상에서 폐암 분할 결과를 나타내며, UNet 의 경우 작은 영역에서는 분할되지 않거나 배경 영역으로 오분할되는 경향이 많이 나타나는 것을 확인할 수 있다. UNet3+의 경우 폐암의 분할 성능이 향상되었지만, 여전히 유사한 밝기값을 가진 주변 기관으로의 누수가 발생하는 경향이 있다. 반면 제안 방법은 주변 기관과의 밝기값 유사성으로 인한 누수를 크게 줄여 안정적인 분할 결과를 얻을 수 있다. 또한 UNet 이나 UNet3+에서 폐암이 거의 분할되지 않는 경우에도 개선된 분할 결과를 확인할 수 있다.

4. 결론

본 논문에서는 흉부 CT 영상에서 다양한 크기와 유사한 밝기값을 가진 주변 구조물이 존재하는 폐암의 분할을

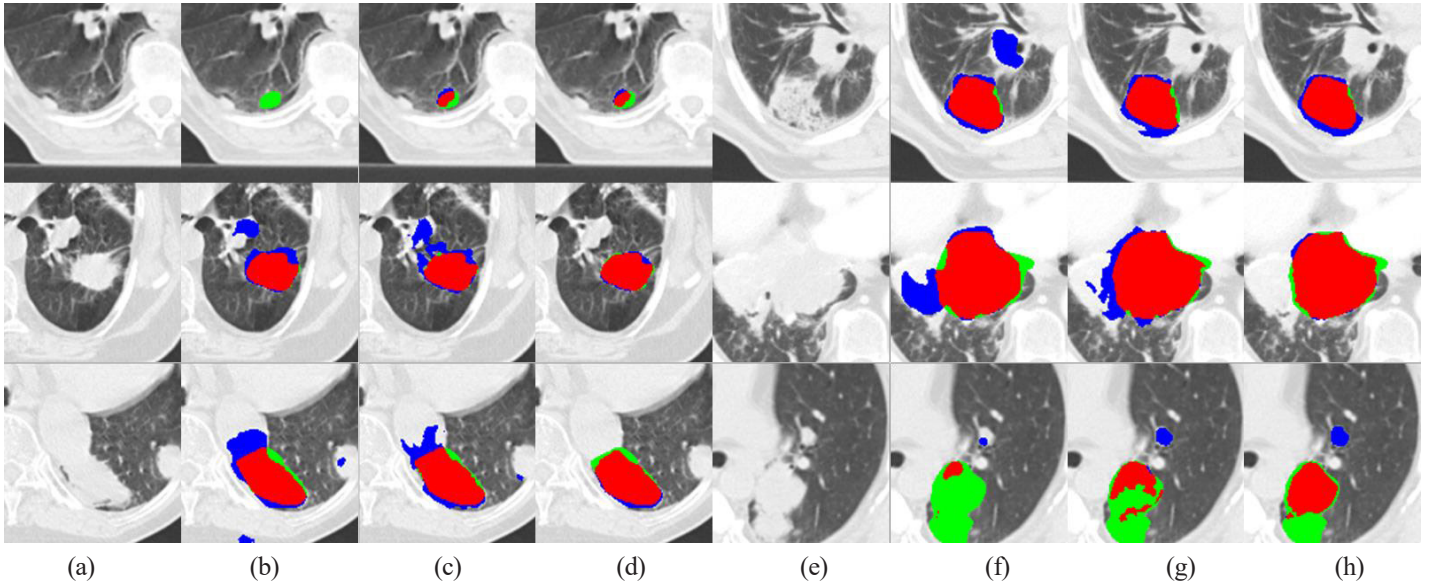


Figure 3. Quantitative evaluation of lung cancer segmentation (a) and (e) original CT images, (b) and (f) U-Net, (c) and (g) U-Net3+, (d) and (h) U-Net3+ with deep supervision and HLF loss (Ours) (Red : overlapping area with ground-truth, Green: under-segmented areas, Blue: over-segmented areas)

향상시키기 위한 분할 네트워크를 제안했다. 제안 네트워크는 UNet3+ 네트워크 구조를 백본으로 사용하며 다양한 스케일의 스킵 연결 및 심층 감독을 포함하고 하이브리드 병변

초점 손실함수를 제안했다. 다양한 스케일의 스킵 연결을 통해 다양한 특징 맵들의 정보를 결합하여 다양한 크기의 폐암 정보를 효과적으로 학습할 수 있도록 하였으며, 하이브리드 병변 초점 손실함수는 픽셀 및 영역 기반의 접근을 통해 폐암 영역에 집중할 수 있도록 손실함수를 설계하였고, 불명확한 경계를 고려하기 위해 폐암 마스크의 형태 정보를 고려한 손실함수를 사용했다. 실험 결과, 전체적인 분할 성능 및 다양한 크기 별 폐암 분할에서 가장 우수한 DSC 성능을 보였으며, 기존의 UNet3+에서 나타나던 FP를 줄일 수 있었다. 향후 연구 방향으로 폐암의 공간 정보를 활용하는 다중-뷰 기반의 3 차원 폐암 분할 네트워크로 확장하고, 폐암과 주변 구조물을 잘 구분할 수 있는 변환된 영상 사용을 통해 폐암 분할 성능을 개선하고자 한다.

감사의 글

본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. RS-2023-00207947), 보건복지부의 재원으로 한국 보건산업진흥원의 보건의료기술연구개발사업 지원 (HI22C1496) 및 서울여자대학교 학술연구비의 지원(2024)을 받아 수행되었으며 이에 감사드립니다.

References

[1] H. Sung, J. Ferlay, R.L. Siegel, M. Laversanne, I. Soerjomataram,

A. Jemal and F. Bray, Global cancer statistics 2020: LOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 71(3), pp. 209-249, 2021

- [2] V. Greenberg, I. Lazarev, Y. Frank, J. Dudnik, S. Ariad and I. Shelef, "Semi-automatic volumetric measurement of response to chemotherapy in lung cancer patients: How wrong are we using RECIST?," *Lung Cancer*, 108, pp. 90-95, 2017
- [3] S. Hossain, S. Najeeb, A. Shahriyar, Z.R. Abdullah and M.A. Haque, "A pipeline for lung tumor detection and segmentation from CT scans using dilated convolutional neural networks," *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal*, pp.1348-1352, 2019.
- [4] H.J. Tuba, M.A. Ullah and F.K. Badhon, "Lung Tumor Segmentation and Detection using U-Net with Dilated Convolutions," *5th International Conference on Electrical Information and Communication Technology (EICT)*, pp. 1-5, 2021.
- [5] F. Zhang, Q. Wang and H. Li, "Automatic segmentation of the gross target volume in non-small cell lung cancer using a modified version of ResNet," *Technology in Cancer Research & Treatment*, 19, 2020.
- [6] J. Lee, J. Jung, H. Hong and B Kim, "Automatic Segmentation of Lung Cancer in Chest CT Images through Capsule Network-based Dual-Window Ensemble Learning," *Journal of the Korea Institute of Information Scientists and Engineers*, 48(8), pp.905-912, 2021
- [7] J.G. Jin, Y.J. Kim and KG Kim, "A Study on Lung Cancer Segmentation Algorithm using Weighted Integration Loss on Volumetric Chest CT Image," *Journal of Korea Multimedia Society*, 23(5), pp. 625-632, 2020.

- [8] H. Huang, L. Lin, R. Tong, H. Hu, Q. Zhang, Y. Iwamoto, X. Han, Y.W. Chen, and J. Wu, "UNet 3+: A Full-Scale Connected UNet for Medical Image Segmentation," *IEEE international conference on acoustics, speech and signal processing (ICASSP)*, pp. 1055-1059, 2020.
- [9] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pp. 234-241, 2015

〈 저자 소개 〉

이 민 진

- 2007년 2월 서울여자대학교 컴퓨터학과 졸업(학사)
- 2016년 8월 서울여자대학교 컴퓨터학과 졸업(박사)
- 2016년 9월~현재 서울여자대학교 소프트웨어융합학과 초빙강의교수
- 관심분야 : 의료 인공지능, 딥러닝, 영상 분할 및 분석
- <https://orcid.org/0000-0002-6773-1364>



오 윤 선

- 2024년 2월 서울여자대학교 소프트웨어융합학과 졸업(학사)
- 관심분야 : 의료 인공지능, 딥러닝, 영상분할
- <https://orcid.org/0009-0001-0196-5256>



홍 헬 렌

- 1994년 2월 이화여자대학교 전자계산학과 졸업(학사)
- 1996년 2월 이화여자대학교 전자계산학과 졸업(석사)
- 2001년 8월 이화여자대학교 컴퓨터학과 졸업(박사)
- 2001년 9월~2003년 7월 서울대학교 컴퓨터공학부 BK 조교수
- 2006년 3월~현재 서울여자대학교 소프트웨어융합학과 교수
- 관심분야 : 의료 인공지능, 딥러닝, 영상처리 및 분석
- <https://orcid.org/0000-0001-5044-7909>

