

Performance Evaluation of Automatic Segmentation based on Deep Learning and Atlas according to CT Image Acquisition Conditions

Jung Hoon Kim*

Department of Radiation Oncology, KonYang University Hospital

Received: March 31, 2024. Revised: June 20, 2024. Accepted: June 30, 2024.

ABSTRACT

This study analyzed the volumes generated by deep learning and atlas-based automatic segmentation methods, as well as the Dice similarity coefficient and 95% Hausdorff distance, according to the conditions of conduction voltage and conduction current in computed tomography for lung radiotherapy. The first result, the volumes generated by the atlas-based smart segmentation method showed the smallest volume change as a function of the change in tube voltage and tube current, while Aview RT ACS and OncoStudio using deep learning showed smaller volumes at tube currents lower than 100 mA. The second result, the Dice similarity coefficient, showed that Aview RT ACS was 2% higher than OncoStudio, and the 95% Hausdorff distance results also showed that Aview RT ACS analyzed an average of 0.2-0.5% higher than OncoStudio. However, the standard deviation of the respective results for tube current and tube voltage is lower for OncoStudio, which suggests that the results are consistent across volume variations. Therefore, caution should be exercised when using deep learning-based automatic segmentation programs at low perfusion voltages and low perfusion currents in CT imaging conditions for lung radiotherapy, and similar results were obtained with conventional atlas-based automatic segmentation programs at certain perfusion voltages and perfusion currents.

Keywords: Computed Tomography, Deep Learning, Atlas-Based Automatic Segmentation Method

I. INTRODUCTION

현대의 방사선 치료계획은 복잡한 과정으로, 컴퓨터 단층촬영 기반의 3차원 영상과 치료계획 전문가팀에 크게 의존한다^[1,2]. 방사선종양학 전문의는 컴퓨터 단층 촬영 시뮬레이션을 기반으로 관련 표적의 부피와 주변 정상 구조물의 윤곽을 파악하고 선량측정 담당자와 손상위험 장기를 줄이면서 표적에 치료 방사선량을 전달할 수 있는 예상 선량 측정 목표를 소통한다^[3]. 폐암 치료의 핵심요소인 폐 방사선 치료는 치료의 효과를 극대화하고 건강한 조직에 대한 손상을 최소화하기 위해 높은 정밀도를 요구한다. 이러한 정밀도를 달성하기 위한 핵심은 컴퓨터 단층 촬영 이미지에서 폐 구조의 정확

한 분할에 있다. 최근 의료영상 분야의 발전은 딥러닝과 아틀라스기반 자동분할과 정교한 분할 기술의 개발로 이어졌고, 이러한 방법들은 방사선 치료계획에 필수적인 폐 분할의 정확도를 향상시킬 가능성을 제공한다. 딥러닝은 다량의 CT 데이터를 학습하여 폐 조직을 자동 분할하는 기법으로, 복잡한 폐 조직의 특징을 인식할 수 있다. 반면, 아틀라스기반 자동분할은 사전에 구축된 폐 조직의 통계적 모델을 활용하여 분할 작업을 수행한다^[4].

폐 방사선 치료는 폐종양을 치료하기 위해 널리 사용되는 중요한 치료방법 중 하나이며, 치료의 효과와 환자의 생존율을 높이기 위해서는 정확한 폐종양의 분할이 필수적이다. 그러나 폐종양의 정확한 분할은 전문가의 수작업에 의존하므로 시간과

* Corresponding Author: Kim Jung Hoon

E-mail: medduck@kyuh.ac.kr

Tel:

노력이 많이 필요하다. 고급 영상 기술, 특히 컴퓨터 단층 촬영의 등장으로 의료 진단 및 치료계획 분야, 특히 방사선종양학에서 혁명을 일으키고 있다^[5]. 폐암 방사선 치료에서 CT 이미지는 폐 조직의 정밀한 구분은 효과적인 방사선 치료 계획을 수립하는 데 매우 중요하다. 이러한 정밀도는 방사선 치료 처방 선량이 암 조직에 정확하게 표적 화되면서 건강한 폐 조직을 보호함으로써 치료 효과를 최적화하고 부작용을 최소화하는 데 도움이 되고 있다^[6,7]. CT 스캔의 설정은 해상도, 슬라이스 두께, 조영제의 사용, 환자의 배치, 그리고 호흡 상태 등 여러 요소를 포함한다. 이러한 요소들이 딥 러닝과 아틀라스기반의 이미지 분할 방법에 어떤 영향을 미치는지를 정확하게 이해하는 것은 방사선 치료의 효율성을 높이는데 매우 중요하다^[7]. 딥 러닝과 아틀라스기반 자동분할은 최근에 발전된 컴퓨터 기술로, 이러한 문제를 해결하기 위해 활발히 연구되고 있다. 이러한 딥 러닝과 아틀라스기반 자동분할의 다양한 CT 스캔 조건 변경에 따라 평가하기 위해서 기존에 사용하는 다양한 CT 스캔 조건에서 어떤 변수들이 성능에 미치는 영향을 체계적으로 분석하여 폐 방사선 치료에서의 정확한 구조 분할을 위한 최적의 조건을 도출하는 것이 이 연구의 주된 목표이다. 이러한 배경을 바탕으로, 본 논문은 폐 방사선 치료를 위한 CT 촬영조건에 따른 폐의 딥 러닝과 아틀라스기반 자동분할의 임상적 타당성을 조사하고 분석한 결과를 제시하고자 한다.


II. MATERIAL AND METHODS

본 실험은 Brilliance CT Big Bore™ (Philips, Amsterdam, Netherlands) 장비를 이용하여 Lungman phantom (Multi-purpose chest phantom N1, kyoto kagaku Co Ltd, Kyoto, Japan)을 사용하여 Chest CT 촬영조건인 helical mode scan으로 단면은 3 mm로 촬영하였다. 실험 촬영조건으로 관전압은 90, 120, 140 kVp 이며, 각각의 관전압 설정에 대해서 관전류를 15, 30, 50, 100, 150, 200 mAs의 범위로 설정하여 스캔을 수행하였다. 각각 스캔된 영상은 치료 계획프로그램인 Eclipse treatment planning system (Version 13.0, Varian, Palo Alto, Ca, USA; ETPS)으


로 보내 3차원 CT 영상 볼륨을 만들었다.



Fig. 1. Lungman phantom.



(a) Rt Lung Contour



(b) Lt Lung Contour

Fig. 2. Comparison of deep learning auto-segmentation and smart segmentation of Rt, Lt lung contour using lung man phantom (Ⓐ:SSM, Ⓑ:ARA, Ⓒ: OCS).

본 연구에서 폐의 자동분할에 사용되는 프로그램은 ETPS의 Smart segmentation (SSM)이며, 딥 러닝 자동분할 프로그램은 OncoStudio (Version 2.0, Oncosoft; OCS)와 Aview RT ACS (version 10.0, coreline: ARA)을 사용하였다.

SSM의 폐의 볼륨은 오른쪽 폐와 왼쪽의 폐 상단 부분인 폐 첨 부위부터 폐 기저 부위까지 영역을

설정하여 두 개의 폐 볼륨을 생성하였으며, OCS와 ARA는 각각 프로그램에서 생성된 볼륨을 ETPS로 불러들여 왼쪽 폐 오른쪽 폐의 볼륨을 생성하였다. 자동분할 평가방법으로는 첫 번째로는 폐의 볼륨 비교와 Dice 유사도 계수(Dice similarity coefficient : DSC) 그리고 95% 하우스도르프 거리(95% Hausdorff distance : HD)를 이용하였다. 폐의 볼륨 측정 방법으로 각 스캔 조건별로 생성된 영상에서 오른쪽 폐와 왼쪽 폐의 볼륨을 ETPS의 자동 볼륨 측정 방법을 이용하여 측정하였다(Fig. 2). 기존 임상에서 폐의 윤곽선은 기관지와 기도 부위의 윤곽선을 제외했지만 본 실험에서는 제외하지 않고 분석을 하였다⁸⁾. DSC의 지표는 두 데이터 세트 간의 유사성을 정량화하는 데 사용된다. 윤곽선 비교의 맥락에서 딥 러닝 알고리즘에 의해 생성된 자동 분할 윤곽선이 의료 전문가에 의해 그려진 수동 분할 윤곽선과 얼마나 밀접하게 일치하는지를 측정하며, 0에서 1까지의 범위를 가지고 1은 두 세트의 윤곽선이 완벽하게 일치함을 나타낸다⁹⁾. DCS는 Eq. (1)를 이용하여 정의된다. HD의 지표는 한 세트에서 가장 가까운 다른 세트의 점까지의 최대 거리를 측정되며, 분할된 윤곽선의 각 점이 수동 윤곽선의 어떤 점에 가까이 있는 정도를 측정하는 것이다¹⁰⁾. 이러한 지표는 폐암 환자의 위험기관 및 임상적 대상 부위에 대한 자동 분할 윤곽과 수동으로 윤곽을 그린 것을 비교하기 위해 사용되었으며 Eq. (2)를 이용하여 정의된다.

$$DSC = \frac{2 \times |X \cap Y|}{|X| + |Y|} \quad (1)$$

$|X \cap Y|$: the size of the intersection of the two sets

$|X|$ and $|Y|$: the sizes of the two sets being compared

X, Y : the similarity between two sets

$$H(A, B) = \max\{\max_{a \in A} \min_{b \in B} d(a, b), \max_{b \in B} \min_{a \in A} d(a, b)\} \quad (2)$$

A and B non-empty sets

$d(a, b)$ distance function representing the distance between an element a of A and an element b of B

III. RESULT

1. 관전압과 관전류의 변화에 따른 폐의 볼륨 변화

좌측, 우측 폐의 볼륨 분석 결과는 Table 1, 2와 같다. SSM 사용에서 관전압과 관전류의 변화에 따른 폐 볼륨의 결과는 좌측 폐 볼륨 90, 120, 140 kVp의 관전압에서 평균 볼륨은 각각 2310.66 cc, 2307 cc, 2306.49 cc 이며, 평균값의 차이는 4.17 cc 값을 나타내고 있다. 우측 폐의 볼륨 90, 120, 140 kVp의 관전압 평균 볼륨은 각각 2503.99 cc, 2500.68 cc, 2499.66 cc 이며, 각각 평균값의 차이는 4.33 cc 값을 나타내고 있다. OCS 자동분할 방법 결과에서 좌측 폐의 볼륨 90, 120, 140 kVp의 관전압에서 평균 볼륨은 각각 2347.43 cc, 2352.58 cc, 2352.19 cc 이며, 볼륨의 평균값 차이는 10.76 cc 값을 나타내고 있다. 우측 폐의 볼륨 90, 120, 140 kVp의 관전압의 평균 볼륨은 각각 2492 cc, 2497.52 cc, 2497.47 cc 이며, 각각 평균값의 차이는 5.53 cc 값을 나타내고 있다. 마지막으로 ARA의 자동분할 방법에서 좌측 폐의 결과로 90, 120, 140 kVp의 관전압 평균 볼륨은 각각 2277.56 cc, 2270.46 cc, 2264.36 cc 이며, 각각 볼륨의 평균값의 차이는 13.2 cc 값을 나타내고 있다. 우측 폐의 볼륨 90, 120, 140 kVp의 관전압 평균 볼륨은 각각 2462.62 cc, 2453.86 cc, 2446.88 cc 이다. 각각 평균값의 차이는 15.74 cc 값을 나타내고 있으며, 좌측 폐의 볼륨의 최대 볼륨은 OCS의 90 kVp, 200 mAs로 촬영한 영상이며, 최소 볼륨을 획득한 영상은 ARA의 140 kVp, 50 mAs로 촬영한 영상이다. 우측 폐의 볼륨의 최대 볼륨은 SSM의 90 kVp, 30 mAs로 촬영한 영상이며, 최소 볼륨을 획득한 영상은 ARA의 140 kVp, 50 mAs의 결과 값을 보여주고 있다. 결과적으로 좌측, 우측 볼륨의 관전압과 관전류의 변화에 따른 CT scan의 결과에서 차이가 크게 나는 방법에서는 ACS의 방법이며, 차이가 가장 적은 방법으로는 SSM 방법으로 분석되었다.

2. DCS와 95% 하우스도르프거리

좌측, 우측 폐의 DCS와 95% HD의 분석 결과는 Table 3, 4와 Fig. 3과 Fig. 4와 같다. DCS와 95%

HD 거리의 결과에서는 좌측, 우측 폐에서 각각 SSM을 기준으로 OCS와 ARA를 비교평가 하였다. 첫 번째로 우측 폐의 OCS 결과에서 DCS 최대값은 0.983865로 120 kVp, 150 mAs에서 획득한 영상이며, 최저값으로는 0.972782로 90 kVp, 15 mAs에서 획득한 영상이다. ARA의 DSC의 최대값은 0.989266으로 120 kVp, 150 mAs에서 획득한 영상이며, 최소값은 0.973951로 90 kVp, 15 mAs로 획득한 영상이다. 95% HD 거리에서 우측 폐의 OCS 최대값은 140 kVp, 15 mAs에서 획득한 영상이며 결과값으로 9.72947 이며, 최소값은 1.163567로 120 kVp, 150 mAs에서 획득한 영상이다. 또한, ARA의 최대값은 6.17991로 140 kVp, 30 mAs로 획득한 영상이며, 최소값은 1.16975로 120 kVp, 150 mAs로 획득한 영상이다. 좌측 폐의 DCS 결과에서 ARA

최대값은 0.990904로 140 kVp, 200 mAs에서 획득한 영상이며, 최저값은 0.977582로 90 kVp, 15 mAs에서 획득한 영상이다. OCS에서 DCS의 최대값은 0.985658로 90 kVp, 150 mAs에서 획득한 영상이며, 최소값은 0.979056로 120 kVp, 150 mAs에서 획득한 영상이다. 95% HD거리의 좌측 폐의 ARA의 최대값은 4.70979로 90 kVp, 30 mAs에서 획득한 영상이며, 최소값은 0.859573로 140 kVp, 200 mAs로 획득한 영상이다. 좌측 폐에서 OCS의 최대값은 3.01498로 90 kVp, 15 mAs에서 획득한 영상이며, 최소값은 1.4501로 90 kVp, 150 mAs에서 획득한 영상이다. Fig. 3.는 OCS와 ARA의 관전류와 관전압의 변화에 따른 DCS의 중앙값, 최대값과 최소값의 결과를 그래프로 보여주고 있다.

Table 1. Volume of the left lung (Smart segmentation:SSM, Oncostudio:OCS, Aview RT ACS:ARA) Measured using the automatic volume measurement method of eclipse treatment planning system

KV/mAs	SSM			OCS			ARA		
	90	120	140	90	120	140	90	120	140
15	2311.1	2307.6	2306.8	2333.8	2347.9	2350.5	2254.5	2237.5	2236.3
30	2310.7	2307.8	2306.6	2332.4	2352.6	2352.5	2244.4	2249.5	2235.5
50	2310.1	2307.5	2306.5	2348.9	2353.1	2352.8	2274.2	2247.6	2247.9
100	2310.8	2307.4	2306.6	2353.2	2353.8	2352.9	2293.2	2289.2	2288.3
150	2310.7	2307.4	2306.3	2354.0	2353.7	2352.1	2293.1	2289.2	2288.0
200	2310.8	2307.4	2306.2	2354.8	2353.5	2352.4	2290.9	2289.1	2290.1
Average Volume	2310.7	2307.5	2306.5	2346.2	2352.4	2352.2	2275.1	2267.0	2264.4
Standard Deviation	0.336	0.174	0.195	10.348	2.254	0.880	21.322	24.591	27.132

Table 2. Volume of the right lung (Smart segmentation:SSM, Oncostudio:OCS, Aview RT ACS:ARA) Measured using the automatic volume measurement method of eclipse treatment planning system

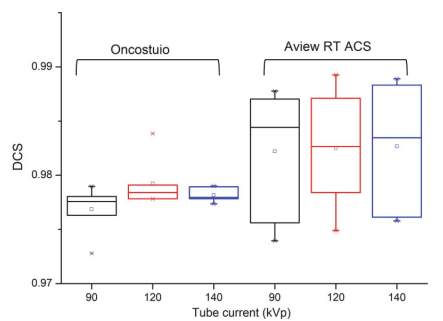
KV/mAs	SSM			OCS			ARA		
	90	120	140	90	120	140	90	120	140
15	2504.5	2501.1	2499.9	2476.2	2495.8	2498.3	2437.8	2415.9	2413.9
30	2504.0	2500.9	2499.9	2489.8	2498.9	2498.2	2424.6	2428.0	2413.1
50	2503.8	2500.8	2499.7	2490.2	2497.8	2497.0	2455.9	2426.0	2426.4
100	2503.9	2500.6	2499.6	2496.9	2497.7	2497.5	2480.8	2476.0	2474.9
150	2504.0	2500.6	2499.5	2497.4	2497.8	2496.6	2480.5	2475.8	2474.9
200	2504.0	2500.6	2499.5	2496.4	2497.6	2497.3	2478.9	2475.7	2478.2
Average Volume	2504.0	2500.8	2499.7	2491.2	2497.6	2497.5	2459.7	2449.6	2446.9
Standard Deviation	0.230	0.201	0.180	8.088	0.979	0.642	24.368	29.052	32.227

Table 3. Comparison DCS and 95% hausdorff of deep learning auto-segmentation and smart segmentation for Rt Lung

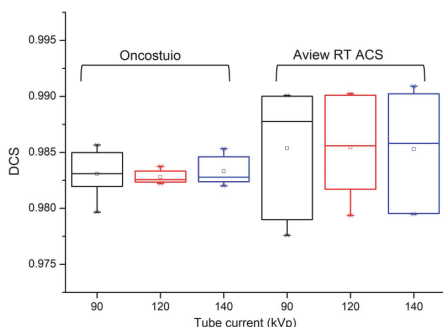
Voltage	mAs	OCS (OncoStuio)		ARA (Aview RT ACS)OCS	
		95% Hausdorff	Dice coefficient	95% Hausdorff	Dice coefficient
90	15	9.69155	0.972782	5.79723	0.973951
	30	9.50776	0.977268	6.03933	0.975613
	50	9.09382	0.976296	2.59795	0.98188
	100	9.25831	0.977865	1.40203	0.986972
	150	9.15714	0.978968	1.40266	0.987033
	200	9.15959	0.978029	1.48211	0.987776
120	15	9.46384	0.978775	6.00064	0.974888
	30	9.4659	0.978025	4.71951	0.978389
	50	9.42104	0.977815	4.91714	0.978441
	100	9.4126	0.977812	1.40203	0.986863
	150	1.163567	0.983865	1.16975	0.989266
	200	9.55206	0.979084	1.40296	0.987107
140	15	9.72947	0.978011	5.95372	0.976123
	30	9.29259	0.977827	6.17991	0.975777
	50	9.38402	0.977894	4.7187	0.978674
	100	9.37212	0.977359	1.48795	0.98825
	150	9.6758	0.978932	1.48804	0.988326
	200	9.58589	0.978996	1.29024	0.988907

Table 4. Comparison DCS and 95% hausdorff of deep learning auto-segmentation and smart segmentation for Lt Lung

Voltage	mAs	OCS (OncoStuio)		ARA (Aview RT ACS)OCS	
		95% Hausdorff	Dice coefficient	95% Hausdorff	Dice coefficient
90	15	3.01498	0.982732	4.49813	0.977582
	30	2.75305	0.979659	4.70979	0.978987
	50	1.62112	0.981956	1.66834	0.986009
	100	1.53575	0.984987	1.19671	0.990018
	150	1.4501	0.985658	1.19725	0.990082
	200	1.62169	0.983468	1.2802	0.989508
120	15	1.85237	0.983334	4.63729	0.979366
	30	1.69105	0.982339	3.42553	0.981933
	50	1.61402	0.982358	3.21543	0.98171
	100	1.61385	0.982214	1.10279	0.990101
	150	1.62461	0.982751	1.48716	0.989266
	200	1.63258	0.983761	0.95824	0.990241
140	15	1.73607	0.98461	4.63729	0.979481
	30	1.691	0.982006	4.63815	0.979542
	50	1.69113	0.982998	3.07824	0.982287
	100	1.5356	0.985329	0.99122	0.990236
	150	1.74307	0.98237	1.149	0.989321
	200	1.71114	0.982554	0.84957	0.990904




(a) Rt Lung

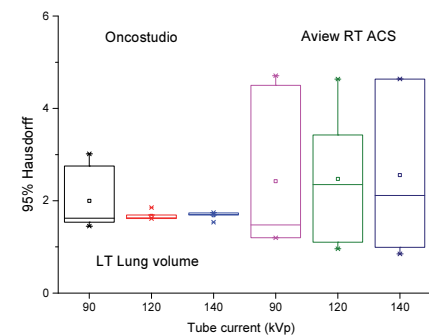


(b) Lt Lung

Fig. 3. Lung volume for CT scan Oncostudio and Aviev RT ACS of DCS.



(a) Rt Lung



(b) Lt Lung

Fig. 4. Lung volume for CT scan Oncostudio and Aviev RT ACS of 95% hausdorff.

DCS는 좌측, 우측 폐의 경우 모두 ARA의 중앙값이 OCS보다 0.2~0.5 % 높게 분석되었으며, 좌측, 우측폐의 최대값과 최소값의 차이에서 OCS는 0.001~0.006 정도이지만 ARA에서는 0.011~0.14의 차이를 보여주고 있다. Fig. 4.는 좌측폐, 우측폐의 95% 하우스드로프의 중앙값, 최대값과 최소값의 결과이며, OCS 방법에서 오른쪽 폐의 경우에는 모든 관전압의 결과에서 중앙값이 9 이상의 결과를 나타내고 있으며, 왼쪽 폐의 결과는 오히려 ARA 결과보다 낮은 결과를 보여주고 있으며, 최대값, 최소값의 차이도 OCS가 ARA보다 낮은 결과를 나타내고 있다.

IV. DISCUSSION

본 연구는 폐 방사선 치료를 위한 CT 촬영조건에 따른 폐의 딥 러닝과 아틀라스기반 자동분할의 임상적 타당성을 조사하고 분석한 결과를 평가하였다. 분석 방법으로 Lungman phantom을 이용하여 좌측, 우측 폐의 볼륨 변화를 확인하였고, 그에 따른 DCS와 95%의 HD 거리도 분석하였다. 좌측, 우측 폐의 볼륨 변화의 분석에서 확인된 결과로 SSM 방법이 촬영조건 변화에 따른 볼륨 변화에서 가장 적은 변화를 보여주었다. 이는 아틀라스기반 자동분할 기술을 사용하여 관심 있는 장기의 경계가 이미 정확하게 표시된 참조 이미지인 아틀라스를 이용하여 참조 이미지와 분할 할 새 이미지가 등록되고, 두 이미지 간의 최적 변화 매개변수를 얻은 다음, 얻은 변화 매개변수를 기반으로 아틀라스 분할에서 새 테스트 이미지로 레이블을 전파하여 자동으로 분할한다. 이 방법은 이론적으로 정확한 분할 결과를 가지지만, 실제로 분할 정도는 참조 이미지와 분할 할 이미지 간의 유사성에 크게 의존하고 있다^[11-13]. 반면에 OCS와 ARA는 관전압과 관전류에 변화에 따라 볼륨의 변화가 나타나고 있다. OCS의 경우에는 낮은 관전압(90 kVp)과 관전류(15, 30 mAs)에서 가장 낮은 볼륨을 나타냈으며, ARA의 경우에는 관전류 50 mAs까지 모든 관전압에서 낮은 볼륨을 나타내고 있다. 이는 CT 촬영에서 낮은 관전압과 관전류 설정은 여러 가지 영상 문제점을 일으킬 수 있음을 나타낸다. 이러한 설정의 문

제점으로는 대조도 감소, 잡음 증가, 영상 선명도 저하, 재구성의 오류가 발생하여 최종 영상의 질을 저하시킬 수 있다. 하지만 환자에게 투여되는 방사선량을 줄이는 데 도움이 되지만, 영상의 품질에 부정적인 영향을 줄 수 있어 딥 러닝 학습으로 영상을 분석하는 방법에는 오류가 발생할 수 있다^[14,15]. 이러한 문제점의 보완으로 첫 번째로 이미지 후처리기술 방법인 영상 잡음을 감소시키고 대조도를 개선하기 위해 다양한 이미지 후처리기술을 사용할 수 있으며, 두 번째로는 최적화된 프로토콜 사용이다. 이 방법은 환자의 체형, 검사 목적에 따라 관전압과 관전류를 최적화하여 방사선 선량과 영상 품질 사이의 균형을 맞추어 영상을 최적화하는 방법이다. 마지막으로 고급 영상 재구성 기술 방법이다. 이는 반복 재구성과 같은 고급 재구성 기술과 인공지능 기반 재구성을 사용하여 잡음을 줄이고 영상 품질을 향상시킬 수 있을 거라 사료된다^[17-21].

두 번째 분석 방법으로 DCS와 95% HD 거리입니다. DSC는 두 데이터 세트 간의 유사성을 알아보는 지표이며, 1에 가까울수록 기준이 되는 지표와 유사하다는 결과이다. 본 실험에서 좌측, 우측 폐 DCS의 중앙값 결과에서는 OCS보다 ARA가 1에 근접한 값을 나타내고 있다. 하지만 ARA의 최대값과 최소값의 차이가 OCS의 결과와 비교했을 때 90 kVp에서는 48%, 120 kVp에서 14%, 140 kVp는 29%정도의 차이를 보이고 있다. 이는 CT 스캔 조건 따라 볼륨의 차이에서 언급한 것처럼 낮은 관전압과 관전류는 영상의 화질저하로 인해 폐의 볼륨을 인식하는 문제가 발생한 것이라 생각된다. 하지만 OCS 측정된 볼륨의 변화에서도 90 kVp와 15 mAs, 30 mAs에서 낮은 볼륨을 나타나고 있어 이 또한 같은 화질저하로 인해 폐의 볼륨 인식 문제가 발생한 것이라 생각된다^[15,16]. 95% HD 거리 결과에서도 최대값 최소값의 차이는 OCS가 ARA보다 낮은 결과이며 DCS와 유사한 경향을 보여주고 있다. 하지만 Tabel 3.결과와 Fig. 5.에서 우측폐의 하우스도프거리가 9이상인 것은 Fig. 2.에서 나타난 것처럼 폐의 볼륨 윤곽선에서 기관지와 기도 부위 볼륨이 그려져 있는 것은 SSM과 ARA이지만, OCS는 그 부분이 그려져 있지 않는 것을 볼 수 있다.

하지만 방사선치료 시 기관지분 기점을 폐로 보지 않기 때문에 실제 치료계획에서 사용되는 폐의 볼륨과 유사하게 생성 되어 임상에서는 폐의 자동분할프로그램으로는 OCS 프로그램이 더 우수하다고 판단된다. 또한 ARA 프로그램 제작회사는 폐와 관련된 다른 딥러닝 프로그램을 이용하여 폐기종분석, 기관지 분석, 폐혈관분석 프로그램을 사용하고 있다. 이러한 딥러닝 학습 프로그램을 공유해서 사용하기에 CT 스캔의 영상 품질에 따라 폐의 볼륨이 생성되어 폐 관련 질병 분석이나 모니터링에 더 적합한 프로그램이라 생각된다^[22,23].

본 연구에는 이러한 상용화된 프로그램을 비교 분석한 실험이 아직까지는 없었다. 처음으로 행해지는 연구로 인해 몇 가지의 제한점이 있다. Lungman phantom 한가지로 하였기에 실제 임상 환자대상으로 하면 다양한 해부학적 구조로 인해 본 연구의 결과와 차이가 있을 것이다. 이러한 문제점을 보완하기 위해서 차후에 실제 임상에서 사용되는 폐의 윤곽선을 기준을 이용하면 좀 더 정확한 결과를 얻을 거라 사료되어 추가 연구를 진행할 것이다. 또한, 다양한 CT 스캔 조건 따른 각각의 영상평가를 하지 않았기에 아틀라스 자동분석프로그램과 딥 러닝 프로그램의 단순 비교결과이며, 차후 연구에서는 CT 영상평가와 같이 비교 분석이 필요하다고 사료된다. 마지막 제한점으로 각 회사에서 사용되는 딥러닝 학습프로그램이 어떤 알고리즘을 사용했는지 알 수 없기에 다른 결과가 도출 될 수 있는 문제점이 있을 거라 사료된다.

V. CONCLUSION

본 연구는 폐 방사선 치료를 폐의 자동분할을 위한 CT 촬영조건에서 낮은 관전압과 관전류에서 딥러닝 기반 자동분할 프로그램을 사용할 때는 주의가 필요하며, 일정 관전압, 관전류 이상에서 기존에 사용하고 있는 아틀라스기반 자동분할 프로그램과 폐의 볼륨 생성이 유사한 결과를 도출할 수 있었으며, DCS와 95% HD 거리의 결과로 보면 ARA 프로그램이 아틀라스 기반 자동분할 프로그램과 유사한 결과를 보여주고 있지만 본 연구에서는 추가하지 않은 임상 볼륨과 비교했을 경우에는 OCS 프로

그램이 더 좋은 프로그램이라 사료되어 추가적인 실제 임상에 적용된 폐의 볼륨을 적용하여 추가적인 비교 연구가 필요하다고 사료된다.

Reference

- [1] M. Dennis, C. C. Chin, "Image Guidance in Radiation Oncology Treatment Planning: The Role of Imaging Technologies on the Planning Process", *Seminars In Nuclear Medicine*, Vol. 38, No. 2, pp. 114-118, 2008. <http://dx.doi.org/10.1053/j.semnuclmed.2007.11.003>
- [2] Y. Inhwan, N. Prashanth, G. Lan, S. Reinhard, B. Stanley, G. Abiel, W. Ning, Y. Gary, L. Ted, B. David, S. Jerry, P. Baldev, "Passive proton therapy vs. IMRT planning study with focal boost for prostate cancer", *Radiation Oncology*, Vol. 10, No. 1, pp. 213, 2015. <http://dx.doi.org/10.1186/s13014-015-0522-5>
- [3] C. Coolens, A. Owrangi, D. A. Jaffray, "Implementation and characterization of a 320-slice volumetric CT scanner for simulation in radiation oncology", *Medical physics*, Vol. 36, No. 11, pp. 5120-5127, 2009. <http://dx.doi.org/10.1118/1.3246352>
- [4] Y. Zepa, C. Insung, C. Junhan, J Jongha, R. Minyeong, H. S. Yong, "Deep learning-based pectoralis muscle volume segmentation method from chest computed tomography image using sagittal range detection and axial slice-based segmentation", *PLOS ONE*, Vol. 18, No. 9, pp. 0290950, 2023. <http://dx.doi.org/10.1371/journal.pone.0290950>
- [5] G. C. Pereira, M. Traughber, R. F. Muzic, "The Role of Imaging in Radiation Therapy Planning: Past, Present, and Future", *BioMed Research International*, Vol. 2014, pp. 1-9, 2014. <http://dx.doi.org/10.1155/2014/231090>
- [6] M. Spencer, J. Carol, B. Mark, P. A. David, L. B. John, B. S. Steven, L. V. Alexander Y. Edward, Y. Brian, Ak. Belal, R. B. George, G. Stewart, "Impact of target volume segmentation accuracy and variability on treatment planning for 4D-CT-based non-small cell lung cancer radiotherapy", *Acta Oncologica*, Vol. 54, No. 3, pp. 322-332, 2014. <http://dx.doi.org/10.3109/0284186X.2014.970666>
- [7] L. Xi, L. Kai-wen, Y. Ruije, G. Li-sheng, "Review of Deep learning based automatic segmentation for lung cancer radiotherapy", *Frontiers in Oncology*, Vol. 11, pp. 717039, 2021. <http://dx.doi.org/10.3389/fonc.2021.717039>
- [8] S. Ukil, J. M. Reinhardt, "Anatomy-guided lung lobe segmentation in X-ray CT images." *IEEE Transactions on Medical Imaging*. Vol. 28, No. 2, pp. 202-214, 2008. 10.1109/TMI.2008.929101
- [9] K, H. Zou, S. K. Warfield, A. Bharatha, C. M.C. 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.", *Radiology Alliance for Health services research*, Vol. 11, No. 2, pp. 178-189, 2004. [https://doi.org/10.1016/S1076-6332\(03\)00671-8](https://doi.org/10.1016/S1076-6332(03)00671-8)
- [10] D. P. Huttenlocher, G. A. Klanderman, W. J. Rucklidge, "Comparing images using the Hausdorff distance.", *IEEE Transactions on Medical Imaging*. Vol. 15, No. 9, pp. 850-863, 1993. 10.1109/34.232073
- [11] E. Gibbons, M. Hoffmann, J. Westhuyzen, A. Hodgson, B. Chick, A. Last, "Clinical Evaluation of Deep Learning and Atlas-Based Auto-Contouring for Head and Neck Radiation Therapy", *Journal of Medical Radiation Sciences*, Vol. 70, No. 2, pp. 15-25, 2023. <https://doi.org/10.1002/jmrs.618>
- [12] P. Aljabar, R. A. Heckemann, A. Hammers, J. V. Hajnal, D. Rueckert, "Multi-atlas based segmentation of brain images: Atlas selection and its effect on accuracy", *NeuroImage*, Vol. 46, No. 3, pp. 726-738, 2009. <http://dx.doi.org/10.1016/j.neuroimage.2009.02.018>
- [13] I. Isgum, M. Staring, A. Rutten, M. Prokop, M. A. Viergever, B. V. Ginneken, "Multi-atlas-based segmentation with local decision fusion-application to cardiac and aortic segmentation in CT scans", *IEEE Trans Med Imaging*, Vol. 28 No. 7, pp. 1000-1010, 2009. <http://dx.doi.org/10.1109/TMI.2008.2011480>
- [14] J. E. Iglesias, M. R. Sabuncu, "Multi-Atlas Segmentation of Biomedical Images: A Survey", *Medical Image Analysis*, Vol. 24, No. 1, pp. 205-219, 2015. <http://dx.doi.org/10.1016/j.media.2015.06.012>
- [15] S. B. Rebecca, J. Lipson, R. Marcus, K. P. Kim, M. Mahesh, R. Gould, A. B. Gonzalez, D. L.

- Miglioretti, "Radiation dose associated with common computed tomography examinations and the associated lifetime attributable risk of cancer", *Archives of Internal Medicine*, Vol. 169, No. 22, pp. 2078-2086, 2009.
<http://dx.doi.org/10.1001/archinternmed.2009.427>
- [16] C. H. McCollough, G. H. Chen, W. Kalender, S. Leng, E. Samei, K. Taguchi, G. Wang, L. Yu, R. I. Pettigrew, "Achieving routine submillisievert CT scanning: report from the summit on management of radiation dose in CT", *Radiology*, Vol. 264, No. 2, pp. 567-580, 2012.
<http://dx.doi.org/10.1148/radiol.12112265>
- [17] X. Liu, K. Gao, B. Liu, C. Pan, K. Liang, L. Yan, J. Ma, f. He. S. Zhang, Y. Yu, "Advanced deep learning techniques for retinal image analysis", *Health Data Science*, Vol. 2021, Article ID 9806173, 2021.
- [18] J. M. Fitzpatrick, M. Sonka, *Statistical image reconstruction methods for transmission tomography*, *Handbook of Medical Imaging*, Volume 2. Medical Image Processing and Analysis, pp. 14-18, 2000.
- [19] G. Wang, J. C. Ye, K. Mueller, J. A. Fessler, "Image reconstruction is a new frontier of machine learning", *IEEE Transactions on Medical Imaging*, Vol. 37, No. 6, pp. 1289-1296, 2018.
<http://dx.doi.org/10.1109/TMI.2018.2833635>
- [20] H. J. Kim, "Analysis of Image Quality and Scan Dose when Applying Reconstruction Algorithm Changes to Chest CT Scans", *Journal of Korean Society of Radiology*, Vol. 17, No 6, pp. 819-825, 2023. <http://dx.doi.org/10.7742/jksr.2023.17.6.819>
- [21] G. H. Kim, J. S. Kim, C. D. Kim, J. P. Lee, J. W. Hong, D. K. Han, "A Study on the Usefulness of Deep Learning Image Reconstruction with Radiation Dose Variation in MDCT", *Journal of Korean Society of Radiology*, Vol. 17, No. 1, pp. 37-46, 2023. <https://doi.org/10.7742/jksr.2023.17.1.37>
- [22] L. D'hondt, P. J. Kellens, K. Torfs, H. Bosmans, K. Bacher, A. Snoeckx, "Absolute ground truth-based validation of computer-aided nodule detection and volumetry in low-dose CT imaging", *European Journal of Medical Physics*, Vol 121, 103344, 2024.
<https://doi.org/10.1016/j.ejmp.2024.103344>
- [23] T. Gao, Y. F. Wang, H. R. Zhang, X. C. Ynag, J. X. Zhou, L. Zhu, "CT quantification of pulmonary vessels in lung aging", *Clinical Radiology*, Vol. 79, No 5, pp. 767-774, 2024.
<https://doi.org/10.1016/j.crad.2024.01.016>

CT 영상획득 조건에 따른 딥 러닝과 아틀라스 기반의 자동분할 성능 평가

김정훈*

건양대학교병원 방사선종양학과

요 약

본 연구는 폐 방사선 치료를 위한 컴퓨터 단층촬영의 관전압, 관전류 조건에 따라 딥 러닝과 아틀라스 기반 자동분할 방법에 따른 생성된 볼륨과 Dice 유사도 계수와 95% 하우스도르프 거리를 분석하였다. 첫 번째 결과로 관전압 관전류의 변화에 생성된 볼륨의 결과에서는 아틀라스기반인 smart segmentation 방법이 가장 적은 볼륨 변화를 보여주었으며, 딥 러닝을 사용한 Aview RT ACS와 OncoStudio에서는 100 mAs보다 낮은 관전류에서는 볼륨이 작아지는 걸 확인했다. 두 번째 결과인 Dice 유사도 계수에서는 Aview RT ACS가 OncoStudio 보다 2% 높은 결과를 보여주고 있으며, 95% 하우스도르프거리 결과에서도 Aview RT ACS가 OncoStudio 보다 평균 0.2~0.5% 높게 분석되었다. 하지만 관전류와 관전압에 따라 각각의 결과의 표준편차에서는 오히려 OncoStudio가 낮으므로 볼륨의 변화에서도 일관성 있을 거라 사료된다. 따라서 폐 방사선 치료를 위한 CT 촬영조건에서 낮은 관전압과 낮은 관전류에서 딥 러닝 기반 자동분할 프로그램을 사용할 때는 주의가 필요하며, 일정 관전압, 관전류 이상에서 기존에 사용하고 있는 아틀라스기반 자동분할 프로그램과 유사한 결과를 도출할 수 있었다.

중심단어: 컴퓨터 단층촬영, 딥 러닝, 아틀라스기반 자동분할방법, Smart Segmentation

연구자 정보 이력

	성명	소속	직위
(단독저자)	김정훈	건양대학교병원 방사선종양학과	부교수