

IX

Current state and limitation of quantification analysis on chest CT

이상민, 서준범

울산대학교 의과대학 서울아산병원 영상의학과

Chronic obstructive pulmonary disease (COPD) is a complex heterogeneous condition with various combinations of emphysema, small airways disease and chronic bronchitis. Previously, quantification of chest CT imaging had some limitation to use in clinical practices. In recent years, pulmonary imaging technologies have advanced in quantification of CT imaging using artificial intelligence. We discuss current situation, limitation, and the future role of quantification of chest CT imaging in assessing COPD.

Key Words: Chronic Obstructive Lung Disease, Quantification Analysis, COPD

Corresponding author: Sang Min Lee, M.D., Ph.D.

Address: Department of Radiology and Research Institute of Radiology, University of Ulsan College of Medicine, Asan Medical Center, 88 Olympic-ro 43 Gil, Songpa-gu, Seoul 138-736, Republic of Korea
Tel: +82-2-3010-5766, Fax: +82-2-3010-6645, E-mail: asellion@hanmail.net

1. 서론

만성폐쇄성폐질환은 다양한 임상적, 병리학적 특징을 가지고 있는 복합적인 질병으로 폐기종, 만성 기관지염 및 빈번한 악화를 포함하는 다양한 표현형을 갖는 다양한 그룹으로 구성된다¹. 폐기종으로 인한 실질 파괴 및 작은 기도 질환, 폐기종과 섬유증의 결합, 및 국소 생체 역학적 기능 장애로 인한 다양한 구성 요소가 있다². 폐에 다양하게 분포되어 있기 때문에 폐 CT 영상의 정량적 분석을 통해 제공되는 지역적, 공간적인 정보는 기존의 폐 기능검사를 넘어 임상적으로 의미 있는 정보를 제공할 수 있다. 폐 CT 영상의 정량적 분석은 주로 폐 기능의 국소 정량화로 정의할 수 있고, 비침습적으로 전체 폐에 걸쳐 해부학적 모양 및 변화, 환기, 관류 및 가스 교환을 포함한 폐 생리학적 변수의 지역적/국소적 정보를 측정할 수 있다. 폐 CT 영상의 정량적 분석은 이론적으로 폐 기능검사와 비교하여 여러 장점이 있으나, 수십 년간의 기술 연구 발전에도 불구하고 폐 CT 영상의 상대적 비용과 정량적 분석의 복잡성에 의해 아쉽게도 폐 CT 영상의 정량적 분석 결과가 환자 치료 및 예후를 개선한다는 데이터가 부족하다. 이 중설에서는 폐 CT 영상의 정량적 분석과 관련된 이미지 기법 및 인공 지능 방법의 현재와 제한점에 대하여 고찰해 보고자 한다.

2. 환기 및 관류 영상

환기 기능 및 정보를 제공하기 위해 여러 흡입 가스를 사용한 CT 영상이 이용될 수 있다. 크립톤 가스 및 제논 가스를 흡입 후 dual energy CT를 이용하여 환기 영상(Figure 1)을 얻을 수 있고³⁻⁵, 흡기 및 호기 CT 영상의 정합을 통해 parametric response map이나 emphysema air-trapping composite map을 얻을 수 있다^{6,7}. 말단 세기관지와 소기도의 초기 및 경미한 폐 이상은 CT 영상에서 명확히 보이지 않으나, parametric response

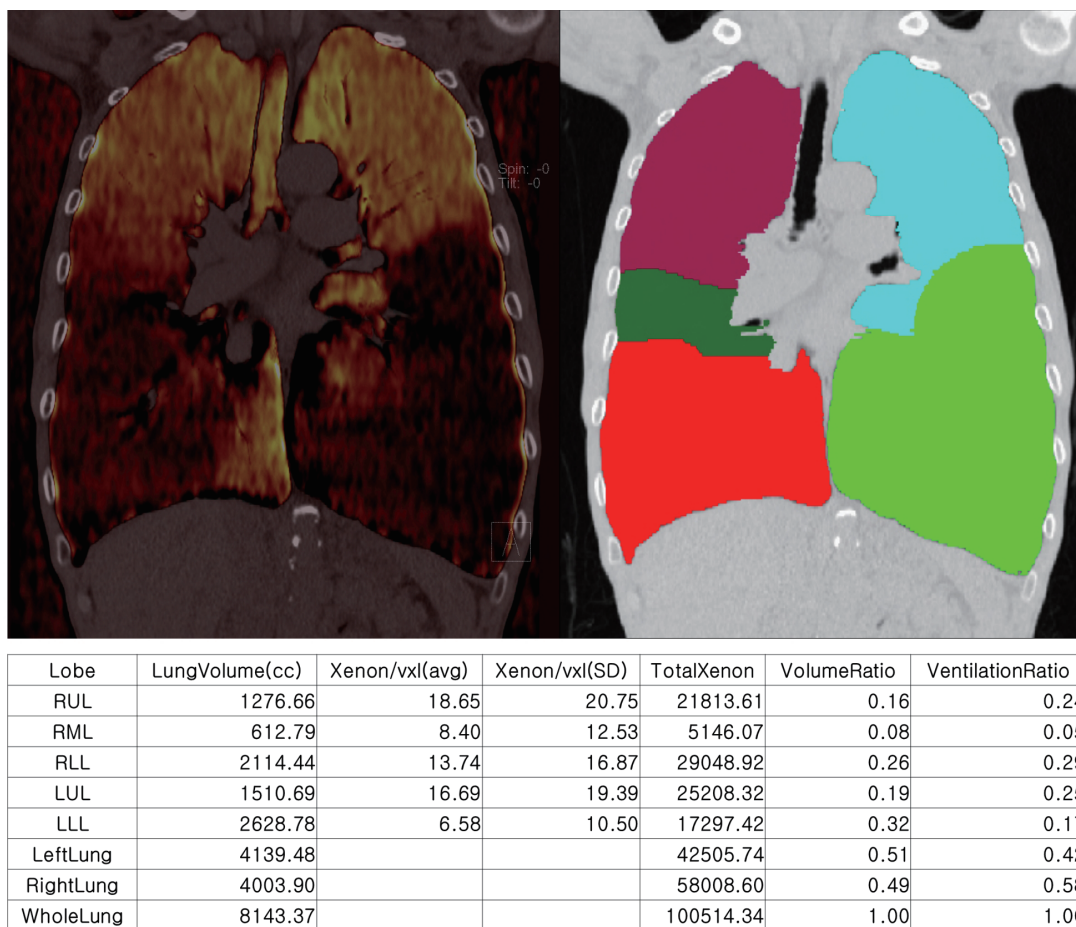


Figure 1. Quantification results of Xenon ventilation CT imaging

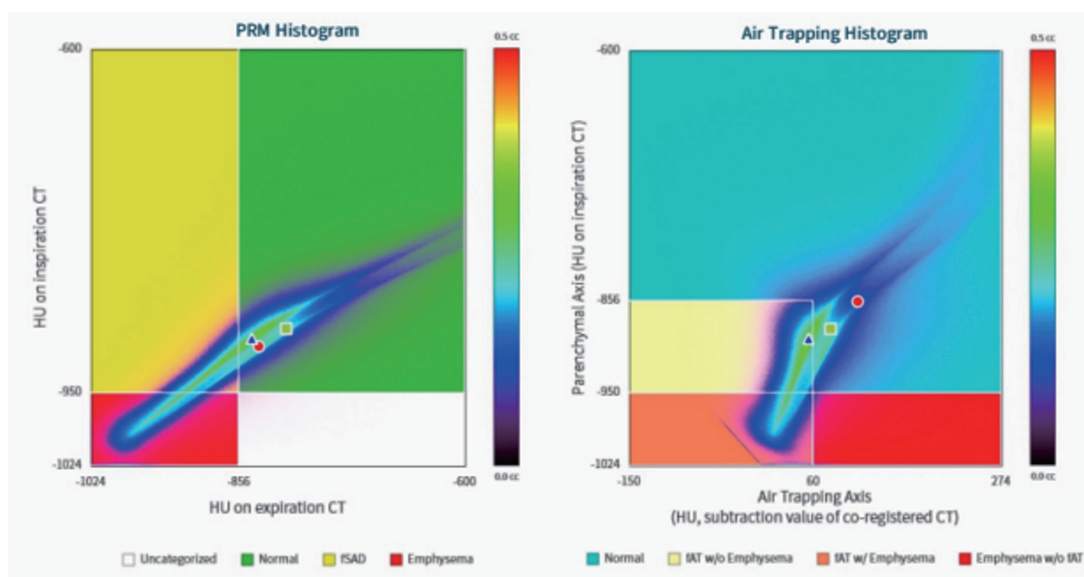


Figure 2. Parametric response map and emphysema air-trapping composite map of same COPD patient

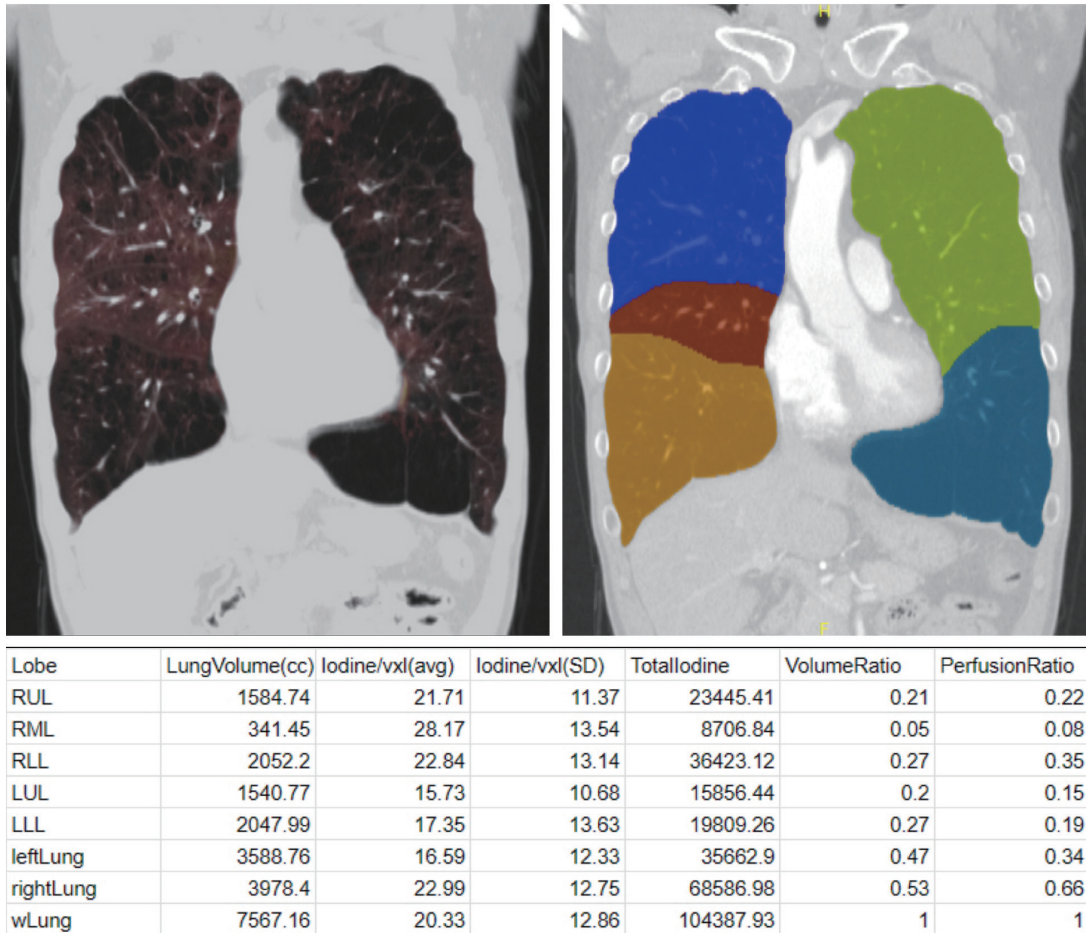


Figure 3. Quantification results of Iodine perfusion CT imaging

maps에서 흡기 시 정상적인 폐 감쇠를 갖지만 호기 시 비정상인 영역, 또는 emphysema air-trapping composite map에서 호기 및 흡기 영상의 HU차이가 적은 영역이 공기 포획 및 소기도 질환을 반영하는 것으로 생각한다. 이러한 방법을 활용하여 CT 영상으로 소기도 질환 및 폐기종의 진행을 구별, 정량화 및 모니터링할 수 있다⁶⁻⁹. CT 영상에서 확인된 소기도 질환은 FEV1의 더 빠른 감소를 예측한다¹⁰. 하지만 흡입 가스를 이용한 환기 영상은 흡입 가스의 비용 및 추가 장비 등으로 인해 임상 환자에서 활용에 제한이 있다. 최근에는 흡기 및 호기 CT 영상의 정합을 통한 분석이 인공지능을 활용하여 자동화되어 일부 임상 환자에서 활용이 되고 있다(Figure 2).

폐관류 측정은 폐쇄성 기도 질환 및 환기 및 관류 불일치가 의심되는 경우 임상적으로 중요하다. 조영제를 투여 후 dual energy CT나 area detector CT를 사용하여 iodine perfusion map을 얻을 수 있으며, CT 장비에 따라 다양한 방법으로 얻을 수 있으며¹¹⁻¹³. 높은 공간적 및 시간적 해상도로 형태 및 기능 정보를 제공한다(Figure 3).

제논 가스 흡입 후 dual energy CT와 조영제 투여 후 dual energy CT를 함께 사용하면 형태학적 변화와 관련된 환기 및 관류 일치에 대한 추가 정보를 제공할 수 있다¹⁴. 이러한 정보는 COPD의 외과적 또는 의학적 치료 후 병태생리학적 변화를 이해하는 데 유용할 수 있다^{15,16}.

3. 정량 분석 및 인공지능

폐 CT 영상에서 폐기종, 기관지 등의 정량적 분석 결과를 얻기 위해서는 전용 소프트웨어를 통해 폐, 엽, 폐 혈

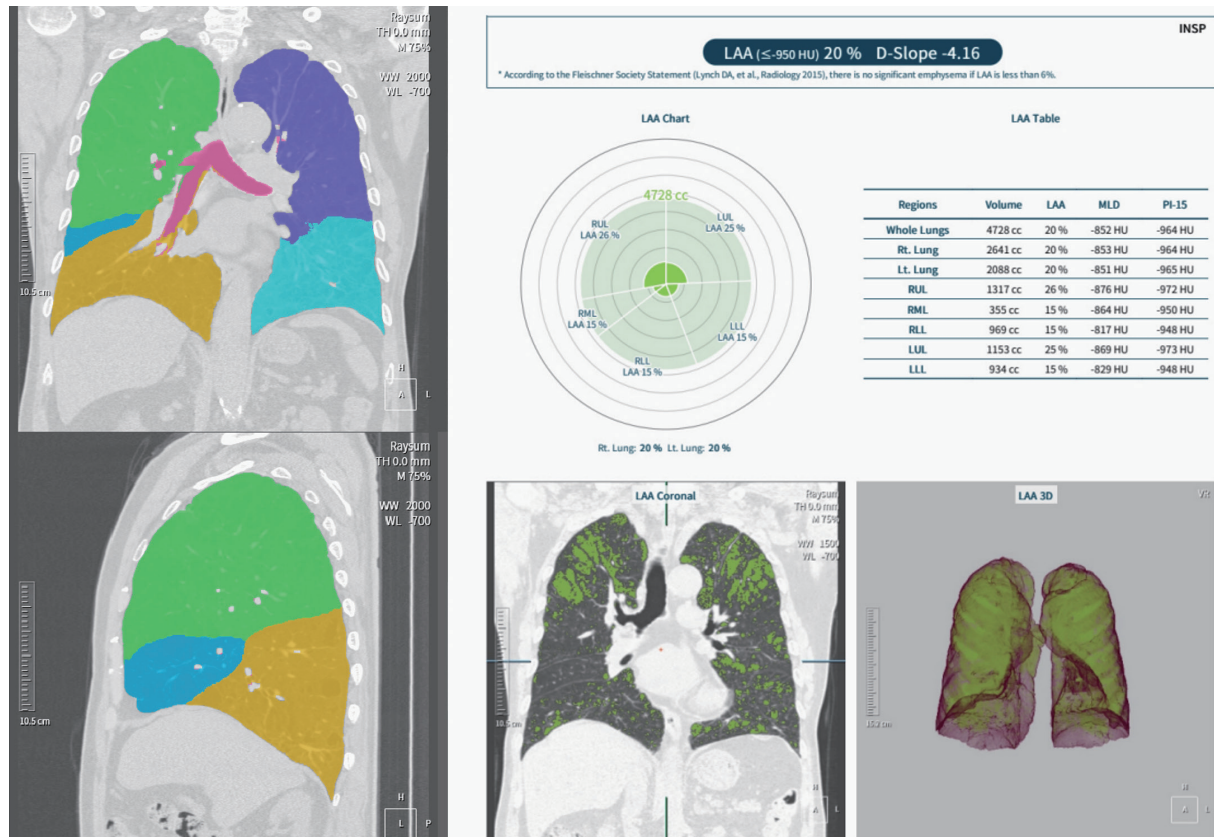


Figure 4. Lung, lobe, and airway segmentation and emphysema quantification results using fully automated quantification software

관 및 기도 분할, 호기/흡기 영상 정합과 같은 과정을 진행해야 한다(Figure 4). 그러나 이러한 방법을 임상 영상에 적용하려면 극복해야 하는 몇 가지 문제가 있다¹⁷. 첫번째로 서로 다른 CT 장비 및 영상 재구성 방법에 따라 서로 다른 영상 신호 패턴 및 잡음 형태를 보이며 이는 정량적 분석 결과의 차이를 만든다. 둘째, 영상처리 방법에 대한 표준화가 없다. 다양한 정량분석 소프트웨어마다 고유의 분할, 정합 및 분석 방법이 사용되므로 서로 다른 소프트웨어의 결과를 비교할 수 없다. 마지막으로, CT 영상의 정량적 분석에는 주로 사람의 상호 작용이 필요하여 상당한 시간과 노력이 소요되며 측정자나 측정 시기에 따라 결과값의 차이가 발생할 수 있다. 이러한 사람의 개입은 일상적인 임상 상황에서 CT 영상의 정량적 분석의 사용을 제한한다.

인공 지능을 사용한 딥 러닝 기술이 최근 의료 영상에 도입되었고^{18,19}, 인공지능을 사용하여 영상의 이상을 감지하고 감별하는 방법의 유용성은 여러 연구에서 입증되었다²⁰. 이러한 인공지능의 발전을 통해 폐 CT영상의 정량적 분석을 임상환자에게 보다 쉽게 사용할 수 있다. 그동안 많은 연구자들이 다기관 연구를 위한 CT 영상 촬영 및 영상 재구성 방법을 표준화하여 각 기관간 차이를 최소화하려고 노력했으나 이러한 관리는 실제 임상 환경에서 적용하기 어렵다. 최근 연구에 따르면 딥 러닝 방법은 다른 획득 프로토콜과 다른 기계를 사용하여 생성된 이미지 간의 신호 차이를 최소화하는 데에도 유용하며 여러 연구에서 이 기술이 폐기종의 측정 변동을 줄일 수 있음을 보여주었다^{21,22}. 또한 폐 CT 영상의 정량적 분석의 모든 단계에서 자동화에 도움이 되며, 최근 연구에 따르면 딥 러닝 방법이 이미지 분할 성능을 크게 향상시키는 것으로 나타났다²³⁻²⁵. 폐 영상의 정합은 특히 호흡과 심장 박동으로 인한 복잡한 움직임을 고려할 때 정확한 정합이 어려우며 긴 이미지 처리 시간이 필요하다. 이 한계를 해결하기 위해 딥 러닝 방법은 영상 정합의 정확도와 속도를 높이는 데에도 유용하다²⁶. 현재 여러 인공지능 방법이 폐

영상의 정량적 분석에 사용되어 자동화된 폐 CT 영상의 정량적 분석이 가능하며 임상 환자에서 적용되고 있다.

4. 결론

폐 CT 영상의 정량적 분석의 현재 상황 및 제한점, 인공 지능의 활용에 대해 이야기했다. 호흡기학, 폐 영상 및 생리학에 대한 전문 지식을 갖춘 여러 분야의 의사와 영상 분석 및 인공지능 분야의 과학자 간의 협력 및 의사 소통이 증가하면 임상 진료 환자에서 폐 CT 영상의 정량적 분석이 증가할 것으로 생각된다.

References

1. Milne, S. and G.G. King, Advanced imaging in COPD: insights into pulmonary pathophysiology. *J Thorac Dis*, 2014. 6(11): p. 1570-85.
2. Bailey, D.L., et al., (68)Ga PET Ventilation and Perfusion Lung Imaging-Current Status and Future Challenges. *Semin Nucl Med*, 2016. 46(5): p. 428-35.
3. Hachulla, A.L., et al., Krypton ventilation imaging using dual-energy CT in chronic obstructive pulmonary disease patients: initial experience. *Radiology*, 2012. 263(1): p. 253-9.
4. Chae, E.J., et al., Xenon ventilation imaging using dual-energy computed tomography in asthmatics: initial experience. *Invest Radiol*, 2010. 45(6): p. 354-61.
5. Lee, S.M., et al., Assessment of regional emphysema, air-trapping and Xenon-ventilation using dual-energy computed tomography in chronic obstructive pulmonary disease patients. *Eur Radiol*, 2017. 27(7): p. 2818-2827.
6. Galban, C.J., et al., Computed tomography-based biomarker provides unique signature for diagnosis of COPD phenotypes and disease progression. *Nat Med*, 2012. 18(11): p. 1711-5.
7. Hwang, H.J., et al., New Method for Combined Quantitative Assessment of Air-Trapping and Emphysema on Chest Computed Tomography in Chronic Obstructive Pulmonary Disease: Comparison with Parametric Response Mapping. *Korean J Radiol*, 2021. 22(10): p. 1719-1729.
8. Boes, J.L., et al., Parametric response mapping monitors temporal changes on lung CT scans in the subpopulations and intermediate outcome measures in COPD Study (SPIROMICS). *Acad Radiol*, 2015. 22(2): p. 186-94.
9. Labaki, W.W., et al., Voxel-Wise Longitudinal Parametric Response Mapping Analysis of Chest Computed Tomography in Smokers. *Acad Radiol*, 2019. 26(2): p. 217-223.
10. Bhatt, S.P., et al., Computed Tomography Measure of Lung at Risk and Lung Function Decline in Chronic Obstructive Pulmonary Disease. *Am J Respir Crit Care Med*, 2017. 196(5): p. 569-576.
11. Lu, G.M., et al., Dual-energy CT of the lung. *AJR Am J Roentgenol*, 2012. 199(5 Suppl): p. S40-53.
12. Ohno, Y., et al., Differentiation of malignant and benign pulmonary nodules with quantitative first-pass 320-detector row perfusion CT versus FDG PET/CT. *Radiology*, 2011. 258(2): p. 599-609.
13. Simons, D., M. Kachelriess, and H.P. Schlemmer, Recent developments of dual-energy CT in oncology. *Eur Radiol*, 2014. 24(4): p. 930-9.
14. Hwang, H.J., et al., Assessment of Regional Xenon Ventilation, Perfusion, and Ventilation-Perfusion Mismatch Using Dual-Energy Computed Tomography in Chronic Obstructive Pulmonary Disease Patients. *Invest Radiol*, 2016. 51(5): p. 306-15.
15. Lee, S.W., et al., Improvement in Ventilation-Perfusion Mismatch after Bronchoscopic Lung Volume

- Reduction: Quantitative Image Analysis. *Radiology*, 2017. 285(1): p. 250-260.
16. Hwang, H.J., et al., Assessment Of Changes In Regional Xenon-Ventilation, Perfusion, And Ventilation-Perfusion Mismatch Using Dual-Energy Computed Tomography After Pharmacological Treatment In Patients With Chronic Obstructive Pulmonary Disease: Visual And Quantitative Analysis. *Int J Chron Obstruct Pulmon Dis*, 2019. 14: p. 2195-2203.
 17. Ohno, Y., et al., Pulmonary Functional Imaging: Part 1-State-of-the-Art Technical and Physiologic Underpinnings. *Radiology*, 2021. 299(3): p. 508-523.
 18. Lee, J.G., et al., Deep Learning in Medical Imaging: General Overview. *Korean J Radiol*, 2017. 18(4): p. 570-584.
 19. Chartrand, G., et al., Deep Learning: A Primer for Radiologists. *Radiographics*, 2017. 37(7): p. 2113-2131.
 20. Lee, S.M., et al., Deep Learning Applications in Chest Radiography and Computed Tomography: Current State of the Art. *J Thorac Imaging*, 2019. 34(2): p. 75-85.
 21. Lee, S.M., et al., CT Image Conversion among Different Reconstruction Kernels without a Sinogram by Using a Convolutional Neural Network. *Korean J Radiol*, 2019. 20(2): p. 295-303.
 22. Bak, S.H., et al., Emphysema quantification using low-dose computed tomography with deep learning-based kernel conversion comparison. *Eur Radiol*, 2020. 30(12): p. 6779-6787.
 23. Dong, X., et al., Automatic multiorgan segmentation in thorax CT images using U-net-GAN. *Med Phys*, 2019. 46(5): p. 2157-2168.
 24. Park, J., et al., Fully Automated Lung Lobe Segmentation in Volumetric Chest CT with 3D U-Net: Validation with Intra- and Extra-Datasets. *J Digit Imaging*, 2020. 33(1): p. 221-230.
 25. Park, B., et al., Lung Segmentation on HRCT and Volumetric CT for Diffuse Interstitial Lung Disease Using Deep Convolutional Neural Networks. *J Digit Imaging*, 2019. 32(6): p. 1019-1026.
 26. Tustison, N.J., B.B. Avants, and J.C. Gee, Learning image-based spatial transformations via convolutional neural networks: A review. *Magn Reson Imaging*, 2019. 64: p. 142-153.