

의미론적 분할을 이용한 X-ray 영상 기반 신생아 호흡곤란 증후군 진단 기법

장어진¹, 조한용¹, 유선경², 강미현³, 장한얼¹

¹한밭대학교 컴퓨터공학과

²충남대학교 영상의학과

³충남대학교 소아청소년과

ej2b514@gmail.com, whgksdyd1@gmail.com, sunkyou@cnuh.co.kr, lubyuhki@cnuh.co.kr, hejang@hanbat.ac.kr

Neonatal Respiratory Distress Syndrome Diagnosis Method Based on X-ray Images Using Semantic Segmentation

Eojin Jang¹, Hanyong Cho¹, Sunkyoung You², Mi Hyeon Gang³, Haneol Jang¹

¹Dept. of Computer Engineering, Hanbat National University

²Dept. of Radiology, Chungnam National University

³Dept. of Pediatrics, Chungnam National University

요 약

신생아 호흡곤란 증후군은 주로 미숙아에게 발생하는 호흡기 질환으로, 특징적 영상 소견 및 다른 검사 소견을 바탕으로 진단된다. 본 논문은 기계 장치 등 외부 요소의 영향을 최소화하고자 폐 영역을 분할하여 신생아 호흡곤란 증후군을 진단하는 기법을 제안한다. 분할에는 UNet 구조를 사용하고 진단에는 EfficientNet-B5를 사용하여 최종적으로 신생아 호흡곤란 증후군의 진단 정확도 0.852를 달성하였다.

1. 서론

AI 의료영상 분석 기술은 특징을 추출하는 방법으로 최근 딥러닝에 기반한 학습 모델이 주목받고 있다 [1].

신생아 호흡곤란 증후군인 RDS(Respiratory Distress Syndrome)는 미숙아에게 가장 흔하게 발생하는 호흡기 질환이다. 호흡곤란을 유발하는 진행성 호흡부전을 초래하는 질환으로 폐의 팽창에 필수적인 폐표면 활성제의 생성 분비 부족으로 인해 발생한다[2]. RDS는 영상의학에서도 X-ray 사진을 가지고 판단하며, 폐 영역만을 보고 판단한다.

RDS가 미숙아에게 흔하게 발생하는 질환이고 미숙아는 고령 산모, 시험관 시술, 제왕절개 등의 이유로 증가되고 있다. 또한, 미숙아 사망 주요 원인 1위가 신생아 호흡곤란인 만큼 심각한 문제이다[3, 4].

본 논문에서는 신생아 출생 후 처음 촬영한 X-ray 영상만으로 RDS를 진단할 수 있는 딥러닝 기반의 알고리즘을 개발하고 그 성능을 평가하고자 하며, 신생아 RDS 진단 및 치료방향 결정에 이바지하고자 한다. 현대 의학에서 X-ray 영상으로 RDS를 추정할 때 폐 영역을 ROI(Region of Interest)로 보기 때문에[5] 폐영역을 분할하는 모델과 진단하는 분류 모델을 설계하고자 한다.

의료 영상에서 특정 장기 또는 질환을 컴퓨터를


활용해 질환을 분석하고자 할 때, 관심 영역을 분할하는 것은 필수적인 단계가 될 수 있다. 이 과정에서 분할이 제대로 이루어지지 못하면 이후 분석에서 큰 오차를 일으킬 수 있기 때문에 강건한 모델을 이용해 관심영역을 정확하게 분할해야 한다. [6]

의료 이미지에서의 질환 진단 연구는 꾸준히 진행되어 왔다. 의료 이미지는 지도학습을 위한 데이터가 충분하지 않은 경우가 많았다. 하지만, 전이학습이 등장하면서 해당 문제가 어느정도 해결되었고 본 논문 역시 전이 학습의 한 종류로 ImageNet 데이터셋에 대해서 사전학습된 모델을 이용하고자 한다. [7]

2. 관련연구

2.1 UNet

의료 영상 분할을 위해 제안된 딥러닝 알고리즘인 UNet[8]은 입력에서 출력까지 신경망으로 한 번에 처리하는 방식의 FCN(Fully-Convolutional Network) 기반 모델이다. UNet은 아주 적은 양의 데이터로 여러 영상 분할에서 우수한 성능을 보여주었다.




(그림 1) UNet 구조

UNet은 그림 1처럼 U자형 아키텍처와 수축경로(Contracting Path), 확장경로(Expanding Path)로 구성되어 있다. 수축 경로는 일반적인 합성곱 신경망(Convolution neural network)처럼 영상의 특징을 압축하는 인코더에 해당하고 확장경로는 압축한 이미지를 다시 원래 형태로 변경해주는 디코더이다. UNet은 인코더 과정에서 축약된 정보를 디코더로 전송하여 기존에 활용하지 못했던 정보를 활용할 수 있다.

2.2 EfficientNet


EfficientNet[9]은 합성곱 신경망 모델의 크기를 효율적으로 증가시킨 모델이다. 기존 합성곱 신경망은 네트워크의 깊이, 너비, 해상도의 최적 값이 서로 영향을 받아 서로 다른 리소스 제약 조건 하에서 값이 변화하는 문제 때문에 깊이, 너비, 해상도 중 하나를 선택하여 합성곱 신경망을 확장했다. EfficientNet은 위에 언급한 세 가지 사이의 관계를 파악해 더 높은 성능을 달성했다. 또한, NAS(Neural Architecture Search)를 사용해 기본 네트워크 구조를 설계하고 크기를 확장하여 EfficientNet을 설계했다. 그림 2처럼 모델의 파라미터 개수(X축)를 증가시킬수록 높은 정확도를 보인다. 본 연구는 EfficientNet 계열 중 EfficientNet-B0, B3, B5 세 가지의 모델을 사용하였다.



(그림 2) 모델 크기 vs ImageNet 정확도


3. RDS 진단 네트워크 구조

그림 3은 X-ray 영상 데이터 분할 및 신생아 RDS 질환 진단 네트워크의 전체 구조도이다. 제안하는 구조는 폐 영역 분할 구조와 RDS 진단 구조로 구성되어 있다. 신생아의 X-ray 영상 입력값에 대해서 분할 모델은 ROI인 폐 영역을 예측한다. 분할 모델의 예측으로 나온 폐 영역 영상을 RDS 진단 모델의 입력값으로 반영하여 RDS 질환을 판별한다.



(그림 3) RDS 진단 네트워크 전체 구조도

그림 4처럼 X-ray 사진에 기계 장치를 비롯한 외부 요소가 포함될 수 있다. 이 경우, 진단 모델이 기계 장치 유무만으로 RDS를 판별할 수도 있다. 따라서 기계 장치 등 외부 요소의 영향을 최소화하기 위해 폐 영역을 먼저 분할하고 분할된 영상 기반으로 RDS를 진단하도록 네트워크 구조를 설계하였다.




(그림 4) 기계 장치가 포함된 X-ray 영상

4. 실험 및 결과

4.1 실험 데이터

그림 5는 신생아 호흡 곤란 증후군 진단을 위한 신생아 X-ray 영상 예시이다. 본 연구에 사용된 신생아 X-ray 영상은 RDS 질환 유무에 따라 RDS와 non-RDS로 구분되어 있다. 해당 영상 데이터는 충남대학교 병원으로부터 제공받았으며 총 632개를 사용하였다. 그림 6처럼 CSV 파일로 각 이미지에 대한 경로와 RDS 질환 유무, 폐 영역 넓이, 이미지에 대한 정보를 분석하였다. 데이터를 분석해본 결과, 전체 데이터 632개 중 341장은 RDS 질환 영상이고 나머지 291장은 non-RDS 영상이다.



<Non-RDS> <RDS>
(그림 5) 신생아 X-ray 영상 예시

filepath	rds	exist_json	roi_area	height	width
C:\dataset\medical_imaging\	1	1	199757	2614	2164
C:\dataset\medical_imaging\	1	1	173892.9	1657	956
C:\dataset\medical_imaging\	0	1	185266	1573	1040
C:\dataset\medical_imaging\	1	1	220792.6	2614	2164
C:\dataset\medical_imaging\	1	1	137998.4	1370	884
C:\dataset\medical_imaging\	0	1	236400	1775	1420
C:\dataset\medical_imaging\	0	1	384889.5	2460	1950
C:\dataset\medical_imaging\	0	1	203891	2614	2164
C:\dataset\medical_imaging\	0	1	133840.8	1484	830
C:\dataset\medical_imaging\	1	1	135895.5	1882	1970
C:\dataset\medical_imaging\	1	1	246811.5	1775	1420

(그림 6) CSV 파일 정보 예시

본 연구는 DICOM 형식으로 주어진 데이터를 PNG로 바꾸는 과정을 거쳤다. 분할한 폐 영역을 보고 RDS를 진단해야 하기 때문에 데이터셋을 구성할 때 폐 영역 정보를 고려하였다. 폐 영역 넓이를 기준으로 정렬하고 RDS 질환 유무에 따라 5개 그룹으로 나눴다. 각 그룹은 약 127장의 데이터를 포함하고 있다. 그 중 3개 그룹을 학습용 데이터셋, 1개 그룹을 검증 데이터셋, 1개 그룹을 테스트 데이터셋으로 활용했고 이를 통해 모델의 학습과 검증을 수행했다.

본 연구에서는 분할과 진단 모델을 분리시켜 독립적으로 학습하였다. 분할 모델의 경우 X-ray DICOM 이미지를 PNG로 변환한 이미지를 입력값으로 사용했다. 진단 모델의 경우 병원에서 레이블링한 폐 영역을 활용하여 먼저 학습과 검증을 수행하였다. 테스트 시에는 학습한 분할과 진단 모델을 연결하여 RDS 판별결과를 획득하였다.

4.2 실험 세팅


본 논문의 제안 모델은 Ubuntu 20.04 LTS에서 Python 3.7, PyTorch 1.9.1 버전을 이용하여 구현하였다. 모델 학습과 테스트 시 NVIDIA RTX A5000 32GB를 사용하였다.

4.3 분할 모델 실험 결과

상기 언급한 UNet을 통해 신생아의 폐 영역을 분할하는 모델을 개발했다. 모델을 학습하기 위해 반복 학습주기(epoch)는 150, 배치 크기(batch size)는 16, 초기 학습률(learning rate)은 0.001로 설정하고 이후 50번의 학습주기를 초과할 때마다 기존 학습률의 1/10 배로 낮추었다. 또한, 인코더는 ImageNet 데이터셋으로 사전 학습된 EfficientNet-B5를 사용하였다.

후처리를 적용하지 않았을 때의 검증 데이터 셋 기준 MIoU score는 0.83으로 나타났다. 이후, 분석했을 때 질환을 진단하기에 부족한 이미지들이 존재하여 추가적인 후처리를 진행했다. 입력 영상을 회전시켜 여러 개의 영상의 평균 예측값을 획득하는 방법과 예측한 폐 영역 이미지에 중간값 필터를 적용하는 방법이다.

먼저, 폐 영역의 평균 픽셀 수는 약 100,000개이고 예측한 폐 영역 픽셀 수가 30,000개 이하일 때는 분할 모델의 성능이 크게 하락하였다. 따라서 해당 이미지에 대해 시계, 반시계 방향 90도 회전을 수행하고 각각 분할을 진행하여 평균 예측값을 획득하였고 성능 향상을 보였다. 또한, 이미지를 분석했을 때 그림 7처럼 분할된 영역 가운데 구멍이 뚫린 것처럼 나타나는 경우가 있었다. 이 문제를 해결하기 위해 폐 영역 분할 예측값에 중간값 필터를 적용하였다. 최종적으로 얻은 성능은 표 1과 같다.



(그림 7) 분할 영역 구멍 예시

<표 1> UNet을 활용한 폐 영역 분할 성능

Model	miou
UNet baseline	0.834
UNet + median filtering	0.847
UNet + median filtering + rotate post processing	0.913

4.4 진단 모델 실험 결과

상기 언급한 EfficientNet을 통해 신생아 호흡곤란 증후군을 진단할 수 있는 모델을 개발했다. 진단 모델의 경우, 폐 영역 분할 모델의 성능이 낮을 때에는 학습을 수행할 수 없는 문제점이 있어서 미리 레이블링한 폐 영역을 기반으로 학습을 진행하였다.

모델을 학습하기 위해 반복 학습주기는 100, 배치 크기는 B0인 경우 48로 설정하였고 B3와 B5 모델은 각각 24와 12로 설정하였다. 학습률은 0.001로 설정하였다. EfficientNet B0, B3, B5 모두 ImageNet 데이터셋으로 사전 학습된 모델을 사용하였다. 학습에서 사용된 데이터 증대의 경우 영상의 크기를 512x512로 조정하였고, torchvision.transforms의 VerticalFlip과 Horizontal Flip을 사용했다. 해당 모델로 얻은 결과는 표 2와 같다.

<표 2> EfficientNet B0, B3, B5에 대한 결과

Model	정확도
EfficientNet B0	0.843
EfficientNet B3	0.836
EfficientNet B5	0.843

4.5 분할과 진단 모델을 결합한 통합 모델의 추가 학습 결과

가장 높은 MIoU score를 보이는 분할 모델과 가장 높은 판별 정확도의 진단 모델을 결합한 통합 모델을 추가 학습하였다. 학습에 사용한 파라미터 역시 4.4와 동일하게 반복 학습주기 100, B0의 배치 크기 48부터 B3는 24, B5는 12로 줄여서 학습하였고, 학습률 0.001로 설정하였다. 해당 모델로 얻은 결과는 표 3과 같다.

<표 3> 연결된 모델에 대한 결과

Model	정확도
EfficientNet B0	0.773
EfficientNet B3	0.797
EfficientNet B5	0.852

5. 결론 및 향후 연구과제

본 연구에서는 신생아 호흡곤란 증후군 진단을 위해 신생아 X-ray 영상 약 630장에 대해 분할 모델과 진단 모델을 각각 학습하여 성능을 평가하였다. 또한, 분할 모델과 진단 모델을 결합한 통합 모델을 추가 학습하여 성능을 평가하였다. 최종적으로 분할 단독 모델은 MIoU 기준으로 0.913을 획득하였으며, 레이블링한 폐 영역에 대한 RDS 진단 정확도는 0.843을 획득하였다. 최고 성능의 분할과 진단 모델을 결합하여 추가학습한 통합 모델의 RDS 진단 정확도는 0.852로 가장 높은 정확도를 획득하였다.

향후 신생아 질병 탐지의 성능을 개선시키기 위해 다양한 데이터 증대 방법과 시각화에 대해서 연구할 계획이다.

Acknowledgement

이 연구는 인증된 연구윤리심의위원회(institutional review board, IRB)의 승인을 받았습니다.

참고문헌

[1] 홍준용, “AI 의료영상 분석의 개요 및 연구 현황에 대한 고찰”, 방사선기술과학, 43권, 3호, 195 - 208

[2] 성태정, “신생아 호흡 곤란증 치료의 최신지견”, 대한주산회지, 25권, 2호, 61 - 67

[3] 통계청, “2019년 사망원인통계 결과”, 통계청 보도자료

[4] 배중우, “초미숙아의 신생아 사망률, 사망시기, 사망원인: 한국과 경제협력개발기구 국가의 비교” Evidence and Values in Healthcare 2015 June 1(2): 95-102

[5] Reuter, S., Moser, C., & Baack, M. “Respiratory distress in the newborn”. Pediatrics in review, 35(10), 417-429

[6] 박범희, “흉부 의료영상에서 딥러닝 기반 분할 및 분류 연구”, 울산대학교 대학원 의학과 학위논문

[7] Abbas, Asmaa, Mohammed M. Abdelsamea, and Mohamed Medhat Gaber. "Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network." Applied Intelligence. 2021

[8] RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-net: Convolutional networks for biomedical image segmentation. In: International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015. p. 234-241.

[9] TAN, Mingxing; LE, Quoc. Efficientnet: Rethinking model scaling for convolutional neural networks. In: International conference on machine learning. PMLR, 2019. p. 6105-6114.