

## 영역 분할 기반 심층 신경망을 활용한 소아 RDS 판별 방법

\*김지영 \*강재하 \*최해철†

\*한밭대학교

jiyeongk34@gmail.com

kario3448@daum.net

choihc@hanbat.ac.kr†

## Pediatric RDS classification method employing segmentation-based deep learning network

Jiyeong Kim, Jaeha Kang, and Haechul Choi

Hanbat National University

## 요 약

신생아 호흡곤란증후군(RDS, Respiratory Distress Syndrome)은 미숙아 사망의 주된 원인 중 하나이며, 이 질병은 빠른 진단과 치료가 필요하다. 소아의 x-ray 영상을 시각적으로 분석하여 RDS 의 판별을 하고 있으나, 이는 전문의의 주관적인 판단에 의지하기 때문에 상당한 시간적 비용과 인력이 소모된다. 이에 따라, 본 논문에서는 전문의의 진단을 보조하기 위해 심층 신경망을 활용한 소아 RDS/nonRDS 판별 방법을 제안한다. 소아 전신 X-ray 영상에 폐 영역 분할을 적용한 데이터 세트와 증강방법으로 추가한 데이터 세트를 구축하며, RDS 판별 성능을 높이기 위해 ImageNet 으로 사전학습된 DenseNet 판별 모델에 대해 구축된 데이터 세트로 추가 미세조정 학습을 수행한다. 추론 시 입력 X-ray 영상에 대해 MSRF-Net 으로 분할된 폐 영역을 얻고 이를 DenseNet 판별 모델에 적용하여 RDS 를 진단한다. 실험결과, 데이터 증강과 폐 영역을 분할을 적용한 판별 방법이 소아 전신 X-ray 데이터 세트만을 사용하는 것과 비교하여 3.9%의 성능향상을 보였다.

## 1. 서론

자기공명영상, X-ray 영상 등은 다양한 질환의 진단 및 수술 계획 수립에 요구되는 선행 절차이나, 필요한 영역을 추출하기 위해 소모되는 인력 및 시간이 상당하다는 문제가 있다. 이에 특정 영역을 추출하기 위한 자동화 기술 연구들이 활발히 이루어지고 있다. 또한, 최근 그래픽 처리 장치와 소프트웨어 기술의 발전으로 인공지능으로 의료영상을 분석하여 판독 및 진단을 돕는 연구분야가 크게 활성화되고 있다. 예로, 의사의 주관적인 판단에 의지해야 하는 X-ray 영상기반 질병 진단에 심층 신경망 기반 판별 방법을 적용하면 시간적 비용과 인력의 소모를 줄일 수 있다.

본 논문에서는 심층 신경망을 활용한 신생아 호흡곤란증후군(RDS, Respiratory Distress Syndrome)의 판별 방법을 제안한다. RDS 는 미숙아 사망의 주된 원인이 되는 질병이며, 빠른 진단과 치료를 필요로 한다. RDS 의 진단 방법으로는 출생 전후기의 폐 성숙도를 통한 진단과 출생 후 RDS 의 진단으로 나눌 수 있다[1]. 제안 심층 신경망을 활용한 RDS 판별 방법은 출생 후 RDS 진단의 방사선 소견에 활용되어 전문의의 진단을 보조한다.

RDS 판별에 필요한 데이터는 대부분 폐에 존재한다. X-ray 로 파악할 수 있는 RDS 의 외적 병태는 폐포의

허탈(collapse)로 인한 과립상 음영, 폐와 심장의 경계선이 보이지 않게 되는 양상, 늘어나는 모양의 공기 기관지 음영 등이 있다[1]. 하지만 소아의 전신 X-ray 에는 폐 이외의 신체부위가 다수 포함되어 있다. 이러한 폐 이외의 신체부위에서 추출된 정보는 RDS 판별 심층 신경망의 성능을 저하시킬 우려가 있다. 따라서 본 논문에서는 폐 영역 분할을 적용한 데이터와 증강방법으로 추가한 데이터를 구축해 판별 모델을 미세조정(fine-tuning)하여 판별 모델의 성능을 향상시켰다.

## 2. 제안 방법

[그림 1]은 본 논문에서 구현하고자 하는 모델의 시스템블록도이다. 먼저, 소아의 전신 X-ray 영상으로부터 분할 모델을 이용해 폐 영역을 분할한다. 분할 모델은 소아의 전신 X-ray 영상과 각 X-ray 영상에 대한 폐 영역 GT(Ground Truth)를 입력으로 한다. 분할 모델의 학습을 위해 RDS/nonRDS 에 대해 각각 344 장, 292 장의 X-ray 영상을 포함하고있는 데이터셋을 사용하였다. 이와 같이, 소아 X-ray 영상과 같은 의료영상은 학습에 필요한 데이터를 충분히 모으기 어렵기에 분할 모델의 성능 향상을 위해 데이터

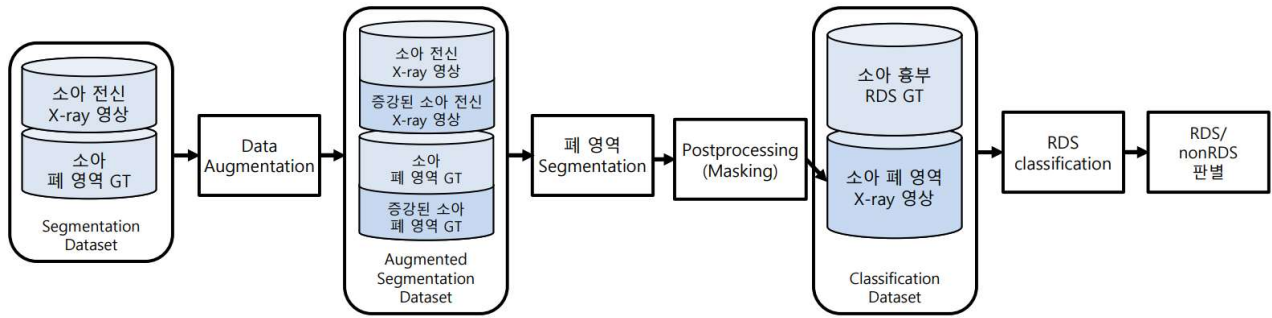


그림 1. 제안 시스템 블록도

증강(agumentation)을 적용한 뒤 분할 모델의 입력데이터로 사용하였다. 분할모델은 입력된 X-ray 영상에 대한 마스크를 256x256 의 크기로 출력하고, 출력된 마스크는 소아 전신 X-ray 영상과 동일한 크기로 재조정된 뒤 소아 전신 X-ray 영상에 적용된다. 이렇게 분리된 소아 폐 영역 X-ray 영상을 판별모델의 입력으로 사용함으로써 판별모델은 최종적으로 RDS/nonRDS에 대한 확률을 출력한다.

### 2.1 폐 영역 분할(segmentation)

폐 영역 분할에는 MSRF-Net(Multi-Scale Residual Fusion Network)을 사용한다. MSRF-Net 은 의료 영상 분할을 위해 특별히 설계된 구조로 DDSF(Dual-Scale Dense Fusion)라는 블록이 사용되는데 DDSF 는 다중 스케일의 특징을 교환할 수 있어 해상도를 보존하고 정확한 분할 맵을 얻을 수 있다는 이점이 있다[2]. 초기 데이터 세트는 소아의 전신 X-ray 영상 636 장, 폐 영역 GT 636 장을 사용한다. X-ray 영상과 GT 는 각각 학습 데이터로 380 장, 검증 데이터로 128 장, 평가 데이터로 128 장이 사용된다.

#### 2.1.1 데이터 증강(Augmentation)

폐 영역 분할모델의 데이터 세트에 회전(rotation)을 적용하여 데이터를 증강한다. 소아 X-ray 영상에서 소아가 누워 있는 방향은 고정되어 있지 않다. 때문에 특정 방향으로 누워 있는 영상에 대해 과소적합(underfitting)이 일어날 수 있다. 이에 입력 영상이 다양한 방향의 소아 X-ray 영상 데이터에 대해 폐 영역 분할을 지원하도록 학습용 소아 X-ray 영상에 90°, 180°, 270° 회전을 적용하여 데이터 수를 4 배로 증강한다. 검증과 확인 데이터세트는 검증에 사용되는 데이터이기 때문에 증강은 학습 데이터세트에만 적용한다. 따라서 폐 영역 분할은 학습 데이터 1520 장, 검증 데이터 126 장, 평가 데이터 126 장의 데이터 세트를 사용하여 모델을 학습시킨다.

#### 2.1.2 후처리(postprocessing)

폐 영역 분할 모델의 출력으로 나온 결과는 256x256 의 크기의 이진 영상이 출력되므로 해당 이미지를 원본의 크기로 되돌린다. 원본의 크기로 조절한 마스크를 사용하여 폐 영역을 분할한 소아 폐 영역 X-ray 영상을 판별모델의 입력으로 사용한다.

### 2.2 RDS/nonRDS 판별(Classification)

판별 모델의 학습은 폐 영역 분할의 적용 유무에 대한 판별성능 비교를 위해 원본 영상인 전신 X-ray 영상과 폐 영역 분할이 적용된 X-ray 영상을 사용해 각각 학습을 수행한다. 학습에는 CNN(Convolutional Neural Network) 구조 중 하나인 DenseNet 모델[3]을 백본(Backbone)으로 사용한다. 판별

모델의 경우 층이 깊어질수록 좋은 성능을 기대할 수 있기 때문에 201 개의 계층으로 구성된 DenseNet-201 를 판별 모델의 백본으로 사용한다. 본 논문에서는 RDS 인 소아 X-ray 영상 344 장, nonRDS 인 소아 X-ray 영상 292 장으로 학습을 수행한다.

앞선 2.1절에서 회전을 통한 증강이 이루어졌음에도 이는 RDS 1376 장, nonRDS 1168 장이라는 적은 데이터 세트에서 학습을 수행하는게 된다. 이러한 적은 데이터로 모델을 학습시키는 것은 과대적합(overfitting)의 원인이 된다. 이에 과대적합을 방지하기 위해 Imagenet 의 데이터로 사전학습(Pre-trained)된 DenseNet 모델을 기반으로 미세조정학습을 수행한다. 데이터 세트는 학습 데이터 1520 장, 검증 데이터 126 장, 실험 데이터 126 장으로 구성하여 학습을 수행한다.

## 3. 실험 결과

폐 영역 분할의 경우 원본 마스크와 예측한 마스크의 차이를 구하기 위해 Dice 성능지표를 사용하여 성능을 계산한다. RDS 판별의 경우 원본인 소아의 전신 X-ray 영상을 사용하여 학습한 모델의 정확도와 데이터 증강과 폐 영역 분할을 거친 데이터를 활용하여 학습한 모델의 정확도를 비교한다.

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

### 3.1 분할 모델 성능

분할 모델의 경우 Dice 성능지표를 사용하여 분할 성능을 계산한다. Dice 성능지표는 [식 1]과 같으며 정답 영역과 예측한 영역이 정확히 같다면 1, 정답 영역을 완전히 벗어나게 예측한 경우에는 0 의 값을 갖는다. Dice 성능지표는 false positives 혹은 false negatives 를 포함하더라도 모든 true 구간을 놓쳐서는 안 되는 경우에 성능지표로 사용하기 적합하다[4]. 그러므로 Dice 성능지표는 의료영상 판별에 주로 사용된다. 먼저 증강을 적용하지 않은 데이터로 학습을 수행했을 때, 분할모델의 dice 성능은 0.940 이다. 그리고 회전을 사용하여 증강한 데이터로 학습시켰을 때, 분할모델의 dice 성능은 0.958 이므로 증강한 데이터를 사용하여 모델을 학습시켰을 때, 증강을 사용하지 않은 데이터로 학습시켰을 때보다 약 1.8%의 성능이 향상된다.

### 3.2 판별 모델 성능

DenseNet 모델을 이용하여 전신 X-ray 영상으로 학습을 수행 하였을 때와 폐 영역을 분할한 X-ray 영상으로 학습을

데이터 세트 종류	정확도
전신 X-ray 영상	0.746
폐 영역 분할 X-ray 영상	0.785

표 1 RDS 판별모델의 성능

수행하였을 때의 성능을 비교하는 실험을 하였다. 실험 결과는 [표 1]과 같다. RDS 판별 모델의 학습에 폐 영역을 분할한 X-ray 영상을 이용한 경우 전신 X-ray 영상을 이용한 결과보다 3.9%의 성능 향상을 보인다.

#### 4. 결론

본 논문에서는 전문의의 RDS 진단을 보조하여 진단에 소모되는 시간적 자원과 인력을 줄이기 위해 심층 신경망을 활용한 RDS 판별 방법을 제안한다. 판별모델의 성능향상을 위해 소아의 전신 X-ray 영상 데이터 세트에서 폐 영역을 분할한 데이터세트와 증강한 데이터 세트를 구축하여 사전 학습된 판별 모델에 미세조정학습을 수행한다. 실험 결과 소아의 폐 영역을 분할한 X-ray 영상 데이터를 사용하여 학습한 판별 모델이 소아의 전신 X-ray 영상을 사용하여 학습한 결과보다 3.9%의 성능이 향상한 것을 확인할 수 있었다. 제안 RDS 판별 방법의 정확도를 더 높이기 위해서는 더 정확한 폐 영역 분할 방법에 대한 연구가 필요하다.

#### 참고 문헌

- [1] 배종우. "신생아 호흡곤란 증후군." *녹십자의보* 30.5 (2002): 235-248.
- [2] Srivastava, Abhishek, et al. "Msrf-net: A multi-scale residual fusion network for biomedical image segmentation." *arXiv preprint arXiv:2105.07451* (2021).
- [3] Huang, Gao, et al. "Densely connected convolutional networks." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
- [4] 김장우, and 김종효. "3 차원 의료 영상 분할 평가 지표에 관한 고찰." *대한의학영상정보학회지* 23.1 (2017): 14-20.