

# 12 리드 심전도 신호의 리드별 스칼로그램과 통합 스칼로그램에 따른 심혈관 질환 진단

김시우, 윤태영, 이희창, 강대성  
인제대학교 헬스케어 IT 공학과

[5830ksw@naver.com](mailto:5830ksw@naver.com), [yty20173270@oasis.inje.ac.kr](mailto:yty20173270@oasis.inje.ac.kr), [gmlckd1254@oasis.inje.ac.kr](mailto:gmlckd1254@oasis.inje.ac.kr),  
[mpkds@inje.ac.kr](mailto:mpkds@inje.ac.kr)

## Diagnosis of cardiovascular disease according to lead-specific scalogram and integrated scalogram of 12-lead ECG signals

Siwoo Kim, Tae Young Yoon, Heechang Lee, Daesung Kang  
Dept. of Healthcare IT, Inje Univ.

### 요 약

본 연구에서는 1 차원 심전도 신호를 2 차원 영상인 스칼로그램으로 변환 후 2D-CNN 알고리즘을 적용하여 심혈관 질환을 분류하려 한다. 1 차원 신호를 2 차원으로 변환하는 이유는 전이학습의 이점을 취할 수 있기 때문이다. 하지만, 12 리드 심전도 신호를 변환하면 각 리드마다 스칼로그램 영상이 얻어지므로 12 개의 딥러닝 모델을 만들어야 한다. 이런 문제점을 해결하기 위해서 본 연구에서는 12 리드에서 변환되는 12 장의 스칼로그램 영상을 한 장의 스칼로그램 영상으로 변환하여 사전 학습된 Inception-v3 모델에 적용하여 심혈관 질환을 분류하여 이러한 방법의 유효성을 확인하려 한다.

### I. 서 론

심전도(electrocardiogram, ECG) 신호 분석은 심혈관 질환을 진단할 때 가장 많이 사용되는 방법이지만, 심장전문의 입장에서는 이는 지루하면서도 많은 시간이 소요되는 작업이다. 최근에는 이런 문제점을 해결하기 위해서 기계학습이나 딥러닝을 통하여 자동으로 심혈관 질환을 분류하려는 시도가 많이 진행되어 왔다.[1-3] 기계학습을 이용하는 방법은 ECG 에서 R 피크, QRS 인터벌 등과 같은 시간 영역에서의 특징값이나, 웨이블릿 변환을 이용한 주파수 영역에서의 특징값을 추출하여 그 특징값을 SVM 이나 랜덤 포레스트 등과 같은 기계학습 알고리즘에 적용하는 방법이다.[1] 딥러닝을 이용하는 방법은 1 차원 신호인 심전도 신호의 시계열적인 특성을 이용하는 RNN 계열의 알고리즘이나 1D-CNN 등과 같은 알고리즘이 있다.[2] 하지만, 위와 같은 방법은 전이학습을 이용하는 이점을 취하지 못한다는 단점이 있다. 딥러닝을 이용하는 또다른 방법은 1 차원 신호를 스칼로그램(scalogram)과 같은 2 차원 신호로 변환하여 2D-CNN 을 적용하는 방법이다.[3] 본 연구에서 다루는 데이터는 12 리드 ECG 데이터이므로, 각 리드의 ECG 신호를 스칼로그램으로 변환하면 12 개의 영상이 얻어진다. 문제는 각 리드별로 딥러닝 모델을 만들면, 12 개의 딥러닝 모델을 만들어야 하는 부담이 생긴다. 이런 문제점을 해결하기 위해서 본 연구에서는 12 리드에서 획득한 12 장의 스칼로그램을 한 장의 스칼로그램으로 변환한 뒤, 사전 학습된 2D-CNN 모델에 적용하는 방법을 취하여, 이러한 방법의 심혈관 질환 진단 효율성을 확인하려고 한다.

### II. 본론

본 연구에서 사용한 데이터는 최근 Scientific Data 저널에 공개된 데이터로 중국 Chapman University 와 Shaoxing People's Hospital 에서 수집한 12 리드 ECG 데이터이다. 이 데이터는 10,646 명의 ECG 를 12 리드로 수집한 데이터이다[4]. 원 신호(raw signal)의 잡음을 제거하기 위해서 버터워스 저역 통과 필터, LOESS 평활기, NLM 등과 같은 전처리 과정을 수행하였고, 그 과정에서 손상된 58 명의 심전도 신호를 제외한 10,588 명의 심전도 신호를 실험에 사용하였다. 이 데이터는 심혈관 질환을 11 개로 분류하였는데, 질환별로 데이터의 수가 불균형하여 11 개의 심혈관 질환을 4 개의 심혈관 질환으로 병합하였다. 10,588 개의 ECG 데이터 중, 64%는 학습용(6,780 건), 16%는 검증용(1,694 건), 나머지 20%는 테스트용(2,114 건) 데이터로 사용하였다.

1 차원 심전도 신호를 2 차원으로 표현하기 위해서 시간과 주파수간의 관계성을 이미지로 표현한 스칼로그램으로 변환하였다. 그림 1 은 한 건의 ECG 데이터를 각 리드별로 스칼로그램을 12 개의 영상으로 표현하였다. 각 리드별로 스칼로그램을 학습하려면, 12 개의 모델을 학습해야 하는 부담이 있다. 그래서 본 연구는 그림 2 와 같이 12 개의 스칼로그램 영상을 하나의 스칼로그램 영상으로 변환하였다. 이를 위해서 각 리드별 스칼로그램의 x 축을 그대로 두고, y 축을 1/12 로 축소하였다. y 축으로 축소된 12 개의 스칼로그램을 순서대로 쌓게 되면, 원본 스칼로그램의 크기인 300x300 픽셀의 영상이 된다. 학습, 검증, 테스트 데이터를 모두 이런 방법으로 변환 한 후, 이미지넷 데이터로 사전 학습된 Inception-v3 모델에 입력하여

학습 모델을 미세조정(fine-tuning) 하였다. 모델을 미세조정할 때, 배치사이즈는 32 를 사용하였고, 아담 옵티마이저(Adam optimizer)로 최적화하였다. 이 때 사용한 아담의 학습률은 [1e-3, 5e-4, 1e-4, 5e-5, 1e-5]를 바꾸면서 사용하였고, 검증데이터에서 가장 높은 정확도를 보이는 학습률 1e-3 일 때의 모델에 테스트 데이터를 적용하였다. 그리고 모델의 오버피팅을 막기위해서 조기 종료(early stopping)방법을 적용하였다.

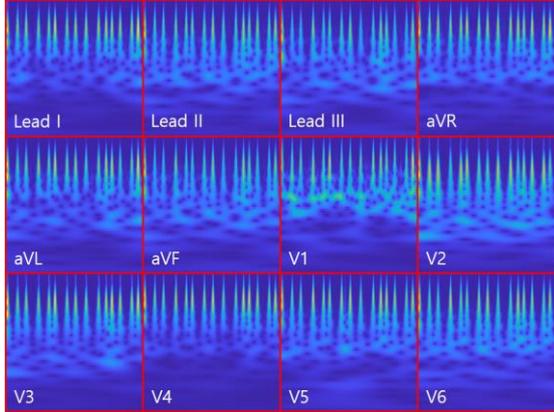


그림 1. AFIB(심방세동)의 12 장의 리드별 스칼로그램

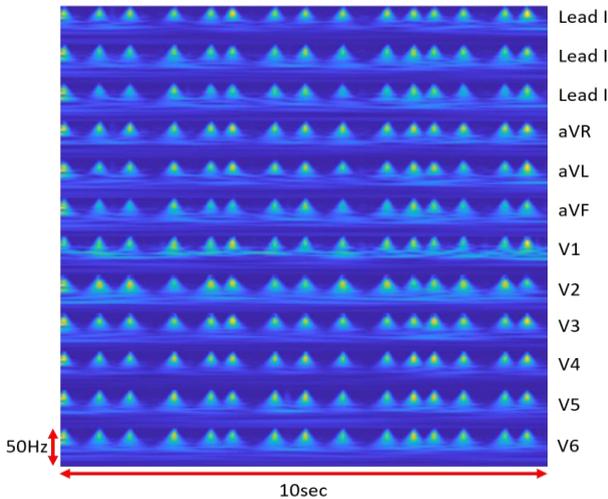


그림2. AFIB(심방세동)의 통합 스칼로그램

표 1 은 그림 1 과 같이 각 리드별로 스칼로그램으로 변환된 영상으로 학습한 모델과 그림 2 와 같이 12 개의 스칼로그램을 통합한 영상으로 학습한 모델의 정확도와 AUC 를 나타낸다. 각 리드별로 스칼로그램을 학습한 경우, Lead II 에서 가장 높은 정확도(94.51%)와 AUC(0.993)을 보였다. 통합 스칼로그램으로 학습한 경우, 각 리드별로 학습한 경우보다 더 높은 정확도(95.74%)와 AUC(0.995)를 보였다.

### III. 결론

본 연구는 12 리드 ECG 신호의 각 리드별 스칼로그램 영상으로 학습한 12 개의 모델과 한 장의 통합 스칼로그램 영상으로 학습한 모델의 정확도와 AUC 를 비교하였다. 통합 스칼로그램을 사용할 경우, 아래와 같은 2 가지 장점을 보인다. 첫째, 12 장의 스칼로그램을 한 장으로 변환하기 때문에 모든 리드의 특징을 한

장으로 표현할 수 있다. 두번째는 각 리드별로 학습할 경우, 12 개의 모델을 학습해야하는 부담이 있다. 이를 통합 스칼로그램으로 하나의 모델 만으로 더 좋은 성능을 보이는 모델을 만들 수 있는 장점이 있다.

본 연구에서는 통합 스칼로그램의 유효성을 보이기 위해서 Inception-v3 모델만을 사용하였지만, 다른 딥러닝 모델에서도 통합 스칼로그램이 나은 결과를 보인다는 보장은 없다. 연구 결과를 일반화하기 위해서는 다양한 2D-CNN 모델의 실험적 결과가 뒷받침되어야 한다.

리드 이름	각 리드 스칼로그램 정확도(AUC)	통합 스칼로그램 정확도(AUC)
Lead I	92.76(0.986)	<b>95.74(0.995)</b>
Lead II	<b>94.51(0.993)</b>	
Lead III	91.82(0.984)	
aVR	93.85(0.991)	
aVL	92.57(0.987)	
aVF	92.81(0.991)	
V1	93.95(0.991)	
V2	90.07(0.981)	
V3	92.34(0.983)	
V4	89.78(0.980)	
V5	92.53(0.985)	
V6	91.49(0.981)	

표 1. 각 리드 스칼로그램과 통합 스칼로그램의 정확도와 AUC.

### ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No.2020R1G1A1A1102881)

### 참 고 문 헌

- [1] Sharma, L.D.; Sunkaria, R.K. Inferior myocardial infarction detection using stationary wavelet transform and machine learning approach. Signal. Image Video Process. 2018, 12, 199– 206.
- [2] Guo, L.; Sim, G.; Matuszewski, B. Inter-patient ECG classification with convolutional and recurrent neural networks. Biocybern. Biomed. Eng. 2019, 39, 868– 879.
- [3] Jun, T.J.; Nguyen, H.M.; Kang, D.; Kim, D.; Kim, D.; Kim, Y. ECG arrhythmia classification using a 2-D convolutional neural network. arXiv 2018, arXiv:1804.06812.
- [4] Zheng, J.; Zhang, J.; Danioko, S.; Yao, H.; Guo, H.; Rakovski, C. A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients. Sci. Data 2020, 7, 48.