

MIT-BIH Database 를 활용한 Wavelet 기반 ECG 특징 추출과 CNN 을 이용한 부정맥 분류: 개선된 접근 방법

조운서¹, 정훈기¹, 오승주², 송하윤^{3*}

¹ 숭실대학교 컴퓨터공학과(GFI) 학부생

² 명지전문대학교 정보통신공학과 학부생

^{3*} 홍익대학교 컴퓨터공학과 교수

yunseo0212234@gmail.com, junghungi@kakao.com, 5sseung@naver.com, hayoon@hongik.ac.kr

저자 기여도: 조운서 (제 1 저자), 오승주 (제 2 저자), 정훈기 (제 3 저자), 송하윤 (교신저자)

Wavelet-Based ECG Feature Extraction and CNN for Arrhythmia Classification: An Enhanced Approach Using MIT-BIH Database

YunSeo Jo¹, HunGi Jung¹, SeungJu Oh², HaYoon Song^{3*},

¹Dept. of Computer Science and Engineering, Sooongsil University(GFI)

²Dept. of Information Technology and Communication, MyongGji College

^{3*}Dept. of Computer Science and Engineering, Hongik University

요 약

부정맥은 심각한 합병증을 초래할 수 있는 심장 질환으로, 조기 진단이 중요하다. 본 연구는 부정맥 진단의 자동화를 위해 Wavelet 변환과 합성곱 신경망(CNN)을 결합한 새로운 접근 방법을 제안한다. MIT-BIH Arrhythmia Database 와 P-Wave Annotations 를 사용하여 ECG 신호에서 QRS complex 와 P-wave 를 동시에 검출하는 전처리 방법을 개발하였다. Wavelet 변환 기반 전처리와 다양한 ECG 특징 추출 기법 결합한 1 차원 CNN 모델을 적용한 결과, 93%의 전체 정확도와 평균 0.9906 의 AUC 점수를 달성하였으며, 특히 심실 부정맥에 대해 96.8%의 높은 재현율을 보였다. 이는 현재 임상에서 사용되는 많은 자동화된 ECG 분석 시스템들의 miss reading 확률(10-15%)보다 낮은 7%의 miss reading 확률을 나타낸다. 본 연구는 ECG 데이터의 효율적인 해석과 부정맥의 조기 진단 가능성을 입증하였으며, 임상 현장에서의 적용 가능성을 제시한다. 향후 연구에서는 다양한 데이터셋 검증과 실시간 처리 능력 평가를 통해 실제 임상 환경에서의 적용성을 높일 계획이다.

1. 서론

부정맥은 심각한 심장 질환으로, ECG 해석의 자동화는 진단의 정확성과 신속성을 높일 수 있다[1,2,3]. 본 연구는 Wavelet 변환과 CNN1D 모델을 결합하여 QRS complex 와 P-wave 를 동시에 검출하는 새로운 ECG 분석 방법을 제안하며[4,5], ECG 신호의 시간-주파수 특성을 효과적으로 포착하여 기존 방법의 한계를 극복하고자 한다.

2. 관련 연구


부정맥 분류 연구는 규칙 기반 알고리즘에서 시작해 Wavelet 변환, 기계학습, 딥러닝으로 발전해왔다[3,4,5]. 주요 연구는 ECG 신호 전처리, 특징 추출, 그리고 CNN 기반 분류에 중점을 두고 있다[3,4,5,6]. 데이터 불균형과 실시간 처리 문제가 여전히 남아있는

가운데, 본 연구는 Wavelet 변환과 CNN 결합을 통해 이를 해결하고 기존 연구와 차별화하고자 한다[4,5].

3. 데이터셋, 전처리, 특징 추출 및 라벨 그룹화

본 연구는 전문 심장학자들에 의해 주석이 달리고 검증된 MIT-BIH Arrhythmia Database 와 P-Wave Annotations[1]를 사용했다. 이 데이터셋들은 360 Hz 샘플링, 11-bit 해상도로 구성되어 있으며, 높은 신뢰도를 가진 데이터를 기반으로 한다. MIT-BIH Arrhythmia Database 에서는 Wavelet 변환으로 R-피크와 P-피크를 직접 검출했고[4,5], P-Wave Annotations 에서는 주석된 P 파 정보를 사용했다[1]. Wavelet 변환은 ECG 신호의 다중 해상도 분석, 시간-주파수 지역화, 노이즈 제거에 효과적이다[4]. 특징 추출을 위해 QRS 복합체, P 파, T 파, 간격 및 변동성 관련 16 가지 특징을 추출했다[6]. SelectKBest 와 f_classif 방법으로 14 개의 중요 특

징을 선별했으며, T 파 역전, PR 간격, RR 간격이 높은 중요도를 보였다. 라벨은 Normal(N), Atrial(A), Ventricular(V), Other(O)의 4 개 클래스로 그룹화했다. 이는 일반적인 부정맥 분류 체계와 일치하며, 클래스 불균형 완화, 모델 성능 향상, 의료진의 해석 용이성 등의 이점을 제공한다. 그림 1에서는 wavelet 변환을 적용한 후 검출된 R-피크(빨간색 점)와 P-피크(녹색 점)를 원래 신호 위에 표시했다.




(그림 1) Wavelet 변환을 이용한 R 피크와 P 피크 검출

4. 모델 아키텍처

본 연구의 CNN1D 모델은 3 개의 1D 컨볼루션 레이어로 구성되며, 각 레이어는 32, 64, 128 개의 필터를 사용한다[5]. 각 컨볼루션 후에는 배치 정규화와 맥스 풀링을 적용하여 과적합을 방지하고 계산 효율성을 높인다[3]. 컨볼루션 레이어 후에는 2 개의 완전 연결 레이어(128, 64 유닛)가 이어지며, 각각 배치 정규화와 드롭아웃(0.5)을 적용한다[3,5]. 마지막으로 2 개의 출력 유닛을 통해 최종 분류를 수행한다. 이 구조는 ECG 신호의 시계열 특성을 효과적으로 포착하며[4], 수동으로 추출된 특징과의 결합을 통해 분류 성능을 향상시킨다[6].

5. 모델 정확도 및 손실

CNN1D 모델의 성능은 정확도 93%, 손실 0.25%로 나왔다[3,5]. 그림 2는 학습 및 검증 과정에서의 손실과 정확도의 변화를 보여준다.



(그림 2) CNN1D 모델 최종 정확도 및 손실

6. 클래스별 성능 분석 보고서

표 1은 CNN1D 모델의 클래스별 성능 지표다.


class	정밀도	재현율	F1-점수	support
Normal	0.90	0.79	0.84	621
Ventricular	0.94	0.97	0.96	12417
Atrial	0.93	0.91	0.92	5208
Other	0.76	0.69	0.72	1177
accuracy			0.93	19423
macro avg	0.88	0.84	0.86	19423
weighted avg	0.93	0.93	0.93	19423

<표 1> CNN1D 분류 성능 보고서

7. AUC 점수

CNN1D 모델은 ECG 신호 기반 부정맥 분류에서 특히 심실성 부정맥 클래스에서 뛰어난 성능을 보였으며(F1-점수 0.96, AUC 0.98), 임상적 유용성을 입증했

다[3]. 'Other' 클래스의 낮은 성능은 추가 연구가 필요함을 시사하지만, 전반적으로 ECG 진단에 효과적으로 적용될 수 있음을 보여준다[3,5]. 그림 3는 CNN1D 모델의 각 클래스별 ROC 곡선과 AUC 점수를 나타낸 그래프다.



(그림 3) CNN1D 모델 AUC 점수 그래프

8. 논의

본 연구의 가장 중요한 발견은 CNN1D 모델이 ECG 신호의 지역적 특징을 효과적으로 포착하여 부정맥 분류에 우수한 성능을 보였다는 점이다[3,5]. 또한, Wavelet 변환을 이용한 특징 추출과 선택 과정이 모델 성능 향상에 크게 기여했다[4].

향후 연구 방향으로 'Other' 클래스에 대한 성능 개선을 위한 데이터 불균형 해결 기법 적용과 모델의 결정 과정을 더 투명하게 만드는 방법을 고려해야 할 것이다.

9. 결론 및 향후 연구

본 연구에서 제안한 Wavelet 변환 기반 특징 추출과 CNN1D 모델은 ECG 신호 부정맥 분류에서 우수한 성능을 보였다(정확도 93%, 평균 AUC 0.9906)[3,5]. 7%의 miss reading 확률로 많은 현존 자동화 ECG 분석 시스템보다 낮은 오류율을 달성했다[2]. 향후 연구 방향으로 'Other' 클래스 성능 개선, 모델 최적화[5], 설명 가능한 AI 기법 적용, 모델 경량화[2], 다양한 데이터셋 검증, 그리고 딥러닝 모델의 일반화 능력 향상[3] 등이 있다. 이를 통해 더욱 정확하고 신뢰할 수 있는 부정맥 진단 시스템 개발이 기대된다.

참고문헌

- [1] Goldberger AL, Amaral LAN, Glass L, et al., "PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals", Circulation, 101(23), e215-e220, 2000.
- [2] Schläpfer J, Wellens HJ, "Computer-interpreted electrocardiograms: benefits and limitations", Journal of the American College of Cardiology, 70(9), 1183-1192, 2017.
- [3] Hannun AY, Rajpurkar P, Haghpanahi M, et al., "Cardiologist-level arrhythmia detection and classifications in ambulatory electrocardiograms using a deep neural network", Nature Medicine, 25(1), 65-69, 2019.
- [4] Addison PS, "Wavelet transforms and the ECG: a review", Physiological Measurement, 26(5), R155-R199, 2005.
- [5] Kiranyaz S, Ince T, Gabbouj M, "Real Time Patient Specific ECG Classification by 1-D Convolutional Neural networks", IEEE Transactions on Biomedical Engineering, 63(3), 665-675, 2016.
- [6] Karpagachelvi S, Arthanari M, Sivakumar M, "ECG Feature Extraction Techniques - A Survey Approach", International Journal of Computer Science and Information Security, 8(1), 76-80, 2010.