

AR 기반의 특징점 추출과 딥러닝을 통한 부정맥 분류

조익성¹ · 권혁승^{2*}

Parameter Extraction for Based on AR and Arrhythmia Classification through Deep Learning

Ik-sung Cho¹ · Hyeog-soong Kwon^{2*}

¹Associate Professor, School of Interdisciplinary Studies, Daegu University, Kyungsan 38453, Korea

^{2*}Professor, Department of IT Engineering, Pusan National University, Miryang 50463, Korea

요 약

부정맥 분류를 위한 기존 연구들은 분류의 정확성을 높이기 위해 신경회로망(Artificial Neural Network), 기계학습(Machine Learning) 등을 이용한 방법이 연구되어 왔다. 특히 딥러닝은 신경회로망의 문제인 은닉층 개수의 한계를 해결함으로써 인공 지능 기반의 부정맥 분류에 많이 사용되고 있다. 본 연구에서는 AR 기반의 특징점 추출과 딥러닝을 통한 부정맥 분류 방법을 제안한다. 이를 위해 먼저 잡음을 제거한 ECG 신호에서 R파를 검출하고 자기 회귀 모델을 통하여 최적의 QRS와 RR간격을 추출하였다. 이후 딥러닝을 통한 지도학습 방법으로 가중치를 학습시키고 부정맥을 분류하였다. 제안된 방법의 타당성 평가를 위해 MIT-BIH 부정맥 데이터베이스를 통해 각 파라미터에 따른 혼란 및 분류 정확도를 확인하였다. 성능 평가 결과 PVC는 약 97% 이상의 평균 분류율을 나타내었다.

ABSTRACT

Legacy studies for classifying arrhythmia have been studied in order to improve the accuracy of classification, Neural Network, Fuzzy, Machine Learning, etc. In particular, deep learning is most frequently used for arrhythmia classification using error backpropagation algorithm by solving the limit of hidden layer number, which is a problem of neural network. In order to apply a deep learning model to an ECG signal, it is necessary to select an optimal model and parameters.

In this paper, we propose parameter extraction based on AR and arrhythmia classification through a deep learning. For this purpose, the R-wave is detected in the ECG signal from which noise has been removed, QRS and RR interval is modelled. And then, the weights were learned by supervised learning method through deep learning and the model was evaluated by the verification data.

The classification rate of PVC is evaluated through MIT-BIH arrhythmia database. The achieved scores indicate arrhythmia classification rate of over 97%.

키워드 : 자기 회귀, 딥 러닝, 심실 조기 수축, QRS, RR 간격

Key word : AR, Deep learning, PVC, QRS, RR

Received 30 June 2020, Revised 9 July 2020, Accepted 19 July 2020

* Corresponding Author Hyeog-Soong Kwon (E-mail:hskwon@pusan.ac.kr Tel:+82-55-350-5411)
Professor, Department of IT Engineering, Pusan National University, Miryang 50463, Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.10.1341>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

부정맥이란 심장 박동이 갑자기 빨라지거나 느려지고, 불규칙하고 고르지 않는 심장의 비정상적인 활동을 의미하며, 정상인의 가벼운 리듬 장애부터 생명을 위협하는 장애까지 다양한 형태로 나타난다[1-2]. 심실조기수축(PVC : Premature Ventricular Contraction)은 건강한 성인에서 흔하게 발견되는 부정맥이다. 심실에서 기원하는 조기 심장박동으로 고령 환자, 고혈압 환자, 심장질환 환자의 경우 심실빈맥(VT : Ventricular Tachycardia), 나아가서는 돌연사를 일으키는 심실세동(VF : ventricular fibrillation)까지 발전될 수 있다. 따라서 PVC와 같은 부정맥의 조기 검출은 심장질환에 대한 예방과 추후 발생여부에 대한 기초조사로서 매우 중요하다[3]. 기존의 부정맥 분류 방법으로는 RR간격을 이용한 심실조기수축, 심실세동, 전도 차단 부정맥 검출 방법, 독립성분검출을 이용한 방법, 한 구간의 심전도 신호를 신경망, 퍼지 등을 이용한 부정맥 검출 방법 등이 있다. 이러한 기존 방법들은 의료 전문가의 개입이 필요하며 새로운 환자의 경우 분류 성능이 일정하지 않은 문제가 발생한다[4-6].

이러한 문제점을 해결하기 위해서는 최소한의 연산량으로 잡음을 제거하여, 정확한 R파를 검출하고 환자 개인의 특성에 맞게 부정맥을 분류할 수 있는 알고리즘의 설계가 필요하다.

본 연구에서는 AR 기반의 특징점 추출과 딥러닝을 통한 부정맥 분류 방법을 제안한다. 이를 위해 먼저 잡음을 제거한 ECG신호에서 R파를 검출하고 자기 회귀 모델을 통하여 QRS와 RR간격 세그먼트를 추출하였다. 이후 딥러닝을 통한 지도학습 방법으로 가중치를 학습시키고 부정맥을 분류하였다. 제안된 방법의 타당성 평가를 위해 MIT-BIH 부정맥 데이터베이스를 통해 각 파라미터에 따른 훈련 및 검증 정확도를 확인하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안한 방법에 대하여 논하고, 3장에서는 실험결과에 대하여 논하고 4장에서 결론으로 마무리한다.

II. 제안한 방법

AR 기반의 특징점 추출과 딥러닝을 통한 부정맥 분류 방법의 전체 구성도는 그림 1과 같은 단계로 나누어

진다. 먼저 ECG신호로부터 전처리 과정을 통해 잡음을 제거한 후 R파를 검출한다. 검출된 R파를 이용하여 QRS와 RR간격을 추출하여 학습을 위한 데이터 셋을 구성한다. 이후 학습데이터와 테스트 데이터에 대해 딥러닝 기법을 사용하여 부정맥을 분류한다.

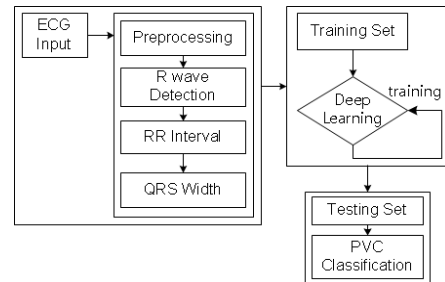


Fig. 1 System configuration

2.1. 전처리

전처리 과정은 심전도 신호에 존재하는 잡음을 제거하여 R파를 정확히 검출함으로써 정확한 진단을 가능하게 한다. R파 검출을 위한 전처리 과정은 그림 2와 같다. 먼저 잡음이 포함된 심전도 신호로부터 기저선(baseline)과 같은 저주파 잡음을 제거하기 위해 미분 연산을 이용하였다. 이후 저주파 과정을 거친 후 발생된 구간에 집중된 고주파 잡음을 제거하기 위해 이동 평균을 통한 적분 함수를 사용하였다.

최종적으로 제곱 연산을 통해 정점을 증폭시킴으로써 불필요한 잡음과 구분되는 원하는 신호를 얻게된다.

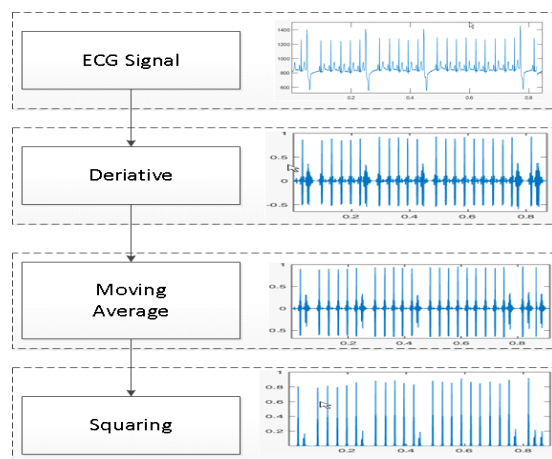


Fig. 2 Preprocessing

2.2. R파 검출

정확한 진단을 위해서는 심전도 신호의 잡음 제거를 통해 정확한 R파를 검출해야한다. 본 연구에서는 샘플링 주파수에 따른 전처리 기법과 적응형 문턱치에 의한 최적치를 통해 R파를 검출하였다[7]. MIT-BIH 데이터 베이스의 경우 샘플링 주파수, 이동 평균, 미분값, 피크 문턱치는 각각 360Hz, 8, 7, 6.6이라는 것을 확인할 수 있다. 이는 교차 실험을 통해 획득한 최적화된 값이며, R파를 검출하기 위해서는 대상 프로세서의 성능에 맞도록 샘플율을 선택하는 것이 필요하다는 것을 확인할 수 있다. R파를 검출한 후에는 정상 신호와 부정맥 신호를 포함하는 최소 심장 사이클에 대한 구간 설정이 필요하다. 이를 위해 QRS와 RR간격의 최적 범위를 설정하였다.

본 연구에서는 추출된 신호의 요소를 직접 처리하는 대신 계산량을 줄이고 신호의 모델링이 가능한 AR (Auto Regressive) 기법을 적용하여 RR 간격과 QRS 간격에 대한 최적 세그먼트 길이와 최적 차수의 AR 모델링 변수를 추출함으로써 부정맥 분류를 위한 딥러닝의 입력 변수로 사용하였다.

2.3. 딥러닝(Deep Learning)

기본적인 딥러닝 모델은 은닉층(hidden layer)이 다수 존재하는 신경회로망으로 일반적인 신경회로망 모델에는 1개 이상의 층(layer)이 존재하는데 입력 데이터를 표현하는 한 개의 입력 층(input layer), 입력층과 은닉층의 선형결합과 비선형변환으로 이루어진 한 개 이상의 은닉층(hidden layer), 출력 값이 있는 한 개의 출력 층(output layer)으로 구성된다. 하나의 은닉층 안에는 여러 개의 은닉 노드(hidden node)가 존재하는데 각 은닉 노드(node)가 하나의 입력 값의 선형 맞춤과 비선형 변환을 표현한다. 출력 층도 모든 은닉 층 값의 선형결합과 비선형변환의 합으로 표현된다.

각 층 사이에는 가중치 매개변수가 출력의 값을 조절하고 활성화 함수(activation function)를 통해 펄스 신호로 변환하는 역할을 하면서 반복적인 학습 과정으로 출력 신호가 정확히 판단 또는 분류되도록 하며, 이 과정에서 생기는 오차는 오류역전파를 통해 각 층으로 전달하여 매개변수들의 기울기가 변화되면서 가중치를 최적의 상태로 만들어준다[8].

2.4. 완전연결 계층

완전연결 계층은 모든 뉴런 사이를 연결하는 가중치와 편향(bias) 파라미터를 갖는 딥러닝에서 가장 기본적인 층을 말하며 가중치 연산의 행렬의 내적으로 출력 값을 계산한다.

딥러닝에서는 각 노드에 들어오는 값들에 대해 곧바로 다음 층으로 전달하지 않고 주로 비선형 함수를 통과시킨 후 전달한다. 이때 사용하는 함수를 활성화 함수라 부른다. 여기서 주로 비선형 함수를 사용하는 이유는 선형함수를 사용할 시 층을 깊게 하는 의미가 줄어들기 때문이다. 대표적인 활성화 함수로는 Sigmoid, Tanh(Hyper Tangent), ReLu(Rectified Linear Unit) 함수 등이 있다. Sigmoid함수는 신경망 초기에는 많이 사용되었지만, 함수 자체의 특성으로 인한 기울기 손실(gradient vanishing) 문제, 함수의 중심값으로 최적화 과정이 느려지는 문제가 발생한다. Tanh함수는 Sigmoid의 최적화 문제를 해결했지만 기울기 손실 문제는 여전히 남아있다. ReLu함수는 Sigmoid와 Tanh함수가 가지고 있는 이와 같은 두 가지 문제를 예방할 수 있다[9-10].

2.5. 딥러닝의 출력층

딥러닝의 출력층은 입력 데이터를 정확한 클래스로 분류하는 과정과 신경회로망의 성능을 평가하는 오차 계산 단계로 이루어진다. 본 연구에서는 수식(1)과 같이 소프트맥스 함수를 통하여 정상파형과 PVC 파형일 확률에 대한 2개의 값을 구한다.

$$y_k = \frac{e^{x_k}}{\sum_{i=1}^n e^{x_i}}, k = 1, \dots, m. \quad (1)$$

여기서 n 은 출력 층의 뉴런 개수, m 은 분류할 클래스의 개수, y_k 는 k 번째 출력임을 뜻한다.

신경회로망의 성능 평가의 지표인 오차는 손실(loss) 함수로 계산된다. 손실 함수는 딥러닝 모델의 출력이 정확한 클래스로 분류되었는지를 평가하는 지표로서 낮은 수치일수록 높은 성능을 의미하기에 손실 지표를 0에 가깝도록 반복적으로 학습을 해야 한다.

신경회로망의 성능 평가의 지표인 오차는 손실(loss) 함수로 계산된다. 손실 함수는 딥러닝 모델의 출력이 정확한 클래스로 분류되었는지를 평가하는 지표로서 낮은 수치일수록 높은 성능을 의미하기에 손실 지표를 0에

Table. 1 R peak detection rate

MIT-BIH Rec. no.	Total Bit no.	Detection Rate(%)
100	2274	99.95
101	1866	99.94
102	2187	99.95
103	2084	99.94
104	2229	99.73
105	2602	93.05
106	2026	99.88
107	2136	100
108	1763	92.48
109	2533	99.95
111	2123	99.94
112	2539	99.95
113	1794	99.93
114	1890	99.56
115	1953	99.94
116	2395	98.96
117	1535	99.92
118	2278	99.95
119	1988	99.94
121	1863	99.87
122	2476	99.95
123	1519	100
124	1619	99.93
200	2601	99.77
201	1949	98.22
202	2138	94.95
203	2988	99.93
205	2656	100
207	2324	99.78
208	2953	100
209	3006	99.87
210	2652	100
212	2748	100
213	3250	100
214	2262	99.96
215	3362	100
217	2208	99.86
219	2154	94.57
220	2048	99.90
221	2427	100
222	2485	98.75
223	2604	99.92
228	2060	97.48
230	2256	98.18
231	1571	100
232	1783	99.94
233	3077	99.97
234	2751	100
total	109,893	99.758

가깝도록 반복적으로 학습을 해야 한다. 딥러닝의 출력 계층의 소프트맥스와 교차 엔트로피 오차 함수를 하나로 묶어서 사용되어 역전파의 최종적인 결과는 출력과 정답레이블의 차이로 표현된다. 즉, 소프트맥스의 함수의 결과를 교차 엔트로피를 통해 변환하게 되면 원-핫 인코딩 값, 즉 하나만 1이고 나머지는 모두 0인 형태로 전환시킬 수 있게 된다.

III. 실험 결과 및 고찰

3.1. R파 검출 성능 비교

본 논문에서는 구현된 분류 방법의 실용성을 검증하기 위하여 샘플링 주파수가 360Hz인 MIT-BIH 데이터베이스에 샘플링 주파수에 따른 전처리 기법을 적용하여 R파 검출의 효율성과 타당성을 확인하였다. 검출률의 계산은 수식 (2)와 같다.

$$\text{검출률} = \frac{\text{전체비트수} - (FP + FN)}{\text{전체비트수}} \quad (2)$$

(FP: False Positive, FN: False Negative)

위의 식에서 FP는 검출알고리즘이 R파를 검출하였으나, MIT-BIH부정맥 데이터베이스에는 존재하지 않을 경우이고, FN은 MIT-BIH부정맥 데이터베이스에는 있으나 알고리즘이 이를 검출하지 못한 경우이다. 전체 비트는 MIT-BIH에 존재하는 R파의 총 개수이다. 표 1과 같이 총 48개 레코드를 대상으로 한 평균 R파 검출률은 99.758%의 우수한 성능을 나타내었다. 또한 표 2와 같이 기존의 필터들을 이용한 방식과 비교하였을 때 좀 더 우수한 검출률을 나타내었다.

Table. 2 Comparison of legacy algorithms for R wave detection result

Algorithm	Linear Filter	Median Filter	Wavelet	proposed
avg(%)	96.54	97.59	98.84	99.77

3.2. PVC 분류 성능 비교

본 연구에서 제안한 딥러닝 모델은 완전연결층과 ReLU층을 이용한 심층신경망 방식으로 구성하였으며, 각 파라미터를 변화시키면서 PVC를 평가하였다.

딥러닝 모델 구현 과정은 다음과 같다. 먼저 ECG 신호로부터 전처리 과정을 통해 잡음을 제거한 후 R파를

검출하고, 검출된 R파를 기준으로 QRS와 RR간격을 검출한다. 학습 및 테스트 데이터 셋은 QRS와 RR간격과 라벨데이터를 하나의 파일로 구성한다. 라벨 데이터는 원-핫 인코딩 형식으로 구성한다. 이 후 학습데이터에 대해 미니배치를 획득하여 각 완전연결 층에서 가중치, 편향과 연산되어 1차원 데이터로 출력된다. 이 출력은 층의 개수에 따라 지속적으로 전달되면서 마지막 층에서 정상과 PVC 2개의 심전도 비트로 분류된다.

분류 평가에 있어 정확도를 평가하기 위해 각 파라미터에 따른 최적값을 비교하였다. 비교 파라미터로는 완전연결층 개수, Epoch 수, 활성화 함수, 최적화 함수에 따른 비교를 수행하였다. 본 연구에서는 학습 과정에서 매개변수를 갱신하여 분류 성능을 높이는 것을 목표로 한다. 매개변수는 가중치와 바이어스로 구성되며 학습 과정을 통해 최적값으로 갱신된다. 초기 가중치, 바이어스 값과 학습률은 모두 0.1로 설정하였다.

실험 결과를 통한 조기수축 부정맥 분류를 위한 최적 파라미터는 다음과 같다. 테스트 과정에서 설명된 바와 같이 이 최적치는 반복적인 실험을 통해 선정된 결과 값이다. 완전 연결층의 개수는 5, Epoch 수는 10,000, 활성화 함수는 ReLU, 최적화 함수는 Adam함수를 사용하였을 경우 제일 높은 분류율을 나타내는 것을 확인할 수 있었다. 특이할 만한 사항은 완전 연결층과 Epoch의 값이 그 이상 또는 이하일 경우와 다른 활성화 함수와 최적화 함수를 사용하였을 경우 분류율이 떨어진다는 것이었다.

정확도는 최종적으로 계산된 값을 사용하였으며 설계한 딥러닝 신경망을 통해 부정맥을 분류한 결과는 표 3과 같다.

각 레코드의 매개변수 갱신에 따른 분류 정확도는 다음과 같다. 100, 202, 205, 209 레코드의 경우에는 처음부터 높은 정확도를 보여주었고 학습을 진행하면서 이 정확도를 계속 유지하였다. 이들 레코드의 경우 Normal 비트가 PVC에 비해 상대적으로 많아 높은 분류 정확도를 보여준 것으로 예상된다. 203 레코드의 경우 잡음이 섞여 있어 초기 정확도는 약 90%로 낮게 나왔지만 반복된 학습으로 96.37%의 최종 정확도를 나타내었다. 106, 119, 200, 210, 215, 221, 228, 233 레코드의 경우 대부분 초기 정확도는 낮았으나 1 epoch 씩 학습이 반복되면서 특정 시점에서 정확도가 향상되어 10,000 epoch에 이르러서는 95% 이상의 정확도를 유지하는 것을 확인할 수 있었다.

PVC의 평균 분류율은 97.84%의 우수한 특징을 나타내었다. PVC에 대한 분류율을 기존 알고리즘과 비교하여 표 4에 나타내었다. 제안한 방법은 기존 신경망을 통한 분류방법(ANN)보다 적은 학습 데이터의 양으로 분류의 정확도와 처리속도를 개선시킬 수 있음을 확인할 수 있었다. 또한 ECG morphology를 이용한 방법과 비교하였을 때 QRS와 RR간격을 분류 변수로 사용한 것은 동일 하지만 제안한 방법은 AR모델링을 통한 세그먼트 특징을 추출과 최적 변수를 사용함 분류의 정확도를 높일 수 있었다. 결과적으로 제안된 AR기반의 특징점 추출과 딥러닝을 통한 부정맥 분류 방법은 복잡도를 줄임과 동시에 우수한 분류율을 나타내었다. 본 연구에서 제안된 QRS, RR세그먼트와 최적 파라미터를 통한 딥러닝 신경망 모델은 훈련 데이터의 지역적 특성에만 적응하는 오버피팅 현상을 해결하여 심실조기수축 비트 분류의 정확도를 향상시키는 것을 확인할 수 있었다.

Table. 3 Arrhythmia classification rate

Record	Accuracy(%)
100	97.86
103	99.78
106	100
119	99.49
200	96.34
202	96.47
203	96.37
205	100
209	99.22
210	96.35
213	93.33
215	99.79
220	96.83
221	95.42
228	100
233	99.28
average	97.84

Table. 4 Performance comparison between the proposed algorithm and state of the art papers

Classification method	Art papers	Avg(%)
ANN	Shyu et al	97.04
ECG morphology	de Chazal et al	94.11
Our approach	proposed	97.84

하지만 213번 레코드는 학습 과정에서 0%의 결과도 중간에 나온 것을 확인할 수 있으며, 최종 정확도가 93.33% 결과로 다른 레코드에 비해 정확도가 상대적으로 낮게 나타났다. 이 레코드의 경우 PVC파형은 582개로 많은 개수를 보유하고 있으나 다양한 PVC패턴이 결합되어 있기 때문에 다른 레코드에 비해 PVC가 Normal로 잘못 검출 되는 경우라고 판단된다. 또한 PVC임에도 불구하고 서로 다른 종류의 PVC가 반복됨으로써 RR간격이 normal과 유사한 형태를 가지고 있기 때문에 정확한 검출이 이루어지지 않았다. 이런 현상을 해결하기 위해서는 합성곱 신경망(CNN : Convolutional Neural Networks)을 통한 분류방식의 적용이 필요할 것으로 판단된다.

IV. 결론

본 연구에서는 전처리를 통해 최적의 R파를 검출하고 이를 활용하여 단기간의 입력데이터를 근거로 연산의 복잡도를 줄이고, 정확하게 부정맥을 분류하기 위해 AR 기반의 특징점 추출과 딥러닝을 통한 부정맥 분류 방법을 제안하였다.

이를 위해 전처리를 통해 잡음을 제거한 ECG신호에서 R파를 검출하고 QRS와 RR간격을 추출하였다. 이후 딥러닝을 통한 지도학습 방법으로 가중치를 학습시키고 검증데이터로 모델을 평가하였다. 제안된 방법의 타당성 평가를 위해 MIT-BIH 부정맥 데이터베이스를 통해 각 파라미터에 따른 딥러닝 모델로 훈련 및 검증 정확도를 확인하였다. 성능 평가 결과 완전 연결층의 개수는 5, Epoch 수는 10,000, 활성화 함수는 ReLU, 최적화 함수는 Adam함수를 사용하였을 경우 R파의 평균 검출율은 99.77%, PVC부정맥의 평균 분류율은 각각 97.84%의 제일 높은 분류율을 나타내는 것을 확인할 수 있었다. 대상자의 증상 유무 및 종류에 따라 정확한 진단을 해야 하는 IoT 헬스케어 기반의 원격진료 시스템의 경우 본 연구에서 제안한 딥러닝 기반의 부정맥 분류 알고리즘이 효율적인 것으로 판단된다. 부정맥 분류 알고리즘에 대한 많은 연구가 진행되어 왔지만, 심장 질환자들에 대한 전문의의 해석을 정리 보관한 데이터베이스의 부재를 들 수 있다. 따라서 국내에 적합한 부정맥 분류 알고리즘을 정착시키기 위해서는 심장전문의와의 협력과

임상 데이터를 통한 데이터베이스 개발과 이를 통한 진단 알고리즘의 정착이 필요하다.

ACKNOWLEDGEMENT

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT)(No. 2019R1G1A1100771).

REFERENCES

- [1] S.-H. Liou, Y.-H. Wu, Y.-S. Syu, Y.-L. Gong, H.-C. Chen, and S.-T. Pan, "Real-time remote ECG signal monitor and emergency warning/positioning system on cellular phone," *Intelligent Information and Database Systems*, Berlin, Germany: Springer-Verlag, vol. 7198, pp. 336-345, 2012.
- [2] C. Ye, B. V. K. Kumar, and M. T Coimbra, "Heartbeat classification using morphological and dynamic features of ECG signals," *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 10, pp. 2930-2941, Oct. 2012.
- [3] M. J. Rooijackers, C. Rabotti, H. D. Lau, S. G. Oei, J. W. M. Bergmans, and M. Mischi, "Feasibility Study of a New Method for Low-Complexity Fetal Movement Detection From Abdominal ECG Recordings," *IEEE Journal of Biomedical and Health Informatics*, vol. 20, no. 5, pp. 1361-1368, Sep. 2016.
- [4] K. Hanbay, "Deep neural network based approach for ECG classification using hybrid differential features and active learning," *Institution of Engineering and Technology*, vol. 13, no. 2, pp. 165 - 175, May. 2019.
- [5] W. Li, "Deep Intermediate Representation and In-Set Voting Scheme for Multiple-Beat Electrocardiogram Classification," *IEEE Sensors Journal*, vol. 19, no. 16, pp. 6895 - 6904, Apr. 2019.
- [6] P. Li, Y. Wang, J. He, L. Wang, Y. Tian, T. Zhou, T. Li, and J. S. Li, "High-Performance Personalized Heartbeat Classification Model for Long-Term ECG Signal," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 1, pp. 78-86, Jan. 2017.
- [7] I. S. Cho and H. S. Kwon, "Optimal Threshold Setting Method for R Wave Detection According to The Sampling Frequency of ECG Signals," *Journal of Korea Institute of*

- Information and Communication Engineering*, vol. 21, no. 7, pp. 1420-1428, Jul. 2017.
- [8] W. Li and J. Li, "Local Deep Field for Electrocardiogram Beat Classification," *IEEE Sensors Journal*, vol. 18, no. 4, pp. 1656 - 1664, Nov. 2019.
- [9] G. Wang, J. Hu, C. Li, B. Guo, and F. Li, "Simultaneous Human Health Monitoring and Time-Frequency Sparse Representation Using EEG and ECG Signals," *IEEE Access*, vol. 7, pp. 85985 - 85994, Jun. 2019.
- [10] Q. Li, C. Rajagopalan, and G. D. Clifford, "Ventricular Fibrillation and Tachycardia Classification Using a Machine Learning Approach," *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 6, pp. 1607 - 1613, Jul. 2013.



조익성(Ik-Sung Cho)

2003.02 : 한국해양대학교 공학박사
2014.02 : 부산대학교 바이오정보전자공학과 공학박사
2014.03 ~ 2018. 03 : 경운대학교 항공정보통신공학과 조교수
2018.03 ~ 현재 : 대구대학교 자유전공학부 조교수
※관심분야 : 생체신호처리, ECG Preprocessing, ECG 특징점 추출, 부정맥 분류 알고리즘



권혁송(Hyeog-Soong Kwon)

1995.08 : 영남대학교 전자공학과 공학박사
1996.04-2006.02 : 밀양대학교 정보통신공학과 부교수
2002.02~2003.02 : 미국 OSU 방문교수
2011.07~2012.07 : 미국 조지아텍 방문교수
2006.03 - 현재 : 부산대학교 IT 응용공학과 정교수
※관심분야 : 생체신호처리, ECG 특징점 추출, CDMA, 통신시스템