

심실 조기 수축 비트 검출을 위한 딥러닝 기반의 최적 파라미터 검출

조익성¹ · 권혁승^{2*}

Optimal Parameter Extraction based on Deep Learning for Premature Ventricular Contraction Detection

Ik-sung Cho¹ · Hyeog-soong Kwon^{2*}¹Associate Professor, Department of Creative Integrated General Studies, Daegu University, Kyongsan 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), 퍼지(Fuzzy), 기계학습(Machine Learning) 등을 이용한 방법이 연구되어 왔다. 특히 딥러닝은 신경회로망의 문제인 은닉층 개수의 한계를 해결함으로써 오류 역전파 알고리즘을 이용한 부정맥 분류에 가장 많이 사용되고 있다. 딥러닝 모델을 심전도 신호에 적용하기 위해서는 적절한 모델선택과 파라미터를 최적에 가깝게 선택할 필요가 있다. 본 연구에서는 심실 조기 수축 비트 검출을 위한 딥러닝 기반의 최적 파라미터 검출 방법을 제안한다. 이를 위해 먼저 잡음을 제거한 ECG 신호에서 R파를 검출하고 QRS와 RR간격 세그먼트를 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 R파의 평균 검출 성능은 99.77%, PVC는 97.84%의 평균 분류율을 나타내었다.

ABSTRACT

Legacy studies for classifying arrhythmia have been studied to improve the accuracy of classification, Neural Network, Fuzzy, etc. 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 optimal parameter extraction method based on a deep learning. For this purpose, R-wave is detected in the ECG signal from which noise has been removed, QRS and RR interval segment 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 detection and classification rate of R wave and PVC is evaluated through MIT-BIH arrhythmia database. The performance results indicate the average of 99.77% in R wave detection and 97.84% in PVC classification.

키워드 : 최적 파라미터, 딥 러닝, 심실 조기 수축, QRS, RR 간격

Key word : Optimal parameter, Deep learning, Premature ventricular contraction, QRS, RR interval

Received 22 August 2019, Revised 28 August 2019, Accepted 16 September 2019

* **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.2019.23.12.1542>

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

일반적으로 심전도(ECG : electrocardiography) 신호의 해석 과정은 인체로부터의 신호 획득, 잡음 제거, QRS의 검출 및 진단을 포함하며, 신호 분석을 토대로 심장질환의 이상 유무를 판단하는데 활용되고 있다. 부정맥은 심박동수가 비정상적이거나 심장의 리듬이 불규칙한 상태를 의미하며, 정상인의 가벼운 리듬 장애부터 생명을 위협하는 장애까지 다양한 형태로 나타난다 [1-3]. 특히 심실조기수축(PVC : Premature Ventricular Contraction)은 가장 흔한 부정맥으로 심장질환이 있었던 환자의 경우 심실빈맥(VT : Ventricular Tachycardia)과 같은 위험한 심장질환을 유발할 수 있으므로 이의 조기 검출은 매우 중요하다[4].

기존의 부정맥 분류 방법으로는 RR간격을 이용한 심실조기수축, 심실세동, 전도 차단 부정맥 검출 방법, 독립성분검출(ICA:Independent Component Analysis)을 이용한 방법, 한 구간의 심전도 신호를 AR(Auto Regressive) 모델로 심전도를 해석하는 부정맥 검출 방법 등이 있다 [5].

이러한 기존 방법들의 경우 전문가의 입력이 빈번하게 필요하고 새로운 환자의 심전도를 분류할 때 성능이 유지되지 않는 단점을 가진다.

이러한 단점을 극복하기 위해 신경회로망(Artificial Neural Network), 퍼지(Fuzzy), 기계학습(Machine Learning), 딥러닝 등의 방법들이 제안되었다. 대다수 연구는 신경회로망의 오류역전파(error back propagation) 알고리즘을 가장 많이 사용하였고 MIT-BIH 부정맥 데이터베이스를 통한 실험 결과 95% 이상의 높은 검출률을 보여준 대[6-7].

기계학습은 통계학 기반의 분류, 회귀 및 군집 모델로서 신호의 특성을 정의하여 데이터 집합을 만들고 이를 기반으로 특성을 판별하는 방식이며, 딥러닝은 신호가 지닌 기본 요소들을 계층적 은닉층으로 표현할 수 있으며, 이 때 추가 은닉층들은 점진적으로 모여진 하위 계층들의 특징들을 스스로 규합시킬 수 있는 방식이다. 이는 비슷하게 수행된 신경회로망에 비해 더 적은 수의 유닛으로 복잡한 데이터를 모델링 할 수 있는 장점을 가진다. 특히 딥러닝은 기존에 해결하지 못했던 신경회로망의 은닉층이 3개 이상일 때의 문제를 풀 수 있게 되었다.

심전도 신호는 영상 이미지와 다르게 구간별 뚜렷한

특징이 있기에 많은 층과 뉴런을 사용할 경우 훈련 데이터의 지역적 특성에만 적응하는 오버피팅(overfitting) 현상이 발생할 수 있는데 선행 연구에서는 은닉층과 뉴런의 수 등의 딥러닝 파라미터를 명확하게 제시하지 않고 있다. 따라서 딥러닝 모델을 심전도 신호에 적용하기 위해선 적절한 모델선택과 파라미터를 최적으로 가깝게 선택할 필요가 있다.

본 연구에서는 조기수축 부정맥 분류를 위한 딥러닝 기반의 최적 파라미터 검출 방법을 제안한다. 이를 위해 심전도 신호 자체를 딥러닝의 입력 데이터로 직접 활용하게 되면 오버피팅현상이 발생하므로 전처리를 통해 R파를 검출한 후, QRS와 RR간격의 정규화 과정을 통하여 학습 및 검증 데이터로 분리하여 사용한다. 이를 통해서 심전도 리듬 평가에 있어 적절한 딥러닝 모델과 최적 파라미터를 제시하고자 하였다. 제안된 방법의 타당성 평가를 위해 MIT-BIH 부정맥 데이터베이스를 통해 각 파라미터에 따른 딥러닝 모델로 훈련 및 검증 정확도를 확인하였다.

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

II. 제안한 기법

조기수축 부정맥 분류를 위한 딥러닝 기반의 최적 파라미터 검출 방법의 전체 구성도는 그림 1과 같은 단계로 나누어진다. 그림에서와 같이 먼저 ECG신호로부터 전처리 과정을 통해 잡음을 제거한 후 R파를 검출한다. 검출된 R파를 이용하여 QRS와 RR간격 구간을 추출하여 학습을 위한 데이터 셋을 구성한다. 이후 학습데이터에 대해 미니배치를 획득하고 딥러닝 알고리즘을 사용하여 매개변수를 갱신한다. 학습과정이 끝난 후에는 테스트 데이터 셋을 이용하여 매개변수의 최적값을 통해 분류 성능을 평가한다.

2.1. 전처리 및 R파 검출

정확한 진단을 위해서는 심전도 신호의 잡음 제거를 통해 정확한 R파를 검출하는 것이 필요하다. 본 연구에서는 샘플링 주파수에 따른 전처리 기법과 적응형 문턱치에 의한 최적치를 통해 R파를 검출하였다[8].

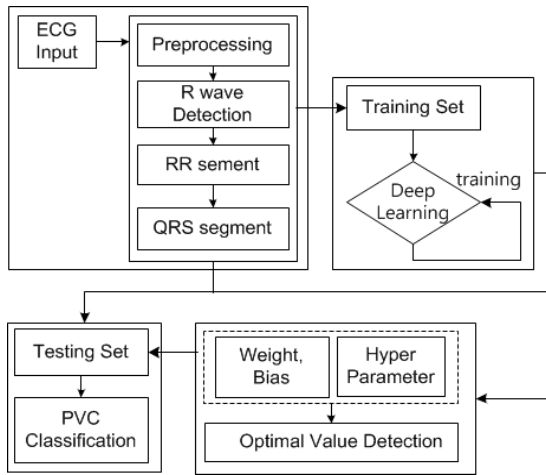


Fig. 1 System configuration

샘플링 주파수에 따른 성능은 분류에 영향을 끼치지 않는 최적의 샘플율을 정하기 위함이다. 일반적으로 MIT-BIH 데이터베이스의 경우 샘플링 주파수는 360Hz, 이동 평균의 범위는 8, 미분 파라미터의 범위는 7, 피크 문턱치는 6.6이라는 것을 확인할 수 있다. 이는 실험을 통한 경험 수치이며, 최적화된 R파를 검출하기 위해서는 분류를 수행할 컴퓨팅 프로세서의 성능에 맞는 샘플율의 선택이 중요하다는 것을 확인할 수 있었다.

본 연구에서는 딥러닝 기반의 부정맥 분류를 위한 입력변수로서 QRS와 RR간격을 이용한다. 이는 심실 조기수축(PVC)을 판단하는 유용한 정보가 된다. 정상신호의 QRS와 RR간격은 그 변화율이 일정한 것에 반해, PVC의 경우, 그 변화율이 규칙적으로 커진다. 즉, PVC는 정상신호에 비해 QRS간격이 넓어지며, RR간격의 경우 급격히 좁아지며, 그 변화율이 일정하게 커지는 특징을 가진다. 따라서 RR간격의 평균과 이전, 이후의 변화량을 이용한다면 PVC의 패턴을 분류하는 것이 가능하다.

일반적으로 부정맥 분류를 위한 입력 데이터의 양은 처리 속도에 영향을 미치므로 신호 데이터의 차원을 감소시키는 것이 필요하다. 본 연구에서는 추출된 신호의 요소를 직접 처리하는 대신 계산량을 줄이고 신호의 모델링이 가능한 AR(Auto Regressive)기법을 전처리 과정에 적용하여 부정맥 분류를 위한 딥러닝의 입력 변수로 사용한다. AR모델링 기법은 ECG신호에서 이전과 현재의 신호 파형에 자기상관을 적용하여 계수를 추출

함으로써 부정맥 신호들 간의 차별성 있는 특징을 파악할 수 있는 방법이다. QRS와 RR간격 세그먼트는 정상과 부정맥을 결정하고 해석하는데 가장 중요하게 쓰이는 특징이며, 분류의 정확도를 높이기 위함이다. 분류를 위한 단기간의 입력 변수로서 QRS와 RR간격 세그먼트에 대한 최적치를 설정하였다. 이 값들은 딥러닝의 입력 인자로 사용되며, 부정맥의 성능개선에 중요한 인자가 된다. 본 연구에서는 MIT-BIH부정맥 데이터베이스 48개 레코드에 대상으로 한 QRS와 RR간격에 대한 최적 세그먼트를 설정하였다. 실험결과 각각 24, 600일 때 최적의 검출율을 얻는 것을 확인할 수 있었다. 이는 반복적인 교차 검증(cross validation) 실험을 통해 최적의 값을 선정한 것이다.

2.2. 딥러닝(Deep Learning)

기본적인 딥러닝 모델은 은닉층(hidden layer)이 다수 존재하는 신경회로망으로 그림 2와 같은 형태로 구성된다. 각 층 사이에는 가중치(weight) 매개변수가 출력값을 조절하기 때문에 반복적인 학습 과정을 통하여 가중치를 최적의 상태로 만들어주어야 한다. 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 은닉층 값의 선형결합과 비선형변환의 합으로 표현된다.




Fig. 2 Deep learning model

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[9].

2.3. 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.

또한, 각 층의 구성은 순전파와 역전파로 구성되며 순전파는 가중치와 입력데이터의 내적연산과 편향의 합으로 출력결과를 다음 층으로 전달하며, 역전파는 각 노드의 규칙을 통해서 입력신호 방향으로 오차 기울기를 전달한다.

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. 딥러닝에서 사용하는 활성화 함수는 입력 신호의 총합이 임계치의 경계로 활성화 여부를 파악할 때 사용한다.

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[10-11].

그림 3은 Sigmoid와 ReLU함수를 비교한 것이다. 그림에서와 같이 Sigmoid는 시간에 따라 값을 변화시키지만 ReLu함수는 임계값을 넘는 순간 입력을 그대로 넘겨줌으로써 기울기 손실 문제를 해결하는 것을 확인할 수 있다.

따라서 딥러닝을 통한 성능을 향상시키기 위해서는 최적화된 활성화 함수의 선택이 중요하다.




Fig. 3 Activation function(Sigmoid & ReLU)

2.4. 딥러닝의 출력층

딥러닝의 출력층은 입력 데이터를 정확한 클래스로 분류하는 과정과 신경회로망의 성능을 평가하는 오차 계산 단계로 이루어진다. 분류과정의 활성화 함수는 소프트맥스(softmax)함수이며 입력 신호(x_k)의 지수함수를 모든 입력 신호의 지수 함수의 합으로 나눈 형태로 수식 (1)과 같다. 소프트맥스 함수는 수식에서와 같이 총합이 1인 형태로 계산해주는 역할을 한다. 합계가 1인 형태로 변환되고 큰 값이 두드러지게 나타나 작은 값은 더 작아지는 결과를 나타낸다. 즉 소프트맥스 함수를 각 분류 값이 0 ~ 1 사이의 실수로 표현되기에 출력을 해석할 수 있다. 본 연구에서는 소프트맥스 함수를 통하여 2개의 값을 구하게 되는데 각각 정상파형과 심실조기수축 파형일 확률을 나타낸다.

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

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. 이 함수에는 평균 제곱 오차(MSE: Mean Squared Error)와 교차 엔트로피 오차(CEE: Cross Entropy Error)가 있으며 딥러닝에서는 소프트맥스 함수와 교차 엔트로피 오차가 함께 하나의 계층으로 구성된다. 교차 엔트로피 오차 함수는 신경망의 출력(y_k)과 정답 레이블(t_k)로 구성되고 자연 로그의 결과가 항상 음의 값이기 때문에 최종결과에 마

이너스 부호를 곱해서 수식 (2)와 같이 표현한다.

$$E = - \sum_k t_k \ln(y_k) \quad (2)$$

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. 딥러닝 모델의 평가방법 및 실험

본 연구에서 제안한 딥 러닝 모델은 그림 4와 같이 완전연결층과 ReLU층을 이용한 심층신경망 방식으로 구성하였으며, 각 파라미터를 변화시키면서 심실 조기수축을 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. 이후 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.

원 핫 인코딩 형식으로 라벨데이터를 구성하였기 때문에 정상 파형일 경우에는 $y = [[1], [0]]$ 이 되며, 심실조기수축일 경우에는 $y = [[0], [1]]$ 이 된다.

분류 평가에 있어 정확도를 평가하기 위해 각 파라미터에 따른 최적값을 비교하였다. 비교 파라미터로는 완전연결층 개수, Epoch 수, 활성화 함수, 최적화 함수에 따른 비교를 수행하였다.

완전연결 층의 개수가 분류 평가에 미치는 영향을 파악하기 위해서 완전연결 층을 2 - 6층으로 증가시키면서 변화를 주었다. 매개 변수 갱신 따른 성능을 평가하기 위하여 epoch수와 각 은닉층에서의 활성화 함수 Sigmoid, Tanh, ReLU에 따른 정확도를 비교하였으며, 딥러닝 모델의 가중치의 최적화 속도를 평가하기 위해서 확률적 경사 하강법(SGD : Stochastic Gradient Descent), Adam,

RMSProp(Root Mean Square Propagation)에 따른 분류 정확도를 비교하였다. 출력층에서의 활성화 함수로는 소프트맥스(softmax)함수를 사용하였다. 단 드롭아웃(dropout)은 사용하지 않는다.

미니 배치는 전체 학습 데이터 중 일부를 추려 전체의 ‘근사치’로 이용하는 방법으로 하이퍼 파라미터인 반복 횟수와 미니배치 크기의 초기값을 설정, 반복횟수 만큼 학습을 진행하면서 1epoch 마다 정해진 미니배치 크기 만큼 랜덤으로 학습 데이터를 획득하여 매개변수를 갱신하는 방식이다. 본 연구에서는 미니배치 크기를 512로 설정하였다. 이는 반복적인 실험과정을 통해 얻은 경험치로서 최적 성능을 낼 수 있는 값으로 설정하였다.

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. 갱신 과정은 아래와 같다. 먼저 기존에 설정이 되어있는 매개변수를 사용하여 순전파 계산을 실행한다. 이때 입력 값은 RR간격과 QRS간격 두 개이며 완전연결층을 거쳐 최종적으로 2개의 값을 구한다. 이 값은 softmax 함수를 통해 계산되며, 각각 Normal과 PVC의 확률값을 나타낸다. 다음으로 계산한 오차를 갱신하고자 하는 가중치로 편미분한 값을 기존의 가중치에서 빼주게 된다. 이러한 과정을 모든 가중치에 대해서 반복하게 되며, 이것이 1 epoch에서 실행되는 과정이다.

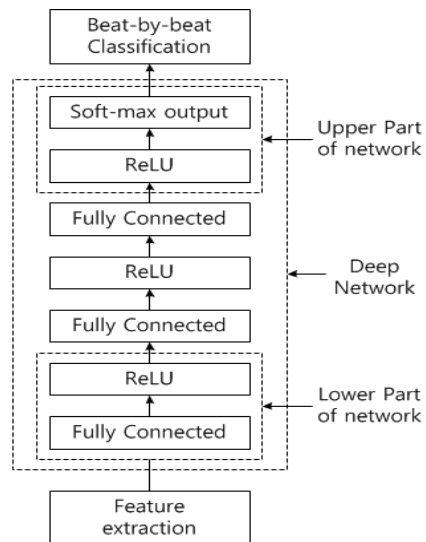


Fig. 4 Proposed deep learning model

3.1. 테스트

딥 러닝 신경망은 크게 학습 과정(training)과 테스트 과정(testing)으로 나눌 수 있다. 학습 과정은 매개변수 갱신이 목표이며 테스트 과정은 갱신된 매개변수를 통해 성능을 확인하는 과정이다. 본 연구에서는 학습 데이터와 테스트 데이터의 비율을 7:3으로 설정하였다. 매개변수는 1 epoch 마다 한번 갱신되며 테스트 데이터 셋을 통해 그 정확도를 확인하였다. 경험적 실험을 통해 선택한 은닉층의 개수에 따른 정확도는 그림 5와 같다. 은닉층의 개수가 5일 때 제일 높은 분류 정확도를 나타내는 것을 확인할 수 있으며, 6개 이후에는 그 차이가 거의 발생하지 않는 것을 확인할 수 있다.




Fig. 5 Accuracy by number of hidden layer

그림 6은 MIT-BIH 부정맥 데이터베이스의 각 레코드별 최고의 분류 정확도를 나타내는 epoch 수를 나타낸 것이다. 대부분의 레코드에서 200번과 233번 레코드의 경우 2000번, 210번 레코드의 경우 8000번, 나머지 레코드의 경우에도 4000번과 6000번 사이의 반복 학습으로 정확도에 수렴하는 것을 확인할 수 있었다. 그림에 나타나지 않는 레코드의 경우 대부분 초기 학습으로 인

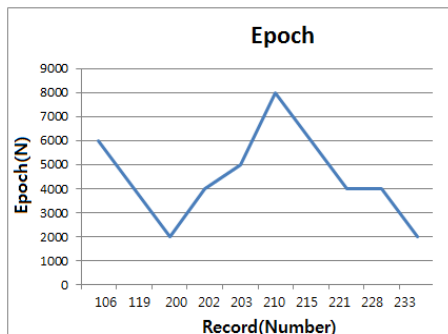


Fig. 6 Optimization epoch number by Record

해 높은 정확도를 나타내었다. 실험결과 대부분의 레코드는 10,000 epoch 이상의 경우 분류 정확도의 변화가 일어나지 않았다. 여기서 1 epoch란 전체 샘플 데이터를 이용하여 한 바퀴 돌며 학습하는 횟수를 말한다.

표 1은 각 은닉층에서의 활성화함수 Sigmoid, Tanh, ReLU에 따른 정확도를 비교한 것이다.

표에서와 같이 활성화함수는 ReLU를 이용하였을 경우 99.38%의 제일 높은 정확도를 나타내었으며, 이는 Sigmoid와 Tanh가 가지고 있는 기울기 손실(gradient vanishing) 문제를 해결함으로써 더 나은 성능을 나타낸 것으로 판단된다.

Table. 1 Activation function

	sigmoid	Tanh	Relu
Acc(%)	98.94	99.26	99.38

표 2는 딥러닝 모델의 가중치의 최적화 속도를 평가하기 위해서 확률적 경사 하강법(SGD : Stochastic Gradient Descent), Adam, RMSProp에 따른 분류 정확도를 비교한 결과를 나타낸 것이다. 최적화 함수로는 Adam 99.41%로 가장 높은 결과를 나타내는 것을 확인할 수 있다. 이는 학습의 갱신 강도를 적응적으로 조절할 수 있는 Adam 함수의 특징이 반영된 결과라고 판단된다.

Table. 2 Optimizer

Optimizer	Adam	RMSProp	Gradient Descent
Acc(%)	99.41	99.37	95.06

실험 결과를 통한 조기수축 부정맥 분류를 위한 최적 파라미터는 표 3과 같다. 테스트 과정에서 설명된 바와 같이 이 최적치는 반복적인 실험을 통해 선정된 결과 값이다.

표에서 보이는 바와 같이 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.

Table. 3 Optimal Parameter

List	Parameter
FC Layer	5
Epoch	10,000
Activation	ReLU
Optimizer	Adam

정확도는 최종적으로 계산된 값을 사용하였으며 설계한 딥러닝 신경망을 통해 부정맥을 분류한 결과는 표 4와 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.

본 연구에서 제안된 QRS, RR세그먼트와 최적 파라미터를 통한 딥러닝 신경망 모델은 훈련 데이터의 지역적 특성에만 적응하는 오버피팅 현상을 해결하여 심실 조기수축 비트 분류의 정확도를 향상시키는 것을 확인할 수 있었다.


결과적으로 제안된 딥러닝 기반의 조기수축 부정맥 분류 방법은 평균 97.84%의 우수한 분류율을 나타내는 것을 확인할 수 있었다.

Table. 4 PVC classification result


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
평균	97.84

그림 7은 MIT-BIH 레코드를 대상으로 한 R피크 검출과 제안한 딥러닝 모델을 이용한 분류 결과를 나타낸 것이다. 하지만 그림 7(b)와 같이 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.


이는 그림 7(c)의 3번째, 8번째 비트에 나타난 것과 같이 PVC임에도 불구하고 normal 이전과 이후가 서로 다른 종류의 PVC가 반복됨으로써 RR간격이 normal과 유사한 형태를 가지고 있기 때문에 정확한 검출이 이루어지지 않았다. 이런 현상을 해결하기 위해서는 합성곱



(a) R peak detection result(213 record)



(b) Classification result of accuracy by epochs



(c) Deep learning classification result(213 record : PVC bit error)

Fig. 7 R peak detection & Deep learning classification result

신경망(CNN : Convolutional Neural Networks)을 통한 분류방식의 적용이 필요할 것으로 판단된다. 합성곱 신경망의 경우 풀링 계층을 이용함으로써 하이퍼 파라미터 수를 줄일 수 있으며, 학습 시간도 개선할 수 있을 것으로 판단된다.

IV. 결론

본 연구에서는 전처리를 통해 최적의 R파를 검출하고 이를 활용하여 단기간의 입력데이터를 근거로 연산의 복잡도를 줄이고, 정확하게 부정맥을 분류하기 위해 딥러닝 기반의 최적 파라미터 검출 방법을 제안하였다.

이를 위해 전처리를 통해 잡음을 제거한 ECG신호에서 R파를 검출하고 QRS와 RR간격 세그먼트를 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 시스템의 경우 본 연구에

서 제안한 딥러닝 기반의 최적 파라미터를 통한 부정맥 자동 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 심장전문 의사와의 협력과 임상 데이터를 통한 데이터베이스 개발과 이를 통한 진단 알고리즘의 정착이 필요하다.

ACKNOWLEDGEMENT

This work was supported by a 2-Year Research Grant of Pusan National University.

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*, vol. 7198. Berlin, Germany: Springer-Verlag, 2012, pp. 336-345.
- [2] C.Ye, B.V.K. Kumar, 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, October. 2012.

- [3] M. J. Rooijackers, C. Rabotti, H.D.Lau, S.G. Oei, J.W.M.Bergmans, 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, Sept. 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, April. 2019.
- [6] P. Li, Y. Wang, J. He, L. Wang, Y. Tian, T. Zhou, T. Li, 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] S. S. Xu, M.-W. Mak, C.-C. Cheung, "Towards End-to-End ECG Classification With Raw Signal Extraction and Deep Neural Networks," *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 4, pp. 1574 - 1584, Sept. 2019.
- [8] I. S. Cho, 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, July 2017.
- [9] W. Li, J. Li, "Local Deep Field for Electrocardiogram Beat Classification," *IEEE Sensors Journal*, vol. 18, no. 4, pp. 1656 - 1664, Nov. 2019.
- [10] G. Wang, J. Hu, C. Li, B. Guo, F. Li, "Simultaneous Human Health Monitoring and Time-Frequency Sparse Representation Using EEG and ECG Signals," *IEEE Access*, vol. 7, pp. 85985 - 85994, June. 2019.
- [11] Q. Li, C. Rajagopalan, 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, July 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 창조융합학부 조교수
 ※관심분야 : ECG Preporcessing, 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