

심전도 신호의 전력선 잡음 제거를 위한 Deep De-noising Network 설계

권오윤[†], 이지은^{**}, 권준환^{***}, 임성준^{****}, 유선국^{*****}

Design of Deep De-noising Network for Power Line Artifact in Electrocardiogram

Oyun Kwon[†], JeeEun Lee^{**}, Jun Hwan Kwon^{***}, Seong Jun Lim^{****}, Sun Kook Yoo^{*****}

ABSTRACT

Power line noise in electrocardiogram signals makes it difficult to diagnose cardiovascular disease. ECG signals without power line noise are needed to increase the accuracy of diagnosis. In this paper, it is proposed DNN(Deep Neural Network) model to remove the power line noise in ECG. The proposed model is learned with noisy ECG, and clean ECG. Performance of the proposed model were performed in various environments(varying amplitude, frequency change, real-time amplitude change). The evaluation used signal-to-noise ratio and root mean square error (RMSE). The difference in evaluation metrics between the noisy ECG signals and the de-noising ECG signals can demonstrate effectiveness as the de-noising model. The proposed DNN model learning result was a decrease in RMSE 0.0224dB and a increase in signal-to-noise ratio 1.048dB. The results performed in various environments showed a decrease in RMSE 1.7672dB and a increase in signal-to-noise ratio 15.1879dB in amplitude changes, a decrease in RMSE 0.0823dB and a increase in signal-to-noise ratio 4.9287dB in frequency changes. Finally, in real-time amplitude changes, RMSE was decreased 0.3886dB and signal-to-noise ratio was increased 11.4536dB. Thus, it was shown that the proposed DNN model can de-noise power line noise in ECG.

Key words: Deep Neural Network, Electrocardiogram, De-noising, Power Line Artifact

1. 서 론

심전도 (Electrocardiogram, ECG) 신호를 측정하는 것은 인간의 건강 상태를 관찰하는 데 매우 중요한 요소이다. 특히 심전도 신호는 심장과 심혈관 질환을 진단하는 데 사용된다. 오늘날 심전도를 이용한

진단은 고령화 사회가 만연해지며 그 중요도가 점점 증가하고 있다. 통계적인 수치를 보면 전 세계적으로 매년 1,730만 명 이상이 심혈관 질환으로 목숨을 잃는다[1]. 심전도 신호를 측정할 때 주위 환경에 따라 다양한 잡음이 들어가는데, 이렇게 심전도 신호와 함께 측정된 잡음은 심혈관 질환 진단에 어려움을 주게

※ Corresponding Author: Sun Kook Yoo, Address: (03722) Yonsei-ro 50, Seodaemun-gu, Seoul, Korea, TEL : +82-2-2228-1919, FAX : +82-2-363-9923, E-mail : SUNKYOO@yuhs.ac

Receipt date : Dec. 26, 2019, Revision date : Feb. 3, 2020
Approval date : Feb. 13, 2020

[†] Graduate Program of Medical Device Industry, Yonsei University (E-mail : koy9303@yonsei.ac.kr)

^{**} Graduate Program of Biomedical Engineering, Yonsei University (E-mail : jeunlee@yuhs.ac)

^{***} Graduate Program of Biomedical Engineering, Yonsei University (E-mail : gr0442@nate.com)

^{****} Graduate Program of Medical Device Industry, Yonsei University (E-mail : issues13@yonsei.ac.kr)

^{*****} Dept. of Medical Engineering, Yonsei University College of Medicine

※ This research was supported by the Private Intelligence Information Service Expansion (No. A0602-19-1002) funded by the NIPA (National IT Industry Promotion Agency)

된다[2]. 심전도 신호에 있어 전력선 잡음은 여러 잡음 중 중요하게 다뤄지는 대표적인 전기적 잡음이다. 이러한 전력선 잡음이 발생하는 원인은 심전도 측정 기기와 연결된 외부 전원에서 생기는 전위가 60Hz 주파수의 신호를 만들면서 발생한다[3]. 대략 1mV 정도의 작은 크기를 갖는 전력선 잡음은 이보다 작은 값을 갖는 심전도 신호인 Q파와 P파에 영향을 준다. 이처럼 전력선 잡음이 Q파와 P파 신호를 가리거나 왜곡하게 되면 전체적인 심전도 신호의 정확성을 떨어뜨리는 경우가 발생한다. 앞선 두 신호를 이용한 QRS 콤플렉스 간격은 심혈관 질환 진단에 중요하게 사용되는 요소이다. 그렇기에 심전도 신호 측정 시 발생하는 전력선 잡음은 심혈관 질환에 관한 진단을 어렵게 한다[4]. 심전도 신호 내에 존재하는 전력선 잡음은 환자에게 정확한 진단을 제공하기 위해 필수적으로 제거해야 하는 요소이다.

기존에는 심전도 내 전력선 잡음 제거에 일반적으로 노치(notch) 필터나 밴드 패스 필터를 사용해왔다 [5]. 그 밖에 베이지안 필터[6]와 칼만 필터도 사용하였다[7]. 본 논문에서는 기존에 사용해오던 필터가 아닌 Deep Neural Network(DNN)를 사용하여 심전도 내 존재하는 전력선 잡음을 제거하는 데 효과를 보이고자 한다. 연구에 사용한 데이터는 객관성을 얻기 위해 PhysioNet/Cinc Challenge 2017에서 제공하는 무료 심전도 데이터를 사용하여 웨이블릿 변환 후 제안한 DNN 모델을 학습시켰다. 모델 성능에 대한 평가는 2장에서 제안한 방법으로 학습한 DNN 모델을 사용하여 다양한 진폭 또는 다양한 주파수로 들어오는 전력선 잡음 포함 심전도 신호와 진폭이 실시간으로 변조되며 들어오는 전력선 잡음 신호 포함 심전도 신호를 입력 데이터로 하여, 모델이 출력하는 데이터를 3장 결과 및 토의에서 확인하여 분석하고자 한다.

2. 실험 방법

2.1 데이터 셋

2.1.1 심전도 데이터

학습에 사용된 심전도 데이터는 PhysioNet/CinC Challenge 2017 데이터이다. 정상 신호(N), 심방세동 신호(AF), 잡음이 많이 섞인 신호(~), 그 외 신호(O)로 구성된다. 심전도 신호는 심혈관 질환 판단에 필

요한 데이터이기 때문에 제안하는 DNN 모델이 정상 신호(N)과 심방세동 신호(AF) 모두에 적용할 수 있음을 보이기 위해 잡음이 없는 두 신호(N, AF)를 사용하였다. 신호 길이는 9-60초로 구성된다[8]. 편차가 심한 데이터는 DNN 모델 학습 과정 중 작은 값은 무시하거나 큰 값에 집중하게 되는 불안정한 학습의 원인이 된다[9]. 데이터 길이는 측정시간 평균에 해당하는 30초로 정했다. 이 과정에서 30초가 되지 않는 신호는 제외하였으며, 60초 이상 신호는 30초 신호 2개로 나누었다. 데이터 크기는 평균을 0, 표준편차를 1로 조정하여 크게 벗어나는 값이 없도록 한다. 원신호는 재구성된 신호의 정답 데이터로 사용된다. 잡음이 포함된 신호는 원신호인 깨끗한 심전도 신호(N, AF)에 60Hz 값을 더하여 만든다. 잡음 신호는 식 (1)과 같이 주어지며 잡음이 포함된 신호는 식 (2)와 같이 주어진다. 깨끗한 신호를 $x(t)$ 로 표현하고, 잡음을 포함하는 신호는 $s(t)$ 로 표현한다. 식 (1)에서 진폭 계수 α 는 0.01-0.9 범위의 임의 값을 갖고 t 는 시간을 의미한다.

$$n(t) = \alpha \cos(2\pi \times 60t) \tag{1}$$

$$s(t) = x(t) + n(t) \tag{2}$$

2.1.2 데이터 웨이블릿 변환

웨이블릿 변환은 신호 데이터를 시간-주파수 영역으로 표현하는 신호 분석법이다. 심전도 신호를 주파수 성분들로 분해하면 각 스케일(scale)에 해당하는 성분들을 알 수 있다[10]. 웨이블릿 변환 수식은 식(3)과 같다[10].

$$\Psi_x^w(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-\tau}{s} \right) dt \tag{3}$$

시간(t)에 대한 신호 $x(t)$ 가 존재할 때, 웨이블릿 모함수 $\psi^* \left(\frac{t-\tau}{s} \right)$ 를 사용하여 주파수와 시간 축으로 신호를 표현해 준다. 웨이블릿 모함수는 크기를 변화시키는 스케일 계수(s)와 시간에 따른 파동 이동을 정해주는 전이 계수(τ)로 이루어진다. 심전도 데이터를 웨이블릿 변환하여 깨끗한 심전도 신호는 라벨로 사용하고 잡음 포함 심전도 신호는 입력값으로 사용하였다.

2.2 제안한 DNN 모델

2.2.1 DNN 모델 구조

Fig. 1을 보면 그림에서 제안하는 DNN 모델을 이용한 심전도 잡음 제거 방법을 볼 수 있다. 전처리가 끝난 데이터는 웨이블릿 변환 과정을 거쳐 DNN 모델에 입력 데이터로 들어간다. 입력 데이터는 60Hz 영역에 전력선 잡음을 포함하고 있으며 모든 웨이블릿 변환 신호를 하나로 연결하였다. 세로축은 웨이블릿 신호 내에서 0.2-100Hz에 해당하는 주파수 성분을 나타내며 90×1의 크기로 모델에 들어간다. 출력 데이터는 깨끗한 심전도 신호와 비슷하게 재구성된다. DNN 모델 구조는 Fig. 1과 같이 입력층과 출력층 그리고 완전히 연결된 계층(Fully Connected Layer) 4개로 구성되며 노드 수의(900-900-360-180) 차이만 있을 뿐 모두 같은 구조를 가진다. 입력에 따른 각 층의 출력값은 ReLU 함수를 적용하였고 출력값들이 학습에 불안정한 영향을 줄 정도로 벌어지지 않게 배치 정규화를 진행한다[11]. 마지막 출력층은 90개 노드에서 값을 출력한다.

2.2.2 DNN 모델 훈련 과정

가중치와 바이어스는 ADAM(Adaptive Moment Estimation) 옵티마이저(Optimizer)를 사용하여 최

적화한다. ADAM은 학습률을 조정하는 확률적 경사 하강법(Stochastic Gradient Descent) 알고리즘이다 [12]. 학습률은 0.00001에서 시작하며, 학습이 1회 진행될 때마다 0.9 비율로 감소한다. 훈련 데이터는 3 epochs 동안 10 mini-batch로 학습된다. 학습 과정 시작 시 웨이블릿 변환 심전도 신호 데이터는 무작위로 한 번 섞어준다. 심전도 신호 웨이블릿 변환 데이터는 입력값에 들어간다. 비용함수는 평균 제곱 오차(mean squared error)를 사용하였고, 비용함수를 최소화하는 방향으로 학습이 진행된다. 비용함수에 관한 수식은 식 (4)를 통해 볼 수 있으며, y_i 는 라벨로 깨끗한 웨이블릿 심전도 신호이고 출력값은 \hat{y}_i 에 해당한다. 과적합을 막기 위해 비용함수에 L2 일반화(Regularization) 항을 더한다. λ 는 일반화 계수, θ 는 가중치를 의미한다. L2 일반화 항이 추가되면서 특정 가중치 값들이 커지는 것을 방지한다.

$$Cost\ function = \frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2 + \lambda \sum_{i=1}^m \theta_i^2 \quad (4)$$

해당 모델은 Matlab 2019b 환경에서 구현하였으며, Window 10 64bit의 운영체제와 24GB 메모리의

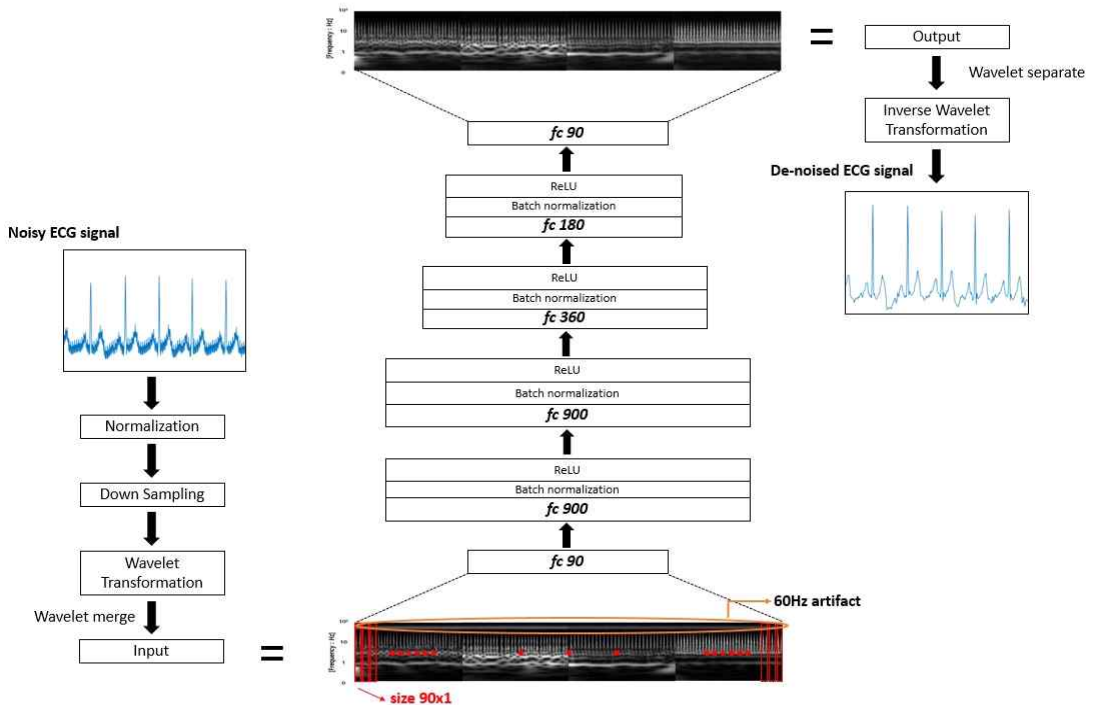


Fig. 1. Block diagram of the proposed DNN Model ECG denoising method.

RAM 그리고, NVIDIA GeForce GTX 1080의 그래픽카드 환경에서 훈련하였다.

2.3 DNN 모델 성능 평가

2.3.1 DNN 모델 성능 평가 지표

DNN 모델에서 출력한 값을 잡음 제거 신호로 볼 수 있는지 평가하는 데 사용한 평가 지표는 신호 대 잡음 비(Signal to Noise Signal Ratio, SNR)와 평균 제곱근 오차(Root mean square error, RMSE) 이다 [13,14].

2.3.1.1 신호 대 잡음 비, SNR

SNR은 잡음이 깨끗한 신호에 미치는 영향을 정량적으로 수치화한 값이다. 본 논문에서는 입력값과 출력값의 SNR을 비교하여 향상된 정도(SNR enhancement)를 보인다. 식 (5)에서 m 은 사용된 총 신호수를 의미하고, x_i 는 i 번째에 해당하는 깨끗한 신호, n_i 는 비교하고자 하는 신호이다. Input SNR과 Output SNR의 향상된 정도를 보는 SNR enhancement를 통해 제안된 모델이 잡음 제거에 효용성이 있음을 확인한다.

$$SNR = 10 \log_{10} \frac{\sum_{i=1}^m x_i^2}{\sum_{i=1}^m (n_i - x_i)^2} \quad (dB) \quad (5)$$

2.3.1.2 평균 제곱근 오차, RMSE

일반적으로 실제값과 예측값 차이를 다룰 때 RMSE를 많이 사용한다. Input RMSE와 Output RMSE의 향상된 정도는 RMSE enhancement로 나타내어 모델이 출력한 결과 데이터가 입력 데이터에 해당하는 잡음 포함 심전도 신호보다 깨끗한 신호와 근접함을 보인다. 식 (6)은 RMSE 식이며 총 신호수 m , i 번째에 해당하는 깨끗한 신호 x_i , 비교하고자 하는 신호 n_i 이다.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (n_i - x_i)^2} \quad (dB) \quad (6)$$

2.3.2 DNN 모델 성능 평가 방법

DNN 기반 모델 성능을 평가하기 위해 전력선 잡음을 포함하는 신호에 다양한 환경을 가정하여 변화된 잡음을 주었다. 1200개 심전도 신호에 대해 3가지 경우로 진행하였으며 진폭의 변화, 주파수의 변화,

실시간 진폭의 변화를 고려하였다.

2.3.2.1 진폭 변화의 경우

첫 번째 가정 상황은 심전도 측정 시 전력선 잡음의 진폭이 다양하게 삽입되는 환경이다. 전력선이나 심전도 세기에 따라 전력선 잡음이 다양한 진폭으로 발생할 수 있다. 특히 강한 진폭에서도 잡음이 제거되는지 확인하기 위해 전력선 잡음의 진폭 범위를 1-10으로 설정하였고 각 신호에 임의의 진폭이 적용되도록 하였다.

2.3.2.2 주파수 변화의 경우

학습에 사용한 전력선 잡음은 60Hz에 해당하는 신호였다. 하지만 실제 환경에선 주파수가 60Hz가 아닌 경우가 생길 수 있다. 따라서 주파수 범위는 59-60.9Hz로 설정하였고, 각 신호에 임의의 주파수 잡음이 들어가도록 하였다. 잡음 신호의 진폭은 0.5로 고정하였다.

2.3.2.3 실시간 진폭 변화의 경우

심전도를 측정하는 동안 전력선 잡음이 진폭 변조를 일으키는 경우이다. 일정하지 않은 진폭으로 잡음이 들어와도 제안한 DNN 모델이 일관되게 잡음을 제거할 수 있는지 확인한다. 전력선 잡음의 진폭이 시간에 따라 변화도록 설정하고 제안한 DNN 모델에 해당 잡음을 적용한 심전도 신호를 입력값으로 넣고 출력 결과를 본다.

3. 결과 및 토의

3.1 데이터 셋

깨끗한 심전도 신호와 잡음 포함 심전도 신호는 Fig. 2 (a)와 (b)에서 볼 수 있으며 이들을 웨이블릿 변환시킨 결과는 Fig. 3 (a),(b)에 있다. Fig. 2 (b)를 보면 심전도 신호에 전력선 잡음이 포함되어 있음을 볼 수 있다. 웨이블릿 변환 결과인 Fig. 3 (b)는 (a)와 다르게 빨간 네모 칸 안에 값이 있음을 보인다. 잡음 포함 신호를 웨이블릿 변환시키면 깨끗한 신호와 다르게 60Hz에 해당하는 값이 있음을 볼 수 있다.

3.2 제안하는 DNN 모델 학습 결과 확인

심전도 신호 내 전력선 잡음 제거 목적으로 학습된 DNN 모델 결과를 확인한다. 진폭 계수를 0.01-0.9

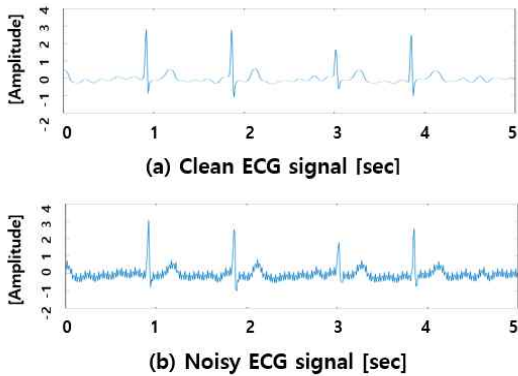


Fig. 2. (a) Clean ECG signal (b) Power line noise contaminated ECG signal.

로 무작위 설정한 60Hz 잡음이 있는 심전도 신호 1200개가 DNN 모델을 거쳐 잡음이 제거됨을 확인했다. SNR과 RMSE를 통한 결과는 SNR enhancement는 1.048dB 향상되었고 RMSE enhancement는 0.0224dB 향상된 것으로 보아 DNN 모델이 잡음 제

거에 효과가 있다는 학습 결과를 볼 수 있었다.

시각적인 결과 확인을 위해 신호를 임의로 선정하여 결과를 확인하였다. Fig. 4 (b)를 보면 잡음을 포함하는 신호는 60Hz에 해당하는 부분에 선명하게 값이 존재하고 있음을 볼 수 있다. 하지만 Fig. 4 (c) DNN 모델 출력값에서는 선명하게 보이던 전력선 잡음이 제거되고 깨끗한 심전도 신호 (a)와 유사하다. 해당 결과를 웨이블릿 역변환하면 Fig. 5과 같이 파형으로도 (c) 잡음 제거 심전도 신호가 (a) 깨끗한 심전도 신호와 유사함을 볼 수 있다.

3.3 DNN 모델 성능 평가

3.3.1 진폭 변화

제안한 DNN 모델을 통해 잡음이 제거된 결과를 확인하였다. 심전도 신호에 진폭 계수 1-10에 해당하는 전력선 잡음을 넣고 DNN 모델이 잡음 제거 효용성이 있는지 실험하였다. 진폭이 큰 경우에도 잡음이

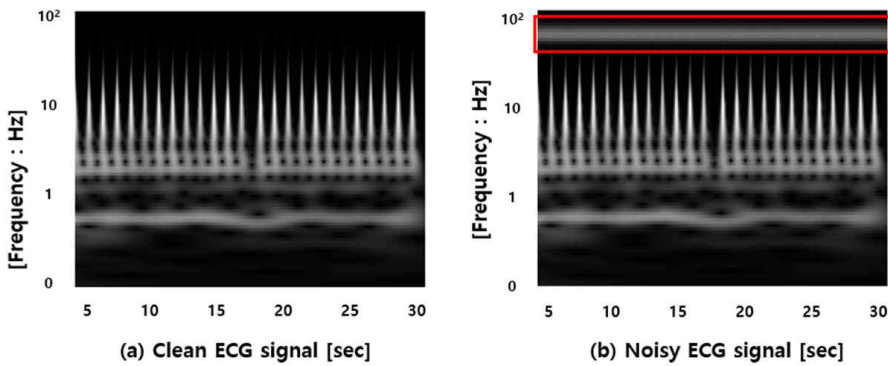


Fig. 3. (a) Result of clean ECG signal wavelet transform, (b) Result of power line noise contaminated ECG signal wavelet transform.




Fig. 4. The analysis of Proposed DNN model learning result a) Result of clean ECG signal wavelet transform, b) Result of power line noise contaminated ECG signal wavelet transform, c) ECG signal with power line noise removed by model.

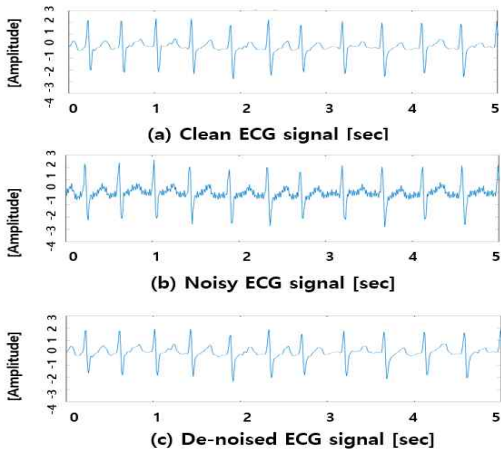


Fig. 5. The analysis of inverse wavelet transform result (a) Clean ECG signal, (b) Noisy ECG signal, (c) Result of Inverse wavelet transform ECG signal de-noised power line noise.

제거됨을 보기 위해 그에 해당하는 경우인 Fig. 6을 보인다. 전력선 잡음 영역이 큰 값을 갖게 되어 Fig. 4 (b)에서 본 것보다 선명해짐을 볼 수 있다. Fig. 6 (b)을 통해 들어간 잡음 진폭이 학습에 사용된 것보다 크다는 것을 확인하고(c), DNN 모델 출력 결과에서 잡음이 제거된 것을 볼 수 있다. 해당 결과를 웨이블릿 역변환하면 Fig. 7에서 보이듯 (c) 잡음 제거 심전도 신호와 (a) 깨끗한 심전도 신호가 유사함을




Fig. 6. The analysis of de-noising result with amplitude coefficient 1 (a) Clean ECG signal (b) Noisy ECG signal (c) Output of DNN model.

Table 1. Result of SNR and RMSE in amplitude coefficient change

	Input SNR(dB)	Input RMSE(dB)	SNR enhancement	RMSE enhancement
1	2.2612	0.3814	10.6335	0.2693
5	-13.3018	2.2882	15.8811	1.9206
10	-17.7388	3.8137	17.4186	3.3003

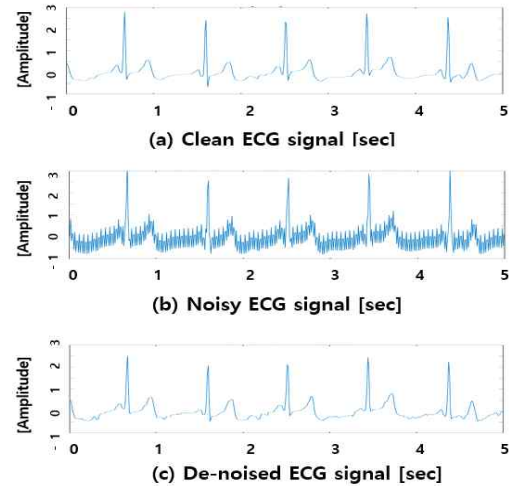


Fig. 7. The analysis of de-noising result with amplitude coefficient 1 in inverse wavelet transform (a) Clean ECG signal (b) Noisy ECG signal (c) De-noised ECG signal.

볼 수 있다.

진폭 변화에 따른 전력선 잡음 포함 신호와 잡음 제거 신호에 대한 SNR, RMSE 값을 확인하여 DNN 모델을 거친 데이터 잡음 제거 정도에 관해 확인하였다. 평균 SNR enhancement는 15.1879dB 향상되었고, 평균 RMSE enhancement는 1.7672dB 향상되었다. Table 1은 진폭 계수 1,5,10 잡음을 포함한 심전도




Fig. 8. The analysis of de-noising result with 59 Hz frequency (a) Clean ECG signal (b) Noisy ECG signal (c) Output of DNN model.

신호와 그 출력값에 관한 결과 분석이다. 진폭이 증가할수록 SNR enhancement와 RMSE enhancement가 더욱 향상됨을 볼 수 있다.

3.3.2 주파수 변화

59-60.9Hz 범위의 전력선 잡음이 들어간 경우에도 DNN 모델은 잡음에 해당하는 영역만 제거함을 보였다. Fig. 8은 59Hz로 들어간 전력선 잡음을 모델에 넣은 결과이다. (a)에서 안보이던 잡음이 (b)에서 선명하게 보이지만, 모델 출력결과인 (c)에선 제거되었음을 알 수 있다. Fig. 9에서도 (b)에 포함된 전력선 잡음이 (c)에선 잡음이 없는 신호인 (a)와 동일하게 나옴을 보인다.

Table 2는 주파수 59Hz, 60Hz, 60.9Hz 전력선 잡음을 포함한 심전도 신호 대해 전력선 잡음을 넣은 신호와 DNN 모델로 나온 출력값에 대한 SNR과 RMSE이다. 59-60.9Hz에 해당하는 잡음이 들어간 심전도 신호라도 모델을 통해 잡음이 제거됨을 볼 수 있었다. SNR enhancement와 RMSE enhancement를 통해 주파수 변화에 따른 잡음 제거 효율성을 확인하였다. 전체적인 SNR enhancement는 평균 4.9287dB 향상되었고, RMSE enhancement는 0.0823 dB 향상되었다.

3.3.3 실시간 진폭 변화

Fig. 10은 실시간으로 진폭의 변화가 있는 심전도

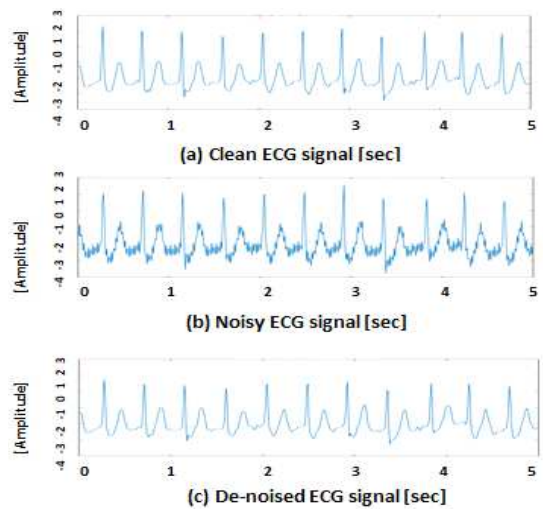


Fig. 9. The analysis of de-noising result with 59 Hz frequency in inverse wavelet transform (a) Clean ECG signal (b) Noisy ECG signal (c) De-noised ECG signal.

를 모델에 넣은 결과를 가져온 것이다. (b)처럼 전력선 잡음 진폭이 일정하게 들어가지 않아도 (c)에서 볼 수 있듯이 전력선 잡음에 해당하는 영역이 제거되었음을 볼 수 있다. 진폭이 변함에 따라 (b)에서 보이는 값도 커졌다, 작아졌다 하는 것을 볼 수 있다. 파형으로 표현한 Fig. 11에서도 전력선 잡음 진폭이 변조된 (b)과 DNN 모델 출력값이 잡음을 제거하고 (c), 깨끗한 신호 (a)와 비슷하다는 것을 보인다.

Table 2. Result of SNR and RMSE in frequency change

	Input SNR(dB)	Input RMSE(dB)	SNR enhancement	RMSE enhancement
59Hz	8.0712	0.1954	5.1340	0.0872
60Hz	8.2818	0.1907	4.9192	0.0825
60.9Hz	8.4770	0.1864	4.7134	0.0780




Fig. 10. The analysis of de-noising result with amplitude modulation noisy ECG signal (b) Clean ECG signal (c) De-noised ECG signal.

Table 3. The analysis of real-time amplitude change noise de-noising result for 3 case ECG signal, SNR, RMSE

	Input SNR(dB)	Input RMSE(dB)	SNR enhancement	RMSE enhancement
ECG 1	-0.7490	0.5393	13.8392	0.4297
ECG 2	-2.3383	0.5293	16.6941	0.4603
ECG 3	4.2446	0.5393	10.0518	0.3698

해당 신호에 대한 SNR과 RMSE 결과는 Table 3과 같으며 실시간 진폭 변화를 준 전력선 잡음 포함 심전도 신호인 입력값과 잡음 제거 신호인 출력값에 대한 SNR, RMSE 값을 확인해보면 모든 신호의 평균 SNR enhancement 은 11.4536dB 이고, 평균 RMSE enhancement는 0.3886dB 이다. SNR enhancement

와 RMSE enhancement의 향상 정도를 보임으로써 실시간 진폭 변화를 준 경우에도 제안된 모델의 잡음 제거 효과를 입증할 수 있었다.

4. 결 론

심전도 신호는 헬스케어와 관련된 다양한 연구에서 사용되는 중요 데이터이다[15]. 본 논문은 심전도 신호를 측정할 때 발생하는 전력선 잡음(60Hz)을 제안된 DNN 모델로 제거하는 것을 목표로 하고 있다. 제안된 모델에 입력값으로 잡음 포함 심전도 신호를 넣고 깨끗한 심전도 신호와 유사한 출력값을 확인함으로써 제안한 DNN 모델이 잡음 제거에 유효함을 보였다. 깨끗한 심전도 신호, 잡음 포함 심전도 신호, 모델의 출력값을 웨이블릿 변환을 통해 확인하여 전력선 잡음에 해당하는 주파수 값이 사라짐을 볼 수 있었다. 시각적인 결과뿐 아니라 제안된 DNN 모델을 평가한 모든 경우에서 SNR 과 RMSE 의 enhancement를 분석하여 수치적으로도 모델이 잡음을 제거함을 보였다.

제안된 DNN 모델 학습 결과를 보면 SNR enhancement는 1.048dB, RMSE enhancement는 0.0224 dB 향상된다. 제안한 모델이 학습에 사용한 데이터가 아닌 다른 전력선 잡음 데이터에도 적용할 수 있음을 보이기 위해 다양한 환경에서 성능평가가 이루어

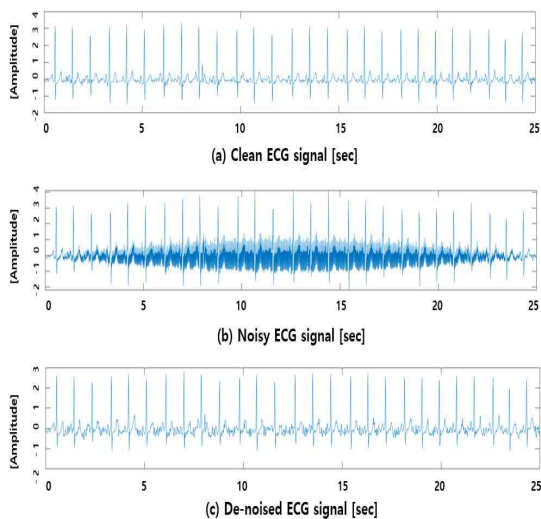


Fig. 11. The analysis of real-time amplitude change noise de-noising result by inverse wavelet transform (a) Clean ECG signal, (b) Noisy ECG signal in real-time amplitude changes, (c) De-noised ECG signal.

어졌다. 학습된 DNN 모델은 3가지 경우, 진폭 변화, 주파수 변화, 실시간 진폭 변화 환경에서 평가되었다. 진폭을 확장한 환경에서는 진폭 계수가 증가할수록 SNR 과 RMSE 의 enhancement가 향상되는 것을 보였다. 그 밖의 주파수 변화와 실시간 진폭 변화 환경을 포함한 모든 경우에서 SNR 과 RMSE 의 enhancement는 향상됨을 알 수 있었다. 이러한 결과로 제안한 DNN 모델이 심전도 신호 내 존재하는 전력선 잡음 제거에 유효함을 보였다.

기존 전력선 잡음 제거는 신경망 기법을 사용하지 않는 노치 필터를 이용한 방법이 주로 사용되었다. 기존 노치 필터는 매우 좁은 주파수 영역만 제거할 수 있다는 한계와 60Hz가 아닌 다른 영역의 주파수를 제거하기 위해선 필터 설정을 다시 바꿔줘야 한다는 불편함이 있었다[16]. 본 논문에서 제안한 DNN 모델은 기본적으로 전력선 잡음 제거 효과가 있음을 보이고, 60Hz 뿐 아니라 실제 측정 환경에서 발생할 수 있는 보다 넓은 주파수 영역에서의 잡음(59-60.9 Hz)도 제거할 수 있음을 보였다. 또한 잡음 제거 방식이 학습에 기반을 두고 있기 때문에 내부 설정을 바꿔줄 필요가 없다. 단순히 학습 데이터만 새로 넣어주면 DNN 모델은 그에 맞게 잡음 제거 기능을 수행할 수 있다. 이를 통해 기존 노치 필터가 가지고 있던 회로의 복잡성 문제를 해결할 수 있다. 기존 노치 필터의 회로 구성에 있어 R,L,C 값을 설정하는 것은 매우 중요했다. R,L,C 값의 정교한 조절을 통해 60Hz 전력선 잡음을 제거하는 노치 필터를 만들 수 있는데, 이 값이 조금만 달라져도 목표한 필터의 기능을 수행하지 못한다. 하지만 본 논문에서 제안한 DNN 모델은 그러한 복잡한 회로 조절 없이 학습을 통해 전력선 잡음에 해당하는 주파수를 제거할 수 있으며 다른 주파수 영역을 제거 하고자 할 때에도 그에 맞는 회로를 조정하는 것이 아닌 학습을 통해 원하는 잡음 제거 필터를 구성할 수 있다. 이는 제안한 DNN 모델이 기존 노치 필터보다 우수한 점이다. 향후 연구에서는 기존 필터가 가진 한계를 해결한 것에 그치지 않고, 성능 측면에서도 뛰어날 수 있음을 연구하고자 한다.

REFERENCE

- [1] E.J. Benjamin, M.J. Blaha, S.E. Chiuve, M. Cushman, S.R. Das, R. Deo, et al., "Heart Disease and Stroke Statistics-2017 Update: A Report from the American Heart Association," *Journal of Circulation*, Vol. 135, No. 10, pp. e146-e603, 2017.
- [2] S.K. Yoo, N.H. Kim, J.S. Song, T.H. Lee, and K.M. Kim, "Simple Self-tuned Notch Filter in a Bio-potential Amplifier," *Journal of Medical and Biological Engineering and Computing*, Vol. 35, No. 2, pp. 151-154, 1997.
- [3] J.C. Huhta and J.G. Webster, "60Hz Interference in Electrocardiography," *IEEE Transactions on Biomedical Engineering*, Vol. 20, NO. 2, pp. 91-95, 1973.
- [4] D.W. Motarra, "Digital Filters for ECG Signals," *Proceeding of Computer in Cardiology*, pp. 511-514, 1977.
- [5] H. Limaye and V.V. Deshmukh, "ECG Noise Sources and Various Noise Removal Techniques: A Survey," *International Journal of Application or Innovation in Engineering and Management*, Vol. 5, No. 2, pp. 86-92, 2016.
- [6] Maniruzzaman, K.S. Billah, U. Biswas, and B. Gain, "Least-mean-square Algorithm Based Adaptive Filters for Removing Power Line Interference from ECG Signal," *Proceeding of International Conference on Informatics, Electronics and Vision*, pp. 737-740, 2012.
- [7] G. Cornelia and R. Romulus, "ECG Signals Processing Using Wavelets," *IEEE Proceedings of the Fifth Lasted International Conference*, 2005.
- [8] G.D. Clifford, C. Liu, B. Moody, L.H. Lehman, I. Silva, Q. Li, et al., "AF Classification from a Short Single Lead ECG Recording: The PhysioNet/Computing in Cardiology Challenge 2017," *Computing in Cardiology*, pp. 1-4, 2017.
- [9] J. Sola and J. Sevilla, "Importance of Input Data Normalization for the Application of Neural Networks to Complex Industrial Problem," *Journal of IEEE Transactions on Nuclear Science*, Vol. 44, No. 3, pp. 1464-1468, 1997.

[10] B. Cazelles, M. Chavez, G.C.D. Magny, J. Guegan, and S. Hales, "Time-dependent Spectral Analysis of Epidemiological Time-series with Wavelets," *Journal of the Royal Society Interface*, Vol. 4, No. 15, pp. 625-636, 2007.

[11] S. Ioffe and C. Szegedy, "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift," *arXiv Preprint arXiv:1502.03167*, 2015.

[12] A. Elola, E. Aramendi, U. Irusta, A. Picon, E. Alonso, P. Owenset, et al., "Deep Neural Networks for ECG-based Pulse Detection during Out-of-hospital Cardiac Arrest," *Journal of Entropy*, Vol. 21, No. 3, pp. 305, 2019.

[13] K. Antczak, "Deep Recurrent Neural Networks for ECG Signal Denoising," *arXiv Preprint arXiv:1087.11551*, 2019.

[14] A. Chacko and S. Ari, "Denosing of ECG Signals Using Empirical Mode Decomposition Based Technique," *Proceedings of IEEE-International Conference on Advances in Engineering, Science and Management*, pp. 6-9, 2012.

[15] J. Lee and S. Yoo, "Correlation Analysis of Electrocardiogram Signal according to Sleep Stage," *Journal of Korea Multimedia Society*, Vol. 21, No. 12, pp. 1370-1378, 2018.

[16] R. Kher, "Signal Processing Techniques for Removing Noise from ECG Signals," *Journal of Biomedical Engineering and Research*, Vol. 3, No. 1, pp. 1-9, 2019.



권오윤

2019년 2월 경희대학교, 물리학 학사
 2019년 3월~현재 연세대학교, 의료기기산업학과 석사과정
 관심분야 : u-Health, 생체신호처리, 딥 러닝, 의료정보시스템



이지은

2012년 2월 건국대학교, 의용전자공학 학사
 2014년 8월 연세대학교, 생체공학협동과정 전기전자공학전공 석사
 2017년 9월~현재 연세대학교, 생체공학협동과정 전기전자공학전공 박사과정

관심분야 : u-Health, 스마트 디바이스, 생체신호처리, 패턴 인식 및 기계학습



권준환

2016년 2월 건국대학교, 의용전자공학 학사
 2018년 8월 연세대학교, 생체공학협동과정 전기전자공학전공 석사
 2019년 2월~현재 연세대학교, 생체공학협동과정 전기전자공학전공 박사과정

관심분야 : 의료영상, 영상 처리, 기계 학습, 딥 러닝



임성준

2014년 2월 단국대학교, 전기전자공학 학사
 2018년 9월~현재 연세대학교, 의료기기산업학과 석사과정
 관심분야 : u-Health, 의료영상, 스마트 디바이스, 생체신호처리, 딥 러닝



유선국

1981년 2월 연세대학교 전기공학과 학사
 1985년 8월 연세대학교 전기공학과 석사
 1989년 8월 연세대학교 전기공학과 박사

1995년 3월~현재 연세대학교 의과대학 의학공학교실 교수

관심분야 : u-Health, 의료영상, 스마트 디바이스, 생체신호처리 및 패턴 인식, 감성공학