

모바일 환경에 적합한 수면 신호 디노이징 네트워크

*유채화, 강제원
이화여자대학교 전자전기공학과
e-mail : *chyoo@ewhain.net, jwongk@ewha.ac.kr*

Sleep Signal De-noising Network on Mobile Environments

*Chaehwa Yoo, Je-Won Kang
Department of Electronic and Electrical Engineering
Ewha W. University

Abstract

With low birthrates and extended life expectancy worldwide, the healthcare industry is speeding up the development of biometric devices that monitor various biological signals using wearable devices or sensors. However, the biological signals are likely to be perturbed by noise due to the physical limitations of the device. This can result in severe degradation on the devices' performance and even become threat to the user's safety. Therefore, pre-processing steps of denoising on the acquired signals from biometric devices are essential.

In this paper, we assume a situation where noise is added to the input signals for the sleep staging network, which is used to develop mobile devices for monitoring and staging sleep states of the user. We propose a deep learning based denoising network with noisy signals as input and use it as pre-processing stage before the sleep staging network. Experiment shows that the proposed denoising network improves decreased staging accuracy when noisy signals are used to original sleep staging network.

I. 서론

세계적으로 저출산과 기대수명 연장으로 인한 고령화가 가속되면서 개인의 의료비 부담이 심각한 사회문제로 대두되고 있다. 이와 함께 개인당 한 대 이상의 모바일 디바이스를 소유하는 시대가 도래하면서 헬스케어 산업에서는 웨어러블 기기나 신체에 장착된 센서를 이용해 사용자의 맥박, 혈압, 심전도, 뇌파, 체온, 혈당 등 다양한 생체 신호를 측정, 획득하고 나아가 특정 질환에 대해 치료까지 하는 생체 신호 디바이스의 개발에 박차를 가하고 있다 [1].

하지만 사용자의 신체 내부에 직접적으로 측정 장치를 부착할 수 없는 물리적 제약이 있고 체내 깊은 곳의 신호가 전파되면서 감쇄, 변형되기 때문에 디바이스가 취득한 생체 신호에는 많은 잡음이 첨가되어 신호가 훼손될 가능성이 높다. 이는 디바이스의 성능 저하로 이어질 수 있으며 심지어는 사용자의 안전에 큰 위협이 될 수 있다. 따라서 생체 신호 디바이스의 신호 처리 과정에서 취득한 신호의 잡음을 제거하는 전처리 단계가 필수적이다.

본 논문에서는 사용자의 수면 상태를 모니터링하고 판별하는 모바일 디바이스를 개발하는 데 사용하는 수면 단계 판별 네트워크의 입력 신호에 잡음이 섞이는 상황을 가정한다. 잡음이 섞인 신호를 입력으로 하는 딥 러닝 기반 디노이징 네트워크를 제안하고 이를 수

면 단계 판별 이전에 전처리 단계로 추가하여 수면 판별을 진행한다. 실험을 통하여 제안하는 디노이징 네트워크를 추가로 사용하였을 때 잡음이 섞인 신호 그대로를 사용하였을 때보다 개선된 판별 정확도를 얻을 수 있음을 확인하였다.

II. 관련 연구

2.1 수면 단계 판별 네트워크

사람의 수면 단계는 W, N1, N2, N3, REM의 5단계로 나뉘는데 이는 사람의 정신질환 또는 신경퇴행성 질환과 밀접하게 관련되기 때문에 그동안 전문지식을 가진 수면 전문가들에 의해 수작업으로 분류되었다. 이러한 경제적 및 시간적 비용을 줄이기 위해 자동으로 수면 단계를 분류하는 알고리즘들이 제안되었는데 [2, 3] 최근에는 CNN 및 RNN을 사용하는 심층 신경망 기반의 알고리즘들이 제안되어 85% 이상의 판별 정확도를 보이고 있다 [4, 5].

2.2 신호 디노이징 (Denosing) 네트워크

신호의 디노이징 목적은 신호의 압축 및 전송 과정에서 잡음이 더해진 신호로부터 깨끗한 신호를 복구하는 것이다. 일반적으로 표준편차 σ 를 가지는 백색 가우시안 잡음 (AWGN)이 더해진다고 가정한다. 오랜 기간 신호 디노이징을 위해 다양한 모델들 [6, 7]들이 이용되어 왔다. 신경망 기반 알고리즘들은 잔차 학습을 사용하여 잡음을 학습한 뒤 입력 신호에서 학습된 잡음을 제거하여 신호를 디노이징 하거나 [8] 생성 모델을 사용하여 원본 신호를 다시 만들어 내는 방법 [9] 등을 사용한다.

III. 제안 방법




그림 1 제안하는 생체 신호 모바일 디바이스의 신호 처리 과정

그림 1에 제안하는 생체 신호 모바일 디바이스의 신호 처리 과정을 나타내었다. 검은색으로 표현한 단계는 기존 모바일 디바이스의 신호 처리 과정이며 주황색으로 표현된 디노이징 단계가 추가되어 신호 처리의 정확도를 향상할 수 있다. 먼저 디바이스의 목적에 따라 맥박, 혈압, 심전도, 뇌파 등의 생체 신호를 모니터

링 시스템 또는 바이오센서 등을 이용하여 획득하고 측정한다. 이때 측정하는 신호들은 주로 체내 깊은 영역의 신호이기 때문에 물리적인 잡음이 더해진다.

이후 제안하는 디노이징 단계는 (1) 데이터 처리의 앞 단계에 위치하여 취득한 전체 신호를 먼저 디노이징한 뒤 데이터 처리를 하거나 (2) 데이터 처리 중 디노이징이 필요한 신호 영역이 있을 때 선별적으로 디노이징을 할 수 있다. 디노이징 단계의 위치는 디바이스가 실시간의 신호 정보를 필요로 하는 지 또는 긴 주기의 전체 신호 정보를 필요로 하는 지에 따라 달라질 수 있다. 혹은 디바이스의 목적에 따라 두 곳 모두에 디노이징 단계가 위치할 수 있다.

데이터 처리 단계에서는 기존의 잡음이 섞인 신호 대신 잡음이 제거된 생체 신호를 수집 및 관리하고 디바이스의 목적에 따라 사용자의 건강 상태, 질병의 발병 또는 악화 여부를 진단하고 진단에 맞는 피드백을 디스플레이 단으로 전송한다. 이후 이 피드백은 치료 신호나 경고 등으로 디바이스 자체에서 적용되거나 정보통신기술을 활용하여 의료 기관 등으로 전송된다. 제안 방법대로 디노이징 네트워크를 추가하면 잡음이 제거된 생체 신호로 데이터 처리를 하게 되어 생체 신호 디바이스의 처리 성능과 안전도가 함께 향상될 수 있다.

IV. 실험

4.1 실험 환경

가. 데이터

실험의 데이터로 sleep-EDF 데이터 [10]를 이용하였다. sleep-EDF는 한 사람당 평균 17시간의 뇌파 데이터, 총 20명의 건강한 사람들의 PSG (polysomnography) 데이터이다. 실험에는 Fpz-Cz EEG 채널의 신호를 사용하였다. 수면 전문가에 분류된 수면 단계 라벨에서 N3와 N4 stage를 하나의 단계인 N3로 단일화하고 수면 단계 전후의 W 단계를 30분으로 제한하고 MOVEMENT, UNKNOWN 단계를 제외하는 등의 입력 신호 전처리 과정을 수행하였다. 네트워크의 학습에는 피험자 1~19번의 뇌파를 사용하였고 피험자 0번의 뇌파로 모델을 평가했다.

나. 사용 네트워크

수면 판별에 사용한 DeepSleepNet [4]은 크게 두 개의 부분으로 나뉜다. 첫 번째 부분은 두 개의 CNN으로 구성되며 필터 크기가 작은 CNN은 언제 EEG 패턴이 나타나는지와 같은 일시적인 정보를 포착하고 큰 필터 크기를 가지는 CNN은 주파수 성분 등 주파수 정보에 대해 알아낸다. 두 번째 부분은 sequence 잔차

학습을 위한 부분으로 앞의 부분에서 추출된 feature 안에 있는 EEG epoch 순서로부터 수면 단계의 전환 규칙 같은 시간적 정보를 인코딩하도록 학습한다. 두 개의 bidirectional LSTM 계층으로 구성되며 short connection을 통해 앞부분의 2개의 CNN으로부터 학습된 feature에 시간적 정보를 더한다.




그림 2 디노이징 네트워크 구조도

수면 신호를 디노이징하기 위해서 영상 디노이징을 위해 제안된 DnCNN [8] 모델의 입력에 영상 대신 수면 신호를 사용하였다. 그림 2와 같이 깨끗한 신호 x 에 잡음 n 을 더한 $y = x + n$ 을 입력으로 하는 이 네트워크는 학습을 적용하여 출력 $R(y)$ 와 n 간의 손실을 줄이도록 파라미터를 학습하고 이때 실제로 원하는 잡음이 제거된 신호는 $x^* = y - R(y)$ 이다. DnCNN 모델은 그림 2과 같이 3종류의 계층을 사용한다. 생체 신호를 입력으로 받는 첫 번째 계층에서는 64개의 feature map을 만들기 위해 $3 \times 1 \times 1$ 크기의 필터가 64개가 사용되고 ReLU 비선형 연산을 수행한다. 2~17번째의 계층에는 크기가 $3 \times 1 \times 64$ 인 필터 64개가 사용되었고 convolution과 ReLU 사이에 batch normalization을 추가했다. 마지막 계층에는 잡음이 제거된 출력 신호를 만들기 위해 크기 $3 \times 1 \times 1$ 필터 1개가 사용된다. 모델의 입력으로 원본 신호에 더해준 잡음은 백색 가우시안 잡음으로 모델링 해 잡음의 크기를 다르게 하여 실험을 진행했다. 실험에서는 AWGN의 표준 편차 σ 의 값을 1, 2, 4, 8로 키워가며 디노이징 네트워크를 각각 학습시켰다.

4.2 실험 결과

표 1은 잡음 신호의 크기를 다르게 했을 때 잡음이 섞인 신호와 원본 신호 간의 SNR (Signal to Noise Ratio)과 디노이징 후 향상된 SNR을 보여준다. 1행은 원본 신호와 잡음이 섞인 신호 간의 SNR, 2행은 원본 신호와 디노이징 된 신호 간의 SNR, 3행은 디노이징 후 향상된 SNR을 표시하였다. 잡음의 크기가 커질수록 필연적으로 잡음이 섞인 신호의 SNR이 낮아지고 디노이징 후 복원된 신호의 SNR 증가 폭이 컸다. 그림 4에 잡음의 크기에 따른 테스트 신호의 5초간의 뇌파 신호를 기록했다. 각 그래프의 1행은 깨끗한 신호, 2행은 크기가 다른 잡음을 더한 신호, 3행은 디노이징 네트워크로 얻은 잡음이 제거된 신호이다. 결과 SNR 값과 더불어 시각적으로도 디노이징 후의 신호가 잡음

섞인 신호보다 원본 신호와 비슷한 파형을 가지는 것을 알 수 있다.

	σ			
	1	2	4	8
Noisy signal (dB)	45.36	39.34	33.32	27.30
De-noised signal (dB)	45.94	40.68	36.25	30.80
Increased SNR (dB)	+0.58	+1.34	+2.93	+3.50

표 1 디노이징 전후 SNR 비교

제안하는 수면 신호 디노이징 네트워크를 수면 단계 판별 알고리즘의 입력 신호 전처리 단계로서 사용했을 때 수면 단계 판별 성능에 미치는 영향을 확인하기 위해 AWGN을 더한 신호와 디노이징 된 신호를 각각 수면 단계 판별 네트워크의 입력으로 삼아 분류 성능을 측정하여 표 2에 기록하였다. 이때 비교 지표로 판별 정확도를 사용하였다. 표 2에서 깨끗한 신호에 대한 overall accuracy는 81.4%였다. σ 가 작은 잡음이 더해진 경우 ($\sigma = 1, \sigma = 2$)에는 수면 신호 판별 성능에 큰 영향을 미치지 않았고 심지어 σ 의 크기가 1인 경우에는 판별 성능이 0.2% 증가하였다. 반면, 잡음의 σ 가 4와 8로 비교적 큰 크기의 잡음이 더해진 신호에 대해서 각각 약 16.7%, 53%의 분류 성능의 저하가 나타났다. 이 신호들을 디노이징 네트워크를 이용하여 복원한 신호로 분류할 경우 각각 13%, 9.8%의 성능 향상이 있었다. 그러나 잡음의 σ 가 8인 경우 분류 성능이 28.4%로 신호가 원본 신호로 회복하기 힘들 정도로 큰 잡음이 더해졌다고 보는 것이 타당하다. 그런데도 잡음의 σ 가 4인 잡음이 더해졌을 때는 원본 신호의 성능에 약 3.7% 낮은 분류 성능까지 향상한 만큼 제안하는 방법이 성공적으로 신호의 잡음을 제거했다고 할 수 있다.

	σ			
	1	2	4	8
Noisy signal (%)	81.6	81.1	64.7	28.4
De-noised signal (%)	81.6	80.6	77.7	38.2
Increased ACC (%)	+0	-0.5	+13	+9.8

표 2. 디노이징 전후 판별 정확도 비교

V. 결론

생체 신호 모바일 디바이스를 통해 취득된 신호는

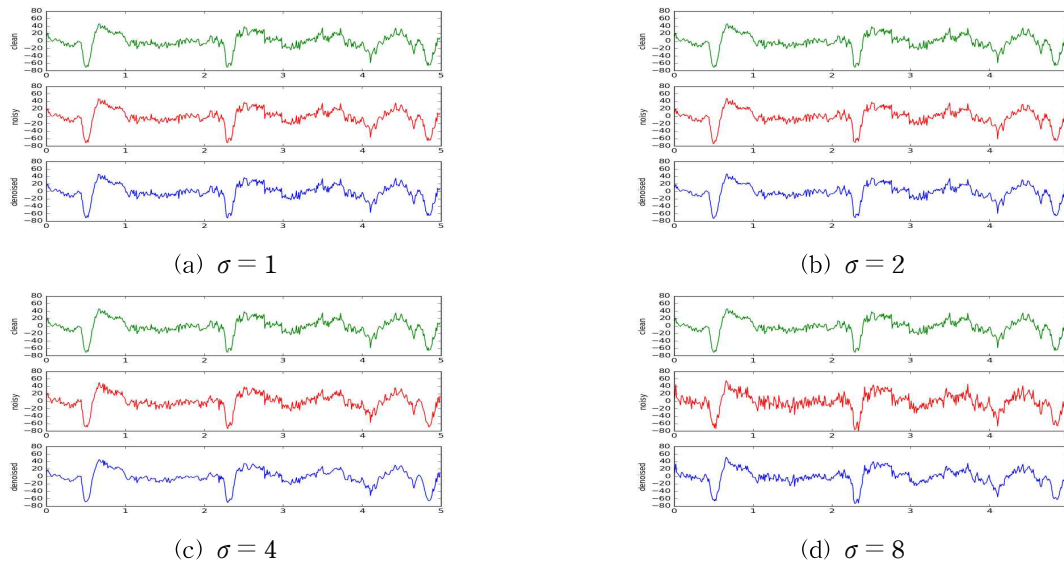


그림 3 잡음 크기에 따른 테스트 신호의 디노이징 결과

디바이스의 물리적 제약 때문에 많은 잡음이 더해지고 이는 디바이스의 성능 저하에 직접적인 영향을 준다. 따라서 신호 처리 알고리즘 이전에 신호를 디노이징하는 전처리 과정이 필요하다. 본 논문에서는 수면 단계 판별 네트워크에 잡음이 더해진 신호가 입력될 경우에 디노이징 네트워크를 사용하여 입력 신호의 잡음을 제거한 뒤 수면 판별 네트워크의 성능을 개선함을 확인하였다. 따라서 제안하는 디노이징 네트워크를 이용하면 잡음이 제거된 신호로 데이터 처리를 하여 생체 신호 디바이스의 성능과 안전도가 함께 개선될 것으로 기대된다.

참고문헌

- [1] 서지영, & 박형준. (2010). 고령자를 위한 의료기기 연구개발 전략. 정책자료, 1-120.
- [2] O. Tsinalis, P. M. Matthews, and Y. Guo, "Automatic sleep stage scoring using time-frequency analysis and stacked sparse autoencoders," *Ann. Biomed. Eng.*, vol. 44, no. 5, pp. 1587-1597, 2016.
- [3] R. Sharma, R. B. Pachori, and A. Upadhyay, "Automatic sleep stages classification based on iterative filtering of electroencephalogram signals," in *Neural Computing and Applications*. London, U.K.: Springer, 2017, pp. 1-20.
- [4] Supratak, A., Dong, H., Wu, C., & Guo, Y. (2017). DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(11), 1998-2008.
- [5] Phan, H., Andreotti, F., Cooray, N., Chén, O. Y., & De Vos, M. (2019). SeqSleepNet: end-to-end hierarchical recurrent neural network for sequence-to-sequence automatic sleep staging. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(3), 400-410.
- [6] K. Dabov, A. Foi, V. Katkovnik, and K. Egiazarian, "Image denoising by sparse 3-D transform-domain collaborative filtering," *IEEE Trans. Image Process.*, vol. 16, no. 8, pp. 2080-2095, Aug. 2007.
- [7] Deledalle, Charles-Alban, Shibin Parameswaran, and Truong Q. Nguyen. "Image denoising with generalized Gaussian mixture model patch priors." *SIAM Journal on Imaging Sciences* 11.4 (2018): 2568-2609.
- [8] Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L. (2017). Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising. *IEEE Transactions on Image Processing*, 26(7), 3142-3155.
- [9] Yu, A., Liu, X., Wei, X., Fu, T., Liu, D., 2018. Generative adversarial networks with dense connection for optical coherence tomography images denoising. In: 2018 11th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). IEEE, pp. 1-5.
- [10] B Kemp, AH Zwinderman, B Tuk, HAC Kamphuisen, JJJ Oberyé. Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG. *IEEE-BME* 47(9):1185-1194 (2000).