

가속도 센서 데이터 기반 수면단계 예측 및 수면주기의 추정

Prediction of Sleep Stages and Estimation of Sleep Cycle Using Accelerometer Sensor Data

강 경 우*, 김 태 선**★

Gyeong Woo Gang*, Tae Seon Kim**★

Abstract

Though sleep polysomnography (PSG) is considered as a golden rule for medical diagnosis of sleep disorder, it is essential to find alternative diagnosis methods due to its cost and time constraints. Recently, as the popularity of wearable health devices, there are many research trials to replace conventional actigraphy to consumer grade devices. However, these devices are very limited in their use due to the accessibility of the data and algorithms. In this paper, we showed the predictive model for sleep stages classified by American Academy of Sleep Medicine (AASM) standard and we proposed the estimation of sleep cycle by comparing sensor data and power spectrums of δ wave and θ wave. The sleep stage prediction for 31 subjects showed an accuracy of 85.26%. Also, we showed the possibility that proposed algorithm can find the sleep cycle of REM sleep and NREM sleep.

요 약

수면 질환에 사용되는 수면다원검사는 그 비용 및 시간적 제약으로 새로운 대안을 찾을 필요가 절실하다. 최근 웨어러블 헬스기기가 대중화 되면서 기존의 액티그래피를 이용한 수면분석을 대신하려는 다양한 연구가 되고 있으나 이들 기기의 데이터 및 알고리즘은 접근성 및 성능에 있어 매우 제한적인 상황이다 본 논문에서는 자체 제작된 가속도계 센서모듈을 이용한 수면 중 움직임 정보를 이용하여 AASM표준 방식 기준으로 분류된 수면 단계를 예측하고, 센서의 움직임 정보와 뇌파의 δ 파와 θ 파의 파워스펙트럼 비교를 통해 수면의 주기를 추정할 수 있는 방법을 제시했다. 31명의 공개된 PSG 분석결과를 이용한 수면 단계 예측 결과 85.26%의 정확도를 보였다. 움직임 신호의 특성과 δ 파와 θ 파의 파워 변화를 비교한 결과 REM수면과 NREM수면의 반복 주기를 제시한 알고리즘으로 찾을 수 있는 가능성이 있음을 보였다.

Key words : Sleep stage prediction, Sleep monitoring, Accelerometer, Actigraphy, Random forest, EEG

* Fusion Data, Inc.

** School of Information, Communications & Electronics Engineering, The Catholic Univ. Korea

★ Corresponding author

E-mail : tkim@catholic.ac.kr, Tel : +82-2-2164-4367

※ Acknowledgment

This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education(2018R1D1A1B07042955)

Manuscript received Dec. 9, 2018; revised Dec. 21, 2019; accepted Dec. 26, 2019.

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.

I. 서론

인간의 생활에 있어 수면은 건강한 일상생활을 위해 가장 중요한 요소 중의 하나이다. 이에 건강한 수면을 위한 관심은 계속 높아지고 있으나 도리어 수면으로 고통 받는 인구는 점점 늘어나고 있다. 2019년 9월 국민건강보험공단이 발표한 보도자료에 따르면 수면장애 질환으로 요양기관을 찾은 환자는 5년간 연평균 8.1% 증가했으며, 2018년 수면장애 진료환자의 수는 약 57만 명으로 전체 건강보험 가입자의 1.1%가 수면질환으로 진료를 받은 것으로 나타났다[1]. 수면질환의 진단을 위해서는 통상 수면다원검사(Polysomnography, PSG)를 실시하게 된다[2]. PSG는 1960년대 이래 수면질환을 파악하는데 사용되는 가장 대표적인 의학표준으로 뇌파(EEG), 안전도(EOG), 턱 및 다리의 근전도(EMG), 심전도(ECG), 호흡, 몸의 위치, 혈액산소포화도 및 코골이 소리 등 다양한 센서 정보를 측정하고 기록하여 이를 바탕으로 수면전문분석가를 통해 생리적 원인을 찾는 방식을 따른다[3]. 그러나, PSG는 수면센터에 머무르면서 한 번에 최소 5~6시간의 검사를 받아야 하고 고가의 검사비를 요구한다. 또한 시간과 장소에 대한 제약으로 장기간에 걸친 진단이 불가능하다. 특히 생소한 검사실에서 센서들을 부착하고 수면을 취하는 동안 검사를 하게 되어 “first-night effect”이라 불리는 문제가 발생하는 경우가 많아 정상적인 진단이 어렵다[4].

위와 같은 PSG의 한계를 극복하기 위한 방법의 한가지로 액티그래피(actigraphy)를 이용한 수면분석에 대한 많은 연구가 이루어지고 있다[5-6]. 그러나 의료 등급의 액티그래피는 그 가격이 \$1,000 정도로 개인이 사용하기에는 부담스러운 수준이며 여전히 수면전문분석가와 대면이 필요하다. 최근에는 헬스케어용 웨어러블 기기의 대중화 및 휴대전화를 통해 많은 사람이 수면상태를 모니터링할 수 있게 되었고 그 성능을 액티그래피와 비교하는 연구들이 속속 등장하고 있다[7-9]. Cheung은 소비자 등급의 웨어러블 디바이스 Arc를 이용하여 19인의 수면클리닉 환자를 대상으로 그 성능이 연구 등급의 액티그래피와 유사함을 보였다[7]. Cook은 일반소비자 등급의 대표적인 웨어러블 헬스기기인 Fitbit Flex(FBF)을 이용하여 주요 우울장애를 겪는 환자들의 수면장애를 PSG와 연구 등급 액

티그래피의 결과와 비교하였다[8]. 그 결과 FBF는 액티그래피의 결과와 일부 유사한 성능을 보이기도 했지만, 사용자의 민감도 세팅 수준에 따라 PSG 대비 수면시간을 너무 길거나 짧게 추정하여 의학적으로 적용하기에는 한계가 있다고 밝혔다. 이렇게 의료등급의 액티그래피를 상용 헬스케어 장치로 대체하기 위한 연구가 꾸준히 이루어지고 있으나, PSG와 상용 모바일 헬스케어 기기간의 성능에 대한 검증은 매우 제한적이고, 웨어러블 기기에서 소비자가 센서 데이터를 직접 접근할 수 있게 지원하는 곳은 거의 없으며, 수면상태의 평가를 위한 알고리즘도 공개되어있지 않아 이의 의학적 신뢰성 및 연구에 사용은 제한적인 상황이다[9]. 이에 현재 미국식품의약국(FDA)는 웰니스에 대한 조언 기능을 가진 소비자 등급의 웨어러블 장치에 법적인 규제를 하지 않고 있다[10]. 이러한 점을 고려하여 본 논문에서는 삼차원 가속도계를 이용하여 센서모듈을 제작하고 이 정보를 바탕으로 사용자의 수면 중 움직임을 파악하여 수면상태를 분석했다. 센서모듈을 통해 수집된 정보는 밴드패스 필터와 무빙 윈도우를 통한 전처리과정을 거쳐 랜덤 포레스트(Random forest) 분류기로 보내지고 이를 바탕으로 American Academy of Sleep Medicine (AASM)의 기준에 따른 5가지의 수면 단계를 예측하였다. 제작된 센서모듈은 아직 의학적 검증을 거치지 못한 관계로 PSG와 동시 측정된 데이터가 없는 상황이다. 이에 본 논문에서 제안하는 알고리즘의 검증을 위해 Walch에 의해 공개된 가속도계 센서데이터와 PSG검사결과를 사용하였다[11]. 또한 센서모듈의 데이터를 바탕으로 수면뇌파의 특성과 비교하여 수면의 주기성을 예측할 수 있는 가능성을 제시했다.

II. 본론

1. 수면의 단계 및 사용된 표준

인간의 수면시간은 각성과 수면의 반복으로 이루어진 90분에서 120분 내외의 주기를 4~5회 반복하면서 지속되는 것으로 알려져 있다[12]. 수면단계의 구분을 위한 대표적인 표준은 Rechtschaffen와 Kales (R&K)의 방법과 AASM의 방법이다[13]. 이 중, 본 논문에서는 최근 더 널리 사용되는 AASM방법을 기준으로 했다. AASM방법에서는 수면을 각성, 세

단계의 NREM수면상태(N1, N2, N3) 및 REM수면의 다섯 단계로 나눈다. 통상 NREM 1단계(N1)는 각성 상태에서 잠이 드는 가벼운 수면 상태로 분류하고 NREM 3단계(N3)를 깊은 수면 상태로 정의한다. N3상태에서는 모든 근육 및 안구의 운동이 정지되며 통상 전체 수면시간의 5~15%를 차지한다[3]. 수면 중 꿈을 꾸는 기간은 대체로 REM수면 시간동안 이루어진다. 이 기간에는 각성 상태와 유사하게 안구운동이 활발해지고 불규칙한 뇌전도가 나타나게 된다.

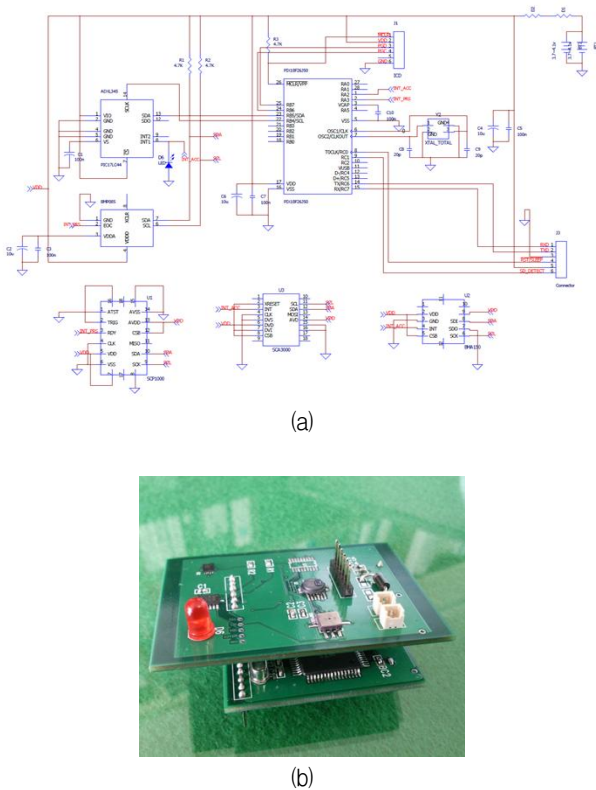


Fig. 1. Designed sensor module.(a) Schematic diagram of sensing module (b) Manufactured sensor module.
그림 1. 센서모듈 (a) 센서부의 스키메틱 회로도 (b) 제작된 센서모듈

2. 센서모듈

수면 중 움직임 정보를 획득하기 위하여 3차원 가속도 센서모듈에 실시간 데이터로거가 가능한 모듈을 제작하였다. 가속도 센서의 신뢰성을 높이기 위하여 Analog Devices사의 ADXL345, BOSCH사의 BMA150, 그리고 VTI사의 SCA3000-E02의 세 가지 센서를 사용하였다. 측정된 센서 데이터는 Zigbee 무선으로 사용자의 PC로 바로 전달 가능하며 SD 카드 모듈을 이용하여 실시간 데이터 로깅이 가능

하도록 구성하였다. 그림 1은 센서부의 회로도 및 완성된 센서모듈의 모습이다. 측정 샘플링 비율은 12.5Hz이고 2GB의 SD카드를 기준으로 최대 4500 시간의 센서 정보를 저장할 수 있다.




Fig. 2. System diagram of sleep analysis.
그림 2. 수면분석 시스템 구조도

3. 수면분석

그림 2는 수면분석을 위한 전체 시스템의 간략한 구조도이다. 제안하는 시스템은 크게 두 가지 모듈로 구성되어 있다. 첫 번째는 수면 중 움직임 정보를 바탕으로 수면단계를 예측하는 모형이고 두 번째는 수면 중 움직임 정보를 이용한 수면 주기의 추정이다.




Fig. 3. Graph of band-pass filtered signal (upper : original, lower : filtered).
그림 3. 밴드패스 필터된 파형 그래프 (위 : 원신호, 아래 : 필터링 후)

가. 수면 단계의 예측

수면 단계의 예측을 위하여 획득한 센서데이터는 다음의 전처리과정을 거쳐 분류기의 입력으로 사용된다. 먼저 제작된 센서를 통해 전달된 3축 가속도정보 X, Y, Z를 읽어 식 (1)을 통해 1차원의 움직임 값으로 변환한다.

$$M = \sqrt{(X^2 + Y^2 + Z^2)} \tag{1}$$

1차원으로 변환된 움직임 값 M은 2-3.5 Hz의 대

역통과 필터를 통해 잡음을 제거하게 된다. 그림 3은 대역통과 필터를 통과한 후의 전후 비교 그림이다. 그림에서는 필터를 거친 후의 신호가 작은 잡음이 더 많은 것으로 보일 수 있으나 이는 비정상적으로 큰 진폭을 가진 잡음신호가 삭제되면서 그림의 Y축 스케일이 변함에 기인한다. 잡음이 제거된 신호는 2초 간격으로 신호의 최대치를 구하게 된다. 이 신호가 Random forest 분류기의 입력으로 사용된다. 통상의 PSG검사에서는 30초를 주기로 수면의 단계를 분류하고 있다. 따라서 본 논문에서는 15개의 연속 신호를 분류기의 입력으로 사용하게 되고 분류기는 각성, N1, N2, N3 및 REM수면 다섯 가지의 단계 중 하나로 분류하게 된다.

나. 수면 주기의 추정

본 논문에서는 상기 기술한 수면 단계의 예측에 추가적으로 수면 중 움직임 정보가 수면의 주기성을 파악하는 도구로 사용 가능한지를 확인하기 위해 수면뇌전도와 동시에 측정하여 그 상관관계에서 추정 가능성을 확인하고자 했다. EEG신호는 수면 중 움직임 신호와 마찬가지로 PSG 검사에 사용되는 정보중의 하나라는 공통점을 갖지만, 통상 수면의 질을 평가하는데 움직임 정보보다는 더 상관관계가 큰 것으로 여겨진다. 이에 제작한 센서모듈의 성능평가를 위해 PSG 검사를 진행할 수 없는 환경적인 제한 내에서 그 대안으로 수면뇌전도 신호를 동시에 측정하여 그 상관관계를 분석하여 수면 주기를 추정했다. 통상적으로 깊은 수면에 빠진 경우의 뇌파는 δ 파가 지배적이고 수면과 깨어있는 상태 중간의 여명상태에서는 θ 파가 지배적이다. 초기 수면에 빠지는 시간을 제외하면 수면 중 움직임이 많은 경우는 각성 상태와 유사한 EEG 파형이 나타나는 REM수면 상태이고 움직임이 적은 기간은 NREM 수면 상태라는 가정 하에 뇌파와의 비교를 진행했다. 뇌파의 측정은 전두엽, 측두엽 및 후두엽 각각 2곳씩 총 6곳에서 측정되었다. 측정된 뇌파신호는 30초 간격으로 rectangular moving window를 취한 후 FFT를 통해 파워 스펙트럼 값을 얻게 된다. 여기서 0.5~4 Hz에 해당하는 δ 파와 4~8 Hz에 해당하는 θ 파의 파워를 전체 전체대역의 뇌파 에너지 값으로 나누어 구하게 된다. 이 값을 상기 제작된 가속도계의 움직임 정보와 비교하여 REM수면 기간과 NREM수면 기간을 추정한다.

이때 대역필터를 통한 잡음제거까지는 수면단계의 예측에 사용한 방식과 동일하게 사용한다. 잡음이 제거된 대역필터 통과신호는 30초 간격의 Rectangular moving window를 취한 후 임계 값 이상의 값을 갖는 데이터 개수를 구한다. 여기서 임계값은 원신호의 파형 크기를 기준으로 휴리스틱하게 결정했다. 이 신호는 다시 5분 간격의 Hann (Hanning) window를 취해 통해 움직임 신호의 크기와 빈도를 좀 더 부드러운 형태의 곡선으로 변화시킨다. 이를 δ 파와 θ 파의 파워스펙트럼과 비교하고 δ 파와 θ 파의 크기 값이 교차하여 변하는 위치를 기준으로 움직임 신호의 파워스펙트럼과 비교하여 REM수면주기와 NREM수면주기를 추정 한다.

III 실험 및 결과

1. 수면단계 예측

본 논문에서 제시한 센서모듈은 연구실 수준에서 제작된 것으로 직접 PSG를 통한 검증을 하기에는 비용 및 환경적으로 무리한 관계로, 수면 주기의 추정 및 뇌파와의 관계 비교실험에는 제작된 센서를 사용할 수 있었으나 수면단계 예측에는 비교평가 지표가 없어 사용할 수 없었다. 대신 Physionet에 공개된 Apple watch의 가속도 정보와 동시에 측정된 PSG의 수면 단계 분석결과 데이터를 이용하여 제안하는 수면단계예측 알고리즘의 성능을 평가하였다. 공개된 데이터는 2017년 6월부터 2019년 3월까지 University of Michigan에서 31명을 대상으로 측정되었다 [11]. 센서모듈을 통해 획득한 데이터의 전처리는 Matlab을 이용하였고 분류기는 WEKA를 사용하여 실험하였다. 측정데이터는 실험 대상에 따라 샘플링 주기 및 시간이 통일되어있지 않은 관계로 전처리 과정을 통해 대상 데이터의 최저 샘플링 비율인 10Hz를 기준으로 변환하여 사용하였다. 또한, PSG 분석결과에 나타난 분석시간과 가속도계 데이터의 저장시간이 일치하지 않는 관계로 PSG분석 결과가 없는 가속도계 데이터는 사용하지 않았다. 예측 성능을 나타내기 위한 지표로 precision, recall(sensitivity) 및 F1 스코어가 사용되었다. 이들은 TP(true positive), TN(true negative), FP(false positive) 및 FN(false negative) 값을 이용하여 식 (2)부터 (4)에 의해 각각 계산된다.

$$Precision = \frac{TP}{(TP+FP)} \tag{2}$$

$$Recall = \frac{TP}{(TP+FN)} \tag{3}$$

$$F1\ Score = 2 \frac{(Recall \times Precision)}{(Recall + Precision)} \tag{4}$$

Table 1. Results of sleep stage prediction.

표 1. 수면 단계의 예측 성능

Sleep Stage	TP	FR	Precision	Recall	F1
Awake	0.865	0.000	1.000	0.865	0.928
N1	0.029	0.000	1.000	0.029	0.056
N2	0.903	0.186	0.848	0.903	0.875
N3	0.667	0.001	0.983	0.667	0.795
REM	0.915	0.086	0.822	0.915	0.866


Table 2. Confusion matrix.

표 2. 혼동행렬


classified as	Awake	N1	N2	N3	REM
Awake	0.865	0.000	0.108	0.000	0.027
N1	0.000	0.029	0.743	0.000	0.229
N2	0.000	0.000	0.903	0.002	0.095
N3	0.000	0/000	0.333	0.667	0.000
REM	0.000	0.000	0.853	0.000	0.915

표 1은 예측 시스템의 성능평가 결과이다. 총 31명의 실험자에 대한 제안한 시스템의 예측 정확도는 85.26%를 보였다. 전체적인 정확도는 예측 성능이 매우 우수하다고 보기에 무리가 있으나, 각 수면단계별 예측 결과를 보면 각성상태와 낮은 수면 상태인 N1은 1의 precision 값을 나타냈다. 특히 표 2의 confusion matrix를 통한 분석에서 각성상태를 수면상태로 잘 못 예측한 경우는 약 11%로 나타났으나, 수면상태를 각성상태로 예측한 경우는 없었다. 상대적으로 N2 단계의 경우 N3로 분류하는 오류가 상대적으로 높았다. 이는 N2 단계의 생리학적인 특징이 점점 안구운동 및 심전도, 체온 및 호흡이 감소하며 N3단계로 가는 형태로서 두 수면 단계 모두 수면 중 움직임이 거의 없는 상태임에 기인하는 것으로 판단된다. 동일한 data를 사용한 Walsh의 연구 결과에서도 가속도계를 이용한 예측은 심박동수를 이용한 예측에 비해서는 분류성능

이 우수하였으나 심박동수 및 움직임 정보에 활동 주기를 나타내는 circadian clock 정보를 포함하였을 때 그 예측도가 상승하였다[11]. 즉, 수면과 각성의 분류에 있어서는 가속도 센서를 이용한 움직임 정보가 유용할 수 있으나 PSG와 같이 의학적으로 정확도를 요구하는 수면분석에는 수면 중 움직임 정보만으로는 분류기나 전처리기술에 따라 정도의 차이는 있으나 근본적인 한계가 있는 것으로 판단된다.



(a)



(b)

Fig. 4. Power of δ -wave and θ -wave (a) signals before smoothing and normalization (b) signals after smoothing and normalization.

그림 4. δ 파와 θ 파형의 파워 (a) 스무딩 및 정규화 이전 신호 (b) 스무딩 및 정규화 후의 신호

2. 수면주기 추정 및 뇌전도(EEG) 신호와의 비교

통상 PSG를 통한 수면분석에서는 2채널 이상의 EEG 신호의 측정을 포함하게 된다. 그러나, 공개된 PSG 데이터에는 EEG의 원신호를 확인할 수 없어 본 논문에서는 자체 제작한 가속도 센서모듈과 동시에 연구용으로 많이 사용되는 락사의 QEEG장치를 이용하여 EEG신호를 동시에 측정하였다. 그림 4는 측정된 EEG신호에서 제안한 알고리즘을 통해 추출한 δ 파형과 θ 파형의 모습이다. 그림 4(a)에서 나타난 바와 같이 두 파형은 전체 EEG 파형의 에너지 대비 크기에 차이가 있다. 따라서 원활한 분석을 위해 두 신호는 그림 4(b)에 나타난 바와 같이 normalize과정을 거쳐 사용했다. 또한 잠음으로 추정되는 큰 변동의 요소들도 제거하였다.

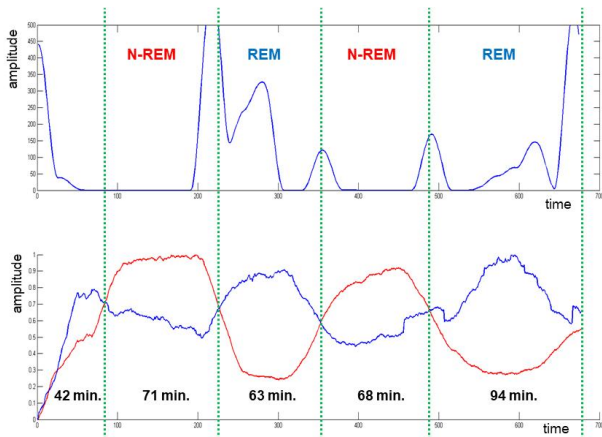


Fig. 5. Estimation of sleep periodic using moving information and EEG(upper : moving information, lower : power of δ -wave and θ -wave).

그림 5. 움직임 정보와 뇌전도의 비교를 통한 수면의 주기성 추정(위 : 움직임 정보, 아래 : δ 파와 θ 파형의 파워)

그림 5는 움직임정보와 수면뇌파에서 추출된 δ 파형과 θ 파형의 모습을 바탕으로 주기성을 추정 한 그림이다. 이의 비교를 위해 전처리 과정을 거친 가속도 센서모듈 기반의 움직임 정보 그래프를 δ 파형 및 θ 파형과 동일한 시간 축으로 나타내었다. 비교결과, 수면 중 움직임이 적은 시간에는 δ 파의 파워가 우세하고 상대적으로 움직임이 많은 시간에는 θ 파의 파워가 우세한 것으로 보인다. 즉, δ 파와 θ 파의 크기가 서로 일치하는 점을 기준으로 δ 파가 우세한 기간을 NREM수면기간, θ 파 우세한 기간을 REM수면 기간으로 본다면 이 정도 수준의 분류는 수면뇌파의 측정 없이 가속도 센서의 정보 만으로도 추정이 가능하다고 보인다. 그러나 이 결과는 아직 충분한 수의 실험데이터가 축적되지 않은 상황이므로, 현재의 결과로 의학적인 유의성을 논하기는 이르다고 본다.

IV. 결론

본 논문에서는 AASM표준 방식 기준으로 분류된 수면 단계를 예측 가능한 시스템을 제안했다. 소비자 등급의 웨어러블 스마트 헬스케어 기기들이 가지고 있는 가속도계 수준의 정보를 이용하여 수면평가의 골든룰로 여겨지는 PSG와 그 결과를 비교하였다. 데이터 획득 및 원활한 실험을 위해 센서모듈을 자체 제작하였고 예측 알고리즘의 성능은 공개된 데이터베이스를 이용하여 검증하였다.

검증결과 85.26%의 예측성능을 보여 의료등급의 수면분석으로 이용되기에는 그 한계가 있을 것으로 보이지만 각성과 수면시간의 구분에는 높은 정확도를 보였다. 또한 EEG신호와와의 비교를 통해 제안한 알고리즘을 통해 수면 중의 주기성 파악이 가능할 수 있음을 보였다. 그러나, 현 수준은 소비자 등급의 웰니스 기기의 정보제공 수준으로 여겨지며, 정확한 수면단계의 예측 및 주기성 분석을 위해서는 추가적인 센서의 정보를 필요로 함이 불가피할 것으로 보인다.

References

[1] National Health Insurance Service, “Tired sleep disorder even after sleeping,” <https://www.nhis.or.kr/bbs7/boards/B0039/31445>

[2] A. Roebuck, V. Monasterio, E. Gederi, M. Osipov, J. Behar, A. Malhotra, T. Penzel, and G. D. Clifford, “A review of signals used in sleep analysis,” *Physiol. Meas.*, vol.35, no.1, pp.R1-R57, 2014. DOI: 10.1088/0967-3334/35/1/R1

[3] S. Roomkham, D. Lovell, J. Cheung and D. Perrin, “Promises and Challenges in the Use of Consumer-Grade Devices for Sleep Monitoring,” *IEEE Rev. Biomed. Eng.*, vol.11, pp.53-67, 2018. DOI: 10.1109/RBME.2018.2811735

[4] J. Newell, O. Mairesse, P. Verbanck, and D. Neu, “Is a one-night stay in the lab really enough to conclude? First-night effect and night-to-night variability in polysomnographic recordings among different clinical population samples,” *Psychiatry Res.*, vol.200, no.2, pp.795-801, 2012. DOI: 10.1016/j.psychres.2012.07.045

[5] A. Sadeh and C. Acebo, “The role of actigraphy in sleep medicine,” *Sleep Med. Rev.*, vol.6, no.2, pp.113-124, 2002. DOI: 10.1053/smr.2001.0182

[6] E. M. Cespedes et al., “Comparison of self-reported sleep duration with actigraphy : Results from the Hispanic Community Health Study/Study of Latinos Sueno Ancillary Study,” *Amer. J. Epidemiol.*, vol.183, no.6, pp.561-573, 2016. DOI: 10.1093/aje/kwv251

[7] J. Cheung, J. M. Zeitzer, H. Lu and E.

Mignot, "Validation of minute-to-minute scoring for sleep and wake periods in a consumer wearable device compared to an actigraphy device," *Sleep Sci. and Prac.*, vol.2, no.11, 2018.

DOI: 10.1186/s41606-018-0029-8

[8] J. Cook., M. Prairie and D. Plante, "Utility of the Fitbit Flex to evaluate sleep in major depressive disorder: A comparison against polysomnography and wrist-worn actigraphy," *J. Affect. Disord.*, vol.217, 2017. DOI: 10.1016/j.jad.2017.04.030

[9] M. de Zambotti, J. G. Godino, F. C. Baker, J. Cheung, K. Patrick, and I. M. Colrain, "The boom in wearable technology : Cause for alarm or just what is needed to better understand sleep?" *Sleep*, vol.39, no.9, pp.1761-1762, 2016.

DOI: 10.5665/sleep.6108

[10] M. Boulos, A. Brewer, C. Karimkhani, D. Buller, and R. Dellavalle, "Mobile medical and health apps: State of the art, concerns, regulatory control and certification," *Online J. Public Health Informat.*, vol.5, no.3, p.229, 2014.

DOI: 10.5210/ojphi.v5i3.4814

[11] O. Walch, "Motion and heart rate from a wrist-worn wearable and labeled sleep from polysomnography," *PhysioNet*, 2019.

DOI: 10.13026/hmhs-py35

[12] S. Hamida, B. Ahmed, D. Cvetkovic, E. Jovanov, G. Kennedy, T. Penzel, "A New Era in Sleep Monitoring: The Application of Mobile Technologies in Insomnia Diagnosis," *Mobile Health*, vol.5, pp.101-127, 2015.

DOI: 10.1007/978-3-319-12817-7_5

[13] S. Fallmann and L. Chen, "Computational Sleep Behavior Analysis : A Survey," *IEEE Access*, vol.7, pp.142421-142440, 2019.

DOI: 10.1109/ACCESS.2019.2944801

BIOGRAPHY

Gyeong Woo Gang (Member)



2010 : BS degree in Sch. Info. Comm. & Elec. Eng, The Catholic Univ. of Korea.

2013 : MS degree in Info. Comm. & Elec. Eng, The Catholic Univ. of Korea.

2016~2019 : Senior Research Engineer, Small Machines, Inc.

2019~current : Chief Research Engineer, Fusion Data.

Tae Seon Kim (Member)



1991 : BS degree in Elec. Eng., Inha University.

1993 : MS degree in Elec. Eng., Inha University.

1998 : PhD degree in Elec. and Comp. Eng., Georgia Institute of Technology.

1999~1999 : Research Fellow, Packaging Research Center.

1999~2001 : Senior Research Engineer, Samsung Electronics.

2001~present : Professor, Sch. Info. Comm. & Elec. Eng, The Catholic Univ. of Korea.