

A Literature Survey of Machine Learning Based Obstructive Sleep Apnea Diagnosis Research

Seo-Young Kim*, Young-Kyoon Suh*

*Student, School of Computer Science and Engineering, Kyungpook National University, Daegu, Korea

*Professor, School of Computer Science and Engineering, Kyungpook National University, Daegu, Korea

[Abstract]

Obstructive sleep apnea (OSA) among sleep disorders is one of relatively common diseases. Patients can be checked for the disease through sleep polysomnography. However, as far as the diagnosis of OSA using polysomnography (PSG) is concerned, many practical problems such as an increasing number of patients, expensive testing cost, discomfort during examination, and the limited number of people for testing have been pointed out. Accordingly, for the purpose of substituting PSG researchers have been actively conducting studies on OSA diagnosis based on machine learning using bio signals. In this regard, we review a rich body of existing OSA diagnosis studies applying machine learning techniques based on bio-signal data. As a result, this paper presents a novel taxonomy of the reviewed studies and provides their comprehensive comparative analysis results. Also, we reveal various limitations of the studies using the bio signals and suggest several improvements about utilization of the used machine learning methods. Finally, this paper presents future research topics related to the application of machine learning techniques using bio signals.

▶ **Key words:** Obstructive Sleep Apnea, Polysomnography, Biosignal, Machine Learning, Feature Extraction

[요 약]

수면 장애 중 폐쇄성수면무호흡증은 비교적 흔한 질병 중 하나이다. 환자들은 수면다원검사를 통해 해당 질환의 여부를 알아볼 수 있다. 그러나 수면다원검사를 이용한 폐쇄성수면무호흡증 진단에 관한 한, 늘어나는 환자 수, 비싼 검사 비용, 검사 중 불편함, 수용 인원 제한 등 현실적인 문제점들이 지적됐다. 이에 따라, 수면다원검사를 대체할 목적으로 연구자들은 생체 신호를 활용한 기계학습 기반 폐쇄성수면무호흡증 진단 연구들을 활발히 진행해 왔다. 이 시점에서, 우리는 생체 신호 데이터를 기반으로 기계학습 기법을 적용하는 폐쇄성수면무호흡증 진단 연구를 복기한다. 그 결과, 본 논문은 복기된 연구들에 대한 최신 분류 체계를 제시하고 그 연구들의 종합적인 비교 분석 결과를 제공한다. 또한, 본 논문은 생체 신호를 활용한 연구들의 다양한 한계점을 밝히고 사용된 기계학습 기법의 활용성에 대한 여러 개선점을 제안한다. 끝으로, 본 논문은 생체 신호를 활용한 기계학습 기법 적용과 관련한 향후 연구 주제를 제시한다.

▶ **주제어:** 폐쇄성수면무호흡증, 수면다원검사, 생체 신호, 기계학습, 특징 추출

• First Author: Seo-Young Kim, Corresponding Author: Young-Kyoon Suh

*Seo-Young Kim (heyksy96@knu.ac.kr), School of Computer Science and Engineering, Kyungpook National University

*Young-Kyoon Suh (yksuh@knu.ac.kr), School of Computer Science and Engineering, Kyungpook National University

• Received: 2020. 04. 22, Revised: 2020. 06. 18, Accepted: 2020. 06. 19.

I. Introduction

폐쇄성수면무호흡증(Obstructive Sleep Apnea, OSA)은 남성의 4%와 여성의 2%가 겪는 비교적 흔한 수면 장애 중 하나로 알려져 있다[1]. 현대 사회의 노령화, 비만으로 OSA 환자는 더 늘어나고 있다. OSA는 고혈압, 당뇨, 심장 질환, 뇌졸중, 우울증과 같은 여러 가지 질환에 영향을 끼친다. 수면의 질을 떨어뜨려 주간졸림증, 생산성 저하, 의욕 저하와 같은 삶의 질을 떨어뜨린다. OSA는 환자 개인의 문제가 아닌 사회적인 문제가 되고 있다[1-5]. 또한, 생활 수준 향상으로 현대인들의 수면의 질에 관한 관심 및 OSA에 관한 관심이 점점 증가하고 있다.

OSA는 수면다원검사(Polysomnography, PSG)를 통하여 진단할 수 있다. 그러나 PSG는 검사실에서 장비를 부착하고 수면을 취하기 때문에 불편함을 느끼고 장소의 제약이 있다는 단점이 존재한다. 또한, 많은 센서를 통하여 검사가 진행되고 평균 7시간의 수면 시간을 전문가가 관찰(Monitoring)해야 하므로, PSG의 비용(회당 약 70만 원)이 저렴하지 않다. 더욱이 보유 중인 PSG 기기 대비 잠재적 OSA 환자들에 따른 PSG 수요가 너무 큰 실정이다. 이러한 이유로, PSG를 진행하지 않아도 OSA를 진단할 방법, 즉 PSG 대체의 필요성이 점점 증대되고 있다.

이에 발맞추어 PSG 대체를 위한 “기계학습(Machine Learning)” 기반의 OSA 진단 연구들이 활발히 진행되고 있다. 이러한 문헌들은 여러 가지 신체 정보 및 생체 신호와의 연관성을 분석하고, 특히 OSA와 연관성이 있다고 알려진 코골이, 뇌파, 산소포화도, 심전도 등과 같은 생체 신호 중 1~2개의 신호 데이터를 활용한 기계학습 모델을 구축해 왔다.

그러나 많은 기존 연구들이 취하고 있는 방법론들은 매우 다르다. 이러한 상이성은 OSA 진단과 연관된 기계학습 기법 적용 연구가 어느 범위까지 수행되었는지 파악하기 어렵게 한다. 이 문헌들은 생체 신호를 활용한 기계학습 모델의 한계점 등도 명확히 진술하지 않는다. 이로 인해 연구자들은 전체적인 연구 스펙트럼을 확보하기 어렵고 최근 급격히 성장하고 있는 인공지능 기법을 어떻게 OSA 자동 진단에 적용할 수 있을지 파악하기 어려운 실정이다.

이 시점에서, 본 논문은 PSG 대체를 위한 기계학습 기반의 OSA 진단 연구들을 광범위하게 복기하고 이러한 연구들을 잘 동기화된 기준에 따라 분류하며, 이들 연구에 있어서 어떤 한계점들이 존재하고 있는지 통합 분석한다.

본 논문 학술적 시사점은 아래와 같이 요약된다.

- 우리는 최신 기계학습 기법을 이용한 다양한 폐쇄성

수면 무호흡증 사전 검사 및 진단 연구에 관한 광범위한 사례 조사 및 분석을 수행한다.

- 그리고 기계학습 기법별 폐쇄성 수면 무호흡증 진단 연구에 대한 깊이 있는 분류 체계 (Taxonomy)를 제공하고 관련하여 사용되는 기계학습 기법을 설명한다.
- OSA 진단 연구가 실질적으로 환자 진단에 사용될 때 고려되는 중요한 지표를 소개하고, 이러한 지표에 따른 종합적인 비교 사례 평가를 수행한다.
- 우리는 생체 신호를 활용할 때 생기는 연구의 제한점과 사용된 기계학습 기법의 활용성 부분에서 개선점이 필요함을 밝힌다.
- 우리는 기계학습 기반 OSA 진단 연구의 개선 및 확장을 위한 향후 연구 방향을 제시한다.

본 논문의 구성은 다음과 같다. 2장은 배경 지식인 PSG, 생체 신호와 OSA와 연관 관계, 신호 분석, 기계학습 기법에 대하여 설명한다. 3장은 기계학습 적용 관련 생체 신호 데이터를 활용한 OSA 진단 연구를 분류한다. 4장은 소개된 연구 사례들을 비교 분석한다. 5장에서 살펴본 연구들에 대한 추가 논의를 수행한 후, 6장에서 본 논문을 종결하고 향후 연구 방향을 제시한다.

II. Background

1. Polysomnography

PSG는 전문 인력이 갖춰진 검사실에서 진행되는 검사이다. 수면 중 몸에 센서를 부착하여 뇌파, 안전도, 턱 근전도, 다리 근전도, 심전도, 코골이, 호흡운동, 산소포화도, 호흡기류, 몸의 위치 등 생체 신호 7가지 이상의 채널을 검사하며 수면 시간을 측정하고 기록한다. 또한, 전문 인력이 수면검사시간 동안 관찰하게 된다. PSG는 측정된 생체 신호를 통하여 수면 상태와 OSA를 비롯한 여러 가지 수면 질환 여부를 평가하게 된다[6]. PSG 시에 호흡의 지표는 호흡운동과 호흡기류를 사용하게 된다. 나머지 생체 신호들로 수면 단계, 수면 시간과 같은 수면 상태를 진단하게 된다.

PSG는 집 이외의 다른 장소인 검사실에서 진행하고 여러 가지 센서를 부착하고 잠을 잔다는 점에서 환자들이 불편함을 느끼고 수면 효율이 떨어질 수 있다. 수면 검사실의 한계와 전문 인력이 필요하다는 점으로 검사가 제한적이고 환자의 대기가 발생한다. 이런 단점들을 보완하기 위하여 집에서 측정 가능한 휴대용 PSG 기기를 사용하기도 한다.

그러나 전문가가 PSG를 감시하지 않기 때문에 검사 중에 기기가 오작동하거나 센서 부착이 제대로 되지 않아 측

정 오류가 발생할 수 있다. 앞서 말한 여러 가지 PSG의 제한점을 해결한 다른 OSA 진단 방법이 필요하다. 이에 관련하여, 다음 절에서 논의한다.

2. Machine Learning Based Obstructive Sleep Apnea Diagnosis

첫 번째 접근 방법은 시계열 데이터인 생체 신호와 수면 중 무호흡 사건의 연관성을 기반으로 OSA 여부 및 AH-I와 심각도를 판단하는 것이다. 뇌파, 심전도, 산소포화도, 코골이와 같은 생체 신호들을 많이 사용한다. 7~8시간의 수면 시간 중 몇 번의 무호흡이 일어났는지 판단하기 위해서는 작은 시간 단위로 분할된 데이터를 사용하여야 한다. 보통 30초로 나누어 사용하게 된다. 30초 동안 측정된 생체 신호 데이터에 따라 정상 또는 무호흡으로 분류하기 때문에 기계학습 기법을 활용한다.

두 번째 접근 방법은 환자의 신체적 특성을 기반으로 폐쇄성수면무호흡증을 진단하는 것이다. 신체적 특성과 AH-I (Apnea and Hyponea Index)의 연관성을 기반으로 OSA의 심각도를 판단. 2.2-1절에서 설명한 환자의 특성인 다변량 데이터를 사용하여 OSA를 진단하는 접근법이다. 환자의 특성 데이터와 AH-I의 상관관계를 기반으로 폐쇄성수면무호흡증 여부와 심각도를 판단하는 연구를 진행한다 [7][8]. AH-I는 0부터 시작하는 정수 데이터로 회귀 기법을 사용할 수 있다. 회귀 기법 기반의 신체적 특성 데이터 사용 모델은 환자의 특성을 사용하기 때문에 크기가 작은 데이터로 모델을 구현할 수 있다는 장점이 있다. 그러나 낮은 설명력으로 실제 PSG를 대체하기에 어려움이 존재한다.

3. Bio signal Dataset for Applying Machine Learning

생체 신호를 활용하여 OSA 진단을 위해서는 생체 신호 데이터가 필요하다. 기계학습 기법 기반의 OSA 진단을 위해서는 우선 가진 데이터는 수면 중에 측정된 데이터이고 호흡 상태를 알아야 학습할 수 있다. 따라서 호흡 상태가 라벨링(Labeling) 되어 있는 데이터를 사용하여야 한다.

그러나 수면 중 호흡 상태를 알기 위해서는 PSG를 거쳐야 알 수 있다. 이러한 이유로 모델에 사용되는 데이터는 대부분 PSG 시에 측정된 생체 신호 데이터가 사용된다. 생체 신호를 사용할 때, PSG 시 측정된 모든 생체 신호를 사용하여 모델을 구현하면 PSG를 간소화할 수 없다. 그러나 측정되는 생체 신호 중 한 가지 또는 두 가지의 데이터를 사용하면 PSG보다 간편하게 OSA 진단이 가능하다.

PSG 데이터는 의료 데이터이고 환자 개인의 정보가 담긴 데이터이다. 이러한 데이터를 사용하기 위해서는 공개된 공공데이터를 구하거나 병원에 의뢰하여 데이터를 받아야 한다. 공공데이터를 구하는 것에는 한계가 있으므로 사용할 수 있는 데이터가 제한적이다.

따라서 많은 연구는 physionet[9]에서 제공되는 Apnea-ECG Database[10]와 Sleep Heart Health Study PSG Database[11]를 주로 사용하였다. Apnea-ECG Database는 PSG 시 측정하는 신호 중 ECG 신호와 무호흡 여부에 대한 데이터이고 Sleep Heart Health Study PSG Database는 OSA 환자뿐만 아니라 여러 가지 수면 장애가 있는 환자들의 PSG 데이터이다. 병원에서 데이터를 받기 위해서는 IRB(연구윤리심의위원회)의 심의를 거치는 과정이 필요하다.

데이터를 구하는 것에도 어려움이 있지만, 받은 데이터가 분석하기 어려운 형태의 데이터인 경우도 존재한다. 데이터를 모델에 적용할 수 있는 형태로 만들기 위해서는 변환하고 원하는 데이터를 뽑아내는 과정이 필요하다. 또한 데이터의 크기가 크기 때문에 과정을 거칠 때 많은 시간이 소요된다.

4. Feature Extraction of Bio signal Data for Machine Learning

생체 신호 데이터를 활용하여 기계학습 기법 기반의 OSA 진단을 위해서는 많은 전처리 과정을 거쳐야 한다. 100Hz의 생체 신호를 30초 구간을 단위로 데이터를 나누었을 때 생성되는 데이터는 3,000개의 속성이 생긴다. 이러한 데이터를 기계학습 기법을 적용하기 위해서는 호흡 상태를 잘 나타낼 수 있는 특징을 추출하는 과정이 중요하다. 생체 신호에서 어떻게 특징을 추출하느냐에 따라서 결과가 달라질 수 있다.

생체 신호에서는 보통 기계학습 기법에서 사용되는 PCA와 같은 차원 축소 기법 적용이 부적절할 수 있다. 생체 신호와 같은 주파수에서 특징 추출하기 위해서 주로 Wavelet 변환 기반의 여러 가지 변환 기법을 주로 사용한다[12].

Wavelet 변환은 Fourier 변환을 개선한 기법이다. 시계열 데이터를 분석하기 위하여 Fourier 변환을 사용하여 주기와 진폭을 가진 사인과 코사인 함수를 통하여 분석하였다. Fourier 변환은 주파수 영역에서의 영함만 받기 때문에 시간 영역 정보를 잃게 된다. 그러한 단점을 보완한 Wavelet 변환 기법을 시계열 데이터 분석에 사용한다[13].

Wavelet 변환 기법을 사용하면 Fourier 변환을 사용한 것보다 데이터의 변화에 대하여 잘 분석할 수 있다.

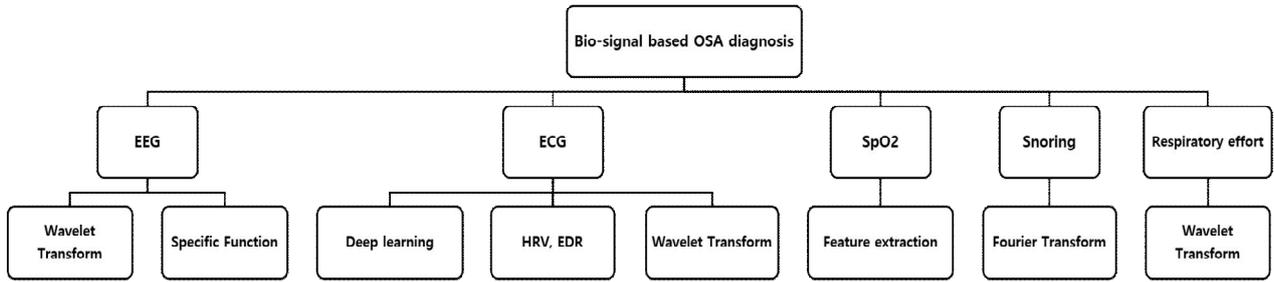


Fig. 1. Bio signal-based OSA diagnosis

Wavelet 변환 기법을 사용하여 생체 신호와 같은 시계열 데이터의 특징을 추출하여 생체 신호의 특이점과 같은 불연속적인 지점을 분석할 수 있다.

특히 ECG 신호에서는 ECG-derived respiratory(EDR) 과 Heart Rate Variability(HRV)를 계산하여 호흡 신호 분류에 사용한다. 이러한 전처리는 많은 계산과 시간이 요구된다. 따라서 최근에는 심층 학습 기법을 사용하여 전처리 과정을 간소화하는 연구가 진행되고 있다.

5. Machine Learning Methods

OSA 진단을 위해서 사용되는 기계학습 기법들은 주로 분류 단계에서 사용하게 된다. 특정 구간으로 분할이 된 신호에서 특징 추출 후 분류 기법을 사용하여 최종적으로 호흡의 상태를 정상과 무호흡으로 분류하게 된다. 주로 사용 분류 기법은 SVM(Support Vector Machine)[14] 을 사용한다. 추출된 특징에 따라 적합한 기계학습 기법이 다르므로 SVM을 비롯하여 여러 가지 기계학습 기법들을 적용한 결과를 비교하여 OSA 진단에 적절한 기계학습 기법을 선택한다 [15], 최근에는 인공신경망(Artificial Neural Network), 합성곱신경망(Convolutional Neural Network)과 같은 신경망 기반의 분류 기법도 사용되고 있다[16].

다음 장에서, 생체 신호 기반의 OSA 진단을 위한 기계 학습 적용 사례들에 대해 살펴본다.

III. Study on Diagnosis of Obstructive Sleep Apnea Based on Bio signal

Fig. 1.은 생체 신호 기반의 OSA 진단 접근법을 분류한 것이다. Fig. 1.에서 보이는 것과 같이 생체 신호 기반의 OSA 진단은 생체 신호의 종류와 피쳐 추출 기법에 따라서 분류할 수 있다.

1. EEG(Electroencephalography)

뇌파는 수면 상태와 밀접한 관계가 있는 생체 신호 중 하나로 알려져 있다. 뇌파 신호만으로도 수면 중 호흡 상태의 식별이 가능하다. [17]은 Wavelet 변환 중 하나인 DWT(Discrete Wavelet Transform)로 특징 추출 후 ANN(Artificial Neural Network)을 사용하여 호흡 상태를 분류하였다. 또한 [51]과 같이 뇌파 신호의 특징을 잘 추출할 수 있게 5개의 주파수 대역에 대해 특징을 추출하여 기계 학습 분류기로 호흡 상태를 분류할 수 있다. IMF(Intrinsic Mode Function) 기반의 특징 추출 후 SVM을 사용하여 호흡 상태를 분류하였다[18]. 뇌파 특징 추출에 최적화된 Hermit Function을 이용하여 특징 추출 후 여러 가지 분류 기법을 사용하여 호흡 상태를 분류하였다[19].

뇌파 신호를 활용한 OSA 진단은 측정할 때 여러 개의 센서를 부착하여 측정한다는 단점이 존재한다. 그리고 뇌파와 OSA의 연관성을 연구하기 위한 데이터가 따로 존재하지 않는다. 사용할 수 있는 공공데이터는 여러 가지 수면 장애가 있는 환자 대상으로 실시한 PSG 데이터가 있다. OSA를 가진 환자 데이터를 사용하여야 하므로 사용할 수 있는 데이터의 양이 한정적이다. 많은 연구가 공공데이터가 아닌 병원에서 받은 데이터를 사용하여 진행한다. 데이터가 다른 연구들이기 때문에 연구 간의 결과를 객관적으로 비교하기에 어려움이 있다.

2. ECG(Electrocardiography)

심전도는 HRV와 EDR을 도출할 수 있으므로 수면 중 호흡 상태와 밀접한 관계가 있는 신호 중 하나이다. 또한, 측정이 간편하고 기기가 저렴한 장점이 있다. 생체 신호 연구 자료를 제공하는 Physionet[9]에서 ECG 신호와 폐쇄성수면무호흡에 관련된 데이터가 공개되어서 많은 연구가 진행되고 있다. 대부분의 연구가 Physionet에서 제공하는 ECG-Apnea database를 사용한다. ECG 신호 기반의 OSA 진단은 세 가지로 나눌 수 있다.

첫 번째 HRV와 EDR을 도출한 후 분류 모델로 호흡을 분류하는 접근법이 있다[20]-[28]. HRV와 EDR을 계산하기 위하여 RR-interval[29]과 QRS[30]를 계산한다. QRS 정상(peak)의 위치를 검출하기 위하여 DWT(Discrete wavelet transform)를 사용한 후 LS-SVM (Least-squares support-vector machine)을 사용하여 호흡 상태를 분류하였다[6]. [23]은 데이터의 구간을 10, 15, 30초로 나누어 호흡 상태를 분류한 후 결과를 비교하였다.

많은 연구가 HRV와 EDR만 사용하는 것이 아니라 HRV와 EDR에서도 특징 추출을 하여 사용하고 있다. 연구[24]는 ECG에서 HRV를 추출한 후에 72개의 특징을 추출하였다. 72개를 모두 사용하지 않고 특징 선택을 통하여 연관성이 높은 특징을 골라 분류 모델에 사용하였다. [25]는 TQWT(tunable-Q factor wavelet transform)를 사용하여 HRV와 EDR을 계산하였다. [27]은 네 가지의 분류 기법을 사용하여 기계학습 기법 중 LS-SVM이 가장 정확도가 높은 결과를 보여 주었다.

두 번째는 특징 추출 방법으로 HRV 또는 EDR을 사용하지 않고 다른 기법으로 특징 추출 후에 호흡 상태를 분류하는 접근법이다. 대부분의 연구가 파동 분해(Wavelet Decomposition)를 사용하여 ECG 신호를 특정 주파수 수준으로 분해하여 특징으로 사용한다. [31]에서 신호에서 특징을 추출하기 위해서 Wavelet Decomposition을 사용하고 SVM 기법으로 호흡 상태를 분류한다. [34]에서는 Wavelet 변환의 변형 기법인 DT-CWT(Dual-tree complex wavelet transform) 기법을 사용하여 특징을 추출하고 Logistic Boosting 기법을 사용하여 호흡 상태를 분류한다. [33]는 TQWT(Tunable Q-Factor Wavelet Transform) 분해를 사용하여 특징을 추출하고 RUSBoost 기법을 사용하여 호흡 상태를 분류하였다. 파라미터값의 변화에 따라 정확도의 차이를 비교하여 파라미터값 설정이 결과에 영향을 줄 수 있음을 보여 주었다. [36]에서는 OWFB(Orthogonal wavelet filter bank) 기법을 사용하여 특징 추출 후 SVM 기법으로 호흡 상태를 분류하였다.

세 번째는 심층 학습 기법을 사용하여 분류 기법 전에 별도의 특징 추출 기법을 사용하지 않는 접근법[37-39]이다. 최근 여러 가지 많은 심층 학습 기법이 제안되면서 진행되고 있는 연구이다. [37]은 데이터를 10초 간격으로 분할 후 CNN을 사용하여 호흡 상태를 분류하였다. 층의 개수에 따라 정확도의 차이를 보여 주었다. [38]는 특징 추출을 생략하지 않았지만, 심층 학습 기법의 하나인 심층신경망(Deep Neural Network)을 사용하여 특징을 추출하고 SVM과 ANN(Artificial Neural Network)을 사용하여 파

라미터를 추정하였다. 추정된 파라미터 값으로 확률을 계산하여 OSA를 진단하였다. [50]은 6가지의 다른 심층 학습 기법을 사용하여 심층 학습이 심전도 분류에 성능이 우수함을 알 수 있다.

이러한 최근 연구 동향을 살펴보면, 생체 신호의 지식이 필요한 특징 추출 기법을 사용하지 않아도 분류가 가능한 심층 학습 기반의 OSA 진단 연구가 활발히 진행될 것으로 보인다. 앞서 연구에서 사용한 합성곱신경망, 심층신경망 또는 시계열 데이터분류에서 잘 사용되는 장단기기억모델(Long Short-Term Memory models), 순환신경망(Recurrent Neural Networks) 등의 기법들을 적용할 수 있다.

3. SpO2

SpO2(산소포화도)는 혈중산소포화도를 나타내는 것으로 호흡과 밀접한 관계가 있다. ECG 신호와 같이 측정이 간편하고 가격이 저렴하다는 장점이 있다.

SpO2를 활용한 OSA 진단은 다른 생체 신호와 함께 사용하는 연구들도 제시되고 있다[38-41]. [42]는 SpO2를 1분 단위로 데이터를 나누어 사용한다. 시간과 주파수에 따라 특징을 추출한 후 ANN 기법을 사용하여 호흡 상태를 분류한다.

[39]은 호흡 노력, HRV, Spo2를 사용하여 특징 추출 후 SVM을 사용하여 분류하였다. 각각의 신호에 따라 호흡 상태 분류 정확도를 비교하였는데, 세 가지 신호 모두 사용하였을 때 가장 높은 정확도를 보여 주었다. SpO2 단일 신호 사용보다 다른 신호와 함께 사용하였을 때 정확도를 더 높일 수 있다는 결과를 보여 주었다. Spo2도 EEG 신호와 마찬가지로 공공데이터 셋이 충분하지 않아서 연구에 한계가 있다.

4. Other

앞에서 설명한 세 가지의 생체 신호가 아닌 다른 생체 신호로 진행된 연구들도 있다[43]-[46][51]. [43][46][51]는 수면 중 코골이를 녹음한 후 특징 추출과 분류를 통하여 코골이를 탐지한 후 코골이 횟수에 따라 OSA 심각도를 진단한다. Fast Fourier Transform (FFT) 기반으로 하여 시간 도메인과 주파수 도메인의 특징을 추출하였다[43]. 코골이를 활용한 OSA 진단은 코골이를 하지 않은 OSA 환자가 존재하기 때문에 PSG를 대체하기는 어렵다. 또한, 코골이를 측정하면서 소음이 포함될 경우도 배제할 수 없다. 따라서 데이터의 신뢰성에 대한 문제점이 발생할 수 있다. 연구[43][45]는 호흡 신호에서 특징을 추출한 후 호흡 상태를 분류한다. 호흡 신호는 수면 시 측정하게 되면 불편함을 느낄 수 있다. 이러한 이유로 다른 생체 신호보다 EEG,

Table 1. Machine learning based OSA diagnosis using ECG signals

Classification method	feature extraction technique		Study
Deep learning Using method	Feature extraction and classification with convolution neural network		[37]
Machine learning Using method	Feature extraction with deep neural network		[36]
	RR-interval, QRS-based HRV extraction	Wavelet decomposition based on HRV and EDR	[35]
		TQWT	[25]
			[33]
			[35]
		[47]	
	SRE based with ECG, HRV, EDR		[48]
	Feature extraction based on wavelet decomposition from ECG signal	Wavelet decomposition in 5 steps	[31]
		DT-CWT	[34]
OWFB		[36]	
Based on time and frequency domains using respiratory effort signals		[49]	

ECG, SpO2를 OSA 진단에 주로 사용하게 된다.

다음 장에서는 PSG를 대체할 수 있는 기계학습 기법 기반 OSA 진단에서 중요한 요소들에 대하여 설명하고, 3장에서 설명한 연구 사례들에 대하여 분석한다.

IV. Comparison Analysis

Table. 1. 은 ECG 신호를 활용한 기계학습 기반 OSA 진단에 대한 사용 기법을 나타낸 것이다. 본 장은 사용되는 법에 따라 기존 연구들을 비교 분석한다.

사용되는 기법은 크게 심층 학습 기법 사용 여부에 따라 나눌 수 있다. 심층 학습 기법은 최근 많이 사용되고 있는 기법으로 자체적으로 특징 추출이 가능하다는 장점이 있다. DNN 기법을 사용하여 특징을 추출한 진단 모델[38]은 특징 추출 시에 심층 학습 기법의 하나인 DNN을 사용하여 ECG 신호의 사전 지식이 없어도 적합한 특징을 추출할 수 있다. 또한, 심층 학습 기법을 사용하면 특징 추출 시 자체적으로 OSA 진단에 적합한 특징을 추출하여 따로 특징 선택을 하지 않아도 된다는 장점이 존재한다.

CNN으로 특징 추출 및 분류한 진단 모델[37]은 ECG 신호를 10초 단위로 나누어 CNN 기법을 사용하여 특징 추출과 분류를 하였다. CNN은 신호 분류에 있어서 좋은 성능을 보이고 특징 추출과 분류를 같이 할 수 있어서 생체 신호, 오디오와 같은 신호 분류에 자주 사용된다. 그러나 앞에서 설명한 심층 학습 기법들은 비교적 최근에 알려진 기법들이라서 아직 OSA 진단에 있어서 심층 학습 기법을 사용한 많은 연구가 존재하지 않는다.

기계학습 기법을 사용한 연구들은 특징 추출 단계를 거친 후 분류 단계에서 SVM을 비롯한 여러 가지 기계학습 기법에 해당하는 분류 기법을 사용한다. 사용하는 특징 추출 기법에 따라 적합한 분류 기법이 다를 수 있다. 여러 가지 기계학습 기법을 사용하고 결과를 비교하여 어떤 기계학습 기법이 적합한지를 판단하여야 좋은 결과를 얻을 수 있다[27].

특징 추출 기법은 같은 데이터 셋을 사용하여도 많은 기법이 존재한다. ECG에서 R-R interval 계산과 QRS 탐색과 같은 패턴 탐지를 통하여 HRV와 EDR을 도출할 수 있다. 여러 가지 기법을 사용하여 HRV와 EDR에서 특징 추출이 가능하다. 특징을 추출하기 위해서 웨이블릿 분해를 사용하는 연구들이 많이 진행되고 있다[35]. TQWT(Tunable Q-Factor Wavelet Transform) 기반 특징 추출 진단 모델들이 [25][33][35][47] HRV, EDR 특징 탐지에 적합한 종류의 웨이블릿 변환(wavelet transforms)을 사용하고 있다. SRE(sparse residual entropy) 기반의 특징 추출 진단 모델[49]은 푸리에(fourier) 사전, 웨이블릿(wavelet) 사전, 아이겐(eigen) 사전, 코사인(cosine) 사전, 무호흡 신호 학습 사전 및 정상 신호 학습 사전과 같은 6 개의 사전을 기반으로 특징을 추출한다. 이러한 HRV와 EDR을 사용하는 모델들은 ECG 신호의 패턴 탐지에 적합하지만 특징 추출 전 계산 과정을 거쳐야 하는 불편함이 있다.

다른 특징 추출 방법은 HRV와 EDR을 계산하지 않고 ECG 신호에서 특징 추출을 하는 진단 모델들 [23][32][34][36]이 있다. HRV와 EDR을 계산하지 않아도 되기 때문에 계산량이 줄어든다는 점에서 전처리의 간소화가 가능하다. Fig. 2.에서 보이는 것과 같이 여러 종류의 웨이블릿 기법을 사용할 수 있다. ECG 신호의 패턴 탐지

가 가능한 HRV와 EDR을 통하여 특징을 추출하는 것이 아니기 때문에 ECG 신호의 패턴 탐지에 적절한 웨이블릿 기법을 선택하여야 한다.

웨이블릿 분해를 통하여 5단계로 분해한 신호들을 사용하거나 이미지 처리에 사용되는 DT-CWT(Dual Tree Complex Wavelet Transform) 기법을 사용하여 ECG 신호의 패턴을 파악할 수 있다. 또한, 웨이블릿 기반으로 6개의 단계로 신호를 분해하고 추가로 퍼지 엔트로피(Fuzzy Entropy) 및 로그 에너지 엔트로피(Log energy Entropy)를 서브 밴드(Sub Band)마다 계산하여 각 신호에 대해 12개의 특징을 추출하는 직교 웨이블릿 필터 뱅크(orthogonal wavelet Filter Bank)를 사용하여 ECG의 새로운 특징을 탐색할 수 있다.

특징 추출만큼 추출된 특징에서 OSA 진단에 적합한 특징을 선택하는 것도 중요하다. 같은 데이터 셋을 사용해도 기계학습 기반의 OSA 진단 방법은 다양하다. 사용되는 기법에 따라서 다른 결과와 장점이 존재한다. OSA 진단 시에 기법에 따른 결과와 장점을 고려하여 적절한 기법을 사용하여야 한다.

ECG 신호만 사용하였을 때보다 진단 결과를 높이기 위해서 추가 생체 신호를 사용하는 진단 모델[48]가 있다. respiratory effort와 같이 주로 호흡 신호에서 파생된 신호를 사용하게 된다. 모델 결과가 높다는 장점이 있지만, 현재 진행된 많은 ECG 신호를 사용한 진단 모델에서도 비슷한 결과를 보여 주는 연구들이 진행되고 있다. 따라서 최근은 단일 ECG 신호를 사용하는 연구가 주로 진행된다.

V. Discussions

PSG를 대체하기 위한 많은 기계학습 기반의 OSA 진단 연구들이 진행되었다. 그러나, 우리는 기계학습 기반 OSA 진단의 신뢰성 개선을 위해 여전히 해결되지 않은 다음과 같은 다섯 가지 향후 연구 이슈가 있음을 발견하였다.

첫째, 환자 개인 특성이 고려된 연구가 진행되어야 한다는 것이다. 환자에 따라 개인차가 존재하기 때문에 어떤 환자는 OSA 진단이 잘 되었는데 어떤 환자는 진단이 잘 되지 않을 수 있다.

둘째, 실제 웨어러블 기기로 측정된 데이터를 사용한 연구가 진행되어야 한다는 점이다. PSG와 웨어러블 기기를 둘 다 측정한 데이터 셋을 사용한 연구가 진행되어야 기계학습 기반의 OSA 진단을 실제 환자에게 사용 가능성 유무를 알 수 있다.

셋째, 현재 진행되고 있는 OSA 진단 연구는 대부분 30초의 단위로 분할된 신호를 정상과 무호흡으로 분류하고 있다. 그러나 실제 무호흡은 10초 이상 숨을 쉬지 않았을 때 무호흡으로 판단하기 때문에 30초가 아닌 10초에 대한 분류 연구가 진행되어야 한다. 10, 15, 30초로 분할된 신호를 분류하는 진단 모델[46]이 진행되었으나, 10초로 분할된 신호를 분류할 때 정확도가 가장 낮았다. 따라서 10초와 같은 짧은 신호도 분류할 수 있는 연구가 필요하다.

넷째, OSA를 진단하는 지표인 AH-I는 무호흡 횟수와 저호흡 횟수를 계산하는 것이기 때문에 저호흡 분류 연구가 필요하다. 저호흡은 무호흡보다 호흡 변화량이 적기 때문에 무호흡 분류보다 더 어려운 문제가 될 수 있다. 따라서 저호흡을 분류하기에 알맞은 특징 추출 방법과 분류 방법을 사용하여 분류하는 연구가 진행되어야 한다.

마지막으로, 여러 현재 진행된 연구들은 검사 중에 환자가 깨어났을 수도 있는 가능성을 배제하고 있다는 것이다. 수면 시간을 확실하게 측정해야 수면 시간 중 무호흡 사건의 횟수를 계산하여 OSA를 진단할 수 있다. 이러한 문제점을 해결하기 위해 수면 단계를 정확하게 분류한 후, 실제 수면 시간을 고려한 모델을 구현하는 것이 필요하다.

VI. Conclusions

OSA 진단에 필요한 PSG는 비싼 검사 비용, 검사 중 불편함, 늘어나는 환자 수에 비해 수용 인원 제한 등 여러 가지 문제점들이 존재한다. 따라서 PSG를 대체하기 위하여 기계학습 기반의 OSA 진단 연구가 진행되고 있다. OSA는 신체적 특성과 생체 신호와 연관 관계가 존재한다. 그러나 신체적 특성은 설명력이 낮아 PSG를 대체하기에 어려움이 있다. 따라서 대부분의 연구는 생체 신호를 활용한 기계학습 기반의 OSA 진단을 수행한다.

생체 신호는 의료 데이터를 사용하여 연구를 진행하기 때문에 데이터 확보에 한계가 있다. 따라서 공공 데이터셋을 이용한 연구들이 진행되고 있다. 사용되는 생체 신호는 EEG, ECG, 산소포화도, 호흡 신호, 코골이가 있다. EEG 신호와 호흡 신호는 측정이 쉽지 않다는 단점이 있고 산소포화도와 ECG 신호는 측정이 간편하다. 그러나 산소포화도는 공공데이터셋이 충분하지 않아서 연구가 진행되기 어렵다. 따라서 측정이 간편하고 가격이 저렴하여 웨어러블 기기에 탑재가 쉬우면서 공공 데이터셋이 존재하는 ECG를 이용하면 PSG를 대체하는 OSA 진단이 가능하기 때문에 많은 연구들이 진행되고 있다.

ECG 신호를 사용한 연구들은 분류 과정에서 기계학습을 사용한 연구와 심층학습을 사용한 연구로 나눌 수 있다. 기계학습을 사용한 연구들은 특징 추출 과정을 거친 뒤 기계학습 기법을 사용하여 호흡 상태를 분류한다. 그리고 심층학습을 사용한 연구는 심층학습을 통하여 특징 추출 및 분류를 하게 된다. ECG 신호를 이용한 연구 사례 분석에 의하면 심층 학습 기법을 사용하면 특징 추출 시 자체적으로 OSA 진단에 적합한 특징을 추출하여 따로 특징 선택을 하지 않아도 된다는 장점이 존재한다. 따라서 앞으로 심층 학습 기법을 사용한 연구들이 많이 진행될 것으로 보인다.

또한, PSG를 대신하여 OSA를 진단하기 위해서 아직 해결되어야 할 문제점들이 존재한다. 실제 환자가 사용하기 위해서는 개인의 차이를 고려하여 환자 개인 특성에 맞는 진단이 가능한 연구가 진행되어야 하고, 웨어러블 기기에서 측정된 데이터를 사용한 연구가 진행되어야 한다. 그리고 실제 정확한 AH-I를 도출하기 위해서는 30초 단위가 아닌 더 작은 단위의 호흡 상태를 분류하고 무호흡 뿐만 아니라 저호흡의 상태도 분류할 수 있는 연구가 진행되어야 하고 환자가 중간에 깨지 않았는지 실제 수면 시간을 고려한 연구가 진행되어야 한다. 앞서 설명한 문제점들을 해결하면 측정이 간편하고 비용이 저렴하면서 정확한 OSA 진단이 가능하여 PSG를 대체할 수 있을 것이다.

ACKNOWLEDGEMENT

This work was supported by the BK21 Plus project funded by the Ministry of Education, School of Computer Science and Engineering, Kyungpook National University, Korea (21A20131600005), by the Basic Science Research Program through the NRF funded by the Ministry of Education (No. NRF-2018R1A6A1A03025109).

REFERENCES

- [1] Terry Young, Mari Palta, Jerome Dempsey, James Skatrud, Steven Weber, Safwan Badr, "The occurrence of sleep-disordered breathing among middle-aged adults," *New England Journal of Medicine* 328, no. 17, pp.1230-1235, April 1993, doi: 10.1056/NEJM19930429328170.
- [2] Sonia Ancoli-Israel, Einat R, DuHamel, Carl Stepnowsky, Robert Engler, Mairav Cohen-Zion, Matthew Marler, "The relationship between congestive heart failure, sleep apnea, and mortality in older men" *Chest* 124, no. 4, .pp. 1400-1405, April, 2003. doi:10.1378/chest.124.4.1400.
- [3] Sassani, Alex, Larry J, Findley, Meir Kryger, Eric Goldlust, Charles George, and Terence M Davidson, "Reducing Motor-Vehicle Collisions, Costs, and Fatalities by Treating Obstructive Sleep Apnea Syndrome." *Sleep* 27, no. 3, May 2004, pp.453-458. doi:10.1093/sleep/27.3.453.
- [4] Zhao Qing, Liu Zhihong, Zhao Zhohui, Luo Qin, McEvoy, Doug, Zhang, Hongliang and Wang Yong, "Effects of obstructive sleep apnea and its treatment on cardiovascular risk in CAD patients", *Heart* 97, no. Suppl 3, A136-A136. October, 2011. doi:10.1136/hartjnl-2011-300867.395.
- [5] Fatemeh Moharrari, Soheila Saberi, Hadi Asadpour, and Fariba
- [6] Rezaeetalab, "The correlation of anxiety and depression with obstructive sleep apnea syndrome.", *Journal of research in medical sciences: the official journal of Isfahan University of Medical Sciences* 19, no. 3, pp.205, 2014.
- [7] Seung Hoon Lee, "Diagnostic Aspects of Polysomnography in Obstructive Sleep Apnea." *Journal of the Korean Medical Association* 55, no. 2, 138, February, 2012. doi:10.5124/jkma.2012.55.2.138.
- [8] Lam, Yuen-yu, Eric Y T, Chan, Daniel K Ng, Chung-hong Chan, Josephine M Y, Cheung, Shuk-yu Leung, Pok-yu Chow, and Ka-li Kwok, "The Correlation Among Obesity, Apnea-Hypopnea Index, and Tonsil Size in Children." *Chest* 130, no. 6, pp.1751-1756, December, 2006. doi:10.1378/chest.130.6.1751.
- [9] Daniel J, Gottlieb, Qing Yao, Susan Redline, Tauqeer Ali, and Mark w Mahowald, "Does Snoring Predict Sleepiness Independently of Apnea and Hypopnea Frequency?" *American Journal of Respiratory and Critical Care Medicine* 162, no. 4, pp.1512-1517, October, 2000. doi:10.1164/ajrccm.162.4.9911073.
- [10] MIT Laboratory for Computational Physiology, "PhysioNet: The Research Resource for Complex Physiologic Signals," URL: <https://physionet.org/>, accessed on March 28, 2020.
- [11] Penzel T, Moody G B, Mark R G, Goldberger A L and Peter J H, "The apnea-ECG database.", *In Computers in Cardiology* 2000, Vol. 27(Cat. 00CH37163), pp.255-258.
- [12] Goldberger A, Amaral L, Glass L, Hausdorff J, Ivanov PC, Mark R, Mietus JE, Moody GB, Peng CK, Stanley HE "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals." *Circulation* 101, 23, pp. e215-e220.
- [13] Hosmer, David W, Stanley Lemeshow and Rodney X Sturdivant. "Applied Logistic Regression." *Wiley Series in Probability and Statistics*, March 2013, doi:10.1002/9781118548387.
- [14] Subasi A, "EEG Signal Classification Using Wavelet Feature Extraction and a Mixture of Expert Model.", *Expert Systems with Applications* 32, no. 4, pp.1084-1093, May, 2007. doi:10.1016/j.

- eswa.2006.02.005.
- [15] Suykens J K A and Vandewalle, "Least squares support vector machine classifiers", *Neural processing letters*, 9(3), pp.293-300, June, 1999. doi: 10.1023/A:1018628609742
- [16] Sharma Hemant, and Sharma K K, "An Algorithm for Sleep Apnea Detection from Single-Lead ECG Using Hermite Basis Functions." *Computers in Biology and Medicine* 77, pp.116-124, October, 2016. doi:10.1016/j.compbiomed.2016.08.012.
- [17] Chaw, Hnin Thiri, Sinchai Kamolphiwong, and Krongthong Wongsritrang, "Sleep Apnea Detection Using Deep Learning." *Tehnicki Glasnik* 13, no. 4. pp.261-266, December, 2019. doi:10.31803/tg-20191104191722.
- [18] Lin, Robert, Ren-Guey Lee, Chwan-Lu Tseng, Heng-Kuan Zhou, Chih-feng Chao, and Joe-Air Jiang, "A New Approach for identifying Sleep Apnea syndrome using Wavelet Transform and Neural Networks." *Biomedical Engineering: Applications, Basis and Communications* 18, no. 03, June 25, 2006. pp.138-143. doi:10.4015/s1016237206000233.
- [19] Taran, Sachin, Varun Bajaj and Dheeraj Sharma, "TEO Separated AM-FM Components for Identification of Apnea EEG Signals." *2017 IEEE 2nd International Conference on Signal and Image Processing (ICSIP)* August, 2017. doi:10.1109/siprocess.2017.8124571.
- [20] Taran, Sachin and Varun Bajaj, "Sleep Apnea Detection Using Artificial Bee Colony Optimize Hermite Basis Functions for EEG Signals." *IEEE Transactions on Instrumentation and Measurement* 69, no.2, February 2020. pp.608-616. doi:10.1109/tim.2019.2902809.
- [21] Khandoker, Ahsan H, Chandan K, Karmakar, and Marimuthu Palaniswami, "Automated Recognition of Patients with Obstructive Sleep Apnoea Using Wavelet-Based Features of Electrocardiogram Recordings." *Computers in Biology and Medicine* 39, no. 1, January, 2009. pp.88-96. doi:10.1016/j.compbiomed.2008.11.003.
- [22] Quiceno-Manrique A F, Alonso-Hernandez J B, Travieso-Gonzalez C M, Ferrer-Ballester M A, and Castellanos-Dominguez G, "Detection of Obstructive Sleep Apnea in ECG Recordings Using Time-Frequency Distributions and Dynamic Features." *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, September, 2009. doi:10.1109/iembs.2009.5333736.
- [23] Alvarez, Hornero D R, Marcos J V, Campo F del and Lopez M, "Spectral Analysis of Electroencephalogram and Oximetric Signals in Obstructive Sleep Apnea Diagnosis." *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, September, 2009. doi:10.1109/iembs.2009.5334905.
- [24] Almazaydeh, Elleithy L K, and Faezipour M, "Obstructive Sleep Apnea Detection Using SVM-Based Classification of ECG Signal Features." *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, August, 2012. doi:10.1109/embc.2012.6347100.
- [25] Nguyen, Hoa Dinh, Brek A, Wilkins, Qi Cheng, and Bruce Allen Benjamin, "An Online Sleep Apnea Detection Method Based on Recurrence Quantification Analysis." *IEEE Journal of Biomedical and Health Informatics* 18, no. 4, pp.1285-1293, July, 2014. doi:10.1109/jbhi.2013.2292928.
- [26] Jafari and Ayyoob, "Sleep Apnoea Detection from ECG Using Features Extracted from Reconstructed Phase Space and Frequency Domain." *Biomedical Signal Processing and Control* 8, no. 6, pp.551-558, November, 2013. doi:10.1016/j.bspc.2013.05.007.
- [27] Da Silva Pinho, Andre Miguel, Nuno Pombo and Nuno M Garcia, "Sleep Apnea Detection Using a Feed-Forward Neural Network on ECG Signal." *2016 IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom)*, September, 2016. doi:10.1109/healthcom.2016.7749468.
- [28] Sharma, Hemant, and K K Sharma, "An Algorithm for Sleep Apnea Detection from Single-Lead ECG Using Hermite Basis Functions." *Computers in Biology and Medicine* 77, pp.116-124, October, 2016. doi:10.1016/j.compbiomed.2016.08.012.
- [29] Abraham Otero, Santiago F Dapena, Paulo Felix, Jesus Presedo, Miguel Tarasco, "A low cost screening test for obstructive sleep apnea that can be performed at the patient's home" *In 2009 IEEE International Symposium on Intelligent Signal Processing*, pp. 199-204, November, 2009.
- [30] Laguna, Pablo, Raimon Jané, and Pere Caminal, "Automatic Detection of Wave Boundaries in Multilead ECG Signals: Validation with the CSE Database." *Computers and Biomedical Research* 27, no. 1, pp.45-60, February, 1994. doi:10.1006/cbmr.1994.1006.
- [31] Pan, Jiapu, and Willis J Tompkins, "A Real-Time QRS Detection Algorithm." *IEEE Transactions on Biomedical Engineering* BME-32, no. 3, pp.230-236, March, 1985. doi:10.1109/tbme.1985.325532.
- [32] Rachim, Vega Pradana, Gang Li, and Wan-Young Chung, "Sleep Apnea Classification Using ECG-Signal Wavelet-PCA Features." *Bio-Medical Materials and Engineering* 24, no. 6, pp.2875-2882, September 2014. doi:10.3233/bme-141106.
- [33] Hassan, Ahnaf Rashik, and Md, Aynal Haque, "Computer-Aided Obstructive Sleep Apnea Screening from Single-Lead Electrocardiogram Using Statistical and Spectral Features and Bootstrap Aggregating." *Biocybernetics and Biomedical Engineering* 36, no. 1, pp.256-266, November, 2015. doi:10.1016/j.bbe.2015.11.003.
- [34] Hassan and Ahnaf Rashik, "Computer-Aided Obstructive Sleep Apnea Detection Using Normal Inverse Gaussian Parameters and Adaptive Boosting." *Biomedical Signal Processing and Control*

- 29, pp.22-30, August, 2016. doi:10.1016/j.bspc.2016.05.009.
- [35] Hassan, Ahnaf Rashik, Syed Khairul Bashar, and Mohammed Imamul Hassan Bhuiyan, "Computerized Obstructive Sleep Apnea Diagnosis from Single-Lead ECG Signals Using Dual-Tree Complex Wavelet Transform." *2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC)*, December, 2017. doi:10.1109/r10-htc.2017.8288902.
- [36] Hassan, Ahnaf Rashik, and Md Aynal Haque, "An Expert System for Automated Identification of Obstructive Sleep Apnea from Single-Lead ECG Using Random Under Sampling Boosting." *Neurocomputing* 235, pp.122-130, April, 2017. doi:10.1016/j.neucom.2016.12.062.
- [37] Sharma, Manish, Mitesh Raval, and U Rajendra Acharya, "A New Approach to Identify Obstructive Sleep Apnea Using an Optimal Orthogonal Wavelet Filter Bank with ECG Signals." *Informatics in Medicine Unlocked* 16, 100170, March, 2019. doi:10.1016/j.imu.2019.100170.
- [38] Urtnasan, Erdenebayar, Jong-Uk Park, and Kyoung-Joung Lee, "Multiclass Classification of Obstructive Sleep Apnea/hypopnea Based on a Convolutional Neural Network from a Single-Lead Electrocardiogram." *Physiological Measurement* 39, no. 6, 065003, June, 2018. doi:10.1088/1361-6579/aac7b7.
- [39] Kunyang Li, Weifeng Pan, Yifan Li, Qing Jiang, and Guanzheng Liu, "A Method to Detect Sleep Apnea Based on Deep Neural Network and Hidden Markov Model Using Single-Lead ECG Signal." *Neurocomputing* 294, pp. 94-101, June, 2018. doi:10.1016/j.neucom.2018.03.011.
- [40] Erdenebayar, Urtnasan, Yoon Ji Kim, Jong-Uk Park, Eun Yeon Joo, and Kyoung-Joung Lee, "Deep Learning Approaches for Automatic Detection of Sleep Apnea Events from an Electrocardiogram." *Computer Methods and Programs in Biomedicine* 180, 105001, October, 2019. doi:10.1016/j.cmpb.2019.105001.
- [41] Al-Angari H M, and A V Sahakian, "Automated Recognition of Obstructive Sleep Apnea Syndrome Using Support Vector Machine Classifier." *IEEE Transactions on Information Technology in Biomedicine* 16, no. 3, pp.463-468, May 2012. doi:10.1109/titb.2012.2185809.
- [42] Xie B and Hlaing Minn, "Real-Time Sleep Apnea Detection by Classifier Combination." *IEEE Transactions on Information Technology in Biomedicine* 16, no. 3, pp.469-477, May, 2012. doi:10.1109/titb.2012.2188299.
- [43] Abedi, Zahra, Nadia Naghavi and Fariborz Rezaeitalab, "Detection and Classification of Sleep Apnea Using Genetic Algorithms and SVM-Based Classification of Thoracic Respiratory Effort and Oximetric Signal Features." *Computational Intelligence* 33, no. 4, pp.1005-1018, August, 2017. doi:10.1111/coin.12138.
- [44] Mostafa, Sheikh Shanawaz, Joao Paulo Carvalho, Fernando Morgado-Dias and Antonio Ravelo-Garcia, "Optimization of Sleep Apnea Detection Using SpO2 and ANN." *2017 XXVII International Conference on Information, Communication and Automation Technologies (ICAT)*, October, 2017. doi:10.1109/icat.2017.8171609.
- [45] Bijoy Laxmi Koley and Debangshu Dey, "Selection of Features for Detection of Obstructive Sleep Apnea Events." *2012 Annual IEEE India Conference (INDICON)*. December, 2012. doi:10.1109/indcon.2012.6420761.
- [46] Avci, Cafer and Ahmet Akbaş, "Sleep Apnea Classification Based on Respiration Signals by Using Ensemble Methods." , *Bio-Medical Materials and Engineering* 26, no. s1, pp. S1703-S1710, August, 2015. doi:10.3233/bme-151470.
- [47] Almazaydeh L, K Elleithy, and M Faezipour, "Obstructive Sleep Apnea Detection Using SVM-Based Classification of ECG Signal Features." *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, August, 2012. doi:10.1109/embc.2012.6347100.
- [48] Nishad, Anurag, Ram Bilas Pachori and U Rajendra Acharya, "Application of TQWT Based Filter-Bank for Sleep Apnea Screening Using ECG Signals", *Journal of Ambient Intelligence and Humanized Computing*, pp.1-12, May, 2018. doi:10.1007/s12652-018-0867-3.
- [49] Viswabhargav, Ch.S.S.S., R.K. Tripathy, and U. Rajendra Acharya, "Automated Detection of Sleep Apnea Using Sparse Residual Entropy Features with Various Dictionaries Extracted from Heart Rate and EDR Signals." *Computers in Biology and Medicine* 108, pp.20-30, May, 2019. doi:10.1016/j.compbiomed.2019.03.016.
- [50] Prabha, Anju, Akta Trivedi, A. Anand Kumar, and C Santhosh Kumar, "Automated System for Obstructive Sleep Apnea Detection Using Heart Rate Variability and Respiratory Rate Variability." *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, September, 2017. doi:10.1109/icacci.2017.8126021.
- [51] Erdenebayar, Urtnasan, Yoon Ji Kim, Jong-Uk Park, Eun Yeon Joo and Kyoung-Joung Lee, "Deep Learning Approaches for Automatic Detection of Sleep Apnea Events from an Electrocardiogram." *Computer Methods and Programs in Biomedicine* 180, 105001, October, 2019. doi:10.1016/j.cmpb.2019.105001.
- [52] Vimala, V., K. Ramar, and M Ettappan, "An Intelligent Sleep Apnea Classification System Based on EEG Signals." *Journal of Medical Systems* 43, 36, January, 2019. doi:10.1007/s10916-018-1146-8.
- [53] Nakano, Hiroshi, Tomokazu Furukawa, and Takeshi Tanigawa, "Tracheal Sound Analysis Using a Deep Neural Network to Detect Sleep Apnea." *Journal of Clinical Sleep Medicine* 15, no. 08, pp.1125-1133, August, 2019. doi:10.5664/jcsm.7804.

Authors



Seo-Young Kim received a B.S. degree in the Department of Mathematics from Daegu University, Korea, in 2019. She is currently pursuing an M.S. degree in the School of Computer Science and Engineering at

Kyungpook National University. Her interests include machine learning, data mining, and data Science.



Young-Kyoon Suh is an Assistant Professor of the School of Computer Science and Engineering at Kyungpook National University (KNU), joining in 2017. Prior to coming to KNU, he was a Senior Researcher at Korea

Institute of Science and Technology Information (KISTI). He earned his Ph.D. in Computer Science from University of Arizona in 2015. His research interests lie in databases, big data, data mining, machine learning, data science, and natural language processing.