

포터블 수면유도 뉴로피드백 시스템 구현을 위한 수면뇌파 상태 분류기 성능 평가

이택

성신여자대학교 융합보안공학과 조교수

Performance evaluation of sleep stage classifier for the sleep-inducing portable neurofeedback system

Taek Lee

Assistant Professor, Department of Convergence Security Engineering, Sungshin Women's University

요 약 최근 많은 사람들이 불면증으로 인한 노동력저하, 인지기능저하, 정신질환 증가 등의 불편을 겪고 있다. 이에 대한 해결책은 인지치료나 약물치료가 거의 전부인 수준이나 부작용과 의존성 문제로 인해 장기적으로는 권장되지 않는 방법이다. 따라서 본 논문에서는 수면 유도에 도움이 되는 포터블 뇌파 측정기 기반 뉴로피드백 시스템을 제안한다. 그리고 시스템을 구현하는 데 가장 핵심적인 기능인 뇌파 상태 분류기를 설계하고 평가하며 성능에 영향을 미칠 수 있는 여러 요인들에 대해 최적화된 분류기 모델링 방법을 제시한다. 제안한 분류기를 이용할 시 포터블 뇌파 측정기에서 각성과 수면 단계를 97.9% 정확하게 구분할 수 있었다.

주제어 : 뉴로피드백, 뇌파, 분류기, 수면 유도, 기계학습

Abstract Recently, many people have suffered from insomnia, labor loss, cognitive decline, and mental illness. The solution to this problem is almost entirely cognitive therapy or medication, but it is not recommended in the long term due to side effects and dependency problems. Therefore, in this paper, we propose a neuro feedback system based on portable EEG that helps induce sleeping. We design and evaluate the EEG classifier, which is the most important function to implement the system, and propose an optimized classifier modeling method for various factors that can affect performance. When using the proposed classifier, we could distinguish 97.9% of awakening and sleep phase in portable EEG.

Key Words : neurofeedback, brainwave, classifier, sleep induction, machine learning

1. 서론

최근에 불면증을 겪는 환자수와 치료비가 빠른 속도로 증가하고 있다. 건강보험심사평가원 질병 통계 데이터를 보면 불면증으로 병원을 찾은 사람은 2016년 기준 54만2천939명을 기록하며 4년 새(2012-2016) 환자 수가 34.2%나 늘었다[1]. 불면증으로 인한 노동력저하, 인지

능저하와 수반되는 사고 및 산업재해, 의료이용증가, 다른 신체 및 정신질환 발생의 증가 등을 고려하면 그 사회적 비용은 천문학적인 수준임을 짐작 할 수 있다. 하지만 이처럼 많은 사람들이 겪는 수면 문제에 비해 이에 대한 해결책은 인지치료나 약물치료가 거의 전부인 수준으로 특히 약물치료는 의존성 문제가 심각하며 자연스런 수면 각성주기를 해치기 때문에 수면장애의 해결책이 되기 어

*This work was supported by the Sungshin Women's University Research Grant of 2018.

*Corresponding Author : Taek Lee (comtaek@sungshin.ac.kr)

Received September 16, 2018

Accepted November 20, 2018

Revised November 1, 2018

Published November 28, 2018

려운 실정이다.

따라서 본 연구에서는 불면증 개선을 위해 뇌기능 조절과 뇌 훈련을 통하여 수면을 유도하는 새로운 패러다임의 포터블 뇌파 측정기 기반의 뉴로피드백 시스템을 제안한다. 수면 전에 뉴로피드백 훈련을 통해 뇌를 명상 상태로 스스로 조절하도록 훈련함으로써 수면을 유도할 수 있는 기술이라 할 수 있다.

제안 시스템을 구현하기 위해 필요한 가장 핵심적인 기능은 피드백 타이밍을 결정하기 위해 수면 진행단계에서 관찰되는 뇌파의 상태(각성/입면/수면)를 실시간으로 분류하는 기술이다. 따라서 본 논문에서는 뇌파 상태 분류기 모델을 기계학습 알고리즘에 기반하여 설계하고 실험을 통해 평가하여 최적화된 모델을 제시하고자 한다.

2. 수면 유도 뉴로피드백 시스템 제안

본 연구에서 제안하는 수면 유도를 위한 뉴로피드백 시스템은 포터블 뇌파 측정기를 통해 일정 시간간격으로 뇌파를 수집하며 기계학습 알고리즘을 통해 뇌파의 수면 진행 상태를 실시간으로 판단하고 분류한다. 분류된 뇌파상태에 따라 입면단계(예: drowsy, shallow sleep)에서 수면에 도움이 되는 소리 자극(예: 물방울 소리, 풀벌레 소리, 심장소리, 화이트 노이즈 등)을 피험자에게 제공하며 피험자는 제공받은 뉴로피드백을 통해 스스로 수면에 진입하는 뇌파를 유도할 수 있는 훈련 기회를 갖게 된다. 이 과정에서 포터블 뇌파 측정기를 사람이 직접 착용하고 잠을 자기 때문에 겉으로는 잠을 청하는 것처럼 보이지만 잠을 청한다기 보다는 뇌 이완을 하는 것이라 할 수 있다. 소리를 통해 뇌 이완 여부를 모니터링할 수 있도록 해주기 때문에 자연스럽게 뇌의 이완을 유도할 수 있다. 이를 통해 사용자는 본인의 뇌상태가 잠에 다가가고 있음을 알게 되어 안심하게 되며 "이대로 가면 잠이 드는구나"하는 안도감을 얻게 되어 더욱 뇌이완이 증가하게 될 것이다. 이에 따라 점차 졸려오게 되며, 뇌파는 점점 수면단계로 진행되어 결국 잠에 들게 되는 것이다. 일단 깊은 잠에 들어서면 더 이상 소리 피드백은 주어지지 않는다.

본 논문의 범위는 상기 제안한 뉴로피드백 시스템을 구현하는 데 있어 핵심 기능에 해당하는 뇌파 상태 분류기 구현을 위한 기계학습 모델링으로 한정한다. 시스템 구현은 현재 진행 중이며 향후 연구 주제로 다루고자 한다.

3. 수면상태 분류기 설계

본 연구에서는 수면 뇌파 상태 분류기 설계를 위해 지도 학습 알고리즘(supervised learning)을 사용한다. 따라서 학습을 위해서는 예측하고자 하는 상태 정보(class)와 예측에 사용될 특징정보(feature)가 필요하다. 먼저 전문 의료장비(Embletta[2], multi-channel, wet sensor)와 포터블 장비(NeuroSky[3], single channel, dry sensor)를 피험자에게 동시에 착용케 하여 피험자로부터 EEG 뇌파 데이터를 수집한다. Embletta는 실험실 안에서만 이용할 수 있는 다소 복잡한 기기이기 때문에 기계학습을 위한 클래스 정보 획득에만 이용하며, 실제 뉴로피드백 시스템 실행단계에서는 NeuroSky에서 실시간으로 추출되는 EEG 데이터만 이용한다.

3.1 분류 클래스 레이블링 단계

객관적이고 신뢰할 수 있는 양질의 클래스 레이블링 데이터를 얻기 위해 Embletta 기기로부터 수집한 EEG 데이터를 수면분석 전문가가 육안으로 관독하여 수면 진행 상태에 따라 6단계(S0 - Eye Open, S1 - Wake, S2 - Arousal, S3 - N1, S4 - N2+N3, S5 - REM)로 상세 레이블링한다. 그러나 2장에서 제안한 뉴로피드백 시스템을 구현하기 위해서는 2단계 또는 3단계 기반 수면 진행상태 클래스 레이블링이면 충분하다. 따라서 포터블 기기인 NeuroSky로부터 얻어지는 EEG 데이터를 윈도우 구간별로 각성/수면 2단계 또는 각성/입면/수면 3단계로 구분하도록 한다. 2단계 클래스 레이블링(binary classification)의 경우 기계학습 알고리즘의 클래스 분류 확률 값을 이용하여 확률값이 0에 가까울수록 각성상태로 판단하고 1에 가까울수록 수면 상태로 판단하며, 0.5 근방인 경우 입면 단계로 해석 가능하다.




Fig. 1. Class labeling of NeuroSky EEG data by referring to the expert labels

예를 들어 Fig. 1은 3단계 레이블링 단계를 설명한다. NeuroSky 데이터를 전문가 상세 레이블링 정보와 같은 시간 축에 나열하여(timestamp를 이용해 시각 동기화) 단계별 판독이 가능하다. NeuroSky 뇌파 상태 레이블링 판독을 위한 기준은 전문가 분석 기준 S0 또는 S1에 해당하는 구간이라면 각성(wake) 상태로 판단하게 된다. 그리고 구간이 전문가 판독 기준 S4 또는 S5에 해당한다면 수면(sleep) 상태로 판단하게 된다. 입면(transition)은 각성상태에서 수면상태로 전이되는 상태이기 때문에 S2와 S3가 함께 관찰될 수 있으나 만약 판독 구간에서 S3가 과반 이상 관찰되면 입면 상태로 레이블링한다. 여기서 판독 구간이란 수면 진행 상태를 판독하고 아울러 특징정보를 추출하기 위해 분석 구간으로 시간 축을 따라 움직이는 일정 구간(sliding window)을 의미한다. 만약 간소화된 2단계 레이블링을 수행하는 경우는 S0 또는 S1을 각성(wake) 단계로 보고 S2-S5를 수면(sleep) 단계로 구분한다.

3.2 특징 추출 단계

EEG 데이터 수집이 완료되면 푸리에 변환(Fourier transform)을 통해 주파수분석을 시행한다. 본 연구에서는 빠른 성능의 푸리에 변환을 위해 Welch FFT(fast Fourier transform) 기법[4]을 이용한다. 피험자에 따라 데이터 수집 일시에 따라 관찰되는 주파수 파워 절대값 범위가 달라지므로 정규화 전처리 과정을 거친다. 결과적으로 Delta(0.5~4Hz), Theta(4~7Hz), Alpha(8~12Hz), Sigma(12~16Hz), Beta(12~30Hz) 대역의 주파수 스펙트럼 파워 정보를 얻는다. 이렇게 5가지 주파수 대역을 추출한 이유는 이들이 특히나 수면 단계를 분석하는 데 있어서 관련성이 크다고 알려져 있기 때문이다[5,6]

Table 1은 수면 상태 분류기 모델링을 위해 제안하는 13개 특징정보이다. 각성, 입면, 수면 단계에서 두드러지게 관찰되는 주파수 대역의 뇌파 신호에 대해 주어진 윈도우 구간에서 mean을 구하는 이유는 노이즈 필터링과 기기 착용 시 마다 시시각각 변하는 신호 편차를 고려한 대표 베이스라인 값을 특징으로 정하기 위함이다. 각성 상태에서는 각 뇌파들이 불안정한 모습(진폭이 요동침)을 보이지만 입면과 숙면 단계에 접어들면 진폭의 편차가 안정화 되는 모습을 보였다. 따라서, 각 뇌파에 대해 관찰 윈도우 구간에서 표준편차를 특징화하였다. alpha파가 줄어들고 delta파가 늘어나는 현상은 수면의 진행을

묘사하는 대표현상이라 할 수 있으므로 이들의 비율을 특징화하였다. 예를 들면 분석을 통해 눈을 감고 각성상태에 있을 때 alpha/theta 증가, alpha/delta 증가, theta/delta 증가되는 현상을 관찰하였고 입면단계에 접어들면 상대적으로 alpha/theta 감소, alpha/delta 감소, theta/delta 감소되는 현상을 관찰할 수 있었다. 특히나 입면단계에서는 alpha파가 줄어들고 점진적으로 theta파가 증가하는 현상을 관찰하였다[12]. 또한 깊은 잠에 들어가면 theta파는 줄어들고 delta파가 증가하며 반대로 얕은 잠에서는 delta파에 비해 theta파가 좀 더 크게 관찰되었다.

Table 1. The proposed features for classification

Feature	Definition
delta_mean	Mean of each delta, theta, alpha, sigma, and beta signals within the window over time
theta_mean	
alpha_mean	
sigma_mean	
beta_mean	
delta_std	Standard deviation of each delta, theta, alpha, sigma, and beta signals within the window over time
theta_std	
alpha_std	
sigma_std	
beta_std	
alpha/delta	Ratio of alpha over delta (i.e., alpha_mean divided by delta_mean)
alpha/theta	Ratio of alpha over theta (i.e., alpha_mean divided by theta_mean)
theta/delta	Ratio of theta over delta (i.e., theta_mean divided by delta_mean)

수면 상태의 진행에 따라 주도적으로 포착되는 뇌파가 있겠으나 대부분의 경우 각종 뇌파의 진폭(주파수 파워)이 매우 확정적으로 나타나지 않는다. 특히나 포터블 뇌파측정기를 이용하기 때문에 기기로부터 수집되는 EEG 데이터에 노이즈가 포함될 가능성도 크다. 따라서 특징추출을 하는 데 있어서 시간 축 상에서 특정 길이의 윈도우 내에서 EEG 데이터를 분석함으로써 안정화된 대표값을 추출할 수 있으며 동시에 이동평균(moving average) 과정을 통해 자연스럽게 노이즈 필터링과 유실 신호 보정 효과를 얻을 수 있다.

4. 분류기 성능 평가 결과

검증 단계에서 제안 분류기 모델의 성능에 영향을 줄 수 있는 다양한 조건들을 테스트하였다. 실험 시 Embletta와 NeuroSky 장비를 동시에 이용하여 12명의 피험자들로부터 EEG 데이터를 수집하였다. 피험자들에게 수면을 취할 수 있는 환경을 제공하고 약 1시간반에서 2시간 가량 데이터를 초단위로 수집하였다. 장비의 sampling rate은 Embletta의 경우 500Hz, NeuroSky의 경우 512Hz이었다. 신뢰할 수 있는 클래스 레이블링을 위해 수면분석전문가가 육아으로 수면 상태 판독을 실시하였다. 기계학습 모델 구축과 성능 평가를 위해 Weka 3.8.3 툴[7]을 이용하였다. 학습 데이터에 과적합(overfitting)되는 문제를 막고 모델의 일반화 성능 확보를 위해 10분할 교차검증(10-fold cross validation)을 실시하였다.

4.1 기계학습 알고리즘 성능 비교

어떤 지도 학습 알고리즘을 사용하는가에 따라 분류기 모델의 성능이 달라질 수 있다. 따라서 실험을 통해 알고리즘별 성능을 비교 분석하였다. 성능 비교를 위해서로 특성이 다른 대표적인 지도학습 알고리즘(Naive Bayes, Logistic Regression, Random Forest, SVM)을 선정하였다.




Fig. 2. Performance comparison of the tested learning algorithms

Fig. 2는 해당 알고리즘을 이용하여 뇌파 분류기 모델을 구축하였을 때 교차검증 과정을 거쳐 나온 성능 평가 결과이다. 평가 척도로는 Accuracy, F-Measure, ROC Area를 이용하였다. 척도는 1에 가까울수록 좋은 성능을 의미한다. Random Forest 분류기의 경우 여러 decision tree를 융합하여 만들어진 최적의 앙상블 모델이기 때문

에 성능이 높게 관찰(Accuracy = 97.9%)된 것으로 판단된다. 참고로 Fig. 2의 결과는 30초 윈도우 사이즈, 2단계 뇌파 상태 클래스 레이블링 방식을 가정한 결과이다.

4.2 특징별 분류 기여도 분석

Fig. 2의 결과를 통해 표1에서 제안한 13개의 특징이 뇌파 상태를 분류하는 데 있어서 효과적임을 입증하였다. 그렇다면 13개의 특징 중에서 어떤 특징이 특히나 뇌파 상태를 분류하는 데 더 높은 기여를 하는가에 대해 살펴보고자 한다.

Fig. 3은 각 특징의 상대적인 분류 기여도이다. 기여도 측정을 위해 gain ratio 알고리즘[8]을 이용하였다. Gain ratio 알고리즘은 decision tree 계열 알고리즘에서 특징의 기여도를 측정하는 데 이용된다. 어떤 특징이 gain ratio 값이 높으면 분류 기준으로 채택되었을 때 더 많은 인스턴스 변별력을 갖는 것을 의미한다. Fig. 3에서는 비교 시 편의를 위해 특징별 gain ratio 값을 정규화(가장 높은 gain ratio 값을 1로 보정)하였으며, 2 단계 뇌파 상태 클래스 레이블링과 30초 윈도우 사이즈를 가정하였다.

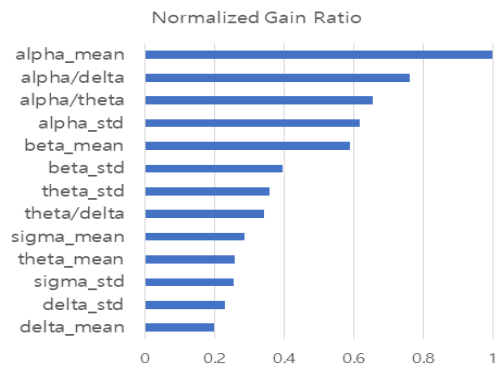


Fig. 3. Contribution of features in classification

기여도 결과를 보면 alpha파 특징이 수면상태를 구분하는데 가장 큰 영향을 미쳤다. 즉, 수면 상태 진행에 따라 alpha파의 증감이 가장 뚜렷하게 관찰되었다고 할 수 있다. 다음으로 alpha파와 delta파 또는 alpha파와 theta파의 비율이 가장 영향력 있는 특징이었다. 즉, 실험 과정에서 입면 단계가 진행될 수록 alpha파가 줄고 delta파가 증가하는 현상 또는 alpha파가 줄고 theta파가 증가하는 현상이 확연하게 나타났다는 의미로 해석된다. 반면에 delta파에 관한 특징은 상대적으로 분류 공헌도가 높지

않았다. 즉, 수면 진행 상태와 상관없이 여기저기서 변칙적으로 delta파가 관찰되었다는 의미로 해석된다.

4.3 뇌파 상태 레이블링 방식에 따른 성능 비교

앞서 언급한 바와 같이 클래스 레이블링은 예를 들어 2단계, 3단계, 6단계가 가능하다. 분류하려는 상태 클래스 레이블링의 단계를 높이면 높일수록 분류기에게는 더 큰 도전이므로 성능이 안 좋아 질 수 있다.

레이블링 방식에 따른 모델 성능 차이를 알아보기 위해 Fig. 4와 같은 성능 비교 실험을 진행하였다. 지도 학습 알고리즘으로 Random Forest를 사용하였고, 30초 윈도우 크기를 가정하였다. 레이블링 단계가 높아지면 성능이 감소하는 것을 확인 할 수 있었으나, 각성 단계에서 임전단계를 구분해야하는 뉴로피드백 시스템에게 필요한 2단계 또는 3단계 레이블링 방식에서는 그래도 상대적으로 훌륭한 성능을 내는 것을 확인할 수 있었다.

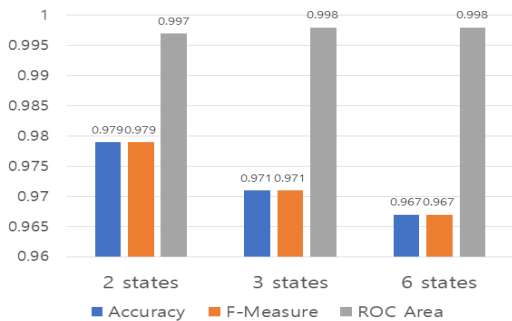


Fig. 4. Performance comparison of the different labeling approaches

4.4 윈도우 크기별 모델 성능 비교

EEG 시계열 데이터를 FFT하고 표1의 특징 추출을 하기 위해서 적절한 윈도우 크기를 선정하여야 한다. 윈도우의 크기에 따라 노이즈 필터링 효과와 뇌파 특징 안정화 효과가 달라질 수 있으므로 당연히 이는 분류기 성능에 영향을 미치게 된다. 따라서 Fig. 5와 같이 윈도우 크기 조건 변화에 따른 분류기 모델의 성능 변화를 실험하였다(단, 2단계 클래스 레이블링 방식 가정).

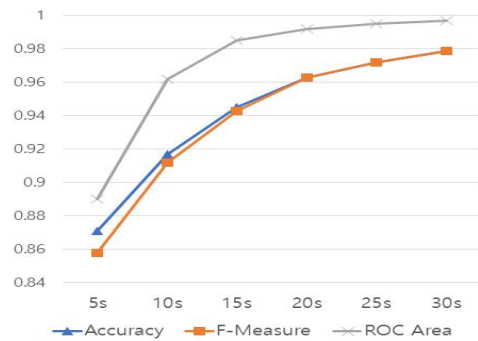


Fig. 5. Performance in the different window size

윈도우 크기를 5초에서 30초까지 변화하며 분류기 모델의 성능을 측정하였다. 과거부터 수면다원검사를 실시할 때 30초 구간으로 뇌파 판독과 기록표를 작성해온 관례[9]에 따라 최대 30초 구간까지 윈도우 크기를 변화시켜 보며 실험하였다. 결과에서 볼 수 있듯이 윈도우 크기가 크면 이동평균 효과에 의해 노이즈가 크게 감소하여 분류 모델의 성능이 증가된다. 반면 윈도우 크기가 작아지면 이동평균 효과가 떨어져 분류기가 노이즈에 취약하게 되며, 학습용 데이터 인스턴들 사이에서 특징정보의 변별력이 떨어져 결국 성능이 감소하게 된다.

높은 성능을 위해서는 윈도우 크기를 늘리는 것이 맞지만 너무 늘리면 뉴로피드백 시스템에서 꽤나 오랜시간 동안(윈도우 크기 만큼) EEG 데이터를 축적해야만 특징추출과 소리 재생 피드백이 가능해지기 때문에 그만큼 피드백 타이밍이 느려지는 단점이 생긴다. 따라서 분류 성능을 위해 막연히 긴 윈도우 크기를 고수할 수는 없다. 반면 너무 짧은 윈도우 크기를 사용하면 피드백 타이밍을 빠르게 가져갈 수는 있지만 뇌파 노이즈에 취약하기 때문에 높은 분류 성능을 기대할 수 없다. 따라서 Fig. 5의 민감도 분석 결과를 이용하여 적절한 윈도우 크기를 정할 필요가 있다. 향후에는 실제 시스템 응용 환경에서 여러 번 반복실험하여 적절한 윈도우 크기를 튜닝하는 trade-off 과정이 필요할 것이다.

4.5 전문 의료장비와 포터블 장비 성능 비교

수집 데이터의 신뢰성 확보를 위해 전문의료장비를 이용하는 것이 바람직하겠으나 본 연구에서는 수면유도를 위한 포터블 뉴로피드백 시스템을 구현하기 위해 포터블 뇌파측정기(NeuroSky)에 기반하여 뇌파 상태 분류기 모델을 구축하였다.




Fig. 6. Performance comparison between Embletta and NeuroSky (6 states, 5s window size)




Fig. 7. Performance comparison between Embletta and NeuroSky (2 states, 30s window size)

Fig. 6과 Fig. 7은 Embletta와 NeuroSky로 수집한 데이터를 기계학습하여 만든 뇌파 상태 분류기 모델의 성능을 비교한 결과이다. Fig. 6은 분류기 모델이 성능을 내기 가혹한 시나리오를 가정하여 실험한 것이고, Fig. 7은 분류기 모델이 상대적으로 성능을 내기 쉬운 시나리오를 가정하여 실험한 것이다. 당연히 두 경우에서 모두 Embletta 기반 모델이 NeuroSky 기반 모델 보다 성능이 좋게 나온다. 이는 NeuroSky의 경우 무선 포터블 뇌파 측정기이고 단일채널에 드라이 센서를 이용하기 때문이다. 그럼에도 불구하고 Fig. 7에서는 성능의 차이가 그렇게 크지 않다. 물론 Fig. 6에서와 같이 성능을 내기 어려운 악조건 상황에서는 Embletta와 NeuroSky의 성능차가 더 벌어지는 것을 확인하였다. 그러나, 본 연구에서 포터블 기기 기반 뉴로피드백 시스템을 구현하기 위해서는 6단계 레이블링과 5초 윈도우 사이즈의 실행 조건은 현실적이지 않은 과한 조건이며 오히려 Fig. 7의 실행 조건이 본 연구의 응용 목적에 더 가까운 조건이므로 NeuroSky 장비를 이용한 뉴로피드백 시스템 구현이 충분히 가능성이 있다고 판단 된다.

5. 분류기 최적화를 위한 제언

제안한 분류기 모델은 여러 가지 요소에 따라 그 성능이 좌우될 수 있다. 따라서 이 같은 요소들의 영향도를 4장에서 실험을 통하여 분석하였다. 결론적으로 최적 성능의 분류기를 도출하기 위해서는 첫째, 지도학습 알고리즘 선택이 중요하며 응용 시 사용자 그룹에 대한 편향-분산 트레이드오프(Bias-variance tradeoff) 과정이 필요하다. 둘째, 모델링에 모든 가능한 특징들을 포함시키기 보다는 성능 기여에 도움이 되는 최소 조합만을 특징 선택 과정을 통해 선별 적용한다. 셋째, 클래스 레이블링은 저단계 방식을 이용하고 분류기 출력 확률을 이용하여 사용자의 민감도에 맞는 피드백 시점을 결정한다. 넷째, 고성능을 위해 윈도우 사이즈를 대략 10초이상으로 설정(Fig. 5 참고) 하되 사용자의 피드백 반응 시간을 고려하여 분류기 확률 임계점을 0.5에서 높거나 낮게 적절히 조절한다.

6. 관련 연구

뇌파 분석을 통하여 수면상태를 자동으로 탐지하기 위한 연구가 오래전부터 진행된 바 있다. 그러나 대부분의 연구가 실험실 내에서 이루어지는 가설검증 연구이었으며, 실제로 수면유도를 위한 포터블 뉴로피드백 시스템 구현을 위한 연구는 거의 없었다. 연구 [10]에서는 단 채널을 이용하여 EEG 데이터를 수집하여 자동으로 수면의 단계를 분석하기 위한 인공지능망과 유전 알고리즘을 제안하였으나 전문의료장비의 다채널 센서를 이용하여 EEG 데이터를 수집하였고(그중 하나의 채널을 이용하여 분석), 성능에 대한 교차검증이 이루어지지 않았으며, 따라서 포터블 뉴로피드백 시스템을 구현하는 데 이용하기에는 검증되지 않은 방법으로 여겨진다. 연구 [11] 역시 인공지능망과 유전자 알고리즘의 조합으로 지도학습 모델을 구현하고 있다. 신경망 알고리즘과 유전자 알고리즘의 조합은 전반적인 최적화된 모델 도출까지 여러 세대를 반복하기 때문에 시간이 오래 걸리는 한계가 있어 실시간 뇌파 상태 분류 응용에 이용하기에는 어려움이 있다. 연구 [12]에서는 졸음운전 방지를 위해 졸음을 탐지하고 경고하기 위한 졸음 탐지 시스템을 제안하였으며 Linear Predictive Coding 계수를 기계학습을 위한 특징 정보로 이용하였다. 다채널 전문 뇌파측정기(8채널 락사

제품 PolyG-I)를 이용하였고 교차검증을 실시하지 않았기 때문에 해당 기술을 포터블 뉴로피드백 시스템에 응용하기 위해서는 추가 검증이 필요할 것으로 보인다. 아울러 연구 [13]에서는 불면장에 치료를 위한 상세한 뉴로피드백 훈련 프로토콜을 제시하였다. 베타파를 줄이고 시그마파를 유지하는 경우 편안한 음악 재생이라는 보상을 제공하는 방식을 취한다. 그러나 해당 연구는 수면 뇌파 분류 자동화 기술을 제안하는 것이 아니라 실험실 내에서 다채널의 전문 뇌파측정 기기(Procomp 5)를 이용하여 뉴로피드백 훈련 프로토콜의 효과성을 검증하기 위한 연구로서 개인차가 있는 뇌파 특성에 유연하게 기계학습하는 포터블 뉴로피드백 시스템 구현에 활용하기 힘들다. 이밖에 졸음 감지에 관한 관련 연구로 눈의 움직임이나 깜빡거림 현상, 동공의 크기 변화, 눈의 응시방향, 얼굴 표정 등을 이미지 인식을 통해 졸음 탐지하는 연구[14], 스트레스와 말초체온과의 상관관계를 분석하는 연구 [15], 졸음 현상이 올 때 심박수의 변화에 대한 분석 연구 [16], 피부 임피던스 신호분석[17] 등에 관한 연구가 있었으나 이는 뇌파 분석 기반 수면상태 분류에 보조적인 특징으로 사용될 수 있으리라 본다.

7. 결론

본 논문에서는 포터블 뇌파측정기를 이용하여 수면 유도에 도움이 되는 뉴로피드백 훈련을 할 수 있는 시스템 아이디어를 제안하였으며, 특히 수면 뇌파 상태 분류기 모델을 설계하고 성능을 검증하여 최적화된 모델을 도출하도록 하였다. 뇌파 상태 분류를 위하여 13가지 특징정보 추출 방법을 제안하였으며, 특징별 기여도를 분석하였고, 뇌파 상태 분류 정확도 평가의 신뢰성 확보를 위해 교차검증을 실시하였다. 향후에는 본 논문에서 제안한 수면 뇌파 상태 분류기를 더욱 고도화하여 불면증을 겪는 환자의 뉴로피드백 임상 연구에 적용하고자 한다.

감사의 글

본 연구를 위한 데이터 수집과 자문에 도움을 주신 고려대학교 의과대학 이현정 교수님 연구팀에 깊은 감사를 드립니다.

REFERENCES

- [1] *Yonhapnews*. (2017. 7. 12). 'Stress republic' ... "540,000 people are insomnia". www.yonhapnews.co.kr/bulletin/2017/07/11/0200000000AKR20170711142900017.HTML
- [2] *Embla Systems, Inc.* (2010). *Embletta X100.carestreammedical.com/wp-content/uploads/Carestream-Embla-Embletta-X100.pdf*
- [3] *NeuroSky* (2018). *NeuroSky Mindwave*. www.neurosky.com
- [4] Welch. P. (1967). The use of Fast Fourier Transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms. *IEEE Transactions on Audio and Electroacoustics*, AU-15 (2): 70-73
- [5] Wolpert. E. (1969). A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. *Archives of General Psychiatry*, 20(2), 246.
- [6] R. Agarwal & G. Jean. (2001). Computer-assisted sleep staging. *IEEE Transactions on Biomedical Engineering*, 48(12), 1412-1423.
- [7] *Weka 3* (2018). Data mining software in Java. www.cs.waikato.ac.nz/ml/weka/
- [8] E. Alpaydin. (2010). *Introduction to Machine Learning*, 2nd ed. Cambridge, MA, USA: The MIT Press.
- [9] A. Rechtschaffen & A. Kales. (1968). A manual of standardized terminology, techniques and scoring system of sleep stages in human subjects. *Los Angeles: Brain Information Service/Brain Research Institute, University of California*.
- [10] J. H. Jang, S. Y. Cho & B. Y. Kim. (2002). Automatic sleep stage scoring using single-channel EEG signal. *Korean Journal of Brain Science and Technology*, 2(2), 129-135.
- [11] J. E. Lee & S. K. Yoo. (2013). The design of feature selecting algorithm for sleep stage analysis. *Journal of The Institute of Electronics Engineers of Korea*, 50(10).
- [12] H. S. Han & U. P. Chong. (2012). Electroencephalogram-based driver drowsiness detection system using AR coefficients and SVM. *Journal of Korean Institute of Intelligence Systems*, 22(6).
- [13] J. E. Jeon & S. W. Choi. (2017). Insomnia treatment using neurofeedback: EEG beta decrease protocol. *Korean Journal of Clinical Psychology*, 36(3), 351-368.
- [14] Y. H. Joo, J. K. Kim & I. H. Ra. (2008). Intelligent drowsiness drive warning system. *Journal of Korean Institute of Intelligent Systems*, 18(2), 223-229.
- [15] H. Kataoka, H. Yoshida, A. Saijo, M. Yasuda & M.

- Osumi. (1998). Development of a skin temperature measuring system for non-contact stress evaluation. *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2, 940-943.
- [16] A. Bunde, S. Havlin, J. Kantelhardt, T. Penzel, J. Peter & K. Voigt. (2000). Correlated and uncorrelated regions in heart-rate fluctuations during sleep. *Phys. Rev. Lett.*, 8(85), 3736-3739.
- [17] Y. B. Lee & M. H. Lee. (2007). Automobile system for drowsiness accident detection using EDA signal analysis. *The Transactions of KIEE*, 56(2), 227-450.

이택(Lee, Taek)

[정회원]



- 2005년 2월 : 고려대학교 컴퓨터
전파통신공학과(이학석사)
- 2016년 2월 : 고려대학교 컴퓨터
전파통신공학과(이학박사)
- 2016년 2월 ~ 2017년 8월 : 고려
대학교 연구교수
- 2017년 9월 ~ 현재 : 성신여자대학교 융합보안공학과
조교수
- 관심분야 : 의료-ICT융합연구, 소프트웨어공학, 정보
보안
- E-Mail : comtaek@sungshin.ac.kr