



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원 저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리와 책임은 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)



2018년 2월
석사학위 논문

뇌파 데이터를 이용한 뉴럴 네트워크 기반의 운전자 이상상태 분석

조선대학교 산업기술융합대학원

소프트웨어융합공학과

김 지 수

뇌파 데이터를 이용한 뉴럴 네트워크 기반의 운전자 이상상태 분석

Analyzing driver's abnormalities based on neural network
using brain wave data

2018년 02월 23일

조선대학교 산업기술융합대학원

소프트웨어융합공학과

김 지 수

뇌파 데이터를 이용한 뉴럴 네트워크 기반의 운전자 이상상태 분석

지도교수 죄 준 호

이 논문을 공학석사학위신청 논문으로 제출함.

2018년 02월

조선대학교 산업기술융합대학원

소프트웨어융합공학과

김 지 수

김지수의 석사학위논문을 인준함

위원장 조선대학교 교수

김판구

(인)



위원 조선대학교 교수

신주현

(인)



위원 조선대학교 교수

최준호

(인)



2017년 11월

조선대학교 산업기술융합대학원

목 차

ABSTRACT

I. 서론	1
A. 연구 배경 및 목적	1
II. 관련 연구	3
A. 생체신호를 이용한 운전자 이상상태 분석 연구	3
B. 뇌파 분석 방법	7
1. 뇌파의 종류와 특징	7
a. 뇌파 특성 및 주파수 대역과 파형의 범위	7
b. 주파수별 뇌파의 특징	8
2. 뇌파의 분석 방법	9
C. Machine Learning 분석 기법	11
1. Deep Learning	12
2. Tensorflow Library	14
III. 뇌파 데이터를 이용한 운전자 이상상태 분석	17
A. 데이터셋	18
B. 학습 알고리즘	20
IV. 실험 및 평가	26
A. 실험 환경	26
B. 실험 방법	27
1. 뇌파 측정 및 데이터 취득	27
2. 뇌파 분석을 통한 학습 모델링 구현	33
3. 실험 평가 및 결과 분석	40
IV. 결론 및 제언	43
참고문헌	44

표 목 차

[표 2-1] 주파수 영역별 뇌파 특징	8
[표 2-2] Tensorflow 특징	15
[표 2-3] Tensorflow 기본 용어	16
[표 3-1] 정상상태 및 이상상태 데이터 취득 환경조건	18
[표 3-2] 측정된 뇌파 데이터 속성	19
[표 4-1] 데스크탑 성능	26
[표 4-2] GPU Tensorflow	26
[표 4-3] EEG Headset	27
[표 4-4] NeuroSky 주파수 분석표	29
[표 4-5] 뇌파 분석 방법과 분류 기준 정의	33
[표 4-6] 이상상태 뇌파 주파수 영역별 증감 표	34
[표 4-7] 데이터셋(1)	38
[표 4-8] 피험자 정보	38
[표 4-9] 데이터셋(2)	39
[표 4-10] 이상상태 1차 분류 성능	40
[표 4-11] 이상상태 2차 분류 성능	41
[표 4-12] 피험자들의 이상상태 분류 성능 결과	42

그 림 목 차

[그림 2-1] 대형 교통사고 원인 분석	3
[그림 2-2] 26세 남성 심전도	4
[그림 2-3] 정상 주파수(P/Q/R/S/T)	5
[그림 2-4] 운전자의 호흡 모니터링 시스템 구성도	5
[그림 2-5] 단계별 출음 그래프	6
[그림 2-6] 정상·출음 상태의 눈 깜박임 비교	6
[그림 2-7] 뇌파 주파수 대역과 파형의 범위와 종류	7
[그림 2-8] 파워 스펙트럼 결과	9
[그림 2-9] Data Flow Graph	15
[그림 2-10] 완전히 구성된 TensorBoard	16
[그림 3-1] 논문의 전체 구성도	17
[그림 3-2] CSV 형식으로 저장된 EEG Log data	19
[그림 3-3] Tensorflow Queue Runner 도식화	20
[그림 3-4] $H(x) = Wx + b$	21
[그림 3-5] The logistic function	22
[그림 3-6] $-\log(x)$, $-\log(1-x)$	24
[그림 3-7] 경사 하강법	25
[그림 4-1] Mind Wave Headset	27
[그림 4-2] 전극 부착 위치	27
[그림 4-3] EEG Headset(Mind Wave Mobile)	28
[그림 4-4] Mind Wave Mobile 작동 방식	28
[그림 4-5] 라이브러리 소스코드 순서도	30
[그림 4-6] EEG Raw-data / Data Log	30
[그림 4-7] NTx(NeuroExperimenter)	31
[그림 4-8] Theta파형 그래프	31
[그림 4-9] 분류된 파형들에 대한 막대그래프	32
[그림 4-10] 운전자 이상상태 지표 검출 모의실험	32
[그림 4-11] 시간증가에 따른 수치 증감 분석	34

[그림 4-12] 주파수 영역별 뇌파 레코드	36
[그림 4-13] Alpha1파형에 대한 증가 비교 그래프	36
[그림 4-14] Alpha2파형에 대한 감소 비교 그래프	37
[그림 4-15] Alpha2파형에 대한 평균 분포도 비교	37

ABSTRACT

Analyzing driver's abnormalities based on neural network using brain wave data

Ji Su Kim

Advisor : Prof. Jun-ho Choi, Ph.D

Department of Software

Convergence Engineering

Graduate School of Industry

Technology Convergence,

Chosun University

As the amount of automobile usage increases, carelessness of drivers incur more big traffic accidents and casualties. According to the causal analysis index of big traffic accidents, drowsiness and drinking accounts for a high percentage of causes of traffic accidents, and it is thought that the incidence of big traffic accidents is directly related to the driver's abnormal condition.

In this paper, the abnormal condition of the driver is analyzed by collecting brainwave data, and Power Spectral Analysis to quantitatively determine each vibration component in the brainwave data. Accordingly, the analyzed data are collected for learning and test data, and classify drivers' abnormal condition with high accuracy through learning modeling for drowsy driving and drunken driving by using DNN(Deep Neural Network), which is a kind of machine learning technique. In conclusion, the performance evaluation of learning modeling about the comparable subjects' data is discussed.

I. 서론

A. 연구 배경 및 목적

자동차 사용량이 증가함에 따라 교통사고 발생으로 인한 치사율은 무시할 수 없는 수준이다. 교통사고 예방을 위해 홍보활동 및 단속 범위 확대, 법적 조치 강화 방안을 통해 사고 발생 비율은 줄어들고 있으나, 아직도 교통사고 발생률과 치사율은 OECD국가 중 대한민국이 세 번째로 높은 나라에 속한다[1]. 특히 교통사고 발생 중 가장 치사율이 높은 법규 위반 사항으로 졸음과 음주 운전이 높은 비율을 차지하였다[2,3,4]. 도로교통공단의 대형교통사고 원인 분석 자료에 따르면 3명 이상 사망하거나, 20명 이상의 사상자가 발생한 사고의 44.1%가 과속과 음주에 의한 사고로 분류되어있다[3]. 교통안전공단에서 졸음운전 실태조사를 벌인 결과 10명 중 4명이 졸음운전을 경험한 것으로 조사되었고, 졸음운전 경험자의 19%는 사고를 경험한 것으로 나타났다[2].

이에 따라, 자동차 선진국에서는 국가적인 차원에서 기술 개발 및 제품화를 촉진하는 차세대 자동차 핵심 기술인 지능형 자동차에 대한 기술들이 연구되고 있다. 현재 기술력은 첨단 운전자 보조 시스템(ADAS : Advanced Driver Systems)으로 다양한 센서를 통해 주행 환경을 인식하고, 사물 인식 알고리즘의 정밀 분석 결과를 기반으로 주행 중 운전자에게 경고하거나, 자동(반자동) 통제하는 것이 가능하다[5]. 보고된 운전자 보조 애플리케이션으로는 충돌 경고, 교통표지 모니터, 차선 이탈 경고, 첨단 차선안내, 보행자 경고, 야간 식별, 적응형 순항제어, 충돌예방 경고 정도이다[6]. 더 나아가 자동차의 사고를 방지해주거나 사고의 피해를 줄여줌으로써 교통사고로 인한 개인적, 사회적 손실을 크게 감소시키는 효과를 얻을 수 있는데 초점을 두고 산업체, 연구소, 대학 간의 산·학·연 협동 관계를 구축하여 기술을 확보하고, 대학의 관련 인력 양성을 통한 기업 연구 활동의 연속성 확보가 중요하다는 방향성을 강조하고 있다[7].

연구소와 대학 간의 대표적인 연구 방법으로는 영상처리 기법과 생체신호를 이용한 연구들이 활발히 진행되어지고 있다. 영상처리 기법을 이용한 연구 방법으로는 차선이탈경고 및 운전자 행동패턴 분석, 안구 개폐, 눈꺼풀 움직임과 같이 얼굴

특정 점 기반의 감지 시스템들이 있다[8,9,10,11]. 운전자의 편의를 위해 비접촉식이라는 장점이 있지만 상황인지 후 즉각 조치가 어려운 위급한 상황에서는 운전자의 안전에 크게 영향을 끼치지 못한다는 단점이 존재한다. 생체신호를 이용한 연구 방법으로는 뇌파(Electroencephalogram, EEG), 심전도(Electrocardiogram, ECG), 근전도(Electromyogram, EMG), 피층 전기반응(Galvanic skin response, GSR) 등을 측정하여 변하는 사람의 생체신호를 분석하여 이상상태를 검출하는 방법으로 가장 높은 정확도와 객관성을 가진다[12].

본 논문에서는 운전자의 피로와 졸음에 따른 변화를 판별하는 방법에 생체신호 중 뇌파(EEG)가 효과적이라는 의학적 연구결과를 바탕으로 연구를 진행하고자 한다[13]. 피험자들의 뇌파 데이터를 취득하여 얻은 Raw data에서 Power spectrum 분석을 통해 분류된 각각의 파형들은 운전자의 일반적인 상태 및 운전자 이상상태(졸음, 음주)에 대한 데이터를 갖는다. 데이터는 초당 512번의 원시데이터가 파형의 형태로 기록되는 수치를 대략 1초에 한번 저장하는 값들로, 측정자의 상태에 따라 증감 수치를 보인다. 뇌파 주파수 영역별 특징과 연구 자료를 토대로 측정된 데이터에 대한 분석을 통해 이상상태에 대해 정의하고, 학습에 필요한 데이터의 증감 형태를 정의한다. Training data set과 Testing data set으로 분류하고, 분류된 데이터를 Machine learning의 일종인 Deep learning을 이용하여 복잡한 자료들 속에서 핵심적인 내용과 기능을 학습한다. 학습 모델을 통해 높은 정확도로 분류해 낼 수 있도록 하는 방법이며 이를 제안하기 위해 다음과 같은 구성으로 작성되었다. 학습 모델을 통해 연구의 성능을 평가 및 분석하기 위한 방법이며, 구성은 다음과 같다.

2장에서는 본 연구와 같은 목적성을 가진 연구 진행 과정들에 관해 서술 하며, 기본 배경이 되는 뇌파와 기계학습에 대해 서술한다.

3장에서는 뇌파 데이터를 이용한 운전자 이상상태 분석 방법으로 데이터 셋을 구성하는 방식과 사용된 학습 알고리즘에 대해 서술한다.

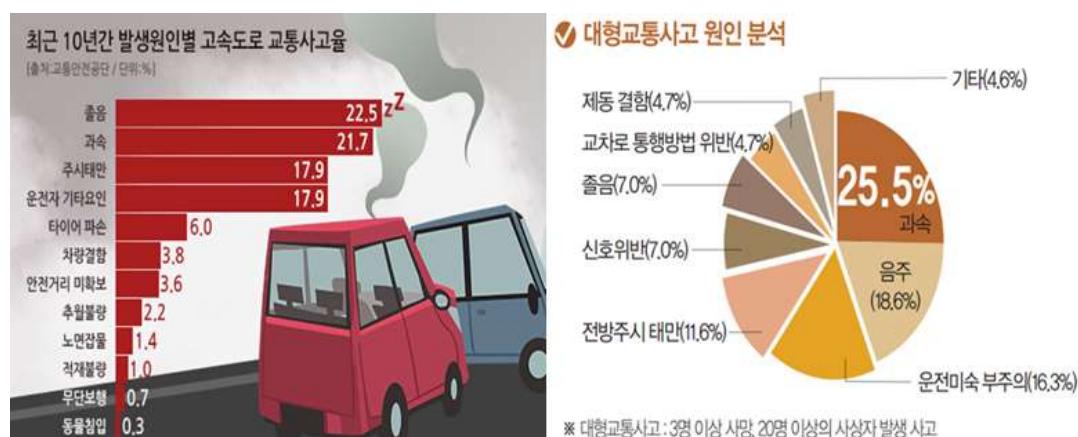
4장에서는 본 연구를 위한 실험 환경과 실험 방법을 기술하며, 테스트 데이터를 이용하여 모델링의 정확도를 평가하고 결과를 분석하여 서술한다.

마지막으로 5장에서는 결론과 향후 연구에 관해 서술하며 마무리한다.

II. 관련 연구

A. 생체신호를 이용한 운전자 이상상태 분석 연구

자동차 사용량이 증가하면서 대형교통사고에 대한 사고사례가 점차 증가 되었고, [그림 2-1]과 같이 사고 발생원인 분석 그래프를 통해 확인하였다. 운전자 이상상태에 대한 원인이 대형교통사고와 직접적인 관련이 있다고 판단되었으며, 기존 관련연구에서는 졸음에 관한 연구가 주를 이루고 있다.

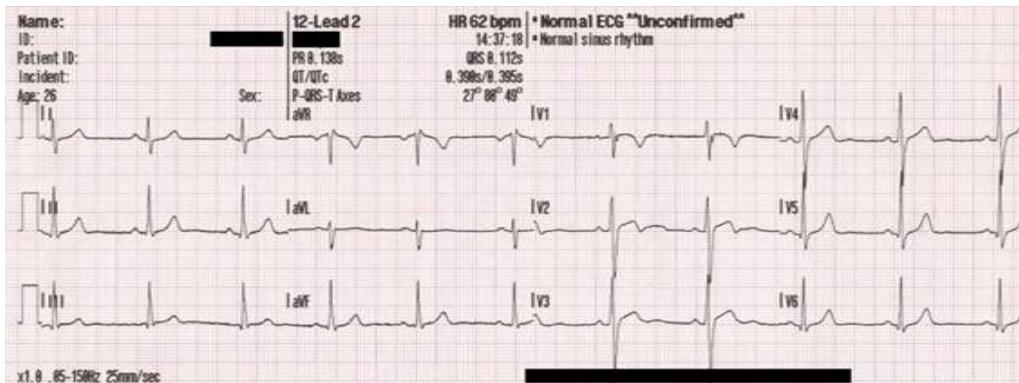


[그림 2-1] 대형교통사고 원인 분석(출처 : 교통안전공단 / 도로교통공단)

서론에서 언급 한 바와 같이, 영상처리를 이용한 방법과 생체신호를 이용한 방법이 대표적이며, 운전자의 이상상태를 분류해 내는데 여러 방면으로 연구가 진행되고 있다. 비접촉식 장점을 이용한 영상처리 기반의 연구들 중 차선 검출과 같은 차량에 설치된 카메라를 이용하여 운전자 보조 시스템이라는 명목으로 제품화되어 차량에 적용된 사례들이 있다[6]. 그러나 졸음을 판단하는 중요한 단서로는 운전자의 얼굴의 변화 중 눈과 눈꺼풀의 움직임이 중요한 단서가 되며 패턴을 감지하기 위해 얼굴 검출 알고리즘을 이용하고, 수평 투영 히스토그램을 이용하여 눈의 위치를 찾는다. 눈의 깜박임을 검출하기 위해 수직 투영 히스토그램을 이용하지만, 운전자의 정면 응시 경우에만 해당이 된다. 또한 속면으로 인한 정면 응시가 불가능

한 상태나 운전자의 안구가 개안 된 상태에서의 졸음으로 인해 운전자가 없는 것과 다름없는 차량이 불과 2~3초만의 시간에 대형교통사고로 이어진다. 이러한 연구 방법들은 사고를 미연에 방지하기 어려울뿐더러, 즉각적인 대응도 어렵다[10,11]. 따라서 본 논문에서는 높은 정확도와 객관성을 가지는 생체신호를 이용한 방법으로 연구를 진행했으며, 이에 관련된 연구들을 서술하고자 한다.

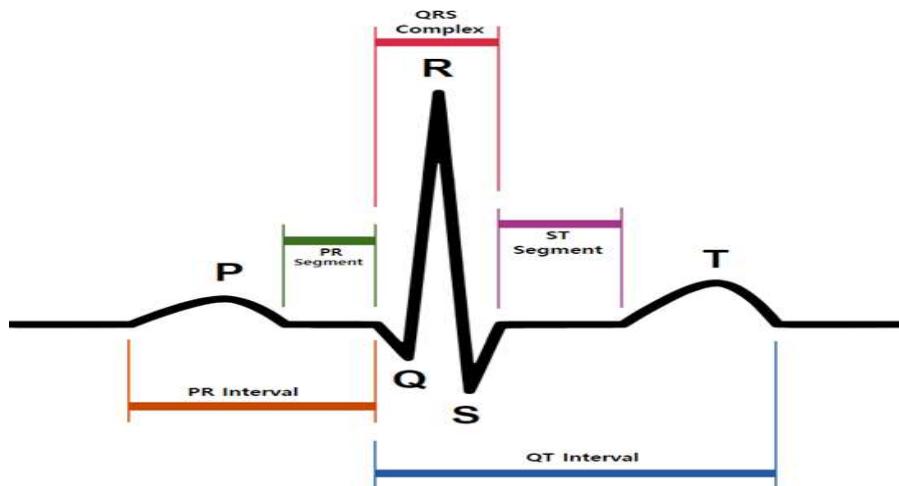
생체신호를 이용한 운전자 이상상태 정보 분석으로는 외부자극에 대하여 발생하는 중추신경계, 특히 인간의 감성에 따르는 자율신경계와 연관이 많은 생체신호인 뇌파(EEG), 심전도(ECG), 피증 전기 반응(GSR), 호흡과 압력센서 기반의 연구들이 진행되고 있다. 그중, 심전도는 심장의 비정상적인 리듬을 측정하고 진단하는 가장 좋은 방법이다. 심전도장비는 심근이 각 심장박동마다 탈분극을 할 때, 피부에서 감지되는 미세한 전기 신호를 검출하고 증폭시키는 장치이며, 휴식기에 각 심근 세포들은 음전하를 띠고 있고, 이것을 막전위라고 부른다. 이 음전하는 Na^+ and Ca^{++} 과 같은 양이온의 유입 때문에 0을 향해 감소하고, 이것을 탈분극이라고 하며 수축하게 만든다. 각각의 심박동안, 건강한 심장은 동방결정에서 나온 신호로부터 심실 전체로 퍼져나가는 질서 있는 탈분극 과정을 가진다. 두 개의 전극에 의해서 감지되는 작은 전압의 과정은 곡선의 형태로 [그림 2-2]와 같이 스크린이나 종이에 나타난다. 이 과정이 전체적인 심장의 리듬을 나타내어 준다[14].



[그림 2-2] 26세 남성 심전도

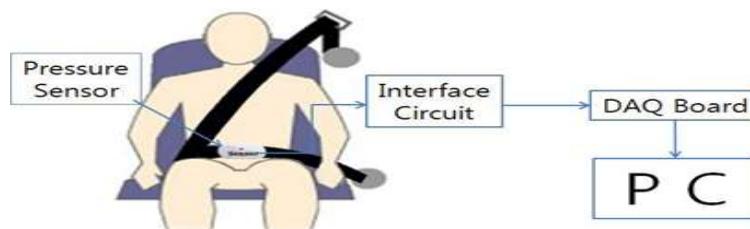
정상적인 부비동 리듬의 심전도는 [그림 2-3]과 같다. 연속적인 P/Q/R/S/T파로 구성되어 있으며, 졸음 측정은 주로 R파(R-peak) 검출 분석을 통한 심박변이도의 시간 영역과 주파수 영역을 해석하여 판단한다.

졸음이나 수면은 상대적으로 부교감 신경계가 활성화되면서 에너지를 비축하는 상황이므로 졸릴수록 LF(Low Frequency)와 HF(High Frequency)의 비율은 감소하게 된다. 이 정보를 토대로 운전자 이상상태 감지에 응용되어 연구가 진행된다 [15,16,17].



[그림 2-3] 정상 주파수(P/Q/R/S/T파)

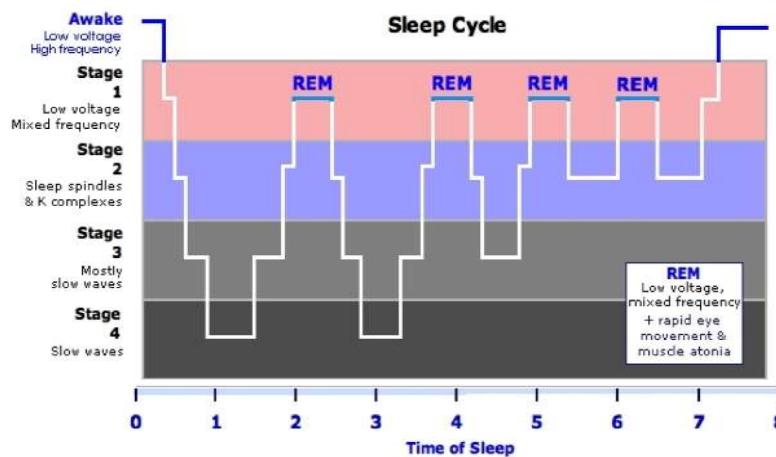
다음은 생체신호 중 호흡에 변화를 감지한 연구이다. 인간의 호흡 신호를 측정하기 위해 여러 종류의 호흡센서가 개발 되었다[18,19]. [그림 2-4]는 운전자의 호흡 모니터링 시스템에 대한 구성도이며, 연구자들은 압력이 크면 클수록 저항 값이 작아지는 특성을 가지는 유형의 압력센서를 사용하여 운전자의 호흡을 측정하였다.



[그림 2-4] 운전자의 호흡 모니터링 시스템 구성도

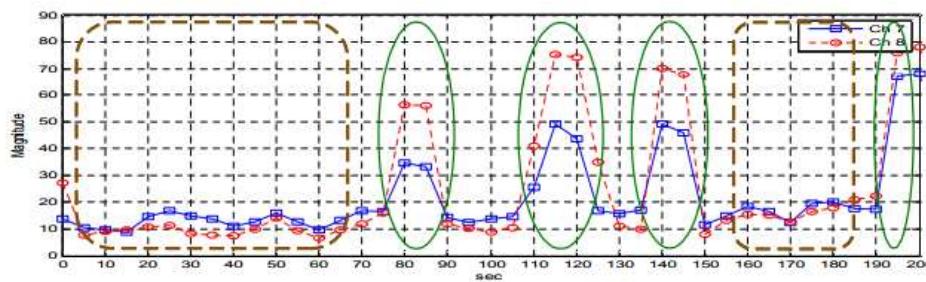
운전자의 들숨이 안전벨트에 작은 압력을 인가하기 때문에 증가하고, 날숨이 안전벨트에 큰 압력을 인가하기 때문에 저항 값이 감소되는 신호들을 얻고, 데이터

가공을 통해 [그림 2-5]와 같이 신호를 분류한다. 이러한 과정을 통해 호흡을 기반으로 각성 상태와 수면 상태를 구분할 수 있으며 호흡을 기반으로 하여 운전자의 졸음도 감지 할 수 있다는 연구이다[20].



[그림 2-5] 단계별 졸음 그래프

마지막으로 뇌파의 알파파 분석을 이용한 개안 상태 졸음 검출에 관한 연구내용으로 피험자의 개안 상태의 졸음을 검출하기 위한 방법을 제안하였다. 정상상태와 졸음상태에서 가장 큰 차이를 보이는 알파파에 초점을 맞추어 진행하였으며, 개안 상태와 졸음 상태는 서로 알파파의 변화가 상반된 경향을 보였다고 기술하고 있다. [그림 2-6]과 같이 정상상태와 졸음상태에서의 눈 깜박임을 비교하여 개안 상태에서의 졸음을 검출하고 비율을 확인한 결과 전체의 27.41%의 비중을 차지하였다는 결론을 기술하였다[21].



[그림 2-6] 정상·졸음 상태의 눈 깜박임 비교

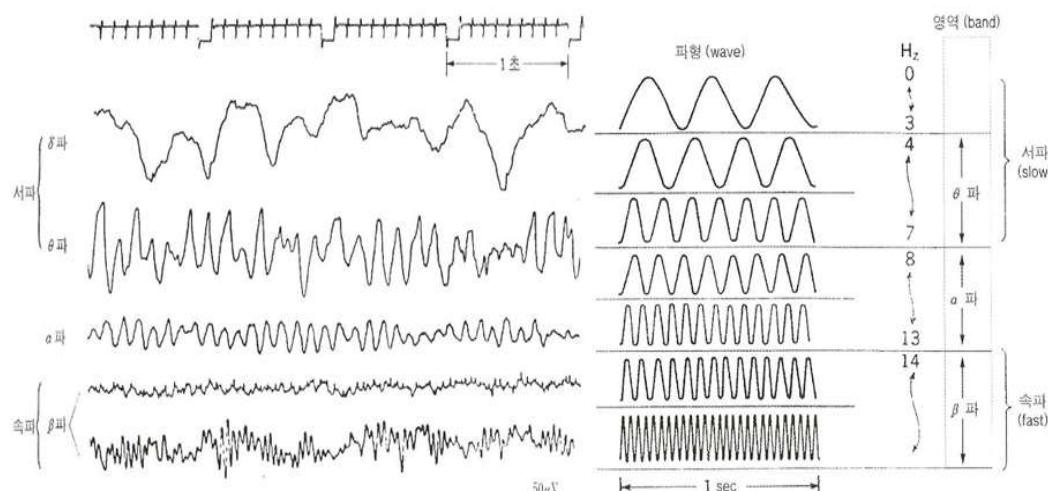
B. 뇌파 분석 방법

1. 뇌파의 종류와 특징

뇌파(Brain wave) 또는 뇌전도(Electroencephalography, EEG)는 신경계에서 뇌 신경 사이에 신호가 전달될 때 생기는 전기의 흐름이다. 심신의 상태에 따라 각각 다르게 나타나며 뇌의 활동 상황을 측정하는 가장 중요한 지표이다. 뇌의 전기적 활동에 대한 신경생리학적 측정방법으로 두피에 부착한 전극을 통해 기록한다. 뇌전도는 다른 종류의 뇌 영상화 시스템과 함께 사용할 수 있다[22].

a. 뇌파 특성 및 주파수 대역과 파형의 범위

인간의 뇌에서 나오는 뇌파의 파장은 기본적으로 0~30Hz의 주파수가 나오며 약 20~200 μ V의 진폭을 보인다. 델타, 세타, 알파, 베타, 감마파는 편리상 임의적으로 분류한 뇌파의 주파수 영역이다. [그림 2-7]에서와 같이 알파파를 기준으로 해서 알파파 보다 주파수가 낮은 델타, 세타파를 서파(slow wave), 알파파 보다 주파수가 높은 베타파를 속파(fast wave)라고 일반적으로 말한다. 어떤 연구자들은 Low 알파, Middle 알파, High 알파 등 더욱 세분화하여 분석하기도 한다[22].



[그림 2-7] 뇌파 주파수 대역과 파형의 범위와 종류

b. 주파수별 뇌파의 특징

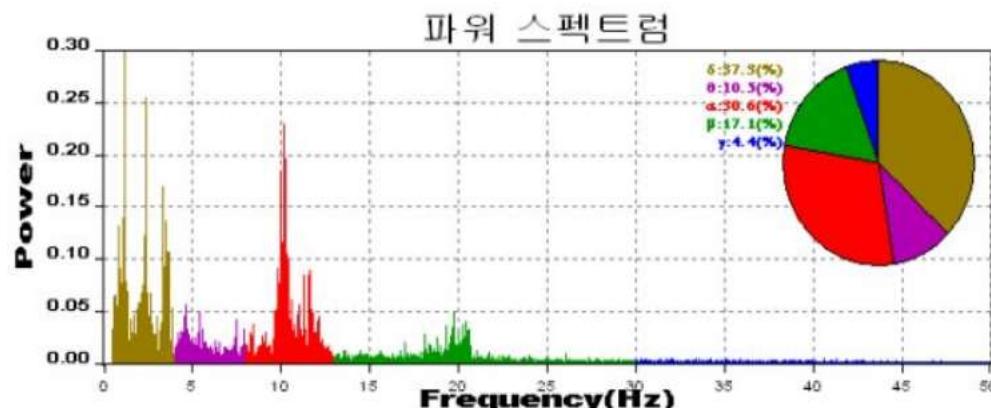
뇌파의 주파수 영역을 나누어 분류된 각각의 특성에 대해, 주파수 영역과 의식 상태 및 심신의 상태, 특성에 대해 [표 2-1]에 일괄적으로 정리하였다.

[표 2-1] 주파수 영역별 뇌파 특징

뇌파 구분	주파수	의식	심신의 상태
감마파	30 ~ 50Hz	외적의식	불안 / 흥분 / 각성
베타파	13 ~ 30Hz	외적의식	평상시의 뇌파 외계와 대응하여 긴장상태에서 일을 처리하고 있는 상태, 사고를 하며, 활동적인 상태에서 집중력 유지
페스트 알파	12 ~ 13Hz	내적의식	주의 집중과 약간의 긴장
미들알파	10 ~ 12Hz		공부능률 향상, 정신통일 상태, 기억력과 집중력 최대 상태, 스트레스 해소
슬로우 알파	8 ~ 9Hz		명상, 무념 명상, 편안한 상태에서 외부 집중력이 느슨한 상태
세타파	4 ~ 8Hz	내적의식	졸음 상태, 얕은 수면, 초능력 발휘할 때의 뇌파
델타파	0.5 ~ 4Hz	무의식	깊은 수면, 뇌 이상상태

2. 뇌파의 분석 방법

뇌파는 매우 복잡한 패턴으로 진동하는 파형 형태로 보인다. 따라서 뇌파 파형 그대로를 시각적으로 관찰하는 것은 그다지 유용하지 않다. 흔히 뇌파를 관찰할 때 주파수에 따라 분류하는 파워 스펙트럼 분석을 이용한다. 파워 스펙트럼 분석은 뇌파가 특정 주파수로 진동하는 단순 진동들의 선형적 결합이라고 가정하고, 이 신호에서 각각의 주파수 성분을 분해하여 그 크기(또는 파워)를 표시한 것이다. 파워 스펙트럼을 이용한 뇌파의 종류는 뇌파를 관찰할 때 그 주파수와 진폭에 따라 분류할 수 있다. 파워 스펙트럼 분석 결과는 [그림 2-8]과 같이 어떤 진동성분이 어느 정도의 비중으로 출현하고 있는지를 막대그래프 형식으로 표현해 준다. 그림에서 수평축은 진동의 빠르기를 나타내는 주파수 값(단위:Hz)이며, 수직방향의 막대 그래프 높이는 해당 주파수 성분이 출현한 정도를 나타내는 파워 값(단위: μV^2)이다. 델타, 세타, 알파, 베타, 감마 영역은 차례로 적록색, 보라색, 빨강색, 초록색, 파랑색 막대그래프들로 표시되어 시각적으로 해당 영역이 쉽게 구분된다.



[그림 2-8] 파워 스펙트럼 결과

이때 해당 영역에 속하는 막대그래프 높이의 합을 해당 영역의 절대파워 (Absolute Power)라고 부르며, 절대파워 분석 시 주로 절대델타파워, 절대세타파워, 절대알파파워, 절대베타파워, 절대감마파워 분석 변수를 사용한다.

전체 영역에 대한 해당 영역의 진동성분이 출현한 상대적인 비율을 나타내는 값을 상대파워(Relative Power)라 하며, 정량적인 상대파워 분석 시 상대델타파워, 상

대세타파워, 상대알파파워, 상대베타파워, 상대감마파워 분석 변수들을 사용한다. 상기 파워 스펙트럼 결과 그림에서 파이그래프 부분은 각 영역별 상대파워가 백분율(%)로 표시된 것이다. 특정상태의 뇌파특징을 분석하고자 하는 연구자들은 0~50 Hz의 각 주파수 성분에 대한 파워의 분포를 전체적으로 보여주는 파워 스펙트럼 분포를 먼저 관찰한 후, 유의미하게 변하는 주파수 성분을 찾아 의미를 부여하기도 한다. 이러한 파워 스펙트럼 분포는 머리표면의 각 측정 부위마다 조금씩 다른 양상을 나타낸다[22].

밴드 패스 필터(Band-pass filter)를 이용하는 방법으로는 입력된 여러 주파수 성분 중 원하는 주파수만 통과시키고 나머지는 감쇄시켜 버리는 역할을 한다. 뇌를 취득할 때 불필요한 잡음을 제거하더라도 주파수 성분을 분석하기 위해서는 필요한 주파수 영역만을 검출해야 한다. 이에 필요한 필터가 저역 필터(low-pass filter)와 고역 필터(high-pass filter)의 조합으로 만들 수 있는 대역 필터 또는 밴드 패스 필터이다. 이 필터는 특정 주파수 사이의 신호만 통과시키는 필터이므로 특정 지표를 검출해 낼 때 유용하다.

기타 분석 방법으로는 주파수 영역에서의 뇌파 분석법으로 사건 관련 진동(event-related oscillations), 자기회기모델(Autoregressive Model), 칼만 필터(Kalman Filter), 제약된 독립성분분석(Constrained ICA) 등이 있다[23].

C. Machine Learning 분석 기법

1959년, 아서 사무엘은 기계학습을 “기계가 일일이 코드로 명시하지 않은 동작을 데이터로부터 학습하여 실행할 수 있도록 하는 알고리즘을 개발하는 연구 분야”라고 정의하였다. 인공 지능의 한 분야로, 컴퓨터가 학습할 수 있도록 하는 알고리즘과 기술을 개발하는 분야를 말한다. 가령, 기계 학습을 통해서 수신한 e-mail이 스팸인지 아닌지를 구분 할 수 있도록 훈련할 수 있다. 기계학습의 핵심은 표현(Representation)과 일반화(Generalization)에 있다. 표현이란 데이터의 평가이며, 일반화란 아직 알 수 없는 데이터에 대한 처리이다. 즉, 훈련 데이터(Training Data)를 통해 학습된 알려진 속성을 기반으로 예측에 초점을 두고 있다는 것이다. 이는 전산 학습 이론 분야이기도 하다. 다양한 기계 학습의 응용이 존재하며, 문자 인식은 이를 이용한 가장 잘 알려진 사례이다[24].

본 논문에서는 기계학습의 한 분야인 딥 러닝(Deep learning)을 이용하여 실험을 진행 하며, 정의에 대해 서술한다. 딥 러닝, 심층학습은 여러 비선형 변환기법의 조합을 통해 높은 수준의 추상화(Abstractions, 다양한 데이터나 복잡한 자료들 속에서 핵심적인 내용 또는 기능을 요약하는 작업)를 시도하는 기계학습 알고리즘의 집합으로 정의되며, 큰 틀에서 사람의 사고방식을 컴퓨터에게 가르치는 기계학습의 한 분야라고 이야기 할 수 있다. 어떠한 데이터가 있을 때 이를 컴퓨터가 알아들을 수 있는 형태로 표현하고 이를 학습에 적용하기 위해 어떻게 하면 더 좋은 표현기법을 만들고, 이것들을 학습할 모델을 만들지에 대해 많은 연구들이 진행되고 있으며, 이러한 노력의 결과로 DNN(Deep Neural Networks), CNN(Convolutional Neural Networks), RNN(Recurrent Neural Network)등 과 같은 다양한 딥러닝 기법들이 컴퓨터 비전, 음성인식, 자연어처리, 음성/신호처리 등의 분야에 적용되어 최첨단의 결과들을 보여주고 있다. 딥 러닝이 부활하게 된 이유는 크게 세 가지로 꼽힌다. 첫 번째는 기존 인공신경망 모델의 단점이 극복되었다는 점이다. 두 번째는 하드웨어의 발전으로 인해, 강력한 GPU가 딥 러닝에서 복잡한 행렬 연산에 소요되는 시간을 크게 단축시켰다. 마지막으로 가장 중요한 세 번째는 빅 데이터를 들 수 있다. 대량으로 쏟아져 나오는 데이터들, 그리고 그것을 수집하기 위한 노력 모두가 종합되고 분석 되어 학습에 이용될 수 있다는 이유이다[25].

1. Deep Learning

Deep Learning 알고리즘의 종류는 대표적으로 쓰이는 세 가지 알고리즘을 기반으로 계속 늘어나고 있으며, 기본이 되는 DNN, CNN, RNN에 대해 서술한다.

심층 신경망(DNN - Deep Neural Network)은 입력 층(Input layer)과 출력 층(Output layer) 사이에 여러 개의 은닉층(Hidden layer)들로 이루어진 인공신경망(Artificial Neural Network, ANN)이다[26,27]. 심층 신경망은 일반적인 인공신경망과 마찬가지로 복잡한 비선형 관계(Non-linear relationship)들을 모델링 할 수 있다. 예를 들어, 사물 식별 모델을 위한 심층 신경망 구조에서는 각 개체가 이미지 기본 요소들의 계층적 구조으로 표현될 수 있다[28]. 이때, 추가 계층들은 점진적으로 모여진 하위 계층들의 특징들을 규합시킬 수 있다. 심층 신경망의 이러한 특징은, 비슷하게 수행된 인공신경망에 비해 더 적은 수의 유닛(Unit, node)들만으로도 복잡한 데이터를 모델링 할 수 있게 해준다[26].

심층 신경망은 표준 오류역전파 알고리즘으로 학습될 수 있다. 이때, 가중치(Weight)들은 식 (1)을 이용하여 확률적 경사 하강법(Stochastic gradient descent)을 통하여 갱신 될 수 있다.

$$\Delta w_{ij}(t+1) = \Delta w_{ij}(t) + \eta \frac{\partial C}{\partial w_{ij}} \quad (1)$$

식 (1)에서, η 은 학습률(Learning rate)을 의미하며, C 는 비용함수(cost function)를 의미한다. 비용함수의 선택은 학습의 형태(지도 학습, 자율 학습, 강화 학습 등)와 활성화 함수(Activation function) 같은 요인들에 의해서 결정된다. 예를 들면, 다중 클래스 분류 문제(Multiclass classification problem)에 지도 학습을 수행할 때, 일반적으로 활성화함수와 비용함수는 각각 softmax함수와 교차 엔트로피 함수(Cross entropy function)로 결정된다. softmax 함수는 식 (2)로 정의 된다.

$$p_j = \frac{\exp(x_j)}{\sum_k \exp(x_k)} \quad (2)$$

이때, p_j 는 클래스 확률(Class probability)을 나타내며, x_j 와 x_k 는 각각 유닛 j 로의 전체 입력(Total input)과 유닛 k 로의 전체 입력을 나타낸다. 교차 엔트로피는 식 (3)으로 정의된다. 이때, d_j 는 출력 유닛 j 에 대한 목표 확률(Target probability)을 나타내며, p_j 는 해당 활성화함수를 적용한 이후의 j 에 대한 확률 출력(probability output)이다[29].

$$C = - \sum_j d_j \log(p_j) \quad (3)$$

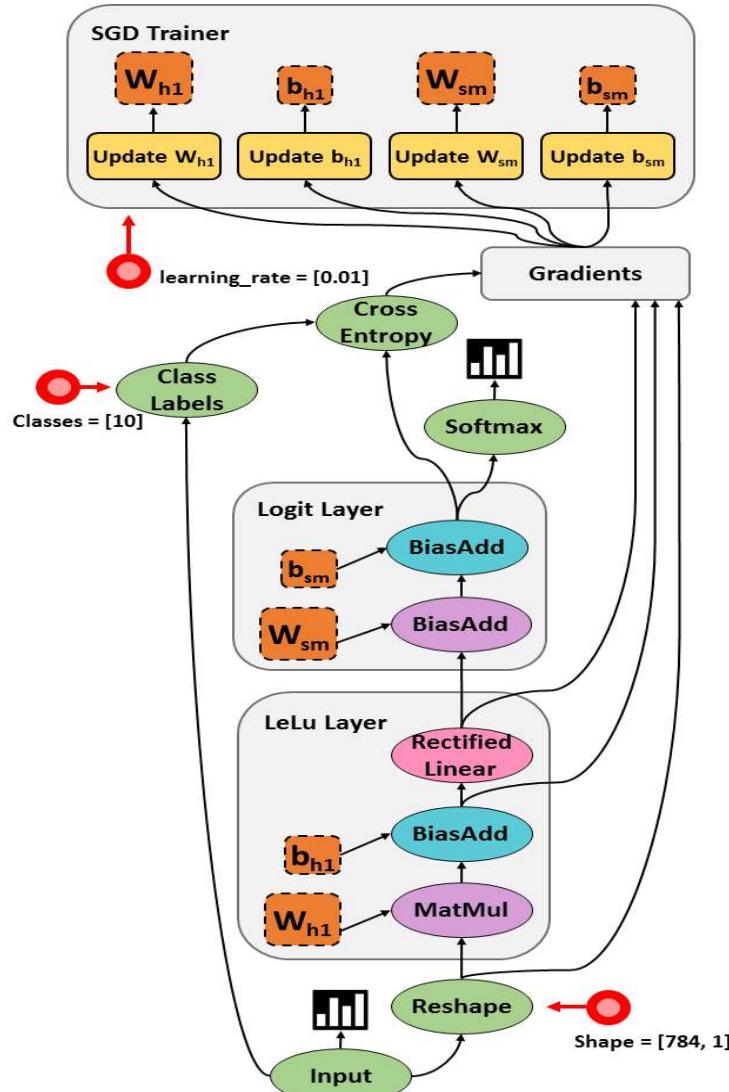
합성곱 신경망(CNN - Convolutional Neural Network)은 최소한의 전처리(Preprocess)를 사용하도록 설계된 다계층 퍼센트론(Multilayer perceptrons)의 한 종류이다. CNN은 하나 또는 여러 개의 합성곱 계층과 그 위에 올려 진 일반적인 인공 신경망 계층들로 이루어져 있으며, 가중치와 통합 계층(Pooling layer)들을 추가로 활용한다. 이러한 구조 덕분에 CNN은 2차원 구조의 입력 데이터를 충분히 활용할 수 있다. 다른 딥 러닝 구조들과 비교해서, CNN은 영상, 음성 분야 모두에서 좋은 성능을 보여준다. CNN은 또한 표준 역전달을 통해 훈련될 수 있다. CNN은 다른 피드포워드 인공신경망 기법들보다 쉽게 훈련되는 편이고 적은 수의 매개 변수를 사용한다는 이점이 있다. 최근 딥 러닝에서는 합성곱 심층 신경망(Convolutional Deep Belief Network, CDBN)가 개발되었는데, 기존 CNN과 구조적으로 매우 비슷해서, 그림의 2차원 구조를 잘 이용할 수 있으며 그와 동시에 심층 신경망(Deep Belief Network, DBN)에서의 선 훈련에 의한 장점도 취할 수 있다. CDBN은 다양한 영상과 신호 처리 기법에 사용될 수 있는 일반적인 구조를 제공하며, CIFAR와 같은 표준 이미지 데이터에 대한 여러 벤치마크 결과에 사용되고 있다[30].

순환 신경망(RNN - Recurrent Neural Network)은 인공신경망을 구성하는 유닛 사이의 연결이 Directed cycle을 구성하는 신경망을 말한다. 순환 신경망은 앞 먹임 신경망과 달리, 임의의 입력을 처리하기 위해 신경망 내부의 메모리를 활용할 수 있다. 이러한 특성에 의해 순환 신경망은 필기체 인식(Handwriting recognition)과 같은 분야에 활용되고 있고, 높은 인식률을 나타낸다[31]. 순환 신경망을 구성할 수

있는 구조에는 여러 가지 방식이 사용되고 있다. 완전 순환망(Fully Recurrent Network), Hopfield Network, Elman Network, Echo state network(ESN), Long short term memory network(LSTM), Bi-directional RNN, Continuous-time RNN(CTRNN), Hierarchical RNN, Second Order RNN 등이 있다. 순환 신경망을 훈련(Training)시키기 위해 대표적으로 경사 하강법, Hessian Free Optimization, Global Optimization Methods 방식이 쓰이고 있다. 하지만 순환 신경망은 많은 수의 뉴런 유닛이나 많은 수의 입력 유닛이 있는 경우에 훈련이 쉽지 않은 스케일링 이슈를 가지고 있다[25].

2. Tensorflow Library

Tensorflow는 기계학습과 딥 러닝을 위해 구글에서 만든 Machine Intelligence 용 오픈소스 소프트웨어 라이브러리이다. 데이터 플로우 그래프(Data Flow Graph) 방식을 사용하였고, 수학 계산과 데이터의 흐름을 노드(Node)와 엣지(Edge)를 사용하여 [그림 2-9]와 같이 방향 그래프(Directed Graph)로 표현한다. 노드는 수학적 계산, 데이터 입/출력, 그리고 데이터의 읽기/저장 등의 작업을 수행한다. 엣지는 노드들 간 데이터의 입출력 관계를 나타내며, 동적 사이즈의 다차원 데이터 배열(텐서)을 실어 나르는데, 여기에서 Tensorflow라는 이름이 지어졌다. 텐서(Tensor)는 과학과 공학 등 다양한 분야에서 이전부터 쓰이던 개념으로 수학에서는 임의의 기하 구조를 좌표 독립적으로 표현하기 위한 표기법으로 알려져 있지만, 분야마다 조금씩 다른 의미로 사용된다[32,33,34]. Tensorflow는 unix계열 OS(Linux / Mac OSX)만 지원하므로 본 논문에서는 실험을 위해 Window10 환경에서 Anaconda 가상 머신을 이용하여 사용하도록 한다. Tensorflow의 특징은 [표 2-2]에 정리되어 있으며, 기본 용어 정리는 [표 2-3]과 같다. 마지막으로 TensorBoard에 대해 서술하며 마무리한다.



[그림 2-9] Data Flow Graph

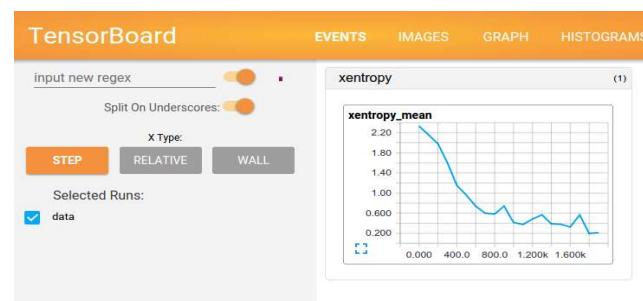
[표 2-2] Tensorflow 특징

Tensorflow 특징	
데이터 플로우 그래프를 통한 풍부한 표현력	
코드 수정 없이 CPU/GPU 모드로 동작	
아이디어 테스트에서 서비스 단계까지 이용 가능	
계산 구조와 목표 함수만 정의하면 자동으로 미분 계산을 처리	
Python/C++를 지원하며, SWIG를 통해 다양한 언어 지원 가능	

[표 2-3] Tensorflow 기본 용어

용어	설명
오퍼레이션 (Operation, op)	-그래프 상의 노드는 오퍼레이션으로 불린다. -오퍼레이션은 하나 이상의 텐서를 받을 수 있다. -오퍼레이션은 계산을 수행하고, 결과를 하나 이상의 텐서로 반환 할 수 있다.
텐서 (Tensor)	-내부적으로 모든 데이터는 텐서를 통해 표현된다. -텐서는 일종의 다차원 배열로, 그래프 내의 오퍼레이션 간에는 텐서만이 전달된다.
세션 (Session)	-그래프를 실행하기 위해서는 세션 객체가 필요하다. -세션은 오퍼레이션의 실행 환경을 캡슐화한 것이다.
변수 (Variables)	-변수는 그래프의 실행 시, 파라미터를 저장하고 갱신하는데 사용된다. -메모리상에서 텐서를 저장하는 버퍼 역할을 한다.

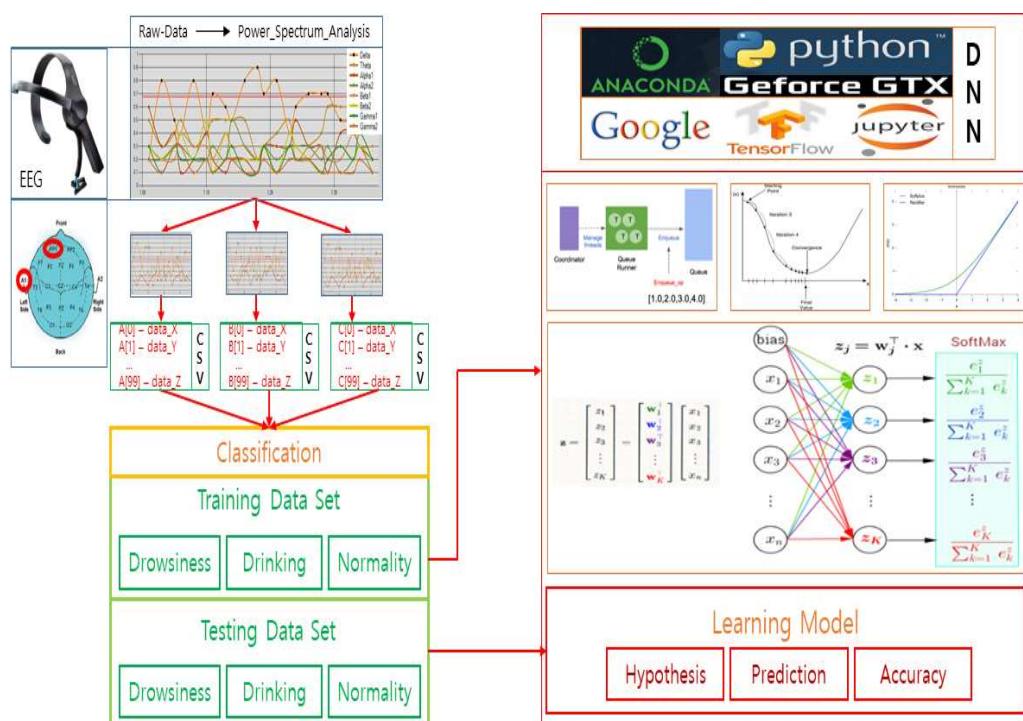
거대한 심 신경 네트워크를 훈련하는 것처럼 Tensorflow를 사용할 계산은 복잡하고 혼란스러울 수 있다. Tensorflow 프로그램을 더 쉽게 이해하고 디버깅하고 최적화하기 위해 TensorBoard라는 시각화 도구 모음이 공개 되었다. TensorBoard를 사용하여 Tensorflow 그래프를 시각화하고 그래프 실행에 대한 정량적 메트릭을 플롯하고 통과한 이미지와 같은 추가 데이터를 표시 할 수 있다. TensorBoard가 완전히 구성되면 [그림 2-10]과 같이 표시 된다.



[그림 2-10] 완전히 구성된 TensorBoard

III. 뇌파 데이터를 이용한 운전자 이상상태 분석

본 논문에서 제안하는 전체적인 구성은 [그림 3-1]과 같다. 뇌파 측정 장치를 통해 피험자의 뇌파 데이터를 취득하고 csv형태로 저장한다. 저장된 데이터의 평균을 구해 데이터 분석을 통해 기존 연구 자료와 비교하여 시간이 증가함에 따라 각 파형에 대한 증감을 확인한다. 학습에 필요한 데이터를 분류하고 Training data set과 Testing data set으로 분류하고, 구글에서 제공하는 Tensorflow 라이브러리를 이용하여 Deep learning 학습 모델링을 진행한다. 마지막으로 피험자의 정상상태와 이상상태에 대한 분류 모델의 성능을 평가한다.



[그림 3-1] 논문의 전체 구성도

A. 데이터셋

운전자의 이상상태에 대한 정확한 검출을 통해 대형교통사고로 이어지는 위험 상황을 미연에 방지할 수 있도록 데이터셋을 구성한다. 학습에 필요한 데이터는 정상상태와 이상상태로 나누게 되며, [표 3-1]과 같은 환경조건에서 취득한다. 이상 상태의 경우 정상상태와 다른 조건으로 출음 및 음주에 관한 뉘파 데이터를 취득 한다.

[표 3-1] 정상상태 및 이상상태 데이터 취득 환경조건

정상상태		<ul style="list-style-type: none">• 피험자는 7시간 이상의 충분한 숙면을 취한다.• 피험자의 정상 컨디션 상태에서 측정한다.• 측정 시간은 30분에서 1시간 단위로 진행한다.• 장기간에 걸쳐 여러 회 측정한다.
이상상태	출음	<ul style="list-style-type: none">• 피험자는 기상 후, 18시간이 지난 상태에서 극도의 피곤함을 느낄 때 측정한다.• 피험자의 컨디션 여부에 따라 출음이 오는 상태에서 시간과 상관없이 측정한다.• 식사 후 출음이 오는 상태에서 측정 한다.
	음주	<ul style="list-style-type: none">• 2잔, 4잔, 6잔, 8잔을 30분 간격으로 측정한다.• 정상 컨디션 상태에서 음주 후 측정한다.• 피로가 누적된 상태에서 음주 후 측정한다.

정상상태와 이상상태에 대한 뇌파 데이터의 파워 스펙트럼 분석된 데이터 값을 CSV(Comma-separated values)파일 형식으로 [그림 3-2]와 같이 저장한다.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
1	obs	time	Delta	Theta	Alpha1	Alpha2	Beta1	Beta2	Gamma1	Gamma2	Attention	Meditative	Blink	Derived	totPwr	class
2	1	1.4	1077105	101077	62880	20268	49675	9976	3664	3338	17	51	54	NA	1327983	0
3	2	2.4	167431	53249	7910	5258	12033	2966	1126	1241	21	60	NA	NA	251214	0
4	3	3.4	31094	56506	3165	14084	25772	16054	7057	9856	21	43	53	NA	163588	0
5	4	4.4	1707035	463284	48095	272385	37339	25832	21875	8415	21	51	48	NA	2584260	0
6	5	5.4	1221269	178532	163297	13377	27692	12333	10521	4408	13	44	NA	NA	1631429	0
7	6	6.4	1369654	97869	98514	41227	17069	44369	12146	7258	37	61	NA	NA	1688106	0
8	7	7.4	886951	77374	93033	25768	25006	9284	6561	2646	26	78	NA	NA	1126623	0
9	8	8.4	820564	213894	6249	13076	4887	8721	4531	5494	16	75	NA	NA	1077416	0
10	9	9.4	396897	50009	8463	48953	17633	21132	8652	5856	57	74	58	NA	557595	0
11	10	10.4	620258	97511	14966	16383	10353	4125	1078	1739	16	60	NA	NA	766413	0
										●						
										●						
										●						
1762	1761	1749.9	615486	287957	77014	19835	48107	58591	4804	8732	43	56	NA	NA	1120526	0
1763	1762	1750.9	203270	90476	17912	13342	15724	24356	8170	7307	41	40	61	NA	380557	0
1764	1763	1751.8	178241	265027	52814	43235	19251	16452	10745	3125	41	35	NA	NA	588890	0
1765	1764	1752.8	33722	32815	47031	19649	16192	7509	8308	3725	38	53	48	NA	168951	0
1766	1765	1753.9	759411	142454	51659	61685	45565	32059	7391	8916	37	63	NA	NA	1139140	0
1767	1766	1754.8	761892	36618	17649	19409	3345	10204	4219	4303	34	74	NA	NA	857639	0
1768	1767	1755.8	106800	294832	38684	24365	35226	14438	8829	2839	34	69	60	NA	526013	0
1769	1768	1756.8	1314341	572558	58012	17135	16494	21972	6738	3826	26	47	NA	NA	2011076	0
1770	1769	1757.8	16237	11450	45735	34364	11045	6935	4560	2345	23	60	NA	NA	132671	0

[그림 3-2] CSV형식으로 저장된 EEG Log data

저장된 데이터는 정상상태의 데이터를 기준으로 피험자의 이상상태 지표 구간 데이터를 구분하여 분류하고, Training data set과 Testing data set으로 나눈다. 각 속성에 대한 설명은 [표 3-2]와 같다.

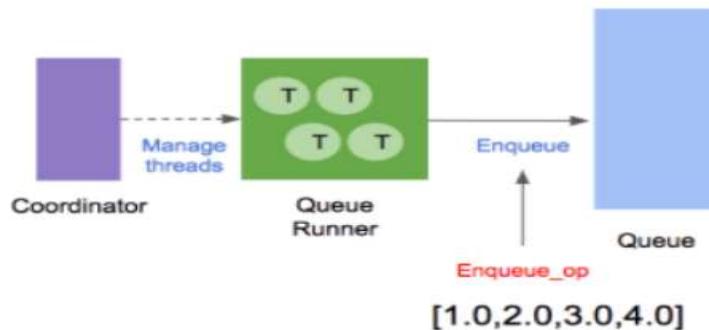
[표 3-2] 측정된 뇌파 데이터 속성

속성	설명
obs	observation - 관측(순서)
time	측정된 시간
Delta	1~3Hz
Theta	4~7Hz
Alpha1 / Alpha2	8~9Hz / 10~12Hz
Beta1 / Beta2	13~17Hz / 18~30Hz
Gamma1 / Gamma2	31~40Hz / 41~50Hz
Attention	집중도
Meditation	명상도
Blink	눈 깜박임
Derived	수식 - 새로운 파형을 생성할 때 사용
totPwr	total power
Class	정상, 졸음, 음주

B. 학습 알고리즘

본 논문에서 제안하는 운전자 이상상태에 대한 뇌파 데이터를 학습시키기 위해 Jupyter notebook을 이용하여 Tensorflow 라이브러리를 활용하여 딥 러닝 알고리즘을 구현하였다. 사용된 알고리즘에 대한 각각의 부연 설명을 끝으로 해당 절을 마무리한다.

첫 번째로, 모델을 만들고 학습하기 위해서는 데이터에 대한 정제와 분류 작업등을 많이 필요로 한다. 실제로 모델을 만들어서 학습 할 때, 데이터의 양이 많기 때문에 메모리에 적재해 놓고 학습 하기는 어렵다. 따라서 모델을 세션에서 실행할 때, 리스트에서 값을 하나씩 읽어 모델에 집어넣는 피딩(Feeding)방식을 이용한다. 본 논문에서는 학습에 필요한 Training data set을 Tensorflow에서 제공하는 Queue Runner를 사용하여 데이터를 불러온다. [그림 3-3]과 같이 Queue Runner가 큐에 어떤 데이터를 어떻게 넣을지 정의 하는 것은 Enqueue_operation인데, 데이터를 읽어서 실제로 어떻게 동작하는지 정의한다.

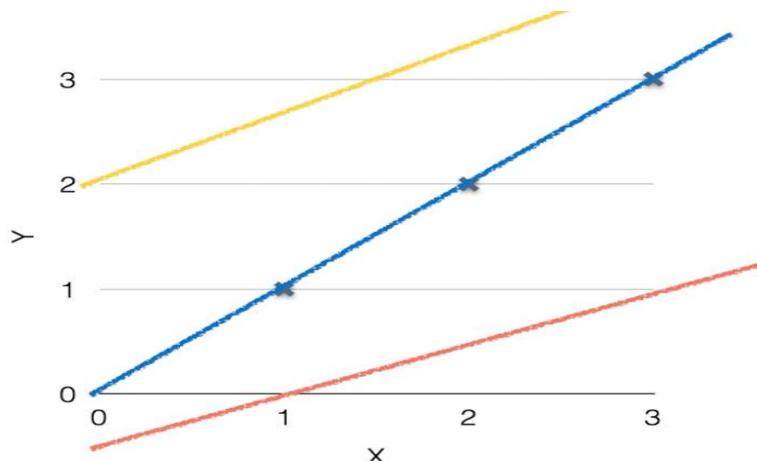


[그림 3-3] Tensorflow Queue Runner 도식화

Queue Runner는 여러개의 쓰레드(T)를 가지고 있고, 이 쓰레드들은 Coordinator들에 의해 관리된다. Queue Runner가 Queue에 데이터를 넣을 때는, Enqueue_op라는 operation에 의해 정의된 방식에 의해 데이터를 Queue에 집어넣는다.

다음은 Hypothesis에 대한 설명으로, 수학식으로 표현하면 식 (4)와 같다. $H(x)$ 는 예측, W 는 Weight, b 는 Bias를 뜻한다. Linear Regression에서는 W 와 b 에 따라 [그림 3-4]와 같이 여러 가지 직선이 만들어질 수 있다.

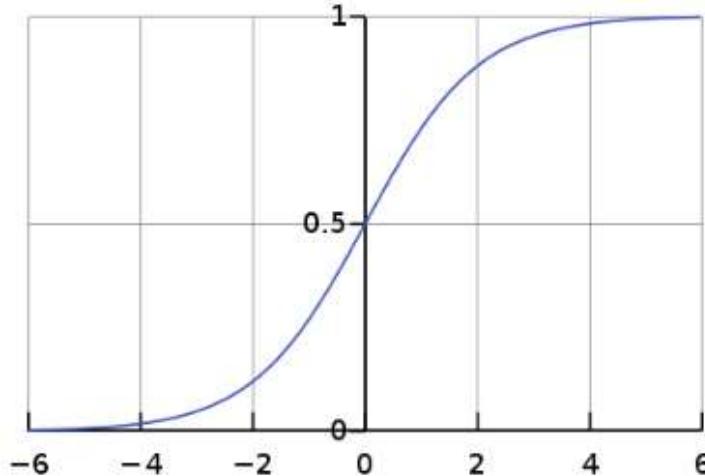
$$H(x) = Wx + b \quad (4)$$



[그림 3-4] $H(x) = Wx + b$

모델링을 위해서는 가설(Hypothesis)을 세우고, 학습하기 위해 데이터에 잘 맞는 직선을 찾는 작업이다. 가설로 세운 직선 위의 점과 실제 데이터와의 거리가 짧으면 좋고, 멀수록 좋지 않다.

다음은 Logistic Regression에 대한 설명으로, D.R.Cox가 1958년에 제안한 확률 모델로서 독립 변수의 선형 결합을 이용하여 사건의 발생 가능성을 예측하는데 사용되는 통계 기법이다. 로지스틱 회귀의 목적은 일반적인 회귀 분석의 목표와 동일하게 종속 변수와 독립 변수간의 관계를 구체적인 함수로 나타내어 향후 예측 모델에 사용하는 것이다. 이는 독립 변수의 선형 결합으로 종속 변수를 설명한다는 관점에서는 선형 회귀 분석과 유사하다. 하지만 로지스틱 회귀는 선형 회귀 분석과는 다르게 종속 변수가 범주 형 데이터를 대상으로 하며 입력 데이터가 주어졌을 때 해당 데이터의 결과가 특정 분류로 나뉘기 때문에 일종의 분류(classification) 기법으로도 볼 수 있다[35].



[그림 3-5] The logistic function

로지스틱 회귀는 [그림 3-5]와 같이 결과 값이 0 또는 1이라는 가장 큰 특징을 갖는다. 따라서 결과 값의 범위가 $[-\infty, +\infty]$ 인 선형 회귀의식을 결과 값의 범위가 $[0,1]$ 이 되도록 logit 변환을 수행한다. odds비를 종속 변수 값에 상관없이 결과 값이 항상 $[0,1]$ 사이에 있도록 식 (5)와 같이 logit변환을 수행한다.

$$\text{logit}(E[Y_i|x_{1,i}, \dots, x_{m,i}]) = \text{logit}(p_i) = \ln \frac{p_i}{1-p_i} \quad (5)$$

변환의 결과는 x 에 대한 선형 함수로 동일하므로, 식 (6)이 되고, 두 식을 결합하면, 식 (7)과 같다.

$$\text{log}(p_i) = \beta_0 + \beta_1 x_{1,i} + \dots + \beta_m x_{m,i} = \beta \cdot X_i \quad (6)$$

$$\ln \frac{p_i}{1-p_i} = \beta \cdot X_i \quad (7)$$

따라서 구하고자 하는 특정 독립 변수 x 가 주어졌을 때, 종속 변수가 1의 카테고리에 속할 확률은 식 (8)과 같다.

$$p_i = \log i t^{-1}(\beta \cdot X_i) = \frac{1}{1 + e^{-\beta \cdot X_i}} \quad (8)$$

이를 확률 질량 함수로 표현하면 식 (9)와 같다.

$$\Pr(Y_i = y_i | X_i) = p_i^{y_i} (1 - p_i)^{1 - y_i} = \left(\frac{1}{1 + e^{-\beta \cdot X_i}} \right)^{y_i} \left(1 - \frac{1}{1 + e^{-\beta \cdot X_i}} \right)^{1 - y_i} \quad (9)$$

다음은 Cost(Loss) Function에 대한 설명으로, 가설이 실제 데이터와의 오차가 어느 정도인지 알 수 있다. 가장 쉬운 방법은 $H(x) - y$ 를 구하는 것이지만, 거리가 음이나 양이 될 수 있기에 거리의 차를 제곱하여 $(H(x) - y)^2$ 평균을 구한다. 항상 양의 값을 가지며 거리의 차이가 커지면 값이 커지기 때문에 페널티 부여가 가능하며, 거리를 작게 만들 수 있다.

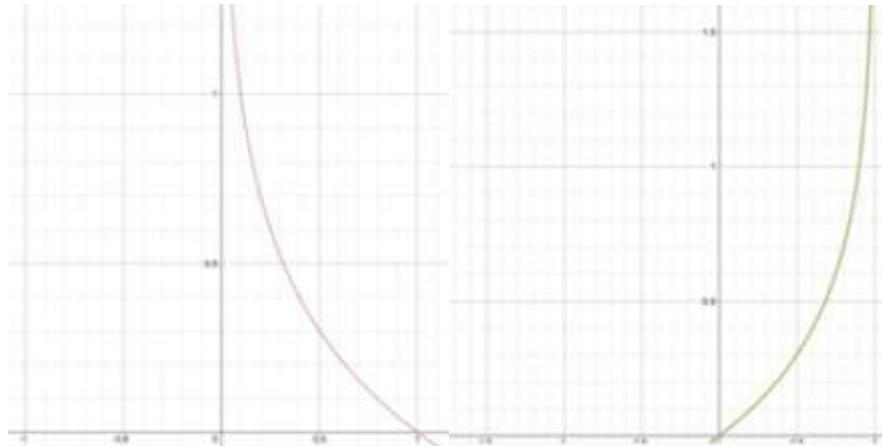
Cost(loss) function은 식 (10)과 같으며, m 은 학습 데이터 개수를 의미한다.

$$\text{cost}(loss)(W, b) = \frac{1}{m} \sum_{i=1}^m (H(x_i) - y_i)^2 \quad (10)$$

두 가지 케이스로 함수를 정의하면 식 (11)과 같고, exp를 사용하는데 상극이 되는 것은 log함수이다.

$$C(H(x), y) = \begin{cases} -\log(H(x)) & : y = 1 \\ -\log(1 - H(x)) & : y = 0 \end{cases} \quad (11)$$

$y = 1$ 일 때, $H(x) = 1$ 이면, $\text{cost} = 0$ 이 된다. $H(x) = 0$ 이라면 $\text{cost} = \infty$ 이 된다. $y = 0$ 일 때도 마찬가지 방식이며, [그림 3-6]과 같다.

[그림 3-6] $-\log(x)$, $-\log(1-x)$

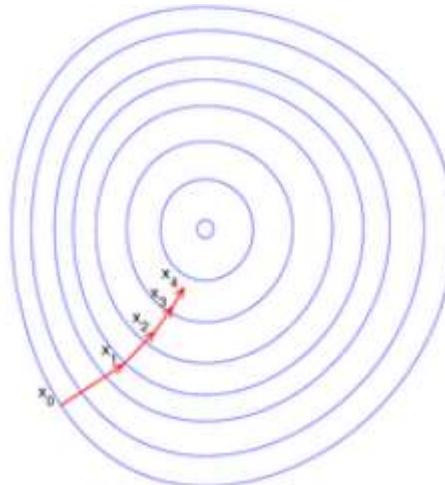
두 식을 결합하면 식 (12)와 같다.

$$C(H(x), y) = -y \log(H(x)) - (1-y) \log(1-H(x)) \quad (12)$$

다음은 Gradient Descent Optimizer에 대한 설명으로, 경사 하강법은 1차 근삿값 발견용 최적화 알고리즘이다. 함수의 기울기(경사)를 구하여 기울기가 낮은 쪽으로 계속 이동시켜서 극솟값에 이를 때까지 반복하는 것으로 최적화할 함수 $f(x)$ 에 대하여 먼저 시작점 x_0 를 정한다. 현재의 점 x_i 가 주어졌을 때, 그 다음으로 이동할 점인 x_{i+1} 을 식 (13)과 같이 계산한다. γ_i 는 이동할 거리를 조절하는 매개변수이다.

$$x_{i+1} = x_i - \gamma_i \nabla f(x_i) \quad (13)$$

[그림 3-7]은 경사 하강법이 진행되는 모습을 그림으로 표현한 것이다, x_0 에서 시작하여, 경사가 낮아지는 쪽으로 이동하여 차례대로 x_1, x_2, x_3, x_4 를 얻게 된다.



[그림 3-7] 경사 하강법

이 알고리즘의 수렴 여부는 f 의 성질과 γ_i 의 선택에 따라 달라지며, 극소점(local minimum)으로 수렴한다. 따라서 구한 값이 전역적인 최적해라는 것을 보장하지 않으며 시작점 x_0 의 선택에 따라 달라진다. 다양한 시작점에 대해 여러 번 경사 하강법을 적용하여 그 중 가장 좋은 결과를 선택하는 것도 하나의 방법이다. 마지막으로 기울기를 구하기 위해 식 (14)와 같이 미분을 적용한다. α 는 Learning rate로 학습률을 의미한다.

$$W := W - \alpha \frac{\partial}{\partial W} \text{cost}(W) \quad (14)$$

본 실험을 위한 데이터 학습 알고리즘은 Sung Kim 교수님과 Andrew Ng 교수님의 딥 러닝 강좌를 참고하였다[36,37].

IV. 실험 및 평가

A. 실험 환경

본 연구를 위해 구글에서 제공하는 Tensorflow를 활용하기 위한 데스크 탑의 GPU 및 성능에 대해 [표 4-1]에 정리하고, Tensorflow의 제약 사항인 UNIX기반 OS에서만 작동하는 것을 Windows에서 구동하는 방법에 대해 간단히 서술한다.

[표 4-1] 데스크 탑 성능

Division		Contents
OS	Version	Windows 10 Education
	System	64-bit 운영체제
H/W	PROCESSOR	Intel(R) Core(TM) i5-4690
	CPU	3.50GHz(4 CPUs), ~3.5GHz
	GPU	NVIDIA GeForce GTX 1060 6GB
	RAM	16.0GB
	HDD / SSD	1TB / 130GB

2016년 11월 29일 Tensorflow v0.12.0 RC0가 업데이트 되었고 핵심 변경 사항으로 Window에서, Ubuntu에서만 가능하던 GPU 버전을 설치 가능하다는 점이다. 따라서 본 논문에서는 Document에 따라 [표 4-2]와 같이 각 버전에 맞게 설치를 진행하였다.

[표 4-2] GPU Tensorflow

S/W		Version
Anaconda(64-bit)		4.2.9
Python		3.5.2
GPU	Tensorflow	GPU
	CUDA Toolkit	8.0.44
	cuDNN	5.1

Windows10 64-bit에서 기존 시스템과의 충돌을 피하기 위해 Anaconda를 이용하여 가상환경을 구축 한 후, Jupyter notebook을 이용하여 프로그램을 구동한다. Jupyter notebook은 수십 개의 프로그래밍 언어에서 오픈 소스 소프트웨어, 개방형 표준 및 대화식 컴퓨팅을 위한 서비스를 개발하는데 사용한다.

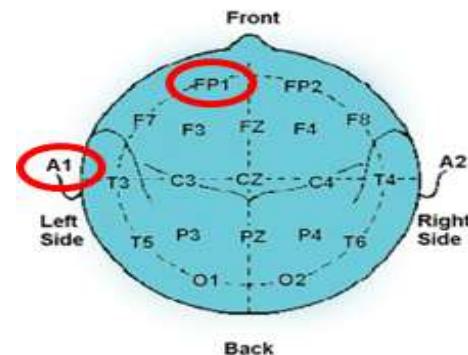
B. 실험 방법

1. 뇌파 측정 및 레이터 취득

뇌파측정을 위한 장비로는 NeuroSky사의 Mind Wave Mobile 제품을 이용하였다. Mind Wave Mobile 제품은 1채널 전두엽 측정 장비로 [그림 4-1]의 형태이며, [표 4-3]과 같은 특징을 갖는다.



[그림 4-1] Mind Wave Headset

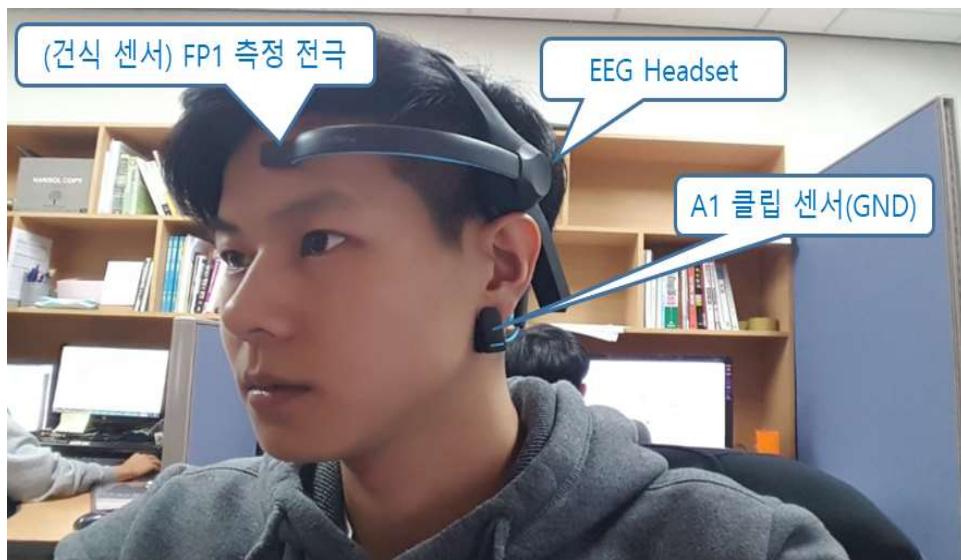


[그림 4-2] 전극 부착 위치

[표 4-3] EEG Headset

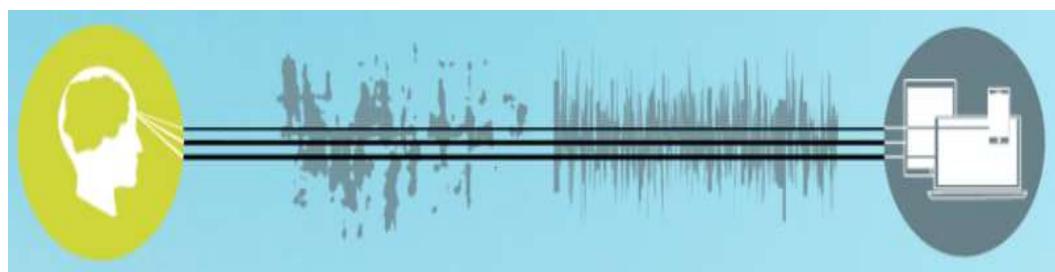
Platform	WINDOWS(XP/7/8/10)
	MAC(OSX 10.8이상)
	ANDROID(2.3 이상)
	IOS(8 이상)
Sensor type	Dry
Channel count	1 channel
Wireless	Bluetooth, optimized for high speed
SDK	Stream SDK for PC

전극 부착 위치는 [그림 4-2]와 같으며, [그림 4-3]과 같이 왼쪽 눈 위 이마 부분의 FP1부위에 센서 암을 조절하여 건식 센서가 이마에 밀착되도록 하고, A1부분은 왼쪽 귓불로 클립 센서를 이용해 귓불을 집는다. A1은 접지(Ground, GND)로, 클립 센서는 접지전극이다.



[그림 4-3] EEG Headset(Mind Wave Mobile)

Mind Wave Mobile 작동방식은 [그림 4-4]와 같으며, 센서는 희미한 브레인 웨이브 신호를 안전하고 수동적으로 감지한다. NeuroSky 기술은 뇌 신호의 의미를 해석하며, Brain wave 신호는 APP을 통해 다양한 효과를 일으킨다.



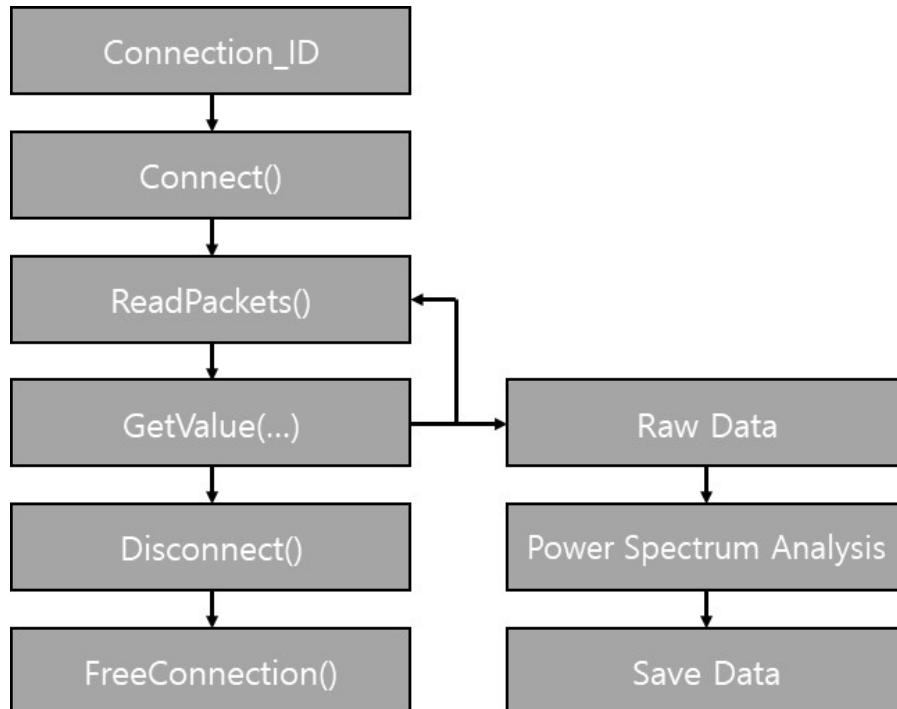
[그림 4-4] Mind Wave Mobile 작동 방식

샘플링 속도는 초당 512Hz의 속도로 12bit의 Raw-Brain waves(3~100Hz)를 출력한다. 뇌파 파워 스펙트럼을 통해 분류된 파형 분석에 대한 NeuroSky에서 제시한 기준은 [표 4-4]와 같이 정리 되어 있다.

[표 4-4] NeuroSky 주파수 분석표

뇌파	주파수(단위:Hz)	정신상태
델타파 (delta)	0.5~4	깊은 수면, 뇌 이상상태
세타파 (theta)	4~7	졸음 상태, 얕은 수면
알파파 (alpha)	8~14	긴장이 이완, 안정된 상태(명상)
SMR파	12~15	문제를 해결할 때, 긴장과 스트레스가 없는 상태에서도 모든 일을 쉽게 해결할 수 있는 능력 상태가 됨.
베타파 (beta)	14~30	집중력 최고, 긴장/불안/흥분상태

PC와 연결하기 위해 블루투스 동글을 사용 하였고, Visual Studio에서 SDK로 불러들인 소스코드에서 라이브러리를 이용하여 뇌파 데이터 취득용 코드를 작성한다. 코드는 [그림 4-5]와 같은 순서를 가지며, EEG Headset이 착용된 상태에서 블루투스와 페어링이 되면 순서도와 같이 수행된다. EEG Headset에 대한 ID값을 취득하고, 접속을 시도하여 패킷을 읽어 들인다. 데이터를 가져오고 나면 접속이 해제되기 전까지 패킷을 계속해서 초당 약 512회 Raw data를 읽어 들이게 된다.



[그림 4-5] 라이브러리 소스코드 순서도

이렇게 가져온 데이터들은 Log형태로 저장되며, 프롬프트 창을 통해 [그림 4-6]과 같이 실시간으로 확인이 가능하다.

C:\#Windows\system32#cmd.exe

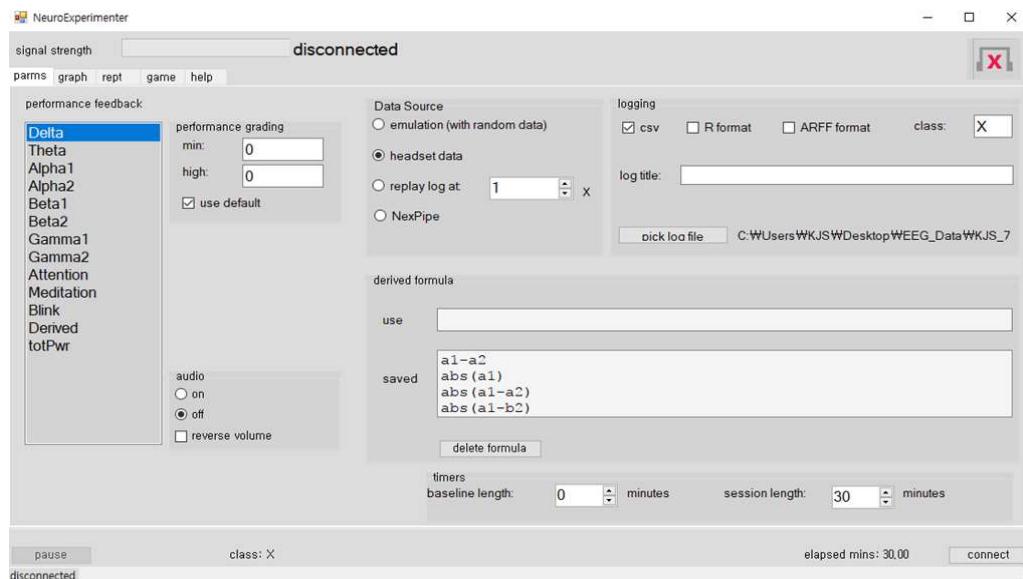
```
Stream SDK for PC version: 3
Thu Jul 6 02:40:24 2017 : raw: 36
Thu Jul 6 02:40:24 2017 : raw: 36
Thu Jul 6 02:40:25 2017 : raw: 19
Thu Jul 6 02:40:25 2017 : raw: 20
Thu Jul 6 02:40:25 2017 : raw: 24
Thu Jul 6 02:40:25 2017 : raw: 25
```

dataLog - 메모장

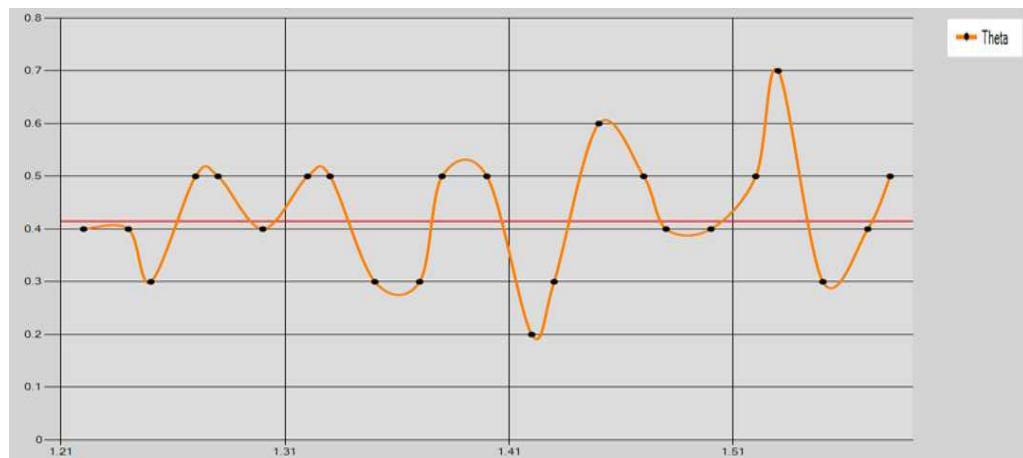
파일(F)	편집(E)	서식(O)	보기(V)	도움말(H)	
1499276425.435:	[80]	17,	0011,	-2.900293	
1499276425.436:	[80]	16,	0010,	-2.906158	
1499276425.437:	[80]	20,	0014,	-2.882698	
1499276425.438:	[80]	21,	0015,	-2.876833	
1499276425.438:	[80]	13,	0000,	-2.923754	
1499276425.439:	[80]	13,	0000,	-2.923754	
1499276425.440:	[80]	18,	0012,	-2.894428	
1499276425.440:	[80]	18,	0012,	-2.894428	
1499276425.441:	[80]	17,	0011,	-2.900293	

[그림 4-6] EEG Raw-data / Data Log

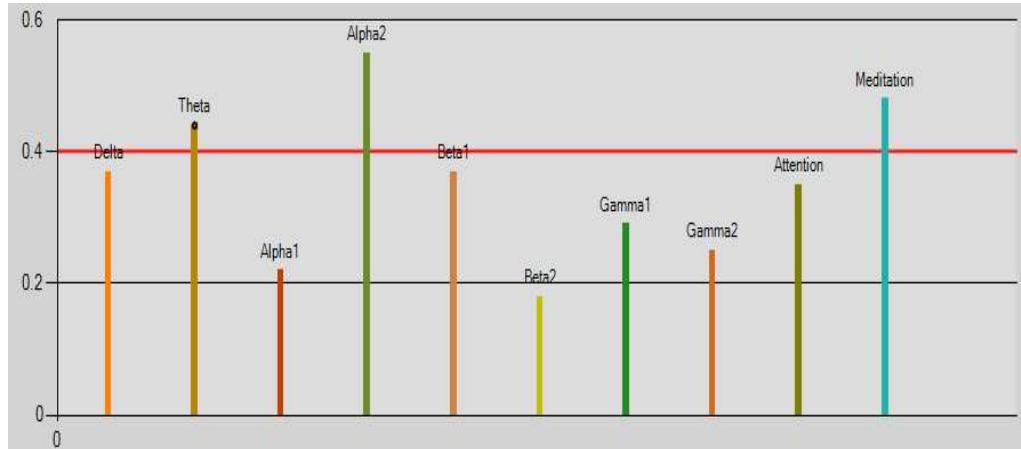
본 실험에서는 NTx(NeuroExperimenter)툴을 사용하였다. NTx툴을 이용하여 [그림 4-7], [그림 4-8], [그림 4-9]과 같이 더 직관적으로 데이터를 확인할 수 있으며, 8개의 파형(Delta, Theta, Alpha1, Alpha2, Beta1, Beta2, Gamma1, Gamma2)으로 더 세밀하게 파형을 분류하여 해석이 가능하다.



[그림 4-7] NTx(NeuroExperimenter)

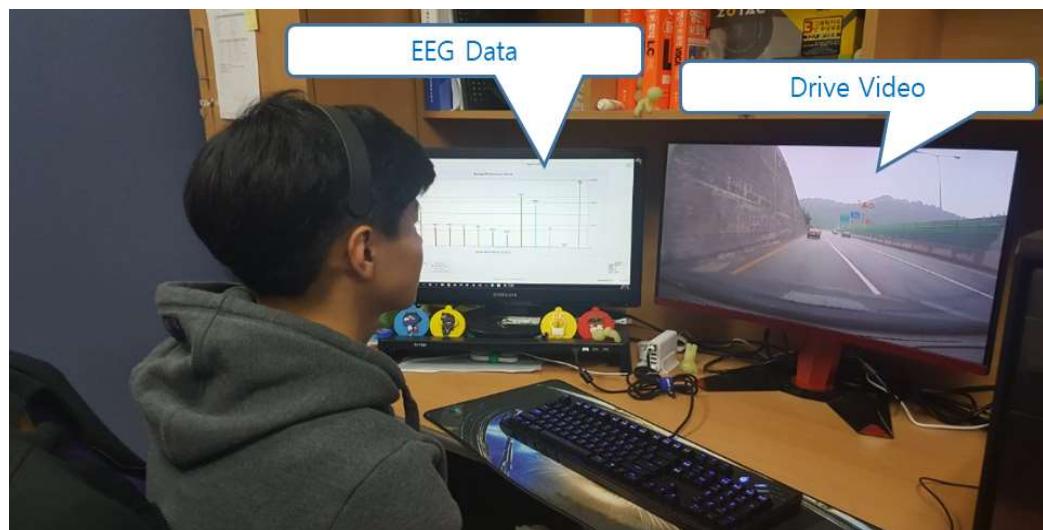


[그림 4-8] Theta파형 그래프



[그림 4-9] 분류된 파형들에 대한 막대그래프

마지막으로, 운전자 이상상태 지표 검출을 위한 데이터 취득 실험을 위해 실험실 내부에서 [그림 4-10]과 같이 차량 블랙박스 영상을 통해 운전자 이상상태에 대한 각 상황의 모의실험을 진행하여 뇌파를 취득한다.



[그림 4-10] 운전자 이상상태 지표 검출 모의실험

2. 뇌파 분석을 통한 학습 모델링 구현

뇌파는 매우 복잡한 패턴으로 진동하는 파형 형태로, 뇌파 측정을 통해 취득한 데이터는 수치 값으로 저장된다. 정상상태에서의 일정한 뇌파 파형과 달리, 이상상태에 따라 주파수 영역별 뇌파의 특징이 증가 또는 감소하는 현상을 볼 수 있다. 이에 따라 각 파일마다 각각의 파형에 대한 평균을 구하여 주파수 영역별 뇌파의 특징 분석을 통해 인지하고 있는 이론을 토대로 학습에 필요한 데이터를 예측할 수 있다. [표 4-5]와 같이 정리하였다.

[표 4-5] 뇌파 분석 방법과 분류 기준 정의

	설명
분석 방법	<ul style="list-style-type: none"> • 뇌파는 파형 형태로 피험자의 상태에 따라 주파수 영역별 뇌파의 증가 또는 감소 현상이 나타난다. • 측정을 통해 취득한 데이터는 수치 값으로 저장되어 있으며, 분석을 위해 각각의 파형에 대한 평균을 구한다. • 분석을 통해 관련파형에 대한 증감 현상을 수치로 확인한다.
분류 기준 정의	<ul style="list-style-type: none"> • 눈을 깜빡이거나 몸을 움직이는 경우, 눈의 움직임이나 몸의 움직임에 의해 발생하는 잡음(artifact)의 주파수 영역과 거의 일치하므로, 마치 델타파가 증가한 것처럼 보일 수 있다. 운전자의 경우 눈 움직임과 몸의 움직임이 필수적으로 발생하므로 델타파의 파워 증감은 분석 요소로 고려하지 않는다. • 뇌파의 주파수 영역별 특징과 실제 데이터의 증감 수치 비교를 통해 이론적 입증과, 다른 영역의 파형에 대한 상관관계 비교를 통해 학습에 필요한 데이터 셋을 정의한다. • 정상상태의 뇌파와 각 상황에 대한 이상상태의 변화를 통해 전체 데이터의 학습과 부분 학습을 통해 비교 분석한다.

학습에 필요한 데이터를 분류하기 위해 실제로 연구되어진 분석된 자료와 데이터 비교를 통해 수치 값의 변화를 확인한다. 실험의 편이를 위해 10개의 파일에서 델타파형을 제외하고, 수치에 대한 소수점은 버리고 정수 형태로 비교한다.

	A	B	C	D	E	F	G	H
1	#time(H)	#Theta	#Alpha1	#Alpha2	#Beta1	#Beta2	#Gamma1	#Gamma2
2	4	78212	26680	31220	19742	13516	5556	3118
3	5	85964	24504	23174	16777	14151	8250	5270
4	8	90115	23167	20765	18859	15483	9246	5755
5	9	97853	25565	21318	19751	16397	9098	5610
6	10	101912	25986	22929	20746	17518	10815	7155
7	14	106520	26314	23587	21415	17257	9824	5415
8	22	116958	27642	23401	21681	18094	13752	8354
9	23	108315	27128	22625	21687	19496	12707	7601
10	26	59848	17910	18568	12266	8845	3834	2690
11	24	60977	18574	16771	12987	10029	4943	3049

[그림 4-11] 시간증가에 따른 수치 증감 분석

[그림 4-11]은 정상 컨디션의 일반적인 상태에서의 기상 후 지난 시간(#time(H))을 표기한 것으로, 졸음이 오거나 컨디션이 악화 되었을 때, 파형을 비교하기 위해 Alpha2파에 대한 내림차순 정렬을 통해 비교하였다. Theta파는 점차적인 증가 수치를 보이다 24시간 이후로 수치가 급격히 감소하였고, Alpha2파형은 수많은 졸음 징후 검출 연구의 이론과 일치하게 점차 감소하는 현상을 보였다.

[표 4-6] 이상상태 뇌파 주파수 영역별 증감 표

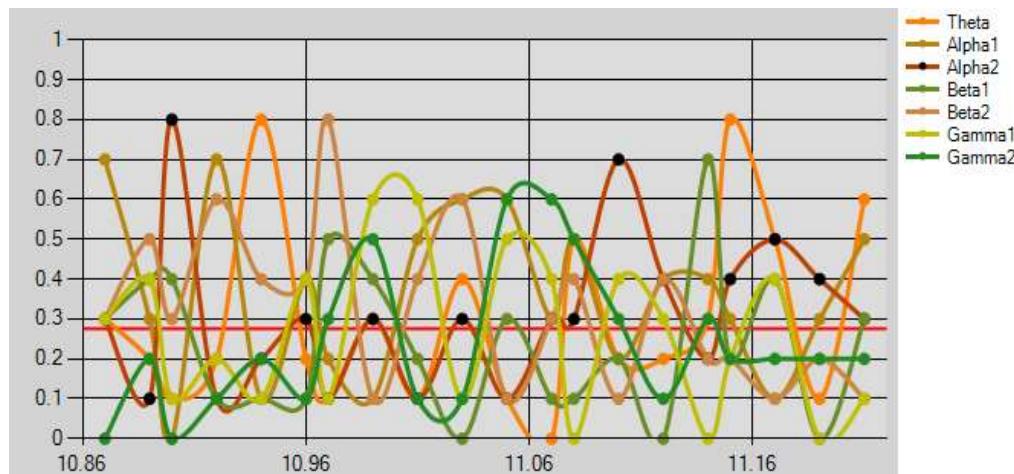
Frequency	Drowsiness	Drinking
Theta	↗	-
Alpha1	↗	↗
Alpha2	↘	↘
Beta1	-	-
Beta2	-	-
Gamma1,2	-	↗

운전자 이상상태에 대한 추가 분석으로 음주에 대해서도 비교를 진행 하였으며, 측정 기준은 30분 간격으로 2잔, 4잔, 6잔, 8잔에 대한 시간 순으로 데이터를 저장하고 비교하였다. 졸음과 마찬가지로 증감 수치에 대해 [표 4-6]과 같이 정리하였다. 각 데이터마다 일정시간 이상이 지나면 증가하다가 급격히 감소하는 경우를 보이는 패형이 있었고, 이와 같은 데이터는 극단적인 경우로 학습 데이터에서 제외한다. 분석을 통해 분류된 각각의 이상상태에 관한 뇌파 데이터를 학습과 정확도 평가를 위해 필요한 Training data set과 Testing data set으로 분류하고, 라벨과 함께 저장한다. jupyter notebook을 이용하여 tensorflow 알고리즘을 적용하여 모델링을 하며, 학습 모델링에 대해 간단히 서술한다.

분류된 학습 데이터 셋에 라벨을 부여한 후 분류하고, batch 사이즈를 지정한다. 학습의 성능을 높이기 위해 신경망 모델의 구현하는데, deep하고 wide한 모델을 위해 Hidden layer를 추가한다. 가중치의 차원은 특성과 뉴런의 개수로 정하며, 마지막 가중치는 첫 번째 히든 레이어의 뉴런 개수와 분류 개수로 정한다. 신경망의 Hidden layer에 Weight와 편향 Bias를 적용하고 최종적인 Output을 계산한다. Tensorflow에서 제공하는 Cross entropy함수를 이용하여 최적화를 위한 Cost 함수를 적용하고 신경망 모델을 학습한다. 정확도는 퍼센트(%)를 나타내며, Testing data가 아닌 Training data set을 이용한 학습이 얼마나 효과적으로 이루어져 있는지 보여준다. 실제로 알고리즘 추가하거나, 종류에 변화를 주는 방식으로 학습 모델의 성능을 끌어 올리는 것이 가능하다.

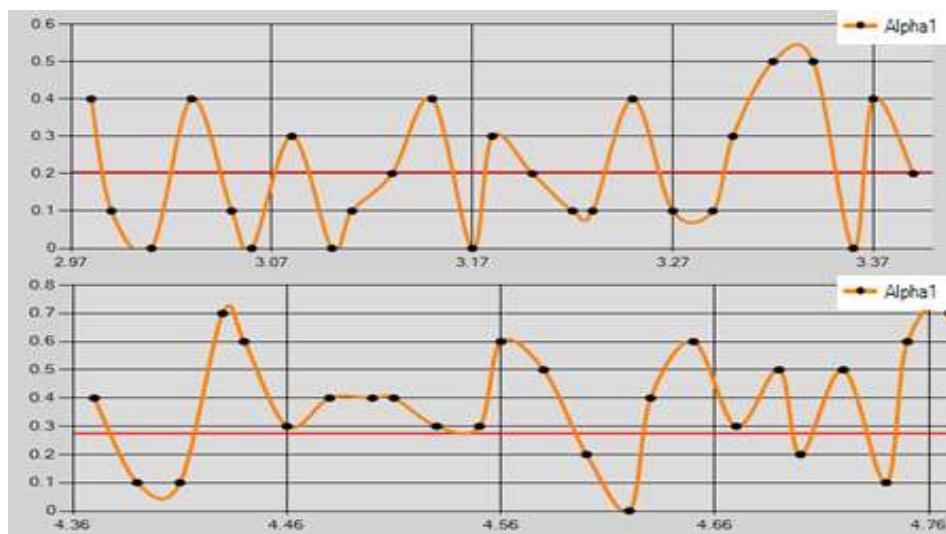
마지막으로 모델링의 성능을 평가하기 위한 방법으로, 검증된 실험데이터 셋을 받아 실험을 하는 방법이 있다. 공개된 뇌파데이터 셋을 이용하기 위해서는 본 연구의 실험과 동일한 이상상태에 관한 측정이 이루어져야 하며, 전극 부착 위치와 주파수 영역에 대한 각 패형의 수치 등 요구조건에 충족해야한다. 따라서 공개된 실험데이터 셋의 사용은 Deep learning의 모델링 평가에 많이 사용되고 있으나, 본 연구의 요구조건에 충족하는 데이터 셋을 구하기 어렵다는 점을 감안하여 다음과 같은 단계를 거쳐 실험을 진행한다.

피험자 1에 대한 정상상태와 이상상태 데이터 셋 분석을 진행하기 위해 저장된 뇌파 데이터 레코드를 리플레이하는 방법으로 [그림 4-12]와 같이 확인할 수 있다.

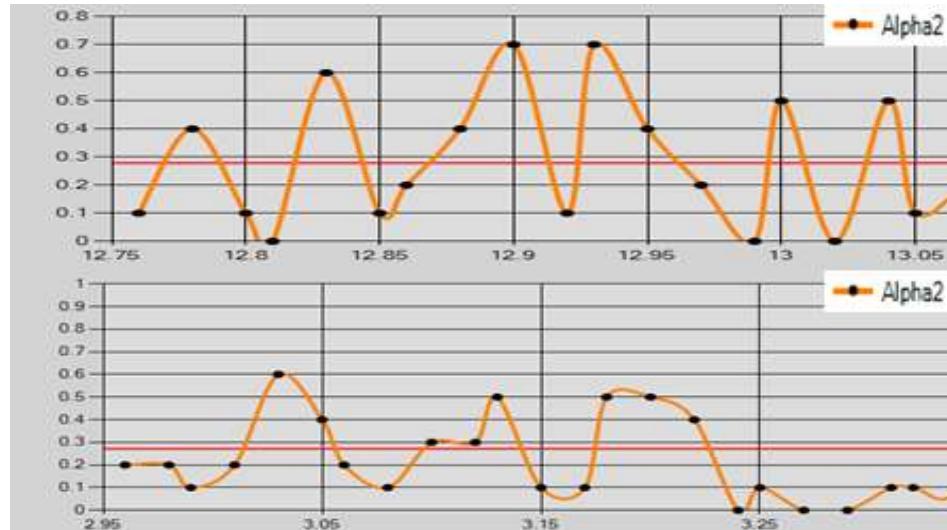


[그림 4-12] 주파수 영역별 뇌파 레코드

7개의 파형을 한꺼번에 모니터링하며 분석하는 방법은 비효율적이므로 각 파형마다 정상상태와 이상상태에 대한 레코드 분석을 진행한다. 대표적으로 Alpha1과 Alpha2에 대한 파형을 [그림 4-13], [그림 4-14]와 같이 비교 분석하였다.

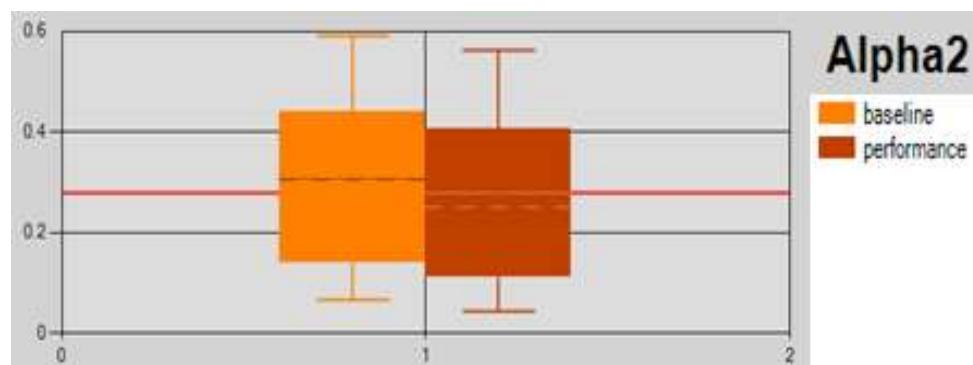


[그림 4-13] Alpha1파형에 대한 증가 비교 그래프



[그림 4-14] Alpha2파형에 대한 감소 비교 그래프

실제 데이터가 기존의 연구 자료와 같이 증감현상을 보이는 것을 확인하였고, 전체적인 레코드 기록을 통해 정상상태와 이상상태에 대한 평균 분포도를 확인한 결과 [그림 4-15]와 같다.



[그림 4-15] Alpha2파형에 대한 평균 분포도 비교

비교 분석을 통해 데이터가 피험자의 정상상태와 이상상태에 대해 측정이 잘 되었음을 확인하였고, [표 4-7]과 같이 Training data set과 Testing data set으로 나누어 저장하였다. Labeling한 최종 학습 데이터 셋의 모델링 구현을 통해, 운전자의 이상상태 1차 분류 성능 분석을 진행한다.

[표 4-7] 데이터 셋(1)

Division	Class	Total data	Used data		Labels
Training data set	Drowsiness	23,153	15,000	32,000	15,000
	Drinking	14,032	7,000		7,000
	Normality	15,723	10,000		10,000
Testing data set	Drowsiness	3,300	1,000	4,000	1,000
	Drinking	3,300	1,000		1,000
	Normality	6,600	2,000		2,000

비교대상이 되는 피험자들의 정보는 [표 4-8]과 같다. 피험자 1과 동일한 환경에서 모의실험을 진행하고 비교 분석을 진행한다.

[표 4-8] 피험자 정보

Class	Subject	Sex	Age	Measuring time(M)
Drowsiness / Normality	1	men	28	70
	2	men	25	30
	3	men	26	30
	4	men	28	40
	5	men	28	35
	6	men	30	30
	7	men	31	30
Drinking / Normality	1	men	28	120
	2	men	26	120
	3	men	28	120

비교 실험을 위한 피험자들의 데이터 셋 분류도 데이터 셋(1)과 같은 방식으로 동일하게 진행하여 [표 4-9]와 같이 Training data set과 Testing data set으로 나누고 Labeling을 한 후 모델링을 구현한다.

[표 4-9] 데이터 셋(2)

Division	Class	Subject	Total data	Used data	Labels
Training data set	Drowsiness	7	12,390	5,800	5,800
	Drinking	3	5,310	2,300	2,300
Testing data set	Drowsiness	7	5,310	1,000	1,000
	Drinking	3	1,770	500	500

운전자 이상상태에 대한 1차 분류를 통해 피험자 1에 대한 모델링의 성능 분석을 통해 지도학습 알고리즘을 가공하여 성능을 강화하고, 2차 학습 모델링을 통해 데이터 분류를 진행하고 학습 모델의 성능을 확인한다. 마지막으로 비교 대상이 되는 피험자들에 대한 데이터 셋(2)의 지도학습 모델링을 통한 분류 성능 분석을 끝으로 마무리한다.

3. 실험 평가 및 결과 분석

본 논문의 실험은 뇌파 데이터의 분석을 통한 학습데이터 분류와, 이상상태에 관해 모델링이 효율적으로 이루어졌는지에 대한 정확도 분석이다. 학습 모델에 대한 정확도와 실제 테스트 데이터에 대한 정확도 비교를 통해 학습의 성과를 확인 할 수 있다. 모델링을 통해 얻은 정확도가 100%에 가까우면 학습이 잘 되었다고 표현 한다. 하지만 과도한 학습을 통해 100%에 가까운 정확도를 얻은 경우, 새로 취득한 데이터를 모델에 적용하면 역효과를 가져온다. 따라서 학습 모델에 테스트 데이터를 입력하여 정확도를 비교한다.

본 논문에서 제안하는 학습 모델링을 통해 성능을 비교하여, [표 4-10]에 정리하였다. 운전자 상황에 따른 이상상태(졸음, 음주)에 관한 모의실험을 진행하여 기존 뇌파 영역별 주파수 연구 자료를 토대로 정의한 데이터를 분류하여 실험을 진행하였다.

[표 4-10] 이상상태 1차 분류 성능

Data set	Drowsiness	Drinking
Training data set	92.87%	94.41%
		58.42%
Testing data set	91.38%	87.24%
		64.00%

학습 모델을 구현하고 운전자의 정상상태와 이상상태에 대한 1차 분류 실험을 진행한 결과 Training data set에서의 졸음과 음주는 92.87%, 94.41%의 정확률을 보였다. Testing data set의 경우 테스트 데이터를 사용하였을 때 91.38%, 87.24%의 정확률을 보였다. 졸음과 음주에 대한 정확률 비교를 통해 학습이 잘 이루어 졌다는 것을 알 수 있다. 하지만 졸음과 음주의 데이터를 동시에 학습 시킨 결과, 각각 58.42%와 64.00%라는 결과의 상이함을 통해 다음과 같은 가설을 세울 수 있다.

- 실험에 사용된 뇌파의 주파수 영역에 대한 예측이 잘못되었다.
- 학습의 오류를 막기 위해 무리하게 학습을 시켰다.

정상상태와 음주에 대한 데이터와 비교해 본 결과, 집중력 수치는 대략 18%정도 감소하였고, 수면 유도에 대한 뇌파가 음주의 시간에 비례해 증가하는 것을 확인할 수 있었다. Testing data set을 이용한 분석 결과와 같이 데이터에 따라 정확률의 증감을 확인 할 수 있으며, 다음과 같은 결론을 얻었다.

- 주파수 영역별 특징을 비교해본 결과, 매우 유사한 특징을 갖는다.
- 데이터를 동시에 학습시킬 경우 30%이상의 교차 분류 상황이 발생한다.
- 명확한 분류를 위해 학습에 필요한 데이터 분석 패형이 필요하다.

지도학습에서의 무리한 학습은 역효과를 불러온다. 또한, 공개적으로 명시된 데이터가 아닌 연구를 위한 개인적인 데이터의 취득에 대해서는 정확한 분석 결과가 필요하며, 학습 모델을 통해 결과를 확인할 수 있다. 따라서 운전자 이상상태 2차 분류 성능에 대한 알고리즘과 데이터 셋에 변화를 주어 실험을 진행하였다.

[표 4-11] 이상상태 2차 분류 성능

Data set	Drowsiness	Drinking
Training data set	97.26%	98.47%
		87.26%
Testing data set	98.8%	98.27%
		89.49%

2차 지도학습 모델링에 사용된 데이터는 Alpha1, Alpha2파형에 대한 중점적인 수치의 변화에 따른 학습이다. 졸음에는 Theta파형, 음주에는 Gamma파형에 대한 분석 자료를 함께 사용하여 테스트한 결과로 운전자 이상상태에 대한 2차 분류 성

능은 [표 4-11]과 같다.

마지막으로 데이터 셋(2)의 학습 모델링 한 결과를 [표 4-12]에 정리하였다. 실험은 기준이 되는 피험자 1의 학습방법과 주파수 영역별 평균 증감 수치를 사용하여 동일하게 진행되었으며, 출음과 음주에 대한 통합된 데이터의 학습은 진행하지 않는다. 피험자 각각에 대한 분류 성능 분석을 끝으로 마무리한다.

[표 4-12] 피험자들의 이상상태 분류 성능 결과

Class	Subject	Train	Test	Total
Drowsiness / Normality	1	97.26%	98.8%	98.03%
	2	96.15%	97.54%	96.845%
	3	98.29%	98.75%	98.52%
	4	87.45%	84.74%	86.095%
	5	96.82%	92.49%	94.655%
	6	97.48%	97.98%	97.73%
	7	82.54%	79.64%	81.09%
				93.28%
Drinking / Normality	1	98.47%	98.27%	98.37%
	2	97.82%	98.17%	97.995%
	3	82.47%	74.55%	78.51%
				91.625%

피험자들의 데이터를 토대로 비교 분석한 결과, 피험자마다 주파수 영역별 각 파형에 대한 증감 변화에 차이를 보였다. 평균적으로 측정되는 기준이 다르다는 것을 확인하였다. 따라서 각 데이터마다 최적의 수치 값을 분류하여 정규화 작업을 진행한다면 각각의 데이터에 따른 성능 및 전체 데이터의 성능이 더 향상될 것이라고 생각한다.

V. 결론 및 제언

운전자 이상상태 관련 연구에서는 비접촉식 장점을 이용한 영상처리 기반의 연구가 진행되고 있고, 운전자 보조 시스템 상품이 실제로 적용되어 제품화 되었다. 하지만 사고 사례에 대한 즉각적인 대응이 어렵고, 사고를 미연에 방지하기 어렵다는 단점이 있다. 본 논문에서는 높은 정확도와 객관성을 가지는 생체신호 중 뇌파를 이용한 방법으로 연구를 진행하였다. 운전자의 이상상태에 관한 모의실험을 통해 피험자의 졸음상태와 음주에 대한 뇌파 데이터를 취득하고, 주파수 영역별로 데이터를 저장하였다. 학습에 필요한 데이터를 분류하기 위해 저장된 데이터는 기존 연구와 통계자료를 참고하여 분석한 정보를 토대로 이상상태 지표를 정의하였다. 데이터는 학습 데이터와 테스트 데이터로 나누었고, 딥 러닝 알고리즘을 이용하여 모델링하였다. 본 논문에서 제안한 방법으로 구현된 학습 모델 실험을 진행 한 결과, 졸음에 대한 정확률은 92.87%, 91.38%이고, 음주에 대한 정확률은 94.41%, 87.24%의 성능을 보였다. 전체적인 데이터 학습 모델링을 통해 58.42%와 64.00%의 정확률을 확인하였다. 각각의 학습 모델링에서는 높은 정확률을 보인 것과 비교하여 상이한 결과를 보였다. 기존 연구자료 분석을 통해 정의한 증감 표를 토대로 졸음 데이터와 음주 데이터는 매우 유사한 형태로 다수 데이터의 교차현상을 확인할 수 있다. 대표적으로 집중력 수치가 감소하며, 졸음 유도로 인한 파형의 변화가 음주 후 시간이 지남에 따라 졸음이 오는 상태와 유사한 데이터의 증감 수치를 보인다. 분석을 통해 학습에 사용되는 뇌파 파형의 데이터를 제한하고, 알고리즘을 강화하여 2차 분류를 한 결과 각각의 성능이 증가하고 전체적인 성능이 87.26%와 89.49%로 1차 분류에 비해 학습이 잘 이루어 진 것을 확인하였다. 마지막으로 비교 대상이 되는 다른 피험자들의 학습 모델을 통해 성능을 분석해 본 결과, 사람마다 주파수 영역별 파형이 각각 차이를 보이는 것으로 확인되었으며, 수치에 대한 증감 비율은 평균적으로 비슷하다는 결론을 얻었다.

본 연구에서 제안하는 방법과 같이 데이터 핵심의 분석을 통해 이상상태를 분석하여 예측상태를 정의하고, 정확한 지표를 검출하기 위한 학습 모델링 방법이 구축된다면 더 명확한 결과가 도출 될 것으로 보인다.

참고문헌

- [1] TASS 교통사고분석시스템, <http://taas.koroad.or.kr/>
- [2] TS 교통안전공단, <http://www.ts2020.kr/main.do>
- [3] KoROAD 도로교통공단, <https://www.koroad.or.kr/>
- [4] 경찰청 - 통계자료, <https://www.police.go.kr/main.html>
- [5] Andreas Patzer, “ATZ elektronik”, 10, 2014.
- [6] Wolfgang Bott, “MOST Cooperation”, 03, 2015.
- [7] 이경수_서울대학교, “Next Generation Active Safety and Advanced Driver Assistance Systems”, Auto Journal, 08, 2006.
- [8] Sam-Yong Kim, Geong-Kwan Kang, Young-Woo Ryu, Se-Young Oh, Kwang-Soo Kim, Sang-Cheol Park, Jin-Won Kim, “Intelligent Driver Assistance Systems based on All-Around Sensing”, 전자공학회 논문지 제 43권 TC편 제 9 호, 2006-43TC-9-7.
- [9] Sangwon Kim, Jungkyu Kim, “Driver Assistance System By Image Based Behavior Pattern Recognition”, Journal of The Institute of Electronics and Information Engineers, Vol. 51, NO. 12, December 2014.
- [10] Meeyeon Oh, Yoosoo Jeong, Kilhoum Park, “Driver Drowsiness Detection Algorithm based on Facial Features”, Journal of Korea Multimedia Society Vol. 19, No. 11, November 2016.
- [11] TaeHyeong Kim, Woong Lim, Donggyu Sim, “A Study on an Open/Closed Eye Detection Algorithm for Drowsy Driver Detection”, Journal of The Institute of Electronics and Information Engineers Vol.53, No.7, July 2016.
- [12] Rami N. Khushaba, Sarath Kodagoda, Sara Lal, Gamini Dissanayake, “Driver Drowsiness Classification Using Fuzzy Wavelet-Packet-Based Feature-Extraction Algorithm”, IEEE TRANSACTIONS BIOMEDICAL ENGINEERING, VOL. 58, NO. 1, PP.121-131 JANUARY 2011.
- [13] M. V. M. Yeo, X. Li, Shen, E. P. V. Wilder-Smith, “Can SVM be used for

- automatic EEG detection of drowsiness during car driving?", Safety Science.
- [14] Braunwald E. (Editor), Heart Disease: A Textbook of Cardiovascular Medicine, Fifth Edition, p. 108, Philadelphia, W.B Saunders Co. 1997.
 - [15] M. Patel, S. K. L. Lal, D. Kavanagh, and P. Rossiter, "Applying Neural Network Analysis on Heart Rate Variability Data to Assess Driver Fatigue", Expert Systems with Applications, Vol.38, No.6, pp.7235–7242, 2011.
 - [16] M. S. Kim, Y.N. Kim and Y. S. Heo, "Characteristics of Heart Rate Variability Derived from ECG during the Driver's Wake and Sleep States", Transaction of KASE, Vol.22, No.3, pp.136–142, 2014.
 - [17] M. H. Choi, J. J. Jung, S. W. Kim, "Drivers Drowsiness Detection System using the ECG measured by Non Contact Sensors", The Korean Institute of Electrical Engineers of Summer Conference, pp.1393–1394, 2015.
 - [18] A. Grillet, D. Kinet, J. Witt, M. Schukar, K. Krebber, F. Pirotte, and A. Depre, "Optical fiber sensors embedded into medical textiles for healthcare monitoring", IEEE Sensors Journal, vol. 8, no. 7, pp.1215–1220, 2008.
 - [19] S. Min, Y. Yun, C. Lee, H. Shin, H. Cho, S. Hwang, and M. Lee, "Respiration measurement system using textile capacitive pressure sensor", Trans KIEE, vol. 52, no. 1, pp. 58–63, 2010.
 - [20] Jaehee Park, Jaewoo Kim, Jaecheon Lee, "Real Time Driver's Respiration Monitoring", Journal of Sensor Science and Technology, Vol. 23, No. 2, pp.142–147, 2014.
 - [21] 김다정, "뇌파의 알파파 분석을 이용한 개인 상태의 졸음 검출", 울산대학교 대학원, 석사학위논문, 2013.
 - [22] 위키백과, <https://ko.wikipedia.org/wiki/EEG>
 - [23] 박문규, "뇌파기반 운전자 졸음감지 및 소형화 장치 개발에 관한 연구", 공학 석사학위논문, 08, 2015.
 - [24] 기계학습, https://ko.wikipedia.org/wiki/Machine_learning
 - [25] 딥 러닝, https://ko.wikipedia.org/wiki/Deep_learning
 - [26] Y. Bengio, A. Courville, and P. Vincent., "Representation Learning: A Review and New Perspectives," IEEE Trans. PAMI, special issue Learning Deep Architectures, 2013

- [27] J. Schmidhuber, "Deep Learning in Neural Networks: An Overview"
- [28] Szegedy, Christian, Alexander Toshev, and Dumitru Erhan. "Deep neural networks for object detection." Advances in Neural Information Processing Systems. 2013.
- [29] G. E. Hinton et al., "Deep Neural Networks for Acoustic Modeling in Speech Recognition: The shared views of four research groups," IEEE Signal Processing Magazine, pp. 82 - 97, November 2012.
- [30] Alex Krizhevsky, "Convolutional Deep Belief Networks on CIFAR-10"
- [31] A. Graves, M. Liwicki, S. Fernandez, R. Bertolami, H. Bunke, J. Schmidhuber. A Novel Connectionist System for Improved Unconstrained Handwriting Recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 31, no. 5, 2009.
- [32] M. Abadi, A. Agarwal, P. Barham and et al., "TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems", Distributed, Parrel, and Cluster Computing, 2016.
- [33] M. Abadi, P. Barham, J. Chen and et al., "TensorFlow: A system for large -scale machine learning", Distributed, Parrel, and Cluster Computing, 2016.
- [34] tensorflow, <https://www.tensorflow.org/>
- [35] Cox, DR (1958). "The regression analysis of binary sequences (with discussion)". 『J Roy Stat Soc B』
- [36] Sung Kim, <https://hunkim.github.io/ml/>
- [37] Andrew Ng, <https://www.coursera.org/learn/machine-learning>