



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 원저작자를 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 권리는 위의 내용에 의하여 영향을 받지 않습니다.

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

[Disclaimer](#)

2022년 2월
석사학위논문

다중의도 예측을 위한 딥러닝 기반 뇌-컴퓨터 인터페이스에 관한 연구

조선대학교 대학원

전자공학과

최 우 성

다중의도 예측을 위한 딥러닝 기반 뇌-컴퓨터 인터페이스에 관한 연구

A Study on Multi-Functional Brain-Computer Interface
Using Deep Learning

2022년 02월 25일

조선대학교 대학원

전자공학과

최 우 성

다중의도 예측을 위한 딥러닝 기반 뇌-컴퓨터 인터페이스에 관한 연구

지도교수 염 홍 기

이 논문을 전자공학석사학위신청 논문으로 제출함

2021년 10월

조선대학교 대학원

전자공학과

최 우 성

최우성의 석사학위논문을 인준함

위원장 조선대학교 교수 이인영 (인)

위원 조선대학교 교수 문지윤 (인)

위원 조선대학교 교수 염홍기 (인)

2021년 12월

조선대학교 대학원

목 차

목 차	I
표 목 차	III
도 목 차	IV
초 록	V
제1장 서 론	1
제1절 신경계와 뇌의 구성	1
제2절 인공지능과 딥러닝	5
제3절 뇌-컴퓨터 인터페이스 개요	7
제4절 연구의 필요성	11
제2장 본 론	12
제1절 뇌파 데이터	12
제2절 인공신경망을 활용한 다중의도 예측	16
1. 신호처리 과정	16
2. 인공신경망 구조	21
3. 인공신경망을 통한 의도 예측	22
제3절 컨볼루션 신경망을 활용한 다중의도 예측	23
1. 컨볼루션을 통한 특징추출	23
2. 컨볼루션 신경망 구조	25
3. 컨볼루션 신경망을 통한 의도 예측	26

제3장 실험결과 27

 제1절 인공신경망 분류결과 27

 제2절 컨볼루션 신경망 분류결과 28

제4장 결 론 30

참고문헌 31

표 목 차

[표 1.1.1 뇌의 분류]	2
[표 1.1.2 뇌파 특징의 종류]	4
[표 2.2.1 인공신경망 구조]	21
[표 2.2.2 컨볼루션 신경망 구조]	25
[표 3.1.1 인공신경망 학습 채널 수에 따른 분류 정확도]	27
[표 3.1.2 컨볼루션 신경망 분류 정확도]	28

도 목 차

[그림 1.1.1 인간 신경계의 구성]	1
[그림 1.1.2 대뇌의 분류]	3
[그림 1.1.3 뉴런의 구성]	4
[그림 1.2.1 뉴런과 인공 뉴런의 구조]	5
[그림 1.2.2 깊은 인공신경망의 구조]	6
[그림 1.3.1 뇌-컴퓨터 인터페이스 시스템 구조]	7
[그림 1.3.2 P300 특징을 활용한 Speller 흐름도]	8
[그림 1.3.3 SSVEP 뇌파 특징]	9
[그림 1.3.4 SMR 뇌파 특징]	10
[그림 2.1.1 SMR 실험 패러다임]	13
[그림 2.1.2 SSVEP 실험 패러다임]	14
[그림 2.1.3 학습에 사용된 뇌파의 채널]	15
[그림 2.2.1 인공신경망을 활용한 다중의도 예측 흐름도]	17
[그림 2.2.2 전처리 과정 도식표]	18
[그림 2.2.3 정규화 과정 도식표]	20
[그림 2.2.4 Tan-Sigmoid 함수]	21
[그림 2.2.5 인공신경망 학습 채널 위치]	22
[그림 2.3.1 컨볼루션 연산을 통한 SSVEP 특징 추출]	23
[그림 2.3.2 컨볼루션 연산을 통한 SMR 특징 추출]	24

ABSTRACT

Multi-Functional Brain-Computer Interface Using Deep Learning

Choi, Woo Sung

Advisor : Prof. Yeom Hong Gi Ph.D.

Dept. of Electronic Engineering,

Graduate School of Chosun University

Introduction: Brain-computer interface (BCI) is a technology that controls computers or machines using brain signals. With this technology, people with various disabilities, such as neural paralysis, and spinal cord injury can control electric devices or express their thoughts by simply thinking. The BCI types can be divided based on which electroencephalography (EEG) characteristic is used to predict intentions as follows. P300-based BCI uses amplitudes of P300. P300 is a positive peak of EEG signal that occur about 300ms after a visual stimulation. SMR is based on the characteristic that the power of alpha wave (8~13Hz) or beta wave (13~30Hz) on motor cortex is changed according to the user's imagination of body movement. Steady state visual evoked potential (SSVEP) based BCI uses a power spectrum of EEG signal measured on the visual cortex. To use the BCI system in daily life, the BCI should be able to predict various intentions such as direction of walking, text typing, and body movements. However, the previous BCI methods have a limitation that they can predict only one type of intention. In this paper, we propose a multi-functional BCI method that can predict various intentions simultaneously.

Method: To evaluate whether the proposed multi-function BCI can or cannot predict multiple intentions, different types of intentions, steady state visually evoked potential (SSVEP), sensory motor rhythm (SMR) and both of SSVEP and SMR (Multiple Intention), were predicted by one BCI model. We used EEG data measured during SSVEP and SMR paradigm, respectively, for 54 subjects. Signal processing of the multi-functional BCI is as


follows; noise was removed from electroencephalography (EEG) data using common average reference (CAR) and a band-pass filtering. After that, features that reflect user's multiple intentions are extracted using power spectrum analysis and normalization process. Finally, artificial neural networks or convolutional neural network predict multiple intentions.

Results: The prediction accuracy using convolutional neural network was 38.89% for Multiple Intentions. Chance level of the prediction was 1.56%. These results indicate that the proposed multi-functional BCI can predict multiple intentions. It also means that users of the proposed BCI system can control various electric devices simultaneously. Also, this will enable the application of practical BCI system for daily life in the near future.

제1장 서론

제1절 신경계와 뇌의 구성

뇌-컴퓨터 인터페이스는 인간의 뇌로부터 발생하는 뉴런 간의 신호를 이용한 인터페이스 방식이다. 따라서 뇌-컴퓨터 인터페이스를 이해하고 응용하기 위해서는 뇌와 뉴런에 대한 신경과학적 이해가 필요하다. 먼저 인간의 신경계는 해부학적으로 크게 두 개의 주요한 영역으로 나눌 수 있다. 그림 1.1.1과 같이 중추신경계(Central Nervous System; CNS)와 말초신경계(Peripheral Nervous System; PNS)로 분류된다 [1].




[그림 1.1.1 인간 신경계의 구성]

중추신경계는 크게 뇌와 척수로 구분할 수 있고, 말초신경계는 대뇌의 지배를 받는 체성신경계와 대뇌의 지배를 받지 않는 자율신경계로 구분할 수 있다. 몸의 여러 감각 기관들을 통해 받아들여진 정보들은 중추신경계인 척수를 통해 뇌로 전달되어 뉴런의 전기적, 화학적 신호작용에 의해 정보들을 처리하게 된다.

뇌는 일반적으로 1.4~1.5Kg의 무게와 1,400~1,500cc 정도의 부피를 지니며, 몸의 3%의 비율을 차지하는 뇌는 전체 사용 에너지의 25% 이상을 사용할 정도로 많은 에너지가 사용 되어지는 몸의 중추기관으로서의 역할을 수행한다. 뇌는 표 1.1.1과 같이 크게 대뇌(Cerebrum), 간뇌(Diencephalon), 소뇌(Cerebellum), 뇌간(Brainstem)으로 분류되며 그 중 대뇌는 그림 1.1.1과 같이 전두엽(Frontal lobe), 두정엽(Parietal lobe), 후두엽(Occipital lobe), 측두엽(Temporal lobe)로 구분할 수 있다 [1].

명칭		
뇌 (Brain)	대뇌 (Cerebrum)	전두엽 (Frontal lobe)
		두정엽 (Parietal lobe)
		후두엽 (Occipital lobe)
		측두엽 (Temporal lobe)
	간뇌 (Diencephalon)	시상 (Thalamus)
		시상하부 (Hypothalamus)
	소뇌 (Cerebellum)	
	뇌간 (Brainstem)	중뇌 (Midbrain)
		뇌교 (Pons)
		연수 (Medulla oblongata)


[표 1.1.1 뇌의 분류]



[그림 1.1.2 대뇌의 분류]

구분된 뇌의 각 영역에 따라 특정 행동들이나 의도를 가질 때 다른 곳에 비해 상대적으로 활발하게 활동하지만 이러한 영역들이 독립적으로 정해진 일만을 수행하는 것이 아닌 여러 영역들이 서로 신호를 주고받는 상호작용을 통해 협력하여 일을 수행하는 방식으로 동작한다.

이러한 뇌는 약 1,000억 개의 뉴런과 1조 개 정도의 신경교세포로 구성되어 있다. 뉴런(Neuron)이란 신경계를 구성하는 세포로서 그림 1.1.2와 같이 다른 뉴런으로부터 신호를 받아오는 축삭돌기(dendrtire), 받아들여진 정보를 추합하는 세포체(cell body)와 처리된 정보를 다른 뉴런에게 전달하는 통로인 축삭돌기(axon)으로 구성되어있다. 축삭돌기의 말단에는 시냅스라는 부분을 통해 전기적, 화학적 작용에 의해 다른 뉴런의 수상돌기로 정보를 전달하게 된다.



[그림 1.1.3 뉴런의 구성]


신경계 중 뇌 신경간의 신호가 전달될 때 생기는 전기적 활동을 기록한 것을 뇌파(Electroencephalography; EEG)라고 하며, 뇌파는 특정 자극이나 의도에 따라 표 1.1.2와 같은 특징을 지닌 뇌파 양상을 관찰할 수 있으며 이러한 각각의 특징들을 이용한 Brain-Computer Interface 연구들이 진행 되어지고 있다 [2].

뇌파 특징	특징의 양상
Steady-State visual evoked potential (SSVEP)	특정 주파수의 시각 자극에 의해 시각피질의 뇌파에서 동일 주파수의 뇌파가 관찰되는 특징
Sensori-Motor Rhythm (SMR)	인체의 움직임이나 움직임의 의도에 따른 알파파와 베타파의 변화
Event-Related Potential (ERP)	반복 자극 중 특이한 특정 자극이 제시될 때 나타나는 뇌파 특징
Slow Cortical Potential (SCP)	0.3초에서 10초 정도 유지되는 서파(slow wave)의 일종
Auditory Steady-State Response (ASSR)	특정 주파수의 소리 자극에 집중할 때 반대 반구 측두엽에서 관찰되는 특징

[표 1.1.2 뇌파 특징의 종류]

제2절 인공지능과 딥러닝

이러한 뇌파의 복잡한 신호 구성과 특징을 분류하기 위해 딥러닝 모델을 활용하고자 한다. 딥러닝 모델의 이해를 위해서는 인공신경망의 기본 단위인 인공 뉴런에 대한 이해가 필요하다. 인공 뉴런은 뉴런의 생물학적 동작에 기반한 통계학적 학습 알고리즘으로서 그림 1.2.1의 우측과 같이 외부로부터 입력데이터를 받아 각각의 가중치를 곱하고 전부 더한 값과 편향(bias) 값을 더한 뒤 활성화 함수를 거쳐 값을 출력하는 구조이다 [3].




[그림 1.2.1 뉴런과 인공 뉴런의 구조]

x_1, x_2, \dots, x_n 은 인공 뉴런의 입력값으로 들어오는 값이다. w_1, w_2, \dots, w_n 은 각각의 입력 값에 곱해지는 가중치 파라미터를 의미한다. b 는 바이어스 파라미터를 의미하며 입력 값에 각각의 가중치가 곱해진 값들의 합과 바이어스의 합이 f 라는 활성화 함수를 거쳐 최종적으로 출력되는 값이 y 이다. 이를 수식으로 표현하면 다음의 (1.1) 식과 같이 표현할 수 있다.

$$y = f((x_1 \times w_1 + x_2 \times w_2 \dots x_n \times w_n) + b) \quad (1.1)$$

하지만 단일 인공 뉴런의 한계점은 1차 선형분류문제를 해결하는 것은 가능하였지만 다차원의 비선형 문제와 같이 분류기준이 복잡한 문제나 XOR와 같은 문제는 분류하지 못한다는 한계점이 존재한다.

이러한 한계를 해결하기 위해 인공 뉴런을 쌓아 확장 시킨 구조가 바로 딥러닝이다. 깊은 인공신경망의 구조는 그림 1.2.2과 같이 외부 데이터 입력을 받는 입력층(Input Layer), 겉으로 드러나지 않고 학습을 진행하는 은닉층(Hidden Layer), 결과값을 출력하는 출력층(Output Layer)로 구성되어있다.

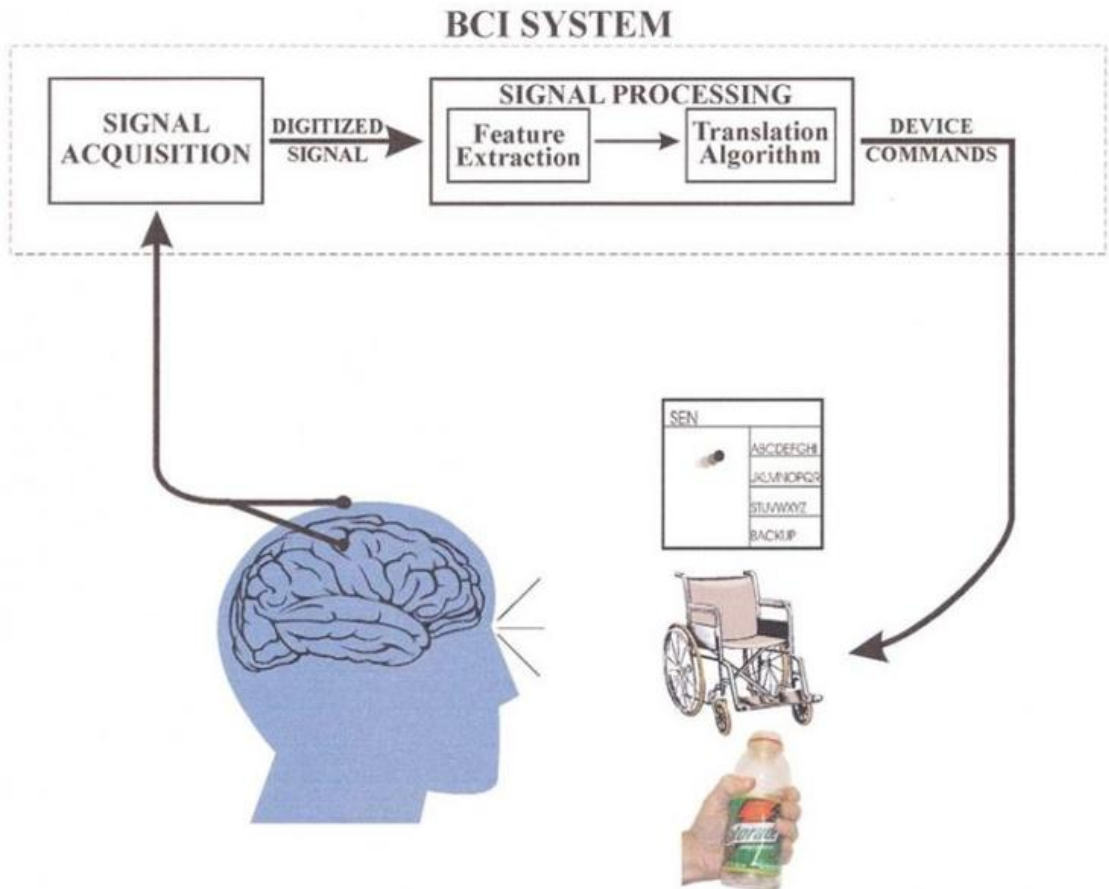


[그림 1.2.2 깊은 인공신경망의 구조]

이러한 신경망은 데이터의 실제 값과 모델이 예측한 값 사이의 손실 값이 최소가 되는 방향으로 가중치를 조정하며 학습한다. 이 때 사용되는 기본적인 방식이 역전파 알고리즘이다 [4]. 역전파 알고리즘은 최초 신경망을 통해 출력된 값과 실제값의 오차를 손실함수를 통해 확인하고, 출력층에서 입력층의 방향으로 손실함수의 미분을 통해 가중치와 바이어스를 업데이트시킨다. 이를 통해 손실 값이 최소가 되도록 가중치를 업데이트하는 방식으로 학습을 진행한다.

제3절 뇌-컴퓨터 인터페이스 개요


뇌-컴퓨터 인터페이스(Brain Computer Interface; BCI)는 그림 1.3.1과 같이 신경 신호를 분석하여 사용자의 의도를 예측하고, 예측된 의도를 바탕으로 로봇이나 컴퓨터를 제어하는 기술이다 [5]. 이는 마비나 척수 손상으로 거동이 불편한 환자나 장애인들이 자신의 생각만으로 전자기기를 제어할 수 있도록 도울 수 있다는 점에서 유망한 인터페이스 기술로 주목받고 있다. BCI 방법에는 의도를 예측하기 위해 사용되는 뇌파 (Electroencephalography; EEG) 특징에 따라 나눌 수 있다.



[그림 1.3.1 뇌-컴퓨터 인터페이스 시스템 구조]

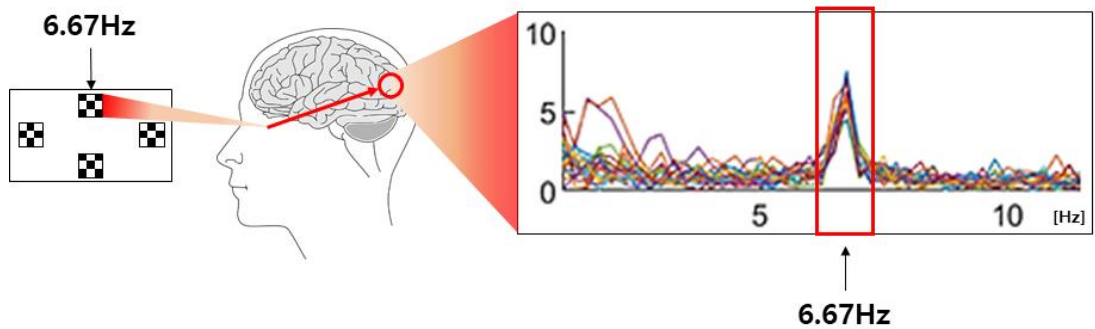
느린 피질 전압(Slow Cortical Potential; SCP) 기반 BCI는 사용자의 의식집중 수준에 따라 EEG 신호의 진폭이 증가하거나 감소하는 특성을 사용한다. SCP 기반 BCI는 스위치(ON/OFF)를 제어하는 연구에 사용되거나, 마비된 뇌졸중 환자 또는 주의력 결핍 과잉 행동 장애(ADHD)의 치료 방법으로 사용되었다. 오늘날 이 방법은 너무 느리고 간단한 작업만 수행하는 데 사용할 수 있기 때문에 거의 사용되지 않는다.

P300 기반 BCI는 P300의 진폭을 사용한다. P300은 동일하게 반복되는 자극 특이한 자극이 제시되고 약 300ms 후에 전위가 발생하는 특징을 지닌 EEG 신호의 값이다. 이러한 뇌파의 특징을 활용한 연구 동향으로는 그림 1.3.2와 같이 화면에 문자로 구성된 행렬의 행 또는 열이 랜덤하게 깜박이는 자극이 주어질 때, 피험자가 입력하고자 한 글자를 응시하고 있으면 P300의 진폭은 사용자의 주의가 집중되는 자극에서 가장 크게 나타난다. 따라서 사용자는 모니터의 글자만 봐도 P300의 최대값을 가진 문자 선택함으로써 키보트 타이핑을 할 수 있도록 돕는 것이다 [6]. P300 speller의 정확도를 향상시키기 위해 2D 대신 자극 형태를 3D로 만들고 [7] 자극 색상을 변경하며 교정 방법을 변경하는 방법이 제안되었다 [8]. 또한 예측 정확도와 입력 속도를 향상시키기 위해 제안된 딥 러닝 방법을 사용한 사례도 보고되었다 [9].



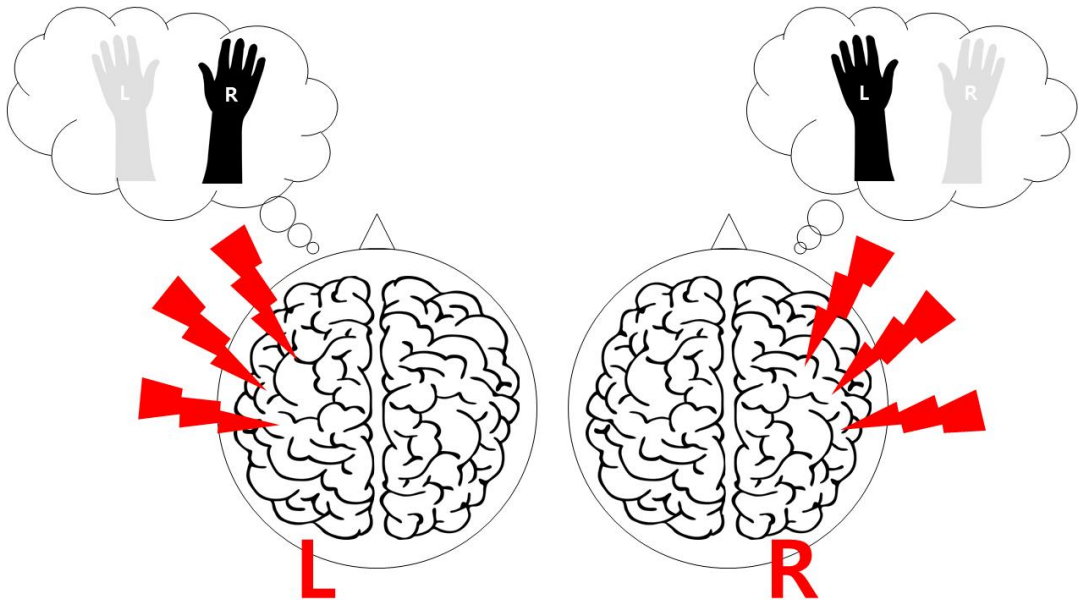
[그림 1.3.2 P300 특징을 활용한 Speller 흐름도]

정상 상태 시각 유발 전위(Steady State Visual Evoked Potential; SSVEP) 기반 BCI는 시각 피질에서 측정된 EEG 신호의 파워 스펙트럼을 사용한다. 그림 1.3.3과 같이 각기 다른 주파수로 깜박이는 시각적 자극이 사용자에게 표시될 때, 사용자가 선택하고자 하는 하나의 시각적 자극에 초점을 맞추면 EEG의 파워 스펙트럼은 자극과 동일한 주파수에서 높은 파워 값을 나타낸다. 최근 연구에서 스위치 기능을 활용한 speller가 제안되어 두 개의 레이어로 구성된 시각 자극 화면을 전환하는 방식으로 4개의 주파수만 사용하여 16개의 텍스트를 선택할 수 있도록 하는 연구가 수행되어졌다 [10]. 티이핑 맞춤법 정확도 향상을 위해 딥 러닝 모델을 사용한 SSVEP 연구도 수행되었다 [11]. 또한 휠체어 방향을 제어하기 위해 SSVEP의 자극을 활용하여 방향을 자가 선택하여 제어가 가능하도록 하는 연구도 수행되었다 [12].



[그림 1.3.3 SSVEP 뇌파 특징]

감각-운동 리듬(Sensory Motor Rhythm; SMR)은 운동피질에서 알파파(8~13Hz)나 베타파(13~30Hz)의 값이 사용자의 신체 움직임이나 신체를 움직이고자 하는 의도에 따라 상상을 할 때 사상관련동기화(Event-related synchronization; ERS)나 사상관련비동기화(Event-Related Desynchronization; ERD) 현상이 나타는데, 이러한 특징의 변화량을 기반으로 한다. 사용자가 왼손의 움직임을 상상하면 오른쪽 대뇌의 운동 피질에서 신호가 감소하는 ERD 특징이 관찰되어지고, 사용자가 오른손의 움직임을 상상하면 왼쪽 대뇌의 운동 피질에서 ERD 변화가 관측된다. SMR 특징은 움직임 상상뿐만 아니라 실제 움직임을 수행할 때도 발생하며 이러한 특징을 활용하여 로봇의 팔이나 휠체어의 방향을 제어할 수 있도록 적용한 연구 등이 진행되었다.



[그림 1.3.4 SMR 뇌파 특징]

제4절 연구의 필요성

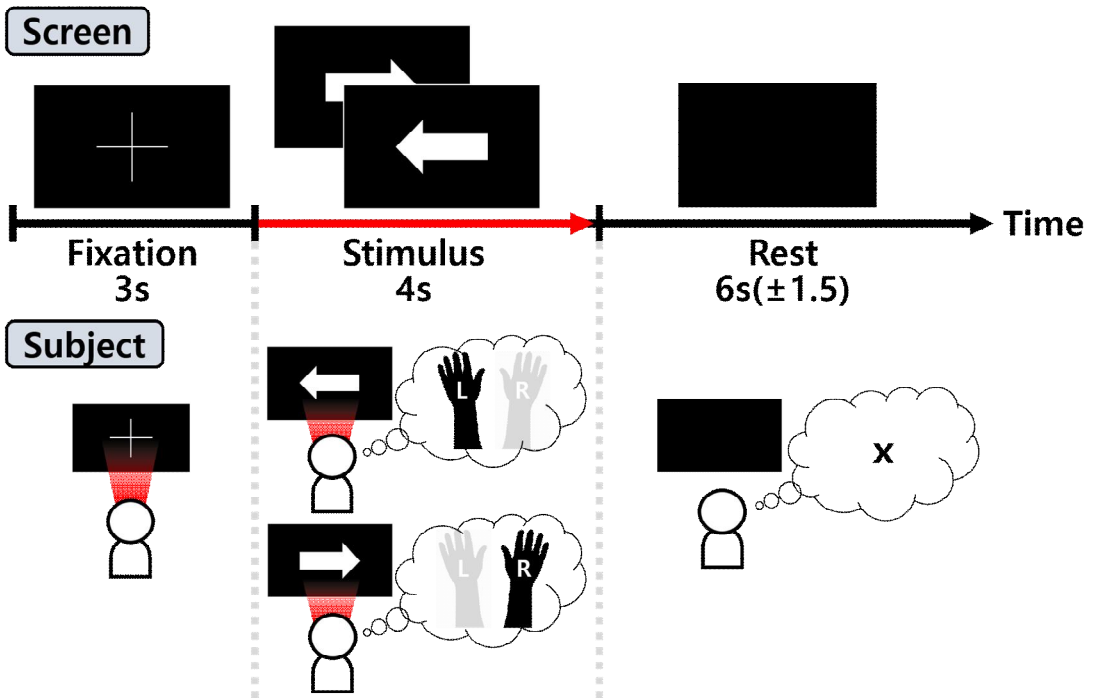
뇌파의 특성은 어떤 의도를 가지는지, 어떠한 자극을 받았는지, 어떠한 뇌파의 특징을 사용하고자 하는지에 따라 각각의 특징을 추출하여 의도를 예측하는 방법에 차이가 있다. 기존의 연구들은 단일 특징을 예측하여 적용하였기 때문에 또 다른 특징의 뇌파를 동시에 예측할 수 없다는 한계점이 존재하였다. 하지만 이러한 뇌-컴퓨터 인터페이스를 일상생활 가운데 적용시키기 위해서는 우리가 일상 가운데 길을 걸으며 의사결정을 하거나 컵을 손에 든 채 키보드를 타이핑 하는 등 여러 가지 의도를 동시다발적으로 처리하고 행동하는 것과 같이 BCI가 의사결정이나 텍스트 타이핑 및 신체 움직임과 같은 다양한 의도를 동시 다발적으로 예측할 수 있어야 한다. 따라서 사용자의 다중 의도를 동시에 예측할 수 있는 다중의도 예측 BCI 시스템을 개발하는 것이 필수적이다. 본 연구에서, 다양한 의도를 동시에 예측하기 위해 딥러닝을 활용하여 단일 특징뿐만 아니라 서로 다른 특징이 동시 다발적으로 수행된 경우도 예측 및 분류가 가능한 다중의도 예측 뇌-컴퓨터 인터페이스 방법을 제안한다.

제2장 본론

제1절 뇌파 데이터

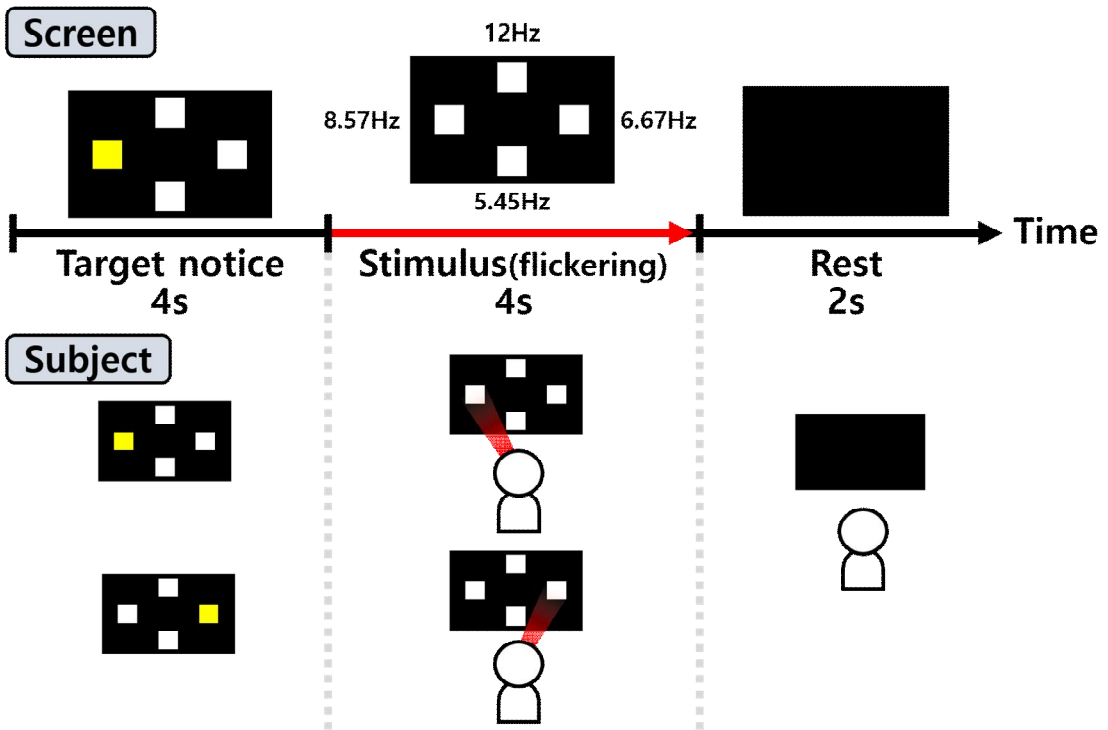
제안하는 뇌-컴퓨터 인터페이스 모델이 여러 의도를 예측할 수 있음을 확인하기 위해 SSVEP 및 SMR 패러다임으로 측정된 두 개의 오픈 데이터 세트를 사용했다 [12]. 데이터는 샘플링 주파수가 1,000Hz인 64 채널 EEG 장치를 사용하여 측정되었다. 제안된 BCI 모델을 평가하기 위해 30명의 피험자 EEG 데이터가 사용되었다. 피험자들은 21인치 LCD 모니터 앞에 있는 의자에 앉아 시각적 자극을 그림 2,3과 같이 화면에 표시해주었다. 피험자들은 각각 SMR과 SSVEP 자극이 제시되는 동안 움직임을 상상하고 표적을 관찰하도록 지시한 상황 가운데 뇌파가 측정되었다.

SMR 패러다임은 움직임에 관한 의도를 반영하는 뇌파를 측정하는 것이다. SMR 패러다임 실험 동안 피실험자는 그림 2.1.1과 같이 시각적 제시로 나타나는 화살표의 방향에 해당되도록 오른쪽 또는 왼쪽 팔 움직임을 상상하도록 지시받는다. 처음 3초 동안 화면 중앙에 고정 십자가가 표시되고, 피실험자들은 화면 중앙에 시선을 집중하라는 지시를 받는다. 십자선이 표시된 후 4초 동안 화면에 왼쪽 또는 오른쪽 화살표가 무작위로 표시되며 피실험자들은 화살표 방향에 따라 오른손이나 왼손의 움직임을 상상해야 한다. 화살표가 표시된 후 피실험자는 약 4.5초에서 7.5초 동안 휴식을 취하라는 지시를 받는 것까지 한 번의 trial로. 실험은 각 방향에 대해 50번 반복되었다. 따라서 각 task 별로 100회(2개 방향 × 50회)를 측정하였다.



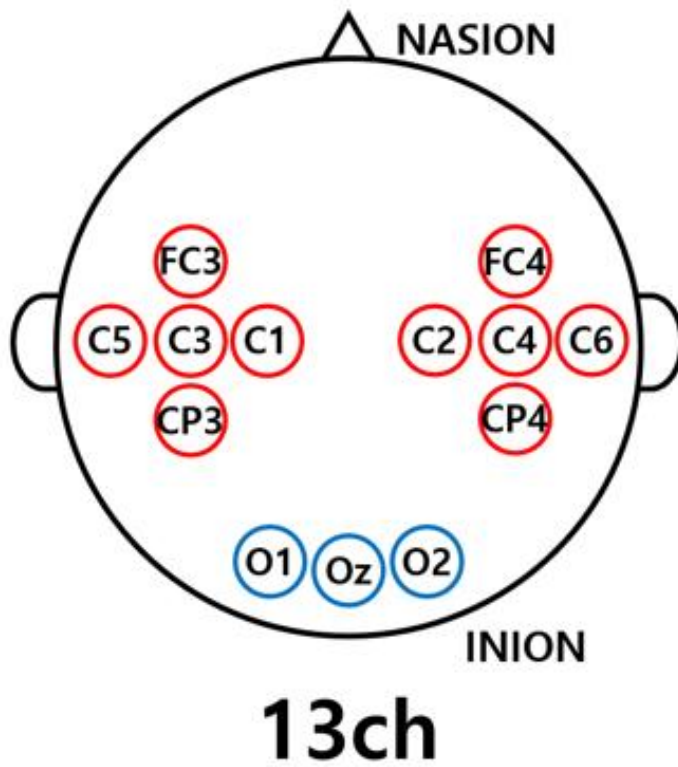
[그림 2.1.1 SMR 실험 패러다임]

SSVEP 패러다임은 시각적 자극에 대한 반응을 반영하는 뇌파를 측정하는 것이다. SSVEP 패러다임 실험 동안 피실험자는 그림 2.1.2와 같이 실험 시작 시 4개의 정사각형이 4초 동안 상, 하, 좌, 우 방향으로 나타납니다. 네 칸 중 세 칸은 흰색이고 한 칸은 피험자가 응시해야 하는 타겟으로서 노란색 박스를 나타낸다. 노란색 사각형은 무작위로 선택된다. 타겟 지시 후 4초 동안 서로 다른 주파수로 깜박(위: 12Hz, 아래: 5.45Hz, 왼쪽: 8.75Hz, 오른쪽: 6.67Hz)이는 4개의 사각형이 표시되었다. 이제, 피실험자는 목표물에 시선을 집중하라는 지시를 받고, 깜박이는 자극 후에 피험자는 2초 동안 쉬도록 지시받는다. 실험은 각 타겟에 대해 25회 반복되었다. 따라서 각 타겟에 대해 100회 자극(4개 타겟 × 25회 반복)이 측정되었다..



[그림 2.1.2 SSVEP 실험 패러다임]

신경망의 학습을 위해 모든 채널을 사용할 수 있지만 데이터가 너무 많을 경우 학습이 진행되는데 오랜 시간이 소요되고 정확도의 향상 폭도 크지 않기 때문에 각 패러다임으로 측정된 62채널의 데이터 중 그림 2.1.3과 같이 특징이 발현될 것으로 기대하는 13개의 채널을 사용하였으며, 각각 SMR의 특징이 잘 나타나는 머리의 중심부 좌,우측의 채널(빨간색 동그라미)과 SSVEP의 특징이 잘 나타나는 후두부의 채널(파란색 동그라미) 데이터 채널을 사용하였다.

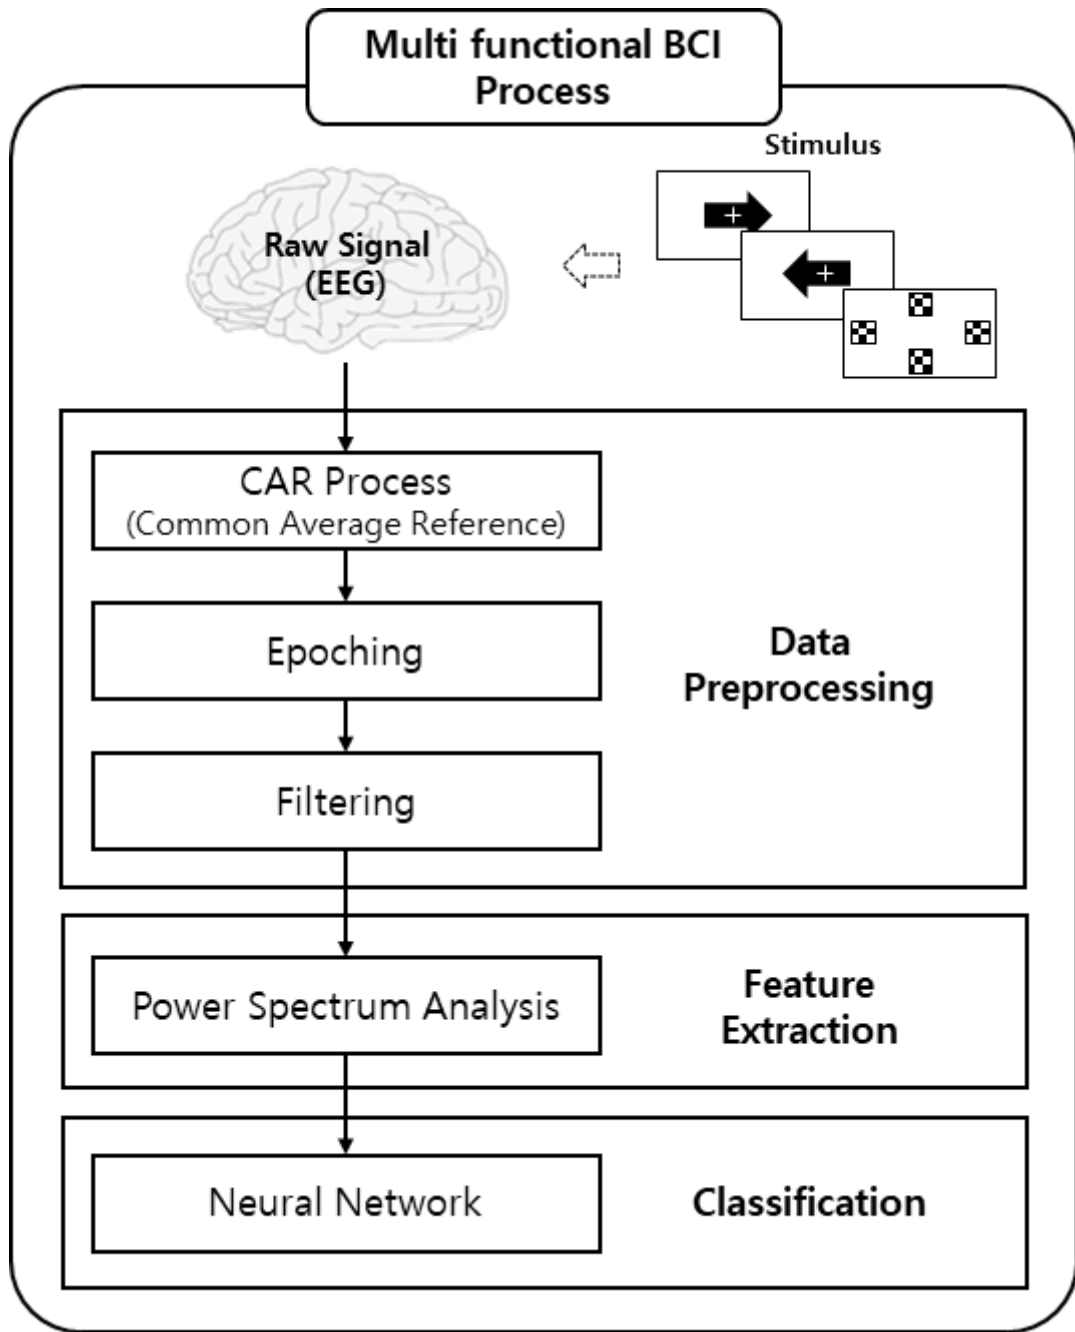


[그림 2.1.3 학습에 사용된 뇌파의 채널]

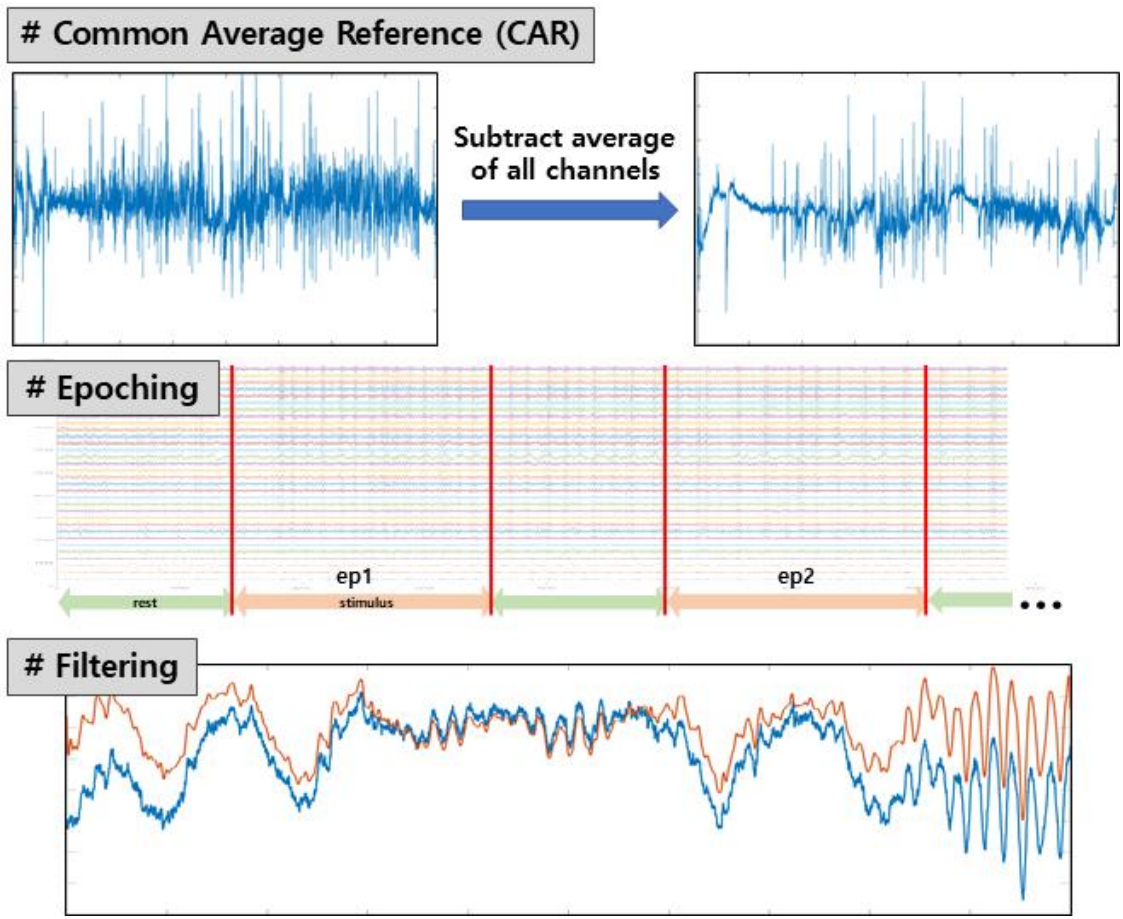
제2절 인공신경망을 활용한 다중의도 예측

1. 신호처리 과정

제안된 다중의도 예측 뇌-컴퓨터 인터페이스 과정은 그림 2.2.1과 같이 데이터 수집, 전처리(Data Preprocessing), 특징추출(Feature Extraction) 및 분류(Classification)의 과정으로 구성된다. 먼저 CAR(Common Average Reference) 과정을 수행한다. 뇌의 뉴런이 서로 정보를 주고 받을 때 전기적 신호가 발생되는데 이러한 신호는 뇌막과 두개골을 거쳐 두피 표면에서 측정된다. 두피는 전도성을 지니기 때문에 주변의 다른 지역의 뉴런의 활동으로 인한 전기적 신호가 섞여 측정된다. 이러한 채널 간의 잡음을 제거하기 위해 각 채널 신호에서 전체 채널 신호의 평균을 빼는 과정을 수행하는데, 이를 CAR 처리과정 이라고 한다. 다음으로, 에포킹(epoching) 과정을 진행한다. 에포킹은 특정 간격으로 신호를 추출하는 과정으로서, SMR 및 SSVEP 패러다임에 대해 각각 자극이 주어진 시점과 휴식 상태의 구간을 추출하였다. 이후 뇌파를 측정하는 주변 환경의 전원공급에 따른 60Hz를 제거하고 불필요한 저역주파수 대역의 정보를 걸러내기 위해 1~50Hz 대역통과필터링(Band-Pass Filtering; BPF)을 진행한다. 데이터의 전후 처리 과정은 그림 2.2.2와 같다.



[그림 2.2.1 인공지능망을 활용한 다중의도 예측 흐름도]



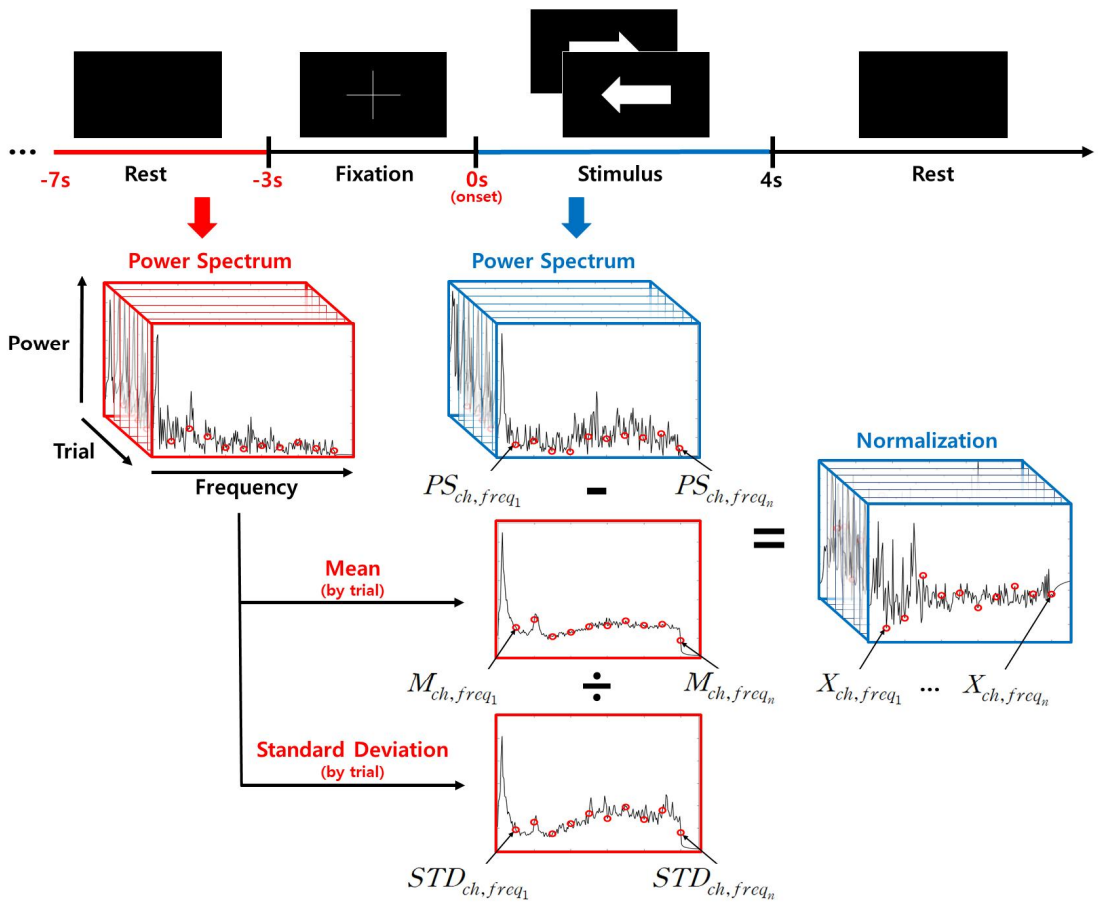
[그림 2.2.2 전처리 과정 도식표]

데이터 전처리 후, 주파수축에서 분석하기 위해 고속 푸리에 변환(Fast Fourier Transform; FFT)을 통해 파워 스펙트럼을 구하였다. 시각 피질 근처의 채널에서 측정된 데이터의 파워 스펙트럼을 통해서 피험자가 응시하는 시각 자극의 깜박이는 주파수와 동일한 값의 주파수 값에서 파워가 높게 나타남을 확인할 수 있다. 또한 운동 피질 근처 채널의 파워 스펙트럼에서는 8-30Hz에서는 움직임 상상에 따라 좌, 우 영역에서 알파파와 베타파에 해당하는 전력 스펙트럼이 감소하는 것을 확인할 수 있다.

이후 정규화(Normalizaion) 과정이 수행된다. 파워 스펙트럼 분석에서 저주파의 대역의 파워가 고주파의 파워보다 상대적으로 높은데, 고주파 대비 저주파의 학습 편향이 일어날 수 있기 때문에 인공신경망의 학습이 원활하게 이루어지지 않아 예측 정확도가 낮아진다. 따라서, 낮은 주파수와 높은 주파수의 특성을 고르게 훈련시키기 위해 정규화를 적용하였다. 또한 정지 상태(휴식) 대비 자극 상태(움직임 상상 또는 깜박이는 표적 관찰)의 변화를 명확하게 만든다. 정규화는 그림 2.2.3과 같이 각 채널 및 주파수에 대해 계산하였다. 평균 및 표준편차는 식 다음 방정식을 사용하여 계산되었다. 방정식에서 n 은 전체 시간 포인트를 나타내며, x_i 는 휴식상태의 각 주파수에 대한 파워 스펙트럼 값을 나타낸다.

$$mean = \sum_{i=1}^n \frac{1}{n} x_i \quad (2.1)$$

$$standard\ deviation = \sqrt{\frac{\sum_{i=1}^n (x_i - mean)^2}{n - 1}} \quad (2.2)$$



$$\therefore X_{ch, freq_1} = (PS_{ch, freq_1} - M_{ch, freq_1}) / STD_{ch, freq_1}$$

[그림 2.2.3 정규화 과정 도식표]

2. 인공신경망 구조


다중의도를 예측하기 위해 인공신경망을 사용하였다. 인공신경망이란 인공 뉴런이라고 불리는 단위의 집합체로서, 생물학적 뇌의 뉴런을 모델링하여 만들어졌다. 각각의 연결은 시냅스처럼 다른 인공 뉴런에게 신호를 전송할 수 있으며, 신호는 입력과 가중치의 곱과 합을 통해 생성된 값이 비선형 함수를 거쳐 생성된 실수 값이다.

본 연구에서 사용한 인공신경망의 구조는 표 2.2.1과 같다.

	# of unit	Activation Function
Input Layer	13	-
1 st Hidden Layer	100	Sigmoid
2 nd Hidden Layer	50	Sigmoid
Output Layer	6	Tan-Sigmoid

[표 2.2.1 인공신경망 구조]

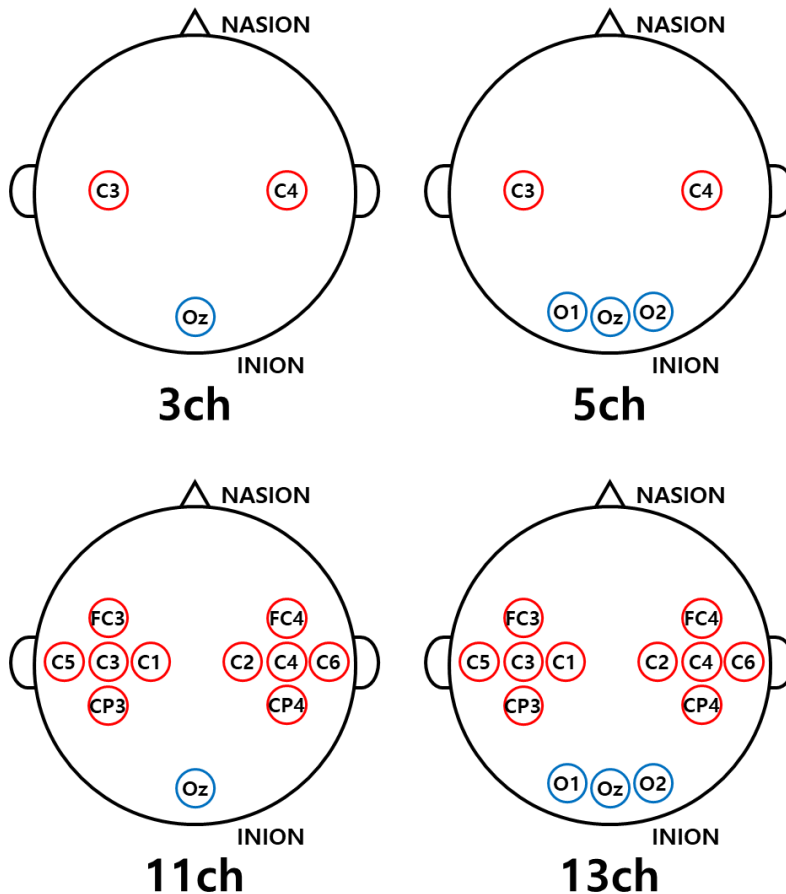
출력단의 활성화 함수로 사용된 Tan-Sigmoid는 그림 2.2.4과 같이 최소 -1부터 +1 사이 값으로 반환해주는 비선형 함수이다.



[그림 2.2.4 Tan-Sigmoid 함수]

3. 인공신경망을 통한 의도 예측

제안된 뇌-컴퓨터 인터페이스 모델이 다중 의도를 예측할 수 있는지를 확인하기 위해 SSVEP와 SMR의 단일 의도에 대한 데이터셋과, SSVEP가 두드러지게 나타나는 시각 피질(O1~O3 채널)의 뇌파 신호와, SMR이 두드러지게 나타나는(C1~4, FC3~4, CP3~4 채널)의 EEG신호를 결합하여 다중의도 데이터 셋을 만들어 학습을 진행하였다. 학습의 종료는 최소 성능 기울기가 '1e-20'을 달성하면 종료되도록 하였으며, 학습이 완료된 모델에 대하여 각각의 동일한 패러다임으로 측정된 테스트 데이터를 통해 신경망의 정확도를 확인하였고, 사용 채널 수에 따른 정확도의 비교를 위해 그림 2.2.5와 같이 각각 3ch, 5ch, 11ch, 13ch로 학습을 진행하였다.



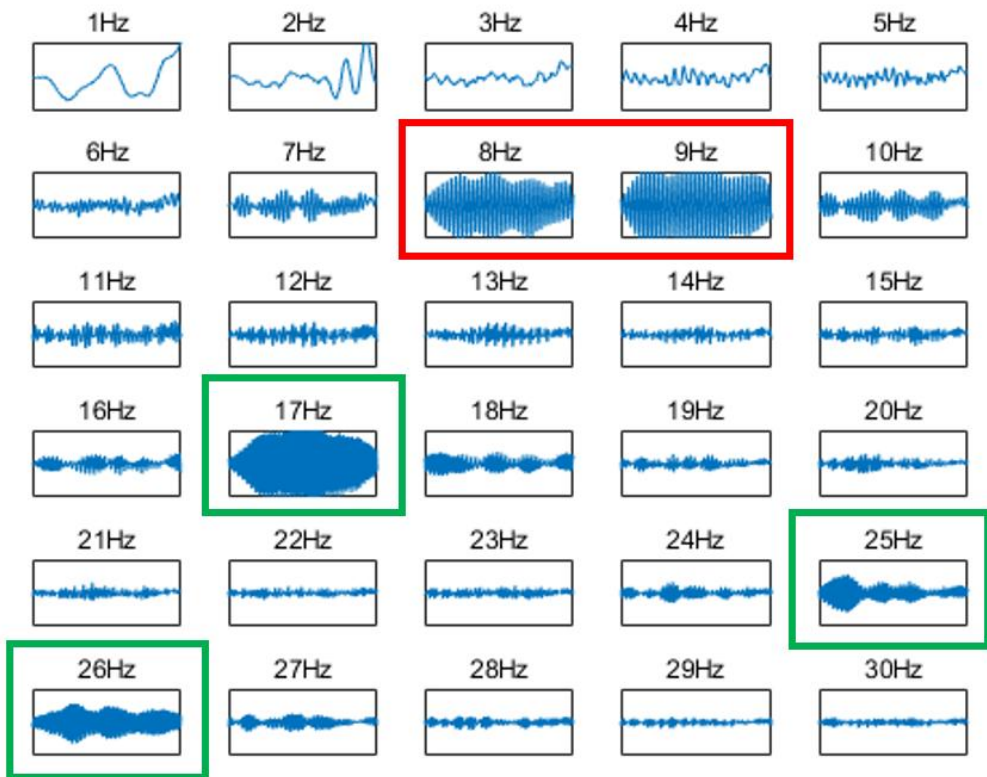
[그림 2.2.5 인공신경망 학습 채널 위치]

제3절 컨볼루션 신경망을 활용한 다중의도 예측

1. 컨볼루션을 통한 특징추출


인공신경망을 활용한 다중의도 분류의 한계점에서는 단일 의도분류에 비해 낮은 분류 정확도와 모델의 학습을 위한 데이터 전처리 과정이 필요하고, 은닉층에서 뇌파 특징이 어떻게 추출 되어지는지 확인할 수 없다는 한계점이 존재하였다. 이러한 한계점을 컨볼루션 신경망을 활용해 개선하기 위해 먼저 컨볼루션 연산이 뇌파의 SSVEP나 SMR과 같은 특징 추출이 가능한지에 대해 확인하였다.

그림 2.3.1과 같이 1~30Hz의 사인 파형을 8.57Hz의 시각 자극 시 측정된 뇌파에 컨볼루션을 수행한 경우 8, 9Hz의 값이(빨간색 상자) 크게 나타난 것을 확인할 수 있다. 또한 8.57의 하모닉 성분(17.14Hz: 2배, 25.71: 3배)에서도 다른 주파수에 비해 값이 크게 나타난 것을 통해 컨볼루션 연산을 통한 SSVEP 특징추출이 가능함을 확인하였다.



[그림 2.3.1 컨볼루션 연산을 통한 SSVEP(8.57Hz 시각자극) 특징 추출]

다음으로 왼손을 움직이는 상상한 경우 측정된 뇌파 데이터에 1~30Hz의 컨볼루션을 진행하였다. 그림 2.3.2와 같이 저주파수 대역에서 휴식 상태(빨간색 상자) 자극이 주어지는 시간 이후(초록색 상자) 파워가 줄어들며 ERD나 나타남을 확인하였다. 이를 통해 전처리 과정 없이 컨볼루션 연산만으로 SSVEP와 SMR의 특징을 동시에 추출할 수 있음을 확인하여 컨볼루션 연산을 통해 다중 의도를 예측해보았다.



[그림 2.3.2 컨볼루션 연산을 통한 SMR 특징 추출]

2. 컨볼루션 신경망 구조

컨볼루션 신경망이란 인공지능이란 컨볼루션 연산을 기반으로 한 인공지능망으로서 이미지로부터 특징을 추출하는데 뛰어난 성능을 보이는 인공지능망 중 하나이다. 신경망의 각 계층은 컨볼루션 연산을 수행하는 컨볼루션 층(Convolution Layer)과 데이터의 특징을 유지하고, 크기는 줄이기 위해 Down Sampling을 수행하는 풀링 층(Pooling Layer)으로 구성되어 있으며, 마지막에 추출된 특징을 학습하여 분류를 학습하는 인공지능망 층(Dense Layer)으로 구성되어 있다. 사용한 컨볼루션 신경망의 세부 구조와 파라미터는 표 2.2.2와 같으며 Optimizer로는 Adam optimizer를 사용하였다.

	Layer	Data shape (Kenel size, # of Filter)	Activation Function
1 st Layer	Convolution	$4000 \times 13 (10 \times 1, 25)$	ReLU
2 nd Layer	Convolution	$3991 \times 13 \times 25 (1 \times 13, 25)$	ELU
3 rd Layer	Max Pooling	$3991 \times 25 (3 \times 1)$	-
4 th Layer	Convolution	$1330 \times 25 (10 \times 25, 50)$	ELU
5 th Layer	Max Pooling	$1321 \times 50 (3 \times 1)$	-
6 th Layer	Convolution	$440 \times 50 (10 \times 50, 100)$	ELU
7 th Layer	Max Pooling	$431 \times 100 (3 \times 1)$	-
8 th Layer	Convolution	$143 \times 100 (10 \times 100, 200)$	ELU
9 th Layer	Max Pooling	$134 \times 200 (3 \times 1)$	-
10 th Layer	Fully-connected	-	Softmax

[표 2.2.2 컨볼루션 신경망 구조]

3. 컨볼루션 신경망을 통한 의도 예측

컨볼루션 신경망을 활용하여 다중의도 예측을 위해 각 패러다임을 측정된 데이터로부터 CAR과정과 자극을 받은 부분만을 epoching하는 과정을 거쳐 별도의 전처리 과정없이 컨볼루션 신경망 모델에 학습을 진행하였다. 인공신경망과 동일하게 SSVEP와 SMR의 단일 의도에 대한 데이터셋과, SSVEP가 두드러지게 나타나는 시각 피질(O1~O3 채널)의 뇌파 신호와, SMR이 두드러지게 나타나는(C1~4, FC3~4, CP3~4 채널) EEG신호 13채널을 결합하여 다중의도 데이터 셋을 만들어 학습과 평가를 진행하여 정확도를 구하였다.

제3장 실험결과

제1절 인공신경망 분류결과

인공신경망을 활용한 다중의도 분류 정확도는 표 3.1.1과 같다.

Intention # of ch	Accuracy[%]		
	SSVEP	SMR	Multiple Intention
3ch	57.35	43.00	32.96
5ch	57.98	44.22	32.33
11ch	65.89	38.85	27.65
13ch	67.81	39.65	28.51
Chance Level	1.56 ($1/2^6$)		

[표 3.1.1 인공신경망 학습 채널 수에 따른 분류 정확도]

SSVEP 분류 정확도의 경우 가장 높은 정확도는 13ch의 67.81%, 가장 낮은 정확도는 3ch의 57.35%이다. SMR 분류 정확도의 경우 5ch의 데이터를 사용한 경우 44.22%로 가장 높은 분류정확도가 측정되었고, 11ch의 경우 38.85%로 가장 낮은 정확도를 보였다. 다중의도의 경우 3ch 32.96%로 가장 높은 정확도를 기록하고, 11ch을 사용한 경우 27.65%의 정확도로 가장 낮았다. 6개의 출력에 대해 각 출력의 기댓값은 2개(0과 1)이기 때문에 최소 기대 정확도는 1.56%입니다. 전체적으로 분류 정확도가 높진 않았지만 최소 기대 정확도 보다 유의하게 높은 결과 값을 통해 인공신경망을 활용하여 다중 의도를 예측할 수 있음을 의미한다.

제2절 컨볼루션 신경망 분류결과

컨볼루션 신경망을 활용한 다중의도 분류 정확도는 표 3.1.2와 같다.

Subjects \ Intention	Accuracy[%]		
	SSVEP	SMR	Multiple Intention
1	100	92	89
2	97	85	47
3	98	94	42
4	92	83	57
5	90	98	67
6	95	93	53
7	52	53	13
8	78	80	30
9	89	70	50
10	45	82	24
11	60	63	13
12	61	91	20
13	92	90	21
14	100	92	67
15	65	48	20
16	99	56	46
17	76	50	14
18	93	73	28
19	99	61	53
20	93	67	28
21	24	64	18
22	98	62	36
23	86	73	32
24	100	66	49
25	100	49	54
26	96	49	45
27	83	50	42.9
28	89	54	47
29	40	56	19.9
30	86	48	40.9
Average	82.53	69.73	38.89
Neural Network	67.81	39.65	28.51

[표 3.1.2 컨볼루션 신경망 분류 정확도]

각 피험자별 뇌파 특징 분류 정확도와 함께 모든 피험자에 대한 분류 정확도의 평균 값을 Average에 표기하였다. 인공지능망의 경우와 비교를 위해 동일한 조건에서 실시한 평균 정확도를 Neural Network에 표시하였다. 컨볼루션 신경망을 활용한 전체 피험자에 대한 평균 정확도는 각각 SSVEP는 82.53%, SMR 69.73%, 다중의도는 38.89%로서 인공지능망을 활용한 경우와 비교해볼 때 SSVEP는 13.72%, SMR 30.08%, 다중의도는 10.38%의 정확도가 높아진 것을 확인할 수 있다.

제4장 결론

본 연구에서는 인공신경망과 컨볼루션 신경망과 같은 딥러닝을 사용하여 움직임 상상이나 시각 자극으로 인해 발생하는 뇌파의 특징을 동시다발적으로 분류하여 예측 할 수 있는 다기능 뇌-컴퓨터 인터페이스 모델을 제안했다. 인공신경망을 활용한 모델을 통해 다중의도 뇌파특징이 동시다발적으로 분류가 가능함을 확인하였고, 더 나아가 컨볼루션 신경망을 활용하여 기존 전처리 과정을 수행하여 특징을 추출해주어야 했던 인공신경망의 신호처리 과정을 간소화 시켰을 뿐 아니라, 뇌파의 특징이 컨볼루션 연산을 통해 추출되는지 확인하였으며 정확도에 대해서도 큰 폭 상승을 통해 더욱 높은 분류 정확도로 다중의도를 예측 가능함을 확인하였다. 이를 통하여 뇌-컴퓨터 인터페이스의 실용화에 한 발짝 더 나아갔으며, 향후 연구를 통해 실시간으로 피험자의 다중의도를 예측하는 뇌-컴퓨터 인터페이스를 구현하고자 한다.

참고문헌

- [1] Bear et al., Neuroscience, Wolters Kluwer, Fourth ed. pp. 8, 2016.
- [2] Im, Chang-Hwan. "Introduction to EEG-based brain-computer interface (BCI) technology." Journal of Biomedical Engineering Research 31.1 (2010): 1-13.
- [3] <https://smartstuartkim.wordpress.com/2019/01/27/history-of-neural-networks-1-perceptron/>
- [4] Hecht-Nielsen, Robert. "Theory of the backpropagation neural network." Neural networks for perception. Academic Press, 1992. 65-93.
- [5] J.R. Wolpaw et al., ClinicalNeurophysiology, 2002
- [6] Mattout, Jérémie, et al. "Improving BCI performance through co-adaptation: applications to the P300-speller." Annals of physical and rehabilitation medicine 58.1 (2015): 23-28.
- [7] J. Qu et al., "A Novel Three-Dimensional P300 Speller Based on Stereo Visual Stimuli," IEEE Transactions on Human-Machine Systems, vol. 48, no. 4, pp. 392-399, 2018, doi: 10.1109/thms.2018.2799525.
- [8] H. Qi, Y. Xue, L. Xu, Y. Cao, and X. Jiao, "A Speedy Calibration Method Using Riemannian Geometry Measurement and Other-Subject Samples on A P300 Speller," IEEE Trans Neural Syst Rehabil Eng, vol. 26, no. 3, pp. 602-608, Mar 2018, doi: 10.1109/TNSRE.2018.2801887.
- [9] G. B. Kshirsagar and N. D. Londhe, "Improving Performance of Devanagari Script Input-Based P300 Speller Using Deep Learning," IEEE Trans Biomed Eng, vol. 66, no. 11, pp. 2992-3005, Nov 2019, doi: 10.1109/TBME.2018.2875024.
- [10] L. Cao et al., "A Novel Real-Time Multi-Phase BCI Speller Based on Sliding Control Paradigm of SSVEP," IEEE Access, vol. 7, pp. 133974-133981, 2019, doi: 10.1109/access.2019.2941642.

- [11] T.-H. Nguyen and W.-Y. Chung, "A Single-Channel SSVEP-Based BCI Speller Using Deep Learning," *IEEE Access*, vol. 7, pp. 1752-1763, 2019, doi: 10.1109/access.2018.2886759.

- [12] N. Gao, Zhai, L. W., J., S. Lu, and Y. Tian, "Intelligent wheelchair research based on SSVEP brain-computer interface," *BIBE 2018; International Conference on Biological Information and Biomedical Engineering. VDE, 2018.*, 2018.

- [13] M. H. Lee et al., "EEG dataset and OpenBMI toolbox for three BCI paradigms: an investigation into BCI illiteracy," *Gigascience*, vol. 8, no. 5, May 1 2019, doi: 10.1093/gigascience/giz002.