

논문 2023-18-11

뇌파를 이용한 맞춤형 주행 제어 모델 설계 (EEG-based Customized Driving Control Model Design)

이진희, 박재형, 김제석, 권순*
(Jin-Hee Lee, Jaehyeong Park, Je-Seok Kim, Soon Kwon)

Abstract : With the development of BCI devices, it is now possible to use EEG control technology to move the robot's arms or legs to help with daily life. In this paper, we propose a customized vehicle control model based on BCI. This is a model that collects BCI-based driver EEG signals, determines information according to EEG signal analysis, and then controls the direction of the vehicle based on the determined information through EEG signal analysis. In this case, in the process of analyzing noisy EEG signals, controlling direction is supplemented by using a camera-based eye tracking method to increase the accuracy of recognized direction. By synthesizing the EEG signal that recognized the direction to be controlled and the result of eye tracking, the vehicle was controlled in five directions: left turn, right turn, forward, backward, and stop. In experimental result, the accuracy of direction recognition of our proposed model is about 75% or higher.

Keywords : BCI (Brain Computer Interface), deep learning, eye tracking

1. 서론

BCI (Brain Computer Interface)는 뇌파 자극을 인식하는 장치를 통해 뇌파를 받아들인 후 신호화 과정을 거쳐, 뇌파를 분석해 입출력 장치에 명령을 내리는 기술이다 [1]. BCI는 뇌파의 측정 부위에 따라 침습형과 비침습형으로 분류된다. 침습형 방식은 마이크로칩을 두피에 시술해 뇌파를 측정하며, 비침습형 방식은 헬멧이나 헤드셋 장비를 이용하여 뇌파를 측정한다. 비침습형 방식을 이용하면 침습형 방식을 이용했을 때보다 잡신호가 더 많이 섞이기 때문에 정확한 측정이 어려운 점이 있다.

뇌파는 수많은 신경세포에서 발생하는 전기 신호이기 때문에 뇌파 신호는 뇌의 활동과 상태에 따라 시간적, 공간적으로 계속해서 변화한다. 따라서 뇌파를 측정할 때에는 시간 분석, 주파수 분석, 시간-주파수 분석, 비선형 동역학 분석, 통계 모델, 시공간 분석 등 다각도의 분석 방법이 필요하다. 복잡한 뇌파 신호의 분석이 요구되기 때문에, 어떤 제약 조건도 없이 다양한 분야에 BCI가 두루 사용되기 위해서는 3가지 조건을 만족해야 한다. 첫째, 활용성을 높이기 위해 뇌에서 필요한 부분만의 뇌파를 분석해야 한다. 원래 뇌파를 정확하게 측정하기 위해서는 두피 전체에 많은 전극을 붙여서 측정해야 하지만, 사용자는 많은 전극을 착용하기 불편하기 때문에 최소 전극의 데이터를 이용한 분석이 필요하다.

둘째, 대부분 뇌파를 분석하는 데 많은 저장 용량이 필요하고, 뇌파를 인식하고 연산하는데도 많은 시간이 소요되므로, 적은 용량과 짧은 시간으로 많은 양의 데이터를 처리할 수 있는 분석법이 필요하다. 마지막으로, 초기의 불완전한 분석법에서 벗어나, 오류가 없는 완벽한 분석법이 요구된다. 그러나 아직 이 세 조건을 모두 충족하기에는 기술적인 한계가 있다.

이러한 개발 기술의 한계에도 불구하고 BCI 기기의 발전으로, 현재는 뇌파 제어기술을 이용해 로봇의 팔이나 다리를 움직여 일상생활을 도와주는 것이 가능해졌다 [2-4]. 또한, 환자가 BCI 장치를 통해 로봇을 조종할 때, 로봇이 느끼는 촉감을 환자도 인식하여 마치 자신이 직접 팔이나 다리를 움직이는 것과 같은 효과를 줄 수 있다. 이 밖에도 스위스 로잔 연방 공대와 미국 브라운대, 프랑스 국립과학연구원 공동연구진이 척수 손상으로 하반신이 마비된 원숭이의 뇌와 척수에 센서와 전기 자극 장비를 심어 로봇 다리나 보조기 사용 없이 직접 걷게 하는 데 성공하기도 했다. 또한, 게임 분야에서도 BCI를 활용하려는 연구가 활발하게 진행 중이다. 뇌파를 통해 명령을 전달받은 후에 가상현실 속의 3D 아바타 캐릭터나 공의 움직임을 제어하는 게임 등이 출시되고 있다 [4-7].

이 논문에서는 팔과 다리가 불편한 사람도 뇌파를 이용하여 차량 제어를 할 수 있도록 보조하는 BCI 기반의 맞춤형 차량 제어 모델을 제안한다. 먼저 BCI 기반의 운전자 뇌파 신호를 수집하고, 이 뇌파 신호 분석에 따라 정보 결정을 한 후에 뇌파 신호 분석 정보 결정을 토대로 차량의 방향을 동작 제어하는 모델이다. 여기에서 뇌파 기반의 제어 방향 인지 정확도를 높이기 위해, 여기서는 시선 추적 기법을 적용하였다.

*Corresponding Author (soonyk@dgist.ac.kr)
Received: Nov. 15, 2022, Revised: Dec. 30, 2022, Accepted: Mar. 29, 2023.
J. H. Lee: DGIST (Senior Researcher)
J. H. Park: DGIST (Researcher)
J. S. Kim: DGIST (Senior Researcher)
S. Kwon: DGIST (Principal Researcher)
* 본 연구는 과학기술정보통신부에서 지원하는 대구경북과학기술원 기관
교유사업 (23-IT-02) 지원을 받아 수행 되었습니다.




그림 1. 뇌파 기반의 맞춤형 주행 제어 모델 개요
Fig. 1. Overview of EEG-based customized driving control model

II. BCI 기반 맞춤형 차량 제어 모델 설계

제안하는 뇌파 기반의 맞춤형 주행 제어 모델은 그림 1에서와 같이 Eye Tracker와 BCI를 이용하고 그 센서들에서 취득한 데이터 융합을 통해 최종적으로 차량의 제어 방향을 결정함으로써 운전자에 따른 맞춤형 주행 제어가 가능한 모델이다. 2.1절에서는 주행 제어 정확도를 높이기 위해 Eye Tracker를 이용한 시선 추적 기술을 제안하고, 2.2절에서는 운전자의 뇌파 신호 분석을 통한 차량 주행 제어 모델을 제안한다.

1. 제어 인식률을 높이기 위한 Eye Tracker

이 논문에서는 먼저, BCI 기반의 주행 제어 정확도를 높이기 위해서 시선 추적 (eye tracking) 기술을 보조적으로 사용한다. 시선 추적이란 눈동자를 추적해 시선이 정확하게 어디에 머물고 있는지를 파악하는 기술로서, 시야의 중심부에 머무르는 시간이나 시선의 경로를 통해 정보를 처리하여 패턴을 분석하는데 활용된다. 우리는 시선 추적 기술을 시선이 향한 쪽에 있는 제어 방향 키 (key)를 선택하는데 사용한다. 그러므로 시선이 향한 눈 움직임을 측정해야 하는데 여기서는 일반적으로 사용하는 각막반사법 (PCCR)방식을 이

용한다 [8]. 이는 각막 상에 빛의 반사점을 만들고, 그 영상을 카메라로 촬영하고, 촬영된 눈 이미지에서 각막 상의 빛의 반사점과 동공을 식별한 후에 빛의 반사점과 기하학적 특징을 바탕으로 눈의 방향을 찾는 방법이다. 이 논문에서는 차량 제어 시스템의 모니터에 카메라와 적외선 LED를 부착한다. 여기서 카메라는 눈의 위치를 추적하기 위한 기기이고, 근적외선 LED는 각막에 생긴 빛의 반사 패턴을 취득하기 위한 기기이다. 만약 BCI를 착용한 사용자가 제어 방향 (전진, 왼쪽, 오른쪽, 후진, 정지)을 일정시간 생각하며 화면상의 방향키를 바라볼 때의 눈 위치를 카메라 및 LED로 데이터를 수집하는 동시에, BCI를 이용하여 사용자의 뇌파를 기록한다. 촬영한 눈 이미지에서 각각의 동공을 식별한 후에, 눈의 방향과 위치를 계산한다. 시선 추적 처리 과정 순서는, 그림 2의 Eye Tracker 처리 흐름도와 같다. 여기서는 Eye Tracker 알고리즘의 성능 검증을 위해서, 초기에는 시야의 영상을 수집하는 카메라 (scene camera)도 추가 사용하여 동시에 데이터를 수집하였다. 이때 근적외선 LED가 빛의 반사 패턴을 생성한 후, 시선 추적 카메라가 고해상도 눈 이미지를 취득하고, 이미지 처리 알고리즘이 눈과 빛의 반사 패턴을 검출한다. 그 다음에 3D 안구 모델 알고리즘으로 공간상의 눈의 위치에 따른 화면상의 시선 (방향 key를 바라보는 경우)을 추출한다. Eye Tracker 부분을 요약하면, 실시간 카메라 이미지의 분석을 통해 동공의 움직임을 검출하고, 근적외선 LED를 통해 각막에 반사된 고정위치를 기준으로 시선의 움직인 방향을 계산하는 것이다. 이는 추가적인 장비 없이 시선의 움직임을 추정 가능함을 확인하였다.

2. 뇌파 신호 분석을 통한 차량 제어 모델

뇌파 신호를 패턴화 할 수 있는 방법 중에 하나는 집중할 때와 이완할 때 뇌파 신호의 형태가 구별이 되는 현상을 이용하는 것이다. 뇌파신호는 0.5Hz부터 50Hz까지의 주파수를 가지고 있고, 그 이상의 주파수를 가진 신호는 여러 가지 잡음을 포함하고 있어 판별과 분석이 어려우며 임상적으로도 의미가 없는 것으로 알려져 있다. 주파수에 따른 뇌파는 δ 파,

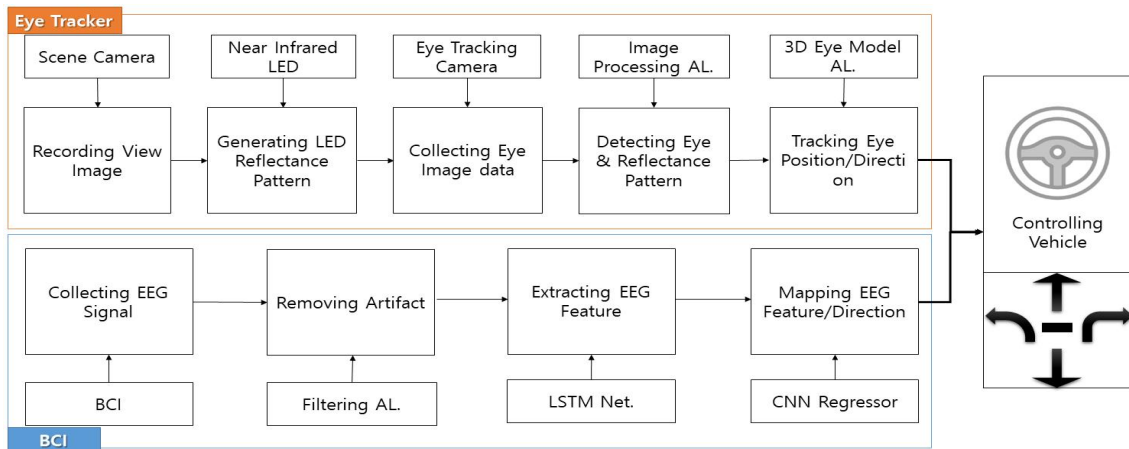


그림 2. 뇌파 기반의 맞춤형 주행 제어 방법 흐름도
Fig. 2. Flow chart of EEG-based customized driving control method




그림 3. 운동영역 C3, C4
Fig. 3. Exercise area C3 and C4

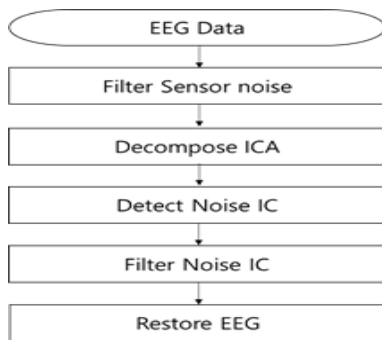


그림 4. EEG artifact 제거 과정
Fig. 4. EEG artifact removal process

θ 파, α 파, β 파 등으로 분류된다. 우리는 이 중에서 집중력을 결정하는 뇌파인 α 파, β 파의 특성을 확인하고, 이 두 파의 피쳐 (feature)를 추출하고 사용한다. α 파 (8~13 Hz)는 생각이 없는 멍한 상태에 나타나며 심리적 완화상태로 눈을 감을 때 발생하며, 10~50 mV의 크기로 이루어진다. β 파 (14~30Hz)는 집중 상태에 나타나며 경계, 각성, 문제풀이, 집중할 때 발생하며 파형이 빠르면서도 크기가 작다. 사람이 이완할 때의 뇌파 신호의 파워 값과 집중할 때의 파워 값을 구하여 좌우 제어 동작에 매칭하여 사용할 수 있다. 그림 3에서와 같이 뇌에서의 운동영역은 정수리를 중심으로 좌우 C3, C4 영역에서 활성화 된다. 이 논문에서는 이 영역의 뇌파 채널을 중심으로 데이터를 수집하고 분석하였다.

위에서 언급한대로 EEG 데이터를 수집할 때, 운전자의 눈 깜빡임으로 artifact가 발생하고, 이는 차량 제어 성능에 영향을 준다는 것을 확인하였다. 이 논문에서는 전처리 과정을 통해 artifact를 제거하였고, 이는 시선 추적 센서로부터 눈 깜빡임 시점 정보를 활용하여 artifact 필터를 잡음 발생 위치에만 적용함으로써 EEG에서 추출된 정보 손실 문제를 최소화하였다. 우리는 정보 손실 이슈가 개선되는 정도를 측정하기 위해, 신호 대 잡음 비율 (SNR, Signal to Noise Ratio), 주파수 스펙트럼 일관성 (coherence)의 수치를 이용하여 정보 손실 비율을 비교하였다. 즉, 뇌파 신호를 왜곡시키기 쉬운 artifact가 포함된 뇌파 데이터에서, 시선 추적 센

서 데이터에서 얻은 눈 깜빡임 시점 정보를 이용하여 artifact 요소를 제거하기 위해 독립성분분석 기법을 적용한다. 우리는 artifact 발생 위치에만 필터를 적용함으로써 artifact 제거 시 발생하는 원본 뇌파 신호의 훼손을 최소화하는 것으로, 그림 4의 순서대로 진행된다. 먼저 센서에서 수집한 EEG 데이터에 Butterworth 대역 필터를 적용하여 진원 노이즈, 심박 등 주파수 대역이 사전에 알려진 왜곡 신호들을 1차로 제거한다. 이후 필터링 된 뇌파 신호에 독립성분분석 방법을 적용하여 n개의 뇌파 신호를 n개의 독립성분 (IC)들로 분해한다. 뇌파 센서에서 측정된 신호를 x , 독립성분분석 결과 얻게 되는 독립성분을 y , 입력 신호를 독립성분으로 변환하기 위한 변환 계수 행렬을 Z 라고 정의할 때, t 에서 원래 신호와 독립성분의 관계는 $y(t)=Z*x(t)$ 와 같다. 이는 독립성분으로 분해된 신호는 artifact 제거를 위한 필터링 과정을 거친 후 변환 계수 행렬의 역행렬을 다시 곱하여 원래 신호의 형태로 복원될 수 있음을 말한다. 이 기법을 적용한 이후 눈 깜빡임 artifact 성분을 포함하는 독립성분을 확인하기 위해 시선 추적 센서로부터 얻은 운전자의 눈 깜빡임 시점 정보를 이용하여 눈 깜빡임으로 인한 artifact 발생 영역을 찾아낸다. 눈 깜빡임 동작은 일반적으로 200~400ms 범위의 시간 내에서 이루어지고 이에 따라 관련 연구에서는 눈 깜빡임으로 인하여 발생하는 뇌파 영역은 약 500ms로 정의하였다 [9]. 실험을 통해서도 artifact에 의한 비정상 영역과 정상 영역의 비교를 통해 artifact에 의한 비정상 영역의 센서 측정값이 정상 영역의 뇌파와 비교했을 때 크게 차이가 있음을 확인하였다. 이후 독립성분 상의 artifact 발생 영역에 있는 데이터의 첨도 (Kurtosis) 값을 확인한 후 기준치 이상의 값을 가지는 독립성분을 왜곡 성분으로 정의하였다. 그 후, artifact 성분이 포함된 것으로 판단되는 독립성분들에 대해 라티스 (lattice) 필터를 적용한다. 결과적으로 필터링 된 노이즈가 포함된 신호는 정상 신호 영역의 데이터와 다르므로 이를 후처리하였다. 마지막으로 필터링된 독립성분과 변환 계수의 역행렬인 혼합 계수의 행렬 곱 연산을 이용하여 독립성분들을 다시 혼합하여 뇌파 신호 형태로 복원한다. 이 과정을 통해 눈 깜빡임으로 인해 발생하는 artifact를 제거한 후에 최종적으로 EEG 데이터를 생성하였다.

제안하는 뇌파 기반의 차량 제어 모델의 기본 원리는 정밀한 EEG 데이터를 취득하기 위해 64채널 EEG 캡을 쓰고, 화면에 보이는 화살표 이미지를 보면서 그 방향으로 움직이도록 상상을 하고, 차량과 연동한 시뮬레이터에서는 사용자의 뇌파를 분석하여 차량의 이동 방향을 움직이게 한다. 그림 5는 제안하는 뇌파 분석 흐름의 아키텍처로 인간의 마음을 읽어서 기계로 옮기는 것을 목표로 한다. 이는 마음 읽기 단계와 시각 피처를 기계로 전송하는 단계로 나누어진다. 먼저 마음 읽기 단계 (그림 5 상단)에서는 사용자가 이미지를 보는 동안에 기록된 시간적 EEG 신호에 대한 저차원 표현은 인코더 모듈에 의해 학습되고, 그 다음 계산된 EEG 피처를 사용하여 이미지 분류기를 훈련한다. 인간의 시각적 피처를 기계로 전송하는 단계 (그림 5 하단)에서 CNN은 이미지에서 직접 EEG 피처를 추정하도록 훈련된다. 그런 다음 마

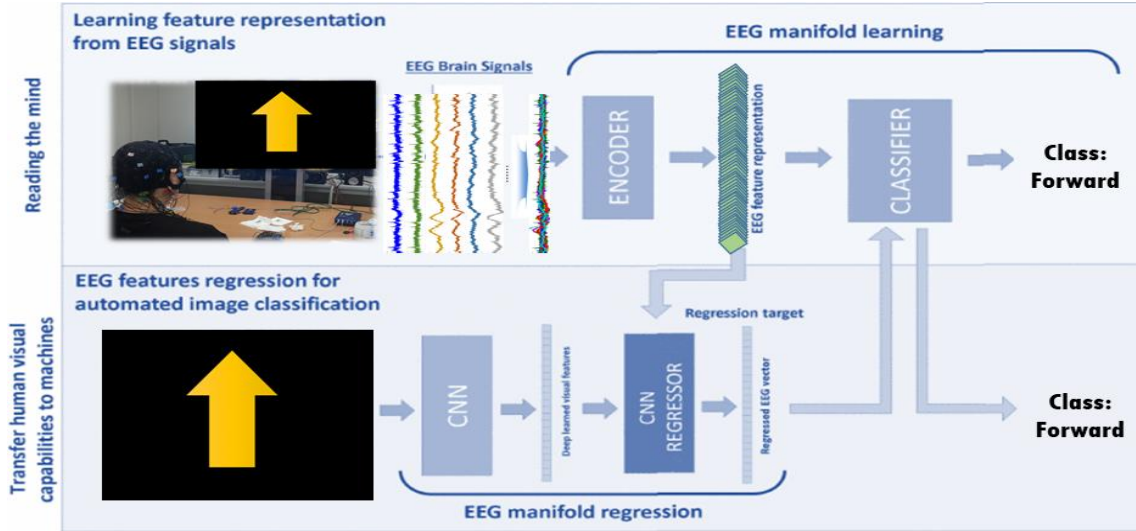


그림 5. 뇌파 데이터 분석 흐름도
Fig. 5. Flow chart of EEG data analysis




그림 6. LSTM 기반의 인코더
Fig. 6. LSTM-based Encoder

음 읽기 단계에서 훈련된 분류기를 새로운 이미지에 대한 EEG 데이터 없이도 자동 분류에 사용할 수 있다.

그림 6은 LSTM (Long Short-Term Memory models) 기반의 인코더를 나타낸다 [10]. EEG 다중 채널 시간 신호는 전체 시간 시퀀스를 처리하고 입력의 간결한 표현으로 EEG 특징 벡터를 출력하는 인코더 모듈에 대한 입력으로 제공된다. 이상적으로, 입력 시퀀스가 이미지를 보는 동안 기록된 EEG 신호로 구성되는 경우, 우리는 결과 출력 벡터가 다양한 이미지 클래스를 구별하기 위해 관련한 뇌 활동 정보를 인코딩하도록 하는 것이다. 따라서 인코더 네트워크는 출력에 분류 모듈 (모든 실험에서 소프트맥스 레이어가 됨)을 추가하고 경사 하강법을 사용하여 전체 모델의 매개변수를 중단 간 학습함으로써 훈련시킨다. 각 시간 단계 t 에서 첫 번째 레이어는 입력 EEG 시퀀스 $s(c, t)$ 를 받는데, 여기서 c 는 채널을 의미하고 t 는 한 세트의 이미지를 연속적으로 보여주는 시간을 의미한다. 이는 모든 EEG 채널이 초기에 동일한 LSTM 레이어에 입력으로 들어감을 의미한다. 약간의 계산 비용으로 모델 용량을 늘리기 위해 LSTM 뒤에 출력 계층 (입력의 선형 조합)을 추가한다. 이 경우에, LSTM 인코딩

아키텍처는 64채널 EEG를 사용하여 LSTM 레이어에 64개 입력과 64개 출력이 되게 하였다. 인코딩된 특징 벡터는 최종 레이어의 출력이다.

그림 5에서 인코더 및 분류기의 학습은 각 EEG 시퀀스가 기록되는 동안에 보여준 이미지와 관련된 클래스 레이블을 제공하여 경사 하강법을 통해 수행된다. 학습 후에 그 인코더는 입력 EEG 시퀀스로부터 EEG 피처를 생성하는 데 사용하며, 분류 네트워크는 설명된 대로 EEG 신호 또는 이미지에서 계산되는 입력 EEG 피처를 위해 이미지 클래스를 예측하는 데 사용된다.

다음으로, 그림 7과 같이 하나의 입력 이미지에서 EEG 피처들을 추출하기 위해 CNN 기반의 접근 방식을 사용하였다 [11-13]. 이는 regressor training을 통한 EEG 피처를 추출하는 방법으로, 사전 훈련된 CNN (Convolution Neural Network) 모델을 사용하여 이미지 피처를 추출하고, regression 기법을 이용하여 이미지 피처를 EEG 피처 벡터에 맵핑시킨다. 여기서는 fine-tuning된 AlexNet, GoogleNet, VGG를 피처 추출기로 사용하는데 마지막 fully connected layer의 출력을 통해 이미지 피처를 얻고, 여러 regression 방법 (k-NN regression, ridge regression, random forest regression)을 적용하여 예측된 EEG 피처 벡터를 얻는다. Regressor의 경우 혼란을 피하기 위해 각 이미지 하나의 EEG 피처 벡터에만 연결하도록 하였다. 분류 (classification)는 기본 CNN을 사용하여 학습된 EEG 피처를 5개 클래스 (전진, 왼쪽, 오른쪽, 후진, 정지)로 분류한다.

III. 실험

이 논문에서는 제안하는 EEG 기반의 주행 제어 모델의 가능성을 실험을 통해 확인하였다. EEG 데이터 수집은 7명의 피험자 (남자 6명, 여자 1명)에게 뇌파 데이터가 기록되

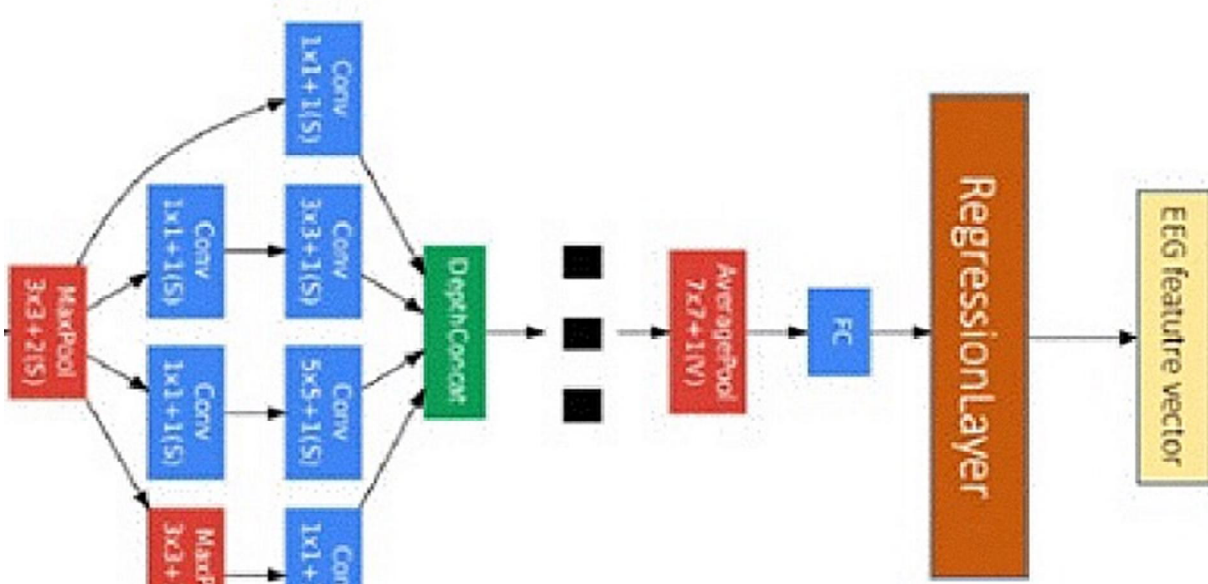


그림 7. 이미지와 EEG 피쳐벡터를 맵핑하기 위한 CNN 기반 regressor
 Fig. 7. CNN-based regressor for mapping image feature and EEG feature vector

는 동안 시각적 자극을 발생하기 위해 이미지를 보여주면서 실험을 진행하였다. 모든 사람은 연령, 교육 수준 및 문화적 배경 측면에서 모두 동일하다. 시각적 자극에 사용된 이미지 데이터 세트는 쉽게 인식할 수 있는 다섯 클래스인 방향 화살표 (전진, 왼쪽, 오른쪽, 후진, 정지)로 분류되는 2,000개 이미지를 사용하였다. 실험하는 동안 임의로 샘플링하여 2,000개의 이미지 (각 클래스는 400개)를 각각 0.5초 동안 연속적으로 보여준다. 피험자에게 이미지를 보여주는 시간 간격은 한 세트인 25초 동안 지속되었고, 총 1000초 (16분 7초)의 실험 시간 동안 한 세트 25초마다 검정색 이미지를 10초 동안 보여주면서 세트마다 일시적으로 중지하여 생각을 쉬도록 하였다. 실험은 64채널 캡을 사용하여 수행되었으며, Brain-vision과 amplifier는 EEG 데이터 수집을 위해 사용되며, 샘플링 주파수와 데이터 해상도는 각각 1000Hz와 16비트로 설정하였다. 만약, 사용자가 관심 있어 하는 어떤 자극이나 이벤트가 수행되면, 정수리 중앙 (Cz) 부분에서 수 μV 로 수백 ms 동안 평균적으로 평상시 보다 더 발현이 되는 특성이 나타나므로, 이를 활용하여 시각 인지와 관련된 밴드의 가중치를 높게 두었다.

2,000개의 데이터를 8:1:1 비율로 training, validation, test 세트로 나누어 초기 실험을 진행하였다. 제안된 RNN 인코더는 validation 세트로 실험한 결과 약 79%의 분류 정확도를 보였다. 우리는 다른 더 복잡한 모델로도 테스트해 보았으나 과적합 (overfitting)이 발생하였다. 정확도를 계산하는데 사용되는 분류기는 인코더에서 훈련된 분류기이며, CNN regressor 기반 EEG 피쳐에 대한 자동 시각적 분류에도 동일한 분류기를 사용하였다. 여기서 CNN 기반의 regression은 하나의 이미지를 볼 때, EEG 피쳐 벡터를 7명의 피험자의 평균값으로 맵핑하도록 하였으며, MSE (Mean Square

Error) 값으로 regressor를 계산하였다. GoogleNet과 k-NN regressor와 결합한 피쳐 추출기를 이용하면 약 0.62 MSE 결과를 보이는데, 이는 fine-tuning 방법에 비해 더 낮은 error 값을 보였다.

다음은 이미지에서 EEG 피쳐를 추출하고, EEG를 Learning 하는 동안에 학습된 소프트맥스 분류기로 피쳐 벡터를 자동 분류하는 자동화된 시각 분류기를 테스트하였다. 이는 사람의 시각적 능력은 피쳐를 학습하고 기계로 이전할 수 있다는 가능성을 테스트하는 실험이다. 우리의 brain-learned 피쳐의 일반화 능력을 테스트하기 위해 제안하는 방법을 피쳐 추출 기법으로 평가하였다. 이 실험에서는 모델 개발에 사용된 클래스와 겹치지 않기 위해, 추가로 200개의 테스트 세트를 생성하고, 별도의 다중 클래스 SVM 분류기를 이용하여 분류 정확도를 측정하였다. 시뮬레이터 기반의 주행 제어 가상 실험에서는 주행 속도는 30km/h 이하, 편도 2차선 도로 상황에서 테스트를 하였으며, 5가지 클래스가 각각 10번의 빈도수를 보이도록 세팅하여 7명의 피험자에게 200개의 테스트 세트로 반복 실험하였다 [14]. 이 시뮬레이터 실험에서는 평균적으로 74.8%의 정확도를 보이는데, 이는 BCI만을 이용한 경우에 비해서는 4.78% 높았고, Eye Tracker만을 이용한 경우에 비해서는 2.36% 높은 결과를 보였다. 이는 EEG 인코더와 regressor가 시각적 피쳐와 직접적으로 관련되지 않은 피쳐 공간에서 훈련되었다는 점을 고려할 때 인상적인 결과를 보였다.

IV. 결론

이 논문에서는 수족이 불편한 사람도 뇌파를 이용하여 차량 제어를 할 수 있도록 보조하는 BCI 기반의 맞춤형 차량

제어 모델을 제안한다. 이는 BCI 기반의 운전자 뇌파 신호를 수집하고, 이 뇌파 신호 분석에 따라 정보 결정을 한 후에 뇌파 신호 분석 정보 결정을 토대로 차량의 이동 방향을 제어하는 모델이다. 이때 노이즈가 많은 뇌파 신호를 분석하는 과정에서 정보의 정확도를 높이기 위해 카메라 기반의 시선 추적 방법을 이용하여 방향 인지 정확도를 보완한다. 제어할 방향을 인지한 뇌파 신호와 시선 추적 결과를 종합하여 좌회전, 우회전, 전진, 후진, 정지 등의 5개 방향으로 차량을 동작 제어하도록 하였다. 차량의 방향 제어 인지 정확도는 평균적으로 약 75% 이상의 성능을 보였다. 또한 좀 더 정확한 방향 제어를 위해서 시선 추적 방법을 적용하므로 기존 방법들에 비해 좀 더 빠르고 정확한 차량 방향 제어가 가능하다. 이를 확장하여 뇌파 기반의 장치 제어 기술은 향후에 장애인의 일상생활에 혜택을 가져다 줄 것이며, 이는 상용화를 통해 심각한 장애를 가진 사람들뿐만 아니라 일반 대중에게도 유용한 응용 서비스 제공이 가능할 것이다.

References

- [1] M. L. Martini, E. K. Oermann, N. L. Opie, F. Panov, T. Oxley, K. Yaeger, "Sensor Modalities for Brain-computer Interface Technology: A Comprehensive Literature Review," *Neurosurgery*, Vol. 86, No. 2, pp. E108-E117, 2020.
- [2] J. Meng, S. Zhang, A. Bekyo, J. Olsoe, B. Baxter, B. He, "Noninvasive Electroencephalogram Based Control of a Robotic Arm for Reach and Grasp Tasks," *Scientific Reports*, Vol. 6, 38565, 2016.
- [3] K. Korovesis, D. Kandris, G. Koulouras, A. Alexandridis, "Robot Motion Control via an EEG-Based Brain - Computer Interface by Using Neural Networks and Alpha Brainwaves," *Electronics*, Vol. 8, No. 12, 1387, 2019.
- [4] H. H. Jo, S. C. Jeon, "EEG based Brain-Computer Interface Technology", *Information and Communications Magazine*, Vol. 29, No. 7, pp. 47-55, 2012 (in Korean).
- [5] D. E. Kim, T. J. Lee, S. M. Park, "EEG Analysis Following Change in Hand Grip Force Level for BCI Based Robot Arm Force Control", *J. Korean. Inst. Intel. Sys.*, Vol. 23, No. 2, pp. 172-177, 2013 (in Korean).
- [6] S. H. Seo, "Development of Deep Learning Model in Brain Signal Classification for BCI Control", *Journal of Next-generation Convergence Technology Association*, Vol. 4, No. 4, pp. 471-477, 2020 (in Korean).
- [7] S. Saha, K. A. Mamun, K. Ahmed, R. Mostafa, G. R. Naik, S. Darvishi, A. H. Khandoker, M. Baumert, "Progress in Brain Computer Interface: Challenges and Opportunities," *Frontiers in Systems Neuroscience*, Vol. 15, 578875, 2021.
- [8] D. S. Bolme, J. R. Beveridge, B. A. Draper, Y. M. Lui, "Visual Object Tracking Using Adaptive Correlation Filters," *IEEE Computer Society Conference on Computer Vision and Pattern Recognit*, pp. 2544-2550, 2010.
- [9] J. S. Yun, J. H. Kim, "A Study on EEG Artifact Removal Method Using Eye Tracking Sensor Data," *J. Inst. Korean. Electr. Electron. Eng*, Vol. 22, No. 4, pp.1109-1114, 2018 (in Korean).
- [10] J. Chang, B. Kim, C. Mun, D. Lee, J. Kwakl, "Efficient Hyperplane Generation Techniques for Human Activity Classification in Multiple-Event Sensors Based Smart Home", *IEMEK J. Embed. Sys. Appl.*, Vol. 14, No. 5, pp. 277-286, 2019 (in Korean).
- [11] H. Jung, M. K. Choi, J. Kim, S. Kwon, W. Y. Jung, "CNN-based Weighted Ensemble Technique for ImageNet Classification," *IEMEK J. Embed. Sys. Appl.*, Vol. 15, No. 4, pp. 197-204, 2020 (in Korean).
- [12] D. Sabbagh, P. Ablin, G. Varoquaux, A. Gramfort, D. A. Engemann, "Predictive Regression Modeling with MEG/EEG: from Source Power to Signals and Cognitive States," *Jour. NeuroImage*, Vol. 222, 2020.
- [13] C. Pan, C. Shi, H. Mu, J. Li, X. Gao, "EEG-Based Emotion Recognition Using Logistic Regression with Gaussian Kernel and Laplacian Prior and Investigation of Critical Frequency Bands," *Jour. Applied Sciences*, Vol. 10, No. 5, 2020.
- [14] A. X. Stewart, A. Nuthmann, G. Sanguinetti, "Single-trial Classification of EEG in a Visual Object Task Using ICA and Machine Learning," *Journal of Neuroscience Methods*, Vol. 228, pp. 1-14, 2014.

Jin-Hee Lee (이진희)



2005 Computer Science from Korea National Open University (B.S.)

2007 Computer and Information Engineering from Inha University (M.S.)

2015 Computer and Information Engineering from Inha University (Ph.D.)

2015~Division of Automotive Technology from Daegu Gyeongbuk Institute of Science & Technology (DGIST). (Senior researcher)

Field of Interests: Autonomous driving, Deep learning, Sensor fusion

Email: jhlee07@dgist.ac.kr

Jaehyeong Park (박재형)



2013 Information and Communication Engineering from Daegu University (B.S.)

2015 Information and Communication Engineering from Daegu University (M.S.)

2015~Division of Automotive Technology from Daegu Gyeongbuk Institute of Science & Technology (DGIST). (Researcher)

Field of Interests: Autonomous driving, Deep learning, Stereo camera

Email: stillrunning@dgist.ac.kr

Soon Kwon (권순)



2003 Electric & Electronic Engineering from Korea University (B.S.)

2006 Electronic Engineering from Seoul National University (M.S.)

2006~Division of Automotive Technology from Daegu Gyeongbuk Institute of Science & Technology (DGIST). (Principal researcher)

Field of Interests: Autonomous driving, Deep learning, Sensor fusion

Email: soonyk@dgist.ac.kr

Je-Seok Kim (김세석)



2009 Mechanical Engineering from Yeungnam University (B.S.)

2012 Automotive Engineering from Hanyang University (M.S.)

2015 Automotive Engineering from Hanyang University (Ph.D.)

2020~Division of Automotive Technology from Daegu Gyeongbuk Institute of Science & Technology (DGIST). (Senior researcher)

Field of Interests: Automotive driving, Planning algorithm

Email: jeseok@dgist.ac.kr