

IoT 환경 기반의 뇌파 및 시선 추적을 활용한 학습 패턴 분석 시스템 설계

홍서빈¹, 김봉현^{2*}

¹서원대학교 정보통신공학과 석사과정, ²서원대학교 컴퓨터공학과 교수

Design of a learning pattern analysis system using brain waves and eye tracking based on IoT environment

Seo-Bin Hong¹, Bong-Hyun Kim^{2*}

¹Master's Student, Department of Information Communication, Seowon University

²Professor, Department of Computer Engineering, Seowon University

요약 본 논문은 학습 장애를 가진 학생들을 위한 생체신호 기반 맞춤형 학습 지원 시스템의 설계를 제안한다. 이 시스템은 EEG(뇌파)와 시선 추적 데이터를 활용하여 학습자의 상태를 실시간으로 모니터링하고, 집중력 저하, 지루함 또는 흥미 감소를 식별한다. 이를 통해 맞춤형 피드백과 적응형 학습 환경을 제공함으로써 학습 경험과 효과를 향상시키고자 한다. 시스템의 주요 구성 요소로는 Emotiv Epoc X와 시선 추적 장치를 사용한 데이터 수집, 수집된 데이터의 전처리, 그리고 CNN(Convolutional Neural Networks) 및 LSTM(Long Short-Term Memory)과 같은 AI 모델의 적용이 포함된다. 또한 Random Forest와 Gradient Boosting을 활용하여 학습자 특성을 예측하고 피드백을 최적화하며, Decision Trees를 통해 학습 성과를 분석하고 개별 맞춤형 피드백을 제공한다. 제안된 시스템은 학습 장애 학생들에게 최적의 학습 환경을 제공하여 교육적 성과와 동기를 향상시키는 것을 목표로 한다.

주제어 : 뇌파, 시선추적, 맞춤형 학습, 인공지능, 학습자 상태 모니터링

Abstract This paper proposes the design of a personalized learning support system for students with learning disabilities, utilizing biometric signals. The system leverages EEG (electroencephalography) and eye-tracking data to monitor the learner's state in real-time, identifying signs of decreased concentration, boredom, or diminished interest. By providing customized feedback and an adaptive learning environment, the system aims to enhance the learning experience and effectiveness. Key components of the system include data collection using Emotiv Epoc X and eye-tracking devices, data preprocessing, and the application of AI models such as Convolutional Neural Networks (CNNs) and Long Short-Term Memory (LSTM) networks. Additionally, Random Forest and Gradient Boosting techniques are employed to predict learner characteristics and optimize feedback, while Decision Trees are used to analyze learning outcomes and deliver individualized recommendations. The proposed system aims to provide an optimal learning environment for students with learning disabilities, with the ultimate goal of improving educational performance and motivation.

Key Words : EEG, Eye-Tracking, Personalized Learning, Artificial Intelligence, Learner State Monitoring

*교신저자 : 김봉현(bhkim@seowon.ac.kr)

접수일 2024년 09월 12일 수정일 2024년 09월 30일 심사완료일 2024년 10월 07일

1. 서론

현대 사회에서 교육의 중요성은 날로 커지고 있으며, 특히 학습자의 특성과 필요에 맞춘 맞춤형 학습이 점차 중요해지고 있다. 그러나 학습 장애를 가진 학생들은 전통적인 교육 환경에서 많은 어려움을 겪고 있다. 2022년 기준으로 국내 학습 장애 학생 수는 약 33만 612명으로 전년 대비 36.7% 증가하였으며[1], 이는 학습 장애 학생들을 위한 교육적 지원이 절실함을 나타낸다. 학습 장애를 가진 학생들은 일반적인 교육 방법으로 충분한 학습 효과를 얻기 어려워, 개인화된 학습 환경이 필요하다.

생체 신호, 특히 EEG(뇌파)와 시선 추적 데이터를 활용하여 학습자의 상태를 실시간으로 모니터링하고 최적화된 학습 환경을 제공하는 시스템은 이러한 문제 해결에 중요한 역할을 할 수 있다. 본 연구의 목적은 생체 신호를 기반으로 맞춤형 학습 지원 시스템을 설계하는 것이다. 이 시스템은 뇌파와 시선 추적 데이터를 통해 학습자의 상태를 실시간으로 분석하여 적절한 피드백을 제공하고, 개인화된 학습 경험을 통해 학습 효과를 극대화하려는 것이다.

주요 기능으로는 학습자 상태 모니터링, AI 기반 학습자 특성 예측, 학습 성과 분석이 포함된다. 학습자 상태 모니터링을 위해 MNE-Python과 EEGLab을 사용하여 뇌파 데이터를 처리하고, Wavelet 변환과 자기상관함수를 통해 뇌파의 시간 및 주파수 영역 특성을 분석한다. 시선 추적 데이터를 통해 사용자의 집중도와 흥미를 파악하고, 이를 기반으로 적절한 피드백을 제공한다.

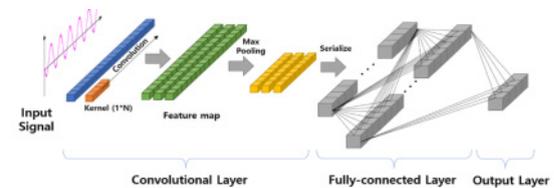
AI 기반 학습자 특성 예측은 TensorFlow를 활용한 CNN과 LSTM 모델을 통해 이루어지며, Random Forest와 Gradient Boosting 같은 앙상블 기법을 사용하여 예측 성능을 향상시킨다. 학습 성과 분석은 Decision Trees를 통해 학습 경로와 성과를 평가하고, 다양한 요인을 분석하여 학습 효과를 극대화하고 지속적인 학습 동기를 부여한다.

본 논문에서는 생체 신호 기반의 맞춤형 학습 지원 시스템을 통해 학습 장애 학생들의 학습 환경을 개선하고 교육의 질을 향상시키는 데 기여할 것이다. 맞춤형 학습을 제공함으로써 학습 효과와 교육 효율성을 높이는 데 중요한 역할을 할 것으로 기대된다.

2. 관련 이론

2.1 Convolutional Neural Networks(CNN)

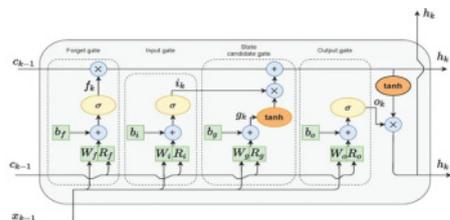
Convolutional Neural Networks(CNN)은 이미지 데이터와 EEG 같은 시계열 데이터의 패턴 분석에 효과적이다. EEG 데이터는 시간에 따라 변하는 신호이기 때문에 여러 층을 통해 복잡한 패턴을 추출하는 것이 중요하다. 첫째, Convolutional Layer에서 EEG 신호의 시간적, 공간적 특징을 추출하기 위해 필터를 적용해 특징 맵을 생성한다. 둘째, Pooling Layer에서 차원을 줄여 주요 정보를 추출하고 모델의 복잡도를 감소시켜 노이즈를 줄인다. 셋째, Fully Connected Layer에서 추출된 특징들을 사용해 EEG 신호의 분류 작업을 수행한다. 마지막으로, 활성화 함수를 통해 비선형성을 부여해 복잡한 패턴을 학습하도록 돕는다. 주로 ReLU 함수를 사용한다[2, 3]. 이러한 과정을 통해 CNN은 뇌파의 공간적/시간적 특성을 효율적으로 추출한다.



[Fig. 1] General structure of 1D CNN for signal pattern recognition

2.2 Long Short-Term Memory(LSTM)

Long Short-Term Memory(LSTM)은 순환신경망(RNN)의 일종으로, 시계열 데이터인 EEG의 장기 의존성을 모델링하는 데 특화되어 있다. EEG 신호는 시간에 따른 변화를 포함하기 때문에, LSTM을 통해 이러한 패턴을 효과적으로 학습할 수 있으며, 뇌파 데이터의 중요한 정보를 기억할지, 버릴지를 결정한다[4, 5]. 본 연구에서는 LSTM을 활용하여 EEG 데이터의 시간적 패턴을 분석하고, 집중력의 변화를 탐지한다.



[Fig. 2] Long Short-Term Memory(LSTM) Network Architecture

2.3 Random Forest

랜덤 포레스트는 다수의 결정 트리를 사용하여 학습자

의 EEG 신호를 분석하고 반응을 예측하는 모델이다. 앙상블 학습을 통해 여러 트리를 결합해 예측 성능을 높이고, 배깅을 통해 훈련 데이터셋을 생성해 모델의 일반화 능력을 향상시킨다. 특히, EEG 데이터의 다양한 특징(예: 주파수 대역, 채널별 파워 스펙트럼)을 사용하여 집중력 수준을 예측할 때 과적합을 방지할 수 있다[6].

2.4 Decision Trees

의사결정트리는 EEG 데이터의 특정 특징을 기반으로 예측하는 트리 구조의 모델로, 변수 간의 관계를 분석하고 학습자의 성과를 예측하는 데 사용된다. EEG 데이터의 주파수 대역, 파워 스펙트럼 밀도 등의 특징을 사용해 집중력의 저하와 같은 요인을 분류한다. Recursive Partitioning을 통해 EEG 데이터의 최적 분기 기준을 찾고, Information Gain을 활용해 분류 작업의 정확성을 높인다. 본 연구에서는 의사결정트리를 통해 EEG 데이터의 학습자의 성과를 분석하고, 이를 통해 최적화된 피드백을 제공하여 학습 효과를 극대화한다[7].

3. 데이터 수집 및 전처리

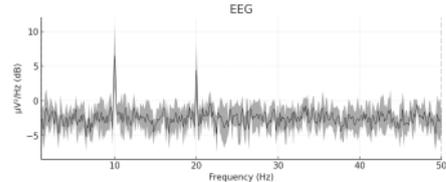
3.1 EEG 데이터

수집된 데이터는 분석에 앞서 전처리 과정을 거친다. 본 연구에서는 Emotiv EPOC X를 사용하여 14채널의 뇌파 데이터를 수집하였다. EEG 신호는 잡음과 인공물을 포함할 수 있어, MNE-Python 라이브러리를 활용해 고속 푸리에 변환(FFT)과 필터링 기법으로 전극 노이즈와 인공물(artefacts)을 제거한다. 특히, 눈 깜빡임 등의 생리적 잡음은 독립 성분 분석(ICA)으로 분리해 제거한다. 데이터의 주파수 범위를 제한하여 분석 정확성을 높인데, 주로 1-50Hz 범위로 설정하며 델타(δ , 1-4Hz), 세타(θ , 4-8Hz), 알파(α , 8-13 Hz), 베타(β , 13-30Hz), 감마(γ , 30-50Hz) 파를 구분해 각 대역의 특성을 분석한다[8]. 실험 시작 전 안정 상태 신호를 기준선으로 설정하고, 실험 데이터를 기준선과 비교해 집중력 변화를 정확히 파악한다.

EEG 신호의 주파수 영역 분석은 Numpy 및 SciPy 라이브러리를 사용하여 고속 푸리에 변환(FFT)으로 수행되며, 다음 수식으로 표현할 수 있다. 수식에서 $f(t)$ 는 시간 도메인에서의 신호를 나타내며, F_m 는 주파수 도메인에서의 성분을 나타낸다.

$$f(t) = \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{m=-\infty}^{\infty} F_m T e^{im\omega_0 t}$$

$e^{im\omega_0 t}$ 는 특정 주파수 성분에 해당하는 복소 지수 함수이다. 이를 통해 주파수 성분들이 시간 도메인에서 어떻게 합성되는지를 나타낸다[9].



[Fig. 3] Simulated EEG Data Power Spectral Density (1-50 Hz) After Preprocessing

3.2 Eye-Tracking 데이터

수집된 데이터에는 카메라 잡음, 조명 변화, 사용자 움직임 등으로 인한 노이즈가 포함될 수 있다. 이를 해결하기 위해 가우시안 필터와 미디언 필터를 사용해 고빈도와 스파이크 노이즈를 제거하여 신호의 선명도와 데이터 품질을 향상시킨다[10].

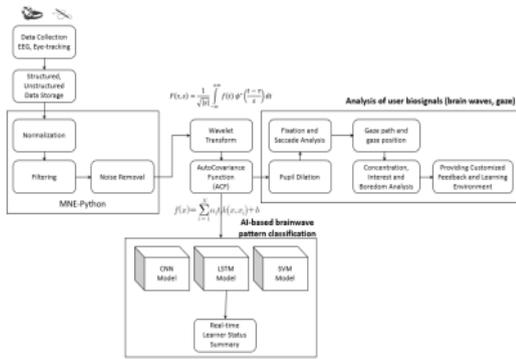
정규화를 통해 사용자마다 다른 얼굴의 위치, 크기, 조명 조건을 표준화한다. 좌표 정규화는 시선 데이터를 0과 1 사이의 값으로 변환해 일관성을 높이고, 히스토그램 균등화를 통해 조명 변화의 영향을 줄여 시선 추적 정확성을 향상시킨다.

정규화된 데이터에서 주요 3D 포인트, 눈의 위치와 움직임을 추출하여 시선 추정 모델의 입력으로 사용하고, 화면상의 시선 위치를 레이블링해 모델 학습에 활용한다[11]. 전처리된 데이터는 학습용과 검증용으로 무작위로 나누어 모델 학습과 성능 평가에 사용되며, 데이터의 편향을 최소화하기 위해 두 데이터 셋은 동일한 분포를 유지한다.

4. 시스템 설계

4.1 Learner State Monitoring

학습자의 상태를 실시간으로 분석하여 집중력 저하, 흥미도 감소, 지루함 등을 감지하고, 이를 바탕으로 적절한 피드백과 학습 환경 조정을 수행한다.

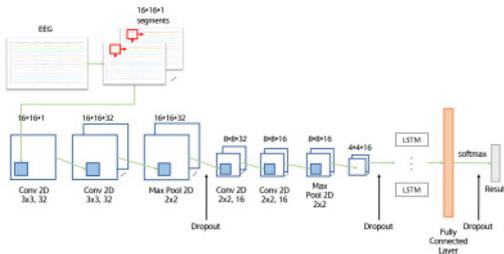


[Fig. 4] Workflow for EEG and Eye-Tracking Data Acquisition, Analysis, and AI-Based Classification

4.1.1 AI-Based EEG Pattern Classification

TensorFlow를 활용해 합성곱 신경망 (CNN)과 장단기 메모리 (LSTM) 모델을 개발한다. CNN은 뇌파의 시각적 패턴을 분석해 지역적 특성을 추출하고, LSTM은 시계열 데이터를 처리해 시간적 의존성을 모델링한다. 두 모델은 교차 검증을 통해 최적의 하이퍼파라미터를 찾고 성능을 비교해 최상의 모델을 선택한다. CNN은 Convolutional Layer와 Pooling Layer로 구성되며, Convolutional Layer는 입력 데이터에 필터를 적용해 특징 맵을 생성하고, Pooling Layer는 차원을 줄여 주요 정보를 추출한다. Fully Connected Layer는 추출된 특징을 활용해 분류 작업을 수행하고, ReLU 활성화 함수를 사용해 복잡한 패턴을 학습한다[12].

LSTM은 시계열 데이터의 장기 의존성을 모델링하며, 셀 상태와 포갯 게이트, 입력 게이트, 출력 게이트로 구성된다. 각 게이트는 데이터를 기억하고 업데이트하며, 필요한 정보를 출력한다. 이를 통해 LSTM은 EEG 데이터의 시간적 패턴을 효과적으로 학습할 수 있다.



[Fig. 5] CNN-LSTM based pattern classification architecture using EEG brain signals

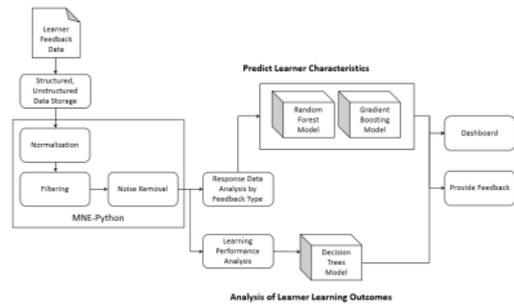
4.1.2 User Biometric Signal Analysis and Prediction

사용자의 생체 신호 데이터를 분석하고 예측하기 위해 EEG 신호와 시선 추적 데이터를 분석을 적용한다. 시선 추적 데이터는 사용자의 집중도와 흥미도를 파악하는 데 중요한 역할을 하며, 컴퓨터 화면을 주시하는 동안 시선의 이동 경로와 주시 시간을 기록하여 수집한다. 수집된 시선 추적 데이터는 전처리 과정을 통해 잡음 제거, 데이터 정규화, 특징 추출 등을 수행하여 분석에 적합한 형태로 변환된다[13].

가우시안 필터와 미디언 필터를 사용해 잡음과 조명 변화의 영향을 최소화하고, 얼굴의 위치와 크기를 정규화하여 데이터의 일관성을 유지한다. 추출된 주요 포인트와 눈의 움직임 등은 시선 추정 모델의 입력으로 사용된다. 시선 추적 데이터와 EEG 데이터를 결합해 사용자의 집중도, 피로도, 흥미도 등을 예측하는 모델을 구축하고, 교차 검증을 통해 최적의 하이퍼파라미터를 찾는다. 최종적으로, 사용자의 상태를 실시간으로 모니터링하여 집중력 저하나 흥미도 감소 등을 감지하고 적절한 피드백을 제공하는 시스템을 구현한다.

4.2 Learner Feedback

학습자의 피드백을 분석하여 효과적인 피드백 유형을 학습하고, 이를 바탕으로 점차적으로 맞춤형 피드백을 제공하는 시스템을 구현한다.



[Fig. 6] Data Processing and Machine Learning Pipeline for Predicting and Analyzing Student Performance

4.2.1 AI-Based Learner Characteristic Prediction

본 연구에서는 다양한 피드백 유형을 분석하고 효과적인 피드백을 예측하여 AI가 맞춤형으로 제공하는 시스템을 구현한다. 이를 위해 Random Forest와 Gradient

Boosting 같은 앙상블 학습 기법을 사용한다.

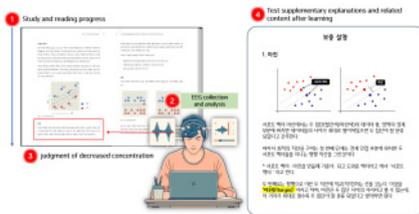
Random Forest는 여러 결정 트리를 결합해 예측 성능을 높이고, 부트스트랩 샘플링과 특징 무작위 선택으로 과적합을 방지한다. Gradient Boosting은 이전 트리의 오류를 보완하며 학습하여 성능을 개선하고, 경사 하강법과 정규화를 통해 과적합을 방지한다.

이 두 기법을 통해 학습자의 피드백 데이터를 분석하고, 최적의 피드백 유형을 예측하는 모델을 구축하여 학습자의 특성과 패턴에 맞는 피드백을 제공함으로써 학습 효과를 극대화한다.

4.2.2 Learner Performance Analysis

학습자의 성과를 분석하고 맞춤형 피드백을 제공하기 위해 Decision Trees 기반 예측 모델을 개발한다. Decision Trees는 데이터를 분할해 예측하는 트리 구조로, 학습 성과와 변수 간 관계를 분석한다. 이 모델은 재귀적 분할로 데이터셋을 나누고, 정보 이득이나 지니 지수를 사용해 최적의 분기 기준을 선택하여 불순도를 줄인다[14].

과적합을 방지하기 위해 가지치기(pruning)로 불필요한 노드를 제거해 모델 복잡도를 줄이고 성능을 높인다[15]. 이를 통해 학습자의 특성에 맞춘 피드백을 제공해 학습 효과를 극대화하고, 변수 간 관계를 분석해 학습 경로와 성과를 평가하는 시스템을 구현한다.



[Fig. 7] Workflow of Concentration Monitoring and Feedback in Study Sessions

5. 분석 및 결과

본 논문에서는 설문을 통해 집중력 저하나 특정 학습 영역에서의 어려움을 경험한 대학생 10명을 피실험자로 선별하였다. 피실험자들은 다양한 학업 성취도를 가진 20대 초반의 성인들로 구성되어있다. 피실험자가 30분 동안 eBook으로 학습한 후 EEG 데이터를 기반으로 집중력 변화를 분석하였다. 집중력 수준은 알파(8-13 Hz)

및 베타(13-30 Hz) 주파수 대역의 파워 스펙트럼 밀도(PSD)를 이용하여 측정하였다. 집중력 감소 구간에서 피실험자가 수행한 테스트 결과를 분석한 결과, 집중력이 떨어진 구간에서 피실험자는 특정 문제를 틀리는 경향이 높았다. 집중력이 떨어진 구간에서 발생한 오답 패턴을 분석한 결과, 피실험자는 주로 복잡한 문제나 긴 문장을 처리하는 데 어려움을 겪는 것으로 나타났다. 예를 들어, 피실험자는 집중력이 높은 구간에서 간단한 문제를 빠르고 정확하게 해결했지만, 집중력이 저하된 구간에서는 복잡한 문제에 대한 이해와 답안 선택이 어려워지는 경향이 두드러졌다. 이러한 분석 결과는 학습자가 집중력이 저하되는 구간에서 맞춤형 피드백을 제공함으로써 학습 효과를 극대화할 수 있는 가능성을 시사한다. 집중력 저하 구간에서 발생하는 오답 유형을 파악하여 해당 문제 유형에 대한 보충 학습을 제안함으로써, 학습자의 이해를 강화하고 지속적인 학습 동기를 부여할 수 있다.



[Fig. 8] Test Accuracy and Errors in Tasks Over Time

6. 결론

본 논문에서는 학습 장애 학생들을 위한 생체신호 기반 맞춤형 학습 지원 시스템을 설계하였다. 이 시스템은 EEG와 시선 추적 데이터를 실시간 분석해 학습자의 집중도, 흥미도, 지루함 등을 감지하고 맞춤형 피드백을 제공하여 학습 효과를 극대화하는 것을 목표로 한다. 시뮬레이션 결과, 집중력이 저하된 구간에서 피실험자가 문제를 더 많이 틀리는 경향이 있어 맞춤형 피드백의 필요성을 확인하였다.

시스템의 주요 구성 요소는 다음과 같다. 첫째, Emotiv EPOC X와 시선 추적 장치로 EEG와 시선 데이터를 수집하고 전처리한다. 둘째, TensorFlow 기반 CNN 및 LSTM 모델을 활용해 EEG 데이터를 분석하고 학습자의 상태를 예측한다. 셋째, Random Forest와 Gradient Boosting 기법으로 피드백 데이터를 분석하여 맞춤형 피드백을 제공한다. 마지막으로, Decision Trees를 사용해 학습 성과를 분석하고 이에 따른 적절한 피드백을

제안하였다.

향후 연구에서는 시스템의 구현과 실제 적용을 통해 효과성을 검증하고, 기능 개선을 통해 더욱 완성도 높은 학습 지원 시스템을 개발할 필요가 있다.

REFERENCES

[1] M. Shin and N. Choi, "The Invisible Population of Students With Learning Disabilities in South Korea" *Intervention in School and Clinic*, Vol.57, No.3, pp. 147-155, 2021.

[2] S. Taheri, M. Ezoji, and S. M. Sakhaei, "Convolutional neural network based features for motor imagery EEG signals classification in brain-computer interface system" *SN Applied Sciences*, Vol.2, No.555, 2020.

[3] W. Mumtaz and A. Qayyum, "A deep learning framework for automatic diagnosis of unipolar depression" *International Journal of Medical Informatics*, Vol.132, No. 103983, 2019.

[4] H. Li, M. Ding, R. Zhang, and C. Xiu, "Motor imagery EEG classification algorithm based on CNN-LSTM feature fusion network" *Biomedical Signal Processing and Control*, Vol.72, No.103342, 2022.

[5] S. U. Amin, M. Alsulaiman, G. Muhammad, M. A. Mekhtiche, and M. S. Hossain, "Deep Learning for EEG motor imagery classification based on multi-layer CNNs feature fusion" *Future Generation Computer Systems*, Vol.101, pp.542-554, 2019.

[6] R. Ben Messaoud and M. Chavez, "Random Forest classifier for EEG-based seizure prediction," *arXiv*, Vol.2106.04510, 2021.

[7] N. S. Bastos, B. P. Marques, D. F. Adamatti, and C. Z. Billa, "Analyzing EEG Signals Using Decision Trees: A Study of Modulation of Amplitude" *Computational Intelligence and Neuroscience*, No.3598416, pp.1-13, 2020.

[8] A. Zabidi et al., "Short-time Fourier Transform analysis of EEG signal generated during imagined writing" *2012 International Conference on System Engineering and Technology (ICSET)*, pp.1-5, 2012.

[9] S. Sanei and J. A. Chambers, "EEG Signal Processing" *John Wiley & Sons Ltd*, pp.1-254, 2007.

[10] A. Kumar and S. S. Sodhi, "Comparative Analysis of Gaussian Filter, Median Filter and Denoise Autoencoder" *2020 7th International Conference on Computing for Sustainable Global Development (INDIACom)*, New Delhi, India, 2020

[11] M. Rashid, N. Sulaiman, M. Mustafa, M. S. Jadin, M. S. Najib, B. S. Bari, and S. Khatun, "Analysis of EEG Features for Brain Computer Interface Application" *Lecture Notes in Electrical Engineering*, Vol.632,

pp.529-540, 2020.

[12] S. U. Park, J. H. Han, and S. K. Hong, "LSTM Based Behavior Classification Deep Learning Algorithm Using EEG" *The Transactions of the Korean Institute of Electrical Engineers*, Vol.70, No.12, pp.1924-1933, 2021.

[13] J. Zheng, Y. Xu, and H. Li, "A Review of EEG-Based Brain-Computer Interfaces as Assistive Technologies for People with Disabilities" *Assistive Technology*, Vol.27, No.2, pp.103-115, 2015.

[14] S. B. Kwon and Y. H. Kim, "Machine learning methods for EEG-based brain-computer interfaces: A review" *Frontiers in Human Neuroscience*, Vol.12, No.522, pp.1-10, 2018.

[15] B. Kang and G. Yoon, "Generation of Control Signal based on Concentration Detection using EEG signal" *Journal of the Institute of Electronics and Information Engineers*, Vol.50, No.12, pp.254-260, 2013.

홍 서 빈(Seo-Bin Hong)

[학성회원]



- 2023년 8월 : 서원대학교 컴퓨터 공학과(공학학사)
- 2023년 9월 ~ 현재 : 서원대학교 정보통신공학과 석사과정
- E-Mail : tjqls691@naver.com

<관심분야>

데이터사이언스, 딥러닝, 뇌과학

김 봉 현(Bong-Hyun Kim)

[정회원]



- 2009년 2월 : 한밭대학교 컴퓨터 공학과(공학박사)
- 2012년 ~ 2015년 : 경남대학교 컴퓨터공학과 교수
- 2020년 3월 ~ 현재 : 서원대학교 컴퓨터공학과 교수

■ E-Mail : bhkim@seowon.ac.kr

<관심분야>

데이터사이언스, 딥러닝, 생체신호분석, IoT응용서비스