

# 아동의 ADHD 진단 보조를 위한 기계 학습 기반의 뇌전도 분류

김민기<sup>†</sup>

## Machine Learning-Based EEG Classification for Assisting the Diagnosis of ADHD in Children

Min-Ki Kim<sup>†</sup>

### ABSTRACT

Attention Deficit Hyperactivity Disorder (ADHD) is one of the most common neurological disorders in children. The diagnosis of ADHD in children is based on the interviews and observation reports of parents or teachers who have stayed with them. Since this approach cannot avoid long observation time and the bias of observers, another approach based on Electroencephalography(EEG) is emerging. The goal of this study is to develop an assistive tool for diagnosing ADHD by EEG classification. This study explores the frequency bands of EEG and extracts the implied features in them by using the proposed CNN. The CNN architecture has three Convolution-MaxPooling blocks and two fully connected layers. As a result of the experiment, the 30-60 Hz gamma band showed dominant characteristics in identifying EEG, and when other frequency bands were added to the gamma band, the EEG classification performance was improved. They also show that the proposed CNN is effective in detecting ADHD in children.

**Key words:** Attention Deficit Hyperactivity Disorder (ADHD), EEG, Gamma band, CNN

### 1. 서론

주의력결핍과잉행동장애(attention deficit hyperactivity disorder, ADHD)는 유전적 요소와 관련된 흔한 신경정신 장애로, ADHD를 가진 아동은 부주의(inattention), 과잉 행동(hyperactivity), 충동성(impulsivity)이라는 특징을 나타낸다. 미국 유아와 아동(2세~17세)의 9.4%에 이르는 약 6백만명이 ADHD로 진단받은 것으로 보고되었으며[1], 우리나라의 경우 ADHD로 인해 진료를 받은 수는 전체 5만 8천명이며, 이중 10대가 65.9%를 차지하는 것으로 나타났다[2]. 이와 같이 아동의 ADHD는 결코 드문 증상이 아니며 ADHD 아동의 경우 집중력 장애로

학습에 어려움을 겪을 뿐만 아니라 학교생활의 부적응으로 이어진다. 게다가 ADHD는 다른 신경정신 장애가 수반되는 동반 질환의 가능성을 내포하고 있어 ADHD의 조기 발견과 적절한 치료가 매우 중요하다.

ADHD 진단은 증후의 관찰과 평가를 통한 행동 분석(behavior analysis)으로 이루어진다[3]. 아동의 ADHD 진단은 행동 분석 표준화 설문 도구를 통해 이루어지며 부모와 교사 등 아동의 행동을 일상에서 관찰할 수 있는 2인 이상으로부터 얻은 설문 결과로 진단에 사용된다. 그러나 이러한 방식은 설문 응답자의 주관적 측정에 의존하는 제한점과 ADHD 진단 대상에 대한 장기간의 관찰자가 필요하므로 오랜 시간이 소요되는 단점이 있다. 뇌전도(electroencepha-

\* Corresponding Author : Min-Ki Kim, Address: (660-701) Jinju-daero 501, Jinju, Gyeongnam, Korea, TEL: +82-55-772-1393, FAX: +82-55-772-1389, E-mail: mkkim@gnu.ac.kr

Receipt date: Aug. 12, 2021, Revision date: Sep. 27, 2021  
Approval date: Oct. 8, 2021

<sup>†</sup> Dept. of Computer Science, Gyeongsang National University, Engineering Research Institute

lography, EEG)는 대뇌 피질의 시냅스 활성화에 의해 생성되는 전기적 신호를 두피 표면에서 측정된 데이터로, 뇌 활동을 분석하는데 유용한 정보를 제공한다. 지난 20여 년간 이루어진 많은 EEG 연구들은 ADHD 환자와 건강한 일반인의 뇌 활동에 차이가 나타남을 보고하였다. 그러나 아직까지 EEG 분석에 의해 ADHD를 진단할 수 있는 표준화된 방법이 부재한 상태로, 연구자에 따라 피험자로 참여한 대상자의 연령, EEG 측정 조건, EEG 채널의 선택을 비롯하여 다양한 EEG 식별 방법이 연구되어 왔다[4,5].

Allahverdy 외[6]와 Mohammadi 외[7]는 주의 집중에 따른 EEG 변화를 통해 ADHD 아동과 일반아동을 식별하기 위하여 EEG의 비선형 특징을 추출하고, 다층 퍼셉트론(Multi-Layer Perception, MLP)을 이용하여 ADHD 아동을 식별하였다. TaghiBeyglou 외[8]는 EEG의 비선형 특징을 이용한 연구[6, 7]에서 제시한 라프노브 지수(Lyapunov exponent), Katz 프랙탈 차원, Higuchi의 프랙탈 차원, 근사 엔트로피에 추가적인 비선형 특징으로 다변량 신호의 분산이 최대가 되도록 부요소로 분리한 CSP(Common Spatial Pattern)를 사용하였다. Aleksandar 외[9]는 19개 채널을 갖는 EEG 신호에 고속 푸리에 변환(fast Fourier transform, FFT)을 적용하여 4개의 주파수 밴드(Delta 0.5~4Hz, Theta 4~8Hz, Alpha 8~12Hz, Beta 12~30Hz)로 분할하고, 각 상태에서 추출한 스펙트럼으로 SVM(Support Vector Machine)을 학습시켜 성인의 ADHD 여부와 하위 유형을 식별하였다. Alchalabi 외[10]는 분할된 주파수 밴드의 자체 값뿐만 아니라 Alpha/Theta를 포함한 5개의 두 주파수 밴드 간의 상대 값을 특징으로 사용하였다.

최근에는 합성곱 신경망(Convolutional Neural Network, CNN)을 이용하여 EEG 특징을 자동으로 추출하고 의학적 진단에 활용하기 위한 다양한 연구들이 활발히 이루어지고 있다. Mao 외[11]는 뇌전증 발작(epileptic seizure) 증세를 진단하기 위하여 1차원 EEG 신호에 연속 웨이블릿 변환을 적용하여 얻은 2D 영상을 입력으로 하는 세 쌍의 합성곱과 Max풀링 계층으로 구성된 CNN을 이용하였으며, Sandheep 외[12]는 우울증 검출에 한 쌍의 합성곱과 Max풀링 계층, 그리고 3개의 완전연결층을 갖는 매우 단순한 CNN을 적용하였다. Moghaddari 외[13]는 ADHD 검출을 목적으로 EEG를 세타(theta), 알파(alpha), 베타

와 하위감마(beta + low gamma)로 구성된 3개 주파수 밴드로 2D 영상을 생성하고, 이것을 합성곱, Max풀링, 드롭아웃으로 구성된 블록 3개를 직렬로 연결한 후 완전연결층 2개로 CNN을 구성하였다. Vahid 외[14]는 56개 채널로 구성된 EEG로부터 ADHD를 식별하기 위한 EEGNet이라고 명명한 CNN을 제안하였다. EEGNet은 0.5~20Hz의 밴드의 스펙트럼을 입력 신호로 구성하고, 시간축의 주파수 변화 특징을 추출하는 합성곱 연산 후 56개 채널에 대한 깊이우선 합성곱(depthwise convolution) 연산을 수행하는 블록과 분리가능 합성곱(separable convolution)을 수행하는 연속된 2개 블록으로 구성되어 있다. Chen 외[15]는 32개 채널로 구성된 EEG로부터 아동의 ADHD를 식별하기 위한 4개의 서로 다른 구조를 갖는 CNN을 제시하였다. CNN 구조는 크게 세 부분으로 나누어 볼 수 있는데, 5개 계층으로 구성된 첫 번째 부분과 9개 계층으로 구성된 마지막 부분은 모두 동일하고, 중앙부의 구조를 달리하여 CNN을 구성하였다. 중앙부의 가장 간단한 구조는 32개의 3×3 커널로 구성하였고, 여기에 스킵 연결(skip connection), 인셉션 모듈(inception module)을 추가하여 복잡한 CNN을 구조를 제시하였다. 실험 결과 제일 단순한 구조의 CNN이 가장 우수한 식별력을 나타내었다.

기존 연구들은 EEG의 특징을 효과적으로 기술할 수 있는 비선형 특징을 중점적으로 탐색하였으며, 최근 CNN을 이용한 딥 러닝 기법을 적용한 연구들은 EEG 신호 자체를 효과적으로 분류할 수 있는 CNN 구조에 초점을 두고 있다. 그러나 ADHD 식별의 정확도를 높이기 위해서는 EEG 신호에서 ADHD의 특징을 잘 기술할 수 있는 주파수 서브 밴드의 선택과 이들을 효과적으로 결합할 수 있는 CNN 분류기가 요구된다. 따라서 본 연구에서는 ADHD 검출에 적합한 EEG 신호의 특징을 추출하기 위하여 EEG 주파수 밴드의 특성을 탐색하고, 여러 주파수 밴드 간에 내포된 특징을 효과적으로 처리할 수 있는 장방형 커널을 사용한 CNN을 제안한다. EEG 신호를 구성하는 전체 주파수를 알파, 베타, 감마, 세타, 델타 주파수 밴드로 분해하여 각 주파수 밴드에서 추출한 특징으로 아동의 ADHD 식별에 대한 정확도를 비교해봄으로써 적합한 주파수 밴드의 선택과 조합이 가능해진다. 제안하는 CNN은 일반적으로 널리 사용되

는 정사각형 형태의 3×3 커널에 비하여 직사각형 형태의 장방형 커널을 사용함으로써 순한 구조의 CNN을 사용하면서도 합성곱에 의해 여러 채널 신호들 간의 관계에 내포된 특징을 효과적으로 추출할 수 있는 장점이 있다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구에서 사용한 EEG 데이터에 대하여 기술하고, 3장에서는 아동의 ADHD 식별을 위한 EEG 신호의 주파수 분할과 CNN 구성에 대하여 설명한다. 4장에서는 공개된 데이터셋을 이용한 실험 결과를 제시하고, 기존 연구 결과와의 비교를 통해 제안된 방식의 타당성을 제시한다. 끝으로 5장에서 결론을 제시한다.

## 2. EEG 데이터

EEG 분석에 의한 아동의 ADHD 식별을 위해서는 먼저 EEG 데이터를 확보하여야 한다. 주의 집중이 필요한 자극을 제시하고 피험자의 두피에 배치된 전극을 통해 EEG 신호를 측정하게 되는데, 자극 제시 방식과 전극의 배치는 연구자에 따라 다양하다. 만화 캐릭터들이 그려진 영상을 제시하고 캐릭터의 수를 세도록 하는 자극을 제시하기도 하고[6,7], 피험자가 게임 플레이어가 되어 아바타를 움직이게 하는 게임을 진행하거나[10]. 시각적 자극을 제시하고 일정 시간이 경과 한 것으로 예측되는 시점에 버튼을 눌러 반응하게 하여 EEG 신호를 측정하기도 한다[14].

본 연구에서 사용한 데이터는 이란의 샤헤드(Shahed) 대학에서 수집한 공개 데이터셋이다 [16]. 이 데이터셋은 영상 상단과 하단에 제시된 만화 캐릭터의 개수를 세어 합을 구하도록 주의 집중을 유도하여 EEG를 획득한다. 이 데이터셋은 7세~12세 아동 121명으로부터 측정된 두 세트의 데이터로 구성되어 있다. Set1은 ADHD 아동 30명과 통제집단 아동 30명, Set2는 ADHD 아동 31명, 통제집단 아동 30명에서 측정된 데이터이다. Fig. 1에 제시된 10-20 표준체계[17]에 따라 전전두부(Fp)에 2개, 전두부(F)에 5개, 중앙부(C)와 두정부(P)에 각각 3개, 좌우 측두부(T)에 각각 2개, 후두부(O)에 2개, 총 19개의 전극을 통해 128Hz의 샘플링으로 EEG 측정이 이루어졌다. 개인마다 머리의 크기가 다르기 때문에 10-20 표준체계는 기준점에서의 거리 비율을 이용한다. 비근점(nasion)과 뒤통수점(inion)을 잇는




Fig. 1. 10-20 system of electrode placement [17].

가상의 수직선을 생성하고, 왼쪽과 오른쪽 귓불(ear lobe)을 연결하는 수평선을 생성한다. 비근점과 뒤통수점에서 위쪽으로 10%되는 부분을 원의 형태로 그려서 전극을 배치하고, 각 전극들간의 거리는 20% 간격으로 배치한다. Fig. 1에서 아래첨자 z는 중앙의 가상 수직선 상의 위치를 나타내며, 이 수직선을 기준으로 홀수 첨자 1, 3, 5, 7은 좌측 영역, 짝수 첨자 2, 4, 6, 8은 우측 영역을 의미한다. 개인당 EEG 측정 시간은 대략 4분~6분 정도로 시각적 자극을 제시하였을 때 캐릭터의 개수를 세어 반응하는 속도가 피험자마다 다르기 때문에 측정된 EEG 신호의 길이는 상이하다.

일반적으로 CNN을 이용하여 신호의 특징을 자동으로 추출하고 특정 클래스로 분류하는 문제를 해결하기 위해서는 CNN을 학습시킬 수 있는 다량의 데이터를 확보하여야 한다. 하지만 ADHD 진단을 받은 아동을 모집하거나 해당 아동과 유사한 연령대의 피험자를 모집하여 EEG 신호를 획득하기 위해서는 많은 시간과 비용이 소요되기 때문에 다량의 데이터를 확보하는 것은 현실적으로 매우 어려운 일이다. 본 연구에서는 피험자 121명으로부터 획득한 EEG 데이터셋을 확장하기 위하여 EEG 신호를 30초 단위로 중첩되지 않도록 분할하였다. 이를 통해 ADHD 집단에 속하는 288개의 EEG 샘플, 통제집단에 속하는 220개의 EEG 샘플로 확장하였다. 두피에 부착된 19개 전극에서 측정된 신호를 128Hz로 샘플링하였으므로, 개별 EEG 샘플은 (19, 3840)의 차원을 갖게 된다.




Fig. 2 EEG spectrums including artifacts.

### 3. 제안하는 방법

#### 3.1 EEG 데이터 처리

측정된 EEG 신호에는 일반적으로 잡음(noise)과 잡파(artifact)가 포함되어 있다. 잡파는 EEG 신호에서 관심 대상이 되는 신호 외에 눈의 깜박임이나 팔다리의 움직임에 의해 발생한다. 잡음이나 잡파로 인하여 EEG 신호에 왜곡이 발생하므로 이들을 제거할 수 있다면 EEG 신호로부터 안정적인 특징 추출을 기대할 수 있다. EEG 신호에서 60Hz 이상은 대개 잡음으로 분류되어 쉽게 제거할 수 있다. 그러나 잡파는 피험자에 따라 형태학적 특징이 조금씩 다르게 나타나므로 일관된 특징을 추출하기 어렵다. 신경과 전문의가 EEG 파형을 보면서 잡파가 발생하는 부분을 제거하거나[7], 매트랩(MATLAB)의 EEGLAB 툴박스를 사용하여 제거하기도 한다[13]. Fig. 2는 19 채널 EEG 파형의 일부를 제시한 것으로 적색 사각형은 잡파가 나타난 영역을 나타낸다. 잡파를 제거하는 것은 별개의 연구 주제로, 본 연구에서는 잡파를 제거하지 않고 잡음만을 제거한 EEG 데이터를 사용한다.

잡파가 포함된 (19, 3840)의 차원의 EEG 샘플 전체에서 특징을 추출하여 ADHD를 식별할 경우 신호의 왜곡으로 분류의 정확도가 낮아지게 된다. 그러나 잡파는 대개 EEG 샘플 중 일부분에서만 발생하므로 잡파가 없는 부분에서 특징을 추출하면 ADHD를 식별할 수 있는 유효한 특징을 찾아낼 수 있다. 한 개의 EEG 샘플 데이터를 여러 개의 세그먼트로 분할하여

각 세그먼트 단위로 EEG 분류를 수행할 경우 잡파가 포함된 세그먼트가 50%미만이라고 가정할 때, 각 세그먼트의 분류 결과를 다수결 규칙(majority rule)에 의해 결합하면 확률적으로 EEG 샘플에 대한 올바른 ADHD 분류가 가능하다. Fig. 3에 제시된 바와 같이 EEG 샘플을 일정한 크기를 갖는 윈도우로 분할하면 확률적으로 잡파가 없는 세그먼트(segment)를 다수 확보할 수 있다. 윈도우의 크기  $w$ 가 EEG 세그먼트의 길이가 되고, 중첩되는 윈도우의 비율에 따라 윈도우를 이동시키는 거리  $s$ 가 결정된다. 예를 들어 128Hz로 샘플링한 4초 분량의 EEG 신호를 한 개의 세그먼트로 구성한다고 할 때, 윈도우의 크기  $w$ 는 512가 되고, 중첩되는 윈도우 비율을 25%로 하면 이동 거리  $s$ 는 384가 된다.  $w$ 가 작아질수록 세그먼트내에 잡파가 포함될 확률이 감소하지만  $w$ 가 너무 작아지면 해당 세그먼트가 ADHD를 식별할 수 있는 충분한 정보를 내포하지 못하게 된다.




Fig. 3. Overlapping window for EEG segment.

3.2 주파수 밴드 탐색

EEG 신호의 주파수와 진폭은 EEG 패턴의 기본 특징이다. EEG 신호는 특정 주파수 범위에 따라 델타(delta, < 4Hz), 세타(theta, 4~8Hz), 알파(alpha, 8~12Hz), 베타(beta, 12~30), 감마(gamma, > 30 Hz) 밴드로 나누어진다. 각 주파수 밴드는 뇌의 활동에 연관된 것으로 알려져 있다. 델타 밴드는 수면 시에, 세타 밴드는 졸음이 올 때 강하게 나타나며, 알파 밴드는 편하게 쉬는 상태, 베타 밴드는 역동적인 활동, 그리고 감마 밴드는 문제 해결이나 기억 작업과 관련되어 있다[18]. 어떤 자극에 반응할 때, 알파 밴드의 값은 감소하고 베타 밴드의 값은 증가하기 때문에 베타/알파 비(ratio)는 피험자의 각성 상태를 나타내는 흥미로운 지표로 널리 알려져 있다.

두뇌의 다양한 활동 상태가 EEG 신호의 서브 밴드의 특성으로 나타나므로, 본 연구에서는 각 서브 밴드에 나타난 스펙트럼이 ADHD 식별에 어떤 유효성을 갖는지 탐색하기 위하여 기계 학습에 기반한 분류기를 사용하였다. 각 서브 밴드의 상대적인 유효성을 평가하는 것이 목적이므로 CNN에 비하여 단순한 구조를 갖는 랜덤 포레스트(random forest)[19]를 이용하였다. 랜덤 포레스트는 학습 과정에서 구성한 다수의 결정 트리로 분류를 수행하는 방식으로, 이를 통해 각 주파수 밴드가 ADHD를 식별하는데 기여도를 파악하고, 최적의 주파수 밴드 조합을 탐색하여 이를 CNN 분류기의 입력으로 사용하였다. 실험 결과 감마 밴드가 ADHD를 식별하는데 기여도가 가장 큰 것으로 나타났다.

3.3 CNN 구조

ADHD를 식별하기 위하여 제안한 CNN의 전단부는 합성곱층(convolution layer)과 맥스풀링층(Max Pooling layer)으로 구성된 블록을 연속적으로 연결하여 구성하고 후단부는 완전연결층(dense layer)으로 구성하였다. 합성곱에 사용한 커널은 여러 채널들 간의 관계에 내포된 특징을 반영할 수 있도록 직사각형 형태의 장방형 커널을 사용하였다. ADHD 식별에 적합한 합성곱-맥스풀링 블록의 개수를 파악하기 위하여 ADHD 아동 30명과 통제집단 아동 30명으로 구성된 Set1 데이터에 대하여 실험을 통해 정확도를 측정하였다. 합성곱 커널의 개수를 32, 완전연결층을 2개로 고정시키고 합성곱 두 계층에 각각 1×11, 2×7

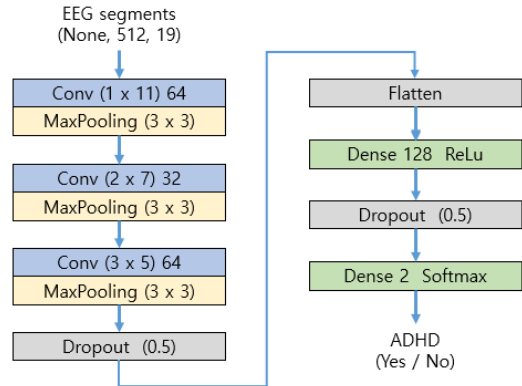


Fig. 4. Architecture of the proposed CNN model.

커널을 적용하였을 때 95.1%였고, 합성곱 층을 한 개 늘려 3×5 커널을 적용하였을 때 정확도가 95.4%로 향상되었다. 그러나 여기에 합성곱 층을 두 개까지 더 늘려 각각 3×3 커널을 적용한 경우는 94.9%, 94.6%로 성능이 저하되었으며, 3계층의 합성곱-맥스풀링 블록에 완전연결층을 3개로 늘렸을 경우에도 정확도는 94.9%로 저하되었다. 이러한 결과를 토대로 최종적으로 제안된 CNN 모델의 구조는 Fig. 4와 같다. 합성곱 커널의 개수는 순서대로 64, 32, 64이고, 옵션은 모두 동일하게 padding은 ‘same’, 활성화 함수는 ‘relu’를 사용하였다. 첫 번째 합성곱 층에 1×11 커널을 사용함으로써 19개 채널 입력 중 이웃한 11개에 입력으로부터 원시 특징을 추출하고, 맥스풀링을 통해 3×3 국소 최대값을 선택한다. 두 번째와 세 번째 합성곱 층의 2×7 커널과 3×5 커널을 거쳐 보다 정제된 특징을 추출한다. 정사각형 형태의 3×3 커널 대신에 직사각형 형태의 커널을 사용한 이유는 합성곱을 통해 여러 채널들 간에 내재된 특징을 추출하기 위한 것이다. 첫 번째 완전연결층은 128개 노드, 두 번째 완전연결층은 2개 노드로 구성하였다. 완전연결층은 입력과 출력을 모두 연결하고 가중치를 학습시키게 되는데, 학습 과정에서 발생하는 과적합(overfitting) 문제를 해소하기 위하여 드롭아웃 층을 두고 0.5 확률로 드롭아웃을 수행하였다.

4. 실험 결과 및 분석

4.1 실험 데이터 및 성능 측정

실험에 사용된 데이터셋[16]는 두 세트로 이루어져 있다. Set1에는 ADHD 아동 30명에게서 얻은

Table 1. Contingency table.

Estimated Class Real Class	ADHD Group	Control Group
ADHD Subject	True Positive	False Negative
Healthy Subject	False Positive	True Negative

149개의 샘플과 통제집단 아동 30명에게서 얻은 101개의 샘플이 있고, Set2에는 ADHD 아동 31명에게서 얻은 139개의 샘플과 통제집단 아동 30명에게서 얻은 119개의 샘플이 있다. 샘플의 80%를 훈련 데이터로 설정하고, 나머지 20%를 테스트 데이터로 설정하였다. 데이터셋이 충분히 크지 않으면 학습 데이터와 테스트 데이터로 어떤 샘플이 선택되었는지에 따라 성능의 차이가 크게 나타날 수 있으며, 이 경우 모델의 성능을 신뢰하기 어렵다. 따라서 본 연구에서는 분류기의 일반화 성능을 측정하는데 적합한 것으로 알려진 5겹 교차검증(5-fold cross-validation) 방식을 사용하였다. 이 방식은 데이터셋을 5개로 나눈 후 번갈아 가면서 1개를 테스트 데이터로 사용하고, 나머지 4개를 학습 데이터로 사용한다.

ADHD 여부를 식별하는 분류기의 성능은 정확도(accuracy), 민감도(sensitivity), 특이도(specificity)를 사용하여 측정하였다. 2-클래스 분류의 결과는 Table 1에 제시된 바와 같이 2×2 분할표로 나타난다. ADHD인 피험자가 ADHD로 올바르게 분류된 경우는 참 양성(TP), 건강한 아동으로 오분류된 경우는

거짓 음성(FN)이라 하고, 통제집단에 속하는 건강한 피험자가 ADHD로 오분류된 경우는 거짓 양성(FP), 올바르게 분류된 경우는 참 음성(TN)이라고 한다. 정확도, 민감도, 특이도는 각각 식(1)~(3)에 의해 계산된다. 정확도는 피험자를 해당 그룹으로 올바르게 분류한 비율을 의미하며, 민감도는 ADHD 피험자를 올바르게 진단한 비율, 특이도는 건강한 피험자를 올바르게 진단한 비율을 의미한다.

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \times 100(\%) \quad (1)$$

$$Sensitivity = \frac{TP}{TP + FN} \times 100(\%) \quad (2)$$

$$Specificity = \frac{TN}{FP + TN} \times 100(\%) \quad (3)$$

#### 4.2 주파수 밴드 탐색

ADHD 식별에 적합한 EEG 신호의 주파수 밴드를 탐색하기 위하여 랜덤 포레스트를 이용하였다. 포레스트내의 트리의 개수는 100, 트리의 내부 노드를 분리하기 위하여 요구되는 샘플의 최소 개수는 2로 설정하였다. Table 2는 19개 채널에서 추출한 각 주파수 밴드의 스펙트럼 값을 정규화하여 랜덤 포레스트 분류기를 통해 ADHD 여부를 식별한 결과로, 5겹 교차검증을 통해 테스트 데이터에서 얻은 정확도(Acc), 민감도(Sen), 특이도(Spe)의 평균값을 제시한 것이다.

모든 주파수 밴드에서 ADHD 아동을 ADHD로 판

Table 2. Classification results by the random forest.

Frequency Bands	Measures	Acc(%)	Sen(%)	Spe(%)
Delta (0.5~4Hz)	Set1	60.90	97.15	63.75
	Set2	66.16	93.48	72.67
Theta (4~8Hz)	Set1	61.83	97.46	64.37
	Set2	65.71	94.55	71.16
Alpha (8~12Hz)	Set1	61.33	97.52	63.80
	Set2	59.76	96.28	63.48
Beta (12~30Hz)	Set1	62.65	97.81	64.85
	Set2	64.17	95.50	64.85
Gamma (30~60Hz)	Set1	<b>89.67</b>	98.47	<b>91.20</b>
	Set2	<b>85.56</b>	98.78	<b>86.78</b>
All Range (0.5~60Hz)	Set1	66.79	97.49	69.30
	Set2	74.74	98.32	76.42



별하는 민감도는 93.5%~98.8%로 높게 나타났으나, 통계집단 아동을 건강한 정상 아동으로 판별하는 특이도는 감마 밴드를 제외하면 63.5%~75.4%로 낮게 나타났다. 감마 밴드는 ADHD 아동과 정상 아동을 식별하는 정확도가 Set1, Set2에 대하여 각각 89.7%, 85.6%을 보여 59.8%~66.2%의 정확도를 보인 다른 밴드들은 물론 0.5~60Hz까지의 주파수 전체를 사용하는 것보다 우수한 성능을 보였다. 이러한 결과는 감마 밴드가 문제 해결이나 기억과 관련되어 있다는 점에 비추어 볼 때 의미 있는 결과로 볼 수 있다. 감마 밴드를 제외한 나머지 주파수 밴드들은 ADHD 식별력에 있어 큰 차이를 나타내지 않았다.

4.3 CNN 성능 측정

제안한 CNN을 이용하여 ADHD 아동을 식별하는 실험을 수행하였다. 랜덤 포레스트를 이용한 분류에서 가장 좋은 성능을 보인 감마 밴드를 기본으로 하고, 여기에 다른 주파수 밴드를 하나씩 추가하여 실험을 수행하였다. CNN의 하이퍼 파라미터(hyperparameter) 중 옵티마이저(optimizer)는 Joo 외[20]의 연구에서 가장 좋은 성능을 나타낸 Adam을 사용하였고, 학습율은 0.001, 에포크(epoch)와 배치크기(batch size)는 각각 50, 64로 설정하였다. 학습 데이터를 통해 학습되는 CNN의 파라미터는 총 1,446,498 개이다.

학습 데이터를 이용하여 CNN을 학습시키고, 테스트 데이터에 대하여 실험을 통해 Table 3에 제시된 결과를 얻었다. 실험 결과 Set1은 감마, 베타, 알파,

췌타의 4개 밴드를 사용하였을 때, Set2는 5개 밴드를 모두 사용하였을 때 정확도, 민감도, 특이도가 가장 높게 나타났다. 감마 밴드만을 사용한 것보다 다른 밴드들을 추가하였을 때 Set1은 정확도가 최대 2.26% 포인트, Set2는 2.02% 포인트 향상되었다. 특히 민감도는 감마와 베타 2개의 밴드만 사용하여도 Set2의 경우 100%까지 향상되었다. 특이도는 Set1, Set2에 대하여 각각 4개 밴드와 5개 밴드를 결합하였을 때 감마 밴드만 사용한 경우에 비교할 때, 각각 1.53% 포인트, 1.26% 포인트 향상되었다. Set1과 Set2의 결과를 산술 평균하였을 때 감마 밴드에 베타, 알파, 췌타 밴드를 결합한 4개의 밴드를 사용했을 때 정확도, 민감도, 특이도가 각각 98.74%, 99.34%, 99.40%로 가장 좋은 성능을 나타내었다.

제안한 방법의 ADHD 식별 성능을 비교하기 위하여 유사하거나 동일한 실험 데이터를 사용한 최근의 연구 결과들을 정리하여 Table 4에 제시하였다. 제시된 연구들은 모두 제시된 영상의 상단과 하단에 나타난 캐릭터의 개수를 세어 더하도록 하는 자극을 제시하여 피험자로부터 EEG 데이터를 측정하였다. 각 연구에서 사용한 데이터셋이 동일하지 않기 때문에 ADHD 분류 성능에 대한 엄격한 비교는 불가능하지만 유사한 실험 데이터를 사용한 연구 결과들을 제시한 것으로 제안된 방식의 성능을 건주어 가늠해 볼 수 있다. [6,7,8]은 EEG 신호의 비선형 특징을 추출한 후 다층퍼셉트론(MLP)과 최근접분류기(KNN)를 사용하였고, [11,13]은 EEG 신호의 스펙트럼을 각각 CNN과 AdaBoost 분류기를 적용하여 EEG 신호를

Table 3. Classification results by the proposed CNN.

Measures		Acc(%)	Sen(%)	Spe(%)
Frequency Bands				
Gamma( $\gamma$ )	Set1	96.05	97.94	98.11
	Set2	97.55	99.24	98.31
$\gamma$ + Beta( $\beta$ )	Set1	97.61	98.22	99.58
	Set2	99.16	<b>100.0</b>	99.16
$\gamma$ + $\beta$ + Alpha( $\alpha$ )	Set1	97.11	98.30	98.81
	Set2	98.79	<b>100.0</b>	98.79
$\gamma$ + $\beta$ + $\alpha$ + Theta( $\theta$ )	Set1	<b>98.31</b>	<b>98.67</b>	<b>99.64</b>
	Set2	99.16	<b>100.0</b>	99.16
$\gamma$ + $\beta$ + $\alpha$ + $\theta$ + Delta( $\delta$ )	Set1	96.34	98.30	98.04
	Set2	<b>99.57</b>	<b>100.0</b>	<b>99.57</b>

Table 4. Performance comparison with some closely related studies.

Studies	Info.	Subject ADHD/Control	Classifier	Acc (%)	Sen (%)	Spe (%)
[6]		29 / 20	MLP	96.7	98.9	95.2
[7]		30 / 30	MLP	93.65	-	-
[13]		31 / 30	CNN	98.48	-	-
[8]		31 / 30	KNN	83.33	83.78	82.86
[11]		61 / 60	AdaBoost	84.0%	96.0	70.0
CNN of [13]		Set1 (30 / 30)	CNN	94.71	95.16	99.55
		Set2 (31 / 30)		97.65	98.50	99.16
		61 / 60		95.02	96.40	98.63
Proposed method		Set1 (30 / 30)	CNN	98.31	98.67	<b>99.64</b>
		Set2 (31 / 30)		<b>99.16</b>	<b>100.0</b>	99.16
		61 / 60		97.34	98.11	99.24

식별하였다. Table 4의 맨 마지막에 제시된 실험 결과는 감마 밴드 외에 베타, 알파, 세타 밴드를 결합한 4개의 밴드를 사용한 결과이다. KNN이나 Adaboost 분류기에 비하여 MLP나 CNN을 이용한 방식이 대체로 더 우수한 성능을 보였다. 그리고 기존 연구들 중에서 98.48%의 정확도를 보인 [13]의 연구가 가장 좋은 성능을 나타냈기 때문에 [13]에서 제시한 CNN 구조와 본 연구에서 제안한 CNN 구조가 성능에 어떤 차이를 보이는지 실험을 통해 비교하였다. ‘CNN of [13]’은 본 연구에서 제안한 4개 스펙트럼 밴드를 [13]에서 제시한 CNN 구조를 직접 구현하여 적용한 실험 결과이다. 본 연구에서 제안한 CNN 구조가 분할된 스펙트럼 밴드의 조합으로부터 ADHD를 식별하는데 더 효과적임을 확인할 수 있었다.

### 5. 결 론

아동의 ADHD 식별은 교사나 학부모와 같이 장기간 아동을 관찰할 수 있는 보호자가 작성한 설문을 토대로 전문의의 진단을 통해 이루어진다. 이 방식은 많은 시간과 경비가 소요되기 때문에 새로운 방안에 대한 수요가 상존해 왔다. 뇌전도(EEG)는 대뇌 피질의 시냅스 활성화에 의해 생성되는 전기적 신호를 두피 표면에서 측정된 데이터로, EEG 신호를 분석하여 ADHD 진단을 보조할 수 있는 새로운 방안이 관심이 집중되고 있다. 본 연구에서는 EEG 신호에서 ADHD를 식별하는데 효과적인 주파수 서브 밴드를 탐색하였고, 이들을 효과적으로 결합할 수 있는 CNN 분류

기를 제안하였다. EEG 신호는 특정 주파수 범위에 따라 델타, 세타, 알파, 베타, 감마 밴드로 나누어지는데, 문제 해결이나 기억 작업과 관련된 감마 밴드가 ADHD를 식별하는데 중요한 특징을 제공하는 것으로 확인되었다. 감마 밴드만으로도 제안한 CNN은 Set1, Set2에 대해 아동의 ADHD의 진단 정확도가 96.95%, 97.55% 였으며, 델타 밴드를 포함한 4개 밴드를 결합하여 98.31%, 99.16%의 정확도를 얻을 수 있었다. 본 연구에서 제안한 접근 방식은 ADHD뿐만 아니라 뇌전증이나 알코올 중독과 같은 다른 신경정신 장애의 진단에도 확장이 가능할 것으로 판단된다.

### REFERENCE

[1] M. L. Danielson R. H. Bitsko, R. M. Ghandour, J. R. Holbrook, M. D. Kogan, and S. J. Blumberg. “Prevalence of Parent-Reported ADHD Diagnosis and Associated Treatment Among U.S. Children and Adolescents,” *Journal of Clinical Child and Adolescent Psychology*, Vol. 47, No. 2, pp. 199-212, 2018.

[2] H. Oh and K. Kim, “Effect of Multi-Sensory Play Therapy Program on the Attention and Learning of Children with ADHD,” *Journal of the Korean Society of Integrative Medicine*, Vol. 7, No. 4, pp. 23-32, 2019.

[3] B. T. Felt, B. Biermann, J. G. Christner, P. Kochhar, and R. V. Harrison, “Diagnosis and



- Management of ADHD in Children,” *American Family Physician*, Vol. 90, No. 7, pp. 456–464, 2014.
- [4] S.D. Silva, S. Dayarathna, G. Ariyaratne, and D. Meedeniya, “A Survey of Attention Deficit Hyperactivity Disorder Identification Using Psychophysiological Data,” *International Journal of Online and Biomedical Engineering*, Vol. 15, No. 13, pp. 61–76, 2019.
- [5] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T.H. Falk, and J. Faubert, “Deep Learning-Based Electroencephalography Analysis: A Systematic Review,” *Journal of Neural Engineering*, Vol. 16, No. 5, pp. 1–37, 2019.
- [6] A. Allahverdy, A.K. Moghaddam, M.R. Mohammadi, and A.M. Nasrabadi, “Detecting ADHD Children using the Attention Continuity as Nonlinear Feature of EEG,” *Frontiers in Biomedical Technologies*, Vol. 3, No. 1–2, pp. 28–33, 2016.
- [7] M.R. Mohammadi, A. Khaleghi, A.M. Nasrabadi, S. Rafieivand, M. Begol, and H. Zarfshan, “EEG Classification of ADHD and Normal Children Using Non-linear Features and Neural Network,” *Biomedical Engineering Letter*, Vol. 6, pp. 66–73, 2016.
- [8] B. TaghiBeyglou, N. Hasanzadeh, and F. Bagheri, “ADHD Diagnosis in Children Using Common Spatial Pattern and Nonlinear Analysis of Filter Banked EEG,” *Proceedings of the Iranian Conference on Electrical Engineering*, pp. 1–5, 2020.
- [9] T. Aleksandar, M.S. Silvana, K. Ljupco, P.J. Jordan, M. Andreas, and C. Gian, “Machine Learning Approach for Classification of ADHD Adults,” *International Journal of Psychophysiology*, Vol. 93, pp. 162–166, 2014.
- [10] A.E. Alchalabi, M. Elsharnouby, S. Shirmohammaadi, and A.N. Eddin, “Feability of Detecting ADHD Patients’ Attention Levels by Classifying Their EEG Signals,” *Proceedings of the IEEE International Symposium on Medical Measurements and Applications*, pp. 314–319, 2017.
- [11] W. Mao, H.I.K. Fathurrahman, Y. Lee, and T.W. Chang, “EEG Dataset Classification Using CNN Method,” *Journal of Physics: Conference Series*, Vol. 1456, pp. 1–7, 2020.
- [12] P. Sandheep, S. Vineeth, P. Meljo, and D.P. Subha, “Performance Analysis of Deep Learning CNN in Classification of Depression EEG Signals,” *Proceedings of IEEE Region 10 Conference*, pp. 1339–1344, 2019.
- [13] M. Moghaddari, M.Z. Lighvan, and S. Danishvar, “Diagnose ADHD Disorder in Children Using Convolutional Neural Network Based on Continuous Mental Task EEG,” *Computer Methods and Programs in Biomedicine*, Vol. 197, pp. 1–12, 2020.
- [14] A. Vahid, A. Bluschke, V. Roessner, S. Stober, and C. Beste, “Deep Learning Based on Event-Related EEG Differentiates Children with ADHD from Healthy Controls,” *Journal of Clinical Medicine*, Vol. 8, No. 1055, pp. 1–15, 2019.
- [15] H. Chen, Y. Song, and X. Li, “A Deep Learning Framework for Identifying Children with ADHD Using an EEG-Based Brain Network,” *Neurocomputing*, Vol. 356, pp. 83–86, 2019.
- [16] EEG Data for ADHD/Control Children, Shahed University of Iran, <https://iee-dataport.org/open-access/eeg-data-adhd-control-children> (accessed October 1, 2012).
- [17] D.O. Bos, “EEG-based Emotion Recognition,” *The Influence of Visual and Auditory Stimuli*, Vol. 56, pp. 1–17, 2006.
- [18] Q. Wang, O. Sourina, and M.K. Nguyen, “EEG-based ‘Serious’ Games Design for Medical Applications,” *Proceedings of the International Conference on Cyberworlds*, pp. 270–276, 2010.
- [19] L. Breiman, “Random Forests,” *Machine Learning*, Vol. 45, pp. 5–32, 2001.
- [20] G. Joo, C. Park, and H. Im, “Performance

Evaluation of Machine Learning Optimizers,”  
*Journal of Institute of Korean Electrical and  
Electronics Engineers*, Vol. 24, No. 3, pp. 766-  
776, 2020.



김민기

1989년 2월 중앙대학교 전자계산  
학과 이학사

1994년 8월 중앙대학교 전자계산  
학과 이학석사

1998년 2월 중앙대학교 컴퓨터공  
학과 공학박사

1998년~1999년 KRIC 선임연구원

1999년~2000년 KERIS 책임연구원, 연구위원

2000년~2010년 경상대학교 컴퓨터교육과 부교수

2011년~현재 경상대학교 컴퓨터학과 교수

2013년~2014년 미국 University of Notre Dame 방문학자

2014년~현재 경상대학교 공학연구원(ERI) 자동화·컴  
퓨터연구센터 책임연구원

관심분야: 딥 러닝, 생체인식, 뇌파(EEG) 식별, 영상처리