

Band-Attention BFE-Net for Subject-Independent EEG Emotion Recognition

Yujin Ji*, Jungpyo Hong**

*Graduate Student, Dept. of Information and Communication Engineering, Changwon National University, Changwon, Korea

**Associate Professor, Dept. of Information and Communication Engineering, Changwon National University, Changwon, Korea

[Abstract]

Electroencephalogram (EEG) signals serve as a core input for brain-computer interface systems, and EEG-based emotion recognition has been widely studied. The Band Feature Extraction Network (BFE-Net) effectively extracts frequency band-specific features; however, it does not consider interactions between frequency bands. To address this limitation, this study proposes the Band-Attention BFE-Net (BA-BFE-Net), which incorporates a self-attention mechanism to explicitly learn dependencies among frequency bands. The proposed model captures non-linear relationships among five frequency bands and enables more effective feature fusion. Subject-independent experiments conducted on the SEED and SEED-IV datasets demonstrate that the proposed model improves classification performance by 1.19% and 2.04%, respectively, compared to the original BFE-Net.

▶ **Key words:** EEG-based emotion recognition, graph neural network, self-attention, BFE-Net, subject-independent

[요 약]

뇌전도는 뇌-컴퓨터 인터페이스의 핵심 입력으로, 이를 활용한 감정 인식 연구가 활발히 진행되고 있다. 기존 BFE-Net은 주파수 대역별 특징을 효과적으로 추출하지만, 대역 간 상호작용을 고려하지 못하는 한계를 가진다. 본 연구에서는 이러한 문제를 해결하기 위해 대역 간 의존성을 명시적으로 학습하는 자기 어텐션 메커니즘을 결합한 Band-Attention BFE-Net (BA-BFE-Net)을 제안한다. 제안한 모델은 다섯 개 주파수 대역 간 비선형적 관계를 효과적으로 학습하여 정교한 특징 융합을 수행한다. SEED 및 SEED-IV 데이터셋 기반 피험자 독립 실험에서 기존 BFE-Net 대비 각각 1.19%와 2.04%의 성능 향상을 달성하였다.

▶ **주제어:** 뇌전도 기반 감정 인식, 그래프 신경망, 자기 어텐션, BFE-Net, 피험자 독립

-
- First Author: Yujin Ji, Corresponding Author: Jungpyo Hong
 - *Yujin Ji (20193036@gs.cwnu.ac.kr), Dept. of Information and Communication Engineering, Changwon National University
 - **Jungpyo Hong (hansin@changwon.ac.kr), Dept. of Information and Communication Engineering, Changwon National University
 - Received: 2026. 01. 21, Revised: 2026. 02. 24, Accepted: 2026. 03. 09.

I. Introduction

감정은 인간의 인지 과정, 의사결정, 그리고 사회적 상호작용에서 중요한 역할을 한다. 인간의 감정 상태를 정확하게 인식하고 이에 적응적으로 반응할 수 있도록 하는 감정 인식은 뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI)와 스마트 헬스케어 시스템의 발전을 위한 핵심 기술로서 활발한 연구 분야로 자리 잡았다. 초기 연구들은 주로 얼굴 표정, 음성, 제스처와 같은 외부에서 관찰 가능한 비언어적 단서에 의존하였다. 그러나 이러한 신호들은 사용자의 의도에 따라 조작되거나 억제될 수 있다는 본질적인 한계를 가진다[1]. 반면, 뇌전도(Electroencephalogram, EEG)는 뇌의 전기적 활동을 직접적으로 반영하며 자발적인 제어가 어렵기 때문에, 사용자의 내적이고 진정한 감정 상태를 객관적으로 이해하는데 가장 신뢰할 수 있는 생리 신호로 간주된다[2].

초기 EEG 연구는 미분 엔트로피(differential entropy, DE)와 파워 스펙트럼 밀도(power spectral density, PSD)와 같은 수동 추출 특징에 주로 집중했다면[3], 2020년대 이후에는 딥러닝 모델이 비선형 EEG 패턴을 학습하는 데 핵심적인 역할을 수행하게 되었다[4]. 특히, 뇌 영역 간의 기능적 연결성을 모델링할 수 있는 그래프 신경망(Graph Neural Network, GNN)의 발전은 주목할 만하다[5]. 구체적으로, Song 등이 제안한 동적 그래프 컨볼루션 신경망(Dynamic Graph Convolutional Neural Network, DGCNN)[6]은 인접 행렬을 활용하여 채널 간의 동적 관계를 학습하는 기반을 마련하였으며, Zhong 등의 정규화 그래프 신경망(Regularized GNN, RGNN)[7]은 생물학적 위상 제약을 도입하여 일반화 성능을 향상시켰다. 또한, Li 등은 피험자 간의 개인차를 극복하기 위해 자기 조직화 그래프 신경망(Self-Organized GNN, SOGNN)[8]을 제안하였다.

최근에는 이러한 GNN 구조에 트랜스포머(Transformer)나 자기 지도 학습을 포함한 최신 기법을 통합하려는 시도가 이루어지고 있다. 구체적으로, Chen 등이 제안한 이중 어텐션 메커니즘 그래프 신경망(Dual Attention Mechanism Graph Convolutional Neural Network, DAMGCN)[9]은 뇌 영역 간의 공간적 의존성과 주파수 대역 간의 중요성을 동시에 학습하기 위해 이중 어텐션 메커니즘을 적용하였다. 또한, Lu 등의 양방향 비전 트랜스포머(Bi-branch Vision Transformer Network, Bi-ViTNet)[10]는 비전 트랜스포머를 EEG 분석에 적용한 모델로, 시공간 및 주파수 특징을 별도의 브랜치에서 추출

하고 융합하는 구조를 제안하였다. 최근에는 대역 특징 추출 네트워크(Band Feature Extraction Neural Network, BFE-Net)[11]가 다섯 개의 독립적인 주파수 대역($\delta, \theta, \alpha, \beta, \gamma$)에서 특징을 효과적으로 추출하는 방법 중 하나로 제안되었다. 그러나 이 모델은 각 대역에서 추출된 특징들을 결합할 때 단순 연결하는 방식에 의존하므로, 항상 최고의 성능을 보장할 수 없다[12]. 이는 모델의 표현력을 제한하는 요인이 된다.

이러한 한계를 근본적으로 해결하기 위해, 본 연구에서는 기존 BFE-Net에 대역 간 상호작용을 모델링하는 대역 어텐션 모듈을 결합한 Band-Attention BFE-Net (BA-BFE-Net)을 제안한다. 본 연구의 주요 기여는 다음과 같다.

1. 어텐션 기반 BFE-Net 대역 융합 구조 제안: 주파수 대역 간의 상호 의존성을 명시적으로 모델링하기 위해 단일 헤드 자기 어텐션(single-head self-attention) 모듈을 제안한다. 이를 통해 모델은 현재 감정 상태를 결정하는데 기여도가 높은 주파수 대역에 가중치를 적응적으로 할당한다.

2. 최신 기법 대비 우수한 성능 달성 및 검증: 벤치마크 데이터셋인 SEED[13] 및 SEED-IV를 사용한 피험자 독립 실험에서, 제안한 모델은 대역 간 의존성 학습을 통해 기존 GNN 모델들을 능가하는 우수한 성능을 달성하였다.

II. Related works

1. BFE-Net

BFE-Net[11]은 본 연구의 백본 모델로서 작동하며, 그래프 합성곱 신경망(Graph Convolutional Network, GCN)의 공간 특징 학습 능력과 주파수 대역별 특성을 결합한 구조를 가진다. 이 모델은 다섯 개의 주요 주파수 대역에서 추출된 DE를 핵심 특징으로 사용한다. DE는 신호의 복잡성과 에너지를 모두 나타내는 지표이다. 추출된 특징은 감정 상태의 시간적 연속성을 반영하기 위해 선형 동적 시스템(linear dynamical system, LDS) 스무딩을 거치며, 이를 통해 급격한 변동이 억제된 매끄러운 시계열 데이터로 변환된다. BFE-Net의 전반적인 구조는 Fig. 1과 같다. 정제된 특징들은 BFE-Net이라 불리는 독립적인 하위 네트워크를 통해 각 주파수 대역별로 처리된다. BFE-Net은 크게 세 단계로 구성된 계층적 특징 추출 과정을 거친다.

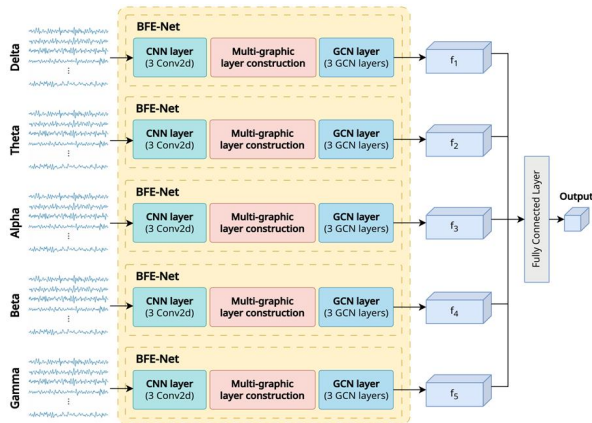


Fig. 1. Overview of BFE-Net model architecture

첫 번째 단계는 계층적 합성곱 신경망 (Convolutional Neural Network, CNN) 계층이다. BFE-Net은 CNN을 사용하여 각 EEG 채널 내의 시간적 흐름과 추상적 특징을 포착한다. 구체적으로, 커널 크기가 1×5 인 합성곱 계층과 최대 풀링(max pooling)을 포함하는 블록을 세 단계로 적층하여 구성하며, 이때 필터의 수는 64개에서 128개, 그리고 256개로 점차 증가한다. 이를 통해 모델은 얇은 계층에서는 국소적인 패턴을 학습하고, 깊은 계층에서는 고차원적인 의미 정보를 학습한다.

두 번째 단계는 자가 적응형 다중 그래프(self-adaptive multi-graphic) 계층이다. 기존 GNN 연구들이 피험자 간 편차를 고려하지 않은 채 고정된 거리 기반 인접 행렬을 사용한 것과 달리, BFE-Net은 데이터로부터 채널 간의 상관관계를 동적으로 학습하는 메커니즘을 사용하였다. 이를 위해 트랜스포머 인코더 구조가 사용된다. 먼저, 채널 간의 잠재적 연결 강도를 나타내는 어텐션 맵 A 를 계산하기 위해 다중 헤드 어텐션(multi-head attention)이 수행된다. 동시에, 인코딩된 특징의 자기 상관 행렬 S 를 산출하고 이를 A 와 결합하여 전역적 정보와 국소적 정보를 모두 포함하는 인접 행렬 $E = \text{softmax}(A + S)$ 를 생성한다. 이 과정에서 각 노드에 대해 연결 강도가 높은 상위 k 개의 간선만을 유지하는 top- k 희소화 전략이 적용되어 불필요한 연결은 제거하고 계산 효율성을 향상시킨다.

마지막 단계는 GCN을 통한 공간적 특징 집계이다. 앞선 단계에서 구성된 희소 인접 행렬 E 와 CNN을 통해 추출된 노드 특징을 결합하여 스펙트럼 GCN 연산을 수행한다. 이는 $H' = \sigma(\hat{D}^{-1/2} \hat{E} \hat{D}^{-1/2} X \Theta)$ 로 정의되며, 여기서 $\hat{E} = E + I$ 는 자기 연결(self-loop)을 포함한 인접 행렬이며, \hat{D} 는 차수 행렬(degree matrix), Θ 는 학습 가능한

가중치 행렬을 나타낸다. 또한 $\sigma(\cdot)$ 는 비선형 활성화 함수이다. 이 과정을 통해 BFE-Net은 뇌 영역 간의 복잡한 연결성을 반영하는 공간적 특징을 효과적으로 학습한다.

이와 함께 EEG 기반 감정 인식 연구에서는 그래프 신경망을 활용하여 뇌 영역 간의 공간적 관계를 모델링하려는 다양한 연구들이 수행되어 왔다. 예를 들어 DGCNN, RGNN, SOGNN과 같은 모델들은 EEG 채널 간의 관계를 그래프 구조로 표현하여 감정 상태를 분류하는 방법을 제안하였다. 이러한 연구들은 EEG 신호의 공간적 의존성을 효과적으로 반영할 수 있다는 장점을 가지지만, 주파수 대역 간의 상호작용을 명시적으로 모델링하는 데에는 한계가 있다. 따라서 본 연구에서는 BFE-Net 구조를 기반으로 주파수 대역 간 상호작용을 학습할 수 있는 어텐션 기반 대역 특징 융합 구조를 제안한다.

III. Proposed Methods

본 장에서는 본 연구에서 제안하는 피험자 독립 감정 인식 프레임워크인 BA-BFE-Net에 대해 자세히 설명한다. 제안된 방법은 감정 인식 성능을 향상시키기 위해 주파수 대역 간 상호 의존성을 학습하는 대역별 자기 어텐션 기반 특징 융합 및 분류 모듈에 집중한다.

1. Self Attention-based Band Aggregation

기존 BFE-Net은 각 주파수 대역에서 추출된 특징을 단순히 연결하여 분류기에 입력한다. 그러나 이 방식은 주파수 대역 간의 비선형적 상호 의존성을 고려하지 못하며, 모든 대역을 서로 독립적인 정보로 취급한다는 한계가 있다. 이를 해결하기 위해, 대역 간의 관계를 학습하기 위한 대역별 쿼리-키-값(query-key-value) 자기 어텐션 메커니즘을 도입하고 이를 반영하여 정제된 특징을 융합하는 모듈을 제안한다. 제안하는 대역별 어텐션 모듈의 전체 구조는 Fig. 2와 같다. 특히, 제한된 EEG 데이터셋에서의 과적합을 방지하고 계산 효율성을 향상시키기 위해, 복잡한 다중 헤드 구조 대신 단일 헤드 구조를 채택하여 모델을 설계하였다. 이는 파라미터 수의 증가를 최소화하면서도 다섯 개 주파수 대역 간의 핵심적인 상호작용을 포착하기에 충분하다.

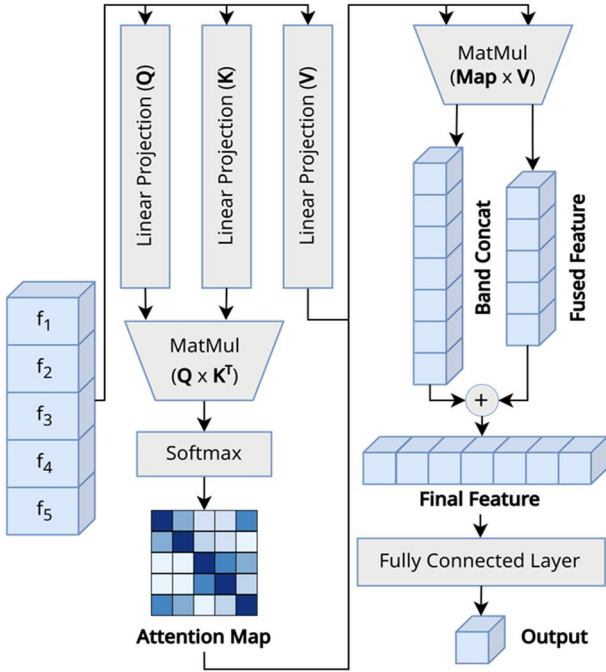


Fig. 2. Overview of the proposed attention-based BFE-Net band aggregation process

1.1 Input Embedding & Projection

BFE-Net으로부터 추출된 주파수 대역별 특징 벡터를 쌓아서 입력 행렬 $X \in \mathbb{R}^{N_b \times D}$ 를 구성한다. 여기서 N_b 는 주파수 대역의 개수를 나타내며, D 는 특징 차원으로 각 대역에 대응되는 채널 수를 의미한다. 이 입력은 학습 가능한 가중치 행렬 W_Q , $W_K \in \mathbb{R}^{D \times d_k}$ 및 $W_V \in \mathbb{R}^{D \times d_v}$ 를 사용하여 쿼리, 키, 값 공간으로 투영된다. 여기서 d_k 와 d_v 는 각각 키와 값의 차원을 의미한다. 이러한 투영 과정은 Eq. (1)과 같다.

$$Q = XW_Q, K = XW_K, V = XW_V \quad (1)$$

여기서 Q , K , V 는 어텐션 점수를 계산하는 데 사용되는 입력 특징의 선형 변환인 쿼리, 키, 값 행렬을 나타낸다.

1.2 Inter-Band Attention Map

각 주파수 대역 간의 상관관계를 측정하기 위해 스케일드 점곱 어텐션(scaled dot-product attention)이 수행된다. 생성된 어텐션 맵 $A \in \mathbb{R}^{N_b \times N_b}$ 은 Eq. (2)와 같이 정의된다.

$$A = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) \quad (2)$$

여기서 각 요소 A_{ij} 는 i 번째 대역과 j 번째 대역 간의 상관관계 강도를 나타내며, $\sqrt{d_k}$ 는 어텐션 점수의 스케일

링을 위한 계수이다. 이 과정을 통해 모델은 특정 대역의 정보를 처리할 때 다른 대역의 정보를 어느 정도 참조해야 하는지를 스스로 학습한다.

1.3 Feature Refinement & Fusion

계산된 어텐션 맵 A 를 값 행렬 V 에 적용하여 대역 간의 상호작용이 반영된 새로운 특징 행렬 X' 을 얻는다. 이후 선형 투영을 통해 차원을 복원한다.

$$X' = \text{Linear}(AV) \quad (3)$$

마지막으로, 종합적인 특징 표현 Z_{final} 을 구성하기 위해 국소적 특징과 전역적 특징을 함께 결합한다. 구체적으로, 세부 정보를 보존하기 위해 대역별 특징을 평탄화한 벡터 F_{concat} 을 생성하고, 전체적인 스펙트럼 문맥을 요약하기 위해 평균 풀링을 통해 전역 특징 벡터 F_{global} 을 계산한다. 최종 특징 표현은 두 벡터를 연결하여 형성된다.

$$F_{concat} = \text{Flatten}(X') \in \mathbb{R}^{(N_b \times 1) \times D} \quad (4)$$

$$F_{global} = \frac{1}{N_b} \sum_{i=1}^{N_b} X'_i \in \mathbb{R}^D \quad (5)$$

$$Z_{final} = [F_{concat}; F_{global}] \in \mathbb{R}^{(N_b + 1) \times D} \quad (6)$$

본 연구에서 생성된 Z_{final} 은 최종 감정 분류기의 입력으로 사용되며, 대역별 세부 정보와 대역 간의 유기적인 결합 정보를 동시에 활용할 수 있도록 설계하였다. Fig. 2에서 F_{concat} 은 Band Concat에 해당하고, F_{global} 은 대역 정보를 통합한 Fused Feature를 의미한다. 또한 두 특징을 결합한 Z_{final} 은 Fig. 2의 Final Feature에 해당하며 이후 완전연결층을 통해 감정 분류가 수행된다.

IV. Experiments

본 장에서는 제안하는 BA-BFE-Net의 성능을 검증하기 위해 수행한 실험과 그 결과를 제시한다. 실험은 감정 인식 분야에서 대표적인 데이터셋인 SEED와 SEED-IV 데이터셋을 사용하여 수행되었다. 피험자 독립 프로토콜을 기반으로 기존 최신 연구들과 비교하여 성능을 분석하였다.

1. Datasets

감정 인식 분야에서 널리 사용되는 두 개의 공개 데이터셋인 SEED(SJTU Emotion EEG Dataset)와 SEED-IV를 사용하였다. 두 데이터셋은 상하이 자오퉁 대학교

(Shanghai Jiao Tong University, SJTU)에서 구축되었으며, 웹사이트(<https://bcmi.sjtu.edu.cn/home/seed>)를 통해 제공된다.

SEED 데이터셋은 총 15명의 피험자(남성 7명, 여성 8명, 평균 23.27세)를 대상으로 수집되었으며, 긍정(positive), 중립(neutral), 부정(negative)의 세 가지 감정 상태를 유발하는 15개의 영화 클립을 시청하도록 구성되어 있다. 각 피험자는 약 1주 간격으로 총 3회의 세션에 참가하여 시간적 안정성을 갖는 데이터를 제공하였다. 각 감정 상태마다 5개의 클립이 할당되었으며, 하나의 클립 길이는 약 4분이다. 실험 프로토콜은 시작 신호(start hint, 5초), 영상 시청(약 4분), 자기 평가(self-assessment, 45초), 휴식(rest, 15초)으로 구성된다. 피험자의 피로도를 고려하여 동일한 감정이 연속적으로 나타나지 않도록 클립 순서를 배치하였다. 데이터는 국제 10-20 시스템에 따라 전극이 배치된 62채널 ESI NeuroScan 시스템을 이용하여 수집되었으며, 200Hz로 다운샘플링한 후 1-75Hz 대역통과 필터를 적용하였다.

SEED-IV 데이터셋은 보다 세분화된 감정 인식을 목표로 구축되었으며, 중립(neutral), 슬픔(sad), 공포(fear), 행복(happy)의 네 가지 감정 상태를 포함한다. SEED와 유사한 인구통계학적 특성을 가진 15명의 피험자가 참여하였으며, 서로 다른 날짜에 총 3회의 세션이 수행되었다. 전체적으로 72개의 영화 클립이 사용되었고, 각 세션마다 감정별로 6개씩 총 24개의 클립을 시청하도록 설계되었다. 각 영상의 길이는 약 2분으로 SEED보다 짧지만, 기존의 '부정' 감정을 '공포'와 '슬픔'으로 세분화함에 따라 분류 난이도는 더 높다. 데이터 수집 및 전처리 과정은 SEED와 동일하게 적용되었다. 본 연구에서 사용한 SEED와 SEED-IV 데이터셋의 주요 구성 정보를 Table 1에 요약하였다.

2. Implementation Details

모델의 입력 데이터는 $(N, 62, T, 5)$ 형태의 4차원 텐서로 구성된다. 기존 연구와 공정하게 비교하기 위해 각 주파수 대역의 특징으로는 SEED 및 SEED-IV 데이터셋에서 제공되는 Differential Entropy(DE) 특징을 사용하였

다. 여기서 N 은 전체 샘플(Trial)의 개수를 의미하며, SEED 데이터셋의 경우 총 675개(15명 피험자 \times 3 세션 \times 15 Trial), SEED-IV 데이터셋의 경우 총 1080개(15명 피험자 \times 3 세션 \times 24 Trial)로 구성된다. 62는 EEG 채널 개수를 나타내며, 5는 주파수 대역($\delta, \theta, \alpha, \beta, \gamma$)의 개수를 의미한다. 예를 들어, SEED 데이터셋에서 하나의 샘플은 (62, 265, 5)의 형태로 표현되며, 이는 62개의 EEG 채널, 265 길이의 시간 축, 그리고 다섯 개 주파수 대역으로 구성된 특징을 의미한다. 시간 차원 T 의 경우, SEED 데이터셋은 185에서 265까지 다양하고, SEED-IV 데이터셋은 12에서 64까지 다양하다. 따라서 서로 다른 Trial 길이를 통일하기 위해 제로 패딩을 적용하였으며, SEED 데이터셋은 265 포인트, SEED-IV 데이터셋은 64 포인트로 고정하였다.

본 연구에서 사용한 모든 모델은 PyTorch 프레임워크를 기반으로 구현하였으며, NVIDIA RTX A6000 GPU 환경에서 학습을 수행하였다. 최적화 알고리즘으로는 Adam 옵티마이저를 사용하였고, 학습률은 0.001, 배치 크기는 64, 전체 학습 에폭 수는 200으로 설정하였다. 손실 함수로는 교차 엔트로피(cross-entropy) 손실을 사용하였으며, 과적합을 방지하기 위해 드롭아웃(dropout) 비율을 0.1로 설정하였다. 또한 모델의 일반화 성능을 검증하기 위해 leave-one-subject-out(LOSO) 교차 검증을 수행하였다. 즉, 전체 15명의 피험자 중 1명의 데이터를 테스트 세트로 사용하고, 나머지 14명의 데이터를 학습 세트로 사용하는 과정을 반복하여 성능을 평가하였다.

3. Experimental Results

3.1 Comparison with State-of-the-Art Models

제안한 BA-BFE-Net의 유효성을 검증하기 위해, SEED 및 SEED-IV 데이터셋을 사용한 감정 인식 모델들과의 성능 비교를 수행하였다. 비교 모델로는 전통적인 머신러닝 기법인 SVM[7]과 DAMGCN[9], DGCNN[5], RGCNN[6], TANN[14], BiHDM[15], SOGNN[8], 그리고 본 연구의 기반 모델인 BFE-Net[11]을 포함하였다. 모든 비교 실험은 동일한 데이터 분할 방식(LOSO)에서 수행되었다.

SEED 데이터셋 실험 결과, 제안한 모델은 평균

Table 1. Summary of SEED and SEED-IV datasets used in this study

Dataset	Subjects	Sessions	Clips per Session	Total Trials	Emotion Classes	Channels	Sampling Rate
SEED	15	3	15	675	Positive, Neutral, Negative	62	200
SEED-IV	15	3	24	1080	Neutral, Sad, Fear, Happy	62	200

93.48%(±3.19%)를 달성하여 모든 비교 모델보다 높은 성능을 보였다. 특히 전통적인 SVM(56.73%) 대비 큰 폭의 성능 향상을 보였으며, SOGNN(86.81%) 대비 6.67%, 기존 SOTA 모델인 BFE-Net(92.29%) 대비 1.19%의 성능 향상을 기록하였다.

분류 난이도가 더 높은 네 가지 감정 상태를 포함하는 SEED-IV 데이터셋에서도 제안한 모델은 평균 정확도 81.85%(±4.74%)로 모든 비교 모델 중 가장 높은 성능을 달성하였다. SVM(37.79%)과 비교하여 큰 성능 격차를 보였으며, 다른 딥러닝 기반 모델들에 비해서도 일관되게 우수한 성능을 나타냈다. 특히 기반 모델인 BFE-Net(79.81%) 대비 2.04%의 성능 향상을 달성하였다. 이러한 결과는 제안한 대역 어텐션 기반 특징 융합 메커니즘이 주파수 대역 간 상호 의존성을 효과적으로 학습함으로써 감정 인식 성능 향상에 실질적으로 기여함을 시사한다. 각 모델별 상세 비교는 Table 2에 나타내었다.

Table 2. Comparison of average accuracy and standard deviation by model for SEED and SEED-IV datasets

Model	SEED	SEED-IV
SVM	56.73%(±16.29%)	37.79%(±12.52%)
DAMGCN	73.21%(±8.35%)	68.22%(±7.03%)
DGCNN	79.95%(±9.02%)	-
RGNN	85.30%(±6.72%)	73.84%(±8.02%)
TANN	84.41%(±8.75%)	68.00%(±8.35%)
BiHDM	85.40%(±7.53%)	69.03%(±8.66%)
SOGNN	86.81%(±5.79%)	75.27%(±8.19%)
BFE-Net	92.29%(±4.65%)	79.81%(±4.11%)
BA-BFE-Net (Ours)	93.48%(±3.19%)	81.85%(±4.74%)

3.2 Ablation Study

제안한 어텐션 기반 대역 특징 융합 구조의 효과를 검증하기 위해 ablation study를 수행하였다. 비교의 공정성을 확보하기 위해 기존 BFE-Net의 논문 보고 성과와 함께, 동일한 실험 환경에서 재구현한 BFE-Net의 성능을 함께 제시하였다. 추가로 다중 헤드 자기 어텐션 구조와 본 연구에서 제안한 단일 헤드 자기 어텐션 구조를 비교하였다. 비교 결과는 Table 3에 나타내었다.

Table 3. Ablation study of the proposed self-attention-based band fusion module

Method	SEED	SEED-IV
BFE-Net (paper reported)	92.29%(±4.65%)	79.81%(±4.11%)
BFE-Net (reproduced)	92.59%(±5.05%)	80.65%(±2.46%)
Multi-Head Self-Attention	92.74%(±4.83%)	81.30%(±4.18%)
Single-Head Self-Attention (proposed)	93.48%(±3.19%)	81.85%(±4.74%)

실험 결과, 동일한 실험 환경에서 재현한 BFE-Net 대비 어텐션 기반 구조가 두 데이터셋 모두에서 더 높은 정확도를 보였다. 특히 제안한 단일 헤드 자기 어텐션 구조는 SEED 데이터셋에서 93.48%, SEED-IV 데이터셋에서 81.85%를 기록하여 가장 우수한 성능을 나타냈다. 또한 다중 헤드 자기 어텐션 구조보다 단일 헤드 구조가 더 높은 성능을 보였는데, 이는 본 연구에서 사용한 입력 시퀀스가 다섯 개의 주파수 대역으로 비교적 짧기 때문이다. 일반적으로 다중 헤드 어텐션은 긴 시퀀스에서 다양한 표현 공간을 동시에 학습하는 데 효과적이지만, 본 연구와 같이 시퀀스 길이가 제한적인 경우에는 이러한 이점이 충분히 나타나지 않을 수 있다. 또한 62차원 특징 벡터가 여러 헤드로 분할될 경우 각 헤드에서 처리되는 특징 차원이 감소하게 되어 원래 특징이 갖고 있는 정보를 충분히 표현하지 못할 가능성이 있다. 이러한 이유로 제한된 대역 수를 갖는 EEG 특징 표현에서는 단일 헤드 구조가 보다 안정적인 특징 표현 학습에 적합한 것으로 해석된다.

3.3 Model Complexity Analysis

제안한 BA-BFE-Net 모델의 계산 복잡도를 분석하기 위해 기존 BFE-Net과 파라미터 수를 비교하였다. 비교 결과는 Table 4에 나타내었다. BA-BFE-Net은 기존 BFE-Net 구조에 주파수 대역 간 관계를 학습하기 위한 어텐션 모듈이 추가된 구조이지만, 전체 파라미터 수는 3,856,763개에서 3,868,793개로 약 0.31%만 증가하였다. 이는 어텐션 연산이 다섯 개의 주파수 대역을 대상으로 수행되기 때문에 추가되는 파라미터 수가 매우 제한적이기 때문이다. 따라서 제안한 BA-BFE-Net은 기존 모델 대비 작은 파라미터 증가만으로도 유의미한 성능 향상을 달성할 수 있음을 확인하였다.

Table 4. Model complexity comparison

Model	Parameters	Increase
BFE-Net	3,856,763	-
BA-BFE-Net	3,868,793	+12,030 (0.31%)

3.4 Band Attention Map Visualization and Analysis

단일 헤드 자기 어텐션 메커니즘이 각 주파수 대역 간의 상호작용을 어떻게 학습하였는지를 분석하기 위해 학습된 모델의 어텐션 가중치를 히트맵 형태로 시각화하였다. Fig. 3(a)와 Fig. 3(b)는 각각 SEED와 SEED-IV 데이터셋에서 한 피험자를 예시로 감정별 평균 어텐션 맵을 나타내었다. 여기서 x축은 정보 제공 대역(source band, key)을, y축은 정보 수신 대역(target band, query)을 의미한다.

먼저 SEED 데이터셋의 경우 여러 감정 상태에서 alpha 및 gamma 대역이 상대적으로 높은 참조 패턴을 보이는 경향이 나타났다. 이는 감정 상태를 구분하는 과정에서 해당 대역의 정보가 중요한 역할을 할 수 있음을 시사한다. 또한 일부 감정 상태에서는 delta 또는 beta 대역이 다른 대역의 정보를 참조하는 패턴도 관찰되었다. SEED-IV 데이터셋에서도 감정 상태에 따라 서로 다른 대역 간 참조 패턴이 나타났다. 예를 들어 슬픔 상태에서는 beta 대역이 비교적 높은 비율로 참조되는 경향이 나타났으며, 공포 상태에서는 delta 대역의 자기참조 경향이 관찰되었다. 또한 중립 상태에서는 alpha 대역의 자기참조가 상대적으로 높게 나타났다. 이러한 결과는 제안한 대역별 어텐션 모듈이 감정 상태에 따라 서로 다른 주파수 대역 간 상호작용을 학습하고 있음을 보여주며, 대역 간 의존성을 효과적으로 반영할 수 있음을 시사한다.

3.5 Confusion Matrix Analysis

마지막으로 혼동 행렬 분석을 수행하였다. 그림 Fig. 4(a)와 Fig. 4(b)는 각각 SEED 및 SEED-IV 데이터셋에 대한 제안 모델의 혼동 행렬을 나타낸다. 두 데이터셋 모두에서 대각선 성분의 값이 비대각선 성분에 비해 상대적으로 높은 값을 보여, 전반적으로 높은 분류 성능을 확인하였다. 특히 SEED-IV에서는 중립과 공포 클래스 간 오분류가 상대적으로 크게 나타났으며, 이는 두 상태에서의 감정 상태에서 나타나는 생리학적 패턴의 유사성에 기인한 것으로 해석할 수 있다. 그림에도 불구하고, 전체적으로는 제안한 모델이 어텐션 메커니즘을 통해 이러한 모호성을 완화함을 확인하였다.

V. Conclusions

본 연구에서는 EEG 기반 감정 인식의 정확도를 향상시키기 위해, 주파수 간 상호작용을 학습하는 BA-BFE-Net 프레임워크를 제안하였다. 제안한 모델은 기존 BFE-Net 구조를 기반으로, 단일 헤드 자기 어텐션 메커니즘을 도입하여 다섯 개 주파수 대역 간의 의존성을 모델링함으로써 감정 상태에 따른 생리학적 특성을 반영하도록 설계되었다. 실험 결과, 제안한 모델은 SEED 및 SEED-IV 데이터셋에서 기존 최신 모델들보다 높은 성능을 보였다. 특히

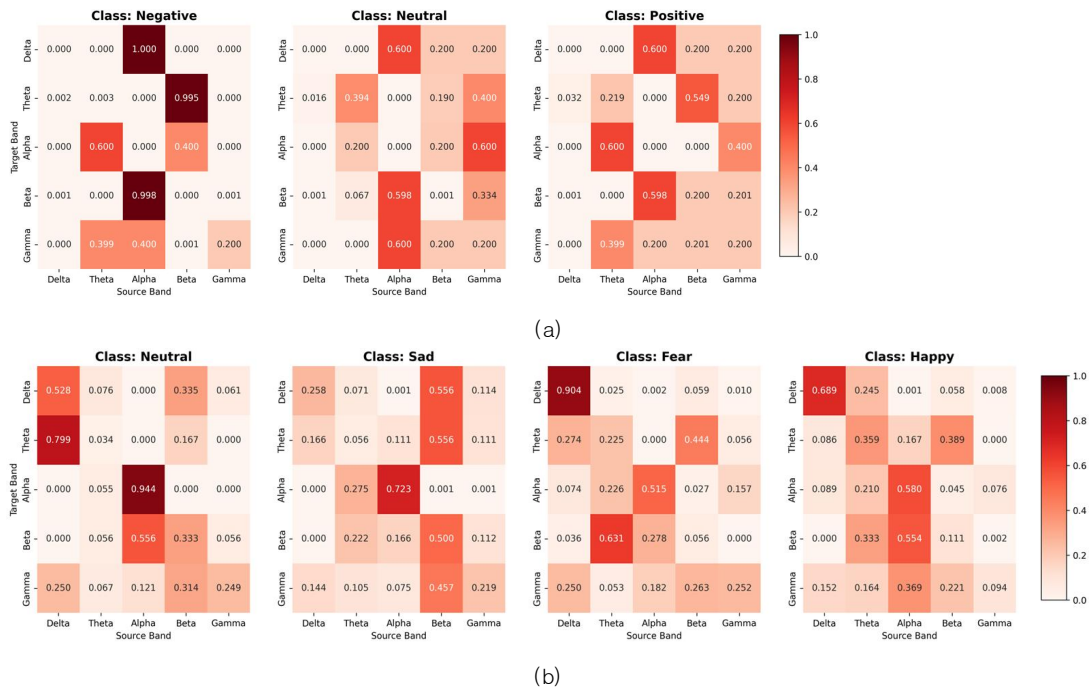


Fig. 3. Visualization of Band Attention Map by Emotion. (a) SEED and (b) SEED-IV datasets. (Heatmap values indicate the weight contributed by the Source Band to the Target Band)




Fig. 4. Confusion Matrix for (a) SEED and (b) SEED-IV datasets

대역별 어텐션 맵 분석을 통해 감정 클래스에 따라 대역 특징 간 참조 및 결합 패턴이 상이하게 형성됨을 확인하였다. 또한 혼동 행렬 분석을 통해 모든 감정 클래스에 대해 균형 잡힌 분류 성능을 보임을 검증하였다. 이러한 결과는 제안한 방법이 피험자 독립 환경에서도 높은 일반화 성능과 신뢰성을 가질 수 있음을 시사한다. 한편, 본 연구에서는 EEG 기반 감정 인식에서 널리 사용되는 DE를 특징으로 활용하였으며, 이는 EEG 신호의 비선형적 특성을 반영할 수 있다는 장점을 가진다. 향후 연구에서는 신호의 동적 특성을 보다 정밀하게 반영할 수 있는 동적 미분 엔트로피(dynamic differential entropy)를 포함한 다양한 특징 추출 기법을 추가적으로 적용하고 비교 분석함으로써 인식 성능을 더욱 향상시킬 수 있을 것으로 기대된다.

ACKNOWLEDGEMENT

This research was supported by Changwon National University in 2025~2026.

REFERENCES

- [1] Hutchison, Ashley, and Larry Gerstein, "Emotion recognition, emotion expression, and cultural display rules: Implications for counseling," *Journal of Asia Pacific Counseling*, Vol. 7, No. 1, pp. 19-35, 2017. DOI: 10.18401/2017.7.1.3.
- [2] Lin, Wenqian, and Chao Li, "Review of studies on emotion recognition and judgment based on physiological signals," *Applied Sciences*, Vol. 13, No. 4, Feb. 2023. DOI: 10.3390/app13042573
- [3] Duan, Ruo-Nan, Jia-Yi Zhu, and Bao-Liang Lu, "Differential entropy feature for EEG-based emotion classification," *Proceedings of the 6th International IEEE/EMBS Conference on Neural Engineering (NER)*, pp. 81-84, San Diego, CA, USA, March 2013. DOI: 10.1109/NER.2013.6695876.
- [4] Sharma, Ramnivas, and Hemant Kumar Meena, "Emerging trends in EEG signal processing: A systematic review," *SN Computer Science*, vol. 5, no. 4, Article no. 415, 2024. DOI: 10.1007/s42979-024-02773-w.
- [5] Bessadok, Alaa, Mohamed Ali Mahjoub, and Islem Rekik, "Graph neural networks in network neuroscience," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 5, pp. 5833-5848, May 2023. DOI: 10.1109/TPAMI.2022.3209686.
- [6] Song, Tengfei, et al., "EEG emotion recognition using dynamical graph convolutional neural networks," *IEEE Transactions on Affective Computing*, vol. 11, no. 3, pp. 532-541, July 2020. DOI: 10.1109/TAFFC.2018.2817622.
- [7] Zhong, Peixiang, Di Wang, and Chunyan Miao, "EEG-based emotion recognition using regularized graph neural networks," *IEEE Transactions on Affective Computing*, vol. 13, no. 3, pp. 1290-1301, July 2022. DOI: 10.1109/TAFFC.2020.2994159.
- [8] Li, Jingcong, et al., "Cross-subject EEG emotion recognition with self-organized graph neural network," *Frontiers in Neuroscience*, vol. 15, Article no. 611653, January 2021. DOI: 10.3389/fnins.2021.611653.
- [9] Chen, Wei, et al., "EEG-based emotion recognition using graph convolutional neural network with dual attention mechanism," *Frontiers in Computational Neuroscience*, vol. 18, Article no. 1416494, 2024. DOI: 10.3389/fncom.2024.1416494.
- [10] Lu, Wei, Tien-Ping Tan, and Hua Ma, "Bi-branch vision transformer network for EEG emotion recognition," *IEEE Access*, vol. 11, pp. 36233-36243, April 2023. DOI: 10.1109/ACCESS.2023.3266117.

- [11] Zhang, Jinhao, et al., "Subject-independent emotion recognition based on EEG frequency band features and self-adaptive graph construction," *Brain Sciences*, vol. 14, no. 3, Article no. 271, March 2024. DOI: 10.3390/brainsci14030271.
- [12] Shen, Fangyao, et al., "Multi-scale frequency bands ensemble learning for EEG-based emotion recognition," *Sensors*, vol. 21, no. 4, Article no. 1262, February 2021. DOI: 10.3390/s21041262.
- [13] Zheng, Wei-Long, and Bao-Liang Lu, "Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks," *IEEE Transactions on Autonomous Mental Development*, vol. 7, no. 3, pp. 162–175, September 2015. DOI: 10.1109/TAMD.2015.2431497.
- [14] Li, Yang, et al., "A novel transferability attention neural network model for EEG emotion recognition," *Neurocomputing*, vol. 447, pp. 92–101, 2021. DOI: 10.1016/j.neucom.2021.02.048.
- [15] Li, Yang, et al., "A novel bi-hemispheric discrepancy model for EEG emotion recognition," *IEEE Transactions on Cognitive and Developmental Systems*, vol. 13, no. 2, pp. 354–367, June 2021. DOI: 10.1109/TCDS.2020.2999337.

Authors



Yujin Ji received the B.S. and M.S. degrees in Information and Communication Engineering from Changwon National University, Korea, in 2023 and 2026, respectively.

Her research interests include brain-computer interfaces, biosignal processing, and machine learning.



Jungpyo Hong received Ph.D. degree in the School of Electrical Engineering from the Korea Advanced Institute of Science and Technology, Korea, in 2016. He is currently an Associate Professor of the Department of

Information and Communication Engineering at Changwon National University. His research interests include noise reduction, array signal processing, and artificial intelligence.