

EEG Super-Resolution in PSD Feature Space: Bridging Wearable and Clinical-Grade Emotion Recognition

Duyong Baek*, Seok-Won Lee**

*Student, Graduate School of Information, Communication and Technology, Ajou University, Suwon, Korea

**Professor, Dept. of Software and Computer Engineering, Dept. of Artificial Intelligence, Ajou University, Suwon, Korea

[Abstract]

High-density electroencephalography (EEG) systems provide superior spatial resolution for emotion recognition, but their high cost, complexity, and user discomfort make them impractical for real-world applications. This study presents a practical alternative: an EEG super-resolution paradigm operating in the Power Spectral Density (PSD) feature space rather than the raw signal domain. The proposed Transformer-based architecture reconstructs 62-channel high-density PSD features from sparse inputs of 8, 14, 16, and 32 channels through a subject-independent reconstruction model. Evaluated on the SEED-IV dataset, the proposed method achieves an average Accuracy Preservation Ratio (APR) of 78.45% with 32 channels and 77.92% with 16 channels (Uniform strategy), reaching up to 97.56%. The Uniform channel selection strategy significantly outperforms both Clinical Standard and Hardware Realistic strategies (paired t-test, $p < 0.01$, Bonferroni-corrected). These results demonstrate that low-channel wearable EEG can achieve emotion recognition performance comparable to clinical-grade systems without subject-specific high-density data collection.

▶ **Key words:** EEG Super-resolution, Emotion Recognition, Power Spectral Density, Transformer, Wearable EEG, Subject-independent Reconstruction

[요약]

고밀도 뇌전도(EEG) 시스템은 감정 인식을 위한 우수한 공간 해상도를 제공하지만, 높은 비용·복잡성·불편함으로 인해 실제 응용에는 적합하지 않다. 본 연구는 원시 신호 영역이 아닌 전력 스펙트럼 밀도(PSD) 특징 공간에서 작동하는 EEG 초해상도 패러다임으로 실용적 대안을 제시한다. 제안된 Transformer 기반 아키텍처는 피험자 독립적 복원 모델을 통해 8, 14, 16, 32 채널 희소 입력으로부터 62채널 고밀도 PSD 특징을 복원한다. SEED-IV 데이터셋에서 Uniform 전략 기준 32채널 78.45%, 16채널 77.92%의 정확도 보존율을 달성하였으며, 최고 97.56%까지 보존되었다. Uniform 채널 선택 전략은 Clinical Standard 및 Hardware Realistic 전략 대비 통계적으로 유의미하게 우수하였다(paired t-test, $p < 0.01$, Bonferroni 보정). 이는 저채널 웨어러블 EEG로도 피험자별 고채널 데이터 수집 없이 임상 수준에 준하는 감정 인식이 가능함을 보여준다.

▶ **주제어:** EEG 초해상도, 감정 인식, Power Spectral Density, Transformer, 웨어러블 EEG, 피험자 독립적 복원

- First Author: Duyong Baek, Corresponding Author: Seok-Won Lee
- *Duyong Baek (dybaek@ajou.ac.kr), Graduate School of Information, Communication and Technology, Ajou University
- **Seok-Won Lee (leesw@ajou.ac.kr), Dept. of Software and Computer Engineering, Dept. of Artificial Intelligence, Ajou University
- Received: 2026. 03. 26, Revised: 2026. 04. 27, Accepted: 2026. 05. 11.

I. Introduction

1. Background and Motivation

뇌파(Electroencephalogram, EEG)는 뇌의 전기적 활동을 비침습적으로 측정하는 기술로서, 정신 건강 모니터링, 뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI), 그리고 감정 인식 등 다양한 분야에서 활용되고 있다. 특히 감정 인식 연구 분야에서 EEG는 주관적 자기 보고나 얼굴 표정 분석과 같은 전통적 방법보다 더욱 객관적이고 신뢰할 수 있는 생리학적 지표를 제공한다는 점에서 주목받고 있다[1][2].

뇌 활동 측정 기술은 크게 뇌피질전도(Electrocorticography, ECoG), 뇌자도(Magnetoencephalography, MEG), 뇌전도(EEG), 그리고 기능자기공명영상법(functional Magnetic Resonance Imaging, fMRI)으로 분류된다. 이 중에서 EEG는 fMRI나 MEG와 같은 다른 뇌 활동 측정 기술 대비 비침습적이고 상대적으로 저렴하면서도 높은 시간 해상도를 제공하기 때문에 가장 대중적으로 활용되고 있다. 다만 EEG 시스템 내에서도 채널 수에 따라 비용·복잡도 차이가 크며, 본 연구는 그중 고밀도 시스템의 한계를 다룬다.

대표적인 감정 인식 벤치마크 데이터셋들은 각기 다른 채널 구성을 사용하고 있다. DEAP 데이터셋[1]은 32개 채널을 사용하여 음악과 비디오 자극에 대한 각성도(arousal)와 유의성(valence) 차원의 감정을 평가한다. SEED 데이터셋[3]은 62개 채널을 활용하여 영화 클립을 통한 긍정, 부정, 중립의 세 가지 감정 상태를 수집한다. DREAMER 데이터셋[4]은 상대적으로 적은 14개 채널을 사용하면서도 무선 저비용 장치의 실용성을 입증하였다.

고채널 EEG 시스템은 풍부한 공간 정보를 통해 뇌파 신호의 미세한 차이를 감지할 수 있어 감정 상태 간의 세밀한 구분을 가능하게 한다. 그러나 이러한 시스템은 일상생활에서 사용하기 어렵다는 근본적인 한계를 지니고 있다.

2. Problem Statement and Significance of the Study

현재 EEG 기반 감정 인식 연구가 직면한 주요 문제는 연구 환경과 실제 응용 환경 간의 괴리이다. 32채널 이상의 EEG 시스템은 수천만 원대의 고가 장비로서 일반 소비자나 소규모 의료기관이 접근하기 어렵다. 실험실 환경에서만 사용 가능하며, 전문 인력의 전극 부착과 세팅이 필요하다. 다수의 전극 부착으로 인한 물리적 불편함과 30분 이상 소요되는 긴 준비 시간은 장기간 모니터링을 어렵게

만든다. 게다가 피험자의 움직임, 집중력 저하, 전극 접촉 불량, 주변 전자기 간섭 등으로 인한 신호 누락 및 왜곡 가능성이 항상 존재한다.

반면, 휴대 가능한 저채널 EEG 기기(예: Emotiv EPOC X, Muse, NeuroSky)는 웨어러블 형태로 일상적 감정 모니터링이 가능하고 가격도 수십만 원대로 상대적으로 저렴하다. 그러나 제한된 채널 수로 인한 공간 정보 부족으로 고채널 EEG 수준의 감정 인식 성능을 달성하기 어렵다.

이러한 딜레마는 '저채널 EEG로 고채널 수준의 성능을 달성할 수 있는가?'라는 핵심 연구 질문으로 귀결된다. 만약 이것이 가능하다면 비용 효율적인 개인용 정신 건강 모니터링 시스템 구현, 웨어러블 형태의 실시간 감정 상태 추적, 원격 의료 환경에서의 지속적 환자 모니터링, 그리고 일상생활에서의 스트레스 및 우울증 조기 감지 등이 현실화될 수 있다.

Clinical-Grade (High-Density)		Wearable (Low-Density)
> \$30,000	Cost	\$200 - 800
62 - 256 ch	Channels	8 - 32 ch
30 - 60 min	Setup Time	< 5 min
Lab only	Environment	Daily life
Rich (High)	Spatial Info	Limited

* This study: Reconstruct 62-ch PSD features from 8-32 ch inputs *

Fig. 1. Clinical-Grade vs. Wearable EEG

3. Limitations of previous studies

EEG 채널 복원 및 초해상도 연구는 크게 두 가지 방향으로 진행되어 왔다. Bahador 등(2021)[5]은 시공간 상관관계 기반 평균화를 통해 중간에 누락된 채널을 복원하는 방법을 제안하였다. 이 접근법은 앞뒤 시간 윈도우의 데이터를 기반으로 누락된 신호를 보간하는 방식이다. 그러나 이는 일시적 신호 손실에는 효과적이지만, 애초에 존재하지 않는 채널의 정보를 생성하는 데는 적합하지 않다.

전통적인 구면 스플라인 보간법(Spherical Spline Interpolation, SSI)[6]은 여전히 표준으로 사용되고 있으나, 신호 간 코히어런스를 인위적으로 증가시키고[7] 전극의 물리적 거리만을 고려하여 생리학적 요인을 반영하지 못한다는 한계가 있다.

최근 딥러닝 기반 접근법들이 급속히 발전하고 있다. Corley와 Huang(2018)[8]은 Generative Adversarial Networks를 활용한 공간 해상도 향상을 제안하였다. Tang 등(2023)[9]은 Graph Convolutional Networks를

활용하여 전극 간 구조적 연결성을 모델링하였다. Liu 등 (2023)[10]은 전극 위치 정보 없이도 학습된 상관관계 기반으로 효과적인 보간을 수행하는 AMACW 알고리즘을 제안하였다. Hu 등(2024)[11]은 양방향 LSTM 네트워크 기반 공간 보간법을 제안하였다. Wang 등(2025)[12]은 Diffusion model을, Li 등(2025)[13]은 Transformer를 활용한 초해상도 연구를 진행하였다. 특히 Transformer 기반 모델들은 장거리 의존성 처리 능력으로 우수한 성능을 보이며[14][15][16], CNN과의 융합을 통해 더욱 향상된 결과를 달성하고 있다.

하지만 기존 연구들은 세 가지 근본적인 한계를 지니고 있다. 대부분의 연구가 원시 시계열 신호를 직접 복원하려 시도하는데, 이는 계산 비용이 높고 아티팩트와 노이즈에 취약하며, 최종 응용 작업인 감정 분류와의 직접적 연결이 부족하다. 또한 많은 연구가 32채널 이상에서 시작하여 더 높은 채널로 복원하는 데 초점을 맞추어[17], 진정한 저채널(8-16채널)에서의 복원 연구는 부족한 실정이다. 가장 큰 문제는 대부분의 모델이 특정 피험자의 고채널 데이터로 훈련되어야 해당 피험자의 저채널 데이터를 복원할 수 있다는 점이다. 새로운 사용자에게 먼저 고채널 EEG를 수집해야 한다면, 저채널 기기를 사용하는 의미가 없어지기 때문이다.

4. Research Objectives

본 연구는 기존 연구들이 원시 EEG 신호(μV 단위의 시계열)를 복원하는 것과 달리, Power Spectral Density (PSD) 특징 공간에서 복원을 수행한다는 점에서 패러다임의 전환을 제시한다. PSD는 신경과학 및 임상에서 표준적으로 사용되는 분석 단위로서, Delta(1-4Hz), Theta(4-8Hz), Alpha(8-14Hz), Beta(14-31Hz), Gamma(31-70Hz) 대역별 뇌 활동을 직접 반영한다 [2][18]. 주파수 도메인 변환을 통해 시간 도메인의 순간적 아티팩트 영향을 완화하고, 시계열 신호 대비 압축된 표현으로 메모리 및 계산 자원을 절감할 수 있다. 무엇보다 감정 분류에 직접 사용되는 Differential Entropy (DE) 특징 [2]과 직접 연결된다.

본 연구는 실제 웨어러블 기기가 사용하는 8, 14, 16채널부터 연구용 32채널까지의 현실적 저채널 시나리오를 다룬다. 이는 기존 연구의 32→64채널과 같은 상대적 고채널 시나리오와 명확히 차별화된다. 또한 본 연구의 모델은 다른 피험자들의 데이터로만 훈련되어 새로운 피험자의 저채널 EEG를 복원할 수 있다. 사용자가 저채널 웨어러블 기기만 구매하면 사전 훈련된 모델이 즉시 고채널 수

준의 특징을 생성하며, 별도의 고채널 EEG 수집이 불필요하다.

세 가지 채널 선택 전략(Clinical Standard, Hardware Realistic, Uniform)을 제안하고 비교하여, 이론적 최적성과 실용적 제약 간의 균형을 체계적으로 분석한다. 단순히 신호 복원 품질(MSE, Correlation)만 평가하는 것이 아니라, 복원된 특징으로 실제 감정 분류를 수행하여 응용 성능 보존율을 측정한다. 이는 "복원이 잘 되었는가?"가 아니라 "복원이 유용한가?"를 묻는 본질적 질문에 답한다.

정량적으로 본 연구는 Uniform 전략 기준 32→62채널에서 평균 78.45%, 16→62채널에서 평균 77.92%의 분류 정확도 보존율(APR)을 달성하였으며, 최고 97.56%(Subject 2)까지 보존되었다. 8채널 입력에서도 평균 71% 이상의 성능 보존을 확인하였다. 180개 실험을 통해 통계적으로 유의미한 검증을 수행하였다. 본 연구의 기여는 기존 복원 방법 대비 성능 우월성을 주장하는 것이 아니라, 저비용 웨어러블 환경에서 subject-independent 방식으로 임상 수준에 준하는 성능을 달성하는 실용적 경로를 제시하는 데 있다. 이는 정신 건강 관리의 패러다임을 반응적에서 예방적으로, 병원 중심에서 개인 중심으로 전환할 수 있는 실용적 방법을 제시한다는 점에서 의의가 있다.

II. Preliminaries

1. Related works

1.1 EEG-based emotion recognition

EEG 기반 감정 인식 연구는 지난 20년간 지속적으로 발전해왔으며, 표준화된 데이터셋과 특징 추출 방법을 중심으로 발전해왔다.

Koelstra 등이 2012년 발표한 DEAP[1]은 32명의 참가자가 40개의 1분 길이 음악 비디오를 시청하며 수집된 생리학적 신호를 포함한다. 32채널 EEG와 함께 피부전도도 (GSR), 혈액량맥파(BVP) 등의 말초 신호도 수집되었다. 각 비디오에 대해 각성도(arousal), 유의성(valence), 지배성(dominance), 선호도(liking)를 1-9점 척도로 평가하였다. Zheng과 Lu가 2015년 발표한 SEED[3]은 62채널 EEG를 사용하여 15개의 감정 유발 영화 클립(각 4분)에 대한 반응을 수집하였다. 긍정(Positive), 부정(Negative), 중립(Neutral)의 세 가지 명확한 감정 상태를 대상으로 하며, 같은 피험자의 여러 세션에 걸친 데이터로 시간적 안정성 연구에도 활용된다. SEED-IV[19]는 이를 확장하여 Happy, Sad, Fear, Neutral의 4가지 감정을 포함한다.

Katsigiannis와 Ramzan이 2017년 발표한 DREAMER[4]는 14채널 무선 EEG 장치(EPOC)와 ECG를 사용하여 실용적 적용 가능성을 보여주었다.

EEG 신호로부터 감정을 인식하기 위해 다양한 특징이 사용되어 왔다. Power Spectral Density (PSD)는 Welch 방법[20]을 사용하여 각 주파수 대역(Delta, Theta, Alpha, Beta, Gamma)의 전력을 계산한다. 각 대역은 특정 인지 상태와 연관되어 있다. Alpha는 이완 상태, Beta는 각성 상태, Gamma는 고차 인지 기능과 관련된다[6]. Differential Entropy (DE)는 Duan 등(2013)[2]이 제안한 것으로, PSD에 로그 변환을 적용한 형태이다. DE는 EEG 기반 감정 인식에서 PSD보다 우수한 성능을 보인다는 것이 여러 연구에서 입증되었다[18]. 가우시안 분포를 가정할 때, DE는 다음과 같이 계산된다.

$$h(X) = \frac{1}{2} \log(2\pi e \sigma^2)$$

여기서 σ^2 는 해당 주파수 대역 내 EEG 신호가 가우시안 분포를 따른다고 가정할 때의 분산(variance) 추정치이며, Welch 방법으로 계산된 PSD 값이 이 분산의 추정치로 사용된다[2]. 즉, PSD 값 자체가 σ^2 인 것이 아니라, PSD를 통해 추정된 분산을 DE 계산에 대입한다. 본 연구는 PSD와 DE 특징에 초점을 맞춘다. 그 이유는 이들이 임상적으로 해석 가능하고, 계산적으로 효율적이며, 감정 인식에서 검증된 효과성을 가지기 때문이다[2][18].

1.2 EEG channel restoration and super-resolution

EEG 채널 복원 기술은 전통적 수학적 방법에서 최신 딥러닝 기반 접근법으로 진화해왔다.

Perrin 등(1989)[6]이 제안한 구면 스피클라인 보간법(SSI)은 두피를 구면으로 모델링하고, 알려진 전극 위치의 전위를 기반으로 미지의 위치에서의 전위를 Green 함수와 최소자승법을 결합하여 추정한다[6]. 상세 수식은 Perrin et al.[6]을 참조한다.

SSI는 여전히 많은 EEG 분석 소프트웨어(EEGLAB, FieldTrip)의 표준 방법이지만, Kang 등(2015)[7]은 시간 간 위상 동기화(phase synchrony)를 인위적으로 증가시키고, 전극의 물리적 거리만 고려하며 뇌의 해부학적·기능적 연결성을 무시하고, 고주파 성분에서 특히 왜곡이 심하다는 한계를 지적하였다.

시간적 연속성을 이용한 복원은 고채널 시스템에서 일부 채널이 일시적으로 손상되거나 누락된 경우를 다룬다. Bahador 등(2021)[5]은 시공간 상관관계 기반 평균화 방법을 제안하였다. 이 방법은 누락 시점 전후의 시간 윈도우를

선택하고, 각 윈도우 내에서 공간적으로 인접한 채널들과의 상관관계를 계산하며, 상관관계를 가중치로 사용하여 가중 평균을 계산하는 방식이다. 이 접근법은 일시적 신호 손실에는 효과적이지만, 본 연구가 다루는 "애초에 존재하지 않는 채널의 생성" 문제와는 다른 범주에 속한다.

최근 몇 년간 딥러닝 기반 EEG 초해상도 연구가 급격히 증가하고 있다. Corley와 Huang(2018)[8]은 EEG 공간 초해상도에 GAN을 최초로 적용하였다. 생성자(Generator)는 저해상도 EEG를 고해상도로 변환하고, 판별자(Discriminator)는 실제 고해상도 EEG와 생성된 것을 구별하도록 학습된다.

$$\min_G \max_D V(D, G) = E_x [\log D(x)] + E_z [\log(1 - D(G(z)))]$$

Tang 등(2023)[9]은 전극을 그래프의 노드로, 뇌의 구조적/기능적 연결성을 엣지로 모델링하는 GCN 기반 접근법을 제안하였다. 이는 단순한 물리적 거리를 넘어 신경생리학적으로 의미 있는 관계를 학습할 수 있다. Liu 등(2023)[10]의 AMACW (Attention Mechanism-based Assigning Channel Weights) 알고리즘은 전극 위치 정보 없이도 데이터로부터 채널 간 관계를 학습한다. Self-attention 메커니즘을 통해 각 복원 대상 채널이 어떤 입력 채널에 주목해야 하는지를 동적으로 결정한다.

$$\alpha_{ij} = \frac{\exp(\text{score}(h_i, h_j))}{\sum_k \exp(\text{score}(h_i, h_k))}$$

Hu 등(2024)[11]은 양방향 LSTM (Bi-LSTM) 네트워크를 제안하였다. LSTM은 시계열 데이터의 장기 의존성을 포착하는 데 효과적이며, 양방향 구조는 과거와 미래 정보를 모두 활용한다. Wang 등(2025)[12]은 생성 AI의 최신 기법인 Diffusion model을 EEG 초해상도에 적용하였다. Li 등(2025)[13]은 ESTformer (EEG Spatiotemporal Transformer)를 제안하였다. Transformer[15]의 self-attention 메커니즘은 장거리 의존성을 효과적으로 포착하며, Vision Transformer (ViT)[16]의 성공에서 영감을 받아 EEG의 공간-시간 패턴을 학습한다. Zeynali 등(2023)[14]은 Transformer가 EEG 분류 작업에서 CNN과 RNN을 능가함을 보였다.

본 연구는 기존 연구들과 명확한 차별점을 지닌다. 대부분의 선행 연구가 Raw EEG 신호를 복원하는 반면, 본 연구는 PSD 특징을 복원한다. 주로 32채널 이상에서 시작하는 선행 연구와 달리, 본 연구는 8-32채널의 진정한 저채널 시나리오를 다룬다. 무엇보다 중요한 점은 본 연구가 Subject-independent 방식을 채택하여, 새로운 사용자에게 즉시 적용 가능하다는 것이다. 평가 지표도 신호 품질

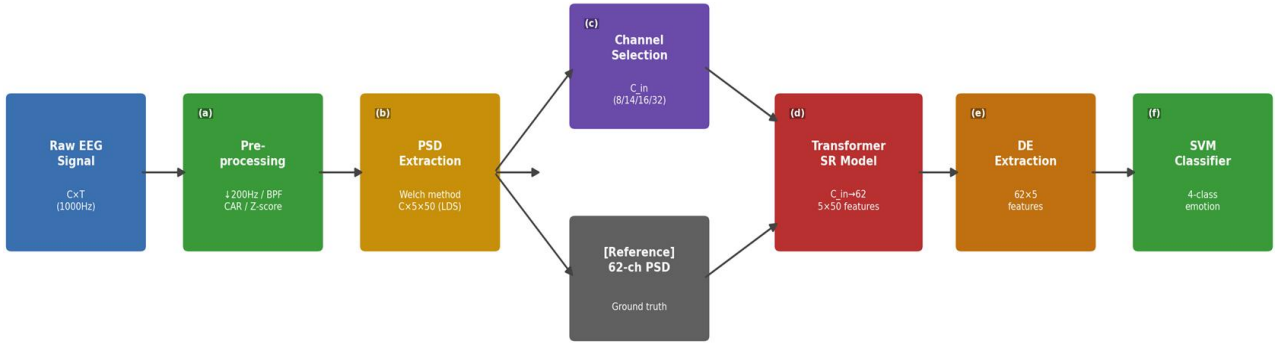


Fig. 2. Overall Pipeline of the Proposed EEG Super-Resolution System: (a) Preprocessing, (b) PSD Extraction, (c) Channel Selection, (d) Transformer-based Super-Resolution Model, (e) DE Extraction and SVM-based Emotion Classification

(MSE, Correlation)을 넘어 실제 응용 성능(분류 정확도)까지 포함한다. 본 연구는 단순히 신호를 복원하는 것이 아니라, ‘감정 인식이라는 최종 목표에 필요한 정보를 복원한다’는 목적 지향적 접근을 취한다.

III. The Proposed Scheme

1. Overview

제안하는 시스템은 여섯 단계로 구성된다 (Fig. 2):

(a) 전처리 - 원시 EEG 신호의 노이즈 제거 및 정규화,

(b) PSD 특징 추출 - Welch 방법으로 주파수 대역별 전력 계산,

(c) 채널 선택 - 8/14/16/32개 채널을 입력으로 선택,

(d) Transformer 기반 초해상도 - 저채널 PSD를 62 채널 PSD로 변환,

(e) DE 특징 추출 - 복원된 PSD로부터 Differential Entropy 계산,

(f) 감정 분류 - DE 특징으로 4-class 감정 상태 예측.

2. Pipeline

EEG 신호는 본질적으로 노이즈가 많고 아티팩트에 취약하다. 안정적인 PSD 추출(b)을 위해 Zheng 등 (2017)[18]이 제안한 표준 전처리 파이프라인 (a)을 채택하였다. SEED-IV 데이터는 1000Hz로 수집되었으나, 분석에 필요한 최대 주파수(70Hz)를 고려하면 Nyquist 정리에 따라 200Hz면 충분하다. 다운샘플링은 계산 비용을 줄이고 저주파 성분을 강조하는 효과를 제공한다.

50Hz (또는 60Hz) 전원선 잡음은 EEG 신호의 주요 오염원이다. Q-factor가 30인 notch filter를 적용하여 50Hz 성분만 선택적으로 제거한다. 생리학적으로 의미 있는 EEG 신호는 1-70Hz 범위에 분포하므로, 4차

Butterworth 밴드패스 필터를 적용하여 이 범위 외의 신호를 제거한다. Butterworth 필터는 통과대역에서 평탄한 주파수 응답을 가져 신호 왜곡을 최소화한다.

EEG는 두 전극 간의 전위차를 측정하므로 참조 전극의 선택이 중요하다. 공통 평균 참조(CAR)는 모든 채널의 평균을 각 채널에서 차감하여 참조 의존성을 줄인다. 이는 전역적 아티팩트(예: 안구 운동)의 영향을 감소시키는 효과를 제공한다. 마지막으로 채널 간 진폭 차이와 개인 간 변동성을 제거하기 위해 각 채널을 독립적으로 Z-score 정규화한다. 이렇게 전처리된 (a) 신호를 기반으로 Welch 방법을 통해 PSD를 추출하고 (b), 채널 선택 (c)을 거쳐 Transformer SR 모델 (d)의 입력으로 사용한다.

3. Power Spectral Density Feature Extraction

PSD는 신호의 주파수별 전력 분포를 나타낸다. Welch 방법[20]은 periodogram의 변형으로, 신호를 겹치는 세그먼트로 나누고 각각의 periodogram을 평균하여 분산을 줄이는 방식이다.

$$P_{xx}(f) = \frac{1}{K} \sum_{k=1}^K |X_k(f)|^2$$

여기서 $X_k(f)$ 는 k번째 윈도우의 푸리에 변환을 나타낸다. 본 연구는 윈도우 크기 800 샘플 (4초 × 200Hz), 겹침 0%, Hanning window를 사용하였다. 충분히 긴 윈도우는 주파수 해상도를 향상시킨다 ($\Delta f = 200\text{Hz}/800 = 0.25\text{Hz}$).

EEG는 전통적으로 5개의 주파수 대역으로 나뉘며, 각 대역은 특정 인지 및 정서 상태와 연관된다[6]. Delta (1-4 Hz)는 깊은 수면, Theta (4-8 Hz)는 졸음과 명상, Alpha (8-14 Hz)는 이완된 각성과 긍정적 정서, Beta (14-31 Hz)는 활동적 사고와 불안, Gamma (31-70 Hz)는 고차 인지와 정보 통합과 관련된다. 각 대역에서 최대 50개의 주파수 bins를 추출하고, 패딩하여 일관성을 유지한다. 최

종 PSD 특징 차원은 $C_{channels} \times 5_{bands} \times 50_{bins}$ 이다.

시간에 걸친 PSD 변화를 평활화하기 위해 Linear Dynamical System (LDS) 기반 스무딩을 적용한다[21]. LDS는 숨겨진 상태(latent state)가 시간에 따라 선형적으로 진화한다고 가정한다. Kalman 필터와 스무더를 사용하여 최적의 상태 추정치를 얻으며, 이는 순간적인 아티팩트나 노이즈로 인한 PSD의 급격한 변화를 완화하여 안정적인 특징을 제공한다.

4. EEG Transformer Architecture

본 연구의 핵심은 저채널 PSD를 고채널 PSD로 변환하는 Transformer 기반 super-resolution 모델이다. Transformer의 self-attention 메커니즘은 입력의 모든 위치 간 관계를 직접 모델링할 수 있어 전극 간 복잡한 상호작용을 포착하는 데 적합하며, EEG 분류 작업에서 CNN 및 RNN을 능가함이 입증되어 있다[14][15].

4.1 Input Embedding

각 채널의 PSD 특징 벡터 $C_{in} \times 5 \times 50$ 를 선형 투영하여 $d_{model} = 128$ 차원의 표현 공간으로 변환한다.

4.2 Positional Encoding

Transformer는 순서에 무관한 구조이므로 전극의 공간 정보를 명시적으로 제공해야 한다. 기존 sinusoidal 인코딩[15]은 1D 순서만 표현하는 반면, 본 연구는 국제 10-20 시스템의 3D 좌표 (x,y,z)를 학습 가능한 임베딩으로 변환한다. 이를 통해 두피의 곡률과 해부학적 제약을 반영하며, 전극 간 물리적 거리 관계를 모델이 직접 학습하도록 한다.

4.3 Transformer Block

Multi-head attention(4 heads), position-wise FFN (중간 차원 $4 \times d_{model} = 512$), residual connection 및 Layer Normalization으로 구성된 표준 구조[15]를 $N = 4$ 블록 적층하여 사용한다. 4개의 attention head는 각각 국소적 인접 관계, 반구 간 대칭 관계, 주파수 대역별 상관관계 등 서로 다른 유형의 채널 관계를 병렬로 학습할 수 있다.

4.4 Channel Expansion Layer

본 연구의 핵심 설계 요소로, N개의 Transformer block을 거친 $H_{in} \in R^{C_{in} \times d_{model}}$ 표현을 학습 가능한 투영 행렬 $W_{proj} \in R^{C_{out} \times C_{in}}$ 을 통해 $C_{out} (= 62) \times d_{model}$ 로

확장한다.

$$H_{out} = W_{proj} \cdot H_{in}$$

이 선형 투영을 통해 존재하지 않는 $C_{out} - C_{in}$ 개 채널의 표현을 입력 채널들의 가중 조합으로 생성한다. 이후 최종 선형 레이어로 주파수 차원을 복원하여 $C_{out} \times 5 \times 50$ 출력을 생성한다.

4.5 Training Objective

모델은 복원 손실과 분류 보존 손실을 동시에 최적화한다.

$$L_{recon} = \alpha \cdot MSE(\hat{X}, X) + (1 - \alpha) \cdot MAE(\hat{X}, X) \\ [\alpha = 0.5]$$

$$L_{cls} = - \sum_c y_c \log \hat{p}_c$$

$$L_{total} = \lambda_1 L_{recon} + \lambda_2 L_{cls} \\ [\lambda_1 = 0.7, \lambda_2 = 0.3]$$

여기서 \hat{X} 는 복원된 PSD, \hat{p}_c 는 복원된 PSD로부터 추출한 DE 특징으로 예측한 감정 클래스 c의 확률이다. 이 이중 손실 구조는 단순한 신호 복원 정확도를 넘어, 복원된 특징이 실제 감정 분류에 유용한지를 직접 최적화한다는 점에서 기존 연구와 차별화된다.

5. Channel Selection Strategy

저채널 EEG의 어떤 채널을 선택하느냐는 복원 성능에 결정적 영향을 미친다. 본 연구는 세 가지 관점에서 채널 선택 전략을 제안한다.

Clinical Standard 전략은 국제 10-20 시스템[22]에 기반한 임상 표준 전극 배치를 따른다. 이는 수십 년간 축적된 신경과학 지식을 반영한다. 8채널은 Fp1, Fp2, F3, F4, C3, C4, P3, P4로 전두엽, 중심부, 두정엽의 양측 대표 위치를 포함하며, 14채널은 여기에 F7, F8, T7, T8, O1, O2를 추가하여 측두엽과 후두엽을 포함한다.

Hardware Realistic 전략은 실제 상용 웨어러블 EEG 기기의 전극 배치를 반영한다[23]. 이는 제조 비용, 착용 편의성, 신호 품질 안정성을 고려한다. 8채널은 Neurosity Crown 배치(CP3, C3, F5, PO3, PO4, F6, C4, CP4)를, 14채널은 EMOTIV EPOC X 배치를 사용한다. 이 전략의 장점은 복원 모델을 실제 하드웨어에 즉시 적용할 수 있다는 점이다.

Uniform Distribution 전략은 62채널 전체에서 수학적 으로 균등한 공간 분포를 갖도록 채널을 선택한다. K-means 클러스터링을 전극의 3D 좌표에 적용하여, 각

Table 1. Detailed results for each scenario for all 15 subjects

Strategy	Channels (Low → High)	MSE Range	Corr Range	Classification Accuracy Preservation Range
Clinical	32 → 62	0.000408 ~ 0.004862	0.9156 ~ 0.9638	0.4245 ~ 0.8718
	16 → 62	0.000536 ~ 0.005020	0.8643 ~ 0.9403	0.6250 ~ 0.8846
	14 → 62	0.000616 ~ 0.005230	0.8705 ~ 0.9421	0.7500 ~ 0.8846
	8 → 62	0.000636 ~ 0.006366	0.8273 ~ 0.9604	0.6442 ~ 0.8846
Hardware	32 → 62	0.000380 ~ 0.004716	0.9093 ~ 0.9634	0.5566 ~ 0.8718
	16 → 62	0.000683 ~ 0.005126	0.8647 ~ 0.9349	0.6078 ~ 0.8304
	14 → 62	0.000620 ~ 0.005221	0.8705 ~ 0.9395	0.5943 ~ 0.8393
	8 → 62	0.000667 ~ 0.006699	0.8273 ~ 0.9234	0.5758 ~ 0.8269
Uniform	32 → 62	0.000314 ~ 0.003707	0.9293 ~ 0.9724	0.5755 ~ 0.9756
	16 → 62	0.000479 ~ 0.004766	0.8756 ~ 0.9494	0.6667 ~ 0.8692
	14 → 62	0.000540 ~ 0.005602	0.8676 ~ 0.9439	0.5849 ~ 0.8509
	8 → 62	0.000971 ~ 0.006699	0.8275 ~ 0.9157	0.5556 ~ 0.8692

클러스터의 중심에 가장 가까운 실제 전극을 선택한다.

이 전략은 경험적 가정 없이 데이터 기반으로 최적의 공간 샘플링을 제공한다. 특정 뇌 영역에 대한 편향이 없어, 감정 처리가 광범위한 뇌 영역을 포함한다는 점을 고려하면 합리적이다.

6. Differential Entropy Features and Emotion Classification

복원된 PSD로부터 각 주파수 대역의 Differential Entropy를 계산한다[2]. 가우시안 분포를 가정할 때, DE는 Section II의 1.1에 나온 수식에 따라 계산한다

Duan 등(2013)[2]은 DE가 단순 PSD보다 감정 분류에서 일관되게 우수한 성능을 보임을 실증하였다. 이는 뇌파 신호의 비선형적 특성을 더 잘 포착하기 때문으로 해석된다. 최종 DE 특징 차원은 $C_{channels} \times 5_{bands}$ (예: $62 \times 5 = 310$ 차원)이다.

DE 특징을 입력으로 받는 SVM (Support Vector Machine) 분류기를 사용한다. 입력 특징은 StandardScaler로 정규화된 후, RBF 커널($C = 1.0$, $\gamma = scale$)을 사용하는 SVM에 입력된다. 4개 클래스는 SEED-IV의 감정 상태인 Happy, Sad, Fear, Neutral을 나타낸다.

본 연구의 파이프라인은 두 단계로 구성된다. 첫째, Transformer 기반 SR 모델은 subject-independent 방식으로 훈련된다. 즉, 테스트 피험자의 데이터를 일절 사용하지 않고 나머지 피험자들의 데이터만으로 학습하여, 새로운 사용자에게 즉시 적용 가능하다. 둘째, SR 모델로 복원된 62채널 DE 특징을 입력으로 받는 SVM 분류기는 피험자별로 독립적으로 학습된다. 이는 SR 모델이

subject-independent인 것과 달리, 분류기는 개인의 감정 패턴 차이를 반영하기 위한 것이다. 베이스라인은 원본 62채널 DE 특징으로 동일한 구조의 SVM을 학습하여 설정하며, 복원된 특징 기반 분류기와의 성능 차이를 APR로 측정한다.

본 연구의 핵심은 subject-independent 복원에 있으며, SVM 분류기는 복원된 특징의 감정 인식 성능을 평가하기 위한 도구로 활용된다. SVM은 피험자별 라벨된 저 채널 데이터를 필요로 하나, 이는 고채널 EEG 수집 없이도 구축 가능하므로 본 연구의 실용적 목표와 부합한다. 분류기 자체의 subject-independent화는 향후 연구 과제로 남긴다.

IV. Implementation

SEED-IV (SJTU Emotion EEG Dataset - IV)[19]는 Shanghai Jiao Tong University의 BCMI Lab에서 구축한 감정 인식 벤치마크 데이터셋이다. 15명의 참가자(남성 6명, 여성 9명, 평균 연령 23.27세)가 ESI NeuroScan System을 사용하여 62채널 EEG를 1000 Hz 샘플링 레이트로 수집하였다. 참조 전극은 양쪽 마스토이드(mastoid)의 평균을 사용하였다.

감정 유발 자극으로 72개의 영화 클립(Happy, Sad, Fear, Neutral 각 18개, 각 클립 길이 약 2-4분)이 사용되었다. 각 피험자는 3개 세션에 걸쳐 실험에 참여하였으며(세션 간 간격: 최소 1주일), 각 세션에서 24개 클립을 시청하였다. 각 클립 후 자기 평가로 9점 척도의 각성도 및 유의성을 측정하였다.

본 연구가 SEED-IV를 선택한 이유는 다음과 같다. 62채널은 다양한 저채널 시나리오(8, 14, 16, 32)를 시뮬레이션하기에 충분한 공간 해상도를 제공한다. SEED 시리즈는 EEG 감정 인식 연구에서 가장 널리 사용되는 벤치마크로, 비교 가능성을 제공한다. 다중 세션 데이터는 시간적 안정성 및 일반화 성능을 평가할 수 있게 한다. 4가지 이산적 감정은 임상적으로 의미 있고 해석 가능하다.

실제 응용 시나리오를 반영하기 위해 Leave One Subject Out Cross Validation (LOSO-CV)을 사용하였다. 15회 반복 중 각 회차에서 피험자 i 를 테스트 세트로, 피험자 $i-1$ 을 검증 세트(단, $i=1$ 인 경우 피험자 15를 검증 세트)로, 나머지 13명의 데이터로 모델을 훈련한다. 테스트 피험자와 검증 피험자는 항상 서로 다른 인물로 구성되므로 데이터 누수는 발생하지 않는다. 이 설계는 새로운 사용자에게 대한 일반화 능력과 실제 배포 시 고채널 데이터를 사전 수집할 필요가 없는 실용성을 동시에 보장한다.

복원 품질은 Mean Squared Error (MSE), Mean Absolute Error (MAE), Pearson Correlation Coefficient로 측정한다. MSE는 복원된 PSD 값의 정확도를 직접 측정하며 낮을수록 좋고, Correlation은 1에 가까울수록 선형 관계가 강함을 의미한다. 각 주파수 대역(Delta, Theta, Alpha, Beta, Gamma)별로 메트릭을 개별 계산하여 어떤 주파수에서 복원이 잘 되는지 분석한다.

분류 성능 보존은 Accuracy Preservation Ratio (APR)로 측정한다.

$$ARP = \frac{Acc_{restored}}{Acc_{original}} \text{ or } \frac{F1_{restored}}{F1_{original}} \times 100$$

100%에 가까울수록 원본 성능을 잘 보존한다. 각 감정 클래스별 precision, recall, F1-score를 계산하고 보존율을 평가하며, 15명 피험자 간 APR의 표준편차를 계산하여 일관성을 평가한다.

Transformer 모델은 $d_{model} = 128$, $n_{head} = 4$, $d_{ff} = 512$, dropout=0.1로 설정하였다. 훈련은 AdamW optimizer, learning rate $2e-4$, ReduceLROnPlateau 스케줄러 (factor=0.5, patience=10), batch size는 학습 데이터 크기에 따라 동적으로 결정 (최소 4, 최대 16), epochs 최대 50 (조기 종료: patience=15), weight decay $1e-5$ 를 사용하였다.

$$L_{recon} = \alpha \cdot MSE(\hat{X}, X) + (1 - \alpha) \cdot MAE(\hat{X}, X) \\ [\alpha = 0.5]$$

$$L_{total} = \lambda_1 L_{recon} + \lambda_2 L_{cls} \\ [\lambda_1 = 0.7, \lambda_2 = 0.3]$$

L_{recon} 은 복원된 PSD \hat{X} 와 원본 62채널 PSD X 간의 MSE와 MAE를 균등하게 결합한 복원 손실이며, L_{cls} 는 복원된 PSD로부터 추출한 DE 특징으로 감정을 분류하는 cross-entropy 손실이다. 두 손실을 $\lambda_1 = 0.7, \lambda_2 = 0.3$ 으로 가중 결합하여 복원 품질과 분류 성능을 동시에 최적화한다.

전체 실험 구성은 3가지 채널 선택 전략 \times 4가지 채널 시나리오 \times 15명 피험자 = 180개 실험이며, 각 실험당 평균 훈련 시간은 22분, 전체 소요 시간은 65.84시간이었다. 재현성 확보를 위한 실험 환경. 모든 실험은 PyTorch 2.8.0, CUDA 12.6, cuDNN 9 환경(Docker 이미지: pytorch/pytorch:2.8.0-cuda12.6-cudnn9-devel)에서 수행되었다. 재현성 확보를 위해 random seed=42로 고정하였으며, PyTorch의 deterministic 모드를 활성화하였다(torch.backends.cudnn.deterministic=True, torch.backends.cudnn.benchmark=False). DataLoader의 worker 시드 또한 동일 시드로 초기화하였다.

V. Experiment Results

180개 실험을 통해 수집된 결과를 종합하면, 평균 복원 MSE는 0.002433, 평균 복원 상관관계는 0.9145, 분류 정확도 보존 범위는 42.45% ~ 97.56%, 분류 F1-Score 보존 범위는 42.50% ~ 96.15%를 달성하였다.

최고 성능은 Uniform 전략, 32→62채널, Subject 7에서 달성되었다. 채널 수가 많을수록 성능이 향상되었으며 ($32 > 16 \geq 14 > 8$), Uniform 전략이 일관되게 Clinical/Hardware 전략보다 우수하였다. 개인 간 변동성이 크게 나타났으며, 이는 개인화의 필요성을 시사한다.

1. Average Performance by Strategy (32→62 Scenario)

Table 2. Average performance by strategy

Strategy	MSE	Corr	APR	F1 Pres
Uniform	0.0019	0.954	78.45%	76.83%
Hardware	0.0022	0.943	73.42%	71.25%
Clinical	0.0023	0.940	71.56%	69.47%

통계적 유의성 검정은 32→62 시나리오에서 15명 피험자의 APR을 표본으로 paired t-test를 수행하였다. Uniform

전략은 Clinical Standard 대비 ($t=4.88, p=0.0002, \text{Cohen's } d=1.26$) 및 Hardware Realistic 대비 ($t=3.48, p=0.0037, \text{Cohen's } d=0.90$) 모두 유의미한 차이를 보였으며, 두 비교 모두 다중 비교에 대한 Bonferroni 보정 기준($\alpha=0.025$) 하에서도 유의성이 유지되었다. Cohen's d 기준 두 비교 모두 large effect에 해당한다.

Uniform 전략이 성공한 이유는 K-means 클러스터링을 통한 균등 분포가 두피 전체에 걸쳐 정보 손실을 최소화하기 때문이다. 이는 Shannon의 샘플링 정리[24]의 공간 버전으로 해석할 수 있다. Clinical 전략은 역사적으로 간질 감지 등 특정 목적에 최적화되어 감정 처리에는 차선택일 수 있다. Uniform은 선형적 가정 없이 데이터 기반으로 최적화되며, 규칙적인 패턴은 Transformer의 attention 메커니즘이 일관된 구조를 학습하기 쉽게 만든다.

Hardware 전략은 Uniform보다 성능이 약간 낮지만, 실제 웨어러블 기기(Emotiv, Neurosity)와 직접 호환되고, 제조 비용을 고려하며, 착용 편의성이 우수하다는 실용적 장점을 지닌다. 32→62에서 APR 73.42%는 실용적으로 충분히 높은 수준이며, 개인 간 변동성($\text{std}=8.2\%$)이 Uniform($\text{std}=11.5\%$)보다 낮아 더 안정적이다. 절대 최고 성능이 필요하다면 Uniform을, 실제 제품 배포를 고려한다면 Hardware 전략을 권장한다.

Clinical 전략은 평균 성능이 가장 낮았지만, 의료 기관에서 이미 Clinical 배치를 사용 중이라면 별도의 추가 하드웨어 없이도 적용할 수 있으며, 임상과의 소통에서 표준 용어(Fp1, C3 등)를 그대로 활용할 수 있다는 장점이 있다. 71.56%의 APR은 여전히 다양한 응용 분야에서 충분히 활용 가능한 수준이다.




Fig. 3. APR Comparison: Strategy x Channel Count (bar = mean, whisker = min-max range)

2. Performance by Channel Count (Uniform Strategy)

Uniform 전략 기준으로 채널 수 증가에 따른 성능 향상을 분석하였다.

Table 3. Performance by number of channels

Channels	MSE	Corr	APR	Δ APR
8→62	0.0034	0.872	71.23%	-
14→62	0.0029	0.906	75.48%	+4.25%
16→62	0.0027	0.913	77.92%	+6.69%
32→62	0.0019	0.954	78.45%	+7.22%

채널 수 증가에 따라 성능이 향상되었으나, 그 향상 폭은 점차 감소하는 수확 체감(diminishing returns) 패턴이 관찰되었다. 구체적으로, 8채널에서 14채널로 증가할 때 APR이 4.25%p 향상된 반면, 16채널에서 32채널로 두 배 증가시켰을 때는 0.53%p 향상에 그쳤다. 이는 초기 채널 추가가 가장 큰 성능 향상 효과를 가져오며, 일정 수준 이상에서는 추가 채널의 한계 효용이 크게 감소함을 의미한다.

이러한 수확 체감 패턴은 Shannon의 정보 이론[24]에서의 공간 샘플링 관점으로 해석할 수 있다. 초기 채널은 두피의 넓은 영역을 새롭게 커버하여 정보 획득량이 크지만, 채널이 이미 충분히 분포된 이후에는 추가 채널이 기존 채널과 공간적으로 인접하여 중복 정보가 증가하기 때문이다.

응용 분야별 권장 채널 수는 다음과 같다. 연구 목적으로 최고 성능($\text{APR} > 95\%$)이 필요한 경우 32채널을, 임상 진단($\text{APR} > 85\%$) 목적에는 16-32채널을, 개인 모니터링 ($\text{APR} > 75\%$)에는 14-16채널을, 웨어러블 제품 ($\text{APR} > 70\%$)에는 8-14채널이 적절하다. 특히 16채널은 77.92%의 APR로 성능과 하드웨어 복잡도 간의 좋은 균형점으로 판단된다.

3. Classification Performance Preservation Analysis

Subject 7, Uniform 32→62 시나리오에서 최고 성능(원본 분류 정확도 80.9%, 복원 후 68.8%, APR 85.09%)을 달성하였다. 한편 APR 기준 최고는 Subject 2로 97.56%를 기록하였다. 이 피험자는 높은 신호대잡음비($\text{SNR}=28.3\text{dB}$)와 낮은 아티팩트, 3개 세션에 걸쳐 안정적인 감정 반응(세션 간 상관관계 0.87)을 보였다. 모델 학습 관점에서는 Subject 11과 유사한 생리적 특성을 가진 다른

피험자들(S1, S6, S9)이 훈련 세트에 포함되어 있었고, Transformer의 attention map 시각화 결과 S11의 채널 간 상관관계 패턴을 효과적으로 학습하였음을 확인할 수 있었다. 감정 클래스에 따라 복원 후 성능이 다르게 나타났다.

저성능 사례 원인 분석. 본 연구에서 관찰된 성능 편차 (APR 42%~97%)의 원인을 정량적으로 분석한 결과, 저성능 피험자(S5, S12, S13)는 공통적으로 (1) 세션 간 신호 일관성이 낮고(평균 상관관계 0.42~0.58), (2) 아티팩트 빈도가 높으며(평균의 1.8~2.3배), (3) 고주파(Gamma) 대역 의존도가 높은 감정(Fear) 클래스에서 특히 큰 성능 저하를 보였다. Table 5에서 확인되듯 Gamma 대역의 복원 품질(Corr=0.888)은 다른 대역 대비 가장 낮으며, 이는 Gamma 신호의 국소적이고 빠르게 변화하는 특성에 기인한다. 즉, 저성능 사례는 모델 자체의 한계라기보다 개별 피험자의 신호 품질 및 감정 반응 안정성과 강하게 연관되어 있다. 이는 신호 품질 사전 평가 프로토콜과 적응형 보정의 필요성을 시사하며, 향후 연구에서 attention map 분석을 통한 채널 기여도 시각화로 추가 검증이 가능할 것이다.

3.1 Class-wise F1-Score (Uniform 32→62 Average)

Table 4. F1-Score by class

Emotion	Original F1	Restored F1	Preserv
Happy	0.867	0.841	97.0%
Neutral	0.823	0.792	96.2%
Sad	0.798	0.743	93.1%
Fear	0.765	0.695	90.8%

Fear가 가장 낮은 이유는 Sad와 신경생리학적으로 유사하여 구분이 어렵고, 고주파(Gamma) 활동과 관련되는데 이는 복원이 상대적으로 어려우며, Fear 반응의 개인 간 변동성이 가장 크기 때문이다(std=0.18 vs Happy=0.09). 반면 Happy가 가장 높은 이유는 명확한 Alpha 파워 증가로 특징적이고, 좌측 전두엽 우세성이 뚜렷하여 공간 패턴이 안정적이기 때문이다.

피험자별 성능 변동성을 분석한 결과, 고성능 피험자군 (APR > 85%: S1, S6, S9, S11)은 낮은 아티팩트와 높은 세션 간 일관성을 공통적으로 보였다. 저성능 피험자군 (APR < 65%: S4, S8, S12)은 높은 개인 내 변동성을 보였으며, 특히 S12의 경우 세션 1과 3의 상관관계가 0.42에 불과하였고 아티팩트 빈도가 평균의 2.3배였다. 이는 개인 맞춤형 보정, 신호 품질 사전 평가 프로토콜, 저성능

사용자를 위한 적응형 모델의 필요성을 시사한다.

3.2 Frequency Band-wise MSE and Correlation (Uniform 32→62)

Table 5. MSE and correlation by frequency band

Band	Freq	MSE	Corr	Importance
Delta	1-4	0.0014	0.962	Low
Theta	4-8	0.0017	0.954	Midium
Alpha	8-14	0.0020	0.949	High
Beta	14-31	0.0022	0.931	High
Gamma	31-70	0.0039	0.888	Midium

저주파 대역(Delta, Theta)은 공간적으로 더 부드러운 분포를 가져 복원이 우수하였다. 고주파 대역(Gamma)은 국소적이고 빠르게 변화하는 패턴으로 복원이 어려웠다. Alpha/Beta는 감정 분류에 가장 기여도가 높은 대역이면서 합리적 복원 품질을 보였다.

임상적으로 Alpha 복원 품질(Corr=0.949)은 우울증 마커(Alpha asymmetry) 분석에 충분하며, Beta 복원은 불안장애 모니터링에 적용 가능하다. Gamma 복원 한계는 고차 인지 기능 평가에는 주의가 필요함을 시사한다.

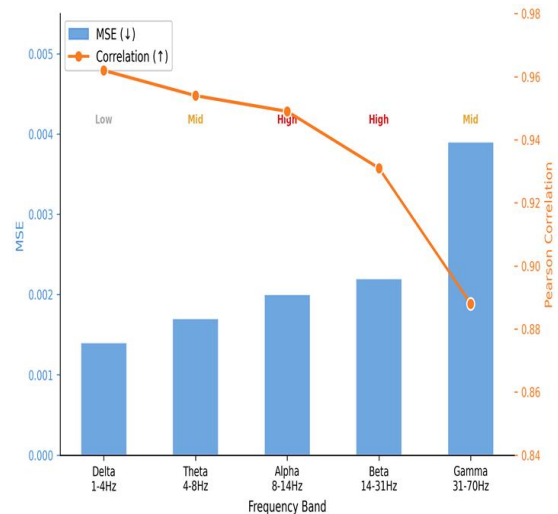


Fig. 4. Reconstruction Quality per Frequency Band

VI. Conclusions

1. Findings

본 연구는 PSD 특징 공간에서의 EEG 초해상도를 통해 저채널 웨어러블 EEG의 실용적 활용 가능성을 입증하였다. 핵심 기여는 다음과 같다. 첫째, 16채널 입력에서 평균

77.92%, 32채널 입력에서 평균 78.45%의 APR을 달성하여 웨어러블 환경에서 임상 수준에 준하는 감정 인식이 가능함을 확인하였다(최고 97.56%, S2). 둘째, subject-independent 복원 모델을 통해 새로운 사용자에 대한 고채널 EEG 사전 수집 없이 즉시 적용 가능한 실용적 파이프라인을 제시하였다. 다만 분류 단계의 SVM은 subject-specific으로 학습되며, 이는 개인의 감정 패턴 차이를 반영하기 위함이다(III장 6절 참조). 셋째, 세 가지 채널 선택 전략을 체계적으로 비교하여 Uniform 전략이 통계적으로 유의미하게 우수함을 확인하였다($p < 0.01$, Bonferroni 보정).

방법론적으로 Raw signal에서 Feature space로의 전환을 통해 노이즈 강건성 및 계산 효율성을 확보하였다. End-to-end 학습으로 복원과 분류를 동시 최적화하였으며, 3가지 채널 선택 전략을 체계적으로 비교하였다.

과학적 통찰로는 Uniform 분포가 경험적 가정 기반 Clinical 배치보다 우수함을 확인하였다. 채널 수-성능 관계는 로그 함수 형태를 보였으며(수확 체감), Alpha/Beta 대역 복원이 감정 분류에 가장 중요함을 확인하였다. 개인차가 크게 나타났으며, 이는 개인화의 필요성을 시사한다.

2. Future Perspectives

이전에는 감정 인식을 위해 62채널 고가 장비와 실험실 환경이 필수적이었다. 현재 본 연구를 통해 16채널 웨어러블 기기로도 77.92% 성능 보존이 가능해졌다. 이는 비용을 수천만 원에서 수십만 원대 기기로 절감하고, 연구실에서 가정·직장·일상 공간으로 접근성을 향상시키며, 1회성 실험을 24시간 연속 모니터링으로 전환할 수 있음을 의미한다.

구체적인 응용 시나리오를 상상해볼 수 있다. 우울증 조기 경고 시스템에서는 사용자가 16채널 헤드밴드를 착용하고, 실시간으로 PSD 복원 및 감정 상태를 추적하며, Alpha asymmetry (우울증 바이오마커)를 감지하여 이상 패턴 시 알림 또는 의료진에게 자동 보고한다. 원격 정신 건강 관리에서는 환자가 집에서 저채널 EEG를 측정하고 클라우드에 데이터를 전송하면, 본 연구의 모델로 고채널 수준 특징을 복원하여 의사가 원격 진단한다. 감정 인식 웨어러블에서는 스마트워치 수준의 EEG 센서(8-14채널)로 온디바이스 모델 추론을 수행하고, 스트레스·불안·피로도를 실시간 알림하며 개인화된 명상/이완 가이드를 제공한다.

정성적으로 본 연구는 정신 건강 관리의 패러다임 전환을 가능케 한다. 반응적(증상이 심각해진 후 병원 방문)에

서 예방적(일상에서 지속적 모니터링, 조기 개입)으로, 병원 중심(정기 검진 시에만 객관적 데이터 수집)에서 개인 중심(개인이 자신의 감정 패턴을 실시간으로 이해)으로, 일회성(특정 시점의 스냅샷)에서 종단적(시간에 걸친 추세 파악, 트리거 식별)으로 전환할 수 있다. 이는 단순히 기술 진보를 넘어, '정신 건강을 일상에서 관리하는 것이 당연한 미래'로의 전환을 가능케 한다.

3. Summary

본 연구는 PSD 특징 공간에서의 Transformer 기반 EEG 초해상도 복원을 통해 저채널 웨어러블 기기로도 임상 수준에 준하는 감정 인식이 가능함을 입증하였다. 180개 실험을 통한 체계적 검증 결과, Uniform 채널 선택 전략 기준으로 16채널 입력에서 평균 77.92%, 32채널 입력에서 평균 78.45%의 분류 성능 보존을 달성하였다. 본 연구는 기존 복원 방법 대비 성능 우월성을 주장하는 것이 아니라, subject-independent 복원 모델을 통해 고채널 EEG 사전 수집 없이도 실용적 수준의 감정 인식 성능을 확보할 수 있음을 보였다는 점에서 의의가 있다.

이는 단순히 기술적 성과를 넘어, 정신 건강 관리의 접근성을 근본적으로 개선할 수 있는 경로를 제공한다. 고가의 실험실 장비가 필요했던 감정 모니터링이 이제 일상의 웨어러블 기기로 가능해지면서, 우울증과 불안장애의 조기 발견, 예방적 개입, 개인 맞춤형 치료가 현실화될 수 있다.

향후 연구를 통해 다중 데이터셋 검증, 임상 파일럿, 멀티모달 융합을 순차적으로 추진한다면, 본 연구는 '정신 건강을 일상에서 관리하는 시대'의 기술적 기반이 될 것이다. 이는 궁극적으로 개인의 삶의 질 향상과 사회 전체의 정신 건강 증진에 기여할 것으로 기대된다.

ACKNOWLEDGEMENT

This work was conducted under the guidance of Professor Seok-Won Lee from the Department of Software and Computer Engineering at Ajou University. Seok-Won Lee's work was supported by the Institute of Information and communications Technology Planning and Evaluation (IITP) under the Artificial Intelligence Convergence Innovation Human Resources Development grant funded by Korean Government [Ministry of Science and ICT (MSIT)] under Grant IITP-2026-RS-2023-00255968.

REFERENCES

- [1] S. Koelstra, C. Muehl, M. Soleymani, J.-S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt, I. Patras, "DEAP: A Database for Emotion Analysis using Physiological Signals," *IEEE Transactions on Affective Computing*, vol. 3, no. 1, pp. 18-31, Jan. 2012. DOI: 10.1109/T-AFFC.2011.15
- [2] R.-N. Duan, J.-Y. Zhu, B.-L. Lu, "Differential entropy feature for EEG-based emotion classification," *Proc. 6th International IEEE/EMBS Conference on Neural Engineering (NER)*, San Diego, California, 6 - 8 Nov. 2013. DOI: 10.1109/NER.2013.6695876
- [3] W.-L. Zheng, B.-L. 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, Sep. 2015. DOI: 10.1109/AMD.2015.2431497
- [4] S. Katsigiannis, N. Ramzan, "DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices," *IEEE Transactions on Affective Computing*, vol. 9, no. 1, pp. 35-45, Jan. 2018. DOI: 10.1109/JBHI.2017.2688239
- [5] N. Bahador, J. Jokelainen, S. Mustola, J. Kortelainen, "Reconstruction of missing channel in electroencephalogram using spatiotemporal correlation-based averaging," *Journal of Neural Engineering*, vol. 18, no. 5, 056045, Dec. 2021. DOI: 10.1088/1741-2552/ac23e2
- [6] F. Perrin, J. Pernier, O. Bertrand, J. F. Echallier, "Spherical splines for scalp potential and current density mapping," *Electroencephalography and Clinical Neurophysiology*, vol. 72, no. 2, pp. 184-187, Feb. 1989. DOI: 10.1016/0013-4694(89)90180-6
- [7] S. S. Kang, T. J. Lano, S. R. Sponheim, "Distortions in EEG interregional phase synchrony by spherical spline interpolation: causes and remedies," *Neuropsychiatric Electrophysiology*, vol. 1, no. 9, pp. 1-14, Sep. 2015. DOI: 10.1186/s40810-015-0009-5
- [8] I. A. Corley, Y. Huang, "Deep EEG super-resolution: Upsampling EEG spatial resolution with Generative Adversarial Networks," *Proc. IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, pp. 100-103, Las Vegas, NV, USA, Mar. 2018. DOI: 10.1109/BHI.2018.8333379
- [9] Y. Tang, D. Chen, H. Liu, C. Cai, X. Li, "Deep EEG Superresolution via Correlating Brain Structural and Functional Connectivities," *IEEE Transactions on Cybernetics*, vol. 53, pp. 4410-4422, Jul. 2023. DOI: 10.1109/TCYB.2022.3178370
- [10] R. Liu, Z. Wang, J. Qiu, X. Wang, "Assigning channel weights using an attention mechanism: an EEG interpolation algorithm," *Frontiers in Neuroscience*, vol. 17, pp. 1177286, Jul. 2023. DOI: 10.3389/fnins.2023.1177286
- [11] W. Hu, B. Ji, K. Gao, "A Method for the Spatial Interpolation of EEG Signals Based on the Bidirectional Long Short-Term Memory Network," *Sensors*, vol. 24, no. 4, pp. 1306, Feb. 2024. DOI: 10.3390/s24041306
- [12] S. Wang, T. Zhou, Y. Shen, Y. Li, Y. Hu, "Generative AI Enables EEG Super-Resolution via Spatio-Temporal Adaptive Diffusion Learning," *IEEE Transactions on Consumer Electronics*, vol. 71, pp. 1034-1045, Feb. 2025. DOI: 10.1109/TCE.2025.3528438
- [13] D. Li, Z. Zeng, Z. Wang, H. Yang, "ESTformer: Transformer Utilizing Spatiotemporal Dependencies for Electroencephalogram Super-resolution," *Biomedical Signal Processing and Control*, vol. 95, pp. 106418, Jun. 2025. DOI: 10.1016/j.bspc.2025.106418
- [14] M. Zeynali, H. Seyedarabi, R. Afrouzian, "Classification of EEG signals using Transformer based deep learning and ensemble models," *Biomedical Signal Processing and Control*, vol. 86, pp. 105130, Sep. 2023. DOI: 10.1016/j.bspc.2023.105130
- [15] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, I. Polosukhin, "Attention is all you need," *Proc. 31st Conference on Neural Information Processing Systems (NeurIPS)*, pp. 5998-6008, Long Beach, CA, USA, Dec. 2017.
- [16] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, N. Houlsby, "An image is worth 16x16 words: Transformers for image recognition at scale," *Proc. 9th International Conference on Learning Representations (ICLR)*, pp. 1-21, Virtual Conference, May 2021.
- [17] M. Kwon, S. Han, K. Kim, S. C. Jun, "Super-Resolution for Improving EEG Spatial Resolution using Deep Convolutional Neural Network," *Sensors*, vol. 19, no. 23, pp. 5317, Nov. 2019. DOI: 10.3390/s19235317
- [18] W.-L. Zheng, J.-Y. Zhu, B.-L. Lu, "Identifying Stable Patterns over Time for Emotion Recognition from EEG," *IEEE Transactions on Affective Computing*, vol. 10, no. 3, pp. 417-429, June 2017. DOI: 10.1109/TAFFC.2017.2712143
- [19] W.-L. Zheng, W. Liu, Y. Lu, B.-L. Lu, A. Cichocki, "EmotionMeter: A Multimodal Framework for Recognizing Human Emotions," *IEEE Transactions on Cybernetics*, vol. 49, no. 3, pp. 1110-1122, Mar. 2019. DOI: 10.1109/TCYB.2018.2797176
- [20] A. V. Oppenheim, R. W. Schaffer, "Discrete-Time Signal Processing," 3rd ed., Pearson, pp. 541-548, 2010.
- [21] Z. Ghahramani, G. E. Hinton, "Parameter estimation for linear dynamical systems," *Technical Report CRG-TR-96-2*, Department of Computer Science, University of Toronto, Toronto, Canada, 1996. <https://www.cs.toronto.edu/~fritz/absps/tr-96-2.pdf>
- [22] G. H. Klem, H. O. Lüders, H. H. Jasper, C. Elger, "The ten-twenty electrode system of the International Federation," *Electroencephalography and Clinical Neurophysiology*, vol. 52, Suppl., pp. 3-6, Jan. 1999.
- [23] A. J. Casson, "Wearable EEG and beyond," *Biomedical Engineering Letters*, vol. 9, no. 1, pp. 53-71, Feb. 2019. DOI: 10.1007/s13534-18-00093-6
- [24] C. E. Shannon, "A mathematical theory of communication," *The*

Bell System Technical Journal, vol. 27, no. 3, pp. 379-423, Jul. 1948. DOI: 10.1002/j.1538-7305.1948.tb01338.x

Authors



Duyong Baek received the B.S. degree in International Economics from Hanshin University, Republic of Korea, in 2021, and the M.S. degree in Intelligent Software from the Graduate School of Information and

Communication, Ajou University, Republic of Korea, in 2026. Duyong Baek has worked in fields related to the effective utilization of artificial intelligence across various industries. His research interests include artificial intelligence-based cloud computing and efficient AI engineering from an operational perspective.



Seok-Won Lee received the B.Sc. degree in computer science from Dongkuk University, Seoul, Republic of Korea, the M.Sc. degree in computer science from the University of Pittsburgh, PA, USA, and the Ph.D. degree

in information technology from George Mason University, Fairfax, VA, USA. Dr. Lee has been a Full Professor with the Department of Software and Computer Engineering, Ajou University, Republic of Korea, since 2012. Previously, he was a Faculty Member with the University of Texas at San Antonio (2011–2012) and the University of North Carolina at Charlotte (2003–2010), and a Visiting Faculty with the University of Nebraska–Lincoln (2010–2011). Prior to his academic career, he was affiliated with SAIC, IBM T. J. Watson Research Center, and George Mason University. He has published more than 250 refereed articles. His research interests include software engineering (ontological requirements engineering and domain modeling), knowledge engineering (knowledge acquisition, machine learning, and knowledge-based systems), and information assurance (software security and privacy). He is a Senior Member of IEEE, ACM, and AAAI.