

그래프 잠재표현 학습을 이용한 우울증 뇌 신경망 규명 연구

(Graph Autoencoder - Based Latent Learning Identifies Depression-related Functional Network)

김예은*, 배한별**, 조한규**

(Ye-Eun Kim, Han Byeol Bae, Han-Gue Jo)

요약

주요우울장애(MDD)는 임상적 이질성이 커 증상 기반 진단을 보완할 객관적 생물학적 지표가 요구된다. 특히 기존의 선형 분석 모델은 복잡한 고차원 뇌 네트워크의 비선형 상호작용을 포착하는 데 한계가 있어, 대규모 데이터를 효과적으로 압축하고 핵심 특징을 추출할 수 있는 접근법이 필요하다. 본 연구는 fMRI 기반 뇌 기능적 연결성 데이터를 분석하여 MDD의 핵심 연결성을 도출하고, 임상 증상과의 연관성을 탐색하였다. MDD 환자 821명의 160개 ROI 연결성 인접행렬을 입력으로, 변분 오토인코더(VAE)와 그래프 합성곱 신경망(GCN)을 결합한 그래프 오토인코더(GAE)를 구축해 저차원 잠재 공간으로 표현한 뒤 민감도 분석으로 핵심 연결성을 추출하였다. 그 결과 16차원 잠재 벡터 모델이 안정적인 성능을 보였고, 전전두엽·측두엽·후두엽을 잇는 연결이 주요 특징으로 나타났다. 특히 superior frontal - occipital 및 vmPFC - temporal 연결은 HAM-D의 초조 및 정신적 불안 문항과 유의한 음의 상관($p < 0.001$)을 보였으며, 이는 전전두엽 중심의 하향식 조절 회로와 불안/초조 증상 간의 연관성을 시사한다. 이러한 결과는 GAE 기반 비지도 학습이 MDD의 복잡한 신경생물학적 패턴을 해석 가능한 형태로 제시할 수 있음을 입증하며, 향후 정밀 진단을 위한 아형 탐색 및 치료 반응 예측의 기초 자료로 활용될 수 있다.

■ 중심어 : 우울증 ; 기능적 자기 공명 영상 ; 그래프 뉴럴 네트워크 ; 우울증 평가 척도

Abstract

Major depressive disorder (MDD) is highly heterogeneous, and there is a growing need for objective biomarkers that can complement symptom-based diagnosis. In this study, we analyzed resting-state fMRI functional connectivity in 821 patients with MDD using a graph autoencoder (GAE) that integrates a variational autoencoder (VAE) and graph convolutional networks (GCNs). Connectivity matrices from 160 regions of interest were embedded into a low-dimensional latent space, and sensitivity analysis was used to identify connections most influential to the learned representations. The model with a 16-dimensional latent vector showed stable performance and emphasized fronto-temporo-occipital connectivity as a key feature. In particular, superior frontal - occipital and ventromedial prefrontal cortex (vmPFC) - temporal connections were negatively associated with HAM-D items related to agitation and psychic anxiety ($p < 0.001$), suggesting a potential role of prefrontal top-down regulation in these symptoms. Overall, our results support the utility of unsupervised GAE-based learning for extracting clinically interpretable connectivity features in MDD, with implications for future studies on subtype characterization and treatment-response prediction.

■ keywords : Depression ; fMRI ; Graph Neural Network ; HAM-D

I. 서론

우울증은 다양한 정서 상태 중 하나로, 일시적인 기분 저하에서부터 지속적이고 심각한 임상적 증후군에 이르기까지 폭넓은 범위를 포함한다. 이 가운

* 준회원, 국립군산대학교 전자정보공학부 정보통신전파공학전공

** 정회원, 국립군산대학교 인공지능융합학과

본 연구는 국립군산대학교 정보통신기술연구소의 부분적인 지원으로 수행되었습니다.

접수일자 : 2026년 01월 23일

게재확정일 : 2026년 02월 19일

교신저자 : 조한규 e-mail :hgjo@kunsan.ac.kr

데 일부 증상은 임상적 기준에 따라 주요 우울 장애(Major Depressive Disorder, MDD)로 진단되며, 정서·인지·행동 및 생물학적 기능 전반에 영향을 미치는 대표적인 정신 질환으로 분류된다[1].

임상 및 연구 현장에서 널리 사용되는 미국 정신의학회(American Psychiatric Association, APA)의 정신 질환 진단 및 통계 편람(Diagnostic and Statistical Manual of Mental Disorders, DSM)에서는 주요 우울 에피소드(Major Depressive Episode)의 진단 기준을 제시하고, 이를 토대로 MDD를 판단한다[1]. 구체적으로, 우울한 기분 또는 흥미·즐거움의 현저한 상실 중 최소 1개가 포함된 상태에서 총 9개 증상 중 5개 이상이 동일한 2주 기간 동안 거의 매일 나타나며, 이전 기능 수준에 비해 뚜렷한 변화가 동반되어야 한다.

그러나 이러한 임상 기준은 다양한 증상을 포괄하는 만큼, 동일한 진단 범주 내에서도 매우 상이한 임상 양상이 나타날 수 있다. 환자마다 서로 다른 증상 조합을 보일 수 있으며, 그 결과 동일하게 MDD로 분류되더라도 공통된 증상이 두드러지지 않을 수 있고, 진단 범주 내부에서 임상적 이질성이 관찰된다는 점이 지속해서 제기되어 왔다[2].

이러한 배경에서 증상 평가만으로는 포착하기 어려운 병태생리적 기전을 규명하고 치료 반응 예측의 정밀도를 높이기 위해, 뇌 영상 등 객관적 뇌 생물학적 데이터를 활용하려는 연구가 활발히 이루어지고 있다[3]. 정신 질환이 뇌 기능 및 구조와 밀접하게 연관된다는 점에서 자기공명영상(Magnetic Resonance Imaging, MRI)과 뇌전도(Electroencephalogram, EEG) 등이 핵심 연구 데이터로 널리 활용되고 있으며[4], 더 나아가 인공지능 기술을 융합하여 대규모 뇌 데이터의 패턴을 딥러닝 기반으로 학습·분석하고 이를 임상 적용으로 확장하려는 시도도 증가하고 있다[5].

특히 최근 연구에서는 그래프 구조로 표현되는 뇌 연결성 패턴을 정량적으로 분석할 수 있는 그래프 뉴럴 네트워크(Graph Neural Network, GNN) 기반 접근이 보고되고 있다[6]. 조현병, 우울증, 자폐스펙

트럼장애 등 다양한 정신질환에서 뇌 연결성 특성을 그래프 수준에서 분석하려는 시도가 이어지고 있으나, 대규모 환자 집단을 대상으로 임상적 연관성까지 함께 규명한 연구는 아직 제한적이다. GNN 기반 비지도 학습을 통해 우울증 환자의 핵심 연결성 특징을 도출한 바 있으나, 해당 특징이 임상 지표와 어떻게 연결되는지에 대한 근거는 충분히 제시되지 않았다[7].

본 연구는 fMRI로부터 추출한 뇌 기능적 연결성 데이터를 기반으로 MDD 환자 집단에서 관찰되는 신경생물학적 특성을 탐색하는 것을 목표로 한다. 이를 위해 그래프 구조로 표현되는 뇌 연결성 패턴을 정량적으로 분석할 수 있는 GNN 기반 프레임워크를 적용하여, 환자 집단 내 뇌 연결성 변이를 파악하고자 한다. 나아가 GNN으로 추출한 연결성 특징과 임상 변수 간의 연관성을 검증함으로써, 증상 중심 접근을 보완할 수 있는 뇌영상 기반 해석을 제시하고, MDD의 생물학적 이질성을 설명하기 위한 후속 연구로 확장 가능한 분석적 기반을 마련하고자 한다.

II. 방 법

1. 데이터 수집 및 전처리

본 연구는 DIRECT(Depression Imaging REsearch ConsorTium)에서 수행한 REST-meta-MDD 프로젝트 데이터셋을 활용하였다[8]. 해당 데이터셋은 MDD 환자 1,300명의 휴식 상태 rs-fMRI를 포함하며, 환자군은 여성 826명과 남성 474명으로 구성되어 있다.

표 1. MDD의 인구통계학적 특성

Variables	MDD
Total subjects (n)	821
Age (years), mean \pm SD	34.36 \pm 11.55
Sex (Male / Female)	299 (37.4%) / 522 (63.6%)
HAM-D, mean \pm SD	21.26 \pm 6.61

수집된 데이터는 DPARSF(Data Processing

Assistant for Resting-State fMRI)에서 채택한 표준화된 rs-fMRI 전처리 파이프라인을 적용하였다[9]. 최종 분석에는 전체 1,300명 중 확인 불가능한 결측 사례를 제외하고, 유효한 MDD 821명의 데이터를 포함하였다.

다음으로 Dosenbach 뇌 아틀라스[10]를 기준으로 뇌를 160개의 관심 영역(Region of Interest, ROI)으로 분할하고, 각 ROI의 평균 BOLD(blood oxygen level dependent) 시계열 신호를 추출하였다. 이후 ROI 쌍 간 피어슨 상관계수(Pearson's correlation coefficient)를 계산하여 기능적 연결성 인접행렬(adjacency matrix)을 구성하였다. 그 결과 160개 ROI로부터 총 12,720개($160 \times (160 - 1) / 2$)의 기능적 연결성이 도출되었으며, 이는 이후 그래프 기반 분석의 입력으로 사용되었다.

2. 그래프 기반 오토인코더 모델 개발

기능적 연결성의 복잡한 그래프 연결성의 잠재 표현을 학습하기 위해, 그래프 기반 오토인코더(Graph Auto Encoder, GAE) 구조 모델을 설계하였다[11]. 본 모델은 변분오토인코더(Variational Autoencoder, VAE)를 기반으로 잠재 공간(latent space, z)을 학습하며, 디코더 단계에서 그래프 컨볼루션 네트워크(Graph Convolution Network, GCN)를 적용하여 그래프 구조 정보를 반영한 인접행렬 복원을 수행한다.

오토인코더(autoencoder)는 인코더에서 입력 데이터를 저차원의 잠재 벡터로 압축한 뒤, 디코더에서 이를 복원하여 원본과 유사한 출력을 재구성하도록 학습한다[12]. 오토인코더의 핵심 목적은 차원 축소를 통해 저차원 표현을 학습하면서도 입력 데이터의 중요한 패턴과 구조적 특성을 최대한 보존하는 데 있다.

VAE는 오토인코더에 확률적 생성 모델 관점을 도입한 확장 구조로, 잠재변수 z 를 하나의 점이 아닌 분포로 모델링함으로써 보다 일반화 가능한 잠재 표현을 학습한다[13]. VAE는 인코더가 추정한 $q(z | x)$ 가 사전분포 $p(z)$ 에 근접하도록 유도하기 위

해 쿨백 - 라이블러 발산(Kullback - Leibler divergence, KLD) 항을 목적함수에 포함한다[12]. 이를 통해 잠재 공간 z 는 연속적이며 구조적으로 해석 가능한 형태로 정규화된다.

GAE 구조는 이러한 VAE의 분포 기반 표현 학습을 그래프 신경망(GCN)과 결합함으로써, ROI 간 상호작용을 그래프 패턴으로 반영하고 전체 기능적 연결 패턴의 지역적 구조를 잠재 공간에서 통합적으로 학습하도록 설계하였다.

본 연구에 적용된 GAE 모델의 전체 구조는 그림 1에 제시하였다. 입력 데이터는 MDD 821명의 기능적 연결성 인접행렬(X)이며, 모델은 비지도 학습 방식으로 인코더를 통해 잠재 공간(z)으로 압축한 뒤 디코더에서 인접행렬을 재구성하도록 학습한다. 이 과정에서 모델은 입력과 재구성 출력 간 차이(Poisson Negative Log-Likelihood 손실 함수 값)를 최소화하여 입력 데이터의 분포적 특성을 학습한다.

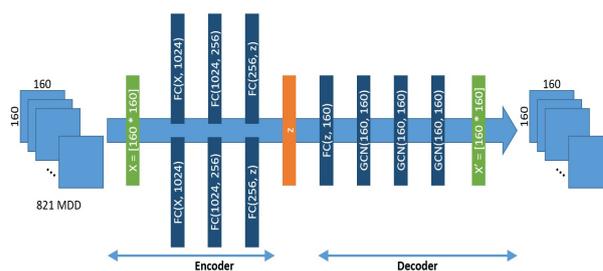


그림 1. GAE 모델 구조

인코더에서는 인접행렬을 벡터화한 입력을 다층 신경망을 통해 단계적으로 저차원 잠재 공간으로 매핑한다. VAE 구조에 따라 인코더는 잠재변수의 평균과 분산을 추정하여 각 MDD의 기능적 연결성 패턴을 확률 분포로 표현한다. 본 연구에서는 입력을 순차적으로 1024차원, 256차원으로 축소한 후 최종적으로 저차원의 잠재 벡터(z)로 임베딩하였으며, 각 은닉층 레어의 활성화 함수로 ReLU(Rectified Linear Unit)를 사용하였다.

디코더에서는 추정된 저차원 잠재 벡터(z)를 입력으로 받아 GCN을 통해 그래프 구조 특성을 반영한 인접행렬을 재구성한다. 디코더 출력층에는

Sigmoid 함수를 적용하여 인접행렬 형태의 값을 복원하도록 설계하였다. 모델 학습의 평가지표로는 손실 함수 값을 사용하였으며, 학습 과정에서 손실 함수가 최소화되도록 하이퍼파라미터를 조정한 뒤, 손실이 가장 낮은 모델을 최적 모델로 선정하여 이후 분석에 사용하였다.

3. 주요 기능적 연결성 도출

GAE는 비지도 학습을 통해 기능적 연결성 인접행렬을 저차원 잠재벡터 z 로 압축하여 표현을 학습한다. 따라서 잠재 표현 z 에 크게 기여하는 기능적 연결성을 규명하기 위해 민감도 분석을 수행하였다.

입력의 12,720개 연결성 값을 하나씩 변형하여 새로운 잠재벡터 z' 를 산출하고, 변형 전 기준 잠재벡터 z 와의 평균제곱오차(Mean Squared Error, MSE)를 계산하였다. 이를 통해 특정 연결성 변화가 잠재표현에 미치는 영향을 정량화하고, 모델이 민감하게 반응하는 주요 기능적 연결성을 도출하였다.

연결성 값의 변형에는 각 개인의 인접행렬에서 관측된 최대 기능적 연결성 값의 3배를 대체값으로 사용하였다. 모든 연결성에 대해 동일한 절차를 반복하여 MSE를 산출하였다.

4. 임상척도와 주요 연결성 간 상관관계

도출된 주요 기능적 연결성의 임상적 의미를 확인하기 위해, MSE 값이 큰 상위 10개 기능적 연결성을 대상으로 피어슨 상관계수를 사용하여 HAM-D(Hamilton Depression Rating Scale) 17 문항 점수와의 상관관계를 평가하였다.

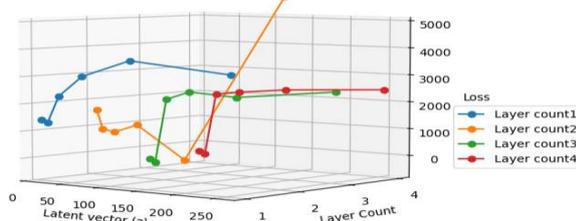


그림 2. 학습 레이어 수와 잠재 벡터 값에 따른 손실 함수의 변화

III. 결 과

1. 모델 학습 및 최적화

GAE 모델의 손실을 최소화하기 위해 레이어 수 (1, 2, 3, 4)와 잠재벡터 차원($z=8, 16, 32, 64, 128, 256$)을 변화시키며 하이퍼파라미터 조합별 성능을 비교하였다. 이때 레이어 수와 z 차원을 제외한 나머지 하이퍼파라미터는 동일하게 고정하여, 모델 복잡도 변화가 손실 함수 값에 미치는 영향을 평가하였다.

그림 2과 표 2와 같이 레이어 3개 및 잠재벡터 차원 $z=16$ 의 조합이 가장 안정적이고 효율적인 학습 결과를 나타냈으며, 해당 모델을 최적 모델로 선정하여 이후 분석에 활용하였다.

표 2. 레이어 수와 잠재벡터 값에 따른 GAE의 손실 값

Layer	Latent vector z					
	8	16	32	64	128	256
1	1397.15	1308.34	2309.68	3071.67	3715.30	3384.21
2	1612.87	913.78	812.64	1140.42	-25.68	152495.49
3	-451.80	-581.80	1885.30	2218.81	2108.37	2508.75
4	-363.38	-456.74	1937.33	2060.27	2248.32	2444.94

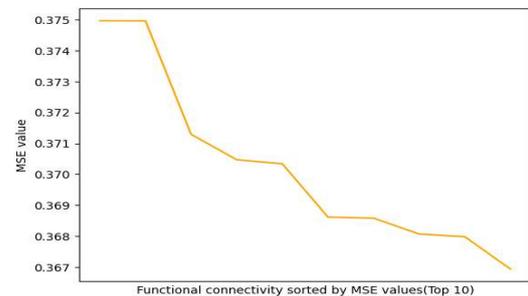
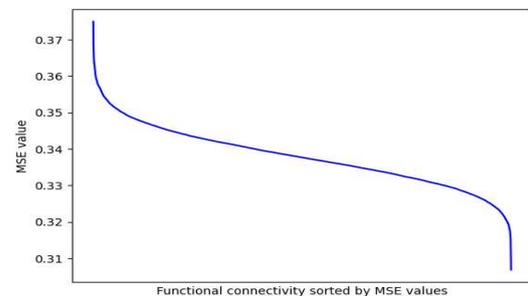


그림 3. 12,720개의 기능적 연결성(x 축)에 대한 MSE(y 축) 분포(왼쪽)와 MSE 상위 10개 연결성(오른쪽) 모든 연결성은 MSE 크기 순으로 정렬함

2. 주요 뇌 연결성 도출

최적화된 GAE 모델에 대해 민감도 분석을 수행

하였다. 그림 3은 개별 연결성 변형에 따른 잠재표현 변화의 크기를 MSE로 정량화한 결과이다. 각 연결성 변화가 잠재벡터에 미치는 영향(MSE)은 연결성 마다 상이하게 나타났으며, 이는 GAE가 특정 연결성에 더 민감하게 반응함을 시사한다.

또한 MSE 증가를 가장 크게 유도한 상위 10개 기능적 연결성을 그림 4와 표 3에 제시하였다. 해당 연결성들은 GAE가 연결성의 구조적 패턴을 잠재공간에 투영하여 표현을 학습하는 과정에서 상대적으로 큰 기여를 한 핵심 연결성으로 해석된다.

표 3. MSE 값 상위 10개 기능적 연결성

Rank	MNI coordinate (ROI - ROI)	ROI label (ROI - ROI)
1	(60, 8, 34)- (58, -41, 20)	'dFC' -'parietal'
2	(34, -39, 65) -(51, -59, 34)	'sup parietal' -'angular gyrus'
3	(42, -46, 21) -(33, -73, -30)	'sup temporal' -'inf cerebellum'
4	(43, -43, 8) -(5, -50, 33)	'temporal' -'precuneus'
5	(40, 17, 40) -(-35, -46, 48)	'dFC' -'post parietal'
6	(-16, 29, 54) -(17, -68, 20)	'sup frontal' -'occipital'
7	(-6, 50, -1) -(-55, -44, 30)	'vmPFC' -'temporal'
8	(-25, 51, 27) -(-54, -9, 23)	'vFC' -'parietal'
9	(-11, 45, 17) -(51, -30, 5)	'vmPFC' -'temporal'
10	(42, 48, -3) -(-4, -31, -4)	'vent aPFC' -'post cingulate'

MNI coordinate: x, y, z coordinate of Montreal Neurological Institute. ROI label: dFC, dorsal Frontal Cortex. parietal, parietal lobe. sup parietal, superior parietal lobule. angular gyrus, angular gyrus. sup temporal, superior temporal gyrus. inf cerebellum, inferior cerebellum. temporal, temporal gyrus. precuneus, precuneus. post parietal, posterior parietal cortex. sup frontal, superior frontal gyrus. occipital, occipital lobe. vmPFC, ventromedial Prefrontal Cortex. vFC, ventral Frontal Cortex.

3. 임상척도와 주요 뇌 연결성 간 상관관계

그림 4에 제시된 MDD 환자의 주요 기능적 연결성에 대해 임상 증상과의 관련성을 검증하기 위해, HAM-D 17문항 점수와와의 상관관계 분석을 수행하였다. 그 결과 HAM-D 9번(초조, agitation)과

HAM-D 10번(정신적 불안, psychic anxiety) 문항에서 통계적으로 유의한 상관관계가 확인되었다.

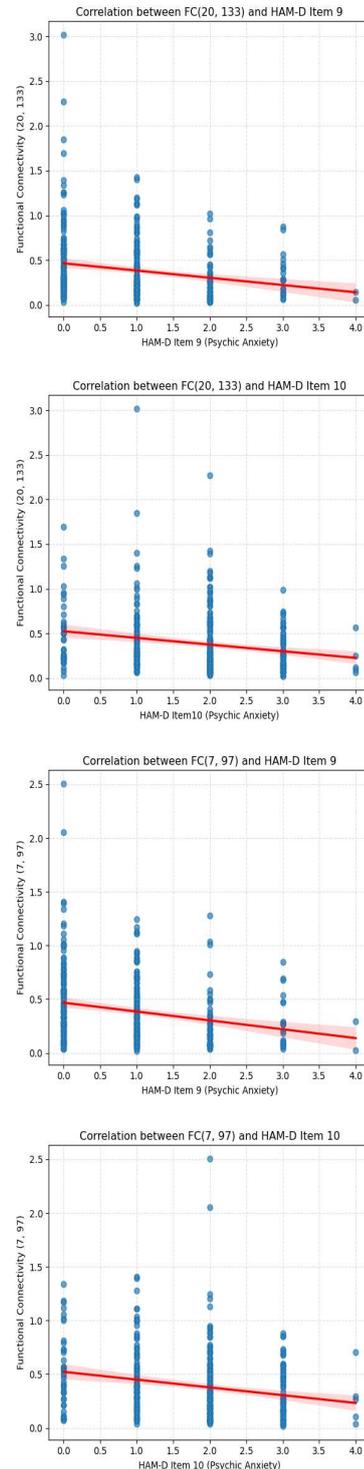


그림 4. 도출된 기능적 연결성과 HAM-D 문항 간 유의한 상관관계 산점도

HAM-D 9번 문항은 superior frontal - occipital

연결($r = -0.205, p < 0.001$) 및 vmPFC - temporal 연결($r = -0.229, p < 0.001$)에서 유의한 음의 상관을 보였다. HAM-D 10번 문항 역시 superior frontal - occipital 연결($r = -0.202, p < 0.001$)과 vmPFC - temporal 연결($r = -0.215, p < 0.001$)에서 유의한 음의 상관관계를 나타냈다.

이러한 결과는 MDD 환자에서 전전두엽(prefrontal cortex), 측두엽(temporal lobe), 후두엽(occipital lobe) 간 기능적 연결성이 초조 및 불안 증상과 연관됨을 시사한다. 즉, 해당 연결성의 값이 증가할수록 초조 및 정신적 불안의 정도가 감소하는 경향(약한 음의 상관)이 나타난다고 해석할 수 있다.

IV. 논의 및 결론

본 연구는 대규모 rs-fMRI 데이터에서 기능적 연결성 인접행렬을 구성한 뒤, GAE를 활용하여 MDD 환자의 뇌 네트워크 패턴을 비지도 학습으로 저차원 잠재표현 z 를 학습하고, 모델의 잠재표현 변화에 민감한 핵심 연결성을 도출하였다. 특히 12,720개의 ROI-ROI 연결성에 대해 단일 연결을 변형하는 민감도 분석을 수행함으로써, 모델이 어떤 연결성에 가장 민감하게 반응하는가를 정량적으로 평가했다는 점에서, 전통적인 집단 비교나 단변량 기능적 연결성 분석과 구별되는 모델 기반 특징을 추출하였다.

모델 학습 결과, 레이어 3개 및 잠재 차원 $z=16$ 조합이 가장 안정적이고 효율적인 성능을 보여 최적 모델로 선정되었다. 이는 과도하게 낮은 차원에서는 복잡한 기능적 연결성 패턴을 충분히 표현하기 어렵고, 반대로 지나치게 높은 차원 또는 깊은 레이어는 데이터의 잡음이나 사이트 변이를 과적합하여 학습 안정성이 저하될 수 있음을 보여준다.

민감도 분석을 통해 도출된 상위 10개 핵심 기능적 연결성은 전전두엽(dFC/vmPFC/vFC/vent aPFC), 두정엽(parietal/post parietal/superior parietal/angular gyrus), 측두엽(temporal/superior temporal), 후두엽(occipital) 등 다양한 뇌 영역 간

연결을 포함하였다. 이는 MDD에서 흔히 보고되는 전전두피질(vmPFC, vFC)와 후대상피질(precuneus) 기반의 인지 조절 회로(Default Mode Network, DMN)의 자기참조 처리[14, 15], 그리고 측두엽(temporal) 기반의 살리언스 감지/전환 회로(Cingulo-Opercular Network, CON)와의 상호작용 이상[16-18]이 모델 관점에서도 중요한 구조적 단서로 작동했음을 시사한다. 특히 DMN- CON 등 네트워크 간 연결성에 포함된 점은, MDD에서 정서·인지 상태 전환의 비효율성(예: 반추, 과각성/불안)이 뇌 네트워크 수준에서 반영될 가능성과 부합한다.

임상척도와의 관련성 분석에서는, 상위 10개 핵심 연결성 가운데 superior frontal - occipital 및 vmPFC - temporal 연결이 HAM-D 9번(초조)과 HAM-D 10번(정신적 불안) 점수와 유의한 음의 상관을 보였다. 이는 전전두엽(prefrontal)과 측두엽(temporal), 후두엽(occipital) 간 기능적 결합이 강화될수록 불안·초조 증상이 낮아지는 경향을 시사한다[19, 20]. 기능적으로 해석하면, (1) vmPFC - temporal 연결은 정서적 의미 부여와 기억·정서 처리(측두엽/변연계 연관 영역) 간 조절과 관련될 수 있으며, (2) superior frontal - occipital 연결은 상위 인지 조절(전두)과 시각/감각 처리(후두) 간 top-down 조절 효율과 연관될 수 있다[21, 22]. 즉, 불안·초조가 높을수록 전전두엽 기반 조절 회로가 감각/정서 처리 영역을 충분히 안정화하지 못하는 네트워크 상태가 나타날 수 있으며, 본 연구의 결과는 이를 기능적 연결성 수준에서 간접적으로 뒷받침한다.

본 연구의 결과를 해석함에 있어 몇 가지 한계를 고려할 필요가 있다. 첫째, 본 연구는 횡단면 데이터에 기반하므로 시간에 따른 뇌 변화와 질병 경과, 치료 반응 및 예후 예측과 같은 종단적 질문을 직접적으로 다루지 못하였다. 둘째, 상위 핵심 연결성 일부가 임상 척도와 통계적으로 유의한 상관을 보였으나 효과 크기가 크지 않아, 임상적으로 즉시 활용 가능한 바이오마커로 일반화하기에는 추가적인 재

현 및 검증 연구가 요구된다. 마지막으로, 본 연구는 환자 집단 내 연속적인 신경생물학적 변이를 탐색하는 데 초점을 두었기 때문에 재현 가능한 하위 유형(subtype)을 직접적으로 제시하지는 못하였다. 향후 연구에서는 더 큰 표본과 종단 자료를 활용하고, 독립 코호트에서 외부 검증을 수행하는 한편, 다양한 임상·행동 지표를 통합한 분석을 통해 본 연구에서 관찰된 뇌 연결성-증상 연관성을 보다 정교하게 확장할 필요가 있다.

본 연구는 대규모 rs-fMRI 데이터를 그래프 기반 모델로 저차원으로 특징을 추출하고, 민감도 분석을 통해 MDD와 관련된 핵심 뇌 연결성을 정량적으로 도출하였다. 또한 도출된 핵심 연결성이 불안·초조 증상과 유의한 관련을 확인함으로써, 기능적 연결성 수준에서의 바이오마커 활용 가능성을 제시하였다.

REFERENCES

- [1] American Psychiatric Association, *Diagnostic and Statistical Manual of Mental Disorders, Fifth Edition (DSM-5)*, American Psychiatric Publishing, 2013.
- [2] Regier, D. A., Narrow, W. E., Clarke, D. E., et al., "DSM-5 Field Trials," *American Journal of Psychiatry*, vol. 170, no. 1, pp. 1 - 11, 2013.
- [3] Drysdale, A. T., et al., "Resting-state connectivity biomarkers define neurophysiological subtypes of depression," *Nature Medicine*, vol. 23, no. 1, pp. 28 - 38, 2017.
- [4] Woo, C. W., Chang, L. J., Lindquist, M. A., Wager, T. D., "Building better biomarkers: Brain models in translational neuroimaging," *Nature Neuroscience*, vol. 20, no. 3, pp. 365 - 377, 2017.
- [5] Bzdok, D., & Meyer-Lindenberg, A. (2018). Machine learning for precision psychiatry: opportunities and challenges. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, vol. 3, no. 3, pp. 223-230.
- [6] Chan, Y. H., Girish, D., Gupta, S., Xia, J., Kasi, C., He, Y., ... & Rajapakse, J. C. (2025). Discovering robust biomarkers of psychiatric disorders from resting-state functional MRI via graph neural networks: A systematic review. *NeuroImage*, 121422.
- [7] Noman, Fuad, et al. "Graph autoencoders for embedding learning in brain networks and major depressive disorder identification." *IEEE journal of biomedical and health informatics* vol. 28, no. 3, pp. 1644-1655, 2024.
- [8] Chen, X., et al., "The DIRECT consortium and the REST-meta-MDD project: Towards neuroimaging biomarkers of major depressive disorder," *Psychoradiology*, vol. 2, no. 4, pp. 234 - 242, 2022.
- [9] Yan, C.-G., Zang, Y.-F., "DPARF: A MATLAB toolbox for 'pipeline' data analysis of resting-state fMRI," *Frontiers in Systems Neuroscience*, vol. 4, article 13, 2010.
- [10] Dosenbach, N. U. F., et al., "Prediction of individual brain maturity using fMRI," *Science*, vol. 329, no. 5997, pp. 1358 - 1361, 2010.
- [11] Liu, M., Zhang, Z., Dunson, D. B., "Graph auto-encoding brain networks with applications to analyzing large-scale brain imaging datasets," *NeuroImage*, vol. 227, article 117683, 2021.
- [12] Hinton, G. E., Salakhutdinov, R. R., "Reducing the dimensionality of data with neural networks," *Science*, vol. 313, no. 5786, pp. 504 - 507, 2006.
- [13] Kingma, D. P., Welling, M., "Auto-Encoding Variational Bayes," *Proceedings of the International Conference on Learning Representations (ICLR)*, pp. 1 - 14, San Diego, USA, 2014.
- [14] Sheline, Y. I., Barch, D. M., Price, J. L., Rundle, M. M., Vaishnavi, S. N., Snyder, A. Z., Mintun, M. A., Raichle, M. E., "The default mode network and self-referential processes in depression," *Proceedings of the National Academy of Sciences of the United States of America*, vol. 106, no. 6, pp. 1942 - 1947, 2009.
- [15] Hamilton, J. P., Furman, D. J., Chang, C., Thomason, M. E., Dennis, E., Gotlib, I. H., "Default-mode and task-positive network activity in major depressive disorder: Implications for adaptive and maladaptive rumination," *Biological Psychiatry*, vol. 70, no. 4, pp. 327 - 333, 2011.
- [16] Dosenbach, N. U. F., Fair, D. A., Cohen, A. L., Schlaggar, B. L., Petersen, S. E., "A dual-networks architecture of top-down control," *Trends in Cognitive Sciences*, vol. 12, no. 3, pp. 99 - 105, 2008.
- [17] Menon, V., Uddin, L. Q., "Saliency, switching, attention and control: A network model of insula function," *Brain Structure and Function*, vol. 214, no. 5 - 6, pp. 655 - 667, 2010.
- [18] Kaiser, R. H., Andrews-Hanna, J. R., Wager, T. D., Pizzagalli, D. A., "Large-scale network dysfunction in major depressive disorder: A meta-analysis of resting-state functional connectivity," *JAMA Psychiatry*, vol. 72, no. 6, pp. 603 - 611, 2015.
- [19] Etkin, Amit, Tobias Egner, and Raffael Kalisch. "Emotional processing in anterior cingulate and medial prefrontal cortex." *Trends in cognitive sciences*, vol. 15, no. 2, pp. 85-93. 2011.
- [20] Hiser, Jaryd, and Michael Koenigs. "The multifaceted role of the ventromedial prefrontal cortex in emotion, decision making, social cognition, and psychopathology." *Biological psychiatry*, vol. 83, no. 8, pp. 638-647, 2018.
- [21] Ding, Jurong, et al. "Disrupted functional connectivity

in social anxiety disorder: a resting-state fMRI study." *Magnetic resonance imaging*, vol. 29, no. 5, pp. 701-711, 2011.

- [22] Zhu, Xueling, et al. "Evidence of a dissociation pattern in resting-state default mode network connectivity in first-episode, treatment-naive major depression patients." *Biological psychiatry*, vol. 71, no. 7, pp. 611-617, 2012.

저 자 소 개



김예은(준회원)

2023년 국립군산대학교 정보통신공학
인공지능융합전공 학사 졸업.
2026년 국립군산대학교 전자정보공학
부 정보통신전파공학전공 석
사 졸업.

<주관심분야 : 인공지능, 머신러닝, 뇌인지과학>



배한별(정회원)

2010년 연세대학교 컴퓨터정보통신공
학과, 전기전자공학과 학사 졸
업.
2015년 연세대학교 생체인식 협동과
정 석사 졸업.
2020년 연세대학교 전기전자공학과
박사 졸업.

<주관심분야 : 머신러닝, 패턴인식, 컴퓨터비전 등>



조한규(정회원)

2007년 국립공주대학교 컴퓨터정보통
신공학부 학사 졸업.
2009년 연세대학교 의료정보 석사 졸
업.
2014년 비아드리나대학교 뇌인지과학
박사 졸업.

<주관심분야 : 인공지능, 디지털 헬스, 뇌인지과학 등>