(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0017380
(43) 공개일자 2025년02월04일

(51) 국제특허분류(Int. Cl.)
G16H 50/20 (2018.01) *A61B 5/055* (2006.01)
A61B 5/16 (2006.01) *G06N 3/044* (2023.01)
G06N 3/08 (2023.01) *G06V 10/25* (2022.01)
G06V 10/82 (2022.01) *G06V 20/69* (2022.01)
G16H 30/20 (2018.01) *G16H 30/40* (2018.01)
G16H 50/50 (2018.01)
(52) CPC특허분류
G16H 50/20 (2018.01)
A61B 5/055 (2022.01)
(21) 출원번호 10-2023-0098026
(22) 출원일자 2023년07월27일
심사청구일자 2023년07월27일

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
감태의
서울특별시 성북구 동소문로44길 17, 101동 1805호
이덕중
경기도 의왕시 흥안대로456번길 125, 105동 810호
(74) 대리인
김준석, 박민욱

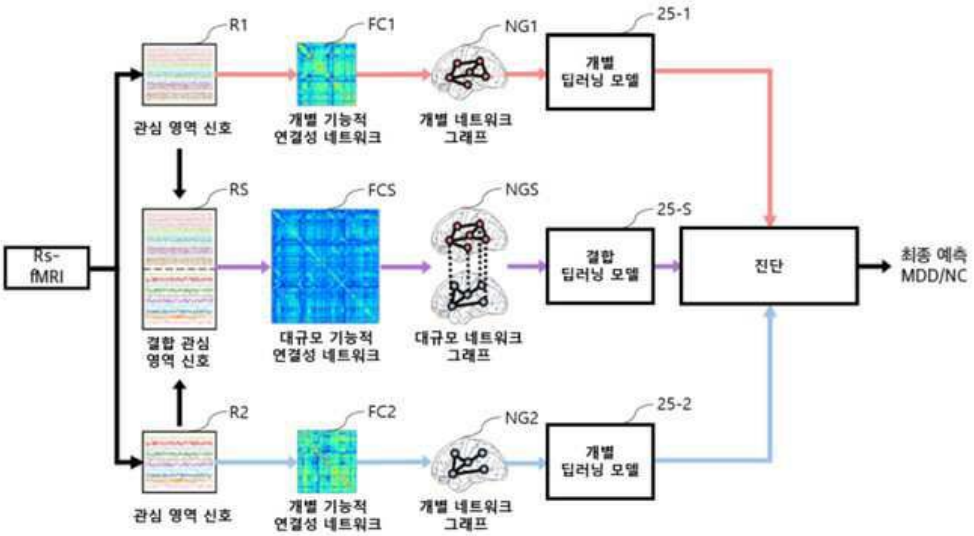
전체 청구항 수 : 총 16 항

(54) 발명의 명칭 **딥러닝 모델을 이용한 주요우울장애 진단 장치 및 방법**

(57) 요 약

본 발명은 딥러닝 모델을 이용한 주요우울장애 진단 장치에 관한 것으로, Rs-fMRI 데이터를 전처리하는 전처리부, 전처리된 Rs-fMRI 데이터에서 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출하는 신호 추출부, 복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호를 산출하는 신호 결합부, 결합 관심 영역 신호에 기초하여 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 포함하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크를 생성하는 네트워크 생성부, 대규모 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 대규모 네트워크 그래프를 생성하는 그래프 생성부, 대규모 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 학습된 그래프 신경망 기반의 결합 딥러닝 모델 및 결합 딥러닝 모델을 통해 주요우울장애 여부를 진단하는 진단부를 포함할 수 있다.

대 표 도 - 도1



(52) CPC특허분류
A61B 5/165 (2013.01)
G06N 3/044 (2023.01)
G06N 3/08 (2023.01)
G06V 10/25 (2023.08)
G06V 10/82 (2022.01)
G06V 20/695 (2022.01)
G16H 30/20 (2018.01)
G16H 30/40 (2018.01)
G16H 50/50 (2018.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711193973
과제번호	2019-0-00079-005
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성
연구과제명	인공지능대학원지원(고려대학교)
기 여 율	100/100
과제수행기관명	고려대학교산학협력단
연구기간	2023.01.01 ~ 2023.12.31

명 세 서

청구범위

청구항 1

딥러닝 모델을 이용한 주요우울장애 진단 장치에 관한 것으로,

Rs-fMRI 데이터를 전처리하는 전처리부;

전처리된 상기 Rs-fMRI 데이터에서 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출하는 신호 추출부;

상기 복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호를 산출하는 신호 결합부;

상기 결합 관심 영역 신호에 기초하여 상기 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 포함하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크를 생성하는 네트워크 생성부;

상기 대규모 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 대규모 네트워크 그래프를 생성하는 그래프 생성부;

상기 대규모 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 학습된 그래프 신경망 기반의 결합 딥러닝 모델; 및

상기 결합 딥러닝 모델을 통해 주요우울장애 여부를 진단하는 진단부; 를 포함하는

주요우울장애 진단 장치.

청구항 2

제1항에 있어서,

상기 네트워크 생성부는,

N개의 상기 서로 다른 아틀라스를 이용하는 경우, 상기 대규모 기능적 연결성 네트워크를 NxN영역으로 나누어 구분하였을 때, 각 nxn영역(n은 1 내지 N)에는 각 개별 아틀라스내에 포함된 관심 영역간 상관관계를 나타내고, 이외의 영역에는 상기 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 나타내도록 상기 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 하는,

주요우울장애 진단 장치.

청구항 3

제1항에 있어서,

상기 네트워크 생성부는,

상기 결합 관심 영역 신호값간의 관계를 피어슨 상관계수를 적용하여 상기 관심 영역간 상관관계를 정량화하여 상기 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 하는

주요우울장애 진단 장치.

청구항 4

제1항에 있어서,

상기 그래프 생성부는,

개별 아틀라스내에 포함된 관심 영역간 상관관계는 인트라 엣지(intra edge)로, 서로 다른 아틀라스에 포함된 관심 영역간 상관관계는 인터 엣지(inter edge)로 구분하여 상기 대규모 네트워크 그래프를 생성하는 것을 특징으로 하는

주요우울장애 진단 장치.

청구항 5

제1항에 있어서,

상기 신호 결합부는,

상기 관심 영역 신호를 행 방향으로 결합하여 상기 결합 관심 영역 신호를 산출하는 것을 특징으로 하는

주요우울장애 진단 장치.

청구항 6

제1항에 있어서,

그래프 신경망 기반의 개별 딥러닝 모델; 을 더 포함하여,

상기 네트워크 생성부는,

상기 관심 영역 신호에 기초하여 관심 영역간 상관관계를 나타내는 개별 기능적 연결성 네트워크를 더 생성하고,

상기 그래프 생성부는,

상기 개별 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 개별 네트워크 그래프를 더 생성하고,

상기 개별 딥러닝 모델은,

상기 개별 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 학습되고,

상기 진단부는,

상기 결합 딥러닝 모델의 진단 결과 및 상기 개별 딥러닝 모델의 진단 결과에 소프트 보팅을 적용하여 후기 융합을 통해 주요우울장애를 진단하는 것을 특징으로 하는,

주요우울장애 진단 장치.

청구항 7

제1항에 있어서,

상기 신호 추출부는,

상기 복수의 서로 다른 아틀라스의 각 영역에서 발생하는 신호의 평균값을 해당 영역의 신호로 하여 상기 관심 영역 신호를 추출하는 것을 특징으로 하는

주요우울장애 진단 장치.

청구항 8

제1항에 있어서,

상기 전처리부는,

머리 움직임 교정, 공간 정규화, 스무딩 및 밴드 패스 중 하나 이상의 전처리 기법을 수행하는 것을 특징으로 하는

주요우울장애 진단 장치.

청구항 9

딥러닝 모델을 이용한 주요우울장애 진단 방법에 관한 것으로,

Rs-fMRI 데이터를 전처리하는 단계;

전처리된 상기 Rs-fMRI 데이터에서 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출하는

단계;

상기 복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호를 산출하는 단계;

상기 결합 관심 영역 신호에 기초하여 상기 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 포함하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크를 생성하는 단계;

상기 대규모 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 대규모 네트워크 그래프를 생성하는 단계;

상기 대규모 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 그래프 신경망 기반의 결합 딥러닝 모델을 학습시키는 단계; 및

상기 결합 딥러닝 모델을 통해 주요우울장애 여부를 진단하는 단계; 를 포함하는

주요우울장애 진단 방법.

청구항 10

제9항에 있어서,

상기 대규모 기능적 연결성 네트워크를 생성하는 단계는,

N개의 상기 서로 다른 아틀라스를 이용하는 경우, 상기 대규모 기능적 연결성 네트워크를 NxN영역으로 나누어 구분하였을 때, 각 nxn영역(n은 1 내지 N)에는 각 개별 아틀라스내에 포함된 관심 영역간 상관관계를 나타내고, 이외의 영역에는 상기 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 나타내도록 상기 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 하는,

주요우울장애 진단 방법.

청구항 11

제9항에 있어서,

상기 기능적 연결성 네트워크를 생성하는 단계는,

상기 결합 관심 영역 신호값간의 관계를 피어슨 상관계수를 적용하여 상기 관심 영역간 상관관계를 정량화하여 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 하는,

주요우울장애 진단 방법.

청구항 12

제9항에 있어서,

상기 대규모 네트워크 그래프를 생성하는 단계는,

개별 아틀라스내에 포함된 관심 영역간 상관관계는 인트라 엣지(intra edge)로, 서로 다른 아틀라스에 포함된 관심 영역간 상관관계는 인터 엣지(inter edge)로 구분하여 상기 네트워크 그래프를 생성하는 것을 특징으로 하는

주요우울장애 진단 방법.

청구항 13

제9항에 있어서,

상기 결합 관심 영역 신호를 산출하는 단계는,

상기 관심 영역 신호를 행 방향으로 결합하여 상기 결합 관심 영역 신호를 산출하는 것을 특징으로 하는

주요우울장애 진단 방법.

청구항 14

제9항에 있어서,

상기 관심 영역 신호에 기초하여 관심 영역간 상관관계를 나타내는 개별 기능적 연결성 네트워크를 생성하는 단계;

상기 개별 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 개별 네트워크 그래프를 생성하는 단계;

상기 개별 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 그래프 신경망 기반의 개별 딥러닝 모델을 학습시키는 단계; 및

상기 결합 딥러닝 모델의 진단 결과 및 상기 개별 딥러닝 모델의 진단 결과에 소프트 보팅을 적용하여 후기 융합을 통해 주요우울장애를 진단하는 단계를 더 포함하는

주요우울장애 진단 방법.

청구항 15

제9항에 있어서,

상기 관심 영역 신호를 추출하는 단계는,

상기 복수의 서로 다른 아틀라스의 각 영역에서 발생하는 신호의 평균값을 해당 영역의 신호로 하여 상기 관심 영역 신호를 추출하는 것을 특징으로 하는

주요우울장애 진단 방법.

청구항 16

제9항에 있어서,

상기 데이터를 전처리하는 단계는,

머리 움직임 교정, 공간 정규화, 스무딩 및 밴드 패스 중 하나 이상의 전처리 기법을 수행하는 것을 특징으로 하는

주요우울장애 진단 방법.

발명의 설명

기 술 분 야

[0001] 주요우울장애를 진단하는 장치 및 방법에 관한 것으로, Rs-fMRI 데이터에 기초하여 복수의 뇌 아틀라스에서의 관심 영역 신호를 추출, 초기 융합하고, 딥러닝을 통해 주요우울장애를 진단하는 장치 및 방법에 관한 것이다.

배 경 기 술

[0002] 주요우울장애란 기분 좋은 감정이나 흥미의 상실, 무쾌감, 무가치감 및 의욕 저하 등을 동반하여, 자신의 감정을 조절하는데 결함이 있는 신경정신질환을 의미한다. 주요우울장애와 같은 신경질환의 경우 뇌의 특정 지역간 상호 작용에 의해 발생하는 경우가 많으므로, 이러한 뇌의 지역간 상호 작용을 측정하고 패턴을 분석하는 것은 주요우울장애의 진단에 있어 많은 도움이 될 수 있다.

[0003] 휴식 상태 기능적 자기 공명 영상(Resting-state functional Magnetic Resonance Imaging, 이하 Rs-fMRI)은 피험자가 아무런 특정 작업을 수행하지 않는 휴식 상태에 있을 때의 뇌의 활동을 측정하는 방법으로, 뇌의 특정 부분에서의 혈류 변화를 감지하여 시각화하는 비침습적인 의료영상 기법이다. Rs-fMRI는 신호 기반의 뇌의 기능적인 활동을 측정할 수 있어 피험자의 뇌기능과 장애를 연구하는데 활용될 수 있으며, 전술한 주요우울장애와 같은 신경질환을 진단하는데 중요한 역할을 할 수 있다.

[0004] Rs-fMRI를 활용하여 주요우울장애를 진단하기 위한 여러 연구에서는, 뇌의 영역을 일 기준에 의해 구분한 아틀라스(atlas) 템플릿을 이용하여, Rs-fMRI로 각 영역의 활성화 정도를 파악하고 영역간 관련성을 통하여 병을 진

단하고자 하는 시도들이 있었다.

[0005] 다만, 기존의 방법들은 하나의 특정 아틀라스만을 사용함으로써 생성된 단일 크기의 뇌 영역간 상호작용 패턴 분석만을 분석하고 있어, 한정적인 분석이 되는 단점이 있었다. 이는 더 복잡한 뇌 영역간 상호작용이 고려되지 못해, 보다 여러 기준으로 분할될 수 있는 뇌 영역간 잠재적인 연결 정보를 활용한지 못한다는 문제가 있다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) 한국공개특허 제10-2021-0059272호(2021.05.25)

발명의 내용

해결하려는 과제

[0007] 본 발명은 Rs-fMRI 및 복수의 아틀라스를 사용하여 추출된 복수의 관심 영역 신호를 초기 융합하여 딥러닝 모델의 입력 데이터로 활용함으로써, 기존의 주요우울장애 진단 장치 및 방법에 비하여 더 일반화되고 강건한 진단 장치 및 방법을 제공하고자 한다.

과제의 해결 수단

[0008] 본 발명의 일 실시예는 딥러닝 모델을 이용한 주요우울장애 진단 장치에 관한 것으로, Rs-fMRI 데이터를 전처리하는 전처리부, 전처리된 Rs-fMRI 데이터에서 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출하는 신호 추출부, 복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호를 산출하는 신호 결합부, 결합 관심 영역 신호에 기초하여 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 포함하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크를 생성하는 네트워크 생성부, 대규모 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 대규모 네트워크 그래프를 생성하는 그래프 생성부, 대규모 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 학습된 그래프 신경망 기반의 결합 딥러닝 모델 및 결합 딥러닝 모델을 통해 주요우울장애 여부를 진단하는 진단부를 포함할 수 있다.

[0009] 또한, 일 실시예에 따라서, 네트워크 생성부는, N개의 서로 다른 아틀라스를 이용하는 경우, 대규모 기능적 연결성 네트워크를 NxN 영역으로 나누어 구분하였을 때, 각 nxn영역(n은 1 내지 N)에는 각 개별 아틀라스내에 포함된 관심 영역간 상관관계를 나타내고, 이외의 영역에는 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 나타내도록 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 할 수 있다.

[0010] 또한, 일 실시예에 따라서, 네트워크 생성부는, 결합 관심 영역 신호값간의 관계를 피어슨 상관계수를 적용하여 관심 영역간 상관관계를 정량화하여 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 할 수 있다.

[0011] 또한, 일 실시예에 따라서, 그래프 생성부는, 개별 아틀라스내에 포함된 관심 영역간 상관관계는 인트라 엣지(intra edge)로, 서로 다른 아틀라스에 포함된 관심 영역간 상관관계는 인터 엣지(inter edge)로 구분하여 대규모 네트워크 그래프를 생성하는 것을 특징으로 할 수 있다.

[0012] 또한, 일 실시예에 따라서, 신호 결합부는, 관심 영역 신호를 행 방향으로 결합하여 결합 관심 영역 신호를 산출하는 것을 특징으로 할 수 있다.

[0013] 또한, 일 실시예에 따라서, 그래프 신경망 기반의 개별 딥러닝 모델을 더 포함하여, 네트워크 생성부는, 관심 영역 신호에 기초하여 관심 영역간 상관관계를 나타내는 개별 기능적 연결성 네트워크를 더 생성하고, 그래프 생성부는, 개별 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 개별 네트워크 그래프를 더 생성하고, 개별 딥러닝 모델은, 개별 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 학습되고, 진단부는, 결합 딥러닝 모델의 진단 결과 및 개별 딥러닝 모델의 진단 결과에 소프트 보팅을 적용하여 후기 융합을 통해 주요우울장애를 진단하는 것을 특징으로 할 수 있다.

[0014] 또한, 일 실시예에 따라서, 신호 추출부는, 복수의 서로 다른 아틀라스의 각 영역에서 발생하는 신호의 평균값을 해당 영역의 신호로 하여 관심 영역 신호를 추출하는 것을 특징으로 할 수 있다.

[0015] 또한, 일 실시예에 따라서, 전처리부는, 머리 움직임 교정, 공간 정규화, 스무딩 및 밴드 패스 중 하나 이상의

전처리 기법을 수행하는 것을 특징으로 할 수 있다.

[0016] 본 발명의 또 다른 실시예는 딥러닝 모델을 이용한 주요우울장애 진단 방법에 관한 것으로, Rs-fMRI 데이터를 전처리하는 단계, 전처리된 Rs-fMRI 데이터에서 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출하는 단계, 복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호를 산출하는 단계, 결합 관심 영역 신호에 기초하여 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 포함하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크를 생성하는 단계, 대규모 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 대규모 네트워크 그래프를 생성하는 단계, 대규모 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 그래프 신경망 기반의 결합 딥러닝 모델을 학습시키는 단계 및 결합 딥러닝 모델을 통해 주요우울장애 여부를 진단하는 단계를 포함할 수 있다.

[0017] 또한, 일 실시예에 따라서, 대규모 기능적 연결성 네트워크를 생성하는 단계는, N개의 서로 다른 아틀라스를 이용하는 경우, 대규모 기능적 연결성 네트워크를 NxN 영역으로 나누어 구분하였을 때, 각 nxn영역(n은 1 내지 N)에는 각 개별 아틀라스내에 포함된 관심 영역간 상관관계를 나타내고, 이외의 영역에는 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 나타내도록 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 할 수 있다.

[0018] 또한, 일 실시예에 따라서, 기능적 연결성 네트워크를 생성하는 단계는, 결합 관심 영역 신호값간의 관계를 피어슨 상관계수를 적용하여 관심 영역간 상관관계를 정량화하여 대규모 기능적 연결성 네트워크를 생성하는 것을 특징으로 할 수 있다.

[0019] 또한, 일 실시예에 따라서, 대규모 네트워크 그래프를 생성하는 단계는, 개별 아틀라스내에 포함된 관심 영역간 상관관계는 인트라 엣지(intra edge)로, 서로 다른 아틀라스에 포함된 관심 영역간 상관관계는 인터 엣지(inter edge)로 구분하여 네트워크 그래프를 생성하는 것을 특징으로 할 수 있다.

[0020] 또한, 일 실시예에 따라서, 결합 관심 영역 신호를 산출하는 단계는, 관심 영역 신호를 행 방향으로 결합하여 결합 관심 영역 신호를 산출하는 것을 특징으로 할 수 있다.

[0021] 또한, 일 실시예에 따라서, 관심 영역 신호에 기초하여 관심 영역간 상관관계를 나타내는 개별 기능적 연결성 네트워크를 생성하는 단계, 개별 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 개별 네트워크 그래프를 생성하는 단계, 개별 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 그래프 신경망 기반의 개별 딥러닝 모델을 학습시키는 단계 및 결합 딥러닝 모델의 진단 결과 및 개별 딥러닝 모델의 진단 결과에 소프트 보팅을 적용하여 후기 융합을 통해 주요우울장애를 진단하는 단계를 더 포함할 수 있다.

[0022] 또한, 일 실시예에 따라서, 관심 영역 신호를 추출하는 단계는, 복수의 서로 다른 아틀라스의 각 영역에서 발생하는 신호의 평균값을 해당 영역의 신호로 하여 관심 영역 신호를 추출하는 것을 특징으로 할 수 있다.

[0023] 또한, 일 실시예에 따라서, 데이터를 전처리하는 단계는, 머리 움직임 교정, 공간 정규화, 스무딩 및 밴드 패스 중 하나 이상의 전처리 기법을 수행하는 것을 특징으로 할 수 있다.

발명의 효과

[0024] 본 발명의 일 실시예에 의한 주요우울장애 진단 장치 및 방법에 따르면, 서로 다른 아틀라스를 이용하여 추출한 관심 영역 신호를 초기 융합하여 딥러닝 모델의 입력 데이터로 활용함으로써, 단일 아틀라스만을 사용한 질환 진단 방법에 비하여 잠재적인 관계 정보를 활용할 수 있어 더 유용하고 일반화된 기능 정보를 추출할 수 있다.

도면의 간단한 설명

[0025] 도 1은 일 실시예에 따른 주요우울장애 진단 장치 및 방법의 전체적인 과정에 관하여 도시한 도면이다.

도 2는 일 실시예에 따른 주요우울장애 진단 장치의 블록도이다.

도 3은 일 실시예에 따른 복수의 아틀라스를 도시한 도면이다.

도 4는 일 실시예에 따라 아틀라스별 관심 영역 신호가 추출되는 것을 도시한 도면이다.

도 5는 일 실시예에 따라 복수의 관심 영역 신호가 결합되어 결합 관심 영역 신호가 산출되는 것을 도시한 도면이다.

도 6은 일 실시예에 따라 기능적 연결성 네트워크가 생성되는 것을 도시한 도면이다.

도 7은 일 실시예에 따라 네트워크 그래프를 생성하는 것을 도시한 도면이다.

도 8은 일 실시예에 따라 본 발명의 주요우울장애 진단 장치 및 기존의 진단 장치의 성능을 비교한 표이다.

도 9는 일 실시예에 따른 주요우울장애 진단 방법의 순서도이다.

발명을 실시하기 위한 구체적인 내용

[0026] 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 후술되어 있는 실시예들을 참조하면 명확해질 것이다. 그러나 본 발명은 이하에서 개시되는 실시예들에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 수 있으며, 단지 본 실시예들은 본 발명의 개시가 완전하도록 하고, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것이며, 본 발명은 청구항의 범주에 의해 정의될 뿐이다.

[0027] 본 명세서에서 사용되는 용어에 대해 간략히 설명하고, 본 발명에 대해 구체적으로 설명하기로 한다.

[0028] 본 발명에서 사용되는 용어는 본 발명에서의 기능을 고려하면서 가능한 현재 널리 사용되는 일반적인 용어들을 선택하였으나, 이는 당 분야에 종사하는 기술자의 의도 또는 판례, 새로운 기술의 출현 등에 따라 달라질 수 있다. 또한, 특정한 경우는 출원인이 임의로 선정한 용어도 있으며, 이 경우 해당되는 발명의 설명 부분에서 상세히 그 의미를 기재할 것이다. 따라서 본 발명에서 사용되는 용어는 단순한 용어의 명칭이 아닌, 그 용어가 가지는 의미와 본 발명의 전반에 걸친 내용을 토대로 정의되어야 한다.

[0029] 명세서 전체에서 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있음을 의미한다. 또한, 명세서에서 사용되는 "부", "모듈", "유닛" 등의 용어는 적어도 하나의 기능 또는 동작을 처리하는 단위를 의미하며, 소프트웨어, FPGA 또는 ASIC과 같은 하드웨어 구성요소, 또는 소프트웨어와 하드웨어의 결합으로 구현될 수 있다. 그렇지만 "부", "모듈", "유닛" 등의 용어가 소프트웨어 또는 하드웨어에 한정되는 의미는 아니다. "부", "모듈", "유닛" 등은 어드레싱할 수 있는 저장 매체에 있도록 구성될 수도 있고 하나 또는 그 이상의 프로세서들을 재생시키도록 구성될 수도 있다. 따라서, 일 예로서 ""부", "모듈", "유닛" 등의 용어는 소프트웨어 구성요소들, 객체지향 소프트웨어 구성요소들, 클래스 구성요소들 및 태스크 구성요소들과 같은 구성요소들과, 프로세스들, 함수들, 속성들, 프로시저들, 서브루틴들, 프로그램 코드의 세그먼트들, 드라이버들, 펌웨어, 마이크로 코드, 회로, 데이터, 데이터베이스, 데이터 구조들, 테이블들, 어레이들 및 변수들을 포함한다.

[0030] 아래에서는 첨부한 도면을 참고하여 본 발명의 실시예에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다. 그리고 도면에서 본 발명을 명확하게 설명하기 위해서 설명과 관계없는 부분은 생략한다. “제1", "제2" 등과 같이 서수를 포함하는 용어는 다양한 구성 요소들을 설명하는데 사용될 수 있지만, 구성 요소들은 용어들에 의해 한정되지는 않는다. 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 본 발명의 권리 범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다. "및/또는" 이라는 용어는 복수의 관련된 항목들의 조합 또는 복수의 관련된 항목들 중의 어느 하나의 항목을 포함한다.

[0031] 본 명세서에 설명된 다양한 시스템, 장치, 저장 매체, 모듈 및 기구는 전용 연산 디바이스, 또는 하나 이상의 전용 연산 디바이스의 하나 이상의 연산 칩에서 구현될 수도 있다.

[0032] 이하, 본 발명의 뇌 관심 영역 초기 융합 기반 주요우울장애 진단 장치 및 방법에 관하여 설명하도록 한다.

[0033] 도 1은 본 발명의 주요우울장애 진단 장치 및 이에 의한 진단 방법의 전체적인 과정을 도시한 도면이다.

[0034] 도 1을 참조하여 설명하면, 본 발명의 주요우울장애 진단 장치 및 방법은 Rs-fMRI 및 복수의 서로 다른 아틀라스를 이용하여 뇌의 각 영역에서 생성되는 신호의 평균값을 계산하여 복수의 서로 다른 관심 영역 신호(R1 및 R2)를 추출할 수 있다. 또한, 주요우울장애 진단 장치 및 방법은 추출한 복수의 서로 다른 관심 영역 신호(R1 및 R2)를 초기 융합을 통해 결합시켜 결합 관심 영역 신호(RS)를 산출할 수 있다. 또한, 주요우울장애 진단 장치 및 방법은 상관계수를 이용, 관심 영역 신호(R1, R2 및 RS)에 포함된 관심 영역간 연결 강도에 기초하여 기능적 연결성 네트워크(FC1, FC2 및 FCS)를 생성할 수 있다. 또한, 주요우울장애 진단 장치 및 방법은 생성한 기능적 연결성 네트워크(FC1, FC2 및 FCS)를 기초로 네트워크 그래프(NG1, NG2 및 NGS)를 생성할 수 있다. 또한, 주요우울장애 진단 장치 및 방법은 네트워크 그래프(NG1, NG2 및 NGS)를 이용하여 딥러닝 모델(25-1, 25-2 및

25-S)을 학습시키고, 학습된 딥러닝 모델(25-1, 25-2 및 25-S)을 통해 피험자의 주요우울장애 여부를 진단할 수 있다.

[0035] 본 발명의 주요우울장애 진단 장치 및 방법에서 진단하고자 하는 주요우울장애는 흥미의 상실, 무쾌감, 무기력감, 지속적인 우울감을 동반하는 자신의 감정을 조절하는데 결함이 있는 신경정신질환일 수 있다. 본 발명의 주요 진단 목적은 우울장애를 진단하고자 하는 것이지만, 활용하는 바에 따라, 뇌의 특정 지역간 상호작용에 따라 나타나는 질병 및 영향 등을 진단하고 예측하는데 사용될 수 있다.

[0036] 도 2는 본 발명의 일 실시예에 따른 주요우울장애 진단 장치(1)의 블록도이다.

[0037] 도 2에 따르면, 본 발명의 주요우울장애 진단 장치(1)는, 입력부(10), 저장부(20), 출력부(30) 및 프로세서(40)를 포함할 수 있다. 이는 일 실시예에 의한 구성들을 예시한 것이며 필요에 따라 이외의 다른 구성을 더 포함할 수 있다. 주요우울장애 진단 장치(1)의 각 구성은 케이블, 회로선 혹은 무선통신 네트워크를 통해 일방으로 또는 쌍방으로 데이터를 전달할 수 있도록 마련될 수 있다.

[0038] 입력부(10)는 본 발명의 주요우울장애 진단 장치(1)의 동작에 필요한 명령, 데이터 및 프로그램 중 적어도 하나를 입력 받고, 이를 프로세서(40) 및/혹은 저장부(20)로 전달할 수 있다. 예를 들어, 입력부(10)는 Rs-fMRI 데이터 및/혹은 아틀라스를 입력 받을 수 있다.

[0039] Rs-fMRI(Resting state-functional Magnetic Resonance Imaging)는 휴식 상태 기능적 자기 공명 영상으로, 피험자가 아무런 특정 작업을 수행하지 않는 휴식 상태에 있을 때의 뇌 활동을 측정하는 방법으로, 뇌의 특정 부분에서의 혈류 변화를 감지하여 시각화하는 비침습적 의료영상 기법이다. Rs-fMRI 데이터는 Rs-fMRI 방법을 이용하여 획득한 데이터를 의미하여, 영상 처리된 이미지 데이터를 포함할 수 있으며, 뇌의 특정 부분에 따라 신호의 세기를 측정한 수치 데이터를 포함할 수 있다. 또한, 연속된 시간에 기초하여 촬영 및 측정된 시계열적 정보를 포함할 수 있다.

[0040] 도 3을 참조하여 아틀라스에 관하여 설명하도록 한다.

[0041] 아틀라스는 뇌를 해부학적 혹은 기능적인 측면 기반으로 여러 영역으로 분획(parcellation)한 뇌 분할 영역 지도의 템플릿을 의미할 수 있다. 뇌는 해부학적 혹은 기능적 기준으로 여러 영역으로 분할되어 구분될 수 있으며, 아틀라스는 이러한 일 기준에 따라 뇌를 여러 영역으로 구분하여 라벨링한 2차원 혹은 3차원 뇌 지도의 템플릿일 수 있다. 여기서 기준은 예시한 해부학적 및 기능적 기준에 한하지 않고 다양한 기준이 활용될 수 있다.

[0042] 도 3은 실시예에 의한 복수의 아틀라스를 도시한 도면이다. 도 3에 도시된 각 아틀라스 1 및 2(A1 및 A2)와 같이, 뇌 구조는 서로 다른 기준에 의해 여러 영역으로 나누어질 수 있다.

[0043] 저장부(20)는 명령, 데이터 또는 프로그램 등을 일시적 또는 비일시적으로 저장할 수 있다. 이러한 명령, 데이터 또는 프로그램 등은 입력부(10)를 통해 입력된 것일 수도 있다. 예를 들어, Rs-fMRI 데이터 및 아틀라스에 관한 데이터를 포함할 수 있다. 또한, 저장부(20)에 저장되는 데이터는 프로세서(40)의 처리 과정에서 생성된 것, 일례로 관심 영역 신호나 기능적 연결성 네트워크에 관한 데이터 등을 포함할 수도 있다. 저장부(20)는 프로세서(40)의 호출에 따라 저장된 데이터 등을 프로세서(40)에 제공하는 것도 가능하다. 저장부(20)는, 주기억장치 및 보조기억장치 중 적어도 하나를 포함할 수 있으며, 이들은 반도체나 자기디스크 등을 이용해 구현될 수 있다.

[0044] 또한, 저장부(20)는 딥러닝 모델을 저장할 수 있다. 딥러닝 모델은 Rs-fMRI 데이터에 기초한 정보를 통해 주요우울장애 여부를 판단할 수 있도록 학습될 수 있다. 딥러닝 모델은 그래프 신경망 네트워크(GNN, Graph Neural Network) 및/혹은 그래프 합성곱 네트워크(GCN, Graph Convolution Network)를 포함할 수 있다.

[0045] 일 실시예에 의하면, 딥러닝 모델은 목적 및 학습하는 데이터에 따라 결합 딥러닝 모델 및 개별 딥러닝 모델로 구분될 수 있다. 딥러닝 모델에 관하여는 후술하도록 한다.

[0046] 출력부(30)는 외부로 데이터나 프로그램 등을 출력할 수 있게 마련된다. 예를 들어, 출력부(30)는 후술할 네트워크 그래프나, 피험자에 대한 주요우울장애 진단 결과 등을 출력하여 사용자에게 제공하거나 다른 정보처리장치로 전송할 수도 있다. 출력부(30)는, 예를 들어, 디스플레이, 프린터 장치, 스피커 장치, 영상 출력 단자, 데이터 입출력 단자 또는 통신 모듈 등을 포함할 수 있으나, 이에 한정되는 것은 아니다.

[0047] 프로세서(40)는 입력부(10) 및 저장부(20)에서 데이터 등을 전달받을 수 있다. 또한, 프로세서(40)는 전달받은

데이터를 전처리하고, 데이터로부터 관심 영역 신호를 추출할 수 있으며, 이를 결합할 수 있다. 또한, 프로세서(40)는 관심 영역 신호로부터 기능적 연결성 네트워크를 생성할 수 있으며, 이를 기초로 네트워크 그래프를 생성할 수 있다. 또한, 프로세서(40)는 이를 활용하여 딥러닝 모델(25)을 학습시키는 등 주요우울장애를 진단하는 일련의 과정에 따른 동작을 수행할 수 있다. 프로세서(40)는 실시예에 따라 전술한 과정을 모두 수행할 수 있으며, 이 중 일부만을 수행할 수도 있다. 이들 동작의 수행을 위해 저장부(20) 등에 미리 저장된 프로그램이 이용될 수 있다. 여기서 프로그램은 설계자 등에 의해 직접 작성된 것일 수 있고, 전자소프트웨어 유통망을 통해 획득 또는 갱신된 것을 수 있다.

[0048] 실시예에 의하면, 프로세서(40)는, 중앙 처리 장치(CPU: Central Processing Unit), 그래픽 처리 장치(GPU: Graphic Processing Unit), 마이크로 컨트롤러 유닛(MCU: Micro Controller Unit), 애플리케이션 프로세서(40)(AP: Application Processor), 전자 제어 유닛(ECU: Electronic Controlling Unit), 마이컴(Micom: Micro Processor) 또는 이외 각종 연산 및 제어 처리를 수행할 수 있는 적어도 하나의 전자 장치 등을 하나 이상 포함할 수 있다. 이들 처리 또는 제어 장치는, 예를 들어, 하나 또는 둘 이상의 반도체 칩, 회로 또는 관련 부품 등을 단독으로 이용하거나 조합하여 구현된 것일 수도 있다.

[0049] 일 실시예에 의하면, 프로세서(40)는 전처리부(400), 신호 추출부(410), 신호 결합부(420), 네트워크 생성부(430), 그래프 생성부(440) 및 진단부(450)를 포함할 수 있다. 여기서, 각 구성은 물리적 및 논리적으로 구분되는 것일 수 있으며, 이들은 하나 또는 둘 이상의 처리 장치(중앙처리장치 및 그래픽처리장치 등)를 이용하여 구현될 수 있다. 실시예에 따라 프로세서(40)의 각 구성 중 일부는 생략될 수 있으며, 필요에 따라서는 전술한 구성 이외의 구성이 더 포함될 수 있다.

[0050] 전처리부(400)는 입력부(10) 및/혹은 저장부(20)로부터 전달 받은 Rs-fMRI 데이터를 전처리할 수 있다. Rs-fMRI 데이터는 개인별 차이가 심하기 때문에 데이터 분석 전, 전처리부(400)는 표준화된 의료 영상 전처리 기법을 적용하여 Rs-fMRI 데이터를 개인별로 표준화된 영상으로 전처리할 수 있다.

[0051] 전처리부(400)에서 수행될 수 있는 전처리 기법은 머리 움직임 교정(head motion correction), 공간 정규화(spatially normalization), 스무딩(smoothing) 및 밴드 패스 필터(band pass filter) 등이 포함될 수 있다. 각 과정에 관한 자세한 설명은 생략하도록 한다. 전처리부(400)에서 수행될 수 있는 전처리 기법은 예시한 것에 한정되지 않으며, 이외에도 다양한 방법이 포함될 수 있다.

[0052] 도 4를 참조하여 신호 추출부(410)에 관하여 설명하도록 한다.

[0053] 신호 추출부(410)는, 전처리된 Rs-fMRI 데이터 및 아틀라스를 이용하여 뇌의 각 영역에서 생성되는 신호의 평균값을 계산하여, 관심 영역(region of interest, ROI) 신호를 추출할 수 있다.

[0054] 또한, 신호 추출부(410)는, 복수의 서로 다른 아틀라스를 이용하여 각 아틀라스별로 관심 영역 신호를 추출할 수 있다.

[0055] 신호 추출부(410)는 전처리된 Rs-fMRI 데이터를 기초로, 아틀라스에 의해 분할된 각 영역에 포함되는 복셀(voxel) 신호 값들의 평균을 관심 영역 신호로 추출할 수 있다.

[0056] 일 실시예에 의하면, 관심 영역 신호는 각 영역별 평균 신호값이 시계열적 정보를 길이로 하여 나열된 형태로 추출될 수 있다. 이는 도 4에 예시된 관심 영역 신호(ROI signal of A1 및 ROI signal of A2)를 참조하면 명확해질 수 있다. 다만, 관심 영역 신호가 추출되는 형태는 이에 한정되는 것은 아니다.

[0057] 일 실시예에 의하면, 추출된 관심 영역 신호의 신호 개수는 해당 관심 영역 신호의 기초가 되는 아틀라스의 기분할 영역 개수와 동일할 수 있다.

[0058] 일 실시예에 의하면, 추출된 각 아틀라스별 관심 영역 신호의 길이는 동일할 수 있다. 이는 관심 영역 신호의 기초가 되는 Rs-fMRI 데이터의 신호 길이가 동일하기 때문일 수 있다.

[0059] 도 4는 일 실시예에 따라 신호 추출부(410)에서 전처리된 Rs-fMRI 데이터 및 서로 다른 두개의 아틀라스(A1 및 A2)를 이용하여 각 아틀라스별 관심 영역 신호(ROI signal of A1 및 ROI signal of A2)가 추출되는 것을 도시한 도면이다. 도 4의 예시에 따르면, Rs-fMRI 데이터의 신호를 서로 다른 아틀라스(A1 및 A2)의 기 분할 영역에 따라 구분한 후, 각 영역에 포함되는 복셀 신호 값들의 평균을 구하여 이를 각 아틀라스에 따른 관심 영역 신호로 추출할 수 있다. 즉, Rs-fMRI 데이터의 신호들을 아틀라스 1(A1)의 영역에 따라 분할할 뒤, 각 영역에 포함된 복셀 신호값의 평균을 계산하여 이를 해당 영역의 신호값으로 하는 과정을 통해 아틀라스 1의 관심 영역 신호(ROI signal of A1)를 추출할 수 있다. 마찬가지로, 동일한 Rs-fMRI 데이터의 신호들을 아틀라스 2(A2)의 영

역에 따라 분할한 뒤, 각 영역에 포함된 복셀 신호값의 평균을 계산하여 이를 해당 영역의 신호값으로 하는 과정을 통해 아틀라스 2의 관심 영역 신호(ROI signal of A2)를 추출할 수 있다.

[0060] 도 5를 참조하여 신호 결합부(420)에 관하여 설명하도록 한다.

[0061] 신호 결합부(420)는, 앞서 신호 추출부(410)에서 추출한 각 아틀라스에 따른 관심 영역 신호를 하나로 결합하여 결합 관심 영역 신호를 산출할 수 있다.

[0062] 이는 여러 융합 방법 중 초기 융합(early fusion) 방식을 활용한 것으로, 딥러닝 모델(25)의 학습 데이터를 입력하기 전에 데이터를 먼저 결합시킴으로써, 다양한 아틀라스간 잠재적인 관계정보를 활용하게 하여 더 유용하고 일반화된 기능 정보를 추출할 수 있도록 할 수 있다.

[0063] 신호 결합부(420)는 복수의 관심 영역 신호를 하나의 결합 관심 영역 신호로 결합할 수 있으며, 바람직하게는 2개의 관심 영역 신호를 하나의 결합 관심 영역 신호로 결합할 수 있다.

[0064] 신호 결합부(420)에서의 관심 영역 신호 결합은 신호를 융합하는데 일반적으로 사용되는 다양한 방법에 의할 수 있으며, 바람직하게는 각 관심 영역 신호가 행 방향으로 결합하는 방법에 의할 수 있다. 관심 영역 신호의 행 방향 결합은 도 5의 예시(R1, R2 및 RS)를 참조하면 명확해질 수 있다.

[0065] 신호가 행 방향으로 결합되는 경우, 이는 각 관심 영역 신호가 동일한 신호 길이를 가지기 때문에 가능할 수 있으며, 결합된 결합 관심 영역 신호는 각 아틀라스에서 추출된 관심 영역 신호의 관심 영역 개수가 더해진 만큼의 관심 영역 개수를 가질 수 있다.

[0066] 일 실시예에 의하면, 생성된 결합 관심 영역 신호는 각 관심 영역 신호의 신호 개수가 더해진 만큼의 신호 개수를 가질 수 있다. 또한, 각 관심 영역 신호의 개수는 기초가 된 아틀라스의 영역 수와 동일할 수 있기 때문에, 결합 관심 영역 신호의 신호 개수는 기초가 된 복수의 아틀라스 모두의 영역 개수를 합한 것과 동일할 수 있다.

[0067] 도 5는 신호 결합부(420)에서 복수의 서로 다른 관심 영역 신호(R1 및 R2)가 결합되어 결합 관심 영역 신호(RS)를 산출하는 것을 도시한 도면이다. 도 5의 예시에 따르면, 각 아틀라스(A1 및 A2)에 따라 추출된 관심 영역 신호(ROI signal of A1(R1) 및 ROI signal of A2(R2))가 행 방향으로 결합되어 하나의 결합 관심 영역 신호(RS)를 생성할 수 있다. 전술한 것과 같이 생성된 결합 관심 영역 신호(RS)는 각 관심 영역 신호(R1 및 R2)의 신호 개수가 더해진 만큼의 신호 개수를 가질 수 있다. 또한, 전술한 바에 따르면, 결합 관심 영역 신호(RS)의 신호 개수는 아틀라스 1 및 아틀라스 2의 영역 개수를 더한 것과 동일할 수 있다.

[0068] 도 6을 참조하여 네트워크 생성부(430)에 관하여 설명하도록 한다.

[0069] 네트워크 생성부(430)는 관심 영역 신호에 기초하여 관심 영역간 상관관계를 나타내는 기능적 연결성 네트워크를 생성할 수 있다. 네트워크 생성부(430)는 각 관심 영역간 상관관계를 기능적 연결성 네트워크로 나타냄으로써, 뇌의 분할 영역간 상호작용 관계를 정량화하여 나타낼 수 있다.

[0070] 네트워크 생성부는 관심 영역 신호에 포함된 관심 영역 신호를 행과 열로 하고, 관심 영역간 상관관계를 정량화하여 대각항을 기준으로 대칭이 되는 행렬로 기능적 연결성 네트워크를 생성할 수 있다. 즉, 기능적 연결성 네트워크는 기능적 연결성 행렬(functional connectivity matrix)이라는 대각항을 기준으로 대칭 형태를 갖는 2차원 형태의 행렬로 표현되어 각 관심 영역간 상관관계를 정량화하여 나타낼 수 있다.

[0071] 일 실시예에 의하면, 네트워크 생성부는 N개의 서로 다른 아틀라스를 이용하는 경우, 대규모 기능적 연결성 네트워크를 NxN 영역으로 나누어 구분하였을 때, 각 nxn영역(n은 1 내지 N)에는 각 개별 아틀라스내에 포함된 관심 영역간 상관관계를 나타내고, 이외의 영역에는 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 나타내도록 대규모 기능적 연결성 네트워크를 생성할 수 있다. 여기서 대규모 기능적 연결성 네트워크를 NxN 영역으로 나누어 구분한다는 것은 기능적 연결성 네트워크의 가로축 및 세로축을 각 N개씩 나누어 전체의 영역을 NxN의 개수로 나누는 것을 의미할 수 있다. 또한, 각 영역은 AxB(A 및 B는 1 내지 N) 영역으로 정의될 수 있다. 즉 대규모 기능적 연결성 네트워크는 1x1, 1x2, 1x3...1xN, 2x1, 2x2...2xN...Nx1, Nx2... NxN 과 같은 영역으로 구분될 수 있다. 여기서 각 nxn(n은 1 내지 N, 예로 1x1, 2x2, NxN 등) 영역은 대규모 기능적 연결성 네트워크의 대각항을 포함하는 영역을 의미할 수 있다. 이는 후술할 도 6의 예시에 관한 설명을 참조하면 명확해질 수 있다.

[0072] 일 실시예에 의하면, 네트워크 생성부가 대규모 기능적 연결성 네트워크를 NxN으로 영역을 구분하기 위하여 가로 및 세로축을 N개로 분할하는 경우, 각 아틀라스에 포함된 관심 영역의 개수를 기준으로 하여 분할할 수

있다. 예를 들어 설명하면, 대규모 기능적 연결성 네트워크가 6개의 관심 영역을 가진 A1 및 4개의 관심 영역을 가진 A2, 총 2개의 아틀라스에 기초하여 생성되는 경우, 대규모 기능적 연결성 네트워크의 가로축을 6:4의 비율로 분할하고, 세로축을 6:4 비율로 분할할 수 있다.

[0073] 네트워크 생성부(430)는 관심 영역 신호에 포함된 각 관심 영역 신호값간의 관계를 정량화하여 수치적으로 표현할 수 있다. 일 실시예에 의하면, 네트워크 생성부(430)는 피어슨 상관계수(pearson's correlation)를 적용하여 관심 영역 간 상관 정도를 정량화할 수 있다. 수학식 1의 피어슨 상관계수를 적용하는 경우, 추출된 관심 영역 신호값 사이의 상관 관계를 통계적 방법을 통해 -1 부터 +1 까지의 범위를 값으로 산출할 수 있으며, 이를 이용하여 각 관심 영역간 얼마나 선형적인 관계를 갖는지 측정할 수 있다.

수학식 1

[0074] $$PCC = \frac{Cov(X,Y)}{\sigma_X \sigma_Y}$$

[0075] 여기서 Cov(X,Y)는 두개의 확률 변수 X 및 Y의 선형관계를 나타내는 공분산을 구하는 식이며, σ_X 및 σ_Y는 각각 X와 Y의 표준편차를 의미한다.

[0076] 일 실시예에 의하면, 네트워크 생성부(430)는 각 개별 아틀라스에 따라 추출된 관심 영역 신호 및 이를 결합한 결합 관심 영역 신호 모두에 대하여 각 기능적 연결성 네트워크를 생성할 수 있다. 즉, 네트워크 생성부(430)는 개별 아틀라스에 따른 관심 영역 신호에 기초한 개별 기능적 연결성 네트워크를 생성할 수도 있고, 복수의 아틀라스에 따른 관심 영역 신호들을 결합한 결합 관심 영역 신호에 기초한 대규모 기능적 연결성 네트워크를 생성할 수도 있다. 이는 도 1의 예시(FC1, FC2 및 FCS)를 참조하면 명확해질 수 있다.

[0077] 도 6은 네트워크 생성부(430)에서 대규모 기능적 연결성 네트워크가 생성되는 것에 관하여 도시한 도면이다. 도 6의 예시에 따르면, 네트워크 생성부(430)는 결합 관심 영역 신호(RS)에 피어슨 상관관계를 적용하여 이에 대한 대규모 기능적 연결성 네트워크(FCS)를 생성할 수 있다. 2개의 서로 다른 관심 영역 신호(R1 및 R2)가 결합된 결합 관심 영역 신호(RS)에 기초하여 생성된 대규모 기능적 연결성 네트워크(FCS)는 대각항을 기준으로 대칭 형태의 2차원 형태의 행렬로 표현될 수 있다. 도 6의 대규모 기능적 연결성 네트워크(FCS)를 중점을 지나는 가상의 수평선(x축) 및 수직선(y축)으로 나누었다고 가정하였을 때, 2사분면에 해당하는 면에 존재하는 값은 아틀라스 1에 기초한 관심 영역 신호(R1)에 포함된 신호간 상관관계에 관한 정보를 포함하고 있을 수 있다. 반면, 4사분면에 해당하는 면에 존재하는 값은 아틀라스 2에 기초한 관심 영역 신호(R2)에 포함된 신호간 상관관계에 관한 정보를 포함하고 있을 수 있다. 또한, 1사분면 및 3사분면은 서로 대칭되어 같은 내용을 포함하고 있으며, 아틀라스 1에 기초한 관심 영역 신호(R1)와 아틀라스 2에 기초한 관심 영역 신호(R2)간 상관관계에 관한 정보를 포함하고 있을 수 있다. 즉, 대규모 기능적 연결성 네트워크를 2x2의 영역으로 분할하였을 때, 1x1의 영역(2사분면) 및 2x2의 영역(4사분면)에는 각각 아틀라스 A1내의 관심 영역간 상관관계 정보 및 아틀라스 A2내의 관심 영역간 상관관계 정보가 나타나도록 생성될 수 있다.

[0078] 도 7을 참조하여 그래프 생성부(440)에 관하여 설명하도록 한다.

[0079] 그래프 생성부(440)는 생성된 기능적 연결성 네트워크를 기초로 네트워크 그래프를 생성할 수 있다. 기능적 연결성 네트워크는 관심 영역간 상관관계 정보를 포함하고 있어, 그래프 생성부(440)는 이를 정점(node, 이하 노드) 및 방향성이 있거나 없는 간선(edge, 이하 엣지)으로 구성되어, 각 연결 관계 정보를 포함하여 구성된 네트워크 그래프를 생성할 수 있다.

[0080] 그래프 생성부(440)는 네트워크 생성부(430)와 마찬가지로, 각 개별 아틀라스에 기반한 기능적 연결성 네트워크를 기초로 개별 네트워크 그래프를 생성할 수 있고, 복수의 아틀라스에 따른 대규모 기능적 연결성 네트워크를 기초로 대규모 네트워크 그래프를 생성할 수도 있다. 이는 도 1의 예시(NG1, NG2 및 NGS)를 참조하면 명확해질 수 있다.

[0081] 그래프 생성부(440)는 대규모 네트워크 그래프를 생성하는 경우, 개별 아틀라스내에 포함된 관심 영역간 상관관계는 인트라 엣지(intra edge)로, 서로 다른 아틀라스에 포함된 관심 영역간 상관관계는 인터 엣지(inter edge)로 구분하여 대규모 네트워크 그래프를 생성할 수 있다. 이에 따라, 대규모 네트워크 그래프는 복수의 서로 다른 아틀라스에 포함된 관심 영역간 상관관계 정보를 포함하고 있을 수 있다.

[0082] 도 7은 그래프 생성부(440)에서 대규모 기능적 연결성 네트워크(FCS)를 기초로 대규모 네트워크 그래프(NG)를 생성하는 것에 관하여 도시한 도면이다. 도 7의 예시에 의하면, 그래프 생성부(440)는 각 아틀라스(A1 및 A2)에 따른 신호를 결합한 결합 관심 영역 신호(RS)에 기초하여 생성된 대규모 기능적 연결성 네트워크(FCS)에 기초하여 엣지와 노드로 구성된 대규모 네트워크 그래프(NGS)를 생성할 수 있다. 대규모 네트워크 그래프(NGS)의 기초가 된 대규모 기능적 연결성 네트워크(FCS)가 각 아틀라스에 기초한 관심 영역을 모두 포함하고 있기 때문에, 이에 기초하여 생성된 대규모 네트워크 그래프(NGS)는 개별 아틀라스에 포함된 관심 영역 간의 상관관계뿐만 아니라 타 아틀라스간 관심 영역의 상관관계 또한 고려된 정보를 포함할 수 있다.

[0083] 진단부(450)는, 학습된 딥러닝 모델을 이용하여, 주요우울장애 여부를 판단할 수 있다.

[0084] 딥러닝 모델은 전술한 바와 같이, Rs-fMRI 데이터 및 아틀라스를 기초로 하여 생성된 네트워크 그래프를 이용하여 주요우울장애 여부를 판단할 수 있도록 학습될 수 있다. 딥러닝 모델은 그래프 신경망 네트워크(GNN, Graph Neural Network) 및/혹은 그래프 합성곱 네트워크(GCN, Graph Convolution Network)를 포함할 수 있다.

[0085] 네트워크 그래프는 위상정보를 포함하고 있기 때문에, 위상정보의 효율적인 추출을 위해 딥러닝 모델은 그래프 신경망 기반의 계층 및 최종 출력단에서의 주요우울장애 분류 진단을 위한 완전 연결 계층(fully connected layer)을 포함할 수 있다. 여기서 그래프 신경망 기반 계층은 복잡한 네트워크 데이터 구조를 학습하는데 특화된 신경망으로, 수학식 2와 같이 표현될 수 있다.

수학식 2

[0086] $$H = \varphi(AXW)$$

[0087] A는 관심 지역간 이웃 연결 관계를 나타내는 adjacency matrix, W는 가중벡터, ϕ는 비선형 활성화 함수를 의미할 수 있다.

[0088] 일 실시예에 의하면, 딥러닝 모델의 개별적인 그래프 신경망을 통해 추출된 특징은 완전 연결 계층을 통과 후 주요우울장애를 분류하기 위해 소프트맥스가 적용될 수 있다.

[0089] 일 실시예에 의하면, 딥러닝 모델의 학습을 위해 소프트맥스의 예측 출력 값과 실제 정답 사이의 차이를 측정하는 교차 엔트로피 손실함수를 사용할 수 있다. 수학식 3은 사용될 수 있는 손실함수의 일 실시예이다.

수학식 3

[0090] $$L = -\sum_{i=1} y_i \log \hat{y}_i$$

[0091] 수학식 3은 딥러닝의 분류문제를 풀 때 사용되는 손실함수의 일 실시예로, y_i는 실제 정답 레이블을 의미하며, y_i^는 딥러닝 모델이 예측한 출력값을 의미할 수 있다.

[0092] 즉, 손실함수 L은 모든 피험자 데이터에 대해 정답 레이블 y_i에 log를 적용한 딥러닝 모델이 예측한 출력값을 곱하고 더해줌으로써 계산될 수 있다.

[0093] 딥러닝 모델은 기 저장된 데이터(예로, Rs-fMRI 및 아틀라스에 기초한 네트워크 그래프, 주요우울장애 여부 등)를 통해 주요우울장애와 정상 그룹을 분류할 수 있도록 학습될 수 있다.

[0094] 다시 도 1을 참조하여 개별 딥러닝 모델 및 결합 딥러닝 모델에 관하여 설명하도록 한다.

[0095] 진단부(450)는 복수의 딥러닝 모델을 활용할 수 있으며, 각 딥러닝 모델은 독립적으로 서로 다른 아틀라스에 기초한 네트워크 그래프를 통해 학습된 모델일 수 있다. 일 실시예에 의하면, 딥러닝 모델은 개별 딥러닝 모델 및 결합 딥러닝 모델을 포함하여, 개별 딥러닝 모델은 일 아틀라스에 기초하여 추출된 관심 영역 신호로부터 생성된 개별 네트워크 그래프만을 이용하여 학습될 수 있고, 결합 딥러닝 모델은 복수의 아틀라스에 기초하여 추출

된 결합 관심 영역 신호로부터 생성된 대규모 네트워크 그래프를 이용하여 학습될 수 있다. 즉, 결합 딥러닝 모델의 경우, 서로 다른 아틀라스에 포함된 관심 영역간 상관관계 정보를 포함하여 학습될 수 있다.

[0096] 도 1의 예시를 참조하면, 일 개별 딥러닝 모델(25-1)은 아틀라스 1에 기초하여 생성된 개별 네트워크 그래프(NG1)만을 통해 학습될 수 있고, 다른 일 개별 딥러닝 모델(25-2)은 아틀라스 2에 기초하여 생성된 개별 네트워크 그래프(NG2)만을 통해 학습될 수 있으며, 또 다른 일 결합 딥러닝 모델(25-S)은 결합 관심 영역 신호(RS)에 기초하여 생성된 대규모 네트워크 그래프(NGS)만을 통해 학습될 수 있다. 따라서, 각 딥러닝 모델은 각각의 학습 데이터(개별 관심 영역 신호에 기초한 네트워크 그래프 혹은 결합 관심 영역 신호에 기초한 네트워크 그래프)에 기초하여 주요우울장애 및 정상인 그룹을 구분할 수 있도록 학습된 것일 수 있다.

[0097] 일 실시예에 의하면, 진단부(450)는 각 독립적인 딥러닝 모델(25-1, 25-2 및 25-S)들에 네트워크 그래프를 입력하여 예측된 결과를 하드 보팅 및/혹은 소프트 보팅을 적용하여 후기 융합(late fusion)을 통해 주요우울장애를 진단할 수 있다.

[0098] 본 발명의 주요우울장애 진단 장치(1)는 전술한 구성을 포함하여, 기존의 진단 장치에 비하여 주요우울장애 진단에 있어 더 일반화되고 강건한 결과를 보여줄 수 있다.

[0099] 도 8은 샘플 데이터셋을 본 발명의 주요우울장애 진단 장치(1)를 통해 진단하고, 정확성을 평가한 후, 기존의 진단 장치들과 정확성을 비교한 표이다.

[0100] 도 8은 REST-meta-MDD consortium에서 제공하는 fMRI 데이터 셋을 샘플 데이터로 활용하여 정확성을 측정하였다.

[0101] 도 8에 의하면, 총 250명의 MDD 환자와 229명의 정상군 데이터로 구성된 샘플로 정확성을 평가하였을 때, 본 발명의 주요우울장애 진단 장치(1)는 ACC, SENS, SPEC 및 F1 면에서 기존의 방법에 비하여 높은 성능을 보임을 확인할 수 있다.

[0102] 도 9는 본 발명의 주요우울장애 진단 방법의 순서도이다.

[0103] 도 9에 따르면, 주요우울장애 진단 방법은 Rs-fMRI 데이터를 전처리하는 단계(S100)를 포함할 수 있다. 또한, 주요우울장애 진단 방법은 전처리된 Rs-fMRI 데이터에서 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출하는 단계(S200)를 포함할 수 있다. 또한, 주요우울장애 진단 방법은 복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호를 산출하는 단계(S300)를 포함할 수 있다. 또한, 주요우울장애 진단 방법은 결합 관심 영역 신호에 기초하여 서로 다른 아틀라스에 포함된 관심 영역간 상관관계를 포함하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크를 생성하는 단계(S400)를 포함할 수 있다. 또한, 주요우울장애 진단 방법은 대규모 기능적 연결성 네트워크에 기초하여 엣지 및 노드로 이루어진 대규모 네트워크 그래프를 생성하는 단계(S500)를 포함할 수 있다. 또한, 주요우울장애 진단 방법은 대규모 네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부를 진단하도록 결합 딥러닝 모델을 학습시키는 단계(S600)를 포함할 수 있다. 또한, 주요우울장애 진단 방법은 결합 딥러닝 모델을 통해 주요우울장애 여부를 진단하는 단계(S700)를 포함할 수 있다.

[0104] 일 실시예에 의하면, 기능적 연결성 네트워크를 생성하는 단계(S400)는, 복수의 관심 영역 신호에 기초하여 각각의 행렬의 형태로 기능적 연결성 네트워크를 생성하고, 진단하는 단계(S700)는, 결합 관심 영역 신호에 기초한 진단 결과 및 관심 영역 신호에 기초한 진단 결과에 소프트 보팅을 적용하여 후기 융합을 통해 주요우울장애를 진단하는 것을 특징으로 할 수 있다.

[0105] 일 실시예에 의하면, 관심 영역 신호를 추출하는 단계(S200)는, 복수의 서로 다른 아틀라스의 각 영역에서 생성되는 신호의 평균값을 생성함으로써 관심 영역 신호를 추출하는 것을 특징으로 할 수 있다.

[0106] 일 실시예에 의하면, 결합 관심 영역 신호를 산출(S300)하는 단계는, 관심 영역 신호를 행방향으로 결합하는 것을 특징으로 할 수 있다.

[0107] 일 실시예에 의하면, 기능적 연결성 네트워크를 생성하는 단계(S400)는, 결합 관심 영역 신호값간의 관계를 피어슨 상관계수를 적용하여 관심 영역간 상관 정도를 정량화하여 행렬로 기능적 연결성 네트워크를 생성하는 것을 특징으로 할 수 있다.

[0108] 일 실시예에 의하면, 전처리하는 단계(S100)는, 머리 움직임 교정, 공간 정규화, 스무딩 및 밴드 패스 중 하나 이상의 전처리 기법을 수행하는 것을 특징으로 할 수 있다.

[0109] 이상 딥러닝 모델을 이용한 주요우울장애 진단 장치 및 방법의 여러 실시예에 대해 설명하였으나, 주요우울장애 진단 장치 및 방법은 오직 상술한 실시예에 한정되는 것은 아니다. 해당 기술 분야에서 통상의 지식을 가진 자가 상술한 실시예를 기초로 수정 및 변형하여 구현할 수 있는 다른 다양한 장치나 방법 역시 상술한 주요우울장애 진단 장치 및 방법의 일 실시예가 될 수 있다. 예를 들어, 설명된 방법(들)이 설명된 바와 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성 요소(들)가 설명된 바와 다른 형태로 결합, 연결 또는 조합되거나 다른 구성 요소 또는 균등물 등에 의하여 대치 또는 치환되더라도, 상술한 주요우울장애 진단 장치 및/또는 진단 방법의 일 실시예가 될 수 있다.

[0110] 본원 발명의 실시예 들과 관련된 기술 분야에서 통상의 지식을 가진 자는 상기 기재의 본질적인 특성에서 벗어나지 않는 범위에서 변형된 형태로 구현될 수 있음을 이해할 수 있을 것이다. 그러므로, 개시된 방법들은 한정적인 관점이 아닌 설명적 관점에서 고려되어야 한다. 본 발명의 범위는 발명의 상세한 설명이 아닌 특허청구 범위에 나타나며, 그와 동등한 범위 내에 있는 모든 차이점은 본 발명의 범위에 포함되는 것으로 해석되어야 한다.

부호의 설명

[0111] 1: 주요우울장애 진단 장치

10: 입력부

20: 저장부

25-1, 25-2: 개별 딥러닝 모델

25-S: 결합 딥러닝 모델

30: 출력부

40: 프로세서

400: 전처리부

410: 신호 추출부

420: 신호 결합부

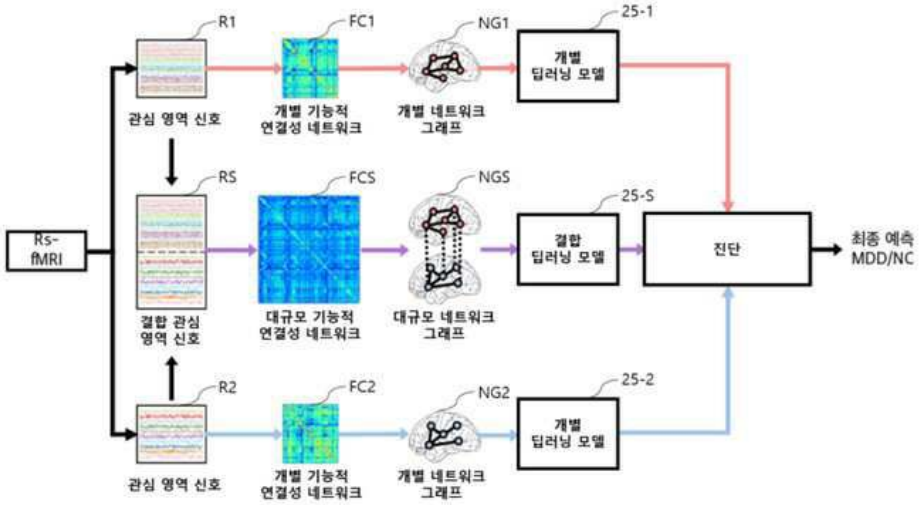
430: 네트워크 생성부

440: 그래프 생성부

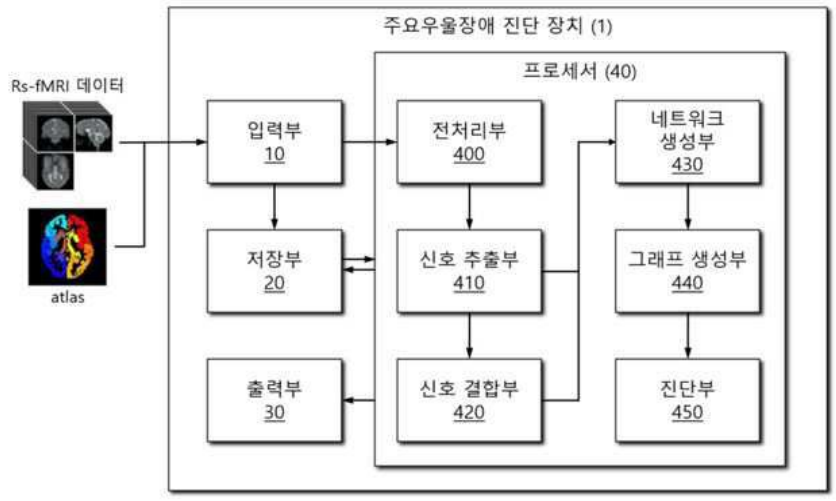
450: 진단부

도면

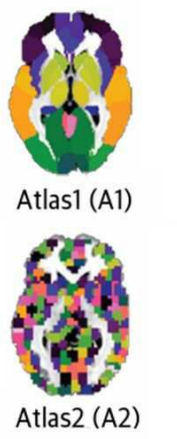
도면1


Rs-fMRI
R1
관심 영역 신호
FC1
개별 기능적 연결성 네트워크
NG1
개별 네트워크 그래프
25-1
개별 딥러닝 모델
RS
결합 관심 영역 신호
FCS
대규모 기능적 연결성 네트워크
NGS
대규모 네트워크 그래프
25-S
결합 딥러닝 모델
진단
최종 예측 MDD/NC
R2
관심 영역 신호
FC2
개별 기능적 연결성 네트워크
NG2
개별 네트워크 그래프
25-2
개별 딥러닝 모델

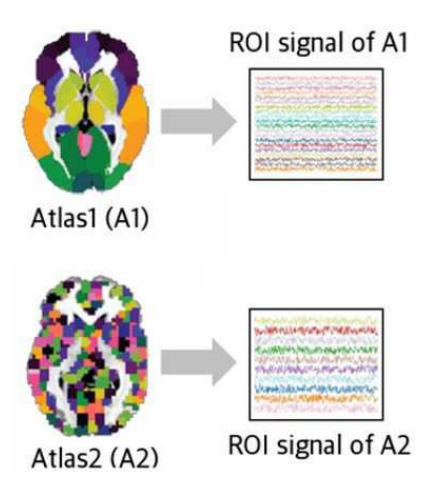
도면2


주요우울장애 진단 장치 (1)
프로세서 (40)
Rs-fMRI 데이터
atlas
입력부 10
저장부 20
출력부 30
전처리부 400
신호 추출부 410
신호 결합부 420
네트워크 생성부 430
그래프 생성부 440
진단부 450

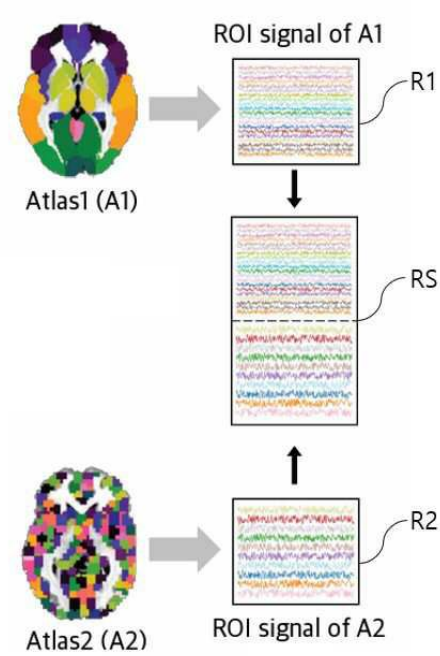
도면3


Atlas1 (A1)
Atlas2 (A2)

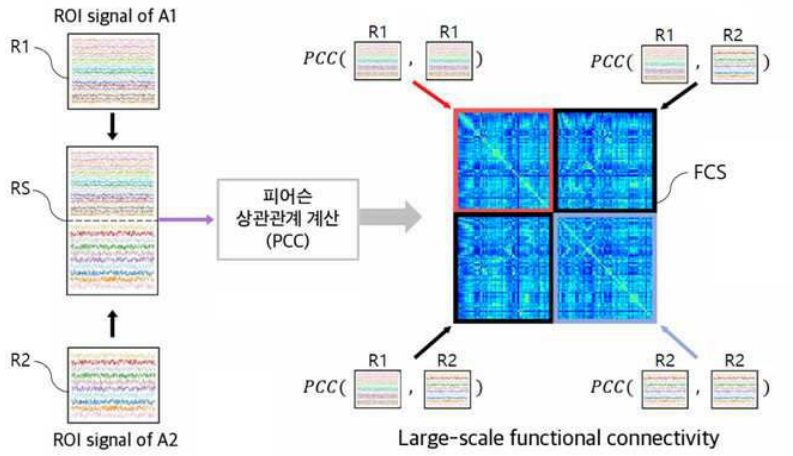
도면4


ROI signal of A1
Atlas1 (A1)
Atlas2 (A2)
ROI signal of A2

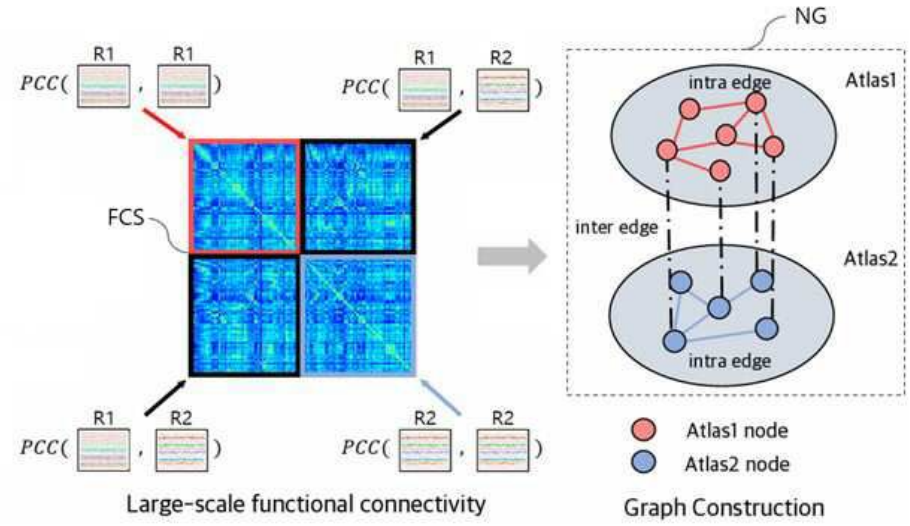
도면5


ROI signal of A1
R1
Atlas1 (A1)
RS
R2
Atlas2 (A2)
ROI signal of A2

도면6


ROI signal of A1
R1
RS
R2
ROI signal of A2
피어슨
상관관계 계산
(PCC)
PCC(R1 , R1)
PCC(R1 , R2)
PCC(R1 , R2)
PCC(R2 , R2)
FCS
Large-scale functional connectivity

도면7

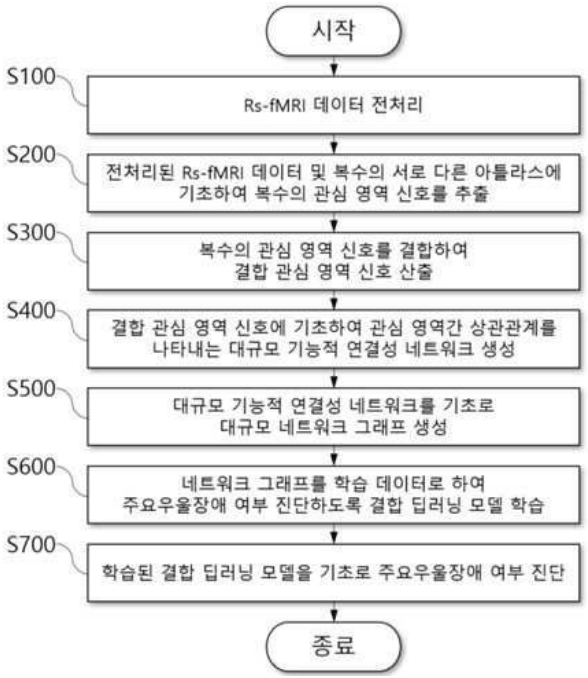


도면8

# of samples	MDD / NC	Age	Education	Male / Female	TR	Timepoint
479	250/229	39.0 ± 13.9	12.0 ± 3.7	157/322	2	232

Methods	ACC (%)	SENS (%)	SPEC (%)	F1 (%)
MISO-DNN	65.92 ± 3.69	63.04 ± 14.06	69.06 ± 12.55	65.00 ± 7.85
MGRL	64.01 ± 3.11	63.92 ± 6.35	64.13 ± 6.87	64.82 ± 3.66
MMTGCN	66.87 ± 4.48	68.19 ± 9.82	65.40 ± 5.02	67.88 ± 6.43
Ours	**69.59 ± 3.15**	**68.99 ± 7.72**	**70.21 ± 4.31**	**70.07 ± 4.72**

도면9


시작
S100
Rs-fMRI 데이터 전처리
S200
전처리된 Rs-fMRI 데이터 및 복수의 서로 다른 아틀라스에 기초하여 복수의 관심 영역 신호를 추출
S300
복수의 관심 영역 신호를 결합하여 결합 관심 영역 신호 산출
S400
결합 관심 영역 신호에 기초하여 관심 영역간 상관관계를 나타내는 대규모 기능적 연결성 네트워크 생성
S500
대규모 기능적 연결성 네트워크를 기초로 대규모 네트워크 그래프 생성
S600
네트워크 그래프를 학습 데이터로 하여 주요우울장애 여부 진단하도록 결합 딥러닝 모델 학습
S700
학습된 결합 딥러닝 모델을 기초로 주요우울장애 여부 진단
종료