(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0050790
(43) 공개일자 2021년05월10일

(51) 국제특허분류(Int. Cl.)
G16H 30/40 (2018.01) *G06N 20/00* (2019.01)
G16H 50/20 (2018.01) *G16H 50/30* (2018.01)
(52) CPC특허분류
G16H 30/40 (2018.01)
G06N 20/00 (2019.01)
(21) 출원번호 10-2019-0135252
(22) 출원일자 2019년10월29일
심사청구일자 2019년10월29일

(71) 출원인
동아대학교 산학협력단
부산광역시 사하구 낙동대로550번길 37, 동아대학교 내 (하단동)
(72) 발명자
강도영
부산광역시 남구 수영로325번길 12 대우푸르지오아파트 101-304
강현
부산광역시 연제구 금련로32번길 4 2층
(74) 대리인
전용철

전체 청구항 수 : 총 14 항

(54) 발명의 명칭 **딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치 및 방법**

(57) 요 약

본 발명은 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치 및 방법에 관한 것으로, 더욱 상세하게는 본 발명의 일면에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치는, 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단

(뒷면에 계속)

대 표 도 - 도1

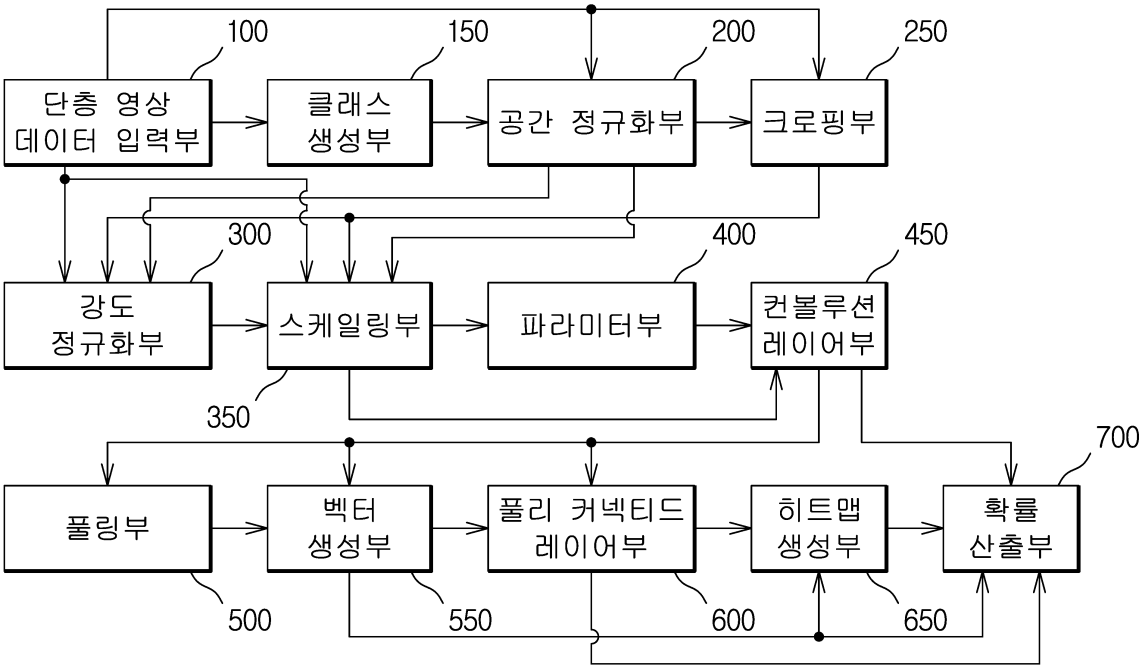

층 촬영 이미지를 입력받는 단층 촬영 이미지 입력부와, 복수 개의 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스들을 생성하는 클래스 생성부와, 복수 개의 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성하는 강도 정규화부와, 강도 정규화된 단층 촬영 이미지에 대하여 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 확률 산출부를 포함한다.

(52) CPC특허분류
G16H 30/20 (2018.01)
G16H 50/20 (2018.01)
G16H 50/30 (2018.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	2019-0035
부처명	부산시
과제관리(전문)기관명	부산과학기술기획평가원
연구사업명	퇴행성 뇌질환 인공지능기반 영상분석기술 개발사업
연구과제명	[2차년도]퇴행성 뇌질환 인공지능기반 영상분석기술 개발사업
기 여 율	1/1
과제수행기관명	동아대학교 산학협력단
연구기간	2019.01.01 ~ 2019.11.30

명 세 서

청구범위

청구항 1

아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 단층 촬영 이미지 입력부;

복수 개의 상기 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스들을 생성하는 클래스 생성부;

복수 개의 상기 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성하는 강도 정규화부; 및

강도 정규화된 단층 촬영 이미지에 대하여 상기 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 확률 산출부;

를 포함하는 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 2

제1항에 있어서,

복수 개의 상기 단층 촬영 이미지에 있어서 객체 영역인 뇌 영역에 해당하는 부분을 경계로 한 테두리 부분을 포함하되 기설정된 이미지 사이즈를 가지도록 뇌 영역에 해당하는 부분을 경계로 한 테두리의 배경 영역을 제거하는 크로핑부; 및

상기 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값들을 기설정된 범위 내의 값으로 스케일링하여 정규화 이미지를 생성하는 스케일링부;를 더 포함하되,

상기 확률 산출부는 상기 정규화 이미지가 상기 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 3

제1항에 있어서,

상기 클래스 생성부는,

복수 개의 상기 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도를 수치화함에 따라 복수 개의 임계값을 설정하여 제1 임계값 이하일 경우는 제1 클래스, 제1 임계값을 초과하고 제2 임계값 이하일 경우는 제2 클래스, 제2 임계값을 초과할 경우는 제3 클래스로 생성하여 복수 개의 클래스를 생성하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 4

제2항에 있어서,

복수 개의 상기 단층 촬영 이미지를 동일한 모양과 형태로 공간 정규화하여 공간 정규화된 단층 촬영 이미지를 생성하는 공간 정규화부;를 더 포함하고,

상기 크로핑부는,

상기 공간 정규화된 단층 촬영 이미지에 대한 배경 영역을 제거하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 5

제4항에 있어서,

상기 크로핑부는,

상기 공간 정규화된 단층 촬영 이미지에 대해 에지 검출을 수행함에 따라 추출되는 에지 성분들에 각각 대응되는 픽셀들을 연결하여 폐곡선을 생성하도록 하고, 곡률 반경이 작은 쪽인 폐곡선의 안쪽을 뇌 영역으로 추출하여 상기 공간 정규화된 단층 촬영 이미지의 배경 영역을 제거하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 6

제2항에 있어서,

상기 정규화 이미지에 대해서 기설정된 마스크와 컨볼루션 연산을 수행함에 따라 반복 학습하여 획득된 기설정된 파라미터들을 저장하는 파라미터부;

상기 정규화 이미지에 있어서 상기 파라미터들에 따른 필터를 이용하여 컨볼루션 연산하여 상기 정규화 이미지에 대한 복수 개의 특징맵을 생성하는 컨볼루션 레이어부; 및

상기 정규화 이미지에 대한 복수 개의 특징맵에 대하여 복수 개의 연산값에 대한 대표값을 할당하여 상기 정규화 이미지에 대한 컨볼루션 연산값의 사이즈를 축소하고 풀링 이미지를 생성하는 풀링부;를 더 포함하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 7

제6항에 있어서,

상기 복수 개의 특징맵이 가지는 사이즈를 축소시켜 복수 개의 상기 특징맵의 갯수와 동일한 갯수의 노드를 가지는 벡터를 생성하는 벡터 생성부; 및

상기 벡터 내의 노드와 각 클래스의 노드를 완전 연결시키는 풀리 커넥티드 레이어부;를 더 포함하고,

상기 확률 산출부는,

복수 개의 상기 특징맵과 상기 클래스의 노드에 완전 연결되는 가중치에 기초하여 확률을 산출하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치.

청구항 8

아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 단계;

상기 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스를 생성하는 단계;

상기 단층 촬영 이미지에 있어서 객체 영역인 뇌 영역에 해당하는 부분을 경계로 한 테두리 부분을 포함하되 기설정된 이미지 사이즈를 가지도록 뇌 영역에 해당하는 부분을 경계로 한 테두리의 배경 영역을 제거하는 단계;

상기 배경 영역이 제거된 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성하는 단계;

상기 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값들을 기설정된 범위 내의 값으로 스케일링하여 정규화 이미지를 생성하는 단계; 및

상기 정규화 이미지가 상기 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 단계;

를 포함하는 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

청구항 9

제8항에 있어서,

상기 클래스를 생성하는 단계는,

복수 개의 상기 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도를 수치화함에 따라 복수 개의 임계값을 설정하여 제1 임계값 이하일 경우는 제1 클래스, 제1 임계값을 초과하고 제2 임계값 이하일 경우는 제2 클래스, 제2 임계값을 초과할 경우는 제3 클래스로 생성하여 복수 개의 클래스를 생성하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

청구항 10

제8항에 있어서,

상기 클래스를 생성하는 단계와 상기 배경 영역을 제거하는 단계 사이에,

상기 복수 개의 단층 촬영 이미지를 동일한 모양과 형태로 공간 정규화하여 공간 정규화된 단층 촬영 이미지를 생성하는 단계;를 더 포함하고,

상기 배경 영역을 제거하는 단계는,

상기 공간 정규화된 단층 촬영 이미지에 대한 배경 영역을 제거하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

청구항 11

제10항에 있어서,

상기 배경 영역을 제거하는 단계는,

상기 공간 정규화된 단층 촬영 이미지들에 대해 에지 검출을 수행함에 따라 추출되는 에지 성분들에 각각 대응되는 픽셀들을 연결하여 폐곡선을 생성하도록 하고, 곡률 반경이 작은 쪽인 폐곡선의 안쪽을 뇌 영역으로 추출하여 상기 공간 정규화된 단층 촬영 이미지의 배경 영역을 제거하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

청구항 12

제8항에 있어서,

상기 정규화 이미지를 생성하는 단계와 상기 확률을 산출하는 단계 사이에,

상기 정규화 이미지에 대해서 기설정된 마스크와 컨볼루션 연산을 수행함에 따라 반복 학습하여 획득된 기설정된 파라미터들을 저장하는 단계;를 더 포함하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

청구항 13

제12항에 있어서,

상기 정규화 이미지를 생성하는 단계 이후에,

상기 정규화 이미지에 있어서 상기 파라미터들에 따른 필터를 이용하여 컨볼루션 연산하여 상기 정규화 이미지에 대한 복수 개의 특징맵을 생성하는 단계; 및

상기 정규화 이미지에 대한 복수 개의 특징맵에 대하여 복수 개의 연산값에 대한 대표값을 할당하여 상기 정규화 이미지에 대한 컨볼루션 연산값의 사이즈를 축소하고 풀링 이미지를 생성하는 단계;를 더 포함하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

청구항 14

제13항에 있어서,

상기 정규화 이미지를 생성하는 단계 이후에,

상기 복수 개의 특징맵이 가지는 사이즈를 축소시켜 상기 특징맵의 갯수와 동일한 갯수의 노드를 가지는 벡터를 생성하는 단계; 및

상기 벡터 내의 노드와 각 클래스의 노드를 완전 연결시키는 단계;를 더 포함하고,

상기 확률을 산출하는 단계는,

상기 복수 개의 특징맵과 상기 클래스의 노드에 완전 연결되는 가중치에 기초하여 확률을 산출하는 것

인 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치 및 방법에 관한 것으로, 더욱 상세하게는, 진단 대상자의 뇌를 촬영한 단층 촬영 이미지를 입력받아 딥러닝을 활용하여 진단 대상자의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지를 분류하는 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치 및 방법에 관한 것이다.

배 경 기 술

[0002] 퇴행성 뇌질환 중 특히 아밀로이드 양성 반응을 보이는 퇴행성 뇌질환은, 상태가 매우 악화되고 나서야 증상이 나타나고 그 증상 또한 정확한 판별이 불가능하여 조기에 발견하는 것이 어려운 실정이다.

[0003] 아밀로이드 양성 반응을 보이는 퇴행성 뇌질환은 뇌세포의 손상으로 발생하는 대표적인 뇌질환으로 주로 노년기에 많이 생기며, 뇌세포는 다른 세포와는 달리 재생되지 않으므로 예방 또는 조기에 발견하여 치료하는 것이 가장 안전하고 효율적으로 치료할 수 있는 방법으로 알려져 있다.

[0004] 최근에 이르러 초음파, CT 및 MRI 등 단층 촬영 장치와 같은 영상 의학적 검사 방법이 발달함에 따라 의학 영상의 분석 및 처리 기술에 의해 인체의 질환을 진단하는 장치의 중요성이 확대되고 있으며, 이에 따라 뇌를 단층 촬영한 이미지를 통해 치매를 일관적이고 정확한 진단을 할 필요가 있다.

[0005] 한편, 현재 단층 촬영 이미지를 육안으로 직접 판단하므로 단층 촬영 이미지에서 뇌의 경계가 모호하고 명암도 특징이 뚜렷하지 않기 때문에 뇌질환을 잘못 판단하는 경우가 발생할 수 있어 치매를 조기에 발견하지 못하는 등 다양한 단층 촬영 장치의 한계점이 있으며, 기존의 진단 시스템은 뇌 전체를 보고 판단하기 때문에, 뇌 영역의 각 부분별 진단 결과를 제공하지 않는 문제점이 있다.

[0006] 또한, 퇴행성 뇌질환의 예측을 위해서는 방대한 MRI 영상자료와 환자의 임상정보를 모두 고려하여야 하므로, 그 진단을 위한 시간이 많이 소요될 뿐만 아니라 의료진의 숙련도에 따라서도 그 진단 결과에 편차가 클 수 있는 문제점이 있다.

선행기술문헌

특허문헌

[0007] (특허문헌 0001) KR 10-2019-0105452 A

(특허문헌 0002) KR 10-2021515 B1

발명의 내용

해결하려는 과제

[0008] 본 발명의 목적은 상기 문제점을 해결하기 위한 것으로서, 진단 대상자의 뇌를 단층 촬영한 단층 촬영 이미지를 입력받아 딥러닝을 활용하여 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지를 분류하는 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치 및 방법을 제공하는 것을 목적으로 한다.

[0009] 본 발명의 목적은 이상에서 언급한 목적으로 제한되지 않으며, 언급되지 않은 또 다른 목적들은 아래의 기재로부터 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0010] 전술한 목적을 달성하기 위한 본 발명의 일면에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치는, 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 단층 촬영 이미지 입력부와, 복수 개의 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스들을 생성하는 클래스 생성부와, 복수 개의 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성하는 강도 정규화부와, 강도 정규화된 단층 촬영 이미지에 대하여 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 확률 산출부를 포함한다.

[0011] 본 발명의 다른 일면에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법은, 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 단계와, 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스를 생성하는 단계와, 단층 촬영 이미지에 있어서 객체 영역인 뇌 영역에 해당하는 부분을 경계로 한 테두리 부분을 포함하되 기설정된 이미지 사이즈를 가지도록 뇌 영역에 해당하는 부분을 경계로 한 테두리의 배경 영역을 제거하는 단계와, 배경 영역이 제거된 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성하는 단계와, 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값들을 기설정된 범위 내의 값으로 스케일링하여 정규화 이미지를 생성하는 단계와, 정규화 이미지가 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 단계를 포함한다.

발명의 효과

[0012] 본 발명에 따르면, 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환의 진단을 클래스별 확률과 함께 정량적, 통계적 결과를 제공하여 의사의 최종 진단에 도움이 되는 효과가 있다.

[0013] 본 발명에 따르면, 환자의 단층 촬영 이미지로 CNN 모델을 이용하여 간단하고 빠르게 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 결과를 출력할 수 있는 효과가 있다.

[0014] 본 발명의 딥러닝 과정에서 생성한 클래스 활성화 맵으로 CNN 모델의 과정에서 단층 촬영 이미지의 어느 부분의 특징을 중요시 했는지 시각화하여 환자의 이해를 도울 수 있는 효과가 있다.

[0015] 본 발명에 따른 효과는 이상에서 예시된 내용에 의해 제한되지 않으며, 더욱 다양한 효과들이 본 명세서 내에 포함되어 있다.

도면의 간단한 설명

[0016] 도 1은 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치를 설명하기 위한 블록도이다.

도 2는 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치의 강도 정규화를 설명하기 위한 도면이다.

도 3은 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치의 스케일링부를 설명하기 위한 도면이다.

도 4는 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치의 풀링부를 설명하기 위한 도면이다.

도 5는 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치의 벡터 생성부를 설명하기 위한 도면이다.

도 6은 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치의 클래스 활성화 맵과 확률 산출부의 결과값을 나타내는 도면이다.

도 7은 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법을 나타낸 순서도이다.

발명을 실시하기 위한 구체적인 내용

[0017] 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시예들을 참고하면 명확해질 것이다. 그러나 본 발명은 이하 개시되는 실시예들에 한정되는 것이 아니라, 서로 다른 다양한 형태로 구현될 것이며, 단지 본 실시예들은 본 발명의 개시가 완전하도록 하며, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것으로서, 본 발명은 청구항의 기재에 의해 정의될 뿐이다. 한편, 본 명세서에서 사용된 용어는 실시예들을 설명하기 위한 것이며, 본 발명을 제한하고자 하는 것은 아니다. 본 명세서에서, 단수형은 문구에서 특별히 언급하지 않는 한 복수형도 포함된다. 이하, 첨부된 도면을 참고하여 본 발명의 일 실시예를 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치 및 방법을 상세히 설명하도록 한다.

[0018] 또한, 본 발명의 실시예들에 있어서, 기능적으로 동일한 구성요소는 도면 부호를 일치시켜 설명하도록 하고, 반복 설명은 생략하도록 한다.

[0019] 도 1을 참조하면, 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치는 단층 촬영 이미지 입력부(100), 클래스 생성부(150), 공간 정규화부(200), 크로핑부(250), 강도 정규화부(300), 스케일링부(350), 파라미터부(400), 컨볼루션 레이어부(450), 풀링부(500), 벡터 생성부(550), 폴리 커넥티드 레이어부(600), 히트맵 생성부(650), 확률 산출부(700)를 포함한다.

[0020] 단층 촬영 이미지 입력부(100)는 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는다.

[0021] 여기서, 단층 촬영 이미지는 400 X 400 픽셀의 사이즈를 가지는 것일 수 있으며, 단층 촬영 이미지 입력부는 50 내지 150장의 복수 개의 단층 촬영 이미지를 입력받는 것일 수 있다.

[0022] 한편, 단층 촬영 이미지 입력부(100)는 Amyloid PET Radiotracer에 의해 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 것일 수 있다.

[0023] 단층 촬영 이미지는 Amyloid PET Radiotracer에 의해 아밀로이드 제재가 투여됨에 따라 병이 존재하는 영역에서는 양성 반응을 보일 수 있으며, 병이 존재하지 않는 영역에서는 음성 반응을 보일 수 있다.

[0024] 또한, 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영하는데 있어서, 아밀로이드 제재의 투여시점으로부터 30분 내지 2시간 정도의 시간이 경과된 후 10분 내지 60분의 기간동안 단층 촬영을 수행함에 따른 복수 개의 단층 촬영 이미지를 단층 촬영 이미지 입력부(100)에서 입력받는 것일 수 있다.

[0025] 한편, 단층 촬영 이미지에 있어서 아밀로이드가 침착된 부분은 하얀색에 가까운 색상을 가지는 것일 수 있다.

[0026] 여기서, 하얀색에 가까운 색상이라는 것은 단층 촬영 이미지에 있어서, 검은색 부분에 대비되는 회색 또는 하얀색으로 나타나는 픽셀 부분들의 색상을 의미한다.

[0027] 단층 촬영 이미지에 있어서, 뇌 영역에 해당하는 부분을 경계로하여 테두리가 형성되는 것일 수 있으며, 뇌 영역에 속하는 세포 또는 조직 부분의 픽셀이 아밀로이드 침착 정도에 따라서 하얀색에 가까운 색상을 가지는 것일 수 있다.

[0028] 클래스 생성부(150)는 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스를 생성한다.

[0029] 클래스 생성부(150)는 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도를 수치화함에 따라 복수 개의 임계값을 설정하여 제1 임계값 이하일 경우는 제1 클래스, 제1 임계값을 초과하고 제2 임계값 이하일 경우는 제2 클래스, 제2 임계값을 초과할 경우는 제3 클래스로 생성하여 복수 개의 클래스를 생성할 수 있다.

[0030] 클래스 생성부(150)는 클래스 마다 각 클래스에 대응되는 노드(node)를 생성하는 것일 수 있다.

[0031] 공간 정규화부(200)는 복수 개의 단층 촬영 이미지를 동일한 모양과 형태로 공간 정규화하여 공간 정규화된 단층 촬영 이미지를 생성한다.

[0032] 공간 정규화부(200)는 복수 개의 단층 촬영 이미지를 하나의 기설정된 기준 좌표에 맞게 배치하도록하고, 이미

지처리의 효율성을 높이기 위해 단층 촬영 이미지들에 포함된 객체 영역이 이미지의 중앙에 위치하도록 하여 공간 정규화된 단층 촬영 이미지를 생성하는 것일 수 있다.

[0033] 또한, 공간 정규화부(200)는 단층 촬영 이미지가 가지는 픽셀의 위치를 이동하여 단층 촬영 이미지의 형태를 변환하는 워핑(Warping)이라는 영상 처리 기법에 기초하여 공간 정규화된 단층 촬영 이미지를 생성하는 것일 수 있다.

[0034] 크로핑부(250)는 공간 정규화된 단층 촬영 이미지에 있어서 객체 영역인 뇌 영역에 해당하는 부분을 경계로 한 테두리 부분을 포함하되 기설정된 이미지 사이즈를 가지도록 뇌 영역에 해당하는 부분을 경계로 한 테두리의 배경 영역을 제거한다.

[0035] 뇌를 단층 촬영하여 획득되는 이미지의 경우, 아밀로이드가 침착된 정도에 따라서 고음영 부분과 저음영 부분으로 구분되는 뇌 영역과, 뇌 영역과 무관한 배경 영역으로 구분될 수 있다.

[0036] 크로핑부(250)는 공간 정규화된 단층 촬영 이미지들에 있어서 에지를 검출하여 에지 내부의 영역을 뇌 영역으로 추출하여 배경 영역을 제거하는 것일 수 있다.

[0037] 뇌 영역은 배경 영역과 대비하여 명도 값의 차이가 크므로 뇌 영역과 배경 영역을 에지 검출에 따라 쉽게 구분할 수 있다.

[0038] 크로핑부(250)는 공간 정규화된 단층 촬영 이미지들에 대해 에지 검출을 수행함에 따라 추출되는 에지 성분들에 각각 대응되는 픽셀들을 연결하여 폐곡선을 생성하도록 하고, 곡률 반경이 작은 쪽인 폐곡선의 안쪽을 뇌 영역으로 추출하여 배경 영역을 제거하는 것일 수 있다.

[0039] 크로핑부(250)는 에지는 영상에서 명도의 변화가 많은 부분에서 발생하므로 인접해 있는 픽셀들 간의 픽셀값을 비교하여 차이가 큰 경우를 변화하는 경계에 해당되는 부분으로 하여 에지 영역을 추출하도록 하고 뇌 영역과 배경 영역을 구분하는 것일 수 있다.

[0040] 크로핑부(250)에 의해 단층 촬영 이미지는 400 X 400 픽셀의 사이즈에서 95 X 79 픽셀의 사이즈로 변환될 수 있다.

[0041] 강도 정규화부(300)는 배경 영역이 제거된 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성한다.

[0042] 여기서, 특이성 섭취(Specific Uptake) 영역은 병의 유무에 따라 아밀로이드 침착이 결정되는 영역을 나타내고, 비특이성 섭취(Non-specific Uptake) 영역은 병의 유무에 상관없이 항상 아밀로이드 침착이 되는 영역을 나타내는 것일 수 있다.

[0043] 병이 없는 환자의 단층 촬영 이미지에서의 특이성 섭취 영역에서는 아밀로이드 침착이 되지 않을 것이고, 병이 있는 환자의 단층 촬영 이미지에서의 특이성 섭취 영역에서는 아밀로이드 침착이 될 것이며, 병의 유무와 관계없이 비특이성 영역에서는 아밀로이드 침착이 항상 되는 것일 수 있다.

[0044] 도 2를 참조하면, 뇌의 백질(White matter) 영역을 비특이성 섭취 영역(301)으로 관찰할 수 있고, 대뇌 회백질 영역을 특이성 섭취 영역(303)으로 관찰할 수 있다.

[0045] 또한, 강도 정규화부(300)는 단층 촬영 이미지에 속하는 픽셀들과 기설정된 마스크간에 사칙연산을 적용하여 강도 정규화를 수행하는 것일 수 있다.

[0046] 강도 정규화부(300)는 배경 영역이 제거된 단층 촬영 이미지가 가지는 전체 픽셀값을 뇌의 백질(White matter) 영역인 비특이성 섭취 영역(301)이 가지는 픽셀값으로 나누어 강도 정규화를 수행하여 강도 정규화된 단층 촬영 이미지를 생성하는 것일 수 있다.

[0047] 다시 말해, 강도 정규화부(300)가 단층 촬영 이미지에서의 뇌의 백질(White matter) 영역인 비 특이성 섭취 영역에 해당하는 픽셀값으로 단층 촬영 이미지의 전체 픽셀값을 나눠주게 되면(즉, 강도 정규화를 하면), 전체 단층 촬영 이미지에서 비 특이성 섭취 영역의 픽셀값은 1에 가까울 것이기 때문에 관찰하고자 하는 영역인 특이성 섭취 영역을 1에 가까운 값을 가지는 비 특이성 섭취 영역을 기준으로 정상인과 비정상인의 단층 촬영 이미지 비교가 가능한 것일 수 있다.

[0048] 강도 정규화부(300)는 강도 정규화된 단층 촬영 이미지를 생성함으로써, 환자 간의 단층 촬영 이미지에서 특이

성 섭취 영역에 기초하여 절대적 및 상대적 비교를 할 수 있다.

[0049] 스케일링부(350)는 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값들을 기설정된 범위 내의 값으로 스케일링하여 정규화 이미지를 생성한다.

[0050] 도 3를 참조하면, 단층 촬영 이미지에서 픽셀값의 분포 변화는 딥러닝(Deep-learning) 기반의 합성곱 신경망(CNN, Convolution Neural Network)에서 학습할 가중치(Weight)의 스케일(Scale) 변화에 영향을 주기 때문에, 스케일링부(350)는 CNN 모델에서 학습할 가중치의 스케일을 일정한 범위 내에서 분포할 수 있게 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값을 기설정된 범위 내의 값으로 스케링일링 하는 것일 수 있다.

수학식 1

[0051] $$\text{스케일링값} = \frac{x_i - m}{SD}$$

[0052] 여기서, x_i는 스켈일링의 대상이 되는 픽셀값이고, m은 단층 촬영 이미지가 가지는 픽셀값의 평균값이며, SD는 단층 촬영 이미지가 가지는 픽셀값의 표준편차를 나타낸다.

[0053] 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치는 진단 대상자의 단층 촬영 이미지를 공간 정규화부(200), 크로핑부(250), 강도 정규화부(300), 스케일링부(350)에 의해 정규화된 정규화 이미지를 딥러닝 기반의 CNN 모델에 적용하여 진단 대상자의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환을 진단할 수 있으며, 단층 촬영 이미지 입력부(100)에서 입력받은 400 X 400 사이즈의 단층 촬영 이미지는 97 X 79 사이즈의 정규화 이미지로 변환되어 CNN 모델에 적용될 수 있다.

[0054] 합성곱 신경망(CNN, Convolution Neural Network)은 단층 촬영 이미지(영상)로부터 테두리, 선 색 등과 같은 특징(features)들을 추출하는 신경망 기법으로서, 복수의 계층들(layers)을 포함할 수 있다. 각각의 계층(layer)은 입력 데이터를 수신하고, 해당 계층의 입력 데이터를 처리하여 출력 데이터를 생성할 수 있다. 합성곱 신경망은 입력된 영상 또는 입력된 특징맵(feature map)을 필터 커널들(filter kernels)과 컨볼루션하여 생성한 특징맵을 출력 데이터로서 출력할 수 있다. 합성곱 신경망의 초기 계층들은 입력으로부터 에지들 또는 그레디언트들과 같은 낮은 레벨의 특징들을 추출하도록 동작될 수 있다. 신경망의 다음 계층들은 눈, 코 등과 같은 점진적으로 더 복잡한 특징들을 추출할 수 있다.

[0055] 합성곱 신경망은 컨볼루션 연산이 수행되는 합성곱 계층(Convolution Layer) 외에도 풀링 연산이 수행되는 풀링 계층(Pooling Layer)도 포함할 수 있다. 풀링 기법은 풀링 계층에서 데이터의 공간적 크기를 축소하는데 사용되는 기법이다. 구체적으로, 풀링 기법에는 해당 영역에서의 최대값을 선택하는 맥스 풀링(Max Pooling) 기법과 해당 영역의 평균값을 선택하는 평균 풀링(Average Pooling) 기법이 있으며, 이미지 인식 분야에서는 일반적으로 맥스 풀링 기법이 사용된다. 풀링 기법에서는 일반적으로 풀링의 윈도우 크기와 간격(스트라이드, stride)을 같은 값으로 설정한다. 여기서, 스트라이드란 입력 데이터에 필터를 적용할 때 이동할 간격을 의미하며, 스트라이드 또한 출력 데이터의 크기를 조절하기 위해 사용될 수 있다.

표 1

[0056]

구분	Layer (type)	Output Shape	# of Parameter
입력층	input	(97, 79, 3)	0
Block1	Conv1	(97, 79, 64)	1792
	Conv2	(97, 79, 64)	36928
	Max2	(48, 39, 64)	0
Block2	Conv3	(48, 39, 128)	73856
	Conv4	(48, 39, 128)	147584
	Max4	(24, 19, 128)	0
Block3	Conv5	(24, 19, 256)	295168
	Conv6	(24, 19, 256)	590080
	Conv7	(24, 19, 256)	590080
	Max7	(12, 9, 246)	0
Block4	Conv8	(12, 9, 512)	1180160

	Conv9	(12, 9, 512)	2359808
	Conv10	(12, 9, 512)	2359808
	Max10	(6, 4, 512)	0
Block5	Conv11	(6, 4, 512)	2359808
	Conv12	(6, 4, 512)	2359808
	Conv13	(6, 4, 512)	2359808
	Max13	(3, 2, 512)	0
GAP	Global_Average_Pooling	512	0
Dense	Fully connected layer	(N, 2)	1026
Total Parameters			14,715,714

[0057] 표 1은 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치에서 적용한 CNN 모델의 과정을 나타낸 것이다.

[0058] 여기서, Conv는 컨볼루션 레이어, Max는 맥스 풀링 레이어, # of Parameter는 파라미터의 수를 의미한다.

[0059] 파라미터부(400)는 정규화 이미지에 대해서 기설정된 마스크와 컨볼루션 연산을 수행함에 따라 반복 학습하여 획득된 기설정된 파라미터(Parameter)들을 저장한다.

[0060] 컨볼루션 레이어부(450)는 정규화 이미지에 있어서 파라미터들에 따른 필터를 이용하여 컨볼루션 연산하여 정규화 이미지에 대한 복수 개의 특징맵을 생성한다.

[0061] 컨볼루션 레이어부(450)는 정규화 이미지에서 특징을 검출하기 위해 기설정된 사이즈의 행렬로 정의되는 복수 개의 필터를 이용하여 정규화 이미지의 픽셀값과 컨볼루션 연산하여, 정규화 이미지에서 필터가 가지는 특성이 있으면 결과값이 큰 값이 산출되고, 정규화 이미지에서 필터가 가지는 특성이 없으면 결과값이 0에 가까운 값이 산출되어 정규화 이미지가 복수 개의 필터에 대한 특성을 가지고 있는지 없는지 여부를 알 수 있다.

[0062] 컨볼루션 레이어부(450)는 정규화 이미지에 있어서, 서로 다른 특징을 추출하는 필터가 좌측에서 우측으로, 또는 상단에서 하단으로 사용자의 입력에 따른 간격(스트라이드, stride)만큼 이동하면서 정규화 이미지와 필터가 겹치는 영역 내에서 컨볼루션 연산을 수행하고, 그 결과로, 복수 개의 특징맵(feature map)을 생성하는 것일 수 있다.

[0063] 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치에서는 필터 커널의 사이즈를 3 X 3, 간격(스트라이드, stride)은 1로 설정하였지만, 본 개시가 이를 한정하는 것은 아니며, 이미지의 사이즈, 특징에 따라 다양하게 변경될 수 있다.

[0064] 풀링부(500)는 정규화 이미지에 대한 특징맵에 대하여 복수 개의 연산값에 대한 대표값을 할당하여 특징맵에 대한 컨볼루션 연산값의 사이즈를 축소하고 풀링 이미지를 생성한다.

[0065] 합성곱 신경망 모델에서 합성곱 계층(Convolution layer)을 통해서 특징맵이 추출되면, 고해상도 사진을 보고 물체를 판별할 수 있지만, 작은 사진을 가지고도 그 사진의 내용이 어떤 사진인지 판단할 수 있는 원리와 마찬가지로, 이 모든 특징을 가지고 판단을 할 필요가 없기 때문에 생성된 특징맵의 사이즈를 인위적으로 줄이는 풀링(Pooling) 작업을 수행하는 것일 수 있다.

[0066] 풀링부(500)는 특징맵을 기설정된 동일한 사이즈를 가지는 복수 개의 영역으로 분할하여 각 영역 내에서 최대값에 기초하여 각 영역을 하나의 값으로 추출하여 특징맵의 사이즈를 축소하고 풀링 이미지를 생성하는 것일 수 있다.

[0067] 도 4를 참조하면, 풀링부(500)는 맥스 풀링(Max Pooling) 필터를 특징맵의 좌측 상단에 위치시키고 기설정된 간격(스트라이드, stride) 만큼 우측으로 이동하면서 필터 영역 내의 값들 중 최대값을 추출한다. 이 후, 더 이상 우측으로 필터를 이동시킬 수 없는 경우 특징맵의 좌측에서서 기설정된 간격(스트라이드, stride) 만큼 아래의 위치부터 우측으로 이동하면서 필터 영역 내의 값들 중 최대값을 추출하여, 최대값을 조합함에 따른 풀링 이미지를 생성하는 것일 수 있다.

[0068] 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치에서는 맥스 풀링(Max Pooling) 필터의 사이즈를 2 X 2, 간격(스트라이트, stride)를 2로 설정하였지만, 이에 한정되는 것은 아니다.

[0069] 풀링부(500)는 풀링(Pooling) 기법으로 전체 데이터의 사이즈가 줄어들기 때문에 연산 과정이 적어지고, 데이터의 크기를 줄이면서 소실이 발생하기 때문에 샘플 데이터에 과적합되는 오버피팅(Overfitting)을 방지할 수 있는 효과가 있다.

[0070] 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치에서 컨볼루션 레이어부(450)와 풀링부(500)를 차례대로 기설정된 횟수만큼 반복 수행할 수 있고, 컨볼루션 레이어부(450)와 풀링부(500)의 반복 수행으로 컨볼루션 레이어부(450)는 복수 개의 최종 특징맵을 생성할 수 있다.

[0071] 벡터 생성부(550)는 특징맵이 가지는 사이즈를 축소시켜 특징맵의 갯수와 동일한 갯수의 노드를 가지는 벡터를 생성한다.

[0072] 벡터 생성부(550)는 복수 개의 최종 특징맵의 갯수는 유지하고 각 특징맵이 가지는 사이즈를 축소시켜 최종 특징맵의 갯수와 동일한 노드(node)를 가지는 벡터를 생성하는 것일 수 있다.

[0073] 예를 들어, 도 5를 참조하면, 벡터 생성부(550)는 GAP(Global Average Pooling) 기법을 이용하여 복수 개의 최종 특징맵에서 각 특징맵의 픽셀값의 평균값을 산출하고 각 특징맵의 평균값을 하나의 노드로 추출하여 벡터를 생성하는 것일 수 있다.

[0074] 예를 들어, 벡터 생성부(550)는 LW X LH의 사이즈로 이루어진 LF(Last Feature map)개의 최종 특징맵을 각 특징맵의 평균값을 산출하여 하나의 값으로 요약하여 1 X 1 사이즈, 최종 특징맵의 노드 갯수와 같은 LF개의 노드로 이루어진 벡터를 생성하는 것일 수 있다.

[0075] 풀리 커넥티드 레이어부(600)는 벡터 생성부(550)에서 생성한 벡터 내의 노드와 클래스 생성부(150)에서 생성한 각 클래스의 노드를 완전 연결시킨다.

[0076] 여기서, 완전 연결은 벡터 내의 LF개의 노드와 클래스 내의 노드를 각각 연결한다는 것을 의미한다. 예를 들어, 클래스의 갯수가 C개 라고 가정하면, LF개의 노드와 클래스 내의 C개의 노드를 완전 연결하면 클래스 내의 각 노드들은 벡터 내의 LF개의 각 노드와 연결될 것이고, 벡터 내의 각 노드들은 클래스 내의 C개의 각 노드와 연결될 것이다. 여기서, 각 노드(node) 간 완전 연결되는 것은 CNN 모델을 수행하면서 학습된 가중치(Weight)를 나타낼 것이며, 서로 다른 수치로 이루어진 가중치(Weight)의 갯수는 LF X C개가 되는 것일 수 있다.

[0077] 여기서, 가중치(Weight)는 최종 특징맵의 특징들을 얼마나 반영하여 복수 개의 클래스 중에서 어떤 클래스를 결정할 것인지에 대한 수치를 나타내며 채널의 중요도인 것일 수 있다. 즉, LF X C개의 가중치(Weight) 값을 LF개의 최종 특징맵의 각 픽셀값과 각각 곱한 수치를 각 최종 특징맵에서 가장 특징이 되는 부분인 것일 수 있다.

[0078] 풀리 커넥티드 레이어부(600)는 벡터 내의 노드와 각 클래스의 노드를 완전 연결시켜 정규화 이미지를 클래스별로 분류하는 것일 수 있다.

[0079] 히트맵 생성부(650)는 최종 특징맵과 가중치와의 가중합을 수행하여 클래스 갯수 만큼의 복수 개의 픽셀값으로 이루어진 히트맵을 생성한다.

[0080] 히트맵 생성부(650)는 벡터 내의 노드와 클래스 내의 노드와, 완전 연결된 가중치와 최종 특징맵 내의 노드 각각과 가중합을 수행하여 클래스 내의 노드 갯수 만큼의 히트맵(Heat map)을 생성하는 것일 수 있다.

[0081] 여기서, 히트맵(Heat map)의 사이즈는 최종 특징맵과 같은 사이즈를 가지는 것일 수 있다.

[0082] 예를 들어, 히트맵 생성부(650)는 최종 특징맵 내의 LF개의 노드와 LF X C개의 가중치와 가중합을 수행하여 클래스 내의 노드 갯수인 C개 만큼의 히트맵을 생성하는 것일 수 있다.

[0083] 여기서, 히트맵(Heat map)은 클래스 활성화 맵(Class Activation map)을 의미하는 것일 수 있다.

[0084] 확률 산출부(700)는 정규화 이미지가 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출한다.

[0085] 확률 산출부(700)는 클래스 별로 분류된 정규화 이미지가 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 것일 수 있다.

[0086] 확률 산출부(700)는 벡터 내의 노드와 클래스 내의 노드가 완전 연결되어 벡터 내의 노드와 가중치가 가중합을 수행하여 클래스 노드 내에 결과값을 출력하여 확률을 산출하는 것일 수 있다.

[0087] 예를 들어, 확률 산출부(700)는 벡터 내의 노드와 LF X C개의 가중치와 가중합을 수행하고 가중합을 수행한 출력값을 Softmax 함수에 기초하여 각 출력값이 각 클래스 내에 대응되는 확률을 산출하는 것일 수 있으며, 확률 산출부(700)는 하기 수학식 1에 의한 Softmax 함수에 기초하여 확률을 산출하는 것일 수 있다.

수학식 2

[0088] $$p_c = \frac{e^{x_c}}{\sum_{c=1}^{c} e^{x_c}}$$

[0089] 여기서, c는 클래스의 갯수를 나타내고, p_j는 c번째 클래스에 대응되는 확률을 나타내며, x_c는 벡터 내의 노드와 LF X C개의 가중치와 가중합을 수행한 c번째 클래스의 출력값을 나타낸다.

[0090] 도 6에 도시된 바와 같이, 히트맵 생성부(650)는 정규화 이미지에 대한 히트맵(Heat map) 또는 클래스 활성화 맵(Class Activation map)을 클래스의 갯수만큼 생성할 수 있고, 확률 산출부(700)는 벡터 내의 노드와 LF X C개의 가중치와 가중합을 수행한 출력값이 각 클래스에 대응되는 확률을 산출할 수 있다.

[0091] 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치는 히트맵 생성부(650)에서 생성한 히트맵으로 CNN 모델의 과정에서 정규화 이미지의 어느 부분의 특징을 중요시 했는지 시각화하여 환자의 이해를 도울 수 있고, 확률 산출부(700)가 정규화 이미지를 CNN 모델로 입력하였을 때, 정규화 이미지가 각 클래스마다 대응되는 확률을 산출함으로써, 가장 높은 확률을 가지는 클래스에 기초하여 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지를 분류하여 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환을 진단에 도움이 되는 효과가 있다.

[0092] 또한, 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치는 환자의 단층 촬영 이미지로 CNN 모델을 이용하여 간단하고 빠르게 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지를 분류할 수 있다.

[0094] 도 7은 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법을 나타내는 순서도이다. 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법은 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치에 의해 수행될 수 있다. 이하, 도 7을 참조하여, 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법을 설명하도록 하고, 도 1 내지 도 6을 참조하여 설명한, 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치와 중복되는 내용 및 구성은 도면 부호를 일치시키고 설명의 편의를 위해 자세한 설명은 생략하도록 한다.

[0095] 먼저, 단층 촬영 이미지 입력부(100)는 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는다(S100).

[0096] 여기서, 단층 촬영 이미지는 400 X 400 픽셀의 사이즈를 가지는 것일 수 있으며, 단층 촬영 이미지 입력부는 50 내지 150장의 복수 개의 단층 촬영 이미지를 입력받는 것일 수 있다.

[0097] 한편, 단층 촬영 이미지 입력부(100)는 Amyloid PET Radiotracer에 의해 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 것일 수 있다.

[0098] 또한, 아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영하는데 있어서, 아밀로이드 제재의 투여시점으로부터 30분 내지 2시간 정도의 시간이 경과된 후 10분 내지 60분의 기간동안 단층 촬영을 수행함에 따른 복수 개의 단층 촬영 이미지를 단층 촬영 이미지 입력부(100)에서 입력받는 것일 수 있다.

[0099] 한편, 단층 촬영 이미지에 있어서 아밀로이드가 침착된 부분은 하얀색에 가까운 색상을 가지는 것일 수 있다.

[0100] 여기서, 하얀색에 가까운 색상이라는 것은 단층 촬영 이미지에 있어서, 검은색 부분에 대비되는 회색 또는 하얀색으로 나타나는 픽셀 부분들의 색상을 의미한다.

[0101] 단층 촬영 이미지에 있어서, 뇌 영역에 해당하는 부분을 경계로하여 테두리가 형성되는 것일 수 있으며, 뇌 영역에 속하는 세포 또는 조직 부분의 픽셀이 아밀로이드 침착 정도에 따라서 하얀색에 가까운 색상을 가지는 것일 수 있다.

[0102] 클래스 생성부(150)는 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도에 따라 단층 촬영 이미지를 분류하고자 하는 복수 개의 클래스를 생성한다(S150).

[0103] 클래스 생성부(150)는 단층 촬영 이미지에서 아밀로이드 제재가 침착된 정도를 수치화하여 따라 복수 개의 임계값을 설정하여 제1 임계값 이하일 경우는 제1 클래스, 제1 임계값을 초과하고 제2 임계값 이하일 경우는 제2 클래스, 제2 임계값을 초과할 경우는 제3 클래스로 생성하여 복수 개의 클래스를 생성할 수 있다.

[0104] 공간 정규화부(200)는 복수 개의 단층 촬영 이미지를 동일한 모양과 형태로 공간 정규화하여 공간 정규화된 단층 촬영 이미지를 생성한다(S200).

[0105] 공간 정규화부(200)는 복수 개의 단층 촬영 이미지를 하나의 기설정된 기준 좌표에 맞게 배치하도록하고, 이미지처리의 효율성을 높이기 위해 단층 촬영 이미지들에 포함된 객체 영역이 이미지의 중앙에 위치하도록 하여 공간 정규화된 단층 촬영 이미지를 생성하는 것일 수 있다.

[0106] 또한, 공간 정규화부(200)는 단층 촬영 이미지가 가지는 픽셀의 위치를 이동하여 단층 촬영 이미지의 형태를 변환하는 워핑(Warping)이라는 영상 처리 기법에 기초하여 공간 정규화된 단층 촬영 이미지를 생성하는 것일 수 있다.

[0107] 크로핑부(250)는 공간 정규화된 단층 촬영 이미지에 있어서 객체 영역인 뇌 영역에 해당하는 부분을 경계로 한 테두리 부분을 포함하되 기설정된 이미지 사이즈를 가지도록 뇌 영역에 해당하는 부분을 경계로 한 테두리의 배경 영역을 제거한다(S250).

[0108] 뇌를 단층 촬영하여 획득되는 이미지의 경우, 아밀로이드가 침착된 정도에 따라서 고음영 부분과 저음영 부분으로 구분되는 뇌 영역과, 뇌 영역과 무관한 배경 영역으로 구분될 수 있다.

[0109] 크로핑부(250)는 공간 정규화된 단층 촬영 이미지들에 있어서 에지를 검출하여 에지 내부의 영역을 뇌 영역으로 추출하여 배경 영역을 제거하는 것일 수 있다.

[0110] 뇌 영역은 배경 영역과 대비하여 명도 값의 차이가 크므로 뇌 영역과 배경 영역을 에지 검출에 따라 쉽게 구분할 수 있다.

[0111] 크로핑부(250)는 공간 정규화된 단층 촬영 이미지들에 대해 에지 검출을 수행함에 따라 추출되는 에지 성분들에 각각 대응되는 픽셀들을 연결하여 폐곡선을 생성하도록 하고, 곡률 반경이 작은 쪽인 폐곡선의 안쪽을 뇌 영역으로 추출하여 배경 영역을 제거하는 것일 수 있다.

[0112] 크로핑부(250)는 에지는 영상에서 명도의 변화가 많은 부분에서 발생하므로 인접해 있는 픽셀들 간의 픽셀값을 비교하여 차이가 큰 경우를 변화하는 경계에 해당되는 부분으로 하여 에지 영역을 추출하도록 하고 뇌 영역과 배경 영역을 구분하는 것일 수 있다.

[0113] 크로핑부(250)에 의해 단층 촬영 이미지는 400 X 400 픽셀의 사이즈에서 95 X 79 픽셀의 사이즈로 변환될 수 있다.

[0114] 강도 정규화부(300)는 배경 영역이 제거된 단층 촬영 이미지에 있어서 특이성 섭취 영역과 비특이성 섭취 영역을 구분하기 위하여 기설정된 마스크를 적용하여 강도 정규화를 수행하고 강도 정규화된 단층 촬영 이미지를 생성한다(S300).

[0115] 여기서, 특이성 섭취(Specific Uptake) 영역은 병의 유무에 따라 아밀로이드 침착이 결정되는 영역을 나타내고, 비특이성 섭취(Non-specific Uptake) 영역은 병의 유무에 상관없이 항상 아밀로이드 침착이 되는 영역을 나타내는 것일 수 있다.

[0116] 병이 없는 환자의 단층 촬영 이미지에서의 특이성 섭취 영역에서는 아밀로이드 침착이 되지 않을 것이고, 병이 있는 환자의 단층 촬영 이미지에서의 특이성 섭취 영역에서는 아밀로이드 침착이 될 것이며, 병의 유무와 관계없이 비특이성 영역에서는 아밀로이드 침착이 항상 되는 것일 수 있다.

[0117] 도 2를 참조하면, 뇌의 백질(White matter) 영역을 비특이성 섭취 영역(301)으로 관찰할 수 있고, 대뇌 회백질 영역을 특이성 섭취 영역(303)으로 관찰할 수 있다.

[0118] 또한, 강도 정규화부(300)는 단층 촬영 이미지에 속하는 픽셀들과 기설정된 마스크간에 사칙연산을 적용하여 강도 정규화를 수행하는 것일 수 있다.

[0119] 강도 정규화부(300)는 배경 영역이 제거된 단층 촬영 이미지가 가지는 전체 픽셀값을 뇌의 백질(White matter) 영역인 비특이성 섭취 영역(301)이 가지는 픽셀값으로 나누어 강도 정규화를 수행하여 강도 정규화된 단층 촬영 이미지를 생성하는 것일 수 있다.

[0120] 다시 말해, 강도 정규화부(300)가 단층 촬영 이미지에서의 뇌의 백질(White matter) 영역인 비 특이성 섭취 영역에 해당하는 픽셀값으로 단층 촬영 이미지의 전체 픽셀값을 나눠주게 되면(즉, 강도 정규화를 하면), 전체 단층 촬영 이미지에서 비 특이성 섭취 영역의 픽셀값은 1에 가까울 것이기 때문에 관찰하고자 하는 영역인 특이성 섭취 영역을 1에 가까운 값을 가지는 비 특이성 섭취 영역을 기준으로 정상인과 비정상인의 단층 촬영 이미지 비교가 가능한 것일 수 있다.

[0121] 강도 정규화부(300)는 강도 정규화된 단층 촬영 이미지를 생성함으로써, 환자 간의 단층 촬영 이미지에서 특이성 섭취 영역에 기초하여 절대적 및 상대적 비교를 할 수 있다.

[0122] 스케일링부(350)는 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값들을 기설정된 범위 내의 값으로 스케일링하여 정규화 이미지를 생성한다(S350).

[0123] 도 3를 참조하면, 단층 촬영 이미지에서 픽셀값의 분포 변화는 딥러닝(Deep-learning) 기반의 합성곱 신경망(CNN, Convolution Neural Network)에서 학습할 가중치(Weight)의 스케일(Scale) 변화에 영향을 주기 때문에, 스케일링부(350)는 CNN 모델에서 학습할 가중치의 스케일을 일정한 범위 내에서 분포할 수 있게 강도 정규화된 단층 촬영 이미지가 가지는 픽셀값을 기설정된 범위 내의 값으로 스케링일링 하는 것일 수 있다.

[0124] 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법은 진단 대상자의 단층 촬영 이미지를 S200, S250, S300, S350 단계에 의해 정규화된 정규화 이미지를 딥러닝 기반의 CNN 모델에 적용하여 진단 대상자의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환을 진단할 수 있으며, S100 단계에서 입력받은 400 X 400 사이즈의 단층 촬영 이미지는 97 X 79 사이즈의 정규화 이미지로 변환되어 CNN 모델에 적용될 수 있다.

[0125] 합성곱 신경망(CNN, Convolution Neural Network)은 단층 촬영 이미지(영상)로부터 테두리, 선 색 등과 같은 특징(features)들을 추출하는 신경망 기법으로서, 복수의 계층들(layers)을 포함할 수 있다. 각각의 계층(layer)은 입력 데이터를 수신하고, 해당 계층의 입력 데이터를 처리하여 출력 데이터를 생성할 수 있다. 합성곱 신경망은 입력된 영상 또는 입력된 특징맵(feature map)을 필터 커널들(filter kernels)과 컨볼루션하여 생성한 특징맵을 출력 데이터로서 출력할 수 있다. 합성곱 신경망의 초기 계층들은 입력으로부터 에지들 또는 그레디언트들과 같은 낮은 레벨의 특징들을 추출하도록 동작될 수 있다. 신경망의 다음 계층들은 눈, 코 등과 같은 점진적으로 더 복잡한 특징들을 추출할 수 있다.

[0126] 합성곱 신경망은 컨볼루션 연산이 수행되는 합성곱 계층(Convolution Layer) 외에도 풀링 연산이 수행되는 풀링 계층(Pooling Layer)도 포함할 수 있다. 풀링 기법은 풀링 계층에서 데이터의 공간적 크기를 축소하는데 사용되는 기법이다. 구체적으로, 풀링 기법에는 해당 영역에서의 최대값을 선택하는 맥스 풀링(Max Pooling) 기법과 해당 영역의 평균값을 선택하는 평균 풀링(Average Pooling) 기법이 있으며, 이미지 인식 분야에서는 일반적으로 맥스 풀링 기법이 사용된다. 풀링 기법에서는 일반적으로 풀링의 윈도우 크기와 간격(스트라이드, stride)을 같은 값으로 설정한다. 여기서, 스트라이드란 입력 데이터에 필터를 적용할 때 이동할 간격을 의미하며, 스트라이드 또한 출력 데이터의 크기를 조절하기 위해 사용될 수 있다.

[0127] 파라미터부(400)는 정규화 이미지에 대해서 기설정된 마스크와 컨볼루션 연산을 수행함에 따라 반복 학습하여 획득된 기설정된 파라미터들을 저장한다(S400).

[0128] 컨볼루션 레이어부(450)는 정규화 이미지에 있어서 파라미터들에 따른 필터를 이용하여 컨볼루션 연산하여 정규화 이미지에 대한 복수 개의 특징맵을 생성한다(S450).

[0129] 컨볼루션 레이어부(450)는 정규화 이미지에서 특징을 검출하기 위해 기설정된 사이즈의 행렬로 정의되는 복수개의 필터를 이용하여 정규화 이미지의 픽셀값과 컨볼루션 연산하여, 정규화 이미지에서 필터가 가지는 특성이 있으면 결과값이 큰 값이 산출되고, 정규화 이미지에서 필터가 가지는 특성이 없으면 결과값이 0에 가까운 값이 산출되어 정규화 이미지가 복수 개의 필터에 대한 특성을 가지고 있는지 없는지 여부를 알 수 있다.

[0130] 컨볼루션 레이어부(450)는 정규화 이미지에 있어서, 서로 다른 특징을 추출하는 필터가 좌측에서 우측으로, 또

는 상단에서 하단으로 사용자의 입력에 따른 간격(스트라이드, stride)만큼 이동하면서 정규화 이미지와 필터가 겹치는 영역 내에서 컨볼루션 연산을 수행하고, 그 결과로, 복수 개의 특징맵(feature map)을 생성하는 것일 수 있다.

[0131] 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법에서는 필터 커널의 사이즈를 3 X 3, 간격(스트라이드, stride)은 1로 설정하였지만, 본 개시가 이를 한정하는 것은 아니며, 이미지의 사이즈, 특징에 따라 다양하게 변경될 수 있다.

[0132] 풀링부(500)는 정규화 이미지에 대한 특징맵에 대하여 복수 개의 연산값에 대한 대표값을 할당하여 특징맵에 대한 컨볼루션 연산값의 사이즈를 축소하고 풀링 이미지를 생성한다(S500).

[0133] 합성곱 신경망 모델에서 합성곱 계층(Convolution layer)을 통해서 특징맵이 추출되면, 고해상도 사진을 보고 물체를 판별할 수 있지만, 작은 사진을 가지고도 그 사진의 내용이 어떤 사진인지 판단할 수 있는 원리와 마찬가지로, 이 모든 특징을 가지고 판단을 할 필요가 없기 때문에 생성된 특징맵의 사이즈를 인위적으로 줄이는 풀링(Pooling) 작업을 수행할 수 있다.

[0134] 풀링부(500)는 특징맵을 기설정된 동일한 사이즈를 가지는 복수 개의 영역으로 분할하여 각 영역 내에서 최대값에 기초하여 각 영역을 하나의 값으로 추출하여 특징맵의 사이즈를 축소하고 풀링 이미지를 생성하는 것일 수 있다.

[0135] 도 4를 참조하면, 풀링부(500)는 맥스 풀링(Max Pooling) 필터를 특징맵의 좌측 상단에 위치시키고 기설정된 간격(스트라이드, stride) 만큼 우측으로 이동하면서 필터 영역 내의 값들 중 최대값을 추출한다. 이 후, 더 이상 우측으로 필터를 이동시킬 수 없는 경우 특징맵의 좌측에서서 기설정된 간격(스트라이드, stride) 만큼 아래의 위치부터 우측으로 이동하면서 필터 영역 내의 값들 중 최대값을 추출하여, 최대값을 조합함에 따른 풀링 이미지를 생성하는 것일 수 있다.

[0136] 본 발명의 다른 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 방법에서는 맥스 풀링(Max Pooling) 필터의 사이즈를 2 X 2, 간격(스트라이트, stride)를 2로 설정하였지만, 이에 한정되는 것은 아니다.

[0137] 풀링부(500)는 풀링(Pooling) 기법으로 전체 데이터의 사이즈가 줄어들기 때문에 연산 과정이 적어지고, 데이터의 크기를 줄이면서 소실이 발생하기 때문에 샘플 데이터에 과적합되는 오버피팅(Overfitting)을 방지할 수 있는 효과가 있다.

[0138] 본 발명의 일 실시예에 따른 딥러닝 기반의 아밀로이드 양성 반응을 나타내는 퇴행성 뇌질환 이미지 분류 장치에서 컨볼루션 레이어부(450)와 풀링부(500)를 차례대로 기설정된 횟수만큼 반복 수행할 수 있고, 컨볼루션 레이어부(450)와 풀링부(500)의 반복 수행으로 컨볼루션 레이어부(450)는 복수 개의 최종 특징맵을 생성할 수 있다.

[0139] 벡터 생성부는 특징맵이 가지는 사이즈를 축소시켜 특징맵의 갯수와 동일한 갯수의 노드를 가지는 벡터를 생성한다(S550).

[0140] 벡터 생성부(550)는 복수 개의 최종 특징맵의 갯수는 유지하고 각 특징맵이 가지는 사이즈를 축소시켜 최종 특징맵의 갯수와 동일한 노드(node)를 가지는 벡터를 생성하는 것일 수 있다..

[0141] 도 5를 참조하면, 벡터 생성부(550)는 GAP(Global Average Pooling) 기법을 이용하여 복수 개의 최종 특징맵에서 각 특징맵의 픽셀값의 평균값을 산출하고 각 특징맵의 평균값을 하나의 노드로 추출하여 벡터를 생성하는 것일 수 있다.

[0142] 예를 들어, 벡터 생성부(550)는 LW X LH의 사이즈로 이루어진 LF(Last Feature map)개의 최종 특징맵을 각 특징맵의 평균값을 산출하여 하나의 값으로 요약하여 1 X 1 사이즈, 최종 특징맵의 노드 갯수와 같은 LF개의 노드로 이루어진 벡터를 생성하는 것일 수 있다.

[0143] 풀리 커넥티드 레이어부(600)는 S550 단계에서 생성한 벡터 내의 노드와 S150 단계에서 생성한 각 클래스의 노드를 완전 연결시킨다(S600).

[0144] 여기서, 완전 연결은 벡터 내의 LF개의 노드와 클래스 내의 노드를 각각 연결한다는 것을 의미한다. 예를 들어, 클래스의 갯수가 C개 라고 가정하면, LF개의 노드와 클래스 내의 C개의 노드를 완전 연결하면 클래스 내의 각 노드들은 벡터 내의 LF개의 각 노드와 연결될 것이고, 벡터 내의 각 노드들은 클래스 내의 C개의 각 노드와 연

결될 것이다. 여기서, 각 노드(node) 간 완전 연결되는 것은 CNN 모델을 수행하면서 학습된 가중치(Weight)를 나타낼 것이며, 서로 다른 수치로 이루어진 가중치(Weight)의 갯수는 LF X C개가 되는 것일 수 있다.

[0145] 여기서, 가중치(Weight)는 최종 특징맵의 특징들을 얼마나 반영하여 복수 개의 클래스 중에서 어떤 클래스를 결정할 것인지에 대한 수치를 나타내며 채널의 중요도인 것일 수 있다. 즉, LF X C개의 가중치(Weight) 값을 LF개의 최종 특징맵의 각 픽셀값과 각각 곱한 수치를 각 최종 특징맵에서 가장 특징이 되는 부분인 것일 수 있다.

[0146] 풀리 커넥티드 레이어부(600)는 벡터 내의 노드와 각 클래스의 노드를 완전 연결시켜 정규화 이미지를 클래스별로 분류하는 것일 수 있다.

[0147] 히트맵 생성부(650)는 최종 특징맵과 가중치와의 가중합을 수행하여 클래스 갯수 만큼의 복수 개의 픽셀값으로 이루어진 히트맵을 생성한다(S650).

[0148] 히트맵 생성부(650)는 벡터 내의 노드와 클래스 내의 노드와, 완전 연결된 가중치와 최종 특징맵 내의 노드 각각과 가중합을 수행하여 클래스 내의 노드 갯수 만큼의 히트맵(Heat map)을 생성하는 것일 수 있다.

[0149] 여기서, 히트맵(Heat map)의 사이즈는 최종 특징맵과 같은 사이즈를 가지는 것일 수 있다.

[0150] 예를 들어, 히트맵 생성부(650)는 최종 특징맵 내의 LF개의 노드와 LF X C개의 가중치와 가중합을 수행하여 클래스 내의 노드 갯수인 C개 만큼의 히트맵을 생성하는 것일 수 있다.

[0151] 여기서, 히트맵(Heat map)은 클래스 활성화 맵(Class Activation map)을 의미하는 것일 수 있다.

[0152] 확률 산출부(700)는 정규화 이미지가 상기 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출한다(S700).

[0153] 확률 산출부(700)는 클래스 별로 분류된 정규화 이미지가 복수 개의 클래스들 중 적어도 하나의 클래스에 대응되는 확률을 산출하는 것일 수 있다.

[0154] 확률 산출부(700)는 벡터 내의 노드와 클래스 내의 노드가 완전 연결되어 벡터 내의 노드와 가중치가 가중합을 수행하여 클래스 노드 내에 결과값을 출력하여 확률을 산출하는 것일 수 있다.

[0155] 확률 산출부(700)는 벡터 내의 노드와 LF X C개의 가중치와 가중합을 수행하고 가중합을 수행한 출력값을 Softmax 함수에 기초하여 각 출력값이 각 클래스 내에 대응되는 확률을 산출하는 것일 수 있다.

[0157] 이상, 바람직한 실시예를 통하여 본 발명에 관하여 상세히 설명하였으나, 본 발명은 이에 한정되는 것은 아니며 특허청구범위 내에서 다양하게 실시될 수 있다. 특히, 전술한 내용은 후술할 발명의 청구범위를 더욱 잘 이해할 수 있도록 본 발명의 특징과 기술적 강점을 다소 폭넓게 상술하였으므로, 상술한 본 발명의 개념과 특정 실시예는 본 발명과 유사 목적을 수행하기 위한 다른 형상의 설계나 변경의 기본으로써 즉시 사용될 수 있음이 해당 기술 분야의 숙련된 사람들에 의해 인식되어야 한다.

[0158] 또한, 상기에서 기술된 실시예는 본 발명에 따른 하나의 실시예일 뿐이며, 해당 기술분야에서 통상의 지식을 가진 자에 의해 본 발명의 기술적 사상의 범위에서 다양한 수정 및 변경된 형태로 구현될 수 있음을 이해할 수 있을 것이다. 따라서, 개시된 실시예는 한정적인 관점이 아니라 설명적인 관점에서 고려되어야 하고, 이러한 다양한 수정 및 변경 또한 본 발명의 기술적 사상의 범위에 속하는 것으로 후술할 본 발명의 청구범위에 나타나 있으며, 그와 동등한 범위 내에 있는 모든 차이점은 본 발명에 포함된 것으로 해석되어야 할 것이다.

부호의 설명

[0159] 100: 단층 촬영 이미지 입력부,

150: 클래스 생성부,

200: 공간 정규화부,

250: 크로핑부,

300: 강도 정규화부,

301: 비특이성 섭취 영역,

303: 특이성 섭취 영역,

350: 스케일링부,

400: 파라미터부,

450: 컨볼루션 레이어부,

500: 풀링부,

550: 벡터 생성부,

600: 풀리 커넥티드 레이어부,

650: 히트맵 생성부,

700: 확률 산출부.

도면

도면1

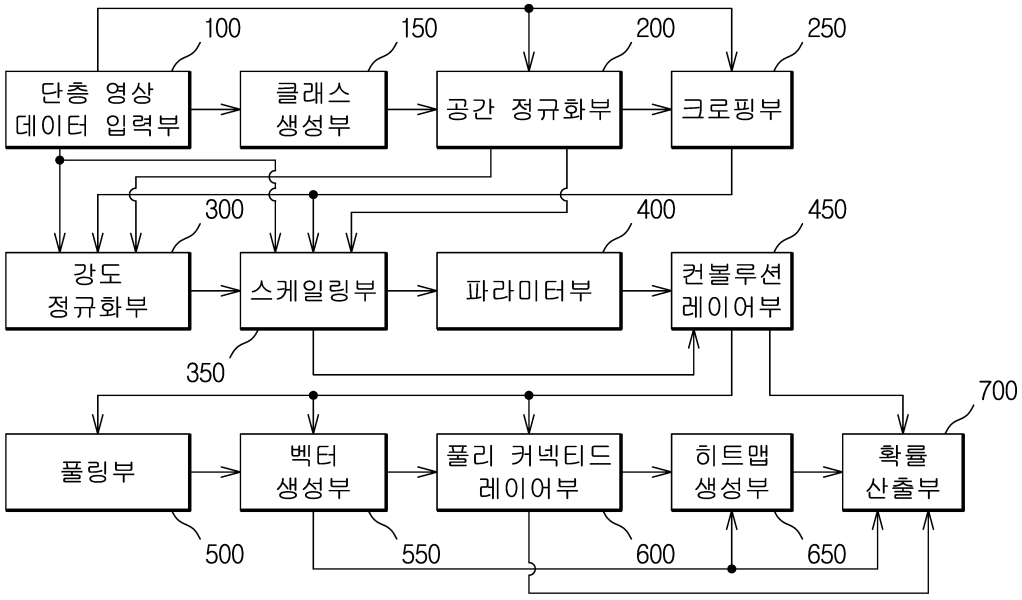

도면2

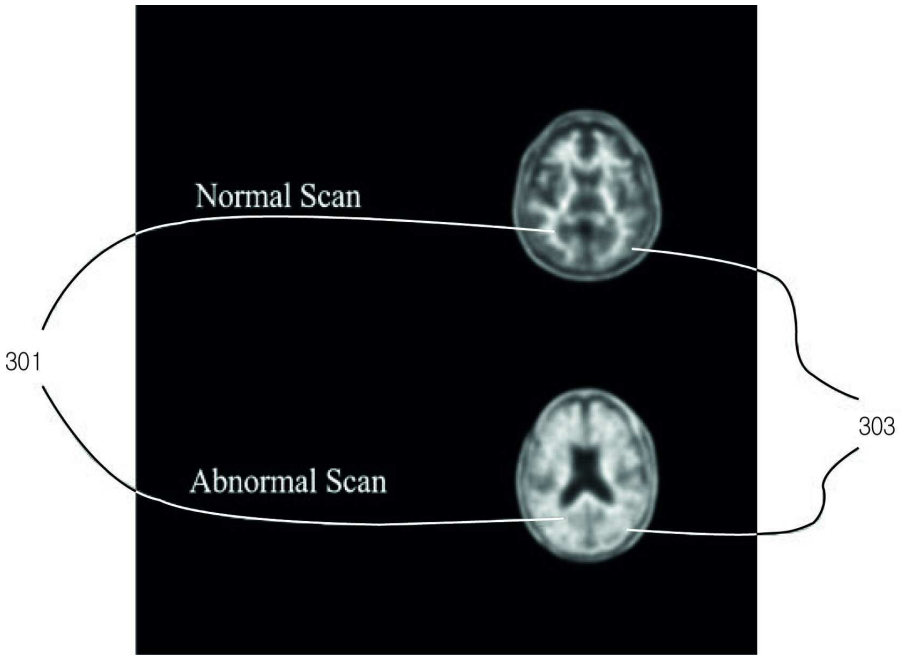
Normal Scan
Abnormal Scan
301
303

도면3

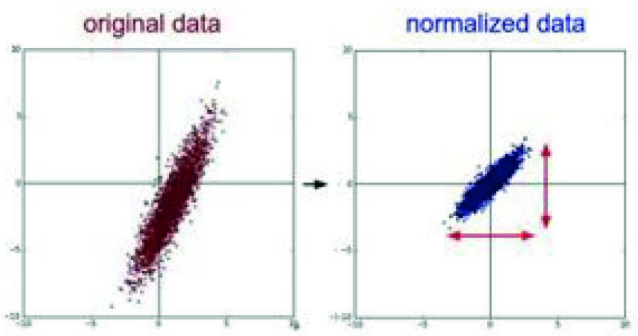
original data
normalized data

도면4

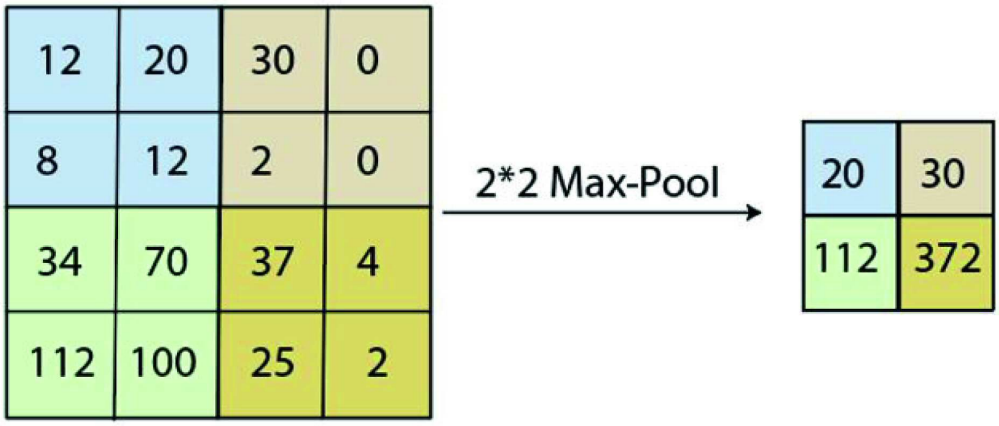
12
20
30
0
8
12
2
0
34
70
37
4
112
100
25
2
2*2 Max-Pool
20
30
112
372

도면5

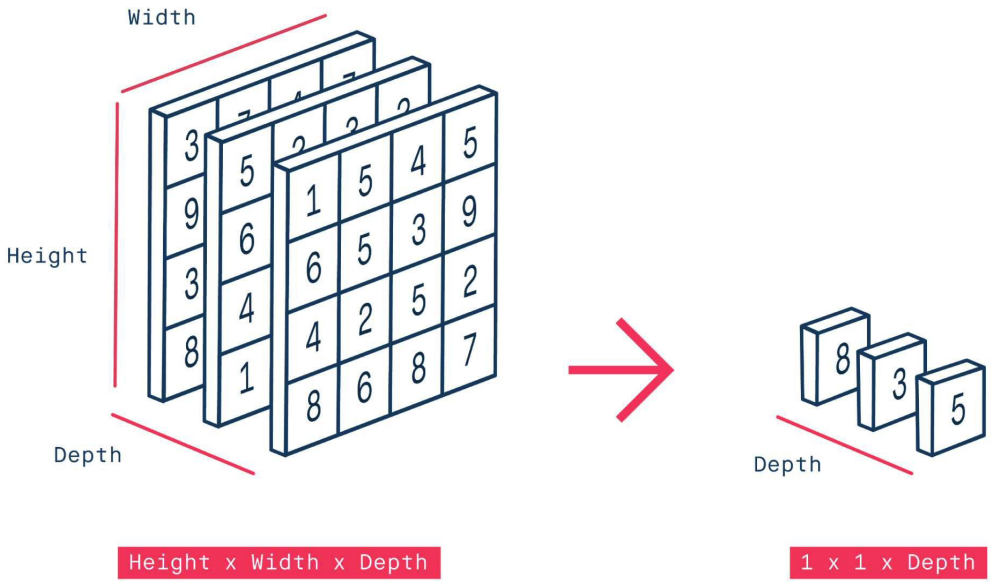
Width
Height
Depth
Height x Width x Depth
1 x 1 x Depth

도면6

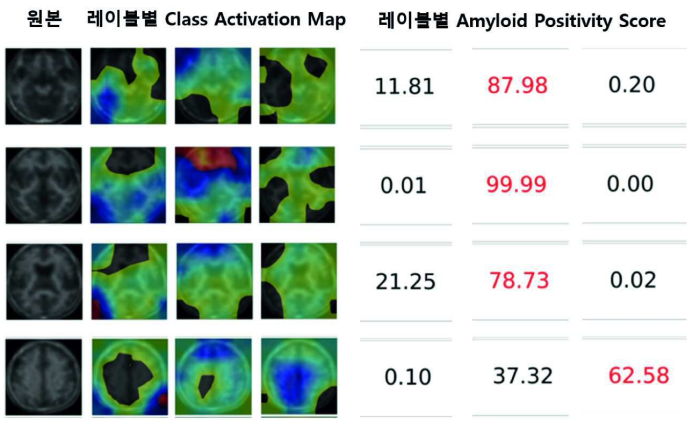
원본
레이블별 Class Activation Map
레이블별 Amyloid Positivity Score
11.81
87.98
0.20
0.01
99.99
0.00
21.25
78.73
0.02
0.10
37.32
62.58

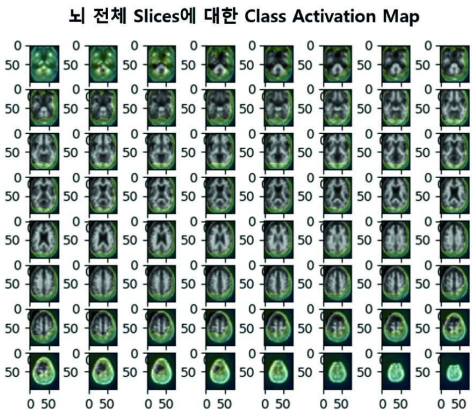
뇌 전체 Slices에 대한 Class Activation Map

도면7

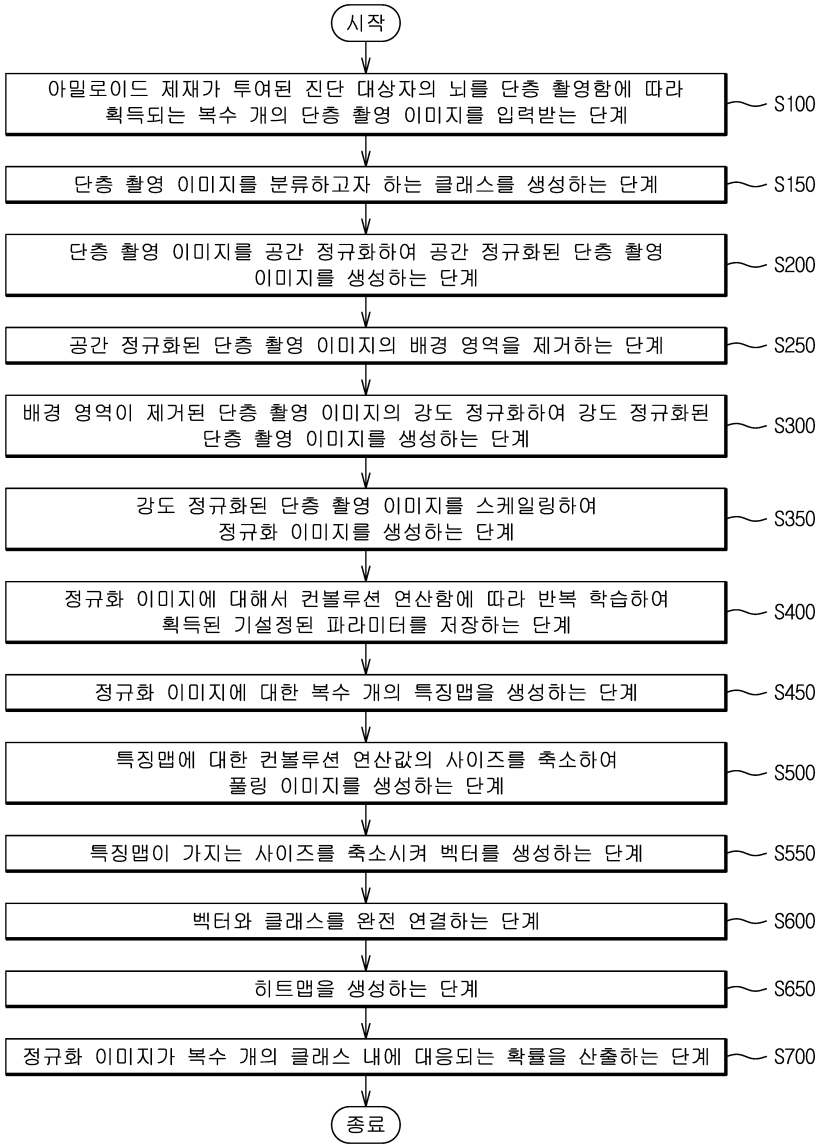
시작
아밀로이드 제재가 투여된 진단 대상자의 뇌를 단층 촬영함에 따라 획득되는 복수 개의 단층 촬영 이미지를 입력받는 단계
S100
단층 촬영 이미지를 분류하고자 하는 클래스를 생성하는 단계
S150
단층 촬영 이미지를 공간 정규화하여 공간 정규화된 단층 촬영 이미지를 생성하는 단계
S200
공간 정규화된 단층 촬영 이미지의 배경 영역을 제거하는 단계
S250
배경 영역이 제거된 단층 촬영 이미지의 강도 정규화하여 강도 정규화된 단층 촬영 이미지를 생성하는 단계
S300
강도 정규화된 단층 촬영 이미지를 스케일링하여 정규화 이미지를 생성하는 단계
S350
정규화 이미지에 대해서 컨볼루션 연산함에 따라 반복 학습하여 획득된 기설정된 파라미터를 저장하는 단계
S400
정규화 이미지에 대한 복수 개의 특징맵을 생성하는 단계
S450
특징맵에 대한 컨볼루션 연산값의 사이즈를 축소하여 풀링 이미지를 생성하는 단계
S500
특징맵이 가지는 사이즈를 축소시켜 벡터를 생성하는 단계
S550
벡터와 클래스를 완전 연결하는 단계
S600
히트맵을 생성하는 단계
S650
정규화 이미지가 복수 개의 클래스 내에 대응되는 확률을 산출하는 단계
S700
종료