



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0018758
(43) 공개일자 2024년02월14일

(51) 국제특허분류(Int. Cl.)
A61B 3/00 (2006.01) A61B 3/12 (2006.01)
G06N 3/04 (2023.01) G06N 3/08 (2023.01)
G16H 30/40 (2018.01) G16H 50/20 (2018.01)
(52) CPC특허분류
A61B 3/0025 (2013.01)
A61B 3/12 (2013.01)
(21) 출원번호 10-2022-0096467
(22) 출원일자 2022년08월03일
심사청구일자 2022년08월03일

(71) 출원인
포항공과대학교 산학협력단
경상북도 포항시 남구 청암로 77 (지곡동)
주식회사 에이아이인사이트
부산광역시 서구 구덕로 187 ,융합의학연구동3층(아미동1가,부산대학교병원)
(뒷면에 계속)
(72) 발명자
유환조
경북 포항시 남구 청암로 77
김형희
부산 남구 전포대로40번길 34-12
김수연
경북 포항시 남구 지곡로 294
(74) 대리인
김종석

전체 청구항 수 : 총 9 항

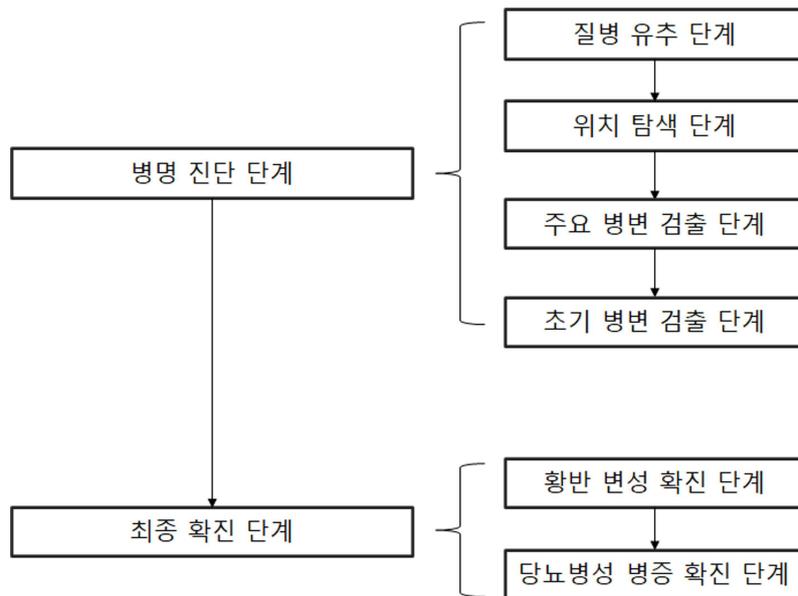
(54) 발명의 명칭 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법

(57) 요약

본 발명은 안저 영상에서 초기 질환 자동판독을 위한 딥러닝 학습방법에 관한 것으로, 더욱 상세하게는 초기 안저 질환의 특성을 용이하게 감지할 수 있고, 적은 양의 데이터로 초기 질환을 잘 구분할 수 있도록 구성된 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법에 관한 것이다.

(뒷면에 계속)

대표도 - 도1



본 발명에 따른 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법은, 다수개로 마련된 브랜치모듈(200)을 이용하여 안저이미지에 대한 병변을 식별하여 해당하는 병명을 진단하는 병명 진단 단계; 및 상기 브랜치모듈(200)로부터 진단된 데이터를 최종확진부(300)가 통합하여 최종 질환명을 결정하여 출력하는 최종 확진 단계;를 포함하되, 추가로 새로운 안저이미지 데이터가 입력되는 경우 상기 브랜치모듈(200)의 파라미터를 고정하고 상기 항반변성확진부(310) 및 당뇨병성확진부(320) 중 어느 하나 이상에 대해 학습 훈련을 수행하며, 상기 학습 훈련은 상기 새로운 안저이미지 데이터에 가중치를 부가하여 상기 새로운 데이터의 분류 정확도를 증가시키는 것을 특징으로 한다.

(52) CPC특허분류

G06N 3/042 (2023.01)

G06N 3/08 (2023.01)

G16H 30/40 (2018.01)

G16H 50/20 (2018.01)

부산대학교병원

부산광역시 서구 구덕로 179, 부산대학병원 (아미동1가)

(71) 출원인

부산대학교 산학협력단

부산광역시 금정구 부산대학로63번길 2 (장전동, 부산대학교)

이 발명을 지원한 국가연구개발사업

과제고유번호 1465036253

과제번호 HR20C0026040022

부처명 보건복지부

과제관리(전문)기관명 한국보건산업진흥원

연구사업명 연구중심병원 육성 R&D

연구과제명 AI-POCT 기반 Screening & Care Solution 개발을 통한 지역사회 건강노화 플랫폼

구축

기여율 1/1

과제수행기관명 부산대학교병원

연구기간 2022.01.01 ~ 2022.12.31

명세서

청구범위

청구항 1

다수개로 마련된 브랜치모듈(200)을 이용하여 안저이미지에 대한 병변을 식별하여 해당하는 병명을 진단하는 병명 진단 단계; 및

상기 브랜치모듈(200)로부터 진단된 데이터를 최종확진부(300)가 통합하여 최종 질환명을 결정하여 출력하는 최종 확진 단계;를 포함하되,

상기 병명 진단 단계는,

질병유추부(210)가 의사의 차팅 과정에서 매칭된 질병명 또는 질병코드로 학습데이터를 생성하여 질병의 카테고리를 유추하되, 데이터의 라벨링에서 비계층적 싱글 라벨링으로 수행하는 질병 유추 단계;

위치탐색부(220)가 상기 안저이미지에서 시삭신경원반(Optic nerve head, ONH)을 찾고 시신경유두(disc) 및 황반(macula)의 위치를 탐색하여 이에 따라 녹내장 레벨을 분류하는 위치 탐색 단계;

주요병변검출부(230)가 질병을 구성하는 요소가 되는 주요 병변(key lesion)을 찾는 주요 병변 검출 단계; 및

초기병변검출부(240)가 상기 안저이미지에서 안저 병변 초기에만 나타나는 특성을 찾도록 학습하는 초기 병변 검출 단계;로 구성되고,

상기 최종 확진 단계는,

황반변성확진부(310)가 황반 변성을 확진하는 황반 변성 확진 단계; 및

당뇨병성확진부(320)가 당뇨병성 병증을 확진하는 당뇨병성 병증 확진 단계;로 구성되며,

추가로 새로운 안저이미지 데이터가 입력되는 경우 상기 브랜치모듈(200)의 파라미터를 고정하고 상기 황반변성 확진부(310) 및 당뇨병성확진부(320) 중 어느 하나 이상에 대해 학습 훈련을 수행하되,

상기 학습 훈련은 상기 새로운 안저이미지 데이터에 가중치를 부가하여 상기 새로운 데이터의 분류 정확도를 증가시키는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법.

청구항 2

제 1항에 있어서,

상기 질병 유추 단계는,

하나의 이미지에 가장 두드러지는 하나의 질병만 라벨링하는 싱글 라벨링을 수행하고,

다중 분류 문제에서 서로 배타적이고 독립적으로 라벨링하는 비계층적 라벨링을 수행하는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법.

청구항 3

제 1항에 있어서,

상기 위치 탐색 단계는,

디스크가 검출 되지 않는 경우(0), 녹내장 없음(1), 녹내장 의심(2), 녹내장 있음(3) 및 비정상 디스크(4)로 상기 녹내장 레벨을 분류하는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법.

청구항 4

제 1항에 있어서,

상기 초기 병변 검출 단계는,

상기 안저이미지에서 황반 변성 초기 및 당뇨병 초기와 관련된 노란점 및 빨간점의 개수를 출력하는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법.

청구항 5

제 1항에 있어서,

상기 학습 훈련은 아래 [수학식 1]의 손실함수에 의해 수행되는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법 :

[수학식 1]

$$focalloss = -(1-p_t)^\gamma \times \log(p_t)$$

(p_t : t번째 샘플의 모델 결과값이 정답 레이블을 가질 확률값, γ : 하이퍼 파라미터, 모델을 학습 시키는 과정에서 모델 성능을 높이기 위해 임의로 조정하는 변수).

청구항 6

제 1항에 있어서,

상기 새로운 안저이미지 데이터의 가중치는 학습에 사용한 전체 이미지데이터 수에 반비례하는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법.

청구항 7

제 1항에 있어서,

상기 학습 훈련에서 전체 안저이미지 데이터의 가중 평균 손실함수는 아래 [수학식 2]에 의해 수행되는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법 :

[수학식 2]

$$Totalloss = \frac{1}{N} \sum_{i=1}^N w_i \times focalloss(i, class[i])$$

(w : 각 데이터가 속한 데이터셋의 해당 클래스가 전체 데이터 중에 차지하는 비율, i : 정답 class, focal loss : $-(1-p_t)^\gamma \times \log(p_t)$, p_t : t번째 샘플의 모델 결과값이 정답 레이블을 가질 확률값, γ : 하이퍼 파라미터, 모델을 학습 시키는 과정에서 모델 성능을 높이기 위해 임의로 조정하는 변수).

청구항 8

제 7항에 있어서,

상기 학습 훈련은 상기 [수학식 1]의 손실함수를 낮추는 방향으로 수행되는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법.

청구항 9

제 1항에 있어서,

상기 최종 확진 단계는,

입력 레이어(X), 은닉 레이어(v) 및 출력 레이어(y)로 구성된 퍼셉트론 레이어를 여러 겹 쌓은 형태의 알고리즘을 사용하여 최종 질환명을 결정하는 것을 특징으로 하는 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습 방법.

발명의 설명

기술 분야

[0001] 본 발명은 안저 영상에서 초기 질환 자동판독을 위한 딥러닝 학습방법에 관한 것으로, 더욱 상세하게는 초기 안저 질환의 특성을 용이하게 감지할 수 있고, 적은 양의 데이터로 초기 질환을 잘 구분할 수 있도록 구성된 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법에 관한 것이다.

배경 기술

[0003] 최근 영상인식 분야에 비약적인 발전을 가져온 딥러닝 신경망은 합성곱신경망 (convolutional neural network, CNN) 이다. 합성곱신경망은 맨 처음 입력 이미지 데이터에 계속해서 반복적으로 필터(filter)를 합성곱 하여 다음 단계의 레이어에 전달하는 것을 특징으로 한다. 합성곱신경망 아키텍처는 초기 AlexNet에서 시작하여 구글의 LeNet, Inception, Skip connection을 특징으로 하는 ResNet 등이 있다. 이들은 서로 다른 아키텍처이지만, 공통적으로 합성곱(convolution)을 수직으로 쌓아가며 전역 특징(global feature)을 추출해내는 특징 추출(feature extraction) 부분과 판단을 내리는 분류 층(classification layer)으로 구성되어 있다. 인공신경망은 degradation problem이라 하여 레이어가 깊어질수록 앞쪽의 정보가 뒤쪽으로 잘 전달되지 않고 희석되는 문제가 있다. 이는 학습과정에서 역전파가 일어날 때에도 마찬가지이며, 오차의 역전파 과정에서 앞쪽으로 되돌아 갈수록 오차가 거의 전달되지 않아 학습이 이루어 지지 않아 신경망의 가중치 값들이 거의 업데이트 되지 않는다. 오차의 역전파 과정에서 앞쪽 레이어가 잘 학습되지 않는 문제를 vanishing gradient problem이라고도 한다.

[0004] 앞서 본 출원인(한국등록특허 10-2281968)은 이러한 문제점을 해결하고, 오히려 이러한 인공신경망의 특징을 역으로 이용하여 신경망 전체를 처음부터 학습시키지 않고 상대적으로 얼마 되지 않는 병목(bottleneck) 부분만 빠르게 학습시키는 방법을 통해 적은 양의 데이터로 학습이 가능하고, 의료 영상 중 안저 영상의 특징을 이용하여 안저 영상을 자동으로 판독할 수 있는 안저영상 자동판독을 위한 딥러닝 학습방법을 제공하였다.

[0005] 한편, 안저 질환의 초기에는 정상과 비정상을 구분하기 어려워 안저 질환의 초기 발견은 매우 힘들며, 이에 따라 안저 영상을 통한 초기 질환의 자동 판독이 어려운 문제점이 있었다. 딥러닝 학습방법을 이용하여 초기 질환을 잘 예측하기 위해서는 많은 데이터가 필요하고, 초기 데이터와 중기 이후 데이터를 같이 학습 시 모델은 구분이 쉬운 중기 이후 데이터의 특성에 집중하게 되어 상대적으로 초기 데이터를 감지하는 능력이 떨어지게 된다. 이러한 문제를 해결하기 위해 일반적으로는 데이터의 양을 늘려 안저의 초기 질환을 자동 판독하나, 이에 따른 데이터의 레이블링 비용이 비싼 문제점이 있다. 따라서 본 발명은 초기 병변의 특성을 감지하기 위해 별도의 모듈을 추가하여 적은 양의 데이터로 초기 질환을 잘 구분할 수 있는 딥러닝 학습방법을 제공하고자 한다.

선행기술문헌

비특허문헌

[0007] (비특허문헌 0001) Varun Gulshan, PhD; Lily Peng, MD, PhD; Marc Coram, PhD; et al. “Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs” December 13, 2016, JAMA. 2016;316(22):2402-2410. doi:10.1001/jama.2016.17216

발명의 내용

해결하려는 과제

- [0008] 본 발명은 상기의 문제점을 해결하기 위해서 안출된 것으로서, 본 발명의 목적은 안저 영상 학습을 위한 데이터 요구량을 최소화 하고 안과 의사가 의학지식을 습득하는 것과 비슷한 방식으로 인공지능을 훈련하여 안저 영상을 자동 판독할 수 있는 학습방법을 제공하는 것이다.
- [0009] 또한, 본 발명은 적은 데이터로도 초기 안저 병변 예측의 성능이 향상된 안저 영상을 자동 판독할 수 있는 학습방법을 제공하는 것이다.
- [0010] 발명이 해결하고자 하는 기술적 과제들은 이상에서 언급한 기술적 과제들로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

- [0012] 본 발명에 따른 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법은,
- [0013] 다수개로 마련된 브랜치모듈(200)을 이용하여 안저이미지에 대한 병변을 식별하여 해당하는 병명을 진단하는 병명 진단 단계; 및
- [0014] 상기 브랜치모듈(200)로부터 진단된 데이터를 최종확진부(300)가 통합하여 최종 질환명을 결정하여 출력하는 최종 확진 단계;를 포함하되,
- [0015] 상기 병명 진단 단계는,
- [0016] 질병유추부(210)가 의사의 차팅 과정에서 매칭된 질병명 또는 질병코드로 학습데이터를 생성하여 질병의 카테고리를 유추하되, 데이터의 라벨링에서 비계층적 싱글 라벨링으로 수행하는 질병 유추 단계;
- [0017] 위치탐색부(220)가 상기 안저이미지에서 시각신경원반(Optic nerve head, ONH)을 찾고 시신경유두(disc) 및 황반(macula)의 위치를 탐색하여 이에 따라 녹내장 레벨을 분류하는 위치 탐색 단계;
- [0018] 주요병변검출부(230)가 질병을 구성하는 요소가 되는 주요 병변(key lesion)을 찾는 주요 병변 검출 단계; 및
- [0019] 초기병변검출부(240)가 상기 안저이미지에서 안저 병변 초기에만 나타나는 특성을 찾도록 학습하는 초기 병변 검출 단계;로 구성되고,
- [0020] 상기 최종 확진 단계는,
- [0021] 황반변성확진부(310)가 황반 변성을 확인하는 황반 변성 확진 단계; 및
- [0022] 당뇨병성확진부(320)가 당뇨병성 병증을 확인하는 당뇨병성 병증 확진 단계;로 구성되며,
- [0023] 추가로 새로운 안저이미지 데이터가 입력되는 경우 상기 브랜치모듈(200)의 파라미터를 고정하고 상기 황반변성 확진부(310) 및 당뇨병성확진부(320) 중 어느 하나 이상에 대해 학습 훈련을 수행하되,
- [0024] 상기 학습 훈련은 상기 새로운 안저이미지 데이터에 가중치를 부가하여 상기 새로운 데이터의 분류 정확도를 증가시키는 것을 특징으로 한다.

발명의 효과

- [0026] 상기 과제의 해결 수단에 의해, 본 발명은 브랜치모듈 별로 각각 개별적인 훈련 할 수 있으면서, 전체 시스템에 영향을 미치지 않고 필요에 따라 일부분만 훈련 할 수 있는 효과가 있다. 즉, 본 발명은 어떤 변화가 생겨 신경망을 재학습 시켜야 할 필요가 있을 때, 전체를 다시 학습시키는 것이 아니라 필요한 부분(branch)만 학습시킬 수 있다.
- [0027] 또한, 본 발명은 안저 이미지의 카테고리를 분류하는 분류(classifier)하는 브랜치(branch)와 안저 이미지 내에

특정 관심 병변을 찾는 객체 탐지(object detector) 브랜치(branch)와 같이 서로 다른 기능을 하는 아키텍처의 장점을 각각 살리면서 하나의 아키텍처처럼 사용할 수 있다.

[0028] 또한, 본 발명은 전체 신경망의 기능 중 개별 기능만 따로 필요한 경우 섹션(section)만 분리하여 그 기능만 따로 사용할 수 있으므로 특정 기능을 이용하기 위해 아키텍처 전체를 사용하지 않으므로 효율적이다.

[0029] 또한, 본 발명은 이미 신경망을 훈련 한 후 새로운 라벨 리스트와 라벨된 데이터가 준비되었을 경우 그것을 처리하는 브랜치만을 하나 더 추가하여 신경망에 새로운 기능을 만들 수 있으므로, 새로운 기능을 추가하기 용이하다.

[0030] 또한, 본 발명은 개별의 아키텍처를 각각 실행한 것에 비해 속도가 빠른 효과가 있다.

[0031] 또한, 본 발명은 적은 데이터로도 초기 안저 병변 예측의 성능이 향상되고, 적은 양의 데이터로도 초기 질환을 잘 구분할 수 있다.

도면의 간단한 설명

[0033] 도 1은 본 발명인 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법의 순서도이다.

도 2는 본 발명의 기본 아키텍처인 안저 영상의 초기 질환 자동판독을 위한 딥러닝 아키텍처 시스템(Wisky)의 구성도이다.

도 3은 본 발명의 기초 아키텍처인 HydraNet(의료영상 자동판독을 위한 딥러닝 아키텍처 시스템) 및 Grem(안저 영상 자동판독을 위한 딥러닝 아키텍처 시스템)의 구성도이다.

도 4는 본 발명의 일실시예에 따라 안저 영상의 초기 질환 자동판독을 위해 기존 안저이미지 데이터에 추가로 새로운 안저이미지 데이터가 입력되어 추가 데이터를 이용한 학습 방법을 나타낸 일실시예이다.

도 5는 본 발명의 일실시예에 따라 최종확진부(300)에서 사용되는 다층 퍼셉트론 (multi layer perceptron, MLP) 알고리즘의 개략도이다.

도 6은 본 발명의 일실시예에 따라 질병유추부(210)에서 각 질병에 대한 확률값을 가질 수 있도록 사용한 함수의 개략도이다. 여기서, N_i 은 상기 질병유추부(210)에서 질병의 개수이다.

발명을 실시하기 위한 구체적인 내용

[0034] 본 명세서에서 사용되는 용어에 대해 간략히 설명하고, 본 발명에 대해 구체적으로 설명하기로 한다.

[0035] 본 발명에서 사용되는 용어는 본 발명에서의 기능을 고려하면서 가능한 현재 널리 사용되는 일반적인 용어들을 선택하였으나, 이는 당 분야에 종사하는 기술자의 의도 또는 관례, 새로운 기술의 출현 등에 따라 달라질 수 있다. 따라서 본 발명에서 사용되는 용어는 단순한 용어의 명칭이 아닌, 그 용어가 가지는 의미와 본 발명의 전반에 걸친 내용을 토대로 정의되어야 한다.

[0036] 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.

[0037] 아래에서는 첨부한 도면을 참고하여 본 발명의 실시예에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다. 그러나 본 발명은 여러 가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시예에 한정되지 않는다.

[0038] 본 발명에 대한 해결하고자 하는 과제, 과제의 해결 수단, 발명의 효과를 포함한 구체적인 사항들은 다음에 기재할 실시 예 및 도면들에 포함되어 있다. 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시 예들을 참조하면 명확해질 것이다.

[0039] 이하, 첨부된 도면을 참조하여 본 발명을 보다 상세히 설명하기로 한다.

[0041] 안저 질환의 경우, 초기에는 정상과 비정상을 구분하기 어려워 안저 질환의 초기 발견은 매우 어렵다. 초기 질환을 잘 예측하기 위해서는 많은 데이터가 필요하지만, 데이터의 레이블링 비용이 비싼 문제점이 있다. 따라서

본 발명은 초기 병변의 특성을 용이하게 감지하기 위해 별도의 모듈인 초기병변검출부(240)를 추가하여 적은 양의 데이터로도 초기 안저 질환을 용이하게 구분할 수 있는 딥러닝 모델의 학습방법에 관한 것이다. 안저 영상의 초기 질환 자동판독을 위한 딥러닝 아키텍처 시스템을 Wisky로 명명하며, 이하 상기 Wisky를 이용한 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법에 대해 설명한다.

- [0043] 본 발명에 따른 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법은 안저 영상의 초기 질환 자동판독을 위한 딥러닝 아키텍처 시스템에 의해 아래 단계에 의해 수행된다. 본 발명에 따른 안저 영상의 초기 질환 자동판독을 위한 딥러닝 학습방법은 크게 병명 진단 단계(S200) 및 최종 확진 단계(S300)로 구성된다.
- [0044] 상기 병명 진단 단계(S200)는 다수개로 마련된 브랜치모듈(200)을 이용하여 안저이미지에 대한 병변을 식별하여 해당하는 병명을 진단한다.
- [0046] 상기 최종 확진 단계(S300)는 상기 브랜치모듈(200)로부터 진단된 데이터를 최종확진부(300)가 통합하여 최종 질환명을 결정하여 출력한다.
- [0047] 상기 병명 진단 단계(S200)는 다시 아래 네 단계에 의해 수행된다.
- [0048] 먼저, 질병 유추 단계(S210)은 질병유추부(210)가 의사의 차팅 과정에서 매칭된 질병명 또는 질병코드로 학습데이터를 생성하여 질병의 카테고리를 유추하되, 데이터의 라벨링에서 비계층적 싱글 라벨링으로 수행한다.
- [0049] 보다 구체적으로, 상기 질병 유추 단계(S210)는 의사의 차팅 과정에서 매칭된 질병명 또는 질병코드로 학습데이터를 생성하여 질병의 카테고리를 유추하되, 데이터의 라벨링에서 비계층적 싱글 라벨링으로 수행한다.
- [0050] 상기 질병 유추 단계(S210)에서 상기 질병유추부(210)는 하나의 이미지에 가장 두드러지는 하나의 질병만 라벨링하는 싱글 라벨링을 수행하고, 다중 분류 문제에서 서로 배타적이고 독립적으로 라벨링하는 비계층적 라벨링을 수행한다. 즉, 상기 싱글 라벨링은 하나의 이미지에 가장 두드러지는 한개의 질병만 라벨링 하여 모델 학습에 사용하는 것으로, 이러한 데이터로 학습된 모델을 추론 단계에서 가장 강한 특성을 나타내는 하나의 질병만 예측한다. 또한, 상기 비계층적 라벨은 다중 분류문제에서 라벨링이 서로 배타적이고 독립적이므로, 예를 들면 개, 고양이, 말은 분류하는 다중 분류문제에서 개, 고양이, 말은 서로 독립적이고 포유류와 말처럼 계층 구조를 가지고 있지 않다.
- [0051] 상기 질병 유추 단계(S210)에서 상기 질병유추부(210)는 사진의 전체를 보고 질병 카테고리를 유추하는 역할을 한다. 이것은 사람 의사가 사진을 보고 첫 인상을 얻는 인상획득(impression) 과정과 유사하다. 상기 질병유추부(210)는 안저이미지 전체를 보고 분류하는 카테고리 분류부(classifier)에 해당하며, 특정 병변의 위치를 탐색하지는 않는다.
- [0052] 상기 질병 유추 단계(S210)에서 상기 질병유추부(210)의 학습데이터는 의사의 차팅 과정에서 질병명 혹은 질병코드와 1:1로 매칭시킬 수 있기 때문에, 대량의 데이터를 이미 차팅 되어 있는 데이터로부터 손쉽게 획득 할 수 있다. 이것은 인공지능의 개발과정에서 상당한 노력과 비용이 드는 학습데이터를 구축하는데 있어 상당한 절감 효과가 있음을 의미한다. 상기 질병유추부(210)의 아키텍처는 다음과 같다.
- [0053] 도 6에서 마지막 Dense2 레이어의 활성화 함수는 소프트맥스 함수(softmax function)를 사용하여, 각 질병에 대한 확률값을 가질 수 있도록 한다. 또한, 도 6에 나타난 바와 같이 아웃풋 값의 개수가 N_1 임을 나타낸다.
- [0055] 다음으로, 위치 탐색 단계(S220)은 위치탐색부(220)가 상기 안저이미지에서 시각신경원반(Optic nerve head, ONH)을 찾고 시신경유두(disc) 및 황반(macula)의 위치를 탐색하여 이에 따라 녹내장 레벨을 분류한다.
- [0056] 보다 구체적으로, 상기 위치 탐색 단계(S220)에서 상기 위치탐색부(220)는 상기 안저이미지에서 시각신경원반(Optic nerve head, ONH)를 찾고 시신경유두(disc) 및 황반(macula)의 위치를 탐색하여 이에 따라 녹내장 레벨을 분류한다.
- [0057] 상기 위치 탐색 단계(S220)에서 상기 위치탐색부(220)는 디스크가 검출 되지 않는 경우(0), 녹내장 없음(1), 녹내장 의심(2), 녹내장 있음(3) 및 비정상 디스크(4)로 상기 녹내장 레벨을 분류한다.

[0058] 상기 위치 탐색 단계(S220)에서 상기 위치탐색부(220)는 종래 기술인 YOLO V3의 디텍션 레이어(detection layer) 아키텍처를 이용한다.

표 1

[0060]

Layer	Filters	Size	Stride	Input	Output	Grid
Convolution0	512	1x1	1	Shortcut4 output	20x20x512	
Convolution1	1024	3x3	1	20x20x512	20x20x1024	
Convolution2	512	1x1	1	20x20x1024	20x20x512	
Convolution3	1024	3x3	1	20x20x512	20x20x1024	
Convolution4	512	1x1	1	20x20x1024	20x20x512	
Convolution5	1024	3x3	1	20x20x512	20x20x1024	
Convolution6	N	1x1	1	20x20x1024	20x20xN	20x20
YOLO1						
Convolution7	256	1x1	1	Convolution4	20x20x256	
Up sample 2x				20x20x256	40x40x256	
Concat0				40x40x256, Shortcut3	40x40x768	
Convolution8	256	1x1	1	40x40x768	40x40x256	
Convolution9	512	3x3	1	40x40x256	40x40x512	
Convolution10	256	1x1	1	40x40x512	40x40x256	
Convolution11	512	3x3	1	40x40x256	40x40x512	
Convolution12	256	1x1	1	40x40x512	40x40x256	
Convolution13	512	3x3	1	40x40x256	40x40x512	
Convolution14	N	1x1	1	40x40x512	40x40xN	40x40
YOLO2						
Convolution15	128	1x1	1	Convolution12	40x40x128	
Up sample 2x				40x40x128	80x80x128	
Concat1				80x80x128, Shortcut2	80x80x384	
Convolution16	128	1x1	1	80x80x384	80x80x128	
Convolution17	256	3x3	1	80x80x128	80x80x256	
Convolution18	128	1x1	1	80x80x256	80x80x128	
Convolution19	256	3x3	1	80x80x128	80x80x256	
Convolution20	128	1x1	1	80x80x256	80x80x128	
Convolution21	256	3x3	1	80x80x128	80x80x256	
Convolution22	N	1x1	1	80x80x256	80x80xN	80x80
YOLO3						

[0061] (여기서, N은 YOLO V3 레이어 직전의 컨볼루션 레이어(convolution layer)의 필터 수로, 디텍션 하고자 하는 라벨의 수를 k개라고 하면, $N = 3 \times (5 + k)$ 이다.)

[0063] 다음으로, 병변 검출 단계(S230)은 주요병변검출부(230)가 질병을 구성하는 요소가 되는 주요 병변(key lesion)을 찾는다.

[0064] 보다 구체적으로, 병변 검출 단계(S230)에서 상기 주요병변검출부(230)는 질병을 구성하는 요소가 되는 주요 병변(key lesion)을 찾는다.

[0065] 상기 병변 검출 단계(S230)에서 상기 주요병변검출부(230)의 아키텍처 구조는 상기 질병유추부(210)와 같이 inceptionV4를 사용한다.

[0066] 상기 병변 검출 단계(S230)에서 상기 주요병변검출부(230)는 안저이미지의 화질분류와 주요 병변(key lesion)의 유무를 디텍션한다.

[0067] 도 6에서 마지막 Dense2 레이어의 활성화 함수는 시그모이드 함수(Sigmoid function)를 사용하여서, 각각의 질병 카테고리별로 0~1사이의 값을 독립적으로 가질 수 있도록 한다. 즉 사람의 질병은 반드시 1개만 가지라는 보장이 없으므로, 각각 0~1 사이의 값으로 독립적으로 득점값(scoring)으로 수행 한다.

- [0069] 다음으로, 초기 병변 검출 단계(S240)는 초기병변검출부(240)가 상기 안저이미지에서 안저 병변 초기에만 나타나는 특성을 찾도록 학습한다.
- [0070] 보다 구체적으로, 상기 초기 병변 검출 단계(S240)에서 상기 초기병변검출부(240)는 상기 안저이미지에서 안저 병변 초기에만 나타나는 특성을 찾도록 학습된다.
- [0071] 상기 초기 병변 검출 단계(S240)에서 상기 초기병변검출부(240)는 상기 안저이미지에서 황반 변성 초기 및 당뇨병 초기와 관련된 노란점 및 빨간점의 개수를 출력한다. 안저 이미지에서 크기가 매우 작으나 매우 중요한 병변을 따로 검출하기 위해 설계된 브랜치이며, 크게 빨간점(R), 노란점(Y) 두개의 라벨만을 갖는다. 상기 초기병변검출부(240)의 출력형식은 발견된 병변의 개수만큼 (라벨명, X좌표, Y좌표, 신뢰수준(Confidence level)) 형태로 출력된다.
- [0072] 일반적인 딥러닝 분류 모델은 병증 초기와 관련된 증상을 직접적으로 검출하지 않고, 이미지의 암시적 규칙을 학습하여 미리 정의된 라벨로 분류한다. 이와 달리 상기 초기병변검출부(240)는 물체 검출 모델인 YOLO-v3을 이용하여 황반 변성 초기 당뇨병 초기와 관련된 노란점과 빨간점의 개수를 출력한다. 이러한 학습을 위해 병증 초기 사진을 수집하여 빨간점과 노란점을 라벨링 하여 모델을 학습시킨다.
- [0074] 다음으로, 상기 최종 확진 단계(S300)는 아래 두 단계에 의해 수행된다.
- [0075] 먼저, 황반 변성 확진 단계(S310)은 황반변성확진부(310)가 황반 변성을 확진한다.
- [0076] 다음으로, 당뇨병성 병증 확진 단계(S320)은 당뇨병성확진부(320)가 당뇨병성 병증을 확진한다.
- [0077] 여기서, 추가로 새로운 안저이미지 데이터가 입력되는 경우 상기 브랜치모듈(200)의 파라미터를 고정하고 상기 황반 변성 확진 단계(S310) 및 당뇨병성 병증 확진 단계(S320) 중 어느 하나 이상에 대해 학습 훈련을 수행하되, 상기 학습 훈련은 상기 새로운 안저이미지 데이터에 가중치를 부가하여 상기 새로운 데이터의 분류 정확도를 증가시키는 것을 특징으로 한다.
- [0078] 상기 최종 확진 단계(S300)에서 상기 최종확진부(300)는 최종확진을 위해 알고리즘을 random forest 에서 다층 퍼셉트론(multi layer perceptron, MLP)으로 변경하여 사용한다. 상기 다층 퍼셉트론 (MLP)은 도 5에 나타난 입력 레이어(X), 은닉 레이어(v) 및 출력 레이어(y)로 구성된 퍼셉트론 레이어를 여러겹 쌓은 형태를 가진다. 입력 노드를 제외하고 각 노드는 비선형 활성화 함수를 사용한다. 다층 퍼셉트론은 훈련을 위해 역전파라는 지도학습 기술을 사용한다. 다중 레이어와 비선형 활성화 함수는 선형으로 분리할 수 없는 데이터를 구별할 수 있게 한다.
- [0079] 본 발명은 안저 영상의 초기 질환 자동판독을 위한 딥러닝 아키텍처 시스템에 의해 학습하는 것으로, 추가로 새로운 안저이미지 데이터가 입력되는 경우 상기 브랜치모듈(200)의 파라미터를 고정하고 상기 황반변성확진부(310) 및 당뇨병성확진부(320) 중 어느 하나 이상에 대해 학습 훈련을 수행하되, 상기 학습 훈련은 상기 새로운 안저이미지 데이터에 가중치를 부가하여 상기 새로운 데이터의 분류 정확도를 증가시키는 것을 특징으로 한다.
- [0080] 딥러닝 모델 학습은 사용된 데이터(도 4의 기존 학습 데이터)와 다른 분포를 가진 데이터(도 4의 추가 데이터)에 대한 성능 확보를 위해 모델을 재학습한다. 이러한 학습 수행에서, 기존 데이터와 새로운 데이터 모두에 대한 성능 확보가 중요하며, 본 발명인 Wisky 학습방법은 여러 모듈로 구성되어 있어 end-to-end 학습이 불가능하지만 학습 데이터와 다른 데이터에 대한 성능 확보를 위해 모델을 재학습 할 때, 일부 모듈만 학습하여도 성능을 향상 시킬 수 있다는 장점이 있다. 여기서, 기존 데이터와 새로운 데이터의 수량 차이가 매우 크므로, 데이터 불균형(Data Imbalance) 영향을 완화할 필요가 있다.
- [0081] 상기 최종 확진 단계(S300)에서 상기 최종확진부(300)를 학습하기 위한 별도의 데이터가 (브랜치모듈(200) 학습에 사용하지 않은 데이터) 없는 상황에서 상기 황반변성확진부(310) 및 당뇨병성확진부(320)이 상기 브랜치모듈(200)의 로짓(logit) 값에 의존하여 사소한(trivial) 해결책을 찾는 것을 방지하기 위해, 상기 브랜치모듈(200) 학습에 간접적으로 사용된 검증(validation) 데이터(도 5의 기존 학습데이터의 10%에 해당하는 8천 장의 데이터)와 새로 추가된 데이터(도 5의 추가 데이터 107장)를 학습에 이용한다.
- [0082] 기존 데이터로 학습한 모델의 표현력이 충분하다고 가정하여 상기 브랜치모듈(200)의 파라미터를 고정하고 상기 황반변성확진부(310) 및 당뇨병성확진부(320) 만 학습시킨다. 여기서, 학습 훈련은 데이터 재조정(re-

balancing) 기법을 도입하는데, 각 기존의 [수학식 1] 손실함수에 각 데이터가 속한 데이터셋의 해당 클래스가 전체 데이터 중에 차지하는 비율을 추가로 반영한 [수학식 2] 의해 수행되는 것을 특징으로 한다.

수학식 1

$$focalloss = -(1-p_t)^\gamma \times \log(p_t)$$

(p_t : t번째 샘플의 모델 결과값이 정답 레이블을 가질 확률값, γ : 하이퍼 파라미터, 모델을 학습 시키는 과정에서 모델 성능을 높이기 위해 임의로 조정하는 변수).

여기서, 각 데이터가 속한 데이터셋의 클래스의 비율을 고려한 전체 안저이미지 데이터의 가중 평균 손실함수는 아래 [수학식 2]에 의해 판단되는 것을 특징으로 한다.

수학식 2

$$Totalloss = \frac{1}{N} \sum_{i=1}^N w_i \times focalloss(i, class[i])$$

(w : 각 데이터가 속한 데이터셋의 해당 클래스가 전체 데이터 중에 차지하는 비율, i : 정답 class, focal loss : $-(1-p_t)^\gamma \times \log(p_t)$, p_t : t번째 샘플의 모델 결과값이 정답 레이블을 가질 확률값, γ : 하이퍼 파라미터, 모델을 학습 시키는 과정에서 모델 성능을 높이기 위해 임의로 조정하는 변수).

상기 [수학식 1]인 데이터 재조정(re-balancing) 기법은 손실함수로 상기 수학식 1에 의한 Focal loss를 사용하여 잘 분류한 샘플과 잘 분류하지 못한 샘플 사이의 손실 값에 차이를 줘서 분류가 어려운 샘플에 대해 분류 성능 향상한다.

일반적으로 딥러닝 모델 학습에서는 새로운 데이터가 학습에 사용 된 기존 데이터와 분포가 다르므로, 모델은 기존 데이터로 학습되었기 때문에 기존 데이터와 분포가 다른 새로운 데이터에 대한 분류성능이 낮을 수밖에 없다. 새로운 데이터와 기존 데이터를 합쳐서 모델을 재학습 시킬 때 데이터의 비율차이가 크면 (ex. 기존 데이터:8000장, 새로운 데이터 107 장) 모델은 수량이 적은 새로운 데이터를 잘 학습하지 못해 여전히 새로운 데이터에 대해 분류 성능이 떨어질 수 있다.

잘 분류하지 못한 샘플(새로운 안저이미지 데이터)의 분류 정확도를 높이기 위해 모델의 손실 함수(모델은 손실 함수를 낮추는 방향으로 학습됨)에 분류 성능이 떨어지는 샘플에 가중치를 주는 방법을 추가한다.

여기서, 상기 학습 훈련은 상기 [수학식 2]의 손실함수를 낮추는 방향으로 수행되는 것이 바람직하다.

또한, 상기 새로운 안저이미지 데이터의 가중치는 학습에 사용한 전체 이미지데이터 수에 반비례한다.

상기 손실함수의 가중치 설정 방법은 아래와 같다.

(1) 아래 식 (1)에서 f_θ 가 뉴럴 네트워크일 때 입력 사진에 대한 출력값을 x 로 지정하고, 뉴럴 네트워크는 상기 손실함수 [수학식 2, 식 (4)]가 줄어드는 방향으로 학습되며 뉴럴 네트워크 출력값(x)과 입력 사진의 정답 class를 이용해 손실 함수가 계산된다.

[0100] 식 (1) : $f_{\theta}(\text{image}) = x$ (f_{θ} : a neural network model)

[0102] (2) 각 이미지가 정답 class에 속할 확률(p_t)은 뉴럴 네트워크가 모든 class에 대한 출력값에 지수승을 해, 정답 class에 대한 정규화 해서 계산한다.

$$p_t(x, \text{class}) = \frac{\exp(x[\text{class}])}{\sum_j \exp(x[j])}$$

[0103] 식 (2) :

[0104] (여기서 j는 전체 class 이다.)

[0106] (3) focal loss는 입력 이미지가 정답에 속할 확률(p_t)값이 작을 때 손실 함수에 가중치를 주어 분류가 어려운 이미지를 잘 분류할 수 있도록 도와준다. 하이퍼 파라미터 γ 는 가중치 여부를 결정하는 변수로 실험을 통해 성능이 가장 높을 때 값을 선택한다.

[0107] 식 (3) : $\text{focalloss}(x, \text{class}) = -(1 - p_t)^\gamma \times \log(p_t)$

[0108] (p_t : t번째 샘플의 모델 결과값이 정답 레이블을 가질 확률값, γ : 하이퍼 파라미터, 모델을 학습 시키는 과정에서 모델 성능을 높이기 위해 임의로 조정하는 변수).

[0110] (4) N개의 학습 데이터에 대한 총 loss 값은 각 데이터가 속한 데이터셋의 클래스(class) 비율을 고려하여 각 샘플에 대한 focal loss를 가중 평균하여 계산한다.

$$\text{Totalloss} = \frac{1}{N} \sum_{i=1}^N w_i \times \text{focalloss}(i, \text{class}[i])$$

[0111] 식 (4)

[0113] (5) 각 샘플의 가중치는 학습에 사용한 데이터 수의 반비례한다. 상기 황반변성확진부(310) 및 당뇨병성확진부(320)에서 사용되는 각 샘플의 가중치는 아래 표와 같다.

표 2

[0115]

황반변성 레이블	설명	추가 학습에 사용한 데이터		
		sect1	heartscan	ai2
Norm	정상	0.154	11.721	13.416
Dry	건성 황반변성	1.302	92.792	17.398
Mottled	미세한 황반병성	6.512	-	-
Wet	습성 황반변성	2.9	-	-

표 3

[0117]

당뇨병성병증 레이블	설명	추가 학습에 사용한 데이터		
		sect1	heartscan	ai2
Norm	정상	0.12	8.48	7.55
FVP	당뇨망막병증 (중증, 섬유화)	34.26	-	-

MILD	당뇨망막병증(붉은점상의병변 소수관찰)	1.76	-	-
MOD	당뇨망막병증(중증도)	7.81	445.4	30.72
PRP	당뇨망막병증(말기)	5.12	-	-
SEVERE	당뇨망막병증(중증)	2.39	-	-

[0119] 보다 구체적으로, 본 발명인 안저 영상의 초기 질환 자동관독을 위한 딥러닝 학습방법은 도 3에 나타난 HydraNet(의료영상 자동관독을 위한 딥러닝 아키텍처 시스템) 및 Grem(안저영상 자동관독을 위한 딥러닝 아키텍처 시스템)을 기본 구조로 하여 구성된 것으로, 상기 HydraNet 및 Grem의 트렁크모듈(100)을 제거하고, 상기 브랜치모듈(200)에 통합하여 성능을 향상시켰다.

[0120] 상기 트렁크모듈(100)은 안저이미지의 특징 추출(feature extraction)을 수행하는 다수 개의 콘볼루션레이어와 연산량을 줄이기 위해 서브샘플링을 수행하는 한 개의 풀링레이어로 구성되는 특징추출레이어 세트가 적어도 한 개 이상 직렬로 배치한 다수개의 합성곱신경망(convolutional neural network, CNN) 아키텍처에서 공통 부분을 하나로 묶은 아키텍처이다.

[0121] 상기 트렁크모듈(100)은 합성곱신경망(convolutional neural network, CNN)을 이용한 안저 영상의 특징 추출(feature extraction)을 위한 공통 레이어(common layer)로, 작은 물체 검출이 잘 되지 않는 문제를 해결하기 위해 입력 해상도를 높였다. 일반적으로 입력해상도와 콘볼루션(convolution) 레이어의 수를 늘리게 되면 인공신경망의 정확도가 높아지는 것으로 알려져 있지만, 그렇다고 무작정 늘리게 되면 메모리 한계를 초과하고 계산속도가 느려지기 때문에 어느 정도 최적화된 점이 필요하다.

[0122] 따라서 본 발명에서 입력 해상도는 640x640을 택하는데, 그 이유는 첫째, 상기 브랜치모듈(200)에서 검출하게 되는 최소 그리드(grid)의 크기(size)가 32x32의 크기가 되기 때문이며, 둘째 안저이미지에서 미세출혈과 같은 작은 병변도 대부분 이정도 그리드(grid)안에 1~2개 정도밖에 포함되지 않으므로 적절한 크기가 되기 때문이다. 또한 실험을 통하여 종래 사용하는 YOLO 아키텍처의 해상도가 높아짐에 따라 녹내장 검출 능력이 좋아지는 것을 확인하였으며, 그것이 640 해상도 이상에서는 크게 진전되지 않았기 때문에, 640 해상도가 녹내장을 검출하는데도 최적이라고 판단해서이다. 본 발명인 wiskey 학습방법에서는 상기 트렁크모듈(100)을 제거하고, 상기 브랜치모듈(200)에 안저이미지의 특징 추출(feature extraction)을 수행 구성을 통합하여 성능을 향상시켰다.

[0124] 아래는 본 발명인 wiskey 학습방법을 이용하여 황반 변성 및 당뇨병성 병증에 대한 구체적인 학습 결과와 기존 방법을 이용한 학습 결과에 대한 실시예를 비교하여 나타내었다. 표 4은 황반 변성에 대한 학습결과이고, 표 5은 당뇨병성 병증에 대한 학습결과이다.

표 4

손실함수	x	성능
기존 방법(CE)	0	84.0
Sample weighted focal	0.1	81.3
	0.3	81.2
	0.5	65.7
	0.7	80.9
	1	85.0
	2	84.2
	3	84.6

표 5

손실함수	x	성능
기존 방법(CE)	0	79.2

Sample	0.1	78.5
weighted focal	0.3	78.3
	0.5	79.5
	0.7	79.9
	1	80
	2	78.7
	3	79.9

- [0130] (1) 성능 지표
- [0131] 학습에 사용된 3 종류의 데이터 (sect1, heart, ai2)의 정밀도와 재현율 평균값 (값이 높을수록 성능이 좋음)
- [0133] (2) 성능 측정 방법
- [0134] 데이터 셋을 3등분 하여 2 fold는 학습에 사용하고 학습에 사용하지 않은 1 fold로 성능 측정. 위 과정을 3회 반복하여 평균 성능 계산
- [0136] (3) 결과
- [0137] ① 황반 변성과 당뇨병성 병증에 대해 기존 손실 함수(CE) 대비 성능 향상을 확인할 수 있음

수학식 3

[0139] $CE\ loss = -\log(p_t)$

[0140] (p_t : t번째 샘플의 모델 결과값이 정답 레이블을 가질 확률값)

- [0142] ② sample weight focal loss에서 하이퍼 파라미터(γ) 값을 변경하면서 성능을 측정하여, 성능이 가장 높은 하이퍼 파라미터 값을 채택
- [0143] ③ γ 값이 1일 때 성능 향상 폭이 가장 큼

[0145] 아래는 기존 방법 손실함수(CE)가중치에 대한 문제점과 이에 대해 본 발명인 wiskey 학습방법에서 가중치를 사용하여 문제점 해결을 확인할 수 있는 실시예이다. 본 발명과 기존 방법을 이용한 학습 결과에 대한 실시예를 비교하여 나타내었다. 표 6은 황반 변성에 대한 실험결과이고, 표 7은 황반변성 데이터이다.

표 6

[0147]

손실함수	성능	Sect1		Heart		AI2	
		정밀도	재현율	정밀도	재현율	정밀도	재현율
기존방법(CE)	84	94.9	89.6	92.6	84.1	76.8	66
weighted CE	87.9	86.9	91.1	94.4	88.9	81.6	84.2
Sample	85	94.8	89	93.4	84.1	76.8	71.9
weighted focal							

표 7

[0149]

레이블	Sect1	Heart	ai2	데이터 수
Norm	7244	95	83	7422
Dry	855	12	64	931
Mottled	171	0	0	171
Wet	384	0	0	384

[0151]

황반 변성 실험 결과 기존 방법 손실 함수(CE) 사용 시 학습에 사용한 데이터 셋이 상대적으로 적은 Heart 와 AI2의 재현율이 Sect1에 비해 상대적으로 낮은 것을 알 수 있다.

[0152]

가중치가 적용된 손실 함수(Weighted CE) 사용 시 평균 성능은 향상되지만 sect1의 정밀도가 95.9에서 86.9로 크게 하락한 것을 볼 수 있다. 모델이 실제 사용되는 현장에서 Sect1 유형의 데이터의 비율이 높기 때문에 Sect1의 성능을 보존하는 것이 중요하다.

[0153]

본 발명에 따른 Sample weighted focal loss 사용 시 평균 성능 향상은 weighted CE보다 적지만 sect1의 성능을 최대한 보존하면서 전체 성능 향상을 얻을 수 있다.

[0155]

상기 과제 해결 수단에 의해, 본 발명은 안저 영상 학습을 위한 데이터 요구량을 최소화하여 안저 영상을 효과적으로 자동 판독할 수 있는 알고리즘을 제공할 수 있다. 또한, 본 발명은 계급에 따른 혼합 분류를 통해 의학용어의 분류체계를 반영할 수 있는 알고리즘을 제공할 수 있다. 또한, 본 발명은 작은 사이즈의 병변에 적합하게 미세 조정된 검출부를 마련하여 안저 영상에서 병변 확인을 용이하게 할 수 있다. 또한, 본 발명은 브랜치 모듈 별로 각각 개별적인 훈련 할 수 있으면서, 전체 시스템에 영향을 미치지 않고 필요에 따라 일부분만 훈련할 수 있는 효과가 있다. 즉, 본 발명은 어떤 변화가 생겨 신경망을 재학습 시켜야 할 필요가 있을 때, 전체를 다시 학습시키는 것이 아니라 필요한 부분(branch)만 학습시킬 수 있다. 또한, 본 발명은 공통 부분이 축약되므로 컴퓨팅의 연산요구량과 저장요구량을 동시에 감소시킬 수 있다. 또한, 본 발명은 안저 이미지의 카테고리를 분류하는 분류(classifier)하는 브랜치(branch)와 안저 이미지 내에 특정 관심 병변을 찾는 객체 탐지(object detector) 브랜치(branch)와 같이 서로 다른 기능을 하는 아키텍처의 장점을 각각 살리면서 하나의 아키텍처처럼 사용할 수 있다. 또한, 본 발명은 신경망을 학습시키기 위해 [이미지+라벨]의 훈련 세트를 준비할 때, 필요한 만큼 진단명만 따로 라벨링하고, 필요한 만큼 병변만 라벨링 하게 되어 각각의 브랜치 별로 따로 라벨을 구성할 수 있어 효율적이다. 또한, 본 발명은 전체 신경망의 기능 중 개별 기능만 따로 필요한 경우 섹션(section)만 분리하여 그 기능만 따로 사용할 수 있으므로 특정 기능을 이용하기 위해 아키텍처 전체를 사용하지 않으므로 효율적이다. 또한, 본 발명은 이미 신경망을 훈련 한 후 새로운 라벨 리스트와 라벨된 데이터가 준비되었을 경우 그것을 처리하는 브랜치만을 하나 더 추가하여 신경망에 새로운 기능을 만들 수 있으므로, 새로운 기능을 추가하기 용이하다. 또한, 본 발명은 개별의 아키텍처를 각각 실행한 것에 비해 속도가 빠른 효과가 있다. 또한, 본 발명은 적은 데이터로도 초기 안저 병변 예측의 성능이 향상되고, 적은 양의 데이터로도 초기 질환을 잘 구분할 수 있다.

[0157]

이와 같이, 상술한 본 발명의 기술적 구성은 본 발명이 속하는 기술분야의 당업자가 본 발명의 그 기술적 사상이나 필수적 특징을 변경하지 않고서 다른 구체적인 형태로 실시될 수 있다는 것을 이해할 수 있을 것이다.

[0158]

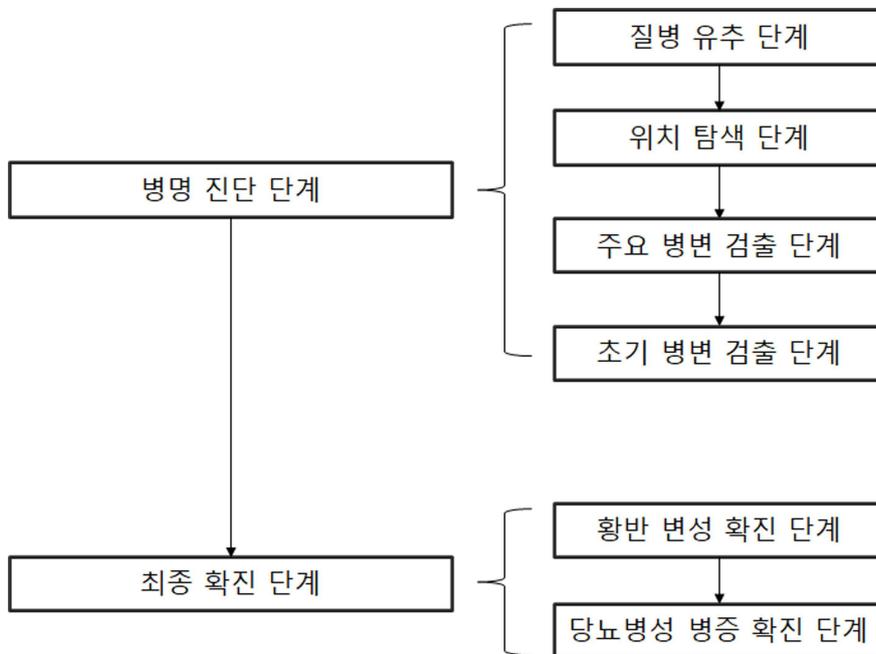
그러므로 이상에서 기술한 실시예들은 모든 면에서 예시적인 것이며 한정적인 것이 아닌 것으로서 이해되어야 하고, 본 발명의 범위는 상기 상세한 설명보다는 후술하는 특허청구범위에 의하여 나타나며, 특허청구범위의 의미 및 범위 그리고 그 등가 개념으로부터 도출되는 모든 변경 또는 변형된 형태가 본 발명의 범위에 포함되는 것으로 해석되어야 한다.

부호의 설명

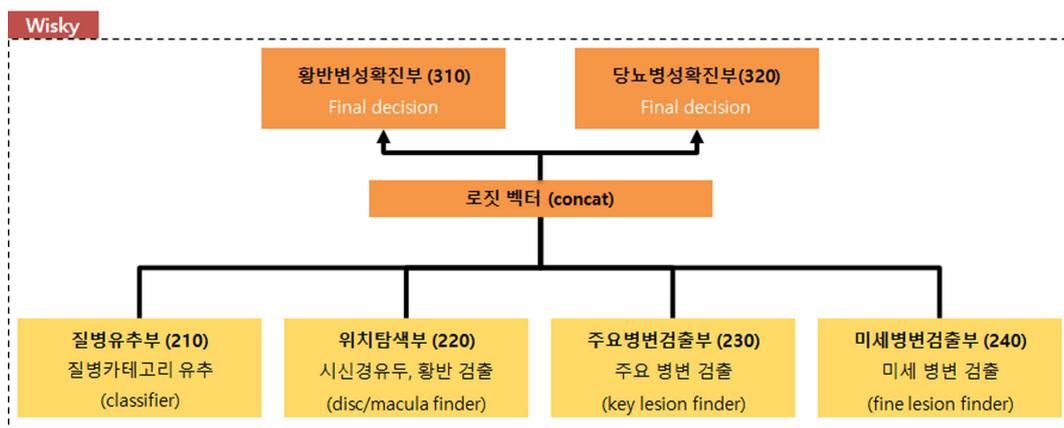
- [0160] 200. 브랜치모듈
- 210. 질병유추부
- 220. 위치탐색부
- 230. 주요병변검출부
- 240. 초기병변검출부
- 300. 최종확진부
- 310. 황반변성확진부
- 320. 당뇨병성확진부

도면

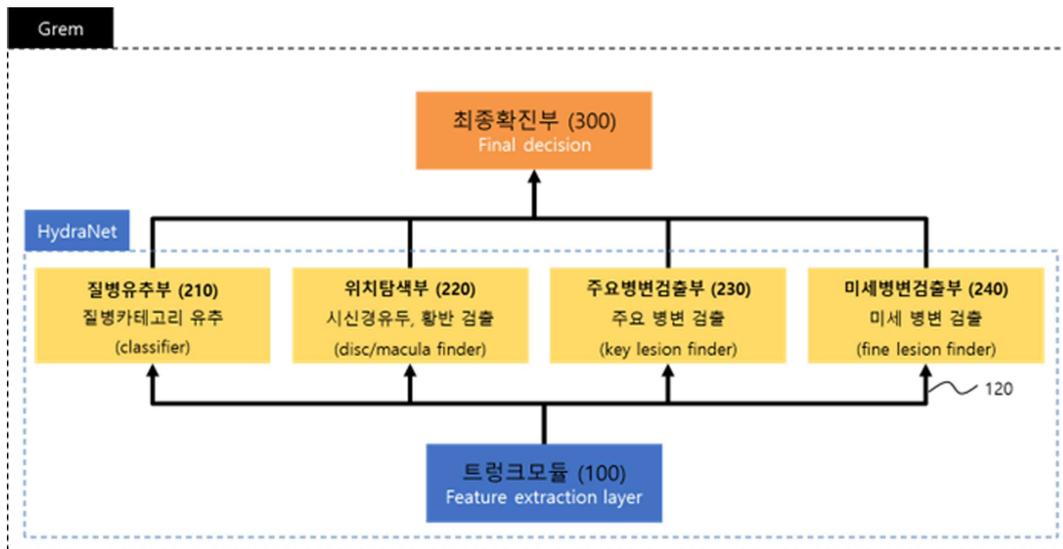
도면1



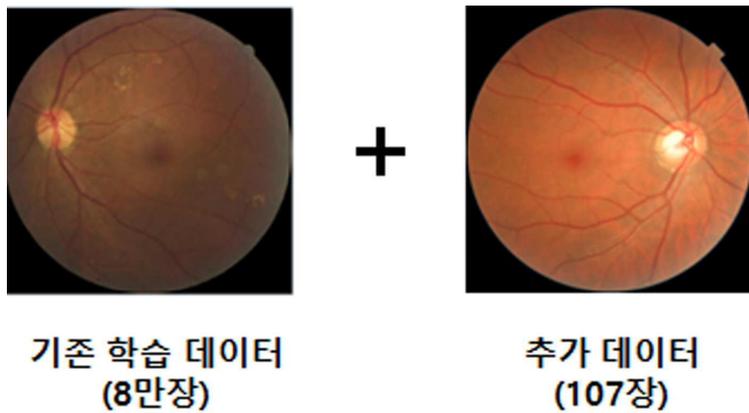
도면2



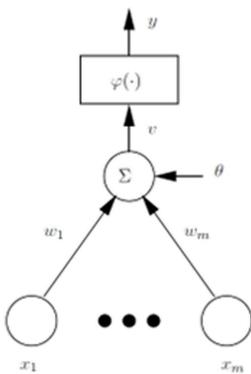
도면3



도면4



도면5



X: 입력값, $X = [x_1, \dots, x_m]$
 θ, w_i : 학습 파라미터
 $v = w_1x_1 + \dots + w_mx_m - \theta$
 $y = \psi(v)$

도면6

