

(19) 대한민국특허청(KR)
(12) 공개특허공보(A)(11) 공개번호 10-2023-0156598
(43) 공개일자 2023년11월14일

(51) 국제특허분류(Int. Cl.)

A61B 3/12 (2006.01) G06N 20/00 (2019.01)

G06N 3/08 (2023.01) G06T 7/00 (2017.01)

(52) CPC특허분류

A61B 3/12 (2013.01)

G06N 20/00 (2021.08)

(21) 출원번호 10-2022-0056228

(22) 출원일자 2022년05월06일

심사청구일자 2022년05월06일

(71) 출원인

인하대학교 산학협력단

인천광역시 미추홀구 인하로 100(용현동, 인하대학교)

(72) 발명자

곽경섭

인천광역시 연수구 해돋이로84번길 10, 604동 802호(송도동, 송도풍림아이원6단지아파트)

(74) 대리인

양성보


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법 및 시스템

(57) 요약

익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법 및 시스템이 제시된다. 본 발명에서 제안하는 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 시스템은 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행하는 전처리부, 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 특징 추출부 및 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 당뇨망막병증 분류부를 포함한다.

대표도



(52) CPC특허분류

G06N 3/08 (2023.01)

G06T 7/0012 (2013.01)

G06T 2207/20081 (2013.01)

G06T 2207/20084 (2013.01)

G06T 2207/30041 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호 1711148616

과제번호 2020R1A2B5B02002478

부처명 과학기술정보통신부

과제관리(전문)기관명 한국연구재단

연구사업명 중견후속연구

연구과제명 [Ezbaro] 빅데이터 분석 기반 퍼지 온톨로지 및 기계학습을 활용한 IoT u-헬스케어
시스템 핵심기술 개발 및 설계

기 여 율 1/1

과제수행기관명 인하대학교 산학협력단

연구기간 2022.03.01 ~ 2023.02.28

명세서

청구범위

청구항 1

당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행하는 전처리부;

상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 특징 추출부; 및

익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 당뇨망막병증 분류부

를 포함하는 당뇨망막병증을 위한 특징 추출 및 선별 시스템.

청구항 2

제1항에 있어서,

상기 전처리부는,

수집된 안저 망막 이미지에 대하여 노이즈를 제거하기 위해 가우시안 블러 방법을 이용하여 블러링하고, 블러링된 안저 망막 이미지에 대하여 히스토그램 균등화를 적용하여 이미지 대비를 개선한 후, 이미지에 대한 사이즈 조정 및 정규화를 수행하는

당뇨망막병증을 위한 특징 추출 및 선별 시스템.

청구항 3

제1항에 있어서,

상기 특징 추출부는,

심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하여 표준화하고, 상기 심층 CNN 모델 복잡성과 시간 비용을 줄이기 위해 특이값 분해를 이용하여 차원 축소를 수행하는

당뇨망막병증을 위한 특징 추출 및 선별 시스템.

청구항 4

제1항에 있어서,

상기 당뇨망막병증 분류부는,

복수의 입력 노드, 복수의 은닉 노드 및 복수의 출력 노드를 포함하고, 복수의 출력 노드의 수에 따라 이진 분류 또는 다중 분류를 감지하며,

입력 가중치 및 바이어스 행렬을 랜덤하게 생성하여 은닉 계층의 출력 및 출력 계층 가중치를 계산하고, 상기 출력 계층 가중치를 이용하여 상기 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는

당뇨망막병증을 위한 특징 추출 및 선별 시스템.

청구항 5

전처리부가 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행하는 단계;

특징 추출부가 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 단계; 및

당뇨망막병증 분류부가 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 단계

를 포함하는 당뇨망막병증을 위한 특징 추출 및 선별 방법.

청구항 6

제5항에 있어서,

상기 전처리부가 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행하는 단계는,

수집된 안저 망막 이미지에 대하여 노이즈를 제거하기 위해 가우시안 블러 방법을 이용하여 블러링하고, 블러링된 안저 망막 이미지에 대하여 히스토그램 균등화를 적용하여 이미지 대비를 개선한 후, 이미지에 대한 사이즈 조정 및 정규화를 수행하는

당뇨망막병증을 위한 특징 추출 및 선별 방법.

청구항 7

제5항에 있어서,

상기 특징 추출부가 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 단계는,

심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하여 표준화하고, 상기 심층 CNN 모델 복잡성과 시간 비용을 줄이기 위해 특이값 분해를 이용하여 차원 축소를 수행하는

당뇨망막병증을 위한 특징 추출 및 선별 방법.

청구항 8

제5항에 있어서,

상기 당뇨망막병증 분류부가 익스트림 기계 학습 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 단계는,

복수의 입력 노드, 복수의 은닉 노드 및 복수의 출력 노드를 포함하고, 복수의 출력 노드의 수에 따라 이진 분류 또는 다중 분류를 감지하며,

입력 가중치 및 바이어스 행렬을 랜덤하게 생성하여 은닉 계층의 출력 및 출력 계층 가중치를 계산하고, 상기 출력 계층 가중치를 이용하여 상기 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는

당뇨망막병증을 위한 특징 추출 및 선별 방법.

발명의 설명

기술 분야

[0001]

본 발명은 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법 및 시스템에 관한 것이다.

배경 기술

[0002]

당뇨병(Diabetes Mellitus)은 사람의 혈당치가 높을 때 일어나는 대사성 질환의 집합체이며, 당뇨병을 가진 환자는 혈당을 조절하기에 충분한 인슐린을 만들지 못한다. 당뇨병 환자는 날이 갈수록 급증하고 있다. 2019년 국제당뇨병연맹(International Diabetes Federation; IDF)은 20세에서 79세 사이의 약 4억6300만 명이 당뇨병에 감염되었다고 발표했다. 2000년 이후 세계보건기구(WHO)는 당뇨병 관련 조기 사망이 5% 증가했다고 추정했다. 당뇨망막병증(Diabetic Retinopathy; DR), 뇌졸중, 신부전, 심장마비 등 다양한 종류의 질병이 당뇨에 의해 발생한다. DR은 과도한 혈당 수치로 인해 망막의 혈관이 흐트러질 때 나타나며, 부기와 출혈을 유발한다. 안저 망막 이미지에서, 이 출혈된 혈액과 액체는 병변이라고 불리는 점으로 보인다. 병변에는 두 가지 유형이 있다. 하

나는 빨간색 병변이고 다른 하나는 우측 병변이다.

[0003] 도 1은 본 발명의 일 실시예에 따른 안저 망막 이미지를 나타내는 도면이다.

[0004] 도 1은 미세동맥류(Microaneurysms; MA)와 출혈(Haemorrhage HM)이 빨간색 병변이 반면 연질 및 경질 삼출물(Exudates; EX)은 우측 병변으로 표현되는 병변을 모두 보여준다. MA는 작고 검붉은 점을 의미하며 HM은 더 큰 점을 나타낸다. 종종 솜털로 알려진 연질 EX는 신경 섬유 손상으로 인해 누르스름한 흰색과 솜털 같은 반점으로 보이는 반면 경질 EX는 독특한 노란색 점으로 나타난다. 안과 전문의들에 따르면 DR은 크게 비증식 DR과 증식 DR(Proliferative DR; PDR)의 두 단계로 나뉜다. 비증식 DR은 경도(mild), 중등도(moderate), 중도(severe)의 세 단계로 더 나뉜다. 따라서 데이터셋에는 다섯 가지 단계가 있다. DR 없음, 경도, 중등도, 중도, PDR이다. 망막 이미지의 병변 수와 유형에 따라 단계가 정의된다.

[0005] 전 세계적으로, 40만 명 이상의 사람들이 시력을 잃었고, 약 260만 명의 사람들이 심각한 시력 손상에 의해 영향을 받고 있다. 이러한 시각 장애는 충분히 신속하게 진단하고 치료하면 예방하거나 최소화할 수 있다. 그러나 DR의 초기 단계에서는 눈에 띄는 증상이 거의 없다; 이러한 이유로, 대부분의 사람들은 치료를 위한 이상적인 시기를 놓친다. 기존 시술에서 안과 전문의는 안저 이미지(Fundus Images; FI)을 활용해 DR을 진단하는데 오랜 시간이 필요하고 많은 노력이 필요하며 질환에 대한 잘못된 해석에 취약하다. 따라서 컴퓨터 보조 진단 시스템을 활용하여 DR을 조기에 감지하고 오진을 방지하며 비용, 시간 및 노력을 절약해야 한다. 지난 몇 년 동안 FI에서 DR을 자동으로 감지하기 위해 여러 딥 러닝(Deep Learning; DL) 알고리즘이 제안되었다.

[0006] 종래기술에 따르면 의료 이미지와 다른 유형의 생명을 위협하는 질병을 자동으로 감지하는 컴퓨터 지원 시스템에 관한 기술에 초점을 맞추었다. DR, COVID-19, 말라리아 등과 같은 일부 질병은 사망률을 줄이기 위해 조기 발견이 필요하다. 따라서 비용과 사망률을 줄이기 위해 이러한 질병을 정확하고 효율적으로 제때 발견하기 위한 시스템을 필요로 한다.

발명의 내용

해결하려는 과제

[0007] 본 발명이 이루고자 하는 기술적 과제는 이진 클래스 분류 및 다중 클래스 당뇨망막병증(Diabetic Retinopathy; DR) 분류 모두에 대해 새로운 아키텍처를 제공하는데 있다. 본 발명은 당뇨병으로 인해 망막에 장애가 발생하는 의료 조건인 당뇨망막병증을 해결하기 위해 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법 및 시스템을 제안한다.

과제의 해결 수단

[0008] 일 측면에 있어서, 본 발명에서 제안하는 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 시스템은 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선하기 위한 전처리를 수행하는 전처리부, 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 특징 추출부 및 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 당뇨망막병증 분류부를 포함한다.

[0009] 상기 전처리부는 수집된 안저 망막 이미지에 대하여 노이즈를 제거하기 위해 가우시안 블러 방법을 이용하여 블러링하고, 블러링된 안저 망막 이미지에 대하여 히스토그램 균등화를 적용하여 이미지 대비를 개선한 후, 이미지에 대한 사이즈 조정 및 정규화를 수행한다.

[0010] 상기 특징 추출부는 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하여 표준화하고, 상기 심층 CNN 모델 복잡성과 시간 비용을 줄이기 위해 특이값 분해를 이용하여 차원 축소를 수행한다.

[0011] 상기 당뇨망막병증 분류부는 복수의 입력 노드, 복수의 은닉 노드 및 복수의 출력 노드를 포함하고, 복수의 출력 노드의 수에 따라 이진 분류 또는 다중 분류를 감지하며, 입력 가중치 및 바이어스 행렬을 랜덤하게 생성하여 은닉 계층의 출력 및 출력 계층 가중치를 계산하고, 상기 출력 계층 가중치를 이용하여 상기 당뇨망막병증의 이진 분류 또는 다중 분류를 감지한다.

[0012] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법은 전처리부가 당뇨망막병증 분류를 위해 수집된 안저 망막 이

미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행하는 단계, 특징 추출부가 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 단계 및 당뇨망막병증 분류부가 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 단계를 포함한다.

발명의 효과

[0013] 본 발명의 실시예들에 따르면 이진 클래스 분류 및 다중 클래스 분류에 대한 당뇨망막병증(Diabetic Retinopathy; DR)을 감지할 수 있다. 본 발명의 실시예들에 따른 DR 이미지는 벤 그레이엄(Ben Graham)의 접근 방식 및 CLAHE(Contrast Limited Adaptive Histogram Equalization)를 전처리함으로써 노이즈가 낮고 더 구별되는 특징을 가진 대비 강화 이미지를 획득할 수 있다. 또한, 하이브리드 컨볼루션 신경망-특이값 분해(Convolutional Neural Network-Singular Value Decomposition) 모델 및 ELM 알고리즘을 이용하여 학습 시간 비용을 최소화하고, 정확도를 더욱 개선할 수 있다.

도면의 간단한 설명

[0014] 도 1은 본 발명의 일 실시예에 따른 안저 망막 이미지를 나타내는 도면이다.
 도 2는 본 발명의 일 실시예에 따른 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 시스템의 구성을 나타내는 도면이다.
 도 3은 본 발명의 일 실시예에 따른 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법을 설명하기 위한 흐름도이다.
 도 4는 본 발명의 일 실시예에 따른 안저 이미지 샘플을 나타내는 도면이다.
 도 5는 본 발명의 일 실시예에 따른 전처리의 효과를 나타내는 도면이다.
 도 6은 본 발명의 일 실시예에 따른 특징 추출부의 CNN 구조를 나타내는 도면이다.
 도 7은 본 발명의 일 실시예에 따른 복수의 특징 측면에서의 누적 에너지를 나타내는 도면이다.
 도 8은 본 발명의 일 실시예에 따른 당뇨망막병증 분류부의 익스트림 기계 학습 모델을 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0015] 본 발명에서는 이진 및 다중 클래스 당뇨망막병증(Diabetic Retinopathy; DR) 분류 모두에 대해 새로운 아키텍처를 제안한다. 본 발명의 실시예에 따른 안저 이미지(Fundus Images; FI)는 벤 그레이엄(Ben Graham)의 전처리 방법에 의해 전처리된다. CLAHE를 이용하여 처리된 이미지의 대비를 더욱 강화했다. 그런 다음 하이브리드 CNN-SVD 방법이라는 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 특징을 추출한다. 마지막으로 새로운 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 DR의 다섯 단계를 분류한다. 제안하는 프레임워크는 다양한 데이터셋에서 잘 수행되었다.

[0016] 본 발명의 실시예에 따르면, FI는 BenGraham-CLAHE를 이용하여 노이즈를 줄이고 이미지 대비를 강화하며 병변을 강조하기 위해 전처리된다.

[0017] 본 발명의 실시예에 따르면, FI에서 특징을 추출하기 위해 새로운 하이브리드 CNN-SVD를 제안한다. CNN은 처리된 FI에서 256개의 특징을 추출하는 데 이용되었다. 이후, SVD를 적용하여 가장 두드러진 특징을 선택하고, 모델 복잡성을 줄이며, 모델 성능을 향상시킴으로써 이러한 특징을 100가지 특징으로 축소한다.

[0018] 본 발명의 실시예에 따르면, 비교 분석을 통해 제안하는 방법이 서로 다른 데이터셋의 분류 문제 모두에서 최첨단 모델을 능가한다는 것을 확인하였다. 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0020] 종래기술에 따르면, FI의 이진 DR 분류를 위해 다양한 DL 알고리즘을 이용해 왔다. 종래기술[1]은 FIs에서 혈관을 추출하기 위해 최대 주 곡률을 활용했다. 선택적 히스토그램 균등화(Adaptive Histogram Equalization; AHE) 및 형태학적 개구부(morphological opening)를 이용하여 거짓으로 분할된 영역을 추가로 개선하고 제거한

다. 마지막으로, DR을 감지하는 데 CNN이 이용되었고 98.7%의 정확도를 달성했다.

- [0021] 종래기술[2]은 DR 감지를 위해 WP-CNN이라는 이름의 가중 경로 CNN을 제안했다. WP-CNN은 가중 경로의 블록을 쌓아 만들었다. WP-CNN은 32, 52, 105개의 컨볼루션 층을 가진 WP-CNN-32, WP-CNN-52, WP-CNN-105를 포함하였다. WP-CNN-105는 다른 두 모델보다 성능이 우수했다.
- [0022] 종래기술[3]은 참조 가능한 DR을 감지하기 위해 FI에서 특징 추출에 대해 사용자 지정 CNN을 조희한다. 데이터와 강력한 특징 추출 확장을 추가함으로써 모델은 더 큰 성능을 달성했다.
- [0023] 종래기술[4]은 CHASE 데이터셋에서 DR을 자동으로 감지하기 위한 하이브리드 유도 ML 알고리즘(Hybrid Inductive ML Algorithm; HIMLA)을 제안했고 96.62%의 정확도를 달성했다[4].
- [0024] 종래기술[5]은 적절하게 인자분해된 컨볼루션과 공격적인 정규화를 적용하여 추가 작업을 가능한 효율적으로 만드는 방식으로 네트워크를 확장하는 방법을 제안했다. 마지막으로, 4개의 모델을 앙상블하고, 멀티-크롭(multi-crop) 평가를 수행했으며, 테스트 데이터에서 3.6%의 상위 5개 오차에 도달했다.
- [0025] 종래기술[6]은 DR의 5단계를 감지하기 위해 사전 훈련된 Inception_ResNet-v2 상에 사용자 지정 CNN 계층을 병합하여 하이브리드 모델을 개발했다. 하이브리드 모델을 훈련하기 위해 Messidor-1과 APTOS 2019 블라인드 데이터셋을 모두 이용했고 더 나은 성능을 달성했다.
- [0026] 종래기술[7]은 APTOS-2019 데이터셋에서 DR 감지를 위해 게이트 주의 메커니즘을 심층 신경망(Deep Neural Network; DNN)과 결합했다. 여기서, 사전 훈련된 CNN 모델을 이용하여 FI를 대표했다. 많은 정보를 삭제하지 않고 이러한 표현의 축소 버전을 획득하기 위해 공간 풀링 접근법이 제시된다. 이들의 합성 모델은 DR의 다섯 단계 감지에 82.54%의 정확도를 달성했다.
- [0027] 종래기술[8]은 CNN512와 YOLOv3, 두 가지 딥 러닝 모델을 제안했다. 다섯 DR 단계를 감지하기 위해 CNN512를 이용했고 DR 병변의 로컬리제이션을 위해 YOLOv3를 이용했다. 마지막으로, DR 병변을 감지하고 로컬리제이션하기 위해 이 두 가지 알고리즘을 융합했다.
- [0028] 종래기술[10]은 FI에서 DR 단계를 분류하기 위해 전송 학습 모델 VGG16[9]을 활용했고 77%의 정확도를 달성했다. 종래기술[11]은 DR 예측을 위한 하이퍼 파라미터 튜닝 Inception-v4 전송 학습(TL) 모델을 개발했다. 여기서, 이미지 품질을 향상시키기 위해 CLAHE를 활용했고 히스토그램 기반 분할을 활용하여 분할을 수행했다.
- [0029] 종래기술[12]는 FI에서 DR을 감지하기 위해 EyePACS 및 APTOS 데이터셋을 활용했다. 두 개의 심층 CNN을 제안했는데, 하나는 4단계를 식별하기 위한 것이고 다른 하나는 마지막 단계를 두 단계로 더 분류하기 위한 것이다. 종래기술[13]은 Resnet50, Inceptionv3, Xception, Dense121, Dense169의 다섯 가지 TL 모델로 앙상블 모델을 개발하여 DR의 단계 분류를 개선하고 복잡한 특성을 추가적으로 인코딩했다.
- [0030] 종래기술[14]은 DR 탐지를 위한 의사결정 트리 기반 앙상블 방법을 제안했다. 그레이 레벨의 강도를 수행하고 유전 알고리즘(Genetic Algorithm; GA)을 이용하여 FI 특징을 추출했으며 94.20%의 정확도를 달성했다. 종래기술[15]는 CNN 모델을 이용하여 FI에서 특징을 추출했다. 여기서 DR의 자동 감지를 위한 지원 벡터 머신(Support Vector Machine; SVM), 랜덤 포레스트(Random Forest; RF), 다층 퍼셉트론(Multi-Layer Perceptron; MLP) 등과 같은 여러 ML 알고리즘을 제안했고 DR의 감지를 위한 Gabor 필터와 ML 알고리즘을 제안했고 70.1516%의 정확도를 달성했다[16]. 종래기술[17]는 DR 분류를 위해 다양한 ML 모델, 예를 들어 DT, SVM, 인공 신경망(Artificial Neural Network; ANN), 로지스틱 회귀(Logistic Regression; LR)를 활용했다. SVM을 이용하여 79.5%의 높은 정확도를 달성했다.
- [0031] 종래기술[18]은 FI에서 DR을 감지하기 위해 ML-BEC라는 ML bagging 앙상블 분류기를 개발했다. 먼저, FI에서 후보 객체를 추출하고 앙상블 분류기를 이용하여 DR을 분류했다. 종래기술[19]은 FI의 DR 분류를 위해 전처리와 증강이 결합된 신경망(Neural Network; NN)을 제안했다. 종래기술[20]은 DR의 4단계 분류를 위해 3개의 계층을 가진 ANN 모델을 개발했다.
- [0032] 종래기술[21]은 FI에서 DR을 분류하기 위한 다중 인스턴스 학습(Multiple Instance Learning; MIL) 프레임워크를 제안했다. 여기서 Messidor 데이터셋을 이용하여 모델을 훈련하고 테스트했으며 93%의 AUC를 달성했다. CLAHE를 이용하여 향상된 FIs를 주입하고 DR 단계 분류를 위해 EffiecentNet-5 아키텍처를 이용했다[22]. 여기서, Messidor-2 데이터셋에 대해 0.945의 AUC를 달성했다.
- [0033] 종래기술[23]은 전송 학습을 활용했고, 그들은 적은 노력으로 학습할 수 있는 샴(Siamese)과 같은 아키텍처를

가진 고유한 CNN 모델을 개발했다. 그들은 7024개의 이미지를 이용하여 모델을 테스트했고 0.951의 ROC를 달성했다. 종래기술[24]은 타겟 병변 감지 및 특성화를 위한 일반적인 프레임워크를 설명했으며, 이는 신속하게 수행될 수 있다. 이 도구는 유사한 모양이지만 타겟이 아닌 타겟 병변 및 기타 안구 구조를 설명하는 이미지 샘플을 추출한 다음, 이미지에서 타겟 병변을 더 쉽게 찾고 선택할 수 있도록 특징 공간을 추출한다.

- [0034] 본 발명은 당뇨병으로 인해 망막에 장애가 발생하는 의료 조건인 당뇨망막병증(Diabetic Retinopathy; DR)을 해결하기 위해 익스트림 기계 학습 접근법을 활용한다. 전 세계적으로 실명의 주요 원인인 DR은 망막 혈관의 과도한 혈당으로 인한 일종의 붓기 누출이다. 따라서 당뇨병 환자의 시력을 잃지 않으려면 조기 진단이 중요하다.
- [0035] 본 발명에서는 APTOS-2019 실명 감지 및 Messidor-2 데이터셋을 기반으로 이진 클래스 및 다중 클래스 분류에 대한 DR을 감지하는 새로운 방법을 제안한다. 먼저, 본 발명의 실시예에 따른 DR 이미지는 벤 그레이엄(Ben Graham)의 접근 방식을 이용하여 전처리한다. 그 후, CLAHE(Contrast Limited Adaptive Histogram Equalization)를 이용하여 노이즈가 낮고 더 구별되는 특징을 가진 대비 강화 이미지를 획득한다. 그런 다음 분류기의 입력 특징을 줄이기 위해 새로운 하이브리드 컨볼루션 신경망-특이값 분해(Convolutional Neural Network-Singular Value Decomposition) 모델이 개발되었다. 마지막으로, 제안된 방법은 학습 시간 비용을 최소화하는 분류기로 ELM 알고리즘을 이용한다. 실험은 정확도, 정밀도, 리콜 및 F1 점수에 초점을 맞추고 DR 진단을 위해 제안된 체계를 채택할 가능성을 보여준다. 제안하는 방법은 종래기술을 능가하며 이진 클래스에 대해 각각 99.73%와 100%의 우수한 정확도와 리콜을 보여준다. 본 발명의 실시예에 따른 DR 분류의 5단계에 대해 제안하는 모델은 APTOS-2019와 Messidor-2 데이터셋에 대해 각각 98.09%와 96.26%의 정확도를 달성하여 종래기술을 능가했다.
- [0037] 도 2는 본 발명의 일 실시예에 따른 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 시스템의 구성을 나타내는 도면이다.
- [0038] 제안하는 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증(Diabetic Retinopathy; DR)을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 시스템은 전처리부(210), 특징 추출부(220) 및 당뇨망막병증 분류부(230)를 포함한다.
- [0039] 본 발명의 실시예에 따른 전처리부(210)는 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지(Fundus Images; FI)에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행한다.
- [0040] 본 발명의 실시예에 따른 전처리부(210)는 수집된 안저 망막 이미지에 대하여 노이즈를 제거하기 위해 가우시안 블러 방법(예를 들어, Ben Grahm)을 이용하여 블러링하고, 블러링된 안저 망막 이미지에 대하여 히스토그램 균등화(예를 들어, CLAHE(Contrast Limited Adaptive Histogram Equalization))를 적용하여 이미지 대비를 개선한다. 이후, 이미지에 대한 사이즈 조정(Resizing) 및 정규화(Normalization)를 수행한다.
- [0041] 본 발명의 실시예에 따른 특징 추출부(220)는 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출한다.
- [0042] 수집된 안저 망막 이미지는 이미지 처리 기술(예를 들어, 벤 그레이엄, CLAHE 등)을 사용하여 전처리 될 수 있다. 전처리 후 가장 차별적인 특징을 추출하고 선택하기 위해 하이브리드 CNN-SVD 모델을 이용한다.
- [0043] 본 발명의 실시예에 따른 특징 추출부(220)는 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하여 표준화(Features Scaling)하고, 상기 심층 CNN 모델 복잡성과 시간 비용을 줄이기 위해 특이값 분해(Singular Value Decomposition; SVD)를 이용하여 차원 축소를 수행한다.
- [0044] 본 발명의 실시예에 따른 당뇨망막병증 분류부(230)는 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지한다.
- [0045] 본 발명의 실시예에 따르면, DR의 두 가지 체계 감지를 위한 새로운 프레임워크를 제안하고, 그 중 하나는 두 클래스(DR 있음 및 DR 없음)이고 다른 하나는 복수의 클래스(DR 없음, 경도, 중등도, 중도, 중식 DR)이다.
- [0046] 본 발명의 실시예에 따른 당뇨망막병증 분류부(230)는 복수의 입력 노드, 복수의 은닉 노드 및 복수의 출력 노드를 포함하고, 복수의 출력 노드의 수에 따라 이진 분류 또는 다중 분류를 감지한다.
- [0047] 본 발명의 실시예에 따른 당뇨망막병증 분류부(230)는 입력 가중치 및 바이어스 행렬을 랜덤하게 생성하여 은닉 계층의 출력 및 출력 계층 가중치를 계산하고, 상기 출력 계층 가중치를 이용하여 상기 당뇨망막병증의 이진 분

류 또는 다중 분류를 감지한다.

- [0049] 도 3은 본 발명의 일 실시예에 따른 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법을 설명하기 위한 흐름도이다.
- [0050] 제안하는 익스트림 기계 학습 알고리즘을 활용한 당뇨망막병증을 위한 하이브리드 CNN-SVD 기반 특징 추출 및 선별 방법은 전처리부가 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행하는 단계(510), 특징 추출부가 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하는 단계(520) 및 당뇨망막병증 분류부가 익스트림 기계 학습(Extreme Learning Machine; ELM) 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지하는 단계(530)를 포함한다.
- [0051] 단계(510)에서, 전처리부가 당뇨망막병증 분류를 위해 수집된 안저 망막 이미지에 대한 노이즈 제거 및 이미지 대비를 개선을 위한 전처리를 수행한다.
- [0052] 본 발명의 실시예에 따르면, 전처리부는 수집된 안저 망막 이미지에 대하여 노이즈를 제거하기 위해 가우시안 블러 방법(예를 들어, Ben Graham)을 이용하여 블러링하고, 블러링된 안저 망막 이미지에 대하여 히스토그램 균등화(예를 들어, CLAHE(Contrast Limited Adaptive Histogram Equalization))를 적용하여 이미지 대비를 개선한다. 이후, 이미지에 대한 사이즈 조정(Resizing) 및 정규화(Normalization)를 수행한다.
- [0053] 단계(520)에서, 특징 추출부가 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출한다.
- [0054] 본 발명의 실시예에 따르면, 특징 추출부는 상기 전처리된 안저 망막 이미지에 대하여 특이값 분해(Singular Value Decomposition; SVD)와 결합된 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출한다.
- [0055] 수집된 안저 망막 이미지는 이미지 처리 기술(예를 들어, 벤 그레이엄, CLAHE 등)을 사용하여 전처리 될 수 있다. 전처리 후 가장 차별적인 특징을 추출하고 선택하기 위해 하이브리드 CNN-SVD 모델을 이용한다.
- [0056] 본 발명의 실시예에 따르면, 특징 추출부는 심층 CNN 모델을 이용하여 당뇨망막병증 분류를 위한 특징을 추출하여 표준화(Features Scaling)하고, 상기 심층 CNN 모델 복잡성과 시간 비용을 줄이기 위해 특이값 분해(Singular Value Decomposition; SVD)를 이용하여 차원 축소를 수행한다.
- [0057] 단계(530)에서, 당뇨망막병증 분류부가 익스트림 기계 학습 알고리즘을 이용하여 당뇨망막병증의 이진 분류 또는 다중 분류를 감지한다.
- [0058] 본 발명의 실시예에 따르면, DR의 두 가지 체계 감지를 위한 새로운 프레임워크를 제안하고, 그 중 하나는 두 클래스(DR 있음 및 DR 없음)이고 다른 하나는 복수의 클래스(DR 없음, 경도, 중등도, 중도, 증식 DR)이다.
- [0059] 본 발명의 실시예에 따르면, 당뇨망막병증 분류부는 복수의 입력 노드, 복수의 은닉 노드 및 복수의 출력 노드를 포함하고, 복수의 출력 노드의 수에 따라 이진 분류 또는 다중 분류를 감지한다.
- [0060] 본 발명의 실시예에 따르면, 당뇨망막병증 분류부는 입력 가중치 및 바이어스 행렬을 랜덤하게 생성하여 은닉 계층의 출력 및 출력 계층 가중치를 계산하고, 상기 출력 계층 가중치를 이용하여 상기 당뇨망막병증의 이진 분류 또는 다중 분류를 감지한다.
- [0062] 도 4는 본 발명의 일 실시예에 따른 안저 이미지 샘플을 나타내는 도면이다.
- [0063] 본 발명의 실시예에 따르면, 두 가지 유형의 데이터셋이 사용되었다. 하나는 APTOS(Asia Pacific Tele-Ophthalmology Society)로부터의 데이터셋이다[25]. 망막 이미지는 여러 종류의 임상 카메라를 사용하여 실험실에서 획득하였으며, 데이터베이스에는 3662개의 고해상도 컬러 FI가 포함되어 있다. 또 다른 데이터셋은 1748개의 FI를 포함하는 Messidor-2이다[25]. 일부 FI는 이 데이터셋에서 잘못 레이블링되어 수정되었으며, 최종 데이터셋에는 1738개의 FI가 포함되어 있다. 각각 0, 1, 2, 3, 4로 표현되는 DR 없음, 경도, 중등도, 중도, 증식 DR의 다섯 가지 단계가 있다. 도 4에 각각의 FI의 샘플 DR 없음(도 4(a)), 경도(도 4(b)), 중등도(도 4(c)), 중도(도 4(d)), 증식 DR(도 4(e))이 표시된다.

표 1은 데이터 분포를 나타내고 표 2는 단계와 그 설명을 보여준다.

<표 1>

Stages	APTOS-2019	Messidor-2
No-DR (0)	1805	1017
Mild (1)	370	269
Moderate (2)	999	343
Severe (3)	193	74
Proliferative DR (4)	295	35
Total	3662	1738

<표 2>

Stages	Description of DR Stages
No DR	No spots.
Mild DR	Only microaneurysms (MA).
Moderate DR	There is more to MA but not as severe as DR One or more of the following: In each of the four quadrants, there is more than 20 intraretinal haemorrhage (HM);
Severe DR	2+ quadrants have evident venous beading; 1+ quadrant has prominent intraretinal MA anomalies but no indications of proliferative DR.
Proliferative DR	Neovascularization, pre-retinal HM, or a combination of the two.

본 발명에서는 DR 분류의 두 가지 체계가 고려되었다. 하나는 DR 분류의 다섯 단계인 다중 분류이고 다른 하나는 이진 분류이다. 이진 분류의 경우 1~4는 클래스 1로 간주되고 0은 0으로 간주되어 DR 있음 및 DR 없음을 분류한다.

다중 클래스와 이진 분류 모두에서 APTOS-2019는 훈련과 테스트를 위해 각각 90:10의 비율로 구분되었다. 제안된 새로운 모델의 하이퍼 파라미터를 검증하기 위해 Messidor-2라는 또 다른 데이터셋이 다중 클래스 분류에 사용되었다. 훈련 및 테스트를 위해 이 데이터셋은 80:20의 비율로 나뉜다.

본 발명의 실시예에 따른 이미지 전처리의 품질은 분류 결과에 영향을 미치기 때문에 이미지 데이터의 전처리는 매우 중요하다. 본 발명의 실시예에 따른 전처리에서는 노이즈를 줄이기 위해 가우시안 블러 방법을 사용하여 이미지를 블러링했다. 블러링 과정은 Ben Graham이라고 명명하고, 여기서 이미지를 흐릿하게 하는 데 사용되는 파라미터를 제안했다. 블러링한 후 CLAHE를 적용하여 이미지 대비를 개선했다. CLAHE 이전에 블러링을 사용함으로써 CLAHE가 이미지에서 원하지 않는 노이즈를 개선하지 않도록 한다.

도 5는 본 발명의 일 실시예에 따른 전처리의 효과를 나타내는 도면이다.

도 5를 참조하면, 5개의 클래스(Class 0 ~ Class 4)에 대한 5개의 이미지가 있다. 첫 번째 열은 전처리 전의 이미지(Normal)를 나타내고, 두 번째 열은 블러링된 이미지(Ben Graham)를 나타내며, 마지막 열은 대비 강화 이미지(CLAHE)를 나타낸다.

본 발명의 실시예에 따르면 히스토그램 균등화(Histogram Equalization; HE)를 통해 이미지 대비와 모델 정확도가 향상되었다. 주로 FIs, X-ray, Satellite, Thermal photos와 같은 과학 활동과 관련된 저대조 영상에 사용된다. DR 영상의 대비가 낮기 때문에 영상 대비 강화를 이용할 수 있다.

본 발명의 실시예에 따르면 CLAHE라고 알려진 HE 접근 방식을 사용했다. 선택적 히스토그램 균등화(Adaptive Histogram Equalization; AHE)의 변형이다. 그러나 이미지가 사실상 균일한 영역에서 AHE는 노이즈를 과도하게 증폭한다. CLAHE는 증폭이 제한적이어서 문제를 극복한다. 클리핑 계수는 증폭을 클리핑한다.

본 발명 실시예에서는 2의 클리핑 팩터와 8×8의 타일 크기를 사용했다. 또 다른 고려 사항은 Ben graham을 FI에 대해 수행한 후, 이미지가 단일 채널로서 그레이 스케일에 있다는 점이다. CLAHE는 BGR 영상에서 작동하므로 단일 채널이 3개의 채널로 복사되어 도 5에 도시된 블러링된 이미지에 대해 CLAHE를 수행한다. 도 5를

참조하면, CLAHE를 수행한 후 학습이 더 정확하다는 것을 알 수 있다.

[0078] 데이터셋에는 특정 모양과 크기로 변환된 다양한 형태와 크기의 FI가 포함되어 있어 CNN 모델에 쉽게 적합할 수 있다. 그 결과, FI는 Ben Graham과 CLAHE를 적용한 후 크기가 224×224 픽셀로 조정된다. 이미지를 나타내기 위해 매우 다양한 강도 값이 사용된다. 결과적으로 많은 이미지 픽셀을 사용하지 않고 불필요한 복잡성을 방지하기 위해 정규화가 사용된다. 각 FI를 이미지 픽셀 값 255로 나눈 후 스케일이 0-255에서 0-1로 변경되어 이미지의 복잡성이 줄어든다.

[0079] 본 발명의 실시예에 따른 데이터셋에서 사용할 수 있는 다양한 특징이 있는데, 그 중 일부는 대상 변수를 예측하거나 데이터 중복을 생성하는 데 가장 적게 기여한다. 고차원 특징 공간은 분류기의 성능에 상당한 영향을 미친다.

[0080] 모델 학습에 있어서 복잡성과 시간 비용을 줄이기 위해 차원 축소 기법을 적용해야 한다. 이것은 원래의 특징 공간을 큰 손실 없이 실제 비중복 정보를 보유할 수 있는 최소 특징 공간으로 변환한다. 이 목적을 위한 기법에는 주성분 분석, 선형 판별 분석 및 특이값 분해((Singular Value Decomposition; SVD)가 있다. 본 발명에서는 CNN이 특징을 추출하는 데 사용되었다. 특징을 추출한 후 특징을 표준화하고, 마지막으로 SVD를 이용하여 차원 축소를 수행한다.

[0082] 도 6은 본 발명의 일 실시예에 따른 특징 추출부의 CNN 구조를 나타내는 도면이다.

[0083] 본 발명의 실시예에 따른 안저 망막 이미지에서 CNN을 사용한 특징 추출은 가장 두드러진 특징을 추출하기 위해 간단한 CNN이 제안되었다. 다양한 DR 단계를 구별하는 관련 속성이 추출되면 모델의 분류 성능이 향상된다. 이러한 이유로, 간단한 CNN 모델이 사용되었다. 특징 추출부 CNN의 구조는 도 6에 도시되어 있다. 표 3은 본 발명에 사용된 CNN 모델의 파라미터 값을 나타내며, 심층 CNN 모델은 표 4에 요약되어 있다.

[0084] <표 3>

Parameter Name	Attribute
Max-polling Filter Size	22
Activation Function	ReLu
Dropout	0.5
Loss Function	sparse categorical cross-entropy
Optimizer	Adam
Learning Rate	0.0001
Batch Size	16
Epochs	50

[0085]

<표 4>

Layer (type)	Output Shape	Param
conv2d_input (InputLayer)	[(None, 224, 224, 3)]	0
conv2d (Conv2D)	(None, 220, 220, 16)	1216
batch_normalization (BatchNo1)	(None, 220, 220, 16)	64
activation (Activation)	(None, 220, 220, 16)	0
max_pooling2d (MaxPooling2D)	(None, 110, 110, 16)	0
conv2d_1 (Conv2D)	(None, 108, 108, 32)	4640
batch_normalization (BatchNo2)	(None, 108, 108, 32)	128
activation_1 (Activation)	(None, 108, 108, 32)	0
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 32)	0
conv2d_2 (Conv2D)	(None, 52, 52, 64)	18496
batch_normalization (BatchNo3)	(None, 52, 52, 64)	256
activation_2 (Activation)	(None, 52, 52, 64)	0
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 64)	0
flatten (Flatten)	(None, 43264)	0
dense (Dense)	(None, 1024)	44303360
batch_normalization (BatchNo4)	(None, 1024)	4096
activation_3 (Activation)	(None, 1024)	0
dropout (Dropout)	(None, 1024)	0
dense_1 (Dense)	(None, 512)	524800
batch_normalization (BatchNo5)	(None, 512)	2048
activation_4 (Activation)	(None, 512)	0
dropout_1 (Dropout)	(None, 512)	0
Feature_Extractor (Dense)	(None, 256)	131328

이러한 추출된 특징은 DR 단계의 분류에 효율적으로 사용될 수 있다. CNN의 각 컨볼루션 계층(Convolutional Layer; CL)에는 배치 정규화와 최대 풀링 계층이 뒤따랐다. 배치 정규화는 계층 입력의 중심을 다시 잡고 크기를 다시 조정하여 모델의 성능을 향상시키고 속도를 높임으로써 채택되었다.

최대 풀링은 각 클러스터의 전체 뉴런에서 가장 큰 값을 선택하고 처리된 FI에서 가장 중요한 특징을 추출하는데 사용되었다. 드롭아웃은 훈련 단계 동안 각 계층의 모든 노드를 자주 훈련하지 않음으로써 이 경우 과적합을 줄이기 위해 사용되며, 이로 인해 훈련 속도가 상당히 향상된다. 마지막으로, 각 FI에서 마지막 밀집 계층을 사용하여 256개의 판별 특징을 추출한다.

본 발명의 실시예에 따른 특이값 분해(SVD)를 이용한 특징 감소는 고속 푸리에 변환(FFT)의 일반화된 개념에 기반한 데이터 기반 기술이다. 수학적 관점에서 행렬 $D_{(m \times n)}$ 는 $D=ASB^*$ 와 같은 또 다른 세 개의 행렬로 인수분해될 수 있다. 인수분해는 모든 행렬에 대해 고유하다. 여기서, $A_{(m \times m)}$ 와 $B_{(n \times n)}$ 는 단일 행렬이다. B^* 는 B 의 켤레 복소수를 나타낸다. 행렬 M 에 대한 $MM^*=I$ 를 단일 행렬이라고 한다면, $M^* = M^T \cdot S_{(m \times n)}$ 는 대각선 요소가 내림차순으로 양의 값이 되고 비대각선 요소가 0인 대각선 행렬이다. 양의 값 대각선 요소의 수는 행렬 D 의 순위와 같다. 행렬의 순위는 선형 독립 열 또는 행의 수를 나타낸다. $D = ASB^*$ 는 FFT와 마찬가지로 직렬 포메이션으로 표현할 수 있다.

예를 들어, a , s , b 가 3 행렬이라고 하자. 그러면 그것들의 곱셈은 다음과 같이 나타낼 수 있다:

$$\begin{aligned}
 asb &= \begin{bmatrix} a_1 & a_2 \\ a_3 & a_4 \end{bmatrix} \begin{bmatrix} s_1 & 0 \\ 0 & s_2 \end{bmatrix} \begin{bmatrix} b_1 & b_2 \\ b_3 & b_4 \end{bmatrix} \\
 &= \begin{bmatrix} a_1s_1 & a_2s_2 \\ a_3s_1 & a_4s_2 \end{bmatrix} \begin{bmatrix} b_1 & b_2 \\ b_3 & b_4 \end{bmatrix} \\
 &= \begin{bmatrix} a_1s_1b_1 + a_2s_2b_3 & a_1s_1b_2 + a_2s_2b_4 \\ a_3s_1b_1 + a_4s_2b_3 & a_3s_1b_2 + a_4s_2b_4 \end{bmatrix} \\
 &= s_1 \begin{bmatrix} a_1 \\ a_3 \end{bmatrix} \begin{bmatrix} b_1 & b_2 \end{bmatrix} + s_2 \begin{bmatrix} a_2 \\ a_4 \end{bmatrix} \begin{bmatrix} b_3 & b_4 \end{bmatrix}
 \end{aligned}$$

[0093] 따라서 ASB*는 다음과 같이 나타낼 수 있다:

$$\begin{bmatrix} | & | & & | \\ A_1 & A_2 & \cdots & A_m \\ | & | & & | \end{bmatrix} \begin{bmatrix} s_1 & 0 & 0 \\ 0 & s_2 & 0 \\ | & | & s_m \end{bmatrix} \begin{bmatrix} - & B_1 & - \\ - & B_2 & - \\ & \vdots & \\ - & B_n & - \end{bmatrix} \\ = s_1 \begin{bmatrix} | \\ A_1 \\ | \end{bmatrix} \begin{bmatrix} - & B_1 & - \end{bmatrix} + s_2 \begin{bmatrix} | \\ A_2 \\ | \end{bmatrix} \begin{bmatrix} - & B_2 & - \end{bmatrix} \\ + \cdots + s_m \begin{bmatrix} | \\ A_m \\ | \end{bmatrix} \begin{bmatrix} - & B_n & - \end{bmatrix}$$

[0094]

[0095] SVD는 S의 값이 지정된 값보다 큰 요소를 선택하여 D를 최적의 하위 근사치로 변환할 수 있다.

[0097] 도 7은 본 발명의 일 실시예에 따른 복수의 특징 측면에서의 누적 에너지를 나타내는 도면이다.

[0098] 도 7을 참조하면, 특징 수에 해당하는 S의 대각선 값의 정규화된 누적 합계를 사용하여 표시되었다. 이는 100개의 특징이 정보의 약 95%를 나타냈음을 나타낸다. 따라서 CNN을 사용하여 256개의 특징을 추출한 후, 100개의 특징을 선택했다.

[0100] 도 8은 본 발명의 일 실시예에 따른 당뇨병망막병증 분류부의 엑스트림 기계 학습 모델을 나타내는 도면이다.

[0101] 본 발명의 실시예에 따르면, 반복 모델 파라미터 조정 방법으로 인한 훈련 시간 비용을 줄이기 위해 엑스트림 기계 학습(Extreme Learning Machine; ELM)을 제안한다. ELM은 입력 계층, 단일 은닉 계층, 출력 계층이 있는 피드포워드 NN으로서 최소 훈련 오류를 달성할 수 있다. ELM 설계가 간단하고 반복적인 파라미터 조정이 필요하지 않기 때문에 훈련 프로세스가 향상된다. 제안하는 ELM 모델은 도 8에 도시하였다. 100개의 입력 노드, 500개의 은닉 노드, 5개의 출력 노드를 가지고 있으며, 이진 분류의 경우 5개 대신 1개의 출력 노드가 있다.

[0102] DR 훈련 샘플이 $\{X_1, Y_1\} = \{x_{(1,m)}, y_{(1,t)} : m \in R+, t \in R+\}$ 로 표현될 수 있다고 가정해 보자. X는 입력을 나타내고 Y는 출력을 나타낸다. 훈련 샘플은 다음과 같은 행렬 형식을 사용하여 나타낼 수 있다:

$$X_{(n,m)} = \begin{bmatrix} x_{(1,1)} & x_{(1,2)} & \cdots & x_{(1,m)} \\ x_{(2,1)} & x_{(2,2)} & \cdots & x_{(2,m)} \\ x_{(3,1)} & x_{(3,2)} & \cdots & x_{(3,m)} \\ \vdots & \vdots & & \vdots \\ x_{(n,1)} & x_{(n,2)} & \cdots & x_{(n,m)} \end{bmatrix} \\ Y_{(n,t)} = \begin{bmatrix} y_{(1,1)} & y_{(1,2)} & \cdots & y_{(1,t)} \\ y_{(2,1)} & y_{(2,2)} & \cdots & y_{(2,t)} \\ y_{(3,1)} & y_{(3,2)} & \cdots & y_{(3,t)} \\ \vdots & \vdots & & \vdots \\ y_{(n,1)} & y_{(n,2)} & \cdots & y_{(n,t)} \end{bmatrix}$$

[0103]

[0104] 여기서 인스턴스 수는 n개, 속성 수는 m, 노드 수는 t이다. 따라서 본 발명의 경우 m = 100 및 n 값은 훈련 및 테스트 데이터셋의 크기에 따라 변경된다. 이진 클래스 분류인 경우 t = 1이고 다중 클래스 분류인 경우 t = 5이다. 그런 다음 입력 가중치 W(m,N) 및 바이어스 B(1,N) 행렬이 랜덤하게 생성되며 N은 은닉 노드의 수이다.

$$W(m, N) = \begin{bmatrix} w(1,1) & w(1,2) & \cdots & w(1,N) \\ w(2,1) & w(2,2) & \cdots & w(1,N) \\ w(3,1) & w(3,2) & \cdots & w(1,N) \\ \vdots & \vdots & & \vdots \\ w(m,1) & w(m,2) & \cdots & w(m,N) \end{bmatrix}$$

$$B(1, N) = [b(1,1) \quad b(1,2) \quad \cdots \quad b(1,N)]$$

여기서, m은 속성의 수이고 N은 은닉 노드의 수이다. 본 발명의 경우 N 값은 500이 된다. 그런 다음 은닉 계층의 출력을 계산한다.

$$H(n, N) = G(X(n, m) \cdot W(m, N) + B(1, N)).$$

여기서 G(x)는 활성화 함수이다. 본 발명에서는 ReLu 활성화 함수가 사용되었다.

$$H(n, N) = \begin{bmatrix} h(1,1) & h(1,2) & \cdots & h(1,N) \\ h(2,1) & h(2,2) & \cdots & h(1,N) \\ h(3,1) & h(3,2) & \cdots & h(1,N) \\ \vdots & \vdots & & \vdots \\ h(n,1) & h(n,2) & \cdots & h(n,N) \end{bmatrix}$$

마지막으로, Moore-Penrose pseudo 역을 사용하여 출력 계층 가중치(N,t)를 계산한다.

$$\beta_{(N,t)} = H_{(N,n)}^{\dagger} \cdot T_{(n,t)}$$

여기서, T는 훈련 데이터 출력, t는 출력 수를 나타낸다.

하기 알고리즘은 이러한 당뇨병망막병증 분류부의 익스트림 기계 학습의 전체 과정을 나타낸다.

Algorithm Extreme Learning Machine

- 1) Randomly generates the input weight $W_{(m,N)}$ and bias $B_{(1,N)}$ matrix.
 - 2) Determine the output $H_{(n,N)}$ of the hidden layer.
 $H_{(n,N)} = G(X_{(n,m)} \cdot W_{(m,N)} + B_{(1,N)})$
 - 3) Determine the output weight matrix $\beta_{(N,t)}$
 $\beta_{(N,t)} = H_{(N,n)}^{\dagger} \cdot T_{(n,t)}$
 - 4) Make prediction using $\beta_{(N,t)}$
-

이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의

조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embodiment)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

- [0119] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 이용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 이용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.
- [0120] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.
- [0121] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.
- [0123] <참고문헌>
- [0124] [1] S. Das, K. Kharbanda, S. M, R. Raman, and E. D. D, "Deep learning architecture based on segmented fundus image features for classification of diabetic retinopathy," Biomed. Signal Process. Control, vol. 68, Jul. 2021, Art. no. 102600.
- [0125] [2] Y.-P. Liu, Z. Li, C. Xu, J. Li, and R. Liang, "Referable diabetic retinopathy identification from eye fundus images with weighted path for convolutional neural network," Artif. Intell. Med., vol. 99, Aug. 2019, Art. no. 101694.
- [0126] [3] R. Pires, S. Avila, J. Wainer, E. Valle, M. D. Abramoff, and A. Rocha, "A data-driven approach to referable diabetic retinopathy detection," Artif. Intell. Med., vol. 96, pp. 93-106, May 2019.
- [0127] [4] M. H. Mahmoud, S. Alamery, H. Fouad, A. Altinawi, and A. E. Youssef, "An automatic detection system of diabetic retinopathy using a hybrid inductive machine learning algorithm," Pers. Ubiquitous Comput., vol. 1, pp. 1-15, Jan. 2021.
- [0128] [5] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., Jun. 2016, pp. 2818-2826.
- [0129] [6] K. He, X. Zhang, S. Ren, and J. Sun, "Identity mappings in deep residual networks," in Proc. Eur. Conf. Comput. Vis. Amsterdam, The Netherlands: Springer, 2016, pp. 630-645.
- [0130] [7] J. D. Bodapati, N. S. Shaik, and V. Naralasetti, "Composite deep neural network with gated-attention mechanism for diabetic retinopathy severity classification," J. Ambient Intell. Hum. Comput., vol. 12, pp. 1-15, Jan. 2021.
- [0131] [8] W. L. Alyoubi, M. F. Abulkhair, and W. M. Shalash, "Diabetic retinopathy fundus image


classification and lesions localization system using deep learning," *Sensors*, vol. 21, no. 11, p. 3704, May 2021.

- [0132] [9] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," 2014, arXiv:1409.1556.
- [0133] [10] O. Dekhil, A. Naglah, M. Shaban, M. Ghazal, F. Taher, and A. Elbaz, "Deep learning based method for computer aided diagnosis of diabetic retinopathy," in *Proc. IEEE Int. Conf. Imag. Syst. Techn. (IST)*, Dec. 2019, pp. 1-4.
- [0134] [11] K. Shankar, Y. Zhang, Y. Liu, L. Wu, and C.-H. Chen, "Hyperparameter tuning deep learning for diabetic retinopathy fundus image classification," *IEEE Access*, vol. 8, pp. 118164-118173, 2020.
- [0135] [12] S. Majumder, Y. Elloumi, M. Akil, R. Kachouri, and N. Kehtarnavaz, "A deep learning-based smartphone app for real-time detection of five stages of diabetic retinopathy," *Proc. SPIE*, vol. 11401, Apr. 2020, Art. no. 1140106.
- [0136] [13] S. Qummar, F. G. Khan, S. Shah, A. Khan, S. Shamshirband, Z. U. Rehman, I. A. Khan, and W. Jadoon, "A deep learning ensemble approach for diabetic retinopathy detection," *IEEE Access*, vol. 7, pp. 150530-150539, 2019.
- [0137] [14] N. Sikder, M. Masud, A. K. Bairagi, A. S. M. Arif, A.-A. Nahid, and H. A. Alhumyani, "Severity classification of diabetic retinopathy using an ensemble learning algorithm through analyzing retinal images," *Symmetry*, vol. 13, no. 4, p. 670, Apr. 2021.
- [0138] [15] G. S., V. P. Gopi, and P. Palanisamy, "A lightweight CNN for diabetic retinopathy classification from fundus images," *Biomed. Signal Process. Control*, vol. 62, Sep. 2020, Art. no. 102115.
- [0139] [16] V. T, S. M, A. Kumaravel, and K. B, "Gabor filter and machine learning based diabetic retinopathy analysis and detection," *Microprocessors Microsyst.*, vol. 2020, Oct. 2020, Art. no. 103353.
- [0140] [17] H.-Y. Tsao, P.-Y. Chan, and E. C.-Y. Su, "Predicting diabetic retinopathy and identifying interpretable biomedical features using machine learning algorithms," *BMC Bioinf.*, vol. 19, no. S9, pp. 111-121, Aug. 2018.
- [0141] [18] S. Somasundaram and P. Alli, "A machine learning ensemble classifier for early prediction of diabetic retinopathy," *J. Med. Syst.*, vol. 41, no. 12, pp. 1-12, Dec. 2017.
- [0142] [19] A. R. Rajanna, K. Aryafar, R. Ramchandran, C. Sisson, A. Shokoufandeh, and R. Ptucha, "Neural networks with manifold learning for diabetic retinopathy detection," 2016, arXiv:1612.03961.
- [0143] [20] M. A. Al-Jarrah and H. Shatnawi, "Non-proliferative diabetic retinopathy symptoms detection and classification using neural network," *J. Med. Eng. Technol.*, vol. 41, no. 6, pp. 498-505, Aug. 2017.
- [0144] [21] P. Costa, A. Galdran, A. Smailagic, and A. Campilho, "A weakly-supervised framework for interpretable diabetic retinopathy detection on retinal images," *IEEE Access*, vol. 6, pp. 18747-18758, 2018.
- [0145] [22] A. M. Pour, H. Seyedarabi, S. H. A. Jahromi, and A. Javadzadeh, "Auto-matic detection and monitoring of diabetic retinopathy using efficient convolutional neural networks and contrast limited adaptive histogram equalization," *IEEE Access*, vol. 8, pp. 136668-136673, 2020.
- [0146] [23] X. Zeng, H. Chen, Y. Luo, and W. Ye, "Automated diabetic retinopathy detection based on binocular siamese-like convolutional neural network," *IEEE Access*, vol. 7, pp. 30744-30753, 2019.
- [0147] [24] G. Quellec, S. R. Russell, and M. D. Abramoff, "Optimal filter framework for automated, instantaneous detection of lesions in retinal images," *IEEE Trans. Med. Imag.*, vol. 30, no. 2, pp. 523-533, Feb. 2011.
- [0148] [25] (2010). Messidor-Adcis. Accessed: Oct. 18, 2021. [Online]. Available:


<https://www.adcis.net/en/third-party/messidor/>

도면


도면1




도면2




도면3




도면4




도면5



도면6



도면7



도면8

