



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0139319
(43) 공개일자 2024년09월23일

(51) 국제특허분류(Int. Cl.)
A61B 5/00 (2021.01) G06N 20/00 (2019.01)
G16H 50/20 (2018.01) G16H 50/50 (2018.01)
(52) CPC특허분류
A61B 5/4088 (2013.01)
A61B 5/0042 (2013.01)
(21) 출원번호 10-2023-0033169
(22) 출원일자 2023년03월14일
심사청구일자 2023년03월14일

(71) 출원인
한림대학교 산학협력단
강원도 춘천시 한림대학길 1, 한림대학교(옥천동)
(72) 발명자
이민우
경기도 안양시 동안구 관평로170번길 22(평촌동)
김철호
강원도 춘천시 삭주로 77, 춘천성심병원 신경과
외래 (교동)
여나영
강원도 춘천시 공지로 453(근화동)
(74) 대리인
특허법인본


전체 청구항 수 : 총 9 항

(54) 발명의 명칭 AIS 환자에 대한 인지 장애를 예측하는 머신 러닝 기반의 방법

(57) 요약

전자 장치가 개시된다. 본 전자 장치는, 인지 장애를 예측하기 위한 인공지능 모델을 포함하는 메모리, 뇌졸중 환자로부터 도출된 복수의 예측 인자를 인공지능 모델에 입력하여 뇌졸중 환자의 인지 장애를 예측하는, 프로세서를 포함한다. 복수의 예측 인자 각각은, 뇌졸중 환자의 인구학적 데이터, 임상 데이터, 및 뇌 이미지 데이터 중 적어도 하나와 관련된 것이다.

대표도



(52) CPC특허분류

A61B 5/4064 (2021.01)

A61B 5/7275 (2013.01)

G06N 20/00 (2021.08)

G16H 50/20 (2018.01)

G16H 50/50 (2018.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1465036270
과제번호	HR21C0198040022
부처명	보건복지부
과제관리(전문)기관명	한국보건산업진흥원
연구사업명	연구중심병원 육성 R&D
연구과제명	유전체 · 인공지능 기반 환자맞춤형 신치료 개발 및 관리 기술 개발
기 여 율	1/1
과제수행기관명	한림대학교산학협력단
연구기간	2021.07.01 ~ 2029.12.31

명세서

청구범위

청구항 1

전자 장치에 있어서,

인지 장애를 예측하기 위한 인공지능 모델을 포함하는 메모리; 및

뇌졸중 환자로부터 도출된 복수의 예측 인자를 상기 인공지능 모델에 입력하여 상기 뇌졸중 환자의 인지 장애를 예측하는, 프로세서;를 포함하고,

상기 복수의 예측 인자 각각은,

상기 뇌졸중 환자의 인구학적 데이터, 임상 데이터, 및 뇌 이미지 데이터 중 적어도 하나와 관련된 것인, 전자 장치.

청구항 2

제1항에 있어서,

상기 인공지능 모델은,

LR(Logistic Regression), SVM(Support Vector Machine), EGB(Extreme Gradient Boosting), 및 MLP(Multi-Layer Perceptron) 중 적어도 하나의 기계 학습 알고리즘을 바탕으로 훈련된 것인, 전자 장치.

청구항 3

제2항에 있어서,

상기 인공지능 모델은,

EGB(Extreme Gradient Boosting) 기법을 바탕으로 훈련된 모델인, 전자 장치.

청구항 4

제3항에 있어서,

상기 복수의 예측 인자는,

뇌졸중의 중증도 및 기저 내측 측두엽 위축(baseline medial temporal lobe atrophy) 여부를 각각 포함하는, 전자 장치.

청구항 5

제4항에 있어서,

상기 복수의 예측 인자는,

연령, 공복 혈당, 우울증 여부, 및 피질 병변의 존재 여부를 각각 포함하는, 전자 장치.

청구항 6

제5항에 있어서,

상기 복수의 예측 인자는,

과거 뇌졸중의 병력 및 과거 심방 세동의 병력을 각각 포함하는, 전자 장치.

청구항 7

인지 장애를 예측하기 위한 인공지능 모델을 포함하는 전자 장치의 동작 방법에 있어서,

상기 전자 장치가, 뇌졸중 환자로부터 도출된 복수의 예측 인자를 상기 인공지능 모델에 입력하는 단계; 및

상기 전자 장치가, 상기 인공지능 모델의 출력을 바탕으로 상기 뇌졸중 환자의 인지 장애를 예측하는 단계;를 포함하고,

상기 복수의 예측 인자 각각은,

상기 뇌졸중 환자의 인구학적 데이터, 임상 데이터, 및 뇌 이미지 데이터 중 적어도 하나와 관련된 것인, 전자 장치의 동작 방법.

청구항 8

전자 장치의 프로세서에 의해 실행되어, 상기 전자 장치로 하여금,

제7항의 동작 방법을 수행하도록 하는, 컴퓨터 판독 가능 매체에 저장된 컴퓨터 프로그램.

청구항 9

전자 장치에 있어서,

인지 장애를 예측하기 위해 EGB(Extreme Gradient Boosting) 기법을 바탕으로 훈련된 인공지능 모델을 포함하는 메모리; 및

뇌졸중 환자로부터 도출된 복수의 예측 인자를 상기 인공지능 모델에 입력하여 상기 뇌졸중 환자의 인지 장애를 예측하는, 프로세서;를 포함하는, 전자 장치.

발명의 설명

기술 분야

[0001] 본 개시는 급성 허혈성 뇌졸중 환자에서 발생할 수 있는 인지 기능 저하를 예측하기 위한 기계학습 모델을 활용하는 전자 장치에 관한 것이다. 급성 허혈성 뇌졸중 환자의 인구학적 특성, 임상 양상, 그리고 뇌 자기공명영상 검사 소견 등을 기반으로 인지기능 저하를 예측할 수 있는 기계학습 모델 적용 사례는 현재까지 없으며, 일반적인 예측 모델로는 인지기능을 예측하는 정확도가 높지 않았다. 본 기계학습 모델을 사용할 경우 효과적으로 정확하게 인지기능 저하를 예측할 수 있으며, 이를 이용하여 뇌졸중 환자들의 인지 예후 예측 및 예방에 활용이 가능하다.

배경 기술

[0002] 급성기 허혈성 뇌졸중(AIS, Acute Ischemic Stroke) 환자는 다양한 임상 양상 및 뇌 영상 소견을 가지고 있다. 이러한 임상 인자를 토대로 기능적 예후 및 인지 예후를 예측하기 위하여 여러가지 예측 모델들이 사용되었는데, 로지스틱 회귀 분석을 통한 전통적인 예측 모델 등이 있다.

[0003] 하지만 허혈성 뇌졸중 이후 인지기능에 미치는 인자들이 매우 다양하고, 인자 간의 간섭효과가 있으며, 사전 지식 혹은 과거 연구 결과로 알 수 없는 미지의 인자들이 있을 수 있기 때문에 최대한 많은 숫자의 인자를 예측 모델에 반영하는 것이 필수적이다. 하지만 전통적인 예측 모델은 사용할 수 있는 예측 인자의 개수가 한정적이기 때문에 현재까지 인지기능 저하를 예측하는 모델들의 정확도, 민감도, 특이도가 모두 낮은 실정이다.

[0004] PSCI(Prediction of Post-stroke Cognitive Impairment)는 병전에 치매가 없는 환자에서 급성 뇌졸중 후 인지 결핍의 발달을 말하며 뇌졸중 후 생존자의 기능적 의존성을 결정하는 주요 요인 중 하나이다. PSCI의 유병률은 민족, 국가, 뇌졸중 후 기간 및 진단 기준에 따라 20~75% 이다. PSCI는 인지 장애를 유발할 뿐만 아니라 뇌졸중 및 사망률을 포함한 다른 재발성 혈관 사건의 위험도 증가시킨다. 뇌졸중 생존자에서 PSCI의 유병률과 부담은 상당하지만 PSCI 발달의 예측은 여전히 최적이 아니다.

[0005] AIS 환자의 뇌졸중 후 인지 예측은 AIS 환자의 만성 치료 중 인지 평가 및 치료 결정에 유용할 수 있다. 이전 연구에서는 AIS 환자의 임상 및/또는 방사선학적 소견을 사용하여 여러 예후 스코어링 시스템을 보고했다. 2개의 채점 시스템인 CHANGE 및 SIGNAL2 scale은 0.740-0.829 범위의 수신기 조작 특성 곡선 아래 영역에서 PSCI의 예측에서 어느 정도 정확한 것으로 나타났다. 뇌졸중 후 인지 저하의 병태생리학 및 체계적 수많은 결정 요인으로 인해 복잡하기 때문에 제한된 수의 변수가 있는 전통적인 점수 시스템은 PSCI를 정확하게 예측하지 못할

수 있다.

발명의 내용

해결하려는 과제

[0006] 본 개시에서는 31 개 이상의 인자들을 사용하여 4개 이상의 기계학습 모델을 통해 효율적으로 정확하게 인지 예측률을 예측할 수 있는 전자 장치를 제공한다. 이때,

[0007] 본 개시의 목적들은 이상에서 언급한 목적으로 제한되지 않으며, 언급되지 않은 본 개시의 다른 목적 및 장점들은 하기의 설명에 의해서 이해될 수 있고, 본 개시의 실시 예에 의해 보다 분명하게 이해될 것이다. 또한, 본 개시의 목적 및 장점들은 특허 청구 범위에 나타난 수단 및 그 조합에 의해 실현될 수 있음을 쉽게 알 수 있을 것이다.

과제의 해결 수단

[0008] 본 개시의 일 실시 예에 따른 전자 장치는, 인지 장애를 예측하기 위한 인공지능 모델을 포함하는 메모리, 뇌졸중 환자로부터 도출된 복수의 예측 인자를 상기 인공지능 모델에 입력하여 상기 뇌졸중 환자의 인지 장애를 예측하는, 프로세서를 포함한다. 상기 복수의 예측 인자 각각은, 상기 뇌졸중 환자의 인구학적 데이터, 임상 데이터, 및 뇌 이미지 데이터 중 적어도 하나와 관련된 것이다.

[0009] 상기 인공지능 모델은, LR(Logistic Regression), SVM(Support Vector Machine), EGB(Extreme Gradient Boosting), 및 MLP(Multi-Layer Perceptron) 중 적어도 하나의 기계 학습 알고리즘을 바탕으로 훈련된 것일 수 있다.

[0010] 구체적으로, 상기 인공지능 모델은, EGB(Extreme Gradient Boosting) 기법을 바탕으로 훈련된 모델일 수 있다.

[0011] 이때, 상기 복수의 예측 인자는, 뇌졸중의 중증도 및 기저 내측 측두엽 위축(baseline medial temporal lobe atrophy) 여부를 각각 포함할 수 있다.

[0012] 또한, 상기 복수의 예측 인자는, 연령, 공복 혈당, 우울증 여부, 및 피질 병변의 존재 여부를 각각 포함할 수 있다.

[0013] 또한, 상기 복수의 예측 인자는, 과거 뇌졸중의 병력 및 과거 심방 세동의 병력을 각각 포함할 수 있다.

[0014] 본 개시의 일 실시 예에 따라 인지 장애를 예측하기 위한 인공지능 모델을 포함하는 전자 장치의 동작 방법은, 상기 전자 장치가, 뇌졸중 환자로부터 도출된 복수의 예측 인자를 상기 인공지능 모델에 입력하는 단계, 상기 전자 장치가, 상기 인공지능 모델의 출력을 바탕으로 상기 뇌졸중 환자의 인지 장애를 예측하는 단계를 포함한다. 상기 복수의 예측 인자 각각은, 상기 뇌졸중 환자의 인구학적 데이터, 임상 데이터, 및 뇌 이미지 데이터 중 적어도 하나와 관련된 것이다.

[0015] 본 개시의 일 실시 예에 따른 전자 장치는, 인지 장애를 예측하기 위해 EGB(Extreme Gradient Boosting) 기법을 바탕으로 훈련된 인공지능 모델을 포함하는 메모리, 뇌졸중 환자로부터 도출된 복수의 예측 인자를 상기 인공지능 모델에 입력하여 상기 뇌졸중 환자의 인지 장애를 예측하는, 프로세서를 포함한다.

발명의 효과

[0016] 본 개시에 따른 전자 장치는 종래의 기법과 달리 기계 학습 모델에 다수의 예측 인자를 입력하여, 뇌졸중 환자의 인지 장애 발생에 대한 예측 정확도가 비약적으로 상승한 효과가 있다.

도면의 간단한 설명

[0017] 도 1은 본 개시의 일 실시 예에 따른 전자 장치의 구성을 설명한 블록도,
 도 2는 뇌졸중 이후 인지 기능 저하를 예측하기 위한 학습 모델 개발 구조,
 도 3은 연구 기간 동안 발생한 인지 장애에 따라 구분된 환자들의 구분 기준을 담은 도면,
 도 4는 본 개시의 전자 장치가 다양한 기계 학습 모델을 활용한 결과에 따른 ROC 곡선 및 confusion 행렬을 도시한 도면,

도 5는 본 개시의 일 실시 예에 따른 전자 장치가 EGB 모델을 활용하는 경우 주요 변수를 선별하기 위한 SHAP 값을 도시한 도면,

도 6은 본 개시의 다양한 실시 예에 따른 전자 장치가 다른 종류의 기계 학습 모델을 활용하는 경우 주요 변수를 선별하기 위한 SHAP 값을 도시한 도면,

도 7은 본 개시의 전자 장치가 다양한 기계 학습 모델을 활용한 결과에 따른 ROC 곡선을 MMSEz(좌측) 및 MMSE(우측) 각각에 대해 도시한 도면이다.

발명을 실시하기 위한 구체적인 내용

- [0018] 본 개시에 대하여 구체적으로 설명하기에 앞서, 본 명세서 및 도면의 기재 방법에 대하여 설명한다.
- [0019] 먼저, 본 명세서 및 청구범위에서 사용되는 용어는 본 개시의 다양한 실시 예들에서의 기능을 고려하여 일반적인 용어들을 선택하였다. 하지만, 이러한 용어들은 당해 기술 분야에 종사하는 기술자의 의도나 법률적 또는 기술적 해석 및 새로운 기술의 출현 등에 따라 달라질 수 있다. 또한, 일부 용어는 출원인이 임의로 선정한 용어도 있다. 이러한 용어에 대해서는 본 명세서에서 정의된 의미로 해석될 수 있으며, 구체적인 용어 정의가 없으면 본 명세서의 전반적인 내용 및 당해 기술 분야의 통상적인 기술 상식을 토대로 해석될 수도 있다.
- [0020] 또한, 본 명세서에 첨부된 각 도면에 기재된 동일한 참조번호 또는 부호는 실질적으로 동일한 기능을 수행하는 부품 또는 구성요소를 나타낸다. 설명 및 이해의 편의를 위해서 서로 다른 실시 예들에서도 동일한 참조번호 또는 부호를 사용하여 설명한다. 즉, 복수의 도면에서 동일한 참조 번호를 가지는 구성요소를 모두 도시되어 있다고 하더라도, 복수의 도면들이 하나의 실시 예를 의미하는 것은 아니다.
- [0021] 또한, 본 명세서 및 청구범위에서는 구성요소들 간의 구별을 위하여 "제1", "제2" 등과 같이 서수를 포함하는 용어가 사용될 수 있다. 이러한 서수는 동일 또는 유사한 구성요소들을 서로 구별하기 위하여 사용하는 것이며 이러한 서수 사용으로 인하여 용어의 의미가 한정 해석되어서는 안 된다. 일 예로, 이러한 서수와 결합된 구성요소는 그 숫자에 의해 사용 순서나 배치 순서 등이 제한되어서는 안 된다. 필요에 따라서는, 각 서수들은 서로 교체되어 사용될 수도 있다.
- [0022] 본 명세서에서 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, "포함하다" 또는 "구성되다" 등의 용어는 명세서상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.
- [0023] 본 개시의 실시 예에서 "모듈", "유닛", "부(part)" 등과 같은 용어는 적어도 하나의 기능이나 동작을 수행하는 구성요소를 지칭하기 위한 용어이며, 이러한 구성요소는 하드웨어 또는 소프트웨어로 구현되거나 하드웨어 및 소프트웨어의 결합으로 구현될 수 있다. 또한, 복수의 "모듈", "유닛", "부(part)" 등은 각각이 개별적인 특정한 하드웨어로 구현될 필요가 있는 경우를 제외하고는, 적어도 하나의 모듈이나 칩으로 일체화되어 적어도 하나의 프로세서로 구현될 수 있다.
- [0024] 또한, 본 개시의 실시 예에서, 어떤 부분이 다른 부분과 연결되어 있다고 할 때, 이는 직접적인 연결뿐 아니라, 다른 매체를 통한 간접적인 연결의 경우도 포함한다. 또한, 어떤 부분이 어떤 구성요소를 포함한다는 의미는, 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다.
- [0025] 도 1은 본 개시의 일 실시 예에 따른 전자 장치의 구성을 설명하기 위한 블록도이다. 도 1을 참조하면, 전자 장치(100)는 메모리(110) 및 프로세서(120)를 포함한다.
- [0026] 전자 장치(100)는 뇌졸중 환자의 인지 장애를 예측 내지 진단하기 위한 정보 제공 장치로 구현될 수 있다. 또한, 전자 장치(100)는 의사의 임상적 판단을 지원하기 위한 다양한 정보를 제공하기 위한 서버로 구현될 수 있다. 또한, 전자 장치(100)는 인지 장애의 예측을 위한 소프트웨어/애플리케이션을 실행할 수 있는 데스크탑 PC, 노트북 PC, 태블릿 PC, 스마트폰 등 다양한 단말 기기에 해당할 수 있다.
- [0027] 메모리(110)는 전자 장치(100)의 구성요소들의 전반적인 동작을 제어하기 위한 운영체제(OS: Operating System) 및 전자 장치(100)의 구성요소와 관련된 적어도 하나의 인스트럭션 또는 데이터를 저장하기 위한 구성이다.
- [0028] 메모리(110)는 ROM, 플래시 메모리 등의 비휘발성 메모리를 포함할 수 있으며, DRAM 등으로 구성된 휘발성 메모

리를 포함할 수 있다. 또한, 메모리(110)는 하드 디스크, SSD(Solid state drive) 등을 포함할 수도 있다.

- [0029] 도 1을 참조하면, 메모리(110)는 인지 장애를 예측하기 위한 적어도 하나의 인공지능 모델(111)을 포함할 수 있다.
- [0030] 본 인공지능 모델(111)은, LR(Logistic Regression), SVM(Support Vector Machine), EGB(Extreme Gradient Boosting), 및 MLP(Multi-Layer Perceptron) 중 적어도 하나의 기계 학습 알고리즘을 바탕으로 훈련된 것일 수 있다.
- [0031] 구체적으로, 인공지능 모델(111)은 EGB(Extreme Gradient Boosting) 기법을 바탕으로 훈련된 모델일 수 있으며, EGB가 채택될 수 있는 근거는 이하 실험 내용에 따라 설명된다.
- [0032] 프로세서(120)는 전자 장치(100)를 전반적으로 제어하기 위한 구성이다. 구체적으로, 프로세서(120)는 메모리(110)와 연결되는 한편 메모리(110)에 저장된 적어도 하나의 인스트럭션을 실행함으로써 본 개시의 다양한 실시 예들에 따른 동작을 수행할 수 있다.
- [0033] 프로세서(120)는 CPU, AP, DSP(Digital Signal Processor) 등과 같은 범용 프로세서, GPU, VPU(Vision Processing Unit) 등과 같은 그래픽 전용 프로세서 또는 NPU와 같은 인공지능 전용 프로세서 등을 포함할 수 있다. 인공지능 전용 프로세서는, 특정 인공지능 모델의 훈련 내지는 이용에 특화된 하드웨어 구조로 설계될 수 있다.
- [0034] 프로세서(120)는 뇌졸중 환자로부터 도출된 복수의 예측 인자를 인공지능 모델(111)에 입력하여 뇌졸중 환자의 인지 장애를 예측할 수 있다. 구체적으로, 프로세서(120)는 급성 허혈성 뇌졸중(Acute Ischemic Stroke, AIS) 환자로부터 도출된 복수의 예측 인자를 인공지능 모델(111)에 입력하여, PSCI(Post-stroke Cognitive Impairment)의 발생 여부를 예측할 수 있다.
- [0035] 복수의 예측 인자 각각은, 뇌졸중 환자의 인구학적 데이터, 임상 데이터, 및 뇌 이미지 데이터 중 적어도 하나와 관련된 것일 수 있다.
- [0036] 구체적인 예로, 인구학적 요인(나이, 성별, 체질량 지수, 교육연수), 심뇌혈관 질환 위험 요인(고혈압, 당뇨, 고지혈증, 관상동맥질환, 과거 뇌경색, 심방세동, 흡연), 뇌졸중의 특성(뇌졸중 중증도 점수, 뇌졸중 분류), 뇌 영상 소견(다발성 병변, 좌측 병변, 피질 병변, 속질 병변, 천막하 병변, 전략적 위치 병변, 뇌졸중 부피, 수정 파제카 점수, 만성 미세출혈, 측두엽 위축), 혈액검사 소견(혈당, 크레아티닌, 총 콜레스테롤, 헤모글로빈, 수축기혈압), 그리고 우울증 척도검사 등 다양한 예측 인자가 활용될 수 있다.
- [0037] 도 2에 표시된 것은 뇌졸중 이후 인지 기능 저하(: 인지 장애)를 예측하기 위한 인공지능 모델의 개발 과정이다. 1,000명이 넘는 환자들로부터 도출된 30개 이상의 예측 인자들은 전처리 과정을 거쳐 모델에 산입될 수 있는 구조로 구성하게 되며, 기술된 바와 같이 LR(Logistic Regression), SVM(Support Vector Machine), EGB(Extreme Gradient Boosting), 및 MLP(Multi-Layer Perceptron) 등 다양한 모델 각각을 토대로 학습이 진행되어 최적의 모델이 개발되었으며, 예측하는 인자의 중요성에 따른 나열을 하기 위하여 Shapley Value를 계산하여 중요 인자를 제시한다.
- [0039] 이하 내용을 통해서는, 본 개시에 따른 전자 장치(100)의 구성 및 동작의 효과를 입증하기 위한 연구 내용 및 그에 따른 구체적인 실시 예를 설명한다.
- [0040] 본 개시에 따른 연구는 증상 발생 후 7일 이내에 3차 대학병원에 입원한 급성 허혈성 뇌졸중 환자를 대상으로 하였다. 모든 환자는 국제 및 국내 지침을 기반으로 한 제도적 뇌졸중 프로토콜에 따라 표준 평가 및 관리를 받았다. 실험실 및 영상 연구와 별도로, 주치의의 재량에 따라 인지 저하를 호소하거나 PSCI 위험이 높은 뇌졸중 발병 3~6개월 후 급성 허혈성 뇌졸중 환자를 대상으로 신경심리학적 배터리를 실시했다.
- [0041] 본 연구의 선정 기준은 이하와 같다. (1) 2011년 1월부터 2020년 12월까지 연속된 허혈성 뇌졸중 환자, (2) diffusion-weighted 영상에서 관련 허혈성 병변이 관찰된 경우, (3) 증상 발현 7일 이내 내원, (4) 뇌졸중 발병 후 3~6개월 동안 이용 가능한 신경심리학적 배터리 데이터.
- [0042] 참가자는 (1) 환자가 병적 치매의 병력이 있는 경우(즉, 이전에 치매로 진단되고 anti-cholinesterase inhibitors 또는 memantine을 처방을 받은 환자), (2) 뇌졸중 전 수정된 Rankin 척도 점수가 2보다 큰 환자인 경우 제외되었다. (3) 난청, 협응력 저하, 중증 실어증 등 신경학적 결손으로 인해 신경심리학적 배터리 수행이

불가능하여 신경심리학적 검사를 시행할 수 없는 환자도 제외하였다.

[0043] 입원 당시 연령, 성별, 교육 수준을 포함한 기준선 및 인구통계학적 요인이 수집되었다. 임상적 요인에는 초기 NIHSS(National Institute of Health Stroke Scale) 점수 및 급성 뇌졸중 치료(TOAST) 분류의 ORG 10172 시험에 따른 뇌졸중 하위 유형이 포함된다. 동맥 고혈압, 이상 지질혈증, 진성 당뇨병, 흡연 상태, 뇌졸중 또는 일과성 허혈 발작의 병력, 심방 세동을 포함하는 심장 색전증의 잠재적 원인 등을 포함한 혈관 위험 인자의 존재를 수집했다. 초기 랜덤 포도당, 백혈구, 전체 콜레스테롤, 저밀도 지단백질, 고밀도 지단백질, 중성 지방 및 크레아티닌을 포함한 실험 결과도 수집되었다. 모든 참가자는 입원 연도에 따라 1.5T 또는 3T의 전신 MRI 시스템을 사용하여 뇌 MRI c촬영을 수행했다. 허혈성 뇌졸중 병변의 편측성, 다중성, 및 부피를 수집하였다. 또한 병변 위치는 피질, 피질하, 천막하 병변으로 분류하였다. 전략적 병변 위치는 기저핵, 시상, 해마, 꼬리뼈, 내측 측두엽, 각이랑으로 정의하였다. 기저 소혈관 질환은 엽성 또는 심부만성 미세출혈의 유무와 수정된 Fazekas 척도에 따른 백질의 고강도 정도를 평가하였다. 또한 내측 측두엽 위축 정도는 Shelten 척도를 이용하여 수집하였다.

[0044] 1차 결과는 영역별 정의를 사용하여 뇌졸중 후 3~6개월에 PSCI 진단으로 정의되었다. PSCI 영역은 기억, 언어, 시공간 및 전두엽/집행 기능 중 적어도 하나의 인지 영역에서 표준화된 z 점수가 2 표준 편차 이하인 것으로 정의되었다. 포함된 모든 참가자는 뇌졸중 발병 후 3~6개월에 한국판 혈관 인지 장애 조화 표준-신경 심리학 프로토콜(K-VCIHS-NP)을 사용하여 60분 신경 심리학 배터리로 평가되었다. K-VCIHS-NP는 4개의 주요 인지 영역으로 구성되며 포함된 신경 심리학적 테스트의 세부 사항은 이전에 자세히 보고되었다.

[0045] 일반 인지 기능 평가를 위한 한국판 간이정신상태검사(K-MMSE)도 시행하였다. K-VCIHS-NP의 모든 인지 배터리는 한국인의 사용에 대해 검증되었으며 각 테스트의 점수는 연령, 성별 및 교육 기간을 조정한 후 z-점수로 변환되었다. 영역별 z-점수는 영역별 테스트를 구성하는 각 인지 테스트의 z-점수의 평균으로 계산되었다. 참가자들의 뇌졸중 전 인지 평가는 한국판 IQCODE(Informed Questionnaire on Cognitive Decline in the Elderly)를 사용하여 구조화된 설문지로 수행되었다. 3.6 이상의 IQCODE 점수는 병전 인지 감퇴에 대한 컷오프로 설정되었다. 이차 결과에는 K-MMSE의 z 점수 및 원시 점수에 따른 진단 PSCI가 포함되니다. PSCI-MMSEz는 MMSE의 z-score가 -2 SD 미만일 때 진단하였고, PSCI-MMSE는 MMSE의 raw score가 24 미만일 때 진단하였다.

[0046] 이하와 같이 총 30개의 임상 및 이미징 변수가 PSCI 예측을 위한 기계 학습 모델 개발에 포함되었다.

Demographics	Age
	Sex
	Body mass index
	Education years
	Previous modified Rankin Scale
Vascular Risk factors	History of hypertension
	History of diabetes mellitus
	History of hyperlipidemia
	History of coronary heart disease
	History of stroke or TIA
	History of atrial fibrillation
Stroke Clinical Characteristics	Smoking status
	Discharge NIHSS
	TOAST classification
Neuroimage characteristics	Multiple lesions
	Left sided lesions
	Stroke volume (mm ³)
	Presence of cortical lesion
	Presence of subcortical lesion
	Presence of infratentorial lesion
	Presence of strategic lesion
	Modified Fazekas score
	Any chronic microbleeds
Laboratory results	Total mesial temporal lobe atrophy
	Fasting blood glucose
	Creatinine
	Total cholesterol
	Hemoglobin
Others	Systolic blood pressure
	SGDS

[0047]

[0048] LR(Logistic Regression), SVM(Support Vector Machine), EGB(Extreme Gradient Boosting), MLP(Multi-Layer Perceptron)의 4가지 기계 학습 알고리즘이 사용되었다. LR은 선형 함수를 sigmoid 함수에 대입하고 그 결과를 0 또는 1로 표현하여 이진 분류에 사용하는 모델이다. SVM은 이진 분류를 위한 초평면을 찾는 모델로, 데이터 입력과 같이 고차원으로 표현된다. 부스팅(Boosting)은 앙상블 기법 중 하나로, 여러 약한 학습자(weak learners)를 순차적으로 학습하는 과정에서 예측하지 못한 데이터에 가중치를 부여해 오차를 개선하는 모델이다. EGB는 Decision Tree인 Weak Learners의 앙상블 모델이며 Gradient Descent를 사용하여 가중치를 업데이트한다. 또한 손실 개선을 위해 사용된 알고리즘에 과대적합을 방지하는 기법을 적용하였다. MLP는 여러 개의 feed-forward 신경망으로 구성된 모델이다. 일반적으로 매우 복잡한 문제의 비선형 분류에 주로 사용되며 계층이나 변수의 수가 증가할수록 성능이 향상된다. 그러나 과도한 레이어 구성과 다중 변수 사용은 오버피팅을 유발할 수 있다. 본 연구에서는 과적합 방지와 모델 최적화를 위해 계층화된 k-fold, 클래스 가중치, 무작위 검색 기법을 사용하였다. 먼저 트레이닝 데이터셋을 10-fold로 나누고, 분할된 데이터셋에 동일한 비율의 클래스를 구성하여 교차 검증을 수행하였다. 교차 검증은 특정 데이터 세트에 대한 과적합을 방지하고 보다 일반화된 모델을 생성할 수 있다. 클래스 가중치, 초점 손실, 데이터 불균형 문제 해결을 위한 리샘플링 기법 중 클래스 가중치 기법을 적용하였다. MMSE 점수, MMSE z-score, PSCI z-score에 따라 나뉜 각 출력 변수의 클래스 비율은 손실 계산에 균등하게 기여할 수 있도록 계산되었다. Grid-Search는 일반적으로 하이퍼 파라미터를 검색하는데 사용되지만 최적의 하이퍼 파라미터를 찾는 데 더 나은 성능을 위해 무작위 검색을 사용했다. 기계 학습 모델은 무작위 검색 기반의 하이퍼 매개변수 최적화 프레임워크인 Optuna를 사용하여 최적화되었다.

[0049] 최근 머신러닝 모델의 성능이 높아지면서 모델의 결과를 설명하는 XAI(eXplainable AI)의 중요성이 높아지고 있다. 그 중 SHAP(SHapley Additive exPlanations)를 활용하여 특징 속성을 수치적으로 표현하였다. 특히 특징

속성은 로컬 정확도, 누락 및 일관성을 충족해야 한다. SHAP 값은 이 세 가지 특성을 충족하는 유일한 추가 기능 중요도 측정이다. 또한 변수 간의 종속성을 고려하여 모델의 영향력을 계산한다. 따라서 PSCI 예측에 있어 각 변수의 기여도를 직관적으로 확인할 수 있다. 따라서 SHAP 값을 통해 PSCI 관련 변수의 특성 중요도와 관계를 도출하였다.

[0050] 연구 모집단 중 80%는 학습 데이터로 무작위로 선택하고 나머지 20%는 테스트 데이터로 사용했다.

[0051] 기술 분석을 위해 연속 변수는 평균 $\pm$ 표준 편차 또는 사분위수 범위(IQR)가 있는 중앙값과 숫자 및 빈도가 있는 범주형 변수로 표시된다. PSCI 그룹과 PSCI 그룹이 없는 그룹 간의 기준선, 임상 및 이미징 특성은 연속 변수에 대해 t-테스트 또는 Mann-Whitney U 테스트를 사용하고 범주형 변수에 대해 카이-제곱 테스트 또는 Fisher의 정확도 테스트를 적절하게 사용하여 비교했다. 개발된 기계 학습 모델의 성능 측정을 평가하기 위해 AUC(Area Under the Curve), 정확도, 및 F1 점수를 계산했다.

[0052] 연구 기간 동안 조사된 4,329명의 환자 중 1,047명이 본 연구에 포함되었다(도 3). 평균 연령은 65.7 ± 11.9 세였고 뇌졸중 발병에서 신경심리학적 평가까지의 평균 간격은 4개월이었다. 우리 코호트에서 중앙 NIHSS 점수는 2(IQR 1-5)였다. 포함된 환자와 제외된 환자 간의 인구통계학적 및 임상적 변수의 비교는 이하 표에서 확인된다.

[0053] 포함된 1,047명의 환자 중 K-VCiHS-NP 결과에 따르면 333명(31.8%)에서 뇌졸중 후 3-6개월에 PSCI가 발생했다. PSCI 그룹과 PSCI 그룹이 없는 그룹의 기본 특성은 이하 표에 나와 있다.

	Patients without PSCI (n=714)	Patients with PSCI (n=333)	p-value
Demographic Characteristics			
Age, mean $\pm$ SD	64.9 $\pm$ 12.2	67.3 $\pm$ 11.1	0.002
Sex, male, n(%)	446 (62.5%)	198 (59.5%)	0.388
Education years, median[IQR]	9.0 [6.0;12.0]	9.0 [6.0;12.0]	0.651
Previous mRS, median[IQR]	0.0 [0.0; 0.0]	0.0 [0.0; 0.0]	0.009
BMI, mean $\pm$ SD	24.3 $\pm$ 3.1	23.9 $\pm$ 3.4	0.056
Stroke Characteristics			
TOAST classification			<0.001
-LAA, n(%)	254 (35.6%)	125 (37.5%)	
-SVO, n(%)	300 (42.0%)	93 (27.9%)	
-CE, n(%)	82 (11.5%)	67 (20.1%)	
-UD and OD, n(%)	78 (10.9%)	38 (11.4%)	
Initial NIHSS, median[IQR]	2.0 [1.0;4.0]	3.0 [1.0;6.0]	<0.001
Thrombolysis			0.057
-IV tPA, n(%)	66 (9.2%)	38 (11.4%)	
-IA thrombectomy, n(%)	9 (1.3%)	4 (1.2%)	
-Combined IV+IA, n(%)	8 (1.1%)	11 (3.3%)	
Lesion Characteristics			
Stroke volume(mm ³), median[IQR]	4.2 [0.8;20.5]	10.3 [1.3;114.8]	<0.001
Left sided lesions, n(%)	402 (56.3%)	192 (57.7%)	0.73
Multiple lesions, n(%)	67 (9.4%)	34 (10.2%)	0.757
Cortical lesions, n(%)	221 (31.0%)	171 (51.4%)	<0.001
Subcortical lesions, n(%)	362 (50.7%)	161 (48.3%)	0.625
Infratentorial lesions, n(%)	201 (28.2%)	65 (19.5%)	0.004
Strategic lesions, n(%)	229 (32.1%)	140 (42.0%)	0.002
Vascular Risk Factors			
Hypertension, n(%)	413 (57.8%)	215 (64.6%)	0.046
Diabetes mellitus, n(%)	191 (26.8%)	121 (36.3%)	0.002
Hyperlipidemia, n(%)	256 (35.9%)	108 (32.4%)	0.311
Previous Stroke/TIA, n(%)	86 (12.0%)	68 (20.4%)	0.001
Coronary Heart Disease, n(%)	34 (4.8%)	27 (8.1%)	0.044
Atrial Fibrillation, n(%)	74 (10.4%)	70 (21.0%)	<0.001
Smoking, n(%)	277 (38.8%)	118 (35.4%)	0.329
Laboratory Findings			
Total Cholesterol(mg/dL), mean $\pm$ SD	181.3 $\pm$ 42.8	177.6 $\pm$ 46.9	0.217
Serum creatinine(mg/dL), mean $\pm$ SD	0.8 $\pm$ 0.5	0.9 $\pm$ 0.8	0.186
Hemoglobin(mg/dL), mean $\pm$ SD	14.0 $\pm$ 1.7	13.9 $\pm$ 1.7	0.243
Fasting blood sugar(mg/dL), mean $\pm$ SD	120.4 $\pm$ 42.6	129.0 $\pm$ 48.9	0.006
Systolic blood pressure(mmHg), mean $\pm$ SD	149.1 $\pm$ 25.8	146.8 $\pm$ 24.6	0.178
Small Vessel Disease Burden and Atrophy			
Microbleeds, n(%)	132 (18.5%)	67 (20.1%)	
Modified Fazekas score			0.086
-mFS grade 0, n(%)	132 (18.5%)	51 (15.3%)	
-mFS grade 1, n(%)	329 (46.1%)	144 (43.2%)	
-mFS grade 2, n(%)	176 (24.6%)	85 (25.5%)	
-mFS grade 3, n(%)	77 (10.8%)	53 (15.9%)	
Total MTLA, median[IQR]	2.0 [1.0;3.0]	2.0 [2.0;4.0]	<0.001

*Abbreviations. PSCI, post-stroke cognitive impairment; BMI, body mass index; TOAST, Trial of ORG 10172 in Acute Stroke Treatment; LAA, large artery atherosclerosis; SVO, small vessel occlusion; CE, cardioembolism; OD, other determined; UD, undetermined; NIHSS, national institute of health stroke scale; IV, intravenous; tPA, tissue plasminogen activator; IA, intraarterial; mFS, modified Fazekas scale; MTLA, medial temporal lobe atrophy

[0054]

[0055] PSCI의 발달은 고령, 심장 색전증 병인, 높은 초기 NIHSS 점수, 더 큰 뇌졸중 용적 및 피질 또는 전략적 병변의 존재와 유의하게 연관되었다. PSCI 그룹은 또한 고혈압, 진성 당뇨병, 관상 동맥 심장 질환, 심방 세동 및 뇌졸중 또는 TIA의 이전 병력, 높은 수준의 공복 혈당 및 MTLA 점수의 더 빈번한 병력이 있다.

[0056] PSCI 예측을 위해 LR(Logistic Regression), SVM(support vector machine), Extreme EGB(Extreme Gradient Boosting(XGBoost)), ANN(multiple layer perception artificial neural network) 모델 등 총 4개의 모델이 개발되었다. PSCI를 예측하기 위한 평균 AUC는 XGBoost에서 0.7919, ANN에서 0.7365, SVM에서 0.7157, LR에서

0.7121이었다.

	Accuracy	AUC	Precision	Recall	F1-score
LR	0.6702(0.5789-0.7684)	0.7121(0.5914-0.8265)	0.4658(0.3514-0.6000)	0.5862(0.4138-0.7586)	0.5191(0.3824-0.6471)
SVM	0.7120(0.6211-0.8000)	0.7157(0.5914-0.8271)	0.5224(0.4000-0.6667)	0.6034(0.4138-0.7586)	0.5600(0.4194-0.6885)
XGB	0.7958(0.7263-0.8632)	0.7919(0.6839-0.8866)	0.7568(0.5789-0.9375)	0.4828(0.3103-0.6552)	0.5895(0.4091-0.7451)
ANN	0.7068(0.6105-0.8000)	0.7365(0.6202-0.8438)	0.5161(0.3793-0.6667)	0.5517(0.3793-0.7241)	0.5333(0.3860-0.6769)

[0057]

[0058]

가장 잘 수행되는 폴드에 대한 ROC 곡선과 해당 confusion 행렬은 도 4에서 확인된다. 평균 정확도는 XGB(0.7958)에서 가장 높았고 SVM, ANN 및 LR이 그 뒤를 이었다.

[0059]

최적의 예측 모델인 XGB의 SHAP 값을 이용하여 PSCI 예측에 사용되는 중요한 변수를 결정하였다(도 5). 퇴원 NIHSS와 뇌졸중 용적으로 평가한 지표 뇌졸중의 중증도가 가장 중요한 변수였다. 기저 내측 측두엽 위축은 PSCI 발병의 두 번째 주요 원인이었고, 연령, 공복 혈당, 우울증, 및 피질 병변의 존재가 그 뒤를 이었다. 이전 뇌졸중 및 심방 세동의 병력도 예측 모델에 활용되었다. 그러나 좌측 병변 또는 다중 영역 병변의 존재는 SHAP 값이 0이었다.

[0060]

따라서, 본 개시의 일 실시 예에 따른 전자 장치(100)는, 뇌졸중의 중증도 및 기저 내측 측두엽 위축(baseline medial temporal lobe atrophy) 여부를 각각 포함하는 복수의 예측 인자를 바탕으로 인지 장애를 예측할 수 있다. 이때, 복수의 예측 인자는, 연령, 공복 혈당, 우울증 여부, 및 피질 병변의 존재 여부를 각각 포함할 수 있다. 또한, 복수의 예측 인자는, 과거 뇌졸중의 병력 및 과거 심방 세동의 병력을 각각 포함할 수 있다. 다만, 좌측 병변 또는 다중 영역 병변의 존재는 복수의 예측 인자에 포함되지 않을 수 있다.

[0061]

일 실시 예로, 인공지능 모델(111)이 EGB 모델인 경우를 가정한다. 여기서, 본 인공지능 모델(111)은 입력되는 예측 인자의 수나 종류가 매번 다르더라도 인지 장애에 대한 출력(ex. 인지 장애의 발생 가능성)을 도출하도록 훈련될 수 있다. 관련하여, 본 인공지능 모델(111)은 다양한 조합의 예측 인자로 구성된 훈련 데이터를 바탕으로 훈련될 수 있다.

[0062]

이 경우, 전자 장치(100)는 매번 다수의 예측 인자를 인공지능 모델(111)에 입력하기보다는, 뇌졸중의 중증도 및 기저 내측 측두엽 위축만을 인공지능 모델(111)에 1차적으로 입력할 수 있다.

[0063]

이때, 상술한 1차 입력을 바탕으로 획득된 출력에 따라 도출된 인지 장애의 발생 가능성이 제1 임계 확률 미만인 경우, 전자 장치(100)는 인지 장애의 발생 가능성이 없는 것으로 (최종적으로) 식별할 수 있다. 여기서, 해당 환자에 대한 인지 장애에 대한 예측은 종료될 수 있다.

[0064]

반면, 상술한 1차 입력을 바탕으로 도출된 인지 장애의 발생 가능성이 제1 임계 확률 이상인 경우, 전자 장치(100)는 뇌졸중의 중증도 및 기저 내측 측두엽 위축에 더하여 연령, 공복 혈당, 우울증 여부, 피질 병변의 존재 여부를 포함하는 예측 인자들을 입력할 수 있다(2차 입력).

[0065]

여기서, 2차 입력을 바탕으로 획득된 출력에 따라 도출된 인지 장애의 발생 가능성이 제2 임계 확률(>제1 임계 확률) 미만인 경우, 전자 장치(100)는 인지 장애의 발생 가능성이 없는 것으로 (최종적으로) 식별할 수 있다. 여기서, 해당 환자에 대한 인지 장애에 대한 예측은 종료될 수 있다.

[0066]

반면, 상술한 2차 입력을 바탕으로 도출된 인지 장애의 발생 가능성이 제2 임계 확률 이상인 경우, 전자 장치(100)는 2차 입력 당시 활용된 예측 인자들에 더하여, 과거 뇌졸중의 병력, 과거 심방 세동의 병력 등을 포함하는 추가적인 예측 인자들을 입력할 수 있다(3차 입력).

[0067]

여기서, 3차 입력을 바탕으로 도출된 인지 장애의 발생 가능성이 제3 임계 확률(>제2 임계 확률)인 경우, 전자 장치(100)는 인지 장애의 발생 가능성이 있는 것으로 최종적으로 식별할 수 있다. 반면, 3차 입력을 바탕으로 도출된 인지 장애의 발생 가능성이 제3 임계 확률 미만인 경우, 인지 장애의 발생 가능성이 없는 것으로 최종적으로 식별될 수 있다.

[0068]

이렇듯, 전자 장치(100)는 적은 수의 예측 인자들만 입력하는 과정을 선제적으로 거침으로써, 인지 장애의 발생 가능성이 현저히 낮은 환자의 데이터에 대하여 처음부터 다수의 예측 인자를 인공지능 모델(111)에 입력하는 상황을 방지할 수 있다. 그 결과, 인지 장애의 예측에 활용되는 전자 장치(100)의 로드가 절감될 수 있다.

[0069]

한편, 3개의 다른 ML 모델에서 캡처한 다른 일반적인 중요한 기능에는 피질 병변, 뇌졸중 중증도, 근심 측두엽 위축, 이전 뇌졸중, 전략적 병변, AF 병력 등이 포함된다. (도 6)

[0070] 본 연구에서, PSCI에 대해 서로 다른 진단 기준을 사용하여 2차 결과에 대해 4가지 기계 학습 모델을 모두 수행했다. PSCI-MMSE를 예측하기 위한 평균 AUC는 XGBoost에서 0.7876, ANN에서 0.7339, SVM에서 0.7463, LR에서 0.7608이었다. 최고 성능의 폴드 및 해당 confusion 행렬에 대한 ROC 곡선은 각각 도 7에서 확인된다. 평균 정확도는 XGB(0.8115)가 가장 높았고, SVM, ANN, LR 순이었다.

	Accuracy	AUC	Precision	Recall	F1-score
PSCI-MMSEz					
LR	0.6702 (0.5789 – 0.7579)	0.7608 (0.6434 – 0.8663)	0.3500 (0.2500 – 0.4474)	0.7179 (0.5263 – 0.8947)	0.4706 (0.3396 – 0.5862)
SVM	0.7068 (0.6105 – 0.8000)	0.7463 (0.6191 – 0.8566)	0.3836 (0.2759 – 0.5000)	0.7179 (0.5263 – 0.8947)	0.5000 (0.3636 – 0.6222)
XGB	0.8115 (0.7579 – 0.8737)	0.7876 (0.6711 – 0.8892)	0.5789 (0.2727 – 0.8889)	0.2821 (0.1053 – 0.4737)	0.3793 (0.1538 – 0.5926)
ANN	0.7644 (0.6947 – 0.8421)	0.7339 (0.6018 – 0.8525)	0.4062 (0.2000 – 0.6364)	0.3333 (0.1579 – 0.5789)	0.3662 (0.1600 – 0.5641)
PSCI-MMSE					
LR	0.8063 (0.7263 – 0.8842)	0.8713 (0.7831 – 0.9414)	0.5536 (0.4138 – 0.7037)	0.7209 (0.5238 – 0.9048)	0.6263 (0.4783 – 0.7556)
SVM	0.8168 (0.7368 – 0.8947)	0.8751 (0.7838 – 0.9472)	0.5690 (0.4333 – 0.7200)	0.7674 (0.5714 – 0.9524)	0.6535 (0.5098 – 0.7826)
XGB	0.8272 (0.7789 – 0.8842)	0.8616 (0.7683 – 0.9389)	0.7500 (0.5000 – 1.0000)	0.3488 (0.1429 – 0.5714)	0.4762 (0.2308 – 0.6667)
ANN	0.8639 (0.8168 – 0.9058)	0.8741 (0.8165 – 0.9241)	0.7576 (0.6279 – 0.8929)	0.5814 (0.4419 – 0.7209)	0.6579 (0.5278 – 0.7727)

[0071]

[0072] PSCI-MMSE의 예측에 대한 전체 AUC는 결과 변수 중에서 가장 높았다. PSCI-MMSE를 예측하기 위한 평균 AUC는 SVM에서 0.8751, ANN에서 0.8741, LR에서 0.8713, XGBoost에서 0.8616이었다. ROC 곡선과 해당 혼동 행렬은 도 7에서 확인된다. 평균 정확도는 ANN(0.8639)에서 가장 높았고 XGBoost, SVM, LR 순이었다.

[0074] 상술하였듯, 급성 허혈성 뇌졸중 환자를 등록한 전향적 PSCI 코호트를 사용한 후향적 연구가 수행되었다. 이전에 PSCI와 관련된 것으로 알려진 뇌 이미지 변수와 함께 인구 통계학적 특징, 임상적 특징이 분석에 포함되었다. 1차 결과는 3-6개월의 PSCI로 한국인의 4가지 인지 영역(기억, 전두엽, 시공간 및 언어) 중 적어도 하나에서 -2.0 표준편차 미만의 조정된 z-점수를 갖는 것으로 정의되었다(혈관 인지 장애 조화 표준 신경 심리학 프로토콜의 버전 참조). 4가지 기계 학습 모델(로지스틱 회귀, 지원 벡터 분류기, XGBoost 및 인공 신경망)을 개발하고 결과의 정확도를 비교했다. 총 1047명의 급성 허혈성 뇌졸중 환자(평균 연령 65.7±11.9세, 남성 61.5%)가 본 연구에 포함되었다. MLP와 XGBoost(EG)의 곡선 아래 면적은 VCIHS-NP 정의에 따른 PSCI 예측에서 4개 모델 중 가장 높았다(각각 0.9432 및 0.9343).

[0075] PSCI의 예측을 위한 가장 중요한 특징은 피질 경색, 측두엽 위축, 초기 뇌졸중 중증도, 이전 뇌졸중 병력 및 전략적 병변 경색의 존재를 포함했다.

[0077] 한편, 이상에서 설명된 다양한 실시 예들은 서로 저촉되거나 모순되지 않는 한 두 개 이상의 실시 예가 서로 결합되어 구현될 수 있다.

[0078] 한편, 이상에서 설명된 다양한 실시 예들은 소프트웨어(software), 하드웨어(hardware) 또는 이들의 조합된 것을 이용하여 컴퓨터(computer) 또는 이와 유사한 장치로 읽을 수 있는 기록 매체 내에서 구현될 수 있다.

[0079] 하드웨어적인 구현에 의하면, 본 개시에서 설명되는 실시 예들은 ASICs(Application Specific Integrated Circuits), DSPs(digital signal processors), DSPDs(digital signal processing devices), PLDs(programmable logic devices), FPGAs(field programmable gate arrays), 프로세서(processors), 제어기(controllers), 마이크로 컨트롤러(micro-controllers), 마이크로 프로세서(microprocessors), 기타 기능 수행을 위한 전기적인 유닛(unit) 중 적어도 하나를 이용하여 구현될 수 있다.

[0080] 일부의 경우에 본 명세서에서 설명되는 실시 예들이 프로세서 자체로 구현될 수 있다. 소프트웨어적인 구현에 의하면, 본 명세서에서 설명되는 절차 및 기능과 같은 실시 예들은 별도의 소프트웨어 모듈들로 구현될 수 있다. 상술한 소프트웨어 모듈들 각각은 본 명세서에서 설명되는 하나 이상의 기능 및 작동을 수행할 수 있다.

[0081] 한편, 상술한 본 개시의 다양한 실시 예들에 따른 전자 장치에서의 처리동작을 수행하기 위한 컴퓨터 명령어(computer instructions) 또는 컴퓨터 프로그램은 비일시적 컴퓨터 판독 가능 매체(non-transitory computer-readable medium)에 저장될 수 있다. 이러한 비일시적 컴퓨터 판독 가능 매체에 저장된 컴퓨터 명령어 또는 컴퓨터 프로그램은 특정 기기의 프로세서에 의해 실행되었을 때 상술한 다양한 실시 예에 따른 전자 장치에서의 처리 동작을 상술한 특정 기기가 수행하도록 한다.

[0082] 비일시적 컴퓨터 판독 가능 매체란 레지스터, 캐쉬, 메모리 등과 같이 짧은 순간 동안 데이터를 저장하는 매체

가 아니라 반영구적으로 데이터를 저장하며, 기기에 의해 판독(reading)이 가능한 매체를 의미한다. 비일시적 컴퓨터 판독 가능 매체의 구체적인 예로는, CD, DVD, 하드 디스크, 블루레이 디스크, USB, 메모리카드, ROM 등이 있을 수 있다.


[0083] 이상에서는 본 개시의 바람직한 실시 예에 대하여 도시하고 설명하였지만, 본 개시는 상술한 특정의 실시 예에 한정되지 아니하며, 청구범위에서 청구하는 본 개시의 요지를 벗어남이 없이 당해 개시에 속하는 기술분야에서 통상의 지식을 가진 자에 의해 다양한 변형실시가 가능한 것은 물론이고, 이러한 변형실시들은 본 개시의 기술적 사상이나 전망으로부터 개별적으로 이해되어서는 안될 것이다.

부호의 설명


[0084] 100: 전자 장치 110: 메모리
120: 프로세서

도면


도면1




도면2




도면3




도면4



도면5



도면6



도면7

