



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0038867
(43) 공개일자 2025년03월20일

(51) 국제특허분류(Int. Cl.)

G16H 50/50 (2018.01) G06N 20/20 (2019.01)
G16H 10/60 (2018.01) G16H 40/20 (2018.01)
G16H 50/70 (2018.01)

(52) CPC특허분류

G16H 50/50 (2018.01)
G06N 20/20 (2021.08)

(21) 출원번호 10-2023-0121123

(22) 출원일자 2023년09월12일

심사청구일자 2023년09월12일

(71) 출원인

이화여자대학교 산학협력단

서울특별시 서대문구 이화여대길 52 (대현동, 이화여자대학교)

가톨릭대학교 산학협력단

서울특별시 서초구 반포대로 222, 가톨릭대학교 성의교정내 (반포동)

(72) 발명자

백승민

서울특별시 양천구 목동서로 70, 219동 506호 (목동, 목동신시가지아파트2단지)

홍경숙

서울시 강서구 마곡동로2길 25 이화여자대학교 의과대학 1034호

박동진

서울특별시 서초구 서초대로74길 29, 803호 (서초동, 서초파라곤)

(74) 대리인

특허법인비엘티

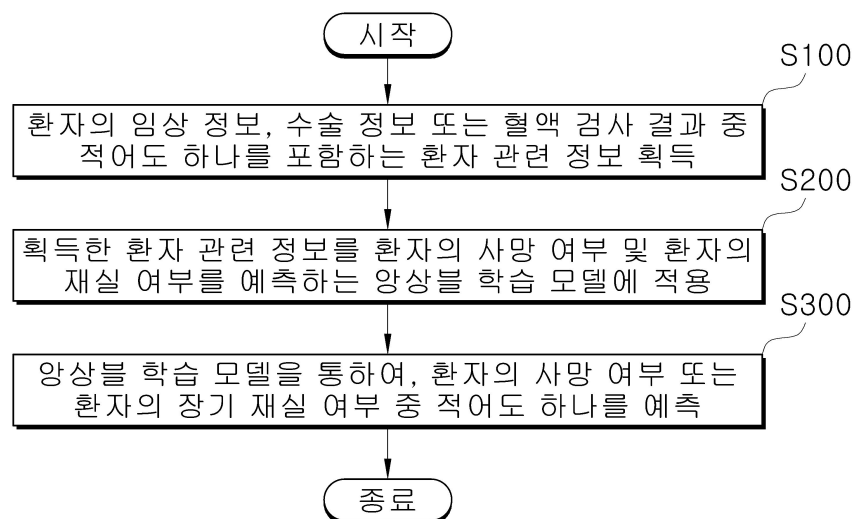
전체 청구항 수 : 총 21 항

(54) 발명의 명칭 **수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버 및 그 동작 방법**

(57) 요약

본 개시의 일 실시예는, 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버 및 서버의 동작 방법을 개시한다. 서버는 메모리에 저장된 적어도 하나의 명령어를 실행하는 적어도 하나의 프로세서를 포함하고, 적어도 하나의 프로세서는 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 환자 관련 정보를 획득하고, 획득한 환자 관련 정보를 환자의 사망 여부 및 환자의 장기 재실 여부를 예측하는 인공지능 학습 모델에 적용하고, 앙상블 학습 모델을 통하여 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측한 결과를 생성할 수 있다.

대표도 - 도3



(52) CPC특허분류

G16H 10/60 (2021.08)

G16H 40/20 (2021.08)

G16H 50/70 (2018.01)

명세서

청구범위

청구항 1

수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버에 있어서,
 적어도 하나의 명령어(instruction)를 저장하는 메모리; 및
 상기 메모리에 저장된 상기 적어도 하나의 명령어를 실행하는 적어도 하나의 프로세서를 포함하고,
 상기 적어도 하나의 프로세서는,
 상기 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 환자 관련 정보를 획득하고,
 상기 획득한 환자 관련 정보를 상기 환자의 상기 사망 여부 및 상기 환자의 상기 장기 재실 여부를 예측하는 인공지능 학습 모델에 적용하고,
 상기 인공지능 학습 모델을 통하여, 상기 환자의 상기 사망 여부 또는 상기 환자의 상기 장기 재실 여부 중 적어도 하나를 예측한 결과를 생성하는 서버.

청구항 2

제1 항에 있어서,
 상기 수술 정보는, 상기 환자에 대하여 수행된 수술이 정규 수술 또는 응급 수술인지 여부, 상기 수술에 걸린 수술 시간 또는 상기 수술이 수행된 진료과 중 적어도 하나에 대한 정보를 포함하고,
 상기 사망 여부 및 상기 장기 재실 여부는, 상기 수술이 수행된 상기 환자에 대한 예측 결과인 서버.

청구항 3

제2 항에 있어서,
 상기 인공지능 학습 모델은, 상기 환자 관련 정보에 기초하여, 상기 환자가 상기 수술 이후에 병원에 입원한 날부터 30일 이상 상기 병원에 입원할 것으로 예측되는지 여부에 의하여 상기 환자의 상기 장기 재실 여부를 예측하는 것으로 학습된 모델인 서버.

청구항 4

제1 항에 있어서,
 상기 서버는, 통신부를 더 포함하고,
 상기 적어도 하나의 프로세서는 상기 통신부를 통하여 외부의 전자 장치에 상기 환자의 상기 사망 여부 또는 상기 환자의 상기 장기 재실 여부 중 적어도 하나를 예측한 결과를 전달하는 서버.

청구항 5

제4 항에 있어서,
 상기 적어도 하나의 프로세서는,
 상기 환자가 장기 재실을 하지 않고, 사망할 것으로 예측됨에 따라, 상기 통신부를 통하여 상기 외부의 장치에 상기 환자가 중증 환자라는 정보를 포함하는 알람을 제공하는 서버.

청구항 6

제1 항에 있어서,

상기 인공지능 학습 모델은,

상기 획득된 환자 관련 정보를 이용하여 상기 수술 후 상기 환자의 상기 사망 여부를 예측하도록 학습된 제1 앙상블 학습 모델; 및

상기 획득된 환자 관련 정보를 이용하여 상기 환자의 상기 장기 재실 여부를 예측하도록 학습된 제2 앙상블 학습 모델을 포함하는 서버.

청구항 7

제6 항에 있어서,

상기 인공지능 학습 모델은,

학습용 환자 관련 정보를 훈련(training) 세트와 검증(validation) 세트로 구분하고,

상기 훈련 세트를 이용하여 상기 환자의 상기 사망 여부 및 상기 환자의 상기 장기 재실 여부를 예측하도록 학습되고,

상기 검증 세트를 이용하여 상기 학습된 모델의 성능을 외부 검증한 모델이며,

상기 학습용 환자 관련 정보는,

훈련용 환자의 임상 정보, 훈련용 환자의 수술 정보, 훈련용 환자의 사망 여부, 훈련용 환자의 재실 기간 또는 훈련용 환자의 혈액 검사 중 적어도 하나를 포함하는 서버.

청구항 8

제7 항에 있어서,

상기 인공지능 학습 모델은,

상기 학습용 환자 관련 정보를 이용하여 학습된 XGBoost(eXtreme Gradient Boosting), CatBoost, LGBM(Light Gradient Boosting Model), Random Forest 및 MLP(Multi-Layer Perceptron)을 앙상블하여 생성된 모델일 수 있고,

상기 XGBoost(eXtreme Gradient Boosting), 상기 CatBoost 및 상기 LGBM(Light Gradient Boosting Model)은 학습 시에 상기 학습용 환자 관련 정보에 포함된 결측치를 공백(Blank)으로 대체하여 학습된 모델이고,

상기 Random Forest 및 상기 MLP는 학습 시에 상기 결측치를 중앙값(median)으로 대체하여 학습된 모델인 서버.

청구항 9

제8 항에 있어서,

상기 제1 앙상블 학습 모델은 상기 임상 정보, 상기 훈련용 환자의 상기 수술 정보, 상기 훈련용 환자의 상기 사망 여부 및 상기 훈련용 환자의 상기 혈액 검사를 포함하는 제1 환자 관련 정보를 이용하여 학습되고,

상기 제2 앙상블 학습 모델은, 상기 임상 정보, 상기 훈련용 환자의 상기 수술 정보, 상기 훈련용 환자의 상기 재실 기간 및 상기 훈련용 환자의 상기 혈액 검사를 포함하는 제2 환자 관련 정보를 이용하여 학습된 서버.

청구항 10

제9 항에 있어서,

상기 제1 및 제2 앙상블 학습 모델은, 상기 XGBoost(eXtreme Gradient Boosting), 상기 CatBoost, 상기 LGBM(Light Gradient Boosting Model), 상기 Random Forest 및 상기 MLP(Multi-Layer Perceptron)에 각각 가중치를 두어 앙상블된 모델인 서버.

청구항 11

수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버의 동작 방법에 있어서,

상기 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 환자 관련 정보를 획득하는

단계;

상기 획득한 환자 관련 정보를 상기 환자의 상기 사망 여부 및 상기 환자의 상기 장기 재실 여부를 예측하는 인공지능 학습 모델에 적용하는 단계;

상기 인공지능 학습 모델을 통하여, 상기 환자의 상기 사망 여부 또는 상기 환자의 상기 장기 재실 여부 중 적어도 하나를 예측한 결과를 생성하는 단계를 포함하는 서버의 동작 방법.

청구항 12

제11 항에 있어서,

상기 수술 정보는, 상기 환자에 대하여 수행된 수술이 정규 수술 또는 응급 수술인지 여부, 상기 수술에 걸린 수술 시간 또는 상기 수술이 수행된 진료과 중 적어도 하나에 대한 정보를 포함하고,

상기 사망 여부 및 상기 장기 재실 여부는, 상기 수술이 수행된 상기 환자에 대한 예측 결과인 서버의 동작 방법.

청구항 13

제12 항에 있어서,

상기 인공지능 학습 모델은, 상기 환자 관련 정보에 기초하여, 상기 환자가 상기 수술 이후에 병원에 입원한 날부터 30일 이상 상기 병원에 입원할 것으로 예측되는지 여부에 의하여 상기 환자의 상기 장기 재실 여부를 예측하는 것으로 학습된 모델인 서버의 동작 방법.

청구항 14

제11 항에 있어서,

상기 서버의 통신부를 통하여 외부의 전자 장치에 상기 환자의 상기 사망 여부 또는 상기 환자의 상기 장기 재실 여부 중 적어도 하나를 예측한 결과를 전달하는 단계를 더 포함하는 서버의 동작 방법.

청구항 15

제14 항에 있어서,

상기 외부의 전자 장치에 상기 예측한 결과를 전달하는 단계에서는,

상기 환자가 장기 재실을 하지 않고, 사망할 것으로 예측됨에 따라, 상기 통신부를 통하여 상기 외부의 장치에 상기 환자가 중증 환자라는 정보를 포함하는 알람을 제공하는 서버의 동작 방법.

청구항 16

제11 항에 있어서,

상기 인공지능 학습 모델은,

상기 획득된 환자 관련 정보를 이용하여 상기 수술 후 상기 환자의 상기 사망 여부를 예측하도록 학습된 제1 앙상블 학습 모델; 및

상기 획득된 환자 관련 정보를 이용하여 상기 환자의 상기 장기 재실 여부를 예측하도록 학습된 제2 앙상블 학습 모델을 포함하는 서버의 동작 방법.

청구항 17

제16 항에 있어서,

상기 인공지능 학습 모델은,

학습용 환자 관련 정보를 훈련(training) 세트와 검증(validation) 세트로 구분하는 단계;

상기 훈련 세트를 이용하여 상기 환자의 상기 사망 여부 및 상기 환자의 상기 장기 재실 여부를 예측하도록 학습되는 단계; 및

상기 검증 세트를 이용하여 상기 학습된 모델의 성능을 외부 검증하는 단계를 통하여 학습된 모델이고,

상기 학습용 환자 관련 정보는,

훈련용 환자의 임상 정보, 훈련용 환자의 수술 정보, 훈련용 환자의 사망 여부, 훈련용 환자의 재실 기간 또는 훈련용 환자의 혈액 검사 중 적어도 하나를 포함하는 서버의 동작 방법.

청구항 18

제17 항에 있어서,

상기 인공지능 학습 모델은,

상기 학습용 환자 관련 정보를 이용하여 학습된 XGBoost(eXtreme Gradient Boosting), CatBoost, LGBM(Light Gradient Boosting Model), Random Forest 및 MLP(Multi-Layer Perceptron)을 앙상블하여 생성된 모델일 수 있고,

상기 XGBoost(eXtreme Gradient Boosting), 상기 CatBoost 및 상기 LGBM(Light Gradient Boosting Model)은 학습 시에 상기 학습용 환자 관련 정보에 포함된 결측치를 공백(Blank)으로 대체하여 학습된 모델이고,

상기 Random Forest 및 상기 MLP는 학습 시에 상기 결측치를 중앙값(median)으로 대체하여 학습된 모델인 서버의 동작 방법.

청구항 19

제18 항에 있어서,

상기 제1 앙상블 학습 모델은 상기 임상 정보, 상기 훈련용 환자의 상기 수술 정보, 상기 훈련용 환자의 상기 사망 여부 및 상기 훈련용 환자의 상기 혈액 검사를 포함하는 제1 환자 관련 정보를 이용하여 학습되고,

상기 제2 앙상블 학습 모델은, 상기 임상 정보, 상기 훈련용 환자의 상기 수술 정보, 상기 훈련용 환자의 상기 재실 기간 및 상기 훈련용 환자의 상기 혈액 검사를 포함하는 제2 환자 관련 정보를 이용하여 학습된 서버의 동작 방법.

청구항 20

제19 항에 있어서, 제19 항에 있어서,

상기 제1 및 제2 앙상블 학습 모델은, 상기 XGBoost(eXtreme Gradient Boosting), 상기 CatBoost, 상기 LGBM, 상기 Random Forest 및 상기 MLP(Multi-Layer Perceptron)에 각각의 가중치를 두어 앙상블된 모델인 서버의 동작 방법.

청구항 21

컴퓨터와 결합되어, 제11 항 내지 제20 항 중 어느 하나의 항의 방법을 실행시키기 위한 프로그램이 저장된 컴퓨터 판독 가능한 기록매체.

발명의 설명

기술 분야

[0001] 본 발명은 서버 및 서버의 동작 방법에 관한 것으로, 보다 구체적으로는 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버 및 그의 동작 방법에 관한 것이다.

배경 기술

[0002] 기술의 발전에 의하여, 환자의 상태를 평가하기 위한 평가 모델들이 개발되고 있다. 통상적으로 중환자의 중증도 평가를 위하여는 APACHE II score가 이용된다. APACHE II score의 사망에 대한 AUROC는 약 0.7-0.8 정도 수준이다.

[0003] 하지만 이 스코어는 수술 정보 등이 많이 포함되어 있지 않고, 사망에 대한 일반적인 cut off value도 통일되지 못하고 있다. 따라서, APACHE II score를 이용하여 사망을 예측하는데 있어 명확한 결과를 얻기 어려움이 있다.

또한, 사망뿐만 아니라 예상 입원 기간 등을 예측하는데 사용하기 어려움도 있다.

선행기술문헌

특허문헌

[0004] (특허문헌 0001) 등록번호 제10-2510992 호 (등록일자: 2023년 03월 13일)

발명의 내용

해결하려는 과제

[0005] 본 개시에 개시된 실시예는 수술 후 중환자를 대상으로 임상 정보, 수술 정보, 혈액 검사 등을 이용하여 치료결과 (사망 또는 생존)를 예측하는 인공지능 모델을 개발하여 제공하는 서버 및 서버의 동작 방법을 제공하는데 그 목적이 있다. 또한 중환자실에서는 장기 입원 등으로 인한 중환자실 병상 부족 문제가 항상 큰 이슈였으므로 본 개시에서는 특정일(예를 들어 30일)을 기준으로 그 이상 또는 그 미만의 환자의 재실 기간을 예측하는 인공지능 모델을 개발하여 제공하는 서버 및 서버의 동작 방법을 제공하는데 그 목적이 있다.

[0006] 본 개시가 해결하고자 하는 과제들은 이상에서 언급된 과제로 제한되지 않으며, 언급되지 않은 또 다른 과제들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0007] 상술한 기술적 과제를 달성하기 위한 본 개시에 따르면, 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버가 제공될 수 있다. 서버는 적어도 하나의 명령어(instruction)를 저장하는 메모리를 포함할 수 있다. 서버는 메모리에 저장된 적어도 하나의 명령어를 실행하는 적어도 하나의 프로세서를 포함할 수 있다. 적어도 하나의 프로세서는 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 환자 관련 정보를 획득할 수 있다. 적어도 하나의 프로세서는 획득한 환자 관련 정보를 환자의 사망 여부 및 환자의 재실 여부를 예측하는 인공지능 학습 모델에 적용할 수 있다. 적어도 하나의 프로세서는 인공지능 학습 모델을 통하여, 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측한 결과를 생성할 수 있다.

[0008] 또한, 본 개시에 따르면, 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버의 동작 방법이 제공될 수 있다. 서버의 동작 방법은 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 환자 관련 정보를 획득하는 단계를 포함할 수 있다. 서버의 동작 방법은 획득한 환자 관련 정보를 환자의 사망 여부 및 환자의 재실 여부를 예측하는 인공지능 학습 모델에 적용하는 단계를 포함할 수 있다. 서버의 동작 방법은 인공지능 학습 모델을 통하여 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측한 결과를 생성하는 단계를 포함할 수 있다.

[0009] 이 외에도, 본 개시를 구현하기 위한 컴퓨터 판독 가능한 기록 매체에 저장된 컴퓨터 프로그램이 더 제공될 수 있다.

[0010] 이 외에도, 본 개시를 구현하기 위한 컴퓨터 프로그램을 기록하는 컴퓨터 판독 가능한 기록 매체가 더 제공될 수 있다.

발명의 효과

[0011] 본 개시의 기술한 과제 해결 수단에 의하면, 수술 후 환자의 사망 여부 예측에 대한 정확도를 높일 수 있는 효과를 제공한다. 또한, 본 개시의 기술한 과제 해결 수단에 의하면, 수술 후 환자가 장기 입원으로 이어질지에 대한 예측을 할 수 있는 효과를 제공한다. 이를 통하여, 수술 후 환자의 중증도를 조기에 평가할 수 있으며 장기 입원으로 이어질지에 대한 정보를 획득함으로써 중환자실 임상 현장 관리의 효율성을 높일 수 있다.

[0012] 본 개시의 효과들은 이상에서 언급된 효과로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0013]

도 1은 본 개시의 일 실시예에 따른 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버를 설명하기 위한 도면이다.

도 2는 본 개시의 일 실시예에 따른 서버의 동작을 설명하기 위한 도면이다.

도 3은 본 개시의 일 실시예에 따른 서버의 동작을 설명하기 위한 순서도이다.

도 4는 본 개시의 일 실시예에 따른 서버에 포함된 인공지능 학습 모델의 학습 동작을 설명하기 위한 순서도이다.

도 5는 본 개시의 일 실시예에 따른 인공지능 학습 모델의 학습에 이용되는 훈련 데이터를 설명하기 위한 도면이다.

도 6a는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 학습 성능을 설명하기 위한 도면이다.

도 6b는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 추론 성능을 설명하기 위한 도면이다.

도 6c는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 학습 성능을 설명하기 위한 도면이다.

도 6d는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 추론 성능을 설명하기 위한 도면이다.

도 7a는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 7b는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 7c는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 7d는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 7e는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 8a는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 8b는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 8c는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 8d는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

도 8e는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0014]

본 개시 전체에 걸쳐 동일 참조 부호는 동일 구성요소를 지칭한다. 본 개시가 실시예들의 모든 요소들을 설명하는 것은 아니며, 본 개시가 속하는 기술분야에서 일반적인 내용 또는 실시예들 간에 중복되는 내용은 생략한다. 명세서에서 사용되는 '부, 모듈, 부재, 블록'이라는 용어는 소프트웨어 또는 하드웨어로 구현될 수 있으며, 실시예들에 따라 복수의 '부, 모듈, 부재, 블록'이 하나의 구성요소로 구현되거나, 하나의 '부, 모듈, 부재, 블록'이 복수의 구성요소들을 포함하는 것도 가능하다.

[0015]

명세서 전체에서, 어떤 부분이 다른 부분과 "연결"되어 있다고 할 때, 이는 직접적으로 연결되어 있는 경우뿐 아니라, 간접적으로 연결되어 있는 경우를 포함하고, 간접적인 연결은 무선 통신망을 통해 연결되는 것을 포함한다.

- [0016] 또한 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다.
- [0017] 명세서 전체에서, 어떤 부재가 다른 부재 "상에" 위치하고 있다고 할 때, 이는 어떤 부재가 다른 부재에 접해 있는 경우뿐 아니라 두 부재 사이에 또 다른 부재가 존재하는 경우도 포함한다.
- [0018] 제 1, 제 2 등의 용어는 하나의 구성요소를 다른 구성요소로부터 구별하기 위해 사용되는 것으로, 구성요소가 전술된 용어들에 의해 제한되는 것은 아니다.
- [0019] 단수의 표현은 문맥상 명백하게 예외가 있지 않는 한, 복수의 표현을 포함한다.
- [0020] 각 단계들에 있어 식별부호는 설명의 편의를 위하여 사용되는 것으로 식별부호는 각 단계들의 순서를 설명하는 것이 아니며, 각 단계들은 문맥상 명백하게 특정 순서를 기재하지 않는 이상 명기된 순서와 다르게 실시될 수 있다.
- [0021] 이하 첨부된 도면들을 참고하여 본 개시의 작용 원리 및 실시예들에 대해 설명한다.
- [0022] 도 1은 본 개시의 일 실시예에 따른 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측 모델을 제공하는 서버를 설명하기 위한 도면이다.
- [0023] 일 실시예에서, 도 1에 도시된 서버(100)는 환자에 대한 환자 관련 정보를 획득하고, 획득한 환자 관련 정보를 이용하여 환자의 사망 여부 또는 환자가 병원에 입원하는 시기와 관련된 환자의 장기 재실 여부 중 적어도 하나를 예측한 결과를 생성할 수 있다.
- [0024] 일 실시예에서, 서버(100)가 획득하는 환자 관련 정보는, 병원에서 수술을 진행한 환자에 대한 정보일 수 있다. 서버(100)가 획득한 환자 관련 정보에 기초하여 예측하는 결과는, 수술을 진행한 수술 후 환자의 사망 여부 또는 수술 후 환자의 장기 재실 여부 중 적어도 하나에 대한 결과일 수 있다.
- [0025] 일 실시예에서, 서버(100)가 획득한 환자 관련 정보에 기초하여 수술 후 환자의 사망 여부 및 환자의 장기 재실 여부를 모두 예측한 결과를 생성할 수 있음은 물론이다. 또한, 서버(100)는 수술 후 환자의 사망 여부 및 환자의 장기 재실 여부의 결과에 기초하여, 수술을 진행한 환자의 상태에 대한 정보(예를 들어, 수술 후 환자가 사망할 것으로 예측되고, 환자가 장기 재실을 하지 않을 것으로 예측되는 경우)를 생성하여 제공할 수도 있다.
- [0026] 이때, 서버(100)는 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측을 위하여 환자 관련 정보에 기초하여 학습된 인공지능의 앙상블(Ensemble) 학습 모델을 이용할 수 있다. 이때, 앙상블 학습 모델은 환자 관련 정보에 기초하여 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측을 하도록 학습된 복수의 딥러닝 모델들(예를 들어, XGBoost(eXtreme Gradient Boosting), CatBoost, LGBM(Light Gradient Boosting Model), Random Forest 및 MLP(Multi-Layer Perceptron) 등)을 조합하여 생성된 모델일 수 있다. 이하, 본 개시의 서버(100)에서 이용하는 앙상블 학습 모델에 대하여는 도 4 내지 도 8e에서 후술하도록 한다.
- [0027] 일 실시예에서, 서버(100)에는 메모리(110), 적어도 하나의 프로세서(130) 및 통신부(120)가 포함될 수 있다. 메모리(110), 적어도 하나의 프로세서(130) 및 통신부(120)는 각각 전기적 및/또는 물리적으로 서로 연결될 수 있다.
- [0028] 다만, 몇몇의 실시예에서, 서버(100)는 도 1에 도시된 구성 요소보다 더 적은 수의 구성 요소나, 혹은 더 많은 구성 요소를 포함할 수도 있다.
- [0029] 일 실시예에서, 메모리(110)는 서버(100)의 다양한 기능을 지원하는 데이터와, 적어도 하나의 프로세서(130)의 동작을 위한 프로그램을 저장할 수 있고, 입/출력되는 데이터들(예를 들어, 문장, 음악 파일, 정지 영상, 동영상 등)을 저장할 있고, 본 장치에서 구동되는 다수의 응용 프로그램(application program 또는 애플리케이션(application)), 본 장치의 동작을 위한 적어도 하나의 데이터들, 적어도 하나의 명령어(instruction)를 저장할 수 있다. 이러한 응용 프로그램 중 적어도 일부는, 무선 통신을 통해 외부 서버로부터 다운로드 될 수 있다.
- [0030] 이러한, 메모리(110)는 플래시 메모리 타입(flash memory type), 하드디스크 타입(hard disk type), SSD 타입(Solid State Disk type), HDD 타입(Hard Disk Drive type), 멀티미디어 카드 마이크로 타입(multimedia card micro type), 카드 타입의 메모리(예를 들어 SD 또는 XD 메모리 등), 램(random access memory; RAM), SRAM(static random access memory), 롬(read-only memory; ROM), EEPROM(electrically erasable programmable read-only memory), PROM(programmable read-only memory), 자기 메모리, 자기 디스크 및 광디스크 중 적어도 하나의 타입의 저장매체를 포함할 수 있다. 또한, 메모리는 서버(100)와는 분리되어 있으나, 유선

또는 무선으로 연결된 데이터베이스가 될 수도 있다.

- [0031] 일 실시예에서, 메모리(110)에는 수술 후 환자의 사망 여부 예측 및 환자의 장기 재실 여부 예측을 위하여 학습된 앙상블 학습 모델이 저장되어 있을 수 있다. 일 실시예에서, 메모리(110)에는 수술 후 환자의 사망 여부 및 환자의 장기 재실 여부를 예측하고자 하는 환자에 대한 환자 관련 정보가 저장되어 있을 수 있다.
- [0032] 일 실시예에서, 적어도 하나의 프로세서(130)는 서버(100)의 전반적인 동작들을 제어할 수 있다. 일 실시예에서, 적어도 하나의 프로세서(130)는 메모리(110)에 저장된 적어도 하나 이상의 명령어를 실행하여, 서버(100)의 동작을 제어할 수 있다.
- [0033] 일 실시예에서, 적어도 하나의 프로세서(130)는 메모리(110)에 저장된 적어도 하나의 명령어를 실행하여, 획득한 환자 관련 정보에 기초하여 수술 후의 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측하는 동작을 수행할 수 있다.
- [0034] 일 실시예에서, 적어도 하나의 프로세서(130)는 CPU, AP, DSP(Digital Signal Processor) 등과 같은 범용 프로세서, GPU, VPU(Vision Processing Unit)와 같은 그래픽 전용 프로세서 또는 NPU와 같은 인공지능 전용 프로세서일 수 있다. 적어도 하나의 프로세서는 메모리에 저장된 명령어들 또는 인공지능 모델에 따라, 환자 관련 정보를 처리하도록 제어한다. 또는, 적어도 하나의 프로세서가 인공지능 전용 프로세서인 경우, 인공지능 전용 프로세서는, 특정 인공지능 모델의 처리에 특화된 하드웨어 구조로 설계될 수 있다.
- [0035] 일 실시예에서, 적어도 하나의 프로세서(130)는 메모리(110)에 저장된 적어도 하나의 명령어를 실행하여, 획득한 환자 관련 정보에 기초하여 수술 후의 환자의 사망 여부 및 환자의 장기 재실 여부를 함께 예측하여, 예측된 결과에 기초하여 서버(100)에 환자 관련 정보를 제공한 외부 전자 장치 또는 서버(100)의 다른 사용자에게 제공할 정보나 알림을 생성할 수 있다.
- [0036] 일 실시예에서, 통신부(120)는 외부의 다른 서버 또는 외부의 전자 장치와 통신을 가능하게 하는 하나 이상의 구성 요소를 포함할 수 있다. 예를 들어, 통신부(120)는 유선 통신 모듈, 무선 통신 모듈 또는 근거리 통신 모듈 중 적어도 하나를 포함할 수 있다.
- [0037] 일 실시예에서, 유선 통신 모듈은, 지역 통신(Local Area Network; LAN) 모듈, 광역 통신(Wide Area Network; WAN) 모듈 또는 부가가치 통신(Value Added Network; VAN) 모듈 등 다양한 유선 통신 모듈뿐만 아니라, USB(Universal Serial Bus), HDMI(High Definition Multimedia Interface), DVI(Digital Visual Interface), RS-232(recommended standard 232), 전력선 통신, 또는 POTS(plain old telephone service) 등 다양한 케이블 통신 모듈을 포함할 수 있다.
- [0038] 일 실시예에서, 무선 통신 모듈은 와이파이(Wifi) 모듈, 와이브로(Wireless broadband) 모듈 외에도, GSM(global System for Mobile Communication), CDMA(Code Division Multiple Access), WCDMA(Wideband Code Division Multiple Access), UMTS(universal mobile telecommunications system), TDMA(Time Division Multiple Access), LTE(Long Term Evolution), 4G, 5G, 6G 등 다양한 무선 통신 방식을 지원하는 무선 통신 모듈을 포함할 수 있다.
- [0039] 일 실시예에서, 근거리 통신 모듈은 근거리 통신(Short range communication)을 위한 것으로서, 블루투스(Bluetooth™), RFID(Radio Frequency Identification), 적외선 통신(Infrared Data Association; IrDA), UWB(Ultra Wideband), ZigBee, NFC(Near Field Communication), Wi-Fi(Wireless-Fidelity), Wi-Fi Direct, Wireless USB(Wireless Universal Serial Bus) 기술 중 적어도 하나를 이용하여, 근거리 통신을 지원할 수 있다.
- [0040] 일 실시예에서, 적어도 하나의 프로세서(130)는 통신부(120)를 통하여 외부의 서버 또는 외부의 전자 장치로부터 수술 후 사망 여부나 장기 재실 여부를 예측하고자 하는 환자의 환자 관련 정보를 획득할 수 있다. 또한, 적어도 하나의 프로세서(130)는 통신부(120)를 통하여 앙상블 학습 모델을 통하여 예측한 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나의 결과를 외부의 서버 또는 외부의 전자 장치로 제공할 수도 있다.
- [0041] 일 실시예에서, 적어도 하나의 프로세서(130)는 통신부(120)를 통하여 외부의 서버 또는 외부의 전자 장치로부터 환자 관련 정보를 이용하여 수술 후 사망 여부나 장기 재실 여부를 예측하도록 미리 학습된 앙상블 학습 모델을 획득할 수도 있다.
- [0042] 도 2는 본 개시의 일 실시예에 따른 서버의 동작을 설명하기 위한 도면이다. 이하, 도 1에서 설명한 구성과 동

일한 구성에 대하여는 동일한 도면 부호를 부여하고, 중복되는 설명은 생략하도록 한다.

- [0043] 도 1 및 도 2를 참조하면, 일 실시예에서, 서버(100)는 통신부(120)를 통하여 외부 전자 장치(200)로부터 환자 관련 정보를 획득할 수 있다. 이때, 서버(100)는 통신부(120)를 통하여 외부 전자 장치(200)로 환자의 사망 여부 또는 환자의 장기 재식 여부 중 적어도 하나를 예측한 결과를 제공할 수 있다.
- [0044] 일 실시예에서, 사용자(300)는 외부 전자 장치(200)를 통하여, 사망 여부 또는 장기 재식 여부 중 적어도 하나를 알고 싶은 환자에 대한 환자 관련 정보를 서버(100)에 제공할 수 있다. 사용자(300)는 외부 전자 장치(200)를 통하여 서버(100)로부터 예측된 환자의 사망 여부 또는 장기 재식 여부 중 적어도 하나에 대한 결과를 획득할 수 있다.
- [0045] 일 실시예에서, 서버(100)는 외부 전자 장치와 통신을 수행하여 정보를 처리하는 서버로써, 애플리케이션 서버, 컴퓨팅 서버, 데이터베이스 서버, 파일 서버, 프록시 서버 및 웹 서버 등을 포함할 수 있다. 일 실시예에서, 외부 전자 장치(200)는 웹 브라우저(WEB Browser)가 탑재된 노트북, 데스크톱(desktop), 랩톱(laptop), 태블릿 PC, 슬레이트 PC, 휴대용 단말기 등을 포함할 수 있다. 다만, 본 개시는 어느 하나로 제한되지 않고, 서버(100) 및 외부 전자 장치(200)는 도 1 및 도 2에서 기재된 동작을 수행할 수 있는 다양한 서버 및 전자 장치들을 포함할 수 있다.
- [0046] 또한, 일 실시예에서, 사용자(300)는 외부 전자 장치(200)가 아닌, 서버(100)를 포함하는 전자 장치에 환자 관련 정보를 제공할 수도 있다. 서버(100)는 사용자 인터페이스 또는 입/출력 인터페이스를 통하여 사용자(300)로부터 환자 관련 정보를 획득할 수도 있다. 서버(100)는 예측된 결과를 서버(100)를 포함하는 전자 장치를 통하여 사용자(300)에게 제공할 수도 있다.
- [0047] 도 3은 본 개시의 일 실시예에 따른 서버의 동작을 설명하기 위한 순서도이다.
- [0048] 도 1 및 도 3을 참조하면, 일 실시예에서, 서버(100)의 동작 방법은 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 환자 관련 정보를 획득하는 단계(S100)를 포함할 수 있다.
- [0049] 일 실시예에서, 환자 관련 정보를 획득하는 단계(S100)에서, 적어도 하나의 프로세서(130)는 환자 관련 정보를 획득할 수 있다. 이때, 환자의 임상 정보는, 환자가 수술하기 전에 병원에서 진료 또는 진단을 받을 때 획득된 정보, 수술 전 설문 조사를 통하여 얻은 정보, 수술 전 병원에 입원 여부 및 입원 기간 등을 포함할 수 있다.
- [0050] 일 실시예에서, 환자의 수술 정보는, 환자에 대하여 수행된 수술이 정규 수술(예를 들어, 진료를 통하여 미리 일정이 예약된 수술)인지, 혹은 응급 수술(예를 들어, 미리 일정이 예약되지 않은 수술 또는 특정일 이내에 예약되어 수행된 수술)인지 여부, 환자의 수술에 대한 내용(수술 대상, 수술 수행 시간 등) 또는 환자의 수술이 수행된 진료과 중 적어도 하나에 대한 정보를 포함할 수 있다.
- [0051] 일 실시예에서, 응급 수술인 경우, 예정된 수술이 아니었으므로 정규 수술과 비교할 때 환자의 건강 상태가 급격히 악화되었다는 판단 근거가 될 수 있다. 일 실시예에서, 환자의 수술이 수행된 진료과가 환자의 사망률이 높다고 판단되는 기록을 갖는 진료과인 경우, 환자의 사망률이 높다고 판단되는 기록을 갖는 진료과에 비하여 환자의 사망 여부의 예측에 있어서 환자가 사망할 것이라고 예측되는 판단 근거가 될 수 있다.
- [0052] 일 실시예에서, 서버(100)를 이용하여 환자의 사망 여부를 예측하기를 원하는 경우, 환자 관련 정보에는 환자의 수술 후 입원 일자 등에 대한 정보가 포함될 수도 있다.
- [0053] 일 실시예에서, 서버(100)의 동작 방법은, 획득한 환자 관련 정보를 환자의 사망 여부 및 환자의 장기 재식 여부를 예측하는 앙상블 학습 모델에 적용하는 단계(S200)를 포함할 수 있다.
- [0054] 일 실시예에서, 앙상블 학습 모델은, 환자의 임상 정보, 수술 정보 또는 혈액 검사 결과 중 적어도 하나를 포함하는 훈련용(trainig) 환자 관련 정보에 기초하여 환자의 사망 여부 및 환자의 장기 재식 여부를 예측하도록 미리 학습된 모델일 수 있다. 일 실시예에서, 앙상블 학습 모델은 환자의 임상 정보, 수술 정보, 혈액 검사 결과, 환자의 사망 여부, 환자의 수술 후 입원 기간 또는 환자의 병원 입원 기간 중 적어도 하나를 포함하는 훈련용(training) 환자 관련 정보에 기초하여 환자의 사망 여부 및 환자의 장기 재식 여부를 예측하도록 미리 학습된 모델일 수 있다.
- [0055] 일 실시예에서, 환자의 사망 여부 및 환자의 장기 재식 여부를 예측하는 단계(S200)에서 적어도 하나의 프로세서(130)는 획득한 환자 관련 정보를 앙상블 학습 모델에 적용할 수 있다. 적어도 하나의 프로세서(130)는 앙상블 학습 모델에 획득한 환자 관련 정보를 입력할 수 있다.

- [0056] 일 실시예에서, 인공지능 학습 모델인 앙상블 학습 모델은 제1 앙상블 학습 모델 및 제2 앙상블 학습 모델을 포함할 수 있다. 제1 앙상블 학습 모델은 획득한 환자 관련 정보에 기초하여 수술 후 환자의 사망 여부를 예측하도록 학습된 모델일 수 있다. 제2 앙상블 학습 모델은 획득된 환자 관련 정보를 이용하여 환자의 장기 재실 여부를 예측하도록 학습된 모델일 수 있다.
- [0057] 일 실시예에서, 적어도 하나의 프로세서(130)는 제1 앙상블 학습 모델 또는 제2 앙상블 학습 모델 중 적어도 하나의 모델을 이용하여, 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 결정할 수 있다.
- [0058] 일 실시예에서, 서버(100)의 동작 방법은, 앙상블 학습 모델을 통하여 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측하는 단계(S300)를 포함할 수 있다.
- [0059] 일 실시예에서, 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측하는 단계(S300)에서, 적어도 하나의 프로세서(130)는 앙상블 학습 모델을 이용하여 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측할 수 있다. 일 실시예에서, 앙상블 학습 모델은, 환자의 사망 여부를 확률로 제공하도록 학습된 것일 수 있다. 일 실시예에서, 앙상블 학습 모델은 예측되는 환자가 사망할 가능성이 높아질수록, 높은 확률을 제공할 수 있다.
- [0060] 다만, 본 개시는 이에 제한되지 않고, 앙상블 학습 모델은 환자가 사망하는지 혹은 사망하지 않는지의 두 가지의 결과로 예측하도록 학습된 모델일 수 있다. 적어도 하나의 프로세서(130)는 앙상블 학습 모델을 이용하여, 환자가 사망하거나, 혹은 사망하지 않거나의 결과를 예측할 수 있다. 이를 통하여, 서버(100)의 사용자에게 명확한 예측 결과를 제공할 수 있다.
- [0061] 일 실시예에서, 앙상블 학습 모델은 환자가 수술 후 입원실에 입원한 날짜를 기준으로 환자의 장기 재실 여부를 판단하도록 학습된 것일 수 있다. 일 실시예에서, 앙상블 학습 모델은 환자가 수술 후 입원실에 입원을 시작한 날부터, 30일을 기준으로 환자가 장기 재실을 할지 여부를 예측하도록 학습된 것일 수 있다. 일 실시예에서, 환자가 수술 후 입원실에 입원을 시작한 날부터, 30일 이내에 입원실에서 퇴원을 할 것이라 예측되는 경우, 앙상블 학습 모델은 환자가 장기 재실을 하지 않을 것이라 예측하도록 학습된 것일 수 있다. 일 실시예에서, 환자가 수술 후 입원실에 입원을 시작한 날부터, 30일 또는 30일 이상 입원실에서 퇴원을 할 것이라 예측되는 경우, 앙상블 학습 모델은 환자가 장기 재실을 할 것이라 예측하도록 학습된 것일 수 있다.
- [0062] 이때, 환자가 수술 후 입원을 시작한 날은, 환자 관련 정보에 포함된 수술의 종류에 따라서, 수술한 날짜를 입원을 시작한 날로 할지 혹은 수술한 다음 날짜를 입원을 시작한 날로 할 지 결정할 수 있다. 다만, 본 개시는 어느 하나로 제한되지 않는다.
- [0063] 또한, 장기 재실 여부를 판단함에 있어 30일은 일 예시일 뿐, 어느 하나로 제한되지 않는다. 환자가 진행한 수술의 종류, 진료과, 환자의 나이, 또한 환자의 수술을 진행하는 병원의 상황 등을 고려하여 미리 입력된 설정 값 등에 따라서 장기 재실 여부를 판단하는 기준이 되는 날짜는 변경될 수 있다.
- [0064] 일 실시예에서, 서버(100)의 동작 방법은 통신부(120, 도 1 참조)를 통하여 외부 전자 장치(200, 도 2 참조)에 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측한 결과를 전달하는 단계를 포함할 수 있다. 적어도 하나의 프로세서(130)는 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측하는 단계(S300)에서 예측된 결과를 외부의 전자 장치(200)에 전달할 수 있다.
- [0065] 이때, 환자의 사망 여부 또는 환자의 장기 재실 여부 중 적어도 하나를 예측하는 단계(S300)에서 예측된 결과에 따라, 적어도 하나의 프로세서(130)가 외부의 전자 장치(200)에 전달하는 정보가 달라질 수 있다.
- [0066] 일 실시예에서, 서버(100)에서 환자의 사망 여부 및 환자의 장기 재실 여부를 모두 예측한 경우에, 예측된 결과가 환자가 장기 재실을 하지 않고, 사망할 것으로 판단된 결과일 수 있다. 이 경우, 환자는 수술 후에 오래 입원하지 않고 사망하는 것으로 예측되는 것으로, 환자의 건강 상태나 수술 후의 예후가 좋지 않다는 의미일 수 있다. 이 경우, 적어도 하나의 프로세서(130)는 외부의 전자 장치(200)에 수술 예정인 상기 환자가 중증 환자라는 정보를 포함하는 알람을 제공할 수 있다. 또한, 적어도 하나의 프로세서(130)는 외부의 전자 장치(200)에 해당 환자에 대하여 수술을 진행한 후에 집중 치료 또는 집중 관찰 등이 요망된다는 정보를 포함하는 알람을 제공할 수 있다.
- [0067] 일 실시예에서, 설명의 편의를 위하여 적어도 하나의 프로세서(130)가 외부의 전자 장치(200)에 정보를 전달하는 것만을 개시하였으나, 외부의 서버에 전달하거나 혹은 서버(100)를 포함하는 전자 장치를 통하여 직접 전달할 수 있음은 물론이다.

- [0068] 도 4는 본 개시의 일 실시예에 따른 서버에 포함된 인공지능 학습 모델의 학습 동작을 설명하기 위한 순서도이다. 도 5는 본 개시의 일 실시예에 따른 인공지능 학습 모델의 학습에 이용되는 훈련 데이터를 설명하기 위한 도면이다.
- [0069] 일 실시예에서, 도 1 및 도 4를 참조하면, 메모리(110)에 포함된 인공지능 학습 모델은 훈련용 환자 관련 정보에 기초하여 수술 후 환자의 사망 여부 및 환자의 장기 재실 여부를 예측하도록 미리 학습된 모델일 수 있다.
- [0070] 일 실시예에서, 서버(100)는 미리 학습된 인공지능 학습 모델을 제공받을 수 있다. 다만, 본 개시는 이에 제한되지 않고, 적어도 하나의 프로세서(130)는 인공지능 학습 모델이 훈련용 환자 관련 정보에 기초하여 수술 후 환자의 사망 여부 및 환자의 장기 재실 여부를 예측하도록 학습시킬 수도 있다. 이러한 학습은 본 개시에 따른 환자의 사망 여부 및 환자의 장기 재실 여부의 예측이 수행되는 서버(100) 자체에서 이루어질 수도 있고, 별도의 서버 및/또는 시스템을 통해 이루어 질 수도 있다. 이하, 설명의 편의를 위하여 적어도 하나의 프로세서(130)가 앙상블 학습 모델을 학습시키는 것으로 설명하도록 한다.
- [0071] 일 실시예에서, 인공지능 학습 모델은 인공 지능 모델을 포함할 수 있다. 일 인공 지능 모델은 복수의 신경망 레이어들로 구성될 수 있다. 복수의 신경망 레이어들 각각은 복수의 가중치들 (weight values)을 갖고 있으며, 이전(previous) 레이어의 연산 결과와 복수의 가중치들 간의 연산을 통해 신경 망 연산을 수행한다. 복수의 신경망 레이어들이 갖고 있는 복수의 가중치들은 인공지능 모델의 학습 결과에 의해 최적화될 수 있다. 예를 들어, 학습 과정 동안 인공지능 모델에서 획득한 로스(loss) 값 또는 코스트(cost) 값이 감소 또는 최소화되도록 복수의 가중치들이 갱신될 수 있다. 인공 신경망은 심층 신경망(DNN: Deep Neural Network)를 포함할 수 있으며, 예를 들어, CNN (Convolutional Neural Network), DNN (Deep Neural Network), RNN (Recurrent Neural Network), RBM (Restricted Boltzmann Machine), DBN (Deep Belief Network), BRDNN(Bidirectional Recurrent Deep Neural Network), 트랜스포머(Transformer), 심층 Q-네트워크 (Deep Q-Networks) 또는 부스팅(Boosting) 알고리즘 등이 있으나, 전술한 예에 한정되지 않는다.
- [0072] 또한, 인공지능 학습 모델은, 앙상블 학습 모델을 포함할 수도 있다. 앙상블 학습 모델은 XGBoost(eXtreme Gradient Boosting), CatBoost, LGBM(Light Gradient Boosting Model), Random Forest 및 MLP(Multi-Layer Perceptron)를 포함할 수 있다. 이하, 설명의 편의를 위하여, 인공지능 학습 모델의 학습 방법을, 앙상블 학습 모델의 학습 방법으로 설명할 수 있다.
- [0073] 도 4 및 도 5를 참조하면, 일 실시예에서, 앙상블 학습 모델의 학습 방법은, 학습용 환자 관련 정보를 훈련 데이터로서 획득하는 단계를 포함할 수 있다.
- [0074] 일 실시예에서, 학습용 환자 관련 정보는 훈련용 환자의 임상 정보, 훈련용 환자의 수술 정보, 훈련용 환자의 사망 여부, 훈련용 환자의 재실 기간 또는 훈련용 환자의 혈액 검사 중 적어도 하나를 포함할 수 있다.
- [0075] 일 실시예에서, 앙상블 학습 모델의 학습 방법은, 학습용 환자 관련 정보(500)를 학습용 세트(400)와 테스트용 세트(410)로 구분하는 단계를 포함할 수 있다. 적어도 하나의 프로세서(130)는 학습용 환자 관련 정보(500)를 학습용 세트(400) 및 테스트용 세트(410)로 구분할 수 있다.
- [0076] 일 실시예에서, 테스트용 세트(410)는 앙상블 학습 모델이 학습용 세트(400)에 의하여 과적합되었는지 여부를 확인하는 과정에서 사용되는 데이터일 수 있다.
- [0077] 일 실시예에서, 학습용 세트(400)는 앙상블 학습 모델을 학습시키는 과정에서 사용되는 데이터일 수 있다. 일 실시예에서, 앙상블 학습 모델의 학습 방법은 학습용 세트(400)를 훈련(training) 세트(401)와 검증(validation) 세트(402)로 구분하는 단계(S10)를 포함할 수 있다. 일 실시예에서, 적어도 하나의 프로세서(130)는 훈련용 세트(400) 중 80%를 훈련 세트(401)로 구분하고, 나머지 20%를 검증 세트(402)로 구분할 수 있다. 일 실시예에서, 학습용 환자 관련 정보를 훈련 세트(401)와 검증 세트(402)로 구분하는 동작은 stratified k-fold validation 기법을 이용하여 수행될 수 있다. 도 5를 참조하면, 훈련 세트(401)는 학습용 세트(400) 중 "V"로 표시된 복수의 데이터들을 의미할 수 있다. 검증 세트(402)는 학습용 세트(400) 중 "T"로 표시된 복수의 데이터들을 의미할 수 있다.
- [0078] 일 실시예에서, 앙상블 학습 모델의 학습 방법은, 훈련 세트(401)를 이용하여 환자의 사망 여부 및 환자의 장기 재실 여부를 예측하도록 앙상블 학습 모델을 학습시키는 단계(S20)를 포함할 수 있다.
- [0079] 일 실시예에서, 훈련 세트(401)는 학습용 환자 관련 정보 중 앙상블 학습 모델에 포함된 복수의 가중치들을 갱신하기 위하여 사용되는 세트일 수 있다. 적어도 하나의 프로세서(130)는 훈련 세트(401)를 이용하여, 앙상블

학습 모델에 포함된 복수의 가중치를 갱신하여 앙상블 학습 모델이 환자 관련 정보에 기초하여 수술 후 환자의 사망 여부 및 환자의 장기 재실 여부를 예측하도록 학습시킬 수 있다.

- [0080] 일 실시예에서, 앙상블 학습 모델의 학습 방법은, 검증 세트(402)를 이용하여 학습된 모델의 성능을 외부 검증하는 단계(S30)를 포함할 수 있다. 일 실시예에서, 검증 세트(402)는 학습용 환자 관련 정보를 이용하여 앙상블 학습 모델의 학습이 완료되었는 여부를 확인하기 위하여 사용되는 세트일 수 있다. 일 실시예에서, 적어도 하나의 프로세서(130)는 검증 세트(402)에 기초하여, 앙상블 학습 모델을 이용하여 나오는 결과 값을 토대로 앙상블 학습 모델의 학습이 일정 목표값 이상의 정확도를 갖는지 여부를 확인할 수 있다.
- [0081] 일 실시예에서, 앙상블 학습 모델은, 단계 S10, 단계 S20 및 단계 S30을 거쳐 학습된 모델일 수 있다.
- [0082] 일 실시예에서, 앙상블 학습 모델은 학습용 환자 관련 정보를 훈련 세트(401)와 검증 세트(402)로 나눈 후 학습시키는 동작을 통하여 학습이 수행된 모델로서, 검증 세트(402)를 통하여 훈련 세트(401)에 의하여 일차적으로 학습이 완료된 앙상블 학습 모델의 성능을 외부 검증한 후 학습을 완료하여, 앙상블 학습 모델에 대한 성능에 대한 신뢰도를 높일 수 있다.
- [0083] 일 실시예에서, 앙상블 학습 모델의 학습 방법은, 훈련 세트(401)와 검증 세트(402)를 통하여 학습이 완료된 앙상블 학습 모델에 대하여, 테스트용 세트(410)를 이용하여 앙상블 학습 모델의 성능을 테스트하는 단계를 포함할 수 있다. 적어도 하나의 프로세서(130)는 학습하는 과정에서 사용되지 않은 데이터인 테스트용 세트(410)를 이용하여 추론 동작을 수행하여, 학습용 세트(400)에 의하여 학습이 완료된 앙상블 학습 모델의 성능을 테스트할 수 있다.
- [0084] 일 실시예에서, 학습용 환자 관련 정보(500)의 80%를 학습용 세트(400)로 구분하고 나머지 20%를 테스트용 세트(410)로 구분하는 경우, 훈련 세트(401)는 학습용 세트(400)의 80%, 즉 학습용 환자 관련 정보(500)의 64%를 구분하고, 검증 세트(402)는 학습용 세트(400)의 20%, 즉 학습용 환자 관련 정보의 16%로 구분될 수도 있다.
- [0085] 이러한 학습 과정을 통하여, 앙상블 학습 모델에 포함된 XGBoost(eXtreme Gradient Boosting), CatBoost, LGBM(Light Gradient Boosting Model), Random Forest 및 MLP(Multi-Layer Perceptron)이 각각 학습될 수 있다.
- [0086] 일 실시예에서, 제1 앙상블 학습 모델은 학습용 세트(400)에 의하여, 환자의 사망 여부를 예측하도록 학습될 수 있다. 일 실시예에서, 제1 앙상블 학습 모델은 학습용 세트(400)에 포함된 임상 정보, 훈련용 환자의 수술 정보, 훈련용 환자의 사망 여부 및 훈련용 환자의 혈액 검사를 포함하는 제1 환자 관련 정보를 이용하여 환자의 사망 여부를 예측하도록 학습될 수 있다.
- [0087] 일 실시예에서, 제2 앙상블 학습 모델은 학습용 세트(400)에 의하여, 환자의 장기 재실 여부를 예측하도록 학습될 수 있다. 일 실시예에서, 제2 앙상블 학습 모델은 학습용 세트(400)에 포함된 임상 정보, 훈련용 환자의 수술 정보, 훈련용 환자의 재실 기간 및 훈련용 환자의 혈액 검사를 포함하는 제2 환자 관련 정보를 이용하여 환자의 장기 재실 여부를 예측할 수 있도록 학습될 수 있다.
- [0088] 일 실시예에서, 학습용 환자 관련 정보(500)를 이용하여 학습 및 성능 평가가 완료된 앙상블 학습 모델에 대하여, 환자 관련 정보(510)를 이용하여 추론을 실행할 수 있다. 다만, 본 개시는 이에 제한되지 않고, 추론을 실행하는데 이용되는 환자 관련 정보(510)는 학습용 환자 관련 정보(500)가 획득된 특정 병원과 다른 병원에서 획득되어, 특정 병원의 정보들을 이용하여 학습된 앙상블 학습 모델의 성능이 다른 병원의 정보를 이용하더라도 유지되는지 여부를 판단하기 위한 정보일 수도 있다.
- [0089] 도 6a는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 학습 성능을 설명하기 위한 도면이다. 도 6b는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 추론 성능을 설명하기 위한 도면이다.
- [0090] 도 6a를 참조하면, 일 실시예에서, 도 6a에는 환자 관련 정보를 이용하여 환자의 사망 여부를 예측하도록 학습된 제1 앙상블 학습 모델의 학습된 성능을 평가한 평가표(600)가 도시되어 있다. 일 실시예에서, 도 6a에 도시된 평가표(600)는, 제1 앙상블 학습 모델의 학습을 마친 후, 학습용 환자 관련 정보를 이용하여 예측된 결과를 평가하여 획득된 표일 수 있다. 일 실시예에서, 도 6a에 도시된 평가표(600)는, 제1 앙상블 학습 모델의 학습을 마친 후, 테스트용 세트(410)를 이용하여 예측된 결과를 평가하여 획득된 표일 수 있다.
- [0091] 일 실시예에서, 평가표(600)에는 학습된 XGBoost, CatBoost, LGBM, Random Forest 및 MLP 모델 각각에 대한 학습된 성능이 도시되어 있다. 일 실시예에서, 평가표(620)에는 각각의 모델에 대한 AUROC(Area Under the Receiver Operating Characteristic Curve), 정확도(Accuracy), 정밀도(Precision), 재현율(Recall) 및 F1-

Score 항목이 도시되어 있다. 일 실시예에서, XGBoost에서의 cut-off 값은 0.2로 설정될 수 있다. CatBoost에서의 cut-off 값은 0.22로 설정될 수 있다. LGBM에서의 cut-off 값은 0.2로 설정될 수 있다. Random Forest에서의 cut-off 값은 0.25로 설정될 수 있다. MLP 모델에서의 cut-off 값은 0.3으로 설정될 수 있다. 이때, cut-off 값은 환자의 사망 여부를 판단함에 있어 사망하는지 혹은 사망하지 않는지 여부로 구분하는 기준이 되는 값일 수 있다.

[0092] 일 실시예에서, 도 4, 도 5 및 도 6a를 참조할 때, XGBoost, CatBoost 및 LGBM 각각의 모델은 학습 과정에서 존재하는 학습용 환자 관련 정보에 포함된 결측치에 대하여 공백(Blank)로 대체하여 학습된 모델일 수 있다. 이와 달리, Random Forest 및 MLP 모델은 학습 과정에서 존재하는 학습용 환자 관련 정보에 포함된 결측치에 대하여 중앙값(median)으로 대체하여 학습된 모델일 수 있다. 이때, 중앙값은 결측치와 인접한 값들의 중앙값 또는 전체 데이터의 중앙값을 의미할 수 있다.

[0093] 일 실시예에서, 제1 앙상블 학습 모델은 Ensemble Model로서 평가표(600)에 도시되어 있다. 제1 앙상블 학습 모델은 XGBoost에 0.15의 가중치, CatBoost에 0.15의 가중치, LGBM에 0.6의 가중치, Random Forest에 0.05의 가중치 및 MLP에 0.05의 가중치를 두어 앙상블 된 모델일 수 있다. 다만, 본 개시는 이에 제한되지 않고, 제1 앙상블 학습 모델은 추론 성능을 향상시키기 위하여 XGBoost, CatBoost, LGBM, Random Forest 및 MLP 모델 각각에 대한 가중치를 달리 하여 제1 앙상블 학습 모델을 생성할 수 있다.

[0094] 일 실시예에서, 도 6b에 도시된 평가표(610)는 제1 앙상블 학습 모델의 추론 성능을 설명하기 위하여, 학습용 데이터가 아닌, 실제 추론을 위하여 입력한 환자 관련 정보를 이용하여 예측된 결과를 평가하여 획득된 표일 수 있다. 일 실시예에서, 학습용 환자 관련 정보가 어느 특정 병원에서 획득된 환자 관련 정보인 경우, 실제 추론을 위하여 입력한 환자 관련 정보는 다른 병원에서 획득된 환자 관련 정보일 수 있다.

[0095] 도 6b에 도시된 평가표(610)를 참조하면, 도 6b에 도시된 평가표(610)는 제1 앙상블 학습 모델 시 사용된 학습용 데이터가 아닌, 실제 추론을 위하여 입력한 데이터를 이용하여 예측된 환자의 사망 여부에 대한 결과를 이용하여 평가한 것임에도 불구하고, 각각의 평가 항목에서 일정 점수 이상을 획득한 것이 도시되어 있다.

[0096] 이를 통하여, 학습용 환자 관련 정보를 이용하여 학습된 제1 앙상블 학습 모델의 학습 성능은 물론이고, 제1 앙상블 학습 모델을 이용한 추론 시에도 제1 앙상블 학습 모델의 환자의 사망 여부 예측의 정확도는 높을 수 있다.

[0097] 도 6c는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 학습 성능을 설명하기 위한 도면이다. 도 6d는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 추론 성능을 설명하기 위한 도면이다. 이하, 도 6a 및 도 6b에서 설명한 구성과 동일한 구성에 대하여 중복되는 설명은 생략하도록 한다.

[0098] 도 6c를 참조하면, 일 실시예에서, 도 6c에는 환자 관련 정보를 이용하여 환자의 장기 재실 여부를 예측하도록 학습된 제2 앙상블 학습 모델의 학습된 성능을 평가한 평가표(620)가 도시되어 있다.

[0099] 일 실시예에서, 제2 앙상블 학습 모델은 Ensemble Model로서 평가표(620)에 도시되어 있다. 제2 앙상블 학습 모델은 XGBoost에 0.1의 가중치, CatBoost에 0.2의 가중치, LGBM에 0.05의 가중치, Random Forest에 0.05의 가중치 및 MLP에 0.6의 가중치를 두어 앙상블 된 모델일 수 있다. 다만, 본 개시는 이에 제한되지 않고, 제2 앙상블 학습 모델은 추론 성능을 향상시키기 위하여 XGBoost, CatBoost, LGBM, Random Forest 및 MLP 모델 각각에 대한 가중치를 달리 하여 제2 앙상블 학습 모델을 생성할 수 있다.

[0100] 일 실시예에서, XGBoost에서의 cut-off 값은 0.08로 설정될 수 있다. CatBoost에서의 cut-off 값은 0.07로 설정될 수 있다. LGBM에서의 cut-off 값은 0.06로 설정될 수 있다. Random Forest에서의 cut-off 값은 0.08로 설정될 수 있다. MLP 모델에서의 cut-off 값은 0.17으로 설정될 수 있다. 이때, cut-off 값은 환자의 장기 재실 여부를 판단함에 있어 장기 재실로 예측되는지 혹은 장기 재실로 예측되지 않는지 여부로 구분하는 기준이 되는 값일 수 있다.

[0101] 일 실시예에서, 도 6c에 도시된 평가표(620)는 제2 앙상블 학습 모델의 추론 성능을 설명하기 위하여, 학습용 데이터가 아닌, 실제 추론을 위하여 입력한 환자 관련 정보를 이용하여 예측된 결과를 평가하여 획득된 표일 수 있다.

[0102] 도 6d에 도시된 평가표(630)를 참조하면, 도 6d에 도시된 평가표(630)는 제2 앙상블 학습 모델 시 사용된 학습용 데이터가 아닌, 실제 추론을 위하여 입력한 데이터를 이용하여 예측된 환자의 장기 재실 여부에 대한 결과를 이용하여 평가한 것임에도 불구하고, 각각의 평가 항목에서 일정 점수 이상을 획득한 것이 도시되어 있다.


- [0103] 이를 통하여, 학습용 환자 관련 정보를 이용하여 학습된 제2 앙상블 학습 모델의 학습 성능은 물론이고, 제2 앙상블 학습 모델을 이용한 추론 시에도 제2 앙상블 학습 모델의 환자의 장기 재실 여부 예측의 정확도는 높을 수 있다.
- [0104] 일 실시예에서, 서버(100, 도 1참조)의 앙상블 학습 모델은 제1 앙상블 학습 모델 및 제2 앙상블 학습 모델을 이용하여 환자의 사망 여부 및 환자의 장기 재실 여부를 예측할 수 있다. 서버(100)는 획득된 환자 관련 정보 및 획득된 환자 관련 정보를 이용하여 예측하려는 정보에 따라, 제1 앙상블 학습 모델 또는 제2 앙상블 학습 모델 중 적어도 하나의 모델을 이용하여 결과를 예측할 수 있다.
- [0105] 도 7a는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 7b는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 7c는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 7d는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 7e는 본 개시의 일 실시예에 따른 제1 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다.
- [0106] 도 7a 내지 도 7e를 참조하면, 일 실시예에서, 도 7a 내지 도 7e에는 각각 제1 앙상블 학습 모델에서 조합된 XGBoost, CatBoost, LGBM, Random Forest 및 MLP 모델 각각에서의 환자 관련 정보를 이용하여 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들의 영향을 분석한 그래프가 도시되어 있다.
- [0107] 일 실시예에서, 도 7a 내지 도 7e에는 SHAP(Shapley Additive exPlanations) 방법을 이용하여 각 모델별로 수술 후 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들의 영향을 분석한 그래프가 도시되어 있다.
- [0108] 일 실시예에서, 도 7a 내지 도 7e에는 SHAP 값을 기반으로 한 XGBoost, CatBoost, LGBM, Random Forest 및 MLP 모델 각각에서의 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다. 이때, 도 7a 내지 도 7e에 도시된 특성들은 그래프의 y축을 기준으로 위에 배치된 특성일수록 XGBoost 모델의 성능에 미치는 영향이 크고, 그래프의 y축을 기준으로 아래쪽에 배치된 특성일수록 XGBoost 모델의 성능에 미치는 영향이 작을 수 있다. 이때, 모델의 성능에 미치는 영향이란, 해당 영향이 높을수록 환자가 사망으로 예측될 확률이 높아지는 것을 의미할 수 있다.
- [0109] 또한, 그래프의 x축을 기준으로, 각각의 특성들에 표시되는 색을 가진 선은, 빨간 색일수록 XGBoost 모델의 성능에 미치는 영향이 크고, 파란 색일수록 XGBoost 모델의 성능에 미치는 영향이 작을 수 있다.
- [0110] 일 실시예에서, 도 7a에 도시된 특성 중 “Age”를 기준으로, x축 중 원점인 0을 기준으로 오른쪽으로 갈수록(나이가 증가할수록) 빨간 색으로 가서, 환자가 사망으로 예측될 확률이 높아지고, 왼쪽으로 갈수록(나이가 감소할수록) 파란 색으로 가서, 환자가 사망으로 예측될 확률이 낮아지는 것을 의미할 수 있다.
- [0111] 일 실시예에서, 도 7a에는 SHAP 값을 기반으로 한 XGBoost 모델에서의 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0112] 일 실시예에서, 도 7b에는 SHAP 값을 기반으로 한 CatBoost 모델에서의 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0113] 일 실시예에서, 도 7c에는 SHAP 값을 기반으로 한 LGBM에서의 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0114] 일 실시예에서, 도 7d에는 SHAP 값을 기반으로 한 Random Forest 모델에서의 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0115] 일 실시예에서, 도 7e에는 SHAP 값을 기반으로 한 MLP 모델에서의 환자의 사망 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0116] 도 8a는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 8b는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 8c는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 8d는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 도 8e는 본 개시의 일 실시예에 따른 제2 앙상블 학습 모델의 성능에 영향을 미친 특징을 설명하기 위한 도면이다. 이하, 도 7a 내지 도 7e에서 설명한 구성과 동일한 구성에 대하여 중복되는 설명은 생략

하도록 한다.


- [0117] 도 8a 내지 도 8e를 참조하면, 일 실시예에서, 도 8a 내지 도 8e에는 각각 제2 앙상블 학습 모델에서 조합된 XGBoost, CatBoost, LGBM, Random Forest 및 MLP 모델 각각에서의 환자 관련 정보를 이용하여 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들의 영향을 분석한 그래프가 도시되어 있다.
- [0118] 일 실시예에서, 도 8a 내지 도 8e에는 SHAP(Shapley Additive exPlanations) 방법을 이용하여 각 모델별로 수술 후 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들의 영향을 분석한 그래프가 도시되어 있다.
- [0119] 일 실시예에서, 도 8a에는 SHAP 값을 기반으로 한 XGBoost 모델에서의 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0120] 일 실시예에서, 도 8b에는 SHAP 값을 기반으로 한 CatBoost 모델에서의 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0121] 일 실시예에서, 도 8c에는 SHAP 값을 기반으로 한 LGBM에서의 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0122] 일 실시예에서, 도 8d에는 SHAP 값을 기반으로 한 Random Forest 모델에서의 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0123] 일 실시예에서, 도 8e에는 SHAP 값을 기반으로 한 MLP 모델에서의 환자의 장기 재실 여부를 예측하는 성능에 영향을 미치는 특징들 및 특징들 각각의 영향이 도시되어 있다.
- [0124] 한편, 개시된 실시예들은 컴퓨터에 의해 실행 가능한 명령어를 저장하는 기록매체의 형태로 구현될 수 있다. 명령어는 프로그램 코드의 형태로 저장될 수 있으며, 프로세서에 의해 실행되었을 때, 프로그램 모듈을 생성하여 개시된 실시예들의 동작을 수행할 수 있다. 기록매체는 컴퓨터로 읽을 수 있는 기록매체로 구현될 수 있다.
- [0125] 컴퓨터가 읽을 수 있는 기록매체로는 컴퓨터에 의하여 해독될 수 있는 명령어가 저장된 모든 종류의 기록 매체를 포함한다. 예를 들어, ROM(Read Only Memory), RAM(Random Access Memory), 자기 테이프, 자기 디스크, 플래쉬 메모리, 광 데이터 저장장치 등이 있을 수 있다.
- [0126] 이상에서와 같이 첨부된 도면을 참조하여 개시된 실시예들을 설명하였다. 본 개시가 속하는 기술분야에서 통상의 지식을 가진 자는 본 개시의 기술적 사상이나 필수적인 특징을 변경하지 않고도, 개시된 실시예들과 다른 형태로 본 개시가 실시될 수 있음을 이해할 것이다. 개시된 실시예들은 예시적인 것이며, 한정적으로 해석되어서는 안 된다.

도면


도면1



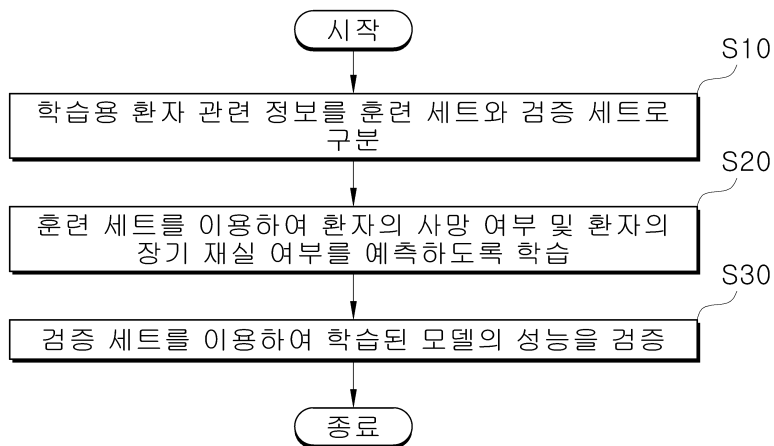
도면2




도면3



도면4



도면5



도면6a

600

Model (cut off)	AUROC	Accuracy	Precision	Recall	F1-score
XGBoost (0.2)	0.8751	0.9066	0.7139	0.6985	0.7058
CatBoost (0.22)	0.8744	0.9059	0.7186	0.6572	0.6811
LGBM (0.2)	0.8792	0.9138	0.7368	0.6667	0.6937
Random Forest (0.25)	0.8482	0.9009	0.7011	0.7097	0.7052
MLP (0.3)	0.8478	0.8951	0.6843	0.6922	0.6882
Ensemble model	0.8806	0.9124	0.7314	0.6874	0.7062

도면6b

610

Model	AUROC	Accuracy	Precision	Recall	F1-score
XGBoost	0.8304	0.9083	0.6599	0.6795	0.6689
CatBoost	0.8106	0.9287	0.7167	0.6311	0.6607
LGBM	0.8242	0.9192	0.6785	0.6467	0.6605
Random Forest	0.8081	0.9012	0.6467	0.6809	0.6613
MLP	0.7867	0.8981	0.6308	0.6534	0.6408
Ensemble	0.8305	0.9204	0.6866	0.6602	0.6721

도면6c

620


Model (cut off)	AUROC	Accuracy	Precision	Recall	F1-score
XGBoost (0.08)	0.7658	0.8606	0.5305	0.5810	0.5329
CatBoost (0.07)	0.7731	0.8506	0.5553	0.6747	0.5648
LGBM (0.06)	0.7490	0.8807	0.5340	0.5750	0.5401
Random Forest (0.08)	0.7708	0.7371	0.5396	0.6979	0.5087
MLP (0.17)	0.7857	0.8951	0.5690	0.6484	0.5876
Ensemble model	0.7918	0.9009	0.5745	0.6514	0.5944

도면6d


630

Model (cut off)	AUROC	Accuracy	Precision	Recall	F1-score
XGBoost	0.7214	0.8350	0.5263	0.5820	0.5221
CatBoost	0.7294	0.8475	0.5359	0.6062	0.5380
LGBM	0.6866	0.8550	0.5231	0.5614	0.5221
Random Forest	0.6687	0.9549	0.5345	0.5030	0.4970
MLP	0.7042	0.9377	0.5606	0.5427	0.5494
Ensemble	0.7380	0.9314	0.5690	0.5659	0.5674


도면7a




도면7b




도면7c




도면7d




도면7e




도면8a




도면8b



도면8c



도면8d



도면8e

