



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0084883
(43) 공개일자 2025년06월11일

(51) 국제특허분류(Int. Cl.)

G16H 50/20 (2018.01) G06F 40/205 (2020.01)
G06N 3/044 (2023.01) G06N 3/045 (2023.01)
G06N 3/0499 (2023.01) G06N 3/0985 (2023.01)
G16H 10/20 (2018.01) G16H 10/60 (2018.01)
G16H 50/70 (2018.01)

(52) CPC특허분류

G16H 50/20 (2018.01)
G06F 40/205 (2020.01)

(21) 출원번호 10-2024-0178640

(22) 출원일자 2024년12월04일

심사청구일자 2024년12월04일

(30) 우선권주장

1020230173523 2023년12월04일 대한민국(KR)

(71) 출원인

(주)아이젠사이언스

서울특별시 성북구 안암로 145, 우정정보관 503호, 이학관별관 108호(안암동5가, 고려대학교)

고려대학교 산학협력단

서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)

(72) 발명자

이상훈

서울시 성동구 독성로1길 25 서울숲한라에코밸리 507호

강재우

서울시 성북구 안암로 145 우정정보관 501B호

(뒷면에 계속)

(74) 대리인

특허법인위솔


전체 청구항 수 : 총 10 항

(54) 발명의 명칭 환자에 대한 임상 노트와 모니터링 데이터의 결합을 통한 임상 결과 예측 방법 및 장치

(57) 요약

일 실시예에 따른 임상 결과 예측 장치는 환자에 대한 임상 노트에 포함된 텍스트 데이터 및 환자의 실시간 상태와 관련된 모니터링 데이터를 획득하는 동작; 상기 텍스트 데이터를 문장 단위로 나누고 셀프 어텐션 매커니즘을 수행하여 텍스트 임베딩을 추출하는 동작; 텍스트 임베딩으로부터 진단 정보를 예측하도록 학습된 제1 신경망에 환자의 텍스트 임베딩을 입력하여 예측 진단 정보를 출력시키는 동작; 순환 신경망을 이용하여 상기 모니터링 데이터로부터 모니터링 임베딩을 추출하는 동작; 및 상기 텍스트 임베딩 및 상기 모니터링 임베딩을 결합한 결합 임베딩을 생성하고, 결합 임베딩으로부터 임상 결과를 예측하도록 학습된 제2 신경망에 환자의 결합 임베딩을 입력하여 예측 임상 결과를 출력시키는 동작을 포함할 수 있다.

대표도 - 도3



(52) CPC특허분류

G06N 3/044 (2023.01)
G06N 3/045 (2023.01)
G06N 3/0499 (2023.01)
G06N 3/0985 (2023.01)
G16H 10/20 (2021.08)
G16H 10/60 (2021.08)
G16H 50/70 (2018.01)

(72) 발명자

김선규

서울시 성동구 뚝섬로1길 25 서울숲한라에코밸리 507호

장광훈

서울시 성북구 안암로 145 우정정보관 501B호

김찬휘

서울시 성북구 안암로 145 우정정보관 501B호

박세정

서울시 성북구 안암로 145 우정정보관 501B호

유기웅

서울시 성동구 뚝섬로1길 25 서울숲한라에코밸리 507호

김지혜

서울시 성동구 뚝섬로1길 25 서울숲한라에코밸리 507호

이 발명을 지원한 국가연구개발사업

과제고유번호	1711188732
과제번호	2023R1A2C3004176
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	생명의료 가설 Co-Design을 위한 Human-in-the-loop 초대형 언어모델 개발
과제수행기관명	고려대학
연구기간	2023.03.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호	2460000596
과제번호	KH088565
부처명	보건복지부
과제관리(전문)기관명	한국보건산업진흥원
연구사업명	연구중심병원육성
연구과제명	인공지능·빅데이터 기반 데이터주도 의료기술 개발 및 고도화
과제수행기관명	고려대학교산학협력단
연구기간	2024.01.01 ~ 2024.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	2460001123
과제번호	KH129295
부처명	보건복지부
과제관리(전문)기관명	한국보건산업진흥원
연구사업명	연구중심병원육성
연구과제명	디지털 트윈 기반 정밀의료 통합 관리 플랫폼 구현
과제수행기관명	고려대학교의료원
연구기간	2024.01.01 ~ 2024.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711198626
과제번호	RS-2023-00262002
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	(원천)바이오의료기술개발사업
연구과제명	바이오 빅데이터 기반 당뇨병 및 합병증 정밀 의료를 위한 AI 플랫폼 및 모델 개발
과제수행기관명	서울대학병원
연구기간	2023.07.01 ~ 2023.12.31

명세서

청구범위

청구항 1

프로세서에 의해 동작하는 임상 결과 예측 장치가 수행하는 방법에 있어서,
환자에 대한 임상 노트에 포함된 텍스트 데이터 및 환자의 실시간 상태와 관련된 모니터링 데이터를 획득하는 동작;
상기 텍스트 데이터를 문장 단위로 나누고 셀프 어텐션 매커니즘을 수행하여 텍스트 임베딩을 추출하는 동작;
텍스트 임베딩으로부터 진단 정보를 예측하도록 학습된 제1 신경망에 환자의 텍스트 임베딩을 입력하여 예측 진단 정보를 출력시키는 동작;
순환 신경망을 이용하여 상기 모니터링 데이터로부터 모니터링 임베딩을 추출하는 동작; 및
상기 텍스트 임베딩 및 상기 모니터링 임베딩을 결합한 결합 임베딩을 생성하고, 결합 임베딩으로부터 임상 결과를 예측하도록 학습된 제2 신경망에 환자의 결합 임베딩을 입력하여 예측 임상 결과를 출력시키는 동작을 포함하는,
방법.

청구항 2

제1항에 있어서,
상기 텍스트 임베딩을 추출하는 동작은
상기 텍스트 데이터를 구성하는 문장을 분리하는 동작;
분리된 각 문장을 사전 학습된 언어 모델에 입력하여 각 문장에 대한 임베딩을 추출하는 동작; 및
상기 각 문장의 임베딩을 트랜스포머 모델 기반의 셀프 어텐션 레이어에 입력하여 환자의 텍스트 임베딩을 추출하는 동작을 포함하는,
방법.

청구항 3

제1항에 있어서,
상기 제1 신경망은
순방향 신경망(Feedforward Neural Network) 또는 완전 연결 신경망(Fully Connected Neural Network)의 구조로 설계되고, 학습용 텍스트 임베딩을 입력하여 출력되는 진단 정보의 클래스에 대한 예측값과, 환자의 진단 정보에 대한 정답 클래스 간의 손실이 크로스 엔트로피 손실 함수를 통해 최소화되도록 학습된,
방법.

청구항 4

제3항에 있어서,
상기 손실 함수는 하기 수학식 1로 구성되는,

[수학식 1]

$$L_{aux} = -\frac{1}{N_p} \frac{1}{N_d} \sum_{i=1}^{N_p} \sum_{j=1}^{N_d} y_{j, diag}^i \log(\hat{y}_{j, diag}^i)$$

(L_{aux} 은 제1 신경망의 손실 함수, N_d 는 예측할 진단 정보 클래스의 개수, N_p 는 학습에 사용된 환자의 수,

$y_{j, diag}^i$ 는 학습에 사용된 환자의 진단 정보의 정답 클래스, $\hat{y}_{j, diag}^i$ 는 학습용 텍스트 임베딩을 입력하여 출력되는 진단 정보의 클래스에 대한 예측값)

방법.

청구항 5

제4항에 있어서,

상기 진단 정보의 클래스에 대한 예측값은 하기 수학식 2의 형태로 구성되는,

[수학식 2]

$$\hat{Y}_{diag} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{N_d}\} = \text{sigmoid}(\text{FFNN}(E_c))$$

(E_c 는 텍스트 임베딩, sigmoid 는 시그모이드 함수, FFNN 는 feedforward neural network 함수, N_d 는 진단 정보의 클래스 개수, 각 예측값의 밑첨자는 진단 정보의 클래스를 특징하는 인덱스)

방법.

청구항 6

제1항에 있어서,

상기 모니터링 데이터는

소정의 시간 범위 동안 복수 개의 측정 항목에 대해 측정된 시계열 데이터를 포함하고,

상기 모니터링 임베딩을 추출하는 동작은,

순환 신경망에 상기 모니터링 데이터를 입력하여 상기 모니터링 데이터의 시계열 데이터가 반영되어 최종적으로 출력되는 데이터를 상기 환자의 모니터링 임베딩으로 추출하는 동작을 포함하는,

방법.

청구항 7

제1항에 있어서,

상기 제2 신경망은

완전 연결 신경망의 구조로 설계되고, 학습용 결합 임베딩을 입력하여 출력되는 임상 결과의 클래스에 대한 예측값과, 환자의 임상 결과에 대한 정답 클래스 간의 손실이 크로스 엔트로피 손실 함수를 통해 최소화되도록 학습된,

방법.

청구항 8

제7항에 있어서,

상기 손실 함수는 하기 수학식 3으로 구성되는,

[수학식 3]

$$L_{\text{main}} = -\frac{1}{N_p} \frac{1}{N_c} \sum_{i=1}^{N_p} \sum_{j=1}^{N_c} y_{j, \text{clinic}}^i \log(\hat{y}_{j, \text{clinic}}^i)$$

(Lmain은 제2 신경망의 손실 함수, Nc는 예측할 임상 결과 클래스의 개수, Np는 학습에 사용된 환자의 수,

$y_{j, \text{clinic}}^i$ 는 학습에 사용된 환자의 임상 결과 정답 클래스, $\hat{y}_{j, \text{clinic}}^i$ 는 학습용 융합 임베딩을 입력하여 출력되는 임상 결과의 클래스에 대한 예측값)

방법.

청구항 9

제8항에 있어서,

상기 임상 결과의 클래스에 대한 예측값은 하기 수학식 4의 형태로 구성되는,

[수학식 4]

$$\hat{Y}_{\text{clinic}} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{N_c}\} = \text{sigmoid}(\text{FFNN}(E_c; h_{N_t}))$$

(Ec는 텍스트 임베딩, h_{N_t} 는 모니터링 임베딩, FFNN는 feedforward neural network 함수, sigmoid는 시그모이드 함수, Nc는 진단 정보의 클래스 개수, 각 예측값의 밑첨자는 임상 결과의 클래스를 특정하는 인덱스)

방법.

청구항 10

명령어를 포함하는 메모리; 및

상기 명령어를 기초로 소정의 동작을 수행하는 프로세서를 포함하고,

상기 프로세서의 동작은,

환자에 대한 임상 노트에 포함된 텍스트 데이터 및 환자의 실시간 상태와 관련된 모니터링 데이터를 획득하는 동작;

상기 텍스트 데이터를 문장 단위로 나누고 셀프 어텐션 매커니즘을 수행하여 텍스트 임베딩을 추출하는 동작;

텍스트 임베딩으로부터 진단 정보를 예측하도록 학습된 제1 신경망에 환자의 텍스트 임베딩을 입력하여 예측 진단 정보를 출력시키는 동작;

순환 신경망을 이용하여 상기 모니터링 데이터로부터 모니터링 임베딩을 추출하는 동작; 및

상기 텍스트 임베딩 및 상기 모니터링 임베딩을 결합한 결합 임베딩을 생성하고, 결합 임베딩으로부터 임상 결과를 예측하도록 학습된 제2 신경망에 환자의 결합 임베딩을 입력하여 예측 임상 결과를 출력시키는 동작을 포함하는,

임상 결과 예측 장치.

발명의 설명

기술분야

[0001] 본 발명은 환자의 진단 정보 및 임상 결과를 예측하는 기술에 관한 것으로, 구체적으로 임상 노트 내 문장 간의 관계성을 분석하여 환자의 진단 정보를 예측하고, 임상 노트와 모니터링 정보를 결합하여 환자의 임상 결과를 예측하는 기술에 관한 것이다.

배경기술

[0002] 현대 의료 환경에서 환자의 데이터를 활용하여 질병의 진행과 임상 결과를 예측하는 기술은 의료진의 효율적인 의사결정을 지원하는 데 있어 핵심적인 역할을 하고 있다.

[0003] 기존의 환자 데이터 기반 임상 결과 예측 기술은 주로 전자건강기록(EHR, Electronic Health Records) 데이터를 활용하여 환자의 상태를 분석하고 예측하는 데 중점을 두어 왔다. 또한, 최근의 연구들은 자연어 처리 기술을 이용하여 환자의 데이터에서 유용한 정보를 추출하고 이를 분석하는 방법을 제안하고 있다.

[0004] 그러나 기존 기술에는 몇 가지 한계가 존재한다.

[0005] 대부분의 기존 기술은 정형화된 데이터나 단일 유형의 임상 데이터를 분석하는 데 초점을 맞추어, 다양한 임상 노트 간의 연관성을 충분히 고려하지 못하였다. 예를 들어, 간호 기록, 방사선 소견, 치료 절차 기록과 같은 다양한 종류의 임상 노트 간에는 서로 다른 정보들이 포함되어, 이들 간의 연관성을 파악하는 것은 정확한 예측을 위해 매우 중요하지만, 기존 기술은 이러한 연관성을 고려하지 않는다는 한계가 있다.

[0006] 또한, 입원 초기의 임상 데이터를 기반으로 퇴원 시 진단 정보를 예측하는 데 있어, 기존 기술은 초기 진단 정보와 최종 진단 정보 간의 불일치 문제를 간과하였다. 이러한 불일치는 환자의 최적화된 치료 방침 수립에 방해 요소로 작용하며, 재원 기간 증가와 비용 상승으로 이어질 수 있다.

[0007] 이에 따라, 다양한 임상 노트에 쓰여진 정보 간의 관계성을 분석하여 중요한 정보를 효과적으로 추출함으로써, 예측 결과를 보다 향상시킬 수 있는 새로운 기법에 대한 필요성이 대두되고 있다.

선행기술문헌

특허문헌

[0008] (특허문헌 0001) 대한민국 등록특허공보 제10-2635609호

발명의 내용

해결하려는 과제

[0009] 본 발명은 중환자실 환자의 입원 초기 데이터를 활용하여 환자의 진단 정보 및 임상 결과를 보다 정확하게 예측하고, 의료진의 의사 결정을 효과적으로 지원할 수 있는 기술을 구현하는 것을 목표로 한다. 이를 통해, 환자의 생존율을 높이고 병원의 자원을 효율적으로 관리할 수 있는 시스템을 제공하고자 한다.

[0010] 이를 위해, 본 발명은 입원 초기의 임상 데이터를 이용하여 진단 정보를 예측할 수 있도록 하는 보조 손실 학습 기법을 제안하여, 초기 진단 정보의 불완전성을 극복하면서 예측 정확도를 향상시키는 기술을 제공하고자 한다. 또한, 본 발명은 임상 노트의 비정형 텍스트를 분석하는 문장 단위의 셀프 어텐션 기법을 활용하여 다양한 임상 노트 간의 관계성과 중요도를 분석하고, 이를 통해 핵심 정보를 추출함으로써 환자의 상태를 보다 정밀하게 평가하는 기술을 제안한다.

[0011] 아울러, 본 발명은 임상 노트 데이터와 모니터링 데이터를 융합하여 환자의 임상 결과를 다각도로 분석할 수 있는 기반을 마련하고, 이를 통해 병원 내 사망률, 중환자실 체류 기간과 같은 임상 결과의 예측 성능을 크게 향상시키고자 한다. 또한, 본 발명은 예측 결과의 근거를 의료진에게 명확히 제공함으로써, 의료진이 결과를 신뢰하고 이를 기반으로 중요한 의사결정을 내릴 수 있도록 돕는 데 주안점을 두고 있다.

[0012] 이에 따라, 본 발명은 환자의 초기 데이터를 종합적으로 분석하여 진단의 정확성을 높이고 예측 결과에 대한 근거를 제공함으로써, 의료 현장에서 실질적으로 활용 가능한 기술적 기반을 제공하고자 한다. 이를 통해, 본 발명은 의료 서비스의 질을 향상시키고 환자의 생존율과 병원의 운영 효율성을 극대화하는 데 기여할 수 있을 것

으로 기대된다.

[0013] 한편, 본 발명의 기술적 과제들은 이상에서 언급한 기술적 과제들로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0014] 일 실시예에 따른 프로세서에 의해 동작하는 임상 결과 예측 장치가 수행하는 방법에 있어서, 환자에 대한 임상 노트에 포함된 텍스트 데이터 및 환자의 실시간 상태와 관련된 모니터링 데이터를 획득하는 동작; 상기 텍스트 데이터를 문장 단위로 나누고 셀프 어텐션 매커니즘을 수행하여 텍스트 임베딩을 추출하는 동작; 텍스트 임베딩으로부터 진단 정보를 예측하도록 학습된 제1 신경망에 환자의 텍스트 임베딩을 입력하여 예측 진단 정보를 출력시키는 동작; 순환 신경망을 이용하여 상기 모니터링 데이터로부터 모니터링 임베딩을 추출하는 동작; 및 상기 텍스트 임베딩 및 상기 모니터링 임베딩을 결합한 결합 임베딩을 생성하고, 결합 임베딩으로부터 임상 결과를 예측하도록 학습된 제2 신경망에 환자의 결합 임베딩을 입력하여 예측 임상 결과를 출력시키는 동작을 포함할 수 있다.

[0015] 또한, 상기 텍스트 임베딩을 추출하는 동작은 상기 텍스트 데이터를 구성하는 문장을 분리하는 동작; 분리된 각 문장을 사전 학습된 언어 모델에 입력하여 각 문장에 대한 임베딩을 추출하는 동작; 및 상기 각 문장의 임베딩을 트랜스포머 모델 기반의 셀프 어텐션 레이어에 입력하여 환자의 텍스트 임베딩을 추출하는 동작을 포함할 수 있다.

[0016] 또한, 상기 제1 신경망은 순방향 신경망(Feedforward Neural Network) 또는 완전 연결 신경망(Fully Connected Neural Network)의 구조로 설계되고, 학습용 텍스트 임베딩을 입력하여 출력되는 진단 정보의 클래스에 대한 예측값과, 환자의 진단 정보 정답 클래스 간의 손실이 크로스 엔트로피 손실 함수를 통해 최소화되도록 학습될 수 있다.

[0017] 또한, 상기 손실 함수는 하기 수학적 식 1로 구성될 수 있다.

[0018] [수학적 식 1]

$$L_{aux} = -\frac{1}{N_p} \frac{1}{N_d} \sum_{i=1}^{N_p} \sum_{j=1}^{N_d} y_{j, diag}^i \log(\hat{y}_{j, diag}^i)$$

[0019] (Laux은 제1 신경망의 손실 함수, Nd는 예측할 진단 정보 클래스의 개수, Np는 학습에 사용된 환자의 수,

[0020] $y_{j, diag}^i$ 는 환자의 진단 정보의 정답 클래스, $\hat{y}_{j, diag}^i$ 는 학습용 텍스트 임베딩을 입력하여 출력되는 진단 정보의 클래스에 대한 예측값)

[0021] 또한, 상기 진단 정보의 클래스에 대한 예측값은 하기 수학적 식 2의 형태로 구성될 수 있다.

[0022] [수학적 식 2]

$$\hat{Y}_{diag} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{N_d}\} = \text{sigmoid}(\text{FFNN}(E_c))$$

[0023] (Ec는 텍스트 임베딩, sigmoid는 시그모이드 함수, FFNN는 feedforward neural network 함수, Nd는 진단 정보의 클래스 개수, 각 예측값의 밀접자는 진단 정보의 클래스를 특징하는 인덱스)

[0025] 또한, 상기 모니터링 데이터는 소정의 시간 범위 동안 복수 개의 측정 항목에 대해 측정된 시계열 데이터를 포함하고, 상기 모니터링 임베딩을 추출하는 동작은, 순환 신경망에 상기 모니터링 데이터를 입력하여 상기 모니터링 데이터의 시계열 데이터가 반영되어 최종적으로 출력되는 데이터를 상기 환자의 모니터링 임베딩으로 추출하는 동작을 포함할 수 있다.

[0026] 또한, 상기 제2 신경망은 완전 연결 신경망의 구조로 설계되고, 학습용 결합 임베딩을 입력하여 출력되는 임상

결과의 클래스에 대한 예측값과, 환자의 진단 정보 정답 클래스 간의 손실이 크로스 엔트로피 손실 함수를 통해 최소화되도록 학습될 수 있다.

[0027] 또한, 상기 손실 함수는 하기 수학식 3으로 구성될 수 있다.

[0028] [수학식 3]

$$L_{\text{main}} = -\frac{1}{N_p} \frac{1}{N_c} \sum_{i=1}^{N_p} \sum_{j=1}^{N_c} y_{j, \text{clinic}}^i \log(\hat{y}_{j, \text{clinic}}^i)$$

[0029]

[0030] (Lmain은 제2 신경망의 손실 함수, Nc는 예측할 임상 결과 클래스의 개수, Np는 학습에 사용된 환자의 수,

$y_{j, \text{clinic}}^i$ 는 환자의 임상 결과 정답 클래스, $\hat{y}_{j, \text{clinic}}^i$ 는 학습용 융합 임베딩을 입력하여 출력되는 임상 결과의 클래스에 대한 예측값)

[0031] 또한, 상기 임상 결과의 클래스에 대한 예측값은 하기 수학식 4의 형태로 구성될 수 있다.

[0032] [수학식 4]

$$\hat{Y}_{\text{clinic}} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{N_c}\} = \text{sigmoid}(\text{FFNN}(E_c; h_{N_t}))$$

[0033]

[0034] (Ec는 텍스트 임베딩, h_{N_t} 는 모니터링 임베딩, FFNN는 feedforward neural network 함수, sigmoid는 시그모이드 함수, Nc는 진단 정보의 클래스 개수, 각 예측값의 밑첨자는 임상 결과의 클래스를 특정하는 인덱스)

[0035] 일 실시예에 따른 임상 결과 예측 장치는 명령어를 포함하는 메모리; 및 상기 명령어를 기초로 소정의 동작을 수행하는 프로세서를 포함하고, 상기 프로세서의 동작은 환자에 대한 임상 노트에 포함된 텍스트 데이터 및 환자의 실시간 상태와 관련된 모니터링 데이터를 획득하는 동작; 상기 텍스트 데이터를 문장 단위로 나누고 셀프 어텐션 매커니즘을 수행하여 텍스트 임베딩을 추출하는 동작; 텍스트 임베딩으로부터 진단 정보를 예측하도록 학습된 제1 신경망에 환자의 텍스트 임베딩을 입력하여 예측 진단 정보를 출력시키는 동작; 순환 신경망을 이용하여 상기 모니터링 데이터로부터 모니터링 임베딩을 추출하는 동작; 및 상기 텍스트 임베딩 및 상기 모니터링 임베딩을 결합한 결합 임베딩을 생성하고, 결합 임베딩으로부터 임상 결과를 예측하도록 학습된 제2 신경망에 환자의 결합 임베딩을 입력하여 예측 임상 결과를 출력시키는 동작을 포함할 수 있다.

발명의 효과

[0036] 본 발명은 중환자실 환자의 입원 초기 데이터를 활용하여, 환자의 진단 정보와 임상 결과를 보다 정확하고 신뢰성 있게 예측함으로써, 의료 현장에서 중요한 효과를 제공할 수 있다. 입원 초기 데이터란 텍스트로 구성된 임상 노트와 vital sign 등 continuous monitoring data의 모니터링 데이터를 일컫는다.

[0037] 이를 위해, 본 발명은 입원 초기의 제한적인 데이터를 기반으로 진단 정보를 예측하는 보조 손실 학습 기법을 통해 초기 진단 정보의 불완전성을 극복하며, 이를 통해 진단 정보 예측의 정확도를 향상시킬 수 있다. 또한, 본 발명은 임상 노트의 비정형 텍스트를 분석하는 문장 단위의 셀프 어텐션 기법을 활용하여 임상노트 내 문장들 간의 관계성과 중요도를 분석함으로써, 의료진이 작성한 다양한 임상 기록 간의 연관성을 종합적으로 고려할 수 있게 한다. 이를 통해, 노이즈가 많은 임상 데이터 속에서 중요한 정보를 효과적으로 추출할 수 있으며 의료진의 의사 결정 과정에서 유용한 근거를 제공할 수 있다.

[0038] 또한, 본 발명은 임상 노트 데이터와 환자의 심박수, 호흡률, 혈압 등의 모니터링 데이터를 융합하여 환자의 임상 결과를 다각적으로 분석할 수 있는 기반을 제공하여, 병원 내 사망률, 중환자실 내 체류 기간 등의 예측 정확도를 기존 기술보다 크게 향상시킬 수 있다.

[0039] 따라서, 본 발명은 진단 정보의 불완전성과 초기 임상 데이터 활용의 제한성을 극복할 수 있으며, 임상 데이터를 종합적으로 분석하여 의료진의 의사 결정을 지원하고 환자의 생존율을 향상시킬 수 있는 효과를 제공할 수 있다. 이는 병원의 자원을 효율적으로 관리할 수 있도록 돕는 동시에, 의료 서비스의 질을 한층 높이는 데 기여할 것이다.

[0040] 한편, 본 발명에 의한 효과는 이상에서 언급한 것들로 제한되지 않으며, 언급되지 않은 또 다른 기술적 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0041] 도 1은 일 실시예에 따른 임상 결과 예측 장치의 구성도이다.

도 2는 일 실시예에 따른 임상 결과 예측 장치가 수행하는 동작의 단계를 나타낸 흐름도이다.

도 3은 일 실시예에 따른 임상 결과 예측 장치가 이용하는 다양한 인코더 및 신경망 모델의 구성과, 도 2의 동작에 따라 임상 결과 예측 장치가 처리하는 데이터의 흐름을 나타낸 개념도이다.

도 4는 S1020의 단계를 세분화하여 나타낸 예시도이다.

도 5는 일 실시예에 따른 제1 신경망의 학습 과정을 나타낸 예시도이다.

도 6은 S1040의 단계를 세분화하여 나타낸 예시도이다.

도 7은 일 실시예에 따른 제2 신경망의 학습 과정을 나타낸 예시도이다.

도 8은 본 발명이 사용하는 신경망 모델에 대한 설계 정보의 예시도이다.

도 9는 기존 연구 기법과 본 발명을 이용하여 임상 결과 예측 성능을 비교한 성능 비교표이다.

발명을 실시하기 위한 구체적인 내용

[0042] 본 발명의 목적과 기술적 구성 및 그에 따른 작용 효과에 관한 자세한 사항은 본 발명의 명세서에 첨부된 도면에 의거한 이하의 상세한 설명에 의해 보다 명확하게 이해될 것이다. 첨부된 도면을 참조하여 본 발명에 따른 실시예를 상세하게 설명한다.

[0043] 본 명세서에서 개시되는 실시예들은 본 발명의 범위를 한정하는 것으로 해석되거나 이용되지 않아야 할 것이다. 이 분야의 통상의 기술자에게 본 명세서의 실시예를 포함한 설명은 다양한 응용을 갖는다는 것이 당연하다. 따라서, 본 발명의 상세한 설명에 기재된 임의의 실시예들은 본 발명을 보다 잘 설명하기 위한 예시적인 것이며 본 발명의 범위가 실시예들로 한정되는 것을 의도하지 않는다.

[0044] 도면에 표시되고 아래에 설명되는 기능 블록들은 가능한 구현의 예들일 뿐이다. 다른 구현들에서는 상세한 설명의 사상 및 범위를 벗어나지 않는 범위에서 다른 기능 블록들이 사용될 수 있다. 또한, 본 발명의 하나 이상의 기능 블록이 개별 블록들로 표시되지만, 본 발명의 기능 블록들 중 하나 이상은 동일 기능을 실행하는 다양한 하드웨어 및 소프트웨어 구성들의 조합일 수 있다.

[0045] 또한, 어떤 구성요소들을 포함한다는 표현은 “개방형”의 표현으로서 해당 구성요소들이 존재하는 것을 단순히 지칭할 뿐이며, 추가적인 구성요소들을 배제하는 것으로 이해되어서는 안 된다.

[0046] 나아가 어떤 구성요소가 다른 구성요소에 “연결되어” 있다거나 “접속되어” 있다고 언급될 때에는, 그 다른 구성요소에 직접적으로 연결 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 한다.

[0047] 이하, 본 발명의 다양한 실시예가 첨부된 도면을 참조하여 기재된다. 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 실시예의 다양한 변경(modification), 균등물(equivalent), 및/또는 대체물(alternative)을 포함하는 것으로 이해되어야 한다.

[0048] 본 발명은 다양한 임상 노트에 쓰여진 텍스트 정보 간의 관계성을 분석하여 환자의 진단 정보를 예측하고, 임상 노트와 모니터링 정보를 결합해 주요한 정보를 효과적으로 추출함으로써 환자의 임상 결과를 보다 정확하게 예측하는 기술을 제안한다.

[0049] 이하, 본 발명의 임상 결과 예측 장치(100)에 대한 구성과, 각 구성의 동작을 살펴보도록 한다.

- [0050] 도 1은 일 실시예에 따른 임상 결과 예측 장치(100)(이하, '장치(100)'로 지칭)의 구성도이다.
- [0051] 도 1을 참조하면, 일 실시예에 따른 장치(100)는 각각 메모리(110), 프로세서(120), 입출력 인터페이스(130) 및 통신 인터페이스(140)를 포함할 수 있다.
- [0052] 메모리(110)는 외부 장치로부터 획득한 데이터 또는 스스로 생성한 데이터를 저장할 수 있다. 메모리(110)는 프로세서(120)의 동작을 수행시킬 수 있는 명령어들을 저장할 수 있다. 예를 들어, 메모리(110)는 Bio+ClinicalBERT와 같은 언어 신경망 모델, 트랜스포머 모델의 셀프 어텐션 인코더, BiGRU 모델과 같은 순환 신경망 모델, 완전 연결 네트워크로 구성된 제1 신경망 및 제2 신경망 등을 저장할 수 있다.
- [0053] 프로세서(120)는 전반적인 동작을 제어하는 연산 장치이다. 프로세서(120)는 메모리(110)에 저장된 명령어들을 실행할 수 있다. 본 문서의 실시예에 따른 사용자 단말(10) 및 장치(100)의 동작은 프로세서(120)에 의해 수행되는 동작으로 이해될 수 있다.
- [0054] 입출력 인터페이스(130)는 정보를 입력하거나 출력하는 하드웨어 인터페이스 또는 소프트웨어 인터페이스를 포함할 수 있다.
- [0055] 통신 인터페이스(140)는 통신망을 통해 정보를 송수신 할 수 있게 한다. 이를 위해, 통신 인터페이스(140)는 무선 통신모듈 또는 유선 통신모듈을 포함할 수 있다.
- [0056] 장치(100)는 프로세서(120)를 통해 연산을 수행하고 네트워크를 통해 정보를 송수신할 수 있는 다양한 형태의 장치로 구현될 수 있다. 예를 들면, 서버, 컴퓨터 장치, 휴대용 통신 장치, 스마트 폰, 휴대용 멀티미디어 장치, 노트북, 태블릿 PC 등의 형태로 구현될 수 있으나, 이러한 예시에 한정되는 것은 아니다.
- [0057] 도 2는 일 실시예에 따른 장치(100)가 수행하는 동작의 흐름도이다. 도 3은 일 실시예에 따른 장치(100)가 이용하는 다양한 인코더 및 신경망 모델의 구성과, 도 2의 동작에 따라 장치(100)가 처리하는 데이터의 흐름을 나타낸 개념도이다. 도 2 및 도 3의 실시예에 따른 장치(100)의 동작은 프로세서(120)에 의해 수행되는 동작으로 이해될 수 있다.
- [0058] 도 3에 도시된 전체 구조는 본 발명에서 사용되는 복수의 인코더와 신경망 모델들의 구성을 나타낸다. 즉, 본 발명에서 사용하는 신경망 모델은 하나의 모델로 구성된 것이 아니라, 도 3의 구조와 같이 복수의 인코더와 신경망 모델의 상호 작용에 의해 동작하는 구조로 설계된다. 도 3의 구조에 포함된 인코더 및 신경망 모델 중 일부는 사전 학습된 모델(Pre-trained Model)이 적용될 수 있다. 또한, 도 3의 구조에 포함된 인코더 및 신경망 모델 중 일부는 초기 모델을 직접 학습시켜 사용될 수 있다. 이하, 본 발명을 설명하면서 사전 학습된 모델을 사용하는 실시예의 경우는 사전 학습 모델의 예시를 함께 설명하며, 초기 모델을 학습시켜 사용하는 실시예의 경우에는 해당 초기 모델의 학습 방법을 함께 설명하기로 한다.
- [0059] 한편, 도 2 및 도 3에 개시된 각 단계는 본 발명의 목적을 달성함에 있어서 바람직한 실시예일 뿐이며, 필요에 따라 일부 단계가 추가 또는 삭제될 수 있음은 물론이고, 어느 한 단계가 다른 단계에 포함되어 수행될 수도 있다. 도 2 및 도 3에 개시된 각 동작의 순서는 이해의 편의를 위해 배치된 순서일 뿐, 이러한 순서가 시계열적인 순서로 한정되는 것이 아니며, 설계자의 선택에 따라 순서가 다르게 변경되어 동작될 수 있다.
- [0060] 도 2 및 도 3을 함께 참조하면, S1010 단계에서, 장치(100)는 환자에 대한 임상 노트에 포함된 텍스트 데이터 및 환자의 실시간 상태와 관련된 모니터링 데이터를 획득할 수 있다.
- [0061] 임상 노트란, 의료진이 환자의 진단, 치료 계획, 증상, 관찰 사항, 소견 등을 기록한 텍스트 기반의 데이터를 의미한다. 임상 노트는 환자의 입원 초기(예: 입원 첫날)에 관찰된 하나 이상의 임상 노트에 대한 텍스트 데이터를 포함할 수 있다. 예를 들어, 하나 이상의 임상 노트는 의사의 진단 기록, 간호사의 간호 기록, 방사선 소견 등을 포함할 수 있다. 임상 노트는 환자 상태에 대한 서술적 정보를 제공하며, 의료진의 판단과 경험을 반영하는 중요한 자료로 사용될 수 있다. 텍스트 데이터란, 임상 노트에 포함된 문장 및 문맥적 정보를 지칭하며, 환자의 상태와 진단에 관한 언어적 표현으로 구성될 수 있다.
- [0062] 모니터링 데이터란, 환자의 실시간 상태와 관련하여 지속적으로 관측될 수 있는 데이터를 의미한다. 예를 들어, 모니터링 데이터는 심박수, 혈압, 호흡률, 산소 포화도, 체온 등 환자의 생리학적 상태를 나타내는 정보를 포함할 수 있다. 또한, 모니터링 데이터는 체혈이나 소변 검사 등 어떠한 수치로 기록되는 모든 데이터를 포함할 수 있다. 모니터링 데이터는 센서를 통해 환자로부터 수집될 수 있으며, 시간에 따른 변화 패턴을 기반으로 환자의 상태를 평가하는 데에 사용될 수 있다.

- [0063] S1020 단계에서, 장치(100)는 S1010에서 획득된 텍스트 데이터를 문장 단위로 나누고, 각 문장에 대해 셀프 어텐션 매커니즘을 수행하여 텍스트 임베딩을 추출할 수 있다. S1020 단계에 대한 구체적인 실시예는 다음 도 4와 같다.
- [0064] 도 4는 S1020의 단계를 세분화하여 나타낸 예시도이다.
- [0065] 도 4를 참조하면, S1021 단계에서, 장치(100)는 OCR(Optical Character Recognition)과 같은 텍스트 인식 기술을 활용하여 임상 노트에 포함된 텍스트 데이터를 인식하고, 인식한 텍스트 데이터를 문장 기준으로 분리할 수 있다. OCR 기술은 스캔된 문서 또는 비정형 텍스트 데이터를 디지털 텍스트 형식으로 변환하는 데 사용된다. 이처럼, OCR은 임상 노트가 종이 문서, 이미지 파일, 또는 PDF와 같은 비구조화된 형태로 저장되는 경우에도 이를 디지털화하여 처리할 수 있도록 한다.
- [0066] S1022 단계에서, 장치(100)는 분리된 각 문장을 사전 학습된 언어 모델에 입력하여 각 문장에 대한 임베딩을 추출할 수 있다. 일 예로, 사전 학습된 언어 모델은 Bio+ClinicalBERT을 포함할 수 있다. Bio+ClinicalBERT 모델은 BERT(Bidirectional Encoder Representations from Transformers) 기반의 사전 학습된 언어 모델로, 생의학 및 임상 데이터를 처리하도록 특화되어 있다. Bio+ClinicalBERT는 PubMed, MIMIC-III 등 생의학 및 임상 도메인의 텍스트를 학습하여, 해당 도메인에서 사용되는 용어와 문맥적 관계를 더 잘 이해할 수 있다. 이를 통해 Bio+ClinicalBERT 모델은 각 문장의 의미를 벡터화하고, 의료와 관련된 중요한 특징을 반영한 고차원 임베딩을 생성할 수 있다.
- [0067] S1023 단계에서, 장치(100)는 각 문장의 임베딩을 트랜스포머(Transformer) 모델 기반의 셀프 어텐션(Self-Attention) 레이어에 입력하여 환자에 대한 임상 노트의 텍스트 데이터에 대한 텍스트 임베딩을 추출할 수 있다.
- [0068] 여기서, 셀프 어텐션 레이어는 입력된 문장 임베딩들 간의 상호 관계를 파악하여, 각 문장의 중요도와 연관성을 반영하여 텍스트 임베딩을 생성할 수 있다. 즉, 장치(100)는 셀프 어텐션 레이어를 통해 임상 노트 전체에서 각 문장의 문맥적 관계를 고려한 정보가 효과적으로 추출되어 결합된 텍스트 임베딩을 생성할 수 있다.
- [0069] S1030 단계에서, 장치(100)는 텍스트 임베딩으로부터 진단 정보를 예측하도록 학습된 제1 신경망에 환자의 텍스트 임베딩을 입력하여 예측 진단 정보를 출력시킬 수 있다. 여기서, 진단 정보란 환자의 건강 상태를 평가하여 환자의 질환이나 상태를 특정한 정보이다. 예를 들어, 진단 정보에 대한 클래스는 심부전, 당뇨병, 고혈압 등과 같은 질환명의 클래스로 구성될 수 있다.
- [0070] 일 예로, 제1 신경망은 학습용 텍스트 임베딩과, 학습용 텍스트 임베딩의 정답 클래스(= 환자의 진단 정보 정답 클래스)를 이용한 지도 학습을 통해, 입력된 텍스트 임베딩으로부터 진단 정보를 예측하도록 학습될 수 있다. 제1 신경망의 학습에 대한 구체적인 실시예는 다음 도 5와 같다.
- [0071] 도 5는 일 실시예에 따른 제1 신경망의 학습 과정을 나타낸 예시도이다.
- [0072] 도 5를 참조하면, 제1 신경망은 완전 연결 신경망 또는 순방향 신경망의 구조로 설계될 수 있고, 학습용 텍스트 임베딩을 입력하여 출력되는 진단 정보의 클래스에 대한 예측값과, 환자의 진단 정보 정답 클래스 간의 손실이 크로스 엔트로피 손실 함수를 통해 최소화되도록 지도 학습될 수 있다.
- [0073] 예를 들어, 제1 신경망의 손실 함수는 하기 수학적 식 1로 구성될 수 있다.
- [0074] [수학적 식 1]

$$L_{aux} = -\frac{1}{N_p} \frac{1}{N_d} \sum_{i=1}^{N_p} \sum_{j=1}^{N_d} y_{j, diag}^i \log(\hat{y}_{j, diag}^i)$$

- [0075]
- [0076] (L_{aux} 은 제1 신경망의 손실 함수, N_d 는 예측할 진단 정보 클래스의 개수, N_p 는 학습에 사용된 환자의 수,

$y_{j, diag}^i$ 는 환자의 진단 정보의 정답 클래스(예: 퇴원 시 기록된 진단 정보), $\hat{y}_{j, diag}^i$ 는 학습용

텍스트 임베딩을 입력하여 출력되는 진단 정보의 클래스에 대한 예측값)

[0077] 또한, 수학식 1의 진단 정보의 클래스에 대한 예측값은 하기 수학식 2의 형태로 구성될 수 있다.

[0078] [수학식 2]

$$\hat{Y}_{diag} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{N_d}\} = \text{sigmoid}(\text{FFNN}(E_c))$$

[0079]

[0080] (E_c 는 텍스트 임베딩, sigmoid는 시그모이드 함수, FFNN는 feedforward neural network 함수, N_d 는 진단 정보의 클래스 개수, 각 예측값의 밑첨자는 진단 정보의 클래스를 특정하는 인덱스)

[0081] S1040 단계에서, 장치(100)는 순환 신경망을 이용하여 모니터링 데이터로부터 모니터링 임베딩을 추출할 수 있다. S1040 단계에 대한 구체적인 실시예는 다음 도 6과 같다.

[0082] 도 6은 S1040의 단계를 세분화하여 나타낸 예시도이다.

[0083] 도 6을 참조하면, 모니터링 데이터는 소정의 시간 범위 동안 복수 개의 측정 항목(예: 심전도, 심박수, 혈압 등)에 대해 측정된 시계열 데이터를 포함할 수 있다. 이때 장치(100)는 순환 신경망 중 하나로서 BiGRU(Bidirectional Gated Recurrent Unit) 모델에 모니터링 데이터를 입력하여, BiGRU 모델을 통해 모니터링 데이터의 시계열적 정보가 분석되어 최종적으로 출력되는 데이터를 환자의 모니터링 임베딩으로 추출할 수 있다. 즉, 장치(100)는 양방향 순환 신경망 구조를 갖춘 BiGRU 모델을 이용하여, 모니터링 데이터의 시계열적 상관 관계를 반영한 모니터링 임베딩을 생성할 수 있다.

[0084] 이처럼, BiGRU 모델과 같은 순환 신경망은 후술할 제1 신경망 및 제2 신경망과 함께 도 3의 구조에서 종단간 학습을 통해 생성된 모델을 포함할 수 있다. BiGRU 모델은 Clinical outcomes 예측 손실을 기반으로 종단간 학습이 수행되어 추론 단계에 사용될 수 있다. Clinical outcomes 예측 손실이란 환자의 임상 결과를 예측하기 위해 모델이 학습하는 과정에서 사용되는 손실 함수(loss function)를 의미한다. 이 손실 함수는 모델의 예측값과 실제 관측값 간의 차이를 측정하고, 이를 최소화하는 방향으로 모델을 최적화하는 데 사용된다. 이에 따라, BiGRU 모델은 환자의 생체 신호와 관련된 시계열 데이터를 시간적 흐름에 따라 정밀하게 분석할 수 있다.

[0085] S1050 단계에서, 장치(100)는 텍스트 임베딩 및 모니터링 임베딩을 결합한 결합 임베딩을 생성하고, 결합 임베딩으로부터 임상 결과를 예측하도록 학습된 제2 신경망에 환자의 결합 임베딩을 입력하여 예측 임상 결과를 출력할 수 있다. 여기서, 임상 결과란 의료 행위, 치료 과정, 또는 질병의 경과로 인해 나타나는 환자 및 관련된 결과 정보를 의미한다. 예를 들어, 임상 결과에 대한 클래스는 병원 내 사망 가능성, 중환자실 내 체류 기간, 퇴원 후 재입원 여부 등의 클래스로 구성될 수 있다.

[0086] 일 예로, 제2 신경망은 학습용 결합 임베딩과, 학습용 결합 임베딩의 정답 클래스(= 환자의 임상 결과 정답 클래스)를 이용한 지도 학습을 통해, 입력된 결합 임베딩으로부터 임상 결과를 예측하도록 학습될 수 있다. 제2 신경망의 학습에 대한 구체적인 실시예는 다음 도 7과 같다.

[0087] 도 7은 일 실시예에 따른 제2 신경망의 학습 과정을 나타낸 예시도이다.

[0088] 도 7을 참조하면, 제2 신경망은 완전 연결 신경망의 구조로 설계될 수 있고, 학습용 결합 임베딩을 입력하여 출력되는 임상 결과의 클래스에 대한 예측값과, 환자의 임상결과 정답 클래스 간의 손실이 크로스 엔트로피 손실 함수를 통해 최소화되도록 지도 학습될 수 있다.

[0089] 예를 들어, 제2 신경망의 손실 함수는 하기 수학식 3으로 구성될 수 있다.

[0090] [수학식 3]

$$L_{main} = -\frac{1}{N_p} \frac{1}{N_c} \sum_{i=1}^{N_p} \sum_{j=1}^{N_c} y_{j, clinic}^i \log(\hat{y}_{j, clinic}^i)$$

[0091]

[0092] (L_{main} 은 제2 신경망의 손실 함수, N_c 는 예측할 임상 결과 클래스의 개수, N_p 는 학습에 사용된 환자의 수,

$y_{j, \text{clinic}}^i$ 는 환자의 임상 결과 정답 클래스, $\hat{y}_{j, \text{clinic}}^i$ 는 학습용 융합 임베딩을 입력하여 출력되는 임상 결과의 클래스에 대한 예측값)

[0093] 또한, 수학적 식 3의 임상 결과의 클래스에 대한 예측값은 하기 수학적 식 4의 형태로 구성될 수 있다.

[0094] [수학적 식 4]

$$\hat{Y}_{\text{clinic}} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_{N_c}\} = \text{sigmoid}\left(\text{FFNN}(E_c; h_{N_t})\right)$$

[0095]

[0096] (E_c 는 텍스트 임베딩, h_{N_t} 는 모니터링 임베딩, FFNN는 feedforward neural network 함수, sigmoid는 시그모이드 함수, N_c 는 진단 정보의 클래스 개수, 각 예측값의 밑첨자는 임상 결과의 클래스를 특정하는 인덱스)

[0097] 도 8은 본 발명이 사용하는 신경망 모델에 대한 설계 정보의 예시도이다.

[0098] 도 8을 참조하면, 장치(100)는 도 2의 단계를 수행하기 이전에, 도 3에 포함된 신경망들의 학습 과정으로서 BiGRU 및 셀프어텐션 레이어에 대한 하이퍼파라미터를 도 8의 정보와 같이 세팅하고, BiGRU 모델, 제1 신경망 및 제2 신경망의 중단간 학습을 수행할 수 있다. 중단간 학습을 수행하는 경우, 장치(100)는 전체 구조의 손실 함수를 하기 수학적 식 5와 같이 구성할 수 있다.

[0099] [수학적 식 5]

$$L = \alpha L_{\text{main}} + \beta L_{\text{aux}}$$

[0100]

[0101] (L 은 중단간 학습의 손실 함수, L_{aux} 은 제1 신경망의 손실 함수, L_{main} 은 제2 신경망의 손실 함수, α 는 제1

신경망 손실의 반영 비율을 특정하는 하이퍼파라미터, β 는 제2 신경망 손실의 반영 비율을 특정하는 하이퍼파라미터)

[0102] 즉, 수학적 식 5에 따르면, 중단간 학습의 손실 함수는 제1 신경망의 손실과 제2 신경망의 손실에 대한 가중합으로 구성될 수 있다. 이때 제2 신경망의 손실은 임상 결과 예측과 관련된 주요 학습 목표를 반영할 수 있고, 제1 신경망의 손실은 보조 손실로서 진단 정보 예측과 같은 보조 학습 목표를 반영할 수 있다.

[0103] 도 9는 기존 연구 기법과 본 발명(DESAM-cp)을 이용하여 임상 결과 예측 성능을 비교한 성능 비교표이다.

[0104] 도 9에서 각 기법의 성능은 AUROC(Area Under the Receiver Operating Characteristic curve) 와 AUPRC(Area Under the Precision-Recall Curve) 지표를 통해 평가되었다.

[0105] 도 9를 참조하면, 본 발명(DESAM-cp)은 병원 내 사망률(In-hospital mortality), 중환자실 내 사망률(In-ICU mortality), 3일 이상 입원(LOS > 3 days), 7일 이상 입원(LOS > 7 days) 등 모든 임상 결과에 대한 예측값에 대해서 기존의 기법보다 뛰어난 예측 정확도를 달성하였음을 확인할 수 있다.

[0106] 상술한 실시예에 따르면, 본 발명은 중환자실 환자의 입원 초기 데이터와 모니터링 데이터를 활용하여, 환자의 진단 정보와 임상 결과를 보다 정확하고 신뢰성 있게 예측함으로써, 의료 현장에서 중요한 효과를 제공할 수 있다.

[0107] 이를 위해, 본 발명은 입원 초기의 제한적인 데이터를 기반으로 진단 정보를 예측하는 보조 손실 학습 기법을 통해 초기 진단 정보의 불완전성을 극복하며, 이를 통해 진단 정보 예측의 정확도를 향상시킬 수 있다. 또한, 본 발명은 임상 노트의 비정형 텍스트를 분석하는 문장 단위의 셀프 어텐션 기법을 활용하여 임상노트 내 문장들 간의 관계성과 중요도를 분석함으로써, 의료진이 작성한 다양한 임상 기록 간의 연관성을 종합적으로 고려할 수 있게 한다. 이를 통해, 노이즈가 많은 임상 데이터 속에서 중요한 정보를 효과적으로 추출할 수 있으며 의료

진의 의사 결정 과정에서 유용한 근거를 제공할 수 있다.

- [0108] 또한, 본 발명은 임상 노트 데이터와 환자의 심박수, 호흡률, 혈압 등의 모니터링 데이터를 융합하여 환자의 임상 결과를 다각적으로 분석할 수 있는 기반을 제공하여, 병원 내 사망률, 중환자실 내 체류 기간 등의 예측 정확도를 기존 기술보다 크게 향상시킬 수 있다.
- [0109] 따라서, 본 발명은 진단 정보의 불완전성과 초기 임상 데이터 활용의 제한성을 극복할 수 있으며, 임상 데이터를 종합적으로 분석하여 의료진의 의사 결정을 지원하고 환자의 생존율을 향상시킬 수 있는 효과를 제공할 수 있다. 이는 병원의 자원을 효율적으로 관리할 수 있도록 돕는 동시에, 의료 서비스의 질을 한층 높이는 데 기여할 것이다.
- [0110] 본 문서의 다양한 실시예들 및 이에 사용된 용어들은 본 문서에 기재된 기술적 특징들을 특정한 실시예들로 한정하려는 것이 아니며, 해당 실시예의 다양한 변경, 균등물, 또는 대체물을 포함하는 것으로 이해되어야 한다. 도면의 설명과 관련하여, 유사한 또는 관련된 구성요소에 대해서는 유사한 참조 부호가 사용될 수 있다. 아이템에 대응하는 명사의 단수 형은 관련된 문맥상 명백하게 다르게 지시하지 않는 한, 아이템 한 개 또는 복수 개를 포함할 수 있다.
- [0111] 본 문서에서, "A 또는 B", "A 및 B 중 적어도 하나", "A 또는 B 중 적어도 하나," "A, B 또는 C," "A, B 및 C 중 적어도 하나," 및 "A, B, 또는 C 중 적어도 하나"와 같은 문구들 각각은 그 문구들 중 해당하는 문구에 함께 나열된 항목들의 모든 가능한 조합을 포함할 수 있다. "1", "제2", 또는 "첫째" 또는 "둘째"와 같은 용어들은 단순히 해당 구성요소를 다른 해당 구성요소와 구분하기 위해 사용될 수 있으며, 해당 구성요소들을 다른 측면(예: 중요성 또는 순서)에서 한정하지 않는다. 어떤(예: 제1) 구성요소가 다른(예: 제2) 구성요소에, "기능적으로" 또는 "통신적으로"라는 용어와 함께 또는 이런 용어 없이, "커플드" 또는 "커넥티드"라고 언급된 경우, 그것은 어떤 구성요소가 다른 구성요소에 직접적으로(예: 유선으로), 무선으로, 또는 제3 구성요소를 통하여 연결될 수 있다는 것을 의미한다.
- [0112] 본 문서에서 사용된 용어 "모듈"은 하드웨어, 소프트웨어 또는 펌웨어로 구현된 유닛을 포함할 수 있으며, 예를 들면, 로직, 논리 블록, 부품, 또는 회로 등의 용어와 상호 호환적으로 사용될 수 있다. 모듈은, 일체로 구성된 부품 또는 하나 또는 그 이상의 기능을 수행하는, 부품의 최소 단위 또는 그 일부가 될 수 있다. 예를 들면, 일 실시예에 따르면, 모듈은 ASIC(application-specific integrated circuit)의 형태로 구현될 수 있다.
- [0113] 본 문서의 다양한 실시예들은 기기(예: 전자 장치)에 의해 읽을 수 있는 저장 매체(예: 메모리)에 저장된 하나 이상의 명령어들을 포함하는 소프트웨어(예: 프로그램)로서 구현될 수 있다. 저장 매체는 RAM(random access memory), 메모리 버퍼, 하드 드라이브, 데이터베이스, EPROM(erasable programmable read-only memory), EEPROM(electrically erasable read-only memory), ROM(read-only memory) 및/또는 등등을 포함할 수 있다.
- [0114] 또한, 본 문서의 실시예들의 프로세서는, 저장 매체로부터 저장된 하나 이상의 명령어들 중 적어도 하나의 명령어를 호출하고, 그것을 실행할 수 있다. 이것은 기기가 호출된 적어도 하나의 명령어에 따라 적어도 하나의 기능을 수행하도록 운영되는 것을 가능하게 한다. 이러한 하나 이상의 명령어들은 컴파일러에 의해 생성된 코드 또는 인터프리터에 의해 실행될 수 있는 코드를 포함할 수 있다. 프로세서는 범용 프로세서, FPGA(Field Programmable Gate Array), ASIC(Application Specific Integrated Circuit), DSP(Digital Signal Processor) 및/또는 등등 일 수 있다.
- [0115] 기기로 읽을 수 있는 저장매체는, 비일시적(non-transitory) 저장매체의 형태로 제공될 수 있다. 여기서, '비일시적'은 저장매체가 실재(tangible)하는 장치이고, 신호(예: 전자기파)를 포함하지 않는다는 것을 의미할 뿐이며, 이 용어는 데이터가 저장매체에 반영구적으로 저장되는 경우와 임시적으로 저장되는 경우를 구분하지 않는다.
- [0116] 본 문서에 개시된 다양한 실시예들에 따른 방법은 컴퓨터 프로그램 제품(computer program product)에 포함되어 제공될 수 있다. 컴퓨터 프로그램 제품은 상품으로서 판매자 및 구매자 간에 거래될 수 있다. 컴퓨터 프로그램 제품은 기기로 읽을 수 있는 저장 매체(예: compact disc read only memory (CD-ROM))의 형태로 배포되거나, 또는 어플리케이션 스토어(예: 플레이 스토어)를 통해 또는 두 개의 사용자 장치들(예: 스마트폰들) 간에 직접, 온라인으로 배포(예: 다운로드 또는 업로드)될 수 있다. 온라인 배포의 경우에, 컴퓨터 프로그램 제품의 적어도 일부는 제조사의 서버, 어플리케이션 스토어의 서버, 또는 서버의 메모리와 같은 기기로 읽을 수 있는 저장 매체에 적어도 일시 저장되거나, 임시적으로 생성될 수 있다.
- [0117] 다양한 실시예들에 따르면, 기술한 구성요소들의 각각의 구성요소(예: 모듈 또는 프로그램)는 단수 또는 복수의

개체를 포함할 수 있다. 다양한 실시예들에 따르면, 전술한 해당 구성요소들 중 하나 이상의 구성요소들 또는 동작들이 생략되거나, 또는 하나 이상의 다른 구성요소들 또는 동작들이 추가될 수 있다. 대체적으로 또는 추가적으로, 복수의 구성요소들(예: 모듈 또는 프로그램)은 하나의 구성요소로 통합될 수 있다. 이런 경우, 통합된 구성요소는 복수의 구성요소들 각각의 구성요소의 하나 이상의 기능들을 통합 이전에 복수의 구성요소들 중 해당 구성요소에 의해 수행되는 것과 동일 또는 유사하게 수행할 수 있다. 다양한 실시예들에 따르면, 모듈, 프로그램 또는 다른 구성요소에 의해 수행되는 동작들은 순차적으로, 병렬적으로, 반복적으로, 또는 휴리스틱하게 실행되거나, 동작들 중 하나 이상이 다른 순서로 실행되거나, 생략되거나, 또는 하나 이상의 다른 동작들이 추가될 수 있다.

부호의 설명


- 100: 장치
- 110: 메모리
- 120: 프로세서
- 130: 입출력 인터페이스
- 140: 통신 인터페이스

도면


도면1




도면2




도면3




도면4




도면5



도면6



도면7



도면8

BiGRU – hidden dimension	128 for each direction (합 256)
Transformer encoder hidden dimension	512 , 8 head, 6 layers
Maximum sentence length	512
Dropout rate	0.2
Batch size	32
Learning rate	1e-4
optimizer	Adam optimizer
Weight decay	5e-6
Early stopping	10 에포크 이상 validation loss가 안떨어질 시

도면9

COMPARISON OF PERFORMANCE RESULTS BETWEEN DESAM-CP AND PREVIOUS WORK FOR CLINICAL OUTCOME PREDICTIONS

Method	In-hospital mortality		In-ICU mortality		LOS > 3 days		LOS > 7 days	
	AUROC	AUPRC	AUROC	AUPRC	AUROC	AUPRC	AUROC	AUPRC
Califorest (Park and Ho.[6])	0.8624 (±0.0084)	0.5377 (±0.0169)	0.8686 (±0.0078)	0.4916 (±0.0074)	0.770 (±0.0018)	0.8129 (±0.0069)	0.8291 (±0.0022)	0.666 (±0.0104)
Khadanga et al.[7]	0.8534 (±0.0042)	0.5272 (±0.0101)	0.8604 (±0.004)	0.4682 (±0.0092)	0.7599 (±0.0041)	0.8019 (±0.0041)	0.8202 (±0.0028)	0.6363 (±0.013)
Denzabi et al.[8]	0.8599 (±0.0082)	0.5403 (±0.017)	0.8682 (±0.0101)	0.485 (±0.0172)	0.7608 (±0.005)	0.8038 (±0.0059)	0.8226 (±0.0041)	0.6412 (±0.0172)
Bardak and Tan[9]	0.8772 (±0.0029)	0.5778 (±0.0053)	0.8822 (±0.0024)	0.5197 (±0.0047)	0.7663 (±0.0029)	0.8056 (±0.0024)	0.8273 (±0.0024)	0.6447 (±0.0109)
PM ² F ² N (Zhang et al.[10])	0.8803 (±0.0108)	0.5787 (±0.0294)	0.8814 (±0.01)	0.5172 (±0.0187)	0.7788 (±0.0054)	0.8158 (±0.0042)	0.8112 (±0.0194)	0.6152 (±0.0342)
DESAM-cp (Ours)	0.9005 (±0.0024)	0.6295 (±0.0099)	0.9048 (±0.0026)	0.5681 (±0.0106)	0.7835 (±0.0057)	0.8232 (±0.0045)	0.8513 (±0.0024)	0.6787 (±0.0109)