

(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)(11) 공개번호 10-2023-0013485  
(43) 공개일자 2023년01월26일

(51) 국제특허분류(Int. Cl.)

G16H 50/50 (2018.01) G06N 3/04 (2023.01)  
G06N 3/08 (2023.01) G16H 10/40 (2018.01)  
G16H 10/60 (2018.01) G16H 50/20 (2018.01)  
G16H 50/70 (2018.01)

(52) CPC특허분류

G16H 50/50 (2018.01)  
G06N 3/042 (2023.01)

(21) 출원번호 10-2021-0094286

(22) 출원일자 2021년07월19일

심사청구일자 2021년07월19일

(71) 출원인

고려대학교 산학협력단

서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)

(72) 발명자

석홍일

서울특별시 성북구 길음로 118, 411동 1202호(길음동, 길음뉴타운)

이유립

서울특별시 동대문구 천호대로 23, 621호(신설동, 동광동대문메르빌)

(74) 대리인

송인호, 윤형근, 최관락


전체 청구항 수 : 총 6 항

(54) 발명의 명칭 불규칙 임상 시계열 데이터 예측 및 분류 방법, 및 장치

## (57) 요약

불규칙 임상 시계열 데이터 예측 및 분류 방법, 및 장치가 개시된다. 불규칙 임상 시계열 데이터 예측 및 분류 장치는, 불규칙한 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터를 통합하여 상기 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성하는 다시점 통합 자가주의 모듈; 상기 심층 표현을 이용하여 보조적인 결측 대체값을 생성하는 보조 해석부; 및 상기 심층 표현을 이용하여 환자 상태 예측 또는 진단을 분류하는 예측 및 분류기를 포함한다.

대표도 - 도1



(52) CPC특허분류

G06N 3/049 (2023.01)

G06N 3/08 (2023.01)

G16H 10/40 (2021.08)

G16H 10/60 (2021.08)

G16H 50/20 (2018.01)

G16H 50/70 (2018.01)

이 발명을 지원한 국가연구개발사업

|             |                          |
|-------------|--------------------------|
| 과제고유번호      | 1711126017               |
| 과제번호        | 2017-0-00053-005         |
| 부처명         | 과학기술정보통신부                |
| 과제관리(전문)기관명 | 정보통신기획평가원                |
| 연구사업명       | 한국전자통신연구원연구개발지원(R&D)     |
| 연구과제명       | 심혈관질환을 위한 인공지능 주치의 기술 개발 |
| 기 여 율       | 2/3                      |
| 과제수행기관명     | 한국전자통신연구원                |
| 연구기간        | 2021.01.01 ~ 2021.12.31  |

이 발명을 지원한 국가연구개발사업

|             |                         |
|-------------|-------------------------|
| 과제고유번호      | 1711126110              |
| 과제번호        | 2019-0-00079-003        |
| 부처명         | 과학기술정보통신부               |
| 과제관리(전문)기관명 | 정보통신기획평가원               |
| 연구사업명       | 정보통신방송혁신인재양성            |
| 연구과제명       | 인공지능대학원지원(고려대학교)        |
| 기 여 율       | 1/3                     |
| 과제수행기관명     | 고려대학교산학협력단              |
| 연구기간        | 2021.01.01 ~ 2021.12.31 |

---

## 명세서

### 청구범위

#### 청구항 1

불규칙한 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터를 통합하여 상기 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성하는 다시점 통합 자가주의 모듈;

상기 심층 표현을 이용하여 보조적인 결측 대체값을 생성하는 보조 해석부; 및

상기 심층 표현을 이용하여 환자 상태 예측 또는 진단을 분류하는 예측 및 분류기를 포함하는 불규칙 임상 시계열 데이터 예측 및 분류 장치.

#### 청구항 2

제1 항에 있어서,

상기 예측 및 분류기 학습시, 상기 보조적인 결측 대체값이 더 이용되는 것을 특징으로 하는 불규칙 임상 시계열 데이터 예측 및 분류 장치.

#### 청구항 3

제1 항에 있어서,

상기 다시점 통합 자가주의 모듈은,

상기 불규칙 임상 시계열 데이터, 상기 관측 여부 데이터 및 상기 시간 정보 데이터 각각을 임베딩하여 각각의 특징값을 구하고, 자가주의 매커니즘을 이용하여 상기 관측 여부 데이터와 상기 시간 정보 데이터의 특징값을 통합하여 결측 패턴 정보를 생성하고, 상기 결측 패턴 정보와 상기 불규칙 임상 시계열 데이터를 자가주의 블록을 이용하여 통합한 후 순방향 신경망(FFN: feed-forward network) 모듈에 적용하여 상기 심층 표현을 생성하는 것을 특징으로 하는 불규칙 임상 시계열 데이터 예측 및 분류 장치.

#### 청구항 4

제1 항에 있어서,

상기 보조 해석부는,

상기 불규칙한 임상 시계열 데이터 중 일부를 마스킹한 후 상기 심층 표현을 이용하여 마스킹된 값을 복원하여 보조적인 결측 대체값을 생성하는 것을 특징으로 하는 불규칙 임상 시계열 데이터 예측 및 분류 장치.

#### 청구항 5

(a) 불규칙한 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터를 통합하여 상기 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성하는 단계;

(b) 상기 불규칙한 임상 시계열 데이터 중 일부를 마스킹한 후 상기 심층 표현을 이용하여 마스킹된 값을 복원하여 보조적인 결측 대체값을 생성하는 단계; 및

(c) 상기 심층 표현 및 상기 보조적인 결측 대체값을 이용하여 환자 상태 예측 또는 진단을 분류하는 예측 및 분류기 모델을 학습시키는 단계를 포함하는 불규칙 임상 시계열 데이터 예측 및 분류 방법.

## 청구항 6

제5 항에 있어서,

상기 (a) 단계는,

상기 불규칙 임상 시계열 데이터, 상기 관측 여부 데이터 및 상기 시간 정보 데이터 각각을 임베딩하여 각각의 특징값을 구하는 단계;

제1 자가주의 모듈을 기반으로 상기 관측 여부 데이터와 상기 시간 정보 데이터의 특징값을 통합하여 결측 패턴 정보를 생성하는 단계; 및

제2 자가주의 모듈을 기반으로 상기 불규칙한 임상 시계열 데이터의 특징값과 상기 결측 패턴 정보를 통합한 후 순방향 신경망(FFN: feed-forward network)에 적용하여 결측 패턴에 대한 심층 표현을 생성하는 단계를 포함하는 것을 특징으로 하는 불규칙 임상 시계열 데이터 예측 및 분류 방법.

## 발명의 설명

### 기술 분야

[0001] 본 발명은 불규칙 임상 시계열 데이터 예측 및 분류 방법, 및 장치에 관한 것이다.

### 배경 기술

[0003] 전자 건강 데이터(EHR: electronic health data, 이하 EHR이라 칭하기로 함)는 진단, 활력 징후, 실험실 테스트 기록, 절차 및 텍스트 설명과 같은 환자의 건강 데이터 모음이다. 최근 10년 동안 풍부한 건강 데이터 세트에 의해 다변수 EHR 시계열을 사용하여 딥 러닝 모델을 개발하는데 상당한 진전이 있었다.

[0004] 특히 EHR을 포함하는 임상 데이터는 시간적, 측정 변수적으로 큰 불규칙성을 보일 뿐만 아니라 높은 결측률로 인해 환자 상태를 예측하고 분류하는데 낮은 성능을 보이고 있다.

[0005] 기계학습 모델을 이용하여 측정값의 특징을 추출하여 예측하는 연구가 많이 진행되었지만, 결측값의 대체나 불규칙 데이터를 규칙형으로 바꾸는 등의 추가적인 데이터의 전처리가 이루어져야 한다는 한계가 존재한다.

[0006] 최근의 딥러닝 기법은 특징의 추출과 예측 및 분류를 동시에 할 수 있다는 장점이 있기 때문에 다양한 자연어처리 등의 다른 분야에서 각광을 받았고 동시에 많은 발전을 보였다. 그러나 딥러닝 기법을 임상 시계열 데이터 분류 분야에서의 예측 및 분류에 사용하기에는 불규칙성이나 높은 결측률 등의 요인 때문에 한계가 존재한다.

## 발명의 내용

### 해결하려는 과제

[0008] 본 발명은 불규칙 임상 시계열 데이터 예측 및 분류 방법, 및 장치를 제공하기 위한 것이다.

[0009] 또한, 본 발명은 자가주의 메커니즘(self-attention mechanism)을 기반으로 결측값이 높고 불규칙적인 임상 데이터와 이에 포함된 결측 패턴 정보를 함께 모델링하여 예측 및 분류 결과 제공이 가능한 불규칙 임상 시계열 데이터 예측 및 분류 방법, 및 장치를 제공하기 위한 것이다.

[0010] 또한, 본 발명은 불규칙적 임상 시계열 데이터와 그에서 파생된 결측 패턴에 대한 정보를 자가주의 메커니즘 기반의 방법으로 통합하여 데이터에 대한 추가적인 전처리 없이 예측 및 분류의 성능을 향상시킬 수 있는 불규칙 임상 시계열 데이터 예측 및 분류 방법, 및 장치를 제공하기 위한 것이다.

## 과제의 해결 수단

- [0012] 본 발명의 일 측면에 따르면, 불규칙 임상 시계열 데이터 예측 및 분류 장치가 제공된다.
- [0013] 본 발명의 일 실시예에 따르면, 규칙한 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터를 통합하여 상기 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성하는 다시점 통합 자가주의 모듈; 상기 심층 표현을 이용하여 보조적인 결측 대체값을 생성하는 보조 해석부; 및 상기 심층 표현을 이용하여 환자 상태 예측 또는 진단을 분류하는 예측 및 분류기를 포함하는 불규칙 임상 시계열 데이터 예측 및 분류 장치가 제공될 수 있다.
- [0014] 상기 예측 및 분류기 학습시, 상기 보조적인 결측 대체값이 더 이용될 수 있다.
- [0015] 상기 다시점 통합 자가주의 모듈은, 상기 불규칙 임상 시계열 데이터, 상기 관측 여부 데이터 및 상기 시간 정보 데이터 각각을 임베딩하여 각각의 특징값을 구하고, 자가주의 메커니즘을 이용하여 상기 관측 여부 데이터와 상기 시간 정보 데이터의 특징값을 통합하여 결측 패턴 정보를 생성하고, 상기 결측 패턴 정보와 상기 불규칙 임상 시계열 데이터를 자가주의 블록을 이용하여 통합한 후 순방향 신경망(FFN: feed-forward network) 모듈에 적용하여 상기 심층 표현을 생성할 수 있다.
- [0016] 상기 보조 해석부는, 상기 불규칙한 임상 시계열 데이터 중 일부를 마스킹한 후 상기 심층 표현을 이용하여 마스킹된 값을 복원하여 보조적인 결측 대체값을 생성할 수 있다.
- [0018] 본 발명의 다른 측면에 따르면, 불규칙 임상 시계열 데이터 예측 및 분류 방법이 제공된다.
- [0019] 본 발명의 일 실시예에 따르면, (a) 불규칙한 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터를 통합하여 상기 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성하는 단계; (b) 상기 불규칙한 임상 시계열 데이터 중 일부를 마스킹한 후 상기 심층 표현을 이용하여 마스킹된 값을 복원하여 보조적인 결측 대체값을 생성하는 단계; 및 (c) 상기 심층 표현 및 상기 보조적인 결측 대체값을 이용하여 환자 상태 예측 또는 진단을 분류하는 예측 및 분류기 모델을 학습시키는 단계를 포함하는 불규칙 임상 시계열 데이터 예측 및 분류 방법이 제공될 수 있다.
- [0020] 상기 (a) 단계는, 상기 불규칙 임상 시계열 데이터, 상기 관측 여부 데이터 및 상기 시간 정보 데이터 각각을 임베딩하여 각각의 특징값을 구하는 단계; 제1 자가주의 모듈을 기반으로 상기 관측 여부 데이터와 상기 시간 정보 데이터의 특징값을 통합하여 결측 패턴 정보를 생성하는 단계; 및 제2 자가주의 모듈을 기반으로 상기 불규칙한 임상 시계열 데이터의 특징값과 상기 결측 패턴 정보를 통합한 후 순방향 신경망(FFN: feed-forward network)에 적용하여 결측 패턴에 대한 심층 표현을 생성하는 단계를 포함할 수 있다.

## 발명의 효과

- [0022] 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 분류, 예측 방법 및 장치를 제공함으로써, 자가주의 메커니즘(self-attention mechanism)을 기반으로 결측값이 높고 불규칙적인 임상 데이터와 이에 포함된 결측 패턴 정보를 함께 모델링하여 정확한 예측 및 분류 결과 제공이 가능한 이점이 있다.
- [0023] 또한, 본 발명은 불규칙적 임상 시계열 데이터와 그에서 파생된 결측 패턴에 대한 정보를 자가주의 메커니즘 기반의 방법으로 통합하여 데이터에 대한 추가적인 전처리 없이 예측 및 분류의 성능을 향상시킬 수 있는 이점이 있다.

## 도면의 간단한 설명

- [0025] 도 1은 본 발명의 일 실시예에 따른 불규칙한 임상 시계열 데이터 예측 및 분류를 위한 장치의 구성을 개략적으로 도시한 도면.
- 도 2는 본 발명의 일 실시예에 따른 다시점 통합 자가주의 모듈의 내부 구성을 개략적으로 도시한 도면.
- 도 3은 본 발명의 일 실시예에 따른 보조 해석부의 내부 구성을 개략적으로 도시한 블록도.
- 도 4는 본 발명의 일 실시예에 따른 불규칙한 임상 시계열 데이터 예측 및 분류 방법을 위한 의사 코드를 도시

한 도면.

도 5는 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 분류, 예측 방법을 나타낸 순서도.

### 발명을 실시하기 위한 구체적인 내용

[0026] 본 명세서에서 사용되는 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "구성된다" 또는 "포함한다" 등의 용어는 명세서상에 기재된 여러 구성 요소들, 또는 여러 단계들을 반드시 모두 포함하는 것으로 해석되지 않아야 하며, 그 중 일부 구성 요소들 또는 일부 단계들은 포함되지 않을 수도 있고, 또는 추가적인 구성 요소 또는 단계들을 더 포함할 수 있는 것으로 해석되어야 한다. 또한, 명세서에 기재된 "...부", "모듈" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어 또는 소프트웨어로 구현되거나 하드웨어와 소프트웨어의 결합으로 구현될 수 있다.

[0027] 이하, 첨부된 도면들을 참조하여 본 발명의 실시예를 상세히 설명한다.

[0029] 도 1은 본 발명의 일 실시예에 따른 불규칙한 임상 시계열 데이터 예측 및 분류를 위한 장치의 구성을 개략적으로 도시한 도면이고, 도 2는 본 발명의 일 실시예에 따른 다시점 통합 자가주의 모듈의 내부 구성을 개략적으로 도시한 도면이고, 도 3은 본 발명의 일 실시예에 따른 보조 해석부의 내부 구성을 개략적으로 도시한 블록도이며, 도 4는 본 발명의 일 실시예에 따른 불규칙한 임상 시계열 데이터 예측 및 분류 방법을 위한 의사 코드를 도시한 도면이다.

[0030] 도 1을 참조하면, 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 예측 및 분류 장치(100)는 다시점 통합 자가주의 모듈(110), 보조 해석부(120), 예측 및 분류기(130), 메모리(140) 및 프로세서(150)를 포함하여 구성된다.

[0031] 다시점 통합 자가주의 모듈(110)은 불규칙한 임상 시계열 데이터, 관측 여부 데이터, 시간 정보 데이터를 각각 입력 데이터로 입력받은 후 이를 순차적으로 통합하여 특징을 찾은 후 순방향 신경망 모델에 적용하여 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성하기 위한 수단이다.

[0032] 다시점 통합 자가주의 모듈(110)은 데이터 임베딩부(210), 통합 모듈(220) 및 순방향 신경망 모듈(230)을 포함하여 구성된다.

[0034] 각 서브젝트  $n$ 에 대해,  $T_n$  길이의 시점  $\mathbf{t}^{(n)} = [t_1, \dots, t_j, \dots, t_{T_n}]$ 의  $D$ -차원 다변량 시계열 집합이 주어지면, 관측 시계열을  $\mathbf{X}^{(n)} = [\mathbf{x}_{t_1}^{(n)}, \dots, \mathbf{x}_{t_j}^{(n)}, \dots, \mathbf{x}_{t_{T_n}}^{(n)}]^\top \in \mathbb{R}^{T_n \times D}$ 와 같이 나타내기로 한다. 여기서,  $\mathbf{x}_{t_j}^{(n)} \in \mathbb{R}^D$ 는 모든 변수의  $t$ 번째 관측을 나타내고,  $x_{t_j,d}^{(n)}$ 는  $\mathbf{x}_{t_j}^{(n)}$  내의  $d$ 번째 엘리먼트를 나타낸다.

[0035] 시계열 데이터  $\mathbf{X}^{(n)}$ 은 결측값(missing values)를 포함하기 때문에, 시계열 데이터에 대해 관측 또는 결측 변수를 마크하기 위해  $\mathbf{X}^{(n)}$ 과 동일한 사이즈를 가지는 관측 여부 정보(즉, 결측 지표(missing indicator))  $\mathbf{M}^{(n)} = [\mathbf{m}_{t_1}^{(n)}, \dots, \mathbf{m}_{t_j}^{(n)}, \dots, \mathbf{m}_{t_{T_n}}^{(n)}]^\top \in \mathbb{R}^{T_n \times D}$ 를 도입하기로 한다.

[0036] 관측 여부 데이터는 만일  $x_{t_j,d}^{(n)}$ 이 관측되면,  $m_{t_j,d}^{(n)} = 1$ 이며, 그렇지 않은 경우  $m_{t_j,d}^{(n)} = 0$ 과 같이 생성될 수 있다. 또한, 불규칙 임상 시계열 데이터의 관측이 결측되는 경우, 입력은  $\mathbf{x}_{t_j}^{(x)}$  내에 상응하는 요소에 대해 제로(0)으로 설정될 수 있다. 각 변수  $d$ 에 대해 시간 간격을  $\Delta^{(n)} = [\delta_{t_1}^{(n)}, \dots, \delta_{t_j}^{(n)}, \dots, \delta_{t_{T_n}}^{(n)}]^\top$ 로 나타내기로 한다. 여기서,  $\delta_{t_j,d}^{(n)} \in \mathbb{R}$ 은 수학적 1과 같이 정

의될 수 있다.

### 수학식 1

$$\delta_{t_j,d}^{(n)} = \begin{cases} t_j - t_{j-1} + \delta_{t_{j-1},d}^{(n)}, & t_j > 1, m_{t_{j-1},d}^{(n)} = 0 \\ t_j - t_{j-1}, & t_j > 1, m_{t_{j-1},d}^{(n)} = 1 \\ 0, & t_j = 1. \end{cases}$$

[0037]

[0038] 불규칙 임상 시계열 데이터셋이  $\mathcal{D} = \{(\mathbf{X}^{(n)}, \mathbf{M}^{(n)}, \Delta^{(n)})\}_{n=1}^N$  와 같이 주어지면, 예측 라벨  $(y_1, \dots, y_N)$  정의를 위한 매핑 함수 구축이 가능하다.

[0039] 데이터 임베딩부(210)는 각 입력 데이터(즉, 불규칙한 임상 시계열 데이터, 관측 여부 데이터, 시간 정보 데이터)를 각각 임베딩하여 특징값을 도출한다. 다시점 통합 자가주의 모듈(110)은 연속적인 시간 값을 입력으로 취하는 위치 인코딩의 변형으로 시간 임베딩(TE: time embedding)을 사용하고, 시간 임베딩을 인코딩 벡터 표현으로 변환할 수 있다.

[0040] 이를 통해, 정확한 시점과 시간 간격을 고려하여 불규칙하게 샘플링된 임상 시계열 데이터를 처리할 수 있다.

[0041] 시간 임베딩은 수학식 2와 같이 나타낼 수 있다.

### 수학식 2

$$\text{TE}_{(t,d)} = \begin{cases} \sin\left(\frac{t}{L_{\max}^{2d/d_{\text{model}}}}\right) & \text{if } d \text{ is even} \\ \cos\left(\frac{t}{L_{\max}^{2d/d_{\text{model}}}}\right) & \text{if } d \text{ is odd} \end{cases}$$

[0042]

[0043] 여기서,  $t$ ,  $d$ ,  $d_{\text{model}}$  및  $L_{\max}$  는 각각 정확한 시간 포인트, 변수의 인덱스, 모델 차원, 데이터의 최대 시간 길이를 나타낸다. 시간 임베딩은 학습된 입력 임베딩에 추가될 수 있다. 이를 수학식으로 나타내면 수학식 3 내지 수학식 5와 같다.

### 수학식 3

$$\mathbf{X}^* = \mathbf{W}_X \mathbf{X} + \text{TE}(t, d)$$

[0044]

### 수학식 4

$$\mathbf{M}^* = \mathbf{W}_M \mathbf{M} + \text{TE}(t, d)$$

[0045]

### 수학식 5

$$\Delta^* = W_{\Delta} \Delta + TE(t, d)$$

여기서,  $W_X, W_M, W_{\Delta}$  는 각각 다시점 입력에 대한 상응하는 임베딩 가중치 행렬을 나타낸다.

종래에는 결측 지표와 시간 간격과 같은 결측치의 소스를 활용할뿐, 결측 데이터의 표현(representation)을 학습하지 않음으로써, 결측에 대한 부적절한 모델링으로 인해 신뢰할 수 없는 평가와 측정 변경에 강건하지 않은 모델 생성으로 이어지는 문제점이 있었다.

따라서, 본 발명의 일 실시예에서는 결측 지표와 시간 간격을 모두 효과적으로 활용하여 불규칙한 임상 시계열 데이터의 심층 표현을 학습할 수 있다.

모든 시간에서, D 측정값이 주어지는 경우, 다시점 통합 자가주의 모듈(110)은 불규칙 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터에 대한 입력 데이터의 임베딩하고, 이를 통해 각 입력 데이터(즉, 불규칙 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터)에 대한 특징값을 구할 수 있다.

다시점 통합 자가주의 모듈(110)은 쿼리(Q), 키(K) 및 값(V) 집합에 대해 스케일된 도트 프로덕트 어텐션(scaled dot-product attention)이 계산되는 다중헤드 자가주의 블록(MHA: multi-head attention)을 기반으로 한다.

자가주의 블록에 기초하여 관측 X를 포함하는 다시점 불규칙 임상 시계열 데이터의 어텐션 표현(attention representation)이 학습될 수 있다.

예를 들어, 각 입력 집합  $(X^*, M^*, \Delta^*)$  은 자가주의 블록을 통해 자신의 표현  $(H^X, H^M, H^{\Delta})$  을 학습할 수 있다. 여기서, 각 데이터 포인트는 자체 가중치 행렬과 선형적으로 결합되어 해당하는 Q, K 및 V로 공급될 수 있다.

각 입력 데이터에 대한 어텐션 표현은 수학식 6 내지 수학식 8과 같이 수학식으로 정리될 수 있다.

### 수학식 6

$$H^X = \sigma \left( \frac{(W_{X^*}^Q X^*)(W_{X^*}^K X^*)^T}{\sqrt{d_k}} \right) (W_{X^*}^V X^*)$$

### 수학식 7

$$H^M = \sigma \left( \frac{(W_{M^*}^Q M^*)(W_{M^*}^K M^*)^T}{\sqrt{d_k}} \right) (W_{M^*}^V M^*)$$

### 수학식 8

$$\mathbf{H}^{\Delta} = \sigma \left( \frac{(\mathbf{W}_{\Delta}^{\mathbf{Q}} \Delta^*)(\mathbf{W}_{\Delta}^{\mathbf{K}} \Delta^*)^{\top}}{\sqrt{d_k}} \right) (\mathbf{W}_{\Delta}^{\mathbf{V}} \Delta^*)$$

[0057]

[0058] 여기서,  $\mathbf{W}$ 는 학습 가능한 가중치 행렬의 집합을 나타내고,  $\sigma$ 는 SoftMax 활성화 함수를 나타내고,  $d_k$ 는 키 벡터의 차원을 나타낸다.

[0059] 통합 모듈(220)은 자가주의 블록에 의존하며, 입력 데이터의 특징값들을 통합하기 위한 수단이다.

[0060] 통합 모듈(220)은 입력 데이터 중 관측 여부 데이터와 시간 정보 데이터의 임베딩된 특징값을 통합하여 복잡한 결측 패턴 정보를 생성할 수 있다. 또한, 통합 모듈(220)은 불규칙한 임상 시계열 데이터의 특징값과 결측 패턴 정보를 표현 공간에서 결합할 수 있다.

[0061] 이와 같이, 결측 자체로부터 기본 표현을 학습하면 결측값을 전가할 필요가 없으며, 어떠한 휴리스틱한 함수를 특정할 필요가 없다.

[0062] 따라서, 통합 모듈(220)은 두 단계의 통합 과정(제1 통합 단계, 제2 통합 단계)가 수반될 수 있다. 이에 대해 보다 상세히 설명하기로 한다.

[0063] 즉, 제1 통합 단계에서, 통합 모듈(220)은 제1 자가주의 블록을 이용하여 시간 정보 데이터에 기초한 시간 간격의 표현과 관측 여부 데이터에 기반한 결측 지표의 표현을 통합하여 결측 패턴의 표현( $\mathbf{H}^{\text{miss}}$ )을 획득할 수 있다. 이를 수학식으로 나타내면 수학식 9와 같다.

### 수학식 9

$$\mathbf{H}^{\text{miss}} = \sigma \left( \frac{(\mathbf{W}_{\Delta}^{\mathbf{Q}} \mathbf{H}^{\Delta})(\mathbf{W}_{\mathbf{M}}^{\mathbf{K}} \mathbf{H}^{\mathbf{M}})^{\top}}{\sqrt{d_k}} \right) (\mathbf{W}_{\mathbf{M}}^{\mathbf{V}} \mathbf{H}^{\mathbf{M}})$$

[0064]

[0065] 제2 통합 단계에서, 통합 모듈(220)은 제2 자가주의 블록을 이용하여 불규칙한 임상 시계열 데이터와 결측 패턴 정보의 표현을 통합할 수 있다. 이를 수학식으로 나타내면 수학식 10과 같다.

### 수학식 10

$$\mathbf{H}^{\text{obs-miss}} = \sigma \left( \frac{(\mathbf{W}_{\text{miss}}^{\mathbf{Q}} \mathbf{H}^{\text{miss}})(\mathbf{W}_{\mathbf{X}}^{\mathbf{K}} \mathbf{H}^{\mathbf{X}})^{\top}}{\sqrt{d_k}} \right) (\mathbf{W}_{\mathbf{X}}^{\mathbf{V}} \mathbf{H}^{\mathbf{X}})$$

[0066]

[0067] 상술한 바와 같이, 통합 모듈(220)은 복수의 자가주의 모듈을 기반으로, 입력 데이터들을 순차적으로 통합할 수 있다.

[0068] 통합 모듈(220)에 의해 입력 데이터들이 순차적으로 통합된 결과는 순방향 신경망 모듈(230)로 입력되며, 순방향 신경망 모듈(230)을 통해 불규칙한 임상 시계열 데이터와 통합된 결측 패턴 간의 관계를 모델링하여 공동 학습된 심층 표현을 출력할 수 있다.

[0069] 순방향 신경망 모듈(230)은 변수간의 종속성을 모델링하도록 각 시점에 동일하게 적용될수 있다.

[0070] 최종 심층 표현  $\tilde{\mathbf{H}}$  은 보조적인 결측 대체값 생성 및 환자 상태 예측 또는 진단을 분류에 이용될 수 있다.

[0071] 보조 해석부(120)는 다시점 통합 자가주의 모듈(110)에서 출력된 심층 표현( $\tilde{\mathbf{H}}$ )을 이용하여 보조적인 결측 대체값을 생성하기 위한 수단이다.

[0072] 보조 해석부(120)는 불규칙한 임상 시계열 데이터의 일부를 고의로 마스킹한 후 다시점 통합 자가주의 모듈(110)에서 생성된 최종 심층 표현을 이용하여 마스킹한 값을 복원하는 과정을 통해 보조적인 결측 대체값을 생성할 수 있다.

[0073] 보조 해석부(120)의 상세 구조는 도 3에 도시된 바와 같다.

[0074] 도 3에 도시된 바와 같이, 보조 해석부(120)는 다중헤드 자가주의 모듈(310)과 순방향 신경망 모듈(320)을 포함하여 구성된다.

[0075] 보조 해석부(120)는 쿼리로서 다시점 통합 자가주의 모듈(110)에서 출력된 심층 표현( $\tilde{\mathbf{H}}$ )과 키와 값으로 불규칙 임상 시계열 데이터( $\mathbf{H}^{\mathbf{X}}$ ) 사이의 다중헤드 자가주의 모듈(310)을 적용하고, 순방향 신경망 모듈(320)을 뒤에 배치할 수 있다.

[0076] 출력 계층은 학습된 임베딩 행렬( $\mathbf{W}_{\mathbf{X}}$ )을 사용하여 타겟 시간 시퀀스에 매핑되고, 대치된 데이터( $\hat{\mathbf{X}}$ )를 생성할 수 있다. 이를 수학식으로 나타내면 수학식 11과 같다.

### 수학식 11

$$\hat{\mathbf{X}} = \mathbf{W}_{\mathbf{X}}^{\top} \times \text{FFN} \left( \sigma \left( \frac{(\mathbf{W}_{\tilde{\mathbf{H}}}^{\mathbf{Q}} \tilde{\mathbf{H}})(\mathbf{W}_{\mathbf{X}}^{\mathbf{K}} \mathbf{H}^{\mathbf{X}})^{\top}}{\sqrt{d_k}} \right) (\mathbf{W}_{\mathbf{X}}^{\mathbf{V}} \mathbf{H}^{\mathbf{X}}) \right)$$

[0077]

[0078] 마스킹된 값을 표시하기 위해 도입된 다른 마스킹 벡터  $\mathbf{M}_{\text{imp}}$  가 주어지면, 전가 손실  $\mathcal{L}_{\text{imp}}$  은 불규칙한 임상 시계열 데이터(X)와  $\mathbf{M}_{\text{imp}}$  에 의해 마스킹된 값을 위한 전가된 샘플( $\hat{\mathbf{X}}$ ) 사이의 마스킹된 평균 제곱 에러(MSE: mean squared error)에 의해 계산될 수 있다.

[0079] 이를 수학식으로 나타내면, 수학식 12와 같다.

### 수학식 12

$$\mathcal{L}_{\text{imp}} = \frac{1}{N} \sum_{n=1}^N \left( \mathbf{X}^{(n)} \odot \mathbf{M}_{\text{imp}}^{(n)} - \hat{\mathbf{X}}^{(n)} \odot \mathbf{M}_{\text{imp}}^{(n)} \right)^2.$$

[0080]

[0081] 목적 함수에 전가 손실을 도입하여 최적의 예측 결과를 달성하기 위한 보조적인 정보 제공이 가능케 할 수 있다.

[0082] 합성 손실은 예측 및 전가 손실을 누적하여 수학식 13과 같이 정의될 수 있다.

### 수학식 13

$$\mathcal{L} = \lambda_{\text{pred}} \mathcal{L}_{\text{pred}} + \lambda_{\text{imp}} \mathcal{L}_{\text{imp}}$$

여기서,  $\lambda_{\text{pred}}$  와  $\lambda_{\text{imp}}$  는 두 손실 사이의 비율 조절을 위한 하이퍼매개변수를 나타낸다.

합성 손실( $\mathcal{L}$ )을 통해 단대단(end-to-end) 방식으로 모델의 모든 매개변수가 최적화될 수 있다.

예측 및 분류기(130)는 다시점 통합 자가주의 모듈(110)로부터 출력된 최종 심층 표현을 기반으로 환자 상태 예측 또는 진단을 분류하기 위한 수단이다.

예측 및 분류기(130)는 학습시 심층 표현과 보조 해석부(120)에 의해 출력된 보조적인 결측 대체값을 이용하여 학습될 수 있다. 예측 및 분류기(130)는 심층 표현과 보조적인 결측 대체값을 이용하여 보조적인 결측 대체값에 대한 손실값이 최소가 되도록 학습될 수 있다.

보조적인 결측 대체값은 예측 및 분류기(130)의 학습에만 이용되며, 학습이 완료된 이후에는 이용되지 않을 수 있다.

예측 및 분류기(130)는 심층 표현을 기반으로 환자 상태를 예측하거나 진단을 분류할 수 있다.

예를 들어, 예측 및 분류기(130)는 병원내 사망률이나 LOS 예측을 수행할 수 있다.

병원내 사망률 예측은 환자가 입원 기간 동안 사망했는지 또는 퇴원할 예정인지를 나타내는 이진 분류로, 자에 대한 타겟 라벨은  $\mathbf{y} = (y_1, \dots, y_N | y_n \in \{0, 1\})$  과 같다.

LOS 예측은 환자의 입원과 입원 종료 사이의 일수를 예측하는 회귀 작업일 수 있다.

최종 심층 표현( $\tilde{\mathbf{H}}$ )이 주어지면, 타임스탬프에 대한 평균 풀링을 수행하고, 풀링된 최종 표현( $\hat{\mathbf{h}}$ ) 다음에 다층 퍼셉트론(MLP)가 뒤 따른다. 최종 계층은 특정 작업에 따라 달라지며 분류 및 다중 레이블 분류에 시그모이드 계층이 사용될 수 있다.

예측 및 분류기(130)는 의료 데이터의 특성상 불균형한 데이터에서의 열악한 분류 성능 문제를 해결하기 위해 각 환자의 타겟 레이블( $\mathbf{y}$ )과 예측된 레이블( $\hat{\mathbf{y}}$ ) 사이의 분류 손실을 계산하기 위해 수학식 14 내지 수학식 16과 같은 목적 함수를 이용할 수 있다.

이진 분류 손실 수학식 14를 이용하여 계산될 수 있다.

### 수학식 14

$$\frac{1}{N} \sum_{n=1}^N -\beta(1 - \hat{y}^{(n)})^\gamma \log(\hat{y}^{(n)})$$

회귀 손실은 수학식 15를 이용하여 계산될 수 있다.

### 수학식 15

$$\sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{y}^{(n)} - y^{(n)})^2}$$

[0098]

[0099] 다중 레벨 분류 손실은 수학식 16을 이용하여 계산될 수 있다.

### 수학식 16

$$\frac{1}{N} \sum_{n=1}^N \left( \frac{1}{K} \sum_{k=1}^K -\beta(1 - \hat{y}^{(n)})^\gamma \log(\hat{y}^{(n)}) \right)$$

[0100]

[0101] 여기서, N은 전체 환자의 수를 나타내고, K는 데이터베이스내의 라벨의 전체 수를 나타내며,  $\gamma$ 는 마이너리티 클래스를 위한 포커싱 매개변수를 나타내며,  $\beta$ 는 클래스간의 중요도 균형을 위한 가중치를 나타낸다.

[0102] 메모리(140)는 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 분류, 예측 방법을 수행하기 위해 필요한 다양한 명령어를 저장한다.

[0103] 프로세서(150)는 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 예측 및 분류 장치의 내부 구성 요소들(예를 들어, 다시점 통합 자가주의 모듈(110), 보조 해석부(120), 예측 및 분류기(130), 메모리(140) 등)을 제어하기 위한 수단이다. 도 4에는 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 분류, 예측 방법에 대한 의사 코드가 예시되어 있다.

[0105] 도 5는 본 발명의 일 실시예에 따른 불규칙 임상 시계열 데이터 분류, 예측 방법을 나타낸 순서도이다.

[0106] 단계 510에서 불규칙 임상 시계열 데이터 예측 및 분류 장치(100)는 불규칙한 임상 시계열 데이터, 관측 여부 데이터 및 시간 정보 데이터를 통합하여 상기 불규칙한 임상 시계열 데이터에 대한 심층 표현을 생성한다.

[0107] 이미 전술한 바와 같이, 불규칙 임상 시계열 데이터 예측 및 분류 장치(100)는 불규칙 임상 시계열 데이터, 상기 관측 여부 데이터 및 상기 시간 정보 데이터 각각을 임베딩하여 각각의 특징값을 구하고, 자가주의 매커니즘을 이용하여 상기 관측 여부 데이터와 상기 시간 정보 데이터의 특징값을 통합하여 결측 패턴 정보를 생성하고, 상기 결측 패턴 정보와 상기 불규칙 임상 시계열 데이터를 자가주의 블록을 이용하여 통합한 후 순방향 신경망(FFN: feed-forward network) 모듈에 적용하여 상기 심층 표현을 생성할 수 있다.

[0108] 단계 515에서 불규칙 임상 시계열 데이터 예측 및 분류 장치(100)는 불규칙한 임상 시계열 데이터와 심층 표현을 이용하여 보조적인 결측 대체값을 생성한다.

[0109] 이미 전술한 바와 같이, 불규칙 임상 시계열 데이터 예측 및 분류 장치(100)는 불규칙한 임상 시계열 데이터 중 일부를 마스킹 처리한 후 심층 표현을 이용하여 마스킹 처리된 값을 복원하는 과정을 통해 보조적인 결측 대체값을 생성할 수 있다.

[0110] 단계 520에서 불규칙 임상 시계열 데이터 예측 및 분류 장치(100)는 심층 표현 및 보조적인 결측 대체값을 이용하여 모델(즉, 예측 및 분류기(130))를 학습한다. 이와 같은 학습 과정이 완료되면, 심층 표현을 이용하여 환자

상태 예측 또는 진단을 분류할 수 있다.


- [0112] 본 발명의 실시 예에 따른 장치 및 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 컴퓨터 판독 가능 매체에 기록되는 프로그램 명령은 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 분야 통상의 기술자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기매체(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 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.
- [0113] 상술한 하드웨어 장치는 본 발명의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.
- [0114] 이제까지 본 발명에 대하여 그 실시 예들을 중심으로 살펴보았다. 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 본 발명이 본 발명의 본질적인 특성에서 벗어나지 않는 범위에서 변형된 형태로 구현될 수 있음을 이해할 수 있을 것이다. 그러므로 개시된 실시 예들은 한정적인 관점이 아니라 설명적인 관점에서 고려되어야 한다. 본 발명의 범위는 전술한 설명이 아니라 특허청구범위에 나타나 있으며, 그와 동등한 범위 내에 있는 모든 차이점은 본 발명에 포함된 것으로 해석되어야 할 것이다.

## 부호의 설명


- [0116] 100: 불규칙 임상 시계열 데이터 예측 및 분류 장치.  
 110: 다시점 통합 자가주의 모듈  
 120: 보조 해석부  
 130: 예측 및 분류기  
 140: 메모리  
 150: 프로세서

도면


도면1




도면2



도면3



도면4



도면5

