



(19) 대한민국특허청(KR)  
(12) 등록특허공보(B1)

(45) 공고일자 2020년10월23일  
(11) 등록번호 10-2169637  
(24) 등록일자 2020년10월19일

(51) 국제특허분류(Int. Cl.)

G16H 50/30 (2018.01) A61B 5/00 (2006.01)  
A61B 5/021 (2006.01) A61B 5/024 (2006.01)  
A61B 5/1455 (2006.01) G06K 9/62 (2006.01)

(52) CPC특허분류

G16H 50/30 (2018.01)  
A61B 5/021 (2013.01)

(21) 출원번호 10-2018-0026873

(22) 출원일자 2018년03월07일

심사청구일자 2018년03월07일

(65) 공개번호 10-2019-0106004

(43) 공개일자 2019년09월18일

(56) 선행기술조사문헌

KR1020110137001 A\*

KR1020170061222 A\*

\*는 심사관에 의하여 인용된 문헌

(73) 특허권자

연세대학교 산학협력단

서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)

주식회사 디에스이트레이드

서울특별시 서초구 서초중앙로24길 27, 지-파이브 센트럴프라자 5층 517호 (서초동)

(72) 발명자

김경원

서울특별시 서대문구 연세로 50-1(신촌동)

이상은

서울특별시 서대문구 연세로 50-1(신촌동)

(뒷면에 계속)

(74) 대리인

특허법인인벤싱크

전체 청구항 수 : 총 16 항


심사관 : 김재현

(54) 발명의 명칭 사망 위험도의 예측 방법 및 이를 이용한 사망 위험도의 예측 디바이스

(57) 요약

본 발명은, 프로세서에 의해 구현되는 사망 위험도를 예측하는 방법에 있어서, 피검자에 대한 생체 신호 데이터를 생체 신호 예측 디바이스로부터 수신하는 단계, 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델을 이용하여 생체 신호 데이터를 기초로 피검자에 대한 생체 신호 패턴을 생성하는 단계, 생체 신호 패턴을 기초로 상기 피검자에 대한 사망 위험도를 예측하는 단계를 포함하는 사망 위험도 예측 방법 및 이를 이용한 디바이스를 제공한다.

대표도 - 도1b



(52) CPC특허분류

*A61B 5/024* (2013.01)  
*A61B 5/14551* (2013.01)  
*A61B 5/7235* (2013.01)  
*A61B 5/7275* (2013.01)  
*G06K 9/6201* (2013.01)

**이성희**

서울특별시 강동구 올림픽로 572, 101동 1602호(성내동, 코오롱 2차아파트)

(72) 발명자

**강희재**

경기도 성남시 분당구 장미로 101, 802동 102호(야탑동, 장미마을)

이 발명을 지원한 국가연구개발사업

과제고유번호	10060085
부처명	산업통상자원부
과제관리(전문)기관명	한국산업기술평가관리원
연구사업명	산업기술혁신사업
연구과제명	의료-헬스 IT분야 Start-up의 글로벌 기술기업 도약 지원 특화 R&D플랫폼 및 관련
의료기기 SW기술 개발	
기 여 율	1/1
과제수행기관명	연세대학교 산학협력단
연구기간	2017.10.01 ~ 2018.07.31

---

## 명세서

### 청구범위

#### 청구항 1

프로세서에 의해 구현되는 사망 위험도를 예측하는 방법에 있어서, 피검자에 대한 생체 신호 데이터를, 생체 신호 예측 디바이스로부터 수신하는 단계;

생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델을 이용하여, 상기 생체 신호 데이터를 기초로 상기 피검자에 대한 생체 신호 패턴을 생성하는 단계, 및

상기 생체 신호 패턴을 기초로 상기 피검자에 대한 사망 위험도를 예측하는 단계를 포함하고,

상기 수신하는 단계는,

상기 피검자에 대한 생체 신호 데이터를 복수회 수신하는 단계를 포함하고,

상기 패턴 생성 모델은 클러스터링 알고리즘 기반의 모델이고,

상기 생체 신호 패턴을 생성하는 단계는,

복수회 수신된 상기 생체 신호 데이터 각각에 대한 패턴을 생성하는 단계, 및

상기 클러스터링 알고리즘에 기초하여 상기 각각에 대한 패턴을 통계적으로 그룹화함으로써 상기 생체 신호 패턴을 생성하는 단계를 더 포함하는, 사망 위험도 예측 방법.

#### 청구항 2

제1항에 있어서,

상기 생체 신호 데이터는, 상기 피검자에 대한 평균 혈압, 산소 포화도, 수축기 혈압, 이완기 혈압, 맥박수 및 약물 조치 데이터로 이루어진 그룹 중 선택된 적어도 하나인, 사망 위험도 예측 방법.

#### 청구항 3

제1항에 있어서,

상기 클러스터링 알고리즘에 기초하여 상기 각각에 대한 패턴을 통계적으로 그룹화함으로써 상기 생체 신호 패턴을 생성하는 단계 전에, 복수회 수신된 상기 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 보정하는 단계를 더 포함하는, 사망 위험도 예측 방법.

#### 청구항 4

제3항에 있어서,

상기 보정하는 단계는,

복수회 수신된 상기 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 제거하거나, 또는,

복수회 수신된 상기 생체 신호 데이터 중 측정되지 않은 생체 신호 데이터에 대하여, 단일 대체법, 결정적 대체법, 다중 대체법 및 확률적 대체법 중 적어도 하나의 대체법을 이용하여 대체값을 갖도록 변환하는 단계를 포함하는, 사망 위험도 예측 방법.

#### 청구항 5

제1항에 있어서,

상기 클러스터링 알고리즘에 기초하여 상기 각각에 대한 패턴을 통계적으로 그룹화함으로써 상기 생체 신호 패턴을 생성하는 단계는,

상기 클러스터링 알고리즘을 반복적으로 수행하여, 복수회 수신된 상기 생체 신호 데이터 각각에 대한 실루엣

계수 (Silhouette Width) 의 평균값을 산출하는 단계;

상기 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 패턴의 개수를 최적 패턴 개수로 결정하는 단계, 및

상기 클러스터링 알고리즘을 이용하여, 결정된 상기 최적 패턴 개수를 기초로 복수회 수신된 상기 생체 신호 데이터에 대한 패턴을 그룹화함으로써 하나의 생체 신호 패턴을 생성하는 단계를 포함하는, 사망 위험도 예측 방법.

## 청구항 6

제5항에 있어서,

상기 패턴 생성 모델을 이용하여, 복수회 수신된 상기 생체 신호 데이터 중 선택된 두 개의 생체 신호에 대한 유사도 및 비유사도 행렬을 산출하는 단계, 및

산출된 상기 유사도 및 상기 비유사도를 기초로 상기 두 개의 생체 신호에 대한 상관관계를 결정하는 단계를 더 포함하고,

상기 클러스터링 알고리즘에 기초하여 상기 각각에 대한 패턴을 통계적으로 그룹화함으로써 상기 생체 신호 패턴을 생성하는 단계는,

상기 두 개의 생체 신호에 대한 상관관계, 상기 최적 패턴 개수를 기초로, 하나의 생체 신호 패턴을 생성하는 단계를 포함하는, 사망 위험도 예측 방법.

## 청구항 7

제1항에 있어서,

상기 예측하는 단계는,

생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된 사망 예측 모델을 이용하여, 상기 피검자에 대한 사망 위험도를 예측하는 단계를 포함하는, 사망 위험도 예측 방법.

## 청구항 8

제7항에 있어서,

상기 생체 신호 데이터는 복수개이고,

상기 사망 예측 모델은 사망 위험도와 연관된 패턴을 기초로 사망 위험도를 예측하도록 트레이닝된 모델이고,

상기 사망 예측 모델은,

상기 수신하는 단계 이전에, 상기 피검자와 상이한 복수의 표본 대상자에 대하여 생체 신호 데이터를 각각 수신하는 단계;

상기 패턴 생성 모델을 이용하여, 상기 생체 신호 각각에 대한 패턴을 생성하는 단계;

생성된 상기 각각에 대한 패턴을 그룹화하여, 상기 복수의 표본 대상자 각각에 대한 하나의 생체 신호 패턴을 생성하는 단계, 및

상기 복수의 표본 대상자 각각에 대하여 생성된 상기 하나의 생체 신호 패턴 중, 사망 위험도와 연관된 패턴을 결정하는 단계에 의해 트레이닝된, 사망 위험도 예측 방법

## 청구항 9

제8항에 있어서,

상기 사망 위험도와 연관된 패턴을 결정하는 단계는,

상기 복수의 표본 대상자 각각에 대한 상기 하나의 생체 신호 패턴에 대한 오즈 비 (odds ratio) 를 산출하는 단계, 및

산출된 상기 오즈 비를 기초로 사망 위험도와 연관된 패턴을 결정하는 단계를 포함하는, 사망 위험도 예측

방법.

#### 청구항 10

제8항에 있어서,

상기 사망 위험도를 예측하는 단계는,

상기 사망 예측 모델을 이용하여, 미리 결정된 상기 사망 위험도와 연관된 패턴 및 상기 피검자에 대하여 생성된 상기 생체 신호 패턴을 비교하는 단계, 및

상기 비교의 결과를 기초로, 상기 피검자에 대한 사망 위험도를 확률적으로 산출하는 단계를 포함하는, 사망 위험도 예측 방법.

#### 청구항 11

제8항에 있어서,

상기 복수의 표본 대상자 각각, 및 상기 피검자에 대한 나이를 수신하는 단계, 및

연령의 범위에 따라 미리 결정된 복수의 유사 연령 그룹으로, 상기 복수의 표본 대상자 각각을 분류하는 단계를 더 포함하고,

상기 클러스터링 알고리즘에 기초하여 상기 각각에 대한 패턴을 통계적으로 그룹화함으로써 상기 생체 신호 패턴을 생성하는 단계는,

상기 생성된 각각에 대한 패턴을, 상기 유사 연령별로 그룹화하여, 상기 복수의 유사 연령 그룹 각각에 대한 하나의 생체 신호 패턴을 생성하는 단계를 포함하고,

상기 사망 위험도와 연관된 패턴을 결정하는 단계는,

상기 복수의 유사 연령 그룹 각각에 대하여 생성된 상기 하나의 생체 신호 패턴 중, 사망 위험도와 연관된 패턴을 결정하는 단계를 포함하고,

상기 사망 위험도를 예측하는 단계는,

상기 사망 예측 모델을 이용하여, 상기 복수의 유사 연령 그룹 중, 상기 피검자의 나이에 해당하는 유사 연령 그룹에 대한 사망 위험도와 연관된 생체 신호 패턴 및 상기 피검자에 대하여 생성된 상기 생체 신호 패턴을 비교하는 단계, 및

상기 비교의 결과를 기초로, 상기 피검자의 연령을 고려한 사망 위험도를 확률적으로 산출하는 단계를 포함하는, 사망 위험도 예측 방법.

#### 청구항 12

제7항에 있어서,

상기 피검자에 대한 성별, 생년월일, 몸무게, 입실일자, 퇴실일자, 사망일자, 병동, 진단명 및 담당의 정보로 구성된 그룹 중 선택된 적어도 하나의 의무기록 데이터 수신하는 단계를 더 포함하고,

상기 사망 예측 모델은 상기 의무기록 데이터를 기초로 사망 위험도를 예측하도록 학습된 모델인, 사망 위험도 예측 방법.

#### 청구항 13

프로세서에 의해 구현되는 사망 위험도를 예측하도록 구성된 디바이스로서,

피검자에 대하여 생체 신호 데이터를 수신하도록 구성된, 데이터 수신부;

생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델을 이용하여, 상기 생체 신호 데이터를 기초로 상기 피검자에 대한 생체 신호 패턴을 생성하도록 구성된, 생체 신호 생성부, 및

생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된, 사망 위험도 예측부를 포함하고,

상기 수신부는, 상기 피검자에 대한 생체 신호 데이터를 복수회 수신하도록 더 구성되고,

상기 패턴 생성 모델은 클러스터링 알고리즘 기반의 모델이고,

상기 생체 신호 생성부는,

복수회 수신된 상기 생체 신호 데이터 각각에 대한 패턴을 생성하고, 상기 클러스터링 알고리즘에 기초하여 상기 각각에 대한 패턴을 통계적으로 그룹화함으로써 상기 생체 신호 패턴을 생성하도록 구성된, 사망 위험도 예측 디바이스.

#### 청구항 14

제13항에 있어서,

상기 생체 신호 데이터는, 상기 피검자에 대하여 측정된 서로 상이한 단위를 갖는 복수개의 생체 신호 데이터이고,

데이터 전처리부를 더 포함하고,

상기 데이터 전처리부는, 상기 복수개의 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 보정하도록 구성됨, 사망 위험도 예측 디바이스.

#### 청구항 15

제14항에 있어서,

상기 데이터 전처리부는,

상기 생체 신호 패턴을 생성하도록 상기 복수개의 생체 신호 데이터의 각각의 단위를 표준화하도록 더 구성된, 사망 위험도 예측 디바이스.

#### 청구항 16

제13항에 있어서,

상기 사망 위험도 예측부는,

생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된, 사망 예측 모델을 기반으로 하고,

상기 사망 예측 모델은 미리 결정된 사망 위험도와 연관된 패턴 및 상기 피검자에 대하여 생성된 상기 생체 신호 패턴을 비교하고, 상기 비교의 결과를 기초로 상기 피검자에 대한 사망 위험도를 확률적으로 산출하도록 구성된, 사망 위험도 예측 디바이스.

### 발명의 설명

#### 기술 분야

[0001] 본 발명은 사망 위험도의 예측 방법 및 이를 이용한 사망 위험도의 예측 디바이스에 관한 것으로, 보다 구체적으로 피검자에 대한 생체 신호를 기반으로 하여 사망의 위험도를 예측할 수 있는 사망 위험도의 예측 방법 및 이를 이용한 사망 위험도의 예측 디바이스에 관한 것이다.

#### 배경 기술

[0002] 의료 서비스를 이용하는 많은 환자들은 치명적인 질환에 쉽게 노출되기 쉽고 경우에 따라 지속적인 건강상태의 체크와 이에 따른 조치를 필요로 한다. 특히, 병원의 중환자실에 수용된 중환자와 같은 요주의 환자들은 환자의 상태에 대한 지속적인 관찰이 보다 중요할 수 있다.

[0003] 중환자에 대하여 맥박수나 혈압 또는 호흡, 등 병의 진행이나 생명유지와 관련된 사항에 관한 환자의 상태를 체크하기 위해, 다양한 예측 장비가 구비될 수 있다. 예측 장비는 환자의 상태를 측정하고 그 결과를 의료진이 확인할 수 있도록 디스플레이 한다. 그러나, 이러한 임상데이터의 양이 기하급수적으로 증가하고 있음에도 불구하고, 현재로서는 일정 시각의 값만 전자 차트에 기록되는 이외에 대부분의 데이터가 그대로 버려지고 있는 실정이다. 본 발명에서는, 임상적으로 어떠한 질환에의 이환이 의심되는 상황이 도래하거나, 또는 질환의 진단

기준에 모두 부합하게 되는 시점 이전에 미리 인체의 생리학적 대응 반응의 일환으로 생체 신호들의 변화가 선행 할 것이라는 가정 하에, 이들을 이용하여 질병 진단 및 잠재적 중한 상태를 포함한 예후 예측 알고리즘을 개발하고자 한다. 이를 이용하여 환자의 질병 상태에 대하여 빠르게 감지하고, 나아가 환자의 사망 위험도를 미리 예측하여, 환자에 대한 처치 시점을 앞당겨 치료 성과를 높일 수 있다. 환자의 생존률 증가, 합병증 예방, 및 치료 비용의 감소 효과 또한 기대할 수 있다.

[0004] 특히 소아는 성인에 비하여 비 특이적인 증상과 다양한 병명으로 중환자실에 입실하는 경우가 많으며 입실 이후에도 급격한 상태 변화를 보이는 경향이 있어 그 예후를 예측하기 더 어려운 특성을 지닌다. 소아 환자의 질병의 다양성이나 성인과는 신체적, 생리적인 차이점을 고려할 때 소아 중환자에 대한 독자적인 연구의 필요성이 점차 강조되고 있으며, 또한 전세계적으로 독립된 소아중환자실을 가진 병원이 증가하고 이에 따라 집중 치료를 받는 소아 환자들이 증가하면서 이러한 환자들의 예후 예측의 중요성도 함께 증가하게 되었다.

[0005] 따라서, 의료 서비스를 제공받은 환자, 특히 중환자에 대하여 사망 위험도와 연관된 정보를 제공하고, 사망 위험도를 정확하게 예측할 수 있는 새로운 의료 시스템에 대한 개발이 지속적으로 요구되고 있는 실정이다.

[0006] 발명의 배경이 되는 기술은 본 발명에 대한 이해를 보다 용이하게 하기 위해 작성되었다. 발명의 배경이 되는 기술에 기재된 사항들이 선행기술로 존재한다고 인정하는 것으로 이해되어서는 안 된다.

## 발명의 내용

### 해결하려는 과제

[0007] 한편, 본 발명의 발명자들은 환자, 특히 시간마다 상태가 변하는 중환자의 사망 위험도의 예측과 관련하여 활력 징후와 같이 중환자실에서 획득할 수 있는 생리학적 데이터에 주목하였다. 보다 구체적으로 본 발명의 발명자들은 환자에 대한 다양한 생리학적 데이터를 분석하였고, 환자의 사망 위험도와 연관된 생체 신호 기반의 패턴을 발견하기에 이르렀다.

[0008] 나아가, 본 발명의 발명자들은 사망의 위험도 예측의 정확도를 높이고 사망과 연관된 아임상적 증상(subclinical signature)에 대한 신속한 처리를 위해, 환자의 사망 위험도와 관련된 정보에 의해 트레이닝된 예측 모델을 이용할 수 있음을 인지하였다.

[0009] 한편, 사망의 위험도 예측에 이용되는 예측 모델에 있어서, 입력된 생체 신호와 같은 생리학적 데이터에 대한 패턴 추출은 매우 중요할 수 있다. 만약, 예측 모델이 잘못된 패턴을 추출할 경우, 의료진들은 불필요한 조치를 취하게 되어 다른 환자에 대한 치료가 지연될 수 있으며 불필요한 비용을 발생시킬 수 있다. 이에, 본 발명의 발명자들은 불필요한 생리학적 데이터를 제거하고, 환자의 생명과 연관된 생체 신호 기반의 패턴을 추출하도록 구성된 예측 모델을 이용하였고, 그 결과 사망 위험도의 예측의 정확도가 높아지는 것을 확인할 수 있었다.

[0010] 그 결과, 본 발명의 발명자들은 환자에 대하여 획득된 생리학적 데이터, 보다 구체적으로 설정된 시간마다 수신된 생체 신호 데이터를 기반으로 사망과 연관된 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델을 이용하고, 이를 기초로 사망의 위험도를 예측하도록 구성된 새로운 사망의 위험도 예측 방법 및 디바이스를 개발하기에 이르렀다.

[0011] 이에, 본 발명이 해결하고자 하는 과제는, 피검자에 대한 생체 신호 데이터를 기반으로 생체 신호 패턴을 생성하는 패턴 생성 모델을 이용하고, 이를 기초로 사망의 위험도를 예측하는, 환자에 대한 사망 위험도의 예측 방법을 제공하는 것이다.

[0012] 본 발명이 해결하고자 하는 다른 과제는, 피검자에 대하여 생체 신호 데이터와 같은 생리학적 데이터를 수신하도록 구성된 데이터 수신부, 패턴 생성 모델을 이용하여 사망의 위험도와 연관된 생체 신호 패턴을 생성하도록 구성된 패턴 생성부, 생체 신호 패턴으로 사망의 위험도를 예측하도록 구성된 사망의 위험도 예측부를 포함하는, 환자에 대한 사망 위험도의 예측 모델을 제공하는 것이다.

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

### 과제의 해결 수단

[0014] 전술한 바와 같은 과제를 해결하기 위하여 본 발명의 일 실시예에 따른 사망 위험도의 예측 방법이 제공된다.

프로세서에 의해 구현되는 사망 위험도를 예측하는 방법으로서 본 방법은, 피검자에 대한 생체 신호 데이터를 생체 신호 예측 디바이스로부터 수신하는 단계, 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델을 이용하여, 생체 신호 데이터를 기초로 피검자에 대한 생체 신호 패턴을 생성하는 단계, 및 생체 신호 패턴을 기초로 피검자에 대한 사망 위험도를 예측하는 단계를 포함한다.

- [0015] 본 발명의 특징에 따르면, 생체 신호 데이터는 피검자에 대한 평균 혈압, 산소 포화도, 수축기 혈압, 이완기 혈압, 맥박수 및 약물 조치 데이터로 이루어진 그룹 중 선택된 적어도 하나이고, 생체 신호 데이터를 수신하는 단계는, 미리 결정된 시간 간격으로 피검자에 대한 생체 신호 데이터를 복수회 수신하는 단계를 포함할 수 있다.
- [0016] 본 발명의 다른 특징에 따르면, 생체 신호 패턴을 생성하는 단계 전에, 복수회 수신된 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 보정하는 단계를 더 포함할 수 있다.
- [0017] 본 발명의 또 다른 특징에 따르면, 정하는 단계는 복수회 수신된 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 제거하거나, 또는 복수회 수신된 생체 신호 데이터 중 측정되지 않은 생체 신호 데이터에 대하여, 단일 대체법, 결정적 대체법, 다중 대체법 및 확률적 대체법 중 적어도 하나의 대체법을 이용하여 대체값을 갖도록 변환하는 단계를 포함할 수 있다.
- [0018] 본 발명의 또 다른 특징에 따르면, 모든 두 쌍의 복수개의 생체 신호들에 대해 상관계수를 산출하여 유사도 및 비유사도 행렬을 산출하는 단계를 더 포함하고, 패턴을 생성하는 단계는 생체 신호 간의 상관관계, 최적 패턴 개수를 기초로 소수의 생체 신호 패턴을 정의하는 단계를 포함할 수 있다.
- [0019] 본 발명의 또 다른 특징에 따르면, 생체 신호 데이터는 복수개이고, 패턴 생성 모델은 클러스터링 알고리즘 기반이고, 패턴을 생성하는 단계는 클러스터링 알고리즘을 반복적으로 수행하여, 복수개의 생체 신호 각각에 대한 실루엣 계수 (Silhouette Width) 의 평균값을 산출하는 단계, 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 패턴의 개수를 최적 패턴 개수로 결정하는 단계, 및 클러스터링 알고리즘을 이용하여, 결정된 최적 패턴 개수를 기초로 복수개의 생체 신호에 대한 패턴을 그룹화함으로써 하나의 생체 신호 패턴을 생성하는 단계를 포함할 수 있다.
- [0020] 본 발명의 또 다른 특징에 따르면, 예측하는 단계는 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된 사망 예측 모델을 이용하여, 피검자에 대한 사망 위험도를 예측하는 단계를 포함할 수 있다.
- [0021] 본 발명의 또 다른 특징에 따르면, 생체 신호 데이터는 복수개이고, 사망 예측 모델은 사망 위험도와 연관된 패턴을 기초로 사망 위험도를 예측하도록 트레이닝된 모델이고, 사망 예측 모델은 피검자에 대한 생체 신호 데이터를 수신하는 단계 이전에, 피검자와 상이한 복수의 표본 대상자에 대하여 생체 신호 데이터를 각각 수신하는 단계, 복수의 표본 대상자 각각에 대한 생체 신호 데이터 각각의 단위를 표준화하는 단계, 패턴 생성 모델을 이용하여 생체 신호 각각에 대한 패턴을 생성하는 단계, 생성된 각각에 대한 패턴을 그룹화하여 복수의 표본 대상자 각각에 대한 하나의 생체 신호 패턴을 생성하는 단계, 및 복수의 표본 대상자 각각에 대하여 생성된 하나의 생체 신호 패턴 중, 사망 위험도와 연관된 패턴을 결정하는 단계에 의해 트레이닝될 수 있다.
- [0022] 본 발명의 또 다른 특징에 따르면, 사망 위험도와 연관된 패턴을 결정하는 단계는, 복수의 표본 대상자 각각에 대한 하나의 생체 신호 패턴에 대한 오즈 비 (odds ratio) 를 산출하는 단계, 및 산출된 오즈 비를 기초로 사망 위험도와 연관된 패턴을 결정하는 단계를 포함할 수 있다.
- [0023] 본 발명의 또 다른 특징에 따르면, 사망 위험도를 예측하는 단계는 사망 예측 모델을 이용하여, 미리 결정된 사망 위험도와 연관된 패턴 및 피검자에 대하여 생성된 생체 신호 패턴을 비교하는 단계, 및 비교의 결과를 기초로 피검자에 대한 사망 위험도를 확률적으로 산출하는 단계를 포함할 수 있다.
- [0024] 본 발명의 또 다른 특징에 따르면, 복수의 표본 대상자 각각, 및 피험자에 대한 나이를 수신하는 단계, 및 연령의 범위에 따라 미리 결정된 복수의 유사 연령 그룹으로, 복수의 표본 대상자 각각을 분류하는 단계를 더 포함할 수 있고, 하나의 패턴을 생성하는 단계는, 생성된 각각에 대한 패턴을 유사 연령별로 그룹화하여, 복수의 유사 연령 그룹 각각에 대한 하나의 생체 신호 패턴을 생성하는 단계를 포함할 수 있고, 사망 위험도와 연관된 패턴을 결정하는 단계는 복수의 유사 연령 그룹 각각에 대하여 생성된 하나의 생체 신호 패턴 중, 사망 위험도와 연관된 패턴을 결정하는 단계를 포함할 수 있고, 사망 위험도를 예측하는 단계는 사망 예측 모델을 이용하여, 복수의 유사 연령 그룹 중, 피험자의 나이에 해당하는 유사 연령 그룹에 대한 사망 위험도와 연관된 생체 신호 패턴 및 피험자에 대하여 생성된 생체 신호 패턴을 비교하는 단계, 및 비교의 결과를 기초로 피검자의 연령을 고려한 사망 위험도를 확률적으로 산출하는 단계를 포함할 수 있다.



- [0025] 본 발명의 또 다른 특징에 따르면, 피험자에 대한 성별, 생년월일, 몸무게, 입실일자, 퇴실일자, 사망일자, 병동, 진단명 및 담당의 정보로 구성된 그룹 중 선택된 적어도 하나의 의무기록 데이터 수신하는 단계를 더 포함하고, 사망 예측 모델은 의무기록 데이터를 기초로 사망 위험도를 예측하도록 학습된 모델일 수 있다.
- [0026] 전술한 바와 같은 과제를 해결하기 위하여 본 발명의 일 실시예에 따른 사망 위험도의 예측 디바이스가 제공된다. 본 디바이스는, 프로세서에 의해 구현되는 사망 위험도를 예측하도록 구성된 디바이스로서, 피험자에 대하여 생체 신호 데이터를 수신하도록 구성된 데이터 수신부, 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델을 이용하여 생체 신호 데이터를 기초로 피험자에 대한 생체 신호 패턴을 생성하도록 구성된 생체 신호 생성부, 및 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된 사망 위험도 예측부를 포함한다.
- [0027] 본 발명의 특징에 따르면, 생체 신호 데이터는 피험자에 대하여 측정된 서로 상이한 단위를 갖는 복수개의 생체 신호 데이터이고, 사망 위험도 예측 디바이스는 데이터 전처리부를 더 포함할 수 있다. 이때, 데이터 전처리부는, 복수개의 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 보정하도록 구성될 수 있다.
- [0028] 본 발명의 다른 특징에 따르면, 데이터 전처리부는 생체 신호 패턴을 생성하도록 복수개의 생체 신호 데이터의 각각의 단위를 표준화하도록 더 구성될 수 있다.
- [0029] 본 발명의 또 다른 특징에 따르면, 사망 위험도 예측부는 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된 사망 예측 모델을 기반으로 할 수 있다. 이때, 사망 예측 모델은 미리 결정된 사망 위험도와 연관된 패턴 및 피검자에 대하여 생성된 생체 신호 패턴을 비교하고, 비교의 결과를 기초로 피검자에 대한 사망 위험도를 확률적으로 산출하도록 구성될 수 있다.

### 발명의 효과

- [0030] 본 발명은 환자의 상태, 나아가 환자의 사망과 연관된 생체 신호 데이터를 설정된 시간마다 입력 받고, 입력된 데이터 기반의 사망 위험도의 예측 방법 및 이를 이용한 사망 위험도의 예측 디바이스를 제공함으로써, 환자의 질병 상태에 대하여 빠르게 감지하고, 환자의 생명과 연관된 정보를 제공함으로써 사망 위험도를 예측하게 할 수 있다. 이에, 본 발명은 환자에 대한 처치 시점을 앞당겨 치료에 대한 좋은 예후를 제공할 수 있다. 나아가, 본 발명은 의료진이 중환자에 대하여 효과적인 조치를 취할 수 있어, 중환자에 대한 생존률 증가에 기여할 수 있는 효과가 있다.
- [0031] 또한, 본 발명은 환자에 대한 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 패턴 생성 모델, 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된 사망 예측 모델을 이용하여, 예측의 정확도가 높은 사망 위험도의 예측 방법 및 이를 이용한 사망 위험도의 예측 디바이스를 제공할 수 있는 효과가 있다.
- [0032] 특히, 본 발명은, 데이터의 분석이 어렵고 패턴 추출이 어려운 소아 중환자에 대한 생체 신호 데이터를 본 발명의 다양한 실시예에서 이용되는 예측 모델에 적용함으로써, 소아 중환자에 대하여 민감도 및 정확도 높게 사망 위험도를 예측할 수 있는 효과가 있다.
- [0033] 나아가, 본 발명은 결측 생체 신호 데이터 또는 오류를 갖는 생체 신호 데이터에 대한 보정을 수행함으로써, 생존과 연관된 환자에 대한 생체 신호 패턴을 정확도 높게 추출할 수 있는 효과가 있다.
- [0034] 본 발명에 따른 효과는 이상에서 예시된 내용에 의해 제한되지 않으며, 더욱 다양한 효과들이 본 명세서 내에 포함되어 있다.

### 도면의 간단한 설명

- [0035] 도 1a는 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스를 이요한 사망 예측 시스템을 예시적으로 도시한 것이다.
- 도 1b는 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스의 구성을 도시한 것이다.
- 도 3은 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 구성을 예시적으로 도시한 것이다.
- 도 4a는 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 패턴 생성부에 의해 생성된 사망 여부에 따른 생체 신호 패턴을 예시적으로 도시한 것이다.
- 도 4b는 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 생체 신호 패턴 생성부에서의 패턴 수 결

정을 위한 스크리차트 (Scree chart) 분석 결과를 도시한 것이다.

도 4c는 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 생체 신호 패턴 생성부에 의해 클러스터링 된 패턴에 대한 오즈 비를 산출한 결과를 도시한 것이다.

도 5a 내지 5d는 본 발명의 일 실시예에 따른 사망 위험도 예측 방법 및 이를 이용한 디바이스에 대한 평가의 결과를 도시한 것이다.

### 발명을 실시하기 위한 구체적인 내용

- [0036] 발명의 이점, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시예들을 참조하면 명확해질 것이다. 그러나 본 발명은 이하에서 개시되는 실시예들에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 것이며, 단지 본 실시예들은 본 발명의 개시가 완전하도록 하며, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것이며, 본 발명은 청구항의 범주에 의해 정의될 뿐이다.
- [0037] 본 발명의 실시예를 설명하기 위한 도면에 개시된 형상, 크기, 비율, 각도, 개수 등은 예시적인 것이므로 본 발명이 도시된 사항에 한정되는 것은 아니다. 또한, 본 발명을 설명함에 있어서, 관련된 공지 기술에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우 그 상세한 설명은 생략한다. 본 명세서 상에서 언급된 '포함한다', '갖는다', '이루어진다' 등이 사용되는 경우, '~만'이 사용되지 않는 이상 다른 부분이 추가될 수 있다. 구성요소를 단수로 표현한 경우에 특별히 명시적인 기재 사항이 없는 한 복수를 포함하는 경우를 포함한다.
- [0038] 구성요소를 해석함에 있어서, 별도의 명시적 기재가 없더라도 오차 범위를 포함하는 것으로 해석한다.
- [0039] 본 발명의 여러 실시예들의 각각 특징들이 부분적으로 또는 전체적으로 서로 결합 또는 조합 가능하며, 당업자가 충분히 이해할 수 있듯이 기술적으로 다양한 연동 및 구동이 가능하며, 각 실시예들이 서로에 대하여 독립적으로 실시 가능할 수도 있고 연관 관계로 함께 실시 가능할 수도 있다.
- [0040] 본 명세서의 해석의 명확함을 위해, 이하에서는 본 명세서에서 사용되는 용어들을 정의하기로 한다.
- [0041] 본 명세서에서 사용되는 용어, "피검자"는 사망의 위험도를 예측을 위한 대상을 의미할 수 있다. 예를 들어, 피검자는 중환자, 특히 19 세 미만의 소아 중환자일 수 있으나, 이에 제한되는 것은 아니다.
- [0042] 본 명세서에서 사용되는 용어, "생체 신호 데이터"는 활력 징후와 같은 피검자의 상태와 연관된 데이터를 의미할 수 있다. 예를 들어, 생체 신호 데이터는 예측 장비로부터 측정된 피검자에 대한 평균 혈압, 산소 포화도 (SpO<sub>2</sub>, saturation of percutaneous oxygen), 수축기 혈압 (SBP, systolic blood pressure), 이완기 혈압 (DBP, diastolic blood pressure), 맥박수 (PR, pulse rate), 또는 약물 조치 데이터일 수 있으나, 이에 제한되지 않고 피검자의 건강 상태와 연관된 다양한 데이터일 수 있다.
- [0043] 본 명세서에서 사용되는 용어, "패턴 생성 모델"은 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 구성된 모델을 의미할 수 있다. 예를 들어, 패턴 생성 모델은 비지도학습의 k-Means, 또는 SOM의 클러스터링 알고리즘에 기초하는 모델일 수 있다. 이러한 패턴 생성 모델은 피검자에 대한 생체 신호 데이터를 기초로 패턴을 생성하도록 구성될 수 있다. 그러나, 본 발명의 패턴 생성 모델은 이에 제한되지 않고 보다 다양한 클러스터링 알고리즘에 기초할 수 있다.
- [0044] 본 명세서에서 사용되는 용어, "사망 예측 모델"은 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성된 예측 모델을 의미할 수 있다. 보다 구체적으로, 사망 예측 모델은 생체 신호 패턴을 기초로 사망의 위험도를 분류, 예측하도록 모형을 학습하는 알고리즘에 기초할 수 있다. 예를 들어, 사망 예측 모델은, Randomized Decision forest 알고리즘, Penalized Logistic Regression 알고리즘의 기계학습에 의한 알고리즘과 Deep Learning 알고리즘에 기초하여, 입력된 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성될 수 있다. 그러나, 본 발명의 사망 예측 모델은 이에 제한되지 않고 보다 다양한 학습 알고리즘에 기초할 수 있다.
- [0045] 먼저, 도 1a 및 도 1b를 참조하여, 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스 및 이를 이용한 사망 위험도 예측 시스템을 구체적으로 설명한다. 도 1a는 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스를 이용한 사망 예측 시스템을 예시적으로 도시한 것이다. 도 1b는 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스의 구성을 도시한 것이다.
- [0046] 도 1a를 참조하면, 본 발명의 일 실시예에 따른 사망 위험도 예측 시스템은, 사망 위험도 예측 디바이스 (100),

생체 신호 계측 디바이스 (200), 및 데이터베이스 (700), 의료진 디바이스 (900) 로 구성되어 있다.

- [0047] 사망 위험도 예측 시스템 (1000) 에서 사망 위험도 예측 디바이스 (100) 는, 피검자 (800) 에 대하여 측정된 생체 신호에 대한 데이터를 수신하여, 피검자 (800) 에 대한 사망의 위험도를 예측하도록 구성될 수 있다. 나아가, 사망 위험도 예측 디바이스 (100) 는 외부로부터 피검자 (800) 에 대한 의무기록 데이터를 포함하는 데이터베이스 (700) 를 더 고려하여, 피검자 (800) 에 대한 사망의 위험도를 예측할 수 있다.
- [0048] 나아가, 생체 신호 계측 디바이스 (200) 는 피검자 (800) 에 대한 평균 혈압, 산소 포화도, 수축기 혈압, 이완기 혈압, 맥박수, 또는 약물 조치 데이터의 생체 신호 데이터를 사망 위험도 예측 디바이스 (100) 에 송신하도록 구성될 수 있다.
- [0049] 의료진 디바이스 (900) 는 사망 위험도 예측 디바이스 (100) 에 의해 예측된 피검자 (800) 에 대한 사망 위험도와 연관된 정보를 수신 받고, 의료진이 수신된 정보를 기초로 피검자 (800) 의 증상에 따른 조치를 취할 수 있게, 피드백을 제공하도록 구성될 수 있다.
- [0050] 보다 구체적으로, 도 1b를 참조하면, 사망 위험도 예측 디바이스 (100) 는 수신부 (110), 입력부 (120), 표시부 (130), 저장부 (140) 및 프로세서 (150) 를 포함한다.
- [0051] 구체적으로 수신부 (110) 는 피검자 (800) 에 대한 생체 신호 데이터 및 의무기록 데이터와 같은 데이터베이스 (700) 를 수신하도록 구성될 수 있다. 예를 들어, 수신부 (110) 는 생체 신호 계측 디바이스 (200) 로부터 피검자 (800) 에 대한 평균 혈압, 산소 포화도, 수축기 혈압, 이완기 혈압, 맥박수, 또는 약물 조치 데이터의 생체 신호 데이터를 수신할 수 있다. 나아가, 수신부 (110) 는 피검자 (800) 에 대한 성별, 생년월일, 몸무게, 입실일자, 퇴실일자, 사망일자, 병동, 진단명, 또는 담당의 정보의 의무기록 데이터를 수신할 수 있다.
- [0052] 다른 실시예에서 수신부 (110) 는 사망 위험도와 연관된 생체 신호 패턴 생성을 위한, 표본 대상자에 대한 생체 신호 패턴, 및 나이를 더 수신하도록 구성될 수 있다.
- [0053] 다른 실시예에서 수신부 (110) 는 의료진 디바이스 (900) 에 대하여, 후술될 프로세서 (150) 에 의해 결정된 피검자 (800) 에 대하여 예측된 사망 위험도에 대한 정보를, 송신하도록 더 구성될 수 있다.
- [0054] 입력부 (120) 는 키보드, 마우스, 터치 스크린 패널 등 제한되지 않는다. 입력부 (120) 는 사망 위험도 예측 디바이스 (100) 를 설정하고, 사망 위험도 예측 디바이스 (100) 의 동작을 지시할 수 있다.
- [0055] 한편, 표시부 (130) 는 수신부 (110) 에 의해 수신된 생체 신호 데이터, 또는 의무 기록 데이터를 표시할 수 있다. 나아가, 표시부 (130) 는 프로세서 (150) 에 의해 생성된 피검자에 대한 생체 신호 패턴을 표시하고, 프로세서 (150) 에 의해 예측된 사망 위험도를 표시할 수 있다.
- [0056] 저장부 (140) 는 수신부 (110) 를 통해 수신한 피검자 (800) 에 대한 생체 신호 데이터, 또는 의무 기록 데이터의 데이터베이스 (700) 를 저장하고, 입력부 (120) 를 통해 설정된 사망 위험도 예측 디바이스 (100) 의 지시를 저장하도록 구성될 수 있다. 나아가, 저장부 (140) 는 후술될 프로세서 (150) 에 의해 생성된 피검자 (800) 에 대한 생체 신호 패턴을 저장하고, 예측된 피검자 (800) 에 대한 사망 위험도에 대한 결과를 저장하도록 구성된다. 그러나, 전술한 것에 제한되지 않고 저장부 (140) 는 사망 위험도 예측을 위해 프로세서 (150) 에 의해 결정된 다양한 정보들을 저장할 수 있다.
- [0057] 프로세서 (150) 는 사망 위험도 예측 디바이스 (110) 의 정확한 예측 결과를 제공하기 위한 구성요소일 수 있다. 이때, 정확한 예측을 위해 프로세서 (150) 는 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 학습된 생체 신호 패턴 생성 모델을 이용하여, 피검자에 대한 생체 신호 패턴을 생성하도록 구성될 수 있다. 이때, 패턴 생성 모델은 클러스터링 알고리즘에 기초하는 모델일 수 있다. 예를 들어, 프로세서 (150) 는, 클러스터링 알고리즘을 반복적으로 수행하여, 수신부 (110) 로부터 수신한 복수개의 생체 신호 각각에 대한 실루엣 계수 (Silhouette Width) 의 평균값을 산출하고, 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 패턴의 개수를 최적 패턴 개수로 결정할 수 있다. 나아가, 프로세서 (150) 는 클러스터링 알고리즘을 이용하여, 결정된 최적 패턴 개수를 기초로 복수개의 생체 신호에 대한 패턴을 그룹화함으로써 하나의 생체 신호 패턴을 생성하도록 구성될 수 있다. 또한, 프로세서 (150) 는 클러스터링 알고리즘을 이용하여, 미리 결정된 시간 간격으로 피검자에 대한 생체 신호 데이터를 복수회 수신함에 따라 생성된, 동일한 생체 신호 데이터의 복수개의 데이터에 대한 클러스터링을 수행하도록 구성될 수 있다.
- [0058] 다른 실시예에서, 프로세서 (150) 는 전술한 패턴 생성 모델을 이용하여, 복수개의 생체 신호 중 선택된 두 개의 생체 신호에 대한 유사도 및 비유사도 행렬을 산출하고, 산출된 유사도 및 비유사도를 기초로 상기 두 개의

생체 신호에 대한 상관관계를 결정하도록 더 구성될 수 있다. 나아가, 프로세서 (150) 는 생체 신호 간의 상관관계, 및 최적 패턴 개수를 기초로, 하나의 생체 신호 패턴을 생성하도록 구성될 수 있다.

[0059] 다른 실시예에서, 프로세서 (150) 는 생체 신호 패턴을 기초로 사망의 위험도를 확률적으로 예측하도록 학습된 사망 예측 모델을 이용하여, 피검자 (800) 에 대한 사망 위험도를 예측하도록 구성될 수 있다. 이때, 사망 예측 모델은, 피검자 (800) 와 상이한 복수의 표본 대상자에 대하여 생체 신호 데이터를 각각 수신하고, 패턴 생성 모델을 이용하여, 생체 신호 각각에 대한 패턴을 생성하고, 생성된 각각에 대한 패턴을 그룹화하여 복수의 표본 대상자 각각에 대한 하나의 생체 신호 패턴을 생성하고, 복수의 표본 대상자 각각에 대하여 생성된 하나의 생체 신호 패턴 중, 사망 위험도와 연관된 패턴을 결정하는 단계에 의해 트레이닝된 예측 모델일 수 있다. 이에, 프로세서 (150) 는 사망 예측 모델을 이용하여, 미리 결정된 사망 위험도와 연관된 패턴 및 피검자 (800) 에 대하여 생성된 생체 신호 패턴을 비교하고, 결과를 기초로, 피검자 (800) 에 대한 사망 위험도를 확률적으로 산출하도록 구성될 수 있다.

[0060] 한편, 프로세서 (150) 는 수신부 (110) 로부터 수신된 표본 대상자 및 피험자에 대한 나이를 기초로, 사망 예측 모델을 이용하여 피험자 (800) 의 나이에 해당하는 유사 연령 그룹에 대한 사망 위험도와 연관된 생체 신호 패턴 및 피험자 (800) 에 대하여 생성된 생체 신호 패턴을 비교하고, 그 결과를 기초로, 피검자의 연령을 고려한 사망 위험도를 확률적으로 산출하도록 구성될 수 있다.

[0061] 이에, 사망 위험도 예측 시스템 (1000) 에 따라, 본 발명의 사망 위험도 예측 디바이스 (100) 는 생체 신호 예측 디바이스 (200) 로부터 수신한 생체 신호 데이터와 의미 기록 데이터와 같은 데이터 베이스 (700) 를 기초로, 환자의 사망 위험도를 분류하고 예측할 수 있다. 나아가, 사망 위험도 예측 디바이스 (100) 는 예측된 사망 위험도에 대한 정보를 의료진 디바이스 (900) 에 제공하여, 의료진은 환자의 질병 상태에 대하여 빠르게 감지할 수 있게 된다. 그 결과, 사망 위험도 예측 시스템 (1000) 에 따라, 발명의 사망 위험도 예측 디바이스 (100) 는 환자에 대한 처치 시점을 앞당겨 치료에 대한 좋은 예후를 제공할 수 있다.

[0062] 이하에서는 도 2를 참조하여, 본 발명의 일 실시예에 따른 사망 위험도 예측 방법을 구체적으로 설명한다. 도 2는 본 발명의 일 실시예에 따른 사망 위험도 예측 방법의 절차를 도시한 것이다.

[0063] 도 2를 참조하면, 본 발명의 일 실시예에 따른 사망 위험도 예측의 절차는 다음과 같다. 먼저, 피검자에 대한 생체 신호 데이터를 수신한다 (S210). 그 다음, 패턴 생성 모델을 이용하여, 수신된 생체 신호 데이터를 기초로 피검자에 대한 생체 신호 패턴을 생성한다 (S220). 마지막으로, 생성된 생체 신호 패턴을 기초로 피검자에 대한 사망 위험도를 예측한다 (S230).

[0064] 구체적으로, 생체 신호 데이터를 수신하는 단계 (S210) 에서는 피검자에 대한 생체 신호 데이터 및 의무기록 데이터를 수신할 수 있다. 예를 들어, 생체 신호 데이터를 수신하는 단계 (S210) 에서는 생체 신호 예측 디바이스로부터 피검자에 대한 평균 혈압, 산소 포화도, 수축기 혈압, 이완기 혈압, 맥박수, 또는 약물 조치 데이터의 생체 신호 데이터를 수신할 수 있다.

[0065] 다른 실시예에서, 본 발명의 사망 위험도 예측 방법은, 피험자에 대한 성별, 생년월일, 몸무게, 입실일자, 퇴실일자, 사망일자, 병동, 진단명, 또는 담당의 정보의 의무기록 데이터를 더 수신할 수 있다.

[0066] 다른 실시예에서, 생체 신호 데이터를 수신하는 단계 (S210) 에서는 미리 결정된 시간 간격으로 피검자에 대한 생체 신호 데이터를 복수회 수신할 수 있다. 나아가, 복수회 수신된 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 보정하는 단계가 더 수행될 수 있다. 예를 들어, 보정하는 단계에서는 복수회 수신된 생체 신호 데이터 중 오류값을 갖는 생체 신호 데이터를 제거하거나, 또는 복수회 수신된 생체 신호 데이터 중 측정되지 않은 생체 신호 데이터에 대하여, 단일 대체법, 결정적 대체법, 다중 대체법 및 확률적 대체법 중 적어도 하나의 대체법을 이용하여 대체값을 갖도록 변환할 수 있다.

[0067] 다음으로, 생체 신호 패턴을 생성하는 단계 (S220) 에서는 생체 신호 데이터를 기초로 생체 신호 패턴을 생성하도록 학습된 생체 신호 패턴 생성 모델을 이용하여, 피검자에 대한 생체 신호 패턴을 생성할 수 있다. 이때, 패턴 생성 모델은 클러스터링 알고리즘에 기초하는 모델일 수 있다. 예를 들어, 생체 신호 패턴을 생성하는 단계 (S220) 에서는 클러스터링 알고리즘을 반복적으로 수행하여, 수신한 복수개의 생체 신호 각각에 대한 실루엣의 평균값을 산출하고, 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 패턴의 개수를 최적 패턴 개수로 결정할 수 있다. 나아가, 생체 신호 패턴을 생성하는 단계 (S220) 에서는 클러스터링 알고리즘을 이용하여, 결정된 최적 패턴 개수를 기초로 복수개의 생체 신호에 대한 패턴을 그룹화함으로써 하나의 생체 신호 패턴을 생성할 수 있다.



- [0068] 다른 실시예에서, 생체 신호 패턴을 생성하는 단계 (S220)에서는 패턴 생성 모델을 이용하여, 미리 결정된 시간 간격으로 피검자에 대한 생체 신호 데이터를 복수회 수신함에 따라 생성된 동일한 생체 신호 데이터의 복수개의 데이터에 대한 클러스터링이 수행될 수 있다.
- [0069] 다른 실시예에서, 생체 신호 패턴을 생성하는 단계 (S220)에서는 패턴 생성 모델을 이용하여, 복수개의 생체 신호 중 선택된 두 개의 생체 신호에 대한 유사도 및 비유사도 행렬을 산출하고, 산출된 유사도 및 비유사도를 기초로 상기 두 개의 생체 신호에 대한 상관관계를 결정할 수 있다. 나아가, 생체 신호 패턴을 생성하는 단계 (S220)에서는 생체 신호 간의 상관관계, 및 최적 패턴 개수를 기초로, 하나의 생체 신호 패턴을 생성할 수 있다.
- [0070] 다음으로, 사망 위험도를 예측하는 단계 (S230)에서는 생체 신호 패턴을 기초로 사망의 위험도를 확률적으로 예측하도록 학습된 사망 예측 모델을 이용하여, 피검자에 대한 사망 위험도를 예측할 수 있다. 이때, 사망 예측 모델은, 피검자와 상이한 복수의 표본 대상자에 대하여 생체 신호 데이터를 각각 수신하고, 패턴 생성 모델을 이용하여, 생체 신호 각각에 대한 패턴을 생성하고, 생성된 각각에 대한 패턴을 그룹화하여 복수의 표본 대상자 각각에 대한 하나의 생체 신호 패턴을 생성하고, 복수의 표본 대상자 각각에 대하여 생성된 상기 하나의 생체 신호 패턴 중, 사망 위험도와 연관된 패턴을 결정하는 단계에 의해 트레이닝된 예측 모델일 수 있다. 이에, 사망 위험도를 예측하는 단계 (S230)에서는 사망 예측 모델을 이용하여, 미리 결정된 사망 위험도와 연관된 패턴 및 피검자에 대하여 생성된 생체 신호 패턴을 비교하고, 결과를 기초로, 피검자에 대한 사망 위험도를 확률적으로 산출할 수 있다.
- [0071] 다른 실시예에서, 사망 위험도를 예측하는 단계 (S230)에서는 수신된 표본 대상자 및 피험자에 대한 나이를 기초로, 사망 예측 모델을 이용하여 피험자의 나이에 해당하는 유사 연령 그룹에 대한 사망 위험도와 연관된 생체 신호 패턴 및 피험자에 대하여 생성된 생체 신호 패턴을 비교하고, 그 결과를 기초로 피검자의 연령을 고려한 사망 위험도를 확률적으로 산출할 수 있다.
- [0072] 그 결과, 본 발명의 일 실시예에 따른 사망 위험도 예측 방법에 따라, 피검자, 예를 들어 소아 중환자에 대한 사망 위험도가 예측될 수 있다. 이에, 의료진은 사망 위험도의 변화에 따른 효과적인 조치를 취할 수 있게 된다.
- [0073] 이하에서는, 도 3 및 도 4a 내지 4c를 참조하여, 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스를 설명한다. 도 3은 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스의 구성을 예시적으로 도시한 것이다. 도 4a는 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 패턴 생성부에 의해 생성된 사망 여부에 따른 생체 신호 패턴을 예시적으로 도시한 것이다. 도 4b는 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 생체 신호 패턴 생성부에서의 패턴 수 결정을 위한 스크리 차트 (Scree chart) 분석 결과를 도시한 것이다. 도 4c는 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 생체 신호 패턴 생성부에 의해 클러스터링된 패턴에 대한 오즈 비를 산출한 결과를 도시한 것이다.
- [0074] 이때, 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스의 각각의 구성들은, 사망 위험도 예측에 이용되는 모델을 트레이닝하고 실질적으로 사망 위험도를 예측하는데 모두 이용될 수 있다. 그러나, 이에 제한되지 않고 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스는, 트레이닝, 또는 예측을 위한 각각의 구성들이 분리되어 설정될 수도 있다. 나아가, 본 발명의 일 실시예에 따른 사망 위험도 예측 디바이스는 예시로 설명된 소아 중환자의 위험도 분류에 제한되어 이용되는 것은 아니다.
- [0075] 도 3을 참조하면, 본 발명의 다른 실시예에 따른 사망 위험도 예측 디바이스 (1000)는, 크게 데이터 수신부 (300), 데이터 전처리부 (400), 생체 신호 패턴 생성부 (500), 및 사망 위험도 예측부 (600)로 구성된다.
- [0076] 보다 구체적으로, 데이터 수신부 (300)는, 피검자에 대한 평균 혈압, 산소 포화도, 수축기 혈압, 이완기 혈압, 맥박 및 약물 조치 데이터와 같은 생체 신호 예측 디바이스 (200)로부터 생체 신호 데이터 (710) 및 의무기록 데이터 (720)를 수신할 수 있다. 데이터 수신부 (300)는 선택적으로, 피험자에 대한 성별, 생년월일, 몸무게, 입실일자, 퇴실일자, 사망일자, 병동, 진단명 및 담당의 정보와 같은 의무 기록 데이터를 더 수신할 수 있다. 나아가, 데이터 수신부 (300)는 사망 위험도와 연관된 패턴 결정과 같은, 예측 모델의 학습을 위한 피검자와 상이한 복수의 표본에 대한 생체 신호 데이터 및 의무 기록 데이터를 수신할 수 있다.
- [0077] 예를 들어, 데이터 수신부 (300)는 중환자, 특히 소아 중환자에 대하여 중환자실 입실로부터 매시간 기록되는 생체 신호 데이터, 나아가 의무 기록 데이터를 수신할 수 있다.

- [0078] 데이터 전처리부 (400) 는 데이터 클리닝부 (410), 및 데이터 스케일링부 (420) 로 구성될 수 있다.
- [0079] 이때, 데이터 클리닝부 (410) 는 피검자에 대한 생체 신호 데이터에 대한 기록의 오류, 결측값을 대체하도록 구성될 수 있다. 예를 들어, 데이터 클리닝부 (410) 는 소아 중환자에 대하여 매 시간마다 수신한 생체 신호 데이터 중, 기록의 오류값을 보정하거나 결측값에 대체값을 갖도록 변환을 수행할 수 있다. 보다 구체적으로, 데이터 클리닝부 (410) 는 생체 신호별 데이터의 가용 기록 범위를 관리하고, 생체 신호에 대한 기준 범위 초과시 변환을 수행함으로써, 생체 신호 데이터별 기록 오류 데이터에 대한 수정을 수행할 수 있다. 또한, 데이터 클리닝부 (410) 는 동일한 유사 연령 그룹, 입실 후 경과 시간을 기준으로 결측값을 변환할 수 있다. 이때, 데이터 클리닝부 (410) 는 단일 대체법, 결정적 대체법, 다중 대체법 및 확률적 대체법 중 적어도 하나의 대체법을 이용할 수 있다. 예를 들어, 데이터 클리닝부 (410) 는 회귀 대체법, 최근방 대체법, 및 평균 대체법의 결정적 대체법을 순차적으로 이용하여 결측값을 결정할 수 있다. 나아가 데이터 클리닝부 (410) 는, 학습을 위한 복수의 표본 대상자에 대하여 유사 연령 그룹별, 예를 들어 0 내지 1세, 1 내지 6세, 6 내지 19세의 연령 그룹별로 상이한 데이터 클리닝 기준을 적용할 수 있다.
- [0080] 한편, 데이터 스케일링부 (420) 는 패턴 처리를 위한 수신된 상이한 단위를 갖는 생체 신호에 대한 표준화를 수행하도록 구성될 수 있다. 예를 들어, 데이터 스케일링 부 (420) 는 생체 신호의 데이터의 특성별로 평균치, 최대치를 설정하여 패턴 처리를 위한 데이터 스케일링을 탐지하고, 생체 신호 데이터별 서로 다른 단위에 대하여 패턴을 추출하도록 표준화, 인덱싱 변환을 수행할 수 있다.
- [0081] 생체 신호 패턴 생성부 (500) 는 기술 통계부 (510), 및 패턴 생성부 (520) 로 구성될 수 있다.
- [0082] 이때, 기술 통계부 (510) 는 패턴의 세부 특성을 표출하기 위한 기본 통계 데이터를 생성하도록 구성될 수 있다. 예를 들어, 기술 통계부 (510) 는 전처리된 생체 신호 데이터 각각에 대하여 기록 범위, 또는 통계적 방법에 따른 이상점을 탐지하고 변환할 수 있다.
- [0083] 한편, 패턴 생성부 (520) 는 클러스터링 알고리즘을 이용하여 생체 신호 데이터에 대한 패턴을 생성하도록 구성될 수 있다. 예를 들어, 도 4a의 (a), (b) 및 (c)를 참조하면 패턴 생성부 (520) 에 의해 이완기 혈압 (DBP), 수축기 혈압 (SBP) 및 맥박의 생체 신호 데이터 각각에 대하여 생성된 생체 신호 패턴이 도시된다. 이들 패턴 생성부 (520) 에 의해 생성된 생체 신호 패턴은 사망 여부에 따라 구별되는 형상을 나타낼 수 있다.
- [0084] 나아가, 패턴 생성부 (520) 는 복수개의 생체 신호 중 선택된 두 개의 생체 신호에 대한 유사도 및 비유사도 행렬을 산출하고, 산출된 유사도 및 비유사도를 기초로 상기 두 개의 생체 신호에 대한 상관관계, 나아가 기 입실한 소아 중환자 및 새로 입실한 소아 중환자에 대한 생체 신호 데이터의 상관 관계를 결정할 수 있다.
- [0085] 구체적인 예를 들어, 두 개의 생체 신호  $X_i$  및  $X_j$ 에 대한 상관관계는, 하기의 [수학식 1]로 산출된 유클리드 거리 (Euclidean distance), [수학식 2] 및 [수학식 3]으로 산출된 상관계수거리 (Correlation distance) 로 정의될 수 있다.

### 수학식 1

$$d_{ij} = d(X_i, X_j) = \sqrt{\sum_{m=1}^p (X_{ik} - X_{jk})^2}$$

[0086]

### 수학식 2

$$d_{ij} = d(X_i, X_j) = 1 - |Corr(X_i, X_j)|$$

[0087]

### 수학식 3

$$Corr(X_i, X_j) = \frac{\sum_{k=1}^n (X_{ik} - \bar{X}_i)(X_{jk} - \bar{X}_j)}{\sqrt{\sum_{k=1}^n (X_{ik} - \bar{X}_i)^2} \sqrt{\sum_{k=1}^n (X_{jk} - \bar{X}_j)^2}}$$

[0088]

[0089] 이때, 두 생체 신호  $X_i$  및  $X_j$ 에 대한 상관관계는 선형적 관계를 기준으로 정의될 수 있다. 즉,  $X_i$  및  $X_j$ 에 대한 상관관계수가 크면 둘 사이의 거리인  $d_{ij}$ 는 0에 가깝고, 서로 독립적인 경우, 두 생체 신호의 거리가 먼 것으로 정의될 수 있다.

[0090] 다른 실시예에서, 패턴 생성부 (520)는 클러스터링 알고리즘을 반복적으로 수행하고, 스크리 차트 분석 방법을 이용하여 복수개의 생체 신호 각각에 대한 실루엣 계수의 평균값을 산출하고, 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 패턴의 개수를 최적 패턴 개수로 결정할 수 있다.

[0091] 구체적인 예를 들어, 실루엣 계수는 하기 [수학식 4]에 의해 산출될 수 있다.

### 수학식 4

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))}$$

[0092]

[0093] 여기서,  $S(i)$ 는  $i$ 번째 데이터 포인트의 실루엣 계수를,  $a(i)$ 는  $i$ 번째 데이터 포인트와 같은 군집에 속한 다른 데이터 포인트들과의 평균거리를,  $b(i)$ 는  $i$ 번째 데이터 포인트와 가장 근접해 있는 군집에 속한 데이터 포인트들과의 평균거리를 의미할 수 있다.

[0094] 도 4b를 참조하면, 유사 연령 그룹별 사망 위험도와 연관된 패턴 생성을 위해, 패턴 생성부 (520)에 의해 산출된 실루엣 계수와, 실루엣 계수에 의해 결정된 최적 패턴의 개수가 도시된다. 이때, 복수개의 생체 신호 각각에 대하여 수학식 4를 이용하여 산출된 실루엣 계수의 평균값을 산출하고, 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 패턴의 개수를 최적 패턴 개수로 결정한다.

[0095] 도 4b의 (a)를 참조하면, 0 내지 1세 그룹에 대하여 패턴 생성부 (520)에 의해 최적 패턴 수로 결정된 패턴의 수는, 실루엣 계수의 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 5개이다. 또한, 도 4b의 (b)를 참조하면 1 내지 6세 그룹에 대하여 패턴 생성부 (520)에 의해 결정된 패턴의 수는, 실루엣 계수의 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 4개이다. 나아가, 도 4b의 (c)를 참조하면 6 내지 19세 그룹에 대하여 패턴 생성부 (520)에 의해 결정된 패턴의 수는, 실루엣 계수의 평균값이 가장 급격하게 증가하는 패턴의 개수 중, 가장 작은 값을 갖는 5개이다.

[0096] 다른 실시예에서, 패턴 생성부 (520)는 k-Means 또는 SOM 알고리즘의, 비지도학습 기반의 클러스터링 알고리즘을 이용하여, 결정된 최적 패턴 개수를 기초로 복수개의 생체 신호에 대한 패턴을 클러스터링함으로써 하나의 생체 신호 패턴을 생성할 수 있다.

[0097] 구체적인 예를 들어, 생체 신호 데이터들은 하기 [수학식 5]에 의해 각 그룹별로 중심점과 그룹 내 데이터들 간의 거리 제곱합이 최소로 하는 집합 (S)이 결정된다.

### 수학식 5

$$\arg \min_S \sum_{i=1}^k \sum_{X \in S_i} \|X - \mu_i\|^2$$

[0098]

[0099] 여기서,  $X = (X_1, X_2, \dots, X_n)$   $X = (X_1, X_2, \dots, X_n)$  는 생체 신호 데이터이고,  $\mu_i \mu_i$  는 그룹화된 집합  $S$  ( $S = \{S_1, S_2, \dots, S_k\}$   $S = \{S_1, S_2, \dots, S_k\}$ ) 의 i번째 그룹 (클러스터)  $S_i$ 의 중심점을 의미할 수 있다.

[0100] 도 4c를 참조하면, 유사 연령 그룹별 사망 위험도와 연관된 패턴 생성을 위해, 패턴 생성부 (520) 에 의해 클러스터링된 패턴에 대한 자유도 (DF, degree of freedom), 카이제곱 (Chisquare), 오즈 비 (OR, Odds ratio) 가 도시된다. 이때, 오즈 비는 상대 위기 (relative risk) 에 대한 추정치로서, 위험 인자에 노출된 대조군에 대한 실험군의 오즈와 위험 인자에 노출되지 않은 대조군에 대한 실험군의 오즈의 비율로 산출될 수 있다.

[0101] 보다 구체적으로, 오즈 비는 하기 [수학식 6]으로 산출될 수 있다.

### 수학식 6

[0102]  $OR = p/(1-p)$

[0103] 여기서, p는 사망한 환자에 대한 전체 중환자실 입원 환자수의 비율인, 중환자실 환자의 사망 확률을 의미하고, (1-p)는 생존 확률을 의미한다.

[0104] 이에, 오즈 비는 사망 위험도와 연관될 수 있어, 패턴 생성부 (520) 는 산출된 오즈 비를 기초로 사망 위험도와 연관된 패턴을 결정하게 된다.

[0105] 보다 구체적으로, 0 내지 1세 그룹에 대하여 패턴 생성부 (520) 에 의해 클러스터 1 내지 5 중, 오즈 비가 2.299, 카이제곱값이 5.313으로 가장 높은 클러스터 5가 사망 위험도와 연관된 패턴으로 결정된다. 1 내지 6세 그룹에 대하여 패턴 생성부 (520) 에 의해 클러스터 1 내지 5 중, 오즈 비가 2.623, 카이제곱값이 15.092로 가장 높은 클러스터 3이 사망 위험도와 연관된 패턴으로 결정된다. 6 내지 19세 그룹에 대하여 패턴 생성부 (520) 에 의해, 클러스터 1 내지 5 중, 오즈 비가 4.641, 카이제곱값이 29.666으로 가장 높은 클러스터 4가 사망 위험도와 연관된 패턴으로 결정된다.

[0106] 한편, 다른 실시예에서 패턴 생성부 (520) 는 미리 결정된 시간 간격으로 피검자에 대한 생체 신호 데이터를 복수회 수신함에 따라 생성된, 동일한 생체 신호 데이터에 대한 복수개의 데이터에 대하여 클러스터링을 수행하도록 구성될 수 있다.

[0107] 이에 따라, 패턴 생성부 (520) 에 의해 각각의 유사 연령 그룹에 대한 사망 위험도와 연관된 패턴인 표본 패턴이 결정될 수 있다. 나아가, 패턴 생성부 (520) 는 피검자에 대한 생체 신호 데이터를 기초로, 새로운 생체 신호 패턴을 생성할 수 있다.

[0108] 한편, 사망 위험도 예측부 (600) 는 예측 알고리즘 학습부 (610), 및 예측 알고리즘 스코어링부 (620) 로 구성될 수 있다.

[0109] 이때, 예측 알고리즘 학습부 (610) 는 기계학습, 또는 머신러닝을 이용하여 생체 신호 패턴 생성부 (500) 에 의해 생성된 표본 대상자에 대한 사망 위험도와 연관된 패턴을 입력자료로 사망의 위험도를 분류, 또는 예측하도록 모델을 학습하도록 구성될 수 있다. 예를 들어, 예측 알고리즘 학습부 (610) 는 Randomized Decision forest 알고리즘, Penalized Logistic Regression 알고리즘의 기계학습에 의한 알고리즘 또는, Neural Network 알고리즘, Deep Learning 알고리즘의 딥 러닝 알고리즘에 기초하여, 입력된 패턴을 기초로 소아 중환자에 대한 사망의 위험도를 예측하도록 학습될 수 있다.

[0110] 예측 알고리즘 스코어링부 (620) 는 예측 알고리즘 학습부 (610) 에 의해 학습된 예측 모델을 이용하여, 피험자에 대하여 생성된 새로운 생체 신호 패턴을 기초로 사망 위험도를 예측하도록 구성될 수 있다. 예를 들어, 알고리즘 스코어링부 (620) 는 예측 모델에 새로 입실한 소아 중환자에 대한 생체 신호 패턴을 적용하여 사망 위험도를 확률적으로 산출하고, 이를 기초로 사망 위험도를 결정할 수 있다.

[0111] 이에, 본 발명의 사망 위험도 예측 디바이스 (1000) 는 중환자, 특히 소아 중환자에 대하여 환자의 위험도를 분류하고 예측함으로써, 중환자들의 상태를 관리하는 시스템에 이용될 수 있다.

[0112] 이하에서는, 실시예 1을 참조하여 본 발명의 일 실시예에 따른 사망 위험도 예측 방법 및 이를 이용한 디바이스에 대한 평가의 결과를 설명한다.



- [0113] 실시예 1: 본 발명의 일 실시예에 따른 사망 위험도 예측 방법 및 이를 이용한 디바이스에 대한 평가
- [0114] 본 평가에서는 중환자실에 입실한 19 세 미만의 소아 중환자의 1730 건에 대한 생체 신호 데이터 및 의무 기록 데이터가 이용되었다. 보다 구체적으로, 0 내지 1 세, 1 내지 6 세, 및 6 내지 19 세의 세 가지의 유사 연령 그룹에 대한 사망도 예측 평가가 수행되었다. 나아가, 생체 신호 데이터로 수축기 혈압 (SBP), 이완기 혈압 (DBP), 및 맥박 수 (PRS) 를 이용하는 모델 ([1] form\_1) 과 수축기 혈압 (SBP), 이완기 혈압 (DBP), 맥박 수 (PRS), 및 산소 포화도 (SpO2) 를 이용하는 모델 ([2] form\_2) 의 두 가지 사망 예측 모델에 대한 평가가 수행되었다. 이때, 학습을 위한 데이터 세트 및 평가를 위한 데이터 세트는 7:3의 비율로 설정되었고, 두 모델에 적용한 알고리즘은 Decision tree, Random Forest 및 Logistic Regression이다.
- [0115] 도 5a 내지 5d는 본 발명의 일 실시예에 따른 사망 위험도 예측 방법 및 이를 이용한 디바이스에 대한 평가의 결과를 도시한 것이다.
- [0116] 도 5a를 참조하면, 0 내지 1 세 그룹에 대한 성능 평가 결과가 도시된다. 보다 구체적으로, 우수한 진단 능력과 연관된, 결과 적중률을 의미하는 AUC (Area Under the Curve) 값은 [1] form\_1 및 [2] form\_2의 두 모델에서 Random Forest 알고리즘을 적용했을 때 각각 0.630, 0.717로 나머지 Decision tree 및 Logit Regression 알고리즘을 적용했을 때 높은 것으로 나타난다. 특히, 생체 신호 데이터로 산소 포화도를 추가적으로 이용한 Random Forest 알고리즘을 적용한 [2] form\_2 모델은 AUC값이 다른 모델들보다 높아, 사망 위험도 예측에 있어서 가장 좋은 성능을 보이는 것으로 나타난다. 나아가, 이용한 Random Forest 알고리즘을 적용한 [1] form\_1 및 [2] form\_2 모델의 정확도 (accuracy) 는 0.860이고, 민감도 (sensitivity) 는 1.000로 나타난다. 나아가, 검출률 (detection rate) 는 0.860으로, 다른 모델들보다 가장 정확하게 사망의 위험도를 예측할 수 있다.
- [0117] 도 5b를 참조하면, 1 내지 6 세 그룹에 대한 성능 평가 결과가 도시된다. 보다 구체적으로, AUC값은 [1] form\_1 및 [2] form\_2의 두 모델에서 Random Forest 알고리즘을 적용했을 때 각각 0.656, 0.706으로 나머지 Decision tree 및 Logit Regression 알고리즘을 적용했을 때 높은 것으로 나타난다. 특히, 생체 신호 데이터로 산소 포화도를 추가적으로 이용한 Random Forest 알고리즘을 적용한 [2] form\_2 모델은 AUC값이 다른 모델들보다 높아, 사망 위험도 예측에 있어서 가장 좋은 성능을 보이는 것으로 나타난다. 나아가, 이용한 Random Forest 알고리즘을 적용한 [1] form\_1 및 [2] form\_2 모델의 정확도는 각각 0.869, 0.864이고, 민감도는 각각 0.983, 0.977이고, 검출률은 각각 0.859, 0.854로 나타난다. 이에, Random Forest 알고리즘을 적용한 [1] form\_1 및 [2] form\_2 모델은 다른 모델들보다 가장 정확하게 사망의 위험도를 예측할 수 있다.
- [0118] 도 5c를 참조하면, 6 내지 19 세 그룹에 대한 성능 평가 결과가 도시된다. 보다 구체적으로, AUC값은 [1] form\_1 및 [2] form\_2의 두 모델에서 Random Forest 알고리즘을 적용했을 때 각각 0.768, 0.791로 나머지 Decision tree 및 Logit 알고리즘을 적용했을 때 높은 것으로 나타난다. 특히, 생체 신호 데이터로 산소 포화도를 추가적으로 이용한 Random Forest 알고리즘을 적용한 [2] form\_2 모델은 AUC값이 다른 모델들보다 높아, 사망 위험도 예측에 있어서 가장 좋은 성능을 보이는 것으로 나타난다. 나아가, 이용한 Random Forest 알고리즘을 적용한 [1] form\_1 및 [2] form\_2 모델의 정확도는 각각 0.818, 0.812이고, 민감도는 1.000이고, 검출률은 0.812로 나타난다. 이에, Random Forest 알고리즘을 적용한 [1] form\_1 및 [2] form\_2 모델은 다른 모델들보다 가장 정확하게 사망의 위험도를 예측할 수 있다.
- [0119] 도 5d를 참조하면, 0 내지 1 세, 1 내지 6 세, 및 6 내지 19 세의 세 가지의 유사 연령 그룹에 대하여 선택된 사망 위험도와 연관된 패턴 클러스터를 대상으로 수행한 사망의 위험도 예측 평가의 결과가 도시된다. 보다 구체적으로, 0 내지 1 세의 그룹의 경우, 오즈 비의 산출 결과에 따라 미리 결정된 사망 위험도와 연관된 패턴 클러스터 5를 적용하였고, 1 내지 6 세의 그룹의 경우, 오즈 비의 산출 결과에 따라 미리 결정된 사망 위험도와 연관된 패턴 클러스터 3을 적용하였다. 또한, 6 내지 19 세의 그룹의 경우, 오즈 비의 산출 결과에 따라 미리 결정된 사망 위험도와 연관된 패턴 클러스터 4, 5를 적용하였다.
- [0120] 그 결과, 세 유사 연령 그룹 모두에서 [1] form\_1 및 [2] form\_2 모델의 AUC는 각각 0.655, 0.624로, 정확도는 각각 0.817, 0.803으로, 민감도는 각각 0.956, 0.915로 분석되었고, 검출률은 각각 0.793, 0.761으로 분석되었다. 이에, 본 발명의 사망 위험도 예측 디바이스는, 유사 연령 그룹에 따라 약 0.7 내지 0.8의 AUC로 사망 여부를 예측할 수 있다.
- [0121] 이상의 실시예 1의 결과로, 높은 정확도, 민감도로 사망의 여부를 예측하는 예측 모델을 이용한 본 발명의 일 실시예에 따른 사망 위험도 예측 방법 및 디바이스는, 의료진이 중환자에 대하여 효과적인 조치를 취할 수 있도록 정보를 제공할 수 있는 효과가 있다. 이에, 본 발명은 중환자에 대한 생존률 증가에 기인할 수 있는 효과가

있다.

[0122] 특히, 본 발명은, 데이터의 분석이 어렵고 패턴 추출이 어려운 소아 중환자에 대한 생체 신호 데이터를 본 발명의 다양한 실시예에서 이용되는 예측 모델에 적용함으로써, 소아 중환자에 대하여 민감도 및 정확도 높게 사망 위험도를 예측할 수 있는 효과가 있다.

[0123] 이상 첨부된 도면을 참조하여 본 발명의 실시 예들을 더욱 상세하게 설명하였으나, 본 발명은 반드시 이러한 실시 예로 국한되는 것은 아니고, 본 발명의 기술사상을 벗어나지 않는 범위 내에서 다양하게 변형 실시될 수 있다. 따라서, 본 발명에 개시된 실시 예들은 본 발명의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시 예에 의하여 본 발명의 기술 사상의 범위가 한정되는 것은 아니다. 그러므로, 이상에서 기술한 실시 예들은 모든 면에서 예시적인 것이며 한정적이 아닌 것으로 이해해야만 한다. 본 발명의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 발명의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

### 부호의 설명

[0124] 100, 100': 사망 위험도 예측 디바이스

110: 수신부

120: 입력부

130: 표시부

140: 저장부

150: 프로세서

200: 생체 신호 계측 디바이스

300: 데이터 수신부

400: 데이터 전처리부

410: 데이터 클리닝부

420: 데이터 스케일링부

500: 생체 신호 패턴 생성부

510: 기술 통계부

520: 패턴 생성부

600: 사망 위험도 예측부

610: 예측 알고리즘 학습부

620: 예측 알고리즘 스코어링부

700: 데이터베이스

710: 생체 신호 데이터

720: 의무 기록 데이터


800: 환자

900: 의료진 단말기


1000: 사망 위험도 예측 시스템

도면


도면1a




도면1b




도면2




도면3



도면4a



도면4b



도면4c

	Cluster	DF	Chisquare	Pr > x2	OR	OR (95% CI)	
0세 내지 1세	Cluster 1	61	0.069	0.792	1.199	0.491	2.639
	Cluster 2	137	0.570	0.450	0.745	0.363	1.447
	Cluster 3	104	0.007	0.932	1.086	0.526	2.127
	Cluster 4	85	2.879	0.909	0.414	0.125	1.075
	Cluster 5	56	5.313	0.021	2.299	1.088	4.632
1세 내지 6세	Cluster 1	83	1.070	0.301	1.404	0.754	2.524
	Cluster 2	56	0.000	1.000	1.028	0.447	2.152
	Cluster 3	107	15.092	0.000	2.623	1.568	4.367
	Cluster 4	96	2.514	0.113	0.544	0.241	1.109
	Cluster 5	140	11.467	0.001	0.294	0.126	0.609
6세 내지 19세	Cluster 1	151	11.081	0.001	0.345	0.167	0.654
	Cluster 2	102	0.033	0.857	0.915	0.496	1.614
	Cluster 3	148	2.372	0.124	0.645	0.362	1.103
	Cluster 4	33	29.666	0.000	4.641	2.491	8.561
	Cluster 5	124	2.718	0.099	1.512	0.922	2.443



0세 내지 1세													
*Training : Test = 70% : 30% as Random													
Input Variables													
Model	DBP	SBP	PRS	SPO2									
[1] form_1	○	○	○										
[2] form_2	○	○	○	○									
Decision tree													
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL			
[1] form_1	0.588	0.853	0.984	0.048	0.847	127	20	2	1	153			
[2] form_2	0.662	0.847	0.977	0.048	0.840	126	20	3	1	153			
Random Forest													
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL			
[1] form_1	0.630	0.860	1.000	0.000	0.860	129	21	0	0	153			
[2] form_2	0.717	0.860	1.000	0.000	0.860	129	21	0	0	153			
Logit													
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL			
[1] form_1	0.503	0.872	0.992	0.100	0.858	127	18	1	2	151			
[2] form_2	0.503	0.853	0.956	0.067	0.845	109	14	5	1	132			

도면5a

1세 내지 6세													
*Training : Test = 70% : 30% as Random													
Input Variables													
Model	DBP	SBP	PRS	SPO2									
[1] form_1	○	○	○										
[2] form_2	○	○	○	○									
Decision tree													
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL			
[1] form_1	0.620	0.834	0.920	0.240	0.804	160	19	14	6	202			
[2] form_2	0.539	0.849	0.948	0.160	0.829	165	21	9	4	202			
Random Forest													
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL			
[1] form_1	0.656	0.869	0.983	0.080	0.859	171	23	3	2	202			
[2] form_2	0.706	0.864	0.977	0.080	0.854	170	23	4	2	202			
Logit													
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL			
[1] form_1	0.654	0.857	0.965	0.083	0.847	166	22	6	2	199			
[2] form_2	0.680	0.817	0.879	0.278	0.789	138	13	19	5	178			

6세 내지 19세

\*Training : Test = 70% : 30% as Random

Input Variables												
Model	DBP	SBP	PRS	SPO2								
[1] form_1	○	○	○									
[2] form_2	○	○	○	○								
Decision tree												
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL		
[1] form_1	0.529	0.782	0.949	0.063	0.771	131	30	7	2	173		
[2] form_2	0.685	0.806	0.928	0.281	0.753	128	23	10	9	173		
Random Forest												
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL		
[1] form_1	0.768	0.818	1.000	0.031	0.812	138	31	0	1	173		
[2] form_2	0.791	0.812	1.000	0.000	0.812	138	32	0	0	173		
Logit												
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL		
[1] form_1	0.655	0.817	0.956	0.143	0.793	130	24	6	4	167		
[2] form_2	0.624	0.803	0.915	0.250	0.761	108	18	10	6	145		

0세 내지 1세 (Cluster-5)										
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL
[1] form_1	0.655	0.817	0.956	0.143	0.793	130	24	6	4	167
[2] form_2	0.624	0.803	0.915	0.250	0.761	108	18	10	6	145
1세 내지 6세 (Cluster-3)										
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL
[1] form_1	0.655	0.817	0.956	0.143	0.793	130	24	6	4	167
[2] form_2	0.624	0.803	0.915	0.250	0.761	108	18	10	6	145
6세 내지 19세 (Cluster-4,5)										
Model	AUC	Accuracy	Sensitivity	Specificity	Detection_Rate	C11	C12	C21	C22	TTL
[1] form_1	0.655	0.817	0.956	0.143	0.793	130	24	6	4	167
[2] form_2	0.624	0.803	0.915	0.250	0.761	108	18	10	6	145