(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2025년05월09일
(11) 등록번호 10-2803901
(24) 등록일자 2025년04월29일

(51) 국제특허분류(Int. Cl.)
G16H 50/20 (2018.01) *G06N 20/00* (2019.01)
G06N 3/045 (2023.01) *G06N 3/0464* (2023.01)
G06N 3/08 (2023.01) *G16H 10/60* (2018.01)
G16H 50/70 (2018.01)
(52) CPC특허분류
G16H 50/20 (2018.01)
G06N 20/00 (2021.08)
(21) 출원번호 10-2023-0195791
(22) 출원일자 2023년12월28일
심사청구일자 2023년12월28일
(56) 선행기술조사문헌
JP2005537068 A
JP2020534061 A
JP2015096212 A

(73) 특허권자
충북대학교병원
충북 청주시 흥덕구 개신동 62번지
(72) 발명자
신윤미
충청북도 청주시 흥덕구 대농로 17,109동 2004호
박승
충청북도 청주시 흥덕구 서현로 62, 305동 1002호 (가경동, 청주가경아이파크 3단지)
김근형
충청북도 청주시 서원구 1순환로727번길 11-14, 연수빌 102호 (사창동)
(74) 대리인
특허법인본

전체 청구항 수 : 총 11 항 심사관 : 여정진

(54) 발명의 명칭 **FT-GAT(Feature Tokenizer - Graph Attention Network) 모델 기반의 인공호흡 환자의 자가호흡 성공률을 예측하기 위한 전자 장치 및 이의 제어 방법**

(57) 요 약

전자 장치 및 이의 제어 방법이 개시된다. 본 개시에 따른 전자 장치는, 환자 정보에 기초하여 환자의 자가호흡 성공률 예측 값을 획득하기 위한 FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 저장하는 메모리; 및 메모리와 연결되어 FT-GAT 모델에 환자의 적어도 하나의 특징 값을 입력하여 환자의 자가 호흡 성공률 예측 값을 식별하는 프로세서;를 포함하고, FT-GAT 모델은, 환자 정보에 대응되는 특징 값을 잠재 공간 상의 임베딩 값으로 변환하는 토크나이저 모듈, 특징 값에 대응되는 노드를 업데이트하는 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈 및 업데이트된 노드가 적용되어 임베딩 값에 대응되는 환자의 자가호흡 성공률 예측 값을 출력하는 멀티 레이어 퍼셉트론(MLP, Multi Layer Perceptron) 모듈을 포함할 수 있다.

대 표 도 - 도2

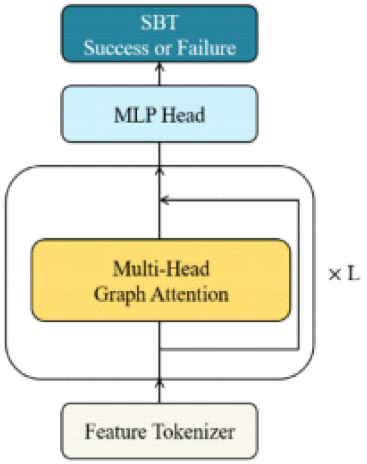

(52) CPC특허분류
G06N 3/045 (2023.01)
G06N 3/0464 (2023.01)
G06N 3/08 (2023.01)
G16H 10/60 (2021.08)
G16H 50/70 (2018.01)

공지예외적용 : 있음

명 세 서

청구범위

청구항 1

전자 장치에 있어서,

환자 정보에 기초하여 환자의 자가호흡 성공률 예측 값을 획득하기 위한 FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 저장하는 메모리; 및

상기 메모리와 연결되어 상기 FT-GAT 모델에 환자의 적어도 하나의 특징 값을 입력하여 상기 환자의 자가 호흡 성공률 예측 값을 식별하는 프로세서;를 포함하고,

상기 FT-GAT 모델은,

상기 환자 정보에 대응되는 특징 값을 잠재 공간 상의 임베딩 값으로 변환하는 토크나이저(Feature-Tokenizer) 모듈, 상기 특징 값에 대응되는 노드를 업데이트하는 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈 및 상기 업데이트된 노드가 적용되어 상기 임베딩 값에 대응되는 상기 환자의 자가호흡 성공률 예측 값을 출력하는 멀티 레이어 퍼셉트론(MLP, Multi Layer Perceptron) 모듈을 포함하는, 전자 장치.

청구항 2

제1항에 있어서,

상기 프로세서는,

상기 환자 정보에 대응되는 특징 값에 가중치를 곱하고 편향을 더하여 상기 임베딩 값을 획득하고,

상기 특징 값은,

상기 환자 정보에 대응되는 카테고리 및 상기 환자 정보에 대응되는 정량 수치 중 적어도 하나인, 전자 장치.

청구항 3

제1항에 있어서,

멀티 헤드 그래프 어텐션 모듈은,

상기 환자 정보에 대응되는 제1 노드를 포함하는 적어도 하나의 싱글 그래프 어텐션 레이어(Single Graph Attention Layer)를 포함하고,

상기 프로세서는,

상기 제1 노드를 선형 변환(Linear Transform)하여 제2 노드를 식별하고,

상기 제2 노드에 인접한 적어도 하나의 제3 노드의 중요도를 식별하고,

상기 적어도 하나의 제3 노드의 중요도를 정규화하여 상기 적어도 하나의 제3 노드 각각에 대응되는 어텐션 계수(Attention Coefficient)를 식별하고,

상기 적어도 하나의 제3 노드 및 상기 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 상기 제2 노드를 업데이트하여 제4 노드를 식별하는, 전자 장치.

청구항 4

제3항에 있어서,

상기 프로세서는,

상기 적어도 하나의 제3 노드 및 상기 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 연쇄 연산 및 평균 연산 중 적어도 하나의 연산을 수행하여 상기 제2 노드를 업데이트하여 상기 제4 노드를 식별하는, 전자 장치.

청구항 5

제3항에 있어서,

상기 프로세서는,

상기 적어도 하나의 제3 노드 및 상기 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 상기 제2 노드를 복수 회 업데이트하여 상기 제4 노드를 식별하는, 전자 장치.

청구항 6

제3항에 있어서,

상기 프로세서는,

상기 제4 노드를 선형 변환하여 제5 노드를 식별하고,

상기 멀티 헤드 그래프 어텐션 모듈의 출력 데이터에 스킵 연결(Skip Connection)을 적용하여 상기 멀티 헤드 그래프 어텐션 모듈에 입력되기 전 상태의 적어도 하나의 싱글 그래프 어텐션 레이어 간의 정보를 조합하는, 전자 장치.

청구항 7

제6항에 있어서,

상기 제1 노드는,

상기 제2 노드에 대응되는 차원과 상이한 차원에 대응되고,

상기 제4 노드에 대응되는 차원과 상이한 차원에 대응되고,

상기 제5 노드에 대응되는 차원과 동일한 차원에 대응되는, 전자 장치.

청구항 8

제1항에 있어서,

상기 프로세서는,

상기 멀티 헤드 그래프 어텐션 모듈에 포함된 적어도 하나의 노드를 평탄화하여 정렬하고,

상기 정렬된 적어도 하나의 노드를 배치 정규화(Batch Normalization) 및 정류 선형 유닛(ReLU, Rectified Linear Unit) 활성화 함수를 포함하는 싱글 연결 레이어에 적용하는, 전자 장치.

청구항 9

제1항에 있어서,

상기 멀티 레이어 퍼셉트론 모듈은,

시그모이드(Sigmoid) 활성화 함수를 포함하고,

상기 프로세서는,

상기 멀티 레이어 퍼셉트론 모듈의 출력 값에 대응되는 상기 환자의 자가 호흡 성공률을 획득하는, 전자 장치.

청구항 10

FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 포함하는 전자 장치의 제어 방법에 있어서,

환자 정보에 대응되는 특징 값을 토크나이저 모듈에 입력하여 잠재 공간 상의 임베딩 값을 식별하는 단계;

상기 특징 값에 대응되는 노드를 업데이트하도록 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈을 제어하는 단계; 및

상기 임베딩 값을 상기 업데이트된 노드가 적용된 멀티 레이어 퍼셉트론 모듈에 입력하여 상기 환자의 자가호흡

성공률 예측 값을 획득하는 단계;를 포함하는, 제어 방법.

청구항 11

전자 장치의 프로세서의 의해 실행되어 상기 전자 장치가 제10항의 제어 방법을 수행하도록 하는 적어도 하나의 인스트럭션이 저장된 비일시적 컴퓨터 판독가능 기록매체.

발명의 설명

기 술 분 야

[0001] 본 개시는 환자의 자가호흡 성공률을 예측하기 위한 전자 장치 및 이의 제어 방법에 관한 것으로, 더욱 상세하게는, FT-GAT(Feature Tokenizer - Graph Attention Network) 모델에 기반하여 환자 정보를 이용해 인공호흡 환자의 자가호흡 성공률을 예측하기 위한 전자 장치 및 이의 제어 방법에 관한 것이다.

본 연구는 보건복지부의 재원으로 한국보건산업진흥원의 보건의료기술연구개발사업 지원에 의하여 이루어진 것임(과제고유번호 : HI21C1074).

배 경 기 술

[0002] 기계식 인공호흡(MV, Mechanical Ventilation)는 급성 호흡 부전 환자의 증상을 개선하기 위해 일시적으로 인공호흡 기능을 대체하는 치료 방식이다. 이전 통계에 따르면 중환자실(ICU, Intensive Care Unit)에 입원한 환자의 39%는 침습적 인공호흡이 필요하다. COVID-19 팬데믹은 급성 호흡곤란 증후군에서 혈관 내 기계식 인공호흡을 포함한 산소 치료 및 호흡기 지원 기계의 중요성을 보여준다.

[0003] 그러나 기계식 인공호흡은 인공호흡기 관련 폐렴, 횡격막 및 근육 약화, 후두 손상, 연하곤란과 같은 장기적인 합병증을 포함한 인공호흡기 관련 합병증을 유발할 수 있으므로 환자에게 추가적인 위험을 초래한다. 또한 장기적인 기계식 인공호흡 사용은 사망률 증가, 생존 후 의료 시스템 사용 연장, 심리적 문제 및 경제적 부담과 관련이 있다. 합병증을 최소화하기 위해 의사는 환자가 기계식 인공호흡을 뗄 준비가 되는 즉시 기계식 인공호흡을 끊도록 시도해야 한다. 이 접근 방식은 중환자실의 제한된 수용 능력을 고려할 때 다른 중환자에게 의료 자원을 재분배하는 데에도 도움이 될 것이다.

[0004] 기계식 인공호흡으로부터 환자를 해방시키기 위해 의사는 일반적으로 3단계 접근 방식을 따른다. 첫 번째 단계는 활력 징후, 정신 상태, 상태 개선, 산소 요구량, 인공호흡기 설정 등의 지표를 바탕으로 환자의 상태가 '인공호흡기 제거 준비' 요건을 충족하는지 평가하는 것이다. 그 후 의사는 30분~2시간 동안 인공호흡기 지원을 최소화하거나 전혀 하지 않은 상태에서 환자가 호흡할 수 있는지 평가하는 자가호흡 시도(SBT, Spontaneous Breathing Trial)를 진행한다. 자가호흡 시도 방법에는 인공호흡기 지원이 없는 T-piece 시험과 낮은 인공호흡기 지원이 포함된다. 자가호흡 시도의 낮은 인공호흡기 지원 모드에는 일반적으로 최대 5-7cmH_2O의 압력 지원 인공호흡(PSV, Pressure Support Ventilation)이 포함되며, 호기말 양압기(PEEP, Positive End-Expiratory Pressure) 유무에 관계없이 지속적 기도 양압(CPAP, Continuous Positive Airway Pressure) 단독(즉, 흡기 압력 지원 없음) 또는 자동 튜브 보정. 자가호흡 시도 성공 여부는 기관내 삽관 가능성에 대한 객관적인 인사이트를 제공하며, 이는 기계식 인공호흡 해제를 위한 마지막 단계이다.

[0005] 많은 연구자들이 급속 얕은 호흡 지수(RSBI, Rapid Shallow Breathing Index), 심박수 변동성(HRV, Heart Rate Variability) 또는 최대 흡기 및 호기 압력과 같이 기계식 인공호흡 해제 성공을 예측할 수 있는 강력한 지표를 찾는 데 주력해 왔지만, 아직 강력한 싱글 지표는 발견되지 않았다. 실제로 기계식 인공호흡 해제 과정의 시작 여부는 다양한 임상 상황과 기계식 인공호흡 해제 프로토콜을 기반으로 한 집중치료 의사의 다차원적 판단에 따라 결정된다. 그러나 환자의 25~40%가 첫 번째 자가호흡 시도에 실패하고 10~25%가 발관 실패를 경험하며, 이는 기관이나 의사에 따라 다르게 나타난다.

선행기술문헌

특허문헌

(특허문헌 0001) 등록특허공보 제10-2168304호

발명의 내용

해결하려는 과제

[0006] 중환자실을 포함한 다양한 의료 지원 시스템을 위한 인공지능(AI)이 개발되고 있다. 한국에서는 중환자실의 많은 중환자실 전문의들의 노력에도 불구하고 중증 중환자의 기계식 호흡을 해제하는 것은 중증 중환자나 호흡기 치료 전문가가 아닌 의사에게 의존하고 있다. 이 경우 조기 퇴원 또는 장기화될 가능성이 높다. 따라서 임상의의 의사 결정을 지원하기 위해 기계식 인공호흡으로부터 적절하고 조기에 자유로워질 수 있는 보다 유용한 딥러닝 모델을 개발하는 것을 목표로 한다.

[0007] 본 연구는 두 단계로 진행되며, 본 연구는 자가호흡 시도 성공 예측을 위한 첫 번째 단계이다. 또한, 이 연구는 조안나 브릭스 인스티튜트(JBI, Joanna Briggs Institute)의 중요 평가 체크리스트(부록 표 1)를 활용하여 체계적으로 진행되었다. 이 연구는 표 형식 데이터에 포함된 특징 값(특징 값은 인자 또는 변수일 수 있음)을 폐 전문의의 관점을 반영하는 그래프로 변환하고 분석한 최초의 연구이다.

[0008] 본 개시의 목적들은 이상에서 언급한 목적으로 제한되지 않으며, 언급되지 않은 본 개시의 다른 목적 및 장점들은 하기의 설명에 의해서 이해될 수 있고, 본 개시의 실시 예에 의해 보다 분명하게 이해될 것이다. 또한, 본 개시의 목적 및 장점들은 특허 청구 범위에 나타낸 수단 및 그 조합에 의해 실현될 수 있음을 쉽게 알 수 있을 것이다.

과제의 해결 수단

[0009] 본 실시 예에 따른 전자 장치는, 환자 정보에 기초하여 환자의 자가호흡 성공률 예측 값을 획득하기 위한 FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 저장하는 메모리; 및 상기 메모리와 연결되어 상기 FT-GAT 모델에 환자의 적어도 하나의 특징 값을 입력하여 상기 환자의 자가 호흡 성공률 예측 값을 식별하는 프로세서;를 포함하고, 상기 FT-GAT 모델은, 상기 환자 정보에 대응되는 특징 값을 잠재 공간 상의 임베딩 값으로 변환하는 토크나이저(Feature-Tokenizer) 모듈, 상기 특징 값에 대응되는 노드를 업데이트하는 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈 및 상기 업데이트된 노드가 적용되어 상기 임베딩 값에 대응되는 상기 환자의 자가호흡 성공률 예측 값을 출력하는 멀티 레이어 퍼셉트론(MLP, Multi Layer Perceptron) 모듈을 포함할 수 있다.

[0010] 한편, 상기 프로세서는, 상기 환자 정보에 대응되는 특징 값에 가중치를 곱하고 편향을 더하여 상기 임베딩 값을 획득하고, 상기 특징 값은, 상기 환자 정보에 대응되는 카테고리 및 상기 환자 정보에 대응되는 정량 수치 중 적어도 하나일 수 있다.

[0011] 한편, 멀티 헤드 그래프 어텐션 모듈은, 상기 환자 정보에 대응되는 제1 노드를 포함하는 적어도 하나의 싱글 그래프 어텐션 레이어(Single Graph Attention Layer)를 포함하고, 상기 프로세서는, 상기 제1 노드를 선형 변환(Linear Transform)하여 제2 노드를 식별하고, 상기 제2 노드에 인접한 적어도 하나의 제3 노드의 중요도를 식별하고, 상기 적어도 하나의 제3 노드의 중요도를 정규화하여 상기 적어도 하나의 제3 노드 각각에 대응되는 어텐션 계수(Attention Coefficient)를 식별하고, 상기 적어도 하나의 제3 노드 및 상기 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 상기 제2 노드를 업데이트하여 제4 노드를 식별할 수 있다.

[0012] 한편, 상기 프로세서는, 상기 적어도 하나의 제3 노드 및 상기 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 연쇄 연산 및 평균 연산 중 적어도 하나의 연산을 수행하여 상기 제2 노드를 업데이트하여 상기 제4 노드를 식별하는, 전자 장치.

[0013] 한편, 상기 프로세서는, 상기 적어도 하나의 제3 노드 및 상기 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 상기 제2 노드를 복수 회 업데이트하여 상기 제4 노드를 식별할 수 있다.

[0014] 한편, 상기 프로세서는, 상기 제4 노드를 선형 변환하여 제5 노드를 식별하고, 상기 멀티 헤드 그래프 어텐션 모듈의 출력 데이터에 스킵 연결(Skip Connection)을 적용하여 상기 멀티 헤드 그래프 어텐션 모듈에 입력되기 전 상태의 적어도 하나의 싱글 그래프 어텐션 레이어 간의 정보를 조합할 수 있다.

[0015] 한편, 상기 제1 노드는, 상기 제2 노드에 대응되는 차원과 상이한 차원에 대응되고, 상기 제4 노드에 대응되는 차원과 상이한 차원에 대응되고, 상기 제5 노드에 대응되는 차원과 동일한 차원에 대응될 수 있다.

[0016] 한편, 상기 프로세서는, 상기 멀티 헤드 그래프 어텐션 모듈에 포함된 적어도 하나의 노드를 평탄화하여 정렬하

고, 상기 정렬된 적어도 하나의 노드를 배치 정규화(Batch Normalization) 및 정류 선형 유닛(ReLU, Rectified Linear Unit) 활성화 함수를 포함하는 싱글 연결 레이어에 적용할 수 있다.

[0017] 한편, 상기 멀티 레이어 퍼셉트론 모듈은, 시그모이드(Sigmoid) 활성화 함수를 포함하고, 상기 프로세서는, 상기 멀티레이어 퍼센트론 모듈의 출력 값에 대응되는 상기 환자의 자가 호흡 성공률을 획득할 수 있다.

[0018] FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 포함하는 전자 장치의 제어 방법에 있어서, 환자 정보에 대응되는 특징 값을 토크나이저 모듈에 입력하여 잠재 공간 상의 임베딩 값을 식별하는 단계; 상기 특징 값에 대응되는 노드를 업데이트하도록 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈을 제어하는 단계; 및 상기 임베딩 값을 상기 업데이트된 노드가 적용된 상기 멀티 레이어 퍼셉트론 모듈에 입력하여 상 기 환자의 자가호흡 성공률 예측 값을 획득하는 단계;를 포함할 수 있다.

[0019] 본 개시에 따른 비일시적 컴퓨터 판독가능 기록매는 전자 장치의 프로세서의 의해 실행되어 상기 전자 장치의 제어 방법을 수행하도록 하는 적어도 하나의 인스트럭션이 저장된 것일 수 있다.

발명의 효과

[0020] 환자 정보에 기초하여 기계식 인공호흡으로부터 적절하고 조기에 자유로워질 수 있는, 자가호흡이 가능성의 확률을 예측하여 유용한 딥러닝 모델을 개발하여 임상의의 의사 결정을 도울 수 있다.

도면의 간단한 설명

[0021] 본 개시의 특정 실시 예의 양상, 특징 및 이점은 첨부된 도면들을 참조하여 후술되는 설명을 통해 보다 명확해질 것이다.

도 1은 본 개시의 일 실시 예에 따른, 전자 장치의 구성을 설명하기 위한 블록도이다.

도 2는 본 개시의 일 실시 예에 따른, 토크나이저 모듈, 멀티 헤드 그래프 어텐션 모듈, 멀티 레이어 퍼셉트론 모듈을 포함하는 FT-GAT 모델을 설명하기 위한 블록도이다.

도 3은 본 개시의 일 실시 예에 따른, 환자 정보 및 기계식 인공호흡과 관련된 제반 정보를 나타내기 위한 표이다.

도 4는 본 개시의 일 실시 예에 따른, 중환자실의 환자 정보 및 자가호흡 시도와 관련된 성공 및 실패를 나타내기 위한 흐름도이다.

도 5는 본 개시의 일 실시 예에 따른, 자가호흡 시도의 실패 및 성공 과정을 설명하기 위한 도면이다.

도 6은 본 개시의 일 실시 예에 따른, 환자 정보를 임베딩 값으로 변환하는 토크나이저의 동작을 설명하기 위한 도면이다.

도 7은 본 개시의 일 실시 예에 따른, 환자 정보의 특징 값에 대응되는 복수의 노드 및 복수의 노드를 연결하는 엣지를 도시한 도면이다.

도 8은 본 개시의 일 실시 예에 따른, 환자 정보의 특징 값에 대응되는 각각의 노드 별 어텐션 계수를 식별하는 어텐션 메커니즘을 설명하기 위한 도면이다.

도 9는 본 개시의 일 실시 예에 따른, 인접 노드 및 인접 노드의 어텐션 계수에 기초하여 환자 정보의 특징 값에 대응되는 각각의 노드를 업데이트하는 동작을 설명하기 위한 도면이다.

도 10은 본 개시의 일 실시 예에 따른, FT-GAT 모델을 이용하여 자가호흡 시도의 성공률을 예측하는데 필요한 하이퍼 파라미터를 설명하기 위한 표이다.

도 11은 본 개시의 일 실시 예에 따른, FT-GAT 모델을 이용하여 자가호흡 시도의 성공률 예측과 관련된 환자 정보를 나타내는 표이다.

도 12는 본 개시의 일 실시 예에 따른, FT-GAT 모델의 자가호흡 시도의 성공률 예측에 대한 성능을 평가한 실험 자료를 나타내는 도면이다.

도 13은 본 개시의 일 실시 예에 따른, FT-GAT 모델의 자가호흡 시도의 성공률 예측에 대한 성능을 평가한 실험 자료를 나타내는 표이다.

도 14는 본 개시의 일 실시 예에 따른, FT-GAT 모델과 다른 모델 간의 성능 비교를 설명하기 위한 지표들을 나타내는 표이다.

도 15는 본 개시의 일 실시 예에 따른, FT-GAT 모델에 포함된 각 노드의 구조 별 실험 결과를 나타내는 표이다.

도 16은 본 개시의 일 실시 예에 따른, FT-GAT 모델과 종래의 다른 모델들의 ROC 곡선 비교를 나타내는 도면이다.

도 17은 본 개시의 일 실시 예에 따른, 정규화된 어텐션 계수의 평균 히트맵을 나타낸 도면이다.

도 18은 본 개시의 일 실시 예에 따른, FT-GAT 모델의 성능을 나타내는 자료를 나타내는 표이다.

발명을 실시하기 위한 구체적인 내용

[0022] 본 실시 예들은 다양한 변환을 가할 수 있고 여러 가지 실시 예를 가질 수 있는바, 특정 실시 예들을 도면에 예시하고 상세한 설명에 상세하게 설명하고자 한다. 그러나 이는 특정한 실시 형태에 대해 범위를 한정하려는 것이 아니며, 본 개시의 실시 예의 다양한 변경(modifications), 균등물(equivalents), 및/또는 대체물(alternatives)을 포함하는 것으로 이해되어야 한다. 도면의 설명과 관련하여, 유사한 구성요소에 대해서는 유사한 참조 부호가 사용될 수 있다.

[0023] 본 개시를 설명함에 있어서, 관련된 공지 기능 혹은 구성에 대한 구체적인 설명이 본 개시의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우 그에 대한 상세한 설명은 생략한다.

[0024] 덧붙여, 하기 실시 예는 여러 가지 다른 형태로 변형될 수 있으며, 본 개시의 기술적 사상의 범위가 하기 실시 예에 한정되는 것은 아니다. 오히려, 이들 실시 예는 본 개시를 더욱 충실하고 완전하게 하고, 당업자에게 본 개시의 기술적 사상을 완전하게 전달하기 위하여 제공되는 것이다.

[0025] 본 개시에서 사용한 용어는 단지 특정한 실시 예를 설명하기 위해 사용된 것으로, 권리범위를 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다.

[0026] 본 개시에서, "가진다," "가질 수 있다," "포함한다," 또는 "포함할 수 있다" 등의 표현은 해당 특징(예: 수치, 기능, 동작, 또는 부품 등의 구성요소)의 존재를 가리키며, 추가적인 특징의 존재를 배제하지 않는다.

[0027] 본 개시에서, "A 또는 B," "A 또는/및 B 중 적어도 하나," 또는 "A 또는/및 B 중 하나 또는 그 이상"등의 표현은 함께 나열된 항목들의 모든 가능한 조합을 포함할 수 있다. 예를 들면, "A 또는 B," "A 및 B 중 적어도 하나," 또는 "A 또는 B 중 적어도 하나"는, (1) 적어도 하나의 A를 포함, (2) 적어도 하나의 B를 포함, 또는 (3) 적어도 하나의 A 및 적어도 하나의 B 모두를 포함하는 경우를 모두 지칭할 수 있다.

[0028] 본 개시에서 사용된 "제1," "제2," "첫째," 또는 "둘째,"등의 표현들은 다양한 구성요소들을, 순서 및/또는 중요도에 상관없이 수식할 수 있고, 한 구성요소를 다른 구성요소와 구분하기 위해 사용될 뿐 해당 구성요소들을 한정하지 않는다.

[0029] 어떤 구성요소(예: 제1 구성요소)가 다른 구성요소(예: 제2 구성요소)에 "(기능적으로 또는 통신적으로) 연결되어((operatively or communicatively) coupled with/to)" 있다거나 "접속되어(connected to)" 있다고 언급된 때에는, 어떤 구성요소가 다른 구성요소에 직접적으로 연결되거나, 다른 구성요소(예: 제3 구성요소)를 통하여 연결될 수 있다고 이해되어야 할 것이다.

[0030] 반면에, 어떤 구성요소(예: 제1 구성요소)가 다른 구성요소(예: 제2 구성요소)에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는, 어떤 구성요소와 다른 구성요소 사이에 다른 구성요소(예: 제3 구성요소)가 존재하지 않는 것으로 이해될 수 있다.

[0031] 본 개시에서 사용된 표현 "~하도록 구성된(또는 설정된)(configured to)"은 상황에 따라, 예를 들면, "~에 적합한(suitable for)," "~하는 능력을 가지는(having the capacity to)," "~하도록 설계된(designed to)," "~하도록 변경된(adapted to)," "~하도록 만들어진(made to)," 또는 "~를 할 수 있는(capable of)"과 바꾸어 사용될 수 있다. 용어 "~하도록 구성된(또는 설정된)"은 하드웨어적으로 "특별히 설계된(specifically designed to)" 것만을 반드시 의미하지 않을 수 있다.

[0032] 대신, 어떤 상황에서는, "~하도록 구성된 장치"라는 표현은, 그 장치가 다른 장치 또는 부품들과 함께 "~할 수 있는" 것을 의미할 수 있다. 예를 들면, 문구 "A, B, 및 C를 수행하도록 구성된(또는 설정된) 프로세서"는 해당 동작을 수행하기 위한 전용 프로세서(예: 임베디드 프로세서), 또는 메모리 장치에 저장된 하나 이상의 소프트

웨어 프로그램들을 실행함으로써, 해당 동작들을 수행할 수 있는 범용 프로세서(generic-purpose processor)(예: CPU 또는 application processor)를 의미할 수 있다.

[0033] 실시 예에 있어서 '모듈' 혹은 '부'는 적어도 하나의 기능이나 동작을 수행하며, 하드웨어 또는 소프트웨어로 구현되거나 하드웨어와 소프트웨어의 결합으로 구현될 수 있다. 또한, 복수의 '모듈' 혹은 복수의 '부'는 특정한 하드웨어로 구현될 필요가 있는 '모듈' 혹은 '부'를 제외하고는 적어도 하나의 모듈로 일체화되어 적어도 하나의 프로세서로 구현될 수 있다.

[0034] 한편, 도면에서의 다양한 요소와 영역은 개략적으로 그려진 것이다. 따라서, 본 발명의 기술적 사상은 첨부한 도면에 그려진 상대적인 크기나 간격에 의해 제한되지 않는다.

[0035] 이하에서는 첨부한 도면을 참고하여 본 개시에 따른 실시 예에 대하여 본 개시가 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다.

[0036] 전자 장치(100)는 학습 데이터에 기초하여 환자의 자가호흡 성공률 예측을 위한 인공지능 모델, 기계학습 모델, 딥러닝 모델 등을 학습시키고, 학습된 인공지능 모델, 기계학습 모델, 딥러닝 모델에 환자 정보, 환자 정보의 특징 정보 등을 입력하여 환자의 자가호흡 성공률 예측 값을 획득하는 장치일 수 있다.

[0037] 전자 장치(100)는, 예를 들어 클라이언트에게 네트워크를 통해 서비스하는 컴퓨터인 서버일 수 있다. 서버는, FTP 서버, 웹 서버, 데이터 베이스 서버, 클라우드형 서버일 수 있으며, 서버는 리눅스 등의 운영체제로 구축될 수 있다.

[0038] 또한, 전자 장치(100)는, 스마트폰(smartphone), 태블릿 PC(tablet Personal Computer), 랩탑 PC(laptop Personal Computer), 넷북 컴퓨터(netbook computer), 모바일 기기, 웨어러블 장치(wearable device) 등과 같이 데이터 연산 동작을 수행할 수 있는 컴퓨팅 장치일 수 있다.

[0039] 본 개시의 일 실시 예에 따른 전자 장치(100)는 상술한 기기에 한정되지 않으며, 전자 장치(100)는 상술한 기기들의 둘 이상의 기능을 갖춘 전자 장치(100)로 구현될 수 있다.

[0040] 도 1은 본 개시의 일 실시 예에 따른, 전자 장치(100)의 구성을 설명하기 위한 블록도이다.

[0041] 도 1을 참조하면, 전자 장치(100)는 메모리(110) 및 프로세서(120)를 포함할 수 있다. 다만, 전자 장치(100)의 구성은 이에 국한되지 않고, 통신 인터페이스, 사용자 인터페이스, 디스플레이 등을 추가로 포함하거나 일부 구성을 생략할 수 있다.

[0042] 메모리(110)는 각종 프로그램이나 데이터를 일시적 또는 비일시적으로 저장하고, 프로세서(120)의 호출에 따라서 저장된 정보를 프로세서(120)에 전달한다. 또한, 메모리(110)는, 프로세서(120)의 연산, 처리 또는 제어 동작 등에 필요한 각종 정보를 전자적 포맷으로 저장할 수 있다.

[0043] 메모리(110)는, 예를 들어, 주기억장치 및 보조기억장치 중 적어도 하나를 포함할 수 있다. 주기억장치는 롬(ROM) 및/또는 램(RAM)과 같은 반도체 저장 매체를 이용하여 구현된 것일 수 있다. 롬은, 예를 들어, 통상적인 롬, 이피롬(EPROM), 이이피롬(EEPROM) 및/또는 마스크롬(MASK-ROM) 등을 포함할 수 있다. 램은 예를 들어, 디램(DRAM) 및/또는 에스램(SRAM) 등을 포함할 수 있다. 보조기억장치는, 플래시 메모리 장치, SD(Secure Digital) 카드, 솔리드 스테이트 드라이브(SSD, Solid State Drive), 하드 디스크 드라이브(HDD, Hard Disc Drive), 자기 드럼, 컴팩트 디스크(CD), 디브이디(DVD) 또는 레이저 디스크 등과 같은 광 기록 매체(optical media), 자기 테이프, 광자기 디스크 및/또는 플로피 디스크 등과 같이 데이터를 영구적 또는 반영구적으로 저장 가능한 적어도 하나의 저장 매체를 이용하여 구현될 수 있다.

[0044] 메모리(110)는 인공지능 모델, 기계학습 모델, 딥러닝 모델을 저장할 수 있다. 구체적으로, 메모리(110)는 노드, 레이어, 엣지, 가중치, 편향, 활성화 함수, 손실함수, 역전파 계수를 저장할 수 있다. 또한, 메모리(110)는 모델 학습에 필요한 학습 데이터를 저장할 수 있다.

[0045] 메모리(110)는 환자 정보에 기초하여 환자의 자가호흡 성공률을 획득하기 위한 FT-GAT 모델을 저장할 수 있다.

[0046] 메모리(110)는 환자 정보에 대응되는 특징 값을 잠재 공간 상의 임베딩 값으로 변환하는 토크나이저(210) 모듈, 특징 값에 대응되는 노드를 업데이트하는 멀티 헤드 그래프 어텐션(220)(Multi Head Gragh Attention) 모듈 및 업데이트된 노드가 적용되어 임베딩 값에 대응되는 환자의 자가호흡 성공률 예측 값을 출력하는 멀티 레이어 퍼셉트론(230)(MLP, Multi Layer Perceptron) 모듈에 대한 정보를 저장할 수 있다.

[0047] 메모리(110)는 FT-GAT 모델에 대응되는 토크나이저(210) 모듈, 멀티 헤드 그래프 어텐션(220) 모듈, 멀티 레이어 퍼셉트론(230) 모듈에 대한 정보, 예를 들어, 각각의 모듈의 제어 동작에 필요한 다양한 노드, 엣지, 레이어, 계수, 파라미터, 함수 등을 저장할 수 있다.

[0048] 메모리(110)는 각각의 모듈의 구조, 그래프 구조 등에 대한 정보 등을 저장할 수 있으며, 각각의 모듈 제어 및 연산에 필요한 인스트럭션을 저장할 수 있다.

[0049] 메모리(110)는 환자 정보, 환자 정보의 특징 값을 저장할 수 있으며, 환자 정보에 기초하여 획득된 자가호흡 성공률 예측 값을 저장할 수 있다.

[0050] 프로세서(120)는, 전자 장치(100)의 전반적인 동작을 제어한다. 구체적으로, 프로세서(120)는 상술한 바와 메모리(110)를 포함하는 전자 장치(100)의 구성과 연결되며, 상술한 바와 같은 메모리(110)에 저장된 적어도 하나의 인스트럭션을 실행함으로써, 전자 장치(100)의 동작을 전반적으로 제어할 수 있다. 특히, 프로세서(120)는 하나의 프로세서로 구현될 수 있을 뿐만 아니라 복수의 프로세서로 구현될 수 있다.

[0051] 프로세서(120)는 다양한 방식으로 구현될 수 있다. 예를 들어, 하나 이상의 프로세서(120)는 CPU (Central Processing Unit), GPU (Graphics Processing Unit), APU (Accelerated Processing Unit), MIC (Many Integrated Core), DSP (Digital Signal Processor), NPU (Neural Processing Unit), 하드웨어 가속기 또는 머신 러닝 가속기 중 하나 이상을 포함할 수 있다. 하나 이상의 프로세서(120)는 전자 장치(100)의 다른 구성요소 중 하나 또는 임의의 조합을 제어할 수 있으며, 통신에 관한 동작 또는 데이터 처리를 수행할 수 있다. 하나 이상의 프로세서(120)는 메모리(110)에 저장된 하나 이상의 프로그램 또는 명령어(instruction)을 실행할 수 있다. 예를 들어, 하나 이상의 프로세서(120)는 메모리(110)에 저장된 하나 이상의 명령어를 실행함으로써, 본 개시의 일 실시 예에 따른 방법을 수행할 수 있다.

[0052] 본 개시의 일 실시 예에 따른 방법이 복수의 동작을 포함하는 경우, 복수의 동작은 하나의 프로세서(120)에 의해 수행될 수도 있고, 복수의 프로세서(120)에 의해 수행될 수도 있다. 예를 들어, 일 실시 예에 따른 방법에 의해 제 1 동작, 제 2 동작, 제 3 동작이 수행될 때, 제 1 동작, 제 2 동작, 및 제 3 동작 모두 제 1 프로세서에 의해 수행될 수도 있고, 제 1 동작 및 제 2 동작은 제 1 프로세서(예를 들어, 범용 프로세서)에 의해 수행되고 제 3 동작은 제 2 프로세서(예를 들어, 인공지능 전용 프로세서)에 의해 수행될 수도 있다.

[0053] 하나 이상의 프로세서(120)는 하나의 코어를 포함하는 싱글 코어 프로세서(single core processor)로 구현될 수도 있고, 복수의 코어(예를 들어, 동종 멀티 코어 또는 이종 멀티 코어)를 포함하는 하나 이상의 멀티 코어 프로세서(multicore processor)로 구현될 수도 있다. 하나 이상의 프로세서(120)가 멀티 코어 프로세서로 구현되는 경우, 멀티 코어 프로세서에 포함된 복수의 코어 각각은 온 칩(On-chip) 메모리(110)와 같은 프로세서 내부 메모리를 포함할 수 있으며, 복수의 코어에 의해 공유되는 공통 캐시가 멀티 코어 프로세서(120)에 포함될 수 있다. 또한, 멀티 코어 프로세서(120)에 포함된 복수의 코어 각각(또는 복수의 코어 중 일부)은 독립적으로 본 개시의 일 실시 예에 따른 방법을 구현하기 위한 프로그램 명령을 판독하여 수행할 수도 있고, 복수의 코어 전체(또는 일부)가 연계되어 본 개시의 일 실시 예에 따른 방법을 구현하기 위한 프로그램 명령을 판독하여 수행할 수도 있다.

[0054] 본 개시의 일 실시 예에 따른 방법이 복수의 동작을 포함하는 경우, 복수의 동작은 멀티 코어 프로세서에 포함된 복수의 코어 중 하나의 코어에 의해 수행될 수도 있고, 복수의 코어에 의해 수행될 수도 있다. 예를 들어, 일 실시 예에 따른 방법에 의해 제 1 동작, 제 2 동작, 및 제 3 동작이 수행될 때, 제 1 동작, 제2 동작, 및 제 3 동작 모두 멀티 코어 프로세서에 포함된 제 1 코어에 의해 수행될 수도 있고, 제 1 동작 및 제 2 동작은 멀티 코어 프로세서에 포함된 제 1 코어에 의해 수행되고 제 3 동작은 멀티 코어 프로세서에 포함된 제 2 코어에 의해 수행될 수도 있다.

[0055] 본 개시의 실시 예들에서, 프로세서(120)는 하나 이상의 프로세서(120) 및 기타 전자 부품들이 집적된 시스템 온 칩(SoC), 싱글 코어 프로세서, 멀티 코어 프로세서, 또는 싱글 코어 프로세서 또는 멀티 코어 프로세서에 포함된 코어를 의미할 수 있으며, 여기서 코어는 CPU, GPU, APU, MIC, DSP, NPU, 하드웨어 가속기 또는 기계 학습 가속기 등으로 구현될 수 있으나, 본 개시의 실시 예들이 이에 한정되는 것은 아니다.

[0056] 프로세서(120)는 메모리(110)와 연결되어 FT-GAT 모델에 환자의 적어도 하나의 특징 값을 입력하여 환자의 자가호흡 성공률 예측 값을 식별할 수 있다.

[0057] 도 2는 본 개시의 일 실시 예에 따른, 토크나이저(210) 모듈, 멀티 헤드 그래프 어텐션(220) 모듈, 멀티 레이어

퍼셉트론(230) 모듈을 포함하는 FT-GAT 모델을 설명하기 위한 블록도이다.

[0058] 도 2를 참조하면, 프로세서(120)는 환자 정보에 대응되는 특징 값을 토크나이저(210) 모듈에 입력하여 잠재 공간 상의 임베딩 값을 식별할 수 있다.

[0059] 프로세서(120)는 특징 값에 대응되는 노드를 업데이트하도록 멀티 헤드 그래프 어텐션(220)(Multi Head Gragh Attention) 모듈을 제어할 수 있다.

[0060] 프로세서(120)는 업데이트된 노드를 멀티 레이어 퍼셉트론(230)(MLP, Multi Layer Perceptron) 모듈에 적용할 수 있다.

[0061] 프로세서(120)는 임베딩 값을 업데이트된 노드가 적용된 멀티 레이어 퍼셉트론(230) 모듈에 입력하여 환자의 자가호흡 성공률 예측 값을 획득할 수 있다.

[0062] 프로세서(120)의 전자 장치(100) 제어 및 FT-GAT 모델 제어 동작에 관한 보다 구체적인 설명은 도 3 내지 18과 함께 설명한다.

[0063] 도 3은 본 개시의 일 실시 예에 따른, 환자 정보 및 기계식 인공호흡과 관련된 제반 정보를 나타내기 위한 표이다.

[0064] 도 3을 참조하면, 등록된 환자의 전자 의료 기록을 검토했으며, 수집된 입력 특징은 도 3에 도시된 바와 같다.

[0065] 구체적으로, 자가호흡 시도 직전에 얻은 모든 입력 기능에는 나이, 성별, 체질량 지수(BMI), 기계식 인공호흡 모드, 기계식 인공호흡 매개변수(압력 지지(PS, Pressure Support) 수준, 폐활량(FiO2), Tidal Volume)가 포함되었다. 또한, 동맥혈 산소 압력(PaO2)과 FiO2의 비율(P/F), pCO2, Tidal Volume - 6mL/kg 사전 지시 체중(PBW, Predicted Body Weight), 기계식 인공호흡 지속 시간, 심박수, 호흡수, 글래스고 코마 점수(GCS, Glasgow Coma Score). 기계식 인공호흡 모드는 보조 제어(AC, Assist Control), 동기화된 간헐적 필수 인공호흡(SIMV, Synchronized Intermittent Mandatory Ventilation), PSV 및 CPAP로 이루어진다. 또한 세 가지 Tidal Volume 값의 평균을 사용하여 TV-6mL/kg PBW를 계산했다.

[0066] 도 4는 본 개시의 일 실시 예에 따른, 중환자실의 환자 정보 및 자가호흡 시도와 관련된 성공 및 실패를 나타내기 위한 흐름도이다.

[0067] 도 4를 참조하면, 중환자실의 환자 정보 및 자가호흡 시도와 관련된 성공, 실패와 관련된 데이터 정리 및 흐름을 볼 수 있다.

[0068] 도 5는 본 개시의 일 실시 예에 따른, 자가호흡 시도의 실패 및 성공 과정을 설명하기 위한 도면이다.

[0069] 도 5를 참조하면, 자가호흡 성공 실패 사례에 대한 추가 수집 절차에서 (a) 삽관과 자가호흡 시도 실패 사이의 시간이 48시간을 초과하거나 (b) 자가호흡 시도 실패가 48시간을 초과한 경우 점선은 추가 수집 지점을 나타낸다.

[0070] 데이터 세트는 데이터 분석에 적합하도록 전처리되었다. 성별 기능은 원핫(One-Hot) 인코딩을 통해 인코딩되었고, 기계식 인공호흡 모드 기능은 라벨 인코딩을 통해 환자의 호흡 지원이 약한 순서부터 강한 순서로 다음과 같이 인코딩 되었다. CPAP(0), PSV(1), SIMV(2), AC(3). 또한 인코딩되지 않은 수치 특징에 대해 최소-최대 스케일링을 수행하여 0에서 1 사이의 값을 얻었다. 최소-최대 스케일링의 수학 공식은 아래 수학식 1과 같다.

수학식 1

[0071]
$$X_{scaled} = \frac{X - min(X)}{max(X) - min(X)}$$

[0072] 여기서 max(X) 및 min(X)는 각각 피처 X의 최대값과 최소값을 나타낸다.

[0073] FT-GAT 모델을 설계하기 위해 인접 노드의 특징 정보를 집계하는 그래프 신경망(GNN, Graph Neural Network)에서 모티브를 얻어 모든 특징을 그래프 구조로 설계했다. 분석에 사용된 그래프는 6년 이상, 15년 이상의 경력을

가진 두 명의 호흡기내과 전문의에 의해 구조화되었다. 또한 어텐션 메커니즘을 포함한 그래프 네트워크(GAT, Graph Attention Network) 구조를 활용하여 그래프 분석을 수행하는 FT-GAT라는 새로운 자가호흡 성공률 예측 모델을 설계했다.

[0074] 프로세서(120)는 환자 정보에 대응되는 특징 값인 x(범주형 x^{cat} 및 수치형 x^{num})를 임베딩 값으로 변환하도록 FT-GAT 모델에 포함된 토크나이저(210) 모듈을 제어한다.

[0075] 도 6은 본 개시의 일 실시 예에 따른, 환자 정보를 임베딩 값으로 변환하는 토크나이저(210)의 동작을 설명하기 위한 도면이다.

[0076] 도 6을 참조하면, 주어진 특징 x_j에 대한 임베딩 값은 다음과 같이 수학식 2로 계산된다.

수학식 2

[0077]
$$H_j^{(num)} = x_j^{(num)} \cdot W_j^{(num)} + B_j^{(num)} \in \mathbb{R}^d$$

$$H_j^{(cat)} = e_j^T \cdot W_j^{(cat)} + B_j^{(cat)} \in \mathbb{R}^d$$

[0078] W_j는 j번째 특징 값에 대응되는 가중치이고, B_j는 j번째 특징 값에 대응되는 편향이다. e^T_j는 j번째 카테고리 특징에 대응되는 원핫(One-Hot) 벡터를 의미한다.

[0079] 프로세서(120)는, 환자 정보에 대응되는 특징 값에 가중치를 곱하고 편향을 더하여 임베딩 값을 획득할 수 있다. 여기서, 특징 값은, 환자 정보에 대응되는 카테고리 및 환자 정보에 대응되는 정량 수치 중 적어도 하나일 수 있다.

[0080] 다양한 실시 예로, 환자 정보의 특징 값에 대응되는 잠재 공간 상의 임베딩 값이 식별되면, 프로세서(120)는 각각의 임베딩 값의 잠재 공간상의 위치 및 상호 간의 거리를 식별할 수 있다. 프로세서(120)는 복수의 서로 다른 특징 값에 대응되는 임베딩 값 중 잠재 공간 상에서 다른 임베딩 값들과의 거리의 평균 값이 가장 큰 임베딩 값을 노이즈 임베딩 값으로 식별할 수 있다. 프로세서(120)는 노이즈 임베딩 값을 삭제하고, 노이즈 임베딩 값에 대응되는 노드를 삭제할 수 있다. 따라서, 프로세서(120)는 환자 정보 중 다른 특징 값과 관련도가 적어 노이즈에 가깝다고 볼 수 있는 값은 제외하고 보다 정확한 모델 연산을 수행할 수 있다.

[0081] 도 7은 본 개시의 일 실시 예에 따른, 환자 정보의 특징 값에 대응되는 복수의 노드 및 복수의 노드를 연결하는 엣지를 도시한 도면이다.

[0082] 도 7을 참조하면, 환자 정보의 특징 값에 대응되는 복수의 노드 및 복수의 노드는 특정 구조를 가져서 서로 연결될 수 있다.

[0083] 프로세서(120)는 환자 정보의 특징 값을 위와 같이 각각의 노드에 입력하여 출력 값을 획득할 수 있다.

[0084] FT-GAT의 멀티 헤드 그래프 어텐션(220) 모듈의 구성은 여러 개의 싱글 그래프 어텐션 레이어를 포함한다. 싱글 그래프 어텐션 레이어는 노드 집합 H = {H1, H2,..., H_N}, $H_i \in R_d$를 입력으로 받는다. N은 노드(즉, 특징)의 수를 나타내고 d는 각 노드의 차원을 나타낸다. 이 레이어에서는 모든 노드가 선형적으로 변환되어 각각의 노드가 충분한 대표성을 가질 수 있도록 한다. 모든 노드와 공유되는 훈련 가능한 가중치 행렬 $W \in R^{d \times d'}$가 사용된다. 여기서, d'는 변환된 노드의 차원이다.

[0085] 도 8은 본 개시의 일 실시 예에 따른, 환자 정보의 특징 값에 대응되는 각각의 노드 별 어텐션 계수를 식별하는 어텐션 메커니즘을 설명하기 위한 도면이다.

[0086] 도 8을 참조하면, 프로세서(120)는 변환된 노드에 기초하여 어텐션 메커니즘을 수행할 수 있다. 어텐션 메커니즘 수행 방식은 Bahdanau가 제안한 접근 방식을 따른다. 구체적으로, 이 메커니즘에 따라 프로세서(120)는 어텐션 계수를 단일 계층 앞먹임(FeedForward) 신경망을 통해 계산할 수 있다.

수학식 3

[0087] $$e_{ij} = LeakyReLU(A^T * Concat(WH_i, WH_j))$$

[0088] 여기서 e_{ij}는 노드 i에 대한 노드 j의 중요도를 의미하며, $A \in R^{2d'}$는 훈련 가능한 가중치 벡터를 나타낸다. 그래프 구조에 정보를 주입하기 위해 메커니즘에 마스크된(Masked) 어텐션 계수를 추가할 수 있다. 마스크된 어텐션 계수를 활용하면 노드에 대해서만 e_{ij}가 계산된다. $j \in \bar{N}_i$, 여기서 $\bar{N}_i$는 노드 i의 이웃 노드이다(노드 i 포함). 또한, 인접 노드 $\bar{N}_i$의 중요도 비교를 용이하게 하기 위해 이웃 노드 $\bar{N}_i$의 중요도 비교를 용이하게 하기 위해, e_{ij}는 softmax함수를 사용하여 정규화될 수 있다.

수학식 4

[0089] $$\alpha_{ij} = softmax_{\tilde{N}_i}(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in \tilde{N}_i} \exp(e_{ik})}$$

[0090] 프로세서(120)는 노드 H_i를 상위 노드로 업데이트하기 위해 정규화된 어텐션 계수 α_{ij}에 가중치 합산 연산을 적용할 수 있다.

[0091] 다시 말해, 프로세서(120)는, 제1 노드를 선형 변환(Linear Transform)하여 제2 노드를 식별하고, 제2 노드에 인접한 적어도 하나의 제3 노드의 중요도를 식별할 수 있다. 여기서 제1 노드는, 제2 노드에 대응되는 차원과 상이한 차원에 대응될 수 있다.

[0092] 프로세서(120)는 적어도 하나의 제3 노드의 중요도를 정규화하여 적어도 하나의 제3 노드 각각에 대응되는 어텐션 계수(Attention Coefficient)를 식별할 수 있다.

[0093] 도 9는 본 개시의 일 실시 예에 따른, 인접 노드 및 인접 노드의 어텐션 계수에 기초하여 환자 정보의 특징 값에 대응되는 각각의 노드를 업데이트하는 동작을 설명하기 위한 도면이다.

[0094] 도 9를 참조하면, 프로세서(120)는 이웃 노드 $\bar{N}_i$와 가중 합산 연산을 수행할 수 있다. 이 과정에서 프로세서(120)는 모든 노드에서 수행된 다음 지수 선형 (ELU, Exponential Linear Unit) 함수를 적용할 수 있다. 프로세서(120)는 노드 H_i는 K 번 병렬로 업데이트하고, 집계된 Hi는 연결 연산 또는 평균 연산을 사용하여 생성할 수 있다.

[0095] 다시 말해, 프로세서(120)는 적어도 하나의 제3 노드 및 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 제2 노드를 업데이트하여 제4 노드를 식별할 수 있다.

[0096] 보다 구체적으로, 프로세서(120)는 적어도 하나의 제3 노드 및 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 연쇄 연산 및 평균 연산 중 적어도 하나의 연산을 수행하여 제2 노드를 업데이트하여 제4 노드를 식별할 수 있다.

[0097] 다양한 실시 예에 따르면, 제3 노드가 복수 개인 경우, 프로세서(120)는 제3 노드 각각에 대응되는 어텐션 계수가 임계 값 미만인지 여부를 식별할 수 있다. 프로세서(120)는 임계 값 미만의 어텐션 계수에 대응되는 제3 노드는 제외한 나머지 제3 노드 및 나머지 제3 노드에 대응되는 어텐션 계수만에 기초하여 제2 노드를 업데이트하여 제4 노드를 식별할 수 있다. 이 경우, 어텐션 계수가 낮아서 중요도가 임계 값 미만인 제3 노드를 배제하고 제2 노드를 제4 노드로 업데이트하여 불필요한 인자, 노이즈 인자 등이 노드 업데이트 과정에서 포함되지 않도록 할 수 있다.

[0098] 프로세서(120)는 적어도 하나의 제3 노드 및 제3 노드 각각에 대응되는 어텐션 계수에 기초하여 제2 노드를 복수 회 업데이트하여 제4 노드를 식별할 수도 있다.

[0099] 연결 연산 또는 평균 연산은 아래와 같은 수학식 5로 수행될 수 있다.

수학식 5

$$\hat{H}_i = Concat_{k=1}^{K}(ELU(\sum_{j\in\tilde{N}_i}\alpha_{ij}^{k})\mathbf{W}^{k}H_j))$$

$$\hat{H}_i = ELU(\frac{1}{K}\sum_{k=1}^{K}\sum_{j\in\tilde{N}_i}\alpha_{ij}^{k}\mathbf{W}^{k}H_j))$$

[0100]

[0101] 여기서 α^{k}_{ij}는 정규화된 어텐션 계수이다. W^{k}는 k 번째 가중치 행렬이다. 프로세서(120)는 Hi는 멀티 헤드 어텐션의 차원 d와 동일한 차원으로 선형 변환할 수 있다. 프로세서(120)는 여러 계층의 정보를 결합하는 스킵 연결(Skip Connection)을 적용하여 레이어 간 정보를 결합할 수 있으며, 프로세서(120)는 위 과정을 L회 반복할 수 있다.

[0102] 프로세서(120)는, 제4 노드를 선형 변환하여 제5 노드를 식별하고, 멀티 헤드 그래프 어텐션(220) 모듈의 출력 데이터에 스킵 연결(Skip Connection)을 적용하여 멀티 헤드 그래프 어텐션(220) 모듈에 입력되기 전 상태의 적어도 하나의 싱글 그래프 어텐션 레이어 간의 정보를 조합할 수 있다. 여기서 제5 노드는, 제1 노드에 대응되는 차원과 동일하고, 제4 노드에 대응되는 차원과 상이한 차원에 대응될 수 있다.

[0103] 프로세서(120)는 멀티 레이어 퍼셉트론(230)(MLP, Multi Layer Perceptron) 모듈에서 업데이트된 모든 노드는 평탄화되고 완전히 연결된 단일 레이어를 통과시킬 수 있다. 프로세서(120)는 업데이트된 노드를 배치 정규화(Batch Normalizatoin) 및 정류된 선형 장치(ReLU, Rectified Linear Unit) 활성화의 함수로 구성된 단일 연결 레이어를 통과시킬 수 있다.

[0104] 즉, 프로세서(120)는, 멀티 헤드 그래프 어텐션(220) 모듈에 포함된 적어도 하나의 노드를 평탄화하여 정렬하고, 정렬된 적어도 하나의 노드를 배치 정규화(Batch Normalization) 및 정류 선형 유닛(ReLU, Rectified Linear Unit) 활성화 함수를 포함하는 싱글 연결 레이어에 적용할 수 있다.

[0105] 최종적으로, 프로세서(120)는 FT-GAT 모델에 환자 정보를 입력하여 자가호흡 성공률 예측 값을 획득할 수 있다. 예를 들어, 프로세서(120)는 시그모이드(Sigmoid) 활성화 함수를 통해 0과 1 사이의 값을 산출하여 자가호흡 성공률 예측 값을 획득할 수 있다. 여기서, 멀티 레이어 퍼셉트론(230) 모듈은, 시그모이드(Sigmoid) 활성화 함수를 포함할 수 있다.

[0106] 프로세서(120)는, 멀티레이어 퍼센트론 모듈의 출력 값에 대응되는 환자의 자가 호흡 성공률을 획득할 수 있다.

[0107] 자가호흡 성공률 예측을 위한 FT-GAT 설계는 하이퍼 파라미터를 통해 구현될 수 있다.

[0108] 도 10은 본 개시의 일 실시 예에 따른, FT-GAT 모델을 이용하여 자가호흡 시도의 성공률을 예측하는데 필요한 하이퍼 파라미터를 설명하기 위한 표이다.

[0109] 도 10을 참조하면, 각각의 과정에서 사용되는 하이퍼 파라미터를 확인할 수 있다.

[0110] 불균형한 학습 데이터로부터 기인한 영향을 최소화하기 위해 가중 이진 교차 엔트로피 손실(Weighted Binary Cross-Entropy Loss)을 채택했다. 학습 데이터의 불균형 비율에 따라 손실에 가중치를 부여했다. 목표 클래스에 대한 학습 데이터 샘플(즉, 자가호흡 성공률)에 0.38의 가중치를 부여했다. 학습은 최대 1000개의 세대에 걸쳐 수행되었으며, 모델 성능 지표가 10epochs 동안 증가하지 않으면 학습률에 0.5를 곱했다. 40세대 동안 모델 성능 지표가 증가하지 않으면 모델 학습을 종료하고 가장 높은 성능 지표에 대응되는 모델이 테스트 데이터를 평가하는 데 사용되었다.

[0111] FT-GAT는 텐서플로우 2.4.1 라이브러, Python 3.8를 이용하여 개발되었다. 또한, FT-GAT 모델은 데스크톱 PC에서 CUDA 11.0.3 툴킷을 사용하여 훈련되었다. 데스크톱 PC의 스펙은 인텔 코어 i7-12,700 @2.10GHz 중앙 처리유닛(CPU) 및 NVIDIA GeForce RTX 3090 Ti 그래픽 처리장치(GPU)로 구성되었다.

[0112] FT-GAT의 모델 성능을 평가하기 위해 5가지 정량적 지표를 채택했다. 정확도, 감도, 특이도, F1 점수, 수신기

작동 특성(AUROC)에서 수신기 작동 특성(AUROC)이다. 여기서 1-특이도에 대하여 감도를 Y축에 표시하여 ROC 곡선을 나타낸다. 평가 지표는 수학식 6을 사용하여 계산되었다.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

$$Sensitivity = \frac{TP}{TP+FN}$$

$$Specificity = \frac{TN}{TN+FP}$$

$$F1-score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity}$$

$$Precision = \frac{TP}{TP+FP}$$

[0113]

[0114] 여기서 TP, FP, TN, FN은 각각 True Positives, False Positives, True Negatives, False Negatives를 나타낸다. 모든 값은 0에서 1 사이이며, 1이 최적값이다. 또한 FT-GAT의 우수성을 검증하기 위해 대표적인 임상 지표와 가장 대표적인 임상 지표의 성능과 비교했다. 여기서 임상 지표는, 호흡률(RR, Respiratory Rate)과 Tidal Volume 비율인 RSBI; 부분 산소포화도(PaO_2)와 산소포화도(FiO_2)의 비율인 P/F 비율일 수 있다. RSBI가 높을수록 자가호흡 성공률이 낮게 나타난다. P/F 비율이 낮을수록 자가호흡 성공률이 낮게 나타난다.

[0115] 또한, FT-GAT의 성능은 머신러닝(ML, Machine Learning) 및 딥러닝(DL, Deep Learning) 모델: 범주형 부스팅(CatBoost), 로지스틱 회귀, 서포트 벡터 머신(SVM), 랜덤 포레스트, 라이트 그라데이션 부스팅 머신(LGBM), 익스트림 그라데이션 부스팅(XGBoost)/탭트랜스포머, DANET, MLP 등과 비교해 볼 수 있다.

[0116] 각 모델은 Scikit-learn 1.1.2, CatBoost 1.1을 사용하여 구현되었고, XGBoost 1.6.2, LightGBM 3.3.2, TensorFlow 2.4.1 라이브러리를 사용하여 구현되었다.

[0117] 또한, 무작위 검색, 그리드 검색 및 베이지안 최적화를 사용하여 최적의 하이퍼 파라미터를 설정했다.

[0118] 데이터 세트에서 자가호흡 성공 및 실패 환자 그룹을 식별 및 비교하고 각 특징과 심층 변수(자가호흡 성공/실패) 간의 관계를 확인하기 위해 통계 분석을 수행했다.

[0119] 각 데이터 유형은 연속형 변수의 경우 평균과 표준편차로, 범주형 변수의 경우 개수와 비율로 표현했다. 또한 각 기능은 카이제곱 (χ^2) 테스트 또는 피셔의 정확한 테스트(범주형 특징) 및 t-테스트(연속형 특징)를 사용했다. P값이 0.05 미만인 경우 통계적으로 유의미한 것으로 간주했으며, 모든 통계 분석은 R 통계 소프트웨어 버전 4.1.2(R Core Team 2021)를 사용했다.

[0120] 도 11은 본 개시의 일 실시 예에 따른, FT-GAT 모델을 이용하여 자가호흡 시도의 성공률 예측과 관련된 환자 정보를 나타내는 표이다.

[0121] 도 11을 참조하면, 데이터 세트에는 1041건의 사례가 포함되었으며, 남성(67.8%)이 여성(32.2%)보다 많았다. 환자 대부분은 51세에서 81세 사이의 연령대였으며, BMI(22.7)는 정상 범위 내에 있었다. 또한 통계적 테스트 결과, TV 6mL/kg PBW 및 HR 특징을 제외한 모든 특징이 종속변수와 유의미한 관계가 있는 것으로 나타났다.

[0122] 모델 오버피팅을 효과적으로 제어할 수 있는 4 중 교차 검증(4-Fold Cross Validation)을 사용하여 FT-GAT 모델의 성능을 평가했다. 구체적으로, 데이터셋을 균등하게 4개로 나누어 자가호흡 시도 성공 사례의 수를 균등하게 분포시켰다. 그 후 4번의 검증 반복을 수행했으며, 각 반복에서 하나의 폴드는 검증(12.5%)과 테스트(12.5%)에, 나머지 폴드는 훈련(75%)에 사용했다.

[0123] 도 12는 본 개시의 일 실시 예에 따른, FT-GAT 모델의 자가호흡 시도의 성공률 예측에 대한 성능을 평가한 실험 자료를 나타내는 도면이다.

[0124] 도 12를 참조하면, FT-GAT 모델의 4배 교차 검증 결과에 따라 FT-GAT 모델의 성능의 우수성을 알 수 있다.

[0125] AUROC 측면에서 FT-GAT 모델은 최대 0.87을 달성했다. 여기서, 혼동 매트릭스를 통해 정량적 지표가 계산될 수

있다.

[0126] 도 13은 본 개시의 일 실시 예에 따른, FT-GAT 모델의 자가호흡 시도의 성공률 예측에 대한 성능을 평가한 실험 자료를 나타내는 표이다.

[0127] 도 13을 참조하면, CI는 신뢰 구간을 의미하며, 모든 폴드의 평균값에 대한 95% CI는 자유도 3의 t 분포를 사용하여 계산되었다. 요약하면, FT-GAT 모델은 평균 정확도 0.72, 민감도 0.75, 특이도 0.72, F1 점수 0.76, AUROC 0.80을 달성했다.

[0128] 도 14는 본 개시의 일 실시 예에 따른, FT-GAT 모델과 다른 모델 간의 성능 비교를 설명하기 위한 지표들을 나타내는 표이다.

[0129] 도 14를 참조하면, FT-GAT 모델의 지표가 다른 모델에 비해 우수한 수치를 갖는 것을 볼 수 잇다.

[0130] FT-GAT의 각 구성 요소의 유효성을 입증하기 위해 제거 연구를 수행했다. 구체적으로 그래프 구조와 네트워크 아키텍처 측면에서 제거 연구를 수행했으며, 그 결과는 도 15와 같다. 연구 결과는 4번의 교차 검증을 통해 계산된 평균 AUROC를 사용하여 측정되었다.

[0131] 도 15는 본 개시의 일 실시 예에 따른, FT-GAT 모델에 포함된 각 노드의 구조 별 실험 결과를 나타내는 표이다.

[0132] 도 15를 참조하면, 각 노드의 구조별 실험 결과를 알 수 있다. 그래프 구조와 관련하여, 구조화된 집합 엣지와 모든 노드가 연결된 모든 에지를 비교하고 셀프 에지의 유무에 따른 모델 성능의 차이도 관찰했다. 셀프 엣지가 있는 그래프가 셀프 엣지가 없는 그래프보다 더 나은 모델 성능을 보였다.

[0133] 네트워크 아키텍처와 관련하여 FT-GAT 모델은 기능 토큰화 메커니즘을 사용한다. 특징 토큰화 메커니즘을 사용하지 않는 것과 성능을 비교했다. 실험 결과, FT-GAT는 피처 토크나이저(210)를 통해 모든 입력 피처를 임베딩으로 변환함으로써 더 나은 성능을 발휘하는 것으로 나타났다.

[0134] 도 16은 본 개시의 일 실시 예에 따른, FT-GAT 모델과 종래의 다른 모델들의 ROC 곡선 비교를 나타내는 도면이다.

[0135] 또한 도 16에서 볼 수 있듯이, FT-GAT 모델은 AUROC 측면에서 모든 임상 지표와 다른 모델보다 우수한 성능을 보였다. 모든 모델의 성능 결과에 대한 더 많은 디테일이 도 11에 도시되었다.

[0136] 도 17은 본 개시의 일 실시 예에 따른, 정규화된 어텐션 계수의 평균 히트맵을 나타낸 도면이다.

[0137] 도 17을 참조하면, 자기 엣지가 있는 집합 에지들로 구성된 그래프가 가장 높은 모델 성능을 보였는데, 이는 영향력이 강한 노드에서만 주의력 계수가 계산되었기 때문이다.

[0138] 시간적 유효성 검사는 다른 기관의 IRB 승인 요건과 같은 다양한 이유로 인해 외부 유효성 검사 대신 자주 사용된다. 여기에는 개발 코호트의 환자와 동일한 연구에 포함되었지만 데이터가 더 일찍 또는 나중에 샘플링된 새로운 환자의 데이터에 대해 모델을 검증하는 것이 포함된다. 또한 생명공학 연구에서는 시간 경과에 따른 환자 집단, 의료 장비 기술 및 전문의 숙련도 변화와 같은 변수를 평가하기 위해 시간적 검증을 수행한다.

[0139] 데이터 세트는 2020년 7월부터 2022년 7월 사이에 기계식 인공호흡 치료를 받은 중증 환자로 구성되었기 때문에 기계식 인공호흡 치료 시작 시점에 따라 2020년 하반기, 2021년 상반기, 2021년 하반기, 2022년 상반기로 나누어 시간적 교차 검증을 수행했다. 각 폴드는 검증(50%)과 테스트(50%)에 사용되었으며, 모델을 새로 학습하고 평가했다.

[0140] 도 18은 본 개시의 일 실시 예에 따른, FT-GAT 모델의 성능을 나타내는 자료를 나타내는 표이다.

[0141] 도 18을 참조하면, 시간적 제약을 고려하여 수행한 시간적 교차 검증의 결과를 알 수 있다. FT-GAT는 일반적인 교차 검증에서 얻은 성능(AUROC:0.8017)보다 약간 낮은 성능(AUROC:0.8028)을 달성했지만, 훈련 데이터와 다른 시점의 테스트 데이터를 평가함으로써 일반화 능력을 충분히 입증했다.

[0142] 기계식 인공호흡 해제 프로토콜은 중환자실에서 널리 사용되어 왔지만, 자가호흡 시도 및 발관 시행을 결정하기 위해서는 주치의의 다차원적 평가가 필요하며, 인공 지능이 이러한 의사결정에 도움이 될 수 있다. 또한, 연구자들은 순응도, 산소 발생, 호흡 및 노력(CORE) 지수, 순응도, 속도, 산소 공급 및 압력(CROP) 지수, RSBI 및 최대 흡기압과 같은 예측 지표를 개발하여 '기계식 인공호흡 해제 준비' 상태를 파악하고 자가호흡을 시도할 수 있도록 했다. 그러나 실제 상황에 대한 강력한 단일 예측 인자는 없다. 첫 번째 자가호흡 시도의 실패율은 25%~40%, 발관 실패율은 약 10%~25%이며, 이는 기관이나 의사에 따라 달라질 수 있다. 호흡기 중환자실 전문의

에게 자가호흡 시도 성공을 예측하는 것은 여전히 어려운 일이며, 성공률은 발관 성공률에 비해 상대적으로 낮다.

[0143] 최근의 인공지능 연구는 기계식 인공호흡에서 발관술을 예측하는 데 탁월한 성능을 보여주었다. Pai 등은 발관 예측을 위한 6가지 주요 특징의 판별 포인트를 식별하는 설명 가능한 XGBoost 모델(AUROC:0.92)을 개발했다. 파브레가트 등은 SVM을 통해 이질적인 데이터를 분석했고(AUROC:0.98), 타카노부 등은 LightGBM을 사용하여 발관 후 72시간 이내에 재삽관을 예측했다(AUROC:0.95). 최근에는 딤러닝 방법도 이 분야에서 사용되었다. Zeng 등은 발관 실패를 동적으로 예측하기 위해 중환자실 의료 정보 마트(MIMIC-IV) 데이터 세트에서 시간 데이터를 추출하여 해석 가능한 RNN 모델(AUROC:0.83)을 설계했다. 또한 Jia 등은 임상적으로 의미 있고 적절한 특징을 사용하여 컨볼루션 신경망 모델(AUROC:0.94)을 사용했다.

[0144] FT-GAT 모델 연구는 주목할 만한 공헌을 했다. 앞서 언급한 연구들에서는 예측 목표가 튜브 발관 성공 여부였다. 그러나 FT-GAT 모델은 튜브 발관 성공 여부가 아니라 자가호흡 성공을 예측한다.

[0145] 단 한 건의 SBT 예측 연구만이 머신러닝 접근법을 사용했지만, 이 연구는 기계식 인공호흡 모드 전환에 초점을 맞추고 자가호흡 시도 정의를 위한 t-piece 시험만을 고려했다.

[0146] 반면, FT-GAT 모델 연구는 업데이트된 정의에 따라 모든 자가호흡 시도 방법을 포함했으며, FT-GAT 모델은 AUROC 측면에서 더 나은 성능을 보여주었다(우리 모델: 0.80 vs 이전 연구에서 사용된 머신 러닝 모델 : 0.79).

[0147] 또한 예측 모델의 일반화 가능성을 높이기 위해 혼합 및 외상 중환자실 환자를 모두 포함했으며, 더 많은 실패 사례를 수집하기 위해 중환자실 전문의가 처방한 이유 프로토콜을 따르는 환자와 비호흡기내과 의사가 처방한 프로토콜을 따르는 환자(프로토콜 없이)를 데이터 세트에 등록했다.

[0148] 자가호흡 시도 성공 여부를 미리 예측하기 위해 딥러닝 모델을 기반으로 새로운 GNN을 개발했다. 모델 개발을 위해 모든 중환자실 환자로부터 얻을 수 있는 특징을 활용하고 이들 간의 관계를 고려했다. 특징 토큰화 메커니즘을 통해 모든 특징(노드)을 임베딩으로 변환하고 GAT 메커니즘을 통해 그래프 분석을 수행함으로써 FT-GAT는 널리 사용되는 임상 지표와 표 형식 데이터 분석에 사용되는 기존의 ML 및 DL 모델보다 우수한 성능을 보였다. 구체적으로 이 모델은 평균 정확도 0.72, 민감도 0.75, 특이도 0.72, F1-점수 0.76, AUROC 0.80을 달성했다. 또한, 절제 연구 결과 자가호흡 성공 예측에 필요한 모든 특징을 그래프 구조로 성공적으로 변환하고, 특징 토큰화 기법을 통해 모델 성능을 개선한 것으로 나타났다.

[0149] 결론적으로, FT-GAT 모델이라는 새로운 GNN 기반 딥러닝 모델을 개발하여 환자의 자가호흡 성공을 예측한다. 평균 정확도 0.72, 민감도 0.75, 사양 정확도는 0.72, F1 점수는 0.76, AUROC는 0.80로 우수한 효과를 나타낸다.

[0150] 일 실시 예에 따르면, 본 문서에 개시된 다양한 실시 예들에 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 스토어TM)를 통해 또는 두개의 사용자 장치들(예: 스마트폰들) 간에 직접, 온라인으로 배포(예: 다운로드 또는 업로드)될 수 있다. 온라인 배포의 경우에, 컴퓨터 프로그램 제품(예: 다운로더블 앱(downloadable app))의 적어도 일부는 제조사의 서버, 어플리케이션 스토어의 서버, 또는 중계 서버의 메모리(110)와 같은 기기로 읽을 수 있는 저장 매체에 적어도 일시 저장되거나, 임시적으로 생성될 수 있다.

[0151] 본 개시에 따른 인공지능과 관련된 기능은 전자 장치(100)의 프로세서(120)와 메모리(110)를 통해 동작된다.

[0152] 프로세서(120)는 하나 또는 복수의 프로세서(120)로 구성될 수 있다. 이때, 하나 또는 복수의 프로세서(120)는 CPU(Central Processing Unit), GPU(Graphic Processing Unit), NPU(Neural Processing Unit) 중 적어도 하나를 포함할 수 있으나 전술한 프로세서(120)의 예시에 한정되지 않는다.

[0153] CPU는 일반 연산뿐만 아니라 인공지능 연산을 수행할 수 있는 범용 프로세서(120)로서, 다계층 캐시(Cache) 구조를 통해 복잡한 프로그램을 효율적으로 실행할 수 있다. CPU는 순차적인 계산을 통해 이전 계산 결과와 다음 계산 결과의 유기적인 연계가 가능하도록 하는 직렬 처리 방식에 유리하다. 범용 프로세서(120)는 전술한 CPU로 명시한 경우를 제외하고 전술한 예에 한정되지 않는다.

[0154] GPU는 그래픽 처리에 이용되는 부동 소수점 연산 등과 같은 대량 연산을 위한 프로세서(120)로서, 코어를 대량으로 집적하여 대규모 연산을 병렬로 수행할 수 있다. 특히, GPU는 CPU에 비해 컨볼루션(Convolution) 연산 등과 같은 병렬 처리 방식에 유리할 수 있다. 또한, GPU는 CPU의 기능을 보완하기 위한 보조 프로세서(120)(co-

processor)로 이용될 수 있다. 대량 연산을 위한 프로세서(120)는 전술한 GPU로 명시한 경우를 제외하고 전술한 예에 한정되지 않는다.

[0155] NPU는 인공 신경망을 이용한 인공지능 연산에 특화된 프로세서(120)로서, 인공 신경망을 구성하는 각 레이어를 하드웨어(예로, 실리콘)로 구현할 수 있다. 이때, NPU는 업체의 요구 사양에 따라 특화되어 설계되므로, CPU나 GPU에 비해 자유도가 낮으나, 업체가 요구하기 위한 인공지능 연산을 효율적으로 처리할 수 있다. 한편, 인공지능 연산에 특화된 프로세서(120)로, NPU 는 TPU(Tensor Processing Unit), IPU(Intelligence Processing Unit), VPU(Vision processing unit) 등과 같은 다양한 형태로 구현 될 수 있다. 인공 지능 프로세서(120)는 전술한 NPU로 명시한 경우를 제외하고 전술한 예에 한정되지 않는다.

[0156] 또한, 하나 또는 복수의 프로세서(120)는 SoC(System on Chip)으로 구현될 수 있다. 이때, SoC에는 하나 또는 복수의 프로세서(120) 이외에 메모리(110), 및 프로세서(120)와 메모리(110) 사이의 데이터 통신을 위한 버스(Bus)등과 같은 네트워크 인터페이스를 더 포함할 수 있다.

[0157] 전자 장치(100)에 포함된 SoC(System on Chip)에 복수의 프로세서(120)가 포함된 경우, 전자 장치(100)는 복수의 프로세서(120) 중 일부 프로세서(120)를 이용하여 인공지능과 관련된 연산(예를 들어, 인공지능 모델의 학습(learning)이나 추론(inference)에 관련된 연산)을 수행할 수 있다. 예를 들어, 전자 장치(100)는 복수의 프로세서(120) 중 컨볼루션 연산, 행렬 곱 연산 등과 같은 인공지능 연산에 특화된 GPU, NPU, VPU, TPU, 하드웨어 가속기 중 적어도 하나를 이용하여 인공지능과 관련된 연산을 수행할 수 있다. 다만, 이는 일 실시예에 불과할 뿐, CPU 등과 범용 프로세서(120)를 이용하여 인공지능과 관련된 연산을 처리할 수 있음은 물론이다.

[0158] 또한, 전자 장치(100)는 하나의 프로세서(120)에 포함된 멀티 코어(예를 들어, 듀얼 코어, 쿼드 코어 등)를 이용하여 인공지능과 관련된 기능에 대한 연산을 수행할 수 있다. 특히, 전자 장치(100)는 프로세서(120)에 포함된 멀티 코어를 이용하여 병렬적으로 컨볼루션 연산, 행렬 곱 연산 등과 같은 인공 지능 연산을 수행할 수 있다.

[0159] 하나 또는 복수의 프로세서(120)는, 메모리(110)에 저장된 기정의된 동작 규칙 또는 인공지능 모델에 따라, 입력 데이터를 처리하도록 제어한다. 기정의된 동작 규칙 또는 인공지능 모델은 학습을 통해 만들어진 것을 특징으로 한다.

[0160] 여기서, 학습을 통해 만들어진다는 것은, 다수의 학습 데이터들에 학습 알고리즘을 적용함으로써, 원하는 특성의 기정의된 동작 규칙 또는 인공지능 모델이 만들어짐을 의미한다. 이러한 학습은 본 개시에 따른 인공지능이 수행되는 기기 자체에서 이루어질 수도 있고, 별도의 서버/시스템을 통해 이루어질 수도 있다.

[0161] 인공지능 모델은, 복수의 신경망 레이어들로 구성될 수 있다. 적어도 하나의 레이어는 적어도 하나의 가중치(weight values)을 갖고 있으며, 이전(previous) 레이어의 연산 결과와 적어도 하나의 정의된 연산을 통해 레이어의 연산을 수행한다. 신경망의 예로는, 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) 및 심층 Q-네트워크 (Deep Q-Networks), Transformer가 있으며, 본 개시에서의 신경망은 명시한 경우를 제외하고 전술한 예에 한정되지 않는다.

[0162] 학습 알고리즘은, 다수의 학습 데이터들을 이용하여 소정의 대상 기기(예컨대, 로봇)을 훈련시켜 소정의 대상 기기 스스로 결정을 내리거나 예측을 할 수 있도록 하는 방법이다. 학습 알고리즘의 예로는, 지도형 학습(supervised learning), 비지도형 학습(unsupervised learning), 준지도형 학습(semi-supervised learning) 또는 강화 학습(reinforcement learning)이 있으며, 본 개시에서의 학습 알고리즘은 명시한 경우를 제외하고 전술한 예에 한정되지 않는다.

[0163] 이상에서는 본 개시의 바람직한 실시 예에 대하여 도시하고 설명하였지만, 본 개시는 상술한 특정의 실시 예에 한정되지 아니하며, 청구범위에서 청구하는 본 개시의 요지를 벗어남이 없이 당해 개시에 속하는 기술분야에서 통상의 지식을 가진 자에 의해 다양한 변형 실시가 가능한 것은 물론이고, 이러한 변형실시들은 본 개시의 기술적 사상이나 전망으로부터 개별적으로 이해되어져서는 안될 것이다.

부호의 설명

[0164] 100: 전자 장치

110: 메모리

120: 프로세서

도면

도면1

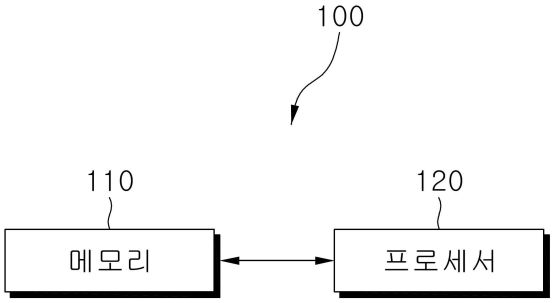

도면2

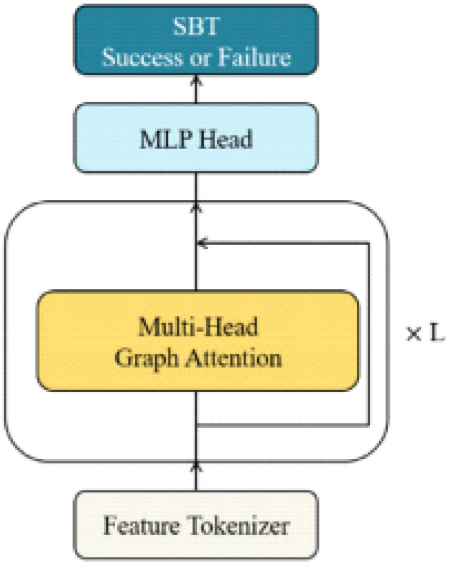

도면3

Table 1
Characteristics of the constructed dataset.

Characteristics	Category	Example
Demographic	Age	18–65 [years]
	Sex	Male/Female
	BMI	12–63 [kg/m^2]
Mechanical ventilator settings	Mode	CPAP/PSV/SIMV/AC
	FiO_2	21–100 [%]
	PS level	0–24 [cmH_2O]
Respiratory function	P/F ratio	45.3–1326.7
	pCO_2	17.9–142.0 [mmHg]
	TV - 6 mL/kg PBW	−263.6–724.6
	MV duration	0.08–600 [h]
Vital signs	Heart rate	43–148 [beats/min]
	Respiratory rate	8–40 [breaths/min]
Central nervous system	GCS	3–15

BMI, body mass index; FiO_2, fraction of inspired oxygen; PS level, pressure support level; P/F ratio, PaO_2/FiO_2 ratio; pCO_2, partial pressure of carbon dioxide; TV, tidal volume; PBW, predicted body weight; MV, mechanical ventilation; GCS, and Glasgow coma score.

도면4

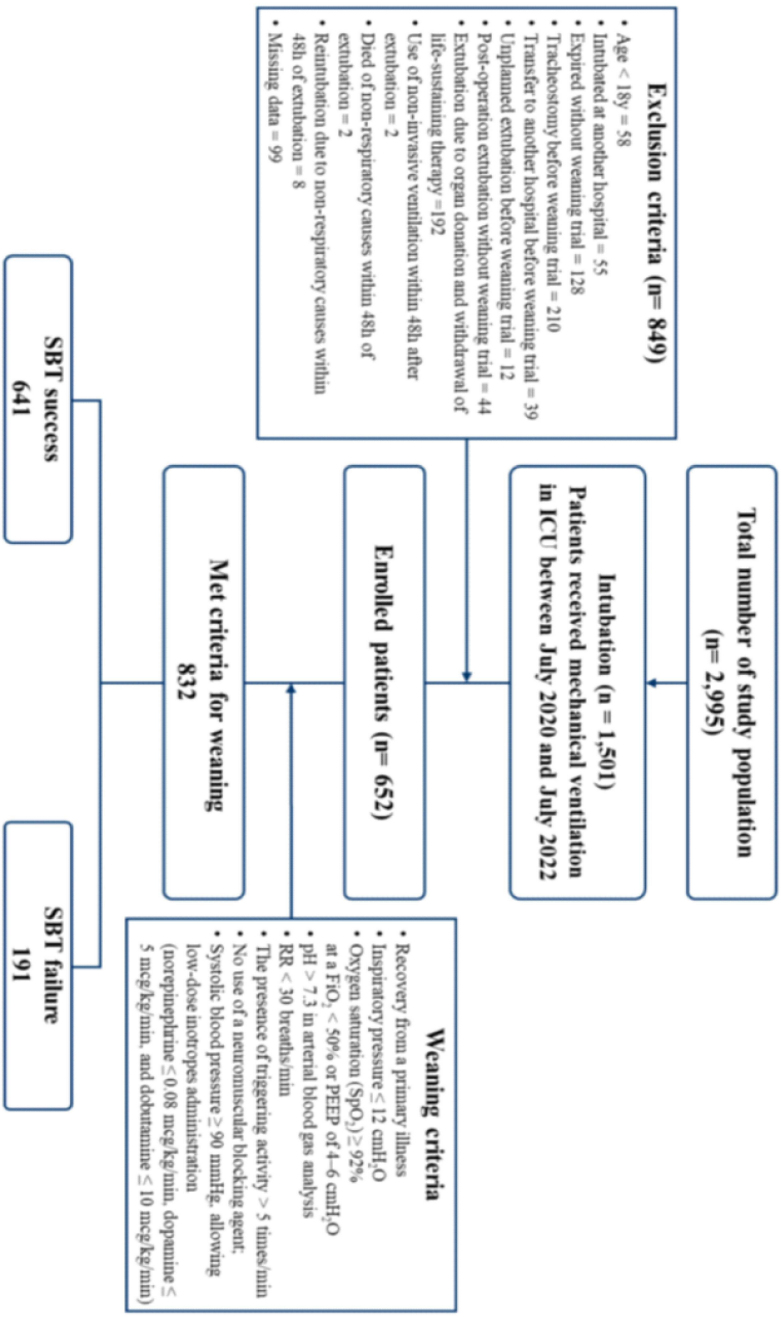
Total number of study population
(n= 2,995)
Intubation (n = 1,501)
Patients received mechanical ventilation
in ICU between July 2020 and July 2022
Exclusion criteria (n= 849)
• Age < 18y = 58
• Intubated at another hospital = 55
• Expired without weaning trial = 128
• Tracheostomy before weaning trial = 210
• Transfer to another hospital before weaning trial = 39
• Unplanned extubation before weaning trial = 12
• Post-operation extubation without weaning trial = 44
• Extubation due to organ donation and withdrawal of life-sustaining therapy = 192
• Use of non-invasive ventilation within 48h after extubation = 2
• Died of non-respiratory causes within 48h of extubation = 2
• Reintubation due to non-respiratory causes within 48h of extubation = 8
• Missing data = 99
Enrolled patients (n= 652)
Met criteria for weaning
832
Weaning criteria
• Recovery from a primary illness
• Inspiratory pressure ≤ 12 cmH2O
• Oxygen saturation (SpO2) ≥ 92%
at a FiO2 < 50% or PEEP of 4–6 cmH2O
• pH > 7.3 in arterial blood gas analysis
• RR < 30 breaths/min
• The presence of triggering activity > 5 times/min
• No use of a neuromuscular blocking agent;
• Systolic blood pressure ≥ 90 mmHg, allowing low-dose inotropes administration
(norepinephrine ≤ 0.08 mcg/kg/min, dopamine ≤ 5 mcg/kg/min, and dobutamine ≤ 10 mcg/kg/min)
SBT success
641
SBT failure
191

도면5

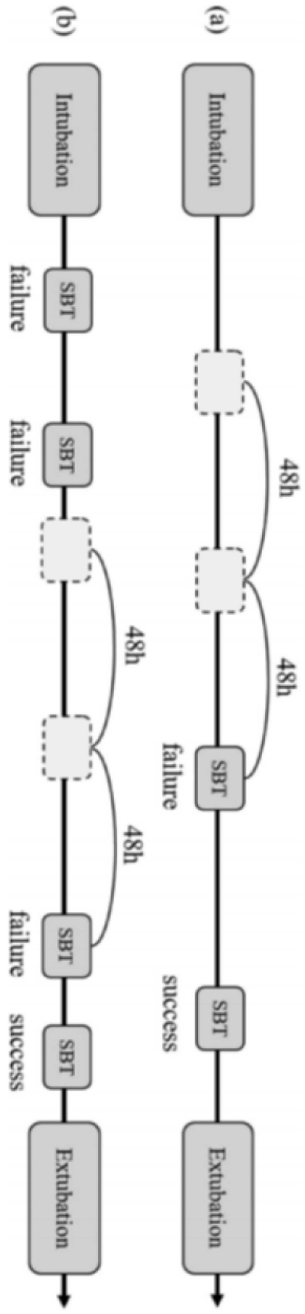
(a)
Intubation
48h
48h
failure
SBT
success
SBT
Extubation
(b)
Intubation
failure
SBT
failure
SBT
48h
48h
failure
SBT
success
SBT
Extubation

도면6

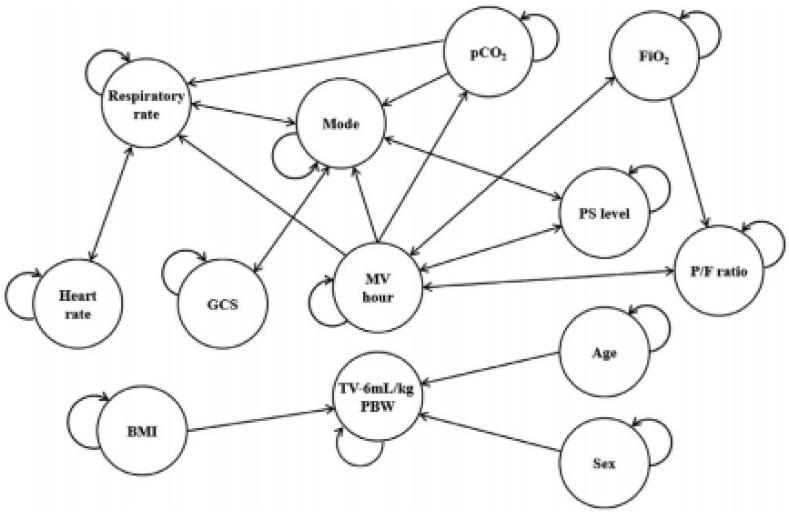
pCO2
FiO2
Respiratory rate
Mode
PS level
P/F ratio
Heart rate
GCS
MV hour
Age
TV-6mL/kg PBW
BMI
Sex

도면7

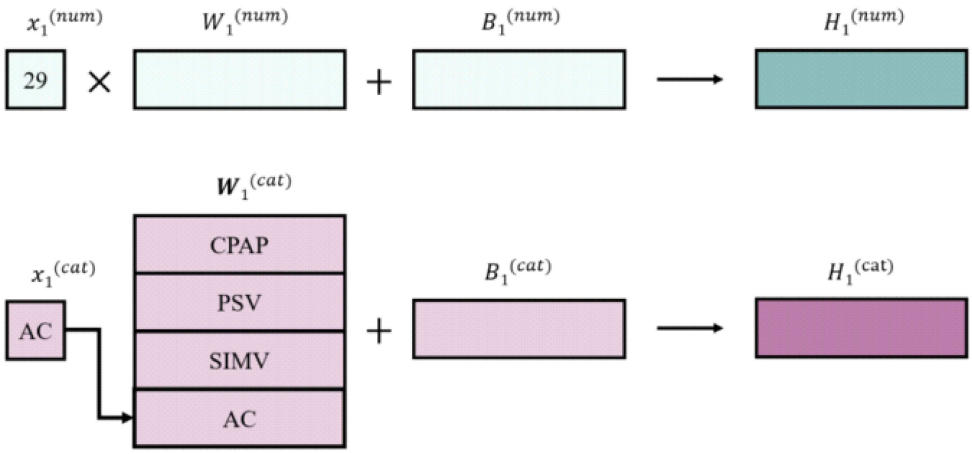
$x_1^{(num)}$
$W_1^{(num)}$
$B_1^{(num)}$
$H_1^{(num)}$
29
$W_1^{(cat)}$
$x_1^{(cat)}$
$B_1^{(cat)}$
$H_1^{(cat)}$
AC
CPAP
PSV
SIMV
AC

도면8

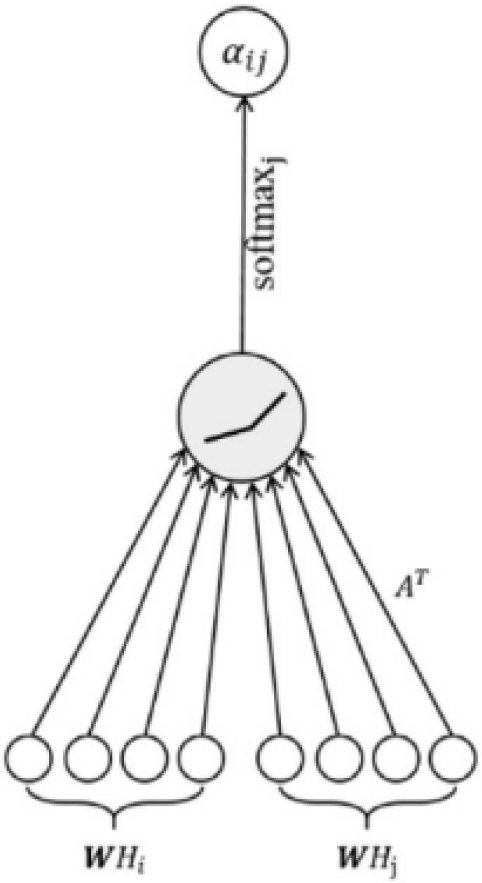

도면9

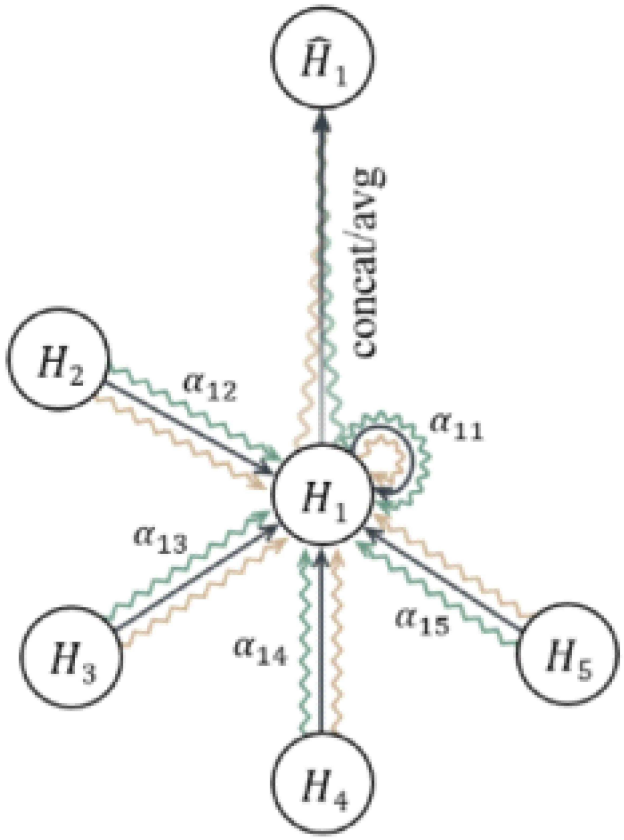
$\hat{H}_1$
concat/avg
H_2
α_{12}
α_{11}
H_1
α_{13}
H_3
α_{14}
α_{15}
H_5
H_4

도면10

Table 2
Hyperparameters of the FT-GAT for predicting SBT success.

	Hyper-parameters	Set value
Network structure	Embedding dimension d	48
	Linear transformed dimension d'	16
	Number of single graph attention K	3
	Number of layers L	2
	Aggregation	Concat
	MLP head hidden units	16
Training	Optimizer	Adam
	Learning rate	1.0e-3
	Batch size	32
	Loss function	weighted binary cross entropy

도면11

Table 3
Descriptive statistics for the constructed dataset.

	Total (cases= 1041)	SBT success (cases = 641)	SBT failure (cases = 400)	p-value
MV hour	33.6 ± 17.5	31.2 ± 14.7	37.3 ± 14.7	< 0.001***
TV - 6 mL/kg PBW	141.3 ± 120.4	144.1 ± 116.3	136.9 ± 126.7	0.355
Respiratory rate	18.3 ± 5.2	17.3 ± 4.8	19.9 ± 5.3	< 0.001***
P/F ratio	362.9 ± 144	388.5 ± 142.7	321.9 ± 136.5	< 0.001***
pCO_2	38.2 ± 8.7	37.6 ± 7.4	39.3 ± 10.5	0.006**
Heart rate	89.1 ± 18.9	88.4 ± 18.4	90.3 ± 19.7	0.105
GCS	11.3 ± 2.3	11.7 ± 2	10.8 ± 2.5	< 0.001***
FiO_2	36.6 ± 11.5	34.7 ± 8.5	39.6 ± 14.5	< 0.001***
Age	66.3 ± 14.7	64.9 ± 15.7	68.6 ± 12.5	< 0.001***
BMI	22.7 ± 4.1	22.9 ± 4.3	22.3 ± 3.7	0.028*
Sex Female	335 (32.2%)	109 (27.3%)	226 (35.3%)	0.009**
Male	706 (67.8%)	532 (72.7%)	174 (64.7%)	
Mode CPAP	22 (2.1%)	14 (2.2%)	8 (2%)	<
PSV	638 (61.3%)	432 (67.4%)	206 (51.5%)	0.001***
SIMV	330 (31.7%)	169 (26.4%)	161 (40.2%)	
AC	51 (4.9%)	26 (4.1%)	25 (6.2%)	

*** $p<0.001$.
** $p<0.01$.
* $p<0.05$.

도면12

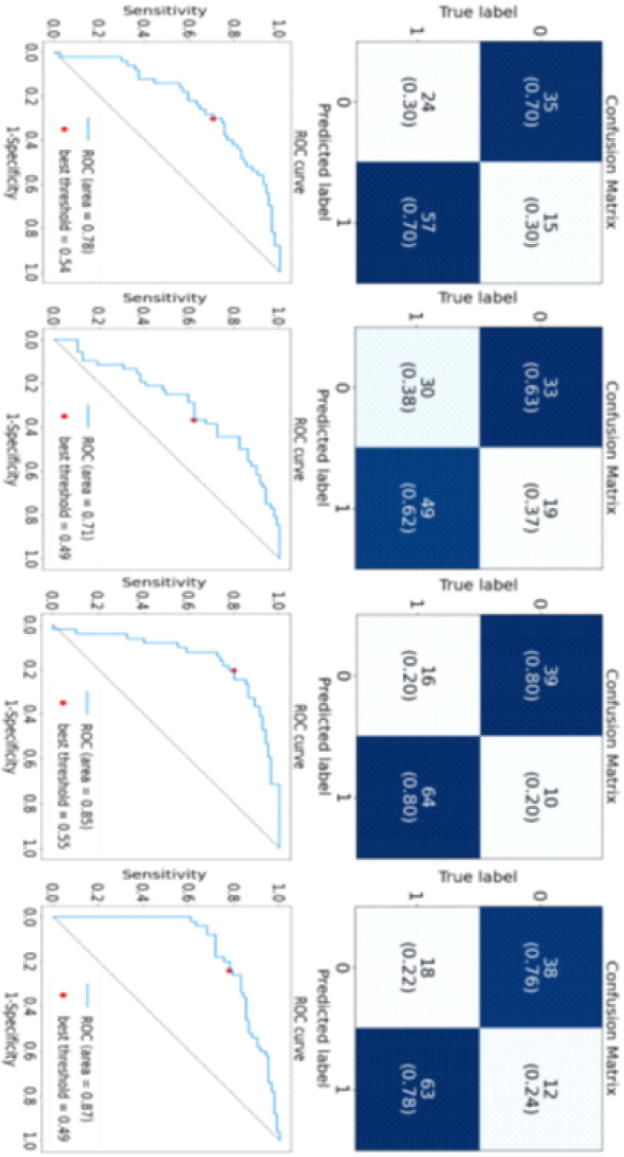

Fig. 6. Confusion matrices (top) and ROC curve plots (bottom) for each validation of the FT-GAT evaluated utilizing four-fold cross-validation. The rows of confusion matrices denote the actual values (0: SBT failure, 1: SBT success), and their columns indicate the model prediction values. The red dots on the ROC curve plots denote the optimal threshold of the model that minimizes the difference between sensitivity and specificity.

도면13

Table 4

Quantitative performance metrics of the FT-GAT via four-fold cross-validation.

	Accuracy	Sensitivity	Specificity	F1-score	AUROC
Fold 1	0.70	0.70	0.70	0.75	0.78
Fold 2	0.63	0.62	0.63	0.67	0.71
Fold 3	0.80	0.80	0.80	0.83	0.85
Fold 4	0.77	0.78	0.76	0.81	0.87
Average (CI 5%–95%)	0.72 (0.60–0.85)	0.75 (0.60–0.85)	0.72 (0.61–0.84)	0.76 (0.65–0.88)	0.80 (0.69–0.91)

도면14

Table 5
Performance of the FT-GAT, clinical indicators, ML, and DL models.

		Accuracy	Sensitivity	Specificity	F1-score	AUROC
Clinical indicators	P/F ratio	0.59	0.59	0.60	0.64	0.65
	RSBI	0.62	0.60	0.61	0.76	0.66
ML models	CatBoost	0.70	0.70	0.70	0.74	0.77
	Logistic Regression	0.70	0.69	0.70	0.74	0.77
	SVM	0.71	0.71	0.70	0.75	0.77
	Random Forest	0.71	0.71	0.70	0.75	0.78
	LGBM	0.70	0.70	0.70	0.74	0.78
	XGBoost	0.71	0.71	0.71	0.75	0.79
DL models	Tabtransformer	0.64	0.65	0.64	0.69	0.69
	DANET	0.71	0.70	0.71	0.75	0.76
	MLP	0.70	0.70	0.70	0.74	0.76
	FT-GAT	0.72	0.75	0.72	0.76	0.80

도면15

Table 6
Ablation study results of graph structure and network architecture.

			Model performance (AUROC)
Graph structure	all edges	self-edges	0.79 ± 0.03
		w/o self-edges	0.77 ± 0.02
	set edges	self-edges	0.80 ± 0.06
		w/o self-edges	0.78 ± 0.04
Network architecture	feature tokenizer		0.80 ± 0.06
	w/o feature tokenizer		0.78 ± 0.05

도면16

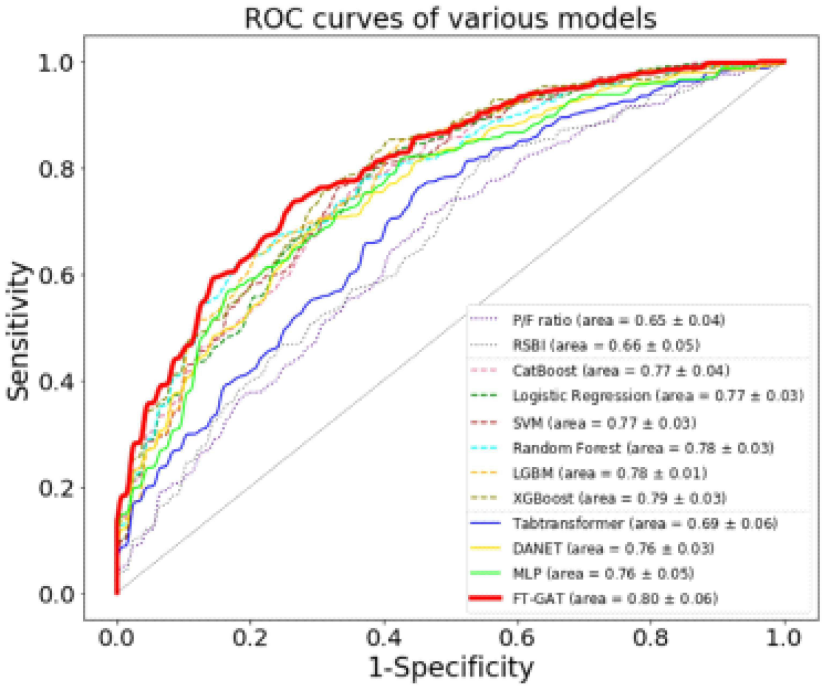
ROC curves of various models
Sensitivity
1-Specificity
0.0
0.2
0.4
0.6
0.8
1.0
P/F ratio (area = 0.65 ± 0.04)
RSBI (area = 0.66 ± 0.05)
CatBoost (area = 0.77 ± 0.04)
Logistic Regression (area = 0.77 ± 0.03)
SVM (area = 0.77 ± 0.03)
Random Forest (area = 0.78 ± 0.03)
LGBM (area = 0.78 ± 0.01)
XGBoost (area = 0.79 ± 0.03)
Tabtransformer (area = 0.69 ± 0.06)
DANET (area = 0.76 ± 0.03)
MLP (area = 0.76 ± 0.05)
FT-GAT (area = 0.80 ± 0.06)

도면17

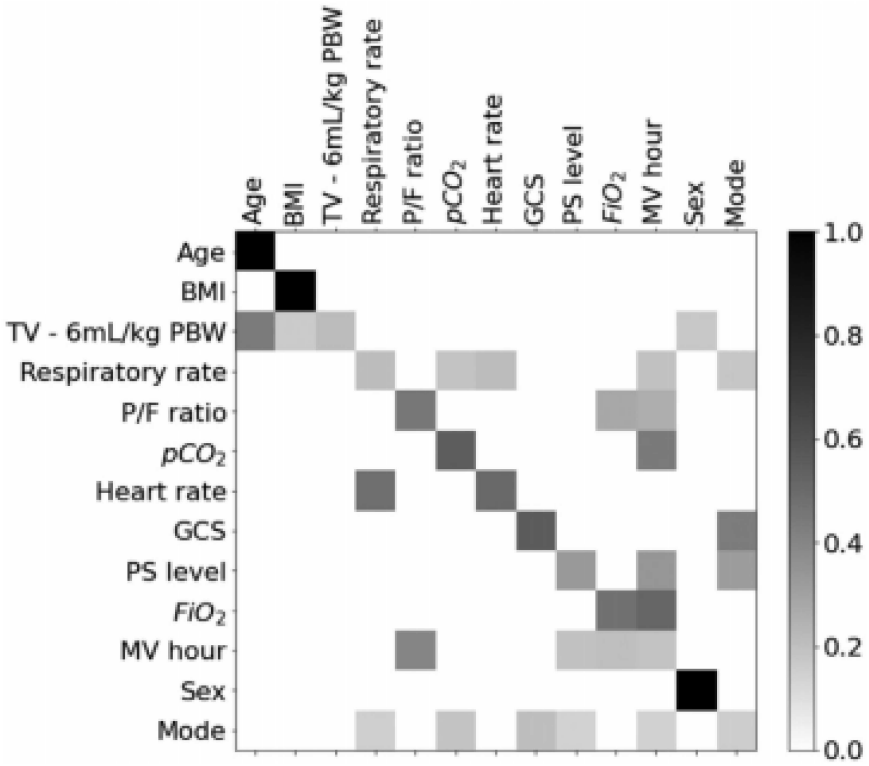
Age
BMI
TV - 6mL/kg PBW
Respiratory rate
P/F ratio
pCO2
Heart rate
GCS
PS level
FiO2
MV hour
Sex
Mode
1.0
0.8
0.6
0.4
0.2
0.0

도면18

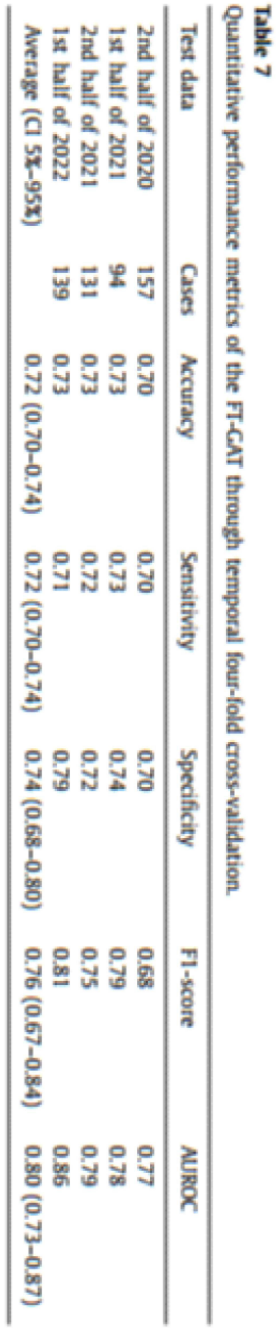

Table 7
Quantitative performance metrics of the FT-GAT through temporal four-fold cross-validation.

Test data	Cases	Accuracy	Sensitivity	Specificity	F1-score	AUROC
2nd half of 2020	157	0.70	0.70	0.70	0.68	0.77
1st half of 2021	94	0.73	0.73	0.74	0.79	0.78
2nd half of 2021	131	0.73	0.72	0.72	0.75	0.79
1st half of 2022	139	0.73	0.71	0.79	0.81	0.86
Average (CI 5%–95%)		0.72 (0.70–0.74)	0.72 (0.70–0.74)	0.74 (0.68–0.80)	0.76 (0.67–0.84)	0.80 (0.73–0.87)

【심사관 직권보정사항】

【직권보정 1】

【보정항목】 청구범위

【보정세부항목】 청구항 9

【변경전】

제1항에 있어서,

상기 멀티 레이어 퍼셉트론 모듈은,

시그모이드(Sigmoid) 활성화 함수를 포함하고,

상기 프로세서는,

상기 멀티 레이어 퍼센트론 모듈의 출력 값에 대응되는 상기 환자의 자가 호흡 성공률을 획득하는, 전자

장치.

【변경후】

제1항에 있어서,

상기 멀티 레이어 퍼셉트론 모듈은,

시그모이드(Sigmoid) 활성화 함수를 포함하고,

상기 프로세서는,

상기 멀티 레이어 퍼셉트론 모듈의 출력 값에 대응되는 상기 환자의 자가 호흡 성공률을 획득하는, 전자 장치.

【직권보정 2】

【보정항목】 청구범위

【보정세부항목】 청구항 10

【변경전】

FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 포함하는 전자 장치의 제어 방법에 있어서,

환자 정보에 대응되는 특징 값을 토크나이저 모듈에 입력하여 잠재 공간 상의 임베딩 값을 식별하는 단계;

상기 특징 값에 대응되는 노드를 업데이트하도록 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈을 제어하는 단계; 및

상기 임베딩 값을 상기 업데이트된 노드가 적용된 상기 멀티 레이어 퍼셉트론 모듈에 입력하여 상기 환자의 자가호흡 성공률 예측 값을 획득하는 단계;를 포함하는, 제어 방법.

【변경후】

FT-GAT(Feature Tokenizer - Graph Attention Network) 모델을 포함하는 전자 장치의 제어 방법에 있어서,

환자 정보에 대응되는 특징 값을 토크나이저 모듈에 입력하여 잠재 공간 상의 임베딩 값을 식별하는 단계;

상기 특징 값에 대응되는 노드를 업데이트하도록 멀티 헤드 그래프 어텐션(Multi Head Gragh Attention) 모듈을 제어하는 단계; 및

상기 임베딩 값을 상기 업데이트된 노드가 적용된 멀티 레이어 퍼셉트론 모듈에 입력하여 상기 환자의 자가호흡 성공률 예측 값을 획득하는 단계;를 포함하는, 제어 방법.