(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0080316
(43) 공개일자 2025년06월05일

(51) 국제특허분류(Int. Cl.)
A61B 5/18 (2006.01) *A61B 5/372* (2021.01)
(52) CPC특허분류
A61B 5/18 (2013.01)
A61B 5/251 (2021.01)
(21) 출원번호 10-2023-0167910
(22) 출원일자 2023년11월28일
심사청구일자 2023년11월28일

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
이성환
서울특별시 강남구 언주로30길 13, B동 2902호(도곡동, 대림아크로빌, 대림아크로텔)
한동균
서울특별시 노원구 공릉로20길 18 (공릉동, 진흥빌라)
(뒷면에 계속)
(74) 대리인
이대호, 박건홍

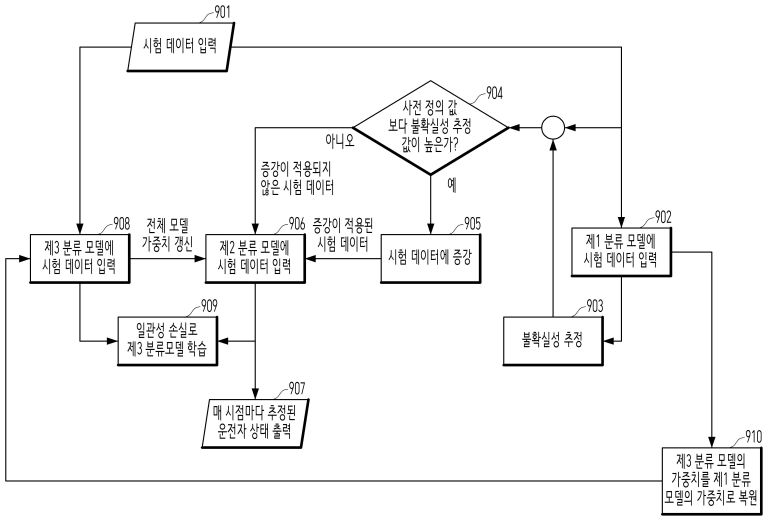
전체 청구항 수 : 총 12 항

(54) 발명의 명칭 **운전자의 상태를 추정하기 위한 방법 및 장치**

(57) 요 약

본 개시의 일 실시예에 따라 컴퓨팅 장치에 의해 수행되는 운전자의 상태를 추정하기 위한 방법으로서, 운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 단계; 사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 단계; 사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 단계; 상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 단계; 및 인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 단계;를 포함할 수 있다.

대 표 도



(52) CPC특허분류
A61B 5/291 (2022.01)
A61B 5/372 (2022.01)
A61B 5/7267 (2013.01)
G16H 50/20 (2018.01)
A61B 2503/22 (2013.01)
(72) 발명자
박서현
서울특별시 송파구 잠실로 88, 113동 502호(잠실동, 레이크팰리스)
장근덕
경기도 용인시 기흥구 마북로 139 (마북동, 교동마을 현대필그린아파트)

이 발명을 지원한 국가연구개발사업
과제고유번호 1711193250
과제번호 2021-0-00866-003
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 ICT첨단유망기술육성사업
연구과제명 자율주행 차량 운전자를 위한 다중 생체신호 기반 BMI 응용 기술 개발
기 여 율 25/100
과제수행기관명 주식회사 소소에이치앤씨
연구기간 2023.01.01 ~ 2023.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711193973
과제번호 2019-0-00079-005
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 정보통신방송혁신인재양성
연구과제명 인공지능대학원
기 여 율 25/100
과제수행기관명 고려대학교산학협력단
연구기간 2023.01.01 ~ 2023.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711193622
과제번호 2021-0-02068-003
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 인공지능(AI)혁신허브사업
연구과제명 인공지능 혁신 허브 연구 개발
기 여 율 25/100
과제수행기관명 고려대학교산학협력단
연구기간 2023.01.01 ~ 2023.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711193362
과제번호 2017-0-00451-007
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 SW컴퓨팅산업원천기술개발
연구과제명 (BCI-2세부) 딥러닝을 이용하여 사람의 의도를 인지하는 BCI 기반 뇌인지컴퓨팅 기술 개발
기 여 율 25/100
과제수행기관명 고려대학교산학협력단
연구기간 2023.01.01 ~ 2023.12.31

명 세 서

청구범위

청구항 1

컴퓨팅 장치에 의해 수행되는 운전자의 상태를 추정하기 위한 방법으로서,

운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 단계;

사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 단계;

사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 단계;

상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 단계; 및

인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 단계;

를 포함하는,

방법.

청구항 2

제 1 항에 있어서,

상기 제1 분류 모델은,

학습용 뇌 신호 데이터, 상기 학습용 뇌 신호 데이터에 대응되는 운전자를 식별하기 위한 운전자 레이블 데이터 및 상기 학습용 뇌 신호 데이터에 대응되는 운전자의 상태를 나타내는 운전자 상태 데이터를 포함하는 학습 데이터셋을 이용하여, 입력되는 뇌 신호 데이터로부터 운전자의 상태를 출력하도록 사전 학습되는,

방법.

청구항 3

제 1 항에 있어서,

상기 제1 분류 모델은,

상기 시험 데이터에서 특징을 추출하는 인코더;

상기 추출된 특징에 대해 신호의 시간 축 정보를 복원시키는 디코더; 및

복원된 시험 데이터에서 채널을 줄여주어 각 시점에 맞는 운전자 상태에 대한 예측 값인 상기 운전자의 제1 상태 추정 정보를 출력하는 상태 분류 모듈;

을 포함하는,

방법.

청구항 4

제 1 항에 있어서,

상기 사전 결정된 불확실성 추정 알고리즘은,

엔트로피(entropy) 추정 알고리즘 및 상호 정보(mutual information) 추정 알고리즘을 포함하는,

방법.

청구항 5

제 1 항에 있어서,

상기 사전 결정된 데이터 증강 알고리즘은,

가우시안 노이즈(Gaussian noise)를 이용한 데이터 증강 알고리즘 및 시간 왜곡(time warping)을 이용한 데이터 증강 알고리즘을 포함하는,

방법.

청구항 6

제 1 항에 있어서,

인공지능 기반의 제3 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제3 상태 추정 정보를 획득하는 단계;

사전 결정된 일관성 손실 알고리즘을 이용하여 상기 제2 상태 추정 정보와 상기 제3 상태 추정 정보로부터 일관성 손실의 값을 산출하는 단계; 및

상기 산출된 일관성 손실의 값에 기초하여 상기 제3 분류 모델의 가중치를 갱신하는 단계;

를 더 포함하는,

방법.

청구항 7

제 6 항에 있어서,

상기 제2 분류 모델 및 상기 제3 분류 모델은 상기 제1 분류 모델과 대응되는 구조 및 가중치로 초기 설정되어 있는,

방법.

청구항 8

제 6 항에 있어서,

상기 사전 결정된 일관성 손실 알고리즘은,

상기 제2 상태 추정 정보 및 상기 제3 상태 추정 정보에 소프트맥스 함수를 적용한 소프트맥스 분포에 대해서, 교차 엔트로피 손실 함수(Cross-Entropy Loss Function) 또는 쿨백 라이블러 발산(Kullback-Leibler divergence)을 적용하는 알고리즘인,

방법.

청구항 9

제 6 항에 있어서,

상기 제3 분류 모델의 가중치를 갱신하는 단계 이후,

상기 갱신된 제3 분류 모델의 매개변수와 상기 제2 분류 모델의 매개변수 간에 지수 이동 평균을 적용하여 상기 제2 분류 모델의 매개변수를 갱신하는 단계;

를 더 포함하는,

방법.

청구항 10

제 9 항에 있어서,

상기 제2 분류 모델의 매개변수를 갱신하는 단계 이후,

무작위로 생성된 마스크 벡터를 이용하여 상기 제3 분류 모델의 일부 가중치를 상기 제1 분류 모델의 가중치로 복원하는 단계;

를 더 포함하는,

방법.

청구항 11

컴퓨터 프로그램을 포함하는 비일시적 컴퓨터 판독 가능 매체로서, 상기 컴퓨터 프로그램은 컴퓨팅 장치의 프로세서로 하여금 운전자의 상태를 추정하기 위한 방법을 수행하도록 하며, 상기 방법은:

운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 단계;

사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 단계;

사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 단계;

상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 단계; 및

인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 단계;

를 포함하는,

컴퓨터 프로그램을 포함하는 비일시적 컴퓨터 판독 가능 매체.

청구항 12

운전자의 상태를 추정하기 위한 컴퓨팅 장치에 있어서,

프로세서; 및

메모리;

를 포함하고,

상기 프로세서는:

운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 동작;

사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 동작;

사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 동작;

상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 동작; 및

인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 동작;

을 수행하는,

컴퓨팅 장치.

발명의 설명

기 술 분 야

[0001] 본 개시는 상태 추정 기술에 관한 것으로, 보다 구체적으로, 운전자의 상태를 추정하기 위한 방법 및 장치에 관한 것이다.

배 경 기 술

[0002] 운전자의 졸음은 주의력, 경계심 및 인지 능력의 저하를 유발하여 심각한 교통 사고를 불러일으킨다. 운전자의 경계 상태를 지속적으로 관찰하고 운전자가 잠들기 전에 경보를 보낼 수 있는 졸음 감시 시스템의 개발은 운전 안전과 교통사고 예방을 위해 많은 관심을 받고 있다. 이를 방지하기 위해 운전자의 상태를 모니터링하는 인공지능(Artificial intelligence, AI) 기술이 개발되고 있다. 현존하는 시스템에서는 차량 움직임, 안면 변화 및 생체 신호를 통해 운전자의 상태를 추정하고 있다. 이때, 생체 신호 중, 뇌 신호를 직관적으로 반영할 수 있는 장치로써 뇌전도 (Electroencephalogram, EEG)를 사용한 운전자 졸음 모니터링을 조사하기 위한 많은 노력이 이루어졌다. 뇌전도는 비침습적 기법으로써 두피 표면에 전극을 부착시켜 뇌 신호를 측정하는 방식이다. 뇌전도는 젤을 도포하여 부착시키는 습식 뇌전도와 젤을 도포하지 않고 부착시키는 건식 뇌전도 방식이 있다. 뇌전도는 시간 해상도가 높고, 비용이 저렴하기 때문에 뇌 역학을 포착하기 위한 가장 실용적인 비침습적인 기술로 볼 수 있다.

[0003] 뇌-컴퓨터 인터페이스 (Brain-computer interface, BCI) 기술에서 사용되는 뇌전도 등의 생체신호에는 본질적으로 운전자 간 변동성 (inter-subject variability) 및 운전자 내 변동성 (intra-subject variability)이 포함되어 있다. 다양한 피험자의 뇌파 신호의 가변성은 전극 변위, 피부-전극 임피던스, 다양한 머리 모양과 크기, 다양한 뇌 활동 패턴, 업무와 무관한 뇌 활동에 의한 교란과 같은 많은 요인에 기인한다. 수작업 기능에 의존하는 기존의 방법은 종종 관심 있는 일부 뇌파 특성에 매우 특정하며, 이는 졸음 인식에 필수적일 수 있는 다른 관련 정보를 잠재적으로 배제한다. 이러한 특성에 의해 구축한 모델의 일반화 성능이 떨어지는 경향을 보인다. 이러한 문제를 해결하기 위해 기존의 발명들은 운전자에 의존적인 모델을 구축하였다. 운전자에 의존적인 모델의 경우에는 목표 피험자의 데이터를 사용하여 학습하고, 평가한다. 하지만, 목표 피험자의 데이터를 학습 단계와 평가 단계 모두에서 수집하는 것은 어려움이 존재한다. 운전자에 의존적인 모델은 특정 운전자에게만 높은 성능을 보이는 과적합 현상을 보일 수 있다. 즉, 다른 운전자에 대해 평가를 진행할 때, 일반화 성능이 하락하여 낮은 성능을 보일 수 있다. 또한, 동일한 운전자의 실험이어도 세션(session) 간에 변동성이 존재할 수 있다. 이를 해결하기 위한 또 다른 방법은 교정(calibration) 과정을 포함시키는 것이다. 교정 과정은 장비를 사용하려는 목표 사용자의 뇌 신호에 시스템을 적응시키기 위해 파라미터들을 재조정하는 세션을 의미한다. 교정 과정은 운전자에게 불쾌한 경험을 제공할 수 있으며, 번거로운 작업을 거쳐 시간 소모가 있다는 단점이 존재한다. 그러나, 교정 과정이 없는 졸음 상태 추정 시스템을 구축하는 것은 어려운 과제이다. 어려운 점은 낮은 신호 대 잡음 비율을 가진 다양한 뇌 신호에서 일반적인 졸음 관련 패턴을 포착하는 데 있다.

선행기술문헌

특허문헌

[0004] (특허문헌 0001) 대한민국 등록특허 제10-1714202호(2017.03.08. 공고)

발명의 내용

해결하려는 과제

[0005] 본 개시는 전술한 배경기술에 대응하여 안출된 것으로, 운전자의 상태를 추정하기 위한 방법 및 장치를 제공하고자 한다.

[0006] 본 개시의 기술적 과제들은 이상에서 언급한 기술적 과제로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 당업자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0007] 전술한 바와 같은 과제를 해결하기 위한 본 개시의 일 실시예에 따라, 컴퓨팅 장치에 의해 수행되는 운전자의 상태를 추정하기 위한 방법으로서, 운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 단계; 사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 단계; 사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 단계; 상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 단계; 및 인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 단계;를 포함할 수 있다.

[0008] 대안적으로, 상기 제1 분류 모델은, 학습용 뇌 신호 데이터, 상기 학습용 뇌 신호 데이터에 대응되는 운전자를 식별하기 위한 운전자 레이블 데이터 및 상기 학습용 뇌 신호 데이터에 대응되는 운전자의 상태를 나타내는 운전자 상태 데이터를 포함하는 학습 데이터셋을 이용하여, 입력되는 뇌 신호 데이터로부터 운전자의 상태를 출력하도록 사전 학습될 수 있다.

[0009] 대안적으로, 상기 제1 분류 모델은, 상기 시험 데이터에서 특징을 추출하는 인코더; 상기 추출된 특징에 대해 신호의 시간 축 정보를 복원시키는 디코더; 및 복원된 시험 데이터에서 채널을 줄여주어 각 시점에 맞는 운전자 상태에 대한 예측 값인 상기 운전자의 제1 상태 추정 정보를 출력하는 상태 분류 모듈;을 포함할 수 있다.

[0010] 대안적으로, 상기 사전 결정된 불확실성 추정 알고리즘은, 엔트로피(entropy) 추정 알고리즘 및 상호 정보(mutual information) 추정 알고리즘을 포함할 수 있다.

[0011] 대안적으로, 상기 사전 결정된 데이터 증강 알고리즘은, 가우시안 노이즈(Gaussian noise)를 이용한 데이터 증강 알고리즘 및 시간 왜곡(time warping)을 이용한 데이터 증강 알고리즘을 포함할 수 있다.

[0012] 대안적으로, 인공지능 기반의 제3 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제3 상태 추정 정보를 획득하는 단계; 사전 결정된 일관성 손실 알고리즘을 이용하여 상기 제2 상태 추정 정보와 상기 제3 상태 추정 정보로부터 일관성 손실의 값을 산출하는 단계; 및 상기 산출된 일관성 손실의 값에 기초하여 상기 제3 분류 모델의 가중치를 갱신하는 단계;를 더 포함할 수 있다.

[0013] 대안적으로, 상기 제2 분류 모델 및 상기 제3 분류 모델은 상기 제1 분류 모델과 대응되는 구조 및 가중치로 초기 설정되어 있을 수 있다.

[0014] 대안적으로, 상기 사전 결정된 일관성 손실 알고리즘은, 상기 제2 상태 추정 정보 및 상기 제3 상태 추정 정보에 소프트맥스 함수를 적용한 소프트맥스 분포에 대해서, 교차 엔트로피 손실 함수(Cross-Entropy Loss Function) 또는 쿨백 라이블러 발산(Kullback-Leibler divergence)을 적용하는 알고리즘일 수 있다.

[0015] 대안적으로, 상기 제3 분류 모델의 가중치를 갱신하는 단계 이후, 상기 갱신된 제3 분류 모델의 매개변수와 상기 제2 분류 모델의 매개변수 간에 지수 이동 평균을 적용하여 상기 제2 분류 모델의 매개변수를 갱신하는 단계;를 더 포함할 수 있다.

[0016] 대안적으로, 상기 제2 분류 모델의 매개변수를 갱신하는 단계 이후, 무작위로 생성된 마스크 벡터를 이용하여 상기 제3 분류 모델의 일부 가중치를 상기 제1 분류 모델의 가중치로 복원하는 단계;를 더 포함할 수 있다.

[0017] 본 개시의 일 실시예에 따른 컴퓨터 프로그램을 포함하는 비일시적 컴퓨터 판독 가능 매체로서, 상기 컴퓨터 프로그램은 컴퓨팅 장치의 프로세서로 하여금 운전자의 상태를 추정하기 위한 방법을 수행하도록 하며, 상기 방법은: 운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 단계; 사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 단계; 사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 단계; 상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 단계; 및 인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 단계;를 포함하는, 컴퓨터 프로그램을 포함하는 비일시적 컴퓨터 판독 가능 매체.

[0018] 본 개시의 일 실시예에 따른 운전자의 상태를 추정하기 위한 컴퓨팅 장치에 있어서, 프로세서; 및 메모리;를 포함하고, 상기 프로세서는: 운전자에 부착된 센서를 통해 상기 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득하는 동작; 사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 상기 시험 데이터로부터 상기 운전자의 제1 상태 추정 정보를 획득하는 동작; 사전 결정된 불확실성 추정 알고리즘을 이용하여 상기 제1 상태 추정 정보에 대한 불확실성 값을 획득하는 동작; 상기 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 상기 시험 데이터에 증강을 수행하는 동작; 및 인공지능 기반의 제2 분류 모델을 이용하여 상기 증강된 시험 데이터로부터 상기 운전자의 상태를 예측한 결과인 상기 운전자의 제2 상태 추정 정보를 획득하는 동작;을 수행할 수 있다.

발명의 효과

[0019] 본 개시는 운전자의 변화에 강인한 인공지능 기반의 모델을 구축할 수 있다. 목표 운전자의 데이터에 따라 실시간으로 인공지능 기반의 모델의 가중치를 업데이트하며 적응하고 예측이 가능하기에 일반화 성능이 향상될 수 있다.

[0020] 본 개시는 시간이 지나감에 따라 피험자 변화에 더욱 강인한 분류 결과를 제공할 수 있다. 본 개시는 목표 운전자의 데이터의 샘플이 입력됨에 따라 모델의 가중치가 갱신되기 때문에 시간에 따라 운전자 변화에 더욱 강인한 모델로 갱신될 수 있다.

[0021] 본 개시는 사용자가 원하는 방식에 따라 온라인 및 오프라인 방식으로 수행할 수 있다. 본 개시는 온라인 방식으로 각 시점의 분류 결과를 제공할 수 있으며, 오프라인 방식으로 목표 운전자의 데이터의 모든 시점에 대해 분류 결과를 제공할 수 있다.

[0022] 본 개시는 캘리브레이션 과정을 없앰으로써, 시간을 절약할 수 있다. 종래의 기술에서는 운전자의 변화에 일반화된 모델을 제공하기 위해 캘리브레이션 과정으로 모델을 적응시켰지만, 본 개시에서는 이를 시험 시간 적응 방식으로 대체하여 강인한 표현의 학습이 가능할 수 있다.

[0023] 본 개시에서 얻을 수 있는 효과는 이상에서 언급한 효과로 제한되지 않으며, 언급하지 않은 또 다른 효과들은 아래의 기재로부터 본 개시가 속하는 기술분야에서 통상의 지식을 가진 자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0024] 다양한 양상들이 이제 도면들을 참조로 기재되며, 여기서 유사한 참조 번호들은 총괄적으로 유사한 구성요소들을 지칭하는데 이용된다. 이하의 실시예에서, 설명 목적을 위해, 다수의 특정 세부사항들이 하나 이상의 양상들의 총체적 이해를 제공하기 위해 제시된다. 그러나, 그러한 양상(들)이 이러한 구체적인 세부사항들 없이 실시될 수 있음은 명백할 것이다.

도 1은 본 개시의 일 실시예에 따른 운전자의 상태를 추정하기 위한 시스템을 설명하기 위한 도면이다.

도 2는 본 개시의 일 실시예에 따른 인공지능 기반의 모델의 예시적인 구조를 나타낸 도면이다.

도 3은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 추정하기 위한 방법을 나타낸 도면이다.

도 4는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 인공지능 기반의 모델의 학습 과정을 간략하게 나타낸 도면이다.

도 5는 본 개시의 일 실시예에 따른 인공지능 기반의 모델을 간략하게 나타낸 도면이다.

도 6은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 시험 데이터에 대한 추론 과정을 간략하게 나타낸 도면이다.

도 7은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 제2 분류 모델의 매개변수 갱신 과정을 간략하게 나타낸 도면이다.

도 8은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 제3 분류 모델의 가중치 복원 과정을 간략하게 나타낸 도면이다.

도 9는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 추정하는 전체적인 과정을 나타낸 도면이다.

도 10은 본 개시의 실시예들이 구현될 수 있는 예시적인 컴퓨팅 환경에 대한 간략하고 일반적인 개략도를 도시한다.

발명을 실시하기 위한 구체적인 내용

[0025] 다양한 실시예들이 이제 도면을 참조하여 설명된다. 본 명세서에서, 다양한 설명들이 본 개시의 이해를 제공하기 위해서 제시된다. 그러나, 이러한 실시예들은 이러한 구체적인 설명 없이도 실행될 수 있음이 명백하다.

[0026] 본 명세서에서 사용되는 용어 "컴포넌트", "모듈", "시스템" 등은 컴퓨터-관련 엔티티, 하드웨어, 펌웨어, 소프트웨어, 소프트웨어 및 하드웨어의 조합, 또는 소프트웨어의 실행을 지칭한다. 예를 들어, 컴포넌트는 프로세서 상에서 실행되는 처리과정(procedure), 프로세서, 객체, 실행 스레드, 프로그램, 및/또는 컴퓨터일 수 있지만, 이들로 제한되는 것은 아니다. 예를 들어, 컴퓨팅 장치에서 실행되는 애플리케이션 및 컴퓨팅 장치 모두 컴포넌트일 수 있다. 하나 이상의 컴포넌트는 프로세서 및/또는 실행 스레드 내에 상주할 수 있다. 일 컴포넌트는 하나의 컴퓨터 내에 로컬화 될 수 있다. 일 컴포넌트는 2개 이상의 컴퓨터들 사이에 분배될 수 있다. 또한, 이러한 컴포넌트들은 그 내부에 저장된 다양한 데이터 구조들을 갖는 다양한 컴퓨터 판독가능한 매체로부터 실행할 수 있다. 컴포넌트들은 예를 들어 하나 이상의 데이터 패킷들을 갖는 신호(예를 들면, 로컬 시스템, 분산 시스템에서 다른 컴포넌트와 상호작용하는 하나의 컴포넌트로부터의 데이터 및/또는 신호를 통해 다른 시스템과 인터넷과 같은 네트워크를 통해 전송되는 데이터)에 따라 로컬 및/또는 원격 처리들을 통해 통신할 수 있다.

[0027] 더불어, 용어 "또는"은 배타적 "또는"이 아니라 내포적 "또는"을 의미하는 것으로 의도된다. 즉, 달리 특정되지 않거나 문맥상 명확하지 않은 경우에, "X는 A 또는 B를 이용한다"는 자연적인 내포적 치환 중 하나를 의미하는 것으로 의도된다. 즉, X가 A를 이용하거나; X가 B를 이용하거나; 또는 X가 A 및 B 모두를 이용하는 경우, "X는 A 또는 B를 이용한다"가 이들 경우들 어느 것으로도 적용될 수 있다. 또한, 본 명세서에 사용된 "또는", "및/또는"이라는 용어는 열거된 관련 아이템들 중 하나 이상의 아이템의 가능한 모든 조합을 지칭하고 포함하는 것으로 이해되어야 한다.

[0028] 또한, "포함한다" 및/또는 "포함하는"이라는 용어는, 해당 특징 및/또는 구성요소가 존재함을 의미하는 것으로 이해되어야 한다. 다만, "포함한다" 및/또는 "포함하는"이라는 용어는, 하나 이상의 다른 특징, 구성요소 및/또는 이들의 그룹의 존재 또는 추가를 배제하지 않는 것으로 이해되어야 한다. 또한, 달리 특정되지 않거나 단수 형태를 지시하는 것으로 문맥상 명확하지 않은 경우에, 본 명세서와 청구범위에서 단수는 일반적으로 "하나 또는 그 이상"을 의미하는 것으로 해석되어야 한다.

[0029] 그리고, "A 또는 B 중 적어도 하나"이라는 용어는, "A만을 포함하는 경우", "B 만을 포함하는 경우", "A와 B의 구성으로 조합된 경우"를 의미하는 것으로 해석되어야 한다.

[0030] 당업자들은 추가적으로 여기서 개시된 실시예들과 관련되어 설명된 다양한 예시적 논리적 블록들, 구성들, 모듈들, 회로들, 수단들, 로직들, 및 알고리즘 단계들이 전자 하드웨어, 컴퓨터 소프트웨어, 또는 양쪽 모두의 조합들로 구현될 수 있음을 인식해야 한다. 하드웨어 및 소프트웨어의 상호교환성을 명백하게 예시하기 위해, 다양한 예시적 컴포넌트들, 블록들, 구성들, 수단들, 로직들, 모듈들, 회로들, 및 단계들은 그들의 기능성 측면에서 일반적으로 위에서 설명되었다. 그러한 기능성이 하드웨어로 또는 소프트웨어로서 구현되는지 여부는 전반적인 시스템에 부과된 특정 어플리케이션(application) 및 설계 제한들에 달려 있다. 숙련된 기술자들은 각각의 특정 어플리케이션들을 위해 다양한 방법들로 설명된 기능성을 구현할 수 있다. 다만, 그러한 구현의 결정들이 본 개시내용의 영역을 벗어나게 하는 것으로 해석되어서는 안 된다.

[0031] 제시된 실시예들에 대한 설명은 본 개시의 기술 분야에서 통상의 지식을 가진 자가 본 발명을 이용하거나 또는 실시할 수 있도록 제공된다. 이러한 실시예들에 대한 다양한 변형들은 본 개시의 기술 분야에서 통상의 지식을 가진 자에게 명백할 것이다. 여기에 정의된 일반적인 원리들은 본 개시의 범위를 벗어남이 없이 다른 실시예들에 적용될 수 있다. 그리하여, 본 발명은 여기에 제시된 실시예 들로 한정되는 것이 아니다. 본 발명은 여기에 제시된 원리들 및 신규한 특징들과 일관되는 최광의의 범위에서 해석되어야 할 것이다.

[0032] 본 개시내용에서의 제 1, 제 2, 또는 제 3 과 같이 제 N으로 표현되는 용어들은 적어도 하나의 엔티티들을 구분하기 위해 사용된다. 예를 들어, 제 1과 제 2로 표현된 엔티티들은 서로 동일하거나 또는 상이할 수 있다.

[0033] 그리고, "A, B 등"과 같이 "~ 등"이라는 용어는, "A만을 포함하는 경우", "B 만을 포함하는 경우", "A와 B의 구성으로 조합된 경우"를 의미하는 것으로 해석되어야 한다.

[0034] 본 개시에서, 사용자와 운전자는 동일한 의미(상호교환 가능한 의미)로 사용될 수 있다.

[0035] 도 1은 본 개시의 일 실시예에 따른 운전자의 상태를 추정하기 위한 시스템을 설명하기 위한 도면이다.

[0036] 도 1을 참조하면, 운전자의 상태를 추정하기 위한 시스템은 컴퓨팅 장치(100), 차량(200), 네트워크부(300) 등을 포함할 수 있다 운전자의 상태를 추정하기 위한 시스템의 구성은 간략화 하여 나타낸 예시일 뿐이다. 컴퓨팅 장치(100), 차량(200), 네트워크(300) 등의 구성 또한 간략화 하여 나타낸 예시일 뿐이다.

[0037] 본 개시의 일 실시예에 따른 컴퓨팅 장치(100)는 운전자의 상태를 추정하기 위한 장치일 수 있다.

[0038] 일 실시예에서, 컴퓨팅 장치(100)는 임의의 형태의 서버 또는 사용자 디바이스를 포함할 수 있다.

[0039] 일 실시예에서, 컴퓨팅 장치(100)는 차량(200)으로부터 차량(200)의 운전자에 부착된 센서를 통해 획득된 운전자의 뇌 신호(예를 들어, 뇌전도(Electroencephalogram, EEG) 신호 등)를 수신하고, 이에 대한 응답으로 운전자의 상태 추정 정보를 획득하고, 획득된 운전자의 상태 추정 정보를 차량(200)(또는, 사용자의 디바이스)에 전달할 수 있다.

[0040] 일 실시예에서, 컴퓨팅 장치(100)는 차량(200)에 포함될 수 있다. 예를 들어, 컴퓨팅 장치(100)는 차량(200)에 존재하는 운전자에 부착된 센서로부터 운전자의 뇌 신호를 직접적으로 획득할 수 있다. 컴퓨팅 장치(100)는 운전자의 상태 추정 정보를 차량(200)의 디스플레이를 통해 출력할 수 있다. 컴퓨팅 장치(100)는 획득된 상태 추정 정보를 사용자의 디바이스에 전달할 수 있다.

[0041] 컴퓨팅 장치(100)는 프로세서(110), 메모리(130), 네트워크부(150)를 포함할 수 있다.

[0042] 프로세서(110)는 하나 이상의 코어로 구성될 수 있으며, 컴퓨팅 장치(100)의 중앙 처리 장치(CPU: central processing unit), 범용 그래픽 처리 장치(GPGPU: general purpose graphics processing unit), 텐서 처리 장치(TPU: tensor processing unit)등의 데이터의 처리에 관련된 동작을 수행하기 위한 프로세서를 포함할 수 있다.

[0043] 본 개시의 일 실시예에 따라 프로세서(110)는 신경망의 학습을 위한 연산을 수행할 수도 있다. 예를 들어, 프로세서(110)는 딥러닝(DL: deep learning)에서 학습을 위한 입력 데이터의 처리, 입력 데이터에서의 피쳐 추출, 오차 계산, 역전파(backpropagation)를 이용한 신경망의 가중치 업데이트 등의 신경망의 학습을 위한 계산을 수행할 수 있다. 프로세서(110)의 CPU, GPGPU, 및 TPU 중 적어도 하나가 네트워크 함수의 학습을 처리할 수 있다. 예를 들어, CPU 와 GPGPU가 함께 네트워크 함수의 학습, 네트워크 함수를 이용한 데이터 분류를 처리할 수 있다. 또한, 본 개시의 일 실시예에서 복수의 컴퓨팅 장치들의 프로세서들을 함께 사용하여 네트워크 함수의 학습, 네트워크 함수를 이용한 데이터 분류를 처리할 수도 있다.

[0044] 프로세서(110)는 통상적으로 컴퓨팅 장치(100)의 전반적인 동작을 제어할 수 있다. 프로세서(110)는 컴퓨팅 장치(100)에 포함된 구성요소들을 통해 입력 또는 출력되는 신호, 데이터, 정보 등을 처리하거나 메모리(130)에 저장된 응용 프로그램을 구동함으로써, 사용자에게 적절한 정보 또는 기능을 제공 또는 처리할 수 있다.

[0045] 본 개시의 일 실시예에서, 메모리(130)는 프로세서(110)가 생성하거나 결정한 임의의 형태의 정보 및/또는 네트워크부(150)가 수신한 임의의 형태의 정보를 저장할 수 있다. 일 실시예에서, 메모리(130)는 데이터베이스를 저장하고 있을 수 있다. 데이터베이스는 컴퓨팅 장치(100)가 처리할 수 있는 형태로 저장된 데이터의 집합일 수 있다. 예를 들어, 메모리(130)는 다중 운전자(또는, 단일 운전자)의 레이블 데이터, 생체 신호 데이터, 상태 정보 등을 포함하는 운전자의 데이터 베이스를 포함할 수 있다. 일 실시예에서, 프로세서(110)는 메모리(130)에 저장된 데이터베이스를 이용하여 학습 데이터(학습 데이터셋)를 생성, 획득, 구성할 수 있다. 프로세서(110)는

학습 데이터를 이용하여 인공지능 기반의 모델을 학습시킬 수 있다.

[0046] 본 개시에서 다중 운전자(또는, 단일 운전자)의 레이블 데이터는 운전자를 식별할 수 있는 데이터(예를 들어, ID, 고유번호 등)를 포함할 수 있다.

[0047] 본 개시에서 생체 신호 데이터는 단일 종류 또는 여러 종류의 생체 신호를 포함할 수 있다. 예를 들어, 생체 신호 데이터는 뇌전도(Electroencephalogram, EEG) 등의 신호 데이터를 포함할 수 있다.

[0048] 본 개시에서 상태 정보는 특정 상황, 시간 등에 운전자의 주관적인 평가 또는 소정의 이벤트에 따라 정량적으로 산정된 상태에 관한 정보를 포함할 수 있다. 예를 들어, 상태 정보는 멀미를 평가하는 척도인 MISC(11-point MIsery SCale), 졸음을 평가하는 척도인 KSS(Karolinska Sleepiness Scale) 등을 포함할 수 있다.

[0049] 본 개시의 일 실시예에서, 메모리(130)는 플래시 메모리 타입(flash memory type), 하드디스크 타입(hard disk type), 멀티미디어 카드 마이크로 타입(multimedia card micro type), 카드 타입의 메모리(예를 들어 SD 또는 XD 메모리 등), 램(Random Access Memory, RAM), SRAM(Static Random Access Memory), 롬(Read-Only Memory, ROM), EEPROM(Electrically Erasable Programmable Read-Only Memory), PROM(Programmable Read-Only Memory), 자기 메모리, 자기 디스크 및/또는 광디스크 중 적어도 하나의 타입의 저장매체를 포함할 수 있다. 컴퓨팅 장치(100)는 인터넷(internet) 상에서 메모리(130)의 저장 기능을 수행하는 웹 스토리지(web storage)와 관련되어 동작할 수도 있다. 전술한 메모리에 대한 기재는 예시일 뿐, 본 개시는 이에 제한되지 않는다. 메모리(130)는 프로세서(110)에 의하여 동작 될 수 있다.

[0050] 본 개시의 일 실시예에 따른 네트워크부(150)는 임의의 형태의 데이터 및 신호 등을 송신 및 수신할 수 있는 임의의 유무선 통신 네트워크가 본 개시 내용에서 표현되는 네트워크에 포함될 수 있다. 본 명세서에서 설명된 기술들은 위에서 언급된 네트워크들뿐만 아니라, 다른 네트워크들에서도 사용될 수 있다.

[0051] 차량(200)은 적어도 하나의 전자 제어장치(ECU, Electronic Control Unit)를 포함할 수 있다. 일 실시예에서, 차량(200)은 차량에 관한 신호, 차량의 운전자에 부착된 센서를 통해 획득되는 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 컴퓨팅 장치(100)에 전달하는 제어부(미도시)를 포함할 수 있다. 다른 일 실시예에서, 운전자의 상태를 감지하기 위한 시스템은 차량(200)에 연결되어 차량에 관한 신호, 차량의 운전자에 부착된 센서를 통해 획득되는 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호 등을 수집하고, 수집된 정보를 컴퓨팅 장치(100)에 전달하는 사용자의 디바이스(미도시)를 더 포함할 수 있다. 차량(200) 및/또는 사용자의 디바이스(미도시)는 컴퓨팅 장치(100)로부터 운전자의 상태 추정 정보를 수신할 수 있다.

[0052] 네트워크(300)는 임의의 형태의 데이터 및 신호 등을 송수신할 수 있는 임의의 유무선 통신 네트워크를 포함할 수 있다. 예를 들어, 네트워크는 컴퓨팅 장치(100)와 차량(200) 간에 데이터, 정보, 신호 등을 송수신할 수 있는 유무선 통신 네트워크를 포함할 수 있다.

[0053] 도 2는 본 개시의 일 실시예에 따른 인공지능 기반의 모델의 예시적인 구조를 나타낸 도면이다.

[0054] 본 명세서에 걸쳐, 인공지능 기반의 모델, 연산 모델, 신경망, 네트워크 함수, 뉴럴 네트워크(neural network)는 동일한 의미(상호교환 가능한 의미)로 사용될 수 있다.

[0055] 신경망은 일반적으로 노드(node)라 지칭될 수 있는 상호 연결된 계산 단위들의 집합으로 구성될 수 있다. 이러한 노드들은 뉴런(neuron)들로 지칭될 수도 있다. 신경망은 적어도 하나 이상의 노드들을 포함하여 구성된다. 신경망들을 구성하는 노드(또는 뉴런)들은 하나 이상의 링크에 의해 상호 연결될 수 있다.

[0056] 신경망 내에서, 링크를 통해 연결된 하나 이상의 노드들은 상대적으로 입력 노드 및 출력 노드의 관계를 형성할 수 있다. 입력 노드 및 출력 노드의 개념은 상대적인 것으로서, 하나의 노드에 대하여 출력 노드 관계에 있는 임의의 노드는 다른 노드와의 관계에서 입력 노드 관계에 있을 수 있으며, 그 역도 성립할 수 있다. 상술한 바와 같이, 입력 노드 대 출력 노드 관계는 링크를 중심으로 생성될 수 있다. 하나의 입력 노드에 하나 이상의 출력 노드가 링크를 통해 연결될 수 있으며, 그 역도 성립할 수 있다.

[0057] 하나의 링크를 통해 연결된 입력 노드 및 출력 노드 관계에서, 출력 노드의 데이터는 입력 노드에 입력된 데이터에 기초하여 그 값이 결정될 수 있다. 여기서 입력 노드와 출력 노드를 상호 연결하는 링크는 가중치(weight)를 가질 수 있다. 가중치는 가변적일 수 있으며, 신경망이 원하는 기능을 수행하기 위해, 사용자 또는 알고리즘에 의해 가변 될 수 있다. 예를 들어, 하나의 출력 노드에 하나 이상의 입력 노드가 각각의 링크에 의해 상호 연결된 경우, 출력 노드는 상기 출력 노드와 연결된 입력 노드들에 입력된 값들 및 각각의 입력 노드들에 대응

하는 링크에 설정된 가중치에 기초하여 출력 노드 값을 결정할 수 있다.

[0058] 상술한 바와 같이, 신경망은 하나 이상의 노드들이 하나 이상의 링크를 통해 상호 연결되어 신경망 내에서 입력 노드 및 출력 노드 관계를 형성한다. 신경망 내에서 노드들과 링크들의 개수 및 노드들과 링크들 사이의 연관관계, 링크들 각각에 부여된 가중치의 값에 따라, 신경망의 특성이 결정될 수 있다. 예를 들어, 동일한 개수의 노드 및 링크들이 존재하고, 링크들의 가중치 값이 상이한 두 신경망이 존재하는 경우, 두 개의 신경망들은 서로 상이한 것으로 인식될 수 있다.

[0059] 신경망은 하나 이상의 노드들의 집합으로 구성될 수 있다. 신경망을 구성하는 노드들의 부분 집합은 레이어(layer)를 구성할 수 있다. 신경망을 구성하는 노드들 중 일부는, 최초 입력 노드로부터의 거리들에 기초하여, 하나의 레이어를 구성할 수 있다. 예를 들어, 최초 입력 노드로부터 거리가 n인 노드들의 집합은, n 레이어를 구성할 수 있다. 최초 입력 노드로부터 거리는, 최초 입력 노드로부터 해당 노드까지 도달하기 위해 거쳐야 하는 링크들의 최소 개수에 의해 정의될 수 있다. 그러나, 이러한 레이어의 정의는 설명을 위한 임의적인 것으로서, 신경망 내에서 레이어의 차수는 상술한 것과 상이한 방법으로 정의될 수 있다. 예를 들어, 노드들의 레이어는 최종 출력 노드로부터 거리에 의해 정의될 수도 있다.

[0060] 본 개시내용의 일 실시예에서, 뉴런들 또는 노드들의 집합은 레이어라는 표현으로 정의될 수 있다.

[0061] 최초 입력 노드는 신경망 내의 노드들 중 다른 노드들과의 관계에서 링크를 거치지 않고 데이터가 직접 입력되는 하나 이상의 노드들을 의미할 수 있다. 또는, 신경망 네트워크 내에서, 링크를 기준으로 한 노드 간의 관계에 있어서, 링크로 연결된 다른 입력 노드들을 가지지 않는 노드들을 의미할 수 있다. 이와 유사하게, 최종 출력 노드는 신경망 내의 노드들 중 다른 노드들과의 관계에서, 출력 노드를 가지지 않는 하나 이상의 노드들을 의미할 수 있다. 또한, 히든 노드는 최초 입력 노드 및 최후 출력 노드가 아닌 신경망을 구성하는 노드들을 의미할 수 있다.

[0062] 본 개시의 일 실시예에 따른 신경망은 입력 레이어의 노드의 개수가 출력 레이어의 노드의 개수와 동일할 수 있으며, 입력 레이어에서 히든 레이어(hidden layer, 은닉층)로 진행됨에 따라 노드의 수가 감소하다가 다시 증가하는 형태의 신경망일 수 있다. 또한, 본 개시의 다른 일 실시예에 따른 신경망은 입력 레이어의 노드의 개수가 출력 레이어의 노드의 개수 보다 적을 수 있으며, 입력 레이어에서 히든 레이어로 진행됨에 따라 노드의 수가 감소하는 형태의 신경망일 수 있다. 또한, 본 개시의 또 다른 일 실시예에 따른 신경망은 입력 레이어의 노드의 개수가 출력 레이어의 노드의 개수보다 많을 수 있으며, 입력 레이어에서 히든 레이어로 진행됨에 따라 노드의 수가 증가하는 형태의 신경망일 수 있다. 본 개시의 또 다른 일 실시예에 따른 신경망은 상술한 신경망들의 조합된 형태의 신경망일 수 있다.

[0063] 딥 뉴럴 네트워크(DNN: deep neural network, 심층신경망)는 입력 레이어와 출력 레이어 외에 복수의 히든 레이어를 포함하는 신경망을 의미할 수 있다. 딥 뉴럴 네트워크를 이용하면 데이터의 잠재적인 구조(latent structures)를 파악할 수 있다. 딥 뉴럴 네트워크는 컨볼루션 뉴럴 네트워크(CNN: convolutional neural network), 리커런트 뉴럴 네트워크(RNN: recurrent neural network), 오토 인코더(auto encoder), 적대적 생성 네트워크(GAN: Generative Adversarial Network), 제한 볼츠만 머신(RBM: Restricted Boltzmann Machine), 심층 신뢰 네트워크(DBN: deep belief network), Q 네트워크, U 네트워크, 샴 네트워크 등을 포함할 수 있다. 전술한 딥 뉴럴 네트워크의 기재는 예시일 뿐이며, 본 개시는 이에 제한되지 않는다.

[0064] 예시적으로, 본 개시내용의 인공지능 기반의 모델은, 트랜스포머, 생성형 사전학습 트랜스포머(GPT), BERT(Bidirectional Encoder Representations from Transformers) 등을 포함할 수 있다.

[0065] 본 개시내용의 인공지능 기반의 모델은 입력 레이어, 히든 레이어 및 출력 레이어를 포함하는 전술한 임의의 구조의 네트워크 구조에 의해 표현될 수 있다.

[0066] 본 개시내용의 인공지능 기반의 모델에서 사용될 수 있는 뉴럴 네트워크는 지도 학습(supervised learning), 비지도 학습(unsupervised learning), 반-지도 학습(semi-supervised learning), 또는 강화학습(reinforcement learning), 분산 딥러닝을 위한 연합학습(Federated Learning), 점진학습(incremental learning) 중 적어도 하나의 방식으로 학습될 수 있다. 뉴럴 네트워크의 학습은 뉴럴 네트워크가 특정한 동작을 수행하기 위한 지식을 뉴럴 네트워크에 적용하는 과정일 수 있다.

[0067] 뉴럴 네트워크는 출력의 오류를 최소화하는 방향으로 학습될 수 있다. 뉴럴 네트워크의 학습에서 반복적으로 학습 데이터를 뉴럴 네트워크에 입력시키고 학습 데이터에 대한 뉴럴 네트워크의 출력과 타겟의 에러를 계산하고, 에러를 줄이기 위한 방향으로 뉴럴 네트워크의 에러를 뉴럴 네트워크의 출력 레이어에서부터 입력 레이어 방향

으로 역전파(backpropagation)하여 뉴럴 네트워크의 각 노드의 가중치를 업데이트 하는 과정이다. 지도 학습의 경우 각각의 학습 데이터에 정답이 라벨링되어있는 학습 데이터를 사용하며(즉, 라벨링된 학습 데이터), 비지도 학습의 경우는 각각의 학습 데이터에 정답이 라벨링되어 있지 않을 수 있다. 즉, 예를 들어 데이터 분류에 관한 지도 학습의 경우의 학습 데이터는 학습 데이터 각각에 카테고리가 라벨링된 데이터일 수 있다. 라벨링된 학습 데이터가 뉴럴 네트워크에 입력되고, 뉴럴 네트워크의 출력(카테고리)과 학습 데이터의 라벨을 비교함으로써 오류(error)가 계산될 수 있다.

[0068] 다른 예로, 데이터 분류에 관한 비지도 학습의 경우 입력인 학습 데이터가 뉴럴 네트워크 출력과 비교됨으로써 오류가 계산될 수 있다. 계산된 오류는 뉴럴 네트워크에서 역방향(즉, 출력 레이어에서 입력 레이어 방향)으로 역전파되며, 역전파에 따라 뉴럴 네트워크의 각 레이어의 각 노드들의 연결 가중치가 업데이트될 수 있다. 업데이트되는 각 노드의 연결 가중치는 학습률(learning rate)에 따라 변화량이 결정될 수 있다. 입력 데이터에 대한 뉴럴 네트워크의 계산과 에러의 역전파는 학습 사이클(epoch)을 구성할 수 있다. 학습률은 뉴럴 네트워크의 학습 사이클의 반복 횟수에 따라 상이하게 적용될 수 있다. 예를 들어, 뉴럴 네트워크의 학습 초기에는 높은 학습률을 사용하여 뉴럴 네트워크가 빠르게 일정 수준의 성능을 확보하도록 하여 효율성을 높이고, 학습 후기에는 낮은 학습률을 사용하여 정확도를 높일 수 있다.

[0069] 뉴럴 네트워크의 학습에서 일반적으로 학습 데이터는 실제 데이터(즉, 학습된 뉴럴 네트워크를 이용하여 처리하고자 하는 데이터)의 부분집합일 수 있으며, 따라서, 학습 데이터에 대한 오류는 감소하나 실제 데이터에 대해서는 오류가 증가하는 학습 사이클이 존재할 수 있다. 과적합(overfitting)은 이와 같이 학습 데이터에 과하게 학습하여 실제 데이터에 대한 오류가 증가하는 현상이다. 예를 들어, 노란색 고양이를 보여 고양이를 학습한 뉴럴 네트워크가 노란색 이외의 고양이를 보고는 고양이임을 인식하지 못하는 현상이 과적합의 일종일 수 있다. 과적합은 머신러닝 알고리즘의 오류를 증가시키는 원인으로 작용할 수 있다. 이러한 과적합을 막기 위하여 다양한 최적화 방법이 사용될 수 있다. 과적합을 막기 위해서는 학습 데이터를 증가시키거나, 레귤라리제이션(regularization), 학습의 과정에서 네트워크의 노드 일부를 비활성화하는 드롭아웃(dropout), 배치 정규화 레이어(batch normalization layer) 활용 등의 방법이 적용될 수 있다.

[0070] 본 개시의 일 실시예에 따른 데이터 구조를 저장한 컴퓨터 판독가능 매체가 개시된다. 전술한 데이터 구조는 본 개시내용에서의 저장부에 저장될 수 있으며, 프로세서에 의해 실행될 수 있으며 그리고 통신부에 의해 송수신될 수 있다.

[0071] 데이터 구조는 데이터에 효율적인 접근 및 수정을 가능하게 하는 데이터의 조직, 관리, 저장을 의미할 수 있다. 데이터 구조는 특정 문제(예를 들어, 최단 시간으로 데이터 검색, 데이터 저장, 데이터 수정) 해결을 위한 데이터의 조직을 의미할 수 있다. 데이터 구조는 특정한 데이터 처리 기능을 지원하도록 설계된, 데이터 요소들 간의 물리적이거나 논리적인 관계로 정의될 수도 있다. 데이터 요소들 간의 논리적인 관계는 사용자 정의 데이터 요소들 간의 연결관계를 포함할 수 있다. 데이터 요소들 간의 물리적인 관계는 컴퓨터 판독가능 저장매체(예를 들어, 영구 저장 장치)에 물리적으로 저장되어 있는 데이터 요소들 간의 실제 관계를 포함할 수 있다. 데이터 구조는 구체적으로 데이터의 집합, 데이터 간의 관계, 데이터에 적용할 수 있는 함수 또는 명령어를 포함할 수 있다. 효과적으로 설계된 데이터 구조를 통해 컴퓨팅 장치는 컴퓨팅 장치의 자원을 최소한으로 사용하면서 연산을 수행할 수 있다. 구체적으로 컴퓨팅 장치는 효과적으로 설계된 데이터 구조를 통해 연산, 읽기, 삽입, 삭제, 비교, 교환, 검색의 효율성을 높일 수 있다.

[0072] 데이터 구조는 데이터 구조의 형태에 따라 선형 데이터 구조와 비선형 데이터 구조로 구분될 수 있다. 선형 데이터 구조는 하나의 데이터 뒤에 하나의 데이터만이 연결되는 구조일 수 있다. 선형 데이터 구조는 리스트(List), 스택(Stack), 큐(Queue), 데크(Deque)를 포함할 수 있다. 리스트는 내부적으로 순서가 존재하는 일련의 데이터 집합을 의미할 수 있다. 리스트는 연결 리스트(Linked List)를 포함할 수 있다. 연결 리스트는 각각의 데이터가 포인터를 가지고 한 줄로 연결되어 있는 방식으로 데이터가 연결된 데이터 구조일 수 있다. 연결 리스트에서 포인터는 다음이나 이전 데이터와의 연결 정보를 포함할 수 있다. 연결 리스트는 형태에 따라 단일 연결 리스트, 이중 연결 리스트, 원형 연결 리스트로 표현될 수 있다. 스택은 제한적으로 데이터에 접근할 수 있는 데이터 나열 구조일 수 있다. 스택은 데이터 구조의 한 쪽 끝에서만 데이터를 처리(예를 들어, 삽입 또는 삭제)할 수 있는 선형 데이터 구조일 수 있다. 스택에 저장된 데이터는 늦게 들어갈수록 빨리 나오는 데이터 구조(LIFO-Last in First Out)일 수 있다. 큐는 제한적으로 데이터에 접근할 수 있는 데이터 나열 구조로서, 스택과 달리 늦게 저장된 데이터일수록 늦게 나오는 데이터 구조(FIFO-First in First Out)일 수 있다. 데크는 데이터 구조의 양 쪽 끝에서 데이터를 처리할 수 있는 데이터 구조일 수 있다.

[0073] 비선형 데이터 구조는 하나의 데이터 뒤에 복수개의 데이터가 연결되는 구조일 수 있다. 비선형 데이터 구조는 그래프(Graph) 데이터 구조를 포함할 수 있다. 그래프 데이터 구조는 정점(Vertex)과 간선(Edge)으로 정의될 수 있으며 간선은 서로 다른 두개의 정점을 연결하는 선을 포함할 수 있으며, 그래프 데이터 구조 트리(Tree) 데이터 구조를 포함할 수 있다. 트리 데이터 구조는 트리에 포함된 복수개의 정점 중에서 서로 다른 두개의 정점을 연결시키는 경로가 하나인 데이터 구조일 수 있다. 즉, 그래프 데이터 구조에서 루프(loop)를 형성하지 않는 데이터 구조일 수 있다.

[0074] 데이터 구조는 신경망을 포함할 수 있다. 그리고 신경망을 포함한 데이터 구조는 컴퓨터 판독가능 매체에 저장될 수 있다. 신경망을 포함한 데이터 구조는 또한 신경망에 의한 처리를 위하여 전처리(preprocessing)된 데이터, 신경망에 입력되는 데이터, 신경망의 가중치, 신경망의 하이퍼파라미터(hyperparameter), 신경망으로부터 획득한 데이터, 신경망의 각 노드 또는 레이어와 연관된 활성 함수(activation function), 신경망의 학습을 위한 손실 함수(lost function) 등을 포함할 수 있다. 신경망을 포함한 데이터 구조는 상기 개시된 구성들 중 임의의 구성 요소들을 포함할 수 있다. 즉 신경망을 포함한 데이터 구조는 신경망에 의한 처리를 위하여 전처리된 데이터, 신경망에 입력되는 데이터, 신경망의 가중치, 신경망의 하이퍼파라미터, 신경망으로부터 획득한 데이터, 신경망의 각 노드 또는 레이어와 연관된 활성 함수, 신경망의 학습을 위한 손실 함수 등 전부 또는 이들의 임의의 조합을 포함하여 구성될 수 있다. 전술한 구성들 이외에도, 신경망을 포함한 데이터 구조는 신경망의 특성을 결정하는 임의의 다른 정보를 포함할 수 있다. 또한, 데이터 구조는 신경망의 연산 과정에 사용되거나 발생되는 모든 형태의 데이터를 포함할 수 있으며 전술한 사항에 제한되는 것은 아니다. 컴퓨터 판독가능 매체는 컴퓨터 판독가능 기록 매체 및/또는 컴퓨터 판독가능 전송 매체를 포함할 수 있다. 신경망은 일반적으로 노드라 지칭될 수 있는 상호 연결된 계산 단위들의 집합으로 구성될 수 있다. 이러한 노드들은 뉴런들로 지칭될 수도 있다. 신경망은 적어도 하나 이상의 노드들을 포함하여 구성된다.

[0075] 데이터 구조는 신경망에 입력되는 데이터를 포함할 수 있다. 신경망에 입력되는 데이터를 포함하는 데이터 구조는 컴퓨터 판독가능 매체에 저장될 수 있다. 신경망에 입력되는 데이터는 신경망 학습 과정에서 입력되는 학습 데이터 및/또는 학습이 완료된 신경망에 입력되는 입력 데이터를 포함할 수 있다. 신경망에 입력되는 데이터는 전처리를 거친 데이터 및/또는 전처리 대상이 되는 데이터를 포함할 수 있다. 전처리는 데이터를 신경망에 입력시키기 위한 데이터 처리 과정을 포함할 수 있다. 따라서 데이터 구조는 전처리 대상이 되는 데이터 및 전처리로 발생되는 데이터를 포함할 수 있다. 전술한 데이터 구조는 예시일 뿐 본 개시는 이에 국한되지 않는다.

[0076] 데이터 구조는 신경망의 가중치를 포함할 수 있다(본 명세서에서 가중치, 파라미터는 동일한 의미로 사용될 수 있다). 그리고 신경망의 가중치를 포함한 데이터 구조는 컴퓨터 판독가능 매체에 저장될 수 있다. 신경망은 복수개의 가중치를 포함할 수 있다. 가중치는 가변적일 수 있으며, 신경망이 원하는 기능을 수행하기 위해, 사용자 또는 알고리즘에 의해 가변 될 수 있다. 예를 들어, 하나의 출력 노드에 하나 이상의 입력 노드가 각각의 링크에 의해 상호 연결된 경우, 출력 노드는 상기 출력 노드와 연결된 입력 노드들에 입력된 값들 및 각각의 입력 노드들에 대응하는 링크에 설정된 가중치에 기초하여 출력 노드에서 출력되는 데이터 값을 결정할 수 있다. 전술한 데이터 구조는 예시일 뿐 본 개시는 이에 국한되지 않는다.

[0077] 제한이 아닌 예로서, 가중치는 신경망 학습 과정에서 가변되는 가중치 및/또는 신경망 학습이 완료된 가중치를 포함할 수 있다. 신경망 학습 과정에서 가변되는 가중치는 학습 사이클이 시작되는 시점의 가중치 및/또는 학습 사이클 동안 가변되는 가중치를 포함할 수 있다. 신경망 학습이 완료된 가중치는 학습 사이클이 완료된 가중치를 포함할 수 있다. 따라서 신경망의 가중치를 포함한 데이터 구조는 신경망 학습 과정에서 가변되는 가중치 및/또는 신경망 학습이 완료된 가중치를 포함한 데이터 구조를 포함할 수 있다. 그러므로 상술한 가중치 및/또는 각 가중치의 조합은 신경망의 가중치를 포함한 데이터 구조에 포함되는 것으로 한다. 전술한 데이터 구조는 예시일 뿐 본 개시는 이에 국한되지 않는다.

[0078] 신경망의 가중치를 포함한 데이터 구조는 직렬화(serialization) 과정을 거친 후 컴퓨터 판독가능 저장 매체(예를 들어, 메모리, 하드 디스크)에 저장될 수 있다. 직렬화는 데이터 구조를 동일하거나 다른 컴퓨팅 장치에 저장하고 나중에 다시 재구성하여 사용할 수 있는 형태로 변환하는 과정일 수 있다. 컴퓨팅 장치는 데이터 구조를 직렬화하여 네트워크를 통해 데이터를 송수신할 수 있다. 직렬화된 신경망의 가중치를 포함한 데이터 구조는 역직렬화(deserialization)를 통해 동일한 컴퓨팅 장치 또는 다른 컴퓨팅 장치에서 재구성될 수 있다. 신경망의 가중치를 포함한 데이터 구조는 직렬화에 한정되는 것은 아니다. 나아가 신경망의 가중치를 포함한 데이터 구조는 컴퓨팅 장치의 자원을 최소한으로 사용하면서 연산의 효율을 높이기 위한 데이터 구조(예를 들어, 비선형 데이터 구조에서 B-Tree, R-Tree, Trie, m-way search tree, AVL tree, Red-Black Tree)를 포함할 수 있다. 전술

한 사항은 예시일 뿐 본 개시는 이에 국한되지 않는다.

[0079] 데이터 구조는 신경망의 하이퍼파라미터를 포함할 수 있다. 그리고 신경망의 하이퍼파라미터를 포함한 데이터 구조는 컴퓨터 판독가능 매체에 저장될 수 있다. 하이퍼파라미터는 사용자에 의해 가변되는 변수일 수 있다. 하이퍼파라미터는 예를 들어, 학습률(learning rate), 비용 함수(cost function), 학습 사이클 반복 횟수, 가중치 초기화(weight initialization)(예를 들어, 가중치 초기화 대상이 되는 가중치 값의 범위 설정), Hidden Unit의 개수(예를 들어, 히든 레이어의 개수, 히든 레이어의 노드 수)를 포함할 수 있다. 전술한 데이터 구조는 예시일 뿐 본 개시는 이에 국한되지 않는다.

[0080] 본 개시의 일 실시예에 따른 인공지능 기반의 모델(예를 들어, 요약 정보 생성 모델, 정보 분류 모델 등)에 대한 네트워크 함수로서 트랜스포머(transformer)가 고려될 수도 있다. 일례로, 인공지능 기반의 모델은 트랜스포머 기반으로 동작될 수 있다. 이러한 인공지능 기반의 모델은 예를 들어, 어텐션(attention) 알고리즘이 적용된 순환 신경망 또는 어텐션 알고리즘이 적용된 트랜스포머를 사용하여 동작될 수 있다.

[0081] 일 실시예에서, 트랜스포머는 임베딩된 데이터들을 인코딩하는 인코더 및 인코딩된 데이터들을 디코딩하는 디코더로 구성될 수 있다. 트랜스포머는 일련의 데이터(series of data)들을 수신하여, 인코딩 및 디코딩 단계를 거쳐 상이한 타입의 일련의 데이터들을 출력하는 구조를 지닐 수 있다. 일 실시예에서, 일련의 데이터들은 트랜스포머가 연산가능한 형태로 가공될 수 있다. 일련의 데이터들을 트랜스포머가 연산가능한 형태로 가공하는 과정은 임베딩 과정을 포함할 수 있다. 데이터 토큰, 임베딩 벡터, 임베딩 토큰 등과 같은 표현들은, 트랜스포머가 처리할 수 있는 형태로 임베딩된 데이터들을 지칭하는 것일 수 있다.

[0082] 트랜스포머가 일련의 데이터들을 인코딩 및 디코딩하기 위하여, 트랜스포머 내의 인코더 및 디코더들을 어텐션 알고리즘을 활용하여 처리할 수 있다. 어텐션 알고리즘이란 주어진 쿼리(Query)에 대하여, 하나 이상의 키(Key)에 대한 유사도를 구하고, 이렇게 주어진 유사도를, 각각의 키(Key)와 대응하는 값(Value)에 반영한 후, 유사도가 반영된 값(Value)들을 가중합하여 어텐션 값을 계산하는 알고리즘을 의미할 수 있다.

[0083] 쿼리(Query), 키(Key) 및 값(Value)를 어떻게 설정하는가에 따라, 다양한 종류의 어텐션 알고리즘이 분류될 수 있다. 예를 들어, 쿼리, 키 및 값을 모두 동일하게 설정하여 어텐션을 구하는 경우, 이는 셀프-어텐션(self-attention) 알고리즘을 의미할 수 있다. 입력된 일련의 데이터들을 병렬로 처리하기 위해, 임베딩 벡터를 차원을 축소하여, 각 분할된 임베딩 벡터에 대해 개별적인 어텐션 헤드를 구하여 어텐션을 구하는 경우, 이는 멀티-헤드(multi-head) 어텐션 알고리즘을 의미할 수 있다.

[0084] 일 실시예에서, 트랜스포머는 복수의 멀티-헤드 셀프-어텐션 알고리즘 또는 멀티-헤드 인코더-디코더 알고리즘을 수행하는 모듈들로 구성될 수 있다. 일 실시예에서, 트랜스포머는 임베딩 레이어, 정규화 레이어, 소프트맥스(softmax) 층 등 어텐션 알고리즘이 아닌 부가적인 구성요소들 또한 포함할 수 있다. 어텐션 알고리즘을 이용하여 트랜스포머를 구성하는 방법은 Vaswani et al., Attention Is All You Need, 2017 NIPS에 개시된 방법을 포함할 수 있으며, 이는 여기에 참조로서 통합된다.

[0085] 트랜스포머는 임베딩된 자연어, 임베딩된 시퀀스 정보, 분할된 이미지 데이터, 오디오 파형 등 다양한 데이터 도메인에 적용하여, 일련의 입력 데이터를 일련의 출력 데이터로 변환할 수 있다. 다양한 데이터 도메인을 가진 데이터들을 트랜스포머에 입력가능한 일련의 데이터들로 변환하기 위해, 트랜스포머는 데이터들을 임베딩할 수 있다. 트랜스포머는 일련의 입력 데이터 사이의 상대적 위치관계 또는 위상관계를 표현하는 추가적인 데이터를 처리할 수 있다. 또는 일련의 입력 데이터에 입력 데이터들 사이의 상대적인 위치관계 또는 위상관계를 표현하는 벡터들이 추가적으로 반영되어 일련의 입력 데이터가 임베딩될 수 있다. 일 예에서, 일련의 입력 데이터 사이의 상대적 위치관계는, 자연어 문장 내에서의 어순, 각각의 분할된 이미지의 상대적 위치 관계, 분할된 오디오 파형의 시간 순서 등을 포함할 수 있으나, 이에 제한되지 않는다. 일련의 입력 데이터들 사이의 상대적인 위치관계 또는 위상관계를 표현하는 정보를 추가하는 과정은 위치 인코딩(positional encoding)으로 지칭될 수 있다.

[0086] 데이터를 임베딩하여 트랜스포머로 변환하는 방법의 일 예는 Dosovitskiy, et al., AN IMAGE IS WORTH 16X16 WORDS: TRANSFORMERS FOR IMAGE RECOGNITION AT SCALE에 개시되어 있으며, 해당 문서는 여기에 참조로서 통합된다.

[0087] 본 개시의 일 실시예에 따른 모델들은 가우시안 분포 노이즈(Gaussian distributed noise)에 대하여 예측된 노이즈의 부분 또는 전부를 제거하여, 상기 예측된 노이즈의 부분 또는 전부가 제거된 데이터를 획득하도록 학습될 수 있다.

[0088] 본 개시의 일 실시예에 따른 컴퓨팅 장치(100)는 등방성 가우시안 분포 노이즈(isotropic gaussian distributed noise)에 대하여 상기 노이즈의 부분 또는 전부를 제거하여, 상기 노이즈의 부분 또는 전부가 제거된 데이터를 획득하도록 뉴럴 네트워크를 학습시킬 수 있다. 이때, 상기 뉴럴 네트워크는 조건부(conditional) 노이즈 예측 모델을 포함할 수 있다. 또한, 조건부 노이즈 예측 모델은 입력과 출력이 동일한 크기를 가지는 U-Net 구조를 포함할 수 있고, 노이즈가 포함된 데이터 x(t)와 확산(diffusion) 타임 스텝(time step) t를 입력으로 하고, 노이즈가 포함된 데이터 x(t)에 포함된 확산 노이즈(diffusion noise)를 예측하여 출력할 수 있다.

[0089] 컴퓨팅 장치(100)는 노이즈가 포함되지 않은 원본 데이터 x(0)에 대하여 T번의 타입 스텝(time step)에 걸쳐 조금씩 랜덤 가우시안 노이즈를 추가하는 과정을 반복하고, 결과적으로 등방성 가우시안 분포 노이즈 x(T)(isotropic gaussian distributed noise)를 획득하는 정방향 과정을 수행할 수 있다. 상기 원본 데이터 x(0)의 종류는 이미지 데이터 이외에도 오디오 데이터 등 다양한 예시들이 포함될 수 있다. 한편, 본 개시의 일 실시예에 따른 정방향 과정은 다음과 같은 수식을 통해 수행될 수 있다.

수학식 1

[0090] $$x_t = \sqrt{1-\beta_t}x_{t-1} + \sqrt{\beta_t}\varepsilon$$

[0091] $$\varepsilon \sim N(0, I)$$

[0092] 상기 수학식 1에서 β_t는 하이퍼 파라미터로써 확산 계수를 계산하는 과정에서 이용될 수 있고, β_t는 임의의 값으로 설정될 수 있으며 0<β_1<β_2< ... <β_T<1의 값으로 설정될 수 있다. 예를 들어 β_1이 0.0001의 값을 가지고 β_T가 0.02의 값을 가질 수 있고, β_1부터 β_T까지 β_t의 값은 선형적으로(linear) 증가할 수 있고, 코사인 함수를 따라 증가할 수 있으며, 총 확산 스텝 수를 의미하는 T는 1000으로 설정될 수 있다. 다만, β_t가 선형적으로 또는 코사인 함수를 따라 증가되는 것은 예시에 불과할 뿐, 본 개시의 실시예들에 따르면 상기 원본 데이터의 종류에 따라 β_t의 증가량이 다르게 결정될 수 있으며, 구체적인 설명은 이하 [수학식 2]를 통해 후술된다. 또한, ε은 랜덤 가우시안 분포 노이즈를 의미할 수 있다. 타임 스텝 t에서 상기 노이즈가 포함된 데이터 x(t)을 노이즈가 포함되지 않은 원본 데이터 x(0) 와 포함된 확산 노이즈(diffusion noise)에 관한 식으로 나타낸 일반식은 다음과 같이 표현될 수 있다.

수학식 2

[0093] $$\alpha_t = 1 - \beta_t \quad \ldots(1)$$

[0094] $$\bar{\alpha}_t = \prod_{i=1}^{t} \alpha_i \quad \ldots(2)$$

[0095] $$x_t = \sqrt{\bar{\alpha}_t}x_0 + \sqrt{1-\bar{\alpha}_t}\varepsilon \quad \ldots(3)$$

[0096] $$n_t = \sqrt{1-\bar{\alpha}_t}, s_t = \sqrt{\bar{\alpha}_t} \quad \ldots(4)$$

[0097] 본 개시의 일 실시예에 따라 상기 수학식 2에서 (1)번 식과 (2)번 식은 확산 계수 $\bar{\alpha}_t$의 구체적인 의미를 표현하는 식이다. 상기 수학식 2의 (1)번 식에서 특정 타임 스텝 t에서 확산 계수α_t는 1에서 상기 하이퍼 파라미터 β_t를 뺀 값으로 계산될 수 있으며, 상기 수학식 2의 (2)번 식에서 확산 계수 $\bar{\alpha}_t$는 타임 스텝 1부터 t까지 순차적으로 누적된 확산 계수를 의미할 수 있다. 따라서, 상기 수학식 2에서 (3)번 식은 타임 스텝 t에서 상기 노이즈가 포함된 데이터 x(t)를 노이즈가 포함되지 않은 원본 데이터 x(0) 와 확산 계수($\bar{\alpha}_t$)와 랜덤 가우시안 분포 노이즈(ε)에 관한 수식으로 나타낸 것이다. 또한, 상기 수학식 2에서 (4)번 식은 본 개시의 일 실시예에 따라 상기 원본 데이터의 종류에 기초하여 결정되는 노이즈의 비율n(t) 및 시그널의 비율s(t)을 의미할 수 있다. 따

라서, 타임 스텝 t에서 노이즈가 포함된 데이터 x(t)는 노이즈의 비율n(t) 및 시그널의 비율s(t)에 기초하여 표현될 수 있다. 구체적으로, 타임 스텝 t에서 노이즈가 포함된 데이터 x(t)는 노이즈가 포함되지 않은 원본 데이터 x(0)의 비율(즉, 시그널의 비율s(t))이 높아질수록 원본 데이터의 형태에 가까워지고, 랜덤 가우시안 분포 노이즈(ε)의 비율(즉, 노이즈의 비율n(t))이 높아질수록 랜덤 가우시안 분포 노이즈의 형태에 가까워질 수 있다.

[0098] 예를 들어, 컴퓨팅 장치(100)는 노이즈가 포함되지 않은 원본 데이터 x(0)에 대하여 T번의 타입 스텝(time step)에 걸쳐 조금씩 랜덤 가우시안 노이즈를 추가하는 정방향 과정에서 상기 결정된 노이즈의 비율에 기초하여 상기 원본 데이터에 제 1 노이즈를 추가하여 제 1 데이터를 획득하고, 상기 결정된 노이즈의 비율에 기초하여 상기 제 1 데이터에 제 2 노이즈를 추가하여 제 2 데이터를 획득할 수 있다. 일 실시예에서, 상기 원본 데이터 x(0)의 종류는 이미지 데이터 이외에도 텍스트 데이터 및 오디오 데이터 등 다양한 예시들이 포함될 수 있다.

[0099] 이를 통해, 컴퓨팅 장치(100)는 노이즈가 포함되지 않은 원본 데이터 x(0)에 대하여 "상기 수학식 2에서 (4)번 식을 통해 결정되는 노이즈의 비율"에 기초하여 T번의 타입 스텝(time step)에 걸쳐 랜덤 가우시안 노이즈를 추가하는 과정을 반복하고, 결과적으로 등방성 가우시안 분포 노이즈x(T)(isotropic gaussian distributed noise)를 획득하는 정방향 과정을 수행할 수 있다. 다만, 상기 정방향 과정은 상기 수학식 2의 예시에 한정되지 않고, 데이터에 노이즈를 추가하는 다양한 과정들이 정방향 과정에 포함될 수 있다.

[0100] 또한, 컴퓨팅 장치(100)는 상기 정방향 과정과 반대 방향으로 등방성 가우시안 분포 노이즈x(T)(isotropic gaussian distributed noise)에 대하여 T번의 타입 스텝(time step)에 걸쳐 조금씩 랜덤 가우시안 노이즈를 제거하는 과정을 반복하고, 결과적으로 노이즈가 포함되지 않은 원본 데이터 x(0)를 획득하는 역방향 과정을 수행하도록 상기 뉴럴 네트워크를 학습시킬 수 있다. 이와 관련하여, 상기 역방향 수행 과정을 나타낸 수식은 다음과 같이 표현될 수 있다.

수학식 3

[0101] $$x_{t-1} = \frac{1}{\sqrt{\alpha_t}}\left(x_t - \frac{1-\alpha_t}{\sqrt{1-\bar{\alpha}_t}}\varepsilon_\theta(x_t,t)\right) + \sigma_t\varepsilon \quad \cdots(1)$$

[0102] $$\alpha_t = \frac{\bar{\alpha}_t}{\bar{\alpha}_{t-1}} \quad \cdots(2)$$

[0103] $$\sigma_t = 1 - \frac{\bar{\alpha}_t}{\bar{\alpha}_{t-1}} \quad \cdots(3)$$

[0104] 상기 수학식 3에서 (1)번 식은 "노이즈가 포함된 데이터 x(t)"에 대하여 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과($\varepsilon_\theta(x_t,t)$)를 제거하여 "상기 노이즈가 일부 제거된 전 단계의 데이터 x(t-1)"를 획득하는 역방향 과정을 나타내는 수식이다. 예를 들어, 컴퓨팅 장치(100)는 "제 2 노이즈가 포함된 제 2 데이터 x(2)"에 대하여 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과를 제거하여 "상기 제 2 노이즈가 제거된 전 단계의 제 1 데이터 x(1)"를 획득할 수 있다. 상기 수학식 3에서 (2)번 식은 현재 타임 스텝 t에서의 확산 계수α_t를 의미하고, 상기 수학식 3에서 (3)번 식에서 σ_t는 분산 파라미터를 의미하고, 확산 계수α_t에 기초하여 계산될 수 있다. 다만, 상기 역방향 과정은 상기 [수학식 3]에 한정되지 않고, 노이즈가 포함된 데이터에 대해 노이즈를 제거하는 다양한 과정들이 역방향 과정에 포함될 수 있다.

[0105] 구체적으로, 컴퓨팅 장치(100)는 뉴럴 네트워크에 노이즈가 포함된 데이터 x(t)와 타임 스텝 t를 입력하고, 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과와 실제로 포함된 확산 노이즈(diffusion noise)를 비교하여 손실 함수를 계산하고, 상기 손실 함수에 따라 경사 하강(gradient down)을 수행하여 상기 뉴럴 네트워크를 학습시킬 수 있다. 예를 들어, 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과와 실제로 포함된 확산 노이즈(diffusion noise)를 비교하여 계산되는 손실 함수는 다음과 같은 수식으로 표현될 수 있다.

수학식 4

[0106] $$\text{노이즈 예측 손실} = E_{t,x_0,\varepsilon}[\|\varepsilon - \varepsilon_\theta(x_t,t)\|^2]$$

[0107] $$x_t = \sqrt{\bar{\alpha}_t}x_0 + \sqrt{1-\bar{\alpha}_t}\varepsilon$$

[0108] 상기 [수학식 4]에서 손실 함수는 실제로 포함된 확산 노이즈(diffusion noise) (ε)과 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과($\varepsilon_\theta(x_t,t)$)를 비교하여 계산될 수 있다. 예를 들어, 컴퓨팅 장치(100)는 "상기 제 1 데이터 x(1)에 포함된 제 1 노이즈"를 예측하고, 상기 예측된 제 1 노이즈 및 상기 원본 데이터 x(0)에 추가된 상기 제 1 노이즈를 비교하여 제 1 손실 함수를 계산할 수 있다. 컴퓨팅 장치(100)는 "상기 제 2 데이터 x(2)에 포함된 제 2 노이즈"를 예측하고, 상기 예측된 제 2 노이즈 및 상기 제 1 데이터 x(1)에 추가된 상기 제 2 노이즈를 비교하여 제 2 손실 함수를 계산할 수 있다. 다만, 상기 손실 함수는 수학식4의 예시에 한정되지 않고, 노이즈 예측 결과와 실제로 포함된 확산 노이즈를 비교하여 계산된 다양한 손실 함수들이 포함될 수 있다.

[0109] 추가적으로, 상기 뉴럴 네트워크는 상기 제 2 노이즈가 포함된 데이터 x(2)에 포함된 확산 노이즈를 예측하고, 상기 예측된 제 2 노이즈를 제거함으로써 "제 2 노이즈가 제거된 데이터 x(1)"를 획득하도록 학습될 수 있다. 예를 들어, 또한, 컴퓨팅 장치(100)는 상기 제 1 손실 함수 또는 상기 제 2 손실 함수 중 적어도 하나에 기초하여 상기 뉴럴 네트워크를 학습시킬 수 있다. 또한, 상기 뉴럴 네트워크는 "상기 노이즈가 포함된 데이터 x(t)"에 포함된 확산 노이즈를 예측하고, 상기 예측된 확산 노이즈를 제거하는 과정을 한번 이상 반복하여, "상기 노이즈가 포함된 데이터 x(t)"에 포함된 확산 노이즈를 전부 제거함으로써, 노이즈가 전부 제거된 원본 데이터 x(0) 가 획득되도록 학습될 수 있다. 한편, 상기 뉴럴 네트워크를 활용하여 노이즈가 포함된 데이터에 대하여 확산 노이즈를 제거하도록 학습하는 과정에서 원본 데이터의 종류에 기초하여 노이즈의 비율이 결정됨으로써, 더 좋은 품질의 데이터를 생성하도록 상기 뉴럴 네트워크가 학습될 수 있다.

[0110] 컴퓨팅 장치(100)는 상기 결정된 원본 데이터의 종류에 대해 표현 가능한 데이터의 크기에 기초하여 노이즈의 비율을 결정할 수 있다. 구체적으로, 컴퓨팅 장치(100)는 상기 결정된 원본 데이터의 종류에 대해 표현 가능한 데이터의 최소 크기보다 상기 원본 데이터에 추가되는 노이즈의 크기가 작도록 상기 노이즈의 비율을 결정할 수 있다. 예를 들어, 상기 원본 데이터의 종류가 이미지(image) 데이터로 결정된 경우, 상기 원본 데이터는 채널 당 8비트(bit) 깊이(depth)를 가질 수 있다. 따라서, 컴퓨팅 장치(100)는 이미지 데이터에 대해 표현 가능한 데이터의 최소 크기인 1/(2^8)(=약 0.00039)보다 상기 원본 데이터에 추가되는 노이즈의 크기가 작도록 상기 노이즈의 제 1 비율을 결정할 수 있다.

[0111] 한편, 본 개시의 다른 실시예에 따르면 상기 원본 데이터의 종류가 오디오(audio) 데이터로 결정된 경우, 상기 원본 데이터는 하나의 샘플 당 16비트(bit) 깊이(depth)를 가질 수 있다. 따라서, 컴퓨팅 장치(100)는 오디오 데이터에 대해 표현 가능한 데이터의 최소 크기인 1/(2^16)(=약 0.000015)보다 상기 원본 데이터에 추가되는 노이즈의 크기가 작도록 상기 노이즈의 제 2 비율을 결정할 수 있다. 따라서, 상기 원본 데이터가 이미지 데이터인 경우의 노이즈의 제 1 비율보다 상기 원본 데이터가 오디오 데이터인 경우의 노이즈의 제 2 비율이 더 작게 결정될 수 있다. 예를 들어, 상기 노이즈의 비율은 다음과 같은 수학식을 통해 결정될 수 있다.

수학식 5

[0112] $$n_t = 2^{t^r} - 1 \ldots (1)$$

[0113] $$s_t = -(2^{t^r} - 1) + 1 \ldots (2)$$

[0114] 구체적으로, 본 개시의 일 실시예에 따라 상기 [수학식 5]에서 (1)번 식을 참조하면 노이즈의 비율n(t)는 지수적으로 증가하도록 결정될 수 있고, 상기 [수학식 5]에서 (2)번 식을 참조하면 시그널의 비율 s(t)는 지수적으로 감소하도록 결정될 수 있다. 이때, r은 상기 노이즈 비율n(t) 및 상기 시그널 비율s(t)의 곡선의 형태(shape)을 결정하는 하이퍼 파라미터를 의미할 수 있다. 다만, 상기 [수학식 5]는 예시에 불과할 뿐 이외에도 노이즈의 비율 및 시그널의 비율은 다양하게 결정될 수 있다. 이를 통해, 이미지 데이터와 비교하여 상대적으로

노이즈에 민감한 데이터 도메인(예시적으로, 오디오 데이터 등)에서도 상기 신경망 모델을 통해 생성된 결과물이 노이즈의 영향이 거의 없도록 상기 신경망 모델이 학습될 수 있다.

[0115] 도 3 내지 도 9를 참조하여 후술되는 인공지능 기반의 모델에 대한 자세한 설명은 앞서 도 2를 참조하여 상술한 내용으로 대체될 수 있다.

[0117] 도 3은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 추정하기 위한 방법을 나타낸 도면이다.

[0118] 일 실시예에서, 도 3에서 도시되는 단계들은 컴퓨팅 장치(100)에 의해 수행될 수 있다. 추가적인 실시예에서, 도 3에서 도시되는 단계들 중 일부는 사용자 단말에서 수행되고 다른 일부는 서버에서 수행되는 방식과 같이 도 3에서의 단계들은 복수의 엔티티(entity)들에 의해 구현될 수도 있다.

[0119] 일 실시예에서, 컴퓨팅 장치(100)의 프로세서(110)는 운전자에 부착된 센서를 통해 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득할 수 있다(310).

[0120] 예를 들어, 프로세서(110)는 차량(200)으로부터 차량의 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 수신할 수 있다. 다른 예를 들어, 컴퓨팅 장치(100)가 차량(200)에 포함되는 경우, 프로세서(110)는 운전자에 부착된 센서를 통해 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 직접적으로 획득할 수 있다. 또 다른 예를 들어, 프로세서(110)는 메모리(130)에 사전 저장되어 있는 시험 데이터를 판독함으로써, 시험 데이터를 획득할 수 있다.

[0121] 시험 데이터는 예를 들어, 운전자의 뇌전도(Electroencephalogram, EEG) 신호(데이터)를 포함할 수 있다.

[0122] 프로세서(110)는 사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 시험 데이터로부터 운전자의 제1 상태 추정 정보를 획득할 수 있다(320).

[0123] 제1 분류 모델은 학습용 뇌 신호 데이터, 학습용 뇌 신호 데이터에 대응되는 운전자를 식별하기 위한 운전자 레이블 데이터 및 학습용 뇌 신호 데이터에 대응되는 운전자의 상태를 나타내는 운전자 상태 데이터를 포함하는 학습 데이터셋을 이용하여, 입력되는 뇌 신호 데이터로부터 운전자의 상태를 출력하도록 사전 학습될 수 있다.

[0124] 운전자 레이블 데이터는 운전자를 식별할 수 있는 데이터(예를 들어, ID, 고유번호 등)를 포함할 수 있다.

[0125] 운전자 상태 데이터는 특정 상황, 시간 등에 운전자의 주관적인 평가 또는 소정의 이벤트에 따라 정량적으로 산정된 운전자의 상태에 관한 데이터를 포함할 수 있다. 예를 들어, 운전자 상태 데이터는 멀미를 평가하는 척도인 MISC(11-point MIsery SCale), 졸음을 평가하는 척도인 KSS(Karolinska Sleepiness Scale) 등을 이용하여 산출된 상태에 관한 데이터를 포함할 수 있다.

[0126] 제1 분류 모델은 인코더, 디코더, 상태 분류 모듈 등을 포함할 수 있다.

[0127] 인코더는 차원을 축소시키는 복수의 히든 레이어를 포함할 수 있다. 인코더는 차원을 축소시키는 복수의 히든 레이어를 이용하여 입력되는 시험 데이터를 잠재 공간 표현으로 압축함으로써, 차원이 감소된 데이터의 새로운 표현인 특징을 추출할 수 있다.

[0128] 디코더는 차원을 확장시키는 복수의 히든 레이어를 포함할 수 있다. 디코더는 차원을 확장시키는 복수의 히든 레이어를 이용하여 입력되는 특징을 확장시킴으로써, 추출된 특징에 대해 신호의 시간 축 정보를 복원시킬 수 있다.

[0129] 상태 분류 모듈은 복원된 시험 데이터에서 채널을 줄여주어 각 시점에 맞는 운전자 상태에 대한 예측 값인 운전자의 제1 상태 추정 정보를 출력할 수 있다. 상태 분류 모듈은 입력되는 데이터로부터 상태 추정 정보를 추출하도록 사전 학습된 인공지능 기반의 모델에 대응될 수 있다.

[0130] 프로세서(110)는 사전 결정된 불확실성 추정 알고리즘을 이용하여 제1 상태 추정 정보에 대한 불확실성 값을 획득할 수 있다(330).

[0131] 사전 결정된 불확실성 추정 알고리즘은 엔트로피(entropy) 추정 알고리즘 및 상호 정보(mutual information) 추정 알고리즘을 포함할 수 있다. 다만, 사전 결정된 불확실성 추정 알고리즘의 종류는 이에 한정되지 않는다.

[0132] 엔트로피 추정 알고리즘은 확률 분포의 불확실성을 측정하는 알고리즘을 의미할 수 있다. 프로세서(110)는 엔트

로피 추정 알고리즘을 이용하여 시험 데이터 및/또는 제1 상태 추정 정보로부터 획득되는 값을 제1 상태 추정 정보에 대한 불확실성 값으로 결정할 수 있다.

[0133] 상호 정보 추정 알고리즘은 두 변수 간의 상호 의존성을 계산하는 알고리즘을 의미할 수 있다. 프로세서(110)는 상호 정보 추정 알고리즘을 이용하여 시험 데이터 및/또는 제1 상태 추정 정보로부터 획득되는 값을 제1 상태 추정 정보에 대한 불확실성 값으로 결정할 수 있다.

[0134] 프로세서(110)는 불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 시험 데이터에 증강을 수행할 수 있다(340).

[0135] 사전 결정된 임계치(사전 정의 값)는 사용자에 의해 사전에 결정되거나 또는 통계적인 실험 결과에 따라 사전에 결정될 수 있다.

[0136] 사전 결정된 데이터 증강 알고리즘은 가우시안 노이즈(Gaussian noise)를 이용한 데이터 증강 알고리즘 및 시간 왜곡(time warping)을 이용한 데이터 증강 알고리즘을 포함할 수 있다.

[0137] 가우시안 노이즈를 이용한 데이터 증강 알고리즘은 데이터에 가우시안 노이즈를 추가하여 가우시안 노이즈가 적용된 데이터를 생성하는 알고리즘일 수 있다.

[0138] 시각 왜곡을 이용한 데이터 증강 알고리즘은 데이터의 일부를 늘리거나 줄임으로써, 왜곡된 데이터를 생성하는 알고리즘일 수 있다.

[0139] 일 실시예에서, 프로세서(110)는 불확실성 값이 사전 결정된 임계치보다 작은 경우, 시험 데이터에 증강을 적용하지 않을 수 있다. 이 경우, 프로세서(110)는 인공지능 기반의 제2 분류 모델을 이용하여 시험 데이터로부터 운전자의 상태를 예측한 결과인 운전자의 제2 상태 추정 정보를 획득할 수 있다.

[0140] 프로세서(110)는 인공지능 기반의 제2 분류 모델을 이용하여 증강된 시험 데이터로부터 운전자의 상태를 예측한 결과인 운전자의 제2 상태 추정 정보를 획득할 수 있다(350).

[0141] 제2 분류 모델은 제1 분류 모델과 대응되는 구조 및 가중치로 초기 설정되어 있을 수 있다. 예를 들어, 제2 분류 모델은 인코더, 디코더, 상태 분류 모듈 등을 포함할 수 있다.

[0142] 프로세서(110)는 인공지능 기반의 제3 분류 모델을 이용하여 시험 데이터로부터 운전자의 제3 상태 추정 정보를 획득할 수 있다.

[0143] 프로세서(110)는 사전 결정된 일관성 손실 알고리즘을 이용하여 제2 상태 추정 정보와 제3 상태 추정 정보로부터 일관성 손실의 값을 산출할 수 있다.

[0144] 프로세서(110)는 산출된 일관성 손실의 값에 기초하여 제3 분류 모델의 가중치를 갱신할 수 있다.

[0145] 제3 분류 모델은 제1 분류 모델과 대응되는 구조 및 가중치로 초기 설정되어 있을 수 있다. 예를 들어, 제3 분류 모델은 인코더, 디코더, 상태 분류 모듈 등을 포함할 수 있다.

[0146] 사전 결정된 일관성 손실 알고리즘은 제2 상태 추정 정보 및 제3 상태 추정 정보에 소프트맥스 함수를 적용한 소프트맥스 분포에 대해서, 교차 엔트로피 손실 함수(Cross-Entropy Loss Function) 또는 쿨백 라이블러 발산(Kullback-Leibler divergence)을 적용하는 알고리즘일 수 있다.

[0147] 교차 엔트로피 손실 함수를 적용하는 알고리즘은 두 확률 분포 간의 차이를 측정하는 알고리즘일 수 있다. 쿨백 라이블러 발산를 적용하는 알고리즘은 한 확률 분포가 다른 분포로부터 얼마나 다른지를 나타내는 알고리즘일 수 있다. 교차 엔트로피 손실 함수를 적용하는 알고리즘 및/또는 쿨백 라이블러 발산을 적용하는 알고리즘은 분류 모델의 예측과 실제 분포 간의 차이를 최소화하고, 분류 모델이 올바른 클래스를 예측하도록 유도할 수 있다.

[0148] 프로세서(110)는 제3 분류 모델의 가중치를 갱신하는 단계 이후, 갱신된 제3 분류 모델의 매개변수와 제2 분류 모델의 매개변수 간에 지수 이동 평균을 적용하여 제2 분류 모델의 매개변수를 갱신할 수 있다.

[0149] 프로세서(110)는 제2 분류 모델의 매개변수를 갱신하는 단계 이후, 무작위로 생성된 마스크 벡터를 이용하여 제3 분류 모델의 일부 가중치를 상기 제1 분류 모델의 가중치로 복원할 수 있다. 마스크 벡터는 특정 연산에서 어떤 값을 무시하거나 강조하기 위해 사용되는 이진 벡터를 의미할 수 있다.

[0151] 이하에서 도 4 내지 도 9를 참조하여 앞서 상술된 컴퓨팅 장치(100)에 의해 수행되는 운전자의 상태를 추정하기 위한 방법에 대한 일 실시예를 추가적으로 후술한다.

[0152] 도 4 내지 도 9를 참조하여 후술되는 내용 중에서 중복되는 내용을 생략될 수 있다. 또한, 도 4 내지 도 9를 참조하여 후술되는 내용 중에서 각 구성 및 방법에 대한 구체적인 설명은 도 1 내지 도 3을 참조하여 상술한 내용으로 대체될 수 있다.

[0153] 도 4는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 인공지능 기반의 모델의 학습 과정을 간략하게 나타낸 도면이다.

[0154] 분류 모델(예를 들어, 제1 분류 모델, 제2 분류 모델, 제3 분류 모델 등)은 인코더, 시점 수준 분류 모듈(timepoint-level estimation of driver's drowsiness state), 운전자 분류 모듈 등을 포함할 수 있다.

[0155] 각 시점의 운전자 상태를 출력하는 시점 수준 분류 모듈은 디코더 및 상태 분류 모듈을 포함할 수 있다.

[0156] 시점 수준 분류 모듈 및 운전자 분류 모듈은 뇌전도 신호의 특징을 추출하는 인코더를 공동으로 사용할 수 있다.

[0157] 도 4를 참조하면, 프로세서(110)는 분류 모델(예를 들어, 제1 분류 모델, 제2 분류 모델, 제3 분류 모델 등)을 사전 학습시킬 수 있다.

[0158] 예를 들어, 프로세서(110)는 학습 데이터를 입력할 수 있다(410). 학습 데이터는 실제 운전자 레이블 데이터, 뇌전도 신호 데이터, 실제 운전자 상태 데이터 등을 포함할 수 있다. 프로세서(110)는 실제 운전자 레이블 데이터를 입력할 수 있다(421). 프로세서(110)는 뇌전도 신호 데이터를 입력할 수 있다(422). 프로세서(110)는 실제 운전자 상태 데이터를 입력할 수 있다(423). 프로세서(110)는 인코더에 의해 데이터 표현을 학습할 수 있다(430). 프로세서(110)는 인코더에 뇌전도 신호 데이터를 입력함으로써, 특징을 추출할 수 있다. 프로세서(110)는 추출된 특징을 운전자 분류 모듈에 포함된 운전자 분류기에 입력함으로써, 운전자 레이블을 추정할 수 있다(441). 프로세서(110)는 추출된 특징을 디코더에 입력함으로써, 데이터를 복원할 수 있다. 그리고, 프로세서(110)는 복원된 데이터를 상태 분류 모듈에 포함된 졸음 상태 분류기를 통해 각 시점의 졸음 상태(상태 추정 정보)를 추정할 수 있다(442). 졸음 상태 분류기는 복원된 데이터에서 채널을 줄여주어 각 시점에 대응되는 운전자 상태를 출력할 수 있다. 상태 분류 모듈은 졸음 상태 분류기를 포함하거나 졸음 상태 분류기와 동일한 의미일 수 있다. 프로세서(110)는 실제 운전자 레이블 데이터와 추정된 운전자 레이블을 비교함으로써, 운전자 레이블 손실 값을 계산할 수 있다(451). 프로세서(110)는 추정된 상태 추정 정보와 실제 운전자 상태 데이터를 비교함으로써, 운전자 상태 손실 값을 계산할 수 있다(452). 프로세서(110)는 운전자 레이블 손실 값 및 운전자 상태 손실 값에 기초하여 손실 함수를 계산할 수 있다(460). 프로세서(110)는 손실 함수를 계산함으로써 획득되는 종합 손실 값을 이용하여 분류 모듈(예를 들어, 제1 분류 모델, 제2 분류 모델, 제3 분류 모델 등)을 학습시킬 수 있다.

[0159] 도 4를 참조하여 상술한 시점 수준 분류 모듈은 인코더를 통해 효과적으로 추출된 특징에 대해 디코더를 통해 신호의 시간 축 정보를 복원시키고 졸음 상태 분류기를 통해 채널을 줄여주어 각 시점에 맞는 운전자 졸음 상태에 대해 예측 값을 출력할 수 있다. 상태 분류 모듈 은 예측된 운전자 상태와 학습 데이터에 포함된 각 시점에서의 실제 운전자 상태 간에 교차 엔트로피 손실 함수를 사용하여 운전자 상태 손실 값을 계산할 수 있다. 예를 들어, 하나의 샘플(입력 데이터)이 1초 신호를 포함하는 32 채널 및 250 샘플링 주파수의 뇌전도 신호인 경우, 입력 데이터 샘플은 (채널, 시점의 개수)의 형태와 같이 (32, 250)의 구조를 가질 수 있다. 인코더 통과 후, 특징 차원은 증가하고(32 -> 256), 시간 차원은 감소할 수 있다(250 -> 40). 즉, 입력 데이터는 (256, 40)의 구조를 가질 수 있다. 디코더 통과 후, 특징 차원이 감소하고 (256 -> 16), 시간 차원이 입력 신호의 차원과 같도록 복원될 수 있다 (40 -> 250). 즉, 입력 데이터는 (16, 250)의 구조를 가질 수 있다. 졸음 상태 분류기 통과 후, 특징 차원을 감소시키고 (16 -> 1), 시간 차원은 유지할 수 있다. 프로세서(110)는 상태 분류 모듈을 이용하여 (1, 250)의 구조를 갖는 시점 수준 운전자 졸음 상태 추정 결과(상태 추정 정보)를 출력할 수 있다. 각 모듈의 입출력 데이터 구조는 이에 국한되지 아니한다.

[0160] 도 4를 참조하여 상술한 인코더에서 추출된 특징에 대해 운전자 분류 모듈은 운전자의 스타일 정보를 오분류하도록 사용자 적대적 학습을 수행할 수 있다. 사용자 적대적 학습이란, 공통된 인코더와 운전자 분류기를 통해 사용자 간에 발생하는 분포 차이를 줄이거나 제거함으로써 사용자 간 분포를 조정하는 기술일 수 있다. 이를 통해, 프로세서(110)는 클래스에 해당하는 정보에 더 집중하고 사용자 특화된 정보를 학습하는 것을 완화할 수 있다.

[0161] 분류 모델을 사전 학습시키는 단계에서의 운전자 레이블 손실 값, 운전자 상태 손실 값 및 손실 함수는 아래의 수학식 6에 대응될 수 있다.

수학식 6

[0162] $$L_{pretrain} = \frac{1}{n}\Sigma_{i=1}^{n}(L_y^i - \lambda L_d^i),$$

[0163] $$L_y = -\Sigma(softmax(y) * logsoftmax(\hat{y})),$$

[0164] $$L_d = -\Sigma(softmax(d) * logsoftmax(\hat{d}))$$

[0165] 수학식 6에서 각 기호의 설명은 아래와 같을 수 있다.

[0166] $L_{pretrain}$: 사전 학습 단계 손실 함수, L_y: 운전자 상태 손실 값, L_d: 운전자 레이블 손실 값, λ: 사용자 정의 매개변수, y: 실제 운전자 졸음 상태, $\hat{y}$: 추정된 운전자 졸음 상태, d: 실제 운전자 레이블, $\hat{d}$: 추정된 운전자 레이블

[0167] 수학식 6의 $L_{pretrain}$은 사전 학습 단계에서의 손실 값으로써 운전자 상태 손실 값과 운전자 레이블 손실 값(L_y,L_d)에 대해 가중치를 두어 뺄셈을 하는 형태로 수행될 수 있다. 여기서 운전자 상태 손실 값과 운전자 레이블 손실 값은 일 실시 예로써 평균 제곱 오차, 교차 엔트로피 손실 함수를 따를 수 있다. 손실 값을 구하는데 사용되는 손실 함수는 특정 손실 함수에 국한되지 아니한다. 이를 통해 모델의 인코더가 학습 데이터의 운전자에 과적합 되는 현상을 방지하고, 운전자 변화에 강인한 표현을 학습할 수 있다.

[0168] 도 4를 참조하여 상술한 바와 같이, 프로세서(110)는 분류 모델(예를 들어, 제1 분류 모델, 제2 분류 모델, 제3 분류 모델 등)을 사전 학습시킬 수 있다.

[0169] 예를 들어, 프로세서(110)는 실제 운전자 레이블 데이터, 뇌전도 신호 데이터 및 실제 운전자 상태 데이터를 포함하는 학습 데이터를 획득할 수 있다.

[0170] 프로세서(110)는 분류 모델에 포함된 인코더에 뇌전도 신호 데이터를 입력함으로써, 특징을 추출할 수 있다.

[0171] 프로세서(110)는 추출된 특징을 분류 모델에 포함된 운전자 분류 모듈에 입력함으로써, 추정된 운전자 레이블을 획득할 수 있다.

[0172] 프로세서(110)는 추정된 운전자 레이블과 실제 운전자 레이블을 비교함으로써, 운전자 레이블 손실 값을 계산할 수 있다.

[0173] 프로세서(110)는 추출된 특징을 디코더에 입력함으로써, 복원된 뇌전도 신호 데이터를 획득할 수 있다.

[0174] 프로세서(110)는 복원된 뇌전도 신호 데이터를 분류 모델에 포함된 상태 분류 모듈에 입력함으로써, 추정된 운전자 상태 정보(데이터)를 획득할 수 있다.

[0175] 프로세서(110)는 추정된 운전자 상태 정보(데이터)와 실제 운전자 상태 데이터를 비교함으로써, 운전자 상태 손실 값을 계산할 수 있다.

[0176] 프로세서(110)는 운전자 레이블 손실 값 및 운전자 상태 손실 값에 기초하여 손실 함수를 계산할 수 있다.

[0177] 프로세서(110)는 손실 함수를 계산함으로써 획득되는 종합 손실 값을 이용하여 분류 모듈을 학습시킬 수 있다.

[0179] 도 5는 본 개시의 일 실시예에 따른 인공지능 기반의 모델을 간략하게 나타낸 도면이다.

[0180] 도 5를 참조하면, 입력되는 데이터에 대한 추론을 수행하는 과정에서 분류 모델(예를 들어, 제1 분류 모델, 제2 분류 모델, 제3 분류 모델 등)은 인코더(510), 시점 수준 분류 모듈(520)을 포함할 수 있다. 즉, 분류 모델은

사전 학습 과정에서는 운전자 분류 모듈을 사용하지만, 추론을 수행하는 과정에서는 운전자 분류 모듈을 제외하고 인코더 및 시험 수준 분류 모듈(디코더 및 상태 추정 모듈 포함)만 사용(포함)할 수 있다.

[0181] 인코더(510)는 입력되는 데이터(예를 들어, 시험 데이터)에서 특징을 추출할 수 있다.

[0182] 시점 수준 분류 모듈(520)은 추출된 특징에 대해 신호의 시간 축 정보를 복원시키는 디코더(521) 및 복원된 시험 데이터에서 채널을 줄여주어 각 시점에 맞는 운전자 상태에 대한 예측 값인 운전자의 상태 추정 정보를 출력하는 상태 분류 모듈(522)을 포함할 수 있다.

[0183] 인코더(510) 및 시점 수준 분류 모듈(520)은 도 4의 사전 학습 과정을 통해 사전 학습되어 있을 수 있고, 사전 학습 과정에서의 가중치에 대응될 수 있다.

[0185] 도 6은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 시험 데이터에 대한 추론 과정을 간략하게 나타낸 도면이다.

[0186] 도 6을 참조하면, 프로세서(110)는 시험 데이터를 입력(획득)할 수 있다(601). 프로세서(110)는 시험 데이터를 제1 분류 모델에 입력함으로써, 제1 상태 추정 정보를 획득할 수 있다(602). 프로세서(110)는 사전 결정된 불확실성 추정 알고리즘을 이용하여 제1 상태 추정 정보에 대한 불확실성(uncertainty)을 추정함으로써, 불확실성 값을 획득할 수 있다(603).

[0187] 사전 결정된 불확실성 추정 알고리즘은 아래의 수학식 7에 대응될 수 있다.

수학식 7

[0188] $$uncertainty = -\Sigma_k p_k \log_2(p_k)$$

[0189] 수학식 7에서 p_k는 k로 예측할 확률이고, k는 클래스를 의미할 수 있다.

[0190] 프로세서(110)는 사전 정의 값(사전 결정된 임계치)보다 불확실성 값이 높은(큰) 경우(604, 예), 사전 결정된 데이터 증강 알고리즘을 이용하여 시험데이터에 증강을 적용할 수 있다(605).

[0191] 프로세서(110)는 사전 정의 값(사전 결정된 임계치)보다 불확실성 값이 낮은(작은) 경우(604, 아니오), 기존의 시험데이터를 그대로 사용할 수 있다.

[0192] 프로세서(110)는 증강된 시험 데이터(또는, 기존의 시험 데이터)를 제 2 분류 모델에 입력함으로써, 운전자의 제2 상태 추정 정보를 획득할 수 있다(606).

[0193] 프로세서(110) 운전자의 제2 상태 추정 정보를 시험 데이터에 대한 예측 값으로 출력(사용, 결정)할 수 있다(607).

[0194] 프로세서(110)는 제3 분류 모델에 시험 데이터를 입력함으로써, 운전자의 제3 상태 추정 정보를 획득할 수 있다(608).

[0195] 프로세서(110)는 사전 결정된 일관성 손실 알고리즘을 이용하여 제2 상태 추정 정보 및 제3 상태 추정 정보로부터 일관성 손실의 값을 계산(산출)할 수 있다(609).

[0196] 프로세서(110)는 계산된 일관성 손실(L_{const})의 값에 기초하여 제3 분류 모델을 학습(제3 분류 모델의 가중치를 갱신)할 수 있다(610).

[0197] 사전 결정된 일관성 손실 알고리즘은 아래의 수학식 8에 대응될 수 있다.

수학식 8

[0198] $$L_{const} = -\Sigma(softmax(y') * logsoftmax(\hat{y}))$$

[0199] 수학식 8에서 y' 은 제2 분류 모델의 출력인 제2 상태 추정 정보에 대한 값이고, $\hat{y}$ 는 제3 분류 모델의 출력인 제3 상태 추정 정보의 값일 수 있다.

[0200] 일 실시예에서, 모델 배치 직후 단계에서 불확실성 값이 사용자 정의 값 보다 낮아 증강이 적용되지 않은 경우, 제2 분류 모델과 제3 분류 모델은 동일한 가중치를 갖기 때문에 입력 데이터에 대해서 동일하게 출력할 수 있다. 동일한 출력 값에 대해서 일관성 손실을 적용하는 것은 제3 분류 모델의 출력에 불확실성을 추정하는 것과 동일할(대응될) 수 있다. 예를 들어, 교차 엔트로피 손실을 통해 동일한 출력의 일관성 손실을 적용하는 경우, 동일한 출력 값에 대해서 일관성 손실을 적용하는 것은 제3 분류 모델의 출력에 엔트로피를 추정하여 제3 분류 모델을 학습시키는 것과 동일할(대응될) 수 있다.

[0202] 도 7은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 제2 분류 모델의 매개변수 갱신 과정을 간략하게 나타낸 도면이다.

[0203] 도 7을 참조하면, 프로세서(110)는 제2 분류 모델의 매개변수를 입력(획득)할 수 있다(711). 프로세서(110)는 제3 분류 모델의 매개변수를 입력(획득)할 수 있다(712). 프로세서(110)는 제3 분류 모델의 가중치가 갱신된 이후(도 6의 610 이후)의 제3 분류 모델의 매개변수를 입력(획득)할 수 있다. 프로세서(110)는 지수 이동 평균을 통해 제2 분류 모델의 매개변수를 갱신(θ'_{t+1})할 수 있다. 이를 통해 프로세서(110)는 가중치의 큰 변동성을 방지할 수 있다. 프로세서(110)는 제2 분류 모델을 안정적으로 학습시키고, 예측의 안정성을 격려할 수 있다.

[0204] 지수 이동 평균의 알고리즘은 아래의 수학식 9에 대응될 수 있다.

수학식 9

[0205] $$\theta'_{t+1} = \alpha\theta'_t + (1-\alpha)\theta_{t+1}$$

[0206] 수학식 9에서 θ'_t 은 제2 분류 모델의 매개변수이고, θ_{t+1} 는 제3 분류 모델의 가중치가 갱신된 이후의 매개변수이고, α 는 사전 결정된 특정 값일 수 있다.

[0208] 도 8은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 제3 분류 모델의 가중치 복원 과정을 간략하게 나타낸 도면이다.

[0209] 도 8을 참조하면, 프로세서(110)는 제1 분류 모델의 가중치를 입력(획득)할 수 있다(811). 프로세서(110)는 제3 분류 모델의 가중치를 입력(획득)할 수 있다(812). 프로세서(110)는 제3 분류 모델의 가중치가 갱신된 이후(도 6의 610 이후)의 제3 분류 모델의 매개변수를 입력(획득)할 수 있다. 프로세서(110)는 무작위로 생성된 마스크 벡터를 입력(획득)할 수 있다(813). 프로세서(110)는 무작위로 생성된 마스크 벡터를 이용하여 제3 분류 모델의 일부 가중치를 제1 분류 모델의 가중치로 복원할 수 있다(820). 예를 들어, 프로세서(110)는 가중치 복원 알고리즘을 이용하여 제3 분류 모델의 일부 가중치를 제1 분류 모델의 가중치로 복원할 수 있다.

[0210] 가중치 복원 알고리즘은 아래의 수학식 10에 대응될 수 있다.

수학식 10

[0211] $$W_{t+1} = M \odot W_0 + (1 - M) \odot W_{t+1}$$

[0212] 수학식 10에서 W_0은 제1 분류 모델의 가중치이고, W_{t+1}는 제3 분류 모델의 가중치가 갱신된 이후의 가중치이고, M은 무작위로 생성된 마스크 벡터일 수 있다.

[0214] 도 9는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 추정하는 전체적인 과정을 나타낸 도면이다.

[0215] 도 9를 참조하면, 프로세서(110)는 시험 데이터를 입력(획득)할 수 있다(901).

[0216] 프로세서(110)는 시험 데이터를 제1 분류 모델에 입력함으로써, 제1 상태 추정 정보를 획득할 수 있다(902).

[0217] 프로세서(110)는 사전 결정된 불확실성 추정 알고리즘을 이용하여 제1 상태 추정 정보에 대한 불확실성(uncertainty)을 추정함으로써, 불확실성 값을 획득할 수 있다(903).

[0218] 프로세서(110)는 사전 정의 값(사전 결정된 임계치)보다 불확실성 값이 높은(큰) 경우(904, 예), 사전 결정된 데이터 증강 알고리즘을 이용하여 시험데이터에 증강을 적용할 수 있다(905).

[0219] 프로세서(110)는 사전 정의 값(사전 결정된 임계치)보다 불확실성 값이 낮은(작은) 경우(904, 아니오), 기존의 시험데이터를 그대로 사용할 수 있다.

[0220] 프로세서(110)는 증강된 시험 데이터(또는, 기존의 시험 데이터)를 제 2 분류 모델에 입력함으로써, 운전자의 제2 상태 추정 정보를 획득할 수 있다(906).

[0221] 프로세서(110) 운전자의 제2 상태 추정 정보를 시험 데이터에 대한 예측 값(운전자의 상태 예측 결과(예를 들어, 졸음, 잠, 정상 등))으로 출력(사용, 결정)할 수 있다(907).

[0222] 프로세서(110)는 제3 분류 모델에 시험 데이터를 입력함으로써, 운전자의 제3 상태 추정 정보를 획득할 수 있다(908).

[0223] 프로세서(110)는 사전 결정된 일관성 손실 알고리즘을 이용하여 제2 상태 추정 정보 및 제3 상태 추정 정보로부터 일관성 손실의 값을 계산(산출)하고, 그리고 계산된 일관성 손실의 값에 기초하여 제3 분류 모델을 학습(제3 분류 모델의 가중치를 갱신)할 수 있다(909).

[0224] 프로세서(110)는 지수 이동 평균을 통해 제2 분류 모델의 매개변수 또는 가중치를 갱신할 수 있다.

[0225] 프로세서(110)는 제3 분류 모델의 가중치를 제1 분류 모델의 가중치로 복원할 수 있다(910). 예를 들어, 프로세서(110)는 무작위로 생성된 마스크 벡터를 이용하여 제3 분류 모델의 일부 가중치를 제1 분류 모델의 가중치로 복원할 수 있다. 예를 들어, 프로세서(110)는 가중치 복원 알고리즘을 이용하여 제3 분류 모델의 일부 가중치를 제1 분류 모델의 가중치로 복원할 수 있다.

[0226] 도 1 내지 9를 참조하여 상술한 바와 같이, 본 개시의 일 실시예에 따른 컴퓨팅 장치(100)는 온라인 방식으로 입력되는 운전자의 연속적인 뇌전도 신호에 따라 매 시점마다 운전자의 변화에 일반화된 표현을 학습하고, 매 시점마다 분류를 수행할 수 있다. 온라인 방식으로 입력되는 목표 데이터의 샘플들에 대해 제2 분류 모델과 제3 분류 모델이 지속적으로 업데이트 되며, 시간이 지날수록 목표 운전자 데이터에 대한 예측 결과의 성능이 향상될 수 있다.

[0227] 본 개시의 일 실시예에 따른 컴퓨팅 장치(100)는 운전자의 변화에 강인한 인공지능 기반의 모델을 구축할 수 있다. 목표 운전자의 데이터에 따라 실시간으로 인공지능 기반의 모델의 가중치를 업데이트하며 적응하고 예측이 가능하기에 일반화 성능이 향상될 수 있다.

[0228] 컴퓨팅 장치(100)는 시간이 지나감에 따라 피험자 변화에 더욱 강인한 분류 결과를 제공할 수 있다. 컴퓨팅 장

치(100)는 목표 운전자의 데이터의 샘플이 입력됨에 따라 인공지능 기반의 모델의 가중치가 갱신되기 때문에 시간에 따라 운전자 변화에 더욱 강인한 인공지능 기반의 모델로 갱신시킬 수 있다.

[0229] 컴퓨팅 장치(100)는 사용자가 원하는 방식에 따라 온라인 및 오프라인 방식으로 수행할 수 있다. 컴퓨팅 장치(100)는 온라인 방식으로 각 시점의 분류 결과를 제공할 수 있으며, 오프라인 방식으로 목표 운전자의 데이터의 모든 시점에 대해 분류 결과를 제공할 수 있다.

[0230] 컴퓨팅 장치(100)는 캘리브레이션 과정을 없앰으로써, 시간을 절약할 수 있다. 종래의 기술에서는 운전자의 변화에 일반화된 인공지능 기반의 모델을 제공하기 위해 캘리브레이션 과정으로 인공지능 기반의 모델을 적응시켰지만, 컴퓨팅 장치(100)는 이를 시험 시간 적응 방식으로 대체하여 강인한 표현의 학습을 수행할 수 있다.

[0232] 도 10은 본 개시의 실시예들이 구현될 수 있는 예시적인 컴퓨팅 환경에 대한 간략하고 일반적인 개략도를 도시한다.

[0233] 본 개시가 일반적으로 컴퓨팅 장치에 의해 구현될 수 있는 것으로 전술되었지만, 당업자라면 본 개시가 하나 이상의 컴퓨터 상에서 실행될 수 있는 컴퓨터 실행가능 명령어 및/또는 기타 프로그램 모듈들과 결합되어 및/또는 하드웨어와 소프트웨어의 조합으로써 구현될 수 있다는 것을 잘 알 것이다.

[0234] 일반적으로, 프로그램 모듈은 특정의 태스크를 수행하거나 특정의 추상 데이터 유형을 구현하는 루틴, 프로그램, 컴포넌트, 데이터 구조, 기타 등등을 포함한다. 또한, 당업자라면 본 개시의 방법이 단일-프로세서 또는 멀티프로세서 컴퓨터 시스템, 미니컴퓨터, 메인프레임 컴퓨터는 물론 퍼스널 컴퓨터, 핸드헬드(handheld) 컴퓨팅 장치, 마이크로프로세서-기반 또는 프로그램가능 가전 제품, 기타 등등(이들 각각은 하나 이상의 연관된 장치와 연결되어 동작할 수 있음)을 비롯한 다른 컴퓨터 시스템 구성으로 실시될 수 있다는 것을 잘 알 것이다.

[0235] 본 개시의 설명된 실시예들은 또한 어떤 태스크들이 통신 네트워크를 통해 연결되어 있는 원격 처리 장치들에 의해 수행되는 분산 컴퓨팅 환경에서 실시될 수 있다. 분산 컴퓨팅 환경에서, 프로그램 모듈은 로컬 및 원격 메모리 저장 장치 둘 다에 위치할 수 있다.

[0236] 컴퓨터는 통상적으로 다양한 컴퓨터 판독가능 매체를 포함한다. 컴퓨터에 의해 액세스 가능한 매체는 그 어떤 것이든지 컴퓨터 판독가능 매체가 될 수 있고, 이러한 컴퓨터 판독가능 매체는 휘발성 및 비휘발성 매체, 일시적(transitory) 및 비일시적(non-transitory) 매체, 이동식 및 비-이동식 매체를 포함한다. 제한이 아닌 예로서, 컴퓨터 판독가능 매체는 컴퓨터 판독가능 저장 매체 및 컴퓨터 판독가능 전송 매체를 포함할 수 있다. 컴퓨터 판독가능 저장 매체는 컴퓨터 판독가능 명령어, 데이터 구조, 프로그램 모듈 또는 기타 데이터와 같은 정보를 저장하는 임의의 방법 또는 기술로 구현되는 휘발성 및 비휘발성 매체, 일시적 및 비-일시적 매체, 이동식 및 비이동식 매체를 포함한다. 컴퓨터 판독가능 저장 매체는 RAM, ROM, EEPROM, 플래시 메모리 또는 기타 메모리 기술, CD-ROM, DVD(digital video disk) 또는 기타 광 디스크 저장 장치, 자기 카세트, 자기 테이프, 자기 디스크 저장 장치 또는 기타 자기 저장 장치, 또는 컴퓨터에 의해 액세스될 수 있고 원하는 정보를 저장하는 데 사용될 수 있는 임의의 기타 매체를 포함하지만, 이에 한정되지 않는다.

[0237] 컴퓨터 판독가능 전송 매체는 통상적으로 반송파(carrier wave) 또는 기타 전송 메커니즘(transport mechanism)과 같은 피변조 데이터 신호(modulated data signal)에 컴퓨터 판독가능 명령어, 데이터 구조, 프로그램 모듈 또는 기타 데이터 등을 구현하고 모든 정보 전달 매체를 포함한다. 피변조 데이터 신호라는 용어는 신호 내에 정보를 인코딩하도록 그 신호의 특성들 중 하나 이상을 설정 또는 변경시킨 신호를 의미한다. 제한이 아닌 예로서, 컴퓨터 판독가능 전송 매체는 유선 네트워크 또는 직접 배선 접속(direct-wired connection)과 같은 유선 매체, 그리고 음향, RF, 적외선, 기타 무선 매체와 같은 무선 매체를 포함한다. 상술된 매체들 중 임의의 것의 조합도 역시 컴퓨터 판독가능 전송 매체의 범위 안에 포함되는 것으로 한다.

[0238] 컴퓨터(1102)를 포함하는 본 개시의 여러가지 측면들을 구현하는 예시적인 환경이 나타내어져 있으며, 컴퓨터(1102)는 처리 장치(1104), 시스템 메모리(1106) 및 시스템 버스(1108)를 포함한다. 시스템 버스(1108)는 시스템 메모리(1106)(이에 한정되지 않음)를 비롯한 시스템 컴포넌트들을 처리 장치(1104)에 연결시킨다. 처리 장치(1104)는 다양한 상용 프로세서들 중 임의의 프로세서일 수 있다. 듀얼 프로세서 및 기타 멀티프로세서 아키텍처도 역시 처리 장치(1104)로서 이용될 수 있다.

[0239] 시스템 버스(1108)는 메모리 버스, 주변장치 버스, 및 다양한 상용 버스 아키텍처 중 임의의 것을 사용하는 로컬 버스에 추가적으로 상호 연결될 수 있는 몇 가지 유형의 버스 구조 중 임의의 것일 수 있다. 시스템 메모리

(1106)는 판독 전용 메모리(ROM)(1110) 및 랜덤 액세스 메모리(RAM)(1112)를 포함한다. 기본 입/출력 시스템(BIOS)은 ROM, EPROM, EEPROM 등의 비휘발성 메모리(1110)에 저장되며, 이 BIOS는 시동 중과 같은 때에 컴퓨터(1102) 내의 구성요소들 간에 정보를 전송하는 일을 돕는 기본적인 루틴을 포함한다. RAM(1112)은 또한 데이터를 캐싱하기 위한 정적 RAM 등의 고속 RAM을 포함할 수 있다.

[0240] 컴퓨터(1102)는 또한 내장형 하드 디스크 드라이브(HDD)(1114)(예를 들어, EIDE, SATA)-이 내장형 하드 디스크 드라이브(1114)는 또한 적당한 섀시(도시 생략) 내에서 외장형 용도로 구성될 수 있음-, 자기 플로피 디스크 드라이브(FDD)(1116)(예를 들어, 이동식 디스켓(1118)으로부터 판독을 하거나 그에 기록을 하기 위한 것임), 및 광 디스크 드라이브(1120)(예를 들어, CD-ROM 디스크(1122)를 판독하거나 DVD 등의 기타 고용량 광 매체로부터 판독을 하거나 그에 기록을 하기 위한 것임)를 포함한다. 하드 디스크 드라이브(1114), 자기 디스크 드라이브(1116) 및 광 디스크 드라이브(1120)는 각각 하드 디스크 드라이브 인터페이스(1124), 자기 디스크 드라이브 인터페이스(1126) 및 광 드라이브 인터페이스(1128)에 의해 시스템 버스(1108)에 연결될 수 있다. 외장형 드라이브 구현을 위한 인터페이스(1124)는 USB(Universal Serial Bus) 및 IEEE 1394 인터페이스 기술 중 적어도 하나 또는 그 둘 다를 포함한다.

[0241] 이들 드라이브 및 그와 연관된 컴퓨터 판독가능 매체는 데이터, 데이터 구조, 컴퓨터 실행가능 명령어, 기타 등등의 비휘발성 저장을 제공한다. 컴퓨터(1102)의 경우, 드라이브 및 매체는 임의의 데이터를 적당한 디지털 형식으로 저장하는 것에 대응한다. 상기에서의 컴퓨터 판독가능 매체에 대한 설명이 HDD, 이동식 자기 디스크, 및 CD 또는 DVD 등의 이동식 광 매체를 언급하고 있지만, 당업자라면 집 드라이브(zip drive), 자기 카세트, 플래쉬 메모리 카드, 카트리지, 기타 등등의 컴퓨터에 의해 판독가능한 다른 유형의 매체도 역시 예시적인 운영 환경에서 사용될 수 있으며 또 임의의 이러한 매체가 본 개시의 방법들을 수행하기 위한 컴퓨터 실행가능 명령어를 포함할 수 있다는 것을 잘 알 것이다.

[0242] 운영 체제(1130), 하나 이상의 애플리케이션 프로그램(1132), 기타 프로그램 모듈(1134) 및 프로그램 데이터(1136)를 비롯한 다수의 프로그램 모듈이 드라이브 및 RAM(1112)에 저장될 수 있다. 운영 체제, 애플리케이션, 모듈 및/또는 데이터의 전부 또는 그 일부분이 또한 RAM(1112)에 캐싱될 수 있다. 본 개시가 여러가지 상업적으로 이용가능한 운영 체제 또는 운영 체제들의 조합에서 구현될 수 있다는 것을 잘 알 것이다.

[0243] 사용자는 하나 이상의 유선/무선 입력 장치, 예를 들어, 키보드(1138) 및 마우스(1140) 등의 포인팅 장치를 통해 컴퓨터(1102)에 명령 및 정보를 입력할 수 있다. 기타 입력 장치(도시 생략)로는 마이크, IR 리모콘, 조이스틱, 게임 패드, 스타일러스 펜, 터치 스크린, 기타 등등이 있을 수 있다. 이들 및 기타 입력 장치가 종종 시스템 버스(1108)에 연결되어 있는 입력 장치 인터페이스(1142)를 통해 처리 장치(1104)에 연결되지만, 병렬 포트, IEEE 1394 직렬 포트, 게임 포트, USB 포트, IR 인터페이스, 기타 등등의 기타 인터페이스에 의해 연결될 수 있다.

[0244] 모니터(1144) 또는 다른 유형의 디스플레이 장치도 역시 비디오 어댑터(1146) 등의 인터페이스를 통해 시스템 버스(1108)에 연결된다. 모니터(1144)에 부가하여, 컴퓨터는 일반적으로 스피커, 프린터, 기타 등등의 기타 주변 출력 장치(도시 생략)를 포함한다.

[0245] 컴퓨터(1102)는 유선 및/또는 무선 통신을 통한 원격 컴퓨터(들)(1148) 등의 하나 이상의 원격 컴퓨터로의 논리적 연결을 사용하여 네트워크화된 환경에서 동작할 수 있다. 원격 컴퓨터(들)(1148)는 워크스테이션, 컴퓨팅 디바이스 컴퓨터, 라우터, 퍼스널 컴퓨터, 휴대용 컴퓨터, 마이크로프로세서-기반 오락 기기, 피어 장치 또는 기타 통상의 네트워크 노드일 수 있으며, 일반적으로 컴퓨터(1102)에 대해 기술된 구성요소들 중 다수 또는 그 전부를 포함하지만, 간략함을 위해, 메모리 저장 장치(1150)만이 도시되어 있다. 도시되어 있는 논리적 연결은 근거리 통신망(LAN)(1152) 및/또는 더 큰 네트워크, 예를 들어, 원거리 통신망(WAN)(1154)에의 유선/무선 연결을 포함한다. 이러한 LAN 및 WAN 네트워킹 환경은 사무실 및 회사에서 일반적인 것이며, 인트라넷 등의 전사적 컴퓨터 네트워크(enterprise-wide computer network)를 용이하게 해주며, 이들 모두는 전세계 컴퓨터 네트워크, 예를 들어, 인터넷에 연결될 수 있다.

[0246] LAN 네트워킹 환경에서 사용될 때, 컴퓨터(1102)는 유선 및/또는 무선 통신 네트워크 인터페이스 또는 어댑터(1156)를 통해 로컬 네트워크(1152)에 연결된다. 어댑터(1156)는 LAN(1152)에의 유선 또는 무선 통신을 용이하게 해줄 수 있으며, 이 LAN(1152)은 또한 무선 어댑터(1156)와 통신하기 위해 그에 설치되어 있는 무선 액세스 포인트를 포함하고 있다. WAN 네트워킹 환경에서 사용될 때, 컴퓨터(1102)는 모뎀(1158)을 포함할 수 있거나, WAN(1154) 상의 통신 컴퓨팅 디바이스에 연결되거나, 또는 인터넷을 통하는 등, WAN(1154)을 통해 통신을 설정하는 기타 수단을 갖는다. 내장형 또는 외장형 및 유선 또는 무선 장치일 수 있는 모뎀(1158)은 직렬 포트 인터

페이스(1142)를 통해 시스템 버스(1108)에 연결된다. 네트워크화된 환경에서, 컴퓨터(1102)에 대해 설명된 프로그램 모듈들 또는 그의 일부분이 원격 메모리/저장 장치(1150)에 저장될 수 있다. 도시된 네트워크 연결이 예시적인 것이며 컴퓨터들 사이에 통신 링크를 설정하는 기타 수단이 사용될 수 있다는 것을 잘 알 것이다.

[0247] 컴퓨터(1102)는 무선 통신으로 배치되어 동작하는 임의의 무선 장치 또는 개체, 예를 들어, 프린터, 스캐너, 데스크톱 및/또는 휴대용 컴퓨터, PDA(portable data assistant), 통신 위성, 무선 검출가능 태그와 연관된 임의의 장비 또는 장소, 및 전화와 통신을 하는 동작을 한다. 이것은 적어도 Wi-Fi 및 블루투스 무선 기술을 포함한다. 따라서, 통신은 종래의 네트워크에서와 같이 미리 정의된 구조이거나 단순하게 적어도 2개의 장치 사이의 애드혹 통신(ad hoc communication)일 수 있다.

[0248] Wi-Fi(Wireless Fidelity)는 유선 없이도 인터넷 등으로의 연결을 가능하게 해준다. Wi-Fi는 이러한 장치, 예를 들어, 컴퓨터가 실내에서 및 실외에서, 즉 기지국의 통화권 내의 아무 곳에서나 데이터를 전송 및 수신할 수 있게 해주는 셀 전화와 같은 무선 기술이다. Wi-Fi 네트워크는 안전하고 신뢰성 있으며 고속인 무선 연결을 제공하기 위해 IEEE 802.11(a, b, g, 기타)이라고 하는 무선 기술을 사용한다. 컴퓨터를 서로에, 인터넷에 및 유선 네트워크(IEEE 802.3 또는 이더넷을 사용함)에 연결시키기 위해 Wi-Fi가 사용될 수 있다. Wi-Fi 네트워크는 비인가 2.4 및 5GHz 무선 대역에서, 예를 들어, 11Mbps(802.11a) 또는 54 Mbps(802.11b) 데이터 레이트로 동작하거나, 양 대역(듀얼 대역)을 포함하는 제품에서 동작할 수 있다.

[0249] 본 개시의 기술 분야에서 통상의 지식을 가진 자는 정보 및 신호들이 임의의 다양한 상이한 기술들 및 기법들을 이용하여 표현될 수 있다는 것을 이해할 것이다. 예를 들어, 위의 설명에서 참조될 수 있는 데이터, 지시들, 명령들, 정보, 신호들, 비트들, 심볼들 및 칩들은 전압들, 전류들, 전자기파들, 자기장들 또는 입자들, 광학장들 또는 입자들, 또는 이들의 임의의 결합에 의해 표현될 수 있다.

[0250] 본 개시의 기술 분야에서 통상의 지식을 가진 자는 여기에 개시된 실시예들과 관련하여 설명된 다양한 예시적인 논리 블록들, 모듈들, 프로세서들, 수단들, 회로들 및 알고리즘 단계들이 전자 하드웨어, (편의를 위해, 여기에서 소프트웨어로 지칭되는) 다양한 형태들의 프로그램 또는 설계 코드 또는 이들 모두의 결합에 의해 구현될 수 있다는 것을 이해할 것이다. 하드웨어 및 소프트웨어의 이러한 상호 호환성을 명확하게 설명하기 위해, 다양한 예시적인 컴포넌트들, 블록들, 모듈들, 회로들 및 단계들이 이들의 기능과 관련하여 위에서 일반적으로 설명되었다. 이러한 기능이 하드웨어 또는 소프트웨어로서 구현되는지 여부는 특정한 애플리케이션 및 전체 시스템에 대하여 부과되는 설계 제약들에 따라 좌우된다. 본 개시의 기술 분야에서 통상의 지식을 가진 자는 각각의 특정한 애플리케이션에 대하여 다양한 방식들로 설명된 기능을 구현할 수 있으나, 이러한 구현 결정들은 본 개시의 범위를 벗어나는 것으로 해석되어서는 안 될 것이다.

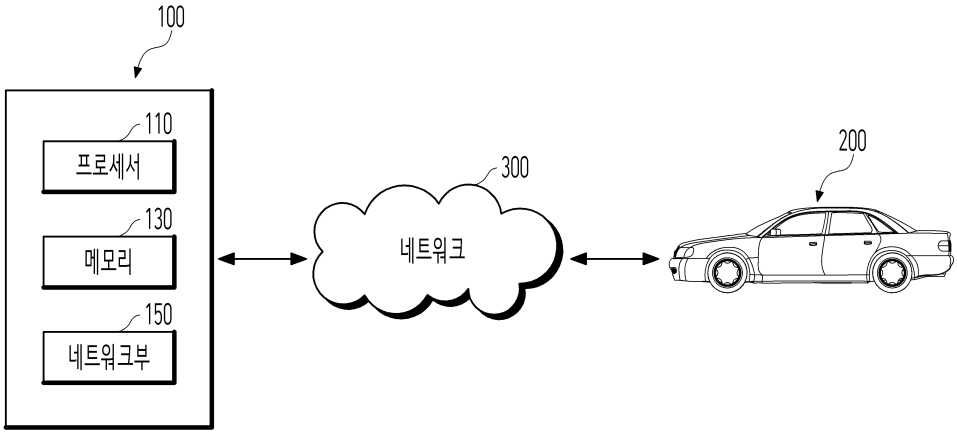
[0251] 여기서 제시된 다양한 실시예들은 방법, 장치, 또는 표준 프로그래밍 및/또는 엔지니어링 기술을 사용한 제조 물품(article)으로 구현될 수 있다. 용어 제조 물품은 임의의 컴퓨터-판독가능 저장장치로부터 액세스 가능한 컴퓨터 프로그램, 캐리어, 또는 매체(media)를 포함한다. 예를 들어, 컴퓨터-판독가능 저장매체는 자기 저장 장치(예를 들면, 하드 디스크, 플로피 디스크, 자기 스트립, 등), 광학 디스크(예를 들면, CD, DVD, 등), 스마트 카드, 및 플래쉬 메모리 장치(예를 들면, EEPROM, 카드, 스틱, 키 드라이브, 등)를 포함하지만, 이들로 제한되는 것은 아니다. 또한, 여기서 제시되는 다양한 저장 매체는 정보를 저장하기 위한 하나 이상의 장치 및/또는 다른 기계-판독가능한 매체를 포함한다.

[0252] 제시된 프로세스들에 있는 단계들의 특정한 순서 또는 계층 구조는 예시적인 접근들의 일례임을 이해하도록 한다. 설계 우선순위들에 기반하여, 본 개시의 범위 내에서 프로세스들에 있는 단계들의 특정한 순서 또는 계층 구조가 재배열될 수 있다는 것을 이해하도록 한다. 첨부된 방법 청구항들은 샘플 순서로 다양한 단계들의 엘리먼트들을 제공하지만 제시된 특정한 순서 또는 계층 구조에 한정되는 것을 의미하지는 않는다.

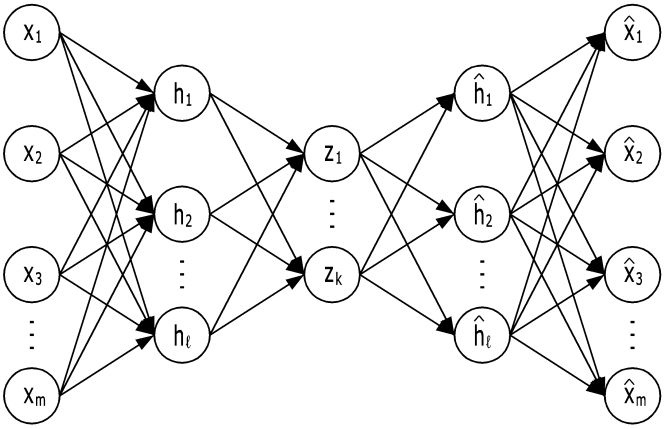
[0253] 제시된 실시예들에 대한 설명은 임의의 본 개시의 기술 분야에서 통상의 지식을 가진 자가 본 개시를 이용하거나 또는 실시할 수 있도록 제공된다. 이러한 실시예들에 대한 다양한 변형들은 본 개시의 기술 분야에서 통상의 지식을 가진 자에게 명백할 것이며, 여기에 정의된 일반적인 원리들은 본 개시의 범위를 벗어남이 없이 다른 실시예들에 적용될 수 있다. 그리하여, 본 개시는 여기에 제시된 실시예들로 한정되는 것이 아니라, 여기에 제시된 원리들 및 신규한 특징들과 일관되는 최광의의 범위에서 해석되어야 할 것이다.

도면

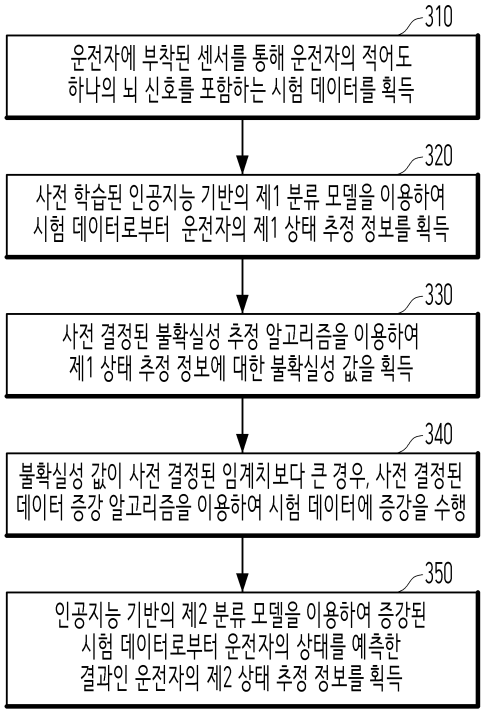
도면1


100
110
프로세서
130
메모리
150
네트워크부
300
네트워크
200

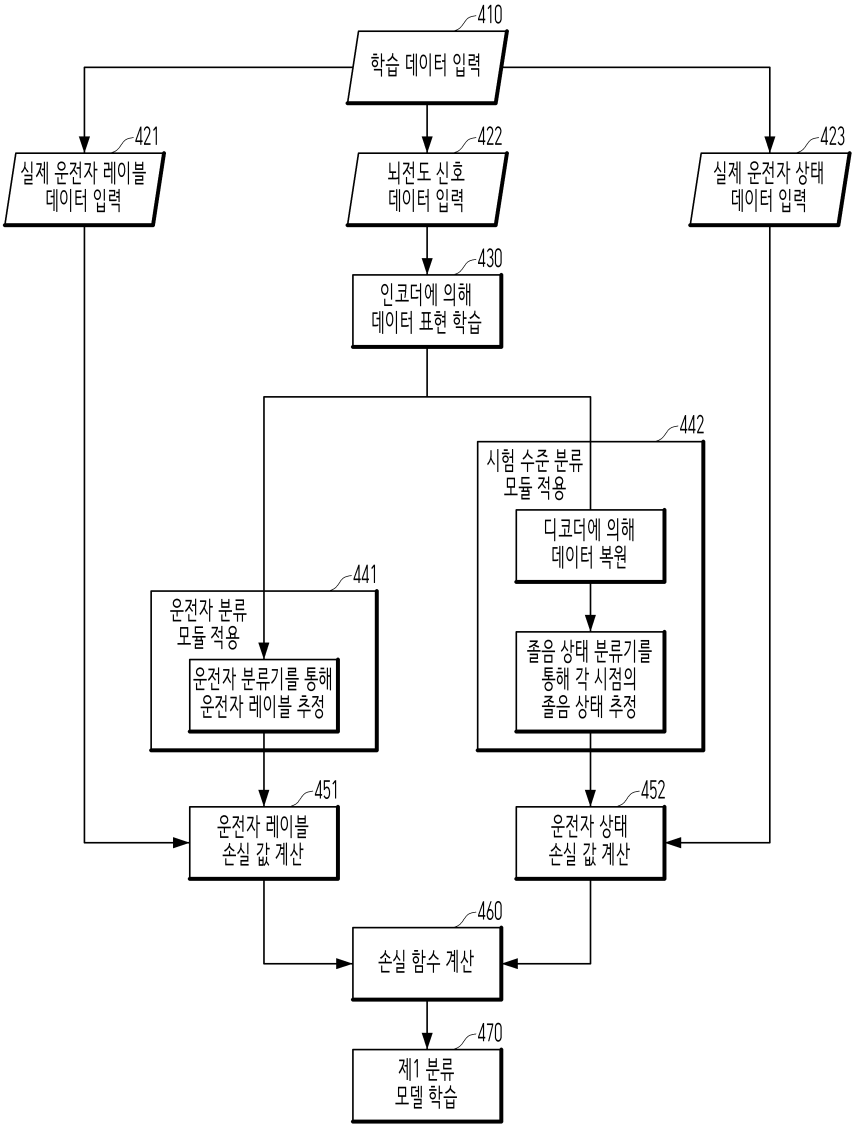
도면2


x1
x2
x3
xm
h1
h2
hℓ
z1
zk
ĥ1
ĥ2
ĥℓ
x̂1
x̂2
x̂3
x̂m

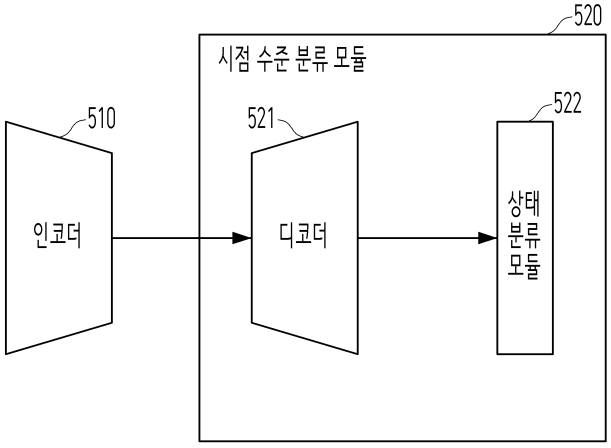
도면3


310
운전자에 부착된 센서를 통해 운전자의 적어도 하나의 뇌 신호를 포함하는 시험 데이터를 획득
320
사전 학습된 인공지능 기반의 제1 분류 모델을 이용하여 시험 데이터로부터 운전자의 제1 상태 추정 정보를 획득
330
사전 결정된 불확실성 추정 알고리즘을 이용하여 제1 상태 추정 정보에 대한 불확실성 값을 획득
340
불확실성 값이 사전 결정된 임계치보다 큰 경우, 사전 결정된 데이터 증강 알고리즘을 이용하여 시험 데이터에 증강을 수행
350
인공지능 기반의 제2 분류 모델을 이용하여 증강된 시험 데이터로부터 운전자의 상태를 예측한 결과인 운전자의 제2 상태 추정 정보를 획득

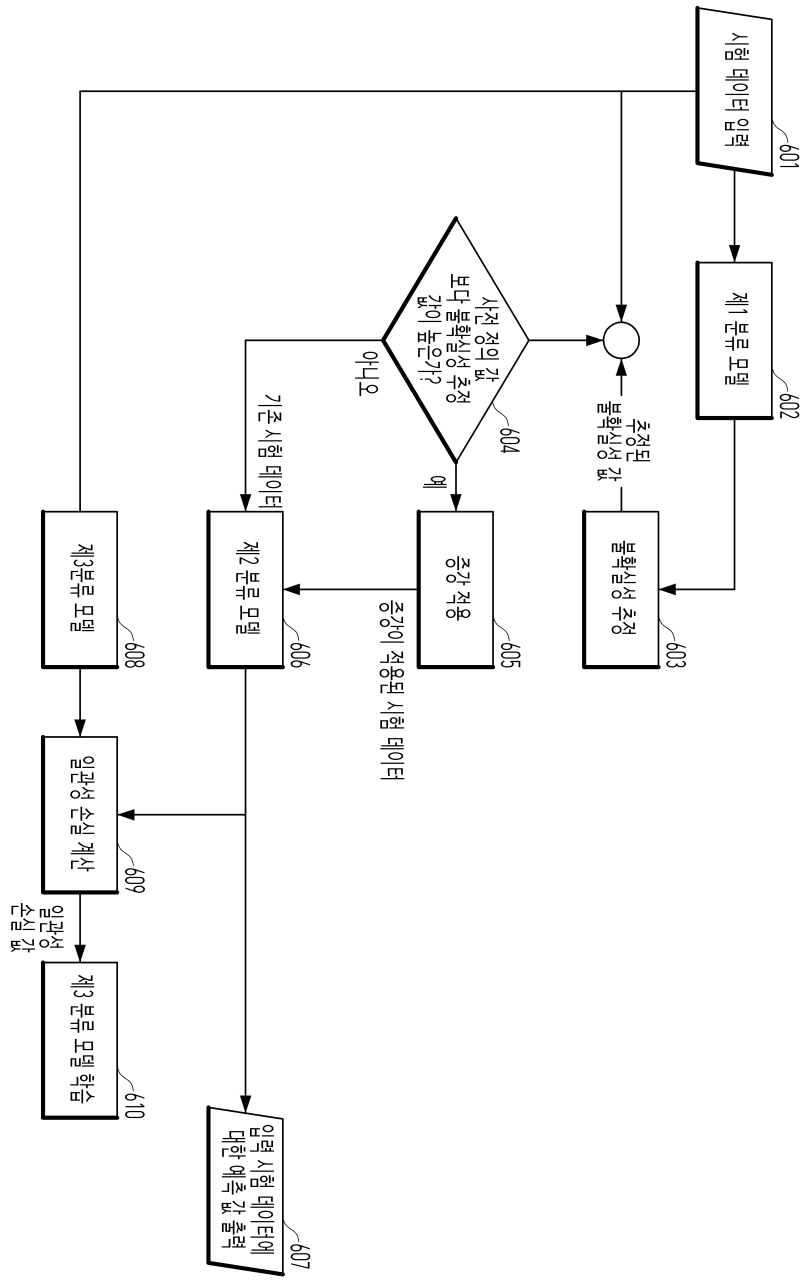
도면4


410
학습 데이터 입력
421
실제 운전자 레이블 데이터 입력
422
뇌전도 신호 데이터 입력
423
실제 운전자 상태 데이터 입력
430
인코더에 의해 데이터 표현 학습
442
시험 수준 분류 모듈 적용
디코더에 의해 데이터 복원
졸음 상태 분류기를 통해 각 시점의 졸음 상태 추정
441
운전자 분류 모듈 적용
운전자 분류기를 통해 운전자 레이블 추정
451
운전자 레이블 손실 값 계산
452
운전자 상태 손실 값 계산
460
손실 함수 계산
470
제1 분류 모델 학습

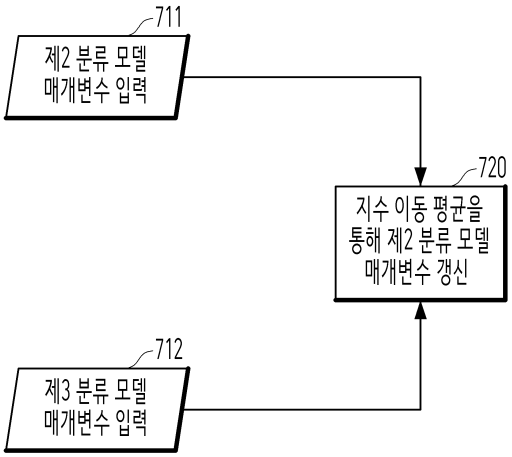
도면5


520
시점 수준 분류 모듈
510
인코더
521
디코더
522
상태 분류 모듈

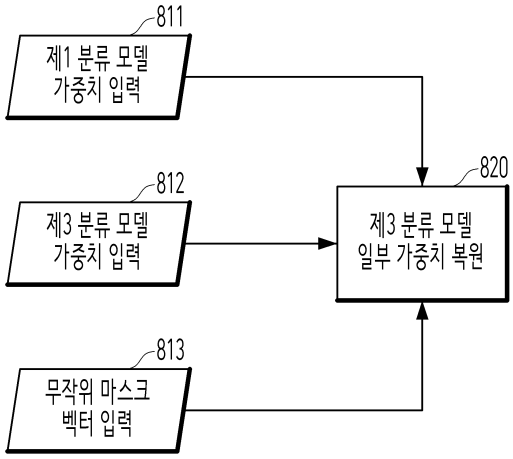
도면6


시험 데이터 입력
601
제1 분류 모델
602
사전 정의 값보다 불확실성 추정 값이 높은가?
604
아니오
예
추정된 불확실성 값
불확실성 추정
603
기존 시험 데이터
증강 적용
605
증강이 적용된 시험 데이터
제2 분류 모델
606
제3분류 모델
608
일관성 손실 계산
609
일관성 손실 값
제3 분류 모델 학습
610
입력 시험 데이터에 대한 예측 값 출력
607

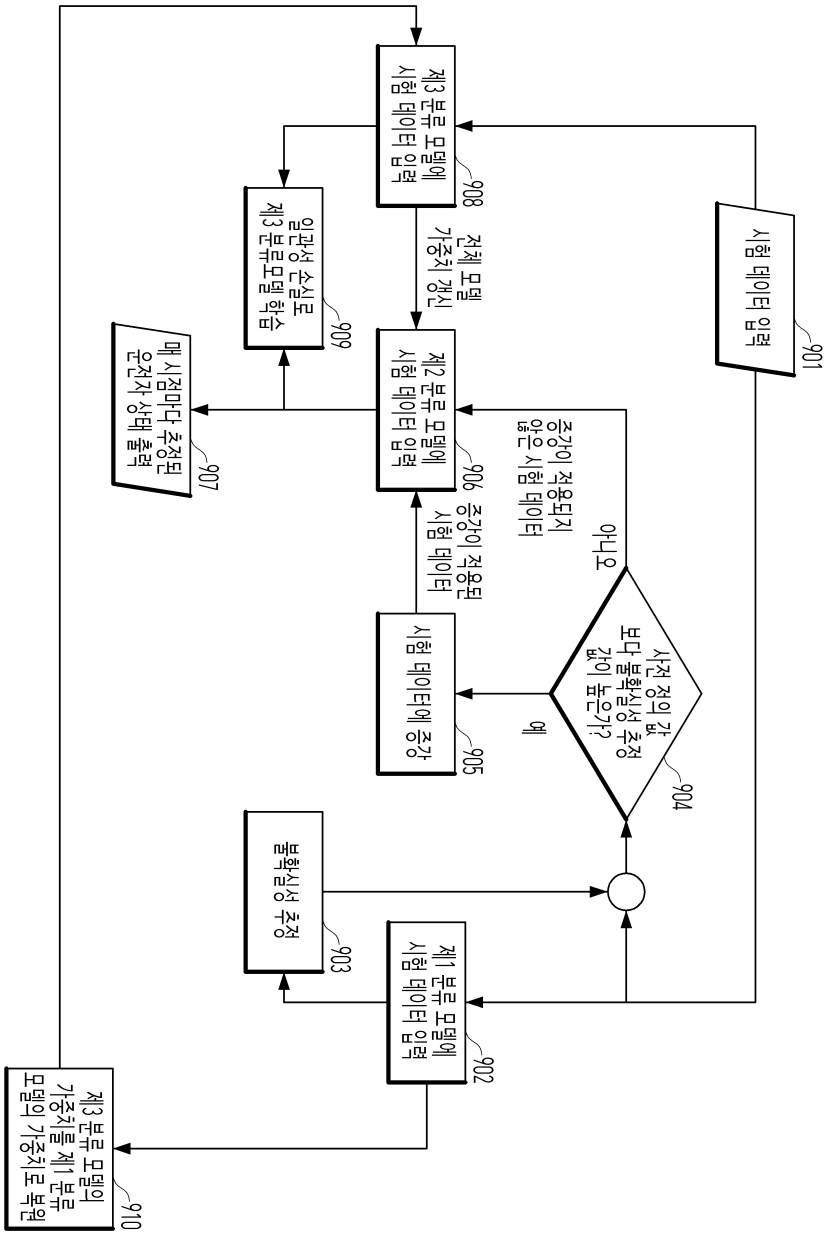
도면7


711
제2 분류 모델
매개변수 입력
720
지수 이동 평균을
통해 제2 분류 모델
매개변수 갱신
712
제3 분류 모델
매개변수 입력

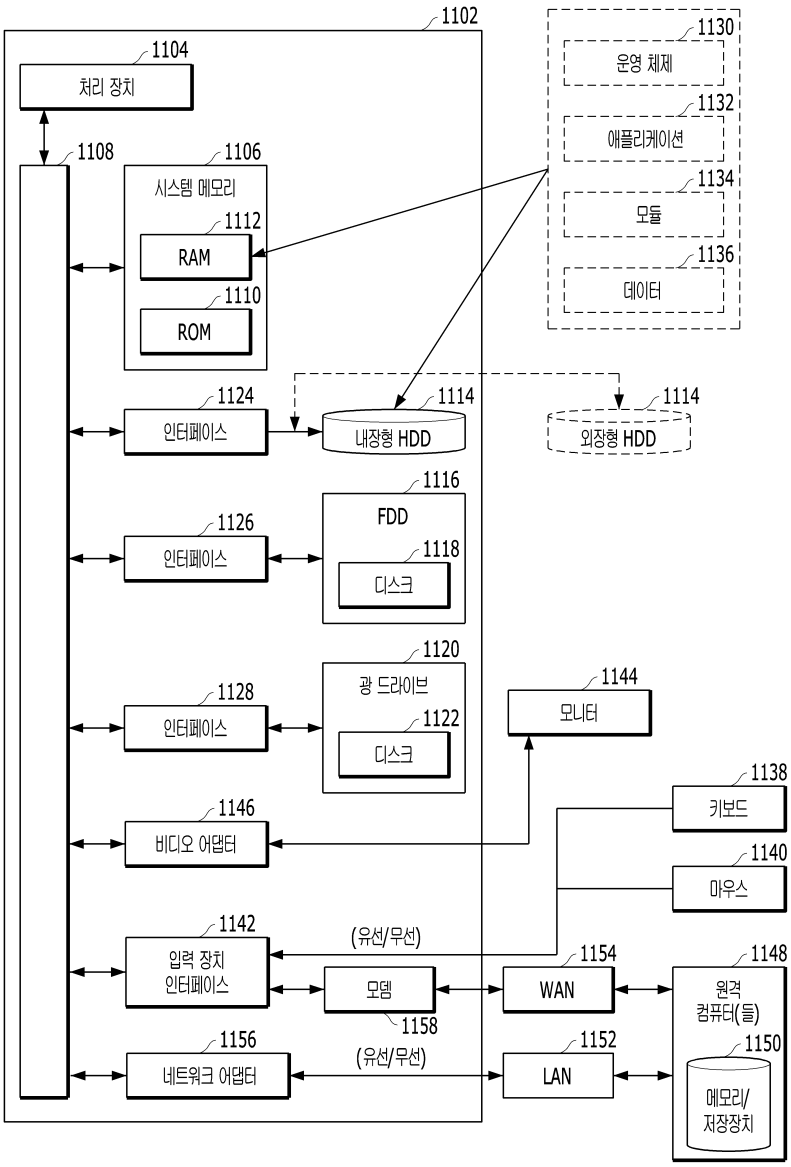
도면8


811
제1 분류 모델
가중치 입력
812
제3 분류 모델
가중치 입력
820
제3 분류 모델
일부 가중치 복원
813
무작위 마스크
벡터 입력

도면9


시험 데이터 입력
901
제1 뉴로 모델에 시험 데이터 입력
902
복합실성 추정
903
사전 정의 값 보다 불확실성 추정 값이 높은가?
904
예
아니오
시험 데이터에 증강
905
증강이 적용되지 않은 시험 데이터
제2 뉴로 모델에 시험 데이터 입력
906
증강이 적용된 시험 데이터
매 시점마다 추정된 운전자 상태 출력
907
일관성 손실로 제3 뉴로모델 학습
909
전체 모델 가중치 갱신
제3 뉴로 모델에 시험 데이터 입력
908
제3 뉴로 모델의 가중치를 제1 뉴로 모델의 가중치로 복원
910

도면10


1102
1104
처리 장치
1108
1106
시스템 메모리
1112
RAM
1110
ROM
1130
운영 체제
1132
애플리케이션
1134
모듈
1136
데이터
1124
인터페이스
1114
내장형 HDD
1114
외장형 HDD
1116
FDD
1126
인터페이스
1118
디스크
1120
광 드라이브
1128
인터페이스
1122
디스크
1144
모니터
1138
키보드
1146
비디오 어댑터
1140
마우스
1142
입력 장치 인터페이스
(유선/무선)
1154
WAN
1148
원격 컴퓨터(들)
모뎀
1158
1156
네트워크 어댑터
(유선/무선)
1152
LAN
1150
메모리/ 저장장치