



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0073876
(43) 공개일자 2025년05월27일

(51) 국제특허분류(Int. Cl.)

B60W 40/08 (2006.01) A61B 5/00 (2021.01)
A61B 5/024 (2025.01) G06N 20/00 (2019.01)
G06N 3/08 (2023.01)

(52) CPC특허분류

B60W 40/08 (2013.01)
A61B 5/024 (2025.01)

(21) 출원번호 10-2023-0160333

(22) 출원일자 2023년11월20일

심사청구일자 2023년11월20일

(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 감지하기 위한 방법 및 장치

(57) 요약

본 개시의 일 실시예에 따라 컴퓨팅 장치에 의해 수행되는 운전자의 상태를 감지하기 위한 방법으로서, 차량으로부터 적어도 하나의 차량에 관한 신호를 획득

(뒷면에 계속)

대표도 - 도3



차량에 관한 신호로부터 신뢰 계수를 산출하는 단계; 시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 단계; 크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 단계; 상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 단계; 및 상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 단계;를 포함할 수 있다.

(52) CPC특허분류

A61B 5/6893 (2013.01)

G06N 20/00 (2021.08)

G06N 3/08 (2023.01)

B60W 2520/105 (2013.01)

B60W 2540/18 (2013.01)

B60W 2540/221 (2020.02)

B60W 2556/35 (2020.02)

(72) 발명자

박서현

서울특별시 송파구 잠실로 88, 113동 502호 (잠실동, 레이크펠리스)

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 인공지능핵심고급인재양성
 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

명세서

청구범위

청구항 1

컴퓨팅 장치에 의해 수행되는 운전자의 상태를 감지하기 위한 방법으로서,

차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 단계;

상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득하는 단계;

상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 단계;

시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 단계;

크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 단계;

상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 단계; 및

상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 단계;

를 포함하는,

방법.

청구항 2

제 1 항에 있어서,

상기 적어도 하나의 차량에 관한 신호는,

가속도, 주행 방향 및 운전대 각도에 대한 신호를 포함하는,

방법.

청구항 3

제 2 항에 있어서,

상기 신뢰 계수를 산출하는 단계는:

구간별 변동성 추정식에 상기 가속도, 상기 주행 방향 및 상기 운전대 각도에 대한 신호를 대입함으로써, 상기 차량의 변동성에 관한 제 1 값을 산출하는 단계; 및

상기 신뢰 계수에 관한 비선형 함수식에 상기 제 1 값을 대입함으로써, 상기 신뢰 계수를 산출하는 단계;

를 포함하는,

방법.

청구항 4

제 1 항에 있어서,

상기 신뢰 계수를 산출하는 단계는:

인공지능 기반의 분류 모델을 이용하여 상기 적어도 하나의 차량에 관한 신호로부터 상기 차량의 변동성에 관한 제 2 값을 산출하는 단계; 및

상기 신뢰 계수에 관한 비선형 함수식에 상기 제 2 값을 대입함으로써, 상기 신뢰 계수를 산출하는 단계;

를 포함하는,

방법.

청구항 5

제 1 항에 있어서,

상기 적어도 하나의 생체 신호는,

심전도(Electrocardiogram, ECG), 맥파(Photoplethysmogram, PPG), 전기피부반응(Galvanic Skin Response, GSR) 및 호흡(Respiration, RSP)을 포함하는,

방법.

청구항 6

제 1 항에 있어서,

상기 시간적 특징 추출 모델은,

상기 뇌전도 신호에 대응되고, 그리고 뇌전도 신호와 관련된 학습 데이터를 이용하여 학습되는 제 1 시간적 특징 추출 서브 모델; 및

상기 적어도 하나의 생체 신호에 대응되고, 그리고 적어도 하나의 생체 신호와 관련된 학습 데이터를 이용하여 학습되는 제 2 시간적 특징 추출 서브 모델;

을 포함하는,

방법.

청구항 7

제 1 항에 있어서,

상기 신뢰 계수는,

상기 시간적 특징 추출 모델 또는 상기 크로스 어텐션 모델 중 적어도 하나의 학습에 사용되는 손실함수에 적용되는,

방법.

청구항 8

제 1 항에 있어서,

상기 차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 단계는:

상기 적어도 하나의 차량에 관한 신호, 상기 운전자의 뇌전도 신호 및 상기 적어도 하나의 생체 신호의 샘플링 레이트(sampling rate)를 통일시키기 위해 상기 차량에 관한 신호의 샘플링 증대 또는 감소를 수행하는 단계;

상기 샘플링 증대 또는 감소된 적어도 하나의 차량에 관한 신호를 시간에 따라 사전 결정된 창 크기(window size)로 세그먼트 분할하는 단계; 및

상기 세그먼트 별로 최대 변화도를 산출하여 데이터 정제를 수행하는 단계;

를 더 포함하는,

방법.

청구항 9

제 8 항에 있어서,

상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 단계는:

상기 세그먼트 별로 산출된 최대 변화도를 이용하여 상기 신뢰 계수를 산출하는 단계;

를 포함하는,

방법.

청구항 10

제 1 항에 있어서,

상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 획득하는 단계는:

상기 적어도 하나의 차량에 관한 신호, 상기 운전자의 뇌전도 신호 및 상기 적어도 하나의 생체 신호의 샘플링 레이트(sampling rate)를 통일시키기 위해 상기 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호의 샘플링 증대 또는 감소를 수행하는 단계; 및

상기 샘플링 증대 또는 감소된 상기 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 시간에 따라 사전 결정된 창 크기(window size)로 세그먼트 분할하는 단계;

를 더 포함하는,

방법.

청구항 11

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

차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 단계;

상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득하는 단계;

상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 단계;

시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 단계;

크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 단계;

상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 단계; 및

상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 단계;

를 포함하는,

컴퓨터 프로그램을 포함하는 비일시적 컴퓨터 판독 가능 매체.

청구항 12

운전자의 상태를 감지하기 위한 컴퓨팅 장치에 있어서,

프로세서; 및

메모리;

를 포함하고,

상기 프로세서는:

차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 동작;

상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득하는 동작;

상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 동작;

시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 동작;

크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 동작;

상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 동작; 및

상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 동작;

을 수행하는,

컴퓨팅 장치.

발명의 설명

기술 분야

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

배경 기술

[0002] 현대 사회에서 자동차는 사람들이 가장 보편적으로 이용하는 이동 수단이다. 현재 운전자에게 편의를 제공해 줄 수 있는 많은 운전 보조 기술들이 연구 및 개발되고 있지만, 차량 내에서 운전자의 안전을 보장해 줄 수 있는 기술이 필요하다. 도로 사고의 발생 요인으로는 운전자의 안전을 위협할 수 있는 외부적인 요인보다 운전자 본인의 부주의, 스트레스, 피로 등의 신체 및 정신적 상태의 문제에 대해 주로 발생한다. 따라서, 안전한 도로 주행을 위해서는 운전자 상태의 지속적인 모니터링이 필요하다.

[0003] 현재 자율주행 기술의 개발 및 상용화가 진행 중이기 때문에 자율주행 단계가 높아짐에 따라 차량 내에서 사람들이 질 높은 여가시간을 보낼 수 있는 시스템 또한 개발되어야 한다. 하지만 주행 상황과 차량 내 탑승자의 행동 및 인지 부조화로 멀미 및 스트레스가 발생할 수 있다. 이에 탑승자의 편안한 도로 주행을 위해서는 운행 중 탑승자의 지속적인 모니터링을 통해 차량과 주행에 대한 피드백을 주고받는 것이 중요하다.

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 감지하기 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 감지하기 위한 방법으로서, 차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 단계; 상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득하는 단계; 상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 단계; 시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 단계; 크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 단계; 상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 단계; 및 상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 단계;를 포함할 수 있다.

[0008] 대안적으로, 상기 적어도 하나의 차량에 관한 신호는, 가속도, 주행 방향 및 운전대 각도에 대한 신호를 포함할 수 있다.

[0009] 대안적으로, 상기 신뢰 계수를 산출하는 단계는: 구간별 변동성 추정식에 상기 가속도, 상기 주행 방향 및 상기 운전대 각도에 대한 신호를 대입함으로써, 상기 차량의 변동성에 관한 제 1 값을 산출하는 단계; 및 상기 신뢰 계수에 관한 비선형 함수식에 상기 제 1 값을 대입함으로써, 상기 신뢰 계수를 산출하는 단계;를 포함할 수 있다.

[0010] 대안적으로, 상기 신뢰 계수를 산출하는 단계는: 인공지능 기반의 분류 모델을 이용하여 상기 적어도 하나의 차량에 관한 신호로부터 상기 차량의 변동성에 관한 제 2 값을 산출하는 단계; 및 상기 신뢰 계수에 관한 비선형 함수식에 상기 제 2 값을 대입함으로써, 상기 신뢰 계수를 산출하는 단계;를 포함할 수 있다.

[0011] 대안적으로, 상기 적어도 하나의 생체 신호는, 심전도(Electrocardiogram, ECG), 맥파(Photoplethysmogram, PPG), 전기피부반응(Galvanic Skin Response, GSR) 및 호흡(Respiration, RSP)을 포함할 수 있다.

[0012] 대안적으로, 상기 시간적 특징 추출 모델은, 상기 뇌전도 신호에 대응되고, 그리고 뇌전도 신호와 관련된 학습 데이터를 이용하여 학습되는 제 1 시간적 특징 추출 서버 모델; 및 상기 적어도 하나의 생체 신호에 대응되고, 그리고 적어도 하나의 생체 신호와 관련된 학습 데이터를 이용하여 학습되는 제 2 시간적 특징 추출 서버 모델;을 포함할 수 있다.

[0013] 대안적으로, 상기 신뢰 계수는, 상기 시간적 특징 추출 모델 또는 상기 크로스 어텐션 모델 중 적어도 하나의 학습에 사용되는 손실함수에 적용될 수 있다.

[0014] 대안적으로, 상기 차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 단계는: 상기 적어도 하나의 차량에 관한 신호, 상기 운전자의 뇌전도 신호 및 상기 적어도 하나의 생체 신호의 샘플링 레이트(sampling rate)를 통일시키기 위해 상기 차량에 관한 신호의 샘플링 증대 또는 감소를 수행하는 단계; 상기 샘플링 증대 또는 감소된 적어도 하나의 차량에 관한 신호를 시간에 따라 사전 결정된 창 크기(window size)로 세그먼트 분할하는 단계; 및 상기 세그먼트 별로 최대 변화도를 산출하여 데이터 정제를 수행하는 단계;를 더 포함할 수 있다.

- [0015] 대안적으로, 상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 단계는: 상기 세그먼트 별로 산출된 최대 변화도를 이용하여 상기 신뢰 계수를 산출하는 단계;를 포함할 수 있다.
- [0016] 대안적으로, 상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 획득하는 단계는: 상기 적어도 하나의 차량에 관한 신호, 상기 운전자의 뇌전도 신호 및 상기 적어도 하나의 생체 신호의 샘플링 레이트(sampling rate)를 통일시키기 위해 상기 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호의 샘플링 증대 또는 감소를 수행하는 단계; 및 상기 샘플링 증대 또는 감소된 상기 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 시간에 따라 사전 결정된 창 크기(window size)로 세그먼트 분할하는 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 감지하기 위한 방법을 수행하도록 하며, 상기 방법은: 차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 단계; 상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득하는 단계; 상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 단계; 시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 단계; 크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 단계; 상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 단계; 및 상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 단계;를 포함할 수 있다.
- [0018] 본 개시의 일 실시예에 따른 운전자의 상태를 감지하기 위한 컴퓨팅 장치에 있어서, 프로세서; 및 메모리;를 포함하고, 상기 프로세서는: 차량으로부터 적어도 하나의 차량에 관한 신호를 획득하는 동작; 상기 차량의 운전자에 부착된 센서를 통해 상기 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득하는 동작; 상기 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출하는 동작; 시간적 특징 추출 모델을 이용하여 상기 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 동작; 크로스 어텐션(cross-attention) 모델을 이용하여 상기 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출하는 동작; 상기 신뢰 계수를 이용하여, 상기 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성하는 동작; 및 상태 분류 모델을 이용하여, 상기 생성된 융합 특징 정보로부터 상기 운전자의 상태 추정 정보를 획득하는 동작;을 수행할 수 있다.

발명의 효과

- [0019] 본 개시는 졸음, 부주의, 스트레스, 멀미와 같이 일반적으로 도로 주행 시 운전자와 탑승자에서 자주 발생하는 운전자의 상태를 딥러닝 기반 분석을 이용하여 감지하여 안전한 도로 주행이 가능한 운전자 보조시스템으로 이용될 수 있다.
- [0020] 본 개시는 운전자의 생체 신호를 실시간으로 분석하여 운전자가 경험하고 있는 상태를 파악하여 차량과 운전자 간에 피드백을 제공하여 운전자 맞춤형 운전 환경을 제공할 수 있다.
- [0021] 본 개시는 주행 중 생체신호 뿐 아니라 인공지능 기반의 다양한 멀티 모달리티 융합으로 확장될 수 있기 때문에 연구적인 측면에서 기여를 할 수 있다.
- [0022] 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

- [0023] 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 감지하기 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 감지하기 위한 방법을 나타낸 도면이다.

도 4a는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 특징 수준에서의 융합 과정을 간략하게 나타낸 도면이다.

도 4b는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 신호 수준에서의 융합 과정을 간략하게 나타낸 도면이다.

도 4c는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 결정 수준에서의 융합 과정을 간략하게 나타낸 도면이다.

도 5는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 감지하기 위한 인공지능 기반의 모델의 학습 과정을 나타낸 도면이다.

도 6은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 감지하는 과정을 나타낸 도면이다.

도 7은 본 개시의 실시예들이 구현될 수 있는 예시적인 컴퓨팅 환경에 대한 간략하고 일반적인 개략도를 도시한다.

발명을 실시하기 위한 구체적인 내용

[0024] 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.

[0025] 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.

[0026] 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.

[0027] 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.

[0028] 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.

[0029] 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.

- [0030] 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 실시예들로 한정되는 것이 아니다. 본 발명은 여기에 제시된 원리들 및 신규한 특징들과 일관되는 최광의의 범위에서 해석되어야 할 것이다.
- [0031] 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.
- [0032] 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.
- [0033] 본 개시에서, 사용자와 운전자는 동일한 의미(상호교환 가능한 의미)로 사용될 수 있다.
- [0034] 도 1은 본 개시의 일 실시예에 따른 운전자의 상태를 감지하기 위한 시스템을 설명하기 위한 도면이다.
- [0035] 도 1을 참조하면, 운전자의 상태를 감지하기 위한 시스템은 컴퓨팅 장치(100), 차량(200), 네트워크부(300) 등을 포함할 수 있다 운전자의 상태를 감지하기 위한 시스템의 구성은 간략화 하여 나타낸 예시일 뿐이다. 컴퓨팅 장치(100), 차량(200), 네트워크(300) 등의 구성 또한 간략화 하여 나타낸 예시일 뿐이다.
- [0036] 본 개시의 일 실시예에 따른 컴퓨팅 장치(100)는 운전자의 상태를 감지하기 위한 장치일 수 있다.
- [0037] 일 실시예에서, 컴퓨팅 장치(100)는 임의의 형태의 서버 또는 사용자 디바이스를 포함할 수 있다.
- [0038] 일 실시예에서, 컴퓨팅 장치(100)는 차량(200)으로부터 적어도 하나의 차량에 관한 신호 및/또는 차량(200)의 운전자에 부착된 센서를 통해 획득된 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 수신하고, 이에 대한 응답으로 운전자의 상태 추정 정보를 획득하고, 획득된 운전자의 상태 추정 정보를 차량(200)(또는, 사용자의 디바이스)에 전달할 수 있다.
- [0039] 일 실시예에서, 컴퓨팅 장치(100)는 차량(200)에 포함될 수 있다. 예를 들어, 컴퓨팅 장치(100)는 차량(200)의 내부에 존재하는 전자 제어장치에 대한 정보를 획득하고, 전자 제어장치에 대한 정보에 기초하여 차량에 관한 신호를 획득할 수 있다. 컴퓨팅 장치(100)는 획득된 차량에 관한 신호에 기초하여 획득된 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.
- [0040] 컴퓨팅 장치(100)는 프로세서(110), 메모리(130), 네트워크부(150)를 포함할 수 있다.
- [0041] 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.
- [0042] 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.
- [0043] 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.
- [0044] 본 개시의 일 실시예에서, 메모리(130)는 프로세서(110)가 생성하거나 결정한 임의의 형태의 정보 및/또는 네트

워크부(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 주행 정보, 차량 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.

- [0045] 본 개시에서 주행 정보는 차량의 주행에 관한 정보일 수 있다. 예를 들어, 주행 정보는 차량의 주행 여부, 주행 시간, 주행 거리 등을 포함할 수 있다.
- [0046] 본 개시에서 차량 데이터는 차량의 주행 중에 획득되는 데이터일 수 있다. 예를 들어, 차량 데이터는 가속도, 주행 방향, 운전대 각도 등을 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), 심전도(Electrocardiogram, ECG), 맥파(Photoplethysmogram, PPG), 전기피부반응(Galvanic Skin Response, GSR), 호흡(Respiration, RSP) 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

입력의 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 가변될 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 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 n 인 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 최종 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 개수보다 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, 삼 네트워크 등을 포함할 수 있다. 전술한 딥 뉴럴 네트워크의 기제는 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 방향으로 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 방향으로) 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 활성화 함수(activation function), 신경망의 학습을 위한 손실 함수(loss 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 활성화 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 발생하는 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 발생하는 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 가변될 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. 전술한 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 사용자에게 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 있

다.

[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) t 를 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 타임 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

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

$$\varepsilon \sim N(0, I)$$

[0092] 상기 수학식 1에서 β_t 는 하이퍼 파라미터로써 확산 계수를 계산하는 과정에서 이용될 수 있고, β_t 는 임의의 값으로 설정될 수 있으며 $0 < \beta_1 < \beta_2 < \dots < \beta_T < 1$ 의 값으로 설정될 수 있다. 예를 들어 β_1 이 0.0001의 값을 가지고 β_T 가 0.02의 값을 가질 수 있고, β_1 부터 β_T 까지 β_t 의 값은 선형적으로(linear) 증가할 수 있고, 코사인 함수를 따라 증가할 수 있으며, 총 확산 스텝 수를 의미하는 T는 1000으로 설정될 수 있다. 다만, β_t 가 선형적으로 또는 코사인 함수를 따라 증가되는 것은 예시에 불과할 뿐, 본 개시의 실시예들에 따르면 상기 원본 데이터의 종류에 따라 β_t 의 증가량이 다르게 결정될 수 있으며, 구체적인 설명은 이하 [수학식 2]를 통해 후술된다.

또한, ε 은 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

$$\alpha_t = 1 - \beta_t \quad \dots (1)$$

$$\bar{\alpha}_t = \prod_{i=1}^t \alpha_i \quad \dots (2)$$

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \varepsilon \quad \dots (3)$$

$$n_t = \sqrt{1 - \bar{\alpha}_t}, s_t = \sqrt{\bar{\alpha}_t} \quad \dots (4)$$

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 계수 α_t 는 1에서 상기 하이퍼 파라미터 β_t 를 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. 따라서, 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.

예를 들어, 컴퓨팅 장치(100)는 노이즈가 포함되지 않은 원본 데이터 x(0)에 대하여 T번의 타임 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.

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 타임 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.

또한, 컴퓨팅 장치(100)는 상기 정방향 과정과 반대 방향으로 등방성 가우시안 분포 노이즈x(T)(isotropic gaussian distributed noise)에 대하여 T번의 타임 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

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(x_t, t) \right) + \sigma_t \epsilon \quad \dots (1)$$

$$\alpha_t = \frac{\bar{\alpha}_t}{\bar{\alpha}_{t-1}} \quad \dots (2)$$

$$\sigma_t = 1 - \frac{\bar{\alpha}_t}{\bar{\alpha}_{t-1}} \quad \dots (3)$$

상기 수학식 3에서 (1)번 식은 "노이즈가 포함된 데이터 x(t)"에 대하여 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과($\epsilon_\theta(x_t, t)$)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 계수 α_t 를 의미하고, 상

기 수학적식 3에서 (3)번 식에서 ϵ 는 분산 파라미터를 의미하고, 확산 계수 α_t 에 기초하여 계산될 수 있다. 다만, 상기 역방향 과정은 상기 [수학적식 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 t 를 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.

수학적식 4

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

[0107]
$$x_t = \sqrt{\alpha_t}x_0 + \sqrt{1 - \alpha_t}\epsilon$$

[0108] 상기 [수학적식 4]에서 손실 함수는 실제로 포함된 확산 노이즈(diffusion noise) (ϵ)과 상기 뉴럴 네트워크가 예측한 노이즈 예측 결과($\epsilon_\theta(x_t, t)$)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 수학적식 4의 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 수학적식을 통해 결정될 수 있다.

수학식 5

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

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

[0114] 구체적으로, 본 개시의 일 실시예에 따라 상기 [수학식 5]에서 (1)번 식을 참조하면 노이즈의 비율 $n(t)$ 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, r 은 상기 노이즈 비율 $n(t)$ 및 상기 시그널 비율 $s(t)$ 의 곡선의 형태(shape)를 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 6을 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 감지하기 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 차량(200)으로부터 적어도 하나의 차량에 관한 신호를 획득할 수 있다(310). 적어도 하나의 차량에 관한 신호는 엔진 및 변속기의 압력, 가속도, 자이로 센서 등으로 수집될 수 있는 차량의 신호를 포함할 수 있다. 예를 들어, 적어도 하나의 차량에 관한 신호는 가속도, 주행 방향 및 운전대 각도에 대한 신호를 포함할 수 있다.

[0120] 일 실시예에서, 프로세서(110)는 적어도 하나의 차량에 관한 신호를 전처리할 수 있다.

[0121] 예를 들어, 프로세서(110)는 적어도 하나의 차량에 관한 신호, 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호의 샘플링 레이트(sampling rate)를 통일시키기 위해 차량에 관한 신호의 샘플링 증대 또는 감소를 수행할 수 있다. 예를 들어, 프로세서(110)는 샘플링 레이트를 통일시키기 위해, 차량에 관한 신호인 가속도, 주행 방향, 운전대 각도에 대한 신호 각각에 대해서 샘플링 증대 또는 감소를 수행할 수 있다. 샘플링 레이트는 아날로그 신호를 디지털로 변환하기 위해 초당 샘플을 수치로 표현한 것을 의미할 수 있다.

[0122] 프로세서(110)는 샘플링 증대 또는 감소된 적어도 하나의 차량에 관한 신호를 시간에 따라 사전 결정된 창 크기(window size)로 세그먼트 분할할 수 있다.

[0123] 프로세서(110)는 세그먼트 별로 최대 변화도를 산출하여 데이터 정제를 수행할 수 있다. 데이터 정제는 작업을 수행하는데 있어서 해당 데이터를 바로 사용할 수 있게 정리하는 일련의 작업을 의미할 수 있다. 따라서, 프로세서(110)는 세그먼트 별로 최대 변화도를 산출하여 데이터 정제를 수행함으로써, 정제된 세그먼트 별 최대 변화도를 이용하여 추후에 수행되는 신뢰 계수의 산출을 효율적으로 빠르게 수행할 수 있다.

[0124] 한편, 프로세서(110)는 차량의 운전자에 부착된 센서를 통해 운전자의 뇌전도(Electroencephalogram, EEG) 신호 및 적어도 하나의 생체 신호를 획득할 수 있다(320). 적어도 하나의 생체 신호는 인체의 활성을 나타내는 징후를 측정된 기록을 의미할 수 있다. 예를 들어, 적어도 하나의 생체 신호는 심전도(Electrocardiogram, ECG), 맥파(Photoplethysmogram, PPG), 전기피부반응(Galvanic Skin Response, GSR), 호흡(Respiration, RSP) 등을 포함할 수 있다. 일 실시예에서, 적어도 하나의 생체 신호는 뇌전도 신호를 제외한 나머지 생체 신호일 수 있다.

[0125] 일 실시예에서, 프로세서(110)는 뇌전도 신호 및 적어도 하나의 생체 신호를 전처리할 수 있다.

[0126] 예를 들어, 프로세서(110)는 적어도 하나의 차량에 관한 신호, 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호의 샘플링 레이트(sampling rate)를 통일시키기 위해 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호의 샘플링

플링 증대 또는 감소를 수행할 수 있다.

[0127] 프로세서(110)는 샘플링 증대 또는 감소된 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호를 시간에 따라 사전 결정된 창 크기(window size)로 세그먼트 분할할 수 있다.

[0128] 프로세서(110)는 필터링을 통해 운전자의 뇌전도 신호 및 적어도 하나의 생체 신호의 노이즈를 제거할 수 있다. 예를 들어, 필터링은 특정 진동수 이상을 차단하는 low-pass 필터링, 특정 진동수 이하를 차단하는 high-pass 필터링, 특정 진동수 사이만 통과시키는 band-pass 필터링, 특정 진동수 사이만 차단하는 band-stop 필터링 등을 포함할 수 있다.

[0129] 한편, 프로세서(110)는 적어도 하나의 차량에 관한 신호로부터 신뢰 계수를 산출할 수 있다(330).

[0130] 프로세서(110)는 세그먼트 별로 산출된 최대 변화도를 이용하여 신뢰 계수를 산출할 수 있다.

[0131] 일 실시예에서, 프로세서(110)는 구간별 변동성 추정식에 가속도, 주행 방향 및 운전대 각도에 대한 신호를 대입함으로써, 차량의 변동성에 관한 제 1 값을 산출할 수 있다.

[0132] 구간별 변동성 추정식은 아래의 수학식 6에 대응될 수 있으나, 이에 한정되지 않고 다양한 추정식을 사용할 수 있다.

수학식 6

$$k_i = \max \left(\frac{x_i^{ACC}}{Avg(x^{ACC})}, \frac{x_i^{ANG}}{Avg(x^{ANG})}, \frac{x_i^{YAW}}{Avg(x^{YAW})} \right)$$

[0133]

[0134] k_i 는 제 1 값으로, 차량의 최대 변화율에 대응될 수 있다. x_i^{ACC} 는 차량의 가속도를 나타내는 값일 수 있다. x_i^{ANG} 는 운전대 각도를 나타내는 값일 수 있다. x_i^{YAW} 는 주행 방향을 나타내는 값일 수 있다.

[0135] 프로세서(110)는 신뢰 계수에 관한 비선형 함수식에 제 1 값을 대입함으로써, 신뢰 계수를 산출할 수 있다.

[0136] 비선형 함수식은 아래의 수학식 7에 대응될 수 있으나, 이에 한정되지 않고 다양한 함수식을 사용할 수 있다.

수학식 7

$$\lambda_i = \begin{cases} 1, & k_i^{ACC} < 1 \\ 1 - \tan(\alpha \cdot k_i), & k_i^{ACC} \geq 1 \end{cases}$$

[0137]

[0138] λ_i 는 신뢰 계수일 수 있다. k_i 는 제 1 값으로, 차량의 최대 변화율에 대응될 수 있다. α 는 신뢰 계수의 조절을 위한 하이퍼 파라미터일 수 있다. α 는 사전에 결정되어 있거나 상황에 따라 사용자에게 의해 결정될 수 있다.

[0139] 신뢰 계수(λ)는 뇌전도 신호 및 적어도 하나의 생체 신호의 정보, 손실을 조정하기 위한 계수일 수 있다. 예를 들어, 신뢰 계수는 시간적 특징 추출 모델 또는 크로스 어텐션 모델 중 적어도 하나의 학습에 사용되는 손실 함수에 적용될 수 있다. 따라서, 프로세서(110)는 신뢰 계수에 따라 해당 시점의 뇌전도 신호와 적어도 하나의 생체 신호의 정보의 특징 및 손실함수의 가중치를 조절하여 상이한 모달리티들의 특성 및 처리를 고려하는 적응형 멀티모달 융합을 수행할 수 있다. 다른 예를 들어, 신뢰 계수는 노이즈에 취약한 뇌 신호(예를 들어, 뇌전도 신호)의 가중치를 낮추기 위해 적용되는 계수일 수 있다.

[0140] 일 실시예에서, 프로세서(110)는 인공지능 기반의 분류 모델을 이용하여 적어도 하나의 차량에 관한 신호로부터

차량의 변동성에 관한 제 2 값을 산출할 수 있다.

- [0141] 인공지능 기반의 분류 모델은 차량에 관한 신호로부터 차량의 변동성에 관한 값을 추정하도록 비지도 학습(예를 들어, 클러스터링(clustering) 등)을 통해 학습되는(또는 사전 학습된) 인공지능 기반의 모델에 대응될 수 있다.
- [0142] 프로세서(110)는 신뢰 계수에 관한 비선형 함수식에 제 2 값을 대입함으로써, 신뢰 계수를 산출할 수 있다. 예를 들어, 프로세서(110)는 상술한 수학식 7에서 제 1 값 대신 제 2 값을 사용함으로써, 신뢰 계수를 산출할 수 있다.
- [0143] 프로세서(110)는 시간적 특징 추출 모델을 이용하여 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출할 수 있다(340).
- [0144] 시간적 특징 추출 모델은 제 1 시간적 특징 추출 서브 모델, 제 2 시간적 특징 추출 서브 모델 등을 포함할 수 있다.
- [0145] 제 1 시간적 특징 추출 서브 모델은 뇌전도 신호에 대응되고, 그리고 뇌전도 신호와 관련된 학습 데이터를 이용하여 학습(또는 사전 학습)될 수 있다. 예를 들어, 제 1 시간적 특징 추출 서브 모델은 뇌전도 신호에 대한 시간적 특징을 추출하도록 학습되는(또는 사전 학습된) RNN, CNN 등의 딥 뉴럴 네트워크에 대응될 수 있다. 따라서, 프로세서(110)는 제 1 시간적 특징 추출 서브 모델을 이용하여 뇌전도 신호에 대한 시간적 특징을 추출할 수 있다.
- [0146] 제 2 시간적 특징 추출 서브 모델은 적어도 하나의 생체 신호에 대응되고, 그리고 적어도 하나의 생체 신호와 관련된 학습 데이터를 이용하여 학습(또는 사전 학습)될 수 있다. 예를 들어, 제 2 시간적 특징 추출 서브 모델은 적어도 하나의 생체 신호에 대한 시간적 특징을 추출하도록 학습되는(또는 사전 학습된) RNN, CNN 등의 딥 뉴럴 네트워크에 대응될 수 있다. 따라서, 프로세서(110)는 제 2 시간적 특징 추출 서브 모델을 이용하여 적어도 하나의 생체 신호에 대한 시간적 특징을 추출할 수 있다.
- [0147] 프로세서(110)는 크로스 어텐션(cross-attention) 모델을 이용하여 추출된 각각의 시간적 특징으로부터 상호적 특징을 추출할 수 있다(350).
- [0148] 크로스 어텐션 모델은 크로스 어텐션 메커니즘을 이용하는 모델에 대응될 수 있다. 어텐션(Attention) 메커니즘은 쿼리(Q, query), 키(K, Key), 밸류(V, value)를 입력으로 받는 연산일 수 있다. 쿼리는 영향을 받는 이미 가지고 있는 정보일 수 있다. 키와 밸류는 영향을 주는 참고할 정보일 수 있다. 따라서 프로세서(110)는 어텐션 메커니즘을 적용함으로써, 쿼리에 따라 키를 주목하여 밸류를 가중합하고 결과적으로 쿼리에 키와 밸류의 정보를 혼합시킬 수 있다. 프로세서(110)는 크로스 어텐션(cross-attention)을 사용함으로써, 다중 모달리티들의 특징들에 대해 연산하여 모달리티들의 관련 정보를 지니는 특징을 추출할 수 있다. 프로세서(110)는 각기 다른 모달리티들의 특징 벡터를 쿼리와 키로 교차 사용하는 크로스 어텐션을 적용함으로써, 연산 후 각 모달리티마다 상이한 하나의 어텐션 임베딩을 갖도록 할 수 있다.
- [0149] 모달리티는 정보, 데이터 등의 유형을 의미할 수 있다. 예를 들어, 오디오 데이터를 다루는 것은 '오디오 모달리티', 텍스트 데이터는 '텍스트 모달리티', 이미지는 '시각 모달리티'라고 할 수 있다. 각 모달리티는 그에 맞는 분석 알고리즘과 처리 방법을 요구하며, 이를 통해 데이터의 본질적인 특성과 정보를 추출할 수 있다. 일 실시예에서, 모달리티는 뇌전도 신호, 적어도 하나의 생체 신호 등을 포함할 수 있다.
- [0150] 어텐션 메커니즘은 아래의 수학식 8에 대응될 수 있으나, 이에 한정되지 않고 다양한 식을 사용할 수 있다.

수학식 8

$$Attention(Q, K, V) = softmax(\frac{QK^T}{\sqrt{d_k}})V$$

[0151]

- [0152] 크로스 어텐션 메커니즘은 아래의 수학식 9에 대응될 수 있으나, 이에 한정되지 않고 다양한 식을 사용할 수 있다.

수학식 9

$$CrossAttention(Q, K, V) = softmax(\frac{Q_i K_j^T}{\sqrt{d_k}}) V_j$$

[0153]

수학식 8 및 9에서 각 기호의 설명은 아래와 같을 수 있다.

$$Q = QW^Q, Q: \text{query}$$

$$K = KW^K, K: \text{key}$$

$$V = VW^V, V: \text{value}$$

d_k : key의 차원

W : 가중치 행렬

$softmax(\cdot)$: 다중 클래스 분류를 위한 활성화 함수

$$Q_i = QW_i^Q, Q_i: i\text{번째 모달리티의 query}$$

$$K_j = KW_j^K, K_j: j\text{번째 모달리티의 key}$$

$$V_j = VW_j^V, V_j: j\text{번째 모달리티의 value}$$

[0155]

[0156]

프로세서(110)는 신뢰 계수를 이용하여, 추출된 각각의 상호적 특징에 가중치를 반영한, 융합 특징 정보를 생성할 수 있다(360).

[0157]

프로세서(110)는 신뢰 계수를 기반으로 각 생체신호의 정보 및 손실에 가중치를 달리 줄 수 있다. 신뢰 계수를 기반으로 한 가중치 조절은 EEG 신호 뿐 아니라 다른 생체 신호들에도 다양한 방법으로 적용할 수 있으며, 노이즈에 취약한 뇌전도 신호에만 직접적으로 가중치 조절하는 간단한 예시는 아래의 수학식 10을 참고할 수 있다.

수학식 10

$$x_i^{total} = \lambda x_i^{EEG} + (x_i^{ECG} + x_i^{PPG} + x_i^{GSR} + x_i^{RSP})$$

$$s_i^{total} = \lambda s_i^{EEG} + (s_i^{ECG} + s_i^{PPG} + s_i^{GSR} + s_i^{RSP})$$

$$p_i^{total} = \lambda p_i^{EEG} + (p_i^{ECG} + p_i^{PPG} + p_i^{GSR} + p_i^{RSP})$$

[0158]

[0159]

x_i 는 원본 신호일 수 있다. 예를 들어, x_i 는 전 처리된 원본 신호일 수 있다. s_i 는 $G(F(x_i))$ 일 수 있다.

p_i 는 $C(s_i)$ 일 수 있다. $F(\cdot)$ 는 뇌전도 신호 및 적어도 하나의 생체 신호 각각에 대한 시간적 특징을 추출하는 시간적 특징 추출 모델일 수 있다. $G(\cdot)$ 는 시간적 특징으로부터 뇌전도 신호 및 적어도 하나의 생체

신호 간에 연관정보 특징인 상호적 특징을 추출하는 크로스 어텐션 모델일 수 있다. $C(\cdot)$ 는 상호적 특징으로부터 운전자의 상태 추정 정보를 획득하는 상태 분류 모델일 수 있다. 해당 수학식에서는 융합 수준에 따라서 early-fusion(수학식 10의 맨 위에 1번째 식에 대응), mid-fusion(수학식 10의 맨 위에서 2번째 식에 대응), late-fusion(수학식 10의 맨 위에서 3번째 식에 대응) 총 3가지 방법들을 보여준다. early-fusion은 모달리티들의 생체 신호를 각각 입력으로 하여 신호 수준에서 결합하는 것을 의미할 수 있다. mid-fusion은 신경망(예를

들어, 시간적 특징 추출 모델, 크로스 어텐션 모델 등)을 통해 추출된 특징들을 특징 수준에서 결합하는 방법일 수 있다. late-fusion은 분류기(예를 들어, 상태 분류 모델)의 출력인 결정수준에서 결합하여 최종 분류를 수행하는 것을 의미할 수 있다.

[0160] 신뢰 계수(λ)는 아래의 수학적 식 11과 같이 생체 신호 각각의 네트워크 학습에 사용되는 손실함수에도 적용할 수 있다.

수학적 식 11

$$[0161] \mathcal{L}_i^{total} = \lambda \mathcal{L}_i^{EEG} + (\mathcal{L}_i^{ECG} + \mathcal{L}_i^{PPG} + \mathcal{L}_i^{GSR} + \mathcal{L}_i^{RSP})$$

[0162] $\mathcal{L}_i$ 는 i 번째 데이터에 해당하는 손실함수일 수 있다. 일 실시예에서, 프로세서(110)는 신뢰 계수를 이용하여, 손실함수 및 정보 조절 시 뇌전도를 제외한 다른 생체 신호에도 가중치 조절을 수행할 수 있다. 신뢰 계수를 적용할 생체 신호는 사용자에게 의해 결정될 수 있다.

[0163] 프로세서(110)는 상태 분류 모델을 이용하여, 생성된 융합 특징 정보(예를 들어, 벡터 형태의 데이터 등)로부터 운전자의 상태 추정 정보를 획득할 수 있다(370).

[0164] 상태 분류 모델은 융합 특징 정보와 관련된 학습 데이터를 이용하여 학습되는(또는 사전 학습된) 인공지능 기반의 모델에 대응될 수 있다. 예를 들어, 상태 분류 모델은 뇌전도 신호 및 적어도 하나의 생체 신호에 정답(운전자의 상태 정보)이 라벨링되어 있는 학습 데이터(즉, 라벨링된 학습 데이터)를 이용하여 학습(또는, 사전 학습)될 수 있다.

[0165] 운전자의 상태 추정 정보는 운전자의 현재 상태에 대한 정보로, 복수의 클래스(class)들(예를 들어, 정상, 졸음, 수면, 멀미, 스트레스 등) 중에서 하나의 클래스에 해당되는 정보를 포함할 수 있다. 따라서, 프로세서(110)는 운전자의 상태 추정 정보를 통해 운전자의 현재 상태를 결정할 수 있다. 프로세서(110)는 네트워크부(150) 이용하여 운전자의 상태 추정 정보 또는 결정된 운전자의 현재 상태를 차량(200) 및/또는 사용자의 디바이스(미도시)에 전송할 수 있다.

[0167] 이하에서 도 4a 내지 도 6을 참조하여 앞서 상술된 컴퓨팅 장치(100)에 의해 수행되는 운전자의 상태를 감지하기 위한 방법에 대한 일 실시예를 추가적으로 후술한다.

[0168] 도 4a 내지 도 6을 참조하여 후술되는 내용 중에서 중복되는 내용은 생략될 수 있다. 또한, 도 4a 내지 도 6을 참조하여 후술되는 내용 중에서 각 구성 및 방법(모델, 시간적 특징, 상호적 특징, 전처리 방법, 시간적 특징의 추출 방법, 상호적 특징의 추출 방법, 신뢰 계수의 산출 방법 등)에 대한 구체적인 설명은 도 1 내지 도 3을 참조하여 상술된 내용으로 대체될 수 있다.

[0169] 도 4a 내지 도 4c는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 각 수준에서의 융합 과정을 나타낸 도면이다. 도 4a 내지 도 4c를 참조하면, 컴퓨팅 장치(100)는 생체 신호와 뇌 신호(예를 들어, 뇌전도 신호 등)를 획득하여 실시간으로 전처리 및 특징 추출을 진행하며, 시간적인 특징과 모달리티들간 연관성 높은 특징 임베딩을 출력할 수 있다. 컴퓨팅 장치(100)는 차량 데이터를 이용하여 뇌 신호 정보의 신뢰도를 계산하기 위한 신뢰 계수를 산출할 수 있다. 컴퓨팅 장치(100)는 산출된 신뢰 계수를 여러 생체 신호들의 융합 과정에서 사용할 수 있다.

[0170] 도 4a는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 특징 수준에서의 융합 과정을 간략하게 나타낸 도면이다.

[0171] 도 4a를 참조하면, 컴퓨팅 장치(100)는 특징 수준에서 각 신호에 대한 정보의 융합을 수행할 수 있다.

[0172] 예를 들어, 컴퓨팅 장치(100)의 프로세서(110)는 뇌 신호(예를 들어, 뇌전도 신호)(410), 뇌전도 신호 이외의 적어도 하나의 생체 신호(420) 및 차량 데이터(430)를 획득할 수 있다. 프로세서(110)는 뇌 신호(410)를 전처리하고, 시간적 특징을 추출하고, 상호적 특징을 추출할 수 있다. 프로세서(110)는 적어도 하나의 생체 신호(42

0)를 전처리하고, 시간적 특징을 추출하고, 상호적 특징을 추출할 수 있다. 프로세서(110)는 차량 데이터(430)를 전처리하고, 신뢰 계수를 산출할 수 있다. 프로세서(110)는 뇌 신호(410) 및 적어도 하나의 생체 신호(420) 각각의 상호적 특징을 융합하는 과정에서 산출된 신뢰 계수를 이용할 수 있다. 예를 들어, 프로세서(110)는 각각의 상호적 특징에 신뢰 계수를 반영한 가중치를 적용할 수 있다. 프로세서(110)는 각각의 상호적 특징에 신뢰 계수를 반영한 가중치를 적용하여 합친 융합 특징 정보를 상태 분류 모델에 입력하고, 상태 분류 모델로부터 출력되는 운전자의 상태 추정 정보를 획득할 수 있다.

[0173] 도 4b는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 신호 수준에서의 융합 과정을 간략하게 나타낸 도면이다.

[0174] 도 4b를 참조하면, 컴퓨팅 장치(100)는 신호 수준에서 각 신호에 대한 정보의 융합을 수행할 수 있다.

[0175] 예를 들어, 컴퓨팅 장치(100)의 프로세서(110)는 뇌 신호(예를 들어, 뇌전도 신호)(440), 뇌전도 신호 이외의 적어도 하나의 생체 신호(450) 및 차량 데이터(460)를 획득할 수 있다. 프로세서(110)는 뇌 신호(440)를 전처리할 수 있다. 프로세서(110)는 적어도 하나의 생체 신호(450)를 전처리할 수 있다. 프로세서(110)는 차량 데이터(460)를 전처리하고, 신뢰 계수를 산출할 수 있다. 프로세서(110)는 전처리된 뇌전도 신호(440) 및 전처리된 적어도 하나의 생체 신호(450)를 융합하는 과정에서 산출된 신뢰 계수를 이용할 수 있다. 예를 들어, 프로세서(110)는 각각의 신호에 신뢰 계수를 반영한 가중치를 적용할 수 있다. 프로세서(110)는 신뢰 계수를 이용하여 융합된 신호에서 시각적 특징 추출 모델을 이용하여 시간적 특징을 추출할 수 있다. 프로세서(110)는 단일 모달리티의 관련도를 보는 셀프 어텐션(self-attention) 모델을 이용하여 시간적 특징으로부터 상호적 특징을 추출, 획득할 수 있다. 프로세서(110)는 상태 분류 모델을 이용하여 상호적 특징으로부터 운전자의 상태 추정 정보를 획득할 수 있다.

[0176] 도 4c는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 결정 수준에서의 융합 과정을 간략하게 나타낸 도면이다.

[0177] 도 4c를 참조하면, 컴퓨팅 장치(100)는 결정 수준에서 각 신호에 대한 정보의 융합을 수행할 수 있다.

[0178] 예를 들어, 컴퓨팅 장치(100)의 프로세서(110)는 뇌 신호(예를 들어, 뇌전도 신호)(470), 뇌전도 신호 이외의 적어도 하나의 생체 신호(480) 및 차량 데이터(490)를 획득할 수 있다. 프로세서(110)는 뇌 신호(470)의 전처리 과정, 전처리된 뇌 신호로부터 시간적 특징을 추출하는 과정, 시간적 특징으로부터 상호적 특징을 추출하는 과정, 상호적 특징으로부터 운전자 상태를 추정하는 과정을 수행할 수 있다. 프로세서(110)는 적어도 하나의 생체 신호(480)의 전처리 과정, 전처리된 뇌 신호로부터 시간적 특징을 추출하는 과정, 시간적 특징으로부터 상호적 특징을 추출하는 과정, 상호적 특징으로부터 운전자 상태를 추정하는 과정을 수행할 수 있다. 프로세서(110)는 차량 데이터(490)를 전처리하고, 신뢰 계수를 산출할 수 있다. 프로세서(110)는 뇌 신호(470)로부터 추정된 운전자 상태 및 적어도 하나의 생체 신호(480)로부터 추정된 운전자 상태를 융합하는 과정에서 산출된 신뢰 계수를 이용할 수 있다. 예를 들어, 프로세서(110)는 각각의 운전자 상태에 신뢰 계수를 반영한 가중치를 적용할 수 있다. 프로세서(110)는 각각의 운전자 상태에 신뢰 계수를 반영한 가중치를 적용함으로써, 가중치가 반영되어 융합된 운전자의 최종 상태 추정 정보를 획득할 수 있다.

[0180] 도 5는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 감지하기 위한 인공지능 기반의 모델의 학습 과정을 나타낸 도면이다. 도 5는 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 특징 수준에서 각 신호에 대한 정보의 융합을 나타낸 도면일 수 있다. 일 실시예에서, 도 5에서 수행되는 인공지능 기반의 모델의 학습은 오프라인에서 수행될 수 있다.

[0181] 도 5를 참조하면, 컴퓨팅 장치(100)의 프로세서(110)는 학습 데이터를 입력, 획득할 수 있다(501). 예를 들어, 프로세서(110)는 메모리(130)에 사전 저장된 차량에 관한 신호, 운전자의 뇌 신호(예를 들어, 뇌전도 신호 등), 적어도 하나의 생체 신호, 라벨링 정보 등을 학습 데이터로 입력, 획득할 수 있다. 라벨링 정보는 운전자의 뇌 신호(예를 들어, 뇌전도 신호 등) 및 적어도 하나의 생체 신호에 운전자의 상태가 시간별 및/또는 구간별로 라벨링되어 있는 정보일 수 있다. 다른 예를 들어, 프로세서(110)는 외부 기기(예를 들어, 사용자 디바이스, 차량 등)로부터 차량에 관한 신호, 운전자의 뇌 신호(예를 들어, 뇌전도 신호 등), 적어도 하나의 생체 신호, 라벨링 정보 등을 학습 데이터로 수신할 수 있다.

[0182] 프로세서(110)는 차량에 관한 신호의 획득 및 전처리를 수행할 수 있다(502).

- [0183] 프로세서(110)는 전처리된 차량에 관한 신호를 이용하여 차량의 변동성을 계산할 수 있다(503).
- [0184] 프로세서(110)는 차량의 변동성을 이용하여 신뢰 계수를 계산할 수 있다(504).
- [0185] 프로세서(110)는 적어도 하나의 생체 신호를 획득하고, 전처리를 수행할 수 있다(505).
- [0186] 프로세서(110)는 사용자 평가 기반의 상태에 관한 정보(또는, 정의 이벤트에 따라 정량적으로 산정된 상태에 관한 정보)의 라벨링을 수행할 수 있다(506).
- [0187] 프로세서(110)는 운전자의 상태 정보가 라벨링된 생체 신호를 이용하여 인공지능 기반의 모델을 포함하는 네트워크 함수를 학습시킬 수 있다(507).
- [0188] 프로세서(110)는 학습된 인공지능 기반의 모델의 가중치를 메모리(130), 외부 저장소 등에 저장할 수 있다(508). 따라서, 프로세서(110)는 운전자의 상태를 분류하는 경우, 사전 저장된 가중치를 가지는 사전 학습된 인공지능 기반의 모델을 이용할 수 있다.
- [0190] 도 6은 본 개시의 일 실시예에 따른 컴퓨팅 장치에서 수행되는, 운전자의 상태를 감지하는 과정을 나타낸 도면이다.
- [0191] 컴퓨팅 장치(100)의 프로세서(110)는 차량의 주행이 시작되는 경우(601) fine-tuning의 수행 여부를 결정할 수 있다. 예를 들어, 프로세서(110)는 차량에 탑승한 운전자의 정보가 메모리(130)에 저장되어 있는 경우, 운전자의 정보(예를 들어, 사전 저장된 운전자의 차량에 관한 신호, 운전자의 뇌 신호(예를 들어, 뇌전도 신호 등), 운전자의 적어도 하나의 생체 신호, 라벨링 정보 등)에 기초하여 fine-tuning의 수행을 진행하는 것으로 결정할 수 있다. 다른 예를 들어, 프로세서(110)는 차량에 탑승한 운전자의 정보가 메모리(130)에 저장되어 있지 않은 경우, fine-tuning을 수행하지 않는 것으로 결정할 수 있다. 다만, fine-tuning의 수행 여부를 결정하는 방법에는 이에 한정되지 않으며, 다양한 기준을 통해 결정될 수 있다.
- [0192] 프로세서(110)는 fine-tuning을 수행하는 것으로 결정(602, Yes)한 경우, 운전자의 정보에 기초하여 fine-tuning을 수행할 수 있다(603). 프로세서(110)는 fine-tuning된 모델을 이용하여 추론을 수행할 수 있다. fine-tuning이란 오프라인 학습에서 저장된 모델과 가중치를 불러와 시스템 사용자의 데이터로 추가적인 학습을 하는 것을 의미할 수 있다. fine-tuning을 위해서는 학습 데이터의 레이블이 필요하므로, 컴퓨팅 장치(100)는 사용자로부터 사용자 본인의 상태에 대해 주행 중 주관적인 상태 평가에 대한 문진 정보를 직접 입력 받거나 사용자 디바이스를 통해 수신할 수 있다. 이후 흐름은 도 5의 학습 흐름도와 동일할 수 있다. 학습이 끝나면 저장된 모델의 네트워크와 가중치를 기반으로 실시간 입력 생체신호들과 차량 센서 데이터로 사용자의 상태 분류를 수행할 수 있다.
- [0193] 프로세서(110)는 fine-tuning을 수행하지 않는 것으로 결정(602, No)한 경우, 사전 학습된 인공지능 기반의 모델을 이용하여 추론을 수행할 수 있다.
- [0194] 프로세서(110)는 fine-tuning을 수행하는 과정과 수행하지 않고 바로 추론하는 과정 모두 실시간으로 획득된 신호들을 입력할 수 있다. 최대 변화도 기반 차량 변동성을 계산할 때 필요한 평균 변화도는 현재 입력되고 있는 데이터의 시점을 기점으로 이전 구간들을 사용하거나, 혹은 오프라인 학습 과정에서 사용한 데이터를 사용할 수 있다.
- [0195] 프로세서(110)는 차량에 관한 신호의 획득 및 전처리를 수행할 수 있다(604).
- [0196] 프로세서(110)는 전처리된 차량에 관한 신호를 이용하여 차량의 변동성을 계산할 수 있다(605).
- [0197] 프로세서(110)는 차량의 변동성을 이용하여 신뢰 계수를 계산할 수 있다(606).
- [0198] 프로세서(110)는 적어도 하나의 생체 신호를 획득하고, 전처리를 수행할 수 있다(607).
- [0199] 프로세서(110)는 사전 학습된 모델(608)을 이용하여 운전자의 상태 추정 정보를 획득하는 추론을 수행할 수 있다(609). 여기서, 사전 학습된 모델은 fine-tuning을 수행한 경우, fine-tuning이 된 인공지능 기반의 모델일 수 있다. 사전 학습된 모델은 fine-tuning을 수행하지 않은 경우, 기존에 학습 후 저장되어 있는 인공지능 기반의 모델일 수 있다.
- [0200] 프로세서(110)는 운전자의 상태 추정 정보를 통해 운전자의 현재 상태를 분류 및 피드백을 수행할 수 있다

(610). 피드백은 차량 내 탑승한 사용자의 졸음, 멀미 및 스트레스 등 다양한 상태 추정을 분류하여 효율적인 사용자 맞춤형 주행을 가능하도록 정보를 제공하는 것을 의미할 수 있다.

[0201] 도 1 내지 6을 참조하여 상술한 바와 같이, 본 개시의 일 실시예에 따른 컴퓨팅 장치(100)는 졸음, 부주의, 스트레스, 멀미와 같이 일반적으로 도로 주행 시 운전자와 탑승자에서 자주 발생하는 운전자의 상태를 딥러닝 기반 분석을 이용하여 감지하여 안전한 도로 주행이 가능한 운전자 보조시스템을 제공할 수 있다.

[0202] 컴퓨팅 장치(100)는 운전자의 생체 신호를 실시간으로 분석하여 운전자가 경험하고 있는 상태를 파악하여 차량과 운전자 간에 피드백을 제공하여 운전자 맞춤형 운전 환경을 제공할 수 있다.

[0203] 컴퓨팅 장치(100)는 주행 중 생체신호 뿐 아니라 인공지능 기반의 다양한 멀티 모달리티 융합으로 확장될 수 있기 때문에 연구적인 측면에서 기여를 할 수 있다.

[0205] 도 7은 본 개시의 실시예들이 구현될 수 있는 예시적인 컴퓨팅 환경에 대한 간략하고 일반적인 개략도를 도시한다.

[0206] 본 개시가 일반적으로 컴퓨팅 장치에 의해 구현될 수 있는 것으로 진술되었지만, 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.

[0207] 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.

[0208] 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.

[0209] 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 저장하는데 사용될 수 있는 임의의 기타 매체를 포함하지만, 이에 한정되지 않는다.

[0210] 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.

[0211] 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.

[0212] 시스템 버스(1108)는 메모리 버스, 주변장치 버스, 및 다양한 상용 버스 아키텍처 중 임의의 것을 사용하는 로

컬 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.

[0213] 컴퓨터(1102)는 또한 내장형 하드 디스크 드라이브(HDD)(1114)(예를 들어, EIDE, SATA)-이 내장형 하드 디스크 드라이브(1114)는 또한 적당한 새시(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.

[0214] 이들 드라이브 및 그와 연관된 컴퓨터 판독가능 매체는 데이터, 데이터 구조, 컴퓨터 실행가능 명령어, 기타 등의 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 zip 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.

[0215] 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.

[0216] 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.

[0217] 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.

[0218] 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.

[0219] 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 설정

하는 기타 수단을 갖는다. 내장형 또는 외장형 및 유선 또는 무선 장치일 수 있는 모뎀(1158)은 직렬 포트 인터페이스(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.

[0220] 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 단순히 적어도 2개의 장치 사이의 애드혹 통신(ad hoc communication)일 수 있다.

[0221] 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.

[0222] 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.

[0223] 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 방식으로 설명된 기능을 구현할 수 있으나, 이러한 구현 결정들은 본 개시의 범위를 벗어나는 것으로 해석되어서는 안 될 것이다.


[0224] 여기서 제시된 다양한 실시예들은 방법, 장치, 또는 표준 프로그래밍 및/또는 엔지니어링 기술을 사용한 제조물품(article)으로 구현될 수 있다. 용어 제조물품은 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.

[0225] 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.


[0226] 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




도면2




도면3




도면4a




도면4b




도면4c



도면5



도면6



도면7

