



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2023년06월02일
(11) 등록번호 10-2540224
(24) 등록일자 2023년05월31일

(51) 국제특허분류(Int. Cl.)
G06N 20/00 (2019.01) A61B 5/00 (2021.01)
A61B 5/18 (2006.01) A61B 5/372 (2021.01)
B60W 40/08 (2006.01) G06N 5/02 (2023.01)
(52) CPC특허분류
G06N 20/00 (2021.08)
A61B 5/18 (2013.01)
(21) 출원번호 10-2021-0002145
(22) 출원일자 2021년01월07일
심사청구일자 2021년01월07일
(65) 공개번호 10-2022-0099816
(43) 공개일자 2022년07월14일
(56) 선행기술조사문헌
“Sleep Quality Estimation with Adversarial Domain Adaptation From Laboratory to Real Scenario”, 2018 International Joint Conference on Neural Networks, 2018.08.15.*
“Cross-Subject Emotion Recognition Using Deep Adaptation Networks”, ICONIP 2018(pp. 403-413), 2018.12.13.*
KR1020160095247 A
*는 심사관에 의하여 인용된 문헌

(73) 특허권자
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 발명자
변혜란
서울특별시 서대문구 연세로 50, 제4공학관 810호(신촌동, 연세대학교)
황선희
서울특별시 서대문구 연세로 50, 제4공학관 810호(신촌동, 연세대학교)
(뒷면에 계속)
(74) 대리인
특허법인우인

전체 청구항 수 : 총 11 항

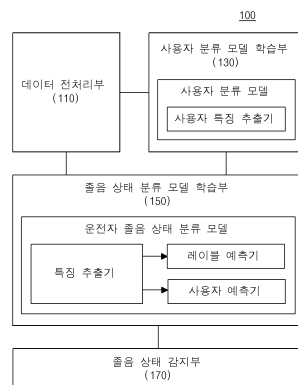
심사관 : 박승철

(54) 발명의 명칭 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치 및 방법

(57) 요약

본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치 및 방법은, 사용자 간 성능 격차를 완화하기 위해 사용자 독립적인 뇌파 기반 운전자 졸음 상태 분류 모델로, 사용자 적대적 학습(Subject Adversarial Training, SAT)을 이용하여 운전자 졸음 상태 분류 모델이 사용자 레이블을 잘못 분류하도록 하고, 서로 다른 사용자 특징 간의 거리를 최소화하는 IFDM(Inter-subject Feature Distance Minimization) 방법을 이용하여 사용자별 성능의 불일치를 줄일 수 있어, 사용자에게 상관없이 적용할 수 있고, 또한, 본 발명에 따른 사용자 분류 모델을 통해 뇌파 사용자 레이블이 부족한 경우에 수도 레이블(pseudo label)을 획득할 수 있어, 학습 데이터가 부족하더라도 운전자 졸음 상태 분류 모델을 구축할 수 있다.

대표도 - 도1



(52) CPC특허분류

A61B 5/372 (2022.01)
A61B 5/7264 (2013.01)
B60W 40/08 (2013.01)
G06N 5/025 (2023.01)
A61B 2503/22 (2013.01)
B60W 2040/0827 (2013.01)
B60W 2040/0872 (2013.01)

(72) 발명자

박성호

서울특별시 서대문구 연세로 50, 제4공학관 810호
 (신촌동, 연세대학교)

이필현

서울특별시 서대문구 연세로 50, 제4공학관 810호
 (신촌동, 연세대학교)

이제욱

서울특별시 서대문구 연세로 50, 제4공학관 810호
 (신촌동, 연세대학교)

김도형

서울특별시 서대문구 연세로 50, 제4공학관 810호
 (신촌동, 연세대학교)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711102931
과제번호	2017-0-00451-004
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송연구개발사업
연구과제명	(BCI-2세부) 딥러닝을 이용하여 사람의 의도를 인지하는 BCI 기반 뇌인지컴퓨팅 기
술 개발(1단계)(4/4)	
기 여 율	1/1
과제수행기관명	고려대학교산학협력단
연구기간	2020.01.01 ~ 2020.12.31

명세서

청구범위

청구항 1

학습 대상들의 뇌파로부터 추출된 제1 뇌파 특징들과 추출된 상기 제1 뇌파 특징들에 대응되는 사용자 레이블들을 이용하여, 사용자 특징 추출기를 포함하는 사용자 분류 모델을 학습하는 사용자 분류 모델 학습부;

상기 제1 뇌파 특징들, 상기 사용자 레이블들 및 상기 제1 뇌파 특징들에 대응되는 졸음 상태 레이블들을 이용하여, 특징 추출기, 레이블 예측기 및 사용자 예측기를 포함하는 운전자 졸음 상태 분류 모델을 학습하고, 상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 상기 특징 추출기를 학습하며, GRL(Gradient Reversal Layer)을 이용하여 상기 사용자 예측기를 사용자 적대적 학습(Subject Adversarial Training, SAT)하는 졸음 상태 분류 모델 학습부; 및

감지 대상의 뇌파로부터 추출된 제2 뇌파 특징들을 상기 운전자 졸음 상태 분류 모델에 입력하고, 상기 운전자 졸음 상태 분류 모델로부터 상기 감지 대상에 대한 졸음 상태 분류 결과를 획득하는 졸음 상태 감지부;

를 포함하고,

상기 졸음 상태 분류 모델 학습부는,

상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여, 동일한 클래스의 서로 다른 사용자 그룹 간의 와서스테인(Wasserstein) 거리를 최소화하도록 상기 특징 추출기를 학습하며,

상기 클래스는,

깨어 있음(awake) 클래스, 피곤함(tired) 클래스 및 졸음(drowsy) 클래스 중 하나인,

운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치.

청구항 2

삭제

청구항 3

제1항에서,

상기 졸음 상태 분류 모델 학습부는,

동일한 클래스에 속하는 샘플들에 대해 상기 사용자 특징 추출기를 통해 상기 제1 뇌파 특징들로부터 상기 사용자 특징들을 획득하고, 상기 사용자 특징들을 k-means 클러스터링을 통해 클러스터링하며, 복수개의 클러스터 중에서 랜덤하게 선택된 서로 다른 2개의 클러스터의 상기 사용자 특징들을 상기 특징 추출기에 입력하고, 상기 특징 추출기의 출력인 특징들의 와서스테인 거리를 최소화하는 과정을, 클래스별로 수행하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 상기 특징 추출기를 학습하는,

운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치.

청구항 4

제3항에서,

상기 와서스테인 거리를 최소화하기 위한 손실 함수(loss function)는,

$$L_w = W_a(H_{g_i^a}, H_{g_j^a}) + W_t(H_{g_i^t}, H_{g_j^t}) + W_d(H_{g_i^d}, H_{g_j^d}) \text{이며,}$$

상기 W_a 는, 상기 깨어 있음 클래스의 샘플들 사이의 와서스테인 거리를 나타내고,

상기 W_t 는, 상기 피곤함 클래스의 샘플들 사이의 와서스테인 거리를 나타내며,

상기 W_d 는, 상기 줄음 클래스의 샘플들 사이의 와서스테인 거리를 나타내고,

상기 와서스테인 거리는,

$$W_c(H_{g_i}, H_{g_j}) = \inf_{\gamma \in \Pi(H_{g_i}, H_{g_j})} E_{(z_i, z_j) \sim \gamma} [\|z_i - z_j\|] \quad \text{이며,}$$

상기 H 는, 상기 특징 추출기의 출력인 특징들을 나타내고,

상기 H_g 는, 상기 복수개의 클러스터 중에서 랜덤하게 선택된 클러스터의 사용자 특징들을 입력으로 하여 상기 특징 추출기로부터 출력된 특징들을 나타내며,

상기 $\Pi(H_{g_i}, H_{g_j})$ 는, 주변값들 H_{g_i} 와 H_{g_j} 를 가지는 모든 결합 분포들(joint distributions) $\gamma(z_i, z_j)$ 의 집합을 나타내는,

운전자 뇌파 기반 사용자 독립적인 줄음 상태 감지 장치.

청구항 5

제1항에서,

상기 사용자 적대적 학습(SAT)을 위한 손실 함수(loss function)는,

$$L_{s'} = -\lambda \sum_{i=1}^n L(M_{s'}(M_f(x_i; \theta_f); \theta_{s'}), s_i) \quad \text{이며,}$$

상기 x 는, 상기 제1 뇌파 특징을 나타내고,

상기 s 는, 상기 사용자 레이블을 나타내며,

상기 M_f 는, 상기 특징 추출기를 나타내고,

상기 θ_f 는, 상기 특징 추출기의 학습 파라미터들을 나타내며,

상기 $M_{s'}$ 는, 상기 사용자 예측기를 나타내고,

상기 $\theta_{s'}$ 는, 상기 사용자 예측기의 파라미터들을 나타내며,

상기 L 은, 상기 사용자 예측기의 손실 함수를 나타내는,

운전자 뇌파 기반 사용자 독립적인 줄음 상태 감지 장치.

청구항 6

제1항에서,

상기 운전자 줄음 상태 분류 모델의 손실 함수(loss function)는,

$$L_y = -\sum_{i=1}^n y_i \log(\hat{y}_i) \quad \text{이며,}$$

상기 y 는, 상기 줄음 상태 레이블을 나타내고,

상기 \hat{y} 는, 상기 운전자 줄음 상태 분류 모델의 출력인 예측 줄음 상태 레이블을 나타내며,

상기 n 은, 상기 줄음 상태 레이블의 개수를 나타내는,

운전자 뇌파 기반 사용자 독립적인 줄음 상태 감지 장치.

청구항 7

제1항에서,

상기 사용자 분류 모델은,
 뇌파 특징들을 입력으로 하고, 사용자 레이블들을 출력으로 하며,
 상기 사용자 분류 모델의 손실 함수(loss function)는,

$$L_s = - \sum_{i=1}^n s_i \log(\hat{s}_i) \quad \text{이고,}$$

상기 s 는, 상기 사용자 레이블을 나타내며,
 상기 \hat{s} 는, 상기 사용자 분류 모델의 출력인 예측 사용자 레이블을 나타내고,
 상기 n 은, 상기 사용자 레이블의 개수를 나타내는,
 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치.

청구항 8

제1항에서,
 상기 학습 대상들의 뇌파에서 밴드 패스 필터(Band Pass Filter)를 통해 아티팩트(Artifact)를 제거하고, 아티팩트가 제거된 뇌파로부터 미분 엔트로피(Differential Entropy, DE) 특징에 대해 미리 설정된 크기 간격으로 특징을 추출하여 상기 제1 뇌파 특징들을 획득하며, 선형 동적 시스템(Linear Dynamic System)을 이용하여 상기 제1 뇌파 특징들을 스무딩(Smoothing)하고, 상기 제1 뇌파 특징들에 대응되는 상기 사용자 레이블들을 획득하는 데이터 전처리부;
 를 더 포함하는 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치.

청구항 9

제8항에서,
 상기 데이터 전처리부는,
 미분 엔트로피(DE) 특징의 계산식을 통해 상기 제1 뇌파 특징들을 획득하며,
 상기 계산식은,

$$h(X) = - \int_{-\infty}^{\infty} f(x) \log(f(x)) dx = - \frac{1}{2} \log 2\pi e \sigma^2 \quad \text{이고,}$$

상기 f 는, 가우시안 분포(Gaussian distribution)를 따르는 랜덤 변수들의 확률 밀도 함수(probability density function)를 나타내는,
 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치.

청구항 10

학습 대상들의 뇌파로부터 추출된 제1 뇌파 특징들과 추출된 상기 제1 뇌파 특징들에 대응되는 사용자 레이블들을 이용하여, 사용자 특징 추출기를 포함하는 사용자 분류 모델을 학습하는 단계;
 상기 제1 뇌파 특징들, 상기 사용자 레이블들 및 상기 제1 뇌파 특징들에 대응되는 졸음 상태 레이블들을 이용하여, 특징 추출기, 레이블 예측기 및 사용자 예측기를 포함하는 운전자 졸음 상태 분류 모델을 학습하고, 상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 상기 특징 추출기를 학습하며, GRL(Gradient Reversal Layer)을 이용하여 상기 사용자 예측기를 사용자 적대적 학습(Subject Adversarial Training, SAT)하는 단계; 및
 감지 대상의 뇌파로부터 추출된 제2 뇌파 특징들을 상기 운전자 졸음 상태 분류 모델에 입력하고, 상기 운전자 졸음 상태 분류 모델로부터 상기 감지 대상에 대한 졸음 상태 분류 결과를 획득하는 단계;
 를 포함하고,

상기 운전자 졸음 상태 분류 모델을 학습하고, 상기 특징 추출기를 학습하며, 상기 사용자 적대적 학습하는 단계는,

상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여, 동일한 클래스의 서로 다른 사용자 그룹 간의 와서스테인(Wasserstein) 거리를 최소화하도록 상기 특징 추출기를 학습하는 것으로 이루어지며,

상기 클래스는,

깨어 있음(awake) 클래스, 피곤함(tired) 클래스 및 졸음(drowsy) 클래스 중 하나인,

운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법.

청구항 11

삭제

청구항 12

제10항에서,

상기 학습 대상들의 뇌파에서 밴드 패스 필터(Band Pass Filter)를 통해 아티팩트(Artifact)를 제거하고, 아티팩트가 제거된 뇌파로부터 미분 엔트로피(Differential Entropy, DE) 특징에 대해 미리 설정된 크기 간격으로 특징을 추출하여 상기 제1 뇌파 특징들을 획득하며, 선형 동적 시스템(Linear Dynamic System)을 이용하여 상기 제1 뇌파 특징들을 스무딩(Smoothing)하고, 상기 제1 뇌파 특징들에 대응되는 상기 사용자 레이블들을 획득하는 단계;

를 더 포함하는 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법.

청구항 13

제10항 및 제12항 중 어느 한 항에 기재된 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법을 컴퓨터에서 실행시키기 위하여 컴퓨터로 읽을 수 있는 기록 매체에 저장된 컴퓨터 프로그램.

발명의 설명

기술 분야

[0001] 본 발명은 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치 및 방법에 관한 것으로서, 더욱 상세하게는 운전자의 졸음 상태를 감지하는, 장치 및 방법에 관한 것이다.

배경 기술

[0002] 졸음 운전은 교통 사고의 주요 원인 중 하나이기 때문에 운전자 피로 상태(즉, 졸음 상태)를 분류할 수 있는 시스템의 개발이 필요하다.

[0003] 뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI) 시스템의 연구가 크게 발전함에 따라 뇌전도(Electroencephalography, EEG) 기반 운전자 피로 상태 분류 모델이 개발되어 그 효과를 입증하고 있다.

[0004] 그러나, 뇌전도(EEG) 신호에는 사용자 간의 큰 차이가 포함되어 있어 통합 모델을 구축하기 어려운 문제가 있다.

발명의 내용

해결하려는 과제

[0005] 본 발명이 이루고자 하는 목적은, 사용자 간 성능 격차를 완화하기 위해 사용자 독립적인 뇌파 기반 운전자 졸음 상태 분류 모델로, 사용자 적대적 학습(Subject Adversarial Training, SAT)을 이용하여 운전자 졸음 상태 분류 모델이 사용자 레이블을 잘못 분류하도록 하고, 서로 다른 사용자 특징 간의 거리를 최소화하는

IFDM(Inter-subject Feature Distance Minimization) 방법을 이용하여 사용자별 성능의 불일치를 줄일 수 있는, 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치 및 방법을 제공하는 데 있다.

[0006] 본 발명의 명시되지 않은 또 다른 목적들은 하기의 상세한 설명 및 그 효과로부터 용이하게 추론할 수 있는 범위 내에서 추가적으로 고려될 수 있다.

과제의 해결 수단

[0007] 상기의 목적을 달성하기 위한 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치는, 학습 대상들의 뇌파로부터 추출된 제1 뇌파 특징들과 추출된 상기 제1 뇌파 특징들에 대응되는 사용자 레이블들을 이용하여, 사용자 특징 추출기를 포함하는 사용자 분류 모델을 학습하는 사용자 분류 모델 학습부; 상기 제1 뇌파 특징들, 상기 사용자 레이블들 및 상기 제1 뇌파 특징들에 대응되는 졸음 상태 레이블들을 이용하여, 특징 추출기, 레이블 예측기 및 사용자 예측기를 포함하는 운전자 졸음 상태 분류 모델을 학습하고, 상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 상기 특징 추출기를 학습하며, GRL(Gradient Reversal Layer)을 이용하여 상기 사용자 예측기를 사용자 적대적 학습(Subject Adversarial Training, SAT)하는 졸음 상태 분류 모델 학습부; 및 감지 대상의 뇌파로부터 추출된 제2 뇌파 특징들을 상기 운전자 졸음 상태 분류 모델에 입력하고, 상기 운전자 졸음 상태 분류 모델로부터 상기 감지 대상에 대한 졸음 상태 분류 결과를 획득하는 졸음 상태 감지부;를 포함한다.

[0008] 여기서, 상기 졸음 상태 분류 모델 학습부는, 상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여, 동일한 클래스의 서로 다른 사용자 그룹 간의 와서스테인(Wasserstein) 거리를 최소화하도록 상기 특징 추출기를 학습하며, 상기 클래스는, 깨어 있음(awake) 클래스, 피곤함(tired) 클래스 및 졸음(drowsy) 클래스 중 하나일 수 있다.

[0009] 여기서, 상기 졸음 상태 분류 모델 학습부는, 동일한 클래스에 속하는 샘플들에 대해 상기 사용자 특징 추출기를 통해 상기 제1 뇌파 특징들로부터 상기 사용자 특징들을 획득하고, 상기 사용자 특징들을 k-means 클러스터링을 통해 클러스터링하며, 복수개의 클러스터 중에서 랜덤하게 선택된 서로 다른 2개의 클러스터의 상기 사용자 특징들을 상기 특징 추출기에 입력하고, 상기 특징 추출기의 출력인 특징들의 와서스테인 거리를 최소화하는 과정을, 클래스별로 수행하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 상기 특징 추출기를 학습할 수 있다.

[0010] 여기서, 상기 와서스테인 거리를 최소화하기 위한 손실 함수(loss function)는, $L_w = W_a(H_{g_i^a}, H_{g_j^a}) + W_t(H_{g_i^t}, H_{g_j^t}) + W_d(H_{g_i^d}, H_{g_j^d})$ 이며, 상기 W_a 는, 상기 깨어 있음 클래스의 샘플들 사이의 와서스테인 거리를 나타내고, 상기 W_t 는, 상기 피곤함 클래스의 샘플들 사이의 와서스테인 거리를 나타내며, 상기 W_d 는, 상기 졸음 클래스의 샘플들 사이의 와서스테인 거리를 나타내고, 상기 와서스테인 거리는,

$$W_c(H_{g_i}, H_{g_j}) = \inf_{\gamma \in \Pi(H_{g_i}, H_{g_j})} E_{(z_i, z_j) \sim \gamma} [\|z_i - z_j\|]$$

이며, 상기 H 는, 상기 특징 추출기의 출력인 특징들을 나타내고, 상기 H_k 는, 상기 복수개의 클러스터 중에서 랜덤하게 선택된 클러스터의 사용자 특징들을 입력으로 하여 상기 특징 추출기로부터 출력된 특징들을 나타내며, 상기 $\Pi(H_{g_i}, H_{g_j})$ 는, 주변값들 H_{g_i} 와 H_{g_j} 를 가지는 모든 결합 분포들(joint distributions) $\gamma(z_i, z_j)$ 의 집합을 나타낼 수 있다.

[0011] 여기서, 상기 사용자 적대적 학습(SAT)을 위한 손실 함수(loss function)는, $L_{s'} = -\lambda \sum_{i=1}^n L(M_{s'}(M_f(x_i; \theta_f); \theta_{s'}), s_i)$ 이며, 상기 x 는, 상기 제1 뇌파 특징을 나타내고, 상기 s 는, 상기 사용자 레이블을 나타내며, 상기 M_f 는, 상기 특징 추출기를 나타내고, 상기 θ_f 는, 상기 특징 추출기의 학습 파라미터들을 나타내며, 상기 $M_{s'}$ 는, 상기 사용자 예측기를 나타내고, 상기 $\theta_{s'}$ 는, 상기 사용자 예측기의 파라미터들을 나타내며, 상기 L 은, 상기 사용자 예측기의 손실 함수를 나타낼 수 있다.

[0012] 여기서, 상기 운전자 졸음 상태 분류 모델의 손실 함수(loss function)는,
$$L_y = - \sum_{i=1}^n y_i \log(\hat{y}_i)$$
이며, 상기 y는, 상기 졸음 상태 레이블을 나타내고, 상기 \hat{y} 는, 상기 운전자 졸음 상태 분류 모델의 출력인 예측 졸음 상태 레이블을 나타내며, 상기 n은, 상기 졸음 상태 레이블의 개수를 나타낼 수 있다.

[0013] 여기서, 상기 사용자 분류 모델은, 뇌파 특징들을 입력으로 하고, 사용자 레이블들을 출력으로 하며, 상기 사용자 분류 모델의 손실 함수(loss function)는,
$$L_s = - \sum_{i=1}^n s_i \log(\hat{s}_i)$$
이고, 상기 s는, 상기 사용자 레이블을 나타내며, 상기 \hat{s} 는, 상기 사용자 분류 모델의 출력인 예측 사용자 레이블을 나타내고, 상기 n은, 상기 사용자 레이블의 개수를 나타낼 수 있다.

[0014] 여기서, 상기 학습 대상들의 뇌파에서 밴드 패스 필터(Band Pass Filter)를 통해 아티팩트(Artifact)를 제거하고, 아티팩트가 제거된 뇌파로부터 미분 엔트로피(Differential Entropy, DE) 특징에 대해 미리 설정된 크기 간격으로 특징을 추출하여 상기 제1 뇌파 특징들을 획득하며, 선형 동적 시스템(Linear Dynamic System)을 이용하여 상기 제1 뇌파 특징들을 스무딩(Smoothing)하고, 상기 제1 뇌파 특징들에 대응되는 상기 사용자 레이블들을 획득하는 데이터 전처리부;를 더 포함할 수 있다.

[0015] 여기서, 상기 데이터 전처리부는, 미분 엔트로피(DE) 특징의 계산식을 통해 상기 제1 뇌파 특징들을 획득하며,
$$h(X) = - \int_{-\infty}^{\infty} f(x) \log(f(x)) dx = - \frac{1}{2} \log 2\pi e \sigma^2$$
상기 계산식은, f 는, 가우시안 분포(Gaussian distribution)를 따르는 랜덤 변수들의 확률 밀도 함수(probability density function)를 나타낼 수 있다.

[0017] 상기의 목적을 달성하기 위한 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법은, 학습 대상들의 뇌파로부터 추출된 제1 뇌파 특징들과 추출된 상기 제1 뇌파 특징들에 대응되는 사용자 레이블들을 이용하여, 사용자 특징 추출기를 포함하는 사용자 분류 모델을 학습하는 단계; 상기 제1 뇌파 특징들, 상기 사용자 레이블들 및 상기 제1 뇌파 특징들에 대응되는 졸음 상태 레이블들을 이용하여, 특징 추출기, 레이블 예측기 및 사용자 예측기를 포함하는 운전자 졸음 상태 분류 모델을 학습하고, 상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 상기 특징 추출기를 학습하며, GRL(Gradient Reversal Layer)을 이용하여 상기 사용자 예측기를 사용자 적대적 학습(Subject Adversarial Training, SAT)하는 단계; 및 감지 대상의 뇌파로부터 추출된 제2 뇌파 특징들을 상기 운전자 졸음 상태 분류 모델에 입력하고, 상기 운전자 졸음 상태 분류 모델로부터 상기 감지 대상에 대한 졸음 상태 분류 결과를 획득하는 단계;를 포함한다.

[0018] 여기서, 상기 운전자 졸음 상태 분류 모델을 학습하고, 상기 특징 추출기를 학습하며, 상기 사용자 적대적 학습하는 단계는, 상기 제1 뇌파 특징들로부터 상기 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여, 동일한 클래스의 서로 다른 사용자 그룹 간의 와서스테인(Wasserstein) 거리를 최소화하도록 상기 특징 추출기를 학습하는 것으로 이루어지며, 상기 클래스는, 깨어 있음(awake) 클래스, 피곤함(tired) 클래스 및 졸음(drowsy) 클래스 중 하나일 수 있다.

[0019] 여기서, 상기 학습 대상들의 뇌파에서 밴드 패스 필터(Band Pass Filter)를 통해 아티팩트(Artifact)를 제거하고, 아티팩트가 제거된 뇌파로부터 미분 엔트로피(Differential Entropy, DE) 특징에 대해 미리 설정된 크기 간격으로 특징을 추출하여 상기 제1 뇌파 특징들을 획득하며, 선형 동적 시스템(Linear Dynamic System)을 이용하여 상기 제1 뇌파 특징들을 스무딩(Smoothing)하고, 상기 제1 뇌파 특징들에 대응되는 상기 사용자 레이블들을 획득하는 단계;를 더 포함할 수 있다.

[0021] 상기의 기술적 과제를 달성하기 위한 본 발명의 바람직한 실시예에 따른 컴퓨터 프로그램은 컴퓨터로 읽을 수 있는 기록 매체에 저장되어 상기한 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법 중 어느 하나를 컴퓨터에서 실행시킨다.

발명의 효과

[0022] 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치 및 방법에 의하면, 사용자 간 성능 격차를 완화하기 위해 사용자 독립적인 뇌파 기반 운전자 졸음 상태 분류 모델로, 사용자 적대적 학습(Subject Adversarial Training, SAT)을 이용하여 운전자 졸음 상태 분류 모델이 사용자 레이블을 잘못

분류하도록 하고, 서로 다른 사용자 특징 간의 거리를 최소화하는 IFDM(Inter-subject Feature Distance Minimization) 방법을 이용하여 사용자별 성능의 불일치를 줄일 수 있어, 사용자에게 상관없이 적용할 수 있다.

[0023] 또한, 본 발명에 따른 사용자 분류 모델을 통해 뇌파 사용자 레이블이 부족한 경우에 수도 레이블(pseudo label)을 획득할 수 있어, 학습 데이터가 부족하더라도 운전자 졸음 상태 분류 모델을 구축할 수 있다.

[0024] 본 발명의 효과들은 이상에서 언급한 효과들로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0025] 도 1은 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치를 설명하기 위한 블록도이다.

도 2는 본 발명의 바람직한 실시예에 따른 사용자 독립적인 운전자 졸음 상태 감지 모델을 설명하기 위한 도면이다.

도 3은 본 발명의 바람직한 실시예에 따른 사용자 특징 간의 거리를 최소화하는 과정을 설명하기 위한 도면이다.

도 4는 본 발명의 바람직한 실시예에 따른 사용자 독립적인 운전자 졸음 상태 감지 모델의 성능을 설명하기 위한 도면이다.

도 5는 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법을 설명하기 위한 흐름도이다.

발명을 실시하기 위한 구체적인 내용

[0026] 이하, 첨부된 도면을 참조하여 본 발명의 실시 예를 상세히 설명한다. 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시 예를 참조하면 명확해질 것이다. 그러나 본 발명은 이하에서 개시되는 실시예들에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 수 있으며, 단지 본 실시예들은 본 발명의 개시가 완전하도록 하고, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것이며, 본 발명은 청구항의 범주에 의해 정의될 뿐이다. 명세서 전체에 걸쳐 동일 참조 부호는 동일 구성 요소를 지칭한다.

[0027] 다른 정의가 없다면, 본 명세서에서 사용되는 모든 용어(기술 및 과학적 용어를 포함)는 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 공통적으로 이해될 수 있는 의미로 사용될 수 있을 것이다. 또 일반적으로 사용되는 사전에 정의되어 있는 용어들은 명백하게 특별히 정의되어 있지 않는 한 이상적으로 또는 과도하게 해석되지 않는다.

[0028] 본 명세서에서 "제1", "제2" 등의 용어는 하나의 구성요소를 다른 구성요소로부터 구별하기 위한 것으로, 이들 용어들에 의해 권리범위가 한정되어서는 아니 된다. 예를 들어, 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다.

[0029] 본 명세서에서 각 단계들에 있어 식별부호(예를 들어, a, b, c 등)는 설명의 편의를 위하여 사용되는 것으로 식별부호는 각 단계들의 순서를 설명하는 것이 아니며, 각 단계들은 문맥상 명백하게 특정 순서를 기재하지 않는 이상 명기된 순서와 다르게 일어날 수 있다. 즉, 각 단계들은 명기된 순서와 동일하게 일어날 수도 있고 실질적으로 동시에 수행될 수도 있으며 반대의 순서대로 수행될 수도 있다.

[0030] 본 명세서에서, "가진다", "가질 수 있다", "포함한다" 또는 "포함할 수 있다"등의 표현은 해당 특징(예: 수치, 기능, 동작, 또는 부품 등의 구성요소)의 존재를 가리키며, 추가적인 특징의 존재를 배제하지 않는다.

[0031] 또한, 본 명세서에 기재된 '~부'라는 용어는 소프트웨어 또는 FPGA(field-programmable gate array) 또는 ASIC과 같은 하드웨어 구성요소를 의미하며, '~부'는 어떤 역할들을 수행한다. 그렇지만 '~부'는 소프트웨어 또는 하드웨어에 한정되는 의미는 아니다. '~부'는 어드레싱할 수 있는 저장 매체에 있도록 구성될 수도 있고 하나 또는 그 이상의 프로세서들을 재생시키도록 구성될 수도 있다. 따라서, 일 예로서 '~부'는 소프트웨어 구성요소들, 객체지향 소프트웨어 구성요소들, 클래스 구성요소들 및 태스크 구성요소들과 같은 구성요소들과, 프로세스들, 함수들, 속성들, 프로시저들, 서브루틴들, 프로그램 코드의 세그먼트들, 드라이버들, 펌웨어, 마이크로코드, 회로, 데이터 구조들 및 변수들을 포함한다. 구성요소들과 '~부'들 안에서 제공되는 기능은 더

작은 수의 구성요소들 및 '~부'들로 결합되거나 추가적인 구성요소들과 '~부'들로 더 분리될 수 있다.

- [0033] 이하에서 첨부한 도면을 참조하여 본 발명에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치 및 방법의 바람직한 실시예에 대해 상세하게 설명한다.
- [0035] 먼저, 도 1 내지 도 3을 참조하여 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치에 대하여 설명한다.
- [0036] 도 1은 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치를 설명하기 위한 블록도이고, 도 2는 본 발명의 바람직한 실시예에 따른 사용자 독립적인 운전자 졸음 상태 감지 모델을 설명하기 위한 도면이며, 도 3은 본 발명의 바람직한 실시예에 따른 사용자 특징 간의 거리를 최소화하는 과정을 설명하기 위한 도면이다.
- [0037] 도 1 및 도 2를 참조하면, 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 장치(이하 '졸음 상태 감지 장치'라 한다)(100)는 사용자 간 성능 격차를 완화하기 위해 사용자 독립적인 뇌파 기반 운전자 졸음 상태(깨어 있음 상태/피곤함 상태/졸음 상태) 분류 모델로, 사용자 적대적 학습(Subject Adversarial Training, SAT)을 이용하여 운전자 졸음 상태 분류 모델이 사용자 레이블을 잘못 분류하도록 하고, 서로 다른 사용자 특징 간의 거리를 최소화하는 IFDM(Inter-subject Feature Distance Minimization) 방법을 이용하여 사용자별 성능의 불일치를 줄일 수 있다. 이에 따라, 사용자에게 상관없이 본 발명에 따른 운전자 졸음 상태 분류 모델을 적용하여, 운전자의 졸음 상태를 감지할 수 있다.
- [0038] 또한, 본 발명에 따른 졸음 상태 감지 장치(100)는 사용자 분류 모델을 통해 뇌파 사용자 레이블이 부족한 경우에 수도 레이블(pseudo label)을 획득할 수 있어, 학습 데이터가 부족하더라도 운전자 졸음 상태 분류 모델을 구축할 수 있다.
- [0040] 이를 위해, 졸음 상태 감지 장치(100)는 데이터 전처리부(110), 사용자 분류 모델 학습부(130), 졸음 상태 분류 모델 학습부(150) 및 졸음 상태 감지부(170)를 포함할 수 있다.
- [0042] 데이터 전처리부(110)는 학습 대상들의 뇌파로부터 제1 뇌파 특징들(X)을 추출하고, 추출된 제1 뇌파 특징들에 대응되는 사용자 레이블들(S)을 획득한다.
- [0043] 여기서, 본 발명에 따른 운전자 졸음 상태 분류 모델을 구축하여 성능을 검증하기 위해, EEG-기반 운전자 피로 상태(fatigue state) 분석을 위해 널리 이용되는 데이터 세트 중 하나인, SEED-VIG 데이터 세트를 이용한다. 이 데이터 세트는 17개의 전극을 통해 기록되고, 밤과 낮의 서로 다른 기록 시간에서 각각 8번과 15번 획득된다. 본 발명은 밤에 획득된 8번의 모든 기록과 낮에 기록된 15번의 기록 중에서 랜덤하게 선택된 8번의 기록을 이용한다. 졸음 상태(drowsiness state)는 단위 시간 당 눈이 감기는 시간의 퍼센트(Percentage Eye Closure, PERCLOS)로 계산된다. 본 발명은 PERCLOS를 0.35 및 0.7의 임계값을 기준으로 하여, 깨어 있음(awake), 피곤함(tired) 및 졸음(drowsy)의 3개의 카테고리로 나누어 이용한다.
- [0044] 즉, 데이터 전처리부(110)는 학습 대상들의 뇌파에서 밴드 패스 필터(Band Pass Filter)를 통해 아티팩트(Artifact)를 제거할 수 있다. 여기서, 밴드 패스 필터는 1Hz ~ 75Hz 대역의 신호만 통과시키는 필터를 말한다. 이때, 데이터 전처리부(110)는 아티팩트가 제거된 뇌파를 200Hz의 샘플링 주파수로 다운-샘플링할 수 있다.
- [0045] 그리고, 데이터 전처리부(110)는 아티팩트가 제거된 뇌파로부터 미분 엔트로피(Differential Entropy, DE) 특징(1Hz ~ 50Hz)에 대해 미리 설정된 크기(예컨대, 2Hz 등) 간격으로 특징을 추출(1채널당 25 dimension)하여 제1 뇌파 특징들(X)을 획득할 수 있다. 여기서, EEG 특징들의 다양한 종류 중에서, 본 발명은 EEG 분류 태스크에서 좋은 성능을 보이는 미분 엔트로피(DE) 특징을 이용한다.
- [0046] 보다 자세히 설명하면, 데이터 전처리부(110)는 아래의 [수학식 1]과 같은 미분 엔트로피(DE) 특징의 계산식을 통해 제1 뇌파 특징들(X)을 획득할 수 있다.

수학식 1

$$h(X) = - \int_{-\infty}^{\infty} f(x) \log(f(x)) dx = \frac{1}{2} \log 2\pi e \sigma^2$$

[0047]

[0048] 여기서, f 는 가우시안 분포(Gaussian distribution)를 따르는 랜덤 변수들의 확률 밀도 함수(probability density function)를 나타낸다.

[0049] 그리고, 데이터 전처리부(110)는 선형 동적 시스템(Linear Dynamic System, LDS)을 이용하여 제1 뇌파 특징들(X)을 스무딩(Smoothing)할 수 있다.

[0051] 사용자 분류 모델 학습부(130)는 데이터 전처리부(110)를 통해 획득된 제1 뇌파 특징들(X)과 사용자 레이블들(S)을 이용하여, 사용자 특징 추출기(M_s)를 포함하는 사용자 분류 모델을 학습한다.

[0052] 여기서, 사용자 분류 모델은 뇌파 특징들을 입력으로 하고, 사용자 레이블들을 출력으로 할 수 있다. 사용자 분류 모델의 히든 레이어들(hidden layers)은 모두 40 dimensions이고, 출력 레이어는 사용자 레이블들의 개수인 8 dimensions일 수 있다.

[0053] 즉, 미분 엔트로피(DE) 특징들 $X_t = \{x_1, x_2, \dots, x_n\}$ 및 이에 대응되는 사용자 레이블들 $S_t = \{s_1, s_2, \dots, s_n\}$ 가 주어지면, 본 발명은 먼저 사용자 분류 모델을 훈련한다. 여기서, n 은 샘플들의 개수를 나타낸다. 사용자 분류 모델은 사용자 특징 추출기(M_s)와 이와 연결된 하나의 출력 완전 연결 레이어(output fully connected layer)로 구성된다. 사용자 특징 추출기(M_s)는 배치 정규화(batch normalization), 드롭아웃(dropout) 및 ELU 연산자들을 가지는 3개의 완전 연결 레이어들로 이루어진다.

[0054] 그리고, 사용자 분류 모델의 손실 함수(loss function)는 아래의 [수학식 2]에 따른 손실 함수를 이용할 수 있다.

수학식 2

$$L_s = - \sum_{i=1}^n s_i \log(\hat{s}_i)$$

[0056] 여기서, s 는 사용자 레이블을 나타낸다. \hat{s} 는 사용자 분류 모델의 출력인 예측 사용자 레이블을 나타낸다. n 은 훈련 데이터 세트에서 샘플(즉, 사용자 레이블)의 개수를 나타낸다.

[0057] 이와 같은, 사용자 분류 모델은 이하에서 설명하는 서로 다른 사용자 특징 간의 거리 최소화에도 이용되지만, 뇌파 사용자 레이블이 부족한 경우 수도 레이블(pseudo label)의 획득에도 이용될 수 있다.

[0059] 졸음 상태 분류 모델 학습부(150)는 제1 뇌파 특징들(X), 사용자 레이블들(S) 및 제1 뇌파 특징들(X)에 대응되는 졸음 상태 레이블들(Y)을 이용하여, 특징 추출기(M_f), 레이블 예측기(M_y) 및 사용자 예측기(M_{s1})를 포함하는 운전자 졸음 상태 분류 모델을 학습한다.

[0060] 즉, 미분 엔트로피(DE) 특징들 X_t 및 이에 대응되는 졸음 상태 레이블들 $Y_t = \{y_1, y_2, \dots, y_n\}$ 를 이용하여 운전자 졸음 상태 분류 모델을 훈련한다. 운전자 졸음 상태 분류 모델은 3개의 완전 연결 레이어들을 가지는 특징 추출기(M_f)와 이와 연결된 2개의 완전 연결 레이어들을 가지는 레이블 예측기(M_y)로 구성된다. 본 발명은 출력 레이어를 제외하고, 각각의 완전 연결 레이어 뒤에 배치 정규화(batch normalization), 드롭아웃(dropout) 및 ELU 연산자들을 추가한다.

[0061] 여기서, 운전자 졸음 상태 분류 모델의 손실 함수(loss function)는 아래의 [수학식 3]과 같다.

수학식 3

$$L_y = - \sum_{i=1}^n y_i \log(\hat{y}_i)$$

[0063] 여기서, y 는 졸음 상태 레이블을 나타낸다. \hat{y} 는 운전자 졸음 상태 분류 모델의 출력인 예측 졸음 상태 레이블을 나타낸다. n 은 졸음 상태 레이블의 개수를 나타낸다.

- [0065] 이때, 졸음 상태 분류 모델 학습부(150)는 제1 뇌파 특징들(X)로부터 사용자 분류 모델의 사용자 특징 추출기(M_s)를 통해 획득된 사용자 특징들(F)을 이용하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 운전자 졸음 상태 분류 모델의 특징 추출기(M_f)를 학습한다. 이에 따라, 사용자별 성능 불일치를 줄일 수 있다.
- [0066] 즉, 사용자간 정확도 차이를 줄이기 위해, 본 발명은 운전자 졸음 상태 분류 모델의 사용자간 특징 거리를 최소화하기 위한 방법(Inter-subject Feature Distance Minimization, IFDM)을 이용한다. 본 발명은 동일한 클래스의 샘플들을 더 가깝게 매핑하기 위해, 운전자 졸음 상태 분류 모델의 특징 추출기(M_s)를 훈련하는 것을 목표로 한다. 따라서, 서로 관련된 2개의 사용자 그룹에서, 본 발명은 2개의 확률 분포들 사이의 불일치를 측정하는, 와서스테인 거리를 최소화한다.
- [0067] 다시 말하면, 졸음 상태 분류 모델 학습부(150)는 제1 뇌파 특징들(X)로부터 사용자 특징 추출기(M_s)를 통해 획득된 사용자 특징들(F)을 이용하여, 동일한 클래스의 서로 다른 사용자 그룹 간의 와서스테인(Wasserstein) 거리를 최소화하도록 특징 추출기(M_f)를 학습할 수 있다.
- [0068] 여기서, 클래스는 깨어 있음(awake) 클래스, 피곤함(tired) 클래스 및 졸음(drowsy) 클래스 중 하나일 수 있다.
- [0069] 도 3을 참조하여 보다 자세히 설명하면, 졸음 상태 분류 모델 학습부(150)는 동일한 클래스(깨어 있음 클래스/피곤함 클래스/졸음 클래스)에 속하는 샘플들에 대해 사용자 특징 추출기(M_s)를 통해 제1 뇌파 특징들(X)로부터 사용자 특징들(F)을 획득할 수 있다.
- [0070] 그리고, 졸음 상태 분류 모델 학습부(150)는 사용자 특징들(F)을 k-means 클러스터링을 통해 클러스터링할 수 있다.
- [0071] 그리고, 졸음 상태 분류 모델 학습부(150)는 복수개의 클러스터 중에서 랜덤하게 선택된 서로 다른 2개의 클러스터(g_i 와 g_j)의 사용자 특징들(F)을 특징 추출기(M_f)에 입력할 수 있다. 클러스터 개수가 증가함에 따라 작업 개수가 비효율적으로 증가하는 것을 방지하기 위해, 본 발명은 모든 조합을 고려하지 않고 랜덤하게 선택된 2개의 클러스터 간의 거리를 최소화한다.
- [0072] 그리고, 졸음 상태 분류 모델 학습부(150)는 특징 추출기(M_f)의 출력인 특징들(H)의 와서스테인 거리를 최소화할 수 있다.
- [0073] 즉, 클래스 c의 사용자 특징들 $F_c=\{f_1, f_2, \dots, f_m\}$ 이 주어지면, 본 발명은 동일하거나 의미적으로 유사한 사용자들을 그룹화하기 위해 이 사용자 특징들(F_c)에 대해 k-means 클러스터링을 수행한다. 여기서, m은 클래스 c에서의 샘플들(즉, 사용자 특징들)의 개수를 나타낸다. 그런 다음, 본 발명은 운전자 졸음 상태 분류 모델의 특징 추출기(M_f)로부터 추출된 특징들(H)의 특징 거리를 최소화한다.
- [0074] 여기서, 클래스 c의 2개의 클러스터 g_i 와 g_j 사이의 와서스테인 거리는 아래의 [수학식 4]와 같다.

수학식 4

$$W_c(H_{g_i}, H_{g_j}) = \inf_{\gamma \in \Pi(H_{g_i}, H_{g_j})} E_{(z_i, z_j) \sim \gamma} [\|z_i - z_j\|]$$

[0075]

- [0076] 여기서, H는 특징 추출기(M_f)의 출력인 특징들을 나타낸다. H_g 는 복수개의 클러스터 중에서 랜덤하게 선택된 클러스터의 사용자 특징들을 입력으로 하여 특징 추출기(M_f)로부터 출력된 특징들을 나타낸다. $\Pi(H_{g_i}, H_{g_j})$ 는 주변값들 H_{g_i} 와 H_{g_j} 를 가지는 모든 결합 분포들(joint distributions) $\gamma(z_i, z_j)$ 의 집합을 나타낸다.

- [0077] 이와 같은 과정을, 졸음 상태 분류 모델 학습부(150)는 클래스별로 수행하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 특징 추출기(M_f)를 학습할 수 있다.

[0078] 이때, 와서스테인 거리를 최소화하기 위한 손실 함수(loss function)는 아래의 [수학식 5]와 같다.

수학식 5

$$L_w = W_a(H_{g_i^a}, H_{g_j^a}) + W_t(H_{g_i^t}, H_{g_j^t}) + W_d(H_{g_i^d}, H_{g_j^d})$$

[0080] 여기서, W_a 는 깨어 있음 클래스의 샘플들 사이의 와서스테인 거리를 나타낸다. W_t 는 피곤함 클래스의 샘플들 사이의 와서스테인 거리를 나타낸다. W_d 는 졸음 클래스의 샘플들 사이의 와서스테인 거리를 나타낸다.

[0082] 또한, 졸음 상태 분류 모델 학습부(150)는 GRL(Gradient Reversal Layer)을 이용하여 운전자 졸음 상태 분류 모델의 사용자 예측기(M_s)를 사용자 적대적 학습(Subject Adversarial Training, SAT)한다. 즉, 사용자 정보를 맞추지 못하도록 함으로써 사용자 독립적인 운전자 졸음 상태 분류 모델을 획득할 수 있다.

[0083] 즉, 사용자 사이의 졸음 분류 정확도 차이를 감소시키기 위해, 본 발명은 도메인 적응 네트워크(domain adaptation network)로 GRL을 가지는 사용자 적대적 네트워크를 구축한다. 미분 엔트로피(DE) 특징들 X_t 및 이에 대응되는 사용자 레이블들 S_t 가 주어지면, 본 발명은 레이블 예측기(M_y)를 훈련하는 도중에 사용자 레이블들을 오분류하기 위해 파라미터들 θ_s 를 가지는 사용자 예측기(M_s)를 훈련한다. 여기서, 사용자 예측기(M_s)는 레이블 예측기(M_y)와 동일한 구조를 가진다.

[0084] 여기서, 사용자 적대적 학습(SAT)을 위한 손실 함수(loss function)는 아래의 [수학식 6]과 같다.

수학식 6

$$L_{s,i} = -\lambda \sum_{i=1}^n L(M_{s,i}(M_f(x_i; \theta_f); \theta_{s,i}), s_i)$$

[0086] 여기서, 사용자 예측기(M_s)로부터 특징 추출기(M_f)로 전달되는 그라디언트(gradient)는 GRL에서 음의 파라미터로 곱해진다. x 는 제1 뇌파 특징을 나타낸다. s 는 사용자 레이블을 나타낸다. M_f 는 특징 추출기를 나타낸다. θ_f 는 특징 추출기의 학습 파라미터들을 나타낸다. M_s 는 사용자 예측기를 나타낸다. θ_s 는 사용자 예측기의 파라미터들을 나타낸다. L 은 사용자 예측기의 손실 함수를 나타낸다.

[0088] 졸음 상태 감지부(170)는 졸음 상태 분류 모델 학습부(150)에 의해 획득된 운전자 졸음 상태 분류 모델을 이용하여 감지 대상의 졸음 상태를 감지할 수 있다.

[0089] 즉, 졸음 상태 감지부(170)는 감지 대상의 뇌파로부터 추출된 제2 뇌파 특징들을 운전자 졸음 상태 분류 모델에 입력할 수 있다.

[0090] 그리고, 졸음 상태 감지부(170)는 운전자 졸음 상태 분류 모델로부터 감지 대상에 대한 졸음 상태 분류 결과를 획득할 수 있다. 여기서, 졸음 상태 분류 결과는 깨어 있음 상태, 피곤함 상태 및 졸음 상태 중 하나를 말한다.

[0093] 그러면, 도 4를 참조하여 본 발명의 바람직한 실시예에 따른 사용자 독립적인 운전자 졸음 상태 감지 모델의 성능에 대하여 설명한다.

[0094] 도 4는 본 발명의 바람직한 실시예에 따른 사용자 독립적인 운전자 졸음 상태 감지 모델의 성능을 설명하기 위한 도면이다.

[0095] 본 발명의 성능을 실험하기 위해, SEED-VIG 데이터 세트를 기록 시간에 따라 2개의 다른 그룹인, 낮과 밤으로 구분하였다. 먼저, SEED-VIG 데이터 세트를 훈련, 검증 및 테스트를 위해 각각 (708개의 샘플들) x (8명의 사용자들), (177개의 샘플들) x (8명의 사용자들) 및 (177개의 샘플들) x (8명의 사용자들)로 구분하였다. 이와 같이 구분한 데이터를 이용하여 사용자 분류 모델과 운전자 졸음 상태 분류 모델을 학습하였다. 반면, 사용자 레이블들이 부족한 경우에도 본 발명이 잘 동작한다는 것을 보여주기 위해, 사용자 레이블들의 일부를 가지고

실험을 진행하였으며, 이를 위해 (177 샘플들) x (8명의 사용자들)의 데이터를 이 훈련을 위해 이용하였다.

[0096] 사용자 분류 모델과 운전자 졸음 상태 분류 모델 내의 히든 레이어들의 차원(dimensionality)은 각각 40 및 400으로 설정하였다.

[0097] 운전자 졸음 상태 분류 모델의 전반적인 손실 함수는 모든 항들의 가중 합계이며, PyTorch 라이브러리를 이용하여 10^{-5} 의 학습률을 가지는 Adam 알고리즘에 의해 최적화되었다. 검증 데이터 세트를 이용하여 매 epoch와 조기-종료(early-stop) 훈련에서 모든 DNN-기반 모델들을 검증하였다.

[0098] 3개의 기본 분류 모델인, K-Nearest Neighbor(KNN), 서포트 벡터 머신(Support Vector Machine, SVM) 및 심층신경망(Deep Neural Networks, DNN)을 본 발명과 비교하였다. KNN과 SVM 분류 모델은 scikit-learn 라이브러리를 이용하여 구현되었다. KNN 분류 모델의 이웃들 개수는 3으로 설정하였다. RBF(Radial Basis Function) 커널로 SVM 분류 모델을 훈련하였다. DNN 분류 모델은 PyTorch 라이브러리를 이용하여 구현되었다. DNN 분류 모델의 구조와 파라미터들은 본 발명에 따른 운전자 졸음 상태 분류 모델의 구조와 파라미터들과 동일하게 하였다.

[0100] EEG 신호들은 개인차가 크기 때문에, 높은 사용자 분류 정확도를 획득하는 것이 쉽다. 본 발명은 낮과 밤에 각각 98.21%와 98.09%의 분류 정확도를 달성하였다. 심지어 사용자 레이블들의 일부를 가지는 데이터 세트를 이용한 경우에도, 본 발명은 낮과 밤에 각각 92.58%와 87.43%의 분류 정확도를 달성하였다.

[0101] 아래의 [표 1]은 본 발명에 따른 운전자 졸음 상태 분류 모델의 정확도를 KNN, SVM 및 DNN 분류 모델과 비교한 결과를 나타내며, 낮과 밤의 2개의 다른 EEG 기록 시간의 결과를 나타낸다. 전반적으로, 본 발명에 따른 결과가 가장 높은 정확도(Accuracy, ACC)와 가장 낮은 개인차(Individual Variation, IV)를 나타내고 있다.

표 1

[0102]

Recording Time	noon		night	
Method	ACC	IV	ACC	IV
KNN	86.02	11.41	68.71	19.48
SVM	81.85	20.01	75.35	18.19
DNN	91.38	10.01	77.61	16.37
Ours	92.09	7.82	78.46	15.17

[0103] 또한, 아래의 [표 2]에 도시된 바와 같이, 본 발명에 따른 사용자 적대적 학습(SAT) 및 사용자간 특징 거리를 최소화하기 위한 방법(IFDM)의 기여도를 확인할 수 있다. IFDM에서, k-means 클러스터링을 위한 k를 4와 8로 설정하여 결과를 비교하였다. 전반적으로, k가 증가하면, 개인차가 감소하지만, 정확도도 감소하는 경향이 있다. [표 2]의 별표(*) 표시는 사용자 레이블들의 일부를 가지는 데이터 세트를 이용한 케이스를 나타낸다. 이 케이스에서는 수도 사용자 레이블(pseudo subject labels)을 생성하고, 일부의 사용자 레이블들로 미리 훈련된 사용자 분류 모델을 이용하여 사용자 관련 특징들을 추출한다. 그런 다음, 수도 레이블들과 추출된 특징들은 사용자 적대적 학습(SAT) 및 IFDM에 이용된다. 훈련 데이터 세트가 충분하지 않은 사용자 레이블들을 포함하고 있지만, 본 발명은 개별 성능 변동성을 완화할 수 있다는 것을 확인할 수 있다.

표 2

[0104]

Recording Time	noon		night	
Method	ACC	IV	ACC	IV
SAT	90.18	9.75	74.01	16.19
IFDM (k=4)	90.89	9.26	79.03	15.49
IFDM (k=8)	90.54	9.18	76.48	15.43
SAT+IFDM (k=4)	91.53	8.71	77.47	14.52
SAT+IFDM (k=8)	91.24	7.88	77.54	14.76
SAT+IFDM* (k=4)	92.09	7.82	78.46	15.17
SAT+IFDM* (k=8)	91.53	7.83	75.42	13.81

[0105] 도 4를 참조하면, 각각의 사용자에 대한 운전자 졸음 상태 분류 모델의 결과를 확인할 수 있다. 본 발명에 따

른 방법, 즉 SAT+IFDM이 성능의 개인차를 완화한다는 것을 확인할 수 있다. 즉, 그래프의 형태가 평형할수록 개인차가 적다는 것을 의미하므로, 본 발명의 성능이 우수함을 확인할 수 있다.

- [0108] 그러면, 도 5를 참조하여 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법에 대하여 설명한다.
- [0109] 도 5는 본 발명의 바람직한 실시예에 따른 운전자 뇌파 기반 사용자 독립적인 졸음 상태 감지 방법을 설명하기 위한 흐름도이다.
- [0110] 도 5를 참조하면, 졸음 상태 감지 장치(100)는 학습 대상들의 뇌파로부터 제1 뇌파 특징들을 추출하고, 추출된 제1 뇌파 특징들에 대응되는 사용자 레이블을 획득한다(S110).
- [0111] 즉, 졸음 상태 감지 장치(100)는 학습 대상들의 뇌파에서 밴드 패스 필터를 통해 아티팩트를 제거할 수 있다. 그리고, 졸음 상태 감지 장치(100)는 아티팩트가 제거된 뇌파로부터 미분 엔트로피(DE) 특징에 대해 미리 설정된 크기 간격으로 특징을 추출하여 제1 뇌파 특징들을 획득할 수 있다. 그리고, 졸음 상태 감지 장치(100)는 선형 동적 시스템(LDS)을 이용하여 제1 뇌파 특징들을 스무딩할 수 있다.
- [0113] 그런 다음, 졸음 상태 감지 장치(100)는 제1 뇌파 특징들과 사용자 레이블들을 이용하여, 사용자 특징 추출기를 포함하는 사용자 분류 모델을 학습한다(S130).
- [0115] 그리고, 졸음 상태 감지 장치(100)는 제1 뇌파 특징들, 사용자 레이블들 및 제1 뇌파 특징들에 대응되는 졸음 상태 레이블들을 이용하여, 특징 추출기, 레이블 예측기 및 사용자 예측기를 포함하는 운전자 졸음 상태 분류 모델을 학습한다(S150).
- [0116] 이때, 졸음 상태 감지 장치(100)는 제1 뇌파 특징들로부터 사용자 특징 추출기를 통해 획득된 사용자 특징들을 이용하여, 동일한 클래스의 서로 다른 사용자 그룹 간의 와서스테인 거리를 최소화하도록 특징 추출기를 학습할 수 있다.
- [0117] 보다 자세히 설명하면, 졸음 상태 감지 장치(100)는 동일한 클래스(깨어 있음 클래스/피곤함 클래스/졸음 클래스)에 속하는 샘플들에 대해 사용자 특징 추출기를 통해 제1 뇌파 특징들로부터 사용자 특징들을 획득할 수 있다. 그리고, 졸음 상태 감지 장치(100)는 사용자 특징들을 k-means 클러스터링을 통해 클러스터링할 수 있다. 그리고, 졸음 상태 감지 장치(100)는 복수개의 클러스터 중에서 랜덤하게 선택된 서로 다른 2개의 클러스터의 사용자 특징들을 특징 추출기에 입력할 수 있다. 그리고, 졸음 상태 감지 장치(100)는 특징 추출기의 출력인 특징들의 와서스테인 거리를 최소화할 수 있다. 이와 같은 과정을, 졸음 상태 감지 장치(100)는 클래스별로 수행하여 서로 다른 사용자 특징 간의 거리를 최소화하도록 특징 추출기를 학습할 수 있다.
- [0118] 또한, 졸음 상태 감지 장치(100)는 GRL(Gradient Reversal Layer)을 이용하여 운전자 졸음 상태 분류 모델의 사용자 예측기를 사용자 적대적 학습(SAT)할 수 있다.
- [0120] 이후, 졸음 상태 감지 장치(100)는 감지 대상의 뇌파로부터 추출된 제2 뇌파 특징들을 운전자 졸음 상태 분류 모델에 입력하고, 운전자 졸음 상태 분류 모델로부터 감지 대상에 대한 졸음 상태 분류 결과를 획득한다(S170).
- [0123] 이상에서 설명한 본 발명의 실시예를 구성하는 모든 구성요소들이 하나로 결합하거나 결합하여 동작하는 것으로 기재되어 있다고 해서, 본 발명이 반드시 이러한 실시예에 한정되는 것은 아니다. 즉, 본 발명의 목적 범위 안에서라면, 그 모든 구성요소들이 하나 이상으로 선택적으로 결합하여 동작할 수도 있다. 또한, 그 모든 구성요소들이 각각 하나의 독립적인 하드웨어로 구현될 수 있지만, 각 구성요소들의 그 일부 또는 전부가 선택적으로 조합되어 하나 또는 복수개의 하드웨어에서 조합된 일부 또는 전부의 기능을 수행하는 프로그램 모듈을 갖는 컴퓨터 프로그램으로서 구현될 수도 있다. 또한, 이와 같은 컴퓨터 프로그램은 USB 메모리, CD 디스크, 플래쉬 메모리 등과 같은 컴퓨터가 읽을 수 있는 기록 매체(Computer Readable Media)에 저장되어 컴퓨터에 의하여 읽혀지고 실행됨으로써, 본 발명의 실시예를 구현할 수 있다. 컴퓨터 프로그램의 기록 매체로서는 자기기록매체, 광기록매체 등이 포함될 수 있다.
- [0124] 이상의 설명은 본 발명의 기술 사상을 예시적으로 설명한 것에 불과한 것으로서, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 발명의 본질적인 특성에서 벗어나지 않는 범위 내에서 다양한 수정, 변경 및 치환이 가능할 것이다. 따라서, 본 발명에 개시된 실시예 및 첨부된 도면들은 본 발명의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시예 및 첨부된 도면에 의하여 본 발명의 기술 사상의 범위가 한정되는 것은 아니다. 본 발명의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범

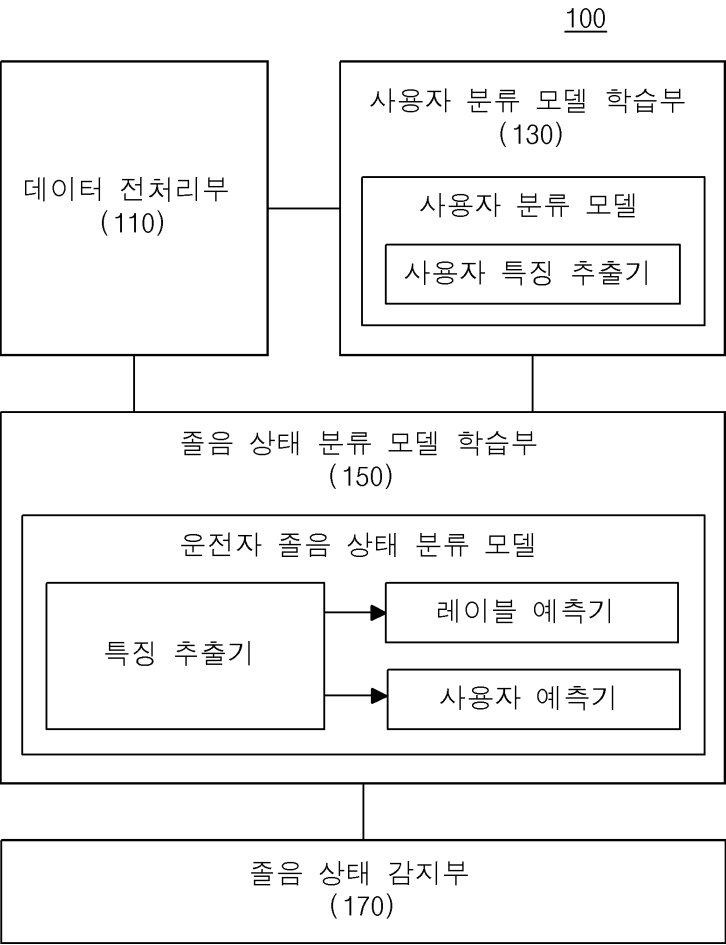
위 내에 있는 모든 기술 사상은 본 발명의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

부호의 설명

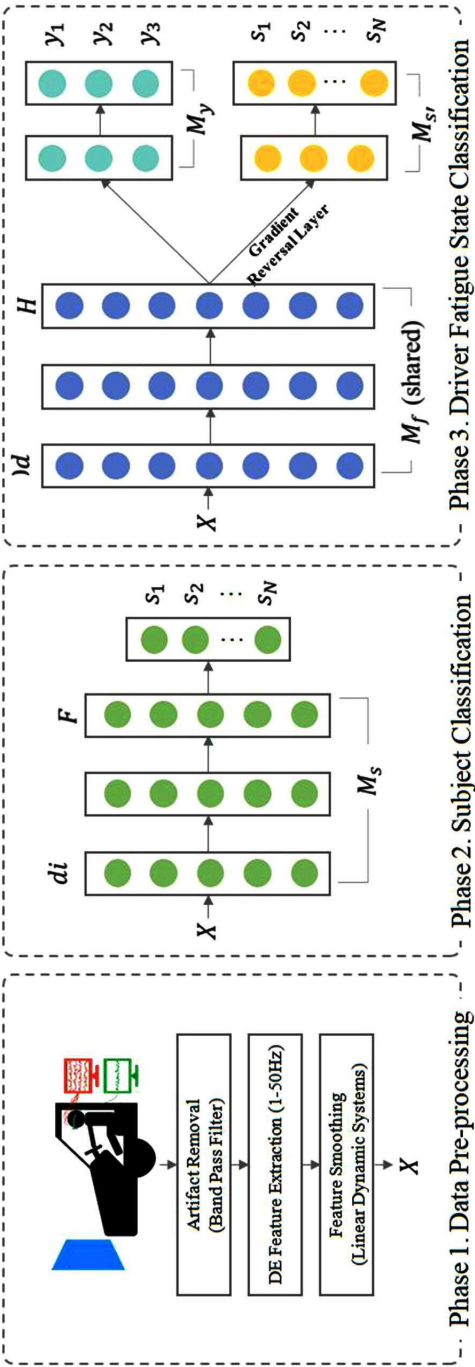
- 100 : 졸음 상태 감지 장치,
- 110 : 데이터 전처리부,
- 130 : 사용자 분류 모델 학습부,
- 150 : 졸음 상태 분류 모델 학습부,
- 170 : 졸음 상태 감지부

도면


도면1




도면2




도면3



도면4



(a) noon



(b) night

도면5

