

(19) 대한민국특허청(KR)
(12) 공개특허공보(A)(11) 공개번호 10-2021-0062565
(43) 공개일자 2021년05월31일

(51) 국제특허분류(Int. Cl.)
G06N 3/06 (2006.01) G06N 3/08 (2006.01)
(52) CPC특허분류
G06N 3/061 (2013.01)
G06N 3/08 (2013.01)
(21) 출원번호 10-2020-0153347
(22) 출원일자 2020년11월17일
심사청구일자 2020년11월17일
(30) 우선권주장
1020190150647 2019년11월21일 대한민국(KR)

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
이성환
서울특별시 강남구 언주로30길 13, B동 2506호 (도곡동, 대림아크로빌)
한동균
서울특별시 강북구 솔매로41길 37-3, 201호 (미아동)
정지훈
서울특별시 성북구 보문로25길 25, 402호 (보문동2가)
(74) 대리인
특허법인엠에이피에스


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 거리 학습을 이용한 사용자간 유사도 반영 특징 추출 기반의 사용자 독립적 뇌-컴퓨터 인터페이스 장치 및 이를 이용한 태스크 분류 방법

(57) 요약

본 발명에 따르는 사용자 독립적 뇌-컴퓨터 인터페이스 장치는 사용자 독립적 뇌-컴퓨터 인터페이스 장치는 메트릭 학습에 기반하여 구축된 뇌 신호의 태스크 분류 학습 모델을 이용하여 사용자의 뇌 신호로부터 태스크를 분류하는 프로그램이 저장된 메모리; 및 상기 프로그램을 수행하는 프로세서를 포함한다. 뇌 신호의 태스크 분류 학
(뒷면에 계속)

대표도 - 도2



습 모델은 뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하고, 상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및, 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하고, 상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축한 것이다.

이 발명을 지원한 국가연구개발사업

과제고유번호	1711080977
과제번호	2015-0-00185-005
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	SW컴퓨팅산업원천기술개발(R&D, 정보화)
연구과제명	(SW 스타랩)이동 환경에서 뇌-컴퓨터 인터페이스를 위한 지능형 패턴인식 소프트웨어

이 개발

기 여 율	1/2
과제수행기관명	고려대학교 산학협력단
연구기간	2019.01.01 ~ 2019.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711080898
과제번호	2017-0-00451-003
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	SW컴퓨팅산업원천기술개발(R&D, 정보화)
연구과제명	(BCI-2세부) 딥러닝을 이용하여 사람의 의도를 인지하는 BCI 기반 뇌인지컴퓨팅 기

술 개발

기 여 율	1/2
과제수행기관명	고려대학교 산학협력단
연구기간	2019.01.01 ~ 2019.12.31

명세서

청구범위

청구항 1

사용자 독립적 뇌-컴퓨터 인터페이스 장치에서 사용되는 뇌 신호의 태스크 분류 학습 모델을 구축하는 방법에 있어서,

뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자 별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하는 단계;

상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하는 단계; 및

상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하는 단계를 포함하되,

상기 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 하는 것인, 뇌 신호의 태스크 분류 학습 모델을 구축하는 방법.

청구항 2

제 1항에 있어서,

상기 사용자 레이블 데이터를 생성하는 단계는

동일 사용자의 서로 다른 세션에서 획득된 뇌 신호는 서로 다른 사용자 식별 정보를 부여하여 서로 다른 사용자 레이블 데이터로 생성하는 것인, 뇌 신호의 태스크 분류 학습 모델을 구축하는 방법.

청구항 3

제 1항에 있어서,

상기 태스크 분류 손실 함수에 곱해지는 제 1 가중치 및 상기 유사도 손실 함수에 곱해지는 제 2 가중치를 조절 함에 따라 상기 태스크 분류 학습 모델의 성능이 조절되는 것인, 뇌 신호의 태스크 분류 학습 모델을 구축하는 방법.

청구항 4

사용자 독립적 뇌-컴퓨터 인터페이스 장치에서 사용되는 뇌 신호의 태스크 분류 학습 모델을 이용하여 뇌 신호의 태스크를 분류하는 방법에 있어서,

복수의 패러다임 중 어느 한 패러다임에 따라 획득한 뇌 신호 데이터를 상기 뇌 신호의 태스크 분류 학습 모델에 입력하여, 상기 뇌 신호 데이터의 태스크를 분류하는 단계를 포함하되,

상기 태스크 분류 학습 모델은

뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자 별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하는 단계;

상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하는 단계; 및

상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하되, 상기 분류 네트워크의 태스크 분류

결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 하는 단계를 수행하여 구축된 것이고,

상기 뇌 신호 데이터의 태스크를 분류하는 단계는

상기 인공 신경망 네트워크 및 상기 분류 네트워크에 상기 뇌 신호 데이터를 입력하여 태스크를 분류하는 것인, 뇌 신호의 태스크를 분류하는 방법.

청구항 5

제 4항에 있어서,

상기 사용자 레이블 데이터를 생성하는 단계는

동일 사용자의 서로 다른 세션에서 획득된 뇌 신호는 서로 다른 사용자 식별 정보를 부여하여 서로 다른 사용자 레이블 데이터로 생성하는 것인, 뇌 신호의 태스크를 분류하는 방법.

청구항 6

제 4항에 있어서,

상기 태스크 분류 손실 함수에 곱해지는 제 1 가중치 및 상기 유사도 손실 함수에 곱해지는 제 2 가중치를 조절함에 따라 상기 태스크 분류 학습 모델의 성능이 조절되는 것인, 뇌 신호의 태스크를 분류하는 방법.

청구항 7

사용자 독립적 뇌-컴퓨터 인터페이스 장치에 있어서,

메트릭 학습(metric learning)에 기반하여 구축된 뇌 신호의 태스크 분류 학습 모델을 이용하여 사용자의 뇌 신호로부터 태스크를 분류하는 프로그램이 저장된 메모리; 및

상기 프로그램을 수행하는 프로세서를 포함하며,

상기 뇌 신호의 태스크 분류 학습 모델은 뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하고, 상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및, 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하고, 상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하되, 상기 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 하는 단계를 수행하여 구축된 것이고,

상기 프로그램은 상기 뇌 신호의 태스크 분류 학습 모델의 상기 인공 신경망 네트워크 및 상기 분류 네트워크에 상기 뇌 신호 데이터를 입력하여 태스크를 분류하는 것인, 사용자 독립적 뇌-컴퓨터 인터페이스 장치.

청구항 8

제 7항에 있어서,

상기 태스크 분류 손실 함수에 곱해지는 제 1 가중치 및 상기 유사도 손실 함수에 곱해지는 제 2 가중치를 조절함에 따라 상기 태스크 분류 학습 모델의 성능이 조절되는 것인, 사용자 독립적 뇌-컴퓨터 인터페이스 장치.

발명의 설명

기술 분야

본 발명은 메트릭 학습(metric learning)을 이용하여 구축한 태스크 분류 학습 모델을 포함하는 사용자 독립적 뇌-컴퓨터 인터페이스 장치 및 이를 이용한 태스크 분류 방법에 관한 것이다.

[0001]

배경 기술

- [0002] 뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI) 장치는 인간의 뇌와 기계간의 연결을 통하여, 직접적인 신체의 움직임 없이 외부기기를 제어하는 인터페이스 장치이다.
- [0003] BCI는 신체를 움직일 수 없는 환자, 신체의 움직임에 어려움이 있는 환자와 같은 사람들을 위해 생활 보조 도구 또는 재활 도구로 사용 될 수 있다. 또한, BCI는 환자뿐만 아니라 일반인들을 위한 엔터테인먼트 서비스 제공 장치, 집중력 향상 도구, 드론 제어, 운동 어플리케이션 등 다양한 용도로 이용될 수 있다.
- [0004] 이와 같은 BCI에서 뇌 신호를 측정하는 방법은 크게 두 가지로 나뉜다. 뇌의 두개골을 열어 뇌파를 취득하는 침습적인 방법과 뇌의 두개골 밖에서 뇌파를 취득하는 비침습적인 방법으로 나뉜다. 침습적 방법의 일 예로는 피질뇌파(Electrocorticography, ECoG) 방법으로 두개골 위에 전극을 삽입하여 뇌파를 측정하는 방법이 알려져 있다. 비침습적 방법보다 정확하고 깨끗한 신호를 취득할 수 있지만 실제로 수술을 진행하여 뇌파의 전극을 삽입해야 한다는 한계점을 가지고 있다. 비침습적 방법으로 가장 많이 이용이 되는 뇌 신호는 뇌의 활동에 따른 전기적 신호를 이용하는 뇌전도(Electroencephalography, EEG)이다. 그 외 비침습적 방법으로, 자기적 신호를 이용하는 뇌자도(Magnetoencephalography, MEG), 혈중 산소포화도의 변화를 이용하는 기능적 자기공명영상(functional Magnetic Resonance Imaging, fMRI) 또는 근적외선 분광장치(Near-infrared Spectroscopy, NIRS) 등 여러 방식을 통해 얻을 수 있다.
- [0005] BCI 기술은 외부자극 혹은 자발적으로 유발되는 뇌 신호를 이용한다. 외부 자극은 시각이나 청각 등과 같은 외부에서 주어지는 특정 신호가 뇌에 반영되는 비자발적 방법이나 움직임을 상상하여 뇌에 반영되는 자발적 방법으로 나눌 수 있다. 외부 자극에 의해 유발되는 비자발적 뇌파 특징으로는 대표적으로 안정-상태 시각 유발 전위(Steady-State Visual Evoked Potential, SSVEP)와 사건 관련 전위(Event-Related Potential, ERP)를 들 수 있다. SSVEP는 사용자가 특정 주파수로 깜빡이는 시각 자극을 응시할 때, 해당 특정 주파수가 뇌의 후두엽에(뇌의 뒷편)유발되도록 하는 방법이고, ERP는 사용자가 특정 자극을 반복적으로 집중하여 응시 할 때, 해당 자극에 대한 반응이 뇌의 후두엽에 유발 되도록 하는 방법이다. 이와 달리, 외부 자극 없이 사용자가 집중하거나 움직임을 상상할 때 자발적으로 발현되는 뇌파 특징으로는 감각 운동 리듬(SensoriMotor Rhythm, SMR)이 있다. SMR은 뇌의 체성감각운동 피질에서 사용자가 특정 부위의 움직임을 상상하는 동작상상(Motor Imagery, MI)을 할 때, 뇌의 좌측 그리고 우측 부분에서 신호의 변화가 일어나고, 이 때 특정 주파수 영역에서 신호의 변화가 발생하는 것을 관찰할 수 있다. 주로, 8~12Hz(Mu rhythm), 18~25Hz(Beta rhythm)의 주파수 영역에서 신호가 감소하는 현상을 볼 수 있는데 이를 사건 관련 탈동기화(Event-Related Desynchronization, ERD)라 부른다. 한편, 뇌 신호를 이용하여 사용자의 의도를 분류하는 BCI 기술은 SSVEP, ERP, MI, 음성 상상과 같이 서로 다른 패러다임 기법을 사용하여 사용자의 의도를 분류할 수 있다.
- [0006] 위와 같은 뇌로부터 취득된 뇌 신호는 크게 5가지의 과정을 거쳐 사용자 의도를 분류하도록 한다. 즉, 1)뇌 신호를 수집하는 데이터 수집 단계, 2)측정된 데이터를 전처리하는 신호 처리 단계, 3) 뇌 신호로부터 유의미한 데이터를 뽑아내는 특징 추출 단계, 4) 데이터로부터 얻어진 정보를 기반으로 결정 경계를 나누는 분류기 학습 단계, 그리고 5) 주어진 결과를 사용자에게 전달하는 피드백 단계로 이루어진다. 이와 같은 뇌 신호 처리 단계를 거친 후 외부 기기를 제어하는 인터페이스 체계를 구축하며, 위의 단계 중 2,3,4 단계는 기계학습 알고리즘을 통해 구현하는 기술이 연구되고 있다.
- [0007] 이와 같은 종래 기술에 따르면, 새로운 사용자가 BCI시스템을 이용하기 위해 약 30분 가량 소요되는 캘리브레이션 과정을 필수적으로 거치게 된다. 캘리브레이션은 분류모델 학습에 필요한 일정량의 사용자별 뇌 신호를 수집하는 측정단계 및 사용자별 뇌신호 분류 모델 학습 과정을 포함한다. 이는 뇌파의 특징 및 패턴이 사용자마다 달라지기 때문에 분류 모델이 새로운 사용자에게 적합한 파라미터를 추정하는 과정이 필요하기 때문이다. 이러한 캘리브레이션 과정은 기존에 뇌 신호를 측정한 경력이 있는 사용자의 경우라도 시간의 변화에 따라 뇌 신호의 비정상성에 의해 그 특징이 변화하고, 뇌 신호 측정 장비가 매실험마다 조금씩 불일치하는 점을 고려한 것이다. 실용적인 BCI 시스템을 위하여 이러한 캘리브레이션을 위한 뇌 신호 측정 과정은 단축 또는 제거될 필요가 있다.
- [0008] 위의 문제를 해결하기 위해 기존에 제안된 사용자 독립적 뇌-컴퓨터 인터페이스 기술로는 강력한 정규화가 적용된 분류기를 통해 소량의 캘리브레이션 데이터를 이용하여 캘리브레이션을 단축하는 방법이 알려져 있다. 또한, 기 구축한 사용자 전체 데이터 풀(pool)을 이용한 분류기 학습을 통해 사용자들 전체에서 공통되고, 일반화된 특징만을 추출하는 방법도 알려져 있다. 전자의 경우 캘리브레이션 과정을 완전히 제거하지 못하며, 소량의

데이터를 반드시 필요로 하고, 새로운 모델을 학습하기 위한 시간까지 필요하다는 단점이 있다. 후자의 기술들은 어느 정도 일반화된 성능을 보장할 수 있으나, 사용자 풀 내부의 상관관계와 사용자 개별적으로 가지는 고유의 특징을 손실하여 특정 사용자에게서 극도로 낮은 성능을 보일 수 있다.

- [0009] 본 발명은 기계학습의 한 범주에 속하는 메트릭 학습(metric learning)을 기반으로 하여 사용자 데이터 풀에서 사용자 개별의 정보를 활용해 인공 신경망 네트워크의 특징 추출부가 사용자 간의 유사도를 고려한 특징을 추출하도록 하고, 이를 통해 사용자 독립적 뇌-컴퓨터 인터페이스 시스템의 분류 성능을 개선한다.

선행기술문헌

특허문헌

- [0010] (특허문헌 0001) 대한민국등록특허 제10-1553256호(발명의 명칭: BCI 시스템의 신뢰성 향상 방법)

발명의 내용

해결하려는 과제

- [0011] 본 발명은 전술한 문제점을 해결하기 위한 것으로, 캘리브레이션 과정을 생략하면서도 뇌-컴퓨터 인터페이스 시스템의 분류 성능을 유지할 수 있는 사용자 독립적 뇌-컴퓨터 인터페이스 장치를 제공하는 것이다.

- [0012] 다만, 본 실시예가 이루고자 하는 기술적 과제는 상기된 바와 같은 기술적 과제로 한정되지 않으며, 또 다른 기술적 과제들이 존재할 수 있다.

과제의 해결 수단

- [0013] 본 발명의 일 실시예에 따르는, 사용자 독립적 뇌-컴퓨터 인터페이스 장치에서 사용되는 뇌 신호의 태스크 분류 학습 모델을 구축하는 방법은 뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하는 단계; 상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하는 단계; 및 상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하는 단계를 포함하되, 상기 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 한다.

- [0014] 본 발명의 다른 실시예에 따르는, 사용자 독립적 뇌-컴퓨터 인터페이스 장치에서 사용되는 뇌 신호의 태스크 분류 학습 모델을 이용하여 뇌 신호의 태스크를 분류하는 방법은, 복수의 패러다임 중 어느 한 패러다임에 따라 획득한 뇌 신호 데이터를 상기 뇌 신호의 태스크 분류 학습 모델에 입력하여, 상기 뇌 신호 데이터의 태스크를 분류하는 단계를 포함하되, 상기 태스크 분류 학습 모델은 뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하는 단계; 상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하는 단계; 및 상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하되, 상기 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 하는 단계를 수행하여 구축된 것이고, 상기 뇌 신호 데이터의 태스크를 분류하는 단계는 상기 인공 신경망 네트워크 및 상기 분류 네트워크에 상기 뇌 신호 데이터를 입력하여 태스크를 분류한다.

- [0015] 본 발명의 다른 실시예에 따르는 사용자 독립적 뇌-컴퓨터 인터페이스 장치는 메트릭 학습에 기반하여 구축된 뇌 신호의 태스크 분류 학습 모델을 이용하여 사용자의 뇌 신호로부터 태스크를 분류하는 프로그램이 저장된 메

모리; 및 상기 프로그램을 수행하는 프로세서를 포함하며, 상기 뇌 신호의 태스크 분류 학습 모델은 뇌 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하고, 상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및, 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하고, 상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하되, 상기 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 하는 단계를 수행하여 구축된 것이고, 상기 프로그램은 상기 뇌 신호의 태스크 분류 학습 모델의 상기 인공 신경망 네트워크 및 상기 분류 네트워크에 상기 뇌 신호 데이터를 입력하여 태스크를 분류하는 것이다.

발명의 효과

[0016] 전술한 본 발명의 과제 해결 수단에 따라, 본 발명은 복수의 사용자로 이루어진 대용량의 뇌 신호 데이터베이스로부터 인공 신경망 네트워크가 복수의 사용자 간의 거리함수, 즉 메트릭을 학습하도록 함으로써, 새로운 사용자의 뇌 신호를 기존 사용자들의 뇌 신호로 학습한 특징 공간에서 분류 할 수 있도록 한다. 이를 통해 기존의 뇌-컴퓨터 인터페이스 시스템 사용시 필요한 초기 캘리브레이션을 제거함으로써, 각각의 사용자가 독립적으로 사용 가능한 사용자 독립적 뇌-컴퓨터 인터페이스를 제공할 수 있어, 사용자 편의성을 향상시킬 수 있다.

도면의 간단한 설명

[0017] 도 1은 본 발명의 일 실시예에 따른 사용자 독립적 뇌-컴퓨터 인터페이스 장치를 도시한 것이다.

도 2는 본 발명의 일 실시예에 따른 뇌 신호의 태스크 분류 학습 모델 구축 과정과 이를 기반으로 뇌 신호의 태스크를 분류 과정을 도시한 순서도이다.

도 3은 본 발명의 일 실시예에 따른 사용자 레이블 데이터 생성과정을 설명하기 위한 도면이다.

도 4는 본 발명의 일 실시예에 따른 인공 신경망 네트워크 구축 과정을 설명하기 위한 도면이다.

도 5는 본 발명의 일 실시예에 따른 인공 신경망 네트워크 구축 결과를 설명하기 위한 도면이다.

도 6은 본 발명의 일 실시예에 따라 구축된 태스크 분류 학습 모델을 이용하여 태스크 분류를 수행하는 과정을 도시한 것이다.

발명을 실시하기 위한 구체적인 내용

[0018] 아래에서는 첨부한 도면을 참조하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 본 발명의 실시예를 상세히 설명한다. 그러나 본 발명은 여러 가지 상이한 형태로 구현될 수 있으며 여기에서 설명하는 실시예에 한정되지 않는다. 그리고 도면에서 본 발명을 명확하게 설명하기 위해서 설명과 관계없는 부분은 생략하였으며, 명세서 전체를 통하여 유사한 부분에 대해서는 유사한 도면 부호를 붙였다.

[0019] 명세서 전체에서, 어떤 부분이 다른 부분과 "연결"되어 있다고 할 때, 이는 "직접적으로 연결"되어 있는 경우뿐 아니라, 그 중간에 다른 소자를 사이에 두고 "전기적으로 연결"되어 있는 경우도 포함한다. 또한 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다.

[0020] 본 명세서에 있어서 '부(部)'란, 하드웨어에 의해 실현되는 유닛(unit), 소프트웨어에 의해 실현되는 유닛, 양방을 이용하여 실현되는 유닛을 포함한다. 또한, 1 개의 유닛이 2 개 이상의 하드웨어를 이용하여 실현되어도 되고, 2 개 이상의 유닛이 1 개의 하드웨어에 의해 실현되어도 된다. 한편, '~부'는 소프트웨어 또는 하드웨어에 한정되는 의미는 아니며, '~부'는 어드레싱 할 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, 데이터베이스, 데이터 구조들, 테이블들, 어레이들 및 변수들을 포함한다. 구성요소들과 '~부'들 안에

서 제공되는 기능은 더 작은 수의 구성요소들 및 '~부'들로 결합되거나 추가적인 구성요소들과 '~부'들로 더 분리될 수 있다. 뿐만 아니라, 구성요소들 및 '~부'들은 디바이스 또는 보안 멀티미디어카드 내의 하나 또는 그 이상의 CPU들을 재생시키도록 구현될 수도 있다.

[0021] 이하에서 언급되는 "저-컴퓨터 인터페이스 장치"는 네트워크를 통해 서버나 타 단말에 접속할 수 있는 컴퓨터나 휴대용 단말기로 구현될 수 있다. 여기서, 컴퓨터는 예를 들어, 웹 브라우저(WEB Browser)가 탑재된 노트북, 데스크톱(desktop), 랩톱(laptop) 등을 포함하고, 휴대용 단말기는 예를 들어, 휴대성과 이동성이 보장되는 무선 통신 장치로서, 각종 이동 통신 기반 단말, 스마트폰, 태블릿 PC 등과 같은 모든 종류의 핸드헬드(Handheld) 기반의 무선 통신 장치를 포함할 수 있다. 또한, "네트워크"는 근거리 통신망(Local Area Network; LAN), 광역 통신망(Wide Area Network; WAN) 또는 부가가치 통신망(Value Added Network; VAN) 등과 같은 유선 네트워크나 이동 통신망(mobile radio communication network) 또는 위성 통신망 등과 같은 모든 종류의 무선 네트워크로 구현될 수 있다.

[0022] 본 발명에서 사용되는 메트릭 학습은 데이터간의 유사도 혹은 거리를 학습 측정 할 수 있는 함수를 학습하는 알고리즘이다. 메트릭 학습은 같은 범주에 속하거나 유사한 데이터에서 추출된 특징간의 거리를 가깝다고 판단하게 하고, 다른 범주에 속하거나 비유사한 데이터에서 추출된 특징간의 거리를 멀다고 판단하는 함수를 학습한다. 딥러닝의 범주에서 메트릭 학습을 확장하면, 딥 네트워크가 사전정의한 거리함수를 이용해 특징 벡터간의 거리를 비교할 때 상술한 메트릭 학습의 목적에 부합하는 특징을 추출하도록 네트워크의 가중치를 학습하는 알고리즘을 포함한다. 이때 네트워크가 추출한 특징간 거리비교 함수로는 일반적으로 유클리드 거리함수가 사용된다. 저 신호의 관점에서 보면 유사한 사용자간 저 신호로부터 추출한 특징이 특징 공간(feature) 상에서 가까이 있고, 비유사한 사용자간 특징은 멀리 존재하도록 특징을 추출하는 것을 목적으로 하는 함수 혹은 네트워크를 학습하는 기계학습 기술을 의미한다.

[0023] 이하, 본 발명의 일 실시예에 대하여 구체적으로 설명하도록 한다.

[0024] 도 1은 본 발명의 일 실시예에 따른 사용자 독립적 저-컴퓨터 인터페이스 장치를 도시한 것이다.

[0025] 저-컴퓨터 인터페이스 장치(100)는 메모리(110), 프로세서(120), 통신모듈(130), 데이터베이스(140)를 포함한다. 또한, 저-컴퓨터 인터페이스 장치(100)는 저파 측정 장치(200)와의 접속을 통해 저신호를 수신할 수 있다. 이때, 저파 측정 장치(200)는 SSVEP, ERP, MI와 같이각 패러다임 별로 상이한 것이 사용될 수 있다.

[0026] 메모리(110)는 메트릭 학습(metric learning)에 기반하여 구축된 저 신호의 태스크 분류 학습 모델을 이용하여 사용자의 저 신호로부터 태스크를 분류하는 프로그램이 저장된다.

[0027] 이때, 저 신호의 태스크 분류 학습 모델은 저 신호 획득을 위한 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성하고, 상기 사용자 레이블 데이터로부터 랜덤하게 추출된 앵커 데이터, 상기 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 긍정 데이터 및, 상기 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 인공 신경망 네트워크를 구축하고, 상기 각 인공 신경망 네트워크 구축 과정에서, 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리는 증가하도록 하는 유사도 손실 함수를 이용하여 메트릭 학습을 수행하고, 상기 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축하되, 상기 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수와 상기 유사도 손실 함수를 합산한 통합 손실 함수의 값이 최소값이 되도록 하는 단계를 수행하여 구축된 것이다.

[0028] 이 태스크 분류 프로그램은 저 신호의 태스크 분류 학습 모델의 인공 신경망 네트워크 및 분류 네트워크에 저 신호 데이터를 입력하여 태스크를 분류한다.

[0029] 또한, 메모리(110)는 프로세서(120)가 처리하는 데이터를 일시적 또는 영구적으로 저장하는 기능을 수행한다. 여기서, 메모리(110)는 휘발성 저장 매체(volatile storage media) 또는 비휘발성 저장 매체(non-volatile storage media)를 포함할 수 있으나, 본 발명의 범위가 이에 한정되는 것은 아니다. 메모리(110)는 프로세서(120)의 처리 및 제어를 위한 운영체제 등 별도의 프로그램이 저장될 수도 있고, 입력되거나 출력되는 데이터들의 임시 저장을 위한 기능을 수행할 수도 있다.

[0030] 프로세서(120)는 메모리(110)에 프로그램을 실행하여, 학습 모델 구축 과정과 태스크 분류 과정 등을 수행한다.

[0031] 여기서, 프로세서(120)는 프로세서(processor)와 같이 데이터를 처리할 수 있는 모든 종류의 장치를 포함할 수

있다. 여기서, '프로세서(processor)'는, 예를 들어 프로그램 내에 포함된 코드 또는 명령으로 표현된 기능을 수행하기 위해 물리적으로 구조화된 회로를 갖는, 하드웨어에 내장된 데이터 처리 장치를 의미할 수 있다. 이와 같이 하드웨어에 내장된 데이터 처리 장치의 일 예로써, 마이크로프로세서(microprocessor), 중앙처리장치(central processing unit: CPU), 프로세서 코어(processor core), 멀티프로세서(multiprocessor), ASIC(application-specific integrated circuit), FPGA(field programmable gate array) 등의 처리 장치를 망라할 수 있으나, 본 발명의 범위가 이에 한정되는 것은 아니다.

- [0032] 통신모듈(130)은 통신망과 연동하여 뇌파 측정 장치(200)로 송수신되는 신호를 패킷 데이터 형태로 제공하는 데 필요한 통신 인터페이스를 제공한다. 여기서, 통신 모듈(130)은 다른 네트워크 장치와 유무선 연결을 통해 제어 신호 또는 데이터 신호와 같은 신호를 송수신하기 위해 필요한 하드웨어 및 소프트웨어를 포함하는 장치일 수 있다.
- [0033] 데이터베이스(140)는 각 사용자들의 뇌 신호 데이터, 그리고 이로부터 획득한 대용량 훈련 데이터를 저장한다. 또한, 데이터베이스(140)에는 각각의 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 생성한 사용자 레이블 데이터가 저장된다.
- [0034] 도 2는 본 발명의 일 실시예에 따른 뇌 신호의 태스크 분류 학습 모델 구축 과정과 이를 기반으로 뇌 신호의 태스크를 분류 과정을 도시한 순서도이다.
- [0035] 먼저, 사용자 독립적 뇌-컴퓨터 인터페이스 장치(100)는 뇌파 측정 장치(200)로부터 뇌 신호를 수신한다. 이때, 수신하는 뇌 신호는 패러다임 별로 상이할 수 있다.
- [0036] 다음으로, 각각의 패러다임 별로, 분류하고자 하는 움직임 상상 클래스를 나타내는 태스크 레이블에 사용자별 식별 번호를 추가하여 사용자 레이블 데이터를 생성한다.
- [0037] 도 3은 본 발명의 일 실시예에 따른 사용자 레이블 데이터 생성과정을 설명하기 위한 도면이다.
- [0038] 복수의 사용자로부터 획득한 대용량 훈련 데이터에 속한 서로 다른 사용자들의 뇌파는 사용자들이 공통된 일부 특징을 공유하고 있다고 가정하며, 이러한 특징은 대다수의 사용자에서 일반적으로 나타나는 특징과 소규모 사용자 그룹만이 가지는 특징으로 나뉜다고 가정한다.
- [0039] 본 발명에서는 사용자간 유사도 메트릭 학습을 위해 훈련 데이터셋에 사용자 식별 정보를 추가적으로 포함시킨다. 기존의 데이터는 태스크 정보만을 레이블로 가지고 있으며, 이때 태스크 정보는 데이터 구축시 할당된 패러다임(MI, SSVEP, ERP 등)별 분류하고자 하는 뇌 신호 속의 의도에 해당하는 클래스 레이블을 포함한다. 본 발명에서는 태스크 레이블에 사용자별 고유 식별 정보를 추가하여 사용자 레이블 데이터를 생성한다.
- [0040] 종래의 경우, MI 패러다임의 오른손, 왼손, 발, 허 움직임 상상 클래스 정보를 포함하는 태스크 레이블만을 사용하였다. 본 발명에서는 사용자별 식별 번호를 추가하여, 도시된 바와 같이, 2클래스 분류 데이터를 10명의 사용자에게서 취득한 경우, 각 사용자가 2개씩(태스크의 개수)의 레이블을 할당받아 총 20개로 분류가 가능한 사용자 레이블이 생성된다.
- [0041] 이러한, 사용자 레이블 생성과정에서, 동일 사용자의 서로 다른 세션에서 획득된 뇌 신호는 뇌 신호의 비정상성을 고려하여 서로 다른 사용자 식별 정보를 부여하여, 서로 다른 사용자 레이블로 할당할 수 있다. 또한 사용자 별로 비정상성의 정도가 다르기 때문에 사용자 종속적 분류기를 이용한 사전 평가 단계를 거쳐 세션 변화에 독립적 사용이 가능한 사용자의 경우 동일한 사용자 레이블로 할당할 수 있다.
- [0042] 다시 도 2를 참조하면, 메트릭 학습에 기반한 인공 신경망 네트워크를 구축한다(S230).
- [0043] 도 4는 본 발명의 일 실시예에 따른 인공 신경망 네트워크 구축 과정을 설명하기 위한 도면이고, 도 5는 본 발명의 일 실시예에 따른 인공 신경망 네트워크 구축 결과를 설명하기 위한 도면이다.
- [0044] 우선, 사용자 레이블 데이터로부터 앵커 데이터, 긍정 데이터, 부정 데이터를 각각 추출한다. 앵커 데이터는 사용자 레이블 데이터로부터 랜덤하게 추출된 것으로서, 기준 데이터로서의 역할을 수행하며, 태스크의 분류 대상이 되는 것이다.
- [0045] 긍정 데이터는 앵커 데이터와 동일한 사용자 레이블을 갖는 데이터로 구성된 것이다. 예를 들면, 앵커 데이터와 동일한 사용자 식별 번호를 갖는 것이거나, 앵커 데이터와 동일한 태스크 레이블을 갖되 시점이 상이한 태스크 레이블을 갖는 것일 수 있다. 이러한 경우, 앵커 데이터와 긍정 데이터의 유사성이 높으므로 각 특징 벡터 간의 거리는 가까워질 수 있다.

- [0046] 부정 데이터는 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 것이다. 예를 들면, 사용자 식별 번호가 다른 사용자 레이블 데이터 부정 데이터에 포함시킨다. 이러한 경우, 앵커 데이터와 부정 데이터의 유사성이 낮아지므로 각 특징 벡터 간의 거리는 증가할 수 있다.
- [0047] 본 발명에서는 앵커 데이터를 기초로 앵커 데이터의 특징을 추출하여 인공 신경망 네트워크를 구축하고, 긍정 데이터를 기초로 긍정 데이터의 특징을 추출하여 상기 인공 신경망 네트워크를 구축하고, 앵커 데이터와 상이한 사용자 레이블을 갖는 데이터로 구성된 부정 데이터를 기초로 부정 데이터의 특징을 추출하여 상기 인공 신경망 네트워크를 구축한다. 이때, 인공 신경망 네트워크로는 DNN(Deep Neural Network), CNN(Convolution Neural Network), RNN(Recurrent Neural Network) 등이 사용될 수 있다. 그리고, 학습 모델 구축과정에서 인공 신경망 네트워크 간에 가중치가 공유될 수 있다.
- [0048] 그리고, 앵커 데이터, 긍정 데이터, 부정 데이터를 순차적으로 입력하여 인공 신경망 네트워크를 구축하는 과정에서 앵커 데이터의 특징 벡터와 긍정 데이터의 특징 벡터간의 거리($D_{positive}$)는 감소하고, 앵커 데이터의 특징 벡터와 부정 데이터의 특징 벡터간의 거리($D_{negative}$)는 증가하도록 하는 유사도 손실 함수($L_{similarity}$)를 이용하여 메트릭 학습을 수행한다.
- [0049] 이때, 유사도 손실함수는 아래와 같이 수학적 식 1에 의해 정의된다.
- [0050] [수학적 식 1]
- [0051]
$$L_{similarity} = \max(0, D_{positive} - D_{negative} + margin)$$
 , $margin$: 사용자 정의 매개변수
- [0052] 사용자 정의 매개변수는 입력 데이터의 특성에 따라 조절될 수 있다.
- [0053] 수학적 식 1은 $D_{positive} < D_{negative} - margin$ 가 만족되지 않는 경우에 학습을 수행한다. 거리 측정 함수로는 유클리드 거리를 사용할 수 있으나, 이는 예시에 해당하는 것으로서, 다른 함수로 대체될 수 있다.
- [0054] 이와 같은 메트릭 학습 과정을 거치게 되면, 도 5에 도시된 바와 같이, 메트릭 학습 후 특징 공간에서 동일 사용자(같은 식별 번호로 표시됨)에서 추출된 특징이 서로 가깝게 분포하는 것을 확인할 수 있다. 점선은 사용자 고유의 특징이 더 잘 보존된 사용자들의 특징 추출 결과를 의미하고, 실선은 유사한 특징을 공유하기 때문에 특징 공간에서 가깝게 분포하는 사용자들을 의미한다.
- [0055] 다음으로, 인공 신경망 네트워크의 가중치를 이용하여 분류 네트워크를 구축한다(S240).
- [0056] 분류 네트워크는 새롭게 입력된 뇌 신호를 입력되면, 해당 뇌 신호가 나타내는 태스크를 분류하는 기능을 수행한다. 이를 위해, 인공 신경망 네트워크에 구축된 가중치를 분류 네트워크에 입력하여 분류 네트워크를 구축한다.
- [0057] 이때, 분류 네트워크의 태스크 분류 결과를 측정하는 태스크 분류 손실함수를 정의한다. 태스크 분류 손실함수(L_{task})는 수학적 식 2와 같이 정의될 수 있다.
- [0058] [수학적 식 2]
- [0059]
$$L_{task} = CEE = - \sum_i^C t_i \log(s_i)$$
- [0060] 이때, t_i 와 s_i 는 C에서의 각 클래스(i)를 위한 참값(groundtruth)과 CNN 점수를 각각 나타냄
- [0061] 태스크 분류 손실함수(L_{task})로는 크로스엔트로피(cross entropy), 평균 제곱 오차(MSE: Mean Squared Error) 등의 손실 함수가 이용될 수 있으며 본 발명이 이에 한정되지는 않는다.
- [0062] 최종적으로는, 수학적 식 3과 같이 유사도 손실 함수에 태스크 분류 손실함수를 합산한 통합 손실 함수(L)의 값이 최솟값을 갖도록 하는 제약조건을 반영하여, 분류 모델의 성능을 조절한다. 예를 들어, 사용자 정의 매개변수에 따라 태스크 분류 손실 함수의 비율이 상대적으로 더 커지면, 분류기 성능 향상과 빠른 학습을 기대할 수 있다.

[0063] [수학식 3]

[0064]
$$L = \alpha L_{task} + (1 - \alpha) L_{similarity} , a : \text{사용자 정의 매개변수}$$

[0065] 여기까지의 단계(S210~S240)를 수행함에 따라, 본 발명에 따른 태스크 분류 학습 모델을 구축할 수 있다.

[0066] 여기에 더하여, 이와 같이 구축된 태스크 분류 학습 모델을 이용하여, 태스크 분류를 추가적으로 수행할 수 있다(S250).

[0067] 도 6은 본 발명의 일 실시예에 따라 구축된 태스크 분류 학습 모델을 이용하여 태스크 분류를 수행하는 과정을 도시한 것이다.

[0068] 즉, 앞선 과정에서 구축된 인공 신경망 네트워크(610) 및 분류 네트워크(620)에 뇌 신호 데이터를 입력하여 태스크를 분류한다.

[0069] 이때, 인공 신경망 네트워크(610)는 도 4의 과정을 통해 구축한 인공 신경망 네트워크(410)의 가중치가 저장된 것이고, 분류 네트워크(620)는 도 4의 과정을 통해 구축한 분류 네트워크의 가중치가 저장된 것이다.

[0070] 인공 신경망 네트워크(610)는 뇌 신호가 입력되면 뇌신호와 가중치를 곱하여, 사용자간 유사도 정보를 고려한 특징을 추출한 후 분류 네트워크(620)를 통해 분류한다.

[0071] 이와 같은 분류 결과는 사용자 독립적 뇌-컴퓨터 인터페이스 장치를 통해 출력되며, 뇌-컴퓨터 인터페이스 장치에 접속된 외부 장치의 동작을 제어하는데 활용될 수 있다.

[0072] 본 발명의 일 실시예는 컴퓨터에 의해 실행되는 프로그램 모듈과 같은 컴퓨터에 의해 실행가능한 명령어를 포함하는 기록 매체의 형태로도 구현될 수 있다. 컴퓨터 판독 가능 매체는 컴퓨터에 의해 액세스될 수 있는 임의의 가용 매체일 수 있고, 휘발성 및 비휘발성 매체, 분리형 및 비분리형 매체를 모두 포함한다. 또한, 컴퓨터 판독 가능 매체는 컴퓨터 저장 매체를 포함할 수 있다. 컴퓨터 저장 매체는 컴퓨터 판독가능 명령어, 데이터 구조, 프로그램 모듈 또는 기타 데이터와 같은 정보의 저장을 위한 임의의 방법 또는 기술로 구현된 휘발성 및 비휘발성, 분리형 및 비분리형 매체를 모두 포함한다. 본 발명의 방법 및 시스템은 특정 실시예와 관련하여 설명되었지만, 그것들의 구성 요소 또는 동작의 일부 또는 전부는 범용 하드웨어 아키텍처를 갖는 컴퓨터 시스템을 사용하여 구현될 수 있다.

[0073] 전술한 본 발명의 설명은 예시를 위한 것이며, 본 발명이 속하는 기술분야의 통상의 지식을 가진 자는 본 발명의 기술적 사상이나 필수적인 특징을 변경하지 않고서 다른 구체적인 형태로 쉽게 변형이 가능하다는 것을 이해할 수 있을 것이다. 그러므로 이상에서 기술한 실시예들은 모든 면에서 예시적인 것이며 한정적이 아닌 것으로 이해해야만 한다. 예를 들어, 단일형으로 설명되어 있는 각 구성 요소는 분산되어 실시될 수도 있으며, 마찬가지로 분산된 것으로 설명되어 있는 구성 요소들도 결합된 형태로 실시될 수 있다.

[0074] 본 발명의 범위는 상기 상세한 설명보다는 후술하는 특허청구범위에 의하여 나타내어지며, 특허청구범위의 의미 및 범위 그리고 그 균등 개념으로부터 도출되는 모든 변경 또는 변형된 형태가 본 발명의 범위에 포함되는 것으로 해석되어야 한다.

부호의 설명

[0075] 100: 뇌-컴퓨터 인터페이스 장치

110: 메모리

120: 프로세서


130: 통신모듈

140: DB


200: 뇌파 측정 장치

도면

도면1




도면2




도면3



도면4



도면5



도면6

