



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0027301
(43) 공개일자 2025년02월26일

(51) 국제특허분류(Int. Cl.)

G06N 3/096 (2023.01) G06N 3/0455 (2023.01)
G06N 3/0495 (2023.01) G06N 3/09 (2023.01)
G06N 3/094 (2023.01) G06V 10/764 (2022.01)
G06V 10/77 (2022.01)

(52) CPC특허분류

G06N 3/096 (2023.01)
G06N 3/0455 (2023.01)

(21) 출원번호 10-2023-0106740

(22) 출원일자 2023년08월16일

심사청구일자 2023년08월16일

(71) 출원인

고려대학교 산학협력단

서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)

(72) 발명자

이성환

서울특별시 강남구 언주로30길 13, 비동 2902호
(도곡동, 대림아크로빌, 대림아크로텔)

은강

서울특별시 성북구 장월로1라길 7, 301호 (상월곡동, 동덕세르빌)

(뒷면에 계속)

(74) 대리인

윤귀상


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 생성 전이 학습 장치 및 그 방법

(57) 요약

본 발명의 일 실시예는 소스데이터와 타겟데이터를 입력받는 데이터 입력부(10); 상기 소스데이터로부터 이상치를 제거하고 데이터를 증강하는 전처리부(20); 상기 전처리부(20)로부터 전달된 상기 소스데이터의 특징벡터와 타겟데이터의 특징벡터를 생성하는 제 1 인코더부; 상기 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성하는 생성부(40)로서, 상기 생성부(40)는 상기 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습된 것인 상기 생성부(40); 상기 전이데이터의 특징벡터를 생성하는 제 2 인코더부; 및 상기 제 2 인코더부로부터 생성된 전이데이터의 특징벡터를 분류하는 분류부(70)로서, 상기 분류부(70)는 상기 전이데이터의 분류결과와 상기 소스데이터의 분류결과가 일치하도록 학습된 것인 상기 분류부(70)를 포함하는 생성 전이 학습장치(1)를 제공한다.

대표도 - 도1



(52) CPC특허분류

G06N 3/0495 (2023.01)

G06N 3/09 (2023.01)

G06N 3/094 (2023.01)

G06V 10/764 (2023.08)

G06V 10/77 (2022.01)

(72) 발명자

신혜빈

경기도 김포시 김포한강2로 362 (장기동 청송마을
중흥에스-클래스)610동 601호

이병후

경기도 안양시 만안구 전파로61번길 28 (안양동)
광신 프로그레스리버뷰 201동 2203호

이 발명을 지원한 국가연구개발사업

과제고유번호	1711193973
과제번호	2019-0-00079-005
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성
연구과제명	인공지능대학원지원(고려대학교)
기 여 율	0.33/1
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	AI혁신허브 사업
연구과제명	인공지능 혁신 허브 연구 개발
기 여 율	0.33/1
과제수행기관명	고려대학교산학협력단
연구기간	2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711190390
과제번호	2022R1A2C3009750
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	MetaSkin: 피부 터치로 메타버스에서의 의사 소통 및 환경 제어가 가능한 차세대 뉴
로봇틱 인터페이스 핵심 기술 개발	
기 여 율	0.34/1
과제수행기관명	고려대학교
연구기간	2022.03.01 ~ 2026.02.28

명세서

청구범위

청구항 1

소스데이터와 타겟데이터를 입력받는 데이터 입력부(10);

상기 소스데이터로부터 이상치를 제거하고 데이터를 증강하는 전처리부(20);

상기 전처리부(20)로부터 전달된 상기 소스데이터의 특징벡터와 타겟데이터의 특징벡터를 생성하는 제 1 인코더부;

상기 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성하는 생성부(40)로서, 상기 생성부(40)는 상기 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습된 것인 상기 생성부(40);

상기 전이데이터의 특징벡터를 생성하는 제 2 인코더부; 및

상기 제 2 인코더부로부터 생성된 전이데이터의 특징벡터를 분류하는 분류부(70)로서, 상기 분류부(70)는 상기 전이데이터의 분류결과와 상기 소스데이터의 분류결과가 일치하도록 학습된 것인 상기 분류부(70)를 포함하는 생성 전이 학습 장치(1).

청구항 2

청구항 1에 있어서,

상기 생성부(40) 및 상기 제2 인코더부(50)와 함께 작동하여 분포적응 훈련 프로세스를 수행하는 판별부(60)를 더 포함하며,

상기 생성부(40)는 분포가 상기 타겟데이터와 정렬되도록 상기 소스데이터에서 상기 전이데이터를 생성하며,

상기 판별부(60)는 상기 전이데이터의 특징벡터와 상기 타겟데이터의 특징벡터를 구별하며,

상기 생성부(40)는 상기 판별부(60)가 상기 타겟데이터의 특징벡터와 상기 전이데이터의 특징벡터를 구별할 수 없을 때까지, 상기 전이데이터를 생성하도록 훈련되는 것을 특징으로 하는, 생성 전이 학습 장치(1).

청구항 3

청구항 2에 있어서,

상기 소스데이터는 뇌전도(EEG) 신호를 포함하며, 상기 생성부(40) 및 상기 분류부(70)는 각기 상기 학습됨으로써, 피험자 간 EEG 신호에 대해 일반화된 모터 이미지 EEG 분류를 하는 것을 특징으로 하는, 생성 전이 학습 장치(1).

청구항 4

청구항 3에 있어서,

상기 생성 전이 학습 장치(1)가 상기 일반화된 모터 이미지 EEG 분류를 하는 학습의 전체 손실함수는, 상기 판별부(60)와 상기 생성부(40) 간의 상기 분포적응 프로세스로부터 계산되는 GAN손실함수와, 상기 전이데이터의 분류결과와 상기 소스데이터의 분류결과가 일치하도록 상기 분류부(70)가 학습되는 과정으로부터 계산되는 분류 손실함수를 포함하는 것을 특징으로 하는, 생성 전이 학습 장치(1).

청구항 5

생성 전이 학습 방법에 있어서,

데이터 입력부(10)가 소스데이터와 타겟데이터를 입력받는 데이터 입력 단계(S10);

전처리부(20)가 상기 소스데이터로부터 이상치를 제거하고 데이터를 증강하는 전처리 단계(S20);

제1 인코더부(30)가 상기 전처리부(20)로부터의 증강된 데이터와 상기 타겟데이터를 받아 상기 소스데이터와 상기 타겟데이터의 각각의 특징벡터를 생성하는 단계(S30);

생성부(40)가 상기 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성하는 단계(S40);

제2 인코더부(50)가 상기 전이데이터의 특징벡터를 생성하는 단계(S50);

판별부(60)가 상기 생성부(40) 및 상기 제2 인코더부(50)와 함께 분포 적응 프로세스를 수행함으로써 상기 생성부(40)가 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습되는 단계(S60); 및

분류부(70)가 제 2 인코더부로부터 생성된 전이된 특징벡터를 분류하되, 전이된 특징벡터의 분류 결과가 소스데이터의 특징벡터의 분류 결과와 일치하도록 훈련되는 단계(S70)를 포함하는 것을 특징으로 하는, 생성 전이 학습 방법.

청구항 6

청구항 5에 있어서,

상기 생성부(40)가 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습되는 단계는,

상기 생성부(40)가 상기 타겟데이터와 정렬되도록 상기 소스데이터에서 상기 전이데이터를 생성하는 단계;

상기 판별부(60)가 상기 전이데이터의 특징벡터와 상기 타겟데이터의 특징벡터를 구별하는 단계;

상기 생성부(40)는 상기 판별부(60)가 상기 타겟데이터의 특징벡터와 상기 전이데이터의 특징벡터를 구별할 수 없을 때까지, 상기 전이데이터를 생성하는 단계를 포함하는 것을 특징으로 하는, 생성 전이 학습 방법.

청구항 7

청구항 6에 있어서,

상기 소스데이터는 뇌전도(EEG) 신호를 포함하며,

상기 전처리 단계는,

cbaDBSCAN 방법으로 상기 이상치를 제거하는 단계;

주성분 분석(PCA)을 사용하여 상기 소스데이터의 차원을 축소하는 단계; 및

MixUp을 사용하여 데이터를 증가시키는 단계를 포함하는 것을 특징으로 하는, 생성 전이 학습 방법.

청구항 8

청구항 7에 있어서,

분포 적응 프로세스에서, 소스 도메인에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 내부 클래스 전송 메커니즘을 사용하는 것을 특징으로 하는, 생성 전이 학습 방법.

발명의 설명

기술 분야

[0001] 본 발명은 생성 전이 학습 장치 및 그 방법에 관한 것으로, 더욱 상세하게는 뇌-컴퓨터 인터페이스(BCI) 기술에서 타겟데이터 중심의 공간과 고품질 소스데이터 선택의 중요성을 강조하는 새로운 비지도 방법을 통해 도메인 적응을 하는 생성 전이 학습 장치 및 그 방법에 관한 것이다.

배경 기술

[0003] 뇌-컴퓨터 인터페이스(BCI) 기술에 있어서, 기존 기술은 주로 침습적 또는 비침습적 방법(예: 뇌전도(EEG))을 통한 뇌 신호의 획득과 해독을 중심으로 발전해 왔다. 이 분야의 주요 과제 중 하나는 EEG 신호의 노이즈 및 외부 아티팩트로 인해 수집된 데이터의 품질과 양에 본질적 결함으로 인해 상당한 어려움을 야기한다는 점이다. 이러한 문제를 해결하기 위해 도메인 일반화(DG, Domain Generalization) 및 도메인 적응(DA, Domain Adaptation)과 같은 기법들은 주제(subjects) 간의 데이터 분포의 차이와 분포 이동을 해결하는 데 사용될 수 있다. 그러나 DG의 실용적인 구현은 종종 어렵기 때문에, DA가 보다 실용적인 대안이 될 수 있다. DA를 위한 전통적인 방법론에는 매개변수 상관 가설, 부분 공간 학습, 매니폴드 학습이 포함되며, 최근에는 신경망 기반 접근법이 선호되고 있다. 그러나 이러한 기법들은 일반적으로 라벨이 부착된 타겟 도메인(대상 도메인) 데이터를 필요로 하며, 이는 항상 BCI 응용 프로그램에서 사용할 수 있는 것은 아니다. 따라서 보다 포괄적인 이해와 검토를 위해, 모든 신호 특성을 활용하는 비지도 도메인 적응(UDA, (Unsupervised Domain Adaptation) 방법을 고려하는 것이 유용하다. 이러한 UDA 방법의 보편적인 적용 가능성을 상승시키기 위해 효과적인 전이 학습(TL)을 위한 관련성있고 품질이 좋은 소스데이터가 필요하다. 특히 소스 도메인과의 타겟 도메인 간의 공유 분포를 학습함으로써 타겟데이터의 무결성이 손상될 수 있으므로, 의료 응용 프로그램에서 타겟데이터의 무결성을 유지하는 것이 중요하며, 따라서 특히 의료 BCI에서 최적의 결과를 위해 전송을 위한 소스데이터의 품질을 우선시하는 것이 중요하다.

발명의 내용

해결하려는 과제

[0005] 본 발명이 이루고자 하는 기술적 과제는 뇌-컴퓨터 인터페이스(BCI)를 위한 도메인 적응(DA) 패러다임 내에서 주요 과제를 해결하는 생성 전이 학습 장치 및 그 방법을 제공하는 것이다.

[0006] 본 발명이 이루고자 하는 기술적 과제는, 자원이 많이 들고 획득하기 어려운 대량의 라벨링된 목표 데이터가 필요한 문제를 해소하는 생성 전이 학습 장치 및 그 방법을 제공하는 것이다.

[0007] 본 발명이 이루고자 하는 기술적 과제는, 다양한 시나리오에 적용할 수 있도록, 확장성과 효율성을 갖춘 생성 전이 학습 장치 및 그 방법을 제공하는 것이다.

[0008] 본 발명이 이루고자 하는 기술적 과제는, 모델이 다양한 입력과 조건을 효과적으로 처리할 수 있도록 함으로써, 전송된 데이터의 일반화 능력을 가진 생성 전이 학습 장치 및 그 방법을 제공하는 것이다.

[0009] 본 발명이 이루고자 하는 기술적 과제는 이상에서 언급한 기술적 과제로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0011] 상기 기술적 과제를 달성하기 위하여, 본 발명의 일 실시예는 소스데이터와 타겟데이터를 입력받는 데이터 입력부(10); 상기 소스데이터로부터 이상치를 제거하고 데이터를 증강하는 전처리부(20); 상기 전처리부(20)로부터 전달된 상기 소스데이터의 특징벡터와 타겟데이터의 특징벡터를 생성하는 제 1 인코더부; 상기 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성하는 생성부(40)로서, 상기 생성부(40)는 상기 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습된 것인 상기 생성부(40); 상기 전이데이터의 특징벡터를 생성하는 제 2 인코더부; 및 상기 제 2 인코더부로부터 생성된 전이데이터의 특징벡터를 분류하는 분류부(70)

로서, 상기 분류부(70)는 상기 전이데이터의 분류결과와 상기 소스데이터의 분류결과가 일치하도록 학습된 것인 상기 분류부(70)를 포함하는 생성 전이 학습 장치를 제공한다.

[0012] 본 발명의 실시예에 있어서, 상기 생성부(40) 및 상기 제2 인코더부(50)와 함께 작동하여 분포적응 훈련 프로세스를 수행하는 판별부(60)를 더 포함하며, 상기 생성부(40)는 분포가 상기 타겟데이터와 정렬되도록 상기 소스데이터에서 상기 전이데이터를 생성하며, 상기 판별부(60)는 상기 전이데이터의 특징벡터와 상기 타겟데이터의 특징벡터를 구별하며, 상기 생성부(40)는 상기 판별부(60)가 상기 타겟데이터의 특징벡터와 상기 전이데이터의 특징벡터를 구별할 수 없을 때까지, 상기 전이데이터를 생성하도록 훈련될 수 있다.

[0013] 본 발명의 실시예에 있어서, 상기 소스데이터는 뇌전도(EEG) 신호를 포함하며, 상기 생성부(40) 및 상기 분류부(70)는 각기 상기 학습됨으로써, 피험자 간 EEG 신호에 대해 일반화된 모터 이미지 EEG 분류를 할 수 있다.

[0014] 본 발명의 실시예에 있어서, 상기 생성 전이 학습 장치가 상기 일반화된 모터 이미지 EEG 분류를 하는 학습의 전체 손실함수는, 상기 판별부(60)와 상기 생성부(40) 간의 상기 분포적응 프로세스로부터 계산되는 GAN손실함수와, 상기 전이데이터의 분류결과와 상기 소스데이터의 분류결과가 일치하도록 상기 분류부(70)가 학습되는 과정으로부터 계산되는 분류손실함수를 포함할 수 있다.

[0015] 상기 기술적 과제를 달성하기 위하여, 본 발명의 다른 실시예는, 생성 전이 학습 방법에 있어서, 데이터 입력부(10)가 소스데이터와 타겟데이터를 입력받는 데이터 입력 단계(S10); 전처리부(20)가 상기 소스데이터로부터 이상치를 제거하고 데이터를 증강하는 전처리 단계(S20); 제1 인코더부가 상기 전처리부(20)로부터의 증강된 데이터와 상기 타겟데이터를 받아 상기 소스데이터와 상기 타겟데이터의 각각의 특징벡터를 생성하는 단계(S30); 생성부(40)가 상기 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성하는 단계(S40); 제2 인코더부(50)가 상기 전이데이터의 특징벡터를 생성하는 단계(S50); 판별부(60)가 상기 생성부(40) 및 상기 제2 인코더부(50)와 함께 분포 적응 프로세스를 수행함으로써 상기 생성부(40)가 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습되는 단계(S60); 및 분류부(70)가 제2 인코더부로부터 생성된 전이된 특징벡터를 분류하되, 전이된 특징벡터의 분류 결과가 소스데이터의 특징벡터의 분류 결과와 일치하도록 훈련되는 단계(S70)를 포함하는 것을 특징으로 하는, 생성 전이 학습 방법을 제공한다.

[0016] 본 발명의 실시예에 있어서, 상기 생성부(40)가 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습되는 단계는, 상기 생성부(40)가 상기 타겟데이터와 정렬되도록 상기 소스데이터에서 상기 전이데이터를 생성하는 단계; 상기 판별부(60)가 상기 전이데이터의 특징벡터와 상기 타겟데이터의 특징벡터를 구별하는 단계; 상기 생성부(40)는 상기 판별부(60)가 상기 타겟데이터의 특징벡터와 상기 전이데이터의 특징벡터를 구별할 수 없을 때까지, 상기 전이데이터를 생성하는 단계를 포함할 수 있다.

[0017] 본 발명의 실시예에 있어서, 상기 소스데이터는 뇌전도(EEG) 신호를 포함하며, 상기 전처리 단계는, cbaDBSCAN 방법으로 상기 이상치를 제거하는 단계; 주성분 분석(PCA)을 사용하여 상기 소스데이터의 차원을 축소하는 단계; 및 MixUp을 사용하여 데이터를 증가시키는 단계를 포함할 수 있다.

[0018] 본 발명의 실시예에 있어서, 상기 분포 적응 프로세스에서, 소스 도메인에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 내부 클래스 전송 메커니즘을 사용할 수 있다.

발명의 효과

[0020] 본 발명의 실시예에 의하면, 이상치 제거와 데이터 증강을 위한 데이터 전처리, 그리고 소스 도메인에서 타겟 도메인으로의 매핑을 위한 적대적 학습을 포함함으로써 BCI에 있어서 다음과 같은 효과를 달성하는 생성 전이 학습 장치 및 그 방법을 제공할 수 있다.

[0021] 첫째, 본 발명의 실시예에 의하면, 타겟데이터 중심의 공간이 소스와 타겟 도메인의 잠재 공간을 공유하는 것보다 변화하는 조건에 더 적응할 수 있어서 개선된 성능을 제공하는 종단간 대상 전이 프레임워크를 제공할 수 있다.

[0022] 둘째, 본 발명의 실시예에 의하면, cbaDBSCAN 방법으로 이상치를 제거한 작은 하위 데이터셋을 사용하여 BCI 시스템의 해석을 향상시키므로 원래 데이터셋의 품질을 향상시킬 수 있다.

[0023] 셋째, 본 발명의 실시예에 의하면, 더 일반화된 타겟데이터 분포를 보장함으로써, 넓은 범위의 입력과 조건을 처리할 수 있는 더욱 견고하고 신뢰할 수 있는 BCI 시스템을 제공함으로써 분류 성능과 모델의 해석 가능성을

모두 향상시킬 수 있다.

[0024] 본 발명의 효과는 상기한 효과로 한정되는 것은 아니며, 본 발명의 상세한 설명 또는 특허청구범위에 기재된 발명의 구성으로부터 추론 가능한 모든 효과를 포함하는 것으로 이해되어야 한다.

도면의 간단한 설명

[0026] 도 1은 본 발명의 일 실시예에 따른 생성 전이 학습 장치를 나타낸다.

도 2는 본 발명의 일 실시예에 따른 일반화된 모터 이미지 EEG 분류를 위한 피험자 간 생성 전이 학습 방법을 나타낸다.

도 3은 프레임워크 학습과정을 나타내는 알고리즘의 일 예이다.

도 4는 전처리부(20)가 이상치를 제거하는 과정을 설명하기 위한 도면이다.

도 5는 소스에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 고전적인 도메인 적응을 나타낸다.

도 6은 소스에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 본 발명의 일 실시예에 따른 도메인 적응을 나타낸다.

발명을 실시하기 위한 구체적인 내용

[0027] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 형태를 가질 수 있는 바, 특정 실시예들을 도면에 예시하고 본문에 상세하게 설명하고자 한다. 그러나, 이는 본 발명을 특정한 개시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다. 각 도면을 설명하면서 유사한 참조부호를 유사한 구성요소에 대해 사용하였다.

[0028] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥 상 가지는 의미와 일치하는 의미를 가지는 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0029] 이하, 첨부한 도면들을 참조하여, 본 발명의 바람직한 실시예를 보다 상세하게 설명하고자 한다.

[0030] 본 발명의 일 실시예에 따른 생성 전이 학습 장치는 뇌전도(EEG)와 같은 침습적 또는 비침습적 방법을 사용하여 뇌 신호를 수집하고 해독하는 데 중점을 둔 뇌-컴퓨터 인터페이스(BCI, (Brain-Computer Interface) 시스템에 일반화된 모터 이미지 EEG 분류를 위한 피험자 간 생성 전이 학습 장치로 적용될 수 있다. 생성 전이 학습 장치는 이상치 제거와 데이터 증강을 위한 데이터 전처리, 소스 도메인에서 타겟 도메인으로의 매핑을 위한 적대적 학습을 포함한다. 여기서 일반화된 모터 이미지 EEG (Generalized Motor Imagery EEG)라는 용어는 신체의 어떤 부분의 상상된 움직임과 관련된 뇌파도(EEG) 데이터를 의미할 수 있다. "일반화된"이라는 용어는 BCI 시스템이 이러한 모터 이미지를 처리할 수 있음을 의미한다. 특별히 훈련된 사람뿐만 아니라 모든 개인의 EEG 데이터로서 운동 상상(MI)은 실제 신체 움직임이 없는 움직임의 정신적 시뮬레이션 또는 상상을 의미할 수 있다. 사람이 신체적 행동을 하는 것을 상상할 때, 뇌는 그 사람이 실제로 그 행동을 하고 있을 때 생성되는 활동과 유사한 전기적 활동을 생성한다. 이 전기적 활동은 EEG로 감지하고 측정할 수 있다. 개인이 자신의 생각을 사용하여 시스템을 제어할 수 있기 때문에 Motor Imagery는 BCI 시스템에서 자주 사용될 수 있다. 예를 들어 오른손을 움직이는 것을 상상하면 컴퓨터 커서에 오른쪽으로 이동하라는 명령을 보낼 수 있다. BCI 시스템 설계의 어려움은 EEG 신호가 사람마다, 심지어 같은 사람의 세션마다 크게 다를 수 있다는 것이다. 본 발명의 실시예에 따른 전이 학습 장치는 도메인 적응(DA) 방법을 통해 BCI 시스템이 새로운 개인과 조건에 효과적으로 적응할 수 있도록 한다. 즉, 본 실시예의 전이 학습 장치에 의하면 데이터가 누구로부터 오는 것인지에 관계없이 EEG 신호에서 이러한 상상된 움직임의 분류 성능을 개선할 수 있다.

[0031] 도 1은 본 발명의 일 실시예에 따른 생성 전이 학습 장치(1)를 나타낸다.

[0032] 도 1을 참조하면, 본 실시예의 생성 전이 학습 장치(1)는 데이터 입력부(10), 전처리부(20), 제1 인코더부(30),

생성부(40)(Generator), 제2 인코더부(50), 판별부(60)(Discriminator) 및 분류부(70)를 포함할 수 있다.

- [0033] 데이터 입력부(10)는 소스데이터와 타겟데이터를 입력받을 수 있다. 데이터 입력부(10)는 소스데이터(예: 원래 개인 그룹의 EEG 신호) 및 타겟데이터(대상 데이터, 예: 새로운 개인 또는 그룹의 EEG 신호)를 수신할 수 있다.
- [0034] 전처리부(20)는 입력 데이터에 대해 전처리를 수행할 수 있다. 전처리부(20)는 소스데이터에서 기계 학습 모델을 왜곡할 수 있는 이상치를 제거하고 노이즈를 추가하지 않고 데이터의 다양성과 대표성을 향상할 수 있는 기술을 통해 데이터를 증강할 수 있다. 나머지 데이터와 크게 다른 이상점 데이터 포인트(이상치)는 모델의 성능을 방해할 수 있다. 전처리부(20)는 cbaDBSCAN 방법을 적용하여 이러한 이상치를 식별하고 제거할 수 있다. 또한, 전처리부(20)는 MixUp과 같은 데이터 증강(Data Augmentation) 기술을 사용하여 데이터 집합을 인위적으로 확장할 수 있다. 이러한 데이터 증강 과정은 이상치 제거 후 및 후술되는 제1 인코더부에 의한 인코딩 전에 적용될 수 있다. MixUp은 두 훈련 예제의 컨벡스 조합(convex combination)을 취하여 새로운 훈련 예제를 생성하는 과정일 수 있다. 이 방법은 모델이 보이지 않는 데이터를 더 잘 일반화하는 데 도움을 줄 수 있다. 이상치 제거와 데이터 증강에 대해서는 더 후술될 수 있다.
- [0035] 제1 인코더부는 상기 전처리부(20)로부터의 증강된 데이터와 타겟데이터를 받아서 상기 소스데이터와 타겟데이터의 특징벡터를 생성할 수 있다. 제1 인코더부(30)는 전처리부(20)에서 정리되고 보강된 소스데이터와 타겟데이터를 가져와 특징벡터라고 하는 저차원 표현으로 변환할 수 있다. 즉 제1 인코더부(30)는 인코딩 프로세스를 수행하여 원시 EEG 데이터를 당면한 작업에 가장 중요한 기능을 강조 표시하는 다른 표현(특징벡터)으로 변환할 수 있다. 특징벡터는 시스템이 집중해야 하는 데이터의 중요한 특성을 나타낼 수 있다. 이러한 인코딩의 목적은 데이터에서 가장 중요하고 관련성이 높은 특징을 추출하고 표현하는 동시에 관련 없는 세부 정보와 노이즈를 제거하는 것이다. 이 변환 프로세스를 통해 데이터 작업이 더 쉬워지고 시스템 후반 단계의 성능을 개선하는 데 도움이 될 수 있다.
- [0036] 생성부(40)는 상기 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성할 수 있다. 상기 생성부(40)는 상기 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습될 수 있다. 즉, 생성부(40)는 소스데이터의 도메인(분포 및 특성)이 타겟데이터의 도메인(분포 및 특성)을 따르도록 생성 프로세스를 학습할 수 있다. 이것은 생성 전이 학습 장치(1)의 도메인 적응 프로세스의 핵심이며, 새로운 개인 또는 그룹의 데이터를 효과적으로 처리할 수 있도록 하는 핵심 과정이 될 수 있다.
- [0037] 제2 인코더부(50)는 상기 전이데이터의 특징벡터를 생성한다. 제2 인코더부(50)는 전이데이터를 분류부(70)가 사용할 수 있는 특징벡터로 인코딩할 수 있다. 이와 같이 인코딩 과정에 의해 원시 EEG 데이터를 보다 관리하기 쉽고 유익한 표현으로 변환함으로써, 시스템이 데이터에서 더 쉽게 학습하고 정확한 분류를 수행할 수 있도록 할 수 있다.
- [0038] 판별부(60)는 생성부(40) 및 제2 인코더부(50)와 함께 작동하여 분포 적응 프로세스를 수행할 수 있다. 생성부(40)는 분포가 타겟데이터와 더 밀접하게 정렬되도록 소스데이터에서 전이데이터를 생성할 수 있다. 판별부(60)는 전이된 특징벡터와 타겟데이터의 특징벡터를 구별하기 위해 작동할 수 있다. 목표는 생성부(40)가 전이데이터를 생성하되, 판별부(60)가 타겟데이터의 특징벡터와 전이된 특징벡터를 구별할 수 없을 때까지, 전이데이터를 생성하도록 생성부(40)를 훈련시키는 것이다. 판별부(60)(Discriminator)와 생성부(40)(Generator) 간의 이러한 적대적 훈련 프로세스에서 GAN손실함수가 계산될 수 있다. 전체 손실 함수에는 이러한 GAN손실함수와 후술될 소스데이터의 특징벡터와 전이데이터의 특징벡터의 일치여부에 대한 분류에서의 분류손실함수가 포함될 수 있다.
- [0039] 분류부(70)는 제 2 인코더부로부터 생성된 전이데이터의 특징벡터를 분류할 수 있다. 분류부(70)는 변환 및 조정된 입력 데이터를 기반으로 원하는 시스템 출력을 실제로 생성하는 부분일 수 있다. 분류부(70)는 전이된 특징벡터의 분류 결과가 소스데이터의 특징벡터의 분류 결과와 일치해야 하는 방식으로 훈련될 수 있다. 이는 소스데이터에서 얻은 지식이 타겟데이터로 효과적으로 전이되도록 하기 위해 수행될 수 있다.
- [0040] 도 1에서 설명된 상기 프레임워크는 EEG 데이터의 처리 및 학습에 대한 일련의 단계를 포함하는 포괄적인 접근 방식을 나타내며, 이러한 각 단계는 시스템이 새로운 데이터에 적응하고 정확한 예측을 할 수 있도록 하는 데 중요한 역할을 함으로써, 새로운 개인의 데이터에 효과적으로 적응하고 높은 성능을 유지하는 방식으로 수행해야 하는 BCI 시스템 분야의 주요 과제를 해결할 수 있다.
- [0041] 도 2는 본 발명의 일 실시예에 따른 일반화된 모터 이미지 EEG 분류를 위한 피험자 간 생성 전이 학습 방법을 나타낸다. 도 3은 프레임워크 학습과정을 나타내는 알고리즘의 일 예이다.

[0042] 도 2 및 도 3을 참조하면, 본 발명의 일 실시예에 따른 일반화된 모터 이미지 EEG 분류를 위한 피험자 간 생성 전이 학습 방법에서, 먼저 데이터 입력부(10)가 소스데이터와 타겟데이터를 입력받는다(S10). 전처리부(20)는 상기 소스데이터로부터 이상치를 제거하고 데이터를 증강한다(S20). 제1 인코더부(30)는 전처리부(20)로부터의 증강된 데이터와 타겟데이터를 받아서 소스데이터와 타겟데이터의 각각의 특징벡터를 생성한다(S30). 생성부(40)는 소스데이터의 특징벡터를 재구성하여 전이데이터를 생성한다(S40). 제2 인코더부(50)는 상기 전이데이터의 특징벡터를 생성한다(S50). 판별부(60)는 생성부(40) 및 제2 인코더부(50)와 함께 작동하여 분포 적응 프로세스를 수행한다(S60). 이에 의해 생성부(40)는 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습될 수 있다. 분류부(70)는 제 2 인코더부로부터 생성된 전이된 특징벡터를 분류하되, 전이된 특징벡터의 분류 결과가 소스데이터의 특징벡터의 분류 결과와 일치해야 하는 방식으로 훈련될 수 있다(S70).

[0043] 전술된 일반화된 모터 이미지 EEG 분류를 위한 피험자 간 생성 전이 학습 방법이 제공하는 프레임워크에 있어서, $(X_s, Y_s) = \{(x_s^{(i)}, y_s^{(i)})\}_{i=1}^m$ 그리고 $X_t = \{(x_t^{(i)})\}_{i=1}^m$ 은 각각 소스 도메인 $\mathcal{I}$ 와 타겟 도메인 $\mathcal{Q}$ 에서 무작위로 샘플링된 데이터라고 하고, 여기서 $m \gg n$ 이다. 베이저안 이론에 따르면, $q(Y|X) = q(X|Y)q(Y)/q(X)$ 이다. 본 발명의 실시예에서 목표는 사후 확률 $q(Y|X)$, 즉 $q(X|Y)q(Y)$ 을 최대화하는 모델을 학습하는 것이다. 전통적인 방법들은 직접 $p(X|Y) = q(X|Y)$ 라고 가정하거나 $\mathcal{I}$ 와 $\mathcal{Q}$ 에서 샘플링된 데이터에 대해 공유된 분포를 학습한다. 반면, 본 실시예에서는 두 도메인에 대해 공유된 레이블 공간을 가정하고, 다음과 같은 매핑 $f_\theta: X_s \rightarrow X_t$ 을 학습하려고 한다.

$$\begin{aligned} \arg \max_{\phi} q(Y|X_s, \phi) &= \arg \max_{\phi, \theta} q(Y|X_s, \theta; \phi) \\ &= \arg \max_{\phi, \theta} q(f(X_s, \theta) | Y; \phi) q(Y) \end{aligned}$$

[0045] 여기서 $f(X_s, \theta)$ 는 소스 도메인에서 타겟 도메인으로의 변환으로, θ 에 의해 매개변수화 될 수 있다. 함수 $q(Y|X_s, \theta)$ 는 타겟 도메인에서의 예측 모델로, ϕ 에 의해 매개변수화 될 수 있다. 본 실시예에서는 이러한 매칭을 이용하여 소스 도메인에서 타겟 도메인으로의 변환 방법을 찾고, 동시에 θ 와 ϕ 를 공동으로 최적화하여 전송된 데이터의 사후 확률을 최대화하도록 할 수 있다.

[0046] 전술된 매핑 네트워크 f_θ 는 도 1에 예시된 바와 같은 인코더-생성자 구조(f_{enc} 와 f_{gen})로 구현되며, 예측 모델 q_ϕ 는 다른 인코더(q_{enc} 와 q_{dz})에 의해 구현될 수 있다. 소스데이터는 먼저 f_{enc} 로 고차원 벡터로 인코딩되고 f_{gen} 에 의해 재구성될 수 있다. 매핑 과정은 적대적인 방식으로 훈련되며, 판별부(60)가 전송된 데이터가 타겟 도메인에 속하는지 여부를 평가하는 데 사용될 수 있다.

[0047] 또한, 전술된 것처럼 높은 품질의 훈련 데이터 그룹을 보장하기 위해, 데이터가 f_θ 로 공급되기 전에 전처리부(20)에 의해 이상치 제거 및 데이터 증강이 이루어질 수 있다. 전체 프레임워크는 종단간 방식으로 훈련되며, q_{enc} 와 q_{dz} 는 훈련 바로 후에 테스트 단계에 준비될 수 있다.

[0048] 이하, 이상치 제거와 데이터 증강 과정에 대해 더 설명한 후, 대상 간 전이 모듈을 설명한다.

[0049] 도 4는 전처리부(20)가 이상치를 제거하는 과정을 설명하기 위한 도면이다.

[0050] 도 4를 참조하면, 전술된 바와 같이, 전처리부(20)는 상기 소스데이터로부터 이상치를 제거하고 데이터를 증강할 수 있다(S20). EEG 신호 수집 단계에서 환경적인 교란이나 피험자의 산만함 또는 졸음 등 여러 요인으로 인해 수집된 데이터의 품질이 저하될 수 있다. 이러한 이상치들이 훈련 데이터에 포함되어 있으면 성능이 크게 감소할 수 있다.

[0051] 도 4는 이진 분류 예를 보여주며, 적응 모델은 소스 도메인의 양성 및 음성 훈련 샘플을 사용하여 잠재 공간에서 선형적으로 분리 가능한 경계를 학습한다. 또한, 실시간 BCI에서는 대량의 데이터를 사용한 훈련은 시간이 오래 걸리고 참여자에게 부담이 되므로 종래의 방법들은 적응 샘플의 선택을 무시했지만, 본 실시예에서는 모든 훈련 샘플(외측 점선으로 된 원의 내측)을 사용하는 것을 피하고 대신 고품질 샘플의 부분집합(내측 원)을 선택한다. 내측 원 내의 샘플은 더 필수적이고 실질적인 클래스 관련 패턴을 포함하고 있다. 그 외의 샘플은 노이즈

에 더 취약할 수 있다. 따라서, 다음 두 가정에 기반하여 이상치 제거가 모델 훈련 전에 수행될 수 있다.

[0052] 첫째, 잠재 공간의 분포는 훈련 없이 직접 얻을 수 있다.

[0053] 둘째, 다른 클래스에 속하는 고품질 데이터의 부분집합은 독립적이고 동일하게 분포되어 있다.

[0054] 첫 번째 가정을 통해 고정된 데이터 분포를 얻을 수 있고, 두 번째 가정은 이상치 제거의 필요성을 뒷받침한다. 본질적으로, 이 과정은 차원 축소와 클러스터링 두 단계로 이루어진다. 첫 번째 단계에서는 주성분 분석(PCA)을 사용하여 소스데이터의 차원을 축소한다.

[0055]
$$A = H \overline{X}_i V$$

[0056] 여기서 $\overline{X}_i$ 는 X_i 의 채널에 대한 평균이며, H 와 V 는 각각 중앙 집중 행렬과 고유 벡터 행렬이다. 차원 축소 후의 데이터는 A 로 표시될 수 있다.

[0057] 잡음이 있는 응용 프로그램의 밀도 기반 공간 클러스터링(DBSCAN)은 임의의 모양의 클러스터를 찾는 것이 적합하며, 이는 본 실시예의 경우 이상치를 찾는 데 적합하다. 그러나 이 방법도 밀도가 다양한 것을 다루는 데 어려움이 있고 매개변수에 민감한 등 여러 한계가 있다.

[0058] 이상치 제거 후 각 클래스의 샘플 수의 균형을 유지하기 위해, 본 실시예에서는 원래의 것을 기반으로 한 클래스 균형 자동 적응 DBSCAN(cbaDBSCAN)을 적용한다. 특히, 각 클래스 내에서 클러스터링을 수행한다. 즉, m 개의 훈련 샘플을 가진 k -카테고리 분류 작업의 경우, 아래의 수식과 같이 데이터는 k 개의 그룹으로 나누어진다.

[0059]
$$A = \bigcup_{j=1}^k A_j$$

[0060] 여기서 각 그룹에는 아래의 수식과 같이 단일 클래스의 샘플만 포함될 수 있다.

[0061]
$$A_j = \{x_i^{(j)} | y_i^{(j)} = j\}_{i=1}^m$$

[0062] 각 그룹에 대해 DBSCAN을 사용한다.

[0063]
$$\ddot{A}_j = \text{DBSCAN}(A_j; \epsilon, \text{minPts})$$

[0064] 여기서 $\ddot{A}_j$ 는 하이퍼파라미터 반경 ϵ 에 의해 결정되는 예약된 클러스터 내 샘플과 이상치 공차의 임계값을 설정하는 최소 네이버 minPts를 나타낸다. 서로 다른 그룹에 대해 공통 ϵ 을 설정하면 클래스별 및 주제별 표본 불균형이 발생하므로 각 그룹에 대해 개별 ϵ 을 계산한다.

[0065] 일단 모든 k 범주에 대한 예약된 샘플을 $\ddot{A} = \bigcup_{j=1}^k \ddot{A}_j$ 와 같이 얻으면, 샘플을 매핑한다. 원시 데이터 X_i 로 인덱스를 되돌려 선택한 $\ddot{X}_i$ 를 얻다. 단순화를 위해 오버헤드를 생략한다. 엑센트 표기법으로 이상치 제거 후의 데이터를 X_i 로 나타낸다.

[0066] 한편, 전처리부(20)에 의한 데이터 증강(mixup) 방법은 훈련 데이터의 양을 증가시켜 이상치 제거에 따른 제한을 완화한다. 이 단계에서는 타겟데이터 레이블을 사용할 수 없으므로 믹스업은 소스데이터에만 적용될 수 있다. 특히, 소스데이터의 m 훈련 샘플 그룹 $(X_s, Y_s) = \{(x_s^{(i)}, y_s^{(i)})\}_{i=1}^m$ 을 고려한다. 본 실시예에서는 다음과 같은 방법으로 $\gamma_1 \sim \beta(\alpha, \alpha)$ 를 무작위로 샘플링할 수 있다.

[0067]
$$\begin{aligned} x_s^{(i)} &\leftarrow \lambda_1 \cdot x_s^{(i)} + (1 - \lambda_1) \cdot x_s^{(j)} \\ y_s^{(i)} &\leftarrow \lambda_1 \cdot y_s^{(i)} + (1 - \lambda_1) \cdot y_s^{(j)} \end{aligned}$$

[0068] 여기서 i 는 훈련 샘플의 인덱스를 나타내며 $1, 2, \dots, m$, 이상의 범위를 나타내며 j 는 같이 무작위로 선택된 인덱스이다 ($j \neq i$).

[0069] 도 5는 소스에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 고전적인 도메인 적응을 나타낸다. 도 6은 소스에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 본 발명의 실시예에 따른 도메인 적응을 나타낸다.

[0070] 전술된 바와 같이, 판별부(60)는 생성부(40) 및 제2 인코더부(50)와 함께 작동하여 분포 적응 프로세스를 수행한다(S60). 이에 의해 생성부(40)는 소스데이터의 도메인이 상기 타겟데이터의 도메인을 추종하도록 학습될 수 있다. 분류부(70)는 제 2 인코더부로부터 생성된 전이된 특징벡터를 분류하되, 전이된 특징벡터의 분류 결과가 소스데이터의 특징벡터의 분류 결과와 일치해야 하는 방식으로 훈련될 수 있다(S70).

[0071] 도 5 및 도 6을 참조하면, 본 실시예에서는 도메인 적응 전략으로서 소스 도메인과 타겟 도메인 간의 격차를 해소하기 위해 도메인 불일치를 식별하고 완화하기 위해 적대적 학습을 활용한다. 판별부(60)는 잠재 공간에서 소스데이터 표현과 타겟데이터 표현을 구별하도록 설계된 반면, 생성부(40)는 판별부(60)를 속여서 잘못된 분류를 하도록 하기 위해 소스데이터의 특성 스타일을 타겟 도메인으로 전송하려고 시도한다.

[0072] 초기에 소스데이터 X_s 와 타겟데이터 X_t 는 각각 잠재 공간 표현 Z_s 와 Z_t 를 얻기 위해 f_{enc} 에 의해 처리될 수 있다. 그런 다음 Z_t 표현은 원시 데이터 공간에서 동일한 크기의 신호 $\hat{X}_t$ 가 되도록 f_{gen} 로 재구성될 수 있다. 그 후 전송된 데이터 $\hat{X}_t$ 는 보조 q_{enc} 로 공급되어 해당 임베딩 $\hat{Z}_t$ 를 얻는다.

[0073] GAN 훈련에서 생성부(40)와 판별부(60)는 번갈아가며 업데이트될 수 있다. 판별부(60) d 를 훈련하기 위해 소스 도메인과 타겟 도메인의 쌍으로 구성된 입력이 각각 참 및 거짓 샘플로 사용될 수 있다. 특히, m 쌍의 데이터가 무작위로 샘플링되고 판별부(60) 손실은 다음 공식을 사용하여 계산될 수 있다.

$$L_{dis} = \frac{1}{m} \sum_{i=1}^m [\log d(z_s^{(i)}) + \log(1 - d(z_t^{(i)})) + \log d(\hat{z}_t^{(i)})]$$

[0075] 개별 샘플 특이성의 영향을 완화하고 타겟 도메인의 지배적인 특성을 강조하기 위해 타겟 샘플의 평균을 계산하여 다음 수식과 같이 배치별 중앙점을 얻는다.

$$\bar{z}_t = \frac{1}{m} \sum_{i=1}^m z_t^{(i)}$$

[0077] 그리고 판별부(60) 손실은 그에 따라 아래의 수식에 의해 업데이트될 수 있다.

$$L_{dis} = \frac{1}{m} \sum_{i=1}^m [\log d(z_s^{(i)}) + \log d(\hat{z}_t^{(i)})] + \log(1 - d(\bar{z}_t))$$

[0079] 생성부(40)의 훈련 중에는 쌍체 샘플이 아닌 전송된 샘플에만 초점이 맞춰진다. 결과적으로 생성부(40) 손실은 다음과 같이 공식화될 수 있다.

$$L_{gen} = \frac{1}{m} \sum_{i=1}^m \log(1 - d(\hat{z}_t^{(i)}))$$

[0081] 한편, 소스 도메인에서 타겟 도메인으로 대상 간 전이하는 동안 레이블 정보를 보존하기 위해 "내부 클래스 전송" 메커니즘을 도입한다. 도 5 및 도 6에서 설명한 바와 같이, 이 메커니즘은 소스 도메인에서 사용 가능한 레이블 정보를 활용하여 전송하는 동안 레이블 일관성을 유지한다. 따라서 전송된 데이터는 도메인 및 클래스 지식을 모두 유지한다.

[0082] 이 메커니즘을 실현하기 위해 전송된 데이터의 레이블이 해당 소스데이터의 레이블과 일치하도록 직접 할당될 수 있다. 그 이유는 레이블 정보를 변경하지 않고 도메인과 관련된 정보만 전송하려고 하기 때문이다. 본 실시예에서 소스데이터의 레이블을 의사 레이블로 직접 가져와서 전송된 데이터에 할당하는데, 이는 실제로 더 간단하고 개념적으로 합리적이다. 따라서 f_{dis} 를 활용하면서 타겟 도메인에서 q_{dis} 를 동시에 훈련하고 분류 손실과 다음과 같이 정의한다.

$$L_{dz} = \frac{1}{m} \sum_{i=1}^m y_z^{(i)} [\log f_{dz}(z_z^{(i)}) + \log q_{dz}(\hat{z}_z^{(i)})]$$

[0083]

[0084] 분류 손실은 판별부(60)와 생성부(40) 모두의 업데이트 단계에서 사용될 수 있다. 따라서 전체 손실 함수는 다음과 같이 공식화될 수 있다. $L = \gamma L_{dz} + L_{gen}/L_{dz}$

[0085] 여기서 γ 는 분류 손실과 GAN 손실의 균형을 맞추는 하이퍼파라미터 역할을 한다. L_{gen} 과 L_{dz} 는 동시에 사용되지 않는다.

[0086] 본 발명의 실시예에 의하면, 비정상적이지 않은 작은 부분집합을 사용하여 대상 데이터 기반 공간을 학습함으로써 향상된 성능을 제공하는 종단 간 대상 간 전송 프레임워크를 제공할 수 있다.

[0087] 본 발명의 실시예에 의하면, cbaDBSCAN방법에 의해 이상치 제거를 함으로써 더 작고 이상값이 없는 하위 데이터 세트를 활용하여 BCI 시스템의 해석을 향상시켜 원래 데이터 세트의 품질을 향상시킬 수 있다.

[0088] 본 발명의 실시예에 의하면, 학습된 대상 데이터 분포가 보다 일반화되어 광범위한 입력 및 조건을 처리할 수 있는 보다 강력하고 신뢰할 수 있는 BCI 시스템으로 이어져 분류 성능과 모델 해석 가능성이 모두 향상된다.

[0089] 본 발명의 실시예에 의하면, 몸의 움직임이 불편한 환자(마비환자, 뇌졸중 등) 및 장애인들뿐만 아니라 일반인에게도 활용이 가능하며, 해당 기술은 뇌-컴퓨터 인터페이스 기반 스마트홈 제어나 인공지능 기술에서도 적용 가능하다. 또한, 본 실시예는 인공 지능 기술로 확장 될 수 있으며, 예를 들면 해당 사용자의 생각만으로 움직이는 로봇 제어 등에 활용 될 수 있다.

[0090] 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.

[0091] 본 발명의 범위는 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

[0093]

1 : 생성 전이 학습 장치

10 : 데이터 입력부

20 : 전처리부

30 : 제1 인코더부


40 : 생성부

50 : 제2 인코더부(50)

60 : 판별부(60)

70 : 분류부(70)

도면2



도면3

Algorithm 1: 프레임워크 학습 과정.

Data: 레이블이 지정된 소스 데이터 $\mathcal{P}_{source}$ 와 레이블이 지정되지 않은 타겟 데이터 $\mathcal{P}_{target}$.

Input: 학습률 η , 배치 사이즈 m , 하이퍼 파라미터 γ, t, α and β .
 $\theta_{enc}, \theta_{cls}, \theta_{gen}, \phi_{enc}, \phi_{cls}, \theta_d$ 에 의해 매개 변수화된 네트워크 $f_{enc}, f_{cls}, f_{gen}, q_{enc}, q_{cls}, d$.


Output: 분류기 q_{cls} 의 훈련된 매개 변수 ϕ_{cls} .

```


1 for 훈련 에포크 횟수 do
2   for 훈련 이터레이션 횟수 do
3     // 샘플링 및 믹스업
4     샘플 소스 배치  $(X_s, Y_s) = \{(x_s^{(i)}, y_s^{(i)})\}_{i=1}^m$  와 타겟 배치  $X_t = \{x_t^{(i)}\}_{i=1}^m$ , 데이터 확대한다;
5     // 순전파
6     소스 데이터  $X_s$ 와 타겟 데이터  $X_t$  모두에 대한 특징을 추출한다
7      $(Z_s, Z_t) = (f_{enc}(X_s), f_{enc}(X_t))$ ;
8     주어진 특징  $Z_s$ 에 전이 된 데이터  $\hat{X}_s$ 를 생성한다:
9      $\hat{X}_s = f_{gen}(Z_s)$ ;
10    주어진 전이 된 데이터  $\hat{X}_s$ 에 전이 된 데이터의 특징  $\hat{Z}_s$ 를 생성한다:
11     $\hat{Z}_s = q_{enc}(\hat{X}_s)$ ;
12    // 역전파
13    소스 데이터  $X_s$ 와 전이 된 데이터  $\hat{X}_s$ 에게 분류 손실함수를 계산한다;
14    역전파 그래프에서  $z_s$ 를 분리한다;
15    if 구분자 업데이트 조건이 충족됨 then
16      구분자의 손실함수를 계산하고  $\theta_{gen}$ 의 파라미터를 프리징하고  $\theta_{enc}, \theta_{cls}, \phi_{enc}, \phi_{cls}, \theta_d$ 를 업데이트한다:
17       $\mathcal{L} = \gamma \cdot \mathcal{L}_{cls} + (1 - \gamma) \cdot \mathcal{L}_{dis}$ ;
18       $\nabla_{(\theta_{enc}, \theta_{cls}, \phi_{enc}, \phi_{cls}, \theta_d)} = (-\frac{\partial \mathcal{L}}{\partial \theta_{enc}}, -\frac{\partial \mathcal{L}}{\partial \theta_{cls}}, -\frac{\partial \mathcal{L}}{\partial \phi_{enc}}, -\frac{\partial \mathcal{L}}{\partial \phi_{cls}}, -\frac{\partial \mathcal{L}}{\partial \theta_d})$ ;
19       $w_{(\theta_{enc}, \theta_{cls}, \phi_{enc}, \phi_{cls}, \theta_d)} \leftarrow w_{(\theta_{enc}, \theta_{cls}, \phi_{enc}, \phi_{cls}, \theta_d)} + \eta \cdot \nabla_{(\theta_{enc}, \theta_{cls}, \phi_{enc}, \phi_{cls}, \theta_d)}$ ;
20    end
21    if 생성자 업데이트 조건이 충족됨 then
22      생성자의 손실함수를 계산하고  $\theta_{enc}, \theta_{cls}, \phi_{enc}, \phi_{cls}, \theta_d$ 의 파라미터를 프리징하고  $\theta_{gen}$ 를 업데이트한다:
23       $\mathcal{L} = \gamma \cdot \mathcal{L}_{cls} + (1 - \gamma) \cdot \mathcal{L}_{gen}$ ;
24       $\nabla_{\theta_{gen}} = -\frac{\partial \mathcal{L}}{\partial \theta_{gen}}$ ;
25       $w_{\theta_{gen}} \leftarrow w_{\theta_{gen}} + \eta \nabla_{\theta_{gen}}$ ;
26    end
27  end
28 end

```

도면4



도면5



도면6

