



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2019-0069031
(43) 공개일자 2019년06월19일

(51) 국제특허분류(Int. Cl.)
A61B 5/00 (2006.01) A61B 5/04 (2006.01)
A61B 5/0476 (2006.01)
(52) CPC특허분류
A61B 5/7264 (2013.01)
A61B 5/04012 (2013.01)
(21) 출원번호 10-2017-0169373
(22) 출원일자 2017년12월11일
심사청구일자 2017년12월11일

(71) 출원인
가톨릭대학교 산학협력단
서울특별시 서초구 반포대로 222, 가톨릭대학교
성의교정내 (반포동)
(72) 발명자
박상훈
인천광역시 계양구 살라리로 7 (서운동)
이다빛
서울특별시 용산구 이촌로87길 21, 104동 1901호
(이촌동, 이촌아파트)
이상국
경기도 안양시 동안구 귀인로 157, 710동 203호
(호계동, 목련우성아파트)
(74) 대리인
특허법인태백

전체 청구항 수 : 총 14 항

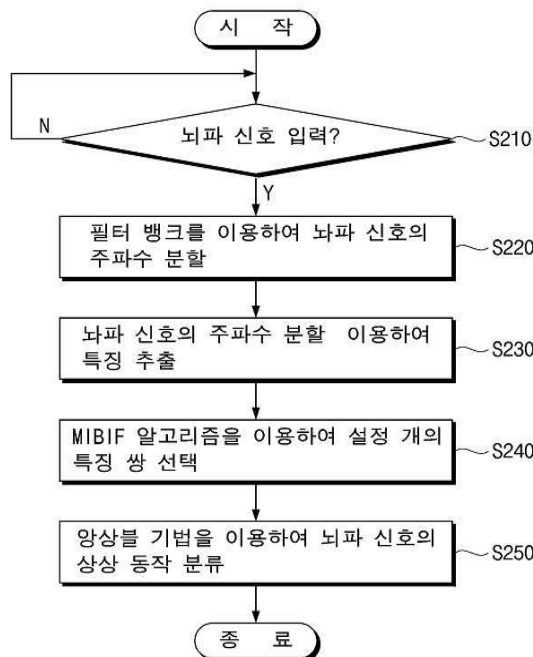
(54) 발명의 명칭 동작 상상 뇌파 신호 분류 장치 및 그 방법

(57) 요약

본 발명은 동작 상상 뇌파 신호 분류 장치 및 그 방법에 대한 것이다.

본 발명에 따른 동작 상상 뇌파 신호 분류 장치를 이용한 동작 상상 뇌파 신호 분류 방법은 동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호를 입력받는 단계; 주파수 범위를 기 설정된 개수로 균등 분할하여 구 (뒷면에 계속)

대표도 - 도2



성된 필터 뱅크(filter bank)를 이용하여 상기 주파수 범위에 대응하도록 상기 뇌파 신호의 주파수를 분할하는 단계; 정규화 공통 구간 패턴(R-CSP) 필터를 통해 상기 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출하여 정규화시키는 단계; MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 상기 추출된 특징 정보 중에서 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 단계; 및 상기 선택된 특징 정보 쌍을 기반으로 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계를 포함한다.

이와 같이 본 발명에 따르면, 필터 뱅크를 통과한 뇌파 신호에 정규화 공통 구간 패턴(R-CSP) 필터를 적용하고 앙상블하여 상상한 동작의 특징을 정확하게 분류할 수 있어, 성능을 향상시킬 수 있는 효과가 있다.

(52) CPC특허분류

A61B 5/0476 (2013.01)

A61B 5/7225 (2013.01)

명세서

청구범위

청구항 1

동작 상상 뇌파 신호 분류 장치를 이용한 동작 상상 뇌파 신호 분류 방법에 있어서,

동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호를 입력받는 단계;

주파수 범위를 기 설정된 개수로 균등 분할하여 구성된 필터 बैं크(filter bank)를 이용하여 상기 주파수 범위에 대응하도록 상기 뇌파 신호의 주파수를 분할하는 단계;

정규화 공통 구간 패턴(R-CSP) 필터를 통해 상기 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출하여 정규화시키는 단계;

MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 상기 추출된 특징 정보 중에서 양상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 단계; 및

상기 선택된 특징 정보 쌍을 기반으로 양상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계를 포함하는 동작 상상 뇌파 신호 분류 방법.

청구항 2

제1항에 있어서,

상기 필터 बैं크는 서로 다른 주파수 대역을 포함하는 다수개의 5차 버터워스(butterworth) 밴드 패스 필터로 구성되는 동작 상상 뇌파 신호 분류 방법.

청구항 3

제1항에 있어서,

상기 뇌파 신호는,

상기 동작 상상 실험을 통해 피험자로부터 획득된 신호 중 레이블링이 되어 있지 않은 테스트 뇌파 신호 및 타 피험자들로부터 일정 시간 동안 획득된 트레이닝 뇌파 신호를 포함하며,

상기 기 설정된 개수의 특징 정보 쌍을 선택하는 단계는,

상기 테스트 뇌파 신호와 상기 트레이닝 뇌파 신호 각각에 대해 상기 양상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 동작 상상 뇌파 신호 분류 방법.

청구항 4

제2항에 있어서,

상기 특징 정보를 추출하여 정규화시키는 단계는,

아래의 수학적식을 이용하여 상기 트레이닝 뇌파 신호의 공분산 추정을 계산하여 정규화시키는 동작 상상 뇌파 신호 분류 방법:

$$\hat{C}_{j,\omega} = \sum_{\hat{m}=1}^{\hat{M}} C_{(j,\omega,\hat{m})}$$

여기서 C는 1회의 동작 상상 실험 신호의 공분산 행렬이고, ω 는 클래스 인덱스, \hat{M} 은 다른 피험자 들로부터 얻은 트레이닝 뇌파 신호의 총 개수를 의미한다.

청구항 5

제1항에 있어서,

상기 MIBIF 알고리즘은,

선택된 특징 벡터 집합, 전체 특징 벡터 집합 및 대응되는 클래스 라벨 집합을 초기화하고, 각 특징 벡터에 대해 상호 정보 값을 계산하여 상기 상호 정보 값의 내림차순으로 특징 벡터 집합을 정렬한 후, 상위 k개의 특징에 대응되는 특징을 선택하는 순서로 수행되며, 모든 파라미터 세트에 대해 동일하게 수행하는 동작 상상 뇌파 신호 분류 방법.

청구항 6

제2항에 있어서,

상기 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계는,

다음의 수학적식을 이용하여 상기 테스트 뇌파 신호의 특징 정보들에 대하여 각 파라미터 간 거리를 계산하는 동작 상상 뇌파 신호 분류 방법:

$$Dis_{\omega} = \|\mu_{\omega} - v\|_2$$

여기서 v는 검증 폴드 특징 벡터, $\|\mu_{\omega} - v\|_2$ 는 L2-norm operator이다.

청구항 7

제6항에 있어서,

상기 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계는,

다음의 수학적식을 이용하여 상기 계산된 거리를 정규화하고,

$$\widetilde{Dis}_{\omega,e} = \frac{Dis_{\omega,e} - \min(Dis)}{\max(Dis) - \min(Dis)}$$

다음의 수학적식을 이용하여 선택된 특징 쌍에 대한 파라미터들의 거리를 합하여 가장 가까운 거리를 가지는 파라미터를 도출하는 동작 상상 뇌파 신호 분류 방법:

$$\widetilde{Dis}_{\omega} = \sum_{e=1}^E \widetilde{Dis}_{\omega,e}$$

여기서 e는 앙상블 인덱스, Dis는 $\{Dis_{\omega,e}\}_{\omega=1}^{\Omega}$ 이다.

청구항 8

주파수 범위를 기 설정된 개수로 균등 분할하여 구성되며, 동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호가 입력되면, 상기 주파수 범위에 대응하도록 상기 뇌파 신호의 주파수를 분할하는 필터 बैं크;

정규화 공통 구간 패턴(R-CSP) 필터를 통해 상기 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출하는 특징 추출부;

MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 상기 추출된 특징 정보 중에서 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 특징 선택부; 및

상기 선택된 특징 정보 쌍을 기반으로 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 앙상블

및 분류부를 포함하는 동작 상상 뇌파 신호 분류 장치.

청구항 9

제8항에 있어서,

상기 필터 बैं크는 서로 다른 주파수 대역을 포함하는 다수개의 5차 버터워스(butterworth) 밴드 패스 필터로 구성되는 동작 상상 뇌파 신호 분류 장치.

청구항 10

제8항에 있어서,

상기 뇌파 신호는,

상기 동작 상상 실험을 통해 피험자로부터 획득된 신호 중 레이블링이 되어 있지 않은 테스트 뇌파 신호 및 타 피험자들로부터 일정 시간 동안 획득된 트레이닝 뇌파 신호를 포함하며,

상기 특징 선택부는,

상기 테스트 뇌파 신호와 상기 트레이닝 뇌파 신호 각각에 대해 상기 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 동작 상상 뇌파 신호 분류 장치.

청구항 11

제9항에 있어서,

상기 특징 추출부는,

아래의 수학적식을 이용하여 상기 트레이닝 뇌파 신호의 공분산 추정을 계산하여 정규화시키는 동작 상상 뇌파 신호 분류 장치:

$$\hat{C}_{j,\omega} = \sum_{\hat{m}=1}^{\hat{M}} C_{(j,\omega,\hat{m})}$$

여기서 C는 1회의 동작 상상 실험 신호의 공분산 행렬이고, ω 는 클래스 인덱스, \hat{M} 은 다른 피험자 들로부터 얻은 트레이닝 뇌파 신호의 총 개수를 의미한다.

청구항 12

제8항에 있어서,

상기 MIBIF 알고리즘은,

선택된 특징 벡터 집합, 전체 특징 벡터 집합 및 대응되는 클래스 라벨 집합을 초기화하고, 각 특징 벡터에 대해 상호 정보 값을 계산하여 상기 상호 정보 값의 내림차순으로 특징 벡터 집합을 정렬한 후, 상위 k개의 특징에 대응되는 특징을 선택하는 순서로 수행되며, 모든 파라미터 세트에 대해 동일하게 수행하는 동작 상상 뇌파 신호 분류 장치.

청구항 13

제9항에 있어서,

상기 앙상블 및 분류부는,

다음의 수학적식을 이용하여 상기 테스트 뇌파 신호의 특징 정보들에 대하여 각 파라미터 간 거리를 계산하는 동작 상상 뇌파 신호 분류 장치:

$$Dis_{\omega} = \|\mu_{\omega} - v\|_2$$

여기서 v 는 검증 폴드 특징 벡터, $\|\mu_{\omega} - v\|_2$ 는 L2-norm operator이다.

청구항 14

제13항에 있어서,

상기 앙상블 및 분류부는,

다음의 수학적식을 이용하여 상기 계산된 거리를 정규화하고,

$$\widetilde{Dis}_{\omega,e} = \frac{Dis_{\omega,e} - \min(Dis)}{\max(Dis) - \min(Dis)}$$

다음의 수학적식을 이용하여 선택된 특징 쌍에 대한 파라미터들의 거리를 합하여 가장 가까운 거리를 가지는 파라미터를 도출하는 동작 상상 뇌파 신호 분류 장치:

$$\widetilde{Dis}_{\omega} = \sum_{e=1}^E \widetilde{Dis}_{\omega,e}$$

여기서 e 는 앙상블 인덱스, Dis 는 $\{Dis_{\omega,e}\}_{\omega=1}^{\Omega}$ 이다.

발명의 설명

기술 분야

[0001] 본 발명은 동작 상상 뇌파 신호 분류 장치 및 그 방법에 관한 것으로서, 더욱 상세하게는 필터 뱅크를 통과한 뇌파 신호에 정규화 공통 공간 패턴(R-CSP) 필터를 적용하고 앙상블하여, 상상한 동작의 특징을 정확하게 분류하는 동작 상상 뇌파 신호 분류 장치 및 그 방법에 관한 것이다.

배경 기술

[0002] 일반적으로 뇌파 신호(Electroencephalogram, EEG)를 이용한 뇌 컴퓨터 인터페이스(Brain-Computer Interface, BCI) 연구는 신호처리, 인지과학, 의학 및 재활 분야에서 활발히 진행되고 있다. 뇌 컴퓨터 인터페이스는 신체에 장애를 가진 사람들이 세상과 소통할 수 있는 수단을 제공한다. 뇌 컴퓨터 인터페이스를 이용한 기술은 뇌 활동으로 발생한 뇌파 신호를 제어 신호로 변환하여 신체를 사용하지 않고도 외부 장치를 제어할 수 있도록 한다.

[0003] 뇌파 신호는 경제성 및 높은 해상도 등 많은 이점을 가지고 있다. 따라서 뇌 컴퓨터 인터페이스 시스템에서 널리 사용되고 있다. 동작 상상을 수행하는 과정에서 발생하는 뇌파 신호의 Event-Related Desynchronization/Event-Related Synchronization(ERD/ERS) 패턴은 뇌 컴퓨터 인터페이스 시스템에서 매우 중요한 특징으로 활용된다. 그러나 ERD/ERS는 개인의 특성에 따라 발생하는 신호 패턴, 주파수 대역 및 위치가 다르다는 문제점이 있다. 또한, 뇌파 신호는 매우 낮은 신호대잡음비(Signal-to-Noise Ratio, SNR)와 비정상성(non-stationary)을 나타내므로 뇌파 신호의 분류는 어려운 작업에 해당한다.

[0004] 종래의 공통 공간 패턴(Common Spatial Pattern, CSP)은 주파수 대역에 대한 의존성이 높다. 따라서 넓은 주파수 대역을 선택하여 사용하거나 개인 특성에 맞는 주파수 대역을 선택해야 한다. 즉, 주파수 선택이 잘못된 경우 뇌 컴퓨터 인터페이스 시스템의 성능은 매우 저하된다. 이러한 문제점을 극복하기 위해, 필터 뱅크 공통 공간 패턴(Filter-Bank Common Spatial Pattern, FBCSP) 알고리즘이 제안되었다.

[0005] 필터 뱅크 공통 공간 패턴(FBCSP)은 4Hz 내지 40Hz 주파수 범위의 뇌파 신호를 여러 개의 좁은 주파수 대역으로

나는 뒤, 분할된 신호에 공통 공간 패턴(CSP) 필터를 적용하여 특징을 추출하는 방법이다. 이러한 방법은 공통 공간 패턴(CSP)의 주파 수에 대한 의존성을 극복할 수 있고 성능 향상에 효과적인 장점이 있다.

[0006] 또한, 공통 공간 패턴(CSP)은 샘플 기반 공분산 행렬에 의존성이 높다. 따라서 Small Sample Setting(SSS) 상황에서 낮은 성능을 보인다. 이러한 문제점을 극복하기 위하여 정규화 공통 공간 패턴(Regularized Common Spatial Pattern, R-CSP)이 제안되었다.

[0007] 정규화 공통 공간 패턴(R-CSP) 방법은 공분산 추정 과정에서 두 개의 파라미터를 이용한다. 두 개의 파라미터 (β , γ)는 분산(variance) 및 편향(bias)의 트레이드 오프(trade-off)를 각각 제어함으로써 Small Sample Setting(SSS) 상황에서 공통 공간 패턴의 성능 한계를 극복하였다. 이러한 연구들은 주파수 대역 및 공분산 행렬 추정에 대한 의존성을 각각 극복하기 위한 연구이다. 이러한 공통 공간 패턴의 문제점들을 동시에 해결하기 위한 기술의 개발이 필요하다.

[0008] 본 발명의 배경이 되는 기술은 대한민국 등록특허공보 제10-1619973호(2016. 05. 03. 공고)에 개시되어 있다.

발명의 내용

해결하려는 과제

[0009] 본 발명이 이루고자 하는 기술적 과제는 필터 뱅크를 통과한 뇌파 신호에 정규화 공통 공간 패턴 필터를 적용하고 앙상블하여 상상한 동작의 특징을 정확하게 분류하는 동작 상상 뇌파 신호 분류 장치 및 그 방법을 제공하기 위한 것이다.

과제의 해결 수단

[0010] 이러한 기술적 과제를 이루기 위한 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법은, 동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호를 입력받는 단계; 주파수 범위를 기 설정된 개수로 균등 분할하여 구성된 필터 뱅크(filter bank)를 이용하여 상기 주파수 범위에 대응하도록 상기 뇌파 신호의 주파수를 분할하는 단계; 정규화 공통 공간 패턴(R-CSP) 필터를 통해 상기 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출하여 정규화시키는 단계; MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 상기 추출된 특징 정보 중에서 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 단계; 및 상기 선택된 특징 정보 쌍을 기반으로 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계를 포함한다.

[0011] 상기 필터 뱅크는 서로 다른 주파수 대역을 포함하는 다수개의 5차 버터워스(butterworth) 밴드 패스 필터로 구성될 수 있다.

[0012] 상기 뇌파 신호는 상기 동작 상상 실험을 통해 피험자로부터 획득된 신호 중 레이블링이 되어 있지 않은 테스트 뇌파 신호 및 타 피험자들로부터 일정 시간 동안 획득된 트레이닝 뇌파 신호를 포함하며, 상기 기 설정된 개수의 특징 정보 쌍을 선택하는 단계는 상기 테스트 뇌파 신호와 상기 트레이닝 뇌파 신호 각각에 대해 상기 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택할 수 있다.

[0013] 상기 특징 정보를 추출하여 정규화시키는 단계는 아래의 수학적식을 이용하여 상기 트레이닝 뇌파 신호의 공분산 추정을 계산하여 정규화시킬 수 있다.

$$\hat{C}_{j,\omega} = \sum_{\hat{m}=1}^{\hat{M}} C_{(j,\omega,\hat{m})}$$

[0014]

[0015] 여기서 C는 1회의 동작 상상 실험 신호의 공분산 행렬이고, ω 는 클래스 인덱스, \hat{M} 은 다른 피험자 들로부터 얻은 트레이닝 뇌파 신호의 총 개수를 의미한다.

[0016] 상기 MIBIF 알고리즘은 선택된 특징 벡터 집합, 전체 특징 벡터 집합 및 대응되는 클래스 라벨 집합을 초기화하고, 각 특징 벡터에 대해 상호 정보 값을 계산하여 상기 상호 정보 값의 내림차순으로 특징 벡터 집합을 정렬한 후, 상위 k개의 특징에 대응되는 특징을 선택하는 순서로 수행되며, 모든 파라미터 세트에 대해 동일하게 수행

할 수 있다.

[0017] 상기 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계는 다음의 수학적식을 이용하여 상기 테스트 뇌파 신호의 특징 정보들에 대하여 각 파라미터 간 거리를 계산할 수 있다.

[0018]
$$Dis_{\omega} = \|\mu_{\omega} - v\|_2$$

[0019] 여기서 v는 검증 폴드 특징 벡터, $\|\mu_{\omega} - v\|_2$ 는 L2-norm operator이다.

[0020] 상기 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 단계는 다음의 수학적식을 이용하여 상기 계산된 거리를 정규화하고,

[0021]
$$\widetilde{Dis}_{\omega, e} = \frac{Dis_{\omega, e} - \min(Dis)}{\max(Dis) - \min(Dis)}$$

[0022] 다음의 수학적식을 이용하여 선택된 특징 쌍에 대한 파라미터들의 거리를 합하여 가장 가까운 거리를 가지는 파라미터를 도출할 수 있다.

[0023]
$$\widetilde{Dis}_{\omega} = \sum_{e=1}^E \widetilde{Dis}_{\omega, e}$$

[0024] 여기서 e는 앙상블 인덱스, Dis는 $\{Dis_{\omega, e}\}_{\omega=1}^{\Omega}$ 이다.

[0025] 또한, 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 장치는, 주파수 범위를 기 설정된 개수로 균등 분할하여 구성되며, 동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호가 입력되면, 상기 주파수 범위에 대응하도록 상기 뇌파 신호의 주파수를 분할하는 필터 बैं크; 정규화 공통 구간 패턴(R-CSP) 필터를 통해 상기 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출하는 특징 추출부; MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 상기 추출된 특징 정보 중에서 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택하는 특징 선택부; 및 상기 선택된 특징 정보 쌍을 기반으로 앙상블 기법을 이용하여 상기 뇌파 신호의 상상 동작을 분류하는 앙상블 및 분류부를 포함한다.

발명의 효과

[0026] 이와 같이 본 발명에 따르면, 필터 बैं크를 통과한 뇌파 신호에 정규화 공통 구간 패턴(R-CSP) 필터를 적용하고 앙상블하여 상상한 동작의 특징을 정확하게 분류할 수 있어, 성능을 향상시킬 수 있는 효과가 있다.

[0027] 또한 본 발명에 따르면, 필터 बैं크 구조를 이용하여 주파수 대역에 대한 의존성을 극복할 수 있고, 정규화 공통 구간 패턴 필터를 이용하여 샘플이 적은 상황에서 성능 저하 문제를 극복할 수 있는 효과가 있다.

[0028] 또한 본 발명에 따르면, 뇌파 신호를 분석하여 상상한 동작을 정확하게 분류해냄으로써 뇌 컴퓨터 인터페이스를 이용한 다양한 기술에 응용할 수 있다.

도면의 간단한 설명

- [0029] 도 1은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 장치를 나타낸 블록구성도이다.
- 도 2는 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법의 동작 흐름을 도시한 순서도이다.
- 도 3은 본 발명의 실시예에 따른 동작 상상 실험에 사용된 전극의 위치를 나타낸 것이다.
- 도 4는 본 발명의 실시예에 따른 파라미터 세트에 따른 분류 정확도를 나타낸 도면이다.
- 도 5는 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법의 분류 정확도를 피험자별로 나타낸 그래프이다.

도 6은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법에서 클래스 당 트레이닝 샘플 수에 따른 분류 정확도를 피험자별로 나타낸 그래프이다.

도 7은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법에서 상상블 개수에 따른 분류 정확도를 나타낸 그래프이다.

도 8은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법과 종래의 동작 상상 뇌파 신호 분류 방법에 있어 트레이닝 및 테스트에 소요되는 시간을 비교한 그래프이다.

발명을 실시하기 위한 구체적인 내용

- [0030] 이하 첨부된 도면을 참조하여 본 발명에 따른 바람직한 실시예를 상세히 설명하기로 한다. 이 과정에서 도면에 도시된 선들의 두께나 구성요소의 크기 등은 설명의 명료성과 편의상 과장되게 도시되어 있을 수 있다.
- [0031] 또한 후술되는 용어들은 본 발명에서의 기능을 고려하여 정의된 용어들로서, 이는 사용자, 운용자의 의도 또는 관례에 따라 달라질 수 있다. 그러므로 이러한 용어들에 대한 정의는 본 명세서 전반에 걸친 내용을 토대로 내려져야 할 것이다.
- [0032] 먼저, 도 1을 통해 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 장치에 대하여 설명한다.
- [0033] 도 1은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 장치를 나타낸 블록구성도이다.
- [0034] 도 1에서와 같이 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 장치는, 필터 뱅크(110), 특징 추출부(120), 특징 선택부(130) 및 상상블 및 분류부(140)를 포함한다.
- [0035] 먼저 필터 뱅크(110)는 주파수 범위를 기 설정된 개수로 균등 분할하여 구성되며, 동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호가 입력되면, 균등 분할된 주파수 범위에 대응하도록 뇌파 신호의 주파수를 분할한다.
- [0036] 이때, 필터 뱅크(110)는 서로 다른 주파수 대역을 포함하는 다수개의 5차 버터워스(butterworth) 밴드 패스 필터로 구성되며, 입력된 신호의 주파수 대역을 각각의 버터워스 밴드 패스 필터를 이용하여 분할하는 것이 바람직하다.
- [0037] 또한 뇌파 신호는 동작 상상 실험을 통해 피험자로부터 획득된 신호 중 레이블링이 되어 있지 않은 테스트 뇌파 신호 및 타 피험자들로부터 일정 시간 동안 획득된 트레이닝 뇌파 신호를 포함한다.
- [0038] 따라서 필터 뱅크(110)는 테스트 뇌파 신호와 트레이닝 뇌파 신호 각각에 대하여 주파수를 분할한다.
- [0039] 그리고 특징 추출부(120)는 정규화 공통 구간 패턴(R-CSP) 필터(121)를 통해 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출한다.
- [0040] 이때, 특징 추출부(120)는 필터 뱅크(110)로부터 주파수가 분할된 테스트 뇌파 신호와 트레이닝 뇌파 신호 각각에 대하여 각각 특징 정보를 추출한다.
- [0041] 그리고 특징 선택부(130)는 MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 특징 추출부(120)로부터 추출된 특징 정보 중에서 상상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택한다.
- [0042] 이때, MIBIF 알고리즘은 선택된 특징 벡터 집합, 전체 특징 벡터 집합 및 대응되는 클래스 라벨 집합을 초기화 하고, 각 특징 벡터에 대해 상호 정보 값을 계산하여 상호 정보 값의 내림차순으로 특징 벡터 집합을 정렬한 후, 상위 k개의 특징에 대응되는 특징을 선택하는 순서로 수행되며, 모든 파라미터 세트에 대해 동일하게 수행하는 것이 바람직하다.
- [0043] 이때, 특징 선택부(130)는 테스트 뇌파 신호와 트레이닝 뇌파 신호 각각에 대해 상상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택한다.
- [0044] 마지막으로 상상블 및 분류부(140)는 특징 선택부(130)에서 선택된 특징 정보 쌍을 기반으로 상상블 기법을 이용하여 뇌파 신호의 상상 동작을 분류한다.
- [0045] 즉, 피험자가 오른손을 움직이는 상상이나 왼발을 움직이는 상상 등과 같이 다양한 동작을 하는 상상을 했을 때 입력되는 뇌파 신호의 분류 결과를 이용하여 해당 동작을 추출해낼 수 있다.

- [0046] 이하에서는 도 2 내지 도 8을 통해 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법에 대하여 설명한다.
- [0047] 도 2는 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법의 동작 흐름을 도시한 순서도로서, 이를 참조하여 본 발명의 구체적인 동작을 설명한다.
- [0048] 본 발명의 실시예에 따르면, 먼저, 다른 동작 상상 뇌파 신호 분류 장치가 동작 상상 실험을 통해 기 설정된 시간 동안 획득된 뇌파 신호가 입력되는지 판단한다(S210).
- [0049] S210 단계의 판단 결과, 뇌파 신호가 입력되면 주파수 범위를 기 설정된 개수로 균등 분할하여 구성된 필터 बैं크(110)가 주파수 범위에 대응하도록 S210 단계에서 입력된 뇌파 신호의 주파수를 분할한다(S220).
- [0050] 필터 बैं크(110)의 주파수 대역은 4Hz 내지 40Hz이며, 4Hz의 주파수 범위를 가지는 5차 버터워스(butterworth) 밴드 패스 필터가 9개로 분할되어 구성되는 것이 바람직하다.
- [0051] 이때, 동작 상상 실험을 통해 피험자로부터 획득된 신호 중 레이블링이 되어 있지 않은 테스트 뇌파 신호와, 타 피험자들로부터 일정 시간 동안 획득된 트레이닝 뇌파 신호가 각각의 필터 बैं크(110)에 의해 주파수가 분할된다.
- [0052] 그 다음 특징 추출부(120)가 기 설정된 개수에 대응하게 구비되는 정규화 공통 구간 패턴(R-CSP) 필터(121)를 통해 뇌파 신호의 주파수 범위 별로 각각 특징 정보를 추출하여 정규화시킨다(S230).
- [0053] 정규화를 위하여 먼저 다음의 수학적 식 1을 이용하여 j번째 필터 बैं크(110)를 통과한 뇌파 신호 X_j 가 $N \times S$ (Channel \times Sampling)의 행렬일 때, X_j 에 대한 샘플 추정 행렬 C를 계산한다.

수학적 식 1

$$C = \frac{XX^T}{tr(XX^T)}$$

- [0054]
- [0055] 여기서, T는 전치행렬이고, tr은 추적 연산자이다. 이때, C는 $N \times S$ 사이즈로 얻어지며, 각 클래스의 M개의 샘플 추정의 합은 다음의 수학적 식 2와 같이 계산된다.

수학적 식 2

$$C_{j,\omega} = \sum_{m=1}^M C_{(j,\omega,m)}$$

- [0056]
- [0057] 여기서, M은 각 클래스에 속한 전체 trial의 개수, m은 trial의 인덱스($m \leq M$), ω 는 클래스 인덱스를 의미한다. 본 발명의 실시예에서는 이진 클래스 분류만을 고려하므로, $\omega \{1,2\}$ 이다.
- [0058] 그리고 정규화를 위해 타 피험자들로부터 수집된 트레이닝 뇌파 신호를 이용하여 다음의 수학적 식 3과 같이 공분산 추정을 계산한다.

수학적 식 3

$$\hat{C}_{j,\omega} = \sum_{\hat{m}=1}^{\hat{M}} C_{(j,\omega,\hat{m})}$$

- [0059]

[0060] 여기서 \hat{M}_i 은 클래스 ω 에 속한 타 피험자들의 데이터 개수이다. 제네릭 러닝에 기반하여, $\hat{C}_{j,\omega}$ 는 정규화된 공분산 행렬을 계산하는 과정에서 분산을 감소시키는 역할을 한다. 이로 인해 더욱 안정적인 결과를 제공할 수 있다.

[0061] 이때, 특정 피험자 및 타 피험자들의 공분산 행렬을 포함하는 $\hat{D}_{j,\omega}$ 는 다음의 수학적 식 4와 같이 계산된다.

수학적 식 4

$$\hat{D}_\omega(\beta) = \frac{(1-\beta)C_\omega + \beta\hat{C}_\omega}{(1-\beta)M + \beta\hat{M}}$$

[0062]

[0063] 여기서 β 는 첫 번째 정규화 파라미터로 추정된 공분산 행렬의 분산을 제어한다. 마지막 정규화 과정으로 각 클래스에 대한 정규화된 공분산 행렬은 다음의 수학적 식 5와 같이 계산된다.

수학적 식 5

$$\hat{\Sigma}_\omega(\beta, \gamma) = (1-\gamma)\hat{D}_\omega(\beta) + \frac{\gamma}{N}tr[\hat{D}_\omega(\beta)]I$$

[0064]

[0065] 여기서 γ 는 두 번째 정규화 파라미터로 큰 고유값은 감소시키고, 동시에 작은 고유값은 증가시키는 역할을 한다. 즉, 적은 샘플로 인해 발생하는 편향을 줄일 수 있다. 이때 $\beta = \gamma = 0$ 일 경우, 필터 뱅크 정규화 공통 공간 패턴(FBRCSP)은 필터 뱅크 공통 공간 패턴(FBCSP)과 같다.

[0066] 그 다음 각 클래스 정규화 공분산 행렬을 이용하여 다음의 수학적 식 6과 같이 혼합 공분산 행렬을 계산하고 고유값 분해를 수행한다.

수학적 식 6

$$\hat{\Sigma}(\beta, \gamma) = \hat{\Sigma}_1(\beta, \gamma) + \hat{\Sigma}_2(\beta, \gamma) = U\lambda U^T$$

[0067]

[0068] 여기서 U_j 는 고유 벡터, λ_j 는 고유값을 의미한다. U_j 및 λ_j 를 이용하여 $Q_j = \sqrt{\lambda_j^{-1} \cdot U_j^T}$ 를 계산할 수 있다. 백색화된 공간 공분산 행렬 $S_{j,\omega}$ 는 다음의 수학적 식 7과 같이 얻을 수 있다.

수학적 식 7

$$S_{j,\omega} = Q_j \cdot \hat{\Sigma}_{j,\omega}(\beta, \gamma) \cdot Q_j^T$$

[0069]

[0070] 여기서, $S_{j,1}$ 과 $S_{j,2}$ 는 고유벡터 B를 공유한다.

[0071] 이를 정리하면, 다음의 수학적 식 8과 같이 나타낼 수 있다.

수학식 8

$$\begin{aligned} S_1 &= B\lambda_1 B^T \\ S_2 &= B\lambda_2 B^T \end{aligned}$$

[0072]

[0073] 그리고 필터뱅크 정규화 공통 공간 패턴(FBRCSP)에 대한 필터 W_j 는 다음의 수학식 9와 같이 고유벡터 B 를 이용하여 얻을 수 있다.

수학식 9

$$W_j = B_j^T Q_j$$

[0074]

[0075] 그리고, X_j 는 각 필터뱅크(110)로부터 얻어진 필터 W_j 에 의해서 다음의 수학식 10과 같이 변환된다.

수학식 10

$$Z_j = W_j X_j$$

[0076]

[0077] 여기서 Z_j 는 필터 W_j 에 의해서 변환된 신호를 의미한다. Z_j 로부터 가장 차별적인 특징을 획득하기 위해 첫 번째 행 그리고 마지막 행으로부터 각각 m 개의 행을 선택한다. 따라서, $2m$ 개의 행이 선택된다. Single trial에 대한

FBRCSP 특징벡터 $v_j = [v_j^1, v_j^2, \dots, v_j^{2d}]$ 는 선택된 신호 $\hat{Z}_j = [\hat{z}_j^1, \hat{z}_j^2, \dots, \hat{z}_j^{2d}]$ 로부터 다음의 수학식 11과 같이 계산된다.

수학식 11

$$v_j^k = \log \left(\frac{\text{var}(\hat{z}_j^k)}{\sum_{k=1}^{2d} \text{var}(\hat{z}_j^k)} \right)$$

[0078]

[0079] 여기서 v_j^k 는 대응하는 신호 \hat{z}_j^k 의 특징 값이고 v_j 의 k 번째 특징 벡터 요소이다. 본 발명의 실시예에서는 $m=3$ 로 설정한다.

[0080] 그 다음 특징 선택부(130)가 MIBIF(Mutual Information Based Individual Feature) 알고리즘을 이용하여 S230 단계에서 추출된 특징 정보 중에서 양상불을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택한다(S240).

[0081] MIBIF 알고리즘은 선택된 특징 벡터 집합, 전체 특징 벡터 집합 및 대응되는 클래스 라벨 집합을 초기화하고, 각 특징 벡터에 대해 상호 정보 값을 계산하여 상호 정보 값의 내림차순으로 특징 벡터 집합을 정렬한 후, 상위 k 개의 특징에 대응되는 특징을 선택하는 순서로 수행되며, 모든 파라미터 세트에 대해 동일하게 수행한다.

[0082] 본 발명의 실시예에서는 $k=2$ 로 설정한다. 따라서, 선택된 특징 벡터 집합 S 는 2차원 또는 4차원 특징 벡터로 구

성된다. MIBIF 알고리즘의 결과로 11×11개의 선택된 특징 벡터 집합이 존재한다.

[0083] 이때, 테스트 뇌파 신호와 트레이닝 뇌파 신호 각각에 대해 앙상블을 위한 파라미터 세트를 구성하기 위한 기 설정된 개수의 특징 정보 쌍을 선택한다.

[0084] 마지막으로, 앙상블 및 분류부(140)가 S240 단계에서 선택된 특징 정보 쌍을 기반으로 앙상블 기법을 이용하여 뇌파 신호의 상상 동작을 분류한다(S250).

[0085] 이때, 다음의 수학적 식 12를 이용하여 테스트 뇌파 신호의 특징 정보들에 대하여 각 파라미터 간 거리를 계산한다.

수학적 식 12

[0086]
$$Dis_{\omega} = \|\mu_{\omega} - v\|_2$$

[0087] 여기서 v는 검증 폴드 특징 벡터, $\|\mu_{\omega} - v\|_2$ 는 L2-norm operator이다.

[0088] 그리고 다음의 수학적 식 13을 이용하여 계산된 거리를 정규화한다.

수학적 식 13

[0089]
$$\widetilde{Dis}_{\omega,e} = \frac{Dis_{\omega,e} - \min(Dis)}{\max(Dis) - \min(Dis)}$$

[0090] 그리고 다음의 수학적 식 14를 이용하여 선택된 특징 쌍에 대한 파라미터들의 거리를 합하여 가장 가까운 거리를 가지는 파라미터를 도출한다.

수학적 식 14

[0091]
$$\widetilde{Dis}_{\omega} = \sum_{e=1}^E \widetilde{Dis}_{\omega,e}$$

[0092] 여기서 e는 앙상블 인덱스, Dis는 $\{Dis_{\omega,e}\}_{\omega=1}^{\Omega}$ 이다.

[0093] 본 발명의 실시예에서는 성능 검증을 위해 공개적으로 사용 가능한 BCI competitionIII DatasetIVa를 이용하였다. 이 데이터 세트는 적은 수의 데이터로 알고리즘의 성능 평가에 유용하여 많은 연구에서 사용된다. 실험을 위해 데이터는 다섯 명의 피험자(aa, al, av, aw, and ay)에게서 획득하였다. 피험자는 편안한 의자에 앉아 동작 상상 실험을 수행하였다. 뇌파 신호는 118개의 채널로부터 기록되었으며 각 클래스당 140trials이 기록되었다. 이때 클래스는 오른손 및 발로 구성될 수 있다. 따라서 각 피험자로부터 280 trials의 뇌파 신호가 제공된다. 각 피험자에 대한 트레이닝 및 테스트 데이터는 다음의 표 1과 같이 구분된다.

표 1

[0094]

subjects	training	Test
aa	168	112
al	224	56
av	84	196
aw	56	224

av	28	252
----	----	-----

- [0096] 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법에서는 100Hz 버전을 사용하고 동작 상상 뇌파 신호 3.5초 중 0.5초부터 2.5초 까지를 사용한다.
- [0097] 도 3은 본 발명의 실시예에 따른 동작 상상 실험에 사용된 전극의 위치를 나타낸 것이다.
- [0098] 도 3에서와 같이 채널은 총 18 채널을 사용하고(C1, C3, Cz, C2, C4, CFC3, CFC4, CFC5, CFC6, CCP3, CCP4, CCP5, CCP6, T7, T8, P3, Pz, and P4), 기준 채널은 Fpz 이다.
- [0099] 본 발명의 실시예에서는 CSP, R-CSP, FBCSP, 및 FBCRSP(β, γ)와 비교한다. FBCRSP(β, γ)는 FBCRSP의 파라미터 선택 결과이다. 다음의 표 2는 BCI competitionIII datasetIVa를 이용하여 얻어진 각 방법의 분류 정확도를 보여준다. FBCRSP의 파라미터 선택 결과에서는 선택된 파라미터 세트도 함께 나타낸다.

표 2

Subject	CSP	SR-CSP	R-CSP	FBCSP	SR-FBCSP	FBCRSP(β, γ)	FBCRSP
aa	75.89	72.32	75.89	88.39	86.61	90.17(0.1, 0.6)	91.07
al	91.07	92.85	91.07	94.64	92.85	92.85(0, 0)	94.64
av	56.63	60.71	60.2	61.22	67.85	69.38(0.2, 0)	75
aw	66.51	69.64	70.98	80.02	75	73.21(0.2, 0)	76.78
ay	79.36	77.77	88	82.14	86.50	88.09(0, 0.4)	93.65
mean	73.89	74.66	77.23	81.28	81.76	82.74	86.23

- [0102] FBCRSP는 CSP, SR-CSP, R-CSP, FBCSP, SR-FBCSP 및 FBCRSP(β, γ)와 비교하여 각각 12.34%, 11.57%, 9%, 4.95%, 4.47%, 3.49%의 평균 분류 정확도 향상을 보였음을 확인할 수 있다. 또한, 피험자 aa, al, av, 및 ay에 대해서 다섯 가지 방법들 보다 더 높은 분류정확도를 가진 것을 알 수 있다. 피험자 aw는 FBCRSP보다 FBCSP 방법에서 3.24% 더 높은 분류 정확도를 도출했다.
- [0103] FBCRSP의 양상을 과정에서 성능에 방해되는 파라미터 세트가 많이 포함되어 FBCSP 방법보다 더 낮은 분류 정확도를 도출하였다.
- [0104] R-CSP는 데이터 수가 적은 피험자 av, aw, 및 ay에 대해서 좋은 성능을 보였다. 따라서, 피험자 av, aw 및 ay에 대해서 CSP 보다 더 좋은 성능을 보였다. 또한, 피험자 aa 및 al에 대해서도 CSP와 동일한 분류 결과를 도출했다. Filter-bank 기반의 방법은 구조적으로 주파수 영역 선택 문제를 해결할 수 있었을 뿐만 아니라 전반적인 성능 향상을 보여주었다. FBCSP의 경우, CSP, SR-CSP 및 R-CSP와 비교하여 더 높은 평균 분류 정확도를 수득했다. 또한, 모든 피험자에 대해서 CSP 및 SR-CSP보다 더 높은 분류 정확도를 획득했다.
- [0105] 도 4는 본 발명의 실시예에 따른 파라미터 세트에 따른 분류 정확도를 나타낸 도면이다.
- [0106] 도 4에서 x 축은 감마 값, y축은 베타 값을 의미한다. 블록의 색은 밝을수록 더 높은 분류 정확도를 도출한 파라미터 세트이다. 피험자 aw는 beta 값에 많은 영향을 받았다. 또한, 전반적으로 beta=0에서 좋은 분류 정확도를 얻었음을 확인할 수 있다. 즉, variance 보다 bias를 억제하는 것이 더 효과적인 결과를 도출한다. FBCRSP(β, γ) 방법에서 피험자 aw는 파라미터 세트 beta=0.2, gamma=0을 선택하였다. 따라서, FBCSP 방법 보다 더 낮은 분류 정확도를 얻었음을 확인할 수 있다.
- [0107] 그러나, 파라미터 세트 beta=0, gamma=0.3에서는 최고 분류 정확도인 82.59%를 도출했다. 이 결과는 선택된 파라미터 세트와 9.38% 차이를 보인다. 즉, FBCRSP(β, γ) 방법은 하나의 파라미터 세트를 선택하기 때문에 성능의 편차가 심하다. 최악의 경우에 50%의 분류 정확도를 도출한다. 즉, beta=1, gamma=0 또는 beta=1, gamma=0.1. 따라서 FBCRSP(β, γ) 방법은 파라미터 선택에 따라 큰 성능차이를 보였음을 확인할 수 있다.
- [0108] 도 5는 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법의 분류 정확도를 피험자별로 나타낸 그래프이다.

- [0109] 도 5는 FBRCSP(β, γ) 방법을 10회 수행한 결과이다.
- [0110] 도 5의 x 축은 실험의 인덱스, y축은 분류 정확도를 의미한다. 데이터의 수가 많은 피험자 aa 및 al은 안정적인 분류 성능을 보인다. 자신의 데이터가 많은 경우에는 정규화 과정에서 많은 영향을 받지 않는다. 또한, 데이터의 수가 많기 때문에 대부분 올바른 파라미터 세트를 선택한다. 반면에 데이터의 수가 적은 피험자 av, aw, 및 ay는 매번 분류 성능이 크게 차이 나는 결과를 도출한다. 즉, 데이터의 수가 적은 경우, generic dataset에 대한 의존성이 높아진다. 따라서 파라미터 세트 변화에 민감한 경향이 있다. FBRCSP(β, γ) 방법에서 평균 분류 정확도는 최대 7.63% 차이가 난다. 이 차이는 대부분 피험자 av, aw 및 ay의 성능 차이 때문에 발생한 것이다. 따라서, 세 명의 피험자에 대해서 더 큰 차이를 보인다. 이러한 결과를 도출하는 BCI 시스템은 신뢰하기 힘들다.
- [0111] 도 6은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법에서 클래스 당 트레이닝 샘플 수에 따른 분류 정확도를 피험자별로 나타낸 그래프이다.
- [0112] 도 6에서 x 축은 generic covariance를 구성하기 위해 사용된 각 피험자의 한 클래스 데이터 개수, y축은 분류 정확도를 의미한다. M=10과 M=140에서 평균 분류 정확도 차이는 6.2%이다. 또한, generic covariance를 계산하기 위해 많은 데이터가 사용될수록 더 좋은 평균 분류 정확도를 도출했다. 즉, 값들이 더욱 "physically plausible" 값으로 이동한다. 이 결과는 제안된 방법이 정규화 이론을 따르는 것을 보여준다.
- [0113] 도 6에서와 같이 피험자 av 및 aw는 데이터의 수가 증가함에 따라 분류 정확도가 크게 향상되었고, 각각 11.2% 및 12.05%의 최대 성능 차이를 보여주었다. 반면에 피험자 ay의 경우, M=10에서 88.49%의 분류 정확도를 도출했다. 이 결과는 기존 방법들과 비교하여 가장 좋은 분류 정확도를 보여준다. 즉, 피험자 ay는 트레이닝 데이터의 수가 매우 적기 때문에 generic covariance에 의해서 영향을 많이 받는 것을 알 수 있다. 또한 모든 방법에서 피험자 av 및 aw보다 트레이닝 데이터의 개수가 적음에도 불구하고, 더 좋은 성능을 보이는 것은 피험자 ay의 수집된 데이터가 매우 양호한 것을 의미한다.
- [0114] 추가적으로, 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법은 M=10에서 CSP 및 R-CSP 보다 더 좋은 평균 분류 정확도를 도출했다. 또한, 모든 피험자에 대해서 더 높은 분류 정확도를 얻었다. 이 결과는 generic covariance를 구성하기 위한 데이터의 수가 적어도 효과적인 성능을 도출하는 것을 보여준다. 동시에, filter-bank 구조를 통해서 트레이닝 데이터가 많은 피험자 aa 및 al에 대해서도 더 높은 분류 정확도를 얻을 수 있었다.
- [0115] 도 7은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법에서 앙상블 개수에 따른 분류 정확도를 나타낸 그래프이다.
- [0116] 도 7은 앙상블 개수에 따른 분류 정확도를 보여준다. 파라미터 세트 중 앙상블을 수행하는 파라미터의 비율은 10% 단위로 구분하였고, 10%부터 100% 까지를 실험하였다.
- [0117] 도 7에서 x축은 앙상블을 위한 파라미터 세트의 비율이고, y축은 분류 정확도를 나타낸다. 앙상블의 개수가 증가함에 따라 평균 분류 정확도가 낮아진다. 121개의 파라미터 세트에서 분류에 방해되는 요소들이 점차 많이 포함되기 때문이다. 앙상블 개수에 따른 피험자의 분류 정확도 차이는 적다. 10%에서 평균 분류 정확도는 81.99%로 CSP, R-CSP 및 FBCSP 방법과 비교하여 더 좋은 성능을 보여준다. 또한, 100%와 평균 분류 정확도 차이는 4.24%이다. 앙상블 기법으로 투표(voting)가 아니라 단순히 거리를 더하는 룰을 이용하였기 때문에 분류에 방해되는 파라미터 세트를 포함하여도 분류 결과는 매우 안정적이다.
- [0118] 도 8은 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 방법과 종래의 동작 상상 뇌파 신호 분류 방법에 있어 트레이닝 및 테스트에 소요되는 시간을 비교한 그래프이다.
- [0119] 도 8에서 x축은 각 방법들을 나타내고, 왼쪽 y축 및 오른쪽 y축은 각각 트레이닝 및 테스트 시간을 보여준다. CSP 및 SR-CSP는 성능이 낮지만 매우 짧은 트레이닝 시간을 필요로 한다. FBCSP 및 SR-FBCSP는 서로 비슷한 시간을 필요로 한다. 이 두 방법은 파라미터 선택을 위한 교차 검증 절차가 필요하지 않다. 따라서, 짧은 시간에 트레이닝을 할 수 있다. 그러나, R-CSP를 기반으로 하는 방법들은 교차검증이 필요하기 때문에 다른 방법들과 비교하여 트레이닝에 많은 시간이 필요하다. 반면에, 테스트 시간은 모든 방법에서 매우 짧게 요구된다. 하나의 trial에 대해서 테스트에 필요한 시간은 0.01초 미만이다. 따라서, 트레이닝은 오프라인상에서 수행한 뒤 테스트를 온라인에서 수행하면 트레이닝에서 시간이 많이 필요한 불편함을 극복할 수 있다.
- [0120] 상술한 바와 같이, 본 발명의 실시예에 따른 동작 상상 뇌파 신호 분류 장치 및 그 방법은 필터 बैं크를 통과한 뇌파 신호에 정규화 공통 공간 패턴(R-CSP) 필터를 적용하고 앙상블하여 상상한 동작의 특징을 정확하게 분류할

수 있어, 성능을 향상 시킬 수 있는 효과가 있다.

[0121] 또한 본 발명의 실시예에 따르면, 필터 뱅크 구조를 이용하여 주파수 대역에 대한 의존성을 극복할 수 있고, 정규화 공통 구간 패턴 필터를 이용하여 샘플이 적은 상황에서 성능 저하 문제를 극복할 수 있는 효과가 있다.

[0122] 또한 본 발명의 실시예에 따르면, 뇌파 신호를 분석하여 상상한 동작을 정확하게 분류해냄으로써 뇌 컴퓨터 인터페이스를 이용한 다양한 기술에 응용할 수 있다.


[0123] 본 발명은 도면에 도시된 실시예를 참고로 하여 설명되었으나 이는 예시적인 것에 불과하며, 당해 기술이 속하는 분야에서 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시예가 가능하다는 점을 이해할 것이다. 따라서 본 발명의 진정한 기술적 보호범위는 아래의 특허청구범위의 기술적 사상에 의하여 정해져야 할 것이다.

부호의 설명

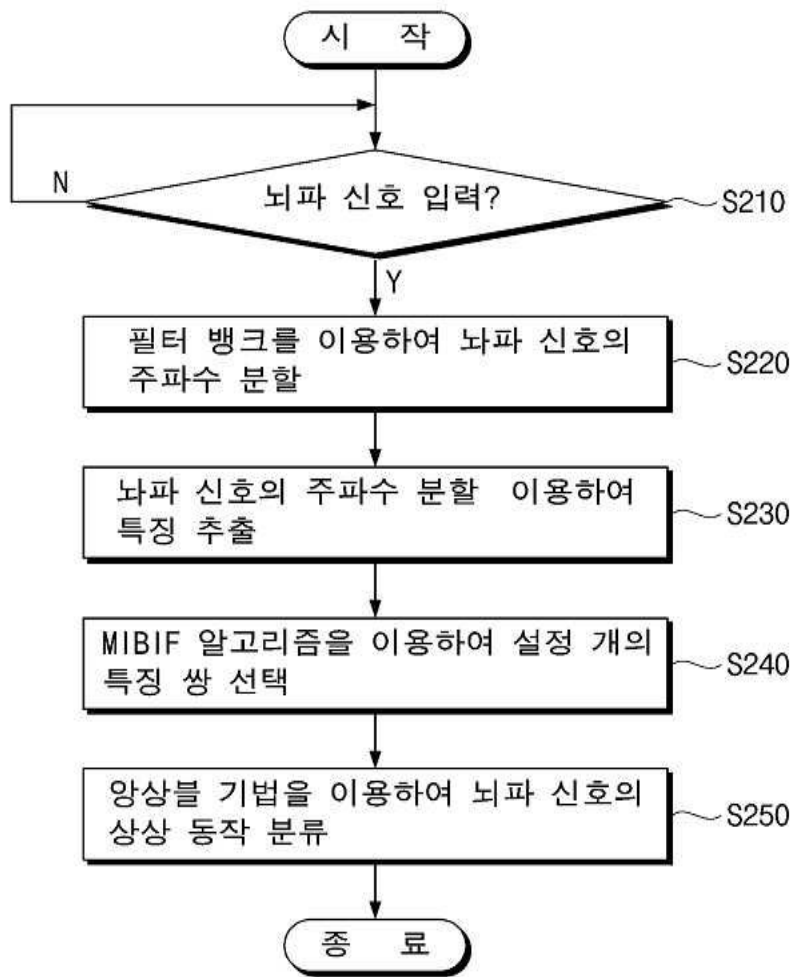
- [0124] 110 : 필터 뱅크 120 : 특징 추출부
- 121 : 정규화 공통 구간 패턴 필터 130 : 특징 선택부
- 140 : 앙상블 및 분류부

도면


도면1




도면2




도면3




도면4




도면5




도면6



도면7



도면8



专利名称(译)	动作虚拟脑电信号分类器及其方法		
公开(公告)号	KR1020190069031A	公开(公告)日	2019-06-19
申请号	KR1020170169373	申请日	2017-12-11
[标]申请(专利权)人(译)	韩国IND学术合作天主教UNIV FOUND		
申请(专利权)人(译)	天主教大学学术合作		
[标]发明人	PARK SANG HOON 박상훈 LEE DA VID 이다빛 LEE SANG GOOG 이상국		
发明人	박상훈 이다빛 이상국		
IPC分类号	A61B5/00 A61B5/0476 A61B5/04		
CPC分类号	A61B5/0476 A61B5/7225 A61B5/04012 A61B5/7264		
其他公开文献	KR102038203B1		
外部链接	Espacenet		

摘要(译)

运动想象的脑电信号分类装置及其方法技术领域本发明涉及运动想象的脑电信号分类装置及其方法。根据本发明，提供了一种使用用于对脑波信号进行成像的设备对脑波信号进行分类的方法，该方法包括：接收通过运动想象实验在预定时间内获得的脑波信号；以及通过使用现有技术中建立的滤波器组，通过将频率范围划分为预定数量，以将EEG信号的频率范围均等地划分，以使其对应于该频率范围；通过归一化公共部分模式 (R-CSP) 滤波器提取和归一化EEG信号每个频率范围的特征信息；使用MIBIF (基于互信息的个体特征) 算法从提取的特征信息中选择预定数量的特征信息对以构建用于整体的参数集；然后基于选择的特征信息对，使用集成技术对脑电信号的虚运动进行分类。如上所述，根据本发明，将归一化的公共空间图案 (R-CSP) 滤波器应用于通过滤波器组和集合体的EEG信号，以准确地对所设想的运动的特征进行分类，从而改善性能。有。

