

논문 2014-51-5-22

# 필터 뱅크 기반 BCI 시스템을 위한 CSP와 LDA를 이용한 필터 선택 방법

( Filter Selection Method Using CSP and LDA for Filter-bank based  
BCI Systems )

박 근 호\*, 이 유 리\*, 김 형 남\*\*

( Geun-Ho Park, Yu-Ri Lee, and Hyoung-Nam Kim<sup>©</sup> )

## 요 약

운동심상(Motor imagery) 기반의 뇌-컴퓨터 인터페이스(Brain-computer Interface)는 주로 뇌전도(Electroencephalography, EEG)를 이용하여 사용자의 자발적인 운동 의지를 읽는 기술로 최근 주목받고 있다. 이 중에서도 피실험자의 운동 의지를 정확히 해석하기 위해 감각운동 영역(sensorimotor area)의 일부분에서 나타나는  $\mu$ -대역(8-13Hz)의 전위 감소 현상인 event related desynchronization(ERD)을 분석하는 연구가 많이 진행되고 있다. 하지만 EEG는 공간 해상도가 낮고 사용자에 따라 ERD가 발생하는 주파수 대역이 다소 차이가 있어 추정에 어려움이 있다. 이에 대한 개선 방법의 하나로서 공간 필터를 구현하는 common spatial pattern (CSP)과 필터 뱅크(filter bank)를 결합한 형태인 discriminative filter bank common spatial pattern(DFBCSP)이 제안되었다. 그러나 DFBCSP는 EEG 신호의 평균 전력(power)의 Fisher ratio를 이용하여 사용자에게 따른 효과적인 주파수 대역을 포함하는 discriminative filter bank(DFB)를 구성하여 분류 정확도를 향상시켰지만 ERD의 공간 패턴이 나타나는 적절한 필터를 선택하지 않는 경우가 발생한다. 이러한 문제를 해결하기 위해 본 논문에서는 EEG 신호의 평균 전력 대신 CSP의 특성 벡터를 이용하여 DFB를 구성하는 방법을 제안한다. 기존의 방법과 제안한 방법의 필터 선택 결과와 분류 정확도 분석을 통해 CSP 특성 벡터가 DFB 구성에 더욱 효과적임을 보인다.

## Abstract

Motor imagery based Brain-computer Interface(BCI), which has recently attracted attention, is the technique for decoding the user's voluntary motor intention using Electroencephalography(EEG). For classifying the motor imagery, event-related desynchronization(ERD), which is the phenomenon of EEG voltage drop at sensorimotor area in  $\mu$ -band(8-13Hz), has been generally used but this method are not free from the performance degradation of the BCI system because EEG has low spatial resolution and shows different ERD-appearing band according to users. Common spatial pattern(CSP) was proposed to solve the low spatial resolution problem but it has a disadvantage of being very sensitive to frequency-band selection. Discriminative filter bank common spatial pattern(DFBCSP) tried to solve the frequency-band selection problem by using the Fisher ratio of the averaged EEG signal power and establishing discriminative filter bank(DFB) which only includes the feature frequency-band. However, we found that DFB might not include the proper filters showing the spatial pattern of ERD. To solve this problem, we apply a band-selection process using CSP feature vectors and linear discriminant analysis to DFBCSP instead of the averaged EEG signal power. The filter selection results and the classification accuracies of the existing and the proposed methods show that the CSP feature is more effective than signal power feature.

**Keywords:** 뇌-컴퓨터 인터페이스, EEG, 운동심상, common spatial pattern, 선형관별분석

\* 학생회원, \*\* 평생회원, 부산대학교 전자전기컴퓨터공학과

(Department of Electrical and Computer Eng., Pusan National University)

© Corresponding Author (E-mail: hnkim@pusan.ac.kr)

※ 이 논문은 2013년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임 (2012R1A1A2008555)

접수일자: 2014년3월10일, 수정일자: 2014년3월29일, 수정완료: 2014년4월29일

## I. 서 론

뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI)는 뇌에서 발생하는 정보를 이용해 기존의 입력장치인 마우스나 키보드를 거치지 않고 인간과 컴퓨터가 직접적으로 정보를 주고받는 시스템을 의미한다. 특히, 운동심상 기반의 BCI는 피실험자의 감각운동 영역(sensorimotor area)에서 나타나는 뇌 반응을 분석하여 어떤 신체 부위의 움직임을 상상했는지 분류하는 분야로 움직임 없이 상상만으로 기계나 컴퓨터를 제어한다는 점에서 최근에 주목받고 있다<sup>[1]</sup>. 신경성 마비 환자나 장애인을 위한 로봇, 기계, 소프트웨어 구현<sup>[2-4]</sup>, 비디오 게임에의 적용<sup>[5]</sup> 등 다양한 분야에서 운동심상 기반의 BCI 연구가 활발히 진행되고 있다. 운동심상 기반의 BCI는 주로 뇌의 두피에서 측정 가능한 뇌전도(electroencephalography, EEG)를 이용하여 상상하고 있는 신체 부위를 구별한다<sup>[6]</sup>. EEG는 다른 뇌 영상법(brain imaging)에 비해 측정이 비교적 간단하여 실생활 적용에 매우 용이하다. 또한, 높은 시간 해상도(temporal resolution)를 가진다는 장점이 있다<sup>[7]</sup>.

하지만 EEG는 운동심상 기반의 BCI를 구현하는 데 있어 해결해야 할 몇 가지 문제점이 존재한다. 먼저, EEG가 시간 해상도는 높은 반면 인간의 두개골 및 두피의 전도도로 인해 공간 해상도(spatial resolution)가 다른 뇌 영상법에 비해 비교적 낮다<sup>[7]</sup>. 특히, 운동심상을 하게 되면 감각운동 영역의 일부분에서 나타나는  $\mu$ -대역(8-13Hz) EEG 전위 감소 현상인 event related desynchronization (ERD)<sup>[6][8]</sup>이 나타나기 때문에 낮은 공간 해상도에서는 이러한 특성을 찾는 데 어려움이 있다. 두 번째 문제점은 ERD 현상이 피실험자에 따라 각기 다른 주파수 대역에서 발생한다는 것이다<sup>[8]</sup>.

EEG의 낮은 공간 해상도를 해결하기 위한 방법으로 common spatial pattern (CSP)이 적용된 BCI 시스템이 제안되었다<sup>[9-10]</sup>. CSP는 두 종류의 운동심상에 대한 EEG 신호의 분산 차이를 크게 하는 공간 필터를 구현하는 알고리즘으로 운동심상 기반의 BCI 성능을 크게 향상시켰다<sup>[9-10]</sup>. 하지만 운동심상을 구별하기 위한 ERD 발생 주파수 대역이 사용자마다 특징적이기 때문에, CSP가 적용된 BCI의 분류 성능은 EEG 신호의 주파수 대역 선택에 따라 큰 영향을 받았고, 분류 가능한 정보를 지닌 주파수 대역이 CSP 알고리즘에 사용되지

않았을 경우에는 분류 성능이 저하되었다<sup>[11-13]</sup>. 이러한 문제를 해결하기 위해 필터 बैं크 기반의 시스템인 sub-band common spatial pattern(SBCSP)<sup>[11]</sup>, filter bank common spatial pattern(FBCSP)<sup>[12]</sup>, 그리고 discriminative filter bank common spatial pattern(DFBCSP)<sup>[13]</sup>이 제안되었다. 이 중에서, DFBCSP는 필터 बैं크를 구성하고 각 주파수 대역별 운동심상의 구별 가능성을 Fisher ratio로 계산하였다. 계산된 Fisher ratio를 이용하여 기존 필터 बैं크보다 적은 수의 필터만으로 discriminative filter bank(DFB)를 구성하였다. DFBCSP는 사용자에 따라 특성 주파수 대역을 찾는 과정을 BCI 시스템이 포함하여 추가적인 분석의 필요성을 제거했다. 하지만 EEG 평균 전력 신호를 이용한 DFB 구성 방식이 운동 심상에 따른 ERD 특성을 효과적으로 나타내는  $\mu$ -대역의 필터를 포함하지 않는 경우가 발생한다.

본 논문에서는 기존의 방법이 특정한 피실험자에 대해 DFB가  $\mu$ -대역을 포함하지 않는 것을 보이고, 이를 해결하기 위하여 CSP 특성 벡터를 이용한 DFB 구성 방법을 제안한다. 운동심상에 따른 ERD의 공간 패턴이 나타나는  $\mu$ -대역의 필터를 제안된 방법으로 적절하게 선택할 수 있음을 운동심상의 분류 정확도를 통해서 보인다.

본 논문의 구성은 다음과 같다. II장에서는 공간 필터 구현을 위한 CSP의 이론적 설명과 DFBCSP의 시스템 구성을 소개한 후 III장에서는 본 논문에서 제안하는 새로운 DFB 구성 방법을 소개한다. IV장에서는 분석에 사용된 EEG 신호의 자세한 설명과 분석 결과를 제시하고 V장에서는 본 논문에서 제시한 방법에 대한 결론을 내리면서 마무리한다.

## II. Discriminative filter bank common spatial pattern (DFBCSP)

본 장에서는 운동심상 분류를 위한 CSP 알고리즘을 소개하고 CSP와 필터 बैं크를 이용한 discriminative filter bank common spatial pattern (DFBCSP)에 대해 다룬다.

### 1. Common Spatial Pattern (CSP)<sup>[9-10]</sup>

Common spatial pattern (CSP)은 두 가지의 운동심

상(motor imagery)에 해당하는 EEG 신호의 분산 차이를 최대로 하는 최적의 공간 필터(spatial filter)인 투영 행렬(projection matrix)  $\mathbf{W}$ 를 추정하는 알고리즘이다<sup>[9-10]</sup>. 투영하고자 하는 EEG 신호를  $\mathbf{X}$ 라 하면, 공간 필터를 통과한 신호  $\mathbf{Z}$ 는 식 (1)과 같다.

$$\mathbf{Z} = \mathbf{W}^T \mathbf{X} \quad (1)$$

투영 행렬은 두 대칭 행렬을 동시 대각화(simultaneous diagonalization)하여 유도된다. 투영 행렬  $\mathbf{W}$ 를 구하기 위해 먼저 각각의 운동심상에 해당하는 공간 공분산 행렬(spatial covariance matrix)을 구해야 한다. 각 운동심상의 종류를  $i \in \{h, f\}$ 라고 하면 정규화 된 공분산 행렬  $\mathbf{C}_i$ 는 식 (2)와 같이 정의된다.

$$\mathbf{C}_i = \frac{\mathbf{X}_i \mathbf{X}_i^T}{\text{trace}(\mathbf{X}_i \mathbf{X}_i^T)} \quad (2)$$

여기서  $\mathbf{X}_i$ 는 각 운동심상  $i$ 에 해당하는 대역 통과 필터(band-pass filter)를 통과한 EEG 신호로, (채널 수  $N_c$ ) $\times$ (시간 샘플 수  $N_t$ )의 크기를 가지는 행렬로 나타난다. 위 첨자로 나타낸  $T$ 는 전치 행렬(transposed matrix)을 의미한다. 공간 공분산 행렬의 정확한 추정을 위해 모든 운동심상 시행에 대한 공분산 행렬을 평균하여 평균 공분산 행렬(averaged covariance matrix)  $\bar{\mathbf{C}}_i$ 를 구한다. 각각의 평균 공분산 행렬로부터 합성 공분산 행렬(composite covariance matrix)  $\mathbf{C}_c$ 는 식 (3)과 같이 얻을 수 있다.

$$\mathbf{C}_c = \bar{\mathbf{C}}_h + \bar{\mathbf{C}}_f \quad (3)$$

백색 변환 행렬(whitening transformation matrix)을 구하기 위해 합성 공분산 행렬의 고유값과 고유벡터를 구해야 한다. 합성 공분산 행렬  $\mathbf{C}_c$ 는 식 (4)와 같이 고유값  $\mathbf{A}_c$ 와 고유벡터  $\mathbf{U}$ 로 분해된다.

$$\mathbf{C}_c = \mathbf{U} \mathbf{A}_c \mathbf{U}^T \quad (4)$$

이 때 백색 변환 행렬  $\mathbf{P}$ 는 다음 식 (5)와 같이 정의되므로,

$$\mathbf{P} = \sqrt{\mathbf{A}_c^{-1}} \mathbf{U}^T \quad (5)$$

$\mathbf{P} \mathbf{C}_c \mathbf{P}^T$ 는 합성 공분산 행렬의 백색화를 나타내는

단위 행렬(identity matrix)이 된다.

백색 변환 행렬  $\mathbf{P}$ 를 이용해 각 운동심상의 공분산 행렬을 변환하는 과정은 식 (6)과 같다.

$$\mathbf{S}_i = \mathbf{P} \bar{\mathbf{C}}_i \mathbf{P}^T, \quad i \in \{h, f\} \quad (6)$$

$\mathbf{S}_h$ 와  $\mathbf{S}_f$ 는 같은 고유벡터를 가지므로  $\mathbf{S}_h$ 가 식 (7)과 같이 분해가 되면,  $\mathbf{S}_f$ 도 식 (8)과 같이 동일한 고유벡터를 통해 분해가 된다.

$$\mathbf{S}_h = \mathbf{B} \boldsymbol{\Psi}_h \mathbf{B}^T \quad (7)$$

$$\mathbf{S}_f = \mathbf{B} \boldsymbol{\Psi}_f \mathbf{B}^T \quad (8)$$

결과적으로, 각각의 운동심상에 해당하는 고유값  $\boldsymbol{\Psi}_h$ 와  $\boldsymbol{\Psi}_f$ 의 합은 식 (9)와 같이 항상 단위행렬이 된다.

$$\boldsymbol{\Psi}_f + \boldsymbol{\Psi}_h = \mathbf{I} \quad (9)$$

식 (9)는  $\boldsymbol{\Psi}_f$ 가 커지면  $\boldsymbol{\Psi}_h$ 가 작아지고 마찬가지로 반대의 경우도 성립하는 특징을 나타낸다. 이러한 특징은 CSP가 각 운동심상을 구별하는 최적의 공간 필터를 구현하도록 하는 중요한 역할을 한다. 고유값의 크기에 따라 고유벡터  $\mathbf{B}$ 를 내림차순으로 정렬한 행렬을  $\mathbf{B}_s$ 라고 하면  $\mathbf{B}_s$ 의 양 끝의 고유벡터가 운동심상을 가장 효과적으로 구별하는 정보를 지니고 있다.

구하고자 하는 공간 필터  $\mathbf{W}$ 는 백색 변환 행렬  $\mathbf{P}$ 와 고유벡터 행렬  $\mathbf{B}_s$ 를 이용해 식 (10)과 같이 나타낼 수 있다.

$$\mathbf{W} = (\mathbf{B}_s^T \mathbf{P})^T \quad (10)$$

이렇게 구해진  $\mathbf{W}$ 를 이용하여 식 (1)에서 주어진 구별하고자 하는 EEG 신호  $\mathbf{X}$ 로부터  $\mathbf{Z}$ 를 얻을 수 있다.  $\mathbf{Z}$ 의 분산을 계산하면 구별하고자 하는 운동심상의 특성 벡터(feature vector)를 얻을 수 있다.  $\mathbf{Z}$ 의 첫 번째 행과 마지막 행인  $N_c$ 번째 행으로부터 각각  $m$ 개의 행벡터를  $\mathbf{Z}_q (q = 1, 2, \dots, 2m)$ 라고 하면 특성 벡터  $\mathbf{v}_q$ 는 식 (11)과 같이 정의할 수 있다.

$$\mathbf{v}_q = \log \left( \frac{\mathbf{Z}_q}{\sum_{k=1}^{2m} \text{var}(\mathbf{Z}_q)} \right) \quad (11)$$

2. Discriminative filter bank (DFB)<sup>[13]</sup>

CSP는 공간 패턴 특성을 추출하는 데 있어 효과적인 알고리즘이다. 하지만, CSP는 필터에 따라 성능이 크게 변하기 때문에 운동심상에 의해 나타나는 특징적인 주파수를 찾는 과정이 필요하다. DFBCSP는 특징적인 주파수 대역을 포함하는 대역 선택 과정(band-selection process)을 통해 초기 필터 집합의 부분 집합으로 이루어진 DFB(discriminative filter bank)를 구성하여 CSP의 성능을 향상시켰다<sup>[13]</sup>.

DFBCSP 시스템의 블록 다이어그램은 그림 1과 같다. 먼저 DFB를 구성하기 위해 대역 선택 과정이 필요하다. 각 필터의 특성 값(feature value)을 얻기 위해 각 운동심상에 따른 EEG 신호(C3 혹은 C4)의 평균 전력(power)을 구한다. 대역 필터  $h_r(n)$  ( $r = 1, 2, \dots, 12$ )을 통과한 EEG 신호  $X_{i,r}$ 의 평균전력은 식 (12)에 의해 정의된다.

$$P_{i,r} = \frac{1}{N_t} \sum_{n=1}^{N_t} X_{i,r}^2 [n] \quad (12)$$

여기서 필터  $h_r(n)$ 은 표 1과 같이 6-32Hz에 해당하는 12개 필터를 의미하고 각각의 필터는 4Hz의 대역폭을 가지며 인접한 필터는 2Hz씩 중첩되어 있다. 필터 선택을 위해 식 (13)과 같이  $P_{i,r}$ 에 대한 Fisher ratio를 얻을 수

있다.

$$F_{SP}^{(r)} = \frac{(\mu_h - \mu_f)^2}{s_h^2 + s_f^2} \quad (13)$$

여기서  $\mu_i$ 는 전력을 시행에 대해 평균한 것을 의미하고,  $s_i^2$ 은 전력의 분산을 의미한다. 식 (13)에 의해,  $F_r$ 의 크기에 따라 각 클래스의 특성 값에 대한 구별 가능성을 판단할 수 있다. 그림 1과 같이 큰 값의  $F_r$ 을 가지는 4개의 필터  $d_k(n)$  ( $k = 1, \dots, 4$ )를 이용해 DFB를 구성한다. 4개의 DFB를 구성하면 CSP를 통해 얻어진 공간 필터  $\mathbf{W}_t^{(k)}$ 를 이용하여 특성 추출 과정이 진행되고 분류기를 통해 BCI 시스템의 분류 정확도를 계산할 수 있다.

III. CSP 특성 벡터와 LDA를 이용한 DFBCSP

기존의 DFBCSP는 EEG 신호의 평균 전력에 대한 Fisher ratio를 구하여 DFB를 구성하였다. 하지만 기존의 필터 선택 방법은 특정한 피실험자에 대해 ERD를 나타내는  $\mu$ -대역의 필터를 선택하지 않는 현상을 보였다. 본 논문에서는 이러한 문제를 해결하기 위한 방법으로 CSP 특성 벡터와 선형 판별 분석(linear discriminant analysis, LDA)을 이용하여 DFB를 구성하는 방법을 제안한다. 먼저, LDA 알고리즘에 대해 소개한 후 기존 시스템의 성능을 개선하기 위해 제안한 방법인 CSP 특성 벡터와 LDA를 이용한 시스템에 대해 다룬다.

1. 선형 판별 분석(linear discriminant analysis)

LDA는  $N$ 차원 데이터의 클래스를 구분하기 위한 분류 알고리즘으로 클래스 내의 분산은 최소로 하고 데이터 전체의 분산은 최대로 하는 투영 벡터(projection vector)  $\mathbf{w}$ 를 구하는 알고리즘이다<sup>[14~15]</sup>. 본 논문에서 LDA는 각 필터의 DFB 포함 여부를 결정하는 데 사용되며, 시험 신호의 특성 벡터  $\mathbf{v}$ 를 분류하기 위한 분류 기로도 사용되었다.

Fisher ratio를 벡터에 대해 확장하기 위해 각 클래스의 평균 벡터와 산란 행렬(scatter matrix)을 정의하면 식 (14), (15)와 같다.

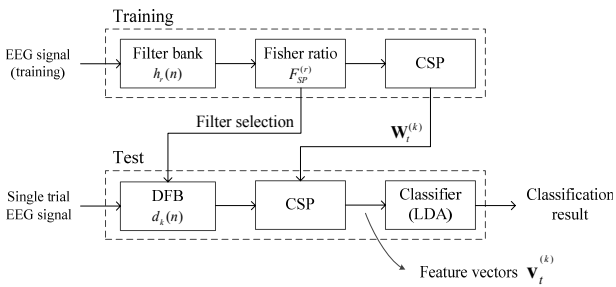


그림 1. 기존 discriminative filter bank common spatial pattern (DFBCSP)의 블록 다이어그램<sup>[13]</sup>

Fig. 1. Block diagram of the existing discriminative filter bank common spatial pattern (DFBCSP)<sup>[13]</sup>.

표 1.  $r$ 번째 필터의 주파수 대역  
Table 1. Frequency band of the  $r$ th filter.

Filter index ( $r$ )	1	2	3	4	5	6
Passband (Hz)	6-10	8-12	10-14	12-16	14-18	16-20
Filter index ( $r$ )	7	8	9	10	11	12
Passband (Hz)	18-22	20-24	22-26	24-28	26-30	28-32

$$\mathbf{m}_i = \frac{1}{n_i} \sum_{\mathbf{v} \in C_i} \mathbf{v} \quad (14)$$

$$\mathbf{S}_i = \sum_{\mathbf{v} \in C_i} (\mathbf{v} - \mathbf{m}_i)(\mathbf{v} - \mathbf{m}_i)^T \quad (15)$$

그리고 클래스 간 산란 행렬(between-class scatter matrix)과 클래스 내 산란 행렬(within-class scatter matrix)은 식 (16), (17)과 같이 정의된다.

$$\mathbf{S}_B = (\mathbf{m}_1 - \mathbf{m}_2)(\mathbf{m}_1 - \mathbf{m}_2)^T \quad (16)$$

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2 \quad (17)$$

각 클래스의 데이터와 평균이  $\mathbf{w}$ 로 투영되므로, 투영된 데이터와 평균은 각각  $y_i = \mathbf{w}^T \mathbf{v}_i$ 와  $\tilde{m}_i = \mathbf{w}^T \mathbf{m}_i$ 로 얻을 수 있고, Fisher ratio에서의 산란  $\tilde{s}_i$ 를 각 클래스의 산란 행렬을 이용하여 식 (18)과 같이 구할 수 있다.

$$\tilde{s}_i = \sum_{y \in C_i} (y - \tilde{m}_i)^2 = \mathbf{w}^T \mathbf{S}_i \mathbf{w} \quad (18)$$

마찬가지로,  $(\tilde{m}_1 - \tilde{m}_2)^2$ 는 클래스 내 산란 행렬을 이용해 식 (19)와 같이 유도된다.

$$(\tilde{m}_1 - \tilde{m}_2)^2 = \mathbf{w}^T \mathbf{S}_B \mathbf{w} \quad (19)$$

따라서 LDA 평가 함수(criterion function)  $F(\mathbf{w})$ 는 Fisher ratio로부터 식 (20)과 같이 정의할 수 있다.

$$F(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (20)$$

식 (20)은 generalized Rayleigh quotient이므로  $F(\mathbf{w})$ 를 최대화하는  $\mathbf{w}$ 는 식 (21)과 같이 generalized eigenvalue problem으로 나타낼 수 있고  $\mathbf{w}$ 는 식 (22)로부터 구할 수 있다.

$$\mathbf{S}_B \mathbf{w} = \lambda \mathbf{S}_W \mathbf{w} \quad (21)$$

$$\mathbf{w} = \mathbf{S}_W^{-1} (\mathbf{m}_1 - \mathbf{m}_2) \quad (22)$$

2. CSP 특성 벡터와 LDA를 이용한 DFB 구성 방법  
본 논문에서는 피실험자의 특징적인 주파수 대역을

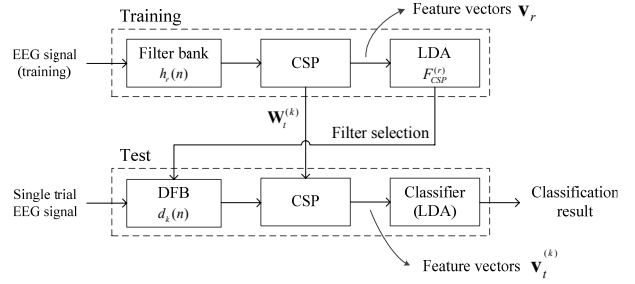


그림 2. 제안한 discriminative filter bank common spatial pattern (DFBCSP)의 블록 다이어그램

Fig. 2. Block diagram of the proposed discriminative filter bank common spatial pattern (DFBCSP).

포함하는 DFB를 구성하기 위해 CSP 특성 벡터를 이용하였다. 제안된 BCI 시스템의 블록 다이어그램은 그림 2와 같다. 기존 방법의 경우, EEG 신호의 평균 전력  $P_{i,r}$ 과 Fisher ratio  $F_{SP}^{(r)}$ 을 계산하여 DFB를 구성하였고 대역 선택 과정에서 채택된 EEG 신호에 대해서만 CSP가 적용되었다. 하지만 제안한 방법은  $h_r(n)$ 을 통과한 모든 EEG 신호에 CSP를 적용하였고, 각 필터에 대한 특성 벡터  $\mathbf{v}_r$ 의 LDA 평가 함수  $F_{CSP}^{(r)}(\mathbf{w})$ 를 구하여 DFB를 구성한 것에 차이가 있다.

기존의 방법은 운동심상에 따른 ERD 발생으로 전력 차이가 나타나는 감각운동 영역의 전극(C3, C4, Cz 중 한 개를 사용<sup>[13])을 하나 선택하여 필터 선택이 이루어졌지만 이 과정은 매우 시간 소모적이다. 선택된 전극에 따라 필터 선택 방법이 달라지기 때문에 이에 따른 분류 정확도를 분석한 후, 높은 분류 정확도를 나타내는 전극을 선택하는 과정을 필요로 한다. 제안한 방법의 경우는 전극 선택에 대한 분석을 필요로 하지 않는다. 공간 패턴을 나타내는 CSP 특성 벡터  $\mathbf{v}_r$ 은 EEG가 측정된 모든 전극에 대해 나타나는 공간 패턴을 포함하므로 CSP의 특성 벡터인  $F_{CSP}^{(r)}(\mathbf{w})$ 를 이용하여 DFB를 구성할 경우 전극에 따른 분석이 필요하지 않게 된다. 따라서 기존의 방법과 같은 수동적 분석을 실행하지 않아도 된다는 장점을 지니고 있다. 본 논문에서 제안한 BCI 시스템의 분류 정확도 및 분석 결과는 모의실험 결과에서 확인할 수 있다.</sup>

## IV. 모의실험 결과

### 1. 실험 데이터

제안된 시스템의 분석을 위해 BCI competition III dataset IVa<sup>[16]</sup>를 사용하였다. 이 EEG 신호는 Berlin BCI group에서 제공되었고, 최초에는 적은 수의 훈련 신호를 이용한 BCI의 성능 분석을 위해 활용되었다. EEG 신호는 다섯 명의 피실험자('aa', 'al', 'av', 'aw', 'ay')로부터 측정되었다. 각각의 피실험자는 세 가지 종류 중 하나의 시각 신호(visual cue)가 모니터에 나타나면 오른손, 왼손, 그리고 다리의 운동심상 중 하나를 실행하였다. 시각 신호는 3.5초간 지속되고, 시각 신호가 사라진 이후 1.75초부터 2.25초 사이의 휴식시간이 임의로 주어졌다. EEG 신호는 현재 왼손을 제외한 오른손과 다리 운동심상에 대하여 공개되어 있고, 두 가지 운동심상에 대해 총 280회 시행되었다. Extended international 10-20 system에 해당하는 118개 전극에서 EEG 신호가 측정되었고 100Hz로 샘플링 되었다.

## 2. 모의실험 방법

BCI 시스템의 정확한 분류 성능의 추정을 위해 10×10-fold cross validation<sup>[13]</sup> 분석 방법을 이용해 시스템의 성능을 확인하였다. 10-fold cross validation은 모든 EEG 신호를 시행에 대해 10개의 부분을 임의로 나누는 후 차례대로 한 부분이 시험 신호, 나머지 9개 부분이 훈련 신호가 되도록 설정하여 10번의 분류 정확도를 얻는 데이터 분석 방법이다. 이 과정을 다시 10번 반복하여 총 100번의 분류 정확도를 얻은 후 평균을 하여 시스템 성능을 계산한다. 분류 알고리즘은 BCI 시스템에 널리 사용되는 선형 분류기인 LDA<sup>[14~15]</sup>를 사용하였다.




그림 3. 10-20 국제 전극법에 의한 전극 배치  
Fig. 3. The international 10-20 system of electrode placement.

EEG 측정 전극은 그림 3과 같이 10-20 국제 전극법에 따른 19개 전극(Fp1, Fp2, F3, F4, F7, F8, Fz, C3, C4, Cz, T3, T4, T5, T6, P3, P4, Pz, O1, O2)을 선택하여 분석하였다.

## 3. 필터 선택 결과 및 분류 정확도

먼저, DFB를 구성하기 위해 사용되는 CSP 특성 벡터의 LDA 평가 함수  $F_{CSP}^{(r)}$ 와 평균 전력 특성의 Fisher ratio  $F_{SP}^{(r)}$ 를 각각 정규화한 후 그림 4에 나타내었고, 필터 번호  $r$ 에 따른 필터의 주파수 통과 대역을 표 1에 표시하였다. 다른 피실험자와 달리 피실험자 'av'의 경우에는  $F_{SP}^{(r)}$ 와  $F_{CSP}^{(r)}$ 가 전혀 다른 경향성을 나타내는 것을 확인할 수 있다. 예를 들어, 최댓값을 나타내는 필터를 찾아보면  $F_{SP}^{(r)}$ 의 경우 18-24Hz,  $F_{CSP}^{(r)}$ 는 8-14Hz에서 가장 큰 값이 나타남을 알 수 있다.

그림 4에서 나타난  $F_{SP}^{(r)}$ 와  $F_{CSP}^{(r)}$ 의 차이는 필터 선택 결과에서도 나타난다.  $F_{SP}^{(r)}$ 와  $F_{CSP}^{(r)}$ 에 따른 필터 선택 횟수를 그림 5에 나타내었다. BCI 성능 분석을 10×10-cross validation를 이용하여 평가했기 때문에 한 개의 필터마다 최대 100번의 선택이 이루어졌다.  $F_{SP}^{(r)}$ 와  $F_{CSP}^{(r)}$ 의 차이가 크게 나타난 'av'의 경우 나머지 4명의 결과와 달리 필터 선택이 크게 다른 것을 확인할 수 있다. 구체적으로, 기존의 방법인 EEG 신호의 전력 특성을 이용하여 DFB를 구성한 경우 7, 8번 필터를 중심으로 선택하는 것을 확인할 수 있지만, CSP의 특성 벡터를 이용한 경우는 일반적으로 ERD가 나타나는  $\mu$ -대역의 필터를 선택하는 것을 확인할 수 있다. 'aa', 'al', 'aw', 'ay'의 경우 'av'와 같이 필터 선택에 있어 뚜렷한 차이를 나타내지 않은 것은 그림 4에서  $F_{SP}^{(r)}$ 와  $F_{CSP}^{(r)}$ 의 경향이 비슷하기 때문인 것으로 설명할 수 있다.

$F_{SP}^{(r)}$ 와  $F_{CSP}^{(r)}$ 를 이용한 필터 선택에 따른 분류 결과를 살펴보면 표 2 같다. 피실험자 'av'와 'aw'에 대해 CSP 특성 벡터를 이용한 DFB 구성이 EEG 신호의 평균 전력을 이용한 시스템보다 평균적으로 더 좋은 분류 성능을 나타내고 있음을 확인할 수 있다. 특히, 피실험자 'av'의 경우 기존의 시스템과  $K=4$ 인 경우 4.14%의 성능 차이를 나타내고 있다.

따라서  $\beta$ -대역의 필터보다  $\mu$ -대역의 필터를 선택하는 것이 더 좋은 성능을 나타내는 것을 알 수 있고, 기

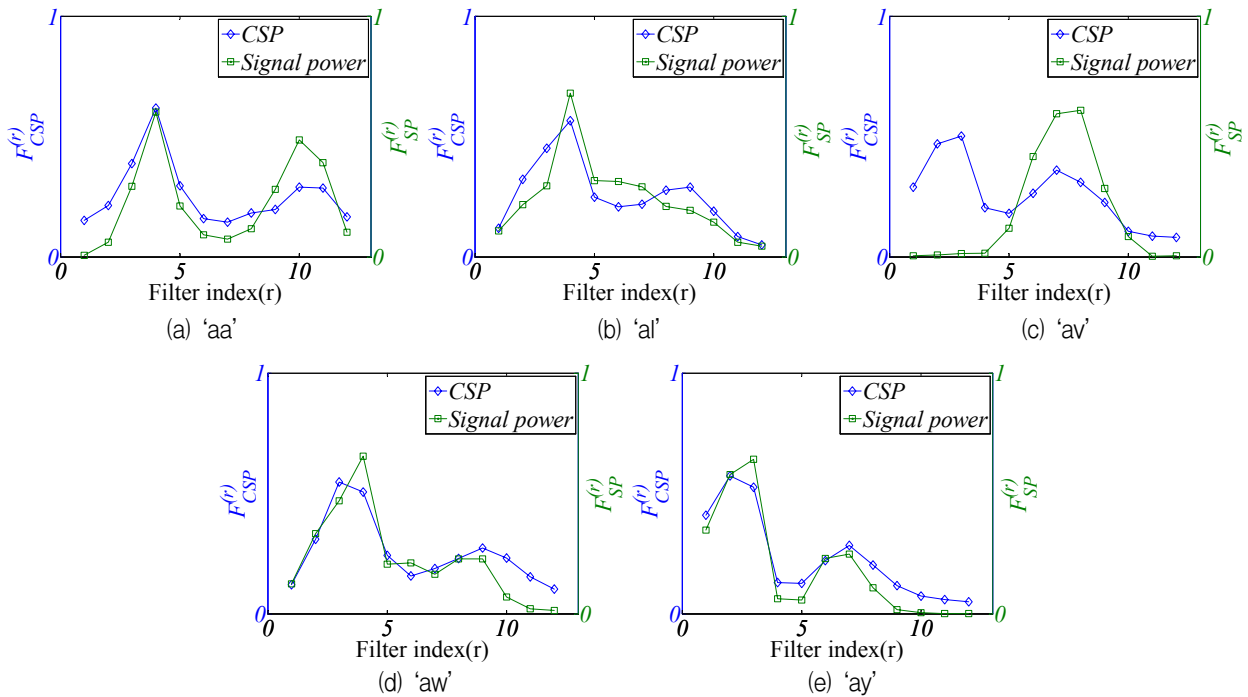


그림 4. 평균 전력(power)의 Fisher ratio  $F_{SP}^{(r)}$  과 CSP 특성 벡터의 LDA 평가 함수  $F_{CSP}^{(r)}$  비교  
Fig. 4. Comparison between Fisher ratio  $F_{SP}^{(r)}$  of signal power and LDA criterion function  $F_{CSP}^{(r)}$  of CSP feature vector.

표 2. 기존 DFBCSP와 제안하는 DFBCSP의 분류 정확도  
Table 2. Classification accuracy of existing DFBCSP and proposed DFBCSP.

피실험자	$F_{SP}^{(r)}$ 를 이용한 분류 정확도(%)								평균	$F_{CSP}^{(r)}$ 를 이용한 분류 정확도(%)								평균
	$K=1$	$K=2$	$K=3$	$K=4$	$K=5$	$K=6$	$K=7$	$K=8$		$K=1$	$K=2$	$K=3$	$K=4$	$K=5$	$K=6$	$K=7$	$K=8$	
'aa'	82.64	84.21	85.00	85.39	85.71	84.89	84.96	84.57	84.67	84.46	85.07	84.29	84.68	85.18	85.14	84.82	85.21	84.86
'al'	93.07	94.00	94.25	94.57	94.46	94.36	95.04	95.00	94.34	93.07	92.89	92.86	94.46	94.39	94.71	94.79	95.00	94.02
'av'	61.61	62.75	62.96	62.75	61.79	61.61	61.32	64.14	62.37	65.54	64.86	67.64	66.89	66.32	66.04	65.36	64.96	65.95
'aw'	80.96	83.86	84.68	84.75	84.04	84.39	84.79	84.54	84.00	82.64	84.64	85.18	85.68	85.32	85.18	85.57	84.54	84.84
'ay'	92.86	92.93	93.00	94.29	93.93	93.93	93.36	93.25	93.44	93.96	92.93	92.86	94.11	93.93	93.86	93.18	93.25	93.51

존의 DFB 구성 방식에 비해 본 논문에서 제안한 DFB 구성 방식이 더욱 효과적임을 보여 준다.

## V. 결 론

본 논문에서는 필터 बैं크 기반 BCI 시스템에서 피실험자의 ERD 공간 패턴이 나타나는 적절한 필터 선택을 위해 EEG 신호의 평균 전력을 대신하여 CSP 특성 벡터의 LDA 평가 함수를 이용하는 방법을 제안하였다. 일반적으로 운동상분류를 위한 ERD 공간 패턴이  $\mu$ -대역에서 나타나기 때문에 이 주파수 대역에 해당하는

필터를 선택해야 높은 분류 정확도를 얻을 수 있다. EEG 신호의 전력을 이용한 DFB 구성 방식을 이용하면 대체적으로  $\mu$ -대역의 필터를 선택하지만 한 명의 피실험자 'av'에 대해서는  $\beta$ -대역의 필터를 중심으로 선택해 나가는 것을 확인하였고 이로 인해 BCI 시스템의 성능 저하가 발생하는 것을 보였다. 이를 해결하기 위해 CSP 특성 벡터의 LDA 평가 함수를 구하면  $\mu$ -대역의 필터부터 선택해 나가며, 이를 통해 BCI 시스템 성능 개선을 얻게 되어, 제안된 선택 방법이 우수함을 확인하였다.

기존의 DFBCSP 시스템에서 분류를 위한 특성 벡터

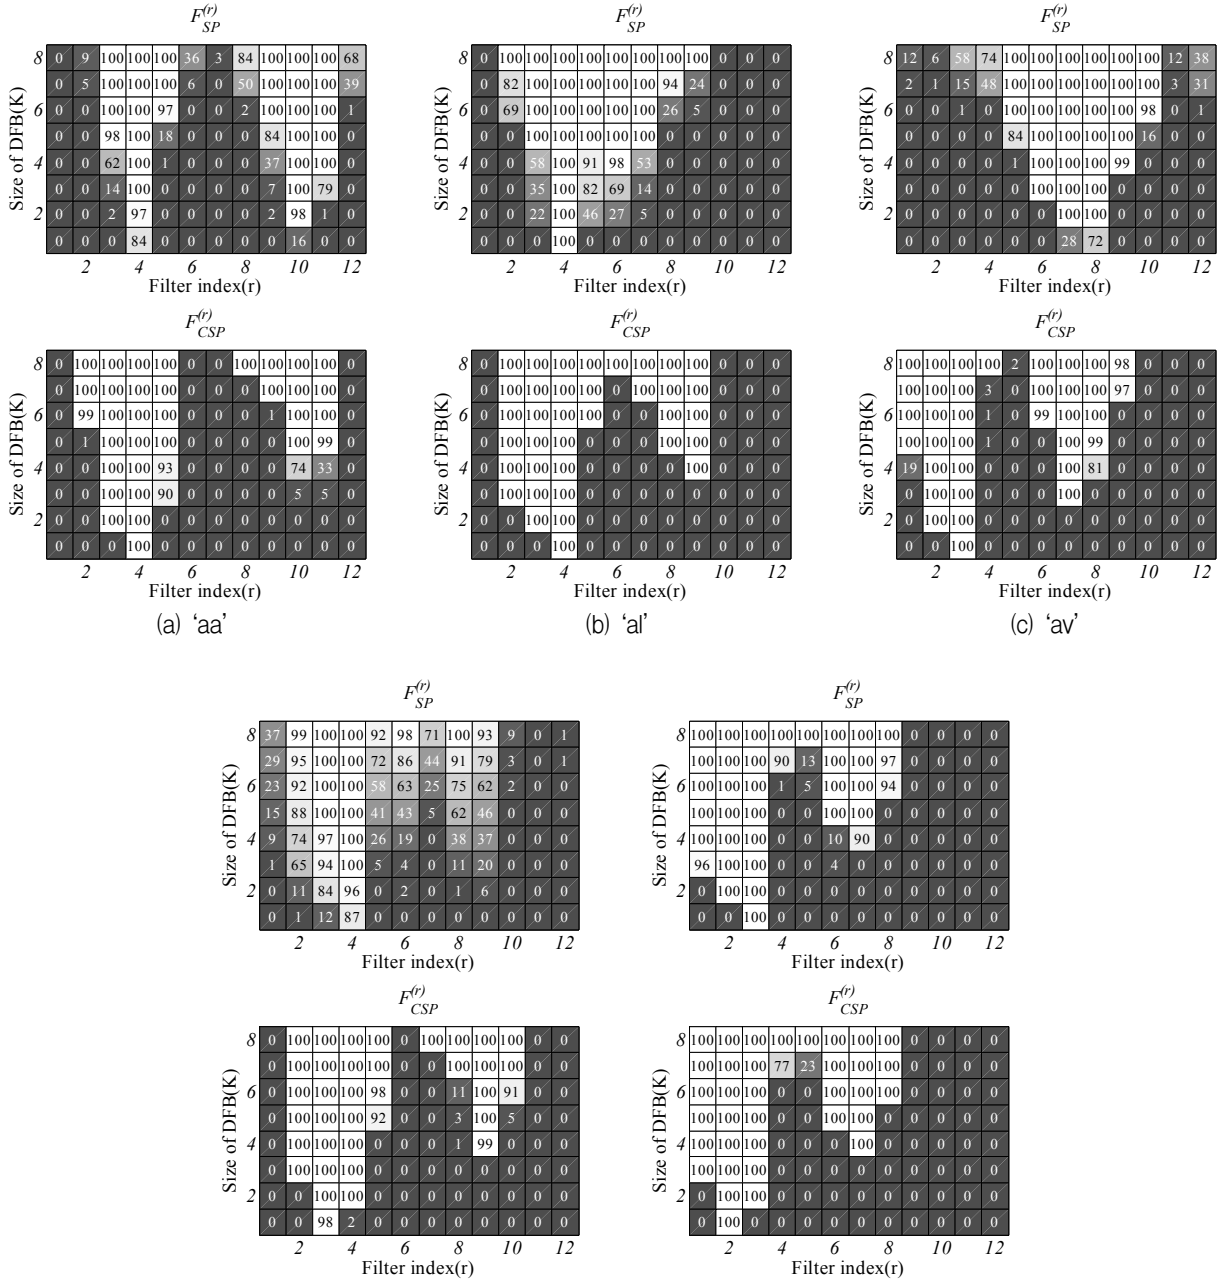


그림 5. Discriminative filter bank의 크기  $K$ 에 따른 필터의 선택 횟수  
 Fig. 5. The number of filters being selected according to the size of discriminative filter bank  $K$ .

는 CSP를 통해 정의 되었다. 하지만 분류에 사용되지 않는 EEG 신호의 평균 전력 특성을 이용해 CSP 특성 벡터의 선택 과정이 이루어졌기 때문에 모든 피실험자에 대해서는 높은 분류 결과를 나타낼 수 없었다. 본 논문은 분류 결과에 직접적으로 영향을 미치는 특성 벡터를 기반으로 특성 선택 과정을 시행하는 것이 시스템 성능의 측면에서 더욱 효과적임을 보였다는 데에 의미가 있다.

REFERENCES

[1] S. Sanei, *Adaptive processing of brain signals*, John Wiley & Sons Ltd, pp. 295–296, 2013.  
 [2] C. Wang, B. Xia, et al, “Motor Imagery BCI-based robot arm system,” in *Proc. 7<sup>th</sup> Int. Conf. Natural Computation. (ICNC)*, July 2011, pp. 181–184.  
 [3] C. Wang, et al, “A Feasibility Study of



- Non-Invasive Motor-Imagery BCI-based Robotic Rehabilitation for Stroke Patients,” in *Proc. 4<sup>th</sup> Int. Conf. Neural Eng., IEEE Eng. Med. Biol. Soc. (EMBS)*, April–May 2009, pp. 271–274.
- [4] R. Rebsamen, E. Burdet, C. Guan, H. Zhang, C. L. Teo, Q. Zeng, C. Laugier, and M. H. Ang Jr., “Controlling a Wheelchair Indoors Using Thought,” *IEEE Intelligent Systems*, vol. 22, no. 2, pp. 18–24, 2007.
- [5] L. Bonnet, F. Lotte, A. Lécuyer, “Two Brains, One Game: Design and Evaluation of a Multiuser BCI Video Game Based on Motor Imagery,” *IEEE Trans. Computational Intelligence and AI in Games*, vol. 5, no. 2, June 2013.
- [6] G. Pfurtscheller, C. Neuper, “Motor imagery activates primary sensorimotor area in humans,” *Neuroscience Letters*, vol. 239, no. 2–3, pp. 65–68, Dec 1997.
- [7] R. Srinivasan, “Methods to Improve the Spatial Resolution of EEG,” *International Journal of Bioelectromagnetism*, vol. 1, no. 1, pp. 102–111, 1999.
- [8] G. Pfurtscheller, and F. H. Lopes da Silva, “Event-related EEG/MEG synchronization and desynchronization: basic principles,” *Clinical Neurophysiology*, vol. 110, no. 11, pp. 1842–1857, Nov. 1999.
- [9] H. Ramoser, J. Müller-Gerking, and G. Pfurtscheller, “Optimal Filtering of Single Trial EEG During Imagined Hand Movement,” *IEEE Trans. Rehab. Eng.*, vol 8, no. 4, pp. 441–446, Dec. 2000.
- [10] Z. J. Koles, “The quantitative extraction and topographic mapping of the abnormal components in the clinical EEG,” *Electroencephalography and clinical Neurophysiology*, vol. 79, no. 6, pp. 440–447, 1991.
- [11] Q. Novi, C. Guan, T. H. Dat, and P. Xue, “Sub-band common spatial pattern for brain-computer interface,” in *Proc. 3rd Int. Conf. Neural Eng. IEEE Eng. Med. Biol. Soc. (EMBS)*, May 2007, pp. 204–207.
- [12] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, “Filter bank common spatial pattern (FBCSP) in brain-computer interface,” in *Proc. IEEE Int Joint Conf. Neural Netw.*, Jun 2008, pp. 2390–2397.
- [13] K. Thomas, C. Guan, C. Lau, A. Vinod and K. Ang, “A new discriminative common spatial pattern method for motor imagery brain-computer interfaces,” *IEEE Trans. Biomed. Eng.*, vol. 56, no. 11, pp. 2730–2733, Nov. 2009.
- [14] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche and B. Arnaldi, “A review of Classification Algorithms for EEG-based Brain-computer Interfaces,” *Journal of Neural Engineering* 4 (2007).
- [15] R. O. Duda, P. E. Hart, D. G. Stork, *Pattern Classification*, John Wiley & Sons Inc, pp. 117–121, 2001.
- [16] B. Blankertz, KR Müller, et al, “The BCI competition III: validating alternative approaches to actual BCI problems,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 14, no. 2, pp. 153–159, Jun. 2006.

저 자 소 개



**박 근 호**(학생회원)  
 2013년 부산대학교 전자전기  
 공학부 학사 졸업  
 2013년~현재 부산대학교  
 전자전기컴퓨터공학과  
 석사과정

<주관심분야 : 디지털 신호처리, 생체 신호처리,  
 배열 신호처리>



**이 유 리**(학생회원)  
 2010년 부산대학교 전자전기  
 통신공학부 학사 졸업  
 2012년 부산대학교 전자전기  
 공학과 석사 졸업  
 2012년~현재 부산대학교  
 전자전기컴퓨터공학과  
 박사과정

<주관심분야 : 디지털 신호처리, 생체 신호처리,  
 디지털 방송 신호처리, 부채널공격>



**김 형 남**(평생회원)-교신저자  
 1993년 2월 포항공과대학교  
 전자전기공학과 학사  
 1995년 2월 포항공과대학교  
 전자전기공학과 석사  
 2000년 2월 포항공과대학교  
 전자전기공학과 박사

2000년 3월~2000년 4월 포항공과대학교  
 전자컴퓨터공학부 박사 후 연구원  
 2000년 5월~2003년 2월 한국전자통신연구원  
 선임연구원  
 2003년 3월~2007년 2월 부산대학교  
 전자공학과 조교수  
 2007년 3월~2012년 2월 부산대학교  
 전자전기공학부 부교수  
 2012년 3월~현재 부산대학교 전자공학과 교수  
 <주관심분야 : 적응신호처리, 레이더 및 소나 신  
 호처리, 디지털 방송신호처리, 생체신호처리>