

# 뇌-컴퓨터 인터페이스를 위한 개인의 특성을 반영하는 뇌파 분류기

(An EEG Classifier Representing Subject's Characteristics for Brain-Computer Interface)

김도연<sup>†</sup> 이광형<sup>\*\*</sup> 황민철<sup>\*\*\*</sup>

(Do-Yeon Kim) (Hyung Lee-Kwang) (Min-Cheol Hwang)

**요약** 인간의 생각만으로 기계를 작동할 수 있게 하는 인터페이스 시스템에 관한 연구 분야인 BCI(Brain-Computer Interface)에서는 피험자의 두피로부터 EEG(Electroencephalograph)를 측정하고 인식하여 뇌 상태를 알아내고 그 결과를 기계의 조종에 응용하는 방법을 사용한다. 본 연구에서는 각 개인으로부터 고유의 뇌파인 EEG를 얻고 신호처리하여 인식하는 인식모델을 제안하였다. 제안된 모델은 특정 작업을 수행하고 있을 때의 EEG 신호로부터 인식에 중요한 영향을 미치는 특징들을 추출해 내고, 이를 인식에 이용한다. 제안된 모델은 인식할 EEG 패턴들을 두개씩 분류하여 각각을 인식한 후, 그 결과를 종합하여 최종적인 인식결과를 얻도록 하였다. 본 연구의 실험에서는 피험자가 4가지의 작업을 수행하는 동안 얻어지는 4가지 EEG 패턴을 인식하였다. 제안된 모델은 90%이상의 높은 인식율을 보였고, 각 피험자에게 독특하게 존재하는 특징들을 인식 결과로서 제공하였다. 제안된 모델의 높은 인식율과 빠른 처리속도는 실시간 BCI 시스템에 응용될 수 있는 가능성을 보여주고 있다.

**Abstract** BCI(Brain-Computer Interface) is studied to control the machines with brain. In this study, an EEG(Electroencephalography) signal classification model is proposed. The model gets EEG pattern from each subject's brain and extracts characteristic features. The model discriminates the EEG patterns by using those extracted characteristic features of each subject. The proposed method classifies each pair of the given tasks and combines the results to give the final result. Four tasks such as rest, movement, mental-arithmetic calculation and point-fixing were used in the experiment. Over 90% of the trials, the model yielded successful results. The model exploits characteristic features of the subjects and the weight table that was produced after training. The analysis results of the model such as its high success rates and short processing time show that it can be used in a real-time brain-computer interface system.

## 1. 서론

현재까지 기계와 인간사이의 인터페이스를 쉽고 편리하게 만들기 위해서 많은 노력이 경주되어 왔고, 인간에

게 좀 더 자연스러운 인터페이스를 만들기 위해 음성인식, 문자인식, 자연어 처리, 이미지 프로세싱, 컴퓨터 그래픽스 등 다양한 기법들이 적용되어 왔다. 그러나 이러한 기술들을 이용한 현재의 인터페이스들은 궁극적으로 사용자의 근육운동에 의존하고 있다는 한계를 지니고 있다. 근육운동에 의존하지 않고 단지 뇌의 의지(인간의 생각)만으로 기계와 의사소통을 가능하게 하는 목적으로 출발한 연구가 있는데, 바로 뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI) 분야이다[3, 4].

BCI 연구는 80년대 후반부터 시작되었고, 미국의 '뇌의 10년' 선포와 더불어 막대한 투자 아래 가속화 되기 시작했다[3, 4]. 현재 뇌파(Electroencephalograph,

· 본 연구는 첨단정보기술연구센터를 통하여 과학재단의 지원을 일부 받았음.

† 비 회 원 : DACOM 종합연구소 연구원  
peach@halla.dacom.co.kr

\*\* 종신회원 : 한국과학기술원 전산학과 교수  
khlee@fuzzy.kaist.ac.kr

\*\*\* 비 회 원 : 상명대학교 정보통신학부 교수  
whang@pine.sangmyung.ac.kr

논문접수 : 1998년 9월 17일

심사완료 : 1999년 8월 20일

EEG)를 이용한 뇌-컴퓨터 인터페이스 연구는 유발 전위(event-related potential)를 이용하는 방법과 자발전위(spontaneous EEG)를 이용하는 방법이 있다. 유발전위는 시각, 청각, 촉각, 미각, 후각 등의 오감을 자극할 때 자극에 반응하여 발생하는 특정 전위(potential)를 지칭하는 말인데, 자극을 주고 이에 반응하여 나타나는 뇌파를 분석하여 뇌의 상태를 알아낸다. 다른 방법으로는 자발전위를 이용하는 것인데, 사람은 훈련을 통해 자신의 자발전위(파)의 방출량을 조절할 수가 있다[3, 4, 9]. Wolpaw는 이 점에 착안하여 컴퓨터와의 의사소통 채널로 이용하였다. 또 다른 최근의 연구자들은 피험자가 특정 과제(task)를 수행하고 있을 때 나오는 뇌파 신호의 인식을 패턴인식 문제로 보고 해결하고 있다. Pfurtscheller와 Keirn, Aunon, Anderson등이 대표적인 사람들인데, 이들은 기존의 신경망[13, 14, 15]이나 LVQ(learning vector quantization) 또는 DSLVQ(distinction sensitive learning vector quantization) 등의 인식기로 뇌파 패턴인식 문제를 해결하고 있다[1, 5, 6, 7, 8, 11, 12].

본 논문의 접근 방법도 Pfurtscheller나 Anderson등의 접근 방법과 기본적인 맥락을 같이 하고 있다. 이러한 접근 방법의 장점은 첫째, 피험자의 학습이 필요 없다는 것이고 둘째, 실시간 시스템을 만들 수 있다는 것이다. 따라서 이 방법은 뇌파를 이용한 인터페이스를 구축하기 위한 핵심적인 조건들을 만족하고 있으므로 가장 의미가 있는 접근 방법이다.

그러나 현재 이루어지고 있는 이러한 연구 방법들에서도 문제는 있다. 이들은 여러 사람의 데이터를 분석할 때에 일괄적으로 똑같은 주파수 대역을 이용하였다. Pfurtscheller는 빠른  $\alpha$  파(10~12Hz)와 중간  $\beta$  파(20~24Hz)를 이용하였고, Anderson은  $\delta$  파(0~3Hz),  $\theta$  파(4~7Hz),  $\alpha$  파(8~13Hz),  $\beta$  파(14~20Hz)를 이용하였다. 하지만 뇌파라는 것은 그 특성상 각 개인마다 모두 다른 양상을 보이기 때문에 모든 사람들에게 똑같은 주파수 특징을 취해서 분석하는 것 보다는 각 개인의 특성을 반영할 수 있도록 주파수 특징을 이용하는 것이 더 합리적일 것이다. 따라서 본 논문에서는 각 개인의 특성을 반영하여 개인의 특성에 적응적인 특징(adaptive

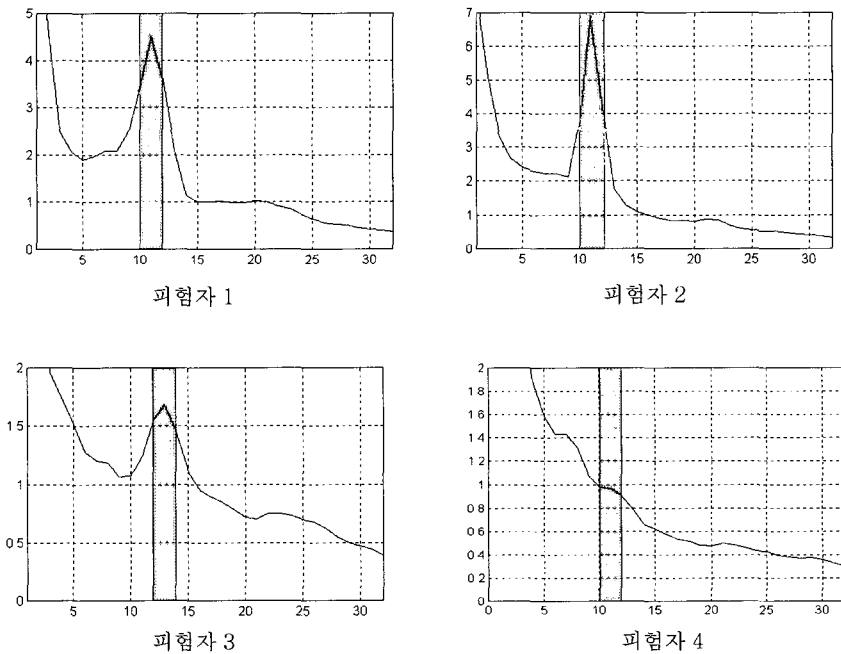


그림 1 4명의 피험자의 안정상태의 뇌파 (x축: 주파수, y축: FFT 파워값)

feature)을 사용하는 분석 모델을 제안하였다. 개인의 특성을 반영하기 위해 DSLVQ라는 분석기를 이용하였다. DSLVQ는 각 특징의 변별력에 대한 가이드를 제시한다. 그래서 DSLVQ의 학습을 통해 나오는 각 특징에 대한 가중치(weight value)를 이용해 특징을 추출한다.

## 2. 제안된 모델

기존의 뇌파 인식 방법들은 모든 사람에 대해 일괄적으로 똑같은 주파수 대역을 고려한다. 일반적으로  $\delta$  파 밴드(0~3Hz),  $\theta$  파 밴드(4~7Hz),  $\alpha$  파 밴드(8~13Hz),  $\beta$  파 밴드(14~20Hz)를 이용하는 방법이 있고[1, 2, 12], 고주파  $\alpha$  밴드(10~12Hz), 중주파  $\beta$  밴드(20~24Hz)를 고려해주는 방법이 있다[12].

그러나 위의 방법들처럼 모든 사람들에게 똑같은 주파수 대역을 적용하면 개인의 특성을 잘 반영하지 못하게 된다. 뇌파라는 것은 개인마다 다른 양상을 띄므로 모든 사람에게 일괄적인 특징을 적용하는 것 보다는 개개인에게 자사의 특성을 잘 반영하는 특징을 추출하여 이용하는 인식기를 제안하는 것이 더욱 적합하다. 그림 1을 보면 같은 안정상태에서의 뇌파라도 피험자에 따라 피크가 나타나는 주파수 영역이 다르고 FFT파워값도 다르게 나타남을 볼 수 있다.

각 개인에 대한 학습 데이터의 개수가 적당하다면 개인의 특성을 잘 반영하는 인식기를 만들어서 그 성공률을 높이는 것이 실제 응용성이 있다고 생각된다. 제안된 모델은 여러 가지 과제(task)에 대응하여 반응하는 각 개인의 뇌파 패턴을 구별 할 때에 각 개인마다 구별에 주요한 영향을 미치는 주파수 대역이 조금씩 다르다는 가정하에 제안되었다. 결과적으로도 3명의 피험자에 대한 실험과 인식을 통해 위의 성질은 어느 정도 타당함이 보여졌다. 제안된 모델은 각 개인의 뇌파 패턴의 인식에 있어서 주요한 영향을 미치는 특징(그 중에서도 특히 주파수 대역)을 추출한다. 그리고 추출된 특징들에 대해 다시 학습 데이터와 테스트 데이터를 재구성한 뒤 재학습 시키고 테스트를 거쳐 결과를 종합한다. 또한 인식율을 향상시키기 위해 여러 가지 클래스 간의 구분에 있어서 부분문제로 나누어 해결한 뒤 결과를 종합하도록 하는 수정-제안 모델도 제안한다.

전자의 제안 모델을 제안 모델1이라 명명하고 수정-제안 모델을 제안 모델2라 명명하였다. 제안 모델 1을 먼저 기술하고 그 후 제안 모델 2를 기술한다.

### 2.1 제안 모델 1

제안 모델 1의 순서도는 그림 2와 같다.

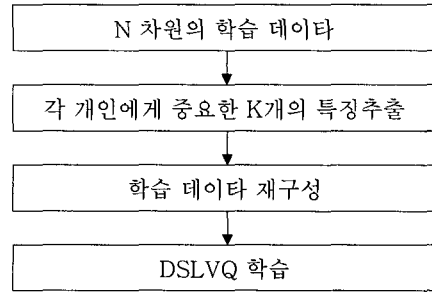


그림 2 제안 모델 1의 순서도 I

각 개인으로부터 고려할 수 있는 모든 정보를 이용해 처음 N차원의 학습 데이터를 만들고 DSLVQ로 학습시킨다. 여기서 정보란 각 주파수 대역에 대한 FFT 파워 값이나 여러 가지 표현법으로 나타내어진 계수 등 특징이 될 가능성을 가지고 있는 모든 것을 말한다. 그런데 여기서 N개의 정보(candidate features)를 모두 이용하여 인식하는 것은 시간면에서나 분석면에서 그다지 좋은 방법은 아니다. N개의 정보가 특별한 중요성을 가지고 있기 때문에 추출된 것들이 아니라, 고려할 수 있는 모든 것을 고려하겠다는 의도로 선택된 것들이기 때문이다. 즉 처음에 선택한 N개의 정보들 중에는 패턴 인식에 전혀 도움을 주지 않는 것들도 존재할 가능성이 있다. 그러므로 이런 것들까지 다 넣어 인식하는 것 보다는 몇 개의 중요한 정보만을 추출해서 재학습시키는 것이 더 효율적이다. 본 제안 모델에서는 고려할 수 있는 N개의 정보들을 모두 모아 하나의 벡터로 만들어 DSLVQ로 학습시킨 후 가중치 값(weight value)이 높은 순으로 몇 개를 선택한다. 이렇게 선택된 것들은 특징이라 불릴 수 있는데, 이러한 특징들은 각 개인의 뇌파의 패턴인식에 적합한 특징들이 된다. 이렇게 해서 추출된 특징들로 학습데이터를 재구성 한 뒤 다시 DSLVQ학습을 시킨다. 이것을 좀 더 자세히 설명한 것이 그림 3이다. 후보특징<sub>1</sub>, 후보특징<sub>2</sub>, ..., 후보특징<sub>N</sub>은 각각 각 개인으로부터 고려할 수 있는 모든 후보특징들(candidate features)을 나타낸다.

후보특징들로 이루어진 N차원의 학습 데이터를 만든 후, 이 N차원의 학습 데이터를 DSLVQ로 학습시킨다. 이렇게 DSLVQ 학습을 시키면 N차원의 후보특징들이 그 변별정도에 따라 서로 다른 가중치 값을 가지게 되는데, 이것이 가중치<sub>1</sub>에서 가중치<sub>N</sub>까지이다.

후보특징 벡터는 가중치 벡터를 수반하여 (후보특징<sub>1</sub>,

가중치<sub>1</sub>), (후보특징<sub>2</sub>, 가중치<sub>2</sub>), ..., (후보특징<sub>N</sub>, 가중치<sub>N</sub>)의 2×N 의 행렬이 된다. 이렇게 만들어진 2×N의 행렬을 가중치 값이 큰 순으로 정렬하여 가중치 값이 큰 후보특징을 K개 추출하면, 구별에 중요한 K개의 특징이 얻어진다. 이렇게 얻어진 특징으로 학습데이터를 재구성한 뒤 다시 DSLVQ 학습시킴으로써 인식에 더욱 적합하도록 가중치 값을 재할당시킨다.

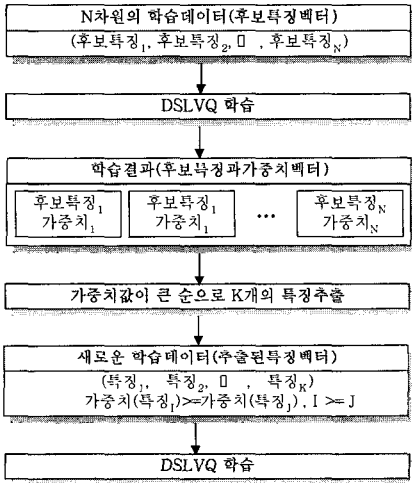


그림 3 제안 모델 1의 순서도 II

2.2 제안 모델 2

제안 모델 1은 개인의 개별성을 고려해 주는 매우 의미있는 방법이다. 하지만 제안 모델1은 개선의 여지가 있다. 제안 모델 2는 제안 모델 1보다 인식률을 향상시키기 위해 여러 가지 클래스간 구분에 있어서 부분문제로 나누어 해결한 뒤 결과를 조합하도록 하였다. 다시 말해, M가지를 인식해야 하는 문제에서 2개의 패턴만을 인식할 수 있는 인식기를 M<sub>C</sub>2개 만든다. 그리고 이러한 부분 인식기들의 결과를 종합하여 M가지의 패턴을 구분해낸다. M가지의 경우로부터 2개씩 짝지을 수 있는 경우는 M<sub>C</sub>2가지이기 때문에 M개의 패턴을 인식하기 위해서는 M<sub>C</sub>2개의 인식기가 필요하다.

그림 4와 같이 임의의 인식대상패턴을 패턴 A, 패턴 B, 패턴 C 중의 하나로 인식하고자 하는 문제를 가정해 보자.

이 때 A/B인식기는 임의의 패턴에 대해 그것이 패턴 A에 속하는지 패턴 B에 속하는지를 결정하는 인식기이다. 다시 말해, A/B인식기는 후보특징벡터로부터 패턴 A와 패턴 B를 가장 잘 인식하도록 특징을 K개 추출하

고 추출된 특징들에 대해 가중치를 부여한 인식기이다. 특징 추출은 제안 모델 1의 방법과 동일하다. 마찬가지로 A/C인식기는 패턴 A와 패턴 C를, 그리고 B/C인식기는 패턴 B와 패턴 C를 구별하는 인식기라고 하자.

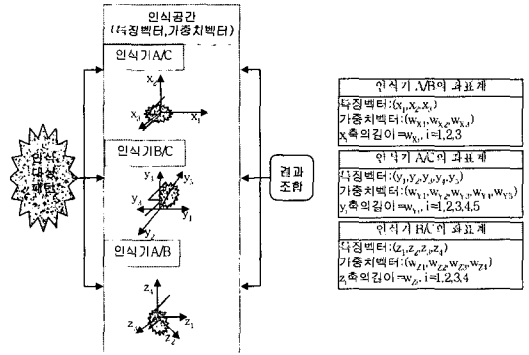


그림 4 인식대상 패턴을 패턴 A, 패턴 B, 패턴 C 중의 하나로 결정

임의의 인식대상패턴이 각각의 인식기에 의해 인식되는 과정이 그림 4에 나타나있다. 추출된 K개의 특징들이 특징 벡터 (x<sub>1</sub>, x<sub>2</sub>, x<sub>3</sub>)가 되고, 가중치벡터는 (w<sub>x1</sub>, w<sub>x2</sub>, w<sub>x3</sub>)가 된다. 다시 말해, A/B인식기는 인식대상패턴을 특징 벡터 (x<sub>1</sub>, x<sub>2</sub>, x<sub>3</sub>)로 구성된 좌표계로 변환(transformation)시킨다. 이때, 각 축의 길이는 그 축이 바탕이 되는 특징의 가중치 값이 된다. 그리고 변환된 인식대상패턴이 A에 가까운 패턴인지 B에 가까운 패턴 인지를 결정한다. B/C인식기와 A/C인식기의 경우에도 마찬가지로 과정이 적용된다. 이렇게 인식대상패턴이 3개(일반적으로 M<sub>C</sub>2개)의 인식기를 통과하면 각각의 인식기는 인식대상패턴이 어느 패턴에 속하는지를 말해준다. 그러면 M<sub>C</sub>2개의 인식기로부터 나오는 모든 결과를 종합하여 최종적으로 인식대상패턴이 어느 패턴에 속하는지를 결정할 수 있게 된다.

표 1 결과 조합

부분문제인식기	인식결과
A/B 인식기	A
A/C 인식기	A
B/C 인식기	B or C

결과를 조합하는 과정은 표 1과 같다. 만일 클래스 A

에 속하는 테스트 데이터가 들어와서 제대로 인식이 되었다면 A/B 인식기는 A를 말할 것이고, 마찬가지로 A/C 인식기도 A를 말할 것이다. 그러나 B/C 인식기는 테스트 데이터가 상대적으로 B에 가까우면 C에 가까우면 따라 B나 C중에 하나를 말할 것이다.

즉, 클래스 A에 속하는 데이터가 A와 관련된 인식기들(A/B, A/C)에서 제대로 인식이 이루어지면, 결국 표 1처럼 A에 2표를 얻고 B나 C에는 많아야 1표 밖에 얻을 수 없게 된다. 따라서 2표를 얻는 클래스 A를 테스트 데이터가 속하는 클래스로 결정한다. 클래스 B나 C에 속한 인식대상패턴이 입력으로 들어올 때도 마찬가지로 적용된다. 본 논문의 제안 모델은 이러한 방식으로 여러 개의 부분문제 인식기들의 결과를 조합하였다. M가지를 인식하는 문제에서는  $M_C$ 개의 부분문제 인식들로부터  $M - 1$ (또는  $M - 1$ 에 가까운 최대값)표를 얻는 클래스를 테스트 데이터가 속하는 클래스가 되도록 결정한다.

제안 모델 2의 방법은 제안 모델 1의 방법보다 유리하다. 두 방법 사이의 가장 큰 차이점은 각 인식기가 이용하는 특징들과 그 특징들에 할당된 가중치 값이다. 제안 모델 2는  $M_C$ 개의 인식기 각각이 자신이 인식할 2가지 패턴을 가장 잘 인식하도록 특징을 추출하고, 추출된 특징들에 대해 최적의 가중치 값을 할당한다. 이것은 결국 각각의 인식기가 인식대상패턴을 인식하기 쉬운 자신만의 공간(좌표계)으로 변환하여 인식하도록 한다. 그래서 제안 모델 2의 방법은 제안 모델 1의 방법보다 유리해 질 수 있다.

시간제약의 관점에서 보면 제안 모델 2는 제안 모델 1에 비해  $M_C$ (약  $M^2$ )배의 시간이 소요된다는 단점이 있다. 그러나 현재의 뇌파 패턴 인식 수준은 굉장히 많은 여러 상태의 뇌파를 인식하는 수준이 아니라 5 이내의 적은 수의 뇌파 상태를 인식하는 수준이므로 시간 문제는 그다지 치명적이지(critical) 않다. 따라서  $M^2$ 배의 시간은 허용할 수 있는(acceptable) 수준이라고 할 수 있다.

제안 모델 2가 제안 모델 1보다 유리 할 것이라는 위의 가정이 맞는지 확인하기 위하여 4장에서는 실험으로부터 얻은 데이터에 대해 제안 모델 1과 제안 모델 2를 적용시켜 인식율을 비교한다.

### 3. 실험

안정상태(rest), 움직임상태(move), 암산상태(mental-arithmetic), 눈 뜬 상태(eye-open)의 총 4가지

다른 과제(task)를 하고 있을 때의 뇌파를 측정하였고, 이를 제안 모델을 적용시켜 구분하였다.

#### 3.1 피험자 및 실험환경

18세에서 25세 사이의 3명의 피험자가 실험에 참가하였다. 이 중 두 명은 여자이고 한 명은 남자였다. 각 피험자에 대해 하루동안 실험을 하였고, 하루동안에 얻은 데이터로 분석하였다. 피험자는 실험자가 원하는 상태를 바로 알고 원하는 상태를 유지하도록 노력하였다. 피험자는 또한 가능한 한 소음 및 기타의 노이즈에 영향을 받지 않도록 소리 및 여러 노이즈로부터 차단된 공간 안에서 실험자의 지시에 따라 실험에 임했다.

EEG 데이터를 얻는데 사용된 시스템은 Biopac, MP100이고 Biopac에서 제공되는 인터페이스를 사용하였다. Biopac은 자체적으로 1~100Hz 밴드패스 필터링 시켜준다. 샘플링율은 256이었고, 게인값(gain)은 10000으로 고정시켰다. 사용된 전극(electrode)은 컵형 전극(metal-cup type)이고, 은 전극(silver electrode)을 사용하였다.

#### 3.2 데이터 수집

4가지 다른 과제(task)를 하고 있을 때의 뇌파를 측정하였다. 안정상태란 눈을 감고 편안한 마음에 있는 상태이고, 움직임상태란 신체의 일부를 움직이고 있는 상태이다. 이 때 움직임을 유도하기 위해 집게를 집는 행동을 취하도록 하였다. 암산상태는 집중을 하여 정신적인 일을 처리할 때와 같은 긴장된 상태이다. 암산을 유도하기 위해 피험자에게 십자리 수와 십자리 수의 곱셈 암산을 요구하였다. 눈 뜬 상태는 눈을 뜬 상태에서 가만히 한 지점을 응시하고 있는 상태이다.

전극을 붙인 위치는 그림 5와 같이 국제 10-20 시스템의 C3, C4, F3, F4, O1이다. 본 실험에서 의도하는 바는 EEG를 측정하여 움직임과 암산할 때와 안정상태와 눈을 뜨고 있는 상태를 인식하는 것이다. 따라서 10-20 시스템의 위치들 중 각 상태들에 민감하게 반응하는 위치를 선정하였다.




그림 5 전극(electrode) 위치

운동신경과 밀접한 연관이 있는, 그 중에서도 손의 움직임과 연관성이 많은 C3, C4의 위치, 정신적인 것(mental-workload - 공포, 스트레스, 희열, 긴장)에 민감한 F3, F4의 위치, 시각반응 신경계과 밀접한 연관이 있는 O1 위치, 이상과 같이 총 5개의 위치에 전극(electrode)을 부착시켰다. 양쪽의 컷볼을 기준으로 잡고, 접지는 귀 뒷부분에 두었다. 샘플링율은 초당 256이었다. 초시계(stop watch)로 과제 시행의 시작과 끝을 알렸다. 안정상태, 암산상태, 눈 뜬 상태의 경우에는 1번의 시행에서 3초간의 데이터를 얻었고, 움직임상태의 경우에는 한 번 집계를 쥐었다 펴는데 1초면 충분하기 때문에 1번의 시행에서 1초간의 데이터를 얻었다. 얻어진 데이터는 1초 구간씩 나누어 독립적인 데이터로 사용하였다.

**4. 분석 결과**

본 논문에서는 4가지 종류의 과제(안정상태, 암산상태, 동작상태, 눈을 뜨고 있는 상태)를 분석하는 문제에 제안 모델을 적용시켜 보았다.

**4.1 제안 모델 1, 제안 모델 2의 성능**

**4.1.1 제안 모델 1의 적용**

그림 5의 C3, C4로부터 나오는 5~34Hz까지의 FFT 파워값과 F3, F4로부터 나오는 5~34Hz까지의 FFT 파워값, O1으로부터 나오는 5~34Hz까지의 FFT 파워값 모두 합해서 총 90개의 후보특징으로 이루어진 90차원의 벡터를 만들었다. 5Hz미만과 35Hz이상의 데이터는 고려의 대상에서 제외시켰다. 저 주파수 대역은 노이즈에 매우 민감하기 때문에 사용하지 않았고, 35Hz이상의 주파수 대역은 머리부근의 근전도가 영향을 끼치지 않는 한 순수한 뇌 활동에서는 거의 나오지 않는 영역이기 때문에 제외시켰다. 그 다음 90차원의 학습데이터를 DSLVQ로 학습 15개의 특징을 추출하였다. 이렇게 얻어진 15개의 특징으로 학습데이터와 테스트 데이터를 재구성 한 뒤 다시 DSLVQ 학습 시켰다.

**4.1.2 제안 모델 2의 적용**

4C2가지의 경우에 대해 따로따로 분석하였다. 즉 안정상태/동작상태를 구분하는 경우, 안정상태/암산상태를 구분하는 경우, 안정상태/암산상태를 분석하는 경우, 움직임상태/암산상태를 구분하는 경우, 움직임상태/눈 뜬 상태를 분석하는 경우, 암산상태/눈 뜬 상태를 분석하는 경우의 총 4C2가지(6가지)의 경우로 나누어 따로따로 인식한 다음 결과를 종합했다. 처음에 고려하는 특징은 제안 모델 1과 마찬가지로 90개이다. 4C2가지의 각 경우에 대해 가중치(weight) 값이 높은 순으로 15개의 특징들

을 추출하고, 학습 데이터와 테스트 데이터를 재구성했다. 이렇게 재구성된 학습 데이터와 테스트 데이터는 다시 DSLVQ를 통해 재학습된 후 테스트과정을 거쳤다.

실험으로부터 얻은 데이터를 가지고 제안 모델 1과 제안 모델 2를 적용시켜 보았다. 표 2에서 표 5는 제안 모델 1과 제안 모델 2를 적용시켜 보았을 때의 테스트 결과이다. 90개의 특징으로부터 선별해 이용한 특징의 수(K = 5, 10, 15, 20)를 변화시켜 가면서 테스트 한 결과이다.

표 2 사용한 특징의 개수가 5일 때

# of feature : 5	피험자 1	피험자 2	피험자 3
제안모델 1	87.5%	55.0%	87.5%
제안모델 2	77.5%	90.0%	90.0%

표 3 사용한 특징의 개수가 10일 때

# of feature : 10	피험자 1	피험자 2	피험자 3
제안모델 1	87.5%	55.0%	87.5%
제안모델 2	87.5%	92.5%	95.0%

표 4 사용한 특징의 개수가 15일 때

# of feature : 15	피험자 1	피험자 2	피험자 3
제안모델 1	85.0%	87.5%	87.5%
제안모델 2	82.5%	95.0%	95.0%

표 5 사용한 특징의 개수가 20일 때

# of feature : 20	피험자 1	피험자 2	피험자 3
제안모델 1	85.0%	92.5%	87.5%
제안모델 2	82.5%	95.0%	95.0%

대부분의 경우 제안 모델 2의 결과가 좋았다. 결국 제안 모델 2가 제안 모델 1보다 더 유리하다는 2장에서의 가정이 분석 결과로 나타났다.

**4.2 여러 특징들에 대한 비교**

본 절에서는 다른 연구자들이 사용했던 특징을 그대로 적용시켜 보았을 때와 제안된 모델의 특징 추출에 의해 분석했을 때 어떠한 차이를 보이는지 살펴본다. Anderson과 Pfurtscheller의 논문을 참조하였다.

Anderson이 사용한 주파수 특징은 0~3Hz( $\delta$  파), 4~7Hz( $\theta$  파), 8~13Hz( $\alpha$  파), 14~20( $\beta$  파)이다. 주파

수 전체 구간을 몇 개로 나누어 각각의 주파수 대역의 스펙트럴 밀도값(spectral density)을 구해서 특징으로 이용했고 좌반구와 우반구의 비 대칭성의 성질을 이용하였다.

또한 Pfurtscheller는 시그널을 빠른  $\alpha$  파(10~12Hz)와 중간  $\beta$  파(20~24Hz)로 밴드 패스 필터링 시저 특징으로 이용했다. 본 절의 분석에서는 그들이 실험에 이용했던 주파수 대역을 그대로 적용시켜 분석해 보았다. 그리고 제안 모델 2의 결과와 비교하였다. 결과는 표 6와 같다.

표 6 다른 연구자들이 사용한 특징들을 적용했을 때의 결과

	피험자 1	피험자 2	피험자 3
Anderson	52.5%	60.0%	65.0%
Pfurtscheller(alpha)	90.0%	80.0%	85.0%
Pfurtscheller(beta)	35.0%	55.0%	60.0%
제안모델	82.5%	95.0%	95.0%

다른 연구자들이 사용했던 특징들을 적용한 9가지 경우 중 1가지 경우만을 제외하고는 제안된 모델이 더 좋은 결과를 보이고 있고 특히 제안 모델 2가 두드러진 결과를 보이고 있다.

다음은 전문가가 실험 데이터를 바탕으로 추출한 특징들을 모든 피험자의 데이터에 일괄적으로 적용했을 때를 분석하였다. 1, 2, 3, 4는 각각에 해당하는 주파수 대역의 FFT 파워 값을 이용했을 때이고, 과제별 구분을 위해 C3와 C4로부터 나오는 FFT 파워 값을 더해 하나의 대표값으로 만들고, F3와 F4로부터의 FFT 파워 값을 더해 하나의 대표 값으로 만들었다. 이용한 주파수 대역은 다음과 같다.

- 1 : 5~7, 10, 11, 12, 22~24
- 2 : 5~7, 10~12, 22~24
- 3 : 5~7, 10~12, 14~21, 22~24
- 4 : 5~7, 10~12, 14~21, 22~24, 25~30 (단위: Hz)

표 7 전문가에 의해 추출된 특징

	피험자 1	피험자 2	피험자 3
1	90.0%	85.0%	92.5%
2	80.0%	92.5%	95.0%
3	80.0%	92.5%	92.5%
4	80.0%	92.5%	87.5%
제안모델	82.5%	95.0%	95.0%

표 7은 위의 특징들을 적용하여 분석한 결과이다. 전문가에 의해 추출된 특징을 적용한 경우에도 좋은 결과를 보이고 있다. 적어도 Anderson이나 Pfurtscheller가 사용했던 특징들 보다 더 좋은 결과를 보였다. 그러나 전문가에 의해 추출된 특징들이 매우 잘 분석이 됨에도 불구하고, 제안된 모델을 적용했을 때 더 좋은 결과를 보이고 있다. 이러한 결과들은 결국 각 개인에게 일괄적으로 똑같은 특징을 적용하기 보다는 제안 모델처럼 각 개인에게 적합한 특징을 선별하여 적용하는 것이 더욱 타당함을 말해주고 있다.

### 4.3 가중치 표 해석

제안 모델은 학습을 거치고 나면 특징 벡터의 각 특징에 대한 가중치를 가중치 값(weight value)을 통해 알 수 있게 해준다. 따라서 가중치(weight) 분석을 통해 각 개인에 대한 경향을 파악할 수 있다. 다음 페이지의 표 8은 제안 모델의 학습을 거친 후 생성된 세 명의 피험자에 대한 가중치 표의 결과를 종합한 것이다. 1번에서 4번의 경우들은 세 명 모두에게서 기본적으로 C3C4와 F3F4의  $\alpha$  파 영역이 중요하게 작용하였고, 거기에서 피험자에 따라서 중요하게 작용하는 주파수 대역이 덧붙여졌다. 그리고 5번과 6번의 경우에서는 O1의  $\alpha$  파가 중요하게 작용하였고 피험자에 따라 O1의  $\beta$  파가 중요하게 작용하는 경우와 C3C4의  $\beta$  파가 중요하게 작용하는 경우로 약간씩 달랐다.

결론적으로 말해, 모든 피험자에 대해 그리고 모든 경우에 항상 중요하게 작용하는 특징은 없었다. 개개인마다 분명히 차이가 있었다. 하지만 한편으론 경향성도 관찰할 수 있었다. 표를 보면 알 수 있겠지만 가장 중요한 특징으로 작용하는 주파수 대역은 전극의 위치에 관계 없이  $\alpha$  파 대역이었다. 즉 C3C4의  $\alpha$  파, F3F4의  $\alpha$  파, O1의  $\alpha$  파가 가장 중요한 특징으로 작용하였다. 이처럼 3명의 피험자 모두에게  $\alpha$  파가 중요하게 작용 하는 경향이 있었다. 하지만 그럼에도 불구하고  $\alpha$  파만을 특징으로 이용하는 것 보다는 제안된 모델의 방법처럼 개인에게 적합한 특징을 추출하여 분석하는 것이 더 타당했고, 이것은 표 6의 결과가 말해주고 있다. 즉, 표 6에서 Pfurtscheller가 제안한대로  $\alpha$  파 대역만을 고려했을 경우의 분석 결과와 제안된 모델에 의한 분석 결과를 비교해 볼 때, 제안 모델의 분석 결과가 더 좋았다.

다시 표 8로 돌아와서  $\alpha$  파 이외에도 개인에 따라  $\beta$  파가 중요하게 작용하는 경우가 있었는데, 그렇다고 해서  $\beta$  파만을 고려하는 것도 분석율이 저조했다(표 6 참조).  $\alpha$  파와  $\beta$  파 두 가지를 동시에 고려하는 경우를 생각해 볼 수 있는데, 표 7의 결과를 참조하면 이것도 역

시 제안된 모델의 특징 추출에 의한 분석보다 분석율이 저조했다.

표 8 피험자 1, 2, 3의 가중치 표 종합

	피험자 1	피험자 2	피험자 3
1. 안정상태 / 움직임상태	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파 O1 - 빠른 $\beta$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파
2. 안정상태 / 암산상태	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파 O1 - 빠른 $\beta$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파
3. 안정상태 / 눈 뜬 상태	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파 O1 - $\alpha$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파 O1 - $\alpha$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파 O1 - $\alpha$ 파
4. 움직임상태 / 암산상태	C3C4 - $\alpha$ , $\beta$ 파 F3F4 - $\alpha$ , $\beta$ 파	F3F4 - $\alpha$ 파 C3C4 - $\alpha$ 파, 빠른 $\beta$ 파	C3C4 - $\alpha$ 파 F3F4 - $\alpha$ 파 O1 - $\alpha$ 파
5. 움직임상태 / 눈 뜬 상태	O1 - $\alpha$ 파 C3C4 - 빠른 $\beta$ 파 F3F4 - 빠른 $\beta$ 파	O1 - $\alpha$ 파, $\beta$ 파	O1 - $\alpha$ 파, $\beta$ 파
6. 암산상태 / 눈 뜬 상태	O1 - $\alpha$ 파 C3C4 - 빠른 $\beta$ 파 F3F4 - 빠른 $\beta$ 파	O1 - $\alpha$ 파, $\beta$ 파	O1 - $\alpha$ 파, $\beta$ 파

따라서 위의 결과를 종합하면 중요한 몇 개의 고정적인 특징만을 이용하는 것 보다는 개인에게 적합한 특징을 찾아서 분석하는 방법이 더 바람직하다는 결론을 얻을 수 있다.

### 5. 결론

본 논문에서는 각 개인의 특성을 반영하도록 주파수 특징을 추출하고, 사용하는 뇌파 패턴 구분 모델을 제안하였다. 본 모델을 사용함으로써 각 개인의 특성을 반영하여 더 높은 분석 성공률을 얻을 수 있었다. 제안된 방법은 기존의 연구자들이 사용했던 특징을 적용했을 경우와 전문가에 의해 추출된 특징을 적용했을 경우보다 그 분석 성공률이 우수했다. 또한 제안된 방법은 개인에 적응적인 특징을 이용할 뿐만 아니라 어떠한 특징들이 구분에 중요하게 작용하는지에 대한 가이드도 제공할 수 있었다. 분석 시간도 실시간 시스템에 응용될 수 있을 정도의 짧은 시간을 요한다. 따라서 제안된 방법을 이용하면 컴퓨터가 EEG를 이용하여 뇌의 신호를 자동으로 인식할 수 있는 가능성이 있다. 그러나, 이와 동시에 본 논문의 결과는 많은 한계를 가지고 있다. 우선 각

피험자에 대해 얻은 데이터들이 하루동안에 측정된 데이터들이다. 그렇기 때문에 여러 날에 걸쳐 얻은 데이터들에 대한 추가적인 검증이 필요하다. 또한 시스템에 적용시키기 위해서는 시스템을 이용하고자 하는 사람마다 학습 데이터를 얻어야 한다. 현재 이용하고 있는 개인별 학습 데이터의 개수는 총 160개이다. 따라서 실제 시스템에 응용 시키기 위해서는 학습 데이터의 개수를 줄이는 문제도 해결 되어야 한다.

### 참고 문헌

- [1] Charles W. Anderson and Saikumar V. Devulapalli, "Determining mental state from EEG signals using parallel implementations of neural networks," <http://www.cs.colostate.edu/~anderson>
- [2] Charles W. Anderson, Erik A. Stolz, and Sanyogita Shamsunder, "Discriminating mental tasks using EEG represented by AR models," <http://www.cs.colostate.edu/~anderson>
- [3] Dennis J. McFarland, Gregory W. Neat, Richard F. Read, and Jonathan R. Wolpaw, "An EEG-based method for graded cursor control," *Psychobiology*, vol. 21, no. 1, pp. 77-81, 1993.
- [4] Grant R. McMillan, and Gloria L. Calhoun, "Direct Brain Interface utilizing self-regulation of steady-state visual Evoked Response," <http://www.cdd.sc.edu>
- [5] G. Pfurtscheller and Chistina Neuper, "Simultaneous EEG 10Hz desynchronization and 40Hz synchronization during finger movements," *Neuro Report*, vol. 3, pp. 1057-1060, 1992.
- [6] G. Pfurtscheller, D. Flotzinger, and Joachim Kalcher, "Brain-Computer Inteface-a new communication device for handicapped persons," *Journal of Microcomputer Applications*, vol. 16, pp. 293-299, 1993.
- [7] G. Pfurtscheller and C. Neuper, "Event-related synchronization of mu rhythm in the EEG over the cortical hand area in man," *Neuroscience Letters*, vol. 174, pp. 93-96, 1994.
- [8] G. Pfurtscheller, M. Pregenzer, and C. Neuper, "Visualization of sensorimotor areas involved in preparation for hand movement based on classification of mu and central beta rhythms in single EEG trials in man," *Neuroscience Letters*, vol. 181, pp. 43-46, 1994.
- [9] Jonathan R. Wolpaw, Dennis J. McFarland, Gregory W. Neat, and Catherine A. Forneris, "An EEG-based brain-computer interface for cursor control," *Electroencephalo Graphy and Clinical Neurophysiology*, vol. 78, pp. 252-259, 1991.
- [10] J. Kalcher, Doris Flotzinger, Ch. Neuper, S. Golly,



and G. Pfurtscheller, "Graz brain-computer interface 2: towards communication between humans and computers based on online classification of three different EEG patterns," *Medical and Biological Engineering and Computing*, vol. 34, pp. 382-388, 1996.

- [11] M. Pregenzer, G. Pfurtscheller, and D. Flotzinger, "Selection of electrode positions for an EEG-based Brain Computer Interface," *Biomedizinische Technik*, Band 39, Heft 10, pp. 264-269, 1994.
- [12] Zarchy A. Keirn and Jorge I. Aunon, "Man-Machine Communications Through Brain-Wave Processing," *IEEE Engineering in Medicine and Biology Magazine*, pp. 55-57, 1990.
- [13] K. M. Lee, D. H. Kwak, and K. H. Lee, "Fuzzy Inference Neural Network for Fuzzy Model Tuning," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 26, no. 4, pp. 637-645, 1996.
- [14] K. H. Lee, K. A. Seong, and K. M. Lee, "Hierarchical Partition of Nonstructured Concurrent Systems," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 27, no. 1, pp. 105-108, 1997.
- [15] K. M. Lee, D. H. Kwak, and K. H. Lee, "Tuning of Fuzzy Models by Fuzzy Neural Networks," *Fuzzy Sets and Systems*, vol. 76, pp. 47-61, 1995.



황민철

1990년 Georgia Institute of Technology 석사. 1994년 Georgia Institute of Technology 박사. 1994년 ~ 1998년 표준과학연구소 인간공학연구실. 1998년 ~ 현재 상명대학교 정보통신학부 교수. 관심분야는 BCI, HCI



김도연

1996년 한국과학기술원 전산학 학사.  
1998년 한국과학기술원 전산학 석사.  
1998년 ~ 현재 DACOM 종합연구소.  
관심분야는 BCI, Network Mangement



이광형

1978년 서울공대 산업공학학사. 1980년 한국과학원 산업공학 석사. 1982년 프랑스 INSA 전산학과 석사(DEA). 1985년 프랑스 INSA 전산학과 공학박사. 1988년 1월 프랑스 국가박사(전산학 INSA-LYON대). 1985년 ~ 1995년 한국과학기술원 전산학과 조교수 및 부교수. 1995년 ~ 현재 한국과학기술원 전산학과 교수. 1985년 프랑스 INSA. 1995년 미국 Stranford Research Institute. 관심분야는 퍼지 이론 및 응용, 인공지능, 전문가 시스템 등