

브레인 컴퓨터 인터페이스를 위한 기계 학습

포항공과대학교 | 이해경* · 최승진**

1. 서론

데이비드 크로넨버그의 영화 '엑시스턴즈'에서는 인간의 신경계와 직접 연결하여 가상현실을 체험하게 하는 생체 컴퓨터 게임 '엑시스턴즈'가 등장한다. 베르나르 베르베르의 소설 '뇌'에서는 자동차 사고로 모든 신경이 마비되어 눈만 깜빡일 수 있는 주인공이 뇌와 직접 연결된 컴퓨터 '아테나'를 통해 네트워크상에서 원하는 정보를 찾으며 지적 욕구를 만족하고, 이를 통해 새로운 정신세계를 경험한다. 여기에서 한발 더 앞서 워쇼스키 형제의 유명한 영화 '매트릭스'에서는 아예 인간의 육체적인 삶을 무시하고 신경의 연결을 통한 의식적인 삶을 가능케 하는 가상 현실 공간 '매트릭스'가 등장한다. 1968년에 만들어진 스탠리 큐브릭 감독의 영화 '2001년 스페이스 오딧세이'에서 인간의 지능을 뛰어넘는 인공지능 로봇 '할'이 그저 시청각을 통해 인간을 감시하고 통제하려했다면, 이제 인간의 상상력은 인간의 뇌에 직접 접속하여 인간의 의식 자체를 감시하고 통제하려는 시도에까지 이르렀다. 인간의 의식이 뇌신경의 전기적, 화학적 작용으로부터 발생한다는 가설로부터 시작된 인간의 상상력은 비단 영화나 소설이 그려내는 허구로써 끝나는 것이 아니라 '브레인 컴퓨터 인터페이스 (brain computer interface, 이하 BCI)'라는 새로운 과학 기술 분야를 창출하고 이를 실용화하려는 시도에 이르러있다.

본고에서는 BCI가 무엇이고, 왜 BCI 시스템을 구축하는데 있어 또다른 SF적 상상력이 가미된 학문인 기계 학습 이론이 필요하며, 지금까지 필자가 속한 연구 그룹에서 수행해온 연구 방법을 토대로 기계 학습이 어떻게 BCI 시스템에 적용될 수 있는지에 대해 설명하도록 하겠다.

* 학생회원

** 정회원

2. 브레인 컴퓨터 인터페이스

BCI는 뇌와 컴퓨터의 직접 연결을 시도하는 인터페이스로써 뇌를 구성하는 뉴런 연합체에 의해 형성된 인간의 의지 내지는 생각을 컴퓨터가 인식할 수 있는 디지털 신호로 바꾸는 새로운 휴먼 컴퓨터 인터페이스(human computer interface) 중 하나이다. 신체를 통해 이루어지는 물리적 세계와의 소통만큼이나 네트워크상에서 이루어지는 디지털 세계와의 소통이 나날이 중요해지고 있는 가운데 더 평등하고, 더 편리하고, 더 자유롭게 컴퓨터를 사용하고자 소비자의 욕구가 강해지고 있다. BCI는 이런 요구에 부합하여 의사 표현에 있어 마우스나 키보드, 혹은 카메라나 음성 등의 입력 장치를 사용해야 하는 한계에서 벗어나 사지가 마비된 장애인에서부터 게임을 즐기려는 아이까지 오직 생각만으로 의료보조기구나 각종 전자기기, 컴퓨터 등을 제어하고자 하는 것을 목표로 한다[1-3].

뇌신경의 신호 전달 과정이 전기적, 화학적 특성을 지닌다는 사실에 착안하여 뇌의 활동을 측정하는 많은 기술들이 개발되어 왔다. PET, fMRI, MEG, EEG 등을 포괄하는 brain functional imaging 기술 중 BCI에서 가장 주목하고 있는 것이 바로 뇌파(electroencephalogram, EEG)이다. 뇌파는 뉴런들이 협동하는 과정에서 동기화된 전기적 신호가 두개골을 거쳐 두피까지 전달되었을 때 관찰되는 신호로 여러 개의 전극을 통해 측정된다(그림 1). 이 때 전극의 위치는 그 위치




그림 1 본 연구실에서 사용하고 있는 뇌파 측정 장비인 BIO-SEMI사의 ActiveTwo system. 32개의 채널을 지원한다.

3. 기계 학습

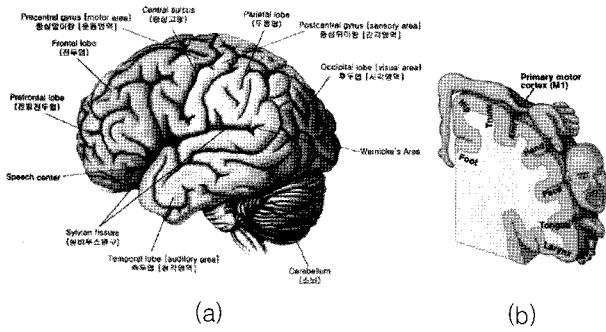


그림 2 뇌의 위치에 따른 명칭과 기능. (a) 좌측에서 바라본 뇌의 모습, (b) motor area 부분만을 떼어낸 것이다. 이와 같이 뇌의 활동은 그 위치에 따라 분업화되어 있다.

에 따라 세분화된 뇌의 기능(그림 2)과 관계가 있기 때문에 뇌파의 spatial property를, 각 전극으로부터 측정된 시계열 신호의 주파수 성분은 뉴런의 협동 양상을 반영하기 때문에 뇌파의 spectral property를 결정하는 중요한 요소가 된다.

뇌파는 흔히 야외 종합 경기장의 환호성과 비교되곤 한다. 경기장 바깥에서 비록 관중 개개인의 소리를 구별할 수는 없지만 동시에 울려 퍼지는 환호성에 골의 득실 내지는 경기 양상을 추측할 수 있는 것과 같이 뇌파 역시 뇌의 바깥에서 측정되는 신호로 뉴런 하나 하나의 동작 기저는 알 수 없지만 특정 자극(stimuli)으로 동시에 반응하는 뉴런들의 커다란 신호로 뇌의 활동 내역을 어느 정도 추측할 수 있게 한다.

BCI에서 널리 쓰이고 있는 자극은 움직임과 관련된 것이다. 움직임이나 움직임을 상상할 경우 뇌파에 나타나는 대표적인 현상으로 event-related desynchronization(ERD)과 event-related synchronization (ERS)이 있다. ERD는 움직임이 있거나 움직임을 준비, 상상할 경우 뮤파(mu rhythm, 8-12Hz)가 감쇠하는 현상이고, ERS는 움직인 후나 안정을 취할 때 뮤파가 커지는 현상을 말하는데 이는 운동 피질 영역 내에서도 움직인 신체 부위에 따라 다른 곳에서 관찰된다(그림 2(b) 참고)[4].

이제 뇌파를 이용하여 간단한 BCI 시스템을 구축하는 것은 어렵지 않아 보인다. 뇌파의 spatial property(위치에 따라 달라지는 운동 피질 영역의 기능)와 spectral property(ERS/ERD 현상)를 이용하면, 오른손, 왼손, 발, 혀의 움직임을 상상한 데이터를 분류할 수 있을 것이고, 이를 상, 하, 좌, 우로 매핑하면 네 방향으로 마우스를 움직이는 정도의 간단한 BCI 시스템을 구축할 수 있으리라 추측할 것이다. 그러나 그것이 어렵기 때문에 기계 학습 이론이 필요한 것이다. 우선 기계 학습과 기본적인 모델인 linear data model에 대해 살펴본 후 이 이유에 대해 설명하도록 하겠다.

기계 학습(machine learning)은 인공지능의 한 분야로 데이터를 통해 컴퓨터가 스스로 학습하는 알고리즘을 연구하는 학문이다. 우리가 실험을 통해 얻은 데이터를 일일이 눈으로 확인하며 숨겨진 패턴들을 찾았다면, 기계 학습에서는 컴퓨터 스스로 주어진 데이터(training data)의 숨겨진 성질을 찾아 새로운 데이터(test data)가 입력되었을 때 일련의 작업을 수행하는 알고리즘을 연구하고 있다. 인공지능의 궁극적인 목적이 뇌의 생물학적 특성 혹은 논리적인 인지 과정을 수학적으로 모델링하는 것이라면, 기계 학습에서 더욱 주목하는 것은 인간이 세계를 통해 접하는 데이터들의 숨겨진 특성이다. 어떻게 하면 컴퓨터가 인간처럼 숨겨진 특성을 쉽게 인식하고 학습할 수 있을 것인가. 기계 학습은 바로 수학, 특히 확률과 통계 이론을 바탕으로 그 해결책에 접근하려 한다.

가장 기본적인 수학적 모델로 linear data model이 있고, 이를 식으로 표현하면 다음과 같다.

$$X = AS \tag{1}$$

여기서 m 차원을 가진 observed data $\{x_j\}$ 가 l 개 존재할 때 이를 열벡터로 하여 data matrix $X = [x_1 \cdots x_l] \in R^{m \times l}$ 를 구성할 수 있다. 이 때, observed data는 열벡터를 basis vector로 갖는 행렬 $A \in R^{m \times n}$ 의 선형 조합이고(그림 3), $S \in R^{n \times l}$ 는 encoding matrix로써 basis vector들로 구성된 공간에서의 hidden source라고 생각할 수 있다. S 는 A 의 pseudo-inverse A^+ 를 이용하여 다음과 같이 구할 수 있다.

$$S = A^+ X = WX \tag{2}$$

따라서 linear data model에서의 문제는 data matrix X 로부터 어떻게 basis matrix A 를 구할 것인가로 압축되고, 이를 위한 알고리즘으로는 principal component analysis(PCA), independent component analysis(ICA), common spatial pattern(CSP), nonnegative matrix factorization(NMF) 등이 있다.

$$X = \begin{bmatrix} | & & | \\ A_{:,1} & & A_{:,n} \\ | & & | \end{bmatrix} S_{1,:} + \dots + \begin{bmatrix} | & & | \\ A_{:,1} & & A_{:,n} \\ | & & | \end{bmatrix} S_{n,:}$$

그림 3 linear model에서 data matrix X 는 basis matrix A 의 열벡터 $A_{:,i} (i = 1, \dots, n)$ 의 선형 조합으로 이루어진다. 이 때, coefficient는 S 의 행벡터 $S_{i,:}$ 이다.

3. 뇌파 인식에 왜 기계 학습이 필요한가

안타깝게도 아직까지 일상생활 중 측정된 임의의 뇌파를 이용하여 뇌의 활동 내역을 추론하는 것은 불가능하다. 두개골과 두피를 거치면서 뇌파 신호끼리 서로 간섭을 일으키기도 하고, 눈깜박임이나 눈동자 혹은 머리의 움직임, 미세한 근육의 떨림 등에 민감하게 노출되기 때문이다. 그리고 사람은 보고, 듣고, 음식을 먹고, 말하는 것 등을 동시에 하는데 이 중 특정한 생각의 특정한 패턴을 뽑아내는 것은 여간해서 불가능하다. 따라서 뇌파 측정은 조용한 환경에서 피험자의 움직임을 제한하고, 정형화된 자극을 반복해서 보여주는 가운데 이루어진다.

그림 4의 (a)는 왼손의 움직임을 상상하였을 때 측정된 뇌파이다. 영상이나 음성 데이터가 눈과 귀를 통해 패턴을 찾아내기 비교적 쉬운데 반해 뇌파는 언뜻 잡음처럼 보인다. (b)는 신호의 시간에 따른 파워 스펙트럼의 변화를 색깔로 표현한 것이다. 이를 통해 왼손의 움직임에 대해 C3 채널이 C4 채널보다 큰 뮤파가 발생함을 확인할 수 있다(빨간색 부분). 그러나 연속적으로 움직임을 상상하고 있는 데이터 임에도 불구하고 눈에 띄는 뮤파가 연속적으로 발생하지 않음을 확인할 수 있다. 따라서 단순히 채널별로 뮤파를 비교하여 분류하는 알고리즘에는 한계가 있음을 알 수 있다. 또 다른 중요한 문제점 중 하나는 사람에 따라 움직임으로 활성화되는 뇌의 위치와 주파수 영역이 조금씩 다르다는 것이다(실제로 뮤파가 8-12 Hz가 아닌 16-20 Hz 사이에서 발생하는 사람도 있다[5]). 따라서 **주어진 뇌파 데이터에서 보이지 않더라도 일관적으로 등장하고 있을 숨겨진 패턴을 피험자에 관계없이 자동적으로 찾아주는 알고리즘이 필요하며, 이러한 역할을 해주는 것이 바로 기계 학습이다. 이를 이용할 경우 움직임뿐만 아니라 언어 형성, 감정과 같이 그 성질이 확실하게 규명되지 않은 다른 인지 과정에도 동일한 알고리즘을 적용할 수 있다.**




그림 4 왼손의 움직임을 상상하였을 때 2.25초 동안 (a) 측정된 뇌파와 (b) 그의 파워 스펙트럼. x축은 시간, y축은 (a) 신호의 세기, (b) frequency를 의미한다. (b)에서 파워 스펙트럼의 세기는 색깔로 표현되며, 커질수록 파란색에서 노란색, 붉은색으로 변화한다. 그림에서 위쪽은 뇌 좌반구에 위치한 C3 채널, 아래쪽은 우반구에 위치한 C4 채널로부터 측정되었다.

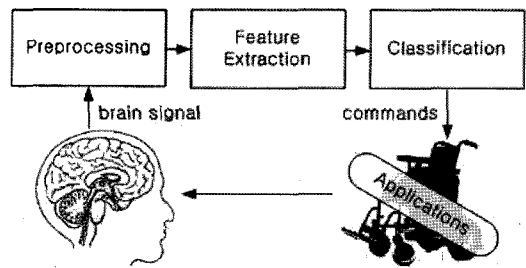


그림 5 기계 학습에 기반한 BCI 시스템 전체 구조

4. 기계 학습 기반의 BCI 시스템

기계 학습에 기반한 뇌파 인식 알고리즘은 크게 다음 세 과정을 거친다(그림 5).

- 전처리(preprocessing) : 필요한 주파수 성분을 추출하기 위해 밴드 패스 필터링을 하거나 뇌파에 섞인 잡음을 제거한다.
- 특징 추출(feature extraction) : 뇌파로부터 분류에 유효한 특징만을 찾아 추출한다.
- 분류(classification) : 추출된 특징이 속할 가능성이 가장 높은 클래스를 찾아낸다.

이 때 전체 알고리즘의 성능에 가장 큰 영향을 끼치는 것이 바로 특징 추출 과정이다. 지면상 본고에서는 위에서 언급한 linear data model을 이용한 특징 추출 과정에 대해 주로 설명할 것이며, 뇌파의 공간, 시간, 주파수 특징 중 어떤 것을 이용할 것인가에 따라 식 (1)에서 언급한 basis matrix A 를 구하는 알고리즘과 data matrix X 의 구성이 달라진다.

1) Temporal property를 이용한 경우[6,7]

뇌파는 보통 0.5초간 stationary하다고 알려져 있으므로 시계열 뇌파 데이터를 0.5초씩 잘라내고 그림 6과 같이 data matrix X 를 구한다. 따라서 X 의 열의 차원은 $0.5\text{sec} \times \text{sampling frequency}$ 이고, 행은 시간에 따라 변화하는 segment를 의미한다. X 의 열벡터를 구성하는 주요한 패턴을 구하기 위해 PCA를 사용하




그림 6 data segmentation

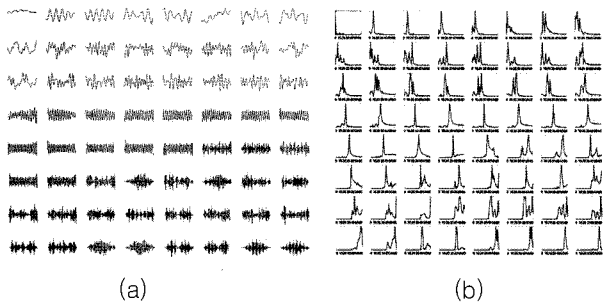


그림 7 PCA를 이용하여 구한 (a) temporal component와 (b) 그것의 power spectrum. 상단 왼쪽으로 갈수록 eigenvalue가 큰 (variance가 큰) component이다. 보통 뇌파의 정보는 30 Hz 이하에서 많이 발견되는데 eigenvalue가 클수록 30 Hz 이하의 낮은 주파수 특성을 갖는 것을 확인할 수 있다. 잡음은 보통 eigenvalue가 작은 성분에 영향을 주므로 PCA에서는 상위 몇 개의 성분만 추출함으로써 잡음 제거로 사용할 수도 있다. 오른쪽의 power spectrum의 관찰을 통해 각 basis가 특정 주파수 성분을 추출하는 필터 역할을 함을 알 수 있다.

였다. 이는 variance를 최대화하는 방향에 정보량이 많을 것이라 가정하고 주성분, 즉, basis vector를 찾는 방법이다. 이 때 구한 basis vector는 식 (1)에서 A 의 열벡터이고 그림 7과 같다.

2) Spatial property를 이용한 경우

X 의 열의 차원을 채널의 개수로 하고, 각 행은 시계열 데이터로 하여 다음 알고리즘에 적용한다.

1) ICA[8]

ICA는 채널의 개수와 같은 차원을 갖는 observed




그림 8 ICA를 이용한 잡음 제거 알고리즘. EOG 채널은 눈의 움직임을 측정하는 채널로 임펄스처럼 보이는 신호가 바로 눈깜박임으로 인한 것이다. observed data X 에서 눈과 가까운 Fp1, Fp2, F3, F4 채널들이 눈 깜박임의 영향을 받고 있다는 것을 확인할 수 있다. 이를 제거하기 위해 ICA를 이용하여 independent source S 를 구하면, 첫 번째와 여섯 번째 행에 눈깜박임으로 인한 잡음이 분리된 것을 관찰할 수 있다. 이를 zero vector로 대체해 제거하고(S_{new}), 다시 mixing matrix A 를 곱해주면, 잡음만 제거된 observed data X_{new} 를 구할 수 있다.

data $\{x_i\}$ 가 원래 독립인 소스들의 선형 조합이라는 가정으로부터 시작한다. 따라서 식 (1)에서 행렬 A 가 mixing matrix, S 가 independent source가 된다. 이 방법은 두피에서 측정된 뇌파가 뇌의 각 영역에서 발생한 독립적인 신호들과 눈깜박임으로 인해 발생한 잡음들의 선형 조합이라는 가정과 잘 부합하기 때문에 뇌파의 잡음 제거에 널리 사용된다. 구체적인 알고리즘은 그림 8과 같다.

2) CSP[9]

오른손을 움직일 경우 뇌의 왼쪽에 위치한 C3 채널에서, 왼손을 움직일 경우 오른쪽에 위치한 C4 채널에서 ERD 현상이 발생한다. CSP에서는 두 개의 클래스의 채널별 차이를 극대화하는 spatial pattern을 구한다. 각 클래스에 속한 observed data를 $\{x_i^1\}$ 와 $\{x_i^2\}$ 라고 할 때 covariance matrix를 각각 R_{x_1} 와 R_{x_2} , 두 covariance matrix의 합을 $R_x = R_{x_1} + R_{x_2}$ 라고 한다. 그리고 R_{x_1} 과 R_{x_2} 를 동시에 diagonalization하는 spatial pattern W 를 구한다.

$$\begin{aligned} WR_x W^T &= \mathbf{I} \\ WR_{x_1} W^T &= \mathbf{D} \\ WR_{x_2} W^T &= \mathbf{I} - \mathbf{D} \end{aligned} \begin{array}{l} \rightarrow \text{simultaneous} \\ \text{diagonalization} \\ \rightarrow \text{inverse} \\ \text{proportion} \end{array}$$

PCA가 클래스 정보가 없는 데이터의 variance를 최대화하는 component를 구했다면, CSP에서는 하나의 클래스에 속한 데이터의 variance는 최대화하고, 다른 클래스에 속한 데이터의 variance는 최소화하는 성분을 구한다. 그림 9는 CSP를 통해 구한 spatial 패턴을 그 크기에 따라 뇌의 단면에 매핑한 것이다.

3) Spectral property를 이용한 경우[12]

spectral property를 이용하기 위해 시계열 데이터로 측정된 observed data를 short-time Fourier transform이나 wavelet transform를 이용하여 전처리 과정




그림 9 CSP를 이용하여 구한 spatial pattern.을 뇌의 단면에 매핑한 모습. 값이 커질수록 진한 색을 띤다. 왼쪽 그림부터 왼손과 오른손의 움직임을 상상할 때 해당 클래스의 variance는 최대화하고, 다른 클래스의 variance는 최소화한 component를 보여주고 있다. 이는 생물학적 사실과 동일한 결과이다.

에서 그림 4의 (b)와 같은 time-frequency representation으로 바뀌어야 하며, 이것이 바로 식 (1)에서의 data matrix X 가 된다. 이 때, spectral component인 X 는 nonnegative 성질을 갖기 때문에 식 (1)의 각 matrix X , A , S 에 nonnegative constraint를 추가해야 한다. 이를 만족하는 A 와 S 를 구하는 알고리즘으로 가장 널리 사용되는 것이 바로 NMF이다[10,11]. NMF는 nonnegative 성질을 유지하기 위해 multiplicative update rule을 사용하는데 이로 인해 더 sparse basis component를 구할 수 있다. 그림 10은 NMF를 이용하여 구한 basis matrix A 를 plot한 것이다. 이 때 흥미로운 것은 basis의 개수가 늘어갈 때마다 움직임의 상향할 경우 나타나는 뇌파의 특징이 중요도순으로 등장한다는 것이다. 2개일 때는 8-12Hz 부근의 뮤파가, 4개일 때는 18-22Hz의 베타파가, 6개일 때는 12-16Hz의 sensori-motor rhythm가 C3, C4 채널에 차례로 등장하고 있다. 기존의 방법들이 여러 번의 시뮬레이션을 거쳐 그 성능에 따라 주요한 주파수 영역을 선택해야 했다면, 이와 같이 NMF는 자동적으로 주요한 성분들을 추출해낼 수 있다.




그림 10 NMF를 이용하여 구한 basis. 파란색에서 붉은색이 될수록 큰값을 의미하며, y축의 상단은 C3 채널의, 하단은 C4 채널의 4-30Hz 사이의 frequency를 1Hz의 resolution으로 보여주고 있다. x축은 basis의 개수이고, 왼쪽부터 차례로 2, 4, 5, 6개의 basis를 추출할 때의 결과를 보여주고 있다.




그림 11 linear discriminant function. 두 개의 클래스 c_1 , c_2 가 있을 때 각 클래스에 속한 데이터가 가우시안 분포를 따른다고 가정하고, 두 클래스를 가장 잘 구분하는 decision boundary w 를 구한다. 이 때 discriminant function은 $g(x) = \ln p(c_1|x) - \ln p(c_2|x) = wx + w_0$ 이고, $g(x) > 0$ 이면 클래스 c_1 , $g(x) < 0$ 이면 클래스 c_2 로 결정한다.




그림 12 HMM과 Viterbi algorithm의 Graphical model. 관찰 가능한 시계열 데이터 $\{x_i\}$ 가 있을 때 이에 영향을 주는 discrete hidden state $\{s_i\}$ 가 있다고 가정한다. 이 때 이 state s_i 는 전단계인 state s_{i-1} 의 영향을 받아 x_i 의 hidden dynamicity를 결정하는 중요한 요소가 된다. 이를 이용하여 분류를 하는 방법에는 크게 두 가지가 있다. (1) hidden state $s_i \in \{c_1, \dots, c_K\}$ (c_k 는 클래스 라벨, K 는 총 클래스의 개수)라고 가정하고, Viterbi algorithm을 이용하여 x_i 에 가장 근사한 클래스 s_i 를 추론해내는 방법과 (2) 각 클래스의 hidden dynamicity에 최적화된 HMM_1, \dots, HMM_K 를 구하고, x_i 에 가장 근사한 hidden dynamicity를 갖는 HMM을 찾는 방법이다. 시계열 데이터의 길이 T 가 정해져있을 때는 (2)의 방법이, 그렇지 않을 때는 (1)의 방법이 유용하게 사용된다.

이상 linear data model을 이용한 특징 추출 방법에 대해 설명하였다. linear data model은 기계 학습에서도 가장 간단한 선형 모델에 속하지만 빠르고 우수한 성능으로 실시간 처리가 필요한 뇌파 분석에 유용하게 사용되고 있다[6-9,12].

특징 추출 후에는 classifier를 이용하여 데이터가 속한 클래스로 분류하는 과정을 거치는데 유효한 특징을 잘 추출했을 경우 linear discriminant function 정도의 간단한 classifier(그림 11 참고)만 사용해도 어느 정도의 성능을 보장할 수 있다[13]. 성능을 더 개선하고 싶다면, 뇌파의 time dependency를 고려한 Viterbi algorithm이나 hidden Markov model(HMM)(그림 12 참고)를 사용한다[14].

5. 결론

지난 2001년부터 2년에 한번씩 열리는 BCI competition의 분석에 따르면, 매 competition마다 참여 연구 그룹이 10에서 57, 92 그룹으로 9배 가까이 늘어나고 있다고 한다. 이미 생물학이나 의학 분야의 BCI에 대한 관심은 지대하여 원숭이의 뇌신경에 전극을 삽입하여 로봇팔을 원격으로 조종한다거나(매사추세츠 공대), 척추분리증 환자의 뇌신경에 전극을 삽입하여 마비된 팔에 부착된 로봇팔을 움직이게 한다는(TU-Graz, 오스트리아) 등의 연구 결과가 나오고 있다. 이와 같은 invasive methods는 해당 작업을 수행하는 단일 뇌 신경 세포에 직접 미세전극을 삽입하여 바로 깨끗한


신호를 추출할 수 있으므로 별다른 분석 없이 로봇이나 컴퓨터 등의 제어 신호로 변환할 수 있다. 하지만 사람의 뇌에 직접 전극을 삽입하는 것은 대단히 큰 위험이 동반되기 때문에 의료 목적 등의 불가피한 경우를 제외하고는 수행하기 어렵다는 단점이 있다. 따라서 우리는 뇌의 바깥에서 잡음에 노출된 채로 측정된 뇌파를 분석해야 하는 난관에 부딪치게 된다.

음성이나 영상 인식에서 자연 언어 처리, 바이오인포매틱스, 금융 공학, 유비쿼터스 컴퓨팅, information retrieval 등 다양한 분야에서 이미 데이터 분석의 돌파구를 기계 학습에서 찾고 있다. 이는 Microsoft, Intel, Google, YAHOO, IBM, SIEMENS, NOKIA 등 유수의 다국적 기업들이 기계 학습으로 유명한 학회인 ICML, NIPS의 스폰서로 나서는 것과 무관하지 않다. BCI 역시 기계 학습에서 그 돌파구를 찾고 있으며, 이에 기계 학습은 기존의 여러 번 반복된 실험을 거쳐 측정된 데이터를 averaging하여 눈으로 패턴을 찾던 한계에서 벗어나 자동적으로 뇌파의 숨겨진 패턴을 찾아 주는 효과적인 알고리즘을 제공해주고 있다.

현재 BCI를 위한 뇌파 측정은 그 성질이 잘 알려진 손과 발 내지는 혀의 움직임을 상상하는 정도로 한정되어 있다. 하지만 점차 언어 형성이나 감정, 복잡한 인지 과정으로 확대되고 있는 추세이며, 그 성질이 확실하게 규명되지 않은 뇌파 데이터의 분석에 있어 기계 학습의 역할이 더욱 두각을 드러낼 것으로 전망된다.

참고문헌

- [1] Ebrahimi, T., Vesin, J.F., Garcia, G., Brain computer interface in multimedia communication. *IEEE Signal Processing Magazine*, 20(1): 14-24, Jan. 2003.
- [2] Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., Vaughan, T. M., Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 113:767-791, 2002.
- [3] Blankertz, B., Muller, K. R., Curio, G., Vaughan, T. M., Schalk, G., Wolpaw, J. R., Scholgl, A., Neuper, C., Pfurtscheller, G., Hinterberger, T., Schroder, M., Birbaumer, N., The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials. *IEEE Trans. Biomedical Engineering* 51, 2004.
- [4] Pfurtscheller, G., Lopes da Silva, F. H., Event related EEG/MEG synchronization and desynchronization: Basic principles. *Clinical Neurophysiology*, 110(11): 1842-1857, 1999.
- [5] Lal, T.N., Schroder, M., Hinterberger, T., Weston, J., Bogdan, M., N. Birbaumer, Scholkopf, B., Support vector channel selection in BCI. Technical Report 120, Max Planck Institute for Biological Cybernetics, 2003.
- [6] Lee, H., Choi, S., PCA-based linear dynamical systems for multichannel EEG classification. In Proc. Int'l Conf. Neural Information Processing, 745-749, Singapore, 2002.
- [7] Lee, H., Choi, S., PCA+HMM+SVM for EEG pattern classification. In Proc. Int'l Symp. Signal Processing and Its Applications, 541-544, Paris, France, 2003.
- [8] Jung, T.P., Humphries, C., Lee, T.W., Makeig, S., McKeown, M.J., Iragui, V., Sejnowski, T.J., Extended ICA Removes Artifacts from Electroencephalographic Recordings. *Advances in Neural Information Processing Systems* 10:894-900, 1998.
- [9] Ramoser, H., Muller-Gerking, J., Pfurtscheller, G., Optimal spatial filtering of single trial EEG during imagined hand movement. *IEEE Trans. Rehabilitation Engineering*, 8:441-446, 2000.
- [10] Lee, D.D., Seung, H.S., Learning the parts of objects by non-negative matrix factorization. *Nature*, 401: 788-791, 1999.
- [11] Lee, D.D., Seung, H.S., Algorithms for nonnegative matrix factorization. In *Advances in Neural Information Processing Systems*, 13, MIT Press, 2001.
- [12] Lee, H., Cichocki, A., Choi, S., Nonnegative matrix factorization for motor imagery EEG classification. In Proc. Int'l Conf. Artificial Neural Networks, Athens, Greece, 2006. Springer.
- [13] Duda, R.O., Hart, P.E., Stork, D.G., *Pattern Classification*. 2nd Edition, Wiley, 2001.
- [14] Rabiner, L.R., Juang, B.H., An introduction to hidden Markov models. *IEEE Trans. Acoustics, Speech, and Signal Processing Magazine*, 3:4-16, 1986.



이혜경

2003~현재 포항공과대학교 박사과정
 2003 포항공과대학교 컴퓨터공학과 석사
 2000 한양대학교 전자공학부 학사
 관심분야 : 기계학습, BCI
 E-mail : leehk@postech.ac.kr



최승진

2001~현재 포항공과대학교 컴퓨터공학과 교수
 1997~2001 충북대학교 전자공학과 교수
 1997 일본 RIKEN Frontier Researcher
 1996 University of Notre Dame 전자공학과 방문조교수
 1996 University of Notre Dame 전자공학과 박사
 1989 서울대학교 전기공학과 석사
 1987 서울대학교 전기공학과 학사
 관심분야 : 통계적 기계학습, 확률 그래프 모델
 E-mail : seungjin@postech.ac.kr

프로그래밍언어연구회 춘계학술발표회

- 일 자 : 2007년 4월 28일
- 장 소 : 숙명여자대학교
- 내 용 : 학술발표 등
- 주 최 : 프로그래밍언어 연구회
- 상세안내 : <http://www.sigpl.or.kr>