

서포트 벡터 머신 기반 손동작 뇌전도 구분에 대한 연구

SVM-Based EEG Signal for Hand Gesture Classification

홍석민 · 민창기 · 오하령 · 성영락 · 박준석

Seok-min Hong · Chang-gi Min · Ha-Ryoung Oh · Yeong-Rak Seong · Jun-Seok Park

요약

뇌전도는 뇌 활동 시 발생하는 뇌 세포 간 상호작용으로 생성된 전기적 활동이며, 손동작 시 뇌 활동으로 인해 뇌전도가 발생한다. 본 연구에서는 16채널 뇌전도 측정 장비를 이용하여 손동작 전과 좌 혹은 우 손동작 시 발생하는 뇌전도를 측정하였으며, 측정된 데이터는 지도 학습 모델인 서포트 벡터 머신으로 분류하며, 서포트 벡터 머신의 학습 시간을 단축 위해 동작관련 정보 손실을 최소화하고, 뇌전도 정보를 축약할 수 있는 필터링을 통한 특징 추출과 벡터 차원 축소 기법을 제안한다. 분류 결과, 전두엽 부위의 전극에서 손동작 전 상태-손동작사이에서 평균 72.7 %의 정확도로 분류되었다.

Abstract

An electroencephalogram (EEG) evaluates the electrical activity generated by brain cell interactions that occur during brain activity, and an EEG can evaluate the brain activity caused by hand movement. In this study, a 16-channel EEG was used to measure the EEG generated before and after hand movement. The measured data can be classified as a supervised learning model, a support vector machine (SVM). To shorten the learning time of the SVM, a feature extraction and vector dimension reduction by filtering is proposed that minimizes motion-related information loss and compresses EEG information. The classification results showed an average of 72.7% accuracy between the sitting position and the hand movement at the electrodes of the frontal lobe.

Key words: EEG, SVM, STFT, Hand Gesture, Kernel Function

I. 서론

최근 인공지능 스피커, 동작인식이 가능한 제품들이 출시하면서 비접촉 동작 제어 방식에 대한 다양한 연구가 진행되고 있다^[1]. 하지만 이러한 비접촉 제어방식은 언어나 신체동작 감지를 위해 명령을 센서가 감지해야만 한다. 이러한 한계를 극복하고 접근성을 높일 수 있는 방식으로 기존 음성, 동작 등의 생체신호 대신 뇌전도(electroencephalogram: EEG)를 이용한 기술이 주목 받고 있다. 뇌전

도는 동작, 상상, 외부 자극 등에 따라 발생하며 이러한 특징의 뇌전도 이용하여 동작 구분을 위해 데이터 마이닝, 패턴인식 분야 등에서 사용되는 기법인 서포트 벡터 머신(support vector machine: SVM) 알고리즘을 이용한 분류 기법의 연구가 진행되고 있다^[2].

본 연구에서는 손동작 시 발생하는 뇌전도를 측정하여 손동작을 하지 않는 상태의 뇌전도와 구분하기 위해 측정된 데이터를 서포트 벡터 머신으로 학습시켜 분류한다. 학습 전 분류 시간을 단축하고 효율을 높이기 위해 측정된

국민대학교 보안-스마트전자자동차학과 (Department of Secured Smart Electric Vehicle, Kookmin University)

· Manuscript received March 16, 2018 ; Revised April 4, 2018 ; Accepted June 15, 2018. (ID No. 20180316-037)

· Corresponding Author: Seok-min Hong (e-mail: kmes578@naver.com)

뇌전도 데이터는 특징 추출과 평균화를 통한 데이터 벡터의 차원을 축소하였다. 뇌전도 데이터는 주파수 영역에서 많은 정보를 가져 주파수 영역 분석에 대한 연구가 이루어지고 있다^{[3][4]}. 이를 위해 측정된 뇌전도 데이터를 시간에 대한 주파수 정보로 변환하기 위한 단시간 푸리에 변환으로 데이터를 처리하고, 운동 관련 뇌전도의 특징을 추출을 위해 알파파 대역 뇌전도 데이터의 평균값을 취하였다.

II. 뇌전도의 취득

인간의 뇌는 기억, 감정, 동작 등 대부분 신체적, 정신적 활동을 제어한다. 이때 뇌 세포들의 생화학적 상호작용에 의해 발생한 이온의 흐름으로 인해 생성된 뇌의 전기적 활동으로 뇌전도가 발생하며, 이를 측정하기 위한 다양한 뇌전도 측정 장치가 개발되었다^[5]. 본 논문에서 사용한 측정 장비는 전도성 겔이 필요 없는 16 채널의 건극식 센서를 사용하며, 이로 인해 피부와 높은 접촉 임피던스를 보상하는 고 임피던스 증폭기로 구성되어 있다. 전극의 배치는 그림 1과 같이 국제 10-20전극 배치법에 따라 피험자의 두피에 전극을 부착한다. 측정된 뇌전도는 24 bit 해상도를 가지는 ADC를 통해 처리되며 뇌전도 데이터는 블루투스를 통해 무선으로 PC로 전송 및 저장된다. 실험에 사용한 장비의 사양은 표 1과 같다.

피험자는 뇌전도 측정 장비의 전극을 10-20전극법에 맞게 두피에 부착시킨 후 전극의 움직임이나 여러 신체

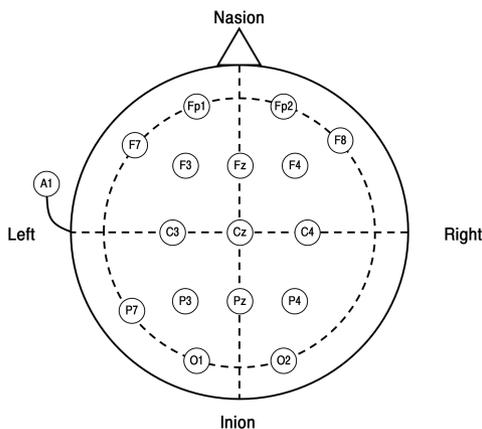


그림 1. 실험에 사용된 16개의 전극 배치도
Fig. 1. The 16 electrode arrangement used in the experiment.

표 1. 뇌전도 측정 장비 사양
Table 1. EEG measurement specifications.

| List | Specifications |
|------------------|--|
| Channel count | 10-20 EEG array, 16 channel |
| Sensor type | Active dry electrodes combined with active shielding |
| Noise | 0.7 μ V RMS from 1~50 Hz, shorted inputs |
| Resolution | 24 bits per sample |
| Wireless | Bluetooth |
| Sampling rate | 250 sample per sec |
| Gain value(user) | 4 |

의 움직임으로 인한 잡음이 유입되지 않도록 안정된 자세로 측정을 준비시킨 후 그림 2처럼 피험자는 5초 동안 진행되는 실험에서 임의로 화면에 출력되는 좌, 우 화살표에 따라 해당하는 손을 들어올린다. 1회 동작은 0에서 5초까지이며, 2초부터 2초간 지시 안내 그림이 출력되고, 5초간 측정된 데이터 즉, 1,250 sample 씩 전극별, 동작별로 저장하였다.

III. 뇌전도 신호처리

3-1 동작 관련 뇌전도 추출 및 잡음 제거

일반적인 성인 기준으로 동작관련 뇌전도는 30 Hz 이내에서 두드러지게 관찰되며^[6], 동작관련 뇌전도를 추출하기 위한 저역통과 필터는 250 Hz의 샘플링 주파수와

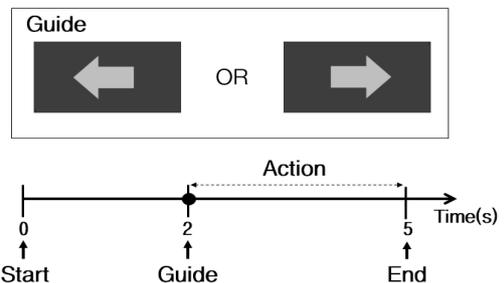


그림 2. 손동작에 따른 뇌전도 측정을 위한 피험자용 명령전달 화면
Fig. 2. Screen for subject for EEG measurement by hand motion.

30 Hz에서 6 dB의 차단 주파수를 가지며 선형 위상 특성이 좋은 FIR 필터로 설계하였다. FIR 필터의 연산량은 샘플링 주파수와 필터의 차수의 곱에 비례하여 참고문헌 [7] 필터의 차수가 높아질수록 필터의 성능은 향상되나 연산량이 증가한다. 따라서 연산량을 최소로 하여 목표 필터 사양을 만족하는 20차 FIR 필터를 설계하였고, 그 특성은 그림 3과 같다. 이를 거친 뇌전도 신호는 그림 4(b)와 같이 고주파 성분이 제거되어 순간적인 움직임, 30 Hz 이상 대역의 근전도나 심전도 등 외부 잡음이 제거된다.

3-2 시간-주파수 해석을 위한 단시간 푸리에 변환

단시간 푸리에 변환은 신호의 각 시간에서 스펙트럼 정보를 얻을 수 있다. 실시간으로 주파수 특성이 변하는 뇌전도 신호는 시간과 주파수 영역을 결합함으로써 분류 성능이 향상될 수 있음이 밝혀졌으며^[8], 시간과 주파수 성분으로 변환하기 위한 신호 $x[m]$ 의 단시간 푸리에 변환은 식 (1)과 같이 나타낸다^[9].

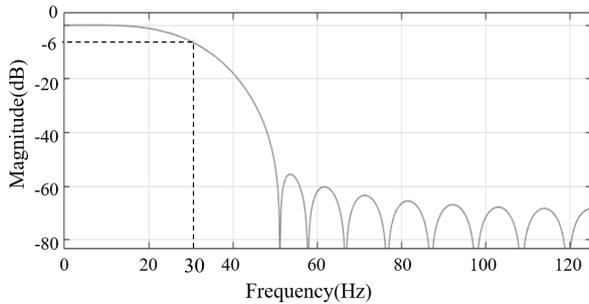


그림 3. 뇌전도 필터링을 위한 FIR 필터
Fig. 3. FIR filter magnitude response for EEG filtering.

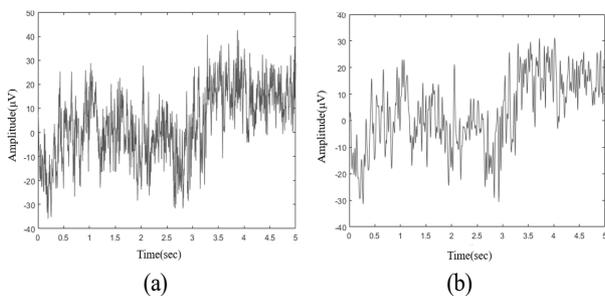


그림 4. (a) 필터링 전, (b) 필터링 후 뇌전도(Fp1 전극)
Fig. 4. (a) Pre-filtering EEG, (b) Filtered EEG(Fp1 pole).

$$X(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]w[n-m]e^{-j\omega n} \quad (1)$$

$w[n]$ 은 윈도우 함수이며, 저지대역 감쇠하에 큰 주엽 폭을 나타내는 카이저 윈도우 함수를 사용하였다.

$$w(n) = \frac{I_0 \left[\beta \sqrt{1 - \left(1 - \frac{2n}{M-1}\right)^2} \right]}{I_0[\beta]} \quad (2)$$

I_0 는 변형된 0차 베셀함수(Bessel function)이며 윈도우 함수에서 n 은 0에서 $M-1$ 사이이다. 최소 저지대역 55 dB(A_s)로 설계하기 위한 β 값은 식 (3)으로 정의된다^[9].

$$\beta = 0.1102(A_s - 8.7), A_s > 50 \quad (3)$$

단시간 푸리에 변환의 시간영역의 해상도와 주파수영역의 해상도는 서로 trade off 관계에 있어 시간적으로 변화하는 주파수 정보의 높은 정확도를 위해 적절한 윈도우 길이 설정이 필요하다. 시간적 해상도 수준 설정은 사람 기준으로 수백 ms 수준인 반응속도를 고려하여^[10] 80 ms 간격의 윈도우 길이를 설정하였으며, 불연속성을 최소화하기 위해 각 윈도우는 50 % 중첩되어 연속적인 함수로 나타내었다. 따라서 시간 샘플링은 초당 250회 주파수 해상도는 400 sample로 설정하였다. 그림 4의 필터링 된 뇌전도 신호의 단시간 푸리에 변환한 결과인 그림 5의 스펙트로그램에서 실험을 시작한 피험자에게 2초에서 손동작 명령이 내려지고 명령을 인지 이후 손동작을 실행한 2초 이후 수백 ms 동안 알파파(8~13 Hz) 대역의 신호가 급격히 감소한 결과가 나타나며, 동작 이후 뇌전도는 다시 동작 전 패턴으로 나타난다.

3-3 분류알고리즘 적용을 위한 데이터 처리

단시간 푸리에 변환된 뇌전도 데이터는 400 sample의 주파수 샘플링을 가지고 있어 1회 동작 시 5초간 50만개의 데이터를 가지므로 서포트 벡터 머신으로 학습데이터로 데이터의 크기가 매우 커 데이터의 차원 축소가 필요하다.

동작의 상상과 실제 동작에 대한 특성이 잘 나타나는 알파파 대역의 변화 패턴 분석을 위해 단시간 푸리에 변환된 데이터에서 알파파에 해당하는 8~13 Hz의 알파파 성분을 평균값을 얻어내어 전극별 알파파 대역의 평균

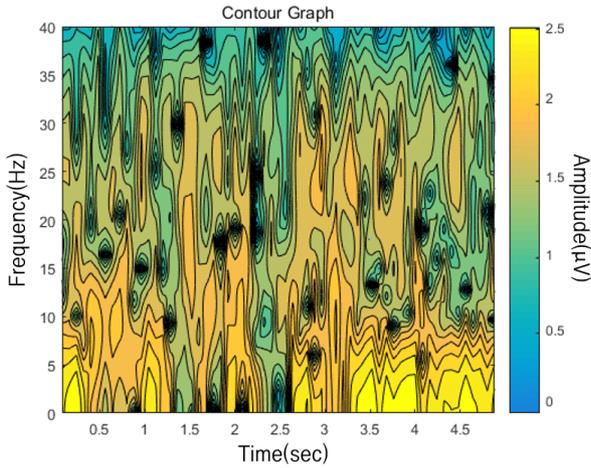


그림 5. 단시간 푸리에 변환된 뇌전도 신호 스펙트로그램 (Fp1 전극, $M=40$)

Fig. 5. Short time Fourier transformed EEG signal spectrogram(Fp1 pole, $M=40$).

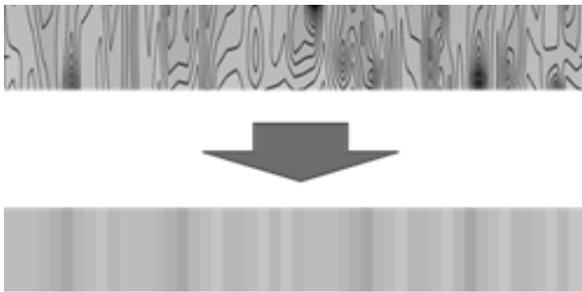


그림 6. 평균화된 알파파 신호

Fig. 6. Power spectral density of EEG.

데이터를 취득하였다.

데이터를 수집한 총 5초 동안 주파수 정보를 담고 있는 스펙트로그램의 데이터 길이는 식 (4)로 정의하며, 식의 S 는 데이터의 Sampling rate, M 은 단시간 푸리에 변환의 윈도우 길이, O 는 윈도우의 중첩률이다. 따라서 본 실험의 뇌전도 데이터는 61개의 데이터로 표현된다.

$$n_{feature} = \frac{S - MO}{M - MO} \quad (4)$$

IV. 서포트 벡터 머신을 통한 뇌전도 분류

본 연구에서는 손동작으로 발생한 뇌전도 신호를 구분

하기 위해 기계학습 알고리즘을 이용하였다. 기계학습은 인공지능의 한 분야이며, 기계학습은 크게 명시적인 정답으로 결과를 예측하는 지도학습, 정답이 없는 데이터로 구성되어 숨겨진 특징을 찾아내는 비지도학습, 보상을 통해 최적의 의사결정을 하는 강화학습으로 나눌 수 있다. 이 중 손동작 전 상태와 왼손 혹은 오른손을 움직인 상태에서 발생한 뇌전도를 측정하여 처리된 데이터를 학습시킨 후 새로운 손동작 데이터를 예측하기 위한 방법으로 기계학습 알고리즘 중 지도학습 알고리즘인 서포트 벡터 머신을 활용하였다. 서포트 벡터 머신은 데이터 마이닝 분야나 패턴인식 응용분야에서 주로 사용되는 기법이며, 비확률적인 이진 선형 분류 모델을 만든다. 만들어진 분류 모델은 데이터가 사상된 공간에서 경계로 표현되며, 데이터를 나누는 여러 개의 경계 중 서로 다른 데이터 사이에 가장 큰 폭을 가진 경계를 찾는 알고리즘이다.

본 논문에서는 MATLAB 2016a의 Classification Learner를 활용해 처리된 데이터를 학습시켜 동작을 구분하였고, 고차원 공간 사상을 위한 Gaussian kernel function을 적용하였으며, 분류 성능 측정의 통계적 신뢰도를 높이기 위해 교차검증(k-fold Cross Validation) 기법을 적용하여 분류 정확도를 구하였다. 생성된 분류기에서 손동작 상태를 손동작이라고 구분한 비율(true positive rate: TPR)과 손동작 전의 상태를 손동작이라고 잘못 예측한 비율(false positive rate: FPR)을 그래프로 나타낸 ROC(Receiver Operating Characteristic) curve의 하단 면적 ACU(Area Under Curve)값을 측정해 통해 서포트 벡터 머신의 동작 분류의 신뢰성을 검증하였다^[11]. 그림 7은 Fp1 전극의 손동작 전 상태와 오른손을 들었을 때 서포트 벡터 머신으로 학습된 분류기의 ROC curve이다. 최적의 분류기의 상태는 TPR이 높을수록 FPR이 낮을수록 좋은 분류기이다. 따라서 그래프 면적인 ACU가 클수록 분류기가 높은 신뢰도를 가진다. 완벽히 구분 가능한 ROC curve의 면적이 1일 때 그림 8의 경우 0.87 정도의 신뢰도를 가진다 할 수 있으며 이때 동작 구분 정확도는 78 % 측정되었다.

V. 측정 결과

손동작 전과 왼손 혹은 오른손을 들어 올린 상태, 왼손과 오른손을 들어 올린 상태를 구분하기 위해 전극당

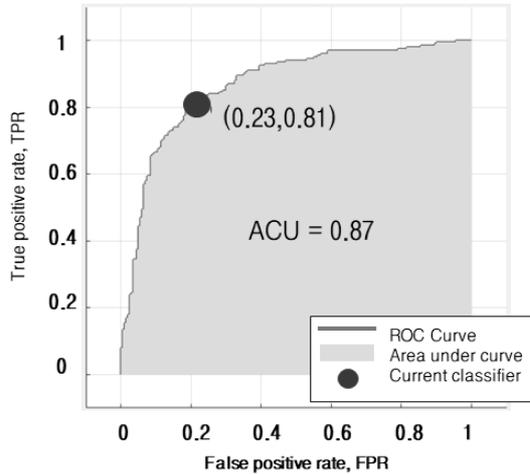


그림 7. SVM을 통한 결과의 ROC curve(Fp1 전극, 오른손)
Fig. 7. ROC curve of result through SVM(Fp1 pole, right).

400 set의 데이터를 입력하여 학습하였고 25회의 교차검증을 통해 분류기의 신뢰도를 확보하였다. 전극별 분류 결과 특징 추출 전과 후의 분류 정확도와 ACU는 표 2~표 4와 같다. 분류 결과 손동작 전과 왼손 혹은 오른손을 들어 올렸을 경우 특징 추출을 통하여 데이터의 수가 50만개에서 61개로 축약했음에도 특징 추출 전과 후 68~69%의 분류 정확도를 보였으며 왼쪽 혹은 오른쪽 손은 특징 추출 전 55.8% 후 59.7%로 4.1% 상승을 보였다. 이는 뇌전도 측정 시 외부 잡음이 제거되어 분류 정확도의 약간의 상승되어 나타났다고 판단된다. 세 경우에서 모두 전두엽 부근이 다른 전극과 비교하여 비교적 분류 정확도가 높게 측정되었으며 데이터의 특징 추출 및 데이터 차원 축소의 유무에 따른 결과 분류 정확도는 평균 약 1.8% 상승하였고 학습시간은 데이터의 차원 축소전보다 85% 감소되었다.

VI. 결 론

본 연구에서는 손동작에 의해 발생한 뇌전도를 구분하기 위해 건극식 뇌전도 측정 장비를 이용하여 1회 측정 시 5초간 뇌전도를 측정하였고, 데이터의 필터링을 통한 특징 추출과 데이터 차원 축소를 통하여 서포트 벡터 머신으로 학습시켰다. 교차검증은 1회에서 50회까지 수행하였으며, 1에서 5회까지 분류기에 신뢰도는 급격하게 상

표 2. 손동작 전 상태와 왼쪽 손을 들었을 때 결과
Table 2. Results before hand gesture and left hand.

| | Non feature extraction | | Feature extraction | |
|-------|------------------------|------|--------------------|------|
| | ACC.(%) | ACU | ACC.(%) | ACU |
| Pole | | | | |
| F7 | 73.5 | 0.79 | 69.3 | 0.76 |
| Fp1 | 70.8 | 0.71 | 73.5 | 0.83 |
| Fp2 | 71.3 | 0.77 | 77.3 | 0.85 |
| F8 | 73.8 | 0.82 | 68.0 | 0.75 |
| F3 | 67.1 | 0.77 | 75.5 | 0.8 |
| Fz | 69.5 | 0.73 | 69.6 | 0.69 |
| F4 | 72.5 | 0.8 | 74.5 | 0.77 |
| F.avg | 71.2 | 0.77 | 72.5 | 0.78 |
| C3 | 69.3 | 0.74 | 66.0 | 0.72 |
| Cz | 67.3 | 0.78 | 68.0 | 0.76 |
| C4 | 64.6 | 0.7 | 65.0 | 0.68 |
| P7 | 64.3 | 0.68 | 66.3 | 0.7 |
| P3 | 62.0 | 0.66 | 62.5 | 0.65 |
| Pz | 67.8 | 0.74 | 64.8 | 0.66 |
| P4 | 76.3 | 0.85 | 72.6 | 0.78 |
| O1 | 64.4 | 0.7 | 66.8 | 0.73 |
| O2 | 53.2 | 0.68 | 60.3 | 0.65 |
| AVG. | 68.0 | 0.75 | 68.8 | 0.74 |
| Time | 154.7s | | 23.8s | |

표 3. 손동작 전 상태와 오른쪽 손을 들었을 때 결과
Table 3. Results before hand gesture and right hand.

| | Non feature extraction | | Feature extraction | |
|-------|------------------------|------|--------------------|------|
| | ACC.(%) | ACU | ACC.(%) | ACU |
| Pole | | | | |
| F7 | 73.0 | 0.8 | 70.5 | 0.78 |
| Fp1 | 71.3 | 0.75 | 78.0 | 0.87 |
| Fp2 | 73.3 | 0.81 | 77.5 | 0.85 |
| F8 | 73.0 | 0.78 | 67.3 | 0.75 |
| F3 | 65.9 | 0.72 | 71.5 | 0.75 |
| Fz | 70.3 | 0.73 | 75.3 | 0.65 |
| F4 | 73.3 | 0.78 | 70.5 | 0.77 |
| F.avg | 71.4 | 0.77 | 72.9 | 0.77 |
| C3 | 67.8 | 0.72 | 64.2 | 0.69 |
| Cz | 72.8 | 0.76 | 65.8 | 0.72 |
| C4 | 63.0 | 0.71 | 65.5 | 0.71 |
| P7 | 63.0 | 0.67 | 67.3 | 0.74 |
| P3 | 64.3 | 0.68 | 67.5 | 0.68 |
| Pz | 65.3 | 0.69 | 62.5 | 0.66 |
| P4 | 72.0 | 0.84 | 70.3 | 0.77 |
| O1 | 67.5 | 0.77 | 65.0 | 0.71 |
| O2 | 55.7 | 0.7 | 65.0 | 0.67 |
| AVG. | 68.2 | 0.74 | 69.0 | 0.74 |
| Time | 159.4s | | 24.1s | |

표 4. 왼쪽 손 또는 오른쪽 손을 들었을 때 결과
Table 4. Results when the subject hears the left or right hand.

| | Non feature extraction | | Feature extraction | |
|-------|------------------------|------|--------------------|------|
| | ACC.(%) | ACU | ACC.(%) | ACU |
| Pole | | | | |
| F7 | 57.0 | 0.58 | 58.1 | 0.61 |
| Fp1 | 53.5 | 0.52 | 56.6 | 0.60 |
| Fp2 | 60.3 | 0.61 | 60.7 | 0.53 |
| F8 | 60.0 | 0.59 | 62.0 | 0.62 |
| F3 | 58.0 | 0.61 | 57.5 | 0.52 |
| Fz | 53.5 | 0.55 | 58.3 | 0.54 |
| F4 | 57.8 | 0.61 | 67.3 | 0.67 |
| F.avg | 57.2 | 0.58 | 60.1 | 0.58 |
| C3 | 51.3 | 0.56 | 65.8 | 0.64 |
| Cz | 52.5 | 0.56 | 60.9 | 0.60 |
| C4 | 58.5 | 0.59 | 57.7 | 0.59 |
| P7 | 55.5 | 0.57 | 54.4 | 0.54 |
| P3 | 59.0 | 0.58 | 57.1 | 0.60 |
| Pz | 55.8 | 0.57 | 59.8 | 0.58 |
| P4 | 51.5 | 0.61 | 60.7 | 0.60 |
| O1 | 56.0 | 0.57 | 56.6 | 0.49 |
| O2 | 52.5 | 0.59 | 62.2 | 0.66 |
| AVG. | 55.8 | 0.58 | 59.7 | 0.59 |
| Time | 162.6s | | 25.5s | |

승하였고, 25회 이상으로는 분류기의 신뢰도나 성능에 큰 영향을 미치지 않았다. 손동작 전 상태와 왼쪽 혹은 오른쪽 손을 들었을 경우, 평균 68.9 % 수준의 정확도로 구분이 가능하며 Fp1전극에서 최대 78 % 정확도를 나타내었다. 비교적 정확도가 높았던 전두엽 부근 전극만 평균을 취하였을 경우, 각각 72.5 %, 72.9 %의 정확도를 나타내었다. 특징 추출 및 데이터 평균화를 통한 데이터의 차원 축소로 동작 구분에 필요한 서포트 벡터 머신의 학습 속도가 6.6배 상승하였고 분류 정확도 또한 평균 1.8 % 상승한 결과를 보였다. 하지만 왼손 또는 오른손을 구분하였을 경우, 정확도가 약 60 % 정도로 측정되었고, 최대 F7전극에서 67.3 %의 정확도로 양 손을 분류하였다. 이는 특정 전극에서만 좌, 우 손동작에 관여하는 것으로 판단된다. 이를 위해 좌뇌와 우뇌의 뇌전도를 비교하는 등 좌, 우 손동작에 따른 뇌생리학적 특성을 반영한 연구와 개개인마다 상이한 뇌전도의 특성을 고려한 분류모델 생성에 대한 연구가 진행되어야 할 것이다.

References

[1] H. Gunes, M. Piccardi, "Bi-modal emotion recognition from expressive face and body gestures," *Journal of Network and Computer Applications*, vol. 30, no. 4, pp. 1334-1345, 2007.

[2] E. S. Nurse, P. J. Karoly, D. B. Grayden, and D. R. Free-stone, "A generalizable brain-computer interface(BCI) using machine learning for feature discovery," *PLoS ONE*, vol. 10, no. 6, 2015.

[3] E. Yavuz, Ö. Aydemir, "Classification of EEG based BCI signals imagined hand closing and opening," in *2017 40th International Conference on Telecommunications and Signal Processing(TSP)*, Barcelona, 2017, pp. 425-428.

[4] A. F. A. Jais, W. Mansor, K. Y. Lee, and W. F. H. Fauzi, "Motor imagery EEG analysis for home appliance control," in *2017 IEEE 13th International Colloquium on Signal Processing & Its Applications(CSPA)*, Batu Feringgi, 2017, pp. 314-317.

[5] A. Van Cott, R. P. Brenner, "Technical advantage of digital EEG," *Journal of Clinical Neurophysiology*, vol. 15, no. 6, pp. 464-475, 1998.

[6] G. Pfurtscheller, F. H. Lopes da Silva, "Eventrelated EEG/MEG synchronization and desynchronization: Basic principles," *Clinical Neurophysiology*, vol. 110, no. 11, pp. 1842-1857, Nov. 1999.

[7] 김정환, 김현태, 박상은, 이정환, 김경섭, "다중레이트 디지털 필터 설계 및 심전도 신호의 기저선 변동 및 전원 잡음 제거," *전기학회논문지*, 63(4), pp. 551-558, 2014년.

[8] W. Ting, Y. Guo-zheng, Y. Bang-hua, and S. Hong, "EEG feature extraction based on wavelet packet decomposition for brain computer interface," *Measurement*, vol. 41, no. 6, pp. 618-625, Jul. 2008.

[9] V. K. Ingle, J. G. Proakis, MATLAB을 이용한 디지털 신호처리, CENGAGE Learning, p. 334, 2007.

[10] S. Trope, D. Fize, and C. Marlot, "Speed of processing in the human visual system," *Nature*, vol. 381, no. 6582,

pp. 520-522, Jun. 1996.

[11] Y. Tian, Y. Shi, X. Chen, and W. Chen, "AUC maxi-

zing support vector machines with feature selection," *Procedia Computer Science*, vol. 4, pp. 1691-1698, 2011.

홍 석 민



2016년 2월: 국민대학교 전자공학부 (공학사)
2018년 2월: 국민대학교 보안-스마트전기 자동차학과 (공학석사)
[주 관심분야] DSP, 데이터 변환, 뇌전도 신호

성 영 락



1989년: 한양대학교 전자공학과 (공학사)
1991년: 한국과학기술원 전자공학과 (공학석사)
1995년: 한국과학기술원 전자공학과 (공학박사)
1996년~현재: 국민대학교 교수
[주 관심분야] Real-Time System, Wireless Sensor Networks, Discrete Event System Modeling and Simulation, and Embedded System.

민 창 기



2016년 2월: 국민대학교 전자공학과 (공학사)
2018년 2월: 국민대학교 보안-스마트전기 자동차학과 (공학석사)
[주 관심분야] Analog IC 설계, 무선전력 전송

박 준 석



1991년: 국민대학교 전자공학과 (공학사)
1993년: 국민대학교 전자공학과 (공학석사)
1996년: 국민대학교 전자공학과 (공학박사)
1998년~2003년: 순천향대학교 정보기술 공학부 조교수
2003년~현재: 국민대학교 교수
[주 관심분야] 마이크로파 공학, RFIC, 신호처리, 센서시스템

오 하 령



1983년: 서울대학교 전자공학과 (공학사)
1988년: 한국과학기술원 전자공학과(공학석사)
1992년: 한국과학기술원 전자공학과(공학박사)
1992년~현재: 국민대학교 교수
[주 관심분야] RFID System, Wireless Sensor Network, and Embedded System