

논문 2010-47SC-5-3

P300 뇌파를 이용한 뇌-기계 인터페이스 기술에 대한 연구

(Brain-Machine Interface Using P300 Brain Wave)

차 갑 문*, 신 현 출**

(Kab-Mun Cha and Hyun-Chool Shin)

요 약

본 논문은 유발전위(evoked potential) 뇌파인 P300에 기반한 뇌-기계 인터페이스의 실시간 구현을 위한 효율적인 알고리즘을 제안한다. P300 뇌파는 외부 시각 자극이 인간의 의지와 일치할 경우, 100-300ms 부근에서 negative pick를 갖는 특성이 있다. 이러한 특성에 기초하여 P300 뇌파의 포텐셜(potential) 감소를 감지하여 인간의 의도를 역으로 추론할 수 있으며, 이를 뇌-기계 인터페이스에 활용할 수 있다. 연구에서 P300 뇌파는 인간의 두개골 외부에 부착된 전극을 통해 얻어졌으며, 시각적 자극으로는 2차원 알파벳 신호를 사용하였다. P300 뇌파의 포텐셜 감소 검출을 위하여 뇌파 포텐셜을 자극과 연계하여 확률적으로 모델링하였다. 확률적 모델은 피실험자가 의도하는 신호의 모델(target model)과 의도하지 않는 신호의 모델(non-target model)로 구성된다. 이러한 확률적 모델에 기반하여 피실험자의 의도를 추론하기 위해서 최우추정법(maximum likelihood estimation)을 사용하였다. 실험에는 신체 건강한 성인 남자 3명이 참가하였으며, 'A'와 'E' 실험에 대한 피실험자 k의 평균 성공률은 98%, 피실험자 j의 평균 성공률 90%, 그리고 피실험자 h의 성공률은 79.8%였다.

Abstract

In this paper, we propose a computationally efficient method detecting the P300 wave for brain-machine interface. Electrophysiological researches have shown that the P300 wave's potential is decreased when human intention matches visual stimulation. Motivated by this fact, we can infer human intention for brain-machine interface by detecting the P300 wave's potential decrease. The P300 wave is recorded from EEG(electroencephalogram) electrodes attached on human brain skull after giving alphabetical stimulation. To detect the potential decrease in P300, firstly we statistically model the P300 wave's negative potential. Then we infer human intention based on maximum likelihood estimation. The proposed method was evaluated on the data recorded from three healthy human subjects. The method achieved an averaging accuracy of 98% from subject k, 90% from subject j and 79.8% from subject h.

Keywords : BMI, BCI, EEG, P300, Maximum likelihood, EP

I. 서 론

인간이 어떤 일에 대한 사고나 행동을 할 때, 뇌 속에 있는 시냅스(synapse)에서는 신경전달물질을 이용해 정보를 전달하게 되고, 이때 뉴런 간에 발생하는 전위차에 의해 전류가 흐르게 되는데, 이것을 뇌파(EEG :

Encephalogram)라 부른다. 뇌-기계 인터페이스(Brain-Machine Interface) 기술은 이런 뇌파를 이용해서 인간의 생각이나 의지를 언어나 신체의 다른 동작을 거치지 않고 시스템에 직접 전달할 수 있는 기술이다^[1~2].

뇌-기계 인터페이스 기술은 신체적 결함이나 장애로 인해, 자신의 의사를 표현, 전달할 수 없는 사람들에게 새로운 의사소통 수단을 제공할 수 있다는 점에 큰 의미를 가지고 있으며^[3~4], 이러한 기술적 이점을 이용해서 신체 장애인을 위한 의료용 보조 기구부터 뇌파를 이용한 새로운 인터페이스의 게임, 가정 자동화를 위한 전자제품 그리고, 학습 보조기구에 이르기까지 많은 응용분야에 사용될 수 있다.

* 학생회원, ** 정회원, 숭실대학교 IT대학 전자공학과 (Information and Telecommunication Engineering, School of IT, Soongsil University)

※ 본 연구는 지식경제부 및 정보통신연구진흥원의 대학 IT연구센터 지원사업의 연구결과로 수행되었음. (IITA-2008-C1090-0803-0006)

접수일자: 2009년7월11일, 수정완료일: 2010년9월7일

VEP(Visual Evoked Potential)는 시각적 자극이 주어졌을 때 발생하는 뇌파의 포텐셜(potential) 변화를 뜻하는 것이며, 특히 빛 자극이 주어졌을 때, 300ms를 전후로 하여 뇌파의 포텐셜이 급격히 변화하는 것을 P300이라 한다. VEP나 P300 연구는 주로 Amplitude의 변화를 측정하여 알고리즘화 하는 것이 일반적이다.

하지만, 두뇌에서 측정되는 뇌파는 지극히 미약하며 두뇌 내부의 전기적인 활동을 총체적으로 반영하기 때문에 뇌파를 통해 알아낼 수 있는 정보는 극히 일부에 지나지 않으며, 다양한 요인으로 인해 신호가 왜곡될 가능성이 크다. 따라서 측정된 뇌파(raw data)로부터 정보를 추출하는 신호처리 알고리즘이 요구된다. PCA(Principal Component Analysis)^[5], Neural-Network^[6] 그리고, Machine Learning^[7] 등이 그러한 예이다. 그 중에서도 P300 관련 논문에서는 PCA^[5], SVM(Support Vector Machine)^[8-9], bayesian^[10] 등의 방법이 주로 쓰이고 있는데, 이와 같은 방법들은 많은 변수들로 인해 성능의 안정성을 보장하기가 어렵고, 구현하기가 쉽지 않다. 그리고 기존의 논문에서 사용되는 알고리즘은 P300의 positive peak를 이용하는데, 이는 0.3초 이후의 뇌파 변화로서, 출현시간이 일정하지 않을 뿐 아니라, 실시간 시스템을 구현함에 있어 제약을 가질 수밖에 없다. 본 논문에서는 실시간 구현을 고려하여, P300의 negative peak를 이용한 뇌파 변화의 확률적인 분포와 최우추정법(Maximum Likelihood Estimation)을 사용해, 계산량이 적고, 설정변수를 최소화하는 알고리즘을 개발하고자 하였다.

II. 본 론

P300은 그림 1에서처럼, 자극이 주어졌을 때 자극이 주어진 시점으로부터 100~300ms 부근의 시간대에서 뇌파의 포텐셜(potential)이 급격히 변하는 패턴을 가진다. 이 패턴을 찾아내는 것이 본 논문 알고리즘의 핵심이라고 할 수 있다.

그림 2는 전체 시스템을 한눈에 볼 수 있게 나타낸 것이다. 피실험자는 컴퓨터 모니터를 통해 총 5개 열(A,B,C,D,E)의 시각적 자극을 입력받게 되는데(모니터 상의 문자열이 무작위(random)로 A~E까지 깜박임), 이때 피실험자의 생각(5개의 문자 중, 피실험자가 바라보는 문자)과 자극이 일치하면 P300이 발생하게 된다. 이렇게 취득한 뇌파에 전처리 필터링(Low-pass




그림 1. P300 패턴
Fig. 1. P300 pattern.

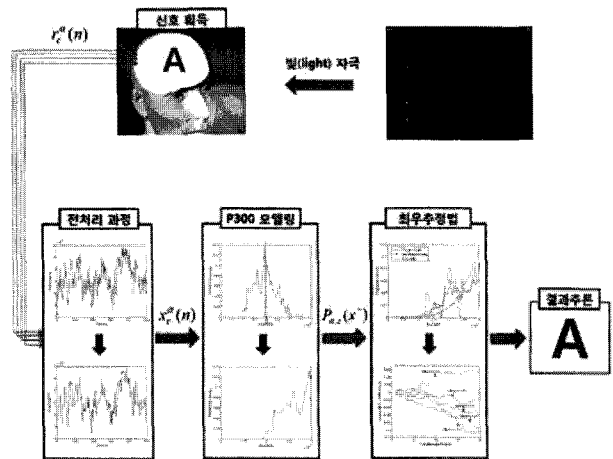


그림 2. 전체 시스템 개요
Fig. 2. System overview.

filtering)을 한 후, 뇌파 포텐셜(potential)의 확률적 분포 모델을 만든다. 그리고 마지막으로 최우추정법(Maximum Likelihood Estimation)을 이용해서 피실험자의 의지를 추론한다.

1. 전처리 과정

인간의 두뇌에서 측정되는 데이터 중에 정보를 포함하는 의미있는 주파수 대역은 0~30Hz이기 때문에, 30Hz 저역통과 필터를 사용해서 전처리 필터링을 한다. 전극으로부터 얻어진 신호를 $r_c^\alpha(n)$ 라 할 때, 저역통과 필터 $h(n)$ 을 거친 신호 $x_c^\alpha(n)$ 은 다음과 같다.

$$x_c^\alpha(n) = r_c^\alpha(n) * h(n) \tag{1}$$

여기서 α 는 문자(A,B,C,D,E)를 의미하는 것이고, c 는 채널을 의미하며, n 은 시간을 나타낸다.

2. P300의 확률적 모델

자극이 주어진 시점으로부터 100~300ms 부근에서 뇌파의 포텐셜(potential)이 감소하는 P300의 특성을 이용해서, 신호 패턴이 뚜렷한 구간을 잘라내고, 여기에 bin 값을 설정해서 히스토그램으로 나타낸 뒤, 각각의 amplitude bin을 전체 bin 값으로 나눔으로써 그림 3과 같이 뇌파 포텐셜(potential)의 확률적 분포 모델 $P_{\alpha,c}(x)$ 를 만든다. 각각의 bin은 다음과 같다.

$$I_m = \left\{ \begin{array}{l} x_c^\alpha | x_{\min} + \frac{D}{M}(m-1) \\ \leq x_c^\alpha < x_{\min} + \frac{Dm}{M} \end{array} \right\}, m=1,2,\dots,M, \quad (2)$$

$$D = x_{\max} - x_{\min}, \quad (3)$$

$$P_{\alpha,c}(x_m) = \frac{\text{Number of samples} \in I_m}{\text{Number of total samples}} \quad (4)$$

위 $P_{\alpha,c}(x)$ 의 데이터 중, 음의 영역만을 따로 잘라내서 확률적으로 모델링하면 다음과 같다.

$$P_{\alpha,c}(x^-) = \begin{cases} \frac{P_{\alpha,c}(x)}{\int_{-\infty}^0 P_{\alpha,c}(x) dx}, & x \leq 0 \\ 0, & x > 0 \end{cases} \quad (5)$$

확률 모델 $P_{\alpha,c}(x^-)$ 를 이용해서 그림 4와 같이 target 모델 P_c^T 와 non-target 모델 P_c^{NT} 를 만든다.

Target 모델 P_c^T 는 피실험자가 의도했던 자극이 입력되었을 때 발생하는 뇌파를 일정시간 누적해서 만들고, non-target 모델 P_c^{NT} 는 피실험자가 의도하지 않은 자극이 입력되었을 때 발생하는 뇌파를 누적해서 만든다.

$$P_c^T = E[P_{\alpha_1,c}(x_n^-)] \quad (6)$$




그림 3. 뇌파 포텐셜(potential)의 확률적 분포 $P_{\alpha,c}(x)$
Fig. 3. Amplitude PDF $P_{\alpha,c}(x)$.

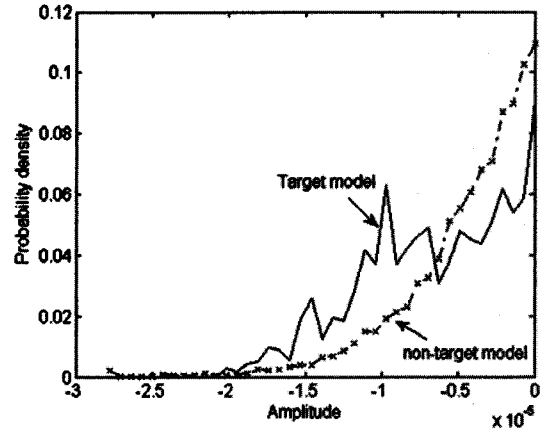


그림 4. Target 모델과 non-target 모델
Fig. 4. Target model and non-target model.

$$P_c^{NT} = \frac{E[P_{\alpha_2,c}(x_n^-)]}{4} + \frac{E[P_{\alpha_3,c}(x_n^-)]}{4} + \frac{E[P_{\alpha_4,c}(x_n^-)]}{4} + \frac{E[P_{\alpha_5,c}(x_n^-)]}{4} \quad (7)$$

여기서 $E[\cdot]$ 는 통계적인 평균(expectation)을 의미한다.

식 (6)에서 α_1 은 피실험자가 의도했던 문자이고, 식 (7)에서 $\alpha_2, \alpha_3, \alpha_4, \alpha_5$ 는 피실험자가 의도하지 않은 나머지 문자이다.

3. 최우추정법 기반 의지추론

입력의 신호(test data)가 입력되었을 때, 입력신호와 모델들 간의 유사도(likelihood)를 구한다. Target model P_c^T 와 입력신호 $P_{\alpha,c}(x^-)$ 간의 유사도를 나타내는 $l_{\alpha,c}^T$ 그리고, non-target model P_c^{NT} 와 입력신호 $P_{\alpha,c}(x^-)$ 간의 유사도를 나타내는 $l_{\alpha,c}^{NT}$ 는 다음과 같이 계산한다.

$$l_{\alpha,c}^T = \| P_{\alpha,c}(x^-) - P_c^T \|_1 \quad (8)$$

$$l_{\alpha,c}^{NT} = \| P_{\alpha,c}(x^-) - P_c^{NT} \|_1 \quad (9)$$

이렇게 구한 입력신호와 모델들 간의 유사도 $l_{\alpha,c}^T$ 와 $l_{\alpha,c}^{NT}$ 는 채널합을 구한 후, 일정시간을 누적한다.

$$l_\alpha^T = \sum_{c=1}^C l_{\alpha,c}^T \quad (10)$$

$$l_\alpha^{NT} = \sum_{c=1}^C l_{\alpha,c}^{NT} \quad (11)$$

$$L_{\alpha}^T = L_{\alpha}^T + l_{\alpha}^T \quad (12)$$

$$L_{\alpha}^{NT} = L_{\alpha}^{NT} + l_{\alpha}^{NT} \quad (13)$$

최종적으로 누적한 L_{α}^T 와 L_{α}^{NT} 의 차이값 e_{α} 를 구하고, 그 중 가장 큰 차이값 e_{α} 를 가지는 문자를 선택한다.

$$e_{\alpha} = L_{\alpha}^{NT} - L_{\alpha}^T \quad (14)$$

$$\hat{\alpha} = \arg_{\alpha}(\max(e_{\alpha})) \quad (15)$$

여기서 e_{α} 가 가장 크다는 의미는 임의로 입력된 신호 x_c^{α} 와 피실험자가 의도(생각)하는 문자와의 유사성이 가장 큰(maximum likelihood) 신호를 뜻한다.

III. 실험 결과

실험에 사용된 시스템은 펜티엄-4 2.66G cpu와 2GB의 메모리가 탑재된 데스크탑을 사용하였고, 신호 취득 장비에는 (주)Laxtha의 PolyG-A를 사용하였다. 실험은 항상 형광등이 켜져 있는 실내에서 진행되었다.

시각적(빛) 자극(stimulation)을 제어하기 위해, 그림 5와 같은 MFC를 이용한 가로 20cm, 세로 15cm의 어플리케이션(application)을 만들었다.

각각의 문자 간격은 좌우 3cm, 상하 2cm로 설정하였으며, 문자는 A~E까지 무작위로 선택되어 지는데, 이때 라인별 깜빡임 시간은 0.25초이다. 1개 round(A~E)의 자극이 실행되는데 걸리는 시간은 1.25초이며, 불이 켜져 있는 시간은 0.08초이다.

채널은 총 4개를 사용하였으며, 샘플링 주파수는




그림 5. 실험에 사용된 빛 자극 어플리케이션
Fig. 5. Stimulation dialog.




그림 6. 채널 부착 위치
Fig. 6. Location of electrodes.

256Hz로 설정하였다. 시각적 자극에 대한 실험이기에 때문에, 시각을 담당하는 후두부(occipital region)에서 뇌파 신호가 두드러질 것이라는 생각에서 P3, P4, O1, O2에 부착하였다. 부착위치는 그림 6에 나타낸 International 10-20 system을 참조하였다.

피실험자의 생각과 일치하는 신호(target model)와 일치하지 않는 신호(non-target model)간의 변별력을 높이기 위해 문턱값(threshold)을 사용하였다. 하지만, 그림 7에서 보듯이 문턱값의 선택에 따라 성공률의 차이가 발생한다. 그렇기 때문에, 가장 성공률이 높은 문턱값을 구할 필요가 있다.

그림 4에서, P300 패턴을 포함하고 있는 target model은 대략 -0.6 이하의 값에서 non-target model보다 큰 값을 가지게 되고, non-target model은 0 부근에서 큰 값을 나타낸다는 것을 알 수 있다. 이러한 이유로 두 모델간의 차이값을 누적하였을 때, 그 값이 가장 커지는 지점을 문턱값으로 설정한다. 실험에서 문턱값은 $-6\mu V$ 로 설정하였다.

실험은 화면상에 보여 지는 A, B, C, D, E 캐릭터가 랜덤하게 한번 씩 깜빡이는 것을 1 round라고 할 때,

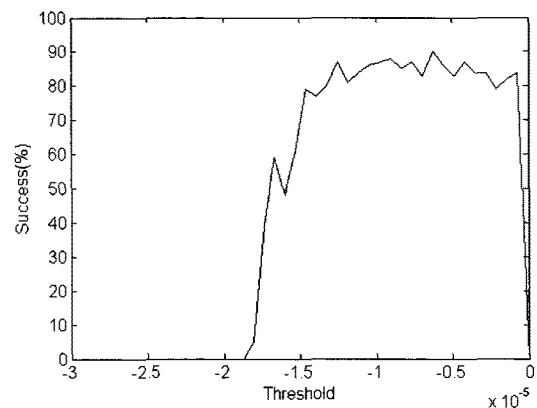


그림 7. 문턱값(threshold)에 따른 성공률
Fig. 7. Success rate for different thresholds.

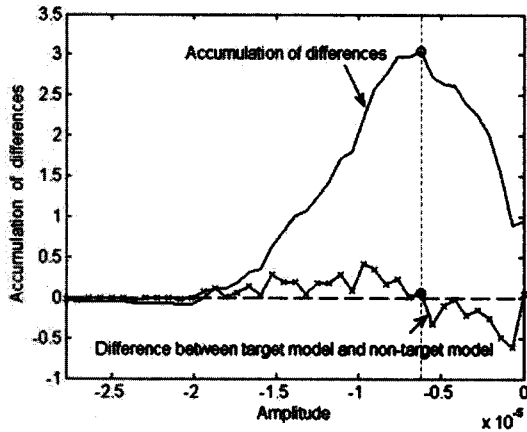


그림 8. 문턱값 설정
Fig. 8. Threshold selection.




그림 9. 실험에 사용된 data set의 구조
Fig. 9. Data set structure.




그림 10. 20개의 rounds에 대한 e_α 의 누적 그래프
Fig. 10. Accumulation of e_α for 20 rounds.

총 40개의 rounds를 묶어서 1 set을 만들었다. 이 1 set마다 1개의 결과값을 유추할 수 있다. 40개의 rounds 중 20개의 rounds를 훈련과정(training)에 사용하였고, 이 과정동안 target model과 non-target model을 만들었다. 그리고 나머지 20개의 rounds를 test data로 사용하였다.

그림 10은 A~E의 자극을 하나의 round라고 생각했을 때, 총 20개의 rounds를 누적했을 때의 그래프이고, 이 그래프를 수치로 나타낸 것이 표 1이다. 표 1에서 나

표 1. 20개의 rounds에 대한 e_α 의 누적 수치
Table 1. Accumulation of e_α for 20 rounds.

입력자극 \ 차이값	L_α^{NT}	L_α^T	e_α
A	1.9172	1.8659	0.0514
B	1.714	1.7277	-0.0136
C	1.6199	1.7135	-0.0936
D	1.696	1.7986	-0.1026
E	1.6236	1.6833	-0.0596

표 2. 성공률
Table 2. Success rate.

입력자극 \ 피실험자	A	E
피실험자 k	97.9%	99.8%
피실험자 j	88.7%	90.3%
피실험자 h	77.8%	81.1%

타난 수치를 토대로 가장 큰 e_α 를 나타내는 A를 결과값으로 선택하게 된다.

실험에는 20대 후반의 건강한 남자 3명이 참가하였고, 표 2에서 보는바와 같이, 입력자극 'A'와 'E'에 대해서 피실험자 k는 각각 97.9%, 99.8%의 성공률을, 피실험자 j는 각각 88.7%, 90.3%, 마지막으로 피실험자 h는 각각 77.8%, 81.1%의 성공률을 보였다.

위 표 2의 성공률은 총 1000 sets에 대한 성공률을 나타낸 것이지만, 1개의 set은 40개의 rounds 중, 20개의 rounds를 무작위로 뽑아서 1개의 training set을 만들고, 이 과정을 1000번 반복해서 1000개의 sets을 만든 것이다.

IV. 결 론

시각적 자극이 인간의 의도와 일치할 경우 P300 뇌파의 포텐셜(potential)이 감소한다는 사실에 기초하여, 인간의 의도를 P300 뇌파 분석을 통하여 역으로 추론하였다. 뇌파(EEG)는 사람에게 따라서, 혹은 동일인일지라도 시간에 따라, 그리고 환경에 따라 다른 신호가 발생한다. 뇌-기계 인터페이스 연구에서의 가장 큰 어려움은 이런 뇌파의 가변성이라 할 수 있다. 이러한 가변성의 문제는 P300 뇌파의 확실적인 모델링을 통하여 해결하고자 하였으며, 뇌-기계 인터페이스의 실시간 구현을 위하여 의도 추론 과정도 최우추정법에 기초하여 계산적 효율성과 성능의 안정성을 고려하였다.

실험 결과 3명의 피실험자 중 2명에 대해서는 90%이

상의 추론 성능을 보였다. 우수한 추론 성능을 보인 피실험자 k는 연구 초기부터 연구와 실험에 참가를 하였고, 피실험자 j는 3개월 이상 훈련을 하였으며, 가장 성능이 좋지 않은 피실험자 h는 실험과 무관하게 임의로 선별되었다. 이렇게 대표성을 가진 피실험자들의 실험 결과를 토대로 미루어 짐작해 보면, 실험 방법이나 실험의 원리에 대해 더 잘 알고 있는 사람일수록 성공률이 높다는 것을 알고 있다. 이는 곧 '훈련(training)'을 통해 성공률이 좋아질 수 있다^[3]는 뇌-기계 인터페이스 연구의 기본 맥락과 일치한다. 따라서 향후 성공적인 뇌-기계 인터페이스를 위해서는 뇌파 분석 방법에 대한 연구뿐만 아니라, 피실험자에 따른 성능 변화에 대해서도 고찰이 필요하다. 그리고 실험에 사용된 'A'와 'E' 두 캐릭터 뿐 만 아니라, 'B', 'C', 'D' 혹은 더 많은 캐릭터에 대한 효율적인 알고리즘 개발을 위한 연구도 불가피하다.

참 고 문 헌

[1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. vaughan, "Brain-computer interfaces for communication and control," Clin. Neurophysiol., vol. 113, pp. 767-791, 2002.

[2] J. R. Wolpaw, D. J. McFarland, G. W. Neat, and C. A. Forneris, "An EEG-based brain-computer interface for cursor control," Electro-encephalogr. clin. Neurophysiol., vol. 78, pp. 252-259, 1991.

[3] G. Pfurtscheller, C. Neuper, C. Guger, W. Harkam, H. Ramoser, A. Schlogl, B. Obermaier, and M. Pregenzer, "Current trends in Graz brain-computer interface(BCI) research," IEEE Trans. Rehab. Eng., vol. 8, no. 2, pp. 216-219, June 2000.

[4] J. R. Wolpaw, D. J. McFarland, and T. M. vaughan, "Brain-computer interface research at the Wadsworth center," IEEE Trans. Rehab. Eng., vol. 8, no. 2, pp. 222-226, June 2000.

[5] A. Lenhardt, M. Kaper, and H. J. Ritter, "An adaptive P300-based online brain-computer interface." IEEE Trans. Neural Syst. Rehab. Eng., vol. 16, no. 2, pp. 121-130, April 2008.

[6] B. J. Culpepper and R. M. Keller, "Enabling computer decisions based on EEG input," IEEE Trans. Rehab. Eng., vol. 11, no. 4, December 2003.

[7] B. Blankertz, G. Dornhege, M. Krauledat, K. R.

Muller, V. Kunzmann, F. Losch, and G. Curio, "The berlin Brain-computer interface: EEG-based communication without subject training," IEEE Trans. Rehab. Eng., vol. 14, no. 2, June 2006.

[8] M. Thulasidas, C. Guan, and J. Wu, "Robust classification of EEG signal for brain-computer interface," IEEE Trans. Neural. Syst. Rehab. Eng., vol. 14, no. 1, pp. 24-29, March 2006.

[9] H. Zhang, C. Guan, and C. Wang, "Asynchronous P300-based brain-computer interfaces: A computational approach with statistical models," IEEE Trans. Biomed. eng., vol. 55, no. 6, June 2008.

[10] P. A. Karjalainen, J. P. Kaipio, A. S. Koistinen, and M. vauhkonen, "Subspace regularization method for the single-trial estimation of evoked potentials," IEEE Trans. Biomed. Eng., vol. 46, no. 7, July 1999.

저 자 소 개



차 갑 문(정회원)

2007년 숭실대학교 정보통신전자공학과 학사 졸업.

2009년 숭실대학교 정보통신공학과 석사 졸업.

2009년~현재 숭실대학교 전자공학 박사과정

<주관심분야 : 신경신호처리, BMI, HCI>



신 현 출(정회원)

1997년 포항공과대학교 전자전기공학과 학사 졸업.

1999년 포항공과대학교 전자전기공학과 석사 졸업.

2004년 포항공과대학교 전자전기공학과 박사 졸업.

2004년~2007년 Johns Hopkins Univ., School of Medicine 박사 후 연구원

2007년~현재 숭실대학교 정보통신전자공학부 조교수

<주관심분야 : 신경신호처리, BMI, 의료영상>