

논문 2015-52-8-13

주행로봇제어를 위한 DWT와 SVM기반의 EEG신호 분류 알고리즘

(EEG Signal Classification Algorithm based on DWT and SVM for Driving Robot Control)

이 기 배*, 이 중 현**, 배 진 호**, 이 재 일*

(Kibae Lee, Chong Hyun Lee[Ⓢ], Jinho Bae, and Jaeil Lee)

요 약

본 논문은 '좌', '우' 방향 제어를 위해 취득된 EEG(Electroencephalogram) 신호 기반 분류 알고리즘과 EEG 센서, Labview, DAQ, Matlab, 주행로봇으로 구성된 방향 제어 시스템을 제안한다. 제안된 알고리즘은 DWT(Discrete Wavelet Transform)로 추출된 주파수대역 정보를 특징으로 이용하며, Fisher score를 이용하여 변별력이 높은 주파수 대역의 특징을 선별한다. 또한, SVM(Support Vector Machine)을 이용하여 분류 성능이 최고가 되는 특징벡터의 조합을 제안하고, 잘못된 판정에 의한 오동작을 방지하기 위한 MLD(Maximum Likelihood Decision) 기반의 판정보류 알고리즘도 제안한다. 제안된 알고리즘에 의해 선택된 4개의 특징벡터는 국제 표준 전극 배치법에 따른 P8 채널의 d2(16-32Hz), d5(2-4Hz) 주파수 대역의 전압의 절대 값 평균과 표준편차이다. SVM 분류기로 실험한 결과 98.75%의 정확도와 1.25%의 오류율 성능을 보였다. 또한, 오류 확률 70%를 판정 보류로 규정할 경우, 제안된 알고리즘은 인식을 95.63%의 정확도와 오류율 0%을 보였다.

Abstract

In this paper, we propose a classification algorithm based on the obtained EEG(Electroencephalogram) signal for the control of 'left' and 'right' turnings of which a driving system composed of EEG sensor, Labview, DAQ, Matlab and driving robot. The proposed algorithm uses features extracted from frequency band information obtained by DWT(Discrete Wavelet Transform) and selects features of high discrimination by using Fisher score. We, also propose the number of feature vectors for the best classification performance by using SVM(Support Vector Machine) classifier and propose a decision pending algorithm based on MLD(Maximum Likelihood Decision) to prevent malfunction due to misclassification. The selected four feature vectors for the proposed algorithm are the mean of absolute value of voltage and the standard deviation of d5(2-4Hz) and d2(16-32Hz) frequency bands of P8 channel according to the international standard electrode placement method. By using the SVM classifier, we obtained 98.75% accuracy and 1.25% error rate. Also, when we specify error probability of 70% for decision pending, we obtained 95.63% accuracy and 0% error rate by using the proposed decision pending algorithm.

Keywords : EEG signal, DWT, SVM, Fisher score, MLD

I. 서 론

뇌파 연구는 의학, 공학, 심리학 등 여러 분야의 융합이 필요한 연구이다. 최근 정보산업사회가 고도화되면서 뇌 정보를 처리하고 모델링 및 공학적 구현을 하는 IT와 BT가 융합된 연구가 주목받고 있다. 뇌 정보 처

* 학생회원, ** 정회원, 제주대학교 해양시스템공학과 (Jeju National University)

Ⓢ Corresponding Author(E-mail: chonglee@jejunu.ac.kr)

※ 이 논문은 2015학년도 제주대학교 학술진흥연구비 지원사업에 의하여 연구되었음.

Received ; March 11, 2015 Revised ; May 8, 2015

Accepted ; July 28, 2015

리 및 모델링 연구는 게임 분야와 로봇 제어 분야에서 많이 응용되고 있다. 이러한 연구에서는 뇌 정보 처리를 위해 BCI(Brain Computer Interface) 기술이 사용되며 이 기술은 자발적 전기신호인 뇌파를 이용하여 두뇌의 정보처리 결과를 언어 및 신체활동을 거치지 않고 시스템에 전달할 수 있도록 만들어 준다.

뇌 정보 처리를 위한 연구에서는 주로 EEG(Electroencephalogram) 신호를 분석한다. EEG 신호는 두피에서 기록되는 자발적 전기신호로 μV 단위로 나타나는 미세한 신호이다. EEG 신호는 Alpha(8-13Hz), Beta(13-30Hz), Theta(4-8Hz), Delta(0-4Hz)로 구분되며 이 주파수 대역들은 무의식 상태와 깨어있는 의식 상태를 반영한다.

최근 EEG 신호를 이용하여 제어 시스템을 구축하기 위한 연구가 진행되고 있으며, 특히 방향을 제어하기 위한 다양한 연구가 진행되었다. 지금까지 진행된 연구로는 손가락 움직임에 따른 EEG 신호 및 손의 움직임을 상상함으로써 취득된 EEG 신호를 이용한 방향 제어연구가 있다^[17]. 또한 방향과 관련된 시각정보 및 Beta (13-30Hz) 주파수 대역의 분석을 통한 집중상태와 휴식상태의 EEG 신호를 이용한 방향 제어 연구가 있다^[5,6]. 선행된 연구들은 방향을 제어하기 위하여 시각정보, 집중과 비 집중 및 신체의 움직임에 의해 취득되는 EEG 신호를 사용한다. 이러한 EEG 신호는 방향을 제어하고자 하는 간접적인 행위에 의해 취득되는 신호라는 점에서 한계를 가지고 있다. 그러나 본 논문에서는 다른 정보는 사용하지 않고 주로 ‘좌’, ‘우’로 제어하고자 하는 의지를 가지는 생각만을 사용하는 EEG 신호 분류 알고리즘을 제안한다. 제안된 알고리즘은 DWT(Discrete Wavelet Transform)와 SVM(Support Vector Machine)을 기반으로 방향 제어를 위한 ‘좌’, ‘우’ 생각에 의해 취득된 EEG 신호를 분류한다. 제안된 알고리즘은 최적의 특징벡터를 얻기 위해 Fisher score를 사용한다. 또한 본 논문에서는 잘못된 분류에 따른 위험을 방지하기 위한 판정보류 알고리즘도 제안한다. 판정보류 알고리즘은 ‘좌’와 ‘우’에 대한 오분류를 정의하고, 이러한 오분류를 방지하기 위하여 MLD(Maximum Likelihood Decision)를 기반으로 판정을 보류하는 것이다. 끝으로 본 논문에서는 제안된 EEG 신호 분류 알고리즘을 기반으로 EEG 센서, Labview, DAQ, Matlab, 주행로봇으로 구성된 방향 제어 시스템도 함께 제안한다. 본 논문에서 제

안하는 시스템의 주행로봇은 ‘좌’, ‘우’, ‘정지’의 세 가지 동작을 가지며, 제안된 시스템을 통해 EEG 신호 분류 알고리즘을 검증한다.

II. EEG 신호 분류 알고리즘

1. DWT(Discrete Wavelet Transform)를 이용한 특징추출 및 선택

본 논문에서 분류를 위한 EEG 신호 특징추출을 위하여 DWT를 이용하여 주파수대역을 나누었다. DWT는 다해상도 분석을 가능하게 함으로써 영상처리 분야에서 널리 사용되고 있는 알고리즘으로 정규 직교 웨이블릿을 이용하여 신호를 이분 주파수 대역으로 사영하는 것을 의미한다^[7]. DWT는 저역통과필터와 고역통과필터를 사용해 신호를 두 대역으로 나누고, 그 결과 데이터를 절반만 취하는 Down sampling 과정을 수행한다. 이 과정은 첫 번째 단계의 분해이며, 이 과정에서 출력되는 신호 $Y[n]$ 은 식 (1)과 식 (2)로 표현할 수 있다.

$$Y_{low}[n] = \sum_{k=-\infty}^{\infty} x[k]g[2n-k] \tag{1}$$

$$Y_{high}[n] = \sum_{k=-\infty}^{\infty} x[k]h[2n-k] \tag{2}$$

여기서 $x[k]$ 는 분해하기 위한 신호를 나타내며, $g[k]$ 는 저역통과필터, $h[k]$ 는 고역통과필터를 나타낸다.

이후 저역통과필터에 여과된 신호에 전 과정과 동일한 방법을 적용하여 대역을 나눈다. 이러한 과정을 원하는 단계까지 반복한다. 그림 1은 2단계의 DWT 수행 과정을 보여준다.

본 논문에서 EEG 신호 분류를 위해 DWT 결과 추출된 주파수대역에서 전압의 절대 값 평균, 전력의 평균, 표준편차, 분산의 4가지 특징을 추출하며, 분류를 위한 특징벡터를 선택하기 위해 Fisher score를 사용하




그림 1. 2단계 DWT 필터뱅크
Fig. 1. 2level DWT filter bank.

여 특징벡터의 변별력을 분석한다. Fisher score는 클래스 내 분산을 척도로 평균 간의 차이를 정규화하여 함수로 표현하고 이 목적함수를 최대화하는 방법이다^[8]. Fisher score 계산식은 식 (3)과 같이 표현된다.

$$J = \frac{|\tilde{w}^T S_B \tilde{w}|}{|\tilde{w}^T S_W \tilde{w}|}$$

$$S_B = \sum_{i=1}^C N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (3)$$

$$S_W = \sum_{i=1}^C \sum_{y \in \omega_i} (y - \mu_i)(y - \mu_i)^T$$

$$\tilde{w} = [1, \dots, 1]^T$$

여기서 S_W 는 각 클래스에 대한 클래스 내 분산, S_B 는 클래스 간 분산, C 는 전체 클래스 수, N_i 는 i 클래스의 데이터 수, y 는 추출된 주파수대역의 4가지 특징의 특징벡터를 나타낸다. 또한 μ 와 μ_i 는 각각 평균과 i 클래스의 평균을 나타낸다.

2. SVM(Support Vector Machine)을 이용한 EEG 신호 분류

본 논문에서 EEG 신호 분류를 위해 SVM 분류기를 사용하였다. SVM은 데이터 마이닝 분야 및 얼굴인식과 패턴인식 응용 분야에 널리 사용되고 있는 알고리즘이다^[9]. 본 논문에서 사용하는 선형 SVM 분류를 위한 결정 초평면은 식 (4), (5)와 같다.

$$W^T X + b < 0 \quad (4)$$

$$W^T X + b > 0 \quad (5)$$

여기서 $X = (x_1, x_2, \dots, x_d)^T$ 로 X 는 샘플을 나타내는 특징벡터이며, W 와 b 는 결정 초평면을 정의하는 매개변수이다^[9~10]. 위 SVM 결정 초평면에서 수식 (4)는 -1class, 수식 (5)는 +1class를 나타낸다.

본 논문에서 오분류를 최소화하기 위해 판정보류처리 범위를 지정하여 SVM 결과 +1class, -1class로 분류하기 어려움이 있는 데이터의 판정을 보류하였다. 식 (6)은 판정보류처리 범위를 나타낸다.

$$\varepsilon_1 \leq W^T X + b \leq \varepsilon_2 \quad (6)$$




그림 2. 판정보류 변수 지정 방법

Fig. 2. Method for judgement pending variable appointment.

식 (6)에서 $\varepsilon_1, \varepsilon_2$ 는 판정보류 변수라 정의하고 판정보류 변수는 가우스 분포 특성을 가지는 확률밀도함수와 MLD에 의해 최대우도비가 되는 지점을 기반으로 결정되어진다. 가우시안 분포 특성을 가지는 확률밀도함수의 우도비는 식 (7)과 같이 표현된다.

$$\Lambda(z) = \frac{p(z|m_1, \sigma_1^2)}{p(z|m_0, \sigma_0^2)} = \frac{\sigma_0}{\sigma_1} \exp \left[\frac{1}{2} \left\{ \frac{(z - m_0)^2}{\sigma_0^2} - \frac{(z - m_1)^2}{\sigma_1^2} \right\} \right] \quad (7)$$

여기서 z 는 식 (4), (5)에서 $W^T X + b$ 를 의미하며, m 과 σ^2 은 평균과 분산을 의미한다. 식 (4), (5)에서 각 클래스의 확률밀도함수가 가우시안 분포 특성을 가진다고 가정하고 식 (7)에서 $\Lambda(z) = 1$ 로 지정하면 최대우도비가 되는 지점 z 를 얻을 수 있다.

본 논문에서 판정보류처리 변수를 지정하기 위해 최대우도비가 되는 지점을 기준으로 각 클래스의 오류율을 계산한 후 최대우도비가 되는 지점으로부터 계산된 오류율의 70%가 되는 지점을 판정보류 변수로 지정하였다. 그림 2는 판정보류 변수를 지정하는 방법을 보여준다.

III. 실험 및 결과

1. 데이터 수집

EEG 신호를 수집하기 위해 Emotiv EPOC Headset을 사용하였다. 이 장비는 128Hz의 표본화율을 가지




그림 3. Emotiv EPOC Headset의 전극부착 위치^[11]
 Fig. 3. Electrode position of Emotiv EPOC Headset^[11].




그림 4. P8 채널 ‘좌’에 대한 생각에 따른 DC offset이 제거된 EEG 신호
 Fig. 4. EEG signal that DC offset is removed in accordance with the thought for ‘left’ at P8 channel.

며, Bluetooth를 이용하여 무선 데이터 전송 시스템을 갖춘 BCI를 구축한다^[11]. Emotiv EPOC Headset은 총 14개의 수신센서를 가지고 있으며, 각 센서는 국제 표준 전극 배치법에 따라 AF3, AF4, F3, F4, F7, F8, FC5, T7, T8, P7, P8, O1, O2 채널에 위치한다^[11]. 그림 3은 Emotiv EPOC Headset의 각 채널의 전극부착 위치를 보여주며, 그림 4는 DC offset이 제거된 P8 채널의 ‘좌’에 대한 제어하고자 하는 생각의 EEG 신호이다.

피 실험자는 센서를 장착한 후 ‘좌’, ‘우’로 제어하고자 하는 생각을 한다. 동시에 BCI를 이용하여 피 실험자의 EEG 신호를 수집한다. EEG 신호의 수집은 집중력이 중요한 요소로 작용하며 외부 자극에 영향을 받기 쉬우므로 사람이 없고 조용한 시각, 청각 및 후각 등에 영향을 받지 않는 장소에서 이루어졌다. 피 실험자는 센서 착용 후 10초씩 5번 데이터를 수집하고 30초 휴식을 가졌다. 이 과정을 통해 ‘좌’, ‘우’ 각각 10개 총 20개의 훈련 데이터를 얻었으며, 각각 80개 총 160개의 Test 데이터를 얻었다.

2. 특징추출 및 선택

본 논문에서는 EEG 신호 특징추출을 위해 5단계의 DWT 과정을 수행한다. EEG 신호는 0-64Hz의 주파수




그림 5. DWT를 이용하여 얻은 주파수 대역
 Fig. 5. Obtained frequency bands by DWT.

표 1. Fisher score 기반의 P8채널의 주파수 대역 별 특징벡터의 내림차순 정렬
 Table 1. Descending array of feature vectors in each frequency band at P8 channel based on fisher score.

주파수 대역	특징
abs(d5)	전압의 절대 값 평균
std(d5)	표준편차
std(d2)	표준편차
abs(d2)	전압의 절대 값 평균
pow(d5)	전력의 평균
var(d5)	분산
std(d4)	표준편차
std(d3)	표준편차
abs(d4)	전압의 절대 값 평균
abs(d3)	전압의 절대 값 평균
pow(d2)	전력의 평균
var(d2)	분산
pow(d3)	전력의 평균
var(d3)	분산
var(d4)	분산
pow(d4)	전력의 평균

대역을 가지며, 주로 Alpha(8-13Hz), Beta(13-30Hz), Theta(4-8Hz), Delta(0-4Hz)로 구분된다. Alpha와 Beta는 깨어 있는 의식 상태를 반영하고 Theta와 Delta는 무의식상태를 반영한다^[12]. 이러한 점에서 기존의 주파수 대역은 본 논문에 그대로 적용하는데 어려움이 있지만, EEG 신호는 0-30Hz에 유의미한 신호가 있음을 확인할 수 있다. 또한 본 논문에서 사용하는 EEG 센서로 취득된 신호는 0-2Hz와 32-64Hz 주파수 대역에서 많은 잡음 성분을 가진다. 이러한 EEG 신호의 기존 주파수 대역과 본 논문에서 사용되는 EEG 센서의 시스템 잡음 특성을 고려하여 DWT를 이용하여 특징추출에 적합한 주파수 대역을 추출하였다. DWT 수행 결과 d1(32-64Hz), d2(16-




그림 6. Fisher score 결과
Fig. 6. Fisher score results.

32Hz), d3(8-16Hz), d4(4-8Hz), d5(2-4Hz)의 주파수 대역을 얻었다. d1(32-64Hz) 대역과 저역통과필터를 통과하여 얻어진 주파수 대역들은 많은 잡음 성분을 포함하고 있으므로 분류를 위한 특징추출에 사용하지 않으며, 분류를 위한 특징추출에는 d2(16-32Hz), d3(8-16Hz), d4(4-8Hz), d5(2-4Hz)의 대역을 사용한다. 그림 5는 DWT 수행 결과 얻게 되는 주파수 대역과 분류를 위해 사용하는 주파수 대역을 보여준다.

총 14개 채널에서 앞서 추출한 4개의 주파수 대역에서 각각 4개의 특징을 추출하여 총 224개의 특징벡터를 얻었다. 각 특징벡터의 변별력을 확인하기 위해 Fisher score를 계산하여 정규화한 결과, P8 채널의 특징벡터들이 다른 채널의 특징벡터들보다 높은 Fisher score를 나타내어 가장 우수한 변별력을 가지고 있음을 확인하였다. 그림 6은 각각의 특징벡터들의 정규화된 Fisher score를 보여주며, 표 1은 그림 6에서 가장 높은 변별력을 보이는 P8채널의 특징벡터들을 Fisher score에 따라 내림차순으로 보여준다.

분류를 위한 최적의 특징벡터 개수를 얻기 위해 가장 높은 Fisher score를 보이는 P8채널의 특징벡터들을 높은 Fisher score순으로 차례대로 개수를 늘려가며 분류 정확도를 계산하였다. 이때 분류 정확도는 좌, '우' 각각 10개 총 20개의 훈련 데이터로 SVM 분류기를 학습시키고, 각각 80개 총 160개의 Test 데이터로 SVM 분류 결과를 얻어 계산하였다. 그림 7은 Fisher score가 높은 순으로 특징벡터들의 개수를 늘려가며 SVM 분류 정확도를 계산한 값을 보여준다. 그림 7에서 4개의 특징벡터를 사용할 경우 가장 높은 분류 정확도를 보이며, 표

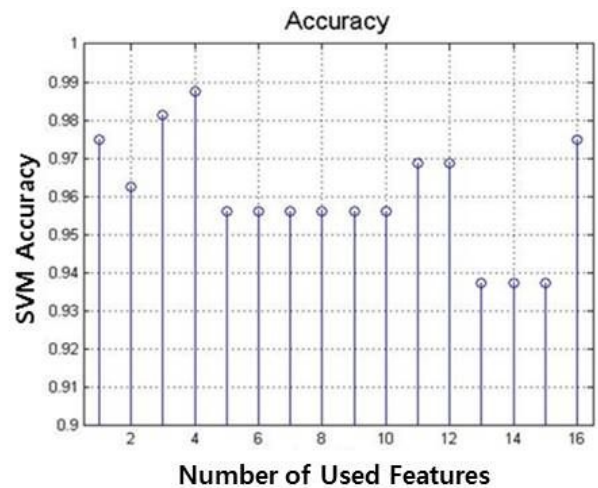


그림 7. 특징벡터의 개수에 따른 SVM 분류의 정확도
Fig. 7. Accuracy of SVM classification in accordance with the number of feature vectors.

1에서 4가지 특징벡터는 P8 채널의 d2(16-32Hz), d5(2-4Hz) 주파수 대역의 전압의 절대 값 평균과 표준편차임을 확인 할 수 있다.

3. SVM(Support Vector Machine) 분류 결과

본 논문에서 EEG 신호 분류를 위해 최대 마진을 갖는 최적 분류 초평면을 찾아 최적의 대역적인 식별이 가능하며, EEG 신호 분류에 주로 이용되는 LDA (Linear Discriminant Analysis)와 비교하여 우수한 성능이 입증된 SVM 분류기를 사용한다^[9, 13-15]. SVM 분류를 위한 특징벡터는 분류 정확도가 가장 높은 P8 채널의 d5(2-4Hz), d2(16-32Hz) 주파수 대역의 전압의 절대 값 평균과 표준편차를 사용한다.

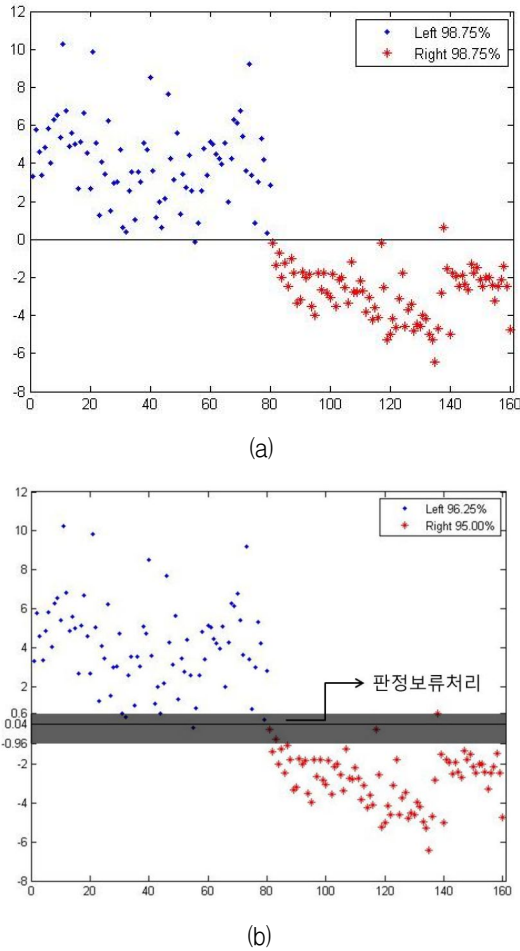


그림 8. SVM 분류 결과. (a) 판정보류 처리 전 SVM 분류 결과, (b) 판정보류 처리 후 SVM 분류 결과
 Fig. 8. SVM classification results. (a) SVM classification results before judgement pending processing, (b) SVM classification results for judgement pending processing.

앞서 분류 정확도를 측정한 방법과 동일하게 SVM 분류를 한 결과 ‘좌’, ‘우’ 각각 1개의 오분류 데이터를 가졌다. 즉 ‘좌’ 98.75%, ‘우’ 98.75%의 정확도와 1.25%의 오류율을 가진다.

오분류로 인한 잘못된 판정을 방지하기 위해 식 (6)과 같이 판정보류처리 범위를 지정해 주었다. 본 논문에서 SVM 분류 결과 각 클래스의 확률 밀도 함수는 ‘좌’, ‘우’ 각각 평균 4.08, 분산 4.66과 평균 -2.79, 분산 1.80으로 가우시안 분포 특성을 가지며, 앞서 언급한 판정보류 변수 지정 방법에 따라 최대우도비를 갖는 지점 0.04를 기준으로 판정보류 변수를 지정한 결과 $\epsilon_1 = -0.96$, $\epsilon_2 = 0.6$ 의 값을 가진다. 판정보류 변수를 기준으로 판정보류처리 범위 지정 결과 ‘좌’ 96.25%, ‘우’ 95%의 정확

표 2. 판정보류 처리 전과 후 SVM 분류 정확성 및 오류율

Table 2. Accuracy and Error rate for SVM classification before and after judgement pending processing.

	판정보류 처리 전 결과	판정보류 처리 후 결과
좌	98.75%	96.25%
우	98.75%	95.00%
Error	1.25%	0%

도와 0%의 오류율을 가졌다. 이때 판정보류처리 범위에 따른 판정보류 데이터는 8.75%를 차지한다. 그림 8의 (a)는 판정보류 범위 지정 전 SVM 분류 결과를 보여주며, (b)는 판정보류 처리 범위 지정 후 SVM 분류 결과를 보여준다. 또한 표 2는 판정보류 처리 범위 지정 전과 후의 SVM 분류 결과를 보여준다.

4. EEG 신호를 이용한 주행로봇 시스템

실험을 통해 얻은 EEG 신호 분류 결과를 이용하여 주행로봇을 제어하였다. 이 주행로봇은 Starter Robot Kit V2.0-Blue를 구동부로 사용한다. 이 주행로봇은 6V의 전압이 요구되고 185rpm의 DC Motor-25(Makeblock, China)를 사용하며, 이 주행로봇의 제어부인 Me BaseBoard V1.0(Makeblock, China)는 Labview를 이용한 제어 신호 생성을 위하여 NI myDAQ(National instruments, USA)으로 대체하였다^[17~18].

본 논문에서 제안하는 시스템은 분류를 위한 최적의 특징벡터를 선택하고 분류 초평면을 결정하기 위해 DWT, Fisher score, SVM기반의 전처리 과정을 수행한다. 또한 방향제어를 위해 입력된 EEG 신호에서 선택된 특징들을 추출하고 SVM과 제안된 판정보류 알고리즘을 이용하여 신호를 분류한다. 분류 결과에 따라 주행로봇은 ‘좌’, ‘우’, ‘정지’의 3가지 동작을 취한다. 여기서 ‘정지’는 판정보류에 따른 결과이다. 그림 9는 주행로봇을 제어하기 위한 시스템 블록도를 보여주며, 그림 10은 EEG 신호를 이용한 주행로봇 제어 시스템을 보여준다. 그림 10의 (a)는 주행로봇 제어 시스템의 구성을 보여주며, (b)는 센서에서 PC로 입력되는 P8채널의 EEG 신호, (c)는 SVM 분류결과, (d)는 EEG 신호 분류결과에 따라 Labview에서 주행로봇에 전달하는 제어신호이다. 그림 10의 (b), (c), (d)에서 ‘좌’에 대한 EEG 신호가 입력되었을 경우에 Labview에서 주행로봇

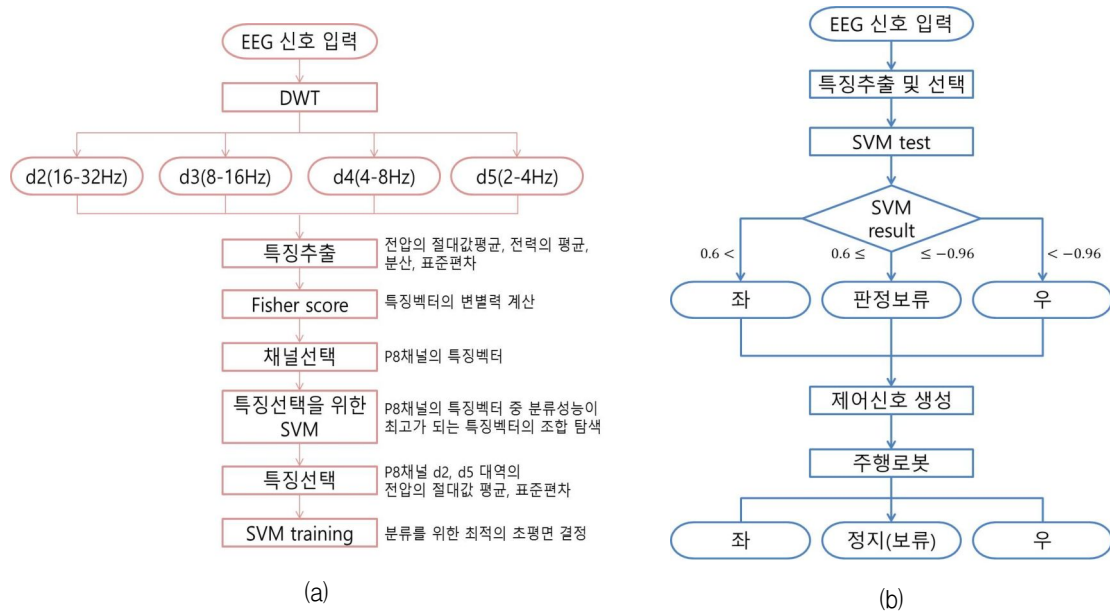


그림 9. (a) 전처리 및 훈련 과정, (b) 주행로봇 제어 블록도
Fig. 9. (a) Preprocessing and training process, (b) Block diagram of driving robot system.

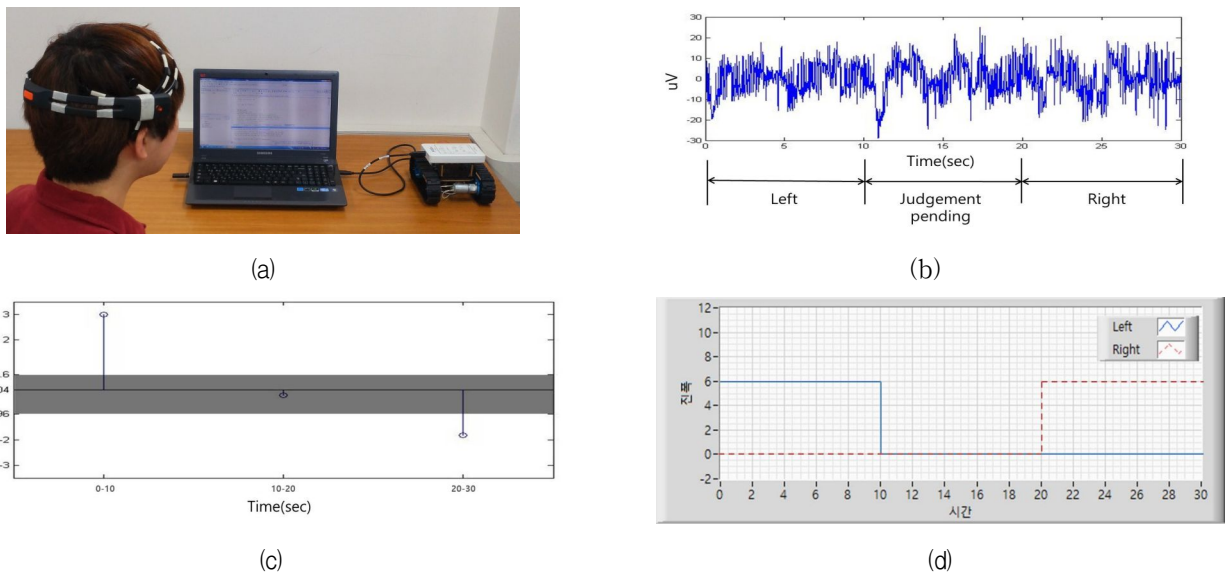


그림 10. EEG 신호를 이용한 주행로봇 시스템. (a) 주행로봇 및 제어부, (b) P8채널 EEG 신호, (c) SVM 분류결과, (d) EEG 신호 분류결과에 따른 모터제어신호
Fig. 10. Driving robot system using EEG signal. (a) Driving robot and controller, (b) EEG signal of P8channel, (c) SVM classification results, (d) Motor control signal according to EEG signal classification results.

에 '좌'로 제어하기 위한 신호를 보내며, '우'에 대한 EEG 신호가 입력되었을 경우에 '우'로 제어하기 위한 신호를 보내는 것을 확인할 수 있다. 또한 '좌', '우'로 판정하기 어려운 EEG 신호가 입력되어 판정이 보류되었을 경우에 어떠한 제어신호도 전달하지 않아 정지 상태를 유지시키는 것을 확인할 수 있다.

IV. 결 론

본 논문에서는 방향 제어를 위한 EEG 신호 분류 알고리즘을 제안하고 주행로봇을 제어함으로써 제안된 알고리즘을 검증하였다. 제안된 알고리즘은 DWT, Fisher score, SVM을 기반으로 구성되며, MLD를 기반으로 판

정보류처리 알고리즘도 포함한다. DWT 결과 추출된 주파수대역의 특징벡터에서 변별력을 계산하고, 분류에 적합한 특징벡터의 개수를 얻은 결과 4가지 특징벡터, P8 채널 d2(16-32Hz), d5(2-4Hz) 주파수 대역의 전압의 절대 값 평균과 표준편차를 선별하였다. 선별된 4가지 특징벡터를 이용하여 SVM 분류한 결과 ‘좌’ 98.75%, ‘우’ 98.75%, ‘오류율’ 1.25%의 결과를 얻었다. 또한 제안된 MLD 기반의 판정보류처리 알고리즘을 사용한 결과, 최대우도비 지점을 기준으로 오류율의 70%를 판정보류처리 범위로 정할 경우, ‘좌’ 96.25% 인식률, ‘우’ 95% 인식률 ‘오류율’ 0%의 결과를 얻었다. 끝으로 제안된 알고리즘을 기반으로 EEG 센서, Labview, DAQ, Matlab, 주행로봇으로 구성된 주행로봇 방향 제어 시스템도 함께 제안하였다. 이로써 제안된 분류 알고리즘의 정확도와 안정성을 확인하였다.

기존의 연구들과 달리 시각정보 및 신체의 움직임과 같은 다른 정보는 사용하지 않고 주로 ‘좌’, ‘우’로 제어하고자 하는 의지를 갖는 생각만을 사용하는 EEG 신호를 분류한 본 연구는 방향 제어를 위한 기존의 EEG 신호 분류 연구들이 약 80-90%의 정확도를 갖는 것과 비교하여 조금 더 높은 정확도를 가지고 있음을 확인했다^[1~6]. 또한, 판정보류 알고리즘을 사용함으로써 잘못된 판단으로 인한 오동작을 방지할 수 있어 향후 EEG 신호를 이용한 방향 제어연구에 크게 기여할 수 있을 것이라 기대한다.

주로 개인적인 생각에 의해 취득되는 EEG 신호는 개인적인 편차가 존재하게 되는데, 이를 해결하여 일반화할 수 있는 연구가 향후 진행되어야 할 것이다. 또한 ‘좌’, ‘우’ 뿐만 아니라 다른 방향에 대한 연구와 판정보류 보류 이후의 실제적인 움직임에 대한 연구가 향후 진행되어야 할 것이다.

REFERENCES

[1] M. Congedo, F. Lotte and A. Lécuyer, “Classification of movement intention by spatially filtered electromagnetic inverse solutions”, *Physics in Medicine and Biology*, Vol. 51, No. 8, pp. 1971-1989, April, 2006

[2] Wenjie Xu, Cuntai Guan, Chng Eng Siong, S. Ranganatha, M. Thulasidas and Jiankang Wu, “High Accuracy Classification of EEG signal”, In 17th

International Conference on Pattern Recognition (ICPR'04), Vol. 2, pp. 391-394, August, 2004

[3] F. Galan, M. Nuttin, E. Lew, P.W. Ferrez, G. Vannacker, J. Philips, J. del R. Millan. “A brain-actuated wheelchair: Asynchronous and non-invasive Brain-computer interfaces for continuous control of robots”, *Clinical Neurophysiology*, Vol. 119, No. 9, pp. 2159-2169, June, 2008

[4] Luca Tonin, Robert Leeb, Michele Tavella, Serafim Perdakis, Jose del R. Millan, “The role of shared-control in BCI-based telepresence”, 2010 IEEE International Conference on System Man and Cybernetics, pp. 1462-1466, October, 2010

[5] Myeong-Chun Lee, Sung-Bae Cho, “Brain-Computer Interface Implementation for Controlling Electroencephalograph Based 3D Virtual Car Simulator”, *KCC Fall Conference*, Vol. 39, No. 2(B), pp. 280-282, November, 2012

[6] Hong Kee Kim, Ki Hong Kim, Jong Sung Kim, Wook Ho Son, “A Control method of Left-Right directions by analyzing EEG Signals”, *HCI 2006*, pp. 1005-1010, February, 2006

[7] Seung Hoon Lee, Dong Han Yoon, *Introduction to the Wavelet Transform*, Jinhan Books, 2003

[8] Jaeil Lee, Youn Joung Kang, Chong Hyun Lee, Seung Woo Lee and Jinho Bae, “Analysis of Features and Discriminability of Transient Signals for a Shallow Water Ambient Noise Environment”, *Journal of the Institute of Electronics and Information Engineers*, Vol. 51, No. 7, pp. 209-220, July, 2013

[9] Hag Yong Han, *Introduction to Pattern Recognition*, Hanbit media, 2009

[10] Hun jun Yang, Kyung Bo Hong and Dong Seok Jeong, “Road Surface Condition detect using Wavelet transform and SVM Classifier”, in *Proc. of IEEE autumn Conf.*, pp. 592-595, Seoul, Korea, November, 2012

[11] Emotiv Systems, *Emotiv - brain computer interface technology*, <http://emotiv.com>

[12] Seung Ho Lee, “Meditation and EEG”, *Journal of Korean Institute of Brain Science*, Vol.50, pp. 32-39, January, 2015

[13] D. Garrett, D. A. Peterson, C. W. Anderson, M. H. Thaut, “Comparison of linear, nonlinear, and feature selection methods for eeg signal classification” *IEEE Transactions on Neural System and Rehabilitation Engineering*, Vol. 11, No. 2, pp. 141-144, June, 2003

[14] G. N. Garcia, T. Ebrahimi, J. M. Vesin, “Supp

port vector eeg classification in the fourier and time-frequency correlation domains”, In Conference Proceedings of the First International IEEE EMBS Conference on Neural Engineering, pp. 591-594, March, 2003

[15] B. Blankertz, G. Curio, K. R. Muller, “Classifying single trial eeg: Towards brain computer interfacing” Advances in Neural Information Processing Systems (NIPS 01), Vol. 14, pp. 11-22, 2004.

[16] Youn Jung Kang, Jaeil Lee, Jinho Bae and Chong Hyun Lee, “Target Classification Algorithm Using Complex-valued Support Vector Machine”, Journal of the Institute of Electronics and Information Engineers, Vol. 50, No. 4, pp. 182-188, April 2013

[17] Makeblock, *Starter Robot kit V2.0*, <http://www.makeblock.cc>.

[18] National instruments, *NI myDAQ Specifications*, <http://digital.ni.com>.

저 자 소 개



이 기 배 (학생회원)
2012년~현재 제주대학교 해양
시스템공학과 학사과정.
<주관심분야 : 통계학적 신호처리,
패턴인식, 생체 신호처리>



이 종 현 (정회원)-교신저자
1985년 한양대학교 전자공학과
학사 졸업.
1987년 Michigan Technological
University 석사 졸업.
2002년 한국과학기술원(KAIST)
전기 및 전자공학과 박사
졸업.

1990년~1995년 한국전자통신연구원 선임연구원.
2000년~2002년 (주)KM Telecom 연구소장.
2003년~2006년 서경대학교 전자공학과 전임강사
2006년~현재 제주대학교 해양시스템공학과
교수.

<주관심분야 : 통계학적 신호처리, 적응 배열 시스템,
수중 및 이동 통신, UWB 무선전송기술>



배 진 호 (정회원)
1993년 아주대학교 전자공학과
학사 졸업.
1996년 한국과학기술원(KAIST)
정보통신공학과
석사 졸업.
2001년 한국과학기술원(KAIST)
전자전산학과 박사 졸업.

1993년~2002년 (주)대양전기공업 실장.
2002년~2002년 한국과학기술원(KAIST)
BK21 초빙교수.
2006년~2007년 Texas A&M 방문교수.
2013년~2014년 UC Santa Cruz 방문교수.
2002년~현재 제주대학교 해양시스템공학과
교수.

<주관심분야 : 광신호처리 및 통신, 레이더 및 소
나 신호처리, 인쇄전자 소재 및 소자, 항해 시스템>



이 재 일 (학생회원)
2009년 제주대학교 해양산업공학
전공 학사 졸업.
2011년 제주대학교 해양 정보
시스템공학과 석사 졸업.
2011년~현재 제주대학교 해양
시스템공학과 박사과정.

<주관심분야 : 통계학적 신호처리, 센서 신호처리,
Parametric Array, 수중통신>