AR계수와 SVM을 이용한 뇌파 기반 운전자의 졸음 감지 시스템

Electroencephalogram-based Driver Drowsiness Detection System Using AR Coefficients and SVM

한형섭 · 정의필[†]

Hyungseob Han and Uipil Chong[†]

울산대학교 전기공학부

School of Electrical Engineering, University of Ulsan

요 약

운전 중 운전자의 졸음은 교통 사망사고를 일으키는 중요한 요인이며 음주운전보다도 더 위험할 수 도 있다. 이러한 이유로 운전자의 졸음을 판별하고 경고하는 시스템 개발이 최근에 매우 중요한 이슈로 떠올랐다. 그중에서도 졸음과 가장 밀접한 관련이 있는 생체 신호 분석이 많이 적용되는데 그중에서도 뇌파(Electroencephalogram, EEG)와 안구전도(Electrooculogram, EOG)를 분석하는 연구가 주류를 이루고 있다. 본 논문에서는 실험 프로토콜을 바탕으로 측정된 뇌파를 주파수별로 분석하여 운전자의 상태별 뇌파 데이터베이스를 구축하였고 선형예측(Linear Predictive Coding, LPC) 계수와 Support Vector Machine(SVM)을 이용한 운전자 졸음 감지 시스템을 제안한다. 실험결과로 졸음의 뇌파분석에서 알파파가 감소하며 세타파가 증가하는 추세를 보였으며, LPC 계수가 각성, 졸음 및 수면상태의 특징을 잘 반영하였다. 특히 제안한 시스템은 적은 샘플(250ms)에서도 96.5%의 높은 분류 결과를 얻어 짧은 순간에 일어날 운전시 돌발 상황을 실시간으로 예측할 수 있는 가능성을 보였다.

키워드 : 뇌파, 졸음운전, 선형예측계수, 서포트 벡터 머신, 신경회로망

Abstract

One of the main reasons for serious road accidents is driving while drowsy. For this reason, drowsiness detection and warning system for drivers has recently become a very important issue. Monitoring physiological signals provides the possibility of detecting features of drowsiness and fatigue of drivers. One of the effective signals is to measure electroencephalogram (EEG) signals and electrooculogram (EOG) signals. The aim of this study is to extract drowsiness-related features from a set of EEG signals and to classify the features into three states: alertness, drowsiness, sleepiness. This paper proposes a drowsiness detection system using Linear Predictive Coding (LPC) coefficients and Support Vector Machine (SVM). Samples of EEG data from each predefined state were used to train the SVM program by using the proposed feature extraction algorithms. The trained SVM program was tested on unclassified EEG data and subsequently reviewed according to manual classification. The classification rate of the proposed system is over 96.5% for only very small number of samples (250ms, 64 samples). Therefore, it can be applied to real driving incident situation that can occur for a split second.

Key Words : EEG, Driver Drowsiness, Linear Predictive Coding, SVM, Neural Network.

1. 서 론

접수일자: 2012년 8월 15일

심사(수정)일자: 2012년 10월 22일

게재확정일자: 2012년 10월 29일

[†] Corresponding author

본 논문은 2012년 울산대학교 전기공학부 일류화사업으로 수행되었습니다.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

졸음은 각성과 수면의 중간상태에서 의식이 사라지면서 수면으로 진행 과정으로 정의한다. 특히 운전과 같은 특별한 과업에서 졸음은 매년 교통사고의 원인에 상당히 기여하고 있는 위험 요인 중의 하나이다[1]. 실제로 2010년 한국도로교통공단의 통계에 따르면 고속도로 교통사고 사망자 3명 중 1명은 졸음운전으로 집계되었다. 운전 시 졸음이 영향을 미치는 치명적인 측면 중에서는 느린 반응속도, 줄어드는 각성상태와, 정보처리의 부족 등이 운전 작업을 비정상적으로 이끌게 한다[2]. 피로는 졸음을 일으킬 수 있는 요인 중 하나이다. 휴식과 휴업으로 피로를 경감시킬 수 있지만 오히려 이것이 졸음을 더욱더 유발시킨다는 연구결과가 있어 졸음 현상을 따로 분석하는 것이 효과적이다[3].

졸음 감지에 대한 기존 연구는 눈의 깜빡거림(blinking),

동공의 크기, 눈의 응시방향, 얼굴표정을 카메라로 촬영하여 영상처리 기술을 적용하는 비전기반 졸음감지 연구가 주류를 이루었다[4]. 또한 스트레스와 말초체온과의 상관관계[5], 심박수의 변화[6], 피부 임피던스 신호분석[7]을 통한 졸음 감지 연구 논문도 발표되었다. 그러나 위의 방법으로는 졸음신호에 대한 명확한 해석이 어렵다는 단점이 있고, 눈동자의 움직임과 근육의 변화는 이미 졸음이 상당히 진행된 상태이므로 졸음의 근본적인 원인을 밝힐 수 있는 신호 선취득과 분석방법이 필요하다.

뇌파(Electroencephalogram, EEG)와 안구전도(Electrooculogram, EOG)를 통한 눈 깜빡거림에 대한 육안 검사가 운전자의 피로와 졸음을 판별하는데 신뢰적이라는 의학적 연구결과를 발표하였다[8]. 운전자는 정신적 피로감이 증가할 때 높은 각성 상태를 유지할 수 없으며 이는 뇌파의 알파와 세타파의 활동량의 일관된 변화와 상관관계가 높다는 것을 보였다. 뇌파분석은 주로 스펙트럼 성분들의 변화를 관찰하는 연구가 주로 진행되었으며 많은 연구자들이 스펙트럼 분석을 기반으로 하여 뇌파의 델타파, 세타파, 알파파, 베타파와 운전 중 졸음의 상호연관관계를 발견하였다[9,10]. 근래의 졸음 연구에 따르면 운전 시 졸음은 운전자가 각성상태를 유지하려고 노력하는 점에서 일반적인 졸음 연구와 차이가 있었고 운전시의 발생하는 각성과 졸음상태의 천이 단계는 Hori's 수면 1단계와 깊은 연관이 있다는 것을 보였다[11, 12]. 이러한 연구결과를 토대로 본 연구는 뇌파분석이 운전자의 졸음상태를 근본적으로 분석하기에 적합하다고 판단하여 실험 프로토콜을 바탕으로 상태별 뇌파를 측정하고 분석하였다.

본 논문은 짧은 시간에 높은 해상도를 가지는 AR모델을 적용하여 뇌파신호의 특징벡터를 추출하고 판단하는 AR 기반 선형예측(Linear Predictive coding, LPC) 계수기반 Multi-class SVM 을 이용한 운전자의 상태별 뇌파 판별 시스템을 제안한다.

본 논문의 구성은 다음과 같다. II장에서는 전체적인 졸음 감지 시스템을 소개하고 데이터 취득 방법, 실험 프로토콜, LPC 특징벡터 추출 알고리즘 및 SVM에 대한 설명과 구성방법에 대해서 자세히 설명한다. III장은 뇌파의 알파파와 세타파의 분석과 운전자의 상태별 LPC 분석 결과에 대하여 설명한다. IV장은 데이터 크기에 따른 운전자의 졸음 판별 결과에 대해 고찰한 후, 마지막으로 결론과 향후 과제에 대해서 요약한다.

2. 본 론

2.1. 제안하는 졸음 감지 시스템

본 논문에서의 전체적인 졸음 감지 시스템은 그림 1과 같다. 신경회로망 기반의 감지 시스템에 적절한 특징벡터를 선정하기 위하여 각기 운전자로부터 뇌파 신호를 취득하였고 LPC 분석으로부터 추출한 계수를 SVM 분류기의 입력 특징벡터로 하여 샘플크기에 따른 분류 결과를 비교 분석하였다.

2.2. 데이터 취득과 실험프로토콜

뇌파 측정에 사용된 장비는 8채널 락싸에서 개발한 PolyG-I이다. 샘플링 주파수는 256Hz이며 그림 2와 같이 무향실에서 10/20 국제표준에 의거하여 전극을 부착하고 실험환경을 구축하였다.

그림 2 뇌파 측정 실험 환경 구축
Fig 2. Measurement of EEG

다음은 실험 프로토콜을 정리한 것이다.

- 실험 전에 Epworth Sleepiness Scale(ESS) 조사[13]를 통한 subject test를 수행하여 평상시 수면상태를 체크함
- 측정에 영향을 끼치는 요소들을 제거하고 측정 당시의 온도와 습도를 정확하게 기록함
- 피험자는 무향실 안의 편안한 의자에 앉아 측정을 준비함
- 10-20 표준을 이용하여 그림 3과 같이 Fp1, Fp4, F3, F4, P3, P4, O1, O2의 위치에 총 8개의 전극을 부착함

그림 1. 제안하는 운전자 졸음 감지 시스템
Fig 1. Proposed driver drowsy monitoring system

- 실험 시간은 2시간으로 한 사람당 1회 30분 간 2회 측정함 (줄지 않을 경우 시간 연장)
- 실험 장면을 웹캠으로 실시간 녹화하여 피험자의 상태를 체크함

그림 3. 10/20 시스템에 기반한 전극 부착 위치
Fig 3. Electrodes placement in 10/20 system

2.3. LPC 계수 추출 알고리즘

LPC는 현재 파형은 과거 값과 가중치의 곱을 합하여 추정될 수 있다는 것을 전제로 한다. 전달 특성 필터는 All-pole 모델을 사용하여 식(1)과 같이 차분 방정식의 형태로 나타낼 수 있다. 여기서 $x(n)$ 과 $s(n)$ 은 입력 신호와 출력 신호이고, a_j 와 p 는 전달 특성 필터 차수와 Pole이며, G 는 입력 신호의 가중치이다. 현재 신호와 과거 신호의 누적된 추정치의 오차는 식 (2)와 같다. 여기서 식(1)의 a_j 에 대한 추정치인 α_j 를 LPC 계수라고 정의한다[14].

$$s(n) = Gx(n) + \sum_{j=1}^p a_j s(n-j) \quad (1)$$

$$e(n) = s(n) - \sum_{j=1}^p \alpha_j s(n-j) \quad (2)$$

식(3)에서 J 는 예측 오차 $e(n)$ 에 대한 MSE(Mean square error)이며 J 를 최소로 하는 LPC 계수 α_j 를 찾아내기 위하여 식(3)을 α_j 에 대해서 편미분하여 0이 되는 p 개의 선형 연립방정식 (4)를 얻을 수 있다.

$$J = E[e^2(n)] = E\left[\left\{s(n) - \sum_{j=1}^p \alpha_j s(n-j)\right\}^2\right] \quad (3)$$

$$\sum_{j=1}^p \alpha_j \phi_n(i, j) = \phi_n(i, 0), \quad \text{for } i = 1, \dots, p, \quad (4)$$

$$\phi_n(i, j) = E\{s(n-i)s(n-j)\} \quad (5)$$

여기서 $\phi_n(i, j)$ 는 LPC 방정식이라 부르며 본 논문은 이 방정식의 해인 p 개의 α_j 를 구하기 위하여 Durbin 알고리즘을 이용하였다[14].

2.4 SVM

SVM은 고정되어 있지만 알려지지 않은 확률 분포를 갖는 데이터에 대해 잘못 분류하는 확률을 최소화하는 구조적

인 위험 최소화(Structural Risk Minimization)방법에 기초로 한 지도학습방법이다. 이는 최대 마진(Maximum classification margin)과 함께 두 클래스간의 학습오류(Empirical error)를 최소화하면서 데이터 샘플을 최적으로 분리하는 초평면(Hyperplane)을 생성함으로써 수행된다. SVM은 이진분류문제에 널리 이용되며 선형적으로 분리가 어려운 입력 공간(Input space) 데이터를 비선형 변환함수(Nonlinear mapping function)를 이용하여 고차원의 특징 공간(Feature space)으로 변환하여 선형 초평면을 만들어 비선형 분류 경계(Nonlinear classification boundary)를 생성한다. 초평면을 기준으로 한쪽을 +1 클래스, 다른 한쪽은 -1 클래스로 구분한다.

N 개의 훈련데이터집합 S 가 클래스에 속한다고 할 때 훈련데이터를 특징공간에서 선형적 분리를 결정할 초평면을 식(6)과 같이 정의한다.

$$y = f(x) = \langle \Phi(x) \cdot w \rangle + b = 0 \quad (6)$$

여기서 (x_i, y_i) , where $x_i \in R^N$, $i = 1, \dots, N$, $\Phi(x)$ 는 특징공간으로의 변환함수, 두 데이터 집합의 경계가 되는 가중치 벡터 w 는 N 차원 입력벡터, b 는 편향(bias)이다.

초평면의 거리(마진)를 최소화하기 위하여 SVM 이진분류에 대한 최적화 문제를 풀기위한 수식은 식(7), 식(8) 같다[15].

$$\text{Max } Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (7)$$

Subject to

$$\sum_{i=1}^N \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad i = 1, \dots, N \quad (8)$$

여기서 α_i 는 라그랑지 승수($\alpha = [\alpha_1 \alpha_2 \dots \alpha_N]'$)이며 kernel함수의 정의는 $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ 이다. kernel 함수로는 RBF(Radial basis function), Polynomial, Perceptron등이 있다.

목적함수 $Q(\alpha)$ 를 최대화하는 $\hat{\alpha}_i$ 를 구하기 위하여 KKT 조건을 이용하여 가중치 벡터 $\hat{\alpha}_i$ 와 $\hat{b}$ 를 구할 수 있으며, 특징공간에서 판별함수는 식(9)와 같이 계산된다.

$$F(x) = \sum_{i=1}^N \hat{\alpha}_i y_i K(x_i, x) + \hat{b} \quad (9)$$

식(9)를 이용하여 임의의 입력 패턴 x 가 주어질 때, $f(x) > 0$ 이면 클래스는 +1로 판별하고 그렇지 않을 경우는 -1 클래스로 판별한다.

2.5 Multi-class support vector machine

SVM은 이진 분류 문제에 대한 효율적인 학습기제로서 소개되었지만 Multi-class 분류 문제로 확장은 현재까지 진행중인 연구 분야이다. SVM의 Multi-class 분류 문제를 해결하기 위하여 여러 방법들이 제안되었었다. 그 중 대표적인 접근방법은 One-against-all, One-against-one, All-together, Direct acyclic graph SVM(DAGSVM)등이 있다[15].

Multi-class 분류 문제를 해결하기 위한 해법은 클래스

의 개수에 비례하는 변수 개수를 요구하기 때문에 같은 수의 데이터에 대해서 이진문제보다 계산적으로 훨씬 더 복잡하다. K-class문제에 대하여 One-against-all 방법은 k개의 초평면을 만들고 각각은 학습데이터의 모든 데이터를 사용함으로써 생성된다. All-together 방법은 One-against-all 방법과 유사하게 k개의 초평면을 생성하지만 모든 초평면은 단일 최적화 문제를 해결함으로써 얻어진다. One-against-one 방법은 $k(k-1)/2$ 개의 초평면을 만들고 각각은 k개의 클래스로 선택된 두 개의 클래스에서의 학습데이터만을 이용함으로써 생성된다. 이렇게 학습시 적은 훈련데이터를 이용하기 때문에 다른 방법들보다 학습시간이 줄어드는 장점이 있다. DAGSVM은 One-against-one 방법과 같은 개수의 초평면을 생성하지만 테스트 시간이 적게 걸린다는 장점이 있다. [16-18]의 연구에서는 위의 방법들을 비교한 결과 One-against-one 방법과 DAGSVM이 보다 실용적이라는 결론을 내렸다. 본 논문에서는 One-against-one 방법과 One-against-all 방법을 이용하여 비교하였다.

3. 뇌파분석결과

3.1. 알파파와 세타파 분석

본 연구에서는 각성상태와 졸음상태에 대한 정의를 Hori's 기준에 맞추었다. Hori's 기준에 의하면 각성상태에서 수면초기상태(sleep stage1)로 진입시 눈의 깜빡임이 둔화되며 후두부의 알파파(8-13Hz)의 활동이 줄어들고 세타파(4-7Hz)가 전반적으로 출현한다[8-11].

그림 4는 실험 시작으로부터 60초에서 130초사이의 8채널 데이터를 10초 단위로 5초간 중첩을 시켜 스펙트럼 분석을 통해 알파파의 변화를 그래프로 나타낸 것이다[17]. 동영상 분석에서 피험자는 80초에서 눈을 감았고 85-90초 사이에서 눈을 떴다. 그리고 다시 110-115초 사이에서 눈 감고 125에서 눈을 떴다. 그림 4의 그래프에서 75초와 90초에서 피험자가 눈을 감은 시기에 순간적으로 후두부 채널 7번과 8번 알파파가 증가하여 졸음으로 넘어가는 시기에 서서히 감소하는 것을 확인할 수 있다. 일반적으로 폐안시 9-11Hz 주파수 사이의 후두부의 알파파가 우세하여야 하지만 졸음이 오는 상황에서는 폐안시 후두부의 알파파가 우세하였다가 감소하는 'alpha block' 현상이 발생한다. 그러므로 75-90초 사이 피험자의 상태를 수면 초기상태로 평가할 수 있다. Hori's 단계 1에서 2(경수면기)로 들어가는 과정에

그림 4. 졸음 구간에서 시간에 따른 알파파의 변화
Fig 4. Changes of alpha waves in drowsiness states

서 세타파의 증가량으로 판단할 수 있다. 그림 5의 그래프에서 ch7, 8의 세타파의 변화를 살펴보면 'alpha block' 구간을 제외하고 세타파가 꾸준히 증가하는 추세를 보이고 있어 피험자의 상태가 점차적으로 졸음이 깊어지고 있다는 것을 확인할 수 있다.

그림 5. 졸음 구간에서 시간에 따른 세타파의 분석
Fig 5. Changes of theta waves in drowsiness state

3.2. LPC를 이용한 특징벡터 추출

동영상 분석과 알파파와 세타파 분석을 통하여 측정데이터를 각성상태, 졸음상태, 수면상태로 분류하여 데이터 집합을 만들었다. 구축된 데이터집합을 LPC 분석을 통해 LPC 계수를 8차로 하여 각 상태별 LPC 계수를 추출하였다. LPC 계수가 피험자의 각성상태, 졸음상태, 수면상태를 구분 지을 수 있는 정량화된 특징벡터인지 판단하기 위하여 상태별 LPC Envelop을 그림 6에 나타내었다. 그림 6의 각 Envelop에서 알 수 있듯이 상태별 추정된 Pole의 위치가 각각 다르게 나타나서 LPC 계수가 피험자의 상태별 신호의 대표성을 가짐을 알 수 있다. 표 1은 각성상태, 졸음상태, 수면상태에 대한 8개의 LPC 계수를 나타낸 것이다[19].

그림 6. 각 상태별 LPC envelop
Fig 6. LPC envelopes for each state

표 1. 각 상태별 LPC 계수
Table 1. LPC coefficients for each state

LPC 계수	α_1	α_2	α_3	α_4	α_5	α_6	α_7	α_8
각성상태	-0.271	-0.244	0.028	-0.209	-0.050	0.002	-0.103	0.075
천이상태	0.026	0.168	0.071	0.039	-0.002	-0.073	-0.067	-0.037
졸음상태	0.101	-0.159	-0.011	0.089	-0.061	-0.009	-0.020	-0.107

4. 운전자 상태 분류 결과

구축된 특징 벡터 데이터베이스를 바탕으로 학습과 테스트를 위한 데이터 설정은 특징 추출 알고리즘으로부터 추출한 특징 벡터의 70%를 학습 데이터로 30%를 테스트 데이터로 나누었고 최상의 학습 모델 선정과 학습 과정에서 조기 중단(Early stopping)을 결정하기 위해 학습 데이터 집합의 하위 집합인 모델을 검증하는 데이터 집합을 나누었다. 제한한 시스템에서는 Kearns의 권장사항으로 학습 데이터의 20%를 검증을 위한 데이터로 나누었다. 논문에서 적용한 MLP 신경회로망 설계 및 학습은 MathWorks사 Matlab 7.6.0의 Neural Network Toolbox를 SVM은 프랑스의 Program Perception Systèmes et Information 연구실에서 개발한 SVM-KM을 이용하였다. 본 실험은 아래의 두 가지 방향으로 진행하였다.

- ① LPC 차수의 변화에 따른 분류율 비교
- ② 데이터 크기의 변화에 따른 분류율 비교

LPC 차수 변화에 따른 운전자의 상태 분류 결과를 표 2에 나타내었다. 6차까지는 각 상태를 잘 분류하는 결과 보였지만 차수가 4 이하일 때 학습데이터에 따라서 학습시 수렴을 하지 못하는 경우가 발생하여 불안정한 결과를 보였다. LPC 분석 방법은 적은 차수에도 높은 분류 성능을 유지하여 안정적인 진단시스템을 구축할 수 있고 시스템을 간소화시킬 수 있어 실시간 시스템에 적합한 것으로 판단된다.

다음은 AR특징 벡터의 특징 중 하나인 적은 샘플수를 가지고도 높은 해상도를 가지는 것을 확인하기 위하여 차수를 12차로 고정시킨 후 데이터를 2초, 0.25초, 0.5초로 나누어 분류실험을 진행하였고 분류결과를 표 3에 나타내었다. 제안 시스템을 차량에 적용하기 위하여 데이터의 크기는 상당히 중요하다. 실험결과 0.25초까지 실험 데이터를 줄여도 안정적인 분류 결과를 보였다. 이는 [8]에서 10초(2560 samples) 길이의 신호를 이용한 졸음검출 시스템을 제안한 것에 비교하여 분류 결과 측면뿐만 아니라 적은 샘플을 가지고도 상당히 우수한 결과이다. 두 가지 실험에 의하여 제안 시스템이 짧은 순간에 일어날 수 있는 운전자 돌발 상황을 실시간으로 검출 가능하다는 것을 확인하였다.

표 2 LPC 차수의 크기에 따른 상태별 분류 결과

Table 2. Driver states classification results for LPC order's size

LPC 차수	20	12	8	6	4
분류 결과(%)	99.2	99.1	99.1	98	un-stable

표 3 샘플별 크기에 따른 상태별 분류 결과(차수 12)

Table 3. Driver states classification results for sample size

데이터 크기	운전자 상태			분류율 (종합)
	각성	천이상태	졸음	
2sec(512샘플)	99%	98.5%	100%	99.1%
250ms(64샘플)	76%	92%	96.6%	88.2%
100ms(25샘플)	60.2%	61.9%	91.6%	71.2%

표 4는 같은 실험 환경에서 Multi-class SVM 분류기를 적용시켰을 때의 결과이다. [12]의 실험에서의 SVM환경과 비교하기 위하여 커널 함수로 RBF를 이용하였고 Multi-class 전략으로 One-against-one과 One-against-all 방법을 적용하였다. One-against-one과 One-against-all의 결과는 크게 차이가 없었지만 MLP의 결과와 비교하였을 때 0.25초의 적은 데이터 샘플이었음에도 95% 이상의 우수한 결과를 보였다. 이 결과는 졸음신호를 분류하는 데 있어서 MLP보다 SVM을 사용하는 것이 더 적절하다고 판단할 수 있다.

표 4. SVM을 이용한 운전자 상태 분류 결과

Table 4. Driver states classification results using SVM

데이터 크기	SVM results(One-against-one)			
	각성	천이상태	졸음	분류율
2 sec	100%	100%	100%	100%
250ms	93.3%	100%	96.6%	96.6%
100ms	53.3%	76.6%	93.3%	74.4%
데이터 크기	SVM results(One-against-all)			
	각성	천이상태	졸음	분류율
2 sec	100%	100%	100%	100%
250ms	90%	96.6%	100%	95.5%
100ms	63.3%	80%	76.6%	73.3%

5. 결론 및 향후 연구

본 논문에서는 AR 기반 선형예측(Linear Predictive coding, LPC) 계수와 SVM(Support Vector Machine)을 이용한 운전자의 상태별 뇌파 판별 시스템을 제안하였다. 기존의 뇌파 분석 연구에서 전체 스펙트럼 분석 또는 알파파, 베타파, 세타파, 감마파와 같은 주파수 대역별 분석을 통해 상태별 특징벡터 추출에 국한되었다면 본 연구에서 시도된 AR(Autoregressive) 모델기반 LPC 분석을 통해 추정된 LPC 계수는 각성 상태, 졸음 상태, 수면 상태를 확실하게 구분 하였고 스펙트럼 분석보다 더 정량화된 특징벡터를 얻었다. LPC 분석은 단시간 샘플에 대해서 스펙트럼 분석보다 높은 해상도를 가지기 때문에 향후 차량에 적용할 때 운전자의 졸음에 대한 빠른 응답과 빠른 경고조치를 취할 수 있을 것이다.

본 연구의 향후 과제는 더 많은 피험자 집단에 대한 데이터베이스를 확립한 후 뇌파의 노이즈 제거와 함께 LPC 계수를 자동으로 분류하는 시스템을 구축하는 것이며 이러한 연구방법을 기반으로 차량제어의 가능성을 타진해 볼 것이다.

References

- [1] Qiang Ji, Zhiwei Zhu, and Peilin Lan, "Real-Time Nonintrusive Monitoring and Prediction of Driver Fatigue," *IEEE Trans. on Vehicular Technology*, vol. 53 no. 4, pp. 1052 - 1068, 2004.

- [2] J. D. Slater, "A definition of drowsiness: One purpose for sleep?," *Med. Hypotheses*, vol. 71, pp. 641 - 644, 2008.
- [3] M. W. Johns, R. Chapman, K. Crowley, and A. Tucker, "A new method for assessing the risks of drowsiness while driving," *Somnologie*, vol. 12, pp. 66 - 74, 2008.
- [4] Young Hoon Joo, Jin Kyu Kim, In Ho Ra, "Intelligent Drowsiness Drive Warning System," *Journal of Korean Institute of Intelligent Systems*, vol. 18, no. 2, pp. 223 - 229, 2008.
- [5] Kataoka et al., 1998 H. Kataoka, H. Yoshida, A. Saijo, M. Yasuda and M. Osumi, "Development of a skin temperature measuring system for non-contact stress evaluation," *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 2, pp. 940 - 943, 1998.
- [6] A. Bunde, S. Havlin, J.W. Kantelhardt, T. Penzel, J.-H. Peter and K. Voigt., "Correlated and Uncorrelated Regions in Heart-Rate Fluctuations during Sleep," *Phys. Rev. Lett.*, vol. 85, pp. 3736-3739, 2000.
- [7] Young-Bum Lee, Myoung-Ho Lee, "Automobile System for Drowsiness Accident Detection using EDA Signal Analysis," *The Transactions of KIEE*, vol. 56, no. 2, pp. 227-450, 2007.2.
- [8] Mervyn V.M. Yeo, Xiaoping Li, Kaiquan Shen, Einar P.V. Wilder-Smith. "Can SVM be used for automatic EEG detection of drowsiness during car driving?," *Safety Science*, vol. 47 pp. 115 - 116, 2009.
- [9] Steriade, M., "Brain electrical activity and sensory processing during waking and sleep states," In: Kryger, M.H., Roth, T., Dement, W.C. (Eds.), *Principles and Practice of Sleep Medicine*. Saunders, Philadelphia, pp. 93 - 111, 2000.
- [10] Lal, S.K.L., Craig, A. "A critical review of the psychophysiology of driver fatigue," *Biological Psychology*, vol. 55, pp. 173 - 94, 2001.
- [11] Yeo, M.V.M., Li, X., Wilder-Smith, E.P.V., "Characteristic EEG differences between voluntary recumbent sleep onset in bed and involuntary sleep onset in a driving simulator," *Clinical Neurophysiology*, vol. 118, pp. 1315 - 1323, 2007.
- [12] Moller, H.J., Kayumov, L., Bulmash, E.L., Nhan, J., Shapiro, C.M., "Simulator performance, microsleep episodes, and subjective sleepiness: normative data using convergent methodologies to assess driver drowsiness," *Journal of Psychosomatic Research*, vol. 61, pp. 335 - 342, 2006.
- [13] Murray W. Johns, "A new method for measuring daytime sleepiness: the Epworth sleepiness scale," *Sleep*, vol. 14, no. 6, pp. 540 - 545, 1991.
- [14] J. D. Markel and A. H. Gray, Jr., "Linear Prediction of Speech," *Springer-Verlag*, Berlin Heidelberg, New York, pp. 42 - 53, 1976.
- [15] R. Debnath, N. Takahide and H. Takahashi, "A decision based one-against-one method for multi-class support vector machine," *Pattern Analysis & Applications*, vol. 7, no. 2, pp. 164-175, 2004.
- [16] Chih-Wei Hsu and Chih-Jen Lin, "A Comparison of Methods for Multiclass Support Vector Machine," *IEEE TRANSACTIONS ON NEURAL NETWORKS*, vol. 13, no. 2, 2002.
- [17] Man-Sun Kim, Sang-Yong Lee, "Multiple SVM Classifier for Pattern Classification in Data Mining," *Journal of Korean Institute of Intelligent Systems*, vol. 15, no. 3, pp. 289 - 293, 2005.
- [18] Sang-Wook Seo, Hyun-Chang Yang, Kwee-Bo Sim, "Behavior Learning and Evolution of Swarm Robot System using Support Vector Machine," *Journal of Korean Institute of Intelligent Systems*, vol. 18, no. 5, pp. 712 - 717, 2008.
- [19] Hyungseob Han, Dajung Kim, Daeyun An, Gi Beom Hong, Uipil Chong, "Driver Drowsiness and Alertness Detection Method Using Linear Predictive Coding and Electroencephalographic Change," *Proceedings of KISPS Falls Conference 2011*, pp. 237 - 239, Dec. 2011.

저 자 소 개

한형섭(Hyungseob Han)
2009년: 울산대학교 컴퓨터정보통신공학부
공학사
2011년: 울산대학교 컴퓨터공학 공학석사
2011년~현재: 울산대학교 대학원
전기공학부 박사과정(박사수료)

관심분야 : 고장진단, 생체신호처리, 인공지능
Phone : +82-10-6733-5112
E-mail : overhs@ulsan.ac.kr

정의필(Uipil Chong)
1978년: 울산대학교 전기공학과 공학사
1980년: 고려대학교 전기공학과 공학석사
1985년: 미국 오레곤 주립대학교 전기 및
컴퓨터 공학석사
1996년: 미국 뉴욕 대학교(폴리테크닉 공대)
전기 및 컴퓨터 공학박사

1997년~현재: 울산대학교 전기공학부 교수
관심분야 : 신호처리, 멀티미디어, 컴퓨터음악
Phone : +82-10-3560-8420
E-mail : upchong@ulsan.ac.kr