

EIV와 MLP를 이용한 뇌파 기반 운전자의 졸음 감지 시스템

한형섭*, 송경영^o

Electroencephalogram-Based Driver Drowsiness Detection System Using Errors-In-Variables(EIV) and Multilayer Perceptron(MLP)

Hyungseob Han*, Kyoung-Young Song^o

요약

졸음운전은 전체 교통사고 원인 중 큰 비중을 차지하며 그 위험성이 음주운전보다도 크다고 알려져 있다. 따라서 운전자의 졸음을 판단하고 경고하는 시스템 개발에 대한 관심이 높아지고 있으며, 뇌파를 분석하는 것이 운전자의 피로와 졸음을 감지하는데 효과적이라는 연구결과들이 발표되었다. 본 논문은 짧은 시간에 높은 해상도를 가지는 auto-regressive 모델 기법 중 잡음에 강인한 errors-in-variables(EIV) 방법을 이용하여 특징벡터를 추출하고 다층신경망(multilayer perceptron; MLP)에 적용하여 운전자의 상태를 각성, 전이, 졸음의 세 가지 상태로 분류하는 졸음 감지 시스템을 제안한다. 생체신호의 측정 환경에 따른 성능을 평가하기 위해 높은 진단률을 갖도록 하는 EIV차수를 결정하고, 잡음에 대한 강인성을 확인하기 위해 신호대 잡음비(signal-to-noise ratio; SNR)에 따른 성능을 선형 예측 부호화(linear predictive coding; LPC) 방법과 비교하였다. 이 결과로부터 제안한 EIV와 MLP를 결합한 졸음 감지 시스템은 기존의 LPC와 MLP를 이용한 시스템에 대해 우수한 성능을 얻을 수 있음을 확인하였다.

Key Words : Auto-regressive(AR) model, drowsiness detection, electroencephalogram(EEG), errors-in-variables(EIV), multilayer perceptron(MLP)

ABSTRACT

Drowsy driving is a large proportion of the total car accidents. 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. Many researches have been published that to measure electroencephalogram(EEG) signals is the effective way in order to be aware of fatigue and drowsiness of drivers. 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, transition, and drowsiness. This paper proposes a drowsiness detection system using errors-in-variables(EIV) for extraction of feature vectors and multilayer perceptron (MLP) for classification. The proposed method evaluates robustness for noise and compares to the previous one using linear predictive coding (LPC) combined with MLP. From evaluation results, we conclude that the proposed scheme outperforms the previous one in the low signal-to-noise ratio regime.

* 본 연구는 2014년 울산과학기술대학교 교내학술연구비 지원(201410019)으로 수행되었습니다.

• First Author : School of Electrical Engineering, University of Ulsan, oversh@ulsan.ac.kr, 학생회원

◦ Corresponding Author : School of Electrical Engineering, Ulsan College, kysong@uc.ac.kr, 종신회원

논문번호 : KICS2014-08-294, Received August 11, 2014; Revised September 19, 2014; Accepted September 19, 2014

I. 서론

졸음(drowsiness)은 각성(alertness)과 수면(sleep)의 중간상태로 의식이 사라지면서 수면으로 진행되는 과정이라고 정의된다. 특히 운전 중 졸음은 교통사고의 원인 중 큰 부분을 차지하고 있다^[1]. 실제로 한국도로교통공단의 통계에 따르면 최근 3년(2011~2013년)간 여름 휴가철(7월 16일~8월 15일) 교통사고를 분석한 결과, 전국적으로 하루 평균 600건의 사고가 발생하여 14명이 사망하고, 949명이 부상당한 것으로 조사되었다. 그리고 졸음운전사고의 치사율을 살펴보면 평균 4.98%로 음주운전(2.98%)에 비해 약 1.7배 가까이 높았으며 전체 교통사고의 치사율(2.49%)보다 2배 더 높은 것으로 나타났다. 이는 졸음이 운전자에게 느린 반응속도를 야기하고 정보처리 능력을 현저히 감소시켜, 위험을 인지하였음에도 정상적으로 대응하지 못하여 대형사고로 연결되기 쉽기 때문이다^[2].

졸음 감지에 대한 기존 연구는 눈의 깜빡거림(blinking), 동공의 크기, 눈의 응시방향, 얼굴표정을 카메라로 촬영하여 영상처리 기술을 적용하는 비전기반의 졸음감지 연구가 주류를 이루었다^[3,4]. 또한 스트레스와 말초체온과의 상관관계^[5], 심박수의 변화^[6], 피부 임피던스 신호분석^[7]을 통한 졸음 감지 연구에 대한 논문도 발표되었다. 그러나 위의 연구들은 졸음 감지에 대한 명확한 해석이 어렵다는 단점이 있고, 또한 실내 조명과 외부 밝기에 민감하게 반응하여 실제로 적용하기가 쉽지 않다. 게다가 눈동자의 움직임과 근육의 변화를 기반으로 한 졸음 감지는 졸음이 이미 진행된 상태에서 얻어진 결과이므로 졸음 감지에 부적합하고, 따라서 졸음 상태로 가기 전 상태를 진단할 수 있는 신호 선취득과 분석방법이 필요하다.

이러한 문제를 해결하기 위하여 다양한 생체신호를 기반으로 한 연구가 진행되었다. 특히 뇌파(electroencephalogram; EEG)와 안구전도(electrooculogram)를 통한 눈 깜빡거림에 대한 육안검사가 운전자의 피로와 졸음을 판별하는데 효과적이라는 의학적 연구결과가 발표되었다^[8]. 운전자는 정신적 피로감이 증가할 때 높은 각성 상태를 유지할 수 없으며 이는 뇌파의 알파파(alpha wave)와 세타파(theta wave)의 변화량과 상관관계가 높다는 것을 보였으며^[9], 스펙트럼 분석을 통한 뇌파의 델타파(delta wave), 세타파, 알파파, 베타파(beta wave)와 운전 중 졸음의 상호연관 관계를 발견하였다^[10]. 졸음 연구에 따르면 운전 시 졸음은 운전자가 각성상태를 유지하려고 노력하는 점에서 일반적인 졸음 연구와 차이가 있고, 운전시의 발

생하는 각성과 졸음상태의 천이 단계(transition)는 Hori의 수면 1단계의 특징과 유사하다는 것을 보였다^[11,12]. 이러한 연구결과를 토대로 측정된 뇌파의 스펙트럼 성분에 대한 ‘alpha block’ 현상과 세타파의 변화를 기준으로 하여 운전자의 상태를 각성, 천이, 졸음의 세 가지 상태로 분류하였다^[13].

기존의 연구에서는 AR(autoregressive) 모델을 기반으로 하여 뇌파의 특징을 분석하는 방법을 제안하였는데, 입력 잡음을 고려하지 않은 선형 예측 부호화(linear predictive coding; LPC) 계수와 그 모델의 잔여신호를 이용하였다^[13]. 잔여신호는 잡음 환경에서의 안정성을 가지고 있지만 여전히 각 특징별 잔여신호의 임계치 설정의 문제를 가지고 있다. 본 논문에서는 짧은 시간에 높은 해상도를 가지는 EIV(errors-in-variables) 방법을 적용하였고 특징벡터를 추출하고, 추출한 벡터와 다층신경망(multilayer perceptron; MLP)을 이용하여 운전자의 상태를 각성, 천이, 졸음 상태로 분류한다. 또한 잡음에 대한 강인성을 확인하기 위해 EIV와 LPC 간의 성능을 평균 분류율(average classification rate) 관점에서 비교하였다.

본 논문의 구성은 다음과 같다. II장에서는 EIV와 MLP를 이용하여 운전자의 졸음을 감지하는 시스템을 제안한다. 또한 EIV를 이용한 특징벡터 추출 알고리즘과 MLP에 대해서 설명한다. III장은 뇌파 취득 환경과 취득한 데이터를 기반으로 한 데이터베이스 구축 방법에 대하여 설명한다. IV장에서는 EIV의 차수와 샘플 데이터 크기에 따른 제안한 졸음 감지 시스템의 성능에 대해 고찰한 후, V장에서 결론을 맺는다.

II. 제안 시스템 및 배경이론

2.1 제안하는 졸음 감지 시스템

본 논문에서 제안하는 졸음 감지 시스템은 그림 1과 같이 세 단계로 구성되며, 자세한 과정은 III장에서 설명한다.

- i) 데이터 취득 및 샘플링을 통한 데이터베이스화
- ii) EIV를 이용한 특징벡터 추출




그림 1. EIV와 MLP를 이용한 졸음 분류 시스템
Fig. 1. Proposed drowsiness detection system using EIV and MLP.

iii) MLP 신경회로망을 통한 상태 분류

2.2 EIV를 이용한 AR 계수 추정

시스템 식별(system identification) 문제에서 오차와 잡음을 입력과 출력에 모두 나타내는 것을 EIV 모델이라 하며, 그림 2는 AR 계수 추정을 위한 EIV 기법을 나타낸 것으로 식 (1)은 p 차 AR 모델로 표현되는 신호를 나타낸 것이다.

$$s[k] = -\sum_{i=1}^p a_i s[k-i] + u[k] \quad (1)$$

여기서 $a_i (i=1, \dots, p)$ 는 AR 모델의 계수를 나타내고, $u[k]$ 는 평균이 0이고 분산이 σ_u^2 인 가산성 백색 잡음(additive white Gaussian noise; AWGN)이다. 신호 $s[k]$ 는 평균이 0이고 분산이 σ_b^2 인 AWGN $b[k]$ 가 더해져서 관측이 된다.

$$y[k] = s[k] + b[k] \quad (2)$$

본 논문에서는 다음과 같은 특징을 갖는 EIV를 이용하여 AR 계수, 입력과 측정 잡음의 분산을 추정한다^[14].

- i) Frisch 기법의 해집합의 성질을 이용
- ii) 시불변 동적 시스템(time-invariant dynamic system)의 shift 성질을 이용
- iii) 공분산 행렬의 양의 정 부호 행렬(positive-definite matrix)을 만족시키는 AR 계수, 입력과 측정 잡음 분산을 동시에 추정

Frisch 기법과 shift 성질을 이용하여 잡음 평면에서의 잡음 분산이 최소가 되는 지점을 찾을 수 있다. 즉, 잡음 환경에서 예측한 AR 계수들의 오차를 최소화 시킬 수 있어 잡음에 보다 강인한 특징벡터를 추출할 수 있다. 다음은 N 개의 유한 데이터에서 EIV에 기반한 AR 계수 예측 알고리즘에 대해 간략히 기술한 것이다^[14].




그림 2. AR 계수 추정을 위한 EIV 기법^[14]
Fig. 2. EIV scheme for AR parameter estimation.

단계 1: $\mathbf{y} = (y[k-p], y[k-p+1], \dots, y[k-1], y[k])^T$ 에 대한 공분산 행렬 $R_p(y) \in \mathbb{R}^{(p+1) \times (p+1)}$ 은 다음과 같이 정의된다.

$$R_p(y) = \lim_{N \rightarrow \infty} \left[\frac{1}{N-p} H_p^T(y) H_p(y) \right] \quad (3)$$

여기서 $H_p(y)$ 는 N 개의 관측된 신호 $y[0], \dots, y[N-1]$ 로 구성되는 $(N-p) \times (p+1)$ Hankel 행렬이고 다음과 같다.

$$H_p(y) = \begin{bmatrix} y[0] & y[1] & \dots & y[p] \\ y[1] & y[2] & \dots & y[p+1] \\ \vdots & \vdots & \ddots & \vdots \\ y[N-p-1] & y[N-p] & \dots & y[N-1] \end{bmatrix} \quad (4)$$

실제 관측 신호의 개수 N 은 유한하므로, AR 계수를 추정함에 있어 공분산 행렬에 대한 추정치를 계산하여 이용해야 한다. AR 차수 $p, p+1$ 에 대해 다음과 같이 공분산의 추정을 계산한다.

$$\hat{R}_p(y) = \frac{1}{N-p} H_p^T(y) H_p(y) \quad (5)$$

$$\hat{R}_{p+1}(y) = \frac{1}{N-p-1} H_{p+1}^T(y) H_{p+1}(y) \quad (6)$$

단계 2: 잡음 평면 $\mathbb{R}^2 = \{(\alpha, \beta) | \alpha \geq \beta > 0\}$ 에서 식 (7)을 만족하는 점 $\xi = (\xi_1, \xi_2)$ 에 대해 연속된 convex 곡선의 집합을 $S(\hat{R}_p(y))$ 라 하자.

$$\hat{R}_p(\xi) = \hat{R}_p(y) - \text{diag}[\underbrace{\beta_\xi \dots \beta_\xi}_{p} \alpha_\xi] \geq 0 \quad (7)$$

식 (8)을 이용하여 원점과 점 $\xi = (\xi_1, \xi_2)$ 를 지나는 직선이 $S(\hat{R}_p(y))$ 와 만나는 점 $A(\alpha_A, \beta_A)$ 는 다음과 같이 구할 수 있다.

$$\alpha_A = \xi_1 / \lambda_M, \quad \beta_A = \xi_2 / \lambda_M \quad (8)$$

여기서 $\lambda_M = \max \text{eig} \left(\hat{R}_p^{-1} \times \text{diag}[\underbrace{\xi_2, \dots, \xi_2}_{p}, \xi_1] \right)$ 이다. 이와 같은 방식으로 원점과 점 $\xi = (\xi_1, \xi_2)$ 를 지나는 직선이 $S(\hat{R}_{p+1}(y))$ 와 만나는 점 $B(\alpha_B, \beta_B)$ 또한 구할 수 있다.




그림 3. MLP 구조
Fig. 3. Structure of MLP.

단계 3: 다음의 관계를 이용하여 $\hat{R}_p(A)$, $\hat{R}_{p+1}(B)$, $\underline{\theta}(A)$ 를 계산한다.

$$\hat{R}_p(A) = \hat{R}_p(y) - \text{diag}[\underbrace{\beta_A, \dots, \beta_A, \alpha_A}_p] \quad (9)$$

$$\hat{R}_{p+1}(B) = \hat{R}_{p+1}(y) - \text{diag}[\underbrace{\beta_B, \dots, \beta_B, \alpha_B}_{p+1}] \quad (10)$$

$$\hat{R}_p(A)\underline{\theta}(A) = 0 \quad (11)$$

여기서 $\underline{\theta}(A)$ 는 점 A 를 이용하여 구한 AR 계수 $\underline{\theta} = [a_p, \dots, a_1, 1]^T$ 를 의미한다.

단계 4: $\bar{\theta}(A) = [0, \underline{\theta}(A)^T]^T$ 일 때, 식 (12)에 주어진 SR 비용함수(shifted relation cost function)를 계산한다.

$$\begin{aligned} J(A, B) &= \|\hat{R}_{p+1}(B)\bar{\theta}(A)\|^2 \\ &= \bar{\theta}(A)^T \hat{R}_{p+1}^2(B)\bar{\theta}(A) \end{aligned} \quad (12)$$

단계 5: SR 비용함수 $J(A, B)$ 를 최소화 하는 분산 $A^* = (\alpha^*, \beta^*)$ 를 탐색한다.

단계 6: $A^* = (\alpha^*, \beta^*)$ 와 일치하는 AR 계수 벡터 $\underline{\theta} = [a_p, a_{p-1}, \dots, a_1, 1]^T$ 를 구한다.

2.3 MLP(다층인식자)

분류시스템에 사용될 MLP 신경회로망은 교사학습(supervised learning)의 한 종류로 음성인식, 단백질 구조분석, 수중음파의 분석 등 광범위한 분야에 응용되고 있으며 다른 신경회로망 분류기와 비교하여 상대적으로 메모리 요구량이 적은 장점을 가지고 있다¹⁵⁾.

다층 신경망은 입력층(input layer)과 출력층(output

layer) 사이에 하나 이상의 중간층인 은닉층(hidden layer)이 존재하는 신경망을 일컫는다. 이러한 다층 신경망은 입력값과 목표출력(target \mathbf{t})으로 이루어진 학습 데이터를 사용하여 입력 값에 대한 신경망의 출력값과 목표 출력 사이의 오차가 최소가 되도록 연결 강도인 가중치를 조정하는 방법이다.

그림 3은 하나의 은닉층을 갖고 있으며, 출력층이 $(c+1)$ 개, 은닉층이 $(h+1)$ 개, 입력층이 $(d+1)$ 개의 뉴런(neuron)으로 구성된 다층 신경망 구조를 보인 것으로, k 번째 뉴런의 출력(z_k)은 다음과 같다.

$$\begin{aligned} z_k &= f_2 \left(\sum_{j=1}^h w_{kj} f_1 \left(\sum_{i=1}^d v_{ji} x_i + v_{j0} \right) + w_{k0} \right) \\ &\equiv f_2(N_k) \end{aligned} \quad (13)$$

$$\text{여기서 } N_k = \sum_{j=1}^h w_{kj} y_j + w_{k0},$$

$$y_j = f_1 \left(\sum_{i=1}^d v_{ji} x_i + v_{j0} \right) \equiv f_1(M_j), \quad M_j = \sum_{i=1}^d v_{ji} x_i + v_{j0}$$

이고 f_1 과 f_2 는 각각 입력층-은닉층과 은닉층-출력층을 관계를 나타내는 전달함수(transfer function)를 나타낸다.

출력 z_k 와 원하는 출력(desired output) t_k 간의 각각의 패턴에 대한 오차함수 $J(\mathbf{V}, \mathbf{W})$ 는 식 (14)와 같다.

$$J(\mathbf{V}, \mathbf{W}) = \frac{1}{2} \sum_{k=1}^c e_k^2 = \frac{1}{2} \sum_{k=1}^c (t_k - z_k)^2 \quad (14)$$

최소 평균 제곱(least mean square) 방법을 이용하여 이 오차 $J(\mathbf{V}, \mathbf{W})$ 를 최소로 하는 연결강도를 구한다. 역전파 학습 규칙(back propagation learning rule)은 식 (15)와 같이 기울기 강하(gradient descent)에 기반으로 하고 있다.

$$\Delta \mathbf{W} = -\eta \frac{\partial J}{\partial \mathbf{W}} \quad (15)$$

먼저 출력층과 은닉층간의 연결강도의 변화량 Δw_{kj} 는 식 (15)를 기반으로 하여 식 (16)으로 유도된다.

$$\begin{aligned} \Delta w_{kj} &= -\eta \frac{\partial J}{\partial w_{kj}} = \eta \frac{\partial J}{\partial N_k} \frac{\partial N_k}{\partial w_{kj}} \\ &= -\eta \delta_k \frac{\partial N_k}{\partial w_{kj}} \end{aligned} \quad (16)$$

여기서 δ_k 는 다음과 같이 나타낼 수 있다.

$$\delta_k = -\frac{\partial J}{\partial N_k} = -\frac{\partial J}{\partial z_k} \frac{\partial z_k}{\partial N_k} = (t_k - z_k) f_2'(N_k) \quad (17)$$

따라서 출력층 k 번째 유닛에 대한 연결강도의 변화량 Δw_{kj} 는 식 (18)과 같이 간단히 쓸 수 있다.

$$\Delta w_{kj} = \eta(t_k - z_k) f_2'(N_k) y_j = \eta \delta_k y_j \quad (18)$$

입력층과 은닉층 간의 연결강도 변화량 Δv_{ji} 도 Δw_{kj} 와 유사하게 다음과 같이 표현된다. 위의 과정을 반복하면 식 (18)과 유사한 형태로 표현이 가능하다.

$$\Delta v_{ji} = \eta \left[\sum_{k=1}^c w_{kj} \delta_k \right] f_1'(M_j) = \eta \delta_j x_i \quad (20)$$

여기서 $\delta_j = f_1'(M_j) \sum_{k=1}^c \delta_k w_{kj}$ 이다.

이와 같이 각 노드 간 연결강도의 변화량을 구할 수 있고 이로 인해 매번 연결강도의 갱신으로 학습이 가능하게 된다¹⁶⁾. 본 논문에서는 신경회로망의 크기를 최적화하기 위해 은닉층의 개수를 범용 근사화 이론(universal approximation)에 따라 1개로 설정하였다. MLP 신경망을 구성하는데 있어서 은닉층의 뉴런 개수를 10개부터 1개까지 줄여가면서 실험하였고, 은닉층의 뉴런 개수가 2개 이하부터는 분류 성능이 점점 줄어드는 것을 확인하였다. 그러므로 본 논문에서는 신경회로망의 크기의 최적화와 분류 성능의 극대화를 동시에 만족시키는 은닉층의 뉴런 개수를 3개로 결정하였다. 학습 알고리즘은 비교적 성능이 뛰어나다고 알려진 scaled conjugated gradient 알고리즘을 이

용하였다. 학습 정도는 학습 횟수(epochs)보다 표준오차평균(mean squared error; MSE)를 우선으로 하여 학습 임계치를 10^{-5} 으로 정하였다. 또한 300번 이상의 학습에도 불구하고 수렴하지 못하면 자동으로 학습 종료로 시켰다. 분석에 사용된 MLP 신경회로망의 설정 값은 표 1과 같다.

III. 뇌파 측정 환경 및 취득 데이터 분할

뇌파 측정에 사용된 장비는 8채널 락싸에서 개발한 PolyG-I이다. 샘플링 주파수는 256Hz이며 울산대학교 무향실에서 10/20 국제표준에 의거하여 Fp1, Fp4, F3, F4, P3, P4, O1, O2의 위치에 총 8개의 전극을 부착하고 실험환경을 구축하였다¹³⁾. 그림 4는 취득 신호에서 데이터를 상태별로 분할하는 과정을 보인 것이다.

i) 본 연구에서는 각성상태와 졸음상태에 대한 정의를 Hori의 기준에 맞추었다. Hori의 기준에 따르면 각성상태에서 수면초기상태(sleep stage 1)로 진입시 눈의 깜빡임이 둔화되며 후두부의 알파파(8-13Hz)의 활동이 줄어들고 세타파(4-7Hz)가 전반적으로 출현하^{11,12)} 알파블락(α -block)현상에 맞추어 피험자의 상태에 따라 “각성”, “천이”, “졸음”의 세 가지 상태로 분류하였다. 동영상 육안검사를 통하여 피험자의 졸음이 오는 시간과 뇌파를 동기화하였다.

ii) 분할된 세 가지 상태의 데이터를 $2^5(32) \sim 2^{11}(2048)$ 샘플 크기별로 윈도우를 조절하면서 A, T, D 세 가지 상태별로 100개의 데이터 집합 $A = \{A[0], \dots, A[99]\}$, $T = \{T[0], \dots, T[99]\}$, $D = \{D[0], \dots, D[99]\}$ 을 생성한다.

iii) 이 데이터 집합을 이용하여 EIV 모델의 차수를 p 차라고 하였을 때 EIV 분석을 통하여 상태별 AR 계수 $\mathbf{a}[k] = (a_1[k], \dots, a_p[k])^T$, $\mathbf{t}[k] = (t_1[k], \dots, t_p[k])^T$, $\mathbf{d}[k] = (d_1[k], \dots, d_p[k])^T$ 를 추출한다. 여기서 $k = 0, 1, \dots, 99$ 이고, 총 300개의 training set과 test data set으로 구성된다.

iv) 앞서 추출한 특징벡터들이 MLP 신경망의 입력 벡터로 사용되고, MLP 신경망에서 학습되고 세 가지 상태 중 하나로 분류가 된다.

v) 샘플의 크기와 EIV의 차수에 따라 분류율과 오분류율을 비교한다.

vi) 측정 환경에 대한 영향을 살펴보기 위해 취득 데이터에 SNR에 따른 AWGN을 더한 후 i)~v)의 과정을 반복한다.

표 1. 다층 신경망에 대한 파라미터
Table 1. Parameters of MLP neural network.

Parameters	Configuration
Learning algorithm	Scaled conjugate gradients
Learning rate	0.05
Transfer function	Tangent sigmoid function
Training method	Batch training
Performance measure	MSE

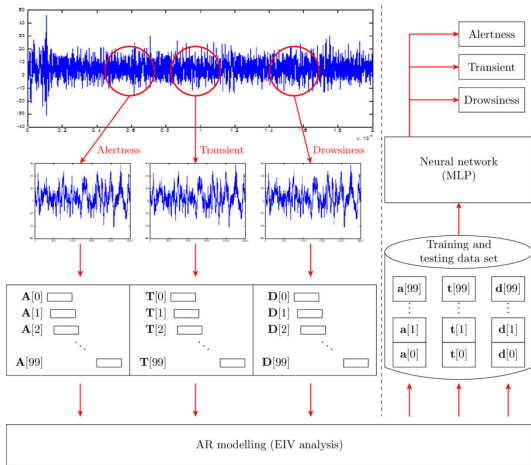


그림 4. 데이터의 분류와 분할
Fig. 4. Data classification and segmentation.

IV. 운전자 상태 분류 결과

구축된 특징 벡터 데이터베이스를 바탕으로 학습과 테스트를 위한 데이터 설정은 EIV 기법으로 추출한 특징 벡터의 70%를 학습 데이터로 30%를 테스트 데이터로 랜덤하게 나누었고 최상의 학습 모델 선정과 학습 과정에서 조기 중단(early stopping)을 결정하기 위해 학습 데이터 집합의 하위 집합인 모델을 검증하는 데이터 집합을 나누었다. 제안한 시스템에서는 Keams의 권장사항으로 학습 데이터의 20%를 검증을 위한 데이터로 나누었다. 논문에서 적용한 신경회로망 설계 및 학습은 MathWorks사 Matlab 8.0의 Neural Network Toolbox를 기반으로 하였다. 본 실험은 아래의 두 가지 방향으로 진행하였다.

- i) AR 차수와 샘플 크기의 변화에 따른 천이상태(정)분류율과 오분류율 비교
- ii) 테스트 데이터에 다양한 SNR을 갖는 AWGN을 더하여 LPC와 EIV의 평균 분류율 비교

AR 차수는 2차에서 10차까지 짝수 차수만을 고려하였고, 샘플의 크기는 32부터 2048로 2의 지수 승단위로 정하였고 10000번의 반복을 통하여 평균값을 분류 결과로 기록하였다.

그림 5는 AR 차수와 샘플의 크기에 따른 천이상태의 분류 결과를 보였다. 이는 실제 운전상황에서 졸음이 시작되는 천이상태가 가장 중요하기 때문이다. 차수에 따른 성능을 비교할 때 4차에서는 샘플 크기에 관계없이 95% 이상의 분류율을 보인다. 이는 취득한 EEG 신호를 AR 모델을 이용하여 EIV 계수를 추정할 때 2개의 극값이 원신호의 특성을 가장 잘 반영




그림 5. AR 차수와 샘플의 크기에 따른 천이상태 분류결과 ([17]의 결과는 스펙트럼 분석을 실시한 결과임.)
Fig. 5. Transient state classification result according to AR order and sample length. Also, reference performance with spectrum analysis using [17] is added for comparison.

하는 것으로 해석 할 수 있다. 또한 제안 시스템을 차량에 적용하기 위하여 샘플의 크기 즉 정보량은 시스템을 설정에 상당히 중요한 지표이다. 4차일 때 샘플 크기에 따른 분류 결과를 볼 때에 32샘플(0.25초)의 정보량에서 전체 분류율이 약 83% 정도였고 천이상태의 분류율이 85% 이상이었다. AR 모델과 기존방법과의 비교를 위하여 논문 [17]에서 제안한 스펙트럼 분석법을 이용한 천이상태의 평균 분류율을 그림 5에 도시하였다. 실험 결과로부터 본 논문에서 제안한 EIV와 MLP를 적용한 방식은 EIV의 차수에 관계없이 스펙트럼 분석법 보다 우수한 평균 분류율을 얻음을 확인하였다. 또한 논문 [8]에서 10초(2560 samples) 길이의 신호를 이용한 졸음 검출 시스템을 제안한 것에 비교하여 볼 때에 EIV 방법이 분류 결과 측면뿐만 아니라 적은 정보량을 가지고도 상당히 우수한 결과를 보인 것이다. 이는 제안 시스템이 짧은 순간에 일어날 수 있는 운전 중 돌발 상황을 실시간으로 검출이 가능하다는 것을 보여준다.

졸음 탐지 시스템에서는 분류율과 마찬가지로 다음과 같이 정의한 오분류율 또한 중요하다. 이 논문에서 오분류율은 “편향 오분류율”(biased misclassification rate)을 의미하고 다음과 같이 정의하였다.

$$P_{bm} = \Pr(\text{Alertness}|\text{Transition}) + \Pr(\text{Alertness}|\text{Drowsiness}) \quad (20)$$

일반적으로 각성 상태를 천이 상태나 졸음 상태로 잘못 판단하는 것은 분류 시스템의 성능의 열화를 의미하지만 실제 안전도 측면에서는 큰 문제가 되지 않는다. 반면에 천이 상태나 졸음 상태를 각성 상태로

판단하는 것은 안전도에 큰 문제를 야기하기 때문에 시스템의 신뢰도 측면에서 중요한 지표가 될 수 있다. 따라서 제안한 시스템의 오분류율에 대한 특성을 알아보는 것도 중요하다. 표 2는 차수와 샘플 크기에 따른 오분류율을 나타내었다. 이 결과로부터 AR의 차수가 4차에서 가장 작은 오분류율을 보임을 확인할 수 있다. 따라서 지금부터 제안한 시스템의 성능을 비교함에 있어 차수를 4로 고정하도록 한다.

뇌파와 같은 생체신호를 실제 현장에서 취득 시 주변 소음이나 기기에서 나오는 전자파 등에 의해 임펄스 잡음이나 기타 잡음이 포함될 가능성이 있다. 본 논문에서는 분석의 편의를 위해 생체신호 취득 시 발생할 수 있는 모든 잡음 상황 중에서 AWGN으로 처리되는 외부 잡음에 대한 영향으로 한정되었다. 이를 위해, 취득한 생체신호는 잡음이 없다고 가정하였고 (SNR→∞), 외부 잡음의 영향에 대한 특징벡터별 분류성능을 알아보기 위하여 취득한 각 데이터의 테스트 집합에 AWGN을 더하여 분류 성능을 평가하는 실험을 하였다. 또한 이전 실험에서 얻은 결과로부터 EIV 차수를 4로 고정시키고 원 신호(SNR→∞)와 SNR이 30, 25, 20, 15, 10, 5dB가 되도록 추가한 신호에 대해 특징 벡터들이 추가된 잡음에 얼마나 강인한지 평가하였고, 이를 LPC를 이용했을 경우와 비교한 결과를 그림 6과 7에 나타내었다.

그림 6은 4차에서 평균 SNR과 샘플의 크기에 따른 EIV와 LPC의 분류율을 비교하였다. EIV와 LPC의 경우 모두 샘플의 크기가 크고 SNR이 클수록 분류율은 향상되는 경향을 보인다. SNR이 낮은 영역에서, EIV의 경우 샘플이 클수록 분류율이 잡음에 민감하지 않지만, LPC의 경우에는 샘플의 크기에 관계없이 분류율이 전반적으로 떨어지는 것을 알 수 있다. 이 결과는 잡음에 취약한 AR모델링에서 EIV가 LPC의 대안이 될 수 있다는 것을 보여준다.

그림 7은 분류율 85%를 달성하기 위한 필요한 최소 샘플 크기에 대해 EIV와 LPC를 비교하였다. LPC의 경우 잡음이 없는 환경에서도 최소 128 샘플 이상




그림 6. 평균 SNR과 샘플의 크기에 따른 EIV와 LPC의 분류율 비교(차수4)
 Fig. 6. Comparison of average classification rate between EIV and LPC according to average SNR and length of samples for order 4(Solid lines with faced marker and dashed lines with unfaced marker represent average classification rates with EIV and LPC, respectively).




그림 7. EIV와 LPC에 대해 분류율 85%를 달성하기 위한 최소의 샘플 크기에 대한 비교(차수4)
 Fig. 7. Comparison of minimum length of samples for more than or equal to 85% average classification rate between EIV and LPC according to average SNR(order 4)

이어야 하고 SNR이 20dB 이하일 경우에는 2048 이상의 큰 샘플 크기가 요구된다. 반면에 EIV는 잡음이 없는 환경에서는 32 샘플 크기를 가지고도 분류율 85%를 얻을 수 있고, 5dB의 경우 샘플 크기가 512 이상이 되어야 한다. 그러므로 제안한 시스템에서 채

표 2. EIV의 차수와 샘플의 크기에 따른 편향 오분류율(%)
 Table 2. Biased misclassification rate according to the order of EIV and sample length.

Sample length \ Order	32	64	128	256	512	1024	2048
2	37.63	36.94	33.52	26.7	18.58	19.27	9.82
4	16.9	11.69	9.69	6.16	5.67	5.3	4.84
6	33.7	30.57	24.71	29.54	27.81	26.2	13.43
8	45.94	48.98	46.77	46.1	43.8	52.92	42.66
10	55.61	47.03	48.21	55.08	57.97	51.53	41.21

널 환경이 나쁜 경우, 즉, SNR이 작은 영역(15dB이하)에서는 85%의 분류율을 얻기 위한 최소 샘플 크기는 512이라는 것을 알 수 있다. EIV는 측정 환경이 좋은 경우(SNR이 높은 영역)에는 작은 크기의 샘플로도 높은 분류율을 얻을 수 있는 장점이 있지만, 측정 환경이 좋지 않은 경우에는 EIV를 활용한 경우에도 낮은 분류율을 보인다. 따라서 안정적인 시스템을 운용하기 위해서는 채널의 상태를 면밀히 고려해야 할 것이다.

V. 결 론

본 논문에서는 AR 계수 추정을 위해 EIV 기법을 활용하고 분류자로서 MLP를 이용한 운전자의 졸음 가지 시스템을 제안하였다. 기존의 뇌파 분석 연구에서 알파파, 베타파, 세타파, 감마파와 같은 스펙트럼 분석을 통한 상태별 특징벡터 추출에 국한되었다면 본 연구에서 제안된 특징벡터 EIV 계수는 스펙트럼 분석보다 특징 벡터를 더 정량화 할 수 있다는 장점을 가진다. 게다가 EIV 분석은 적은샘플에 대해서도 스펙트럼 분석보다 높은 분류율을 가지기 때문에 향후 차량에 적용할 때 운전자10의 졸음에 대한 빠른 응답과 빠른 경고조치를 취할 수 있을 것이다. 또한 AR 모델의 취약점이라고 할 수 있는 잠음 문제에 대해서도 EIV는 기존의 LPC 방법을 이용한 것보다 낮은 SNR영역에서 우수한 분류 성능을 보여 기존 연구보다 분류 성능 향상에 기여하였다.

그동안 운전자에게 편리함 제공 및 구현 시 가격적인 측면에서 졸음 감지 시스템이 비전 기반으로 한 개발이 주가 되었다. 하지만 근래에 무선으로 뇌파를 측정하는 방법이 이미 개발되었고 집중력 향상 등에 도움을 주는 뇌파 측정장비의 보급이 일반화되었다. 그러므로 앞으로 근본적인 졸음을 찾아낼 수 있는 생체 신호를 기반으로 하는 시스템 개발은 더욱 확대될 것으로 예상된다. 이를 토대로 본 연구진은 향후 더 많은 피험자 집단에 대한 데이터베이스를 확립한 후 뇌파의 잠음 제거와 같은 전처리 과정을 추가하여 EIV 계수를 자동으로 분류하는 시스템을 구축할 것이며 이러한 연구방법을 기반으로 차량제어의 가능성을 추진해 볼 것이다.

References

[1] Q. Ji, Z. Zhu, and P. Lan, "Real-time nonintrusive monitoring and prediction of

driver fatigue," *IEEE Trans. Veh. Technol.*, 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] J.-M. Choi, H. Song, S. H. Park, and C.-D. Lee, "Implementation of driver fatigue monitoring system," *J. KICS*, vol. 37, no. 8, pp. 711-720, 2012.

[4] Y. H. Joo, J. K. Kim, and I. H. Ra, "Intelligent drowsiness drive warning system," *J. KIIS*, vol. 18 no. 2, pp. 223-229, 2008.

[5] H. Kataoka, H. Yoshida, A. Saijo, M. Yasuda, and M. Osumi, "Development of a skin temperature measuring system for non-contact stress evaluation," in *Proc. 20th Annual Int. Conf. IEEE Eng. Medicine Biology Soc.*, 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] Y.-B. Lee and M.-H. Lee, "Automobile system for drowsiness accident detection using EDA signal analysis," *Trans. KIEE*, vol. 56. no. 2, pp. 227-450, 2007.

[8] M. V. M. Yeo, X. Li, K. Shen, and E. 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] M. Steriade, "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] S. K. L. Lal and A. Craig, "A critical review of the psychophysiology of driver fatigue," *Biological Psychology*, vol. 55, pp. 173-94, 2001.

[11] M. V. M. Yeo, X. Li, and E. P. V. Wilder-Smith, "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] H. J. Moller, L. Kayumov, E. L. Bulmash, J. Nhan, and C. M. Shapiro, “Simulator performance, microsleep episodes, and subjective sleepiness: normative data using convergent methodologies to assess driver drowsiness,” *J. Psychosomatic Research*, vol. 61, pp. 335-342, 2006.
- [13] H. Han, D. Kim, D. An, G. B. Hong, and U. Chong, “Driver drowsiness and alertness detection method using linear predictive coding and electroencephalographic change,” in *Proc. KISPS Falls Conf. 2011*, pp. 237-239, Dec. 2011.
- [14] R. Diversi, U. Soverini, and R. Guidorzi, “A new estimation approach for AR models in presence of noise,” in *Proc. Preprints 16th IFAC World Congr.*, pp. 290-294, 2005.
- [15] Y.-S. Kang and C.-S. Bae, “License plates detection using a Gaussian windows,” *J. KICS*, vol. 37, no. 9, pp. 780-785, 2012.
- [16] C. J. Lee, B. Son, and H. S. Hong, “Improvement of pattern recognition capacity of the fuzzy ART with the variable learning,” *J. KICS*, vol. 38, no. 15, pp. 954-961, 2013.
- [17] B. T. Jap, S. Lal, P. Fischer, and E. Bekiaris, “Using EEG spectral components to assess algorithms for detecting fatigue,” *Expert Syst. Appl.*, vol. 36, no. 2, pp. 2352-2359, 2009.

한 형 섭 (Hyungseob Han)



2009년 8월 : 울산대학교 컴퓨터정보통신공학부 졸업
 2011년 8월 : 울산대학교 컴퓨터공학과 석사
 2011년 8월~현재 : 울산대학교 전기공학부 박사과정
 <관심분야> 고장진단, 생체신호처리, 인공지능

송 경 영 (Kyoung-Young Song)



2004년 2월 : 고려대학교 전기전자공학부, 수학과 졸업
 2010년 8월 : 서울대학교 전기컴퓨터공학부 박사
 2010년 8월~2012년 2월 : LG 전자 선임연구원
 2012년 3월~현재 : 울산과학기술대학교 전기전자공학부 조교수
 <관심분야> 스마트그리드 보안, 생체신호처리, MIMO 통신