

논문 2013-50-11-25

감성판별을 위한 생체신호기반 특징선택 분류기 설계

(The Design of Feature Selection Classifier based on Physiological Signal for Emotion Detection)

이 지 은*, 유 선 국**

(JeeEun Lee and Sun K. Yoo[©])

요 약

감성은 학습, 행동, 의사결정, 상호대화를 포함한 인간의 일상생활에 중요한 요소이다. 본 논문에서는 시스템의 복잡도를 줄이기 위하여 생체신호로부터 최소한의 중요한 특징만을 추출하여 사용하는 감성 분류기를 설계하고자 한다. 생체신호는 맥파, 피부온도, 피부전도도, 뇌파신호(전두엽, 두정엽)를 사용하였으며, 4가지 감정(보통, 슬픔, 공포, 행복)은 영화 관람을 통하여 유도하였다. 측정된 생체신호로부터 추출한 24개의 특징으로부터 최적의 특징 집합의 결정은 서포트벡터머신 기반 적합도 함수를 사용하는 유전알고리즘을 적용하였다. 최적의 4감정 분류 정확도는 96.4%이었으며, 서포트벡터머신만을 사용하였을 경우보다 17% 높았다. 선택된 최소에러 특징은 맥파 심박변이도의 평균, NN50, 맥파 유도 맥파 전달 시간의 평균, 피부전도도의 평균과 두정엽 뇌파의 δ , β 주파수 대역에너지였다. 실험을 통하여 두정엽 뇌파, 맥파, 피부전도도의 조합이 고정밀 감정 장비에 적합하였으며, 79% 성능을 보인 맥파와 피부전도도의 조합이 간단한 감성장비에 적절하게 적용할 수 있다.

Abstract

The emotion plays a critical role in human's daily life including learning, action, decision and communication. In this paper, emotion discrimination classifier is designed to reduce system complexity through reduced selection of dominant features from biosignals. The photoplethysmography(PPG), skin temperature, skin conductance, frontal and parietal electroencephalography(EEG) signals were measured during 4 types of movie watching associated with the induction of neutral, sad, fear joy emotions. The genetic algorithm with support vector machine(SVM) based fitness function was designed to determine dominant features among 24 parameters extracted from measured biosignals. It shows maximum classification accuracy of 96.4%, which is 17% higher than that of SVM alone. The minimum error features selected are the mean and NN50 of heart rate variability from PPG signal, the mean of PPG induced pulse transit time, the mean of skin resistance, and δ and β frequency band powers of parietal EEG. The combination of parietal EEG, PPG, and skin resistance is recommendable in high accuracy instrumentation, while the combinational use of PPG and skin conductance(79% accuracy) is affordable in simplified instrumentation.

Keywords : 감성, 생체신호, 서포트벡터머신, 유전알고리즘

Emotion, Physiological signal, Support vector machine, Genetic algorithm

* 학생회원, 연세대학교 일반대학원 생체공학협동과정

(Graduate School of Biomedical Engineering, Yonsei University, Seoul, Korea)

** 정회원, 연세대학교 의과대학 의학공학교실

(Department of Medical Engineering, Yonsei University College of Medicine, Seoul, Korea),

© Corresponding Author (E-mail: sunkyoo@yuhs.ac)

※ 본 연구는 2012년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행되었음 (No.2010-0026833).

접수일자 : 2013년7월26일, 수정완료일 : 2013년11월4일

I. 서 론

감성은 학습능력, 행동, 판단력 등 사람의 삶에서 많은 부분에 영향을 끼치므로 사람의 본질을 이해하는데 중요한 역할을 한다^[1]. 감성을 이해하고 표현하는 것은 사람간의 의사소통에 중요한 역할을 미친다. 따라서 연구자들에게 감성분석은 중요한 이슈가 되고 있으며 이는 사람과 기계의 상호작용을 가능하게 해주는 기술로 인식되고 있다^[2-3].

감성은 사람의 뇌와 밀접하게 연관되어 있으며 아무런 의식 없이 자발적으로 일어나는 정신 상태에서 생리학적인 변화를 동반한다고 정의된다^[4]. 연구자들은 감성연구에 있어서 두 개의 모델에 집중한다. 그 중 하나는 행복, 슬픔, 공포, 놀람, 역겨움, 분노의 6가지 감성을 기본적으로 수용하여 다른 감정들을 이 기본 감성의 한 부분이 되도록 고려하는 것이고^[5], 나머지 하나는 감성의 유의성 상태와 각성 상태를 스케일로 나타내어 이차원 그래프로 확인하는 것이다^[6].

얼굴표정, 몸짓 혹은 글 등은 감성을 추측할 수는 있으나 진짜 그러한 감성을 느끼는 지에 관해서는 알 수가 없다. 그러나 우리가 느끼는 감성으로부터 일어나는 중추신경계와 자율신경계의 반응인 생체신호의 특징으로부터는 감성상태의 판별이 가능하다^[7]. 생체신호는 주위조건에 매우 민감하기 때문에 비특이적이라는 단점이 있다. 그러나 생체신호는 연속적으로 감성의 변화를 알 수 있을 뿐만 아니라 생리학적으로 감성이 사람에게 영향을 미치는지에 관하여 직접적으로 알 수 있다^[8]. 따라서 생체신호는 감성연구에 있어 중요한 지표로 사용될 뿐만 아니라 현재는 이를 이용하여 많은 기술이 응용되고 발전하는 시대이다.

본 연구에서는 행복, 슬픔, 공포, 보통상태의 감성 자극이 주어졌을 때의 측정된 생체신호를 바탕으로 특징을 추출한다. 추출된 여러 특징을 이용하여 감성판별을 하는데 주요한 역할을 하는 특징을 선택해주는 데 본 논문의 목적이 있으며, 이를 통하여 최적화된 감성판별 알고리즘의 구현이 가능하게 하고자 한다.

II. 본 론

1. 실험 및 데이터생성

(1) 실험환경 및 프로토콜

실험은 질환을 가지고 있지 않은 평균 60세의 노년층 여성 10명을 대상으로 진행하였다. 피험자의 생체신호는 BIOPAC MP 150TM에서 측정되었고, 1kHz로 샘플링 되었다. 피험자의 원활한 감성을 유발하기 위하여 진행자는 피험자와 다른 공간에 있으며 실험을 진행시켰고, 피험자는 자극유발 영상물을 4인치 스크린을 통하여 시청하였다. 생체신호의 잡음을 최소화시키기 위하여 피험자에게 움직임은 최소화시켜달라는 권유 하에 실험을 진행하였다^[9].

자극유발에 앞서 피험자를 30분간 휴식을 취하도록 하여 생체신호의 기저 선을 일정하게 유지하도록 하였으며 휴식 후 본 실험이 진행되었다. 본 실험은 감성유발 영상을 보여주기 전 15분 동안 다큐멘터리 영상을 시청하게 하여 참조치(reference)로 측정하여 피험자 간 개인차를 최소화 시키도록 하였다. 참조치를 측정 후 60분 동안 감성유발 영상을 시청하게 하여 영상자극 시 생체신호를 측정하였다^[9].

본 연구는 보통, 슬픔, 공포, 행복 4가지 감성에 관한 생체신호 특징선택에 목적이 있다. 따라서 보통, 슬픔, 공포, 행복 감성별 생체신호 획득을 위하여 사용한 감성유발영상은 각각 역사 다큐멘터리 영상, 휴먼 다큐멘터리 '폴빵엄마', 'saw3', 'mamma mia'이다^[9]. 각 영상은 참조치를 측정하는 15분의 영상을 제외하고 한 영상 당 60분간 시청하도록 하였으며, 피험자 한 명당 4개의 감성유발영상을 보여주었다. 또한 각 영상은 하루에 한 개씩 상영하여 한 피험자 당 4일간의 실험기간이 필요하였다.

(2) 신호측정 및 데이터 생성

실험프로토콜을 사용하여 측정된 생체신호는 맥파, 피부온도, 피부전도도, 뇌파 신호로 총 4개이다. 맥파, 피부온도, 피부전도도는 자율신경계의 신호로 연속적으로 신호가 나타나므로 시간에 따른 변화를 알기가 쉽고, 뇌파는 중추신경계를 대표하는 생체신호로 감성에 따라 뚜렷한 특징을 가진다.

적외선을 피부에 쏘아주어 측정하는 맥파 신호는 심전도 신호의 정보를 담고 있을 뿐만이 아니라 맥파 전달 시간과 호흡신호의 간접유도도 가능하다. 또한 심전도 장치보다 간단한 하드웨어 구성이 가능하므로 본 연구에서는 심전도 신호를 대신하여 맥파 신호를 사용하

여 맥파 신호의 피크 간격의 변화를 통하여 심박변이도(Heart rate variability)를 추출하였다^[10~11]. 심박변이도로부터 추출한 파라미터는 심박변이도의 평균(Mean), SDNN(the standard deviation of NN intervals), RMSSD(the square root of the mean squared difference of successive NNs), NN50(the number of pairs of successive NNs that differ by more than 50ms), HF/LF(the ratio of both high frequency and low frequency)의 총 5개의 특징이다. 간접유도 된 맥파 전달 시간으로부터 추출한 파라미터는 맥파 전달 시간(Pulse transit time)의 평균과 표준편차 값 2개이다. 또한 맥파로부터 간접유도 된 호흡(Respiration) 정보는 영교차율을 이용하여 호흡시간의 평균, 표준편차 그리고 영교차율(Zero-crossing)의 총 3개 특징이 추출되었다^[12,13]. 따라서 맥파 신호로부터 추출된 특징들은 총 10개로 정의되며, 이들은 심박변이도, 맥파 전달 시간, 호

흡의 다양한 생체신호 특징을 모두 포함한다.

자율신경계 중 하나인 피부온도는 빠른 응답 특성을 보이므로 감성판별을 위한 생체신호로 사용하였고, 추출된 파라미터는 피부온도 평균과 표준편차이다^[14].

피부전도도는 손가락에 2개의 전극을 부착하여 측정한다. 피부전도도는 교감신경계의 활성정도를 분별하는데 사용이 가능하며 사용한 피부전도도의 특징은 평균과 영교차율 총 2개이다^[15].

뇌파신호는 전두엽과 두정엽에서 측정되었다. 뇌의 전두엽과 두정엽은 감정 및 감각기능과 밀접한 관계를 가지고 있으므로 이 부위에서 뇌파신호는 감정상태 분별을 위해 뚜렷한 특징을 가지게 된다^[16]. 획득된 뇌파신호를 고속 푸리에 변환(FFT)을 이용하여 δ 파, θ 파, α 파, β 파, γ 파 각 각의 주파수 대역 에너지를 구하여 전체 에너지에 대한 상대적인 비를 개별 특징벡터로 사용하였다. 이에 따라 뇌파신호의 특징은 전두엽(Frontal

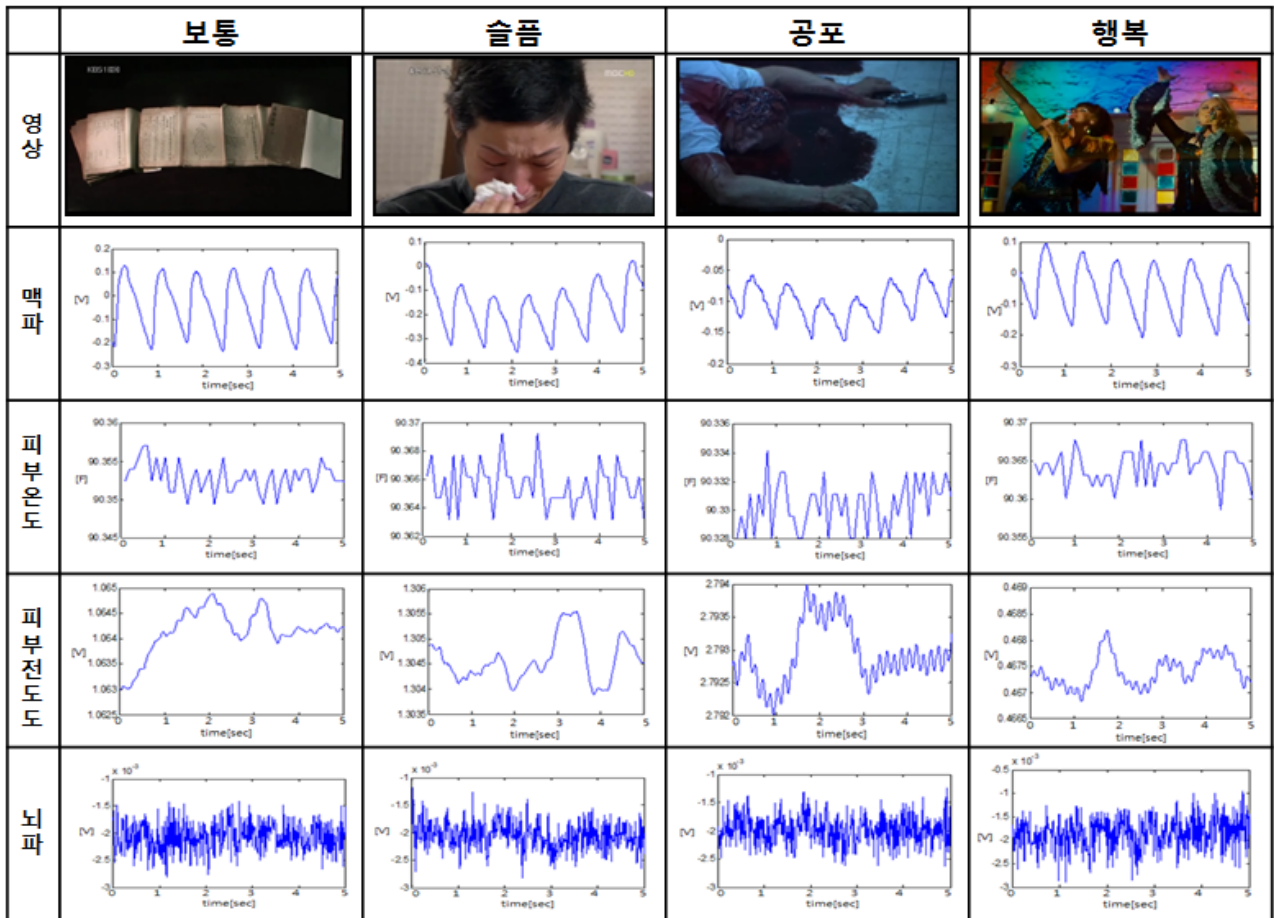


그림 1. 각 감성별 영상 및 측정된 생체신호
 Fig. 1. Video and physiological signal of each emotion.

EEG)과 두정엽(Parietal EEG)에서 각각 δ 파, θ 파, α 파, β 파, γ 파 주파수대역 에너지 5개 씩 총 10개의 특징벡터가 추출되었다.

본 논문에서는 실험데이터를 훈련과 테스트 데이터 집합으로 구분하였고 추출한 총 24개의 특징들로부터 감성판별을 위한 특징선택 분류기를 설계하고자 하였다.

그림 1은 본 연구에서 사용한 각 감성에 따른 영상 및 측정된 생체신호를 나타낸 것이다. 생체신호의 가로축은 시간을 나타내고, 맥파, 피부온도, 피부전도도, 뇌파 각각의 세로축은 각각 전압[V], 화씨온도[F], 전압[V], 전압[V]을 나타낸다. 본 논문에서는 추출된 특징들을 간략화하여 표현하기 위하여 다음과 같이 특징벡터를 정의하고자 한다.

$$F.V. = [m_H, d_H, r_H, n_H, f_H, m_T, s_T, m_R, z_R, s_R, m_S, s_S, z_G, m_G, \delta_F, \theta_F, \alpha_F, \beta_F, \gamma_F, \delta_C, \theta_C, \alpha_C, \beta_C, \gamma_C]$$

F.V.: Feature vector

m: Mean; s: Standard deviation; z: Zero-crossing

d: SDNN; r: RMSSD; n: NN50; f: HF/LF

δ : δ frequency band power; θ : θ frequency band power

α : α frequency band power; β : β frequency band power

γ : γ frequency band power

P: PPG

H: Heart rate variability derived from P

T: Pulse transit time derived from P

R: Respiration derived from P

S: SKT; G: GSR; F: Frontal EEG; C: Parietal EEG

2. 특징 선택 분류기

(1) 서포트벡터머신(SVM; Support vector machine)

SVM은 오류율을 최소화할 뿐 아니라, 부류사이의 일반화 능력을 최대화한다는 목적을 가지고 만들어졌다^[16]. SVM은 데이터의 고차원적 매핑으로 데이터 분류가 용이하고, 다른 분류기와 비교하여 보다 높은 성능을 가지므로 SVM을 사용하였다^[17].

4가지 감성상태 시 획득된 생체신호의 특징들을 SVM 분류기의 입력으로 사용하였다. 또한 복잡한 형태를 보이고 뇌파신호에 대한 결정곡선의 분리성을 향상하기 위하여 고차원로의 매핑변환을 해주는 커널함수를 아래와 같이 사용하였다.

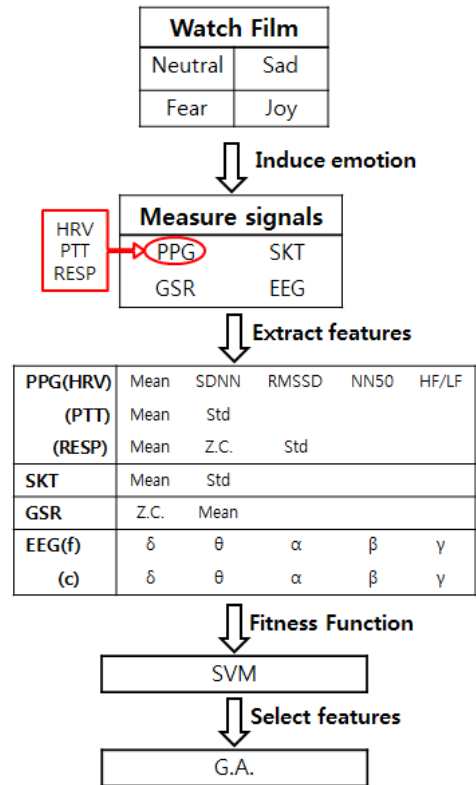


그림 2. 전체적인 처리과정 흐름도

Fig. 2. Flowchart of overall processing.

Linear Function: uv (1)

Polynomial Function: $(\gamma uv + c)^d$ (2)

Radial Basis Function: $\exp(\gamma uv^2)$ (3)

Sigmoid Function: $\tanh(\gamma uv + c)$ (4)

여기서 u 는 테스트 집합, v 는 서포트 벡터, γ 는 정도를 조절해주는 감마값, c 는 계수, d 는 차원을 나타낸다. 따라서 γ, c, d 를 조정해주므로 최적의 커널함수를 선별할 수 있다^[18].

(2) 유전알고리즘(GA; Genetic algorithm)

GA는 진화방법과 유사하게 초기해가 적합함수에 따라 선택(selection), 교차(crossover), 변이(mutation)를 일으키며 해를 개선시키는 방향으로 전개된다. GA는 해가 지역 최저점에 빠지더라도 전이 과정을 통하여 고착된 지역해로부터 벗어나 전역최저점을 찾아갈 확률을 높인다. 따라서 추출한 파라미터의 최적조합 결정을 위하여 GA를 적용하였다^[19].

본 논문에서는 해를 1과 0으로 표현하였다. 해가 1의 값을 가지면 그 때의 생체신호특징은 입력으로 선택이 되고, 해가 0의 값을 가지면 생체신호특징은 선택되지 않는다. SVM을 사용하여 최적화 분류 계산된 오류율이 GA의 적합도 함수로 사용하였다. 여기서 오류율은 틀리게 분류한 개수를 총 개수로 나누어 준 비이다. 또한 해의 개수, 선택조건, 교차조건, 변이조건을 변화시키며 GA의 최적동작 조건을 찾아주었다.

그림 2는 본 연구의 전체적인 흐름을 나타내어 준 것이다. 보통, 슬픔, 공포, 행복 4가지 감성유발 비디오 시청 시 맥파, 피부온도, 피부전도도, 뇌파신호를 측정한다. 그로부터 그림 2에 나타난 것과 같이 총 24개의 특징을 추출할 수 있다. 추출된 특징을 입력으로 하여 적합함수인 SVM에 적용시키고, GA를 사용하여 오류율이 가장 작을 때의 특징들을 선택하여준다.

III. 결과 및 토의

1. 추출된 특징

본 연구의 특징추출 과정을 통하여 추출된 특징은 그

림 3과 같다. 각 감성별 평균과 표준편차는 표 1과 같다. 이는 각 감성별로 추출된 생체신호 특징들의 평균을 나타낸 것이고, 이를 통하여 감성별로 어떠한 특징이 차이가 나는지를 알 수 있다.

표 1에서 알 수 있듯이 각각의 특징들 모두 표준편차들을 고려하면 중첩되는 부분을 가지고 있다. 가장 감성 간 평균의 차이가 큰 특징인 피부전도도 평균의 경우, 평균과 표준편차는 보통상태 시 0.44 ± 0.20 , 슬픔감성 시 0.23 ± 0.08 , 공포상태 시 0.80 ± 0.10 , 행복감성 시 0.03 ± 0.03 이다.

그러나 전반적으로는 특징 간 큰 차이가 있음에도 불구하고 표준편차에 의하여 보통상태의 최소값 0.24와 슬픔 감성 시의 최대값 0.31이라는 값이 추출되면 두 개의 상태는 서로 중첩되어 감성을 구분하는 데 어려움이 생긴다.

또한 맥파 신호에서 추출된 호흡과 같이 감성 간 평균의 차이가 매우 작은 경우에는 평균과 표준편차가 보통상태 시 0.61 ± 0.12 , 슬픔감성 시 0.61 ± 0.13 , 공포상태 시 0.61 ± 0.09 , 행복감성 시 0.61 ± 0.14 이고, 이는 데이터 특징이 유의한 차이를 보이지 않으므로 의미 있는 특징




그림 3. 각 감성별 신호 특징
Fig. 3. Signal feature of each emotion.

표 1. 각 감성 별 평균과 표준편차

Table 1. Mean and standard deviation of each emotion.

	Neutral	Sad	Fear	Joy
m _H	0.65±0.10	0.45±0.09	0.31±0.09	0.63±0.15
d _H	0.05±0.08	0.05±0.10	0.03±0.02	0.08±0.17
r _H	0.03±0.06	0.03±0.10	0.01±0.01	0.06±0.17
n _H	0.37±0.11	0.51±0.11	0.63±0.12	0.39±0.13
f _H	0.04±0.07	0.04±0.04	0.05±0.11	0.05±0.11
m _T	0.51±0.07	0.12±0.11	0.24±0.07	0.34±0.10
s _T	0.04±0.08	0.05±0.15	0.02±0.01	0.06±0.10
m _R	0.61±0.12	0.61±0.13	0.61±0.09	0.61±0.14
z _R	0.53±0.12	0.04±0.10	0.03±0.11	0.30±0.12
s _R	0.10±0.05	0.09±0.04	0.09±0.03	0.47±0.26
m _S	0.26±0.08	0.32±0.04	0.36±0.14	0.31±0.10
s _S	0.23±0.17	0.12±0.06	0.30±0.16	0.26±0.16
z _G	0.42±0.20	0.39±0.18	0.49±0.23	0.51±0.18
m _G	0.44±0.20	0.23±0.08	0.80±0.10	0.03±0.03
δ _F	0.74±0.13	0.76±0.09	0.74±0.11	0.81±0.10
θ _F	0.40±0.08	0.41±0.04	0.40±0.05	0.42±0.09
α _F	0.27±0.12	0.25±0.06	0.26±0.08	0.22±0.07
β _F	0.35±0.19	0.31±0.16	0.35±0.20	0.23±0.16
γ _F	0.51±0.17	0.46±0.14	0.51±0.15	0.36±0.17
δ _C	0.33±0.06	0.29±0.06	0.23±0.17	0.81±0.11
θ _C	0.62±0.03	0.62±0.05	0.69±0.11	0.20±0.12
α _C	0.59±0.03	0.61±0.03	0.64±0.13	0.18±0.10
β _C	0.21±0.02	0.22±0.02	0.19±0.09	0.75±0.10
γ _C	0.83±0.02	0.82±0.02	0.82±0.16	0.25±0.15

데이터라고 정의할 수 없다. 이러한 생체신호 특징은 감성분류를 위해 사용할 때 분류 마진 간격이 작아 분리 효율성이 낮은 파라미터이다.

따라서 한 신호만을 넣게 된다면 정규화시킨 신호의 표준편차 때문에 분류 오류가 발생할 수 있는 문제점을 가지게 된다. 이러한 오류를 줄이기 위하여 감성분류를 위하여 하나의 신호가 아닌 여러 생체신호의 조합이 필요로 된다.

2. 적합함수 조건 설정

앞의 수식 (1)~(4)의 대한 커널함수를 기반으로 γ , c , d 를 조절하며 실험데이터에 최적조건의 SVM 적합함수를 선택하였다. 이때 입력은 추출된 특징을 모두 사용하였다.

Polynomial 커널함수의 변수에서 γ 는 0에서 1까지 0.1씩 변화시켜주었고, d 는 0에서 10까지 1의 간격으로 변화시켜주었다. 최대 성능은 γ 를 1로 설정하였을 때 73.87%였고 d 역시 1일 때 73.42%의 성능을 가졌다.

표 2. 커널함수별 정확도

Table 2. Accuracy of each kernel function.

Kernel Function	정확도
Linear Function	72.97%
Polynomial Function	73.42%
Radial Basis Function	77.03%
Sigmoid Function	72.52%

Radial basis 커널함수의 변수 γ 를 0에서 1까지 0.1씩 변화시켜 주었을 때, $\gamma=1$ 에서 76.13%의 최대 성능을 가짐을 확인하였다. Sigmoid 커널함수의 γ 를 0에서 1까지 변화시켜 주었을 때 0.2에서 72.52%의 정확도를 가졌고, c 를 -1에서 1까지 변화시켜 주었을 때 0에서 64.86%의 정확도를 가짐을 확인하였다^[20].

표 2는 (1)~(4) 각각의 커널함수의 사용 시 최대성능을 정리하여 놓은 것이다. radial basis 커널함수가 77.03%의 가장 좋은 성능을 보임을 확인할 수 있다.

본 연구에서는 가장 높은 정확도 77.03%를 보이는 $\gamma=1$ 인 radial basis 함수를 커널함수로 사용하였다.

3. GA을 이용한 특징선택

GA-SVM 분류기를 설계를 위하여 추출된 모든 특징들을 입력으로 사용하였다. 해의 개수, 선택조건, 교차조건, 변이조건을 변화시켜가며 최적의 GA 조건을 조정하였다.

그림 4는 해의 개수에 따른 에러율의 변화를 보여준다. 해의 개수는 5개부터 100개까지 5 간격으로 변화시켜 주었다. 해의 개수가 5개일 때는 오류율이 28.83%였고 해의 개수가 10개 일 때는 7.21%로 오류율이 급격




그림 4. 해의 개수에 따른 GA 변화

Fig. 4. Change of GA about number of population.

표 3. GA 조건별 정확도 및 선택된 특징
Table 3. Accuracy and selected feature for GA condition.

Selection	Crossover fraction	Mutation	Accuracy(%)	Selected features
Roulette	One	Gaussian	96.4	$m_H, n_H, m_T, m_R, s_S, m_G, \delta_C, \alpha_C, \gamma_C$
Roulette	One	Feasible	96.4	$m_H, d_H, r_H, n_H, m_T, s_R, s_S, m_G, \delta_C, \alpha_C,$
Roulette	One	Uniform	95.5	$m_H, r_H, n_H, f_H, m_T, s_T, m_R, s_R, m_S, m_G, \delta_C, \alpha_C$
Roulette	Two	Gaussian	96.4	$m_H, d_H, r_H, n_H, m_T, s_S, m_G, \delta_C, \theta_C, \beta_C, \gamma_C$
Roulette	Two	Feasible	96.4	$m_H, r_H, n_H, f_H, m_T, s_R, s_S, m_G, \delta_C, \theta_C, \alpha_C, \beta_C$
Roulette	Two	Uniform	95.95	$m_H, r_H, n_H, m_T, s_R, m_S, m_G, \alpha_C, \beta_C, \gamma_C$
Roulette	Scatter	Gaussian	96.4	$m_H, n_H, m_T, s_R, m_G, \delta_C, \beta_C$
Roulette	Scatter	Feasible	96.4	$m_H, n_H, m_T, s_S, m_G, \delta_C, \theta_C, \alpha_C, \beta_C, \gamma_C$
Roulette	Scatter	Uniform	96.4	$m_H, n_H, m_T, m_S, m_G, \alpha_F, \delta_C, \gamma_C$
Tournament	One	Gaussian	95.95	$m_H, r_H, n_H, m_T, s_R, m_G, \theta_C, \gamma_C$
Tournament	One	Feasible	96.4	$m_H, n_H, m_T, m_G, \delta_C, \beta_C, \gamma_C$
Tournament	One	Uniform	95.95	$m_H, r_H, n_H, m_T, m_S, s_S, m_G, \theta_F, \alpha_C, \beta_C, \gamma_C$
Tournament	Two	Gaussian	96.4	$m_H, n_H, f_H, m_T, m_G, \delta_C, \theta_C$
Tournament	Two	Feasible	95.5	$m_H, r_H, n_H, m_T, s_T, z_R, m_S, m_G, \theta_F, \alpha_F, \alpha_C, \beta_C$
Tournament	Two	Uniform	95.95	$m_H, r_H, n_H, f_H, m_T, m_S, m_G, \alpha_C, \beta_C$
Tournament	Scatter	Gaussian	96.4	$m_H, r_H, n_H, f_H, m_T, m_S, m_G, \alpha_C, \beta_C$
Tournament	Scatter	Feasible	96.4	$m_H, n_H, m_T, m_G, \delta_C, \beta_C$
Tournament	Scatter	Uniform	96.4	$m_H, d_H, r_H, n_H, f_H, m_T, s_R, s_S, m_G, \delta_C, \beta_C$
Uniform	One	Gaussian	70.27	$m_H, n_H, f_H, m_R, z_R, s_R, m_S, s_S, z_G, m_G, \delta_F, \alpha_F, \beta_F, \gamma_F, \delta_C, \beta_C, \gamma_C$
Uniform	One	Feasible	71.17	$m_H, d_H, n_H, f_H, m_R, z_R, s_R, m_S, m_G, \delta_F, \theta_F, \alpha_F, \beta_F, \gamma_F, \delta_C, \theta_C, \alpha_C, \beta_C, \gamma_C$
Uniform	One	Uniform	92.34	$m_H, r_H, n_H, f_H, m_T, m_R, z_R, s_R, s_S, m_G, \beta_F, \delta_C, \theta_C, \alpha_C, \beta_C$
Uniform	Two	Gaussian	88.29	$m_H, n_H, f_H, m_T, z_R, s_R, z_G, m_G, \delta_F, \theta_F, \alpha_F, \beta_F, \gamma_F, \alpha_C, \beta_C, \gamma_C$
Uniform	Two	Feasible	92.34	$m_H, d_H, n_H, f_H, m_T, s_T, m_R, z_R, s_R, m_S, s_S, z_G, m_G, \delta_F, \alpha_F, \beta_F, \gamma_F, \delta_C, \theta_C, \alpha_C, \beta_C, \gamma_C$
Uniform	Two	Uniform	79.28	$m_H, r_H, n_H, f_H, m_T, s_T, m_R, z_R, z_G, m_G, \delta_F, \theta_F, \alpha_F, \beta_F, \gamma_F, \delta_C, \theta_C, \gamma_C$
Uniform	Scatter	Gaussian	94.14	$d_H, r_H, n_H, m_T, z_R, m_G, \delta_F, \theta_F, \beta_F, \delta_C, \theta_C$
Uniform	Scatter	Feasible	63.96	$d_H, r_H, n_H, s_T, z_R, m_G, \theta_F, \alpha_F, \beta_F, \gamma_F, \delta_C, \beta_C$
Uniform	Scatter	Uniform	81.98	$m_H, s_T, m_R, m_G, \delta_F, \theta_F, \alpha_F, \beta_F, \gamma_F, \beta_C, \gamma_C$

히 감소하다가 해의 개수가 늘며 오류율이 3.6%~5.4%의 범위 내에서 변동하면서 해의 개수가 50개일 때 3.6%의 최소오류율을 가졌다. 선택된 해의 개수는 최소 오류율인 3.6%가 처음 나온 경우인 해의 개수인 50일 때를 GA 조건으로 설정하였다.

표 3은 선택방법, 교차방법, 변이방법에 따른 정확도 및 선택된 특징이다. 선택방법이 roulette과 tournament일 때 정확도는 95.5%~96.4%로 큰 차이는 보이지 않았으나 선택방법을 uniform으로 하였을 때는 정확도가 떨어짐을 확인할 수 있으며 정확도의 차가 큰 것을 볼 수 있다. 또한 다른 조건시보다 이 때 선택되는 특징들이 많음을 볼 수 있으며 이는 분류기의 정확도를 낮추는 원인이 된다. 따라서 분류기의 정확도를 올리기 위하여 GA의 선택조건은 roulette 또는 tournament로

해주어야 한다. 본 연구 데이터에서는 교차방법 및 변이가 바뀌더라도 약 1% 미만의 정확도 차이를 가지므로 많은 영향을 받지 않는다. 따라서 정확도가 가장 높은 경우, 최종적으로 선택한 특징이 가장 적은 경우를 GA의 조건으로 설정하여 주었다. 이때의 GA는 tournament 선택방법으로 우수 해를 선택하고 해를 scatter방법으로 무작위 교차시켜주며 세대에 따라 feasible하게 변이가 필요한 경우만 변이가 발생할 수 있도록 동작시켰다. 이 조건 하에서 정확도는 96.4%이고 선택된 특징은 맥과 신호에서 추출된 심박변이도의 평균, NN50, 맥과 전달 시간의 평균, 피부전도도의 평균, 두정엽 영역에서 뇌파신호의 δ 파, β 파 주파수 대역 에너지이다.




그림 5. 특징선택을 위한 누적곡선
Fig. 5. Cumulative curve for feature selection.

또한 GA-SVM분류기가 에러를 최소화하는 최적 값으로 수렴했을 때 선택된 특징이 무엇인지 확인하기 위하여 누적곡선을 사용하였다. 이는 최적화 반복, 교차, 변이에 따른 선택 파라미터의 변동을 확인할 수 있다. 그림 5에서와 같이 그래프의 x축과 y축은 모두 세대수를 나타낸다. 하나의 해가 선택될 때마다 1씩 더해지며 그래프가 그려지며 계속적으로 선택되는 파라미터는 기울기가 1인 사선으로 표현된다. 선택된 파라미터(맥과 신호에서 추출된 심박변이도의 평균, NN50, 맥과 전달 시간의 평균, 피부전도도의 평균, 두정엽 영역에서 뇌파 신호의 δ 파, β 파 주파수 대역 에너지)는 표 3의 결과와 일치하였다.

표 3에서는 각각의 조건을 변경시켜가며 GA를 사용하였을 때, 조건에 따라 최대의 정확도를 갖도록 선택된 특징 파라미터 조합이다. 따라서 최종적으로 최대

표 4. 생체신호 별 정확도 및 선택된 특징
Table 4. Accuracy and selected feature for signal.

No.	P	S	G	F	C	SVM Accuracy(%)	GA-SVM Accuracy(%)	Selected features
1	o	x	x	x	x	42.79	43.69	m_H, n_H, m_T
2	x	o	x	x	x	23.42	23.42	m_S, s_S
3	x	x	o	x	x	34.68	35.59	m_G
4	x	x	x	o	x	23.42	23.42	θ_F, β_F
5	x	x	x	x	o	50.45	50.45	$\theta_C, \alpha_C, \beta_C, \gamma_C$
6	x	x	x	o	o	50.45	50.45	$\delta_F, \alpha_F, \delta_C, \theta_C, \beta_C, \gamma_C$
7	o	o	x	x	x	43.24	44.14	$m_H, n_H, n_H, m_T, s_R, m_S$
8	o	x	o	x	x	64.86	79.28	m_H, n_H, m_T, s_R, m_G
9	o	x	x	o	x	40.09	43.69	m_H, n_H, m_T, z_R
10	o	x	x	x	o	70.27	71.62	$m_H, n_H, m_T, \delta_C, \theta_C, \alpha_C, \beta_C$
11	o	x	x	o	o	64.86	71.62	$m_H, n_H, m_T, s_R, \theta_F, \delta_C, \theta_C, \beta_C$
12	x	o	o	x	x	34.68	35.59	m_S, m_G
13	x	o	x	o	x	23.42	24.42	$\delta_F, \theta_F, \alpha_F, \beta_F$
14	x	o	x	x	o	50.45	50.45	$\delta_C, \theta_C, \gamma_C$
15	x	o	x	o	o	50.45	50.45	$m_S, \alpha_F, \beta_F, \gamma_F, \delta_C, \alpha_C, \beta_C, \gamma_C$
16	x	x	o	o	x	30.63	35.59	m_G, θ_F
17	x	x	o	x	o	59.46	62.61	m_G, δ_C, θ_C
18	x	x	o	o	o	55.86	67.71	$m_G, \alpha_F, \alpha_C, \beta_C$
19	o	o	o	x	x	63.96	80.63	$m_H, n_H, m_T, s_R, s_S, m_G$
20	o	o	x	o	x	39.64	44.14	$m_H, n_H, n_H, f_H, m_T, s_T, z_R, z_G$
21	o	o	x	x	o	70.27	72.07	$m_H, n_H, m_T, s_R, m_S, \delta_C, \theta_C, \alpha_C, \gamma_C$
22	o	o	x	o	o	63.86	72.07	$m_H, n_H, m_T, s_T, m_S, \delta_C, \theta_C, \beta_C$
23	o	x	o	o	x	51.80	79.28	m_H, n_H, m_T, s_R, m_G
24	o	x	o	x	o	88.29	96.4	$m_H, n_H, m_T, m_G, \delta_C, \beta_C$
25	o	x	o	o	o	76.13	96.4	$m_H, n_H, m_T, s_R, m_G, \delta_C, \alpha_C, \beta_C$
26	x	o	o	o	x	30.18	35.59	m_S, m_G, θ_F
27	x	o	o	x	o	50.01	62.61	m_G, δ_C, β_C
28	x	o	o	o	o	56.31	62.61	m_G, δ_C, θ_C
29	o	o	o	o	x	54.05	80.63	$m_H, n_H, m_T, s_R, m_S, s_S, m_G$
30	o	o	o	x	o	88.29	96.4	$m_H, n_H, m_T, s_R, m_G, \delta_C, \beta_C$
31	o	o	o	o	o	77.03	96.4	$m_H, n_H, m_T, m_G, \delta_C, \beta_C$

정확도가 96.4%일 때 선택되어진 특징은 맥파 신호에서 추출된 심박변이도의 평균, NN50, 맥파 전달 시간의 평균, 피부전도도의 평균, 두정엽 영역에서 뇌파신호의 δ 파, β 파 주파수밴드파워였고 이는 감성분류에 유의한 특징들이라고 볼 수 있다.

GA-SVM의 성능은 적합함수 SVM만을 적용했을 때의 정확도 약 77%보다 GA으로 선택되는 입력특징에 따라 약 17%향상되는 약 94%의 정확도를 보였다. 표 3에서 정확도는 같아도 선택되는 특징들이 다른 것을 볼 수 있다. 96.4% 정확도 경우 이는 본 알고리즘에서는 입력으로 들어가는 특징이 많으며 특징 간에는 서로 상관관계가 존재하므로 정확도에 영향을 끼치지 않는다는 것을 의미하다.

표 4에서는 최적으로 선택된 GA 조건인 해의 개수 50개, tournament 선택방법, scatter 교차방법, feasible 면이방법에 대하여 사용하는 생체신호의 조합을 변경하여 가며 SVM만 사용했을 경우와 GA-SVM을 복합으로 사용했을 때의 성능 및 선택되는 특징을 비교하였다. 표 4를 보면 SVM을 사용하였을 경우보다 GA-SVM을 사용하였을 때 동일한 성능을 보이는 총 6 경우(2번, 4번, 5번, 6번, 14번, 15번)를 제외한 모든 경우 정확도가 높아짐을 볼 수 있다. 6가지 경우는 정확도가 SVM만 사용한 경우와 같다. 정확도가 같은 경우는 피부온도 혹은 뇌파신호가 입력으로 들어갔을 경우의 조합임을 확인할 수 있다.

표 4의 4번, 5번, 6번 혹은 9번, 10번, 11번 혹은 20번, 21번, 22번의 경우는 측정된 뇌파 부위에 따른 경우를 비교해 본 경우이다(전두엽, 두정엽). 전두엽 영역의 뇌파신호는 두정엽 영역의 뇌파신호보다 분류 정확도가 떨어지며, 두정엽 영역의 뇌파신호만 넣은 경우와 전두엽 영역과 두정엽 영역 모두의 뇌파신호를 넣은 경우의 정확도가 같음으로 보아 전두엽 영역의 뇌파 신호는 분류에 있어 영향이 적음을 확인할 수 있다.

또한 4번, 5번, 6번 경우의 선택된 특징을 보면 두정엽에서 뇌파신호특징은 일정한 특징이 선택되지만 전두엽에서 뇌파신호특징은 무작위로 선택됨을 보인다. 9번 경우 역시 맥파와 전두엽부분 뇌파신호를 입력으로 사용하지만 선택된 특징은 맥파에서만 추출된 것임을 볼 수 있다. 따라서 전두엽부분에서 뇌파신호는 감성분류의 영향이 적음을 알 수 있다.

1번~6번의 각 신호별 정확도를 보았을 때 두정엽 부

위의 뇌파 신호가 입력일 때 분류 정확도가 가장 높고, 다음으로 맥파 신호가 입력으로 들어갔을 때 분류기의 정확도가 높아짐을 확인할 수 있다. 19번과 28번은 각각 뇌파신호만 제외하고 맥파만 제외한 입력을 사용하였을 때이며 맥파를 사용하였을 때가 더 높은 정확도를 가짐을 볼 수 있다. 가장 높은 분류정확도를 가지는 경우는 24번, 25번, 30번, 31번 경우로 96.4%의 정확도를 가진다. 이 중 24번은 맥파, 피부전도도, 두정엽 부위 뇌파 신호가 입력으로 들어가 4개의 경우 중 가장 적은 입력이 들어간다. 또한 이 경우 선택된 특징도 가장 적으므로 이때의 생체신호 선택이 시스템 효율을 가장 높여준다고 할 수 있다. 이 때 선택되어진 특징 값은 맥파 신호에서의 심박변이도의 평균, NN50, 맥파 전달 시간의 평균, 피부전도도의 평균, 두정엽 영역에서 측정된 뇌파신호의 δ 파, β 파 주파수대역에너지로 앞서 모든 생체신호를 이용하여 작동시킨 GA-SVM의 결과와 유사함을 확인할 수 있다. 특히 본 연구과정에서 최고성능을 보여 준 경우, 대부분 앞과 유사한(맥파 신호에서의 심박변이도의 평균, NN50, 맥파 전달 시간의 평균, 피부전도도의 평균, 두정엽 영역에서 측정된 뇌파신호의 δ 파, β 파 주파수대역에너지) 생체신호조합이 들어감을 확인할 수 있다.

19번과 같이 생체신호 조합에 대하여 뇌파신호를 제외하고 맥파, 피부온도, 피부전도도를 사용하여도 분류기를 80%이상의 정확도를 가지도록 설계가 가능하다. 이는 생체신호의 측정을 더욱 간편하게 해주므로 하드웨어 설계 시, 뇌파를 사용하면 전극과 시스템의 복잡도가 증가하나 맥파, 피부온도, 피부전도도 사용 시 간단한 시스템 설계를 가능하게 하여 시스템 복잡도를 줄이고, 이에 따라 특징 추출 시 계산 복잡도를 줄인다는 장점을 가진다.

IV. 결 론

본 논문은 4가지 감성판별을 하는데 있어 생체신호를 기반으로 주요 특징들을 선택하는 알고리즘 설계에 목적이 있다. 사람이 어떠한 감성을 느끼게 되면 신경계에 자극을 주고 그 자극은 생체 내에 반응을 일으키므로 생체신호가 변하게 된다. 따라서 이를 역으로 생각하면 생체신호를 분석함으로써 이를 통한 감성판별이 가능하게 된다^[1].

본 연구에서는 GA-SVM 분류기를 사용하여 최종적으로 맥파 신호의 심박변이도 평균, NN50, 맥파 전달 시간의 평균, 피부전도도의 평균, 두정엽 부위의 뇌파 신호의 δ 파, β 파 주파수밴드파워를 주요 특징으로 선택할 수 있음을 확인하였다. 맥파 신호로부터 추출된 심박변이도는 감성변화에 따른 교감신경과 부교감신경의 변화를 볼 수 있다. 스트레스가 발생되면 교감신경이 활성화되어 있는 상태를 추측할 수 있고 이에 따라 연관된 생체신호가 변화하므로 이는 주요 특징으로 선택됨을 볼 수 있다. 또한 맥파 신호는 침착함을 유지하는 상태 시에는 느려지고 흥분 시에는 빨라지는 경향을 가지게 되므로 맥파 전달 시간 역시 유의한 특징으로 선택되었다^[12]. 피부전도도는 교감신경계의 활성정도를 분별하는데 사용이 가능하므로 감성변화가 크면 신호의 진동 역시 크고 특히 폭력적 장면에서는 피부전도도의 활성이 증가함을 보이기 때문에 감성판별을 위한 생체신호로 사용하기 유의하다^[15]. 마지막으로 뇌는 자극과 가장 밀접하게 관련이 되기 때문에 뇌파신호는 감성상태 분별을 위해 가장 뚜렷한 특징을 가진다^[4]. δ 파는 수면 시 많이 나타나는 요소로 알려져 있다. 그러나 본 연구에서 주요 특징으로 선택된 이유는 두뇌에서 무의식에 관한 정보를 담고 있기 때문에 감성에 관한 직관력 및 영상에 관한 안정도가 큰 영향을 끼쳤을 것이라고 예상된다. θ 파는 집중을 할 때 많이 나타나고, α 파는 안정된 상태에서 β 파는 불안한 상태에서 많이 나타나며, γ 파는 초조한 상태에서 많이 나타나므로 뇌파 신호는 감성판별에 주요 역할을 한다^[16]. 또한 본 연구에서 볼 수 있듯이 두정엽 영역에서의 뇌파가 전두엽 영역에서 뇌파보다 높은 성능을 가질 수 있도록 해 주는데 전두엽에서는 EOG 잡음 영향을 받으므로 불안정성에 원인이 있을 수도 있다.

앞의 결과에서 볼 수 있듯이 맥파 신호, 피부전도도, 두정엽에서의 뇌파 측정만으로도 높은 성능을 가지는 감성판별이 가능하다. 이는 향후 감성판별을 위하여 생체신호의 측정을 간편하게 할 수 있을 것으로 사료된다. 또한 감성판별을 위해서는 맥파 신호 혹은 뇌파 신호와 다른 생체신호와의 조합이 하나의 생체신호만을 사용하였을 때보다 성능을 높여줄 수 있었고, 생체신호의 조합에 따라서도 다양한 정확도를 가짐을 알 수 있다. 특히 맥파 신호와 피부전도도의 조합은 약 79%의 정확도를 가지므로 맥파 신호, 피부전도도, 피부

온도의 조합보다 약 1% 낮은 정확도를 갖는다. 그러나 센서 부착을 위한 간편성 혹은 측정된 생체신호의 특징을 뽑는 비용함수의 계산 등을 모두 고려한다면 더 효율적인 측정방법이 될 수 있을 것이라 생각된다. 더 나아가 본 연구에서 입력으로 사용하기 위하여 추출된 특징들은 서로 밀접한 관련을 가지고 있으므로 각각 계산에 드는 비용을 줄여주는 특징을 선택해줌이 중요할 것이다.

심전도 신호, 근전도 신호, 호흡 신호, 피부전도도를 사용하여 GA로 감성분류를 한 사전연구와 비교하여 본 연구는 비슷한 정확도를 가지고 있음을 보였다^[7]. 더 나아가 본 연구에서는 더 많은 생체신호들을 가지고 주요 특징들을 선택하는 분류기를 설계했다는 점에 의의를 가지고 있다. 이는 향후 사람의 감성을 이용하여 사람과 기계의 상호작용을 탐구하는 지능형 시스템과 같은 분야에서의 기술발전에 있어 기여가 가능할 것으로 보인다^[2,21]. 본 방법은 노년층의 데이터를 이용하여 분석한 것으로 노년층의 건강관리의 데이터로 활용이 가능하다. 또한 향후 일반인 데이터와의 비교분석 및 반복 실험을 통한 피험자 데이터 추출을 통하여 상호연관성을 밝힐 수 있을 것이며 다른 알고리즘의 개발 혹은 특징 검출에 있어 기본 자료로 사용 가능할 것으로 생각된다. 감성은 사람의 경험에 따라 유발되는 범위가 다르기에 개인적 차에 관한 연구가 지속되어야 한다. 또한 실험 시에도 더 정교한 프로토콜을 사용하여 개인차를 줄일 수 있어야하므로 실험프로토콜에 관한 연구 역시 좀 더 많은 테스트 데이터에 대하여 지속적으로 연구 되어야한다.

REFERENCES

- [1] Mu Li and Bao-Liang Lu, "Emotion Classification Based on Gamma-band EEG", *31th Annual International Conference of the IEEE EMBS*, pp.1323-1326, Minnesota, USA, Sep 2009.
- [2] Jerritta Selvaraj, Murugappan Murugappan, Khairunizam Wan and Sazali Yaacob, "Classification of emotional states from electrocardiogram signals: a non-linear approach based on hurst," *BioMedical Engineering Online*, 2013.
- [3] 안형철, 최진영, "[특집]지능로봇의 감성행동 기술 동향," *Journal of the IEEK*, vol.32(1), pp.50-59,

- 2005.
- [4] Jonghwa K and Ande E, "Emotion Recognition Based on Physiological Changes in Music Listening," *Pattern Anal. Mach. Intell., IEEE Transact.*, pp.2067-2083 2008.
- [5] Ekman P. and Friesen WV, "Universals and Cultural Differences in the Judgments of Facial Expressions of Emotion," *J pers Soc Psychol*, pp.712-714, 1987.
- [6] Lang PJ, "The Emotion Probe: Studies of Motivation and Attention," *Am Psychol*, pp.372-385, 1995.
- [7] LIU Guang-Yuan and HAO Min, "Emotion Recognition of Physiological Signals Based on Adaptive Hierarchical Genetic Algorithm," *2009 World Congress on Computer Science and Information Engineering*, pp.670-674, 2009.
- [8] Xiaowei Niu, Liwan Chen and Qiang Chan, "Research on Genetic Algorithm based on Emotion recognition using physiological signals," *ICCP Proceedings*, pp.614-618, 2011.
- [9] WooJin Chio, "A classification analysis of negative emotion based on PPG signal using Fuzzy-GA," July, 2007.
- [10] John Aleen, "Photoplethysmography and its application in clinical physiological measurement," *Physiological measurement*, vol.28(3), pp.1-39, 2007.
- [11] Pierre Rainville, Bechara A, Naqvi N and Damasio AR, "Basic emotions are associated with distance patterns of cardiorespiratory activity," *International Journal of Psychophysiology*, pp.5-18, 2006.
- [12] Foteini Agrafioti, "ECG Pattern Analysis for Emotion Detection", *IEEE Transactions on Affective Computing*, vol.3, 2012.
- [13] Malik M., "Measurement of heart rate variability," *Heart Rate Variability. Armonk*, pp.33-132, 1995.
- [14] Zhai, J. and Barreto, A., "Stress Detection in Computer Users Based on Digital Signal Processing of Noninvasive Physiological Variables," *The 28th Annual International Conference Engineering in Medicine and Biology Society*, pp.1355-1358, 2006.
- [15] Guanghua Wu, Guangyuan Liu and Min Hao, "The analysis of emotion recognition from GSR based on PSO," *2010 International Symposium on Intelligence Information Processing and Trusted Computing*, pp.360-363, 2010.
- [16] Murugappan Murugappan, Nagarajan Ramachandran and Yaacob Sazali, "Classification of human emotion from EEG using discrete wavelet transform," *J. Biomedical Science and Engineering*, vol.3, pp.390-396, April, 2010.
- [17] Edgar Osuna, Robert Freund, and Federico Girosi, "Support Vector Machines: Training and Applications," *C.B.C.I. Paper No.144*, March, 1997.
- [18] Chih-Chung Chang and Chih-Jen Lin, "Libsvm: a library for support vector machines," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol.2, pp.3-27, 2011.
- [19] David E. Goldberg, "Genetic Algorithm in Search, Optimization, and Machine Learning," *Addison-Wesley Professional*, 1 edition, 1989.
- [20] Melanie Dumas, "Emotional Expression Recognition using Support Vector Machines," *In Proceedings of International Conference on Multimodal Interfaces*, 2001.
- [21] 권오상, "감성로봇 현황과 추세," *Journal of the IEEK*, vol.28(12), pp.18-25, 2001.

 저자 소개



이지은(학생회원)
 2012년 건국대학교 의용전자
 공학과 학사
 2012년~현재 연세대학교 생체
 공학협동과정 석사 과정
 <주관심분야 : u-Health, 스마트
 디바이스, 생체신호처리 및 패턴인
 식, 감성공학>



유선국(정회원)-교신저자
 1981년 연세대학교 전기공학과
 학사
 1985년 연세대학교 전기공학과
 석사
 1989년 연세대학교 전기공학과
 박사

1995년~현재 연세대학교 의과대학 의학공학교실
 교수
 <주관심분야 : u-Health, 의료영상, 스마트 디바
 이스, 생체신호처리 및 패턴인식, 감성공학>