

논문 2011-48CI-6-5

# 프로파일기반의 FLD와 단계적 분류를 이용한 감성 인식 기법 ( Emotion Recognition Method Using FLD and Staged Classification Based on Profile Data )

김 재 협\*, 오 나 래\*\*, 진 갑 송\*, 문 영 식\*\*\*

( Jae Hyup Kim, Na Rae Oh, Gab Song Jun, and Young Shik Moon )

## 요 약

본 논문에서는 피셔 선형 분리(FLD, Fisher’s Linear Discriminant) 기반의 단계적 분류를 이용한 감성 인식 기법을 제안한다. 제안하는 기법은 2종 이상의 감성에 대한 다중 클래스 분류 문제에 대하여, 이진 분류 모델의 연속적인 결합을 통해 단계적 분류 모델을 구성함으로써 복잡도 높은 특징 공간상의 다수의 감성 클래스에 대한 분류 성능을 향상시킨다. 이를 위하여, 각 계층 단계의 학습에서는 감성 클래스들로 이루어진 두 개의 클래스 그룹에 따라 피셔 선형분리 공간을 구성하며, 구성된 공간상에서 Adaboost 방식을 이용하여 이진 분류 모델을 학습하여 생성한다. 각 계층 단계의 학습 과정은 모든 감성 클래스가 구분이 완료되는 시점까지 반복 수행된다. 본 논문에서는 MIT 생체 신호 프로파일을 이용하여 제안하는 기법을 실험하였다. 실험 결과, 8종의 감성에 대한 분류 실험을 통해 약 72%의 분류 성능을 확인하였고, 특정 3종의 감성에 대한 분류 실험을 통해 약 93% 분류 성능을 확인하였다.

## Abstract

In this paper, we proposed the method of emotion recognition using staged classification model and Fisher’s linear discriminant. By organizing the staged classification model, the proposed method improves the classification rate on the Fisher’s feature space with high complexity. The staged classification model is achieved by the successive combining of binary classification model which has simple structure and high performance. On each stage, it forms Fisher’s linear discriminant according to the two groups which contain each emotion class, and generates the binary classification model by using Adaboost method on the Fisher’s space. Whole learning process is repeatedly performed until all the separations of emotion classes are finished. In experimental results, the proposed method provides about 72% classification rate on 8 classes of emotion and about 93% classification rate on specific 3 classes of emotion.

**Keywords :** emotion recognition, FLD, Fisher’s linear discriminant, Adaboost, staged classification

## I. 서 론

IT 기술은 기술 및 시설 인프라 구축 중심에서 인간

중심으로 진보되었다. 인간 중심의 발전 방향은 계속될 것이고, 이에 따른 서비스의 중요성도 더욱 부각될 것이다. 또한, 다양한 IT 기술의 발전을 토대로 융합 서비스, 상황인식 서비스 등에 대한 수요와 연구가 증가하고 있다. 최근 디지털 융합(Digital Convergence)에 대한 인식이 보편화되고 있으며, 산/학계에서 많은 연구가 진행되고 있다. 이러한 융합기술이 적용되는 분야 중 최근 가장 대표적인 분야가 u헬스케어분야이다. 이는 헬스케어 분야가 최대의 산업형 시장을 갖추고 있기 때문이다. 이 분야의 기술 진보와 산업 동향을 보면 핵심요소는 네가지로 볼 수 있다. 센서, 단말기, 분석, 피드백 서비스이다. 다양한 융합기술 기반의 개인화 서

\* 정회원, 삼성탈레스 (Samsung Thales)

\*\* 정회원, 우리에프아이에스 (Woori FIS)

\*\*\* 평생회원-교신저자, 한양대학교 컴퓨터공학과 (Dept. of Computer Science and Engineering, Hanyang University)

※ 이 논문은 2009년 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2009-0077434, 한양대학교)

접수일자: 2011년9월28일, 수정완료일: 2011년11월2일

스, 헬스케어 등의 시스템을 구축하여 귀해서는, 대상이 되는 개인의 상태에 대한 다각도의 분석이 필요하다. 소형/첨단화 되어가는 센서로부터 다양한 형태의 인간 생체 신호를 획득할 수 있으며, 이를 기반으로 사람의 감성 상태, 육체적 변화 및 건강 상태 등을 획득할 수 있다면, 보다 앞선 형태의 융합 서비스 시스템 구축이 가능할 것이다. 현 수준으로써는 센서 및 단말기 분야에 대한 연구개발이 상당 수준 이루어져 있으나, 이후 단계인 분석 분야에 대한 연구는 미흡한 편이다.

인간의 감성을 인식하는 방법으로는 영상 정보를 이용한 방법과 음성 정보를 이용한 방법이 주로 연구되고 있다<sup>[1]</sup>. 이 연구들은 영상 정보 또는 음성 정보를 피실험자에게 제시한 후, 피실험자의 심리적 변화에 따른 생체 신호를 측정하여 감성 인식에 활용한다. 즉, 생체 신호를 이용해서 감성 상태를 검출하는 것은 인간의 모든 감성 상태가 생체 신호를 통해 나타날 수 있고, 생체 신호만을 이용해서 감성 상태를 구분할 수 있다는 연구 결과에 바탕을 두고 있다. 지금까지 연구가 진행되어온 주된 생체 신호의 종류에는 심전도(ECG, electrocardiogram), 뇌전도(EEG, electroencephalogram), 근전도(EMG, electromyogram), 피부 전도도(GSR, Galvanic Skin Response), 피부 온도(SKT, Skin Temperature), 맥파(PPG, photoplethysmography), 혈압(BVP, Blood Volume Pressure), 호흡률(RES, Respiration), 심장 박동수(HR, Heart Rate) 등이 있다<sup>[1]</sup>.

감성 인식 분야는 William James 등<sup>[2]</sup>에 의해 연구되기 시작하였으며, 초기에는 인간의 감성은 강한 생리학적 반응과 함께 신체적 변화의 특정한 패턴에 의해 구분될 수 있음을 확인하는 과정이 주를 이루었다. 이후 Ekman 등<sup>[3]</sup>은 피부 온도를 이용하여 분노, 두려움, 슬픔을 구분하였고, 심장 박동수를 이용하여 행복, 혐오감, 놀라움과 분노, 두려움, 슬픔을 구분하는 연구를 진행하였으며, Levenson<sup>[4]</sup>, Prkachin<sup>[5]</sup>, Keil<sup>[6]</sup> 등은 다양한 감성 상태 검출을 목표로 감성과 연관된 체성 내장(Somato-visceral) 징후를 확인하는 연구를 진행하였다. 대표적으로, Levenson<sup>[4]</sup> 등은 감성 상태에 따른 자율신경계의 반응을 관찰한 결과 긍정적인 감성에서의 심박수나 피부 저항이 부정적 감성에서 보다 낮게 나타났다는 결과를 제시하였다. 그러나 이러한 연구의 결과들은 특정한 감성 상태에서의 생리적 신호 중에서 일부 특성이 비교되는 감성 상태와 통계적으로 유의할 만한 차이를 나타낸다는 사실만 확인되었을 뿐, 슬픔과 같은 특

정한 감성 상태를 판별할 수 있는 생체 신호의 절대적인 특성 또는 기준을 제시하지 못하고 있다.

반면, Picard 등<sup>[7~9]</sup>은 4개의 센서로부터 획득된 호흡률, 피부 전도도, 혈압, 근전도 신호를 바탕으로 감성 상태를 인식하는 기법을 제안하였다. 이 연구들은 일정 상황에서 인간이 발생시키는 생체 신호 자체를 이용하여 패턴 분류 분야의 기법을 도입함으로써, 감성 인식 기법을 구축하였으며, 특징 추출, 특징 선택, 분류 기법 등의 분야에서 연구를 진행하였다. 다양한 형태의 실험 결과를 토대로 생체 신호를 이용한 감성의 구분이 가능함을 보였다. 특징 추출에서는 통계적 특징을 사용하였고, 특징 선택에서는 SFFS(Sequential Floating Forward Search), FS(Fisher Space, 피셔 공간) 등을 활용하였으며, SFFS와 FS의 융합 기법을 제안하였다. 분류 기법으로는 MAP(Maximum A Posteriori), K-NN(K-Nearest Neighbor) 등을 이용하였다.

Leon 등<sup>[10~12]</sup>은 Picard 등이 공개한 생체 신호 데이터를 기반으로 연구를 진행하였다. 이 연구에서는 Picard 등이 정한 8종의 감성 상태를 무감성(No Emotion)의 상태와 유감성(Emotion)의 상태로 나누고, 이를 가장 잘 분류하는 생체신호가 근전도(EMG) 신호임을 제시하였다. Kim<sup>[13]</sup> 등은 Picard 등의 연구와 유사한 관점에서, 110여개의 통계적 특징을 추출하여 SBS(Sequential Backward Selection), PCA(Principle Component Analysis), 피셔 공간 등을 활용한 연구를 진행하였다.

국내에서는 최근 몇 년간 본격적인 생체 신호 및 감성과 관련하여 연구가 진행되고 있다. Shin<sup>[14]</sup> 등은 텍스타일 영상과 그에 연결되는 감성에 대한 분류를 연구하였으며, Jo<sup>[15]</sup> 등은 성별 구분을 이용하여 음성 기반의 감성 인식에 대하여 연구를 진행하였다. Lee<sup>[16]</sup> 등은 피부 전도도(GSR)를 기반으로 감정 인식 알고리즘을 연구하였으며, Kim<sup>[17]</sup> 등은 감정 분석을 이용한 홈 네트워크 서비스 시스템 개발에 대하여 연구를 진행하였다.

앞서 언급한 Picard<sup>[7~9]</sup> 등, Kim<sup>[13]</sup> 등, 그리고 Lee<sup>[16]</sup> 등의 연구는 다양한 생체 신호 데이터에 패턴 분류 기법을 적용하여 인간의 감성에 대한 분류를 시도한 대표적인 연구 결과이다. Picard<sup>[7~9]</sup> 등의 연구에서는 8종(무감성, 분노, 미움, 슬픔, 정신적 사랑, 낭만적 사랑, 기쁨, 숭배)의 감성에 대하여 분류 실험을 진행하였다. 8종으로 정의된 감성 클래스는 클래스 간의 중복성과

복잡성이 매우 높다. 그러나 클래스 간의 구분성을 최대화하기 위하여 피셔 공간으로 변환시켜 분류 실험을 진행하였으나, 다종의 감성 클래스의 복잡도 문제를 해결하지 못하고 낮은 분류 성능을 도출하였다. Kim<sup>[13]</sup> 등의 연구에서는 4종의 감성에 대하여 실험을 진행하였으며, 3명의 피실험자에 대한 독립적인(Subject-independent) 감성 데이터를 이용하여 실험했을 때, 약 65%의 분류 성능을 제시하였다. Lee<sup>[16]</sup> 등의 연구에서는 피부전도도(GSR)와 음성을 기반으로 감성 인식을 수행하였으며, 3종 감성에 대하여 약 88%의 분류 성능을 제시하였다. 그러나 감성의 종류가 3종류이며, 일반적인 상황에서는 획득이 어려운 음성 데이터를 함께 고려하여 감성 인식 성능을 향상 시켰다. 이와 같은 연구들은 패턴 분류 기법을 이용한 대표적인 연구지만, 다종의 감성에 대한 분류 실험에서 낮은 분류 성능을 보였다. 이는 아래와 같이 3가지 측면으로 분석할 수 있다.

- ① 감성의 종류와 프로파일의 형태에 따른 분석적인 특징값이 정의되지 않고, 일반적인 통계기반의 수치를 사용하고 있다.
- ② 다종의 감성 각각을 독립적인 개별 클래스로 간주하여 특징 공간을 구성하고 있다.
- ③ 일반화 성능이 높은 다양한 분류 모델에 대한 적용이 부족하다.

①항의 경우, 기존의 연구들에서 사용하는 특징값들이 통계적인 값을 계산하여 사용하고 있음을 의미한다. 분류 기법에서의 특징값이란, 클래스의 특성을 대표하고 다른 클래스와의 구분성을 높일 수 있는 값이어야 한다. 그러나 기존의 연구들에서의 특징값은 단순히 통계적 수치로 정의되고 있기 때문에, 다종의 감성 클래스 분류에 적합하다고 보기 어렵다. ②항의 경우, 다종의 감성을 동시에 분류하는 특징 공간을 구성함으로써 분류 성능이 저하됨을 의미한다. 기존의 연구들에서는 특징 선택과 피셔 공간 구성을 이용하여 클래스 간의 복잡도를 낮추고자 하였다. 그러나 다종의 감성 클래스들 간의 복잡도를 낮추지 못하였으며 낮은 분류 성능을 도출하였다. ③항의 경우, 우수한 분류 성능을 보이는 분류 모델에 대한 적용이 부족하며, 주어진 감성 클래스의 복잡도에 비해 단순한 분류 기법을 사용하고 있음을 의미한다. 패턴 분류 분야에서는 특징 공간의 복잡

도가 높아지면 특징공간의 복잡도를 낮추는 기법을 적용하거나, 또는 복잡한 분류 경계 설정이 가능한 분류 기법을 적용해야 한다.

본 논문에서는 앞서 제시한 분석 사항 중, ②항과 ③항에 대하여 새로운 기법을 적용하여 분류 성능을 향상시킨다. ①항은 감성 데이터를 분석하고, 감성 클래스 간의 데이터 차이를 해석하여 표현할 수 있는 특징 추출 기법을 정의해야 한다. 그러나 특징 추출에 대한 연구 분야가 매우 광범위하고, 감성 클래스별 데이터의 확보가 매우 어려운 상황이다. 따라서 본 논문에서는 데이터 분석과 특징값 추출 분야는 기존의 연구에서 제시하는 방식을 따르며, 특징 공간의 복잡도와 분류 성능의 개선을 위한 분류 모델을 제안한다. 제안하는 기법은 다종의 감성에 대한 복잡도 높은 분류 문제를 2종의 감성 그룹에 대한 이진 분류 문제로 변환하여 특징공간의 복잡도를 낮춘다. 감성 클래스 그룹이 단계별로 정의되어 각각의 이진 분류 모델이 생성되며, 이진 분류 모델들이 결합되어 단계별 구조를 가지는 다종의 감성 클래스 분류 모델을 구성한다. 본 논문은 II장에서 실험에 사용되는 데이터와 기법들에 대하여 설명하고, III장에서는 실험 과정으로써 실험 환경과 제안하는 기법의 구성에 대해 설명한다. 그리고 IV장에서는 본 논문의 결론 및 향후 과제에 대하여 기술한다.

## II. 제안하는 기법

### 1. 생체 신호 프로파일

본 논문에서는 실험과 분석을 위해 Picard 등이 제공하는 MIT 생체 신호 데이터<sup>[18]</sup>를 이용하였다. 이 데이터는 한 명의 여배우에게 8종의 감성을 느끼게 하는 그림을 보여준 후, 20Hz으로 100초 동안 샘플링하여 생체 신호를 획득한 것이다.

획득 과정은 32일 동안 진행되었다. 센서는 4개가 사용되었으며, 호흡률(RES), 피부 전도도(GSR), 혈압(BVP), 근전도(EMG)로 구성된다. 그림 1에서는 '분노(Anger)' 감성의 4가지 센서의 생체 신호를 보여준다. MIT 생체 신호 데이터는 초기 획득 데이터를 그대로 저장한 데이터와 각 생체 신호를 감성별 구간의 차이를 두고 일정한 간격으로 분리시켜 저장한 데이터로 구분된다. 전자의 경우는 DATAII로 명칭 되며, 후자의 경우는 DATA I으로 명칭 된다. 본 논문에서는 후자의 경우인 DATA I으로 실험과 분석을 진행하였다.




그림 1. 분노(Angry) 감성의 생체 신호 프로파일  
 Fig. 1. Bio-signal profiles of angry emotion.

표 1. MIT DATA I 구성

Table 1. The constitution of MIT DATA I.

감성 종류	획득 일수	센서 개수	데이터 개수
무감성(No Emotion)	20	4	80
분노(Anger)	20	4	80
미움(Hate)	20	4	80
슬픔(Grief)	20	4	80
정신적사랑(Platonic Love)	20	4	80
낭만적사랑(Romantic Love)	20	4	80
기쁨(Joy)	20	4	80
숭배(Reverence)	20	4	80

DATA II는 획득 과정의 다양한 요소와 환경에 대한 기본적인 정보를 파악할 수 없기 때문에, 일정한 기준 하에 선별하여 제공되는 DATA I을 기본적인 실험 데이터로 결정하였다. DATA I은 32일의 실험일 중 별도로 선택된 20일에 해당하는 감성 데이터이다. 따라서 각각의 감성 클래스 당 20개의 데이터가 포함되어 있다. 표 1은 DATA I에서 제공하는 생체 신호 데이터의 구성을 정리하였다. 각각의 데이터는 2000개의 샘플로 이루어져 있다.

## 2. 감성 인식 기법

제안하는 기법은 감성에 따라 획득되는 생체 신호에 대하여, 특징 추출, 감성 클래스 그룹 구성, 피셔 공간 구성, 계층별 학습, 계층 결합의 단계로 이루어진다. 그

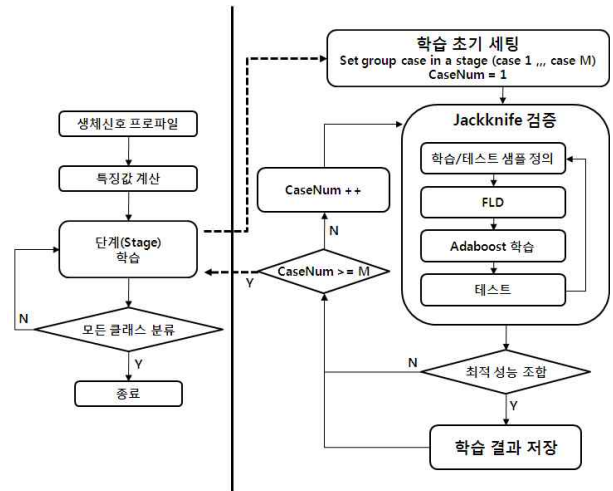


그림 2. 제안하는 기법  
 Fig. 2. Proposed method.

림 1에서 좌측부는 전체 과정을 의미하며, 우측부는 각각의 단계별로 학습하는 과정의 상세를 의미한다. 특징 추출은 생체 신호로부터 각 신호의 특성을 표현할 수 있는 특징값을 추출하는 단계이며, 감성 클래스들을 2개의 그룹으로 나눈 후 피셔 공간을 구성한다. 피셔 공간에 사상된 샘플들은 Adaboost로 학습되며, 잭나이프 기법으로 클래스 그룹의 학습 성능을 검증한다.

한 단계 내에서 조직 가능한 모든 클래스 그룹에 대하여 학습과 검증이 이루어지며, 가장 우수한 성능을 보이는 클래스 그룹을 현 단계에서의 클래스 그룹으로 확정한다. 한 단계에서 나누어진 클래스 그룹 각각은 독립된 단계로 간주되며, 클래스 그룹 구성과 학습 과정이 다시 수행된다. 이러한 과정은 다종의 감성 클래스가 각각 독립된 클래스로 분류될 때까지 반복된다. 그림 2에서 표기된 case는 한 단계 내에서 구성 가능한 모든 이진 그룹 각각을 의미한다. 그림 2는 제안하는 기법의 전체 구성을 보여준다.

## 3. 특징 추출

생체 신호 프로파일은 그림 1에서와 같이 연속된 수열 형태의 데이터이다. 생체 신호 프로파일로부터 매우 다양한 특징값을 추출할 수 있으나, 충분한 데이터의 확보가 어렵고 감성 간의 데이터 분석이 매우 어렵다. 따라서, 제안하는 기법에서는 기존의 연구와 동일한 방법을 사용하여 특징값으로 정의하였다. 생체 신호 프로파일을 이용한 통계적 특징값은 6개의 값으로 계산되며, 아래의 수식 (1)에서 수식 (6)과 같은 과정을 통해 추출된다.

$$\mu_X = \frac{1}{N} \sum_{n=1}^N X_n \quad (1)$$

$$\sigma_X = \left( \frac{1}{N-1} \sum_{n=1}^N (X_n - \mu_X)^2 \right)^{\frac{1}{2}} \quad (2)$$

$$\delta_X = \frac{1}{N-1} \sum_{n=1}^{N-1} |X_{n+1} - X_n| \quad (3)$$

$$\delta_X^* = \frac{1}{N-1} \sum_{n=1}^{N-1} |X_{n+1}^* - X_n^*| \quad (4)$$

$$\gamma_X = \frac{1}{N-2} \sum_{n=1}^{N-2} |X_{n+2} - X_n| \quad (5)$$

$$\gamma_X^* = \frac{1}{N-2} \sum_{n=1}^{N-2} |X_{n+2}^* - X_n^*| \quad (6)$$

위의 수식에서  $X$ 는 생체 신호 프로파일 중의 하나를 의미한다.  $N$ 은  $X$ 의 길이를 의미하며,  $X^*$ 는 아래의 수식 (7)에 의해 정규화 된 생체 신호 프로파일을 의미한다.

$$X_n^* = \frac{X_n - \mu_X}{\sigma_X} \quad (7)$$

따라서 하나의 감성 데이터는 식 (1)에서 식 (6)의 과정을 통해 계산된 통계적 수치를 24(4센서×6)개 가지게 되어, 24차원의 특징값으로 사용된다. 즉, 전체 생체 신호 데이터는 하나의 감성마다 20개의 24차원 특징값으로 생성되며, 모든 감성을 포함하여 160개의 특징값이 생성된다.

#### 4. 피셔 선형 분리

피셔 선형 분리(FLD, Fisher's Linear Discriminant)는 피셔 투영(FP, Fisher's Projection), 피셔 공간(FS, Fisher's Space) 등으로 불린다. 피셔 선형 분리 공간을 구성하는 방법은 아래의 수식 (8)-(12)와 같다.

$$\mu_i = \frac{1}{N_i} \sum_{i \in C_i} X_i \quad (8)$$

$$\bar{X} = \frac{1}{N} \sum_{i=1}^c N_i \mu_i \quad (9)$$

수식 (8)과 (9)에서  $C_i$ 는  $i$ 번째 클래스를 의미하며,  $N_i$ 는 클래스  $C_i$  내에 포함되어 있는 샘플의 개수를 의

미한다.  $N$ 은 모든 클래스에 포함된 전체 샘플의 개수를 의미한다. 이때, 클래스는 총  $c$ 개이다. 따라서 수식 (8)은 각각의 클래스에 대한 평균을 의미하며, 수식 (9)는 모든 클래스의 샘플 전체에 대한 평균을 의미한다.

$$S_b = \sum_{i=1}^c N_i (\mu_i - \bar{X})(\mu_i - \bar{X})^T \quad (10)$$

$$S_w = \sum_{i=1}^c \sum_{j \in C_i} (X_j - \mu_i)(X_j - \mu_i)^T \quad (11)$$

수식 (10)에서는 전체 샘플에 대한 평균과 각 클래스의 평균과의 공분산 행렬을 계산하며, 이를 클래스 간의 행렬(Between-Class Matrix)이라 한다. 수식 (11)에서는 각 클래스의 공분산 행렬의 합을 계산하며, 이를 클래스 내의 행렬(Within-Class Matrix)이라 한다.

$$\mathcal{J}(W) = \frac{\operatorname{argmax}_W \frac{|W^T S_b W|}{|W^T S_w W|}}{W} \quad (12)$$

수식 (12)는 피셔 선형 분리 공간을 찾기 위한 목적식을 나타내고 있다. 클래스 간의 행렬을 최대로 하면서 클래스 내의 행렬을 최소로 하는  $W$ 를 찾는 것이 피셔 공간의 목적이다. 위의 목적식을 만족시키는 피셔 공간은 식 (13)과 같이 클래스 간의 행렬의 역행렬과 클래스 내의 행렬의 곱행렬에 대한 고유벡터(Eigenvector)로 얻을 수 있다.

$$EIG(S_w^{-1} S_b) \quad (13)$$

식 (13)에 의해 구해진 고유벡터들은 피셔 선형 분리를 구성하는 공간 변환축으로 해석되며, 샘플을 변환축으로 사상시켜 특징 공간을 변환시킬 수 있다.

피셔 선형 분리 공간은 샘플이 소속된 클래스에 대한 개념이 포함된다. 즉, 동일한 클래스 내의 샘플 내에서는 최소의 분포를 가지며, 다른 클래스 간에는 최대의 분포를 가질 수 있는 공간을 구성한다. 전자의 경우 클래스 내 분산(Within-Class Distribution)이라 하며, 후자의 경우 클래스 간 분산(Between-Class Distribution)이라 한다. 제안하는 기법에서는 감성 클래스의 분류에 목적을 두고, 클래스 간 분리성을 최대화할 수 있는 피셔 선형 분리 공간을 특징 공간으로 선택하였다.

#### 5. 이진 그룹을 이용한 피셔 선형 분리 공간 구성 복잡도 높은 특징 공간에서의 분류 문제는 4절에서




그림 3. 8종 감성에 대한 2축 피셔 선형 분리 공간 분포  
 Fig. 3. The distribution of 8 emotion samples in 2-D space of Fisher's linear discriminant.




그림 5. 2개의 감성 그룹에 대한 3축 피셔 선형 분리 공간 분포  
 Fig. 5. The distribution of 2 emotion groups in 3-D space of Fisher's linear discriminant

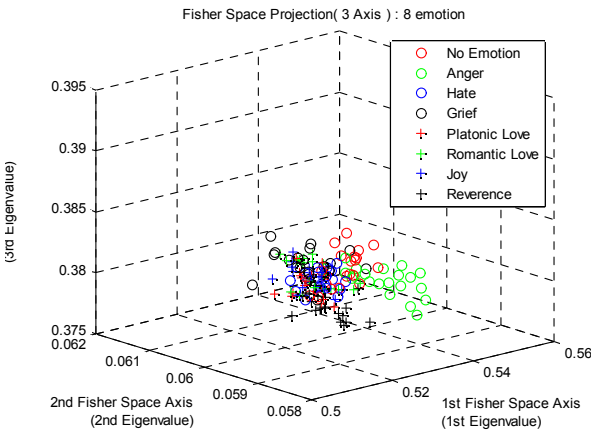


그림 4. 8종 감성에 대한 3축 피셔 선형 분리 공간 분포  
 Fig. 4. The distribution of 8 emotion samples in 3-D space of Fisher's linear discriminant.

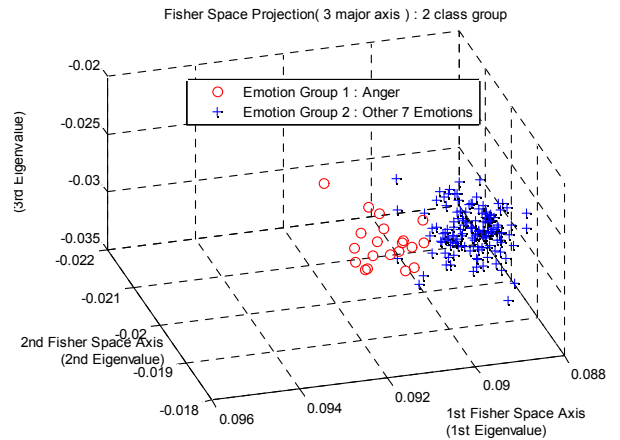


그림 6. 2개의 감성 그룹에 대한 3축 피셔 선형 분리 공간 분포  
 Fig. 6. The distribution of 2 emotion groups in 3-DB space of Fisher's linear discriminant.

설명한 피셔 선형 분리 공간을 통해 클래스 간 복잡도를 줄이고 구분성을 최대화함으로써 분류 성능을 향상시킬 수 있다. 그러나, 본 논문에서 목적으로 하는 감성 샘플은 클래스가 8종이며, 특징값의 공간적 복잡도가 매우 높다. 이런 경우 피셔 선형 분리 공간으로의 변환을 통해서도 복잡도를 낮추기 어렵다.

그림 3과 4에서는 MIT 생체 신호 데이터를 피셔 선형 분리 공간으로 투영한 예를 보여준다. 그림 3에서는 상위 변환축 2개를 이용하여 2차원 공간에 표시하였으며, 그림 4에서는 상위 변환축 3개를 이용하여 3차원 공간에 표시하였다. 3절에서 정의된 특징값을 이용하여 피셔 선형 분리 공간을 구성한 후 투영하였으나, 감성

클래스 간의 구분성이 매우 낮은 분포를 보인다. 따라서 이러한 공간 분포 상에서 분류 기법을 적용할 경우에는 분류 성능이 매우 낮다.

제안하는 기법은 다종의 클래스 간의 복잡도를 낮추고 분류 성능을 향상시키고자 한다. 따라서 다종의 감성 클래스를 분리성이 높은 두 개의 클래스 그룹으로 할당하여 피셔 공간을 구성함으로써, 높은 분리성을 가지는 피셔 선형 분리 공간을 구성한다.

그림 5는 8종의 감성 클래스를 2개의 감성 클래스 그룹으로 나누었을 때의 피셔 선형 분리 공간을 변환축 상위 3축을 이용하여 보여준다. 두 개의 그룹은 분노, 슬픔, 낭만적 사랑, 기쁨으로 이루어진 한 그룹과 무감

성, 미움, 정신적 사랑, 숭배로 이루어진 한 그룹으로 구성되었다. 그림 4에 비해 그림 5에서는 클래스 그룹 경계에서 약간의 복잡성이 식별되지만, 전체적으로 두 개의 그룹 단위로는 상대적으로 우수한 분리성을 확인할 수 있다.

그림 6은 분노 감성을 한 그룹으로 하고, 나머지 7개의 감성을 한 그룹으로 한 경우의 피셔 선형 분리 공간을 나타낸다. 그림 6에서의 클래스 그룹 구성에서도 그룹 간의 분리성을 확인할 수 있다. 따라서 각 계층 단계에서 구성될 그룹의 구성 형태도 전체 분류 모델의 성능을 결정할 수 있는 중요한 요소임을 알 수 있다.

### 6. Adaboost

제안하는 기법에서는 각 단계별로 이진화된(이진 그룹으로 분리된) 클래스 그룹에 대해 학습을 수행한다. 이진 분류 문제를 해결하는 기법에는 매우 많은 기법이 있으며, 대표적으로 Adaboost(Adaptive Boosting) 등이 있다. Adaboost는 Shapire<sup>[9]</sup> 등에 의해 제안되었으며, 표 2는 Adaboost의 가상 코드를 보여준다.

표 2의 라인 3에서는 모든 학습 샘플에게 같은 가중치를 주고 출발한다. 이후, 각 반복 회수마다 주어진 샘플 가중치의 에러를 최소화 하는 약한 분류 모델  $c_t$ 가 정의되며, 이때  $c_t$ 에 의한 분류에서 에러가 발생하는 학습 샘플에 대해서는 가중치를 높여주어, 다음 반복 회수에서는 반드시 분류될 수 있도록 조정한다. 최종적으로 반복 회수 T개의 약한 분류기가 생성되며, 이 약한 분류기의 가중치 합의 형태로 분류 모델이 완성된다.

제안하는 기법에서는 단계별 이진 분류 모델로 Adaboost를 이용하였다. Adaboost를 선택한 이유는 다음과 같다. 첫째, 학습 시에 결정해야 할 파라미터가 학습 반복회수 한 개만이 존재한다. 학습에 필요한 파라미터는 학습 성능을 결정하는 중요한 요소이다. 일반적인 학습 과정에서는 최대한 많은 경우의 파라미터에 대한 수많은 반복 학습을 통하여 최적의 결과를 얻게 된다. 그러나 제안하는 기법의 경우, 단계별로 구성되는 클래스 그룹에 대한 모든 경우에 대해 학습과 검증을 진행해야 하므로, 파라미터가 많은 분류 모델을 사용할 경우, 발생하는 수많은 반복 학습을 진행하기 어렵다. 둘째, 복잡한 특징 공간에서도 우수한 분류 성능을 보인다. Adaboost는 복잡도가 높은 특징 공간에서도 높은 분류 성능을 보이며, 선형 및 비선형 경계 모두 표현이

표 2. Adaboost  
Table 2. Adaboost.

<p>입력: 훈련 집합</p> $X = \{(x_1, t_1), (x_2, t_2), \dots, (x_N, t_N)\}$ <p>출력: 분류기 앙상블 <math>C = \{c_t, 1 \leq t \leq T\}</math></p> <p>분류기 신뢰도 <math>\alpha_t, 1 \leq t \leq T</math></p> <p>알고리즘</p> <ol style="list-style-type: none"> <li>1. <math>t = 1</math></li> <li>2. <math>C = \emptyset</math></li> <li>3. for (<math>j = 1</math> to <math>N</math>) <math>w_t(j) = 1/N</math></li> <li>4. repeat{</li> <li>5. <math>w_t</math>를 감안하여 분류기 <math>c_t</math>를 학습시킨다.</li> <li>6. <math>\epsilon_t = 0</math></li> <li>7. for (<math>j = 1</math> to <math>N</math>) if (<math>c_t(x_j) \neq t_j</math>) <math>\epsilon_t = \epsilon_t + w_t(j)</math></li> <li>8. if (<math>\epsilon_t &lt; 0.5</math>) {</li> <li>9. <math display="block">\alpha_t = \frac{1}{2} \ln \left( \frac{1 - \epsilon_t}{\epsilon_t} \right)</math></li> <li>10. for (<math>j = 1</math> to <math>N</math>)</li> <li>11. if (<math>c_t(x_j) \neq t_j</math>) <math>w_{t+1}(j) = w_t(j) * e^{\alpha_t}</math></li> <li>12. else <math>w_{t+1}(j) = w_t(j) * e^{-\alpha_t}</math></li> <li>13. <math display="block">s = \sum_{j=1}^N w_{t+1}(j)</math></li> <li>14. for (<math>j = 1</math> to <math>N</math>) <math>w_{t+1}(j) = w_{t+1}(j) / s</math></li> <li>15. <math>C = C \cup c_t</math></li> <li>16. <math>t++</math></li> <li>17. }</li> <li>18. }until(멈춤 조건)</li> <li>19. <math>T = t - 1</math></li> </ol>
---

가능하다. 결정 경계의 세분화 정도는 Adaboost 학습의 반복 회수에 따라 결정된다. 그림 7에서는 반복 회수에 따른 결정 경계의 변화의 예를 보여준다. 그림 7에서와 같이, Adaboost는 반복 회수에 따라 결정 경계의 세분화 수준이 결정된다. 반복 회수가 많아질수록 결정 경계의 세분화가 심화되며, 학습 샘플의 분류 성능은 높아진다. 그러나 일정 수준 이상으로 결정 경계가 세분화될 경우 과분할(Over-splitting)이 발생하여 오히려 분류 성능을 저하시킬 수 있다. 따라서 반복 회수에 따른 학습 결과를 분석하여 최적의 반복 회수를 결정하는 과정이 필요하다. 셋째, 구현이 매우 용이하다.

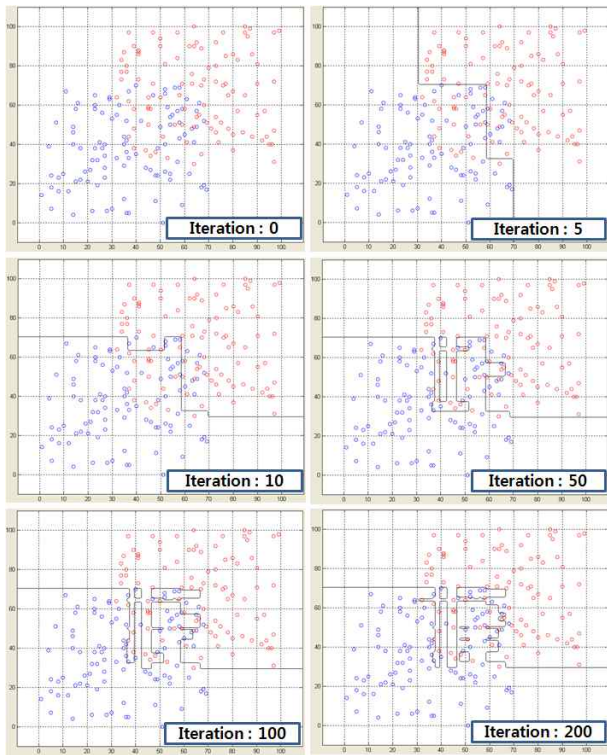


그림 7. Adaboost 반복 회수에 따른 결정경계  
 Fig. 7. The decision boundary on the number of Adaboost iteration.

Adaboost는 약한 분류기(Weak classifier)의 결합을 통해 강한 분류기(Strong classifier)를 생성하는 기법으로써, 약한 분류기 자체의 구현이 매우 단순하다. 또한, 단 한 개의 파라미터만 존재하므로 별도로 고려해야 할 구현 요소가 없다.

7. 검증 기법

제안하는 기법에서 각 계층의 Adaboost 학습을 진행할 때, 다양한 경우의 클래스 그룹이 발생한다. 따라서 한 계층 단계의 분류 모델을 확정하기 위해서는, 모든 경우의 클래스 그룹에 대해 검증을 실행하여, 가장 우수한 분류 성능을 보이는 클래스 그룹을 선택해야 한다. 주어진 샘플에 대한 분류 성능을 검증하는 기법은 K-겹 교차검증(K-Fold Cross Validation)이 있다.

K-겹 교차검증 기법은 주어진 샘플을 K개의 부분 집합으로 나눈 후, K-1개의 부분 집합으로 학습을 시키고, 나머지 한 개의 부분 집합으로 학습된 분류 모델의 성능을 측정한다. 이러한 과정을 서로 다른 부분 집합으로 다수 반복하여 나온 결과를 최종적인 성능으로 확정한다. 이때, 극단적인 경우로 K를 샘플의 개수와 일치시키면, 한 개의 샘플을 제외한 나머지 샘플로 학습

을 진행시키고, 한 개의 샘플을 테스트하는 경우가 되는데 이러한 경우를 하나 남기기(Leave-One-Out) 또는 잭나이프(Jack-Knife)라 한다. 제안하는 기법에서는 샘플의 개수가 적으며, 많은 검증 과정이 필요한 점을 고려하여 잭나이프 기법을 검증 기법으로 선택하였다.

III. 실험 결과

1. 실험 환경

실험과 분석을 위하여 사용된 시스템의 세부 사양은 아래와 같다.

- Intel P-Dual CPU 1.60GHz 1.0GB RAM
- Microsoft Windows XP
- MATLAB 7.6.0

본 논문에서는 8종의 감성 클래스를 대상으로 실험을 진행하였으며, 각각의 감성 클래스에 대하여 표기의 편의를 위하여 아래의 표 3과 같이 레이블을 부여하였다. 이는 실험 대상으로 하는 MIT 생체 신호 데이터의 구조 순서를 그대로 사용하였다.

표 3. 감성 클래스 레이블  
 Table 3. The label of emotion classes.

레이블	감성 클래스
1	무감성(No Emotion)
2	분노(Anger)
3	미움(Hate)
4	슬픔(Grief)
5	정신적인 사랑(Platonic Love)
6	낭만적인 사랑(Romantic Love)
7	기쁨(Joy)
8	숭배(Reverence)

실험은 통계적 특징값으로 구성되는 24차원의 특징 공간에서의 계층형 분류 모델 학습 및 성능 평가, 피쳐 공간에서의 계층형 분류 모델 학습 및 성능 평가, 그리고 특정 감성 클래스를 대상으로 한 계층형 분류 모델 학습 및 성능 평가로 진행하였다. 각각의 실험은 다음의 파라미터에 따라 수행하였다.

- 클래스 그룹 분리의 경우의 수



- Adaboost 반복 회수
- 피셔 선형 분리 공간의 변환축 개수

클래스 그룹 분리의 경우의 수는 각 단계에서 대상이 되는 클래스를 분리할 수 있는 모든 경우에 대하여 실험을 하였으며, 클래스 그룹은 2개로 한정하였다.

Adaboost의 반복 회수는 100회, 200회, 300회의 경우에 대하여 실험을 수행하였으며, 피셔 선형 분리 공간의 변환축 개수는 2개와 3개의 경우에 대하여 실험을 수행 하였다. 그리고 각각의 이진 분류 학습에 대하여 잭나이프 검증을 수행하여 분류 성능을 평가하였으며, 최종 결합된 단계적 분류 모델에서도 잭나이프 검증을 통해 분류 성능을 평가하였다. 따라서 각 단계의 이진 분류 성능은 클래스 개수의 20배수의 잭나이프 검증이 수행되었으며, 최종 분류 성능은 160회의 잭나이프 검증이 수행되었다.

## 2. 실험 결과

### 가. 특징 공간에서의 단계적 분류 실험

제안하는 기법의 성능을 평가하기 위하여, Picard<sup>[7~9]</sup> 등과 Kim<sup>[13]</sup> 등이 사용한 24차원의 통계적 특징값을 그대로 사용하여 계층형 분류 모델을 구축하고, 성능을 평가하였다.

표 4에서는 실험 결과를 보여주고 있다. 복잡도가 높은 24차원의 통계적 특징기반의 공간상에서는 각 단계 별로 한 개의 클래스를 하나의 그룹으로 할당하고, 나머지 클래스를 다른 하나의 그룹으로 할당한 후 학습을 진행했을 때, 가장 높은 분류 성능을 확인할 수 있었다.

그림 8은 단계별 학습 결과를 토대로 최종적으로 결

표 4. 학습 단계별 결과

Table 4. The training results of each stages.

단계	그룹 1	그룹 2	단계 분류 성능
1	2	1, 3, 4, 5, 6, 7, 8	90.6 %
2	8	1, 3, 4, 5, 6, 7	86.4 %
3	1	3, 4, 5, 6, 7	84.2 %
4	3	4, 5, 6, 7	77.0 %
5	6	4, 5, 7	81.3 %
6	5	4, 7	78.3 %
7	4	7	77.5 %

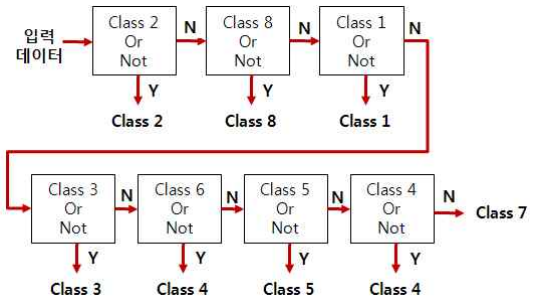


그림 8. 단계별 분류 구조

Fig. 8. The structure of staged classification.




그림 9. 분류 성능 검증 결과

Fig. 9. The experimental result of classification.

정된 분류 단계의 구조를 보여준다.

결정된 단계 분류 구조를 토대로 8종의 감성 클래스에 대한 최종 분류 성능을 실험하였다. 실험 결과 Adaboost의 반복 회수는 200회인 경우에서 가장 우수한 분류 성능을 확인하였다. 그러나 전체적으로 8종의 감성 클래스에 대한 분류 성능이 약 48~51% 수준에 머물고 있어 통계적 특징으로 구성된 24차원의 공간에서는 감성 클래스의 분류가 매우 어려운 상태임을 확인하였다. 그림 9에서는 분류 성능 검증 결과를 보여준다.

### 나. 피셔 선형 분리 공간에서의 단계적 분류 실험

제안하는 기법의 성능을 평가하기 위하여, Picard<sup>[7~9]</sup> 등과 Kim<sup>[13]</sup> 등이 사용한 24차원의 통계적 특징값을 피셔 선형 분리 공간으로 변환한 후, 단계적 분류 구조를 구축하고 성능을 평가하였다. 표 5에서는 단계별 클래스 그룹 구성 현황과 검증 결과를 보여주고 있다.

실험 결과, 두 개의 클래스 그룹을 피셔 선형 분리 공간으로 사상시킨 후, 단계 별로 학습을 진행했을 때, 각 단계 내에서 약 86~95%의 분류 성능을 나타내었다. 실험 결과 최대 4단계 레벨의 단계 분류 구조가 생

표 5. 학습 단계별 결과  
Table 5. The training results of each stages.

단계	그룹 1	그룹 2	분류 성능
1	2, 4, 6, 7	1, 3, 5, 8	93.5 %
2-1	2	4, 6, 7	91.3 %
2-2	1, 8	3, 5	86.3 %
3-1	4	6, 7	86.7 %
3-2	1	8	95.0 %
3-3	3	5	95.0 %
4-1	6	7	90.0 %

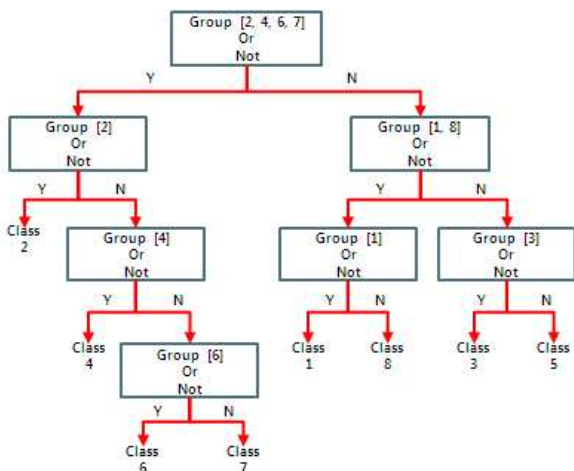


그림 9. 단계별 분류 구조  
Fig. 9. The structure of staged classification.




그림 10. 분류 성능 검증 결과  
Fig. 10. The experimental result of classification.

성되었으며, 특히 모든 반복 단계에서 2번 및 8번 클래스는 항상 서로 다른 그룹에 속해 있을 때 높은 분류 성능을 나타내었다. 앞서 표 3에 의하면 2번 클래스는 분노 감성이며, 8번 클래스는 숭배 감성을 의미한다. 그림 9는 각 단계별 분류 모델을 연결한 단계별 분류 구조를 보여준다.

결정된 단계별 분류 구조를 토대로 8종의 감성 클래스에 대한 최종 분류 성능을 실험하였다. 그림 10에서는 실험 결과로 얻어진 분류 성능을 보여준다.

실험 결과 Adaboost의 반복 회수는 200회, 피셔 공간 주축의 개수는 3개인 경우에서 가장 우수한 분류 성능을 확인하였다. 전체적으로 8종의 감성 클래스에 대한 분류 성능이 약 64~72% 수준을 보이고 있다. 또한, 피셔 공간의 축이 2축에 비해 3축일 경우 보다 높은 성능을 보임을 확인하였으며, Adaboost 반복 회수는 적정선을 넘어서면 오히려 분류 성능에 악영향을 미치는 것으로 확인되었다.

다. 특정 감성 클래스에 대한 단계적 분류 실험

Picard<sup>[7~9]</sup> 등의 연구에서는 2, 7, 8번 클래스에 해당하는 3종의 감성 클래스에 대한 분류 성능이 88.3%로 가장 뛰어났다. 표 3에 의하면 2번 클래스는 분노 감성이고, 7번 클래스는 기쁨 감성이며, 8번 클래스는 숭배 감성을 의미한다. 실험 결과, 단계별 분류 구조는, 1차로 2번과 7, 8번 그룹으로 분리되고, 2차로 7번과 8번을 분리한다. Adaboost의 반복 회수는 300회, 피셔 공간 주축의 개수는 3개인 경우에서 가장 우수한 분류 성능을 확인하였다. 전체적으로 특정 3종의 감성(2, 7, 8)의 분류 성능은 약 88~93%로 나타났다. 그림 11은 Adaboost의 반복회수와 피셔 공간 주축의 개수에 따른 성능 실험 결과를 보여준다.

Picard<sup>[7~9]</sup> 등의 연구에서 2, 4, 8번 클래스에 해당하는 3종의 감성 클래스에 대한 분류 성능 또한 상대적으로 우수한 성능이 확인되었다. 따라서 위의 실험과 동일한 방향으로 감성 클래스 분류 성능에 대한 실험을




그림 11. 특정 감성(2, 7, 8)에 대한 분류 성능 검증 결과  
Fig. 11. The experimental result of 2, 7, 8 emotion classification.




그림 12. 특정 감성(2, 4, 8)에 대한 분류 성능 검증 결과  
Fig. 12. The experimental result of 2, 4, 8 emotion classification.

하였다. 앞서 표 3에 의하면 2번 클래스는 분노 감성이고, 4번 클래스는 슬픔 감성이며, 8번 클래스는 숭배 감성을 의미한다. 실험 결과, 앞선 시험과 유사하게 1차로 2번과 4, 8번 그룹으로 분리되고, 2차로 4번과 8번을 분리하는 구조가 구성되었다. Adaboost의 반복 회수가 200회, 피셔 공간 주축의 개수가 3개인 경우와 Adaboost의 반복 회수가 300회인 경우가 동일하게 가장 우수한 분류 성능을 보였다. 그림 12는 Adaboost의 반복회수와 피셔 공간 주축의 개수에 따른 성능 실험 결과를 보여준다.

#### IV. 결 론

본 논문에서는 복잡도 높은 다종의 감성 클래스에 대하여 단계별 클래스 그룹을 형성하여 피셔 선형 분리 공간을 구성한 후, 분류 모델을 학습하고, 단계별로 생성된 분류 모델을 결합하여 분류 모델을 구성하는 감성 분류 기법에 대하여 제안하였다. 실험 결과, 다종의 감성 클래스 각각을 동시에 분류하는 방법에 비하여 이진 클래스 분류 문제로 단순화하여, 단계별로 분류해 나가는 방법이 최종적으로 다종의 감성 클래스 분류 성능을 향상시켰다. 또한 특정 소수의 감성 클래스 분류 문제에서도 92% 이상의 우수한 분류 성능을 보였다. 그러나 제안하는 기법에서 고려한 Adaboost의 반복 회수, 피셔 공간의 주축의 개수, 그리고 그룹을 구성하는 개수 등의 파라미터에 대한 다양한 연구를 진행하여 기법의 일반성을 확보해 나가야 한다. 또한 실험 결과에서 언급하였듯이, 특정 감성들 간의 분류성과 유사성이 상당수 존재한다는 것을 알 수 있다. 따라서 개별 클래스

간의 관계에 따른 감성 데이터의 분포 패턴을 분석하는 연구를 진행하여 감성 인식에 보다 우수한 성능을 내는 분류 모델을 확립해 나가야 한다.

본 논문에서는 8종의 감성을 일으키는 이미지를 통해 획득된 MIT 생체 신호 데이터를 이용하였다. 그러나 대부분의 기존 연구에서는 자체적인 실험 환경을 구축하여 생체 신호를 획득하고, 감성 인식 연구에 이용하였다. 본 논문에서도 생체 신호 획득 환경에 대한 분석을 진행하여 자체 획득한 데이터 기반의 연구와 분석을 진행하여야 한다. 향후 생체 신호 데이터 획득으로부터 감성 인식 모델을 확립하고, 감성 데이터의 패턴을 인식할 수 있다면, 감성 지능형 컴퓨팅은 학문적/산업적인 적용이 가능한 능력을 갖추게 될 것이다.

#### 참 고 문 헌

- [1] Zhihong Z., Maja P., Glenn I. R. and Thomas S. H., "A Survey of Affect Recognition Method: Audio, Visual, and Spontaneous Expressions," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol 31, No. 1, January 2009.
- [2] Carlson NR., "Physiology of Behaviour. Needham Heights," *MA: Allyn and Bacon*, 1998.
- [3] Ekman P., Levenson R. W., and Friesen W. V., "Autonomic Nervous System Activity Distinguishes among Emotions," *Science*, Vol. 221, pp. 1208-1210, 1983.
- [4] Levenson R., "Autonomic nervous system differences among emotions," *Psychological Science*, 3(1):23 - 7. 1992.
- [5] Prkachin K., Williams-Avery R., Zwaal C. and Mills D., "Cardiovascular Changes During Induced Emotion: An Application of Lang's Theory of Emotional Imagery," *Journal of Psychosomatic Research*, 47(3):255 - 67. 1999.
- [6] Keil A., Bradley M., Hauk O., Rockstroh B., Elbert T. and Lang P., "Large-scale Neural Correlates of Affective Picture Processing," *Psychophysiology*, 39(2002):641 - 9. 2002.
- [7] Picard R., Vyzaz E. and Healey J., "Toward Machine Emotional Intelligence: Analysis of Affective Physiological State," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 23(10):1175 - 91, October 2001.
- [8] Healey J. and Picard R., "Digital Processing of Affective Signals: Acoustics, Speech and Signal Processing," *Proc. of the ICASSP'98*, pp 3749 - 3752, Vol. 6, May 1998.

[9] Vyzaz E and Picard R., "Affective Pattern Classification," *AAAI Fall symposium Series: Emotional and Intelligent: The Tangled Knot of Cognition*, October 1998.

[10] Leon E., Clarke G., Sepulveda F. and Callaghan V., "Optimised Attribute Selection for Emotion Classification Using Physiological Signals," *26th Annual International Conference of the IEEE*, pp. 184 - 187, September 2004.

[11] Leon E., Clarke G., Sepulveda F. and Callaghan V., "Neural network-based improvement in class separation of physiological signals for emotion classification," *IEEE Int. Conf on Cybernetics and Intelligent Systems*, pp. 724 - 728, 2004.

[12] Leon E., Clarke G., Callaghan V. and Sepulveda F., "Real-time detection of emotional changes for inhabited environments." *Computers & Graphics*, Vol. 28, Issue 5, pp. 635-642, October 2004.

[13] Kim J. and Elisabeth A., "Emotion Recognition Based on Physiological Changes in Music Listening," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 30, No. 12, December 2008.

[14] 신윤희, 김영래, 김은이, "킬러와 패턴을 이용한 텍스스타일 영상에서의 감성인식 시스템", *대한전자공학회 논문지 CI편*, 제45권, 제6호, 154-161쪽, 2008년 11월

[15] 조윤희, 박규식, "성별 구분을 통한 음성 감성인식 성능 향상에 대한 연구", *대한전자공학회 논문지 SP편*, 제45권, 제4호, 107-114쪽, 2008년 7월

[16] 이계환, 장준혁, "최소 분류 오차 기법과 멀티 모달 시스템을 이용한 감정 인식 알고리즘", *대한전자공학회 논문지 SP편*, 제46권, 제4호, 76-81쪽, 2009년 7월

[17] 김준수, 김동엽, 빈성환, 김대영, 류민우, 조국현, "감정 분석을 통한 개인화 홈 네트워크 서비스 시스템의 설계 및 구현", *대한전자공학회 논문지 CI편*, 제47권, 제6호, 2010년 11월.

[18] J. Healey and R. W. Picard, "Eight-emotion Sentic Data," MIT Affective Computing Group, <http://affect.media.mit.edu>, 2002.

[19] Y. Freund, and R.E. Schapire, "A decision-theoretic generalization of on-line learning and application to boosting," *Journal of Computer and System Sciences*, Vol. 55, pp. 119-139, 1997.

— 저 자 소 개 —



김 재 협(정회원)  
 2001년 한양대학교 전자계산학과  
 학사 졸업  
 2003년 한양대학교 컴퓨터공학과  
 석사 졸업  
 2008년 한양대학교 컴퓨터공학과  
 박사 졸업

2008년~2009년 한양대학교 엠비언트인텔리전스  
 S/W연구팀 박사후 연구원  
 2009년~현재 삼성탈레스 책임연구원  
 <주관심분야 : 컴퓨터비전, 패턴인식>



전 갑 송(정회원)  
 1997년 연세대학교 전자공학과  
 학사 졸업  
 2004년 아주대학교 시스템공학과  
 석사 졸업  
 1998년~2006년 고등기술연구원  
 선임연구원

2006년~현재 삼성탈레스 책임연구원  
 <주관심분야 : 지상무인감시정찰체계, 전자광학  
 시스템, 영상처리>



오 나 래(정회원)  
 2009년 가톨릭대학교 디지털미디  
 어공학과 학사 졸업  
 2011년 가톨릭대학교 디지털미디  
 어공학과 석사 졸업  
 2011년~현재 우리에프아이에스  
 연구원

<주관심분야 : 에이치시아이, 감성분석>



문 영 식(평생회원)  
 1980년 서울대학교 공과대학 전자  
 공학과 학사 졸업  
 1982년 한국과학기술원 전기및  
 전자공학과 석사 졸업  
 1990년 University of California  
 at Irvine Dept. of  
 Electrical and Computer  
 Engineering. 박사 졸업

1982년~1985년 한국전자통신연구소 연구원  
 1989년~1990년 Inno Vision Medical 선임연구원  
 1990년~1992년 생산기술연구원 선임연구원  
 1992년~현재 한양대학교 컴퓨터공학과 정교수  
 <주관심분야: 영상보안, 영상검색, 패턴인식>