

## 영상과 음성의 출력 데이터를 이용한 감성 인식

### Emotion Recognition Using Output Data of Image and Speech

주영훈<sup>·</sup> · 오재홍<sup>·</sup> · 박창현<sup>·</sup> · 심귀보<sup>··</sup>

Young-Hoon Joo, Jae-Heung Oh, Chang-Hyun Park, and Kwee-Bo Sim

\* 군산대학교 전자정보공학부

\*\* 중앙대학교 전자전기공학부

#### 요약

본 논문에서는 영상과 음성의 출력 데이터를 이용한 사람의 감성을 인식하는 방법을 제안한다. 제안된 방법은 영상과 음성의 인식률에 기반하여 인간의 감성을 인식하는 방법이다. 영상이나 음성 중 하나의 출력 데이터만을 이용할 경우에는 잘못된 인식에 대한 결과를 해결하기가 힘들다. 이를 보완하기 위해서 영상과 음성의 출력을 이용하여 인식률이 높은 감성 상태에 가중치를 인가함으로써 잘못된 인식의 결과를 줄일 수 있는 방법을 제안한다. 제안된 방법을 실험하기 위해 영상과 음성에 의한 감정 인식 방법이 간단히 제안되었다. 마지막으로 본 논문에서 제안한 방법은 실험을 통해 응용가능성을 제시하였다.

#### Abstract

In this paper, we propose a method for recognizing the human's emotion using output data of image and speech. The proposed method is based on the recognition rate of image and speech. In case that we use one data of image or speech, it is hard to produce the correct result by wrong recognition. To solve this problem, we propose the new method that can reduce the result of the wrong recognition by multiplying the emotion status with the higher recognition rate by the higher weight value. To experiment the proposed method, we suggest the simple recognizing method by using image and speech. Finally, we have shown the potentialities through the expriment.

**Key Words :** 감성 인식(emotion recognition), 피치(pitch), 형판 벡터(template vector), DRNN, Backpropagation

#### 1. 서 론

최근 컴퓨터의 급속한 발전과 함께, 사용자의 의지나 감성을 인지하는 인간 친화적인 컴퓨터 인터페이스를 구축하고자 하는 연구들이 활발히 진행되고 있다[3]. 일례로, 최근에 개발, 발표되고 있는 로봇들은 두 발로 걷고, 춤을 추는 등 인간의 행동과 매우 유사한 동작을 할 수 있다. 물론, 아직 영화나 만화에서 꿈꿔오던 것처럼 실제 인간과 구분이 힘들 정도로 동작할 수 있는 기술까지는 부족하지만, 현 시점에서는 그 정도의 움직임을 보이는 것만으로도 매우 놀라운 발전임은 분명하다. 그러나 단순한 움직임만을 구현하는 것은 인간의 보조자로써 한계가 있다. 기계의 업무 영역을 넓히기 위해서는 좀더 인간과 유사해져야 한다. 이 때 필요한 것이 감성의 인식이다. 인간의 감성을 인식하게 됨으로써 좀 더 유연한 방법으로 인간에게 도움을 줄 수 있을 것이다.

예를 들면, 어떤 사람이 로봇에게 음악을 틀라고 명령을 내렸을 경우, 로봇이 사람의 감정을 인식한다면, 적절한 음악의 목록을 제시하고 명령을 수행할 수 있을 것이다. 그리고

로봇 이외에도 게임 등의 소프트웨어에도 적용하면 더욱 재미있는 제품들이 만들어 질 수 있을 것이다.

감성 인식은 얼굴 표정 인식과 음성으로부터의 인식[1,2], 두 가지 접근 방법이 있다. 본 논문에서는 두 방법을 같이 사용하여서 감성을 인식하는 방법을 연구하였다. 기존의 연구에서는 음성과 영상을 따로 분리하여서 사람의 감정을 인식하였다. 이렇게 사람의 감정을 인식하는데 있어서 영상과 음성을 따로 분리하여서 연구할 경우, 출력된 결과에 있어서 잘못된 인식이 수행되었을 경우, 이를 보상해 줄 방법이 없다. 그렇기 때문에 본 논문에서는 영상과 음성의 출력을 이용한 통합된 인식에 대한 연구를 행하였다.

영상을 이용한 사람의 감정을 인식하는 방법은 형판 벡터를 추출한 후, 추출된 형판 벡터를 역전파 알고리즘(Back-propagation Algorithm)을 사용하여서 학습과 인식을 수행하였고, 음성을 이용한 감정 인식은 피치의 패턴을 감정 인식의 주요 요소로써 사용하였고, 각각의 음성 신호의 특성에 맞춰 DRNN(Dynamic Recurrent Neural Network)을 사용하여 학습하였다.

이렇게 해서 출력된 음성과 영상의 감정 정보가 서로 같은 경우에는 결과를 산출해 내는데 있어서 그리 어려운 문제가 아니다. 하지만 두 가지 경우가 서로 상이한 결과를 산출했을 경우에는 두 가지 감정 상태 중 하나의 감정 상태를 선택해주어야 한다. 이를 위해서는 영상과 음성 각각의 감정 상태에 대한 인식률을 바탕으로 가중치를 할당하고, 할당된

접수일자 : 2003년 3월 2일

완료일자 : 2003년 6월 3일

본 연구는 산업자원부 차세대 신기술 개발 사업(과제 번호 : N09-A08-4301-09)에 의해 지원되었습니다.

가중치 정보를 바탕으로 음성과 영상이 통합된 시스템에서의 감정 상태를 출력 할 수 있게 된다.

## 2. 영상과 음성의 감성 정보 추출

### 2.1 영상의 감성 정보 추출

#### 2.1.1 얼굴 영역 추출

칼라 CCD 카메라를 통해서 획득한 정면 얼굴 영상으로부터 특징 점을 추출하는데 사용되는 메모리 인식 시간을 줄이기 위해  $320 \times 240$ 의 해상도로 축소하여 실험할 수 있도록 시스템을 구성하였다. 초기에 획득한 영상으로부터 영상 크기에 따른 거리별 오차를 보상하기 위해 각 특징의 크기를 일정한 크기 범위로 제한시키는 일반화 방법을 사용한다. 그림 1은 영상을 이용한 감정 인식 시스템의 전체 구조를 나타낸다.

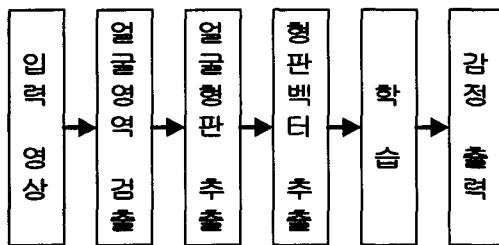


그림 1. 영상을 이용한 감정인식 구조

Fig. 1. Structure of emotion recognition using image.

초기에 획득한 칼라 영상으로부터 얼굴 영역의 위치를 찾기 위해 칼라 공간의 색조 차이를 이용한다. CCD 카메라로부터 입력된 RGB 영상을 피부색 영역 추출에 널리 사용되는 YIQ 모델을 사용하여 피부색 영역을 추출한다. RGB 모델은 색의 밝기 값을 가지고 있는 인자가 따로 분리되어 있지 않기 때문에, YIQ 모델을 사용할 경우 밝기에 민감한 피부색 영역을 추출하는데 있어서 유용하게 사용되어 진다. YIQ 모델을 사용하여 피부색 영역과 그 이외의 영역을 나눈 후, 피부색 영역의 중심점으로부터 얼굴 영역을 산출하게 된다. 그림 2는 실제 실험을 통해서 추출된 얼굴 영역 추출 그림이다.



그림 2. 얼굴 영역 추출 예  
Fig. 2. Example of face region extraction

그림 2에서 사각형 영역이 실제 추출된 얼굴 영역을 의미한다. 즉, 사각형 영역은 다음 단계인 형판 추출 단계에서 전처리 과정으로 정량화 된 크기로 만들게 될 영역을 의미한다.

#### 2.1.2 형판 벡터 추출

입력 영상에 얼굴 영역은 일정한 크기로 입력되어지는 것 이 아니다. 즉, 카메라와 일정한 거리를 유지한 채로 입력되

어지지 않는다. 정확한 형판을 추출하기 위해서는 추출 된 얼굴 영역을 일정한 크기로 정규화 하지 않으면 안 된다. 어떠한 이미지의 크기가 변화할 때는 여러 가지 보간법을 사용하여 불필요한 데이터의 추가나 손실을 최소화해야 한다. 본 논문에서는 구현이 용이하고, 성능 또한 우수한 양선형 보간법(Bilinear Interpolation)을 사용한다. 양선형 보간법은 세 개의 일차 보간법 때문에 가장 인접한 이웃 화소 보간법 보다 상당히 많은 양의 계산을 요구하지만, 가장 인접한 이웃 화소 보간법보다 더 성능이 우수한 영상을 산출할 수가 있다. 이렇게 정량화 된 얼굴 영역 영상에서 눈, 눈썹, 입의 형판을 추출하기 위해서는 얼굴 영역을 얻을 때 사용한 방법인 YIQ 칼라 공간 하나만을 사용하여 각각의 형판을 정확히 분리하여 추출하기가 곤란하다[4]. 이를 보완하기 위해서 두 번째 과정에서는 HSV, YCbCr 칼라 공간을 추가적으로 적용시켜 데이터 손실을 최소화시킬 수 있게 된다. 여기에 사용된 HSV 공간에서의 피부색 데이터를 가장 잘 표현하는 조건은 아래의 식 (1)을 만족하는 영역이다.

$$\begin{aligned} S &\geq 10, \quad V \geq 40, \\ S &\leq -H - 0.1V + 100, \\ H &\leq -0.4V + 75, \\ \text{if } H &\geq 0 \\ S &\leq 0.08(100 - V)H + 0.5V \\ \text{else } S &\leq 0.5H + 35 \end{aligned} \quad (1)$$

다음으로는 YCbCr 공간에서의 피부색 표현 영역에 대한 조건 식은 식 (2)와 같다.

$$\begin{aligned} \text{if } (Y > 128) \quad \theta_1 &= -2 + \frac{256 - Y}{16}, \\ \theta_2 &= 20 - \frac{256 - Y}{16}, \\ \theta_3 &= 6, \quad \theta_4 = -8 \\ \text{if } (Y \leq 128) \quad \theta_1 &= 6, \quad \theta_2 = 12, \quad \theta_3 = 2 + \frac{Y}{32}, \\ \theta_4 &= -16 + \frac{Y}{16} \quad (2) \\ Cr \geq -2(Cb + 24), \quad Cr &\geq -(Cb + 17), \\ Cr \geq -4(Cb + 32), \quad Cr &\geq 2.5(Cb + \theta_1), \\ Cr \geq \theta_3, \quad Cr &\geq 0.5(\theta_4 - Cb), \\ Cr \leq \frac{220 - Cb}{6}, \quad Cr &\leq \frac{4}{3}(\theta_2 - Cb). \end{aligned}$$

여기서 노이즈 제거를 위한 Labeling 처리 후 Size filtering을 거치게 되고, 마지막으로 Blob 처리를 거쳐서 원하고자 하는 형판을 추출 할 수 있게 된다.

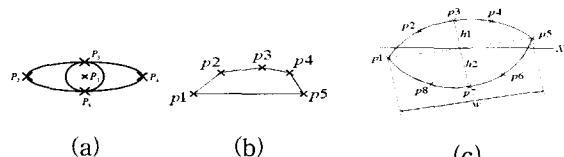


그림 3. (a) 눈의 특징 점. (b) 눈썹의 특징 점. (c) 입의 특징 점  
Fig. 3. (a) Feature point of eye. (b) Feature point of eyebrow. (c) Feature point of mouth.

인간은 감정에 따라서 눈썹, 눈, 입의 크기나 모양이 변화하게 된다[5]. 이러한 변화에 따라서 각각의 상태 정보를 가지고 있는 형판 벡터를 추출한다. 이를 위해서는 각각의 형판에 대해 같은 방법으로 형판 벡터를 추출하는 것보다는 각각의 형판에 대해 같은 방법으로 형판 벡터를 추출하는 것보다는 각각의 형판에 대한 특징과 감성 인식에 있어서 얼마나

중요한지를 따져서 형판별로 다른 방법을 적용해 형판 벡터를 추출하는 것이 더 효율적이다. 그림 3은 각각의 형판에 대한 특징 점들을 표시하였으며, 그림 4에서는 그림 3을 사용해서 실제적으로 실험을 통해 얻어진 형판 벡터들을 나타낸다.

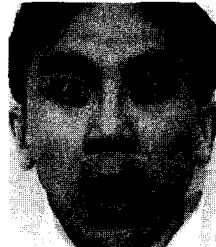


그림 4. 형판 벡터 추출 예

Fig. 4. Example of template vector extraction

### 2.1.3 인식을 위한 학습 알고리즘

본 실험에서 최종적으로 얻고자 하는 것은 사람의 감성 상태 인식이다. 이를 위해서는 얻어진 형판 벡터들에 대한 학습 과정이 필요하게 되는데, 본 논문에서 사용한 학습 알고리즘은 역전파 알고리즘이다. 이 역전파 알고리즘의 입력으로는 각각의 추출된 형판 벡터들이 입력으로 들어가며, 결과적으로 우리가 얻고자 하는 출력 값인 감성 상태를 얻게 된다. 획득한 형판 벡터를 이용하여 인간의 감성(무표정, 놀람, 화남, 기쁨)들에 대해 각각 50개씩 전체 200개의 학습 이미지들에 대한 데이터를 산출한다. 이를 신경회로망을 이용하여 각각의 감성 상태에 따라서 학습을 시킨다. 역전파 알고리즘은 학습이 수행되는 동안 가중치 정보가 향상되고 원하는 반복 횟수에 도달하면 학습을 멈추고, 최종 가중치 정보가 저장된다. 이 정보를 이용하여 감성 인식을 수행하게 된다. 마지막으로 형판 벡터의 추출 과정에서부터 인식까지 일련의 과정을 그림 5에 나타내었다.

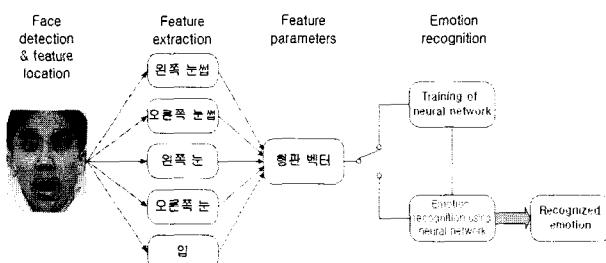


그림 5. 형판 벡터 추출에서 학습까지의 단계.

Fig. 5. Step from template vector extraction to learn.

## 2.2 음성의 감성 정보 추출

### 2.2.1 음향의 감성 정보

소리의 정보 전달에는 자료의 전달 뿐 아니라 정서적인 정보 또한 포함하고 있다. 동일한 정보를 전달하더라도 부드러운 목소리로 전달하는 경우와 불쾌한 목소리로 전달하는 경우의 정보전달 효과는 다르다. 소리 신호는 푸리에의 이론에 여러 주파수들의 조합으로 이루어져 있으므로 갖가지 감성을 갖는 소리들을 주파수 영역에서 분석하여 분류 할 수 있다. 목소리의 기본음(Fundamental Frequency)은 125Hz~250Hz 이고, 목소리의 힘을 주는 음역대는 350Hz에서

2000Hz이다. 즉, 에너지가 가장 많은 부분이다. 표 1에서는 주파수 대역에 따라 다른 청각적 느낌을 나타낸 표이다.

표 1. 주파수 대역에 따른 청각적 느낌.

Table 1. Hearing impression by frequency band.

| 주파수           | 청각적 느낌   |
|---------------|--|
| 125Hz~500Hz   | 증폭하면 목직함이 생기고, 줄이면 굉장히 약한 목소리가 됨                               |
| 2000Hz~5000Hz | 증폭하면 목소리의 명확도가 높아짐   |
| 4000Hz~8000Hz | 지찰음, S, SH, CH, C 등을 말할 때의 듣기 쉬운 소리가 나옴. 줄이게 되면 목소리의 깨끗함도 감소됨. |
| 8000Hz 이상     | 입에서 나오는 공기소리   |

### 2.2.2 음향 요소 분석

본 논문은 음향 요소를 날카로움, 저음, 굵음, 가슴, 큼, 작음의 6가지로 정의한다. 6가지 요소의 분석을 위하여 모음 '아'에 대한 실험을 하였다. 표 2에서 F : Formant, Mag : Magnitude, Int : Intensity, NU : Non Uniform, M1 : Man 1을 의미한다.

표 2. M1에 대한 음향적 분석

Table 2. Sound analysis about M1

|           | M1_평  | M1_날카로움 | M1_저음 | M1_중저음 |
|-----------|-------|---------|-------|--------|
| 1F(Hz)    | 824   | 800     | 600   | 650    |
| 2F(Hz)    | 1100  | 1200    |       |        |
| 3F(Hz)    | 3000  |         | 2800  | 2780   |
| 4F(Hz)    | 3480  |         | 3300  | 3400   |
| 5F(Hz)    | 4570  |         | NU    | 4300   |
| Mag       | 0.8   | 1.65    | 0.6   | 1.4    |
| Int(dB)   | 78dB  | 88dB    | 75dB  | 80dB   |
| Pitch(Hz) | 134Hz | 370Hz   | 109Hz | 130Hz  |

표 3. M2에 대한 음향적 분석

Table 3. Sound analysis about M2

|           | M1_평  | M1_날카로움 | M1_저음 | M1_중저음 |
|-----------|-------|---------|-------|--------|
| 1F(Hz)    | 812   | 700     | 630   | 743    |
| 2F(Hz)    | 1210  | 1200    | 1100  | 1160   |
| 3F(Hz)    | 2760  | 2700    | 2500  | 2600   |
| 4F(Hz)    | 3700  |         | 3400  | 3400   |
| 5F(Hz)    | NU    |         | 없음    | 3600   |
| Mag       | 1.6   | 1.6     | 0.6   | 1.4    |
| Int(dB)   | 83dB  | 87dB    | 75dB  | 80dB   |
| Pitch(Hz) | 117Hz | 290Hz   | 109Hz | 130Hz  |

표 2와 3은 각각 여러 가지 실험 데이터 중 대표적인 결과이다. 위의 결과에 따르면 음의 높낮이는 피치(Pitch)로 명명한 구분이 가능하다. 그리고 날카로운 소리의 경우는 3, 4, 5 Formant가 순간 순간 변하는 것을 알 수 있다. 날카로운 소리와 저음의 경우를 비교해 보면, 배에서부터 나온 소리의 경우 Uniform한 Formant의 분포를 보이나, 날카로운 소리

중 머리로부터 올리는 경우는 3, 4, 5 Formant에서 Non Uniform한 특성을 보인다. 이 경우에는 소리가 맑지 않다. 그리고 125 - 500Hz는 풍부한 느낌의 주파수가 분포한다. 또한, 1F가 500Hz 주변에서 많이 분포하는 경우에 더 굵은 목소리로 들린다. 표 2에서 저음과 중저음 부분의 1F, 2F가 같은 대역에 분포하는 경우는 각각 다른 대역에 분포하는 경우보다 에너지의 크기가 더 크므로 더욱 굵은 소리를 낸다. 반대로 500Hz에서 멀수록 가는 소리이다. 이러한 음향 요소의 분석 결과와 감정과의 관계는 본 연구에서 매우 중요하다. 따라서 그림 6은 음성의 입력 데이터 중 피치의 평균값, 분산 그리고 웨이브의 크기와 분산이 본 논문에서 제한한 감정과 어떤 관계를 갖고 있는지 실험적으로 분석한 결과이다. 실험에 사용된 음성들은 10명의 화자에게서 발화된 음성이고, 여러 문장 4가지 감정을 포함하여 발화하도록 하였다. 또한, 본 실험은 음성의 크기/방향이 결과에 영향을 미칠 수 있으므로 화자와 마이크의 위치를 정확히 고정하였다. 그림 6에서 보는 바와 같이 평서형과 화의 경우는 분류가 어느 정도 용이하나 웃음과 놀람의 경우는 중첩되는 경우 때문에 오인식률을 높이게 된다. 이러한 문제 때문에 주파수 영역의 분석 결과를 특정 점으로 추가하여야 하고, 또한 피치의 패턴 정보를 포함 할 수 있는 수치적 특징 점을 추가하는 연구가 필요하다.

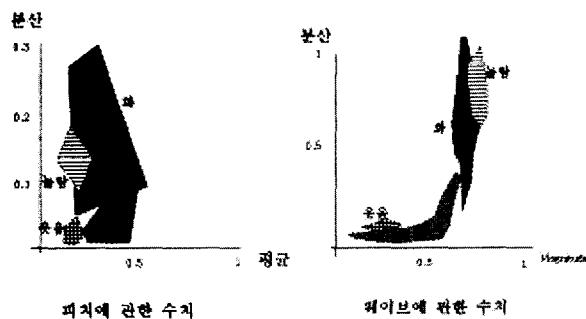


그림 6. 음성의 수치적 특성과 감정과의 관계  
Fig. 6. Relation of emotion and numerical characteristic of speech

### 2.2.3 DRNN을 이용한 감성인식을 위한 특징 추출

감성 인식 시뮬레이터의 입력 값으로는 피치의 패턴들을 사용한다. 즉, 4가지 감정에 대한 대표적인 패턴들을 DRNN(Dynamic Recurrent Neural Network) 구조를 이용하여 학습, 인식한다. 피치를 추출하기 위해서 우선 Autocorrelation Approach Using Center-Clipping Function을 사용한다.

$$A(k) = \sum_{m=-\infty}^{\infty} x(m)x(m+k) \quad (3)$$

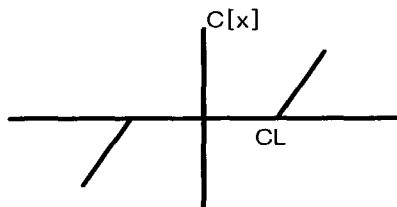


그림 7. Center clipping function  
Fig. 7. Center clipping function

식 (3)은 Autocorrelation 함수를 나타내고, Center Clipping function은 Autocorrelation 함수에 데이터를 입력시키기 전에 필요 없는 정보를 제거하는 역할을 수행한다.

$$y(n) = c[x|n] \quad (4)$$

식 (4)와 그림 7이 Center Clipping Function을 나타낸다. 이 함수는 음성 신호가 일정한 레벨 ( $C_L$ )내에 있으면 그 신호를 무시하고,  $C_L$ 보다 크면 원래 신호에서  $C_L$ 을 뺀다. 이는 음성 신호 중에서 피치에 해당하는 성분은 크기가 크게 나타나는 특징을 이용해서 잔여 성분을 제거하는 방법이다. 그리고  $C_L$ 은 프레임 내의 가장 큰 음성 신호 레벨의 64%를 기준으로 한다[6].

### 2.2.4 시뮬레이터

그림 8은 시뮬레이터의 구조를 나타낸다. 마이크를 통하여 음성이 입력되면, 음성의 피치를 추출하고 추출 된 피치를 각 감정에 대응하여 학습을 시킨다. 학습을 통하여 신경망의 가중치를 획득 인식기를 통하여 인식을 한다[7].

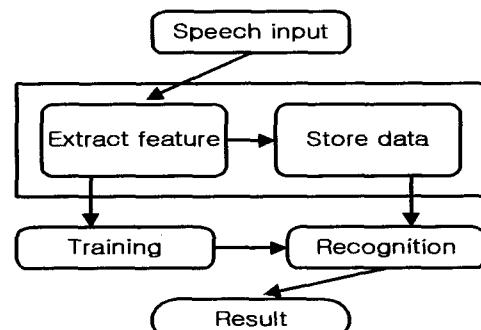


그림 8. 시뮬레이터의 구조  
Fig. 8. Structure of simulator

### 2.2.5 DRNN

- Fully connected.
- Input : 1, Hidden : 2, Out : 4
- Input : Pitch,
- Out : Normal, Angry, Laugh, Surprise

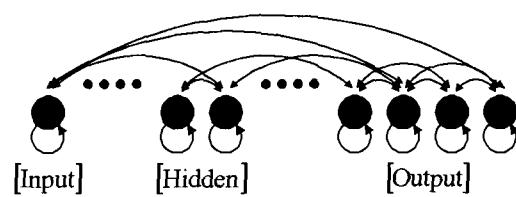


그림 9. DRNN  
Fig. 9. DRNN

DRNN의 구조는 그림 9와 같고, 음성의 입력이 시간에 따라 순차적으로 들어오므로 DRNN이 이러한 종류의 데이터에 적합하다.  $i$ 번째 뉴런의 출력은 다음과 같다.

$$y_i = f(h_i(t-1)) + A(\sigma) \quad (5)$$

$$h_i = (\sum_j w_{ij} y_j(t) + x_i(t)) \quad (6)$$

$h_i(t-1)$ 은 시간  $(t-1)$ 에서  $i$ 번째 노드에 대한 입력이

다.  $x_i(t)$ 는  $i$ 에서의 외부 입력이다.  $f(\cdot)$ 는 Nonlinear Derivative Activation Function이다[8].

$$f(x) = \frac{2}{1 + \exp\left(-\frac{2x}{u_0}\right)} - 1 = \tanh\left(\frac{x}{u_0}\right) \quad (7)$$

### 3. 영상과 음성의 출력을 이용한 감정 인식

영상과 음성 각각의 출력이 서로 상이한 경우에 우리는 어느 하나의 감정을 선택해 주어야 한다. 이를 위해서는 우선 영상과 음성에 대해서 각각의 감정 상태에 대한 인식률을 계산되어져 있어야 한다. 계산된 인식률을 사용하여서 각각의 감정 상태에 대한 가중치 값을 할당하게 된다.

각각의 감정 상태와 음성과 영상의 가중치는 아래와 같이 표현된다.

$$\begin{aligned} \text{Image Weight} &: W_{1\text{neutral}}, W_{1\text{happiness}}, W_{1\text{surprise}}, W_{1\text{anger}} \\ \text{Speech Weight} &: W_{2\text{neutral}}, W_{2\text{happiness}}, W_{2\text{surprise}}, W_{2\text{anger}} \end{aligned}$$

하나의 감정 상태에 대해서 가중치는 영상과 음성 2가지의 경우가 나오게 되는데, 이 두 가지 중에서 하나는 0에 가까운 값을 갖게 되고, 다른 하나는 그 감정의 인식률의 차의 곱을 취함으로써 가중치를 할당하게 된다.

이렇게 구해진 가중치 정보를 가지고 실제 시스템의 출력을 결정하게 되는데 여기에 사용된 방법은 식 (8)과 같이 표현이 된다. 여기서  $I$ 는 영상의 감정 상태 출력이고,  $S$ 는 음성의 감정 상태 출력이다. 이를 각각의 감정 상태에 대해서 가중치와 곱을 취하면, 각각의 감정 상태에 대한 출력이 나오게 되는데, 결과적으로는 값이 제일 큰 감정 상태가 출력으로 나오게 된다. 이는 식 (9)에 표현하였다.

$$\begin{aligned} O_{\text{neutral}} &= W_{1\text{neutral}}I_{\text{neutral}} + W_{2\text{neutral}}S_{\text{neutral}} \\ O_{\text{happiness}} &= W_{1\text{happiness}}I_{\text{happiness}} + W_{2\text{happiness}}S_{\text{happiness}} \\ O_{\text{surprise}} &= W_{1\text{surprise}}I_{\text{surprise}} + W_{2\text{surprise}}S_{\text{surprise}} \\ O_{\text{anger}} &= W_{1\text{anger}}I_{\text{anger}} + W_{2\text{anger}}S_{\text{anger}} \end{aligned} \quad (8)$$

최종적으로 우리가 얻고자 하는 감정은 아래의 식 (9)처럼, 각각의 감정 상태의 출력 값에 최대값을 선택해 줌으로써 얻을 수 있게 된다.

$$\text{System Output} = \max\{O_{\text{neutral}}, O_{\text{happiness}}, O_{\text{surprise}}, O_{\text{anger}}\} \quad (9)$$

영상과 음성의 입력으로부터 감정의 출력까지를 표시한 그림은 아래의 그림 10과 같다.

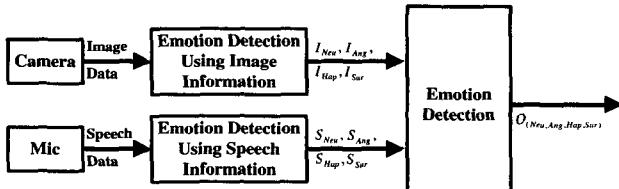


그림 10. 감정 인식의 전체 시스템

Fig. 10. Whole system of emotion recognition

### 4. 실험 결과 및 고찰

제안한 방법의 융용 가능성을 확인하기 위해서 실험을 통해 얻어진 결과들을 비교 분석해 보았다. 그림 11, 12, 13은 각각 실제 실험을 통해 구현한 감정인식 시뮬레이터의 화면의 한 예를 보여준다. 먼저, 음성과 영상의 인식률을 제안한 방법에 의해서 각각 추출한 후, 이를 바탕으로 음성과 영상에 대해서 각각의 감정 상태에 대한 가중치를 할당한다. 가중치를 할당한 후, 식 (8)을 이용해서 영상과 음성의 출력 데이터를 이용해서 영상과 음성의 출력 데이터를 이용한 감정인식을 행하게 된다. 영상과 음성의 오 인식의 결과에 대한 몇 가지 실험 값을 이용하여서 제안한 방법을 실험한 결과 약 60% 정도의 오 인식에 따른 결과를 해결할 수가 있었다.

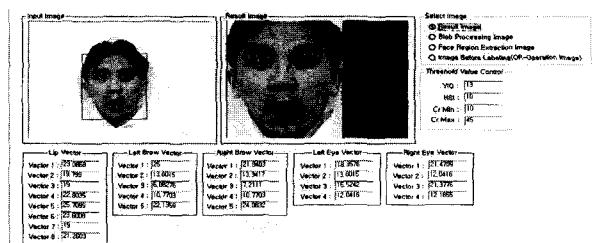


그림 11. 형판 벡터를 이용한 감성 인식 실험 화면  
Fig. 11. Experimental window for emotion recognition using template vector

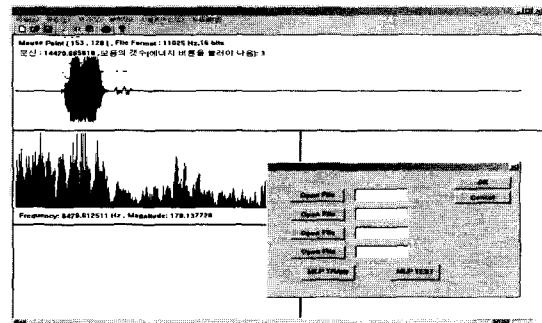


그림 12. 피치를 이용한 감성 인식 실험 화면  
Fig. 12. Experimental window for emotion recognition using pitch

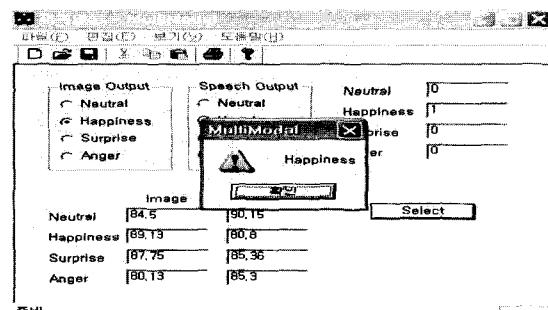


그림 13. 영상과 음성의 출력 데이터를 이용한 감성 인식 실험 화면  
Fig. 13. Experimental window for emotion recognition using output data of speech and image

평균적으로 영상과 음성의 감정 인식률은 75% 정도인데, 제안한 방법을 추가하여 실험한 경우에는 약 80% 정도 이상의 결과를 산출할 수가 있었다. 이는 제안한 방법 자체가 영상이나 음성의 출력 중 어느 하나에 가중치를 줌으로써 각각의 감정 상태에 대한 오인식의 결과를 보완하기 위해서 제안되었기 때문이다.

## 5. 결 론

본 논문에서는 영상과 음성의 출력 데이터를 이용한 감정 인식 방법을 제안하였다. 기존의 연구에서는 감정 인식을 행하는데 있어서, 영상과 음성을 따로따로 분리하여 실험을 행하였다. 제안된 방법은 영상의 감정 상태 출력과 음성의 감정 상태 출력이 서로 상이 할 때, 어느 한쪽의 감정에 가중치를 줌으로써 인간의 감정 상태를 식별하였다. 여기에 사용된 가중치는 음성과 영상의 각각의 감정 상태에 대한 인식률을 기반으로 계산되어지게 된다. 영상에서의 감정 상태 출력은 형판 벡터를 이용하여 추출된 얼굴의 형판 벡터들을 역전파 알고리즘을 통해서 학습과 인식을 수행하였으며, 음성은 피치 정보를 이용하여 DRNN으로 학습 시켰다. 이러한 학습을 통해 출력된 결과를 이용하여 각각의 감정 상태에 대한 인식률을 계산하며, 이렇게 계산된 인식률을 바탕으로 영상과 음성의 출력 데이터가 상이할 때 어느 한쪽의 결과에 가중치를 줌으로써 감정 상태의 출력 확률을 높힐 수 있음을 실험을 통해 증명하였다.

## 참 고 문 헌

- [1] 이상윤, 주영훈, 심귀보, "CCD 컬러 영상에 의한 감성인식", 퍼지 및 지능 시스템학회 논문지 Vol. 12, No. 2, pp. 97-102, 2002.
- [2] 주영훈, 이상윤, 심귀보, "Eigenface를 이용한 인간의 감정인식 시스템", 퍼지 및 지능 시스템학회 논문지 Vol. 13, No. 2, pp. 216-221. 2003.
- [3] A. Samal, and P. A. Iyengar, "Automatic recognition and analysis of human faces and facial expressions : A survey", Pattern Recognition, Vol. 25, No. 1, pp. 65-77, 1992.
- [4] C. Garcia and G. Tziritas, "Face detection using quantized skin color regions merging and wavelet packet analysis", IEEE Trans. on Multimedia, Vol. 1, No. 3, pp. 264-277, 1999.
- [5] Y. Tian, T. Kanade, and J. Cohn, "Recognizing action units for facial expression analysis" IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. 23, No. 2, pp. 97-115, 2001.
- [6] J. S. Han., *Speech signal processing*, Seoul, O-Sung-media, pp. 90, 2000.
- [7] C. H. Park and K. S. Heo and D. W. Lee, Y. H. Joo, and K. B. Sim, "Emotion recognition based on frequency analysis of speech signal", Proc. of the FIRA Robot 2002 Conference, Seoul, Korea, May. 27-29, 2002.
- [8] K. B. Sim, *Methodology of Artificial Life*, Seoul, Dream-Media, 2000.

## 저 자 소 개



주영훈 (Young Hoon Joo)

제 13권 2호(2003년 4월호) 참조



오재홍(Jae-Heung Oh)

2002년 : 군산대 제어계측공학과 졸업  
2002년-현재 : 군산대학교 대학원 전자정

보공학과 석사과정

관심분야 : 컴퓨터 비전시스템, 감성공학,  
지능제어.

Phone : 063-469-4706

Fax : 063-469-4706

E-mail : jaeheung@dreamwiz.com



박창현 (Chang-Hyun Park)

제 13권 1호(2003년 2월호) 참조



심귀보(Kwee-Bo Sim)

제 13권 2호(2003년 4월호) 참조