

# 폐지 소속도를 이용한 얼굴 영상 분할

이 창 수, 이 정 훈

Computer Vision and Fuzzy Systems Laboratory

한양대학교 전자공학과

425-791 경기도 안산시 사1동 1271번지

{cslee, frhee}@fuzzy.hanyang.ac.kr.

## 요약

본 논문에서는 디지털 이미지 안에서의 얼굴 영상 분할을 위해서 데이터로부터 얼굴 영상과 배경 영상의 소속도(membership degree)를 학습시켜 구한다. 그리고 입력 이미지의 각 픽셀 값에 해당하는 소속도를 이용하여 얼굴 영상의 분할을 수행한다. 실험에서는 8-bit 그레이 스케일 영상의 ORL Database를 이용하였다.

## I. 서론

얼굴 영상 분할은 얼굴 영상 패턴 검출과 얼굴 인식의 기초가 되는 알고리즘이다. 지난 약 26년 동안의 얼굴 영상 인식 알고리즘은 많은 노력으로 연구되어 왔다. 1970년대 초의 얼굴 인식은 주로 눈, 코, 입, 눈썹 등과 같은 얼굴의 특징들에만 기초되어 왔다. 그런데 얼굴 영상 특징 추출에 대한 알고리즘과 컴퓨터의 계산기술의 부족 때문에 거의 몇 안 되는 테스트만이 얼굴 영상 인식 시스템에 적용되어 왔다. 그 후 잡복기인 1980년대를 지나서 1990년대 초에 얼굴 영상 인식에 대한 연구가 다시 살아나게 되었다. 그리하여 얼굴 영상 인식에 대한 많은 연구가 근 10년 동안 발전되어 왔다. 지금까지 연구되어 온 기술들을 몇 가지 적어보면 다음과 같다.

- Principle Component Analysis(PCA), [1]
- Linear Discriminant Analysis(LDA), [2]
- Singular Value Decomposition(SVD)
- Neural Network-based technique [5], [6], [7]

일반적으로 얼굴 영상 인식의 알고리즘에 대해서는 다음의 두 가지가 가장 주된 작업이다.  
1) 입력 이미지 안에서 얼굴의 위치를 찾는 것  
2) 찾아낸 얼굴 영상을 인식하는 것.

본 논문에서 얼굴 영상 인식과 검출의 기초가 되는 얼굴 영상 분할을 위해 새롭게 제시한 방법은 다음과 같다. 얼굴을 배경과 분할하기 위해 얼굴 영상과 배경 영상에 대한 멤버쉽 함수를 많은 양의 데이터로부터 학습시켜 얻는다. 그리고 학습시켜 얻게 된 멤버쉽 함수를 이용해서 입력 영상 각 픽셀의 얼굴과 배경의 소속도를 이용해 시 클래스를 분류한다.

## II. 본론

### II-1. 전처리 과정

주어진 영상 안에서 얼굴 영상을 분할하기

위해 입력 영상의 각 픽셀의 분포를 균등하게 하기 위해서 히스토그램 균일화를 전처리 과정으로 수행한다. 히스토그램 균등화는 영상의 픽셀의 분포를 전체적으로 균등하게 해주기 때문에 전체적인 밝기가 조정된다.



(a) 입력영상



(b) 히스토그램 균일화 영상

### II-2. 특징 추출 과정

특징 추출 과정에서는 히스토그램 균등화된 영상을 입력으로 한다. 이 영상에 대한 히스토그램을 구해서 입력 영상에 대한 특징값으로 정한다. 즉, 입력 영상의 픽셀 값의 빈도수를 특징값으로 정하게 된다. 그림2는 입력 영상을 히스토그램 균일화한 영상의 히스토그램을 나타내고 있다.

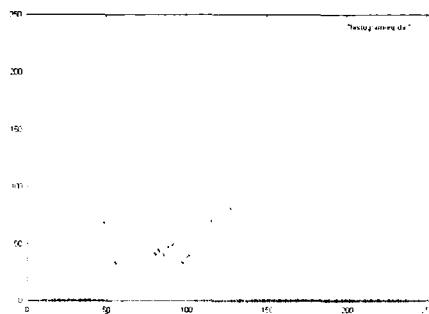


그림 2. 히스토그램 균일화 히스토그램

### II-3. 멤버쉽 함수의 설계

특징 추출 과정까지 끝나고 나면 입력 영상에 대한 히스토그램 특징값을 얻게 된다. 얻어진 히스토그램 특징값으로부터 얼굴 영상에

대한 멤버쉽 함수와 배경 영상에 대한 멤버쉽 함수를 구한다. 그리고 멤버쉽 함수를 얻기 위해서 먼저 멤버쉽 함수를 설계하는 과정이 필요하다. 이 논문에서 설계한 멤버쉽 함수는 히스토그램을 기초해서 구한 가우시안 함수의 형태이다.[4]

### II-3-1. 히스토그램 기반의 멤버쉽 함수

학습시키는 데이터로부터 얻어지게 되는 정상화(normalized)된 히스토그램은 가능성 분포함수(possibility distribution function)로 간주될 수 있다. 히스토그램 값을 기초로 해서 설계한 멤버쉽 함수는 어느 한 특징값에 대해서 각 클래스의 소속도가 가능성 함수를 이용해서 계산되어진다는 특징을 갖고 있다. 이 방법은 각각의 클래스에 대한 멤버쉽 값이 다른 클래스의 멤버쉽 값에 좌우되지 않는다는 장점을 가지고 있는데 반해서, 학습시켜야 하는 데이터의 양이 많아야 한다는 문제를 가지고 있다. 만약 그렇지 않다면 적당한 멤버쉽 함수를 얻기 위해서 보간법(interpolation)이나 다른 방법을 사용해야 할 것이다.

예를 들어  $k$  개의 특징값들  $x_1, \dots, x_k$  을 생각해보자. 우선 학습시켜야 하는 특징값들의 범위가 [0,1]에 오도록 특징값의 크기를 정상화(normalize)한다. 그리고 그림3에서 각각의 특징값들을 Q 레벨의 퍼지 집합들로 나타낸다.

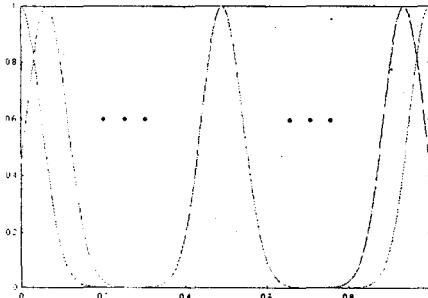


그림 3. Q 레벨의 Q개 퍼지 집합  
여기서  $u^{th}$  특징값 벡터를  $x_u^j = (x_{1u}^j, \dots, x_{Ku}^j)$  로 나타낼 때,  $k$  번째 특징값의 영역에서 정의되어지는  $j$  클래스에 대한 멤버쉽 함수  $\mu_k^j$  는 다음과 같다.

$$\mu_k^j(i) = \frac{1}{N^j} \sum_{u=1}^{N^j} f_{ki}^j(x_{ku}^j), \quad i = 1, \dots, Q \quad (2.1)$$

$f_{ki}^j()$  는 클래스  $j$ 에 대해서  $x_k$  의 영역에 정의된  $i$  번째 멤버쉽 함수이고,  $N^j$  은  $j$  클래스의 샘플 개수이다. 식(2.1)은  $Q$  개의 퍼지 레벨에서의 특징값의 소속도를 준다.

### II-3-2. 멤버쉽 함수 설계

일반적인 가우시안 함수의 파라미터 벡터를  $p = (a, c, \sigma)$  라고 하면, 멤버쉽 함수  $m_k^j(x_k)$  가 여러 개의 최고점(multiple peaks)을 가지고 있다면, 멤버쉽 함수는  $L_k^j$  개의 가우시안 함수로 모델화할 수 있다.[4]

$$m_k^j(x_k) \approx \tilde{G}_k^j(x_k) = \sum_{i=1}^{L_k^j} a_{ki}^j G_{ki}^j(x_k), \quad (2.2)$$

$$\text{여기서 } G_{ki}^j(x_k) = \exp \left[ -\frac{1}{2} \left( \frac{x_k - c_{ki}^j}{\sigma_{ki}^j} \right)^2 \right]$$

함수는 클래스  $j$ 에서  $x_k$  특징값의  $i$  번째 파라미터  $p_{ki}^j = (a_{ki}^j, c_{ki}^j, \sigma_{ki}^j)$ 에 해당하는 함수이고  $a_{ki}^j, c_{ki}^j, \sigma_{ki}^j$  는 각각 가우시안 함수의 높이, 평균값, 표준편차 값을 나타낸다. 가우시안 함수를 멤버쉽 함수로 더 유동성있게 설계하기 위해서, 비대칭 가우시안 함수  $F(x)$  를 다음과 같이 정의할 수 있다.

$$F(x) = \begin{cases} G(x, c, \sigma_1) & x < c \\ G(x, c, \sigma_2) & x \geq c \end{cases} \quad (2.3)$$

멤버쉽 함수  $m_k^j(x_k)$  가 다중 최고점을 가지고 있다면, 비대칭 가우시안 함수의 합으로써 모델화할 수 있다[4].

$$m_k^j(x_k) \approx \tilde{F}_k^j(x_k) = \sum_{i=1}^{L_k^j} a_{ki}^j F_{ki}^j(x_k) \quad (2.4)$$

$$F_{ki}^j(x_k) = \begin{cases} G(x_k, c_{ki}^j, \sigma_{1ki}^j) & x_k < c_{ki}^j \\ G(x_k, c_{ki}^j, \sigma_{2ki}^j) & x_k \geq c_{ki}^j \end{cases}$$

그리고  $F_{ki}^j(x_k)$  함수는 클래스  $j$ 의 특징값  $x_k$  의 파라미터  $p_{ki}^j = (a_{ki}^j, c_{ki}^j, \sigma_{1ki}^j, \sigma_{2ki}^j)$ 에 해당하는 비대칭 가우시안 함수가 된다.

**II-4. 멤버쉽함수로서 가우시안 파라미터 학습**  
얼굴 영상과 배경 영상의 멤버쉽 함수를 각각 영상으로부터 학습시킨다. 그리고 학습이 끝난 후에는 각각 얼굴 영상과 배경 영상에 대한 멤버쉽 함수 파라미터를 얻게 된다. 그리고 각각의 멤버쉽 함수를 비대칭 가우시안 함수의 합으로 영상으로부터 학습시킬 때, 목적함수(objective function)를 최소화할 수 있다.

$$J_k^j(p_k^i) = \frac{1}{2} \left( \sum_{i=1}^{L_k^j} h_k^j(x_k, p_{ki}^j) - m_k^j(x_k) \right)^2 \quad (2.5)$$

$h_k^j(x_k, p_{ki}^j)$  는 클래스  $j$ 의 특징값  $x_k$ 에 대한 멤버쉽 함수  $m_k^j(x_k)$  를 모델화하기 위해서 선택한 파라미터의 함수이다. 그리고 파라미터 벡터를 학습, 갱신시켜서 최종적인 값을 구하기 위해서 gradient descent 방법을 사용한다.

$$p_{ki}^{j(new)} = p_{ki}^{j(old)} - \rho \frac{\partial J_k^j}{\partial p_{ki}^j} \quad (2.6)$$

$\rho$  는 학습상수(learning constant)이다. 파라미터 벡터는 파라미터의 값의 변화가 아주 적거나 없을 때까지 계속 반복적으로 갱신된다. 이

령계 파라미터 벡터의 값의 변화가 거의 없을 때는 파라미터 벡터  $p_{ki}^j$ 의 각 성분에 대해서  $J_k^j$ 의 편미분의 값이 0에 아주 가까울 때 일어난다. 즉, 함수  $h_k^j(x_k, p_{ki}^j)$ 의 극사가 거의 멤버쉽 함수  $m_k^j(x_k)$ 와 같을 때의 경우이다. 비대칭의 가우시안 함수의 파라미터 벡터의 성분에 대한  $J_k^j$  함수의 편미분은 식(2.7)에서 식(2.9)과 같다.

$$\frac{\partial J_{ki}^j}{\partial a_{ki}^j} = (\tilde{F}_k^j - m_k^j(x_k^j)) F_{ki}^j(x_k) \quad (2.7)$$

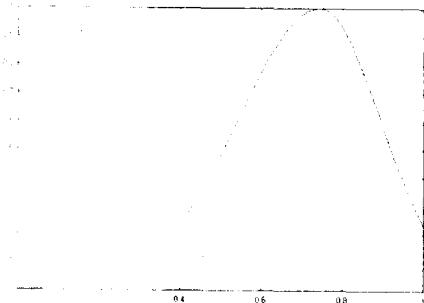
$$\frac{\partial J_{ki}^j}{\partial c_{ki}^j} = \begin{cases} (\tilde{F}_k^j(x_k) - m_k^j(x_k)) \frac{d F_{ki}^j(x_k)(x_k - c_{ki}^j)}{(\sigma_{ki}^j)^2} & x_k < c_{ki}^j \\ (\tilde{F}_k^j(x_k) - m_k^j(x_k)) \frac{d F_{ki}^j(x_k)(x_k - c_{ki}^j)}{(\sigma_{ki}^j)^2} & x_k \geq c_{ki}^j \end{cases} \quad (2.8)$$

$$\frac{\partial J_{ki}^j}{\partial \sigma_{ki}^j} = (\tilde{F}_k^j - m_k^j(x_k^j)) \frac{d F_{ki}^j(x_k)(x_k - c_{ki}^j)^2}{(\sigma_{ki}^j)^3}, l=1,2 \quad (2.9)$$

실험에서 퍼지 멤버쉽 함수로 사용되는 비대칭 가우시안 함수의 높이는 1로, 평균은 각각 얼굴 영상, 배경 영상에 대한 히스토그램 최고 값으로, 표준 편차의 초기치는 0.1로 실험을 하였다. Gradient method 방법으로 학습했으며, 학습상수  $\rho$ 는 0.01로 초기치를 정해주었다. 그림4에서는 얼굴 영상에 대한 학습 영상과 학습시킨 얼굴 영상에 대한 가우시안 멤버쉽 함수를 나타내고 있다.



(a) 얼굴영상



(b) 멤버쉽 함수

그림 4. 학습시킨 얼굴 영상과 학습 후에 얻은 얼굴 영상의 비대칭 가우시안 멤버쉽 함수

그림5는 얼굴을 제외한 배경 영상의 학습된 비대칭 가우시안 멤버쉽 함수이다.

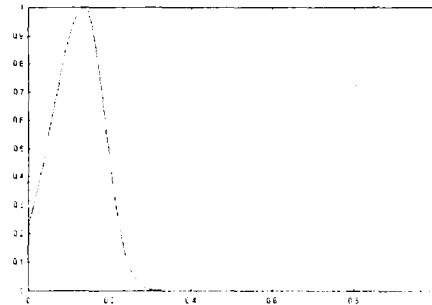


그림 5. 학습 후에 얻은 배경 영상의 비대칭 가우시안 멤버쉽 함수

## II-5. 분류과정

학습 후에 얻어진 얼굴과 배경 영상의 가우시안 파라미터 벡터로부터 각각 멤버쉽 함수를 얻게 되고, 입력 영상 픽셀의 얼굴과 배경에 대한 소속도를 얻게 된다. 그 후에 주어진 입력 영상의 각 픽셀에 대해서 소속도의 값을 비교해서 얼굴과 배경을 분할하게 된다.

```
If( face_membership > bkgrnd_membership )
    Pixel is WHITE (FACE)
Else
    Pixel is BLACK (NON-FACE)
```

## II-6. 시스템 구성도

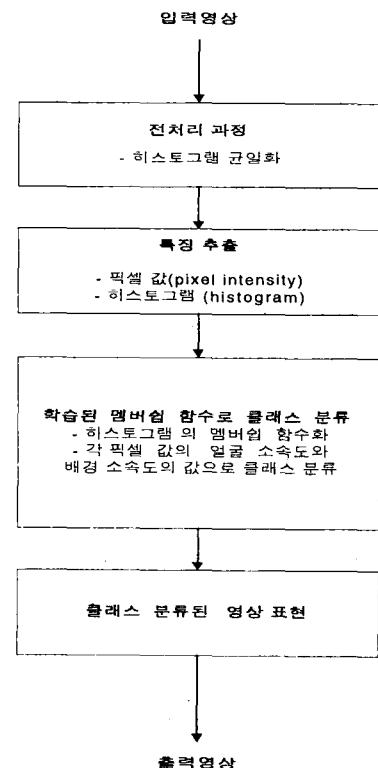


그림 6. 전체 시스템 구성도

## II-7. 실험 결과 (Experimental Result.)

실험에서는 ORL database 영상으로 실험했다. 얼굴 영상에 대한 멤버쉽 함수를 만들기 위해서 그림4의 10개의 얼굴 영상으로 학습했고. 배경 영상은 얼굴을 제외한 배경 영상으로 멤버쉽 함수를 만들었다. 그림 7에서는 학습 후에 최종적으로 얻게 된 얼굴과 배경 영상에 대한 멤버쉽 함수를 나타내고 있다. 표1에서는 학습된 최종 파라미터의 값을 보여주고 있다.

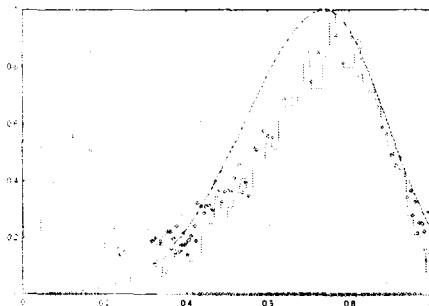


그림 7. 최종적으로 얻은 멤버쉽 함수.

<표 1>. 학습된 최종 파라미터.

	높이	평균	좌편차	우편차
Face	1.0	0.74218	0.2	0.15
Nonface	1.0	0.13823	0.08	0.125

표1에서와 같이 학습된 파라미터로 얻어진 얼굴과 배경 영상에 대한 멤버쉽 함수로 입력 영상의 각 픽셀에 대해서 얼굴과 배경에 대한 소속도를 구한다. 소속도의 값을 비교해서 II-5 분류과정으로 각 픽셀의 클래스를 분류한다.

그림8은 주어진 10개의 입력 영상에 대해서 얼굴과 배경을 분할해서 분류한 실험 결과이다.



그림 8. 얼굴영상 분할 실험 결과.

위의 실험 결과에서 보면 10개의 영상 중에 얼굴과 배경이 비교적 잘 분할된 영상은 8개이고, 다른 2개는 배경과 얼굴이 같은 소속도를 가져서 오분할된 경우도 보이고 있다. 이것은 입력영상에 대해서 픽셀의 값으로 소속도를 구해서 얼굴과 배경을 분할했기 때문이다.

## III. 결론

본 논문은 얼굴 영상과 배경 영상을 각각의 멤버쉽 함수로 많은 데이터로부터 학습시켜서 얻은 멤버쉽 함수로부터 각 픽셀의 얼굴 영상에 대한 소속도와 배경 영상에 대한 소속도를 구해서 영상을 분할하는 과정으로 얼굴과 배경으로 클래스를 구분하는 실험을 하였다.

보다 향상된 연구를 위해 템플릿 얼굴 영상 패턴에 대한 정의와 함께 퍼지 추정 시스템(fuzzy inference system)을 이용해서 템플릿 단위로 얼굴영상을 찾는 알고리즘을 현재 연구 중이다.

## IV. 참고문헌

- [1] M. Turk, A. Pentland, "Eigenfaces for recognition," *Journal of Cognitive Neuroscience*, vol. 3, no. 1, 1991.
- [2] F. Webber, A. Hernandez, "Face location by template matching with a quadratic discriminant function", *2nd ICAFGR*, 1999.
- [3] B. Jahne, H. HauBecker, and P. Geißler, *HANDBOOK OF COMPUTER VISION AND APPLICATIONS*, Fuzzy image understanding, Academic Press.
- [4] F. C-H. Rhee, R. Krishnapuram, "Fuzzy Rule Generation and Inference Methods for Pattern Recognition and Computer Vision," Ph.D. Thesis.
- [5] H. Rowley, S. Baluja, and T. Kanade, "Neural Network-Based Face Detection," *IEEE Trans. PAMI*, vol. 20, no.1, Jan. 1998
- [6] K. Sung, T. Poggio, "Example-based learning for view-based human face detection," *IEEE Trans. PAMI*, vol. 20, no. 1, Jan. 1998
- [7] S. Lawrence, C. Giles, A. Tsoi, and A. Back, "Face Recognition : A convolutional neural-network approach", *IEEE Trans. Neural Networks*, vol. 8, no. 1, Jan. 1997.
- [8] L. Hong and A. Jain, "Integrating faces and fingerprints for personal identification," *IEEE Trans. PAMI*, vol. 20, no. 2, Dec. 1998.