

# 데이터와 적용되는 알고리즘의 연관성을 이용한 클러스터링 기법

한 우 연<sup>†</sup> · 남 미 영<sup>††</sup> · 이 필 규<sup>†††</sup>

## 요 약

영상 처리와 패턴 인식 그리고 컴퓨터 비전 분야의 가장 성공적인 응용들 중 하나인 얼굴 인식을 위해 많은 알고리즘이 제안되었고, 최근에는 얼굴의 어떤 속성이 대상을 인식하는 것을 더 쉽거나 어렵게 만드는지에 대한 연구가 진행되고 있다. 본 논문에서는 얼굴의 속성(조명, 표정)에 따라 각각의 알고리즘의 인식 성능이 달라지는 점에 착안해서, 얼굴 데이터와 적용된 알고리즘과의 연관성을 이용하여 인식 성능을 높이는 클러스터링 방법을 제안하였다.

실험에서는 인식 알고리즘으로 n-tuple, PCA 그리고 가보 웨이블릿이 사용되었고, 세 가지 벡터화 방법이 제안되었다. 우선 학습 데이터를 k-means 알고리즘을 이용하여 클러스터링하고 각각의 클러스터에 대한 세 가지 인식 알고리즘의 적합도를 평가한 후, 같은 알고리즘을 선택한 클러스터들을 통합하여 새로운 클러스터를 구성한다. 그리고 테스트 데이터에서 새로운 클러스터에 대한 유사도를 평가하여 가장 가까운 클러스터가 선택한 알고리즘으로 인식을 수행한다. 그 결과 클러스터링 과정을 거치지 않고 단일 알고리즘을 사용하여 인식했을 때보다 인식 성능이 향상된 것을 관찰할 수 있다.

**키워드 :** 얼굴 인식, 패턴 인식, 컴퓨터 비전, 클러스터링

## Clustering Technique Using Relevance of Data and Applied Algorithms

Woo-Yeon Han<sup>†</sup> · Mi-Young Nam<sup>†</sup> · Phillip Kyu Rhee<sup>†††</sup>

## ABSTRACT

Many algorithms have been proposed for face recognition that is one of the most successful applications in image processing, pattern recognition and computer vision fields. Research for what kind of attribute of face that make harder or easier recognizing the target is going on recently. In this paper, we propose method to improve recognition performance using relevance of face data and applied algorithms, because recognition performance of each algorithm according to facial attribute(illumination and expression) is change.

In the experiment, we use n-tuple classifier, PCA and Gabor wavelet as recognition algorithm. And we propose three vectorization methods. First of all, we estimate the fitnesses of three recognition algorithms about each cluster after clustering the test data using k-means algorithm, then we compose new clusters by integrating clusters that select same algorithm. We estimate similarity about a new cluster of test data, and then we recognize the target using the nearest cluster. As a result, we can observe that the recognition performance has improved than the performance by a single algorithm without clustering.

**Key Words :** Face Recognition, Pattern Recognition, Computer Vision, Clustering

## 1. 서 론

패턴 인식과 컴퓨터 비전 등을 이용한 생체 인식 기술은 친화성, 편리성, 다양성 및 괘적성을 고려한 얼굴 로봇, 재활 공학 시스템, 가상현실, 수화 인식, 멀티미디어 시스템 및 게임 등 다양한 산업 분야에 응용 가능하다. 이러한 생체 인

식 기술 중 얼굴 인식 기술은 사용자에게 특별한 행위를 요구할 필요가 없으며, 또한 비접촉식으로 인식을 수행할 수 있어 편리하다는 장점이 있다. 현재까지 얼굴 인식 기술은 국내외의 관련 업체와 대학을 중심으로 활발한 연구가 수행되어 왔다[1, 2]. 얼굴 인식 기술의 발전을 위해서는 얼굴 인식 기술의 성능을 평가할 수 있는 얼굴 영상 데이터가 필요하다[3]. 얼굴 데이터들은 그들의 목적에 따라서 얼굴 인식 기술에 사용되거나 얼굴 표정 인식이나 포즈 추정 등에 이용된다. 따라서 얼굴 인식을 위해 구축된 얼굴 DB들은 각각 고유한 특성을 갖는다.

<sup>†</sup> 준회원: 인하대학교 컴퓨터·정보공학과 석사과정

<sup>††</sup> 비회원: 인하대학교 컴퓨터·정보공학과 박사과정

<sup>†††</sup> 종신회원: 인하대학교 컴퓨터·정보공학과 교수  
논문접수: 2005년 1월 15일, 심사완료: 2005년 8월 2일

많은 알고리즘이 얼굴 인식을 위해 제안되었고, 과학자들은 얼굴 인식 시스템에서 어떤 사람이 다른 어떤 사람보다 인식되기가 더 힘들다는 것을 알게 되었다. 최근 G. Givens은 얼굴의 어떤 속성이 대상을 인식하는 것을 더 쉽거나 어렵게 만드는지에 대한 연구를 진행했다. 그리고 그들은 어떤 속성들이 그들이 사용한 각각 다른 세 가지 알고리즘의 인식에 어려움을 만드는지에 대해 설명하였다. G. Givens에 의해 기술된 속성은 나이, 인종, 성별, 피부, 안경, 수염, 화장, 앞머리, 표정, 입, 눈 등이다. 이 속성들에 의해서 각 알고리즘의 인식 성능이 달라지는 것을 알 수 있다. 예를 들어 두 눈을 다 감았을 경우 두 개의 알고리즘의 성능에는 도움이 되고, 다른 하나의 알고리즘에서는 인식을 더욱 어렵게 만든다[4].

본 논문에서는 얼굴의 속성에 따라 각각의 알고리즘의 인식 성능이 달라지는 점에 착안해서, 다양한 얼굴 데이터를 클러스터링한 후 가장 효과적인 알고리즘을 선택적으로 사용하여 인식 성능을 높이는 방법을 제안하였다. 얼굴의 속성은 조명, 표정 등의 얼굴 인식 혹은 얼굴 검출에 있어서 문제가 되는 부분이다. 따라서 본 논문에서는 얼굴 데이터를 클러스터링하기 위하여, 얼굴의 벡터화 방법을 얼굴의 조명 상황을 반영할 수 있으며, 또한 얼굴의 표정 변화를 반영할 수 있도록 벡터화 한다.

본 논문에서 제안된 얼굴 인식은 두 단계로 나뉘는데, 첫 번째는 다양한 데이터를 통합하여 사용되는 알고리즘에 최적화되며 클러스터링하는 단계이고, 두 번째는 입력받은 영상을 유사한 클러스터로 분류하여 그에 적합한 알고리즘을 선택하여 인식하는 단계이다.

본 논문의 구성은 다음과 같다. 2장에서는 인식에 사용되는 세 가지 분류기들에 대하여 설명하고, 3장에서는 얼굴의 다양한 속성을 반영하기 위한 데이터 사용과 데이터 속성과 알고리즘과의 연관성을 이용한 클러스터링 방법에 대해서 설명하였다. 4장에서는 다양한 데이터의 클러스터링과 얼굴 인식에 대한 실험을 기술하며, 5장에서는 결론 및 향후 연구 방향에 대해 기술한다.

## 2. 인식에 사용되는 분류기

얼굴 인식 과정은 크게 얼굴 영역 추출, 특징 추출 및 매칭을 통한 인식 과정으로 구분할 수 있다. 얼굴 데이터들마다 영상의 크기와 범위가 다르기 때문에, 학습을 위해서는 같은 크기 같은 영역의 영상을 추출해낼 필요가 있다. 얼굴 영역을 학습 데이터로 정하는데 있어서 얼굴 영역 추출은 매우 중요한 요소이다. 이에 대해 Henry A. Rowley는 두 눈과 입의 중심점을 기준으로 하여 표준이 되는 평균 좌표를 만든 후 기준 영상을 이에 맞추어 변형하는 방법을 사용하였다[5]. 본 논문에서도 같은 방법을 사용하여 얼굴 영역을 추출하는데, 두 눈의 좌표는 미리 주어져야 한다.

본 논문에서 인식 및 성능 평가에 사용되는 분류기들은 세 개가 있다. 첫 번째가 수정된 n-tuple 분류기[6]이고 두

번째가 주성분 분석[7] 그리고 세 번째가 가보 웨이블릿 변환[8]이다. 세 개의 알고리즘은 모두 외형기반의 인식을 하며 특징점 정보를 필요로 하지 않는다.

### 2.1 N-tuple 분류기

S.M Lucas가 제안한 얼굴 인식을 위한 연속 n-tuple 분류기는 tuple의 무작위적 추출을 기본으로 하여 만들어졌다. 이 알고리즘은 무작위적 추출로 인하여 간단한 개념과 빠른 속도, 비교적 효율적인 성능 등의 장점을 갖는다. 반면에 인식률이 무작위적으로 추출된 n-tuple에 의해 결정되므로 인식 성능에 대한 신뢰도가 떨어지며, 명도값 매칭 알고리즘의 한계로 인해 학습 데이터의 추출 방법에 따라 인식률이 달라질 수 있다. 본 논문에서는 보다 얼굴 인식에 적합한 신뢰할 수 있는 n-tuple을 추출하여 얼굴 인식 성능을 향상시킬 수 있도록 하기 위하여 클러스터에 적합한 전처리 방법을 적용하기 위하여, 유전자 알고리즘[9, 10]을 이용한다. n-tuple 분류기는 이미지의 픽셀값을 그대로 사용하기 때문에, 조명의 속성에 따라 얼굴 인식 성능이 달라질 수 있기 때문에 전처리 방법이 중요하게 작용된다. 따라서 n-tuple에서의 인식률을 적합성 함수로 설정하여, 각 클러스터에 적합한 전처리 방법을 적용한다. 이때 적용하는 전처리 방법은 히스토그램 평활화, 주파수 영역에서의 필터링 방법, 콘트라스트 스트래칭 기법, 호모몰픽 기법을 이용하여 유전자 알고리즘에 의하여, 적절한 전처리 알고리즘을 적용하도록 한다.

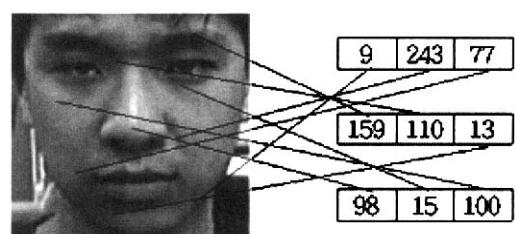
전통적인 n-tuple 분류기[11]는 입력 벡터로 이진 값을 받는다. 이것을 입력이 연속적 이거나 여러 단계인 입력에 적당하도록 새롭게 제안한 연속적인 n-tuple 분류기는 속도와 단순성에 장점을 갖고 있다.

(그림 1)은 d 차원의 입력 공간이 m개의 n-tuple로 샘플링 되는 것을 보여준다. 각 n-tuple은 입력 공간에서 고정된 위치의 집합을 정의한다. j 번째 n-tuple의 위치 집합은 식 (1)과 같다.

$$n_j = \{a_{j1}, a_{j2}, \dots, a_{jn} \mid 1 \leq a_{ji} \leq d\} \quad (1)$$

학습 과정에서는, 입력 벡터  $x = x(1) \dots x(d)$ 에 대하여 다음과 같은 투영을 수행하고 저장한다.

$$y_j = x(a_{j1}) \dots x(a_{jn}) \quad (2)$$



(그림 1) n-tuple 추출 방식 ( $n=3, m=3$ )

인식 과정에서는, 각 클래스마다  $j$  번째 투영된 벡터에 대해, 각 클래스마다 가장 가까운 저장된 벡터를 찾아서 거리를 더하여 인식 점수를 구한다.

$$r_c = \sum_{j=1}^m \min_k D(\mathbf{y}_{jk}^c, \mathbf{z}_j) \quad (3)$$

$$D(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n |x_i - y_i| \quad (4)$$

그리고 테스트 영상은  $r_c$  값이 가장 작은 클래스에 할당되게 된다.

유전 알고리즘을 적용하기 위해서 필수적으로 선행되어야 할 두 가지 절차는 다음과 같다.

- 크로모좀 설계
- 적합도 평가 함수 설계

본 논문에서는 크로모좀으로 미리 무작위적으로 추출된  $n$ -tuple의 사용 여부를 결정하는 이진 염색체를 사용하였다. 그리고 얼굴 인식에 효과적인  $n$ -tuple을 추출하기 위해서 인식률과 사용하는  $n$ -tuple 개수를 이용하는 적합도 평가 함수를 만들어 사용하였다. 인식률 평가에서 테스트 영상에 할당된  $r_c$  값이 가장 작은 클래스가 테스트 영상 본래의 클래스와 같다면 인식률은 증가한다. 사용하는  $n$ -tuple의 개수가 적을수록, 인식률이 높을수록 적합도 함수는 큰 값을 갖게 된다.

적합도 함수의 식은 다음과 같다.

$$\text{Fitness} = \frac{\text{NumofResult}}{\text{NumofTestImage}} + \frac{1 - \text{Count}^2}{\text{ChromosomeLength}^2} \quad (5)$$

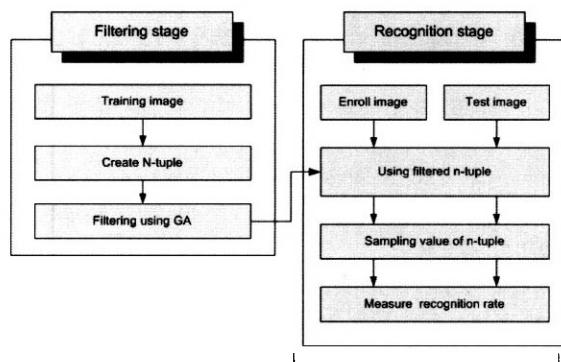
$\text{NumofResult}$  : 테스트 영상 중 인식된 영상의 개수

$\text{NumofTestImage}$  : 테스트 영상의 총 개수

$\text{Count}$  : 사용되는 tuple의 개수

$\text{ChromosomeLength}$  : 총 tuple의 개수

(그림 3)은  $n$ -tuple의 필터링을 적용한 인식기의 구조를 보여준다. 필터링 단계에서 유전 알고리즘을 이용하여 인식



(그림 3)  $n$ -tuple 필터링을 이용한 인식기

에 효과적인  $n$ -tuple을 추출한 후, 인식 단계에서는 추출된  $n$ -tuple을 이용하여 인식을 수행한다.

## 2.2 주성분 분석(Principal Component Analysis)

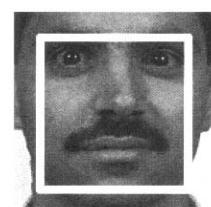
주성분 분석은 고차원 데이터로부터 데이터의 구조를 밝히거나, 데이터의 차원을 낮추는데 많이 이용되는 다변량 통계 분석 방법이다. 이는 상관 행렬의 고유벡터를 찾아내어 주어진 데이터를 분산이 최대가 되는 축으로 변환하는 것으로, 이 새로운 차원에서 데이터의 벡터들을 주성분이라고 한다. S. Romdhani는 주성분 분석 기법을 사용한 얼굴 인식 방법을 제안하였는데, PCA를 통하여 주성분을 분석하고 고유 벡터를 추출하여 이를 이용하여 고유 얼굴을 생성한다[13]. 고유 얼굴은 데이터베이스 내에 저장된 얼굴 데이터들을 고유 공간 좌표계로 이동시킨 후 고유 얼굴을 이용하여 해당하는 사람을 인증하도록 한다. 얼굴만을 위한 공간을 고유 공간(eigen space)이라 하며 그 공간을 구성하는 좌표계에 해당하는 벡터들을 고유 얼굴(eigen face)이라 한다. 이 고유 얼굴은 학습영상들의 공분산 행렬에 대해서 선형대수학에서의 고유 값, 고유 벡터 문제를 풀어서 계산된다. 그리고 인식 단계에서 새로 들어온 영상들 역시 얼굴만의 고유 공간상의 좌표계로 변환하여 그 둘 사이의 떨어진 거리를 측정함으로써 등록된 얼굴과의 일치 여부를 결정하게 된다.

본 논문에서는 입력 영상을  $64 \times 64$ 로 리사이징(resizing)을 한 후,  $44 \times 44$  크기로 가운데 영역만 선택하여 벡터화 한다.  $64 \times 64$  크기로 줄이는 이유는, 벡터의 크기를 줄이기 위함이다. PCA를 생성하기 위해서는 공분산 행렬을 만들어야 하는데 공분산행렬의 크기는 ( $\text{벡터크기} \times \text{벡터크기}$ )이다. 즉 리사이징을 하지 않으면  $128^4$ 이라는 매우 큰 크기의 공분산행렬이 생성될 것이고, 계산하는 비용 또한 매우 커지게 된다.

(그림 4)는 전체가  $64 \times 64$  크기의 이미지다. 가운데 하얀 상자 안의 부분은  $44 \times 44$  크기의 영역이다. 이처럼 가운데의 영역만을 선택해서 벡터화 하였다. 그 이유는 벡터의 차원 감소 및 바깥영역의 노이즈 제거이다.

벡터의 유사도를 측정하기 위해서 코사인 거리 측정법을 사용한다. 위의 벡터화 방법으로 벡터화된 얼굴 영상의 특징을 나타내는 벡터들의 집합을  $V$ 라고 할 때, 비교하기 위한 두 개의 영상에 대해 벡터 집합  $V_1$ 과  $V_2$ 가 존재한다. 이 때 식을 이용하여 두 영상간의 유사도를 측정할 수 있다.

$$\text{유사도} = \frac{V_1 \cdot V_2}{\sqrt{|V_1||V_2|}} \quad (9)$$



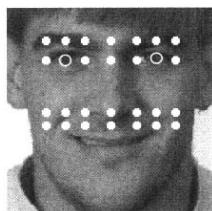
(그림 4)  $44 \times 44$  벡터화

### 2.3 가보 웨이블릿(Gabor wavelet)

가보 웨이블릿은 생물학적인 연관성과 계산적인 특성에 의해 영상 분석 분야에 도입되었다[14]. 가보 웨이블릿의 커널은 2-D 시각 피질 내 세포의 수용계와 유사하며, 공간적 지역성과 방향의 분리성 등의 바람직한 특성을 가진다. 또한 공간과 주파수 도메인에서 최적의 지역적 형태로 분포된다.

가보 필터는 이미지로부터 추출된 지역 주파수 정보를 제공하는 것이고, 웨이블릿 변환은 해상도에 따라 크기가 변화하는 특징에 따라 신호 또는 이미지의 스케일 정보를 분리 추출하여 그 특성을 분석하는데 이용하는 방법이다. 전체 이미지에 총체적인 주파수 영역의 표현을 결정하는 퓨리에 분석과는 다르게, 가보 필터는 이미지의 각 영역에서 주파수 범위와 방향의 강도를 예측하고, 공간 도메인에서의 결과를 제공 한다. 퓨리에 변환 및 국소 퓨리에 변환과는 달리 한번의 연산으로 신호가 아닌 모든 스케일 성분을 하나의 공간에 표현함으로써 다 해상도 분석에 강점을 지니고 있다.

본 논문에서는 대부분의 일반적인 경우와 같이 5개의 다른 크기(scale)와, 8개의 방향(orientation)의  $32 \times 32$  사이즈의 가보 웨이블릿을 이용한다[15, 16]. 영상 특징 추출을 위한 특징점은 사전 정보 없이, 정규화된 영상에서 같은 위치에 두 눈이 위치한다는 사실만을 이용하여 28개의 특징점을 추출하였다. 추출된 특징점의 정보는 (그림 5)와 같다.



(그림 5) 28개의 특징점 정보 추출

(그림 5)에서 빨간색 점은 고정된 두개의 눈 좌표이고, 하얀색 점은 확장된 스물여섯 개의 특징 좌표이다.

## 3. 데이터와 알고리즘의 연관성을 이용한 클러스터링

본 논문에서는 얼굴 속성에 따라 각 알고리즘의 성능이 달라진다는 기존의 연구에 따라, 얼굴 속성을 구분하여 그에 적합한 알고리즘을 적용하는 방법을 제안하고자 한다. 앞선 연구에서 기술된 얼굴의 속성은 나이, 인종, 성별, 피부, 안경, 수염, 화장, 앞머리, 표정, 입, 눈 등이었는데, 각각의 속성을 정확하게 구분하기 위한 자동적인 분류 방법이 존재하지 않는다. 이에 본 논문에서는 클러스터링을 이용하여 몇몇의 속성에 대한 분류를 시도하였다. 얼굴의 다양한 속성을 반영하기 위해 여러 개의 DB를 통합하여 사용하였고, 클러스터링을 위해 몇몇 속성에 특화된 벡터화 방법을 이용하였다. 얼굴 영상에 대한 기본적인 전처리로써 히스토그램 평활화를 이용하였다.

### 3.1 다양한 얼굴 데이터

얼굴 인식을 위한 대표적인 데이터 집합으로는 FERET DB, XM2VTS DB, Yale DB, AR face DB, MIT face DB 그리고 ORL DB가 있다.

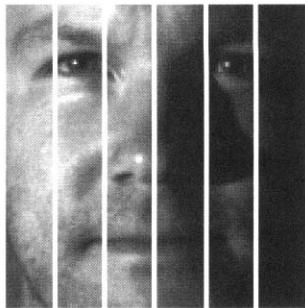
위의 데이터 집합을 포함하는 얼굴 데이터 집합에는 두 가지 단점이 있다. 첫 번째는 오직 제한된 숫자의 아시아 사람을 포함한다는 것이다. 그리고 두 번째 단점은 체계적이고 다양한 변화가 없다는 점이다. 체계적인 변화를 가지는 몇몇의 데이터 집합조차도 변화 정도의 범위가 제한되어 있다.

본 논문에서는 오프라인 환경에서의 얼굴 인식을 위해 FERET DB와 Yale DB를 이용하였다. 그리고 얼굴 데이터 집합이 가지는 첫 번째 단점인 아시아 사람의 얼굴 영상 수 제한을 해결하기 위하여 IT 연구실에서 수집한 얼굴 데이터 베이스를 추가하였다. 실험에 사용한 IT 연구실 얼굴 이미지 데이터는 인하대 전산과 지능미디어 연구실에서 전자통신연구소로부터의 과제 수행으로 수집한 데이터 중  $128 \times 128$  크기의 회색조 데이터이다. 동일 조명 상태에서 100명에 대해 각각 10장씩의 영상으로 이루어져 있다. 두 번째 단점을 극복하기 위해 몇몇의 DB를 통합하여 사용하는 방법을 제안하였다. DB마다 존재하는 변화의 폭이 다르므로 여러 개의 DB를 통합함으로써 더 다양한 변화 정도를 이용하여 얼굴 인식 기술의 성능을 평가할 수 있도록 하였다.

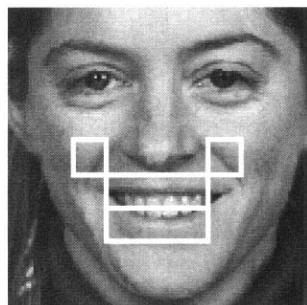
### 3.2 벡터화

대개의 클러스터링 알고리즘들은 고차원 공간을 갖는 데이터에서는 제대로 작동을 하지 못하고 있다. 데이터 자체의 고유한 회박성이 원인이 되어 클러스터링의 결과가 좋지 않기 때문이다. 고차원 데이터를 갖는 응용 분야에서, 데이터 중에서 어느 두 객체는 몇 개의 차원에서만 값이 밀접하게 존재하고 나머지 차원에서는 아주 멀리 떨어져 있을 가능성이 많다. 그래서 어떤 클러스터링 알고리즘은 특징 추출을 먼저 시행하여 그 차원을 줄이는 방법을 사용하기도 한다[17, 18]. 그 과정은 데이터 상의 객체들이 관련되어 있는 특정 차원만을 선택하고, 나머지 차원들은 데이터에서 잡음으로 간주하여 삭제하는 것이다. 그러나 이런 경우, 특정 차원을 미리 추출하여 사용하게 됨으로써 정보의 손실을 가져올 수 있다. 실제로 많은 응용 예에서 어떤 데이터 집합은 한 차원 집합에 관련되고, 다른 데이터 집합에서는 다른 차원 집합에 관련이 있을 수 있기 때문에, 일률적으로 특정 차원을 삭제하는 경우에는 정보 손실로 인하여 클러스터링이 제대로 되지 못하게 된다. 때문에 고차원의 얼굴 영상을 클러스터링 하기 위해서는 영상의 벡터화 작업이 선행되어야 한다. 그리고 잡음을 제거하는 동시에 정보 손실을 최소화하려면 클러스터링 목적과 데이터 특성에 맞는 벡터화 방법이 필요하다.

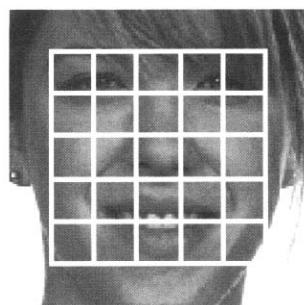
본 논문에서는 사용되는 얼굴 데이터에서 가장 큰 변화를 보이는 조명, 표정 등을 제어하기 위해서 세 종류의 벡터화 방법을 사용하였다.

(그림 6)  $6 \times 1$  벡터화

그 중 첫 번째는 얼굴 인식에 영향을 미치는 환경 중에서 대표적인 조명의 영향을 반영하기 위한 세로 방향의 벡터화 방법이다. 대부분의 영상이 좌측, 우측, 정면의 조명으로 구분될 수 있고, 특히 Yale DB는 각 각도별 조명을 모델링 하여 조명의 영향을 매우 많이 받는 데이터이다. 영상을 (그림 6)과 같이 세로 방향으로 벡터화를 함으로써 좌, 우 조명의 영향을 나타낼 수 있다.

(그림 7)  $5 \times 1$  벡터화

두 번째는 표정의 영향을 반영하기 위한 벡터화 방법이다. 얼굴 데이터의 표정은 인식에 매우 큰 영향을 미칠 수 있다. 특히 Feret DB에서 다양한 표정의 변화가 나타난다. 표정을 나타내는 요소는 매우 다양한데, 본 논문에서는 표정 변화에 가장 민감한 입 주위를 벡터화하여 반영하였다. (그림 7)에서 보여 지는 입 위쪽 두개의 작은 정사각형은 웃을 때 나타나는 표정 주름을 벡터화한 것이다.

(그림 8)  $5 \times 5$  벡터화

세 번째는 (그림 8)과 같이 얼굴 바깥 영역의 잡음을 없애고 전체적인 얼굴의 표현을 위한 벡터화 방법이다. 얼굴

영상에서 가장자리 부분은 배경이나 머리카락 등의 영향을 받기 쉬우므로 그 부분을 제거하고 좀 더 고유한 특징을 나타내는 얼굴 중심 부분만 선택적으로 사용하였다.

### 3.3 클러스터링

클러스터링이란 주어진 데이터 집합을 서로 유사성을 가지는 몇 개의 클러스터로 분할해 내가는 과정으로, 하나의 클러스터에 속하는 데이터 점들 간에는 서로 다른 클러스터 내의 점들과는 구분되는 유사성을 갖게 된다. 클러스터링 방법은 기존의 통계학, 기계 학습, 데이터마이닝 그리고 패턴 인식에서 주로 쓰인다. 클러스터링은 크게 통계적 방법과 인공 지능적 방법으로 나뉘며, 통계적 클러스터링 방법에는 계층적 클러스터링과 분할적 클러스터링이 사용된다.

본 논문에서는 간단하고 차원의 제약이 없는 k-means 클러스터링 방법을 이용하여 얼굴 속성의 분류를 시행하였다. k-means 알고리즘은 MacQueen에 의하여 제안된 분할적 클러스터링 알고리즘으로써, 우선 패턴을 k 개의 클러스터로 나눈 후 클러스터에 포함되어 있는 패턴들의 평균으로 클러스터의 중심값을 계산하고 이 중심값과 각 패턴과의 거리를 계산한 후 가장 거리가 가까운 클러스터에 패턴을 포함시키는 방법으로 그 조건은 다음과 같다[19, 20].

$$x_i \in c_j \quad \|x_i - z_j\|^2 < \|x_i - z_k\|^2 \quad (12)$$

여기서,

$$1 \leq i \leq N, 1 \leq k \leq c, j \neq k$$

N = 패턴수

c = 클러스터 수

z = 클러스터 중심값

그리고 이 계산은 각 클러스터의 중심값이 더 이상 변하지 않을 때까지 반복한다. 초기 k개의 클러스터의 중심값을 주는 방법에는 주어진 패턴에서 처음 k개의 패턴을 추출하여 중심값으로 하는 방법과 임의로 k개를 추출하여 중심값으로 하는 방법이 있는데, 본 논문에서는 임의로 k개를 추출하여 클러스터의 초기 중심값으로 하였다. 본 논문에서는 k를 9로 설정하여, 초기 클러스터를 생성한다. 이는 Yale 얼굴 데이터베이스에서의 9단계의 기본적인 조명 속성을 바탕으로 하며, 인식 성능에 따라 선택된 인식기가 동일한 클러스터를 통합한다.

본 논문에서는 k-means 클러스터링 알고리즘을 이용하여 데이터를 매우 세분화한 후, 그것을 다시 통합해 나가는 방법을 사용하였다. 작게 분류된 클러스터들을 통합하는 기준은 그 클러스터에 속한 데이터와 거기에 적용될 알고리즘과의 상관관계이다. 작게 분류된 클러스터들은 학습 데이터를 이용해서 각 알고리즘에 대한 적합도 평가를 거친 후, 더 큰 클러스터로 통합되게 된다. 하나의 클러스터에 대한 각 알고리즘의 적합도를 평가하기 위해, 학습 데이터를 이

용하여 본 논문에서 사용한 세 개의 알고리즘에 대한 인식률을 평가하고 인식률이 가장 높은 것을 그 클러스터에 가장 적합한 알고리즘이라고 정의한다. 모든 클러스터에 대해서 같은 방식으로 적합한 알고리즘을 선택한 후, 다시 알고리즘을 중심으로 클러스터를 통합하는 것이다. 그 결과 우리는 사용되는 여러 알고리즘에 최적화되어 있는 클러스터들을 얻을 수 있다.

따라서 본 논문에서는 초기에  $k$ 값을 9로 설정하여 얼굴데이터를 분류하였으며, 이것은 Yale 데이터베이스에서의 조명 분류 개수를 참조하여 수행하였다. 이러한 클러스터의 수를 구성함으로써 성능이 우수한 인식기를 구성하도록 하였다.

#### 3.4 인식 시스템의 구조

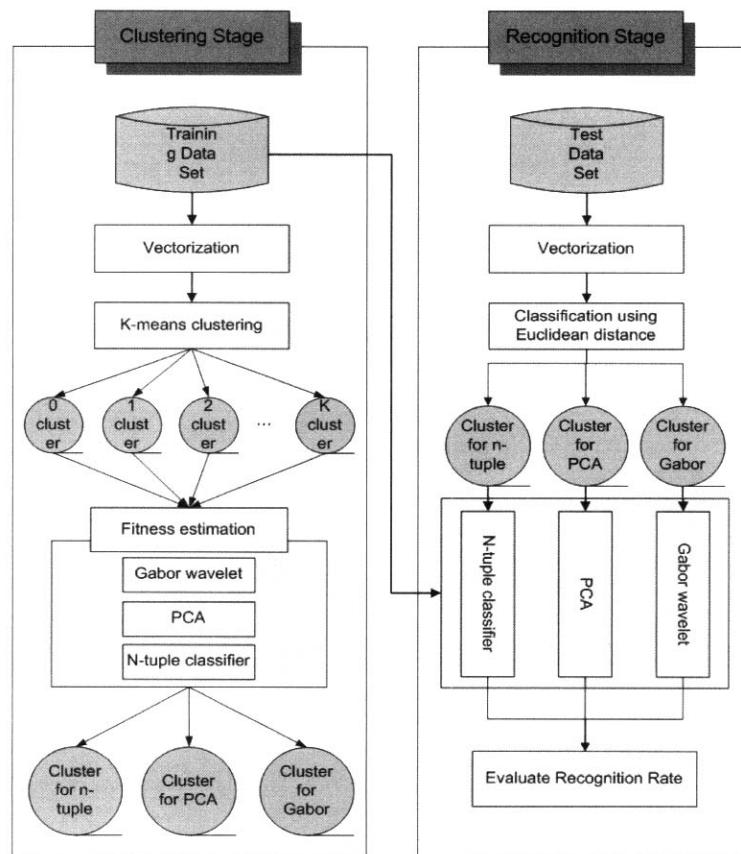
전체 시스템은 (그림 10)에서 보여지는 것처럼 크게 클러스터링 단계와 인식 단계로 구분된다. 클러스터링 단계에서 사용되는 알고리즘에 최적화되어 있는 클러스터를 구성하고, 인식 단계에서는 그 클러스터를 이용하여 테스트 데이터에 적합한 알고리즘을 선택함으로써 효과적인 인식을 수행한다.

클러스터링 단계에서는 우선 데이터를 3.2절에서의 벡터화 방법을 이용하여  $6 \times 6$  크기로 벡터화한다. 그리고 벡터화된 데이터를 k-means 알고리즘을 이용하여 적당히 큰  $k$ 개의 클러스터로 클러스터링 한다. 그리고 3.3절에서처럼 각각

세 개의 알고리즘에 대한 적합도를 판단하여, 알고리즘에 대한 적합도 우선순위를 기준으로 클러스터를 통합한다. 인식 단계에서는 입력 영상을 클러스터링 단계에서 통합된 클러스터로 분류하여 그에 적합한 알고리즘을 적용하여 인식을 수행한다. 입력된 테스트 데이터에 대해 각 클러스터의 평균 벡터와의 거리를 판단하여 가장 가까운 클러스터로 분류해준다. 본 논문에서는 분류를 위해 유clidean 거리 측정법을 이용한다. 클러스터링 단계에서 알고리즘에 대한 적합도를 판단할 때와 인식 단계에서 분류된 클러스터에 적합한 분류기를 선택하여 적용할 때에는 수정된 n-tuple 분류기와 PCA 그리고 가보 웨이블릿이 사용된다.

#### 4. 실험 결과

본 장에서는 앞서 제안된 클러스터링 기법과 그에 적합한 알고리즘을 이용한 인식에 대한 실험을 수행하였다. 다양한 얼굴 데이터의 집합에서 각 알고리즘에 적합한 클러스터를 찾기 위해, k-mean 클러스터링 알고리즘을 이용하여 얼굴 데이터들을 작은 클러스터들로 나누었다. 그리고 나누어진 작은 클러스터 각각에 대해 n-tuple, PCA, 가보 웨이블릿에 대한 성능이 가장 뛰어난 인식기를 기준으로 하여 클러스터를 통합하였다. 그리고 통합된 클러스터에 대해 가장 효율적인 알고리즘을 적용하여 인식을 수행하였다. 본 논문에서



(그림 10) 인식 시스템 구조

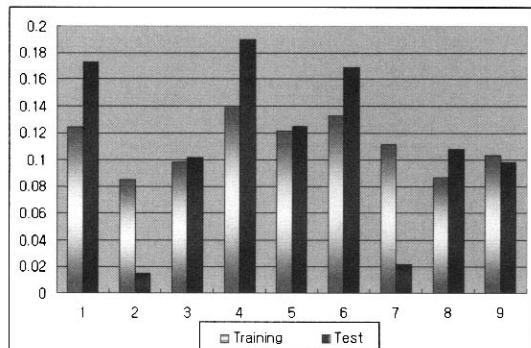
제안된 방법의 타당성을 입증하기 위하여 클러스터링 과정을 거치지 않고 하나의 알고리즘만을 사용한 것과 비교 분석하였다.

본 실험에서는 데이터 집합의 변화 폭을 넓히기 위해 세 가지 DB를 통합하여 사용하였다. 사용된 데이터는 IT 연구실에서 수집한 동일 조명상태의 100명에 대한 정면 얼굴 데이터 1000개와, Yale DB의 10명 얼굴 데이터 중 좌, 우측 편향 조명과 역광을 받은 데이터를 포함한 조명 데이터와 포즈 데이터를 합하여 총 970장, 그리고 FERET에서 제공하는 1209명에 대한 이미지 2418장이 사용되었다. 그리고 모든 데이터들은 얼굴 부분에 대해서  $128 \times 128$  이미지로 재추출하여 사용하였다.

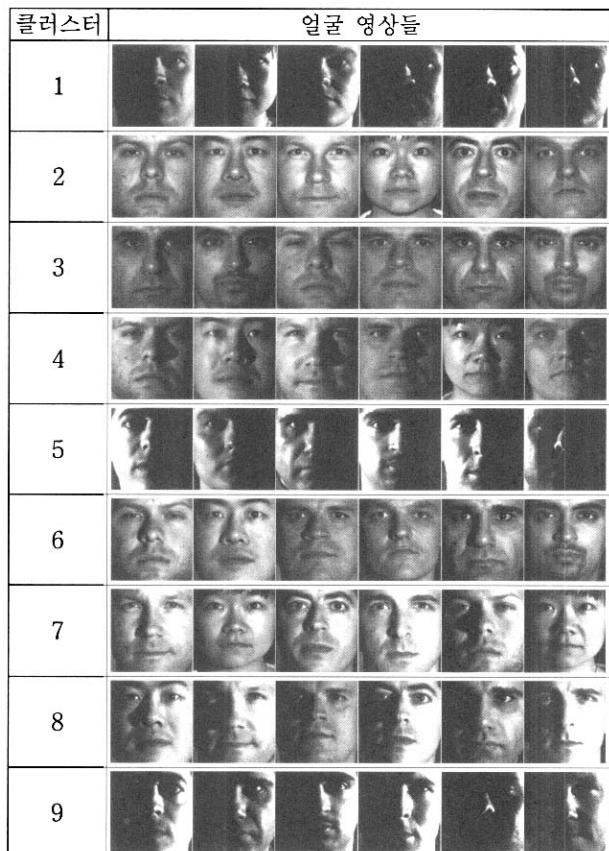
#### 4.1 다양한 데이터의 클러스터링 실험

클러스터링 실험은 IT 연구실 DB 100명, FERET DB 1209명, Yale DB 10명에 대해서 분류된 학습 데이터를 이용해 진행되었다. 각 영상에 대해 앞서 말한 세 가지 방법의 벡터화를 수행하여  $6 \times 6$  크기의 벡터를 만든 후, k-means 클러스터링의 입력으로 사용하였다.

클러스터링의 신뢰성을 입증하기 위해서 학습 데이터를 9개로 클러스터링한 것에 유사도 측정을 통해 테스트 데이터를 분류하였다. 세로축은 전체 데이터 개수 분에 클러스터



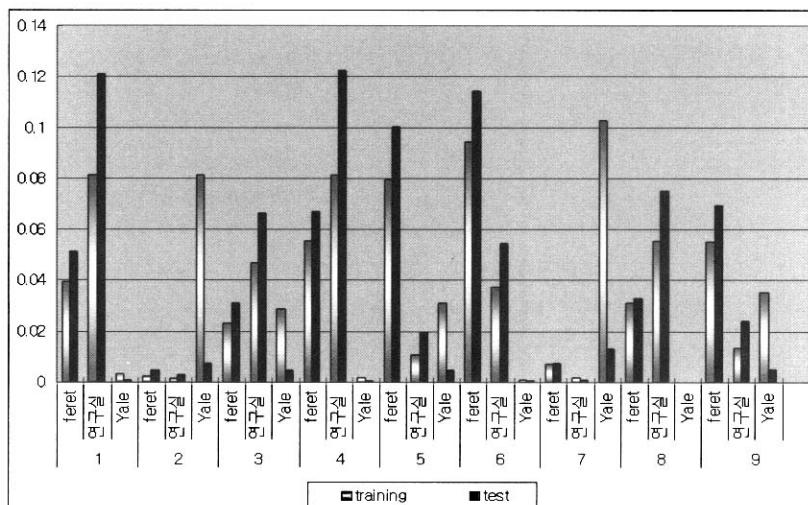
(그림 11) 다양한 데이터들을 9개로 클러스터링한 결과



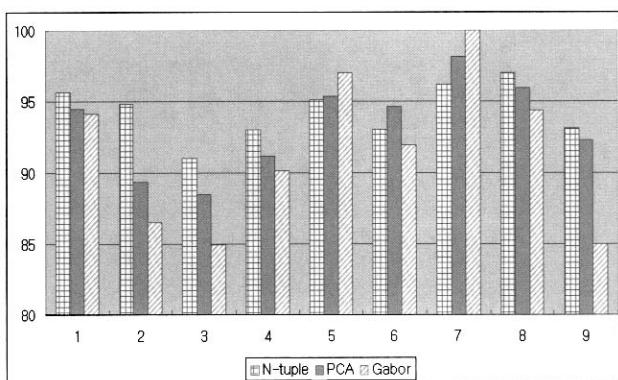
(그림 12) Yale DB 테스트 데이터를 9개로 클러스터링한 얼굴 데이터의 예

에 속하는 데이터의 개수를 나타낸 것이다. 그 결과 대체로 (그림 11)와 같이 학습 데이터가 많은 클러스터에 테스트 데이터 역시 많이 분류되는 것을 볼 수 있다. 하지만 그림에서 클러스터 2와 7에서 학습 데이터가 테스트 데이터보다 눈에 띄게 많은 것을 볼 수 있다.

이것을 분석하기 위해서 각 클러스터를 분류된 데이터의 종류에 따라 세분화 하였다. (그림 12)에서 클러스터 2와 7



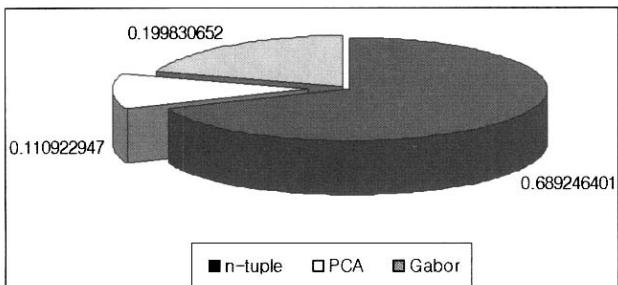
(그림 13) 3개의 DB를 9개로 클러스터링한 결과



(그림 14) 각 클러스터의 세 가지 알고리즘에 대한 인식률

&lt;표 1&gt; 알고리즘 적합도를 기준으로 통합된 클러스터

| 선택된 알고리즘 | 클러스터 번호          |
|----------|------------------|
| n-tuple  | 1, 2, 3, 4, 8, 9 |
| PCA      | 6                |
| 가보 웨이블릿  | 5, 7             |



(그림 15) 알고리즘을 기준으로 통합된 세 개의 클러스터

을 보면 Yale 데이터가 가장 큰 비율을 차지하고 있는 것을 볼 수 있는데, 이것은 학습 데이터에 비해 테스트 데이터에서 Yale DB가 차지하는 비율이 작기 때문인 것으로 해석된다. Yale DB에서 두 그래프의 차이가 많이 나는 것은 Yale DB의 학습 데이터와 테스트 데이터의 개수 차이 때문이다.

각 클러스터에 대해 가장 효율적인 알고리즘을 선택하기 위하여 클러스터마다 n-tuple, PCA 그리고 가보 웨이블릿에 대한 인식률을 구한다. 그리고 선택된 알고리즘을 기준으로 클러스터를 통합한다.

(그림 14)에서의 결과가 <표 1>을 통해서 정리되었다. <표 1>에서처럼 가장 효율적인 알고리즘 별로 클러스터들을 통합하여 보다 알고리즘에 적응적인 클러스터를 생성하였다. 그 결과 각각 n-tuple, PCA 그리고 가보 웨이블릿 알고리즘에 적합한 클러스터 세 개가 만들어진다.

(그림 15)는 각 알고리즘을 기준으로 통합된 세 개의 클러스터의 크기를 보여주고 있다. n-tuple이 약 70%, 가보 웨이블릿이 약 20%, PCA가 약 10%의 데이터에서 가장 효율적으로 동작하는 것을 알 수 있다.

#### 4.2 인식률에 대한 실험

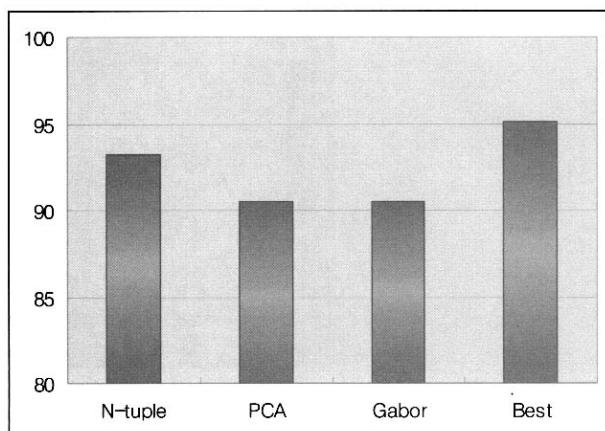
인식 실험은 IT 연구실 DB에서 100명, FERET DB에서 1209명, Yale DB에서 10명에 대해 분류된, 클러스터 실험에서 사용되지 않은 2542개의 테스트 데이터를 이용해 진행되었다. 각 영상에 대해 벡터화를 수행하여  $6 \times 6$  크기의 벡터를 만든 후, 분류된 클러스터링에 대한 유사도 측정을 위해 사용하였다.

앞서 진행된 실험에서 만들어진 각 알고리즘에 적합한 클러스터에 대해 테스트 데이터를 이용하여 실험을 하였다. 테스트 영상은 가장 가까운 클러스터로 분류되었고, 그 클러스터에 적합한 알고리즘을 적용하여 실험한 결과가 <표 2>에 있다. 표에서는 n-tuple을 위한 클러스터로 분류된 데이터는 개수는 많지만 인식률이 낮은 반면, PCA와 가보 웨이블릿을 위한 클러스터로 분류된 데이터는 인식률은 높지만 개수가 적은 것을 볼 수 있다. 이것은 n-tuple에 비해 PCA나 가보 웨이블릿이 특정 데이터 집합에 특화되어 있음을 보여준다.

인식 단계에서는 본 논문에서 제안한 방법의 효용성을 보이기 위해, 클러스터링 과정과 효과적인 알고리즘 선택 과정을 거치지 않고 단일 알고리즘을 사용한 방법과 비교하였다. 실험 결과 (그림 15)에서 보이는 것처럼 본 논문에서 제안한 방법이 95.12%로 가장 우수한 성능을 나타냈고, 그 다음이 n-tuple과 PCA 그리고 가보 웨이블릿 순이었다.

&lt;표 2&gt; 각 알고리즘에 적합하게 정의된 클러스터에 대한 인식률 테스트 결과

|         | 영상수  | 성공수  | 인식률    |
|---------|------|------|--------|
| n-tuple | 1856 | 1752 | 94.40% |
| PCA     | 254  | 247  | 97.24% |
| Gabor   | 432  | 419  | 96.99% |
| 합계      | 2542 | 2418 | 95.12% |



(그림 15) 단일 알고리즘을 이용한 인식 성능과 논문에서 제안된 방법에 의한 인식 성능 비교

## 5. 결론 및 향후 연구

본 논문에서는 다양한 데이터의 클러스터링을 이용해서 인식에 효과적인 알고리즘을 선택하는 방법을 제안하였다. 실험에 사용된 알고리즘은 n-tuple, PCA 그리고 가보 웨이블릿으로 총 세 종류이다. 데이터의 효과적인 클러스터링을 위해서 k-means 알고리즘을 이용하여 클러스터링한 후 알고리즘에 대한 적합도를 판단하여 클러스터를 통합하였다. 또 보다 다양한 변화 정도를 이용하여 얼굴 인식 기술의 성능을 평가하기 위해 3개의 DB를 통합하여 사용하였다. 사용된 DB는 FERET DB, 연구실 DB 그리고 Yale DB이다.

실험 결과로는 데이터를 클러스터링하지 않고 단일 알고리즘을 적용하는 것과 본 논문에서 제안한 방법을 사용하는 것을 비교할 수 있는데, 효과적인 알고리즘을 선택적으로 사용하여 성능이 향상되었음을 볼 수 있다. 이것은 일반적으로 얼굴인식 과정에서 평균 인식률이 최고인 알고리즘만을 사용하는 것보다, 초기에 입력 데이터들을 분류하고, 분류된 소규모의 집단에 각각 최적화 되어있는 인식 알고리즘 사용하는 것이 효과적임을 보인다.

향후 연구 방향으로 생각할 수 있는 것들은 다음과 같다. 클러스터링 단계에서 다양한 데이터를 클러스터링할 때, 인식에 영향을 주는 속성을 더 세분화하여 그 특징을 벡터화하고, 계층적 클러스터링을 구성함으로써 클러스터의 신뢰도를 높일 수 있을 것이다. 그리고 인식 단계에서 얼굴 데이터의 특정 속성에 매우 적합한 알고리즘들로 인식기를 구성할 수 있다. 전반적으로 높은 성능을 보이는 알고리즘이 아닌 특정 속성의 데이터에 특화되어있는 알고리즘들로 시스템을 구성한다면, 각 알고리즘의 장점만을 모아 인식 성능을 뛰어나게 향상시킬 수 있을 것이다.

## 참 고 문 헌

- [1] R. Chellappa et. al., "Human and Machine Recognition of Faces: a Survey," Proceedings of the IEEE, Vol.83, No.5, pp.705-740, 1995.
- [2] 송근원, "얼굴 인식 기술 및 동향," 한국멀티미디어학회지, Vol.7, No.2, Jun., 2003.
- [3] Intelligent Multimedia Lab., "Asian Face Image Database DF01," Technical Report, 2001.
- [4] G. Givens et. al., "How Features of the Human Face Affect Recognition: a Statistical Comparison of three Face Recognition Algorithms," IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004.
- [5] Henry A. Rowley et. al. "Neural Network-Based Face Detection," IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol.20, No.1, Jan., 1998.
- [6] S.M Lucas, "Real-time face recognition with the continuous n-tuple classifier," Vision, Image and Signal Processing, IEE Proceedings, Vol.145, Oct., 1998.
- [7] M. A. Turk, A. P. Pentland, "Face Recognition Using Eigen faces," Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, pp.586-591, 1991.
- [8] C. Liu, H. Wechsler, "Gabor Feature Based Classification Using the Enhanced Fisher Linear Discriminant Model for Face Recognition," IEEE Transactions on Image Processing, Vol.11, No.4, 2002.
- [9] J. Baker, "Adaptive Selection Methods for Genetic Algorithms," Proceedings First ICGA, pp.101-111, Jul., 1987.
- [10] J. Holland, "Adaptation in Natural and Artificial Systems," University of Michigan Press, Ann Arbor, 1975.
- [11] N. M. Allinson, A. Kolcz, "A Principled Approach to n-tuple Recognition Systems," the Institution of Electrical Engineers, 1997.
- [12] 문병로, "유전 알고리즘", 다성출판사, 2001.
- [13] S. Romdhani, "A Generic Face Appearance Model of Shape and Texture Under Vary Large Pose Variations from Profile Views," Proceedings 15th International Conference on, Vol.1, pp.1060-1063, 2000.
- [14] M. Lades et. al., "Distortion Invariant Object Recognition in the Dynamic Link Architecture," IEEE Transaction Computer, Vol.42, pp.300-311, 1993.
- [15] D. Field, "Relations Between the Statistics of Natural Images and the Response Properties of Cortical Cells," J. Opt. Soc. Amer. A, 1987.
- [16] C. Liu, H. Wechsler, "Gabor Feature Classifier for Face Recognition," Computer Vision 8th IEEE International Conference on, pp.270-275, 2001.
- [17] R. Kohavi, D. Sommerfield, "Feature Subset Selection Using the Wrapper Method: Overfitting and Dynamic search Space Topology," Proceedings of the First International Conference on Knowledge Discovery and Data Mining, 1995.
- [18] H. Liu, H. Motoda, "Feature Extraction, Construction and Selection : A Data Mining Perspective," Kluwer Academic Publishers, 1998.
- [19] 박종수, 김도형, "고차원 데이터를 부분차원 클러스터링하는 효과적인 알고리즘," 정보처리학회논문지, 제10-D권, 2003.
- [20] R. Ng, J. Han, "Efficient and Effective Clustering Methods for Spatial Data Mining," Proceedings of the 20th VLDB Conference, pp.144-155, 1994.

## 한 우연



e-mail : parthia80@hanmail.net

2003년 인하대학교 컴퓨터공학과  
(공학학사)

2003년~현재 인하대학교 컴퓨터·정보공학과  
석사과정

관심분야: 컴퓨터비전, 패턴인식, 생체정보  
인식



### 남 미 영

e-mail : rera@im.inha.ac.kr  
1999년 신라대학교 전자계산학과  
(이학학사)  
2001년 신라대학교 전자계산학과  
(이학석사)  
2002년 ~ 현재 인하대학교 컴퓨터·  
정보공학과 박사과정

관심분야: 컴퓨터비전, 패턴인식, 생체정보인식



### 이 필 규

e-mail : pkrhee@inha.ac.kr  
1975년 ~ 1982년 서울대학교 전기공학과  
(학사)  
1982년 ~ 1985년 KIST 시스템구조  
데이터통신실 연구원  
1985년 ~ 1986년 East Texas State  
University 전산학(석사)  
1987년 ~ 1990년 University & Louisiana 전산학(박사)  
1991년 ~ 1992년 한국전자통신연구소 컴퓨터 연구단 선임연구원  
1992년 ~ 2000년 인하대학교 전자계산공학과 부교수  
1993년 ~ 1994년 IBM T. J. Watson Research Center  
객원연구원  
2000년 ~ 현재 바이오메트릭 연구회 운영위원  
2000년 ~ 현재 한국컴퓨터산업교육학회 편집이사  
2000년 ~ 현재 전자상거래 편집 기술 위원  
2000년 ~ 현재 멀티미디어 학회 부위원장  
2001년 ~ 현재 인하대학교 컴퓨터·정보공학과 교수  
2001년 ~ 현재 정보처리학회 편집위원  
2001년 ~ 현재 정보보호진흥원 표준화분과 자문위원

관심분야: 컴퓨터비전, 패턴인식, 지능시스템