

부분공간과 LVQ 분류기에 기반한 실시간 얼굴 인식[☆]

Real-Time Face Recognition Based on Subspace and LVQ Classifier

권오륜*
Oh-ryun Kwon

전준철**
Jun-chul Chun

민경필***
Kyong-pil Min

요약

본 논문에서는 실시간 얼굴인증 시스템의 구축을 위한 LVQ 신경망 기반의 새로운 얼굴 인식 방법을 제안한다. 기존의 연구에서 PCA, LDA 변환이 많이 적용되며 신경망을 결합한 형태가 제안되고 있지만 신경망 학습 시간이 오래 걸리는 단점을 가지고 있다. LVQ 신경망은 학습 시간이 짧고 클래스간의 분리도를 최대화할 수 있는 교차학습방법이다. 따라서, 본 논문에서 제안된 방법은 동영상으로부터 실시간으로 입력되는 얼굴영상을 PCA와 LDA변환을 순차적으로 적용하여 부분공간상의 변환된 특징벡터로부터 LVQ 신경망의 학습을 통하여 얼굴을 인식한다. 외부조명의 영향에 강건한 인식시스템을 구축하기 위하여 얼굴검출 단계에서 검출된 얼굴영역은 밝기값의 최대-최소 정규화 방법에 의해 보정된 정규화 영상을 생성한다. 정규화된 얼굴영상은 PCA와 LDA 변환을 통해 부분공간상의 특징벡터로 변환된다. 변환된 훈련 데이터로부터 LVQ 신경망의 초기 중심 벡터를 결정하고 신경망의 학습을 향상 위해 K-Means 클러스터링 알고리즘을 적용하며, 초기 중심 벡터를 이용하여 LVQ2 학습 방법에 의해 학습된 중심벡터는 클래스의 대표 벡터가 된다. 결국 각 클래스의 대표 벡터로부터 입력 영상의 특징벡터간의 유클리디언 거리 비교법을 적용하여 얼굴 인식을 수행한다. ORL 데이터베이스를 이용한 정지 영상에 대한 인식과 실시간으로 입력되는 영상에 대한 인식 등 두 가지 형태의 영상을 기반으로 실험한 결과 두 경우에 모두 제안된 방법이 기존의 인식 방법보다 인식률에서 우수함을 입증할 수 있었다.

Abstract

This paper presents a new face recognition method based on LVQ neural net to construct a real time face recognition system. The previous researches which used PCA, LDA combined neural net usually need much time in training neural net. The supervised LVQ neural net needs much less time in training and can maximize the separability between the classes. In this paper, the proposed method transforms the input face image by PCA and LDA sequentially into low-dimension feature vectors and recognizes the face through LVQ neural net. In order to make the system robust to external light variation, light compensation is performed on the detected face by max-min normalization method as preprocessing. PCA and LDA transformations are applied to the normalized face image to produce low-level feature vectors of the image. In order to determine the initial centers of LVQ and speed up the convergency of the LVQ neural net, the K-Means clustering algorithm is adopted. Subsequently, the class representative vectors can be produced by LVQ2 training using initial center vectors. The face recognition is achieved by using the euclidean distance measure between the center vector of classes and the feature vector of input image. From the experiments, we can prove that the proposed method is more effective in the recognition ratio for the cases of still images from ORL database and sequential images rather than using conventional PCA or a hybrid method with PCA and LDA.

Keyword : LVQ(Linear Vector Quantization) neural net, face recognition, LDA(Linear Discriminant Analysis), PCA(Principal Component Analysis)

1. 서론

* 준회원 : (주)한글과 컴퓨터 연구원
kor5663@hotmail.com

** 종신회원 : 경기대학교 전자계산학과 교수
jcchun@kyonggi.ac.kr(교신저자)

*** 정회원 : (주) 휴민텍 책임 연구원
buffalo21@hotmail.com

[2006/12/27 투고 - 2007/01/08 심사 - 2007/03/15 심사완료]

☆ 본 연구는 21세기 프론티어 연구개발사업의 일환으로 추

진되고 있는 정보통신부의 유비쿼터스컴퓨팅및네트워크
원천기반기술개발사업의 지원에 의한 것임

진되고 있는 정보통신부의 유비쿼터스컴퓨팅및네트워크
원천기반기술개발사업의 지원에 의한 것임

없이 다가갈 수 있는 장점을 가지고 있다. 그러나 얼굴 인식 기술은 이러한 장점들을 지니고 광범위한 응용 범위를 지닌 반면 실제적인 응용에 있어서 몇 가지 문제점을 가지고 있다. 얼굴인식에 있어 대표적인 문제점은 인식 환경과 얼굴 자체의 가변성이 크다는 것이다. 즉, 얼굴 인식은 사용자의 기분과 상황에 따른 표정 변화, 머리모양, 얼굴 방향 등에 대한 특성을 고려해야하며, 주위 조명에 많은 영향을 받게 되는 단점이 있다. 또한 얼굴 인식을 위해 원본 데이터를 저장할 때, 자연스러운 자세가 아닌 인위적인 자세에서 촬영하기 때문에 데이터베이스에 저장된 영상과 카메라에 의해 획득된 영상을 비교하는 것은 여전히 해결되어야 하는 문제로 남아 있다. 이러한 문제를 해결하기 위하여 시스템 설계 시에 얼굴 영상을 획득하는 환경의 조명을 일정하게 고정시키고, 사용자로 하여금 가능한 중립적인 표정을 짓도록 요구함으로써 얼굴 모양의 변화를 통제하고 있다. 그러나 안정적인 얼굴 인식 성능을 갖기 위해서는 이와 같은 문제점들을 시스템의 인식단계에서 처리할 수 있어야 하며 인식 속도에 있어서도 응용분야에 적합한 수준이 보장되어야 한다[1].

기존의 얼굴 인식 시스템에 적용되고 있는 방법은 크게 특징 기반 방법과 통계적 방법으로 분류할 수 있다[2,3]. 특징 기반 방법은 얼굴 구성 성분의 특징을 이용하는 방법으로 얼굴의 크기와 방향, 얼굴의 시점 변화 등에 상관하지 않고 적용할 수 있는 유용한 방법으로 주로 에지, 그레이 정보, 그리고 컬러 정보 등을 이용한다[4,5]. 반면 통계적인 방법은 개개인의 얼굴 정보를 얼굴 공간상에서 적절히 부호화하여 사용하는 방법으로 대표적인 얼굴 인식 방법으로는 PCA(Principal Component Analysis), LDA(Linear Discriminant Analysis), 신경망 등이 있다. 이들 방법은 학습데이터로부터 학습을 통해 학습 모델을 생성한 후 입력 데이터에 의한 최적의 출력 값을 내는 것이다.

본 논문에서는 전처리 과정, PCA와 LDA변환에 의한 부분공간 변환, 그리고 LVQ 신경망의

결합을 통한 실시간 얼굴 인식 시스템을 제안한다. 입력 영상에서 얼굴 영역을 검출하고 검출된 얼굴 영역으로부터 정규화 영상을 전처리과정을 통해 생성한다. 정규화된 얼굴 영상을 PCA와 LDA 변환을 통해 얼굴 데이터의 차원을 축소된 부분공간상의 특징벡터를 생성하고 LVQ 신경망의 LVQ2 학습 방법을 통해 최적의 클래스 중심 벡터를 획득한다. 각 클래스의 중심벡터와 입력 영상의 특징 벡터간의 유클리디언 거리 비교를 통해 얼굴 인식을 수행한다. LVQ 신경망의 초기 중심벡터는 K-Means 클러스터링을 통해 생성하며 LVQ 신경망의 학습률 향상을 볼 수 있다. 또한, 실험은 크게 정지영상과 실시간에서 기존의 얼굴 인식 방법과의 제안한 방법을 비교를 하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 대표적 얼굴 인식 방법에 대하여 소개하며, 3장에서는 제안하는 얼굴 인식 시스템에 대해 기술한다. 4장에서는 실험을 통해 기존의 방법과 제안된 방법을 비교하여 제안된 방법의 우수성을 입증하였다. 끝으로 5장에서는 결론 및 향후 연구 방향에 대하여 기술하였다.

2. 관련 연구

기존의 얼굴 인식 및 검증 시스템에 사용되고 있는 방법은 크게 특징 기반 방법과 통계적 방법으로 분류할 수 있다[2,3]. 특징 기반 방법은 얼굴 구성 성분의 특징을 이용하는 방법으로 얼굴의 크기와 방향, 얼굴의 시점 변화 등에 상관하지 않고 적용할 수 있는 유용한 방법이다. 주로 사용되는 특징들로는 에지, 그레이 정보, 그리고 컬러 정보 등 여러 가지가 있다. 통계적인 방법은 개개인의 얼굴 정보를 얼굴 공간상에서 적절히 부호화하여 사용하는 방법으로 대표적인 얼굴 인식 방법으로는 PCA(Principal Component Analysis), LDA(Linear Discriminant Analysis), 신경망, SVM(Support Vector Machines) 등이 있다. 이들

방법은 학습데이터로부터 학습을 통해 학습 모델을 생성한 후 입력 데이터에 의한 최적의 출력값을 내는 것이다.

2.1 특징 기반 방법

특징 기반 방법은 눈, 코, 입과 같은 얼굴의 특징들의 위치나 크기 또는 이들 간의 거리와 같은 기하학적인 인자들만으로도 각 개인의 얼굴을 인식할 수 있다는 사실에 착안한 것으로서, 얼굴의 기하학적 특징을 검출하여 일치 여부를 판단한 인식 방법이다[4]. 이들 기하학적 특징들은 입력영상의 해상도를 낮추었을 때 최종적으로 남은 요소들에 해당되는 것으로 눈, 코, 입, 볼, 모양, 크기와 같은 얼굴의 구성요소 사이의 위치 관계는 얼굴을 분류하는데 큰 기여를 한다.

연구 초기에는 눈, 코, 입과 같은 얼굴 특징점을 표시하여 특징점간의 거리, 각도, 영역 같은 모든 종류의 기하학적 특징들을 수동적으로 계산하여 추론된 특징들에 따라 인식률을 연구하고 관찰하였다. 그 후, 연구 작업은 눈, 코, 입 같은 특징들의 검출과 눈의 기하학적 특징들, 얼굴 모양 묘사와 볼의 모양, 입의 위치, 코의 길이, 폭 등과 같은 35개의 특징들을 자동적으로 획득하는데 초점이 맞춰졌다. 이 자동 특징 추출 알고리즘은 얼굴의 핵심점의 위치를 결정하기 위해 개발되었다. Cox[5]에 의해 제안된 변형 템플릿은 얼굴 모양을 더 선세하게 나타내는 기하학적 방법으로서 모든 얼굴 구성 요소를 위해 파라미터 적용 모델을 고안하고, 모델 파라미터와 함께 얼굴 구성 요소의 에지 영상과 그레이 영상을 변수로 하는 에너지 함수를 정의한다. 연속적으로 학습을 통해 에너지 함수가 최소화된 모델 파라미터는 얼굴 구성 요소의 기하학적 특징들이 된다. 템플릿 기반 방법은 에너지 함수의 계수가 경험적으로만 정의된다는 것과 일반화될 수 없다는 단점이 있다. 더욱이 에너지 함수의 최적화 진행과정은 느리고, 그 결과는 국소 최소점에 위치할 수 있다.

2.2 통계적 방법


PCA 변환은 K-L 변환을 기반으로 얼굴 영상을 저차원의 벡터로 표현하는 방법이다[7]. 1980년대 말에 Sirovich와 Kirby는 사람의 얼굴을 효과적으로 표현하기 위해서 PCA 변환을 개발하였고, 1991년 Turk와 Pentland[6]는 얼굴 영상이 존재하는 얼굴 공간(face Space)을 정의하고, 그 공간 안에 존재하는 얼굴 영상을 고유 얼굴(eigenface)이라 불리는 기저(basis)로 표현하는 방법을 제안하였다. 이 고유 얼굴은 학습 영상들의 공분산 행렬에 대해서 선형대수학에서의 고유값, 고유벡터 문제를 풀어서 계산된다. 훈련 영상들은 고유 얼굴 공간에서 새로운 좌표계로 변환되며 테스트 영상과의 거리 비교를 통해 얼굴 인식을 수행한다. 이와 같이 PCA변환을 사용하는 이유는 고차원의 데이터를 다룸으로써 생기는 비효율성 문제를 해결하는데 있다고 하겠다. 하지만 PCA변환은 입력영상의 포즈, 조명, 표정 등의 변화로 인해 훈련 데이터 집합과 다를 경우 인식률이 떨어지는 단점을 가지고 있다.

LDA 변환은 FLD(Fisher Linear Discriminant)를 분류 알고리즘으로 적용한 얼굴 인식 방법으로, 사람 개인의 특성을 학습함으로써 보다 정확하고 환경변화에 둔감한 특성이 지니고 있어 온라인상에서 실시간으로 적용 가능한 알고리즘이다 [8,9].

일반적으로 PCA 변환을 얼굴 인식에 적용하였을 경우 가장 큰 문제점은 데이터간의 분산이 큰 방향에 대해서 고려를 하기 때문에 클래스간의 중첩문제가 발생할 경우 제대로 분류할 수 없다는 것이다(그림 1). 특히 조명, 표정 또는 그 밖의 다른 요인에 의한 변화를 구분할 수 없다. LDA 변환은 개체가 다른 클래스간의 분리가 잘 되도록 표현하게 만들어진 방법으로 각각 클래스간의 분산은 최대화시키며 클래스내의 분산은 최소화시켜 클래스간의 분리도를 높이는 방법이다.

$$J_K(\omega) = \frac{|S_b|}{|S_w|} \quad (\text{식 1})$$

위의 Fisher 판별식이 최대가 되는 선형 변환을 통해 특징 그룹을 분류한다. $S_w^{-1}S_b$ 의 가장 큰 고유값을 갖는 고유벡터가 찾고자 하는 특징들이 된다. 이 고유벡터들을 Fisherface라 한다. 클래스 간의 분산뿐 아니라 클래스 내 학습 데이터들 간의 분산도 고려하기 때문에 PCA 변환에 의한 얼굴 인식보다 성능이 좋다.



(그림 1) 2차원에서 데이터의 투영

SVM은 AT&T에서 Vapnik[10]에 의해서 제안된 학습기법으로 커널을 사용하여 복잡한 비선형 문제를 다룰 수 있는 이진 분류기법이다. 이진 클래스 문제나 회귀 분석, 패턴 인식 등에 사용되며 좋은 성능을 보인다. 다항식 분류기(polynomial classifier), 신경망 분류기 또는 Radial Basis Function 분류기 등 분류기의 마진(margin)을 최대 로 하여 예상되는 위험을 최소화하는 것을 목적으로 한다. 이들 분류기들은 훈련 과정에서의 오류를 최소화하는 경험적 오차(ERM : Empirical Risk Minimization)를 이용하는 것과 달리 구조적 오차 최소화 방법(SRM : Structural Risk Minimization)을 이용하여 일반화 오차를 감소시키는 방법이다. SVM은 기본적으로 이진 클래스 분류기이며 얼굴 인식에 적용하기 위해서는 이진 클래스 분류기가 아닌 다중 클래스 분류기로 확장을 해야만 한다. 다중 클래스 분류기로의 확장에 따라 그 그룹의 데이터를 분리할 수 있는 최

적 분리 경계면(Optimal hyperplane)을 구한다. 이때 최적 분리 경계면과 각 그룹의 Support Vector 간의 거리가 최대가 되는 지점에서 최적 분리 경계면을 설정하여 얼굴 인식 시스템에 적용한다. SVM은 비교적 높은 인식률을 보이지만 아직 커널 함수 선택에 관한 가이드라인이 존재하지 않고 얼굴 인식과 같은 다중 클래스에 적용하기에는 시간과 메모리가 많이 소모되는 알고리즘이다.

신경망을 이용한 얼굴 인식 기법에 대한 연구는 예전부터 활발히 진행되어 왔다. 신경망을 이용한 얼굴 인식 방법은 얼굴 영상에 대한 특징 값을 정의하고 추출된 특징값들을 이용하여 신경망 학습을 한 후, 인식을 수행하는 것이다[11,12]. 신경망 학습 방법으로는 대부분 오류역전과 학습 방법을 사용하는데, 학습 방법의 기본은 현재 주어진 연결강도로 생성되는 오차값을 구하여 이를 감소시키는 방향으로 연결 강도의 값을 조정하는 것으로 이때 오차값의 계산을 위해 각 노드의 올바른 출력값을 제공해 주어야 한다. 이러한 문제를 해결하기 위해 오류역전과 방법은 만일 어떤 뉴런의 활성이 다른 뉴런의 잘못된 출력에 영향을 미친다면 두 뉴런간의 연결 가중치를 그것에 비례하게 조절해 주는 방법을 기본으로 하고 있다.

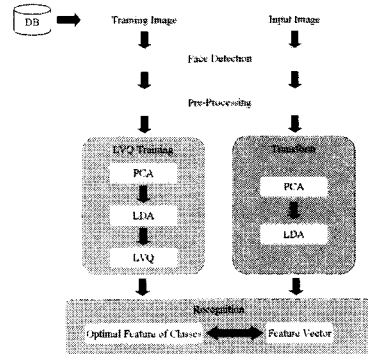
Fatemi[13]의 연구에서는 RBF 네트워크를 이용한 신경망을 얼굴 인식에 적용하였다. RBF 신경망은 입력벡터가 데이터베이스 전체에 영향을 주는 오류역전과와 달리, 데이터베이스 내 채택 필드 중심 근방에 입력 벡터가 있을 때, 그 중심값들에 관련된 뉴런들만 활성화되는 방법이다. 입력 벡터와 일정거리 이상 떨어진 뉴런들은 영향을 받지 않아 활성화되지 않으므로 시간적인 측면에서 오류역전과보다 우수한 특징을 가지고 있다.

Tolba[14]의 연구에서는 LVQ 신경망과 RBF 신경망을 얼굴 인식에 적용하였다. 이 연구에서는 LVQ1 학습 알고리즘을 적용한 LVQ 신경망과 RBF 신경망을 이용한 방법, 그리고 LVQ와 RBF 신경망의 결합을 통한 방법을 통해 얼굴 인식 결과를 비교하였다.

3. 제안 시스템

본 논문에서 제안하는 얼굴 인식 시스템은 크게 전처리 과정, 얼굴 검출, 그리고 얼굴 인식 단계로 구성되어 있다. 전처리 과정에서 최대-최소 정규화를 통해 조명 보정을 수행한다. 정규화된 얼굴 영상에 대해 PCA와 LDA 변환으로부터 부분공간상 저차원의 특징벡터로 변환한다. 특징 벡터로부터 K-Means 알고리즘을 이용하여 LVQ 신경망의 초기 중심 벡터를 획득한다. 초기 중심 벡터를 LVQ 신경망의 초기 가중치로 하여 LVQ2 학습 알고리즘을 적용하여 훈련 영상으로부터 LVQ 신경망을 학습한다. 학습된 LVQ 신경망은 최적의 클래스 대표 벡터를 획득하게 되며 입력

영상의 특징 벡터간의 유클리디언 거리를 이용하여 얼굴 인식에 적용한다. 제안된 얼굴 인식 시스템의 전체 구성도는 (그림 2)와 같다.



(그림 2) 얼굴 인식 시스템 구조

1. Training Process // 훈련 단계
 - 1.1 input image // 이미지를 입력
 - 1.2 Transform PCA to calculate Eigenface // PCA 변환을 위한 고유얼굴 계산
 - 1.2.1 Mean image // 평균 영상
 - 1.2.2 Sub image // 차영상
 - 1.2.3 Covariance matrix & eigenvalue, eigenvector
 - 1.3 Transform LDA to calculate Eigenface // LDA 변환
 - 1.3.1 Between Scatter Matrix // 클래스간 산란행렬
 - 1.3.2 Within Scatter Matrix // 클래스내 산란행렬
 - 1.3.3 Covariance matrix & eigenvalue, eigenvector
 - 1.4 LVQ2 Training
 - 1.4.1 Initialize the center vector using K-Means Clustering // 초기 중심 벡터
 - 1.4.2 모든 훈련 영상에 대해
 - 1.4.2.1 입력 벡터와 각 클래스간의 거리 계산
 - 1.4.2.2 입력 벡터가 짧은 거리의 두 클래스의 윈도우 영역 안에 있는 경우 중심 벡터 갱신
 - 1.4.2.3 학습률 갱신
 - 1.4.2.4 윈도우 영역 안에 없는 경우 1.4.2 반복
 - 1.4.3 에러의 개수가 1개 이하일때까지 1.4.2 반복하며 1개 이하이면 학습 종료
2. Face Recognition Process // 인식 단계
 - 2.1 input image
 - 2.2 Transform the PCA
 - 2.3 Transform the LDA
 - 2.4 Calculate the distance the input image between center vector
 - 2.5 거리가 가장 짧은 클래스의 대표 영상을 인식 결과로 출력

(표 1) 제안된 방법의 전체 프로세스 알고리즘 표현

본 논문에서 제안하는 방법을 알고리즘 형태로 표현하면 (표 1)과 같다.

3.1 조명보정

부분공간으로의 변환을 위해 PCA와 LDA 변환은 그레이 영상을 이용함으로써 조명에 많은 영향을 받는다. 따라서 조명에 대한 보정이 필요하다. 본 논문에서는 최대-최소 정규화를 통해 입력 영상의 조명 보정을 수행한다. 최대-최소 정규화 방법은 입력 영상을 새롭게 정의된 데이터 범위로 변형시켜주는 방법으로, 아주 어둡거나 밝은 입력 영상을 특정 밝기 영역 안에 존재할 수 있도록 변화시키는 방법으로 (식 2)와 같이 정의된다.

$$y' = \left(\frac{y - \min_1}{\max_1 - \min_1} \right) (\max_2 - \min_2) \quad (\text{식 2})$$

최대-최소 정규화 알고리즘에 의해 입력 영상의 밝기 값인 y 가 입력되면 새롭게 정의된 밝기 값인 y' 이 결과로 출력된다. \max_1 과 \min_1 은 입력 영상의 최대, 최소 밝기값이며, \max_2 와 \min_2 는 새롭게 정의된 영상의 최대, 최소 밝기 값이다.

3.2 부분공간 변환

본 논문에서는 얼굴 영상에서 특징 추출을 위해 부분공간으로의 변형을 적용한다. 부분공간이란 PCA와 LDA변환을 통해 변형된 선형 공간을 뜻하는 것으로 얼굴의 특징을 저차원의 벡터로 표현한다. 부분공간으로 변환하기 위해 PCA와 LDA변환을 순차적으로 적용하여 얼굴 특징 벡터를 생성하며 이 벡터는 LVQ 신경망의 입력 데이터로써 이용된다.

(1) PCA 변환

PCA 변환은 얼굴 영상을 재구성한 고유벡터의 집합으로서, 얼굴 영상 집합에 대해 통계적으로 매우 중요한 정보들을 추출하는 방법이다. 영상 데이터를 선형 공간으로 변환하여 고유벡터라고 불리는 형태로 표현하는 방법이다. 고유벡터 집합을 얼굴에 적용할 때 보통 고유 얼굴이라고 부르며 훈련 얼굴 영상들에 대한 공분산 행렬의 고유벡터를 계산하고, 새롭게 입력된 얼굴을 고유 얼굴 공간으로 투영시켜 얼굴 영상에 대한 특징 벡터를 계산한다. 일반적으로 입력 영상을 PCA 변환을 통해 고차원의 얼굴 데이터를 저차원의 특징 벡터로 변환한다. PCA 변환을 적용하였을 경우 주성분의 최대 수는 원래 영상 공간상의 변수의 수이다. 그러나 영상 차원을 줄이기 위해서 몇몇의 주성분들은 생략될 수 있다. 즉, 고유값을 내림차순으로 배열하였을 때, 마지막 몇 개의 고유값을 생략하더라도 큰 오차 없이 원래의 얼굴 영상으로 복원할 수 있다. 특히 PCA 변환에서 고유값은 지수함수처럼 급속히 감소되므로 마지막 여러 주성분들은 생략하더라도 원래 영상들과의 오차가 매우 작다. 전체 데이터베이스의 평균 영상과 각 개인 영상의 차영상으로 구성된 공분산 행렬(Covariance matrix)의 고유벡터를 고유공간에 투영시킨 영상이 고유 얼굴이며, 큰 고유값에 대응하는 고유벡터일수록 얼굴과 비슷함을 알 수 있다. 이를 수학적으로 전개하면, $N \times N$ 인 2차원 얼굴 영상에 대해 $N^2 \times 1$ 인 얼굴 벡터와 M 개의 얼굴 벡터($\Gamma_1, \Gamma_2, \dots, \Gamma_M$)에 대한 평균영상 벡터는 다음과 같다(식 3).

$$\Psi = \frac{1}{M} \sum_{k=1}^M \Gamma_k \quad (\text{식 3})$$

여기서 Ψ 는 평균영상으로 $N^2 \times 1$ 크기의 벡터이고, Γ_k 는 훈련 영상이며 M 은 훈련 영상의 개수이다.

각각의 훈련영상에 대한 평균영상의 차영상은 (식 4)와 같이 구할 수 있다.

$$\phi_i = \Gamma_i - \Psi \quad (\text{식 4})$$

이때 $\phi_i = N^2 \times 1$ 벡터가 되고, 차영상에 대한 공분산 행렬 C 는 다음 (식 5)와 같이 정의된다.

$$C = \frac{1}{M} \sum_{i=1}^M \phi_i \phi_i^T = AA^T \quad (\text{식 5})$$

(식 5)에서 $A = \frac{1}{\sqrt{M}} [\phi_1, \phi_2, \dots, \phi_M]$ 는 $N^2 \times M$ 크기가 되며, C 는 $N^2 \times N^2$ 크기의 고차행렬이 된다. 일반적으로 공분산 행렬 C 에 대해 고유값과 고유 벡터를 구하는 방법은 (식 6)과 같다.

$$Cu_i = \lambda_i u_i \quad (\text{식 6})$$

만약 입력 영상이 80×80 크기의 영상이라면 N^2 은 6400이 되기 때문에 C 의 크기가 6400×6400 이 된다. 따라서 이 정도 크기의 고유벡터를 구하는 것은 많은 연산시간과 메모리량을 필요로 한다. 따라서 C 의 크기는 다음 과정을 통해 줄일 수 있다.

$$A^T A V = V X \quad (\text{식 7})$$

(식 7)을 가정하면 V 는 고유벡터가 되고 X 는 고유값이 된다. (식 7)의 양변에 A 를 곱하면 (식 8)과 같이 된다.

$$AA^T A V = A V X \quad (\text{식 8})$$

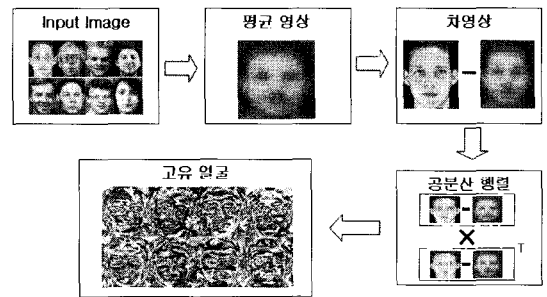
(식 8)에서 $A V$ 는 AA^T 의 고유벡터가 되고 X 는 고유값이 된다. 따라서 A 에 $A^T A$ 의 고유 벡터를 구해서 곱하면 공분산 행렬 C 의 고유 벡터를 구할 수 있고, 고유값은 X 로서 변함이 없는 것을 알 수 있다. $A^T A$ 의 크기는 $M \times M$ 이므로 크기는 훨씬 작은 크기의 행렬이 된다

($M \ll N$).

얼굴 영상 Γ_i 를 고유 얼굴 공간상에 투영했을 때, 전체 고유 얼굴 u_i^T 에 대한 얼굴 영상의 특징 벡터를 ω_{ik} 라고 하면, 특징 벡터는 (식 9)에 의해 계산할 수 있다.

$$\omega_{ik} = u_k^T (\Gamma_i - \Psi) \quad (\text{식 9})$$

전체 영상의 특징 벡터 $\Omega_i^T = [\omega_{i1}, \omega_{i2}, \dots, \omega_{iM}]$ 는 훈련 영상에 대한 고유 얼굴 공간상의 위치를 나타낸다. 다음 (그림 3)은 PCA 변환 과정을 도식화한 것이다.



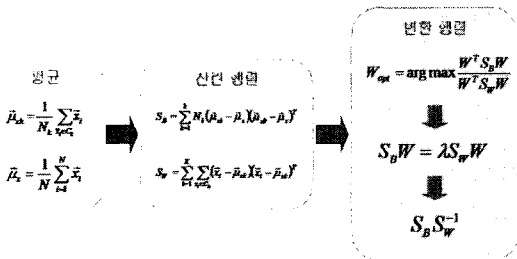
(그림 3) PCA 변환 과정

PCA 변환의 가장 큰 문제점은 데이터간의 분산이 큰 방향에 대해서 고려를 하기 때문에 클래스간의 중첩 문제가 발생할 경우 제대로 분류할 수 없다는 것이다. 특히 조명, 표정 또는 그 밖의 다른 요인에 의한 변화를 구분할 수 없다. 따라서 PCA의 단점을 보완하기 위해 LDA 변환을 같이 사용함으로써 얼굴 인식의 정확도를 높일 수 있다.

(2) LDA 변환

LDA 변환은 PCA 변환과 같이 효율적인 식별을 위해 차원을 축소시키는 방법이지만, PCA 변환이 얼굴 영상 패턴의 전체 분포를 잘 근사시킬 수 있는 부분공간을 찾는 과정인데 비해서 LDA

변환은 각 클래스의 패턴 분포의 분리도를 최대한으로 하는 부분공간을 찾는 과정으로 환경변화에 둔감한 특성을 가지고 있다. LDA 변환은 얼굴 영상들에 대해 독립적인 특징들이 주어졌을 때 클래스들 사이에 가장 큰 평균적 차이를 나타내는 특징들의 선형 결합을 만들어낸다. 즉, 각각의 얼굴 영상에 대한 데이터를 가장 잘 나타내는 벡터를 찾는 것이 아니라 해당 공간에서 클래스들 간의 차이를 가장 잘 나타내는 벡터를 찾는 것이다. LDA 변환의 변환 과정은 다음 (그림 4)와 같다.



(그림 4) LDA 변환 과정

본 논문에서는 PCA 변환을 통해 생성된 특징 벡터를 LDA 변환 과정의 입력 벡터로 적용하여 LDA 변환과 결합한다. 먼저 PCA 변환을 통해 생성된 특징 벡터를 LDA 변환의 입력 벡터로 적용한다. 임의의 입력 벡터 x_i^j 는 j 번째 클래스의 i 번째 특징 벡터를 나타내고 n_j 는 j 번째 클래스의 특징 벡터 개수라고 하면, i 번째 클래스의 평균 벡터 m_i 는 다음 (식 10)과 같다.

$$m_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_i^j \quad (\text{식 } 10)$$

클래스 내 산란행렬은 다음 식과 같이 정의된다.

$$S_W = \sum_{j=1}^c \sum_{i=1}^{n_j} (x_i^j - m_j)(x_i^j - m_j)^T \quad (\text{식 } 11)$$

전체 입력 벡터의 수 n 에 대해서 i 번째 입력 벡터를 x_i 라고 하면, 입력 벡터 전체의 평균 벡터 m 은 다음 식과 같다.

$$m = \frac{1}{m} \sum_{i=1}^n x_i \quad (\text{식 } 12)$$

또한 전체의 입력 벡터에 대한 평균 벡터 m 으로부터 클래스간의 산란행렬은 (식 13)에 의해 계산된다.

$$S_B = \sum_{j=1}^c (m_j - m)(m_j - m)^T \quad (\text{식 } 13)$$

S_W 와 S_B 로부터 (식 14)를 유도할 수 있으며 $S_W^{-1} S_B$ 의 고유벡터와 고유값을 구함으로써 (식 15)와 같이 LDA 공간상으로 변환을 수행한다.

$$S_W^{-1} S_B U = \lambda_i U \quad (\text{식 } 14)$$

$$y_i = W^T x_i \quad (\text{식 } 15)$$


W 의 행렬은 $S_W^{-1} S_B$ 의 고유벡터들이며 얼굴 영상의 고유 벡터 y_i 를 fisherfaces라고 한다.

LDA 변환만을 이용하여 얼굴을 인식한다면 데이터가 비선형적이거나 각 클래스가 같은 평균을 가지는 경우는 분리하기 어렵다는 단점이 있기 때문에 PCA 변환을 통해 생성된 특징 벡터를 이용하여 LDA 변환을 수행하는 방법을 적용한다.

3.4 LVQ 신경망

본 논문에서는 최적의 클래스 중심 벡터를 찾기 위해 LVQ 신경망[15]을 이용한다. LVQ 신경망은 (그림 5)와 같이 입력층과 출력층으로만 구성된 단층 신경망으로, 입력층의 뉴런은 출력층의 모든 뉴런들과 연결되어 있는 구조이다. 입력 벡터 x 가 신경망에 입력되면, 중심 벡터와 x 의 유클리디언 거리를 기반으로 출력 뉴런들이 경쟁을

별여 입력 벡터와의 거리가 가장 작은 한 개의 뉴런이 출력되며, 이 뉴런을 승리 뉴런이라 한다. 뉴런에 클래스가 할당된 경우, 승리 뉴런의 클래스가 출력이 된다.



(그림 5) LVQ 신경망의 구조

LVQ 신경망의 학습은 입력과 출력 사이의 연결 벡터인 중심 벡터와 입력 벡터의 거리를 비교하여 중심 벡터와의 거리가 가장 가까운 입력 벡터가 승리 벡터가 되고, 중심 벡터와 승리 벡터가 같은 클래스로 분류되면 연결 벡터를 증가시키고, 다른 클래스로 분류되면 연결 벡터를 감소시킨다. 이러한 과정을 통해 입력되는 얼굴의 특징 벡터는 분류가 되고 연결 벡터는 학습을 하게 된다. 하지만 우수한 성능에도 불구하고 LVQ 신경망은 중심 벡터의 초기값을 선정하는 방법에 따라 성능이 좌우될 수 있다. LVQ 신경망의 중심 벡터는 클래스의 경계를 결정하고 그것의 수렴에 영향을 미치기 때문에 중심 벡터의 초기값을 선정하는 것은 매우 중요한 문제이다. 일반적으로 중심 벡터를 정하는 방법으로 입력 패턴의 학습 데이터 중에서 임의로 선택하거나 또는 랜덤하게 선택하는 방법이 사용되나 정확한 분류에는 적합하지 않다. 따라서 본 논문에서는 중심 벡터의 초기값을 선택하기 위해 K-Means 클러스터링 알고리즘을 이용한다.

(1) K-Means 클러스터링

LVQ 신경망의 초기 중심 벡터를 얻기 위해 본 논문에서는 K-Means 알고리즘을 적용한다. K-Means 알고리즘을 적용함으로써 LVQ 신경망 수렴 속도의 향상을 보였고 좀 더 정확한 클래스 경계를 생성할 수 있다. 다음 (표 2)는 K-Means 클러스터링 알고리즘이다.

(표 2) K-Means 클러스터링 알고리즘


1. 초기화 : 모든 학습 벡터와 최대 반복횟수를 입력
2. 클러스터 형성 : 모든 학습 벡터에 대해 임의의 중심 벡터와의 거리가 가장 가까운 중심 벡터를 찾아 클러스터를 형성
3. 중심 벡터 갱신 : 형성된 클러스터에 존재하는 벡터들의 평균으로 중심 벡터를 갱신
4. 모든 클러스터의 중심 벡터의 이동이 없다면 종료하고 그렇지 않으면 2번부터 반복

(2) LVQ 신경망 학습

LVQ 신경망은 경쟁식 신경망이 형성하는 결정 경계를 베이지언 최적 결정 경계에 접근하도록 고안된 방법으로써 LVQ 신경망의 교사 학습 알고리즘으로는 LVQ1, LVQ2, LVQ2.1, LVQ3 등 여러 가지 학습 알고리즘이 있다. 본 논문에서는 LVQ2 학습 알고리즘을 이용하여 신경망을 학습한다. LVQ2는 두 개의 중심 벡터에 의해 형성되는 결정 경계를 베이지언 최적 경계에 가까워지도록 하기 위해 한번에 두 개의 출력 뉴런의 연결 벡터를 갱신하는 방법이다.

(그림 6)에서 두 개의 곡선은 각각 입력 벡터 x 에 대한 클래스 i 와 클래스 j 의 분포를 나타낸다. (그림 6)에서와 같이 두 개의 중심 벡터의 클래스가 서로 다른 경우, LVQ2 알고리즘은 두 기준 벡터가 형성하는 결정 경계 부근에 윈도우라고 하는 영역을 설정하여 윈도우 안에 존재하는 입력 벡터에 대해서만 학습한다. LVQ 알고리즘은 입력 벡터와 출력 뉴런의 클래스가 같으면 입

력 벡터 방향으로 당기고 그렇지 않으면 반대 방향으로 밀어내므로 결과적으로 LVQ2 알고리즘은 두 클래스의 분포가 같아지는 베이저언 최적 경계에 가까워지도록 결정 경계를 이동시키게 된다.



(그림 6) 두 클래스간의 분포도

LVQ2의 학습 과정은 다음과 같다. 입력 벡터 x 에 대해 두 개의 승리 뉴런의 중심 벡터, 즉 벡터 x 와 거리가 가장 가까운 두 개의 중심 벡터 $v_i(t)$ 와 $v_j(t)$ 를 찾는다. 가중치 벡터들은 x 의 승리 뉴런의 중심 벡터 클래스가 $v_i(t)$ 와는 다르고 $v_j(t)$ 와 같은 경우에만 갱신되며 갱신하는 방법은 (식 16)과 같다.

$$\begin{aligned} v_i(t+1) &= v_i(t) + \alpha(t)(x - v_i(t)) \\ v_j(t+1) &= v_j(t) + \alpha(t)(x - v_j(t)) \end{aligned} \quad (\text{식 16})$$

이때 입력 벡터 x 는 $v_i(t)$ 와 $v_j(t)$ 의 윈도우 안에 존재하여야 한다. 입력 벡터 x 가 윈도우 내부에 존재하는지의 여부는 두 가중치 벡터 사이의 길이에 대한 윈도우의 상대적인 폭을 w 라고 할 때, (식 17)에 의해 결정된다.

$$\min\left(\frac{d_i}{d_j}, \frac{d_j}{d_i}\right) > s, \quad s = \frac{1-w}{1+w} \quad (\text{식 17})$$

LVQ 신경망 학습을 통해 최적의 클래스 중심 벡터를 찾을 수 있다. 학습된 클래스의 중심 벡터와 입력 벡터간의 유클리디언 거리를 비교하여 얼굴 인식에 적용한다.

4. 실험 결과

본 논문에서의 얼굴 인식 실험은 ORL 데이터베이스[16]를 이용한 정지영상과 웹캠에서 실시간으로 획득한 영상에 대한 비교 실험을 하였다. 제안된 방법의 우수성을 입증하기 위하여 기존의 얼굴 인식 방법과 제안된 방법에 의한 인식률을 비교 평가한다.

4.1 정지 영상에 대한 인식률 비교

정지 영상에 대한 얼굴 인식 실험을 위해 ORL 데이터베이스를 이용한다. ORL 데이터베이스는 총 400장(40명 * 10장)의 얼굴 영상으로 구성되어 있다. 본 논문에서는 학습을 위하여 한 사람에 대해 각각 5장의 영상을 훈련 영상으로 이용하였으며 나머지 5장의 영상을 얼굴 인식 실험에 적용하였다. 또한, 실험 대상의 사람의 수를 다르게 변화하면서 실험을 통해 얼굴의 인식률을 비교하였다.

LVQ 신경망의 학습률을 비교하기 위하여, LVQ2 학습과정에서 초기의 중심 벡터 설정에 대해 K-Means 알고리즘을 적용한 경우, 임의의 중심 벡터를 적용한 경우, 그리고 각 클래스의 평균 벡터를 적용한 경우 수렴 속도의 차이와 훈련 영상의 오류 개수의 결과는 (표 3)과 같다. 실험 결과 K-Means를 이용하여 초기 중심 벡터를 적용한 경우에 학습률이 향상된 것을 확인 할 수 있었다.

(표 3) LVQ 신경망 학습률 비교

* 최대 반복 횟수 : 2000회

방법	반복 횟수	오류 개수
임의의 중심 벡터	1374	1
평균 벡터	712	0
K-Means	498	0

기존의 얼굴 인식 방법과 제안한 방법의 인식률을 비교한 결과는 (표 4)와 같다. (표 4)의 실험

결과에서 보듯이 사람 수가 적을 경우 제안된 방법과 기존의 방법과 인식률에 있어 큰 차이를 보이지 않았으나 사람의 수가 많아질수록 제안한 방법의 인식률이 높다는 것을 알 수 있다.

(표 4) 실험 결과 인식률 비교

사람 수	방법	테스트 결과 (+/시도횟수)	인식률
10명	PCA	49/50	98.0%
	PCA+LDA	49/50	98.0%
	PCA+LVQ1	49/50	98.0%
	PCA+LDA+LVQ1	49/50	98.0%
	제안한 방법	49/50	98.0%
20명	PCA	90/100	90.0%
	PCA+LDA	91/100	91.0%
	PCA+LVQ1	90/100	90.0%
	PCA+LDA+LVQ1	92/100	92.0%
	제안한 방법	91/100	91.0%
30명	PCA	132/150	88.0%
	PCA+LDA	143/150	95.3%
	PCA+LVQ1	137/150	91.3%
	PCA+LDA+LVQ1	143/150	95.3%
	제안한 방법	144/150	96.0%
40명	PCA	171/200	85.5%
	PCA+LDA	180/200	90.0%
	PCA+LVQ1	175/200	87.5%
	PCA+LDA+LVQ1	183/200	91.5%
	제안한 방법	189/200	94.5%

ORL 데이터베이스의 특정영상에 대하여 PCA+LDA 방법과 제안된 방법에 의해 수행된 얼굴 인식 실험 결과는 (그림 7)과 같다. PCA+LDA 방법 적용 시 오류로 인식한 얼굴에 대하여 본 논문에서 제안한 방법을 적용 시 올바른 인식을 하고 있음을 확인 할 수 있다.

4.2 실시간에서의 얼굴 인식 시스템 적용


본 논문에서 제안된 방법을 실시간에 적용하기 위해 웹캠으로부터 입력된 영상을 이용하여 얼굴 인식을 수행하였다. 웹캠으로부터 5초 동안 검출된 얼굴 영역의 오차가 임계치 이하일 때 제안된 방법에 의해 얼굴 인식을 수행한다. LVQ 신경망을 학습하기 위한 10명의 대상자로부터 개인당 6장의 훈련 영상을 적용하였다(그림 8). 실험은 실시간으로 입력되는 영상에 대해 기존의 방법과 제안한 방법을 이용한 실험을 비교 수행하였다.

실험 대상 한명 당 총 50번(10회 * 5번)의 테스트를 통해 평균 인식률 결과는 (표 5)와 같다. 실험 결과에서 볼 수 있듯이 정지 영상보다는 인식률이 감소하였다. 그 이유는 입력 영상이 정해진 환경이 아닌 다양한 환경에 노출되어 주변 환경에 영향을 받기 때문이다. 또한, 훈련 영상 수집 시 같은 자리에서 6장의 훈련 데이터를 얻기



(그림 7) 얼굴 인식 실험 결과 비교

때문에 정확한 학습을 하기 힘든 단점도 있다. 그러나 정지영상의 경우와 같이 기존의 방법보다 향상된 인식률을 보였다.



(그림 8) 동영상으로 입력된 훈련 영상

(표 5) 동영상으로부터 입력된 영상의 얼굴인식 결과 비교

방법	인식률(%)										평균 인식률 (%)
	1회	2회	3회	4회	5회	6회	7회	8회	9회	10회	
PCA	76	70	78	76	71	73	71	74	80	75	74.4
PCA+LDA	84	77	88	85	78	82	80	83	92	82	83.1
PCA+LVQ1	79	75	80	77	74	76	74	76	83	78	77.2
PCA+LDA+LVQ1	87	79	94	91	82	84	86	84	96	85	86.8
제안한 방법	91	82	97	95	86	90	89	91	97	91	90.9

(표 6)은 실험 대상을 10명으로 하였을 경우 기존 방법과의 학습 시간 비교 및 학습을 제외한 얼굴 인식 처리 시간 비교한 것이다. 비교 결과 학습 시간에서는 LVQ 신경망 학습에 의해 처리시간이 증가하였으나 실제 얼굴 인식 처리 시간은 기존의 방법과 차이가 없다는 것을 볼 수 있다.

(표 6) 학습 시간 및 처리 시간 비교

방법	학습 시간 (sec)	학습을 제외한 얼굴 인식 처리 시간(sec)
PCA	0.01	0.005
PCA+LDA	0.02	0.003
PCA+LVQ1	1.36	0.006
PCA+LDA+LVQ1	1.25	0.003
제안한 방법	1.33	0.003

또한, 제안한 방법에서 특정 영상에 대한 오류인 경우는 (그림 9)와 같다. 오류가 발생한 경우에 대한 이유는 다음과 같다.

- 실시간으로 입력된 영상에서 얼굴 영상을 추출하기 때문에 정확한 얼굴 영상을 획득하지 못한 경우
- 주변 환경(조명)에 대한 영향을 많이 받기 때문에 정규화된 영상으로도 인식할 수 없는 경우
- 6장의 학습 영상에서 나타나지 못한 얼굴의 형태(안경, 모자 등의 착용)가 입력 영상으로 들어온 경우
- 검출된 얼굴 영상에서 얼굴의 방향이 기울어진 경우

5. 결론 및 향후 연구 방안

본 논문에서는 부분공간으로의 변환인 PCA와 LDA 변환과 LVQ 신경망의 LVQ2 학습 방법을 적



(그림 9) 실시간 적용시 오류인 경우

용한 새로운 얼굴 인식 방법을 제안하였다. 웹캠 으로부터 입력된 영상으로부터 얼굴을 검출하여 영상의 밝기값을 보정하여 외부 조명의 영향을 감소시킨 후, PCA와 LDA 변환을 순차적으로 적용하여 획득된 부분공간상의 얼굴 특징 벡터를 LVQ 신경망을 통해 실시간 얼굴 인식을 수행하였다. LVQ 신경망 학습 시 기존의 연구에서 적용되던 LVQ1 학습 방법이 아닌 LVQ2 학습 방법을 적용하였다. 실험 결과에서 ORL 데이터베이스의 정지 영상에 대한 실험과 동영상에서의 얼굴 인식 실험을 통해 기존의 얼굴 인식 방법에 의한 얼굴 인식을보다 제안한 방법이 향상된 얼굴 인식을 보임을 입증하였다. 또한, LVQ 신경망 학습 과정에서 K-Means 알고리즘의 적용하여 빠른 학습 수렴 속도를 보였다.


향후 연구 과제로는 얼굴 명암의 심한 변화와 얼굴 모션의 많은 변화가 있는 영상에 대해 LVQ2 알고리즘을 적용하는 방안에 관한 연구가 필요하며, 실시간 적용 시 주변 환경에 영향을 줄이기 위한 방안과 인식률을 높이기 위한 방안에 관한 보강된 연구가 필요하다.

참 고 문 헌

- [1] M. Kaneko, O. Hasegawa, "Processing of Face Image and Its Application.", IEICE Trans. Int., vol. E82-D, no. 3, 1999.
- [2] W. Zhao, R. Chellappa, A. Resenfeld, "Face Recognition : A Literature Survey", ACM Journal of Computing Surveys, Vol. 35, pp. 399-458, 2003.
- [3] A.S. Tolba, A.H. El-Baz, and A.A. El-Harby, "Face Recognition: A Literature Review", International Journal of Signal Processing, Vol. 2, pp. 88-103, 2005.
- [4] A. S. Georghiades, P. N. Belhumeur, D. J. Kriegman, "From Few to Many : Illumination Cone Models for Face Recognition under Variable Lighting and Pose", IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 23, No. 6, pp. 643-660, 2001.
- [5] I. J. Cox, J. Ghosn, P. N. Yianilos, "Feature-based Face Recognition Using Mixture Distance", CVPR'96, pp. 209-216, 1996.
- [6] M. Turk, A. Pentland, "Eigenfaces for recognition", J. Cognitive Neuroscience, Vol. 3, pp. 71-86, 1991.
- [7] H.J. Moon and P.J. Phillips, "Computational and performance aspects of PCA-based face recognition algorithms", Perception, vol. 30, pp. 301-321, 2001.
- [8] J. Lu, K.N. Plataniotis, and A.N. Venetsanopoulos, "Face Recognition Using LDA-Based Algorithms", IEEE Trans. on Neural Networks, Vol. 14, No. 1, pp. 195-200, 2003.
- [9] G.L. Marcialis and F. Roli, "Fusion of LDA and PCA for Face Recognition", Proc. of the Workshop on Machine Vision and Perception, Association for Artificial Intelligence (AIIA'02), 2002.
- [10] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A Training Algorithm for Optimal Margin Classifier", In Proc. 5th ACM Workshop on Computational Learning Theory, pp. 144-152, 1992.
- [11] K. K. Sung and T. Poggio, "Example-Based Learning for View-Based Human Face Detection", IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 20, No. 1, pp. 39-51, 1998.
- [12] Steve Lawrence, C. Lee Giles, Ah Chung Tsoi, and Andrew D. Back, "Face Recognition: A Hybrid Neural Network Approach", Technical Report, UMIACS-TR-96-16 and

- CS-TR-3608, Univ. Maryland, 1996.
- [13] H. Fatemi, R. Kleihorst, H. Corporaal, and PP Jonker, "Real-Time Face Recognition on a Smart Camera", Proc. of ACIVS2003, pp. 222-227, 2003.
- [14] A.S. Tolba and A.N. Abu-Rezq, "Combined Classifiers for Invariant Face Recognition", Journal of Pattern Analysis and Applications, pp. 289-302, 2000.
- [15] T. Kohonen, J. Hunninen, J. Kangas, J. Kaaksonen, and K. Torkkola, "LVQ_PAK: The Learning Vector Quantization Program Package", Technical Report A30, Helsinki Univ., 1996.
- [16] S. AS "Face Recognition Using Hidden Markov Models" PhD Dissertation, Trinity College, University of Cambridge, UK, 1994.

● 저자 소개 ●



권 오 룬(Oh-ryun Kwon)

2005년 경기대학교 전자계산학과 졸업
2007년 경기대학교 대학원 전자계산학과 석사
2007년~현재 (주)한글과 컴퓨터 연구원
관심분야 : Vision-Based Animation, Motion Tracking, Face Recognition
E-mail : kor5663@hotmail.com



전 준 철(Jun-chul Chun)

1984년 중앙대학교 전자계산학과 졸업
1986년 중앙대학교 대학원 전자계산학과 석사(소프트웨어 공학)
1992년 The Univ. of Connecticut 컴퓨터공학과 석사(컴퓨터 그래픽스)
1995년 The Univ. of Connecticut 컴퓨터공학과 박사(컴퓨터 그래픽스)
2001년 미시건 주립대학 PRIP(Pattern Recognition. & Image Processing) 객원교수
1995~현재 경기대학교 전자계산학과 교수
관심분야 : 3D Face Modeling & Animation, Vision-Based HCI
E-mail : jcchun@kyonggi.ac.kr



민 경 필(Kyong-pil Min)

1996년 경기대학교 수학과 졸업
1998년 경기대학교 대학원 전자계산학과 석사
2005년 경기대학교 대학원 전자계산학과 박사(컴퓨터 그래픽스)
2005년~현재 (주) 휴민텍 책임연구원
관심분야 : 3D Face Modeling & Animation, Ubiquitous Computing
E-mail : buffalo21@hotmail.com