

논문 2004-41SP-5-20

아이겐공간에서 벡터 양자기를 이용한 얼굴인식

(Face Recognition using Vector Quantizer in Eigenspace)

임 동 철*, 이 행 세*, 최 태 영*

(Dong-Cheol Lim, Haing Sei Lee, and Tae Young Choi)

요 약

본 논문은 얼굴의 아이겐공간에서 벡터 양자화 기법을 이용한 얼굴 인식을 제안한다. 아이겐페이스 방법의 문제점은 하나의 아이겐페이스로 얼굴의 다양한 변이를 표현하기에 부족하다는데 있다. 이러한 약점을 극복하기 위해 제안된 방법은 아이겐페이스 공간에서 얼굴의 변이를 벡터 양자화 기법으로 군집화한다. 벡터 양자기는 학습과정을 통해 각 사람의 아이겐 페이스 집합을 양자화된 대표점들로 표현한다. 그리고 인식 과정을 통해 벡터 양자기는 얼굴 데이터 베이스에 저장된 대표점들과 입력된 얼굴 특징벡터와의 양자화 오차를 최소로 하는 대표점을 찾는다. 실험은 Faces94 데이터베이스에서 600장의 얼굴을 가지고 수행하였다. 실험 결과 기존의 아이겐페이스 방법은 최소 64개의 오인식을 하였고 제안된 방법은 코드북의 크기를 4개로 하였을 때 최소 20개의 오인식을 보였다. 결론적으로 제안된 방법은 얼굴의 변이를 수용하여 인식률을 향상시키는 효과적인 방법으로 사료된다.

Abstract

This paper presents face recognition using vector quantization in the eigenspace of the faces. The existing eigenface method is not enough for representing the variations of faces. For making up for its defects, the proposed method use a clustering of feature vectors by vector quantization in eigenspace of the faces. In the training stage, the face images are transformed the points in the eigenspace by eigenface(eigenvector) and we represent a set of points for each people as the centroids of vector quantizer. In the recognition stage, the vector quantizer finds the centroid having the minimum quantization error between feature vector of input image and centroids of database. The experiments are performed by 600 faces in Faces94 database. The existing eigenface method has minimum 64 miss-recognition and the proposed method has minimum 20 miss-recognition when we use 4 codevectors. In conclusion, the proposed method is an effective method that improves recognition rate through overcoming the variation of faces.

Keywords : vector quantization, face recognition, eigenface, mixture model

I. 서 론

얼굴 인식이란 얼굴 영상으로부터 변별력 있는 얼굴의 특징을 추출하여 비교 판별하는 방법을 말한다. 얼굴 인식에 관해 많은 방법들이 제안되어 왔다. 대표적인 알고리즘들은 아이겐페이스(Eigenface), Fisherface, Elastic Graph Matching, Support Vector Machine, Neural Network 등이다^[1]. 이들 방법들의 주된 관심사는 얼굴의 특징 추출과 패턴 정합, 이 두 가지 문제를 어떻게 해결하는 가이다^[2].

위의 방법 중 아이겐페이스는 효율성이 뛰어나 많이 사용되는 방법이다^[3]. 아이겐페이스는 주성분 분석(Principal Component Analysis, 이하 PCA)기법을 이용한다. 즉, 아이겐페이스는 얼굴 집합의 주성분 분석으로 생성된 아이겐 벡터를 통해 얼굴의 아이겐공간을 형성한다. 그리고 그 아이겐벡터 축에 얼굴을 사영(projection)시켜 얼굴의 특징 계수를 추출하고, 이렇게 형성된 얼굴 사이의 유사도를 판별함으로 패턴 정합을 하게 된다.

아이겐페이스 얼굴인식 방법은 데이터의 차원을 감소시켜 인식하는 방법이다. 이러한 차원의 감소로 인해 아이겐페이스는 계산량과 구현에 큰 장점을 가지지만 조명의 변화, 얼굴의 방향, 표정 변화 등의 심한 변이

* 정회원, 아주대학교 전자공학부
(Dept. of Electronic Engineering, Ajou University)
접수일자: 2004년3월22일, 수정완료일: 2004년8월7일

(variation)에는 인식률이 떨어지는 단점을 가진다. 이를 개선하기 위해 다양한 방법들이 제안되었다.

Fisher Linear Discriminant(FLD)는 Linear Discriminant Analysis(LDA) 방법을 이용하여 PCA의 단점을 개선한 방법이다. LDA 방법은 구분하고자 하는 군집간 산포도(between-class scatters)를 최대화하고 군집안 산포도(within-class scatters)는 최소화하는 방향으로 선형 분석을 한다^[16]. FLD는 직교하지 않는 사영(projection) 축을 생성하고 이는 변별력을 증가시키도록 형성된다. FLD에 의해 생성된 사영 공간은 Most Discriminating Features(MDF) 공간으로 불리며 충분한 데이터에 의해 생성된 경우, 아이젠페이지에 의해 생성되는 공간인 Most Expressive Features(MEF)보다 얼굴의 변이를 잘 나타내는 것으로 보고 되었다. LDA는 PCA의 단점을 개선하나 선형 분석이기에 군집 간 데이터가 다차원 공간상에 비선형적인 형태로 결합되어 존재할 경우, 분석에 어려움이 존재한다. 또한 FLD의 단점은 일반화를 위하여 많은 양의 데이터를 필요로 한다는 것이다. 이를 개선하기 위해 인공의 데이터를 생성하여 데이터 량을 증가시키는 방법이 제안되고 있다^[10].

Kambhatla와 Leen은 PCA의 선형 확장 방법으로 Vector Quantization PCA (VQPCA)를 제안하였다^[4]. 이 방법은 비선형적 형태로 초공간상에 존재하는 데이터의 군집들을 Local PCA에 의해 지역적으로 클러스터링한다. 그리고 이렇게 군집화된 지역은 초공간에서 근사적으로 선형 모델링된 것으로 볼 수 있다. VQPCA는 얼굴 합성에 있어 얼굴 재구성 오차를 줄이는 장점을 가지나 얼굴 인식의 구성에는 여러 문제점을 나타낸다. 우선 VQPCA는 지역적 PCA를 수행하므로 전체 데이터 집합에 대한 주성분을 표현하지 못하게 된다. 즉, 얼굴인식은 얼굴에 대한 전역적 PCA 분석을 기반으로 동작함에 반하여 VQPCA는 데이터의 차원을 감소시키기 전에 군집을 분할함으로 전역적 얼굴 정보의 손실을 가져오는 문제점이 있다. 또한 VQPCA는 데이터의 거대한 전체 차원에 대해 벡터 양자화를 적용하므로 학습에 많은 시간을 소모하게 되고 계산량과 저장 공간이 인식기 구현에 문제가 된다.

이 문제를 해결하기 위해 Tinppping과 Bishop은 PPCA(Probabilistic PCA)와 그의 조합을 사용하였다^[5]. 이에 더 나가 유사한 개념으로 2002년에 Kim 등은 가우시안 조합을 사용하는 방법을 제안하였다^[6]. Kim의 방법은 확률적 접근법을 사용하여 아이젠페이지의 가우시안 조합을 사용한 것이다. 이와 유사한 확률적 방법으로

MPC(mixture of principal components)가 발표되었다^[7]. 확률적 방법들은 확률적 파라미터를 사용함으로 적절한 통계적 확률 분포를 형성할 수 있는 데이터의 집합이 필요하며 확률적 제약이 따른다.

이 밖에 PCA의 비선형 확장 방법으로 Hastie와 Stuetzle은 새로운 principal surface를 제안하였다^[15]. 이 비선형 확장에 Oja와 Kung과 Diamantaras등은 신경망을 사용한 방법들을 제안하였다^{[11][12]}. 이외에 다른 비선형 확장으로 Multi-Dimensional Scaleing(MDS), Locally Linear Embedding(LLE)등이 있다^{[13][14]}. 비선형 확장 기법의 일반적 문제점은 계산량이 방대하고 수식의 가역적 변환에 어렵다는 것이다.

본 논문은 얼굴의 변이를 수용하는 PCA의 확장 방법으로 주성분 분석 벡터 양자기(PCA Vector Quantization, 이하 PCAVQ) 방법을 제안하였다. 본 논문에서 제안한 PCAVQ의 동작 개요는 다음과 같다. 우선 PCAVQ는 얼굴의 변이를 포함하고 있는 데이터 집합을 아이겐 공간상에 사영하고 학습과정을 통해 얼굴의 특징벡터 집합의 대표점을 구한다. 그리고 이 집합이 존재하는 아이겐공간상에서 미지의 영상과 대표점 간의 유사도를 벡터 양자기를 통해 판별하고 인식을 수행한다.

실험 결과 제안된 PCAVQ는 기존의 PCA 방법보다 인식률에서 우수한 성능을 나타내었다. PCAVQ는 다음과 같은 성질을 가진다. PCAVQ는 아이겐공간상에서 비선형 분포를 가지는 얼굴의 군집을 대표하는 벡터 양자기를 사용함으로 PCA보다 얼굴의 변이를 잘 수용할 수 있다. 둘째, PCAVQ는 데이터의 차원이 압축된 아이겐공간상에서 벡터 양자화를 수행함으로 작은 계산량으로 벡터 양자기를 구현할 수 있다. 셋째, 기존의 통계적 확장 방법과 달리 벡터양자기를 통한 접근은 통계적 제약이 적어 구현에 장점이 있다.

본 논문의 구조는 다음과 같다. 제 II장은 기존의 아이젠페이지 방법에 대해 기술한다. 제 III장은 벡터 양자기에 대해 고찰한다. 제 IV장은 PCAVQ의 동작원리와 인식 알고리즘에 대해 설명한다. 제 V장은 실험의 구성과 결과를 제시하고 분석한다. 제 VI장에서는 결론을 맺는다.

II. 아이젠페이지

아이젠페이지는 Sirovich 와 Kirby에 의해 1987년 PCA의 응용으로 처음 제안되었다. 아이젠페이지는 얼

굴을 주된 변이를 담고 있는 적은 수의 아이겐 벡터(eigen vector)로 표현할 수 있다는 것이다. 그들은 PCA로부터 얻어진 아이겐 벡터의 가중합으로 얼굴을 근사시켜 재구성하였다. Pentland 와 Turk는 1991년에 얼굴의 검출과 처리과정을 더하여 주된 얼굴인식 알고리즘을 제안하였다. 이들은 아이젠페이지스로 알려진 아이겐 벡터를 이용하여 얼굴 인식에 사용하였다. 다음은 아이젠페이지스의 개략적 설명이다.

아이젠페이지스는 공분산 행렬 C 의 아이겐벡터와 아이겐상수를 발견하는 것으로 동작한다. 이때 공분산 행렬 C 는 $\{X_1, X_2, \dots, X_m\}$ 으로 구성된 m 개의 얼굴 영상으로부터 생성된다. 얼굴의 공분산 행렬은 주성분 분석에 의해 다음과 같이 나타낼 수 있다. 그리고 이로부터 아이겐벡터(아이젠페이지스) u_j 와 이와 관련된 아이겐상수 λ_j 를 구할 수 있다.

$$Cu_j = \lambda_j u_j \quad j = 1, \dots, n \quad (1)$$

m 개의 영상으로부터 구해진 아이젠페이지스를 $\{E_1, E_2, \dots, E_m\}$ 라 하자. 그러면 미지의 얼굴 영상 I 는 다음과 같이 E_k 축으로의 사영된 W_k 로 표현할 수 있다. 여기서 Ψ 는 평균 얼굴 행렬이다.

$$W_k = E_k^T (I - \Psi) \quad k = 1, 2, \dots, m \quad (2)$$

여기서 W_k 는 k 번째 아이젠페이지스로 사영된 값으로 실수로 표현된다. 그래서 미지의 얼굴 영상 I 에 대해 얼굴의 특징 벡터

$$W^{(I)} = [W_1, W_2, \dots, W_m]^T \quad (3)$$

를 생성하게 된다. 이때 $W^{(I)}$ 를 형성하는 공간을 아이젠크간이라 한다. 얼굴간의 거리척도 $d_{PCA}(I, J)$ 는 다음과 같이 정의 된다.

$$d_{PCA}(I, J) = |W^{(I)} - W^{(J)}| \quad (4)$$

여기서 $W^{(I)}$ 는 미지의 얼굴 영상 I 의 특징벡터이고 $W^{(J)}$ 은 데이터베이스에 저장되어 있는 기준 얼굴 영상이다. 각각의 특징 벡터 W 는 아이젠크간상에 하나의 점으로 나타난다. 결국 아이젠페이지스는 이 얼굴간 거리가 가장 작은 얼굴을 인식된 결과로 나타내는 방법이다.

III. 벡터 양자기

벡터 양자기는 벡터 공간 $R = \{R_j, j = 1, \dots, m\}$ 에 존재하는 벡터 집합 T 를 제한된 집합인 C 로 사상(mapping)하는 것을 말한다^[8].

$$Q : T \rightarrow C, C = \{\theta_1, \theta_2, \dots, \theta_m\}, \theta_i \in T \quad (5)$$

이렇게 정의된 벡터 양자기의 성능의 평가를 위해서 양자화 오차는 다음과 같이 정의된다.

$$D(Q) = \sum_{i=1}^m D_i(Q) \quad (6)$$

$$D_i(Q) = \int_{R_i} d(x, Q(x)) p(x) dx \quad (7)$$

여기서 $d()$ 는 거리 척도로 유clidean 거리 등을 사용한다. 그리고 $p(x)$ 는 R 에 존재하는 x 의 확률 밀도 함수를 의미한다.

벡터 양자기가 최소의 양자화 오차를 갖기 위해서는, 즉, 최적 벡터 양자기가 되기 위해서는 다음의 두 가지 필요조건이 성립해야 한다.

첫째로, 벡터 양자기의 부호기의 측면에서 T 는 주어진 θ_j 에 의해 벡터 공간 R 을 분할한 영역 $R_j, j = 1, 2, \dots, m$ 에 속한 벡터 집합들로 나누어질 수 있다. 그리고 분할된 T 의 집합에 대해 θ_j 가 최적 양자점이 되기 위해서는 최근접 이웃 조건(nearest neighbor condition)이 필요하다. 즉, 고정된 C 에 대해서

$$d(x, \theta_j) \leq d(x, \theta_k), (k = 1, \dots, m), \quad (8)$$

이 성립하도록 $Q(x) = \theta_j$ 가 되어야 한다.

둘째로, 벡터 양자기의 복호기의 입장에서 최적화되기 위해서는 무게 중심 조건(centroid condition)이 필요하다. 즉, 코드벡터가 가지는 고정된 분할 지역인 $R_j, j = 1, \dots, m$ 에 대해서 각각의 코드 벡터 θ_j 는 아래 조건이 성립하는 $\theta_j = y$ 이다. 즉,

$$\int_{R_j} d(x, \theta_j) p(x) dx = \min_y \int_{R_j} d(x, y) p(x) dx \quad (9)$$

이다.

최적 벡터 양자기가 되기 위한 두 가지 필요 조건을 만족시키기는 해는 해석적인 방법으로 구할 수 없다.

이의 해결책으로 반복적 계산 방법인 로이드 알고리즘(LBG 알고리즘)이 제안되었고, 이는 일반화된 하드 클러스터링 알고리즘인 K-means 알고리즘에 해당한다^[9].

IV. 주성분 분석 벡터 양자기

본 장은 PCAVQ 방법의 동작 원리를 설명하고 구체적 알고리즘을 제시한다. 제 1절에서는 그림 1과 설명을 통해 아이젠페이스 방법이 변이에 약한 원인을 분석한다. 그리고 그림 2와 설명을 통해 PCAVQ가 아이젠페이스 방법보다 변이를 수용할 수 있음을 보인다. 마지막으로 그림 3과 설명을 통해 PCAVQ의 구조를 개략적으로 설명한다. 제 2절에는 PCAVQ 학습 알고리즘을 3절에서는 PCAVQ 인식 알고리즘을 기술한다.

1. PCAVQ의 동작 원리

그림 1은 아이겐공간상에 존재하는, 얼굴표정의 변이를 가진 특징벡터들을 투영하여 표시한 것이다. 그림 1의 데이터들은 실제 실험에 사용되었다. 그림 1의 각 평면은 아이겐공간의 초평면을 표시할 수 없어 아이젠페이스 4개 차원을 2차원씩 투영한 것이다. 그림 1의 각 점은 각 얼굴 영상을 아이젠페이스(아이겐벡터)로 사영하여 나타난 아이겐공간상의 값이다. 그리고 그림 1의 네 종류의 도형은 아이겐 공간상에 표현된 4명의 얼굴 영상에 대한 4차원 특징 벡터 값이다. 도형들은 종류 별로 20개씩 표시되어 있다. 그림 1에서 각 얼굴을 대표하는 도형들은 아이젠페이스를 기저(basis)로 하는 아이겐공간상에 얼굴의 변이에 따라 특징벡터 분포를 형성하는 군집을 이루고 있다.

기존의 아이젠페이스 방법은 각 사람 얼굴 간 변이에 의한 거리가 한 사람 얼굴 안에서의 변이에 의한 거리보다 크다는 점을 이용하여 하나의 특징 벡터를 선택하여 인식하게 된다. 그러나 기존의 아이젠페이스 방법이 변이에 약한 사실은 그림 1에서 명백히 드러난다. 그림 1에서 동그라미와 역삼각형은 거의 겹쳐져 있는 경우도 있으며 한 종류의 도형이 다른 종류의 도형 군집에 가까운 경우가 많다. 그런 경우 같은 도형간 거리보다 다른 도형과 더 근접한 거리 값이 발생하게 되고 이는 오인식의 원인이 된다.

여기서 주지할 사실은 한 사람의 얼굴 내 변이와 각 사람 간 얼굴의 변이가 같은 분포를 이루지 않고 변별력 있는 군집을 형성한다는 것이다. 그러므로 벡터 양자기를 이용한 인식방법을 사용하면 변이에 약한 기준

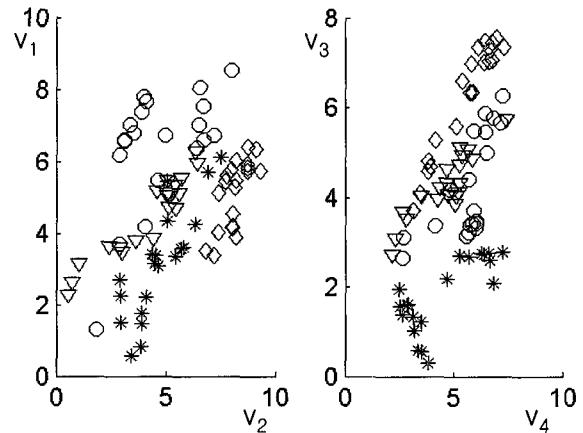


그림 1. 아이겐공간 4개의 차원에 표시된 특징벡터 집합들

Fig. 1. Groups of feature vectors exist in eigenspace of 4 dimensions.

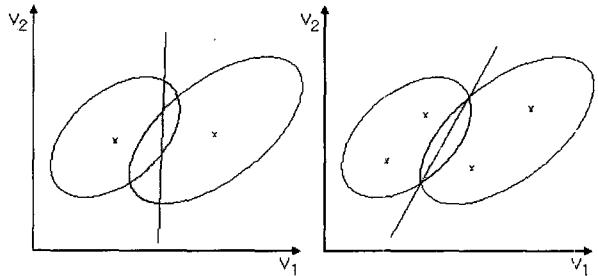


그림 2. PCA와 PCAVQ의 오인식 영역 비교

Fig. 2. Comparison of miss recognition region between PCA and PCAVQ.

의 아이젠페이스 방법의 약점을 극복할 수 있다. 최적 벡터 양자기는 군집의 분포를 대표하는 코드북을 생성하고 이를 이용하여 입력 신호들에 대해 기존의 군집과의 유사도를 평가한다. 이런 성질을 이용해 인식기로 사용할 수 있다. 최적 벡터 양자기는 분포가 다른 두 개의 군집이 겹쳐져 존재하더라도 입력 신호의 분포와 군집 간의 유사도를 평가해 변별하는 인식 성능까지 가진다.

그림 2는 아이겐공간에서 벡터 양자화를 적용한 예를 개념적으로 설명하기 위한 그림이다. 각 타원은 아이겐공간상에서 얼굴의 변이에 의해 발생되는 군집들을 나타낸다. 그림 2의 원편 평면의 회색 영역은 기존의 아이젠페이스 기법에서 오인식이 발생하는 영역이다. 그림 2의 오른편 평면의 회색 영역은 벡터 양자기를 이용하여 분포를 대표하는 대표점을 구하고 이를 통하여 인식할 경우 오인식이 발생하는 영역을 나타내고 있다. 그림에서 보는 바와 같이 군집의 분포를 대표하는 벡터 양자기를 사용하면 군집 간 변별력을 높여 오

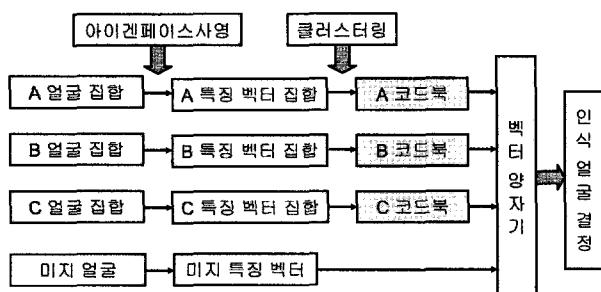


그림 3. PCAVQ 시스템의 구조

Fig. 3. The structure of PCAVQ system.

인식을 줄일 수 있다. 더나가 벡터 양자기는 입력 신호가 분포를 형성하기에 충분할 경우 두 군집이 겹쳐지더라도 분포 간 유사도를 평가하여 어느 군집에 속하는지를 인식해 낼 수 있다.

제안된 PCAVQ는 학습과정을 통해 아이젠풍간상에서 각 사람의 얼굴 집합의 분포를 대표하도록 최적화된 벡터 양자점을 생성한다. 이후에 미지의 입력 영상은 아이젠풍간상의 점으로 변환되고 각각의 얼굴의 분포를 대표하는 양자점들과 양자화 거리들을 계산한다. 이렇게 구해진 거리들은 각 얼굴 분포에 최적이 되는 유사도를 의미하게 된다. 최종적으로 가장 작은 양자화 거리를 갖는 분포의 양자점이 선택되고 이 분포의 얼굴을 인식된 얼굴로 결정하게 된다.

기존의 아이젠페이지 방법은 얼굴간 거리가 얼굴 내 변이의 거리보다 먼 경우에 한정되어 인식이 가능하며 선형 분석이기 때문에 비선형적인 얼굴의 변이를 수용하기에 어려운 단점이 생긴다. 이와 달리 제안된 PCAVQ는 아이젠풍간상에 생성된 특징 벡터 집합을 군집화한 벡터 양자점을 이용하여 학습과 인식을 수행한다. 이 사실은 제안된 PCAVQ가 아이젠풍간상에 변이의 군집을 대표하는 여러 개의 특징벡터를 비선형적으로 생성한다는 것을 의미한다. 따라서 PCAVQ는 PCA보다 얼굴의 변이를 잘 수용할 수 있는 장점이 생긴다. 그리고 제안된 PCAVQ는 전역적 얼굴정보를 나타내는 압축된 데이터 공간인 특징벡터 공간상에서 벡터 양자화를 수행한다. 그러므로 전역적 얼굴 정보를 손실하지 않고 작은 계산량으로 벡터 양자화가 가능하다. 또한 기존의 통계적 확장 방법과 달리 벡터 양자기를 통한 접근은 확률적 구성에 민감하지 않고 통계적 제약이 적어 구현에 장점이 있다.

그림 3은 제안된 PCAVQ 시스템의 구조를 보여준다. 각 얼굴 집합과 미지얼굴에 대해 아이젠페이지로 사영하여 특징벡터를 구하고 학습과정을 거쳐 생성된 각 얼

굴의 코드북과 미지 특징벡터와의 오차를 구하여 인식 얼굴을 결정하게 된다. 본 논문은 벡터 양자화 기법으로 하드 클러스터링 방법인 K-means를 사용하였다.

2. PCAVQ 학습 알고리즘

- 1) 아이젠풍간의 기저(basis)가 되는 아이젠페이지 E_1, E_2, \dots, E_m 를 계산한다. 여기서 m 은 아이젠페이지의 개수이다. 즉, 아이젠풍간의 차원을 나타낸다.
- 2) 학습하고자 하는 전체 얼굴 집합 $T^{(ij)}$ 의 모든 원소에 대해서 각각의 아이젠페이지 E_1, E_2, \dots, E_m 에 사영한 $W^{(ij)} = \{W_1^{(ij)}, W_2^{(ij)}, \dots, W_m^{(ij)}\}$ 를 구한다. 여기서 $i = 1, \dots, I$ 는 기준 얼굴의 개수, $j = 1, \dots, J$ 는 각 얼굴 변이의 개수이다.
- 3) 각 얼굴 집합 $\{W_j^{(i)}, j = 1, \dots, J\}, i = 1, \dots, I$ 에 대해 K-means 알고리즘을 적용시켜 코드 벡터 집합 $C^{(i)} = \{C_1^{(i)}, C_2^{(i)}, \dots, C_K^{(i)}\}, i = 1, \dots, I$ 를 생성한다. K 는 코드북의 크기이다. 이때 $C^{(i)}$ 의 k 번째 원소인 코드벡터 $C_k^{(i)}$ 는 아이젠풍간상의 값 $\{c_1^{(i)}, \dots, c_m^{(i)}\}$ 으로 구성된다.

3. PCAVQ 인식 알고리즘

- 1) 미지의 영상 T 에 대해 아이젠페이지 사영을 통하여 $W^{(T)} = \{W_1^{(T)}, \dots, W_m^{(T)}\}$ 를 구한다.
- 2) 구해진 $W^{(T)}$ 에 대하여 벡터 양자기의 부호기를 통해 최근접 이웃 조건을 만족하도록 즉, $d(C_l^{(i)}, W^{(T)}) \leq d(C_p^{(i)}, W^{(T)})$, 가 성립하는 ($p = 1, \dots, K$), $l \neq p$ $C_l^{(i)}, i = 1, \dots, I$ 를 구한다. 즉, l 은 각 코드 벡터 집합 $C^{(i)}$ 의 원소들과 $W^{(T)}$ 사이에 최근접 이웃 조건을 만족하도록 각각의 i 마다 다른 값으로 선택된다.
- 3) 선택된 $C_l^{(i)}, i = 1, \dots, I$ 와 $W^{(T)}$ 사이에 최소 오차를 가지는 $C_l^{(i)}$ 의 인덱스 i 를 인식된 얼굴 Id (Identification)로 선택한다.

$$\text{즉, } Id = \underset{i}{\operatorname{argmin}} W^{(T)} - C_l^{(i)}$$

4) 인식된 얼굴 Id 의 검증을 위해 거리 $dffs$ (distance from face space)를 계산한다. 이 거리는 아이젠페이지 영역에서 영상이 떨어져 있는 정도를 의미한다.

$$dffs = | Y - Y_f |$$

여기서 $Y = I - \Psi$, $Y_f = \sum_{i=1}^m W_i^{(l)} E_i$ 이다.

5) If $dffs < Threshold1$

아이젠페이지 공간에 충분히 가깝다.

if $dffs < Threshold2$

T 는 Id 로 인식되며 이는 $i = 1, \dots, I$ 중 가장 가까운 얼굴 영상 번호이다.

else

T 는 미지의 얼굴 영상으로 분류된다.

else

얼굴 영상이 아니다.

V. 실험 결과

1. 실험의 구성

실험에 사용된 데이터베이스는 Libor SpaceK 의 Faces94를 이용하였다. 이 데이터베이스는 일정한 거리에서 S-VHS 비디오 카메라로 촬영된 영상에서 수집되었다. 저장된 형식은 180×200 크기의 24-bit 컬러 JPEG으로 구성되었다. 나이는 20대 초반이며 인종은 다양하다. 각 얼굴 영상은 얼굴 표현의 변이를 주기 위해 일정한 텍스트를 읽도록 되어있다. 얼굴의 성별은 남성과 여성 모두 존재하며 안경을 낀 얼굴도 포함되어



그림 4. 실험에 사용된 얼굴들의 예

Fig. 4. Example of the faces used for the experiment.

있다. 사진의 배경은 평탄한 초록으로 되어있다.

인식 실험에 사용될 사진은 그림 4에 주어진 30명으로부터 각 사람 당 20장씩 총 600장으로 구성되었다. 실험을 위하여 각 얼굴들은 그레이 색상으로 변환되었다. 아이젠페이지는 그림 4에 주어진 얼굴 중 3개에서 30개를 선택하여 변화시키면서 생성하여 구성하였다. 즉, 아이겐 공간의 차원을 3차에서 30차까지 변화시키면서 기존의 PCA와 비교 실험하였다. 각 사람의 얼굴의 군집화 하기 위한 훈련과정에는 4장($T=4$), 10장($T=10$), 20장($T=20$)의 얼굴을 변화시켜 사용하였다. 제안된 PCAVQ 방법은 2개($K=2$)의 코드벡터와 4개($K=4$)의 코드벡터를 가지도록 구성하였다. 즉, K-means 알고리즘의 K 개의 벡터 양자점을 2개와 4개로 구성하였다. 따라서 PCA가 3개의 아이젠페이지를 가질 때 PCAVQ는 $K=2$ 인 경우 6개의 아이젠페이지를 사용하게 되고 $K=4$ 인 경우 12개의 아이젠페이지를 사용하게 된다. 그리고 각각의 경우에 대해 전체 얼굴 집합에 대해 인식 실험을 하였다.

2. 결과 및 분석

실험 결과 제안된 PCAVQ는 모든 경우에 대해 기존의 PCA보다 우월한 인식률을 나타내었다. 그림 5는 아이젠페이지 개수 변화에 따른 인식률의 변화를 보여 주고 있다. 그림 5를 통해 결과를 살펴보면 PCA는 인식률이 85%대에 머무르고 있으며 불안정한 인식률을 나타낸다. 이에 반하여 PCAVQ는 아이젠페이지의 개수가

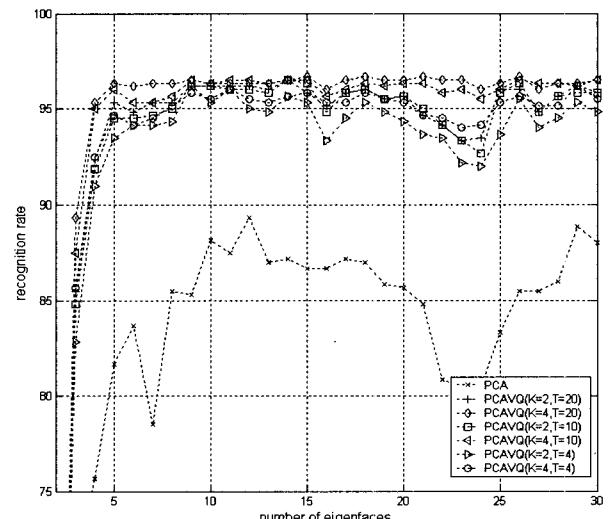


그림 5. 아이젠페이지 개수에 따른 인식률

Fig. 5. Recognition rate according to number of eigenfaces

5개 이상이 되면 평균 95%의 인식률로 모든 아이젠페이스 개수에 대해 안정적인 인식률을 나타내었다.

실험 결과를 분석하여 보면 다음과 같다. 우선 PCA의 오인식의 원인은 한 사람의 얼굴 표정 혹은 모양의 변이가 각 사람 얼굴 간 변이보다 아이젠풍간상에서 크기 때문이다. 또한 PCA가 불안정한 인식률을 나타내는 원인은 A의 얼굴을 B의 얼굴로 오인식 하면 해당 A의 얼굴들이 다발성으로 B의 얼굴로 오인식되는 경향이 있기 때문이다. 이에 반하여 PCAVQ가 PCA보다 우수한 인식률을 나타내는 이유는 아이젠풍간에서 한 사람 내의 얼굴 변이를 벡터 양자기가 수용하여 각 사람 간 얼굴 변이를 보다 더 크게 만들 수 있기 때문이다. PCAVQ가 아이젠페이스 개수의 변화에 대해 안정적인 인식률을 나타내는 이유도 얼굴의 변이를 적절히 수용하여 다발성 오인식이 감소하였기 때문이다.

PCAVQ간의 성능을 비교분석해보면 훈련 개수(T)가 많을수록 안정적이고 좋은 결과를 가져온다. 그런데 PCAVQ는 학습 개수가 4인 경우에도 학습하지 않은 데이터에 대해서 PCA보다 좋은 인식률을 나타내었다. 이 사실은 PCAVQ가 변이를 잘 수용하여 학습에 참여하지 않은 데이터에 대해서도 효과적으로 동작함을 보여준다. 그리고 코드벡터(K) 개수가 클수록 좋은 결과를 보여준다. 이것은 코드 벡터 개수가 커짐에 따라 군집 안 분포의 양자화 오차가 줄어들어 군집을 보다 잘 표현하기 때문이다.

계산량과 저장 공간의 측면에서 성능 비교를 위하여 같은 개수의 아이젠페이스를 사용하였을 때의 인식률 비교에서도 PCAVQ는 PCA보다 우수한 성능을 보여준다. PCAVQ의 인식률 향상은 반대급부로 저장 공간과 계산량이 증가를 가져올 수 있다. 그러나 저장 공간은 얼굴 특징 계수의 크기를 고려할 때 미미하며 계산량 증가 또한 인식률의 향상을 고려할 때 허용되는 수준이다.

VI. 결 론

이 논문에서 우리는 PCAVQ 방법을 제안하였다. 또한 제안한 PCAVQ는 벡터 양자기를 통하여 아이젠풍간 상의 특징벡터 집합을 군집화 함으로써 얼굴인식 성능을 개선시킴을 설명하였다. 실험결과, PCAVQ 방법은 얼굴인식에 있어 기존의 PCA 방법보다 우수한 성능을 나타내었다. PCAVQ 방법은 압축된 데이터 공간인 아이젠풍간상에서 벡터 양자기를 통해 얼굴의 변이를

수용함으로서 작은 계산량으로 학습과 인식이 가능하다. 또한 벡터 양자기는 확률적 구성을 민감하지 않으므로 구현이 간편하다.

PCAVQ는 많은 량의 데이터가 주어질 경우 얼굴 군집 간 분포의 비교를 통해 효과적으로 인식기를 구성할 수 있을 것으로 사료된다. 즉, PCAVQ는 다양한 데이터에 대해 분포의 평가를 통한 인식을 수행할 수 있으므로 동영상과 같은 다양한 입력 정보로부터 학습하고 인식하기 적합할 것이다. 이는 추후 실험을 통한 검증이 필요하다.

향후 연구과제는 다수의 동영상을 통한 인식 시스템을 구현하는 것, 아이젠풍간상에서 표정, 인종, 성별, 등 의 변이를 분류하는 분류기로의 구조를 연구하는 것, PCA의 다른 확장 방법들과 성능을 비교 평가하는 것이다.

참 고 문 현

- [1] J. Zhang, Y. Yan and M. Lades, "Face Recognition: Eigenface, Elastic Matching, and Neural Nets," *Proceedings of the IEEE*, vol. 85, issue 9, pp. 1423-1435, Sept. 1997.
- [2] R. Chellappa, C. L. Wilson and S. Sirohey, "Human and machine recognition of faces: a survey," *Proc. of the IEEE*, vol. 83, no. 5, pp. 705-740, 1995.
- [3] M. A. Turk and A. P. Pentland, "Face recognition using eigenfaces," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition 1991*, pp. 586-591, Jun. 1991.
- [4] N. Kambhatla and T. K. Leen, "Dimension reduction by local principal component analysis," *Neural Computation*, vol. 11, no. 2, pp. 1493-1516, 1997.
- [5] M. Tipping and C. M. Bishop, "Mixtures of probabilistic principal component analyzers," *Neural Computation*, vol. 11, no. 2, pp. 443-482, 1999.
- [6] H. Kim, D. Kim and S. Y. Bang, "Face recognition using the mixture of eigenfaces method," *Pattern Recognition Letters*, vol. 23, pp. 1549-1558, 2002.
- [7] D. S. Turaga and R. Chen, "Face recognition using mixtures of principal components," *Proceedings. 2002 International Conference on Image Processing.*, vol. 2, pp. 101-104, Sept. 2002.
- [8] R. M. Gray and D. L. Neuhoff, "Quantization," *IEEE Trans. on Information Theory*, vol. 44, no. 6, pp. 2325-2383, Oct. 1998.

- [9] Y. Linde, A. Buzo and R. M. Gray, "An algorithm for vector quantizer design," *IEEE Trans. Commun.*, vol. COM-28, pp. 84-95, Jan. 1980.
- [10] K. Etemad and R. Chellappa, "Discriminant Analysis for Recognition of Human Face Images," *J. Optical Soc. Am. A*, vol. 14, pp. 1,724-1,733, 1997.
- [11] E. Oja, "Neural networks, principal components and subspaces," *International Journal of Neural Systems*, vol. 1, pp. 61-68, 1989.
- [12] S. Y. Kung and K. I. Diamantaras, "A neural network learning algorithm for adaptive principal component extraction (APEX)," *Proc. of the IEEE ICASSP*, pp. 861-864, 1990.
- [13] T. Cox and M. Cox, *Multidimensional Scaling*, Chapman and Hall, London 1994.
- [14] S. T. Roweis and L. K. Saul, "Nonlinear dimensionality reduction by locally linear embedding," *Science*, vol. 290, pp. 2323-2326, Dec. 2000.
- [15] T. Hastie and W. Stuetzle, "Principal curves," *Journal of the American Statistical Association*, vol. 84, pp. 502-516, 1989.
- [16] Aleix M. Martinez and Avinash C. Kak, "PCA versus LDA," *IEEE Trans. on PAMI*, Vol. 23 no. 2, Feb. 2001.

저자소개



임 동 철(정회원)
 1996년 아주대학교 전자공학
 학사 졸업
 1996년 LG 반도체 근무
 1999년 아주대학교 전자공학
 석사 졸업
 1999년 ~ 현재 아주대학교
 전자공학부 박사 수료

<주관심분야: 음성 및 영상신호처리, 패턴인식>

이 행 세(정회원)
 제38권 SP편 제1호 참조

최 태 영(정회원)
 제39권 SP편 제1호 참조