

웨이브릿 변환과 PCA/LDA를 이용한 얼굴 인식

Face Recognition using wavelet transform and PCA/LDA

송영준, 김영길, 문성원, 권혁봉*
충북대학교, 김포대학*

Song young-jun, Kim young-kil, Mun Sung-won,
Hong sam-dong*

Chungbuk Univ., Kimpo Col.*

요약

최근 보안 시스템 분야에서 컴퓨터 기술의 발전으로 얼굴 인식에 대한 관심이 높아지고 있다. 얼굴 인식은 기하학적 특징을 이용하는 방법과 통계적 특징을 이용하는 방법이 있다. 본 연구는 정면 얼굴에 대한 대수적인 방법이다. 제안 방식은, 웨이브릿 변환을 통한 k 단계의 LL, LH, HL 부대역을 구하고, 이를 PCA/LDA를 적용하여 얼굴 인식을 하였다. 전체 영상에 대한 얼굴 인식률에 비해 웨이브릿 변환을 이용한 부대역 영상에 대한 얼굴 인식률이 더 높음을 보여준다.

Abstract

It was recently focus to face recognition at a security system according to development of computer. The face recognition has method using geometrical feature and one using statistical feature. The proposed method uses k level LL, LH, HL, HH subband images adopting wavelet transform. And, we adopt PCA/LDA to subband images. As a result of simulation, recognition rate of subband images using wavelet transform is more high than one of full size image.

I. 서론

최근 보안 시스템 및 인증 분야에서 컴퓨터 기술의 발전으로 얼굴 인식에 대한 관심이 높아지고 있다. 특히 생체 인식 분야에서는 지문인식, 홍채 인식에 이어 얼굴 인식이 최종 인증 분야로 연구되어지고 있다. 사람들이 다른 사람을 만나게 될 때, 누구인지를 알아보는 기준은 90% 이상이 상대방의 얼굴을 보고 알아보게 된다. 얼굴 인식의 장점은 다른 생체 인식 기술이 사용자로 하여금 일정한 동작을 취하도록 요구하는 것과 달리 사용자의 특별한 동작이나 행위에 대한 요구가 없이 비접촉식으로 인식할 수 있다.

얼굴 인식에 사용되는 알고리즘은 초기에는 얼굴의 국부적인 기하학적 특징을 이용하거나, 템플릿 매칭

을 적용하는 방법[1]이 있었으나, 조명 변화나 표정 변화를 갖는 얼굴 영상을 인식하기 위해서는 많은 훈련 영상으로 인한 메모리양과 계산 시간이 문제가 되어 왔다. 이를 극복하기 위해 하나의 얼굴 영상을 벡터 공간상의 하나의 특징 벡터들로 변환하여 입력 얼굴 영상의 특징 벡터와 인식 대상 얼굴의 특징 벡터들을 비교함으로써 얼굴을 인식하는 방법이 연구되어 왔으며, 대표적인 방법으로 PCA(Principle component analysis)와 LDA(Linear discriminant analysis)가 있다[2-3].

얼굴 인식에 사용된 데이터베이스는 ORL 데이터베이스이고 제안 방법은 먼저 입력 영상을 k 레벨 웨이브릿 변환하여 14x11 크기의 저주파 대역을 구한 후, 이를 PCA/LDA를 적용하여 가장 유사한 영상을

찾는다. 또한 LH, HL, HH 대역의 에너지 값을 특징 벡터로 추가하여 인식한다.

본 논문의 구성은 2장에서 기존의 PCA/LDA의 이론에 대하여 기술하고, 3장에서는 웨이브릿 변환을 이용한 PCA/LDA 기법에 대하여 설명한다. 그리고 4장에서 시뮬레이션 결과를 보여주고, 마지막으로 결론을 맺는다.

II. PCA와 LDA

1. PCA

PCA의 적용 과정은 2차원의 학습 영상을 1차원의 벡터로 변환하는 것이 우선이다. 1차원으로 변환된 N 개의 학습 영상에 대하여 학습 영상의 집합을 $\Phi = [\Phi_1, \Phi_2, \dots, \Phi_N]$ 로 표기하고 각 영상으로부터 평균 영상 벡터 $\bar{\Phi}$ 를 뺀 영상의 집합을 $X = [\Phi_1 - \bar{\Phi}, \Phi_2 - \bar{\Phi}, \dots, \Phi_N - \bar{\Phi}]$ 으로 표기한다. 이 식에서 $x_N = \Phi_N - \bar{\Phi}$ 라 하고 X 의 집합을 다시 기술하면, 식 (1)과 같다.

$$X = [x_1, x_2, \dots, x_N] \quad (1)$$

scale factor $1/N$ 을 생략하면 공분산은 식 (2)와 같이 주어진다.

$$\sum x = \sum_{i=1}^N x x_i^t = XX^t \quad (2)$$

$\sum x$ 의 고유값과 고유벡터인 Λ 와 Ψ 는 식 (3)과 같은 관계를 갖는다.

$$(XX^t)\Psi = \Psi\Lambda \quad (3)$$

식 (3)의 양변에 X^t 를 곱하고, 행렬 X^tX 의 고유값과 고유벡터를 Λ' 와 V 라 하면 식 (4)와 같이 된다.

$$(X^tX)V = V\Lambda' \quad (4)$$

이 식의 양변에 X 를 곱하면 식 (5)와 같다.

$$X(X^tX)V = (XX^t)(XV) = (XV)\Lambda' \quad (5)$$

고유값의 크기가 큰 순으로 정렬했을 때, p 개의 고유 벡터로 구성된 식 (6)에 의해 구할 수 있다.

$$W_{PCA} = [XV_1, XV_2, \dots, XV_p] \quad (6)$$

결국 주성분 분석은 데이터 샘플이 표현하고 있던 분산이 최대가 되도록 새로운 축을 만들고, 이러한 축들은 서로 직교하게 됨으로서 상위 몇 개의 축에 의해서 표현되는 값은 입력 벡터가 담고 있는 대부분의 정보를 담게 된다.

2. PCA/LDA

LDA는 클래스 정보를 사용하여 동일 부류에 속한 데이터는 서로 모이고, 다른 부류에 속한 데이터는 되도록 분리가 잘 되도록 저차원 공간으로 축소하는데 목적을 두고 있다[4-5].

LDA를 수행하기 위해 먼저 클래스 내부 분산 행렬(within-class scatter matrix; S_w) 및 클래스간 분산 행렬(between-class scatter matrix; S_b)을 각각 식 (7)과 식 (8)로 정의한다.

$$S_w = \sum_{j=1}^{N_c} \sum_{i=1}^{N_j} \Pr(C_j) E[(x_i^j - \mu_j)(x_i^j - \mu_j)^t] \quad (7)$$

$$S_b = \sum_{j=1}^{N_c} \Pr(C_j) (\mu_j - \mu)(\mu_j - \mu)^t \quad (8)$$

여기서, x_i^j 는 식 (6)에서 구해진 j 번째 클래스에 있는 i 번째 영상의 PCA에 의한 투영 벡터를 의미한다. μ 는 PCA에서 구해진 P 차원 투영 벡터의 전체 평균 벡터를 나타내고, μ_j 는 P 차원 투영 벡터의 j

번째 클래스의 평균 벡터를 나타낸다. 결국 식 (9)에서 $J(W)$ 의 값을 최대화 하는 투영 행렬 W 를 구해 클래스간 분산은 최대화, 클래스내 분산은 최소화 하게 하도록 한다.

$$J(W) = \frac{|W'S_b W|}{|W'S_w W|} \quad (9)$$

고유값의 크기가 큰 순서부터 정렬했을 때 q 개의 고유벡터로 구성된 행렬을 식 (10)과 같이 구할 수 있다.

$$W_{LDA} = [\mu_1, \mu_2, \dots, \mu_q] \quad (10)$$

III. 웨이브릿 변환을 이용한 PCA/ LDA

본 논문에서는 9/7탭 웨이브릿 변환[6]을 3 레벨까지 적용된 LL 대역에 대하여 PCA/LDA 방법이 적용된다. 따라서, 웨이브릿 변환시 제로 패딩 기법을 사용하여 3 레벨의 LL 대역의 영상을 14×11 의 크기로 만들어 사용한다.

제로 패딩 기법은 웨이브릿 변환이 2의 멱제곱 형태의 크기로 다운샘플링됨으로써, 이 크기에 맞지 않으면 손실이 발생하게 된다. 따라서 가로 세로의 크기가 2의 멱제곱 형태가 되지 않을 경우 부족한 데이터를 0으로 채워 다운샘플링 하는 기법을 말한다.

본 논문에서 사용할 얼굴 데이터가 112×92 의 크기이므로 1 레벨에서 56×46 , 2 레벨에서 28×23 으로 2의 멱제곱으로 구성되지 않는 부분이 발생한다. 따라서 부족한 데이터를 0으로 채워 28×28 의 크기로 영상을 재구성한 후 3 레벨 LL 대역 영상을 구한다. 이때, 14×14 의 크기로 웨이브릿 변환 후 영상에서 이전 단계에서 패딩했던 0의 데이터를 없애야 한다. 보편적으로 웨이브릿 변환을 하면 가로와 세로 각각 1/2씩 크기가 줄어들게 된다. 따라서 최종 LL 대역의 영

상의 크기는 14×11 이 되고 이 영상을 웨이브릿 변환 후 얼굴 인식에 사용되는 실험 영상으로 사용한다.

3 레벨 웨이브릿 변환된 LL 대역의 영상은 PCA를 적용하여 고유 얼굴을 구하여 값이 큰 순으로 40개의 고유 얼굴을 배열한다. 40개의 고유 얼굴에 대해 투영된 투영 벡터를 LDA의 입력으로 하여 fisher face을 구해 크기순으로 정렬한다. 정렬된 fisher face에서 20개를 추출하여 투영된 결과를 데이터베이스에 저장한다. 또한 LH, HL, HH 대역은 각각 얼굴의 예지 성분을 보여주므로 3개의 에너지 벡터 값을 데이터베이스에 저장한다.

IV. 시뮬레이션 결과

본 논문에서는 얼굴 인식 성능 평가를 하기 위해 Olivetti Research Lab(ORL)의 얼굴 데이터베이스를 사용하였다. 총 400장의 얼굴로 구성되어 있으며, 40명에 대해 10장씩 각각 약간의 포즈 변화, 명암 변화, 표정 변화가 있다. 배경은 없고, 전체 영상이 얼굴 전체 영역을 다 포함하고 있으며, 일부 영상이 선글라스, 콧수염, 안경 등과 같이 얼굴의 구성 요소를 가릴만한 요소도 있다.

또한 훈련 영상과 질의 영상 구분은 Hold and out 방법을 사용하였다. 이 방법은 각 클래스별 동일한 수의 훈련 영상과 질의 영상을 사용한다. 본 논문에서는 한 명당 10장의 얼굴 영상이 있으므로, 5장은 훈련 영상으로 나머지 5장은 질의 영상으로 사용한다. 40명에 대해 모두 적용하여 식 (11)과 같이 평균 인식률을 구해 성능을 평가한다.

$$R = \frac{N_R}{N_Q} \times 100 \quad (11)$$


여기서 N_R 은 인식되는 얼굴 영상 개수, N_Q 는 전체 질의 영상 개수, 그리고 R 은 인식률을 의미한다. 인식 정도는 질의 영상에 대해 해당 클래스의 일

굴 중 하나를 인식할 경우 인식된 것으로 평가하고, 다른 클래스의 얼굴을 인식하게 될 경우 오인식으로 간주한다. 질의 영상에 대한 훈련 영상의 인식 여부는 가장 일반적으로 사용되고 있는 식 (12)와 같은 유클리디언 거리를 이용하여 특징 벡터들간의 유사도를 측정하였다.

$$D(Q, T) = \sum_j |V_Q(P) - V_T(P)| \quad (12)$$

여기서 Q 는 질의 영상을 의미하고, T 는 훈련 영상, P 는 특징 벡터를 의미한다. 특징 벡터는 PCA/LDA에서 결정되는 특징들을 말한다.

그림 1의 경우에는 PCA/LDA 방법을 전체 영상과 웨이브릿을 적용한 3 레벨 LL 대역의 영상에 대해 적용한 경우의 인식 성능을 보여준다. 이때, PCA의 결과 차원 수는 40 차원으로 고정하였고, LDA의 결과 차원수에 따른 인식 성능을 비교하였다. 결과적으로 전체 영상에 비해 3 레벨 LL 대역에 대해 더 효과적으로 인식됨을 알 수 있다. 또한 아주 적은 수의 특징일 경우, LL 대역의 특징과 LH, HL, HH 대역의 에너지 특징 벡터를 함께 비교해주는 것이 효과적인 것을 알 수 있다.



▶▶ 그림 1. 특징 수에 따른 인식률 비교

V. 결론

본 논문에서는 전체 크기의 입력 영상에 대해 PCA/LDA 기법을 적용한 얼굴 인식 방법과 웨이브릿을 적용한 영상에 대한 PCA/LDA를 적용한 얼굴 인식의 성능을 비교하였다. 전체 얼굴 영상에 대한 얼굴 인식률에 비해 3 레벨 웨이브릿을 한 LL 영상에 대해 PCA/LDA를 적용한 것이 인식률이 좋았으며, 아주 적은 수의 특징 벡터로서 비교할 때에는 에너지 벡터를 추가하여 인식하는 것이 좋다.

추후 연구 과제는 LDA의 입력으로 사용되는 PCA의 투영 벡터 값의 최적 차원을 찾아 LDA를 적용하는 것과, 대수적인 방법과 기하학적 방법의 접목으로 인식률 향상을 꾀할 수 있을 것이다. 또한 웨이브릿 변환의 각 영역별 분산 정도에 따라 특징 벡터의 수를 최적화시키는 연구가 필요하다.

■ 참고문헌 ■

- [1] A. L. Yuille, D. S. Cohen and P. W. Hallinan, "Feature extraction from faces using deformable templates," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp.104-109, 1989.
- [2] A. M. Martinez and A. C. Kak, "PCA versus LDA," IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 29, pp.228-233, 2001.
- [3] M. H. Yang, "Kernel Eigenfaces vs. Kernel Fisherfaces : Face recognition Using Kernel Methods," Automatic Face and Gesture Recognition, 2002. Proceedings. Fourth IEEE International Conference on, pp.208-213, 2002.
- [4] C. Liu, H. Wechsler, "Enhanced fisher linear discriminant models for face recognition," 14th Int's Conf. on Pattern Recognition, ICPR'98, Brisbane, Australia, pp.17-20, 1998.
- [5] W. Zhao and R. Chellappa, "Discriminant analysis of principle components for face recognition," automatic Face and Gesture Recognition, 1998.
- [6] J. D. Villasenor, B. Bellzer, and J. Liao, "Wavelet filter evaluation for image compression," IEEE Trans. on Image Processing, vol. 4, no. 8, pp. 1053-1060, Aug. 1995.