

웨이블렛에 기반한 FLD를 사용한 얼굴인식

이완수, 이형지, 정재호

인하대학교 전자공학과

Wavelet-Based FLD for Face Recognition

W.S. Lee*, H. J. Lee, J. H. Chung

Dept of Electronic Engr., Inha Univ.,

*g1992024@inhavision.inha.ac.kr

요약

본 논문에서는 웨이블렛에 기반한 FLD(Fisher Linear Discriminant) 방법을 제안한다. 본 논문은 얼굴인식에 대한 속도와 정확성을 다룬다. 128×128 의 해상도를 가진 영상은 웨이블렛 변환을 통해 16×16 의 부영상들로 분해된 후에, 저대역과 중대역에 해당하는 두 개의 부영상 사용하여 학습과 인식을 한다. 실험 결과, 제안된 방법은 기존의 FLD 방법의 인식률을 유지하며, 보다 더 빠른 속도를 가진다. 우리의 실험에서는 약 6배의 속도 향상을 보인다.

1. 서 론

컴퓨터를 사용한 얼굴인식은 인간의 뛰어난 물체 인식 능력을 이용한 것이다. 이것은 크게 신경망을 이용한 방법과 고유얼굴을 이용한 방법으로 나뉘어져 연구되어지고 있다. 고유얼굴을 이용한 방법은 PCA 방법으로 알려져 있다[1, 2]. 이 방법은 적은 영상 데이터로도 비교적 좋은 인식률을 유지하지만, 표정이나 조도, 안경 등의 변화에 대해 심한 영향을 받는다[3, 4]. 이러한 문제들을 해결하기 위해 FLD 방법이 제시되었다[5, 6, 7]. 이 방법 또한 고유얼굴을 이용한다. PCA와 FLD는 많은 학습시간을 필요로 한다. 이것은 영상벡터의 차원에 기인한다. 예를 들어, 128×128 의 해상도를 가진 영상은 $16384 (=128 \times 128)$ 의 차원을 가진다. 학습시간은 16384^2 에 비례한다. 이것은 시스템에 커다란 연산량을 가져온다. 따라서 작은 해상도를 가진 영상을 사용하여 이것을 해결할 수 있지만, 인식률이 나빠지게 된다.

본 논문에서, 우리는 기존의 FLD 방법에 기반을 두고, 더 작은 학습시간을 가지며, 기존의 인식률을 유지하는 알고리즘을 제안한다. 제안된 방법은 전처리 단계에서 웨이블렛 변환을 사용하여 영상의 차원을 줄인다. 우리는 2절에서 웨이블렛 변환과 FLD 방법에 대해 간단히 살펴보고, 3절에서 FLD의 학습시간 측면의 개선시킨 알고리즘을 제안할 것이다.

2. 웨이블렛 변환과 FLD

2.1 웨이블렛 변환

웨이블렛 변환의 기본개념은 주어진 함수 $f(x)$ 를 웨이블렛 평면에 투사하여 여러 개의 해상도로 분해하는 것이다. 웨이블렛 평면은 서로 다른 해상도를 갖는 기본 함수들로 구성되어 있어서, $f(x)$ 는 다른 해상도를 갖는 부함수들로 변환된다. 웨이블렛 변환은 신호에 대해 시간과 주파수의 지역성을 갖는다.

그림 1은 2차원 웨이블렛 변환의 분해과정(그림 1(a))과 합성과정(그림 1(b))의 구조를 나타낸다.

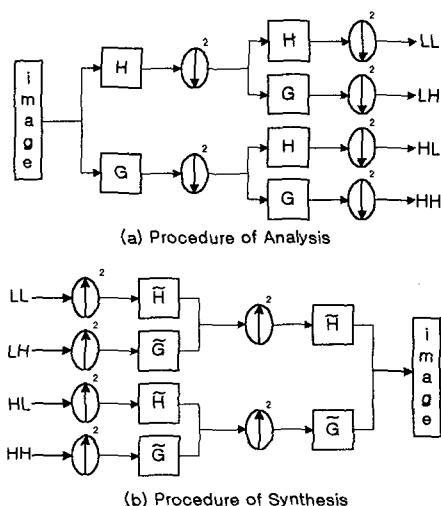


그림 1. 웨이블렛 변환 필터 뱅크

1	2	5	8
3	4		
6	7		
		9	10

그림 2. 3차 웨이블렛 분해

웨이블렛 변환을 사용하여 영상은 여러 개의 부대역을 갖는 영상들로 분해된다. 그림 2는 영상을 3차 웨이블렛 분해한 것이다. 부영상 1, 2, 3, 4는 3차 웨이블렛 변환된 결과들이고, 각각 LL, LH, HL, HH의 주파수대에 해당한다.

2.2 고유방법을 이용한 얼굴인식

고유방법을 이용한 얼굴인식은 Karhunen-Loeve(혹은 K-L) 변환을 사용한다. K-L 방법은 또한 주성분 분석법(PCA)으로 불려진다. 이 방법은 공분산 행렬의 고유 벡터를 사용한다. 주어진 샘플벡터를 고유벡터에 투사하여 특징벡터를 만들 수 있다. 이 고유벡터들은 얼굴의 형태를 닮았기 때문에, 고유얼굴(eigenface)이라고도 부른다.

고유얼굴에 의해 만들어진 특징벡터를 사용하여 얼굴 인식을 한다. 특징벡터들은 샘플벡터의 차원보다 작기 때문에, 인식과정은 상당히 간단하지만, 비교적 높은 인식률을 유지한다.

2.2.1 PCA(주성분 분석법)

PCA 방법은 벡터들의 확률적인 성질을 이용한 것이다. 이 방법은 다음과 같이 나타내어지는 선형변환의 일종이다.

$$y = A^T x \quad (1)$$

위 식은, 특징벡터 y 는 원래의 벡터 x 를 A 영역에 투사하여 만들어지는 것을 나타낸다. PCA 방법은 x 의 공분산 행렬의 고유벡터를 A 의 기저로 사용한다. 고유 벡터들은 서로 수직이고 또한 크기가 정규화되어 있기 때문에 이 변환은 직교정규변환(orthonormal transform)이라고도 불린다. 만들어진 특징벡터들은 서로 상관하지 않기 때문에 이 모델들에 대한 특별한 분류 기의 설계 없이 단지 유clidean 거리(Euclidean distance)를 사용하여 분류할 수 있다.

2.2.1.1 PCA의 학습 과정

PCA 과정은 다음과 같다. 우선 m 차원을 가진 벡터 x 가 N 개 있고, 또한 $N < m$ 이라고 가정한다. x 의 평균 벡터를 μ 라고 하면, 공분산 행렬 C_x 는 다음과 같다.

$$C_x = \frac{1}{N} \sum_{n=1}^N (x_n - \mu)(x_n - \mu)^T = Q\Lambda Q^T \quad (2)$$

C_x 의 랭크(rank)는 $N-1$ 이기 때문에, 우리는 다음과 같이 고유치(아래 식의 Λ)가 0이 아닌 고유얼굴(아래 식의 QE)를 최대 $N-1$ 개 구할 수 있다.

$$Q\Lambda Q^T QE = Q\Lambda E \quad (3)$$

여기에서 E 와 Λ 는 각각 $Q^T Q$ 의 고유벡터 행렬과 고유치 행렬에 해당한다. 고유얼굴들은 고유치의 크기에 따라서 내림차순으로 정렬된다. 특징벡터 y 는 $x - \mu$ 를 고유벡터 행렬에 투사시켜 얻을 수 있다.

$$y = (QE)^T (x - \mu) \quad (3)$$

특징벡터의 공분산 행렬 C_y 는, 대각선 성분은 C_x 의 고유치로 되어 있고 그 외에는 0으로 이루어진 대각선 행렬이다. 따라서 특징벡터들은 서로 상관하지 않는다.

2.2.1.2 PCA의 인식과정

인식과정은 다음과 같다. 임의의 영상벡터에 대해 앞의 학습과정에서의 평균벡터와 고유얼굴을 사용하여 새로운 특징벡터를 만들 수 있다. 특징벡터들의 비상관성을 이용하여, 단순히 Euclidean distance를 사용하여 인식을 할 수 있다.

2.2.2 FLD(Fisher Linear Discriminant)

FLD 방법은 위의 PCA 방법을 개선한 것이다. 이 방법은 한사람 내에서의 변화와 다른 사람들간의 변화의 비를 고려한 것이다. 즉, 다른 사람들 간의 scatter 행렬 (S_b)의 행렬식의 값을 최대화하고, 동시에 조도, 표정, 안경 등의 변화와 같은 자신들간의 scatter 행렬 (S_w)의 행렬식 값을 최소화한다.

2.2.2.1 FLD의 학습과정

FLD은 다음과 같다. 먼저 총 영상의 개수를 N 개, 총 사람의 수를 c 개, 한 사람 당 영상 수를 K 개라고 가정하자. 먼저 PCA 방법으로부터 $N-1$ 개의 고유얼굴을 얻을 수 있다. 이 중에서 단지 $N-c$ 개의 고유얼굴들만이 S_w 의 랭크에 해당하므로, $N-c$ 차원의 특징벡터를 얻을 수 있다. 전반적인 에러를 줄이기 위해, 즉 S_w 의 행렬식을 최소화하고, S_b 의 행렬식을 최대화하기 위해,

$S_w^{-1}S_b$ 행렬을 구성하고, 그것으로부터 fisherface(고유벡터)를 얻을 수 있다. S_w 와 S_b 는 다음과 같이 정의된다.

$$S_w = \sum_{i=1}^c P_i \left\{ \sum_{j=1}^n (y_j - M_j)(y_j - M_j)^T \right\} \quad (5)$$

$$S_b = \sum_{i=1}^c P_i (M_i - M)(M_i - M)^T \quad (6)$$

여기에서 M_i 는 i 번째 클래스의 평균 벡터이고, M 은 전체 클래스의 평균 벡터이다. $S_w^{-1}S_b$ 는 대칭(symmetric)행렬이 아니므로, 이 고유시스템은 불안정해질 수 있다. 이 문제는 S_w 과 S_b 의 대칭성을 이용하여 $S_w^{-1}S_b$ 를 대각화(digonalization)하여 해결할 수 있다[6]. $S_w^{-1}S_b$ 의 대각화는 동시에 대각화(simultaneous diagonalization)와 백색변환(whitening transform)을 이용하여 만들 수 있다[8].

PCA에서 얻어진 특징벡터를 fisherface에 투사하여 $c-1$ 차원을 갖는 FLD의 특징벡터를 구할 수 있다.

2.2.2.2 FLD의 인식과정

FLD의 인식은 PCA 방법과 비슷하다. 임의의 영상벡터에 대해, 앞에서의 평균 벡터와 고유얼굴, fisherface를 사용하여 새로운 특징벡터를 구할 수 있다. FLD의 특징벡터들은 또한 서로 상관하지 않으므로 Euclidean distance를 사용하여 주어진 영상벡터를 분류할 수 있다.

FLD 방법은 PCA에서 발생되는, 빛 방향의 변화와 같은 클래스의 분류에 부적절한 영향을 끼치는 요소를 줄일 수 있다. 따라서, PCA의 인식률은 FLD 방법을 사용하여 개선할 수 있다.

3. 웨이블렛에 기반한 FLD 알고리즘

고유얼굴에 기반을 둔 얼굴인식 시스템은 학습과정과 인식과정으로 나뉘어져 있다. 이 중에서 인식과정은 거의 실시간으로 처리되는 반면, 학습과정은 많은 시간을 필요로 한다. 학습과정의 시간을 줄이면서, 또한 인식률을 유지하기 위해 우리는 새로운 방법을 제시한다. 그림 3은 우리가 제안한 시스템을 나타낸다.

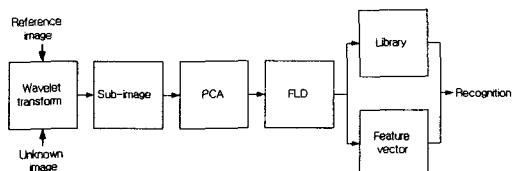


그림 3. 제안된 시스템의 블럭도

학습과정에서, 공분산 행렬과 그것에 대한 고유얼굴의 구성은 영상벡터의 차원에 의존한다. d 차원을 가진 영상벡터의 경우, 공분산 행렬과 고유벡터 행렬은 각각 d^2 만큼의 메모리를 요구하게 된다. 따라서 학습에 필요한 메모리 공간과 시간은 영상의 차원을 줄임으로써 해결할 수 있다.

앞에서 언급된 아이디어를 실현하기 위해 그림 3에서 와 같이 기존의 영상을 웨이블렛 변환을 통해 여러 개의 부영상으로 분해한 다음, 특정 대역의 부영상들을 사용하여 PCA의 학습과정에 적용한다. N 개의 부영상들은 각각의 차원보다 작기 때문에 최대 $N-1$ 개의 고유얼굴을 얻을 수 있고, 그로부터 $N-1$ 차원의 특정벡터를 얻을 수 있다. 여기에서 얻어진 특정벡터들을 FLD 알고리즘에 적용한다. S_w 와 S_b 로부터, fisherface와 그것에 해당하는 특정벡터들을 추출할 수 있다. 단순히 Euclidean distance를 사용하여 인식할 수 있다.

4. 실험 결과

제안한 알고리즘을 테스트하기 위해, Yale 대학교의 영상데이터를 사용하였다. 사용한 데이터는 150개로 총 15명(15 클래스)의 남자와 여자, 한사람 당 10개의 영상들로 구성되어져 있다. 또한 이 영상들은 빛의 변화, 얼굴표정, 안경착용의 유무의 변화요소를 가지고 있다. 이 영상들은 160×121 의 해상도를 가지고 있고, 이것은 2의 8 (power)이 아니므로 웨이블렛 변환이 적용되기 어렵다. 이러한 문제를 풀기 위해, 우리는 우선 이 영상들을 91×91 로 자른 다음, 다시 128×128 의 해상도로 리사이즈(resize) 하여, 이 영상들에 우리의 알고리즘을 적용하였다. Leaving-One-Out방식을 사용하여 우리의 알고리즘의 성능을 검사하였다. 즉, 149개의 영상들을 가지고 학습을 하였고 사용되지 않은 다른 1개의 영상을 가지고 인식을 하여, 전체 영상들에 대해 총 150번의 학습과 인식을 하였다.

첫 번째 실험에서는, 웨이블렛 변환을 사용하여 16×16 의 해상도를 가진 부영상들을 사용하였다. 대칭적인 FIR 필터를 사용하기 위해, 직교 웨이블렛 필터 대신에 쌍직교(biorthogonal) 웨이블렛 필터를 사용하였다. 그 다음에 4개의 부영상들에 대해 각각 PCA와 FLD를 적용하였다. 실험 결과는 표 1에 나타나 있다. 전체 인식률은 LL, LH, HL, HH 순으로 나타나 있다. 표 2에 나타난 기존의 FLD의 인식률과 비교해 볼 때, 제안된 방법은 계산 속도 측면에서는 효과적이거나 인식률 측면에서는 다소 떨어지는 것을 볼 수 있다. 그러나 LL 부영상은 가지고 인식하지 못한 부분을 LH 부영상으로 인식할 수 있는 것을 발견할 수 있었다.

데이터	인식률(%)		평균시간(초)	
	PCA	FLD	PCA	FLD
LL	80.67	96.00	18	21
LH	79.33	82.67	18	21
HL	74.67	77.33	18	21
HH	64.00	71.33	18	21

표 1. 16×16 해상도를 가진 웨이블렛 부영상의 인식률과 평균시간

두 번째 실험에서, 우리는 LL과 LH를 하나의 영상, 즉 16×32 의 해상도를 가진 영상을 사용하였다. 표 2에 이것에 대한 인식률과 평균시간이 나타나 있다. 계산시간은 기존의 FLD방법에 비해 약 6배의 속도향상을 보이고 있고, 인식률의 기존 방법과 같은 인식률을 보이고 있다. 영상의 차원은 $16384 (=128 \times 128)$ 에서 $512 (=16 \times 32)$ 로 32배의 감소를 가진다. 이러한 차원의 감소는 공분산 행렬 구성시 16384^2 에서 512^2 로 32²배의 감소의 효과가 있지만 실제적으로, 우리가 필요한 고유벡터에 대한 메모리는 식 (3)에 의해 차원수 \times 영상수가 되므로 32배만큼의 메모리 절감의 효과가 있다.

방법 (해상도)	인식률(%)		평균시간(초)	
	PCA	FLD	PCA	FLD
기존의 방법 (128×128)	79.33	99.33	130	136
제안된 방법 (16×32)	78.66	99.33	18.5	22

표 2. 기존의 방법과 제안된 방법의 비교

5. 결 론

고유얼굴을 사용하는 기존의 얼굴인식 방법은 매우 많은 학습시간을 필요로 한다. 본 논문에서는 이 문제를 해결하고자 하였다. LL 대역의 부영상 사용한 첫 번째 실험은 가장 짧은 학습시간을 가지고 있지만, 기존의 방법보다는 낮은 인식률을 보이고 있다. 두 번째 실험에서는 이것을 보상하기 위해 LL 대역과 LH 대역을 모두 사용하였다. 제안된 방법은 기존의 방법보다 약 6배의 빠른 학습시간을 가지고 있으며, 기존의 방법과 같은 인식률을 유지하고 있다.

그러나, 우리가 제안한 알고리즘은 데이터의 개수가 영상차원보다 지나치게 많거나 얼굴부분의 크기가 일정하지 않으면 인식률이 떨어지는 단점을 지니고 있다. 앞으로 우리는 영상들을 몇 개의 그룹으로 나누어 첫 번째 문제를 해결하고, 앞에서 사용한 필터 대신에 여러 가지 다른 필터를 사용하여 두 번째 문제를 해결하고자 한다.

6. 참 고 문 헌

- [1] M. Turk and A. Pentland, Eigenfaces for recognition, *Journal of Cognitive Neuroscience*, Vol. 3, No.1, pp.71-86, 1991.
- [2] M. Kirby and L. Sirovich, Application of Karhunen-Loeve Procedure for Characterization of Human Faces, *IEEE Trans. On Pattern Anal., And Mach. Intell.*, Vol. 12, pp. 103-108, 1990.
- [3] A. Z. Kouzani, F. He, K. Sammut, and A. Bouzerdoum, Illumination Invariant Face Recognition, *Proceedings of the 1998 IEEE International Conference on Systems, Man, and Cybernetics*, Vol 5, pp.4240-4245, 1998
- [4] Y. Moses, Y. Adini, and S. Ullman, Face Recognition: The Problem of Compensating for Changes in Illumination Direction. *European Conf. Computer Vision*, pp.286-296, 1994
- [5] Peter N. Belhumeur, João P. Hespanha, and David J. Kriegman, Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, *Journal of IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.19, No.7, pp 711-720, 1997
- [6] Daniel L. Swets and John (Juyang) Weng, Short Papers: Using Discriminant Eigenfeatures for image retrieval, *Journal of IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.18, No.8, pp 831-836, 1996
- [7] Mayer Aladjem, Linear Discriminant Analysis for Two Classes via Removal of Classification Structure, *Journal of IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.19, No.2, pp 187-192, 1997
- [8] K. Fukunaga, *Introduction to Statistical Pattern Recognition*, Academic Press