

논문 2008-45SP-6-8

포톤 카운팅 선형판별법을 이용한 저해상도 얼굴 영상 인식

(Low Resolution Face Recognition with Photon-counting Linear Discriminant Analysis)

염 석 원*

(Seokwon Yeom)

요 약

얼굴영상의 인식 기술은 보안과 감시를 비롯하여 머신 인터페이스와 콘텐츠 검색 등에서 활용이 광범위 하다. 그러나 주로 고해상도 영상이 연구의 대상이었고 원거리에서 획득된 저해상도 표적에 대하여 상대적으로 드물게 연구가 이루어졌다. 본 논문에서는 포톤 카운팅(Photon-counting) 선형판별법을 이용하여 저해상도 환경에서 얼굴영상의 인식을 수행한다. 포톤 카운팅 선형판별법은 Fisher 선형 판별법에서 발생하는 특이행렬 문제없이 Fisher의 최적화 기준을 실현한다. 즉, 차원의 축소나 특징 추출 과정 없이 고차원 공간에서 최적화된 투영을 위한 선형판별함수를 구성하고 이를 이용하여 판정하므로 저해상도 환경을 비롯한 얼굴영상의 왜곡의 극복에 효과적이다. 실험 결과는 제안한 방법이 주성분 분석을 활용하는 Eigen face 또는 주성분 분석과 Fisher 선형판별법이 결합된 Fisher face보다 우수하다는 것을 보여준다.

Abstract

This paper discusses low resolution face recognition using the photon-counting linear discriminant analysis (LDA). The photon-counting LDA asymptotically realizes the Fisher criterion without dimensionality reduction since it does not suffer from the singularity problem of the Fisher LDA. The linear discriminant function for optimal projection is determined in high dimensional space to classify unknown objects, thus, it is more efficient in dealing with low resolution facial images as well as conventional face distortions. The simulation results show that the proposed method is superior to Eigen face and Fisher face in terms of the accuracy and false alarm rates.

Keywords : face recognition, low resolution image, photon-counting LDA, Fisher LDA, PCA

I. 서 론

얼굴영상을 자동으로 인식하는 기술은 실시간 보안과 감시를 비롯하여 로봇 비전, 휴먼-머신 인터페이스, 콘텐츠 검색 등에서 활용이 날로 증대해 가고 있다. 얼굴 인식의 장점은 일반 가시영역의 카메라를 사용하여 대상자의 정보를 손쉽게 얻을 수 있다는 획득성과 대상자의 거부감이 적다는 수용성이 크다는 것이다^[1]. 심지어

어 대상자가 전혀 의식하지 못한 채 모든 인증 절차를 마칠 수가 있다.

컴퓨터와 영상획득 기술의 발전과 더불어 패턴 (Pattern)인식, 신호처리, 컴퓨터 비전에서의 여러 기법들이 얼굴인식 시스템을 위하여 개발되고 있다. 주요 인식기술로 학습데이터의 통계적인 특성을 분석하는 PCA (Principal Component Analysis: 주성분 분석), LDA (Linear Discriminant Analysis: 선형 판별법), SVM (Support Vector Machine)과 같은 통계적 패턴인식 방법^[2~7]과 Gabor 필터에 의한 특징 추출을 이용하는 EGM (Elastic Graph Matching)이 있다^[8]. 최근에는 3D 영상의 획득과 합성을 통한 인식의 연구도 수행되고 있다^[9]. 그러나 얼굴인식의 연구는 주로 고해상도 영상을 대상으로 수행되었으며 저해상도 얼굴영상의 검출

* 정희원, 대구대학교 정보통신공학부
(Daegu University, Dept. of Computer and Communication Engineering)

※ 본 연구는 2007년도 정부재원(교육인적자원부 학술 연구조성사업비)으로 한국학술진흥재단의 지원을 받아 연구되었음(KRF-2007-331-D00330).

접수일자: 2008년8월28일, 수정완료일: 2008년10월13일

과 인식은 상대적으로 드물게 이루어졌다^[10~11]. 실시간 보완체계에서 대상 표적이 원거리에서 획득될 경우 물체의 공간해상도는 낮아진다. 그러므로 영상의 활용성을 높이고 부가가치를 극대화하기 위하여 저해상도 영상의 처리와 인식에 대한 연구가 필요하다.

통계적 얼굴인식 기술의 대표적인 방법은 Eigen face 와 Fisher face이다. Eigen face는 PCA를 이용하는 것이고 Fisher face는 PCA와 결합된 Fisher LDA를 이용한다^[2~3]. Fisher LDA는 서로 다른 클래스의 분포를 최대화 하며 동일 클래스의 분포를 최소화 하는 공간에 선형투영을 하는 방법이다^[12~13]. 그러나 일반적으로 학습영상의 수가 적은 경우에 PCA와 같은 차원 축소 과정이 필요하다.

본 논문에서는 차원 축소 혹은 특징 추출 과정 없이 Fisher의 최적화 기준을 구현하는 포톤 카운팅 (Photon-counting) LDA를 이용한 저해상도 얼굴영상 인식을 제안한다. 포톤 카운팅 LDA는 광자계수(Photo-Counts) 영상에서 Fisher의 최적화 투영법을 이용하는 것으로 광자계수 검출기로 획득한 미지의 영상을 인식하기 위하여 제안되었다^[14]. 본 논문에서는 가시광선 영역에서 획득한 일반영상을 인식하기 위하여 판정기법을 확장하고 이론적인 타당성을 보인다.

포톤 카운팅 LDA는 훈련영상의 수가 적은 경우에 발생하는 특이(singularity)행렬 문제가 없다. 즉, Fisher의 최적화 투영법을 차원 축소 과정 없이 고차원 공간에서 구현한다. 고차원 학습영상의 직접적인 분석을 통한 선형판별함수를 형성함으로써 포즈, 표정, 조명의 변화와 같은 전형적인 얼굴인식의 어려움과 더불어 저해상도 환경에서 오는 왜곡에 효과적이다.

흔히 고차원의 특징벡터에서 오는 학습의 어려움을 “차원의 저주(curse of dimensionality)”라고 표현하나 이는 non-parametric 분류기에 해당되고 포톤 카운팅 LDA는 parametric 분류기로 이에 해당되지 않는다.

클래스의 판정은 유클리드(Euclidean) 거리를 이용한다. 미지의 영상정보는 학습된 클래스 중 최소 유클리드 거리를 가지는 클래스로 판단한다. 실험 결과는 제안한 방법이 기존의 Eigen face 또는 Fisher face보다 우수하다는 것을 보여준다.

본 논문의 구성은 다음과 같다. II장에서는 Fisher LDA를 설명하고 III장에서는 포톤 카운팅 LDA의 학습과 판정과정, 성능평가 방법을 제안한다. IV장에서는 얼굴인식 실험을 수행한다. V장에서는 결론과 추후 연구 방향을 제시한다.

II. Fisher LDA

Fisher LDA는 서로 다른 클래스의 분포를 최대화 하며 동일 클래스 내의 구성원의 분포를 최소화 하는 공간에 선형 투영을 하는 방법이다. Fisher의 최적화 기준은 다음과 같다.

$$W_F = \arg \max_{w \in R^{d \times c}} \frac{|W^t \sum_{xx}^B W|}{|W^t \sum_{xx}^W W|} \quad (1)$$

\sum_{xx}^B 는 학습영상벡터 $x = [x_1 \dots x_d]^t$ 의 집단 내(between-class) 공분산 행렬로 다음과 같다.

$$\sum_{xx}^B = E_j[(\mu_{x|j} - \mu_x)(\mu_{x|j} - \mu_x)^t] \quad (2)$$

위의 식에서 d 는 영상의 화소 수이고 위첨자 t 는 전치행렬을 나타낸다. $\mu_{x|j}$ 는 학습영상 x 의 클래스 j -조건평균 벡터이고 μ_x 는 x 의 평균 벡터이다.

$$\mu_{x|j} = E_{x|j}(x|j) \quad (3)$$

$$\mu_x = E_x(x) \quad (4)$$

\sum_{xx}^W 는 집단 내(within-class) 공분산 행렬이다.

$$\sum_{xx}^W = E_j\{E_{x|j}[(x - \mu_{x|j})(x - \mu_{x|j})^t|j]\} \quad (5)$$

정규(Normal) 분포라는 가정 하에 식(2)-식(5)는 MLE (Maximum Likelihood Estimation)와 Invariance of MLE^[15]의 특성을 이용하여 다음과 같이 추정된다.

$$\hat{\sum}_{xx}^B = \sum_{j=1}^{n_c} (\hat{\mu}_{x|j} - \hat{\mu}_x)(\hat{\mu}_{x|j} - \hat{\mu}_x)^t \quad (6)$$

$$\hat{\sum}_{xx}^W = \frac{1}{n_c} \sum_{j=1}^{n_c} \frac{1}{n_j} \sum_{n=1}^{n_j} (x_j(n) - \hat{\mu}_{x|j})(x_j(n) - \hat{\mu}_{x|j})^t \quad (7)$$

위의 식에서 $x_j(n)$ 는 클래스 j 의 n 번째 학습영상이고 n_c 는 클래스 수이다. n_j 는 클래스 j 의 학습영상의 수이므로 총 학습영상의 수 n_t 는 $\sum_{j=1}^{n_c} n_j$ 이다. $\hat{\mu}_{x|j}$ 와 $\hat{\mu}_x$ 는 표본평균으로 다음과 같다.

$$\hat{\mu}_{x|j} = \frac{1}{n_j} \sum_{n=1}^{n_j} x_j(n) \quad (8)$$

$$\hat{\mu}_x = \frac{1}{n_c} \sum_{j=1}^{n_c} \hat{\mu}_{x|j} \quad (9)$$

식 (1)에 의하여 정의된 W_F 의 열벡터는 $(\hat{\Sigma}_{xx}^W)^{-1}(\hat{\Sigma}_{xx}^B)$ 의 0이 아닌 고유치에 대응하는 고유벡터로 구현한다. 그러나 $\text{Rank}(\hat{\Sigma}_{xx}^W) \leq \min(n_t - n_c, d)$ 이므로 학습영상의 수가 적은 경우 $\hat{\Sigma}_{xx}^W$ 는 특이(singular)행렬이 되어 역행렬을 구할 수가 없다. Fisher face는 이러한 문제를 극복하기 위하여 PCA를 Fisher LDA의 전 단계에 사용한다.

Fisher face의 판정 과정은 다음과 같이 유클리드(Euclidean) 거리를 이용한다.

$$\text{Fisher face} : \hat{j} = \arg \min_{j=1, \dots, n_c} \| W_F^t W_{PCA}^t (x_{test} - \hat{\mu}_{x|j}) \| \quad (10)$$

위의 식에서 W_{PCA} 는 PCA의 투영행렬이고 x_{test} 는 미지의 입력영상벡터이다.

III. 포톤 카운팅 LDA

1. 학습 과정

광자계수 영상은 다음과 같은 고전적 포톤 카운팅 모델인 포아송(Poisson) 분포에 기반을 둔다고 가정한다 [16]

$$y_i \sim \text{Poisson}(N_P x_i) \quad (11)$$

위의 식에서 y_i 는 i 번째 화소에서 검출된 광자 계수이고 x_i 는 정규화된 i 번째 화소의 세기이다. 즉,

$$\sum_{i=1}^d x_i = 1 \quad (12)$$

이므로

$$E[\sum_{i=1}^d y_i] = \sum_{i=1}^d N_P x_i = N_P \quad (13)$$

이다. 그러므로 N_P 는 영상의 평균 광자계수이다. 광자계수 영상벡터 $y = [y_1 \dots y_d]^t$ 의 집단 간 공분산 행렬과 집단 내 공분산 행렬은 각각 다음과 같이 유도된다[14].

$$\Sigma_{yy}^B = N_P^2 \Sigma_{xx}^B \quad (14)$$

$$\Sigma_{yy}^W = N_P \text{diag}(\mu_x) + N_P^2 \Sigma_{xx}^W \quad (15)$$

그리고 Fisher의 최적화 기준을 적용하면 다음과 같

은 투영행렬 W_P 을 얻는다.

$$\begin{aligned} W_P &= \arg \max_{W \in R^{d \times c}} \frac{|W^t \Sigma_{yy}^B W|}{|W^t \Sigma_{yy}^W W|} \\ &= \arg \max_{W \in R^{d \times c}} \frac{|W^t \Sigma_{xx}^B W|}{|W^t [\text{diag}(\mu_x)/N_P + \Sigma_{xx}^W] W|} \end{aligned} \quad (16)$$

식(14)와 식(15)는 Invariance of MLE의 특성을 이용하여 다음과 같이 추정된다.

$$\hat{\Sigma}_{yy}^B = N_P^2 \hat{\Sigma}_{xx}^B \quad (17)$$

$$\hat{\Sigma}_{yy}^W = N_P \text{diag}(\hat{\mu}_x) + N_P^2 \hat{\Sigma}_{xx}^W \quad (18)$$

그러므로 W_P 의 열벡터는 $(\text{diag}(\hat{\mu}_x)/N_P + \hat{\Sigma}_{xx}^W)^{-1}(\hat{\Sigma}_{xx}^B)$ 의 0이 아닌 고유값에 대응하는 고유벡터이다. $\hat{\mu}_x$ 의 성분은 0이 아니므로 $\text{diag}(\hat{\mu}_x)/N_P + \hat{\Sigma}_{xx}^W$ 는 항상 정규(nonsingular, regular)행렬이다. 그러므로 포톤 카운팅 LDA는 Fisher LDA에 발생하는 특이행렬 문제가 없다.

2. 판정 과정

본 논문에서는 일반 영상센서로 획득한 세기(Intensity) 영상을 이용하여 미지의 표적을 판정한다. 포톤 카운팅 LDA의 최적화 기준은 N_P 를 무한대로 크게 할 경우 Fisher LDA에 근접한다. 즉,

$$\lim_{N_P \rightarrow \infty} \frac{|W^t \Sigma_{xx}^B W|}{|W^t [\text{diag}(\mu_x)/N_P + \Sigma_{xx}^W] W|} = \frac{|W^t \Sigma_{xx}^B W|}{|W^t \Sigma_{xx}^W W|} \quad (19)$$

또한 광자계수 영상의 포아송 분포는 다음과 같이 정규분포와 가까워진다.

$$\lim_{N_P \rightarrow \infty} \text{Poisson}(N_P x_i) = N(N_P x_i, N_P x_i) \quad (20)$$

위의 식에서 $N(\cdot)$ 는 정규분포를 나타낸다. 즉, y_i 는 평균 $N_P x_i$ 의 주위에서 가장 큰 확률밀도를 갖는다. 그러므로 다음과 같은 추정이 가능하다.

$$\hat{y}_{test} = N_P x_{test} \quad (21)$$

판정은 다음과 같이 최소 유클리드 거리를 이용하여 수행된다.

$$\hat{j} = \arg \min_{j=1, \dots, n_c} \| W_P^t (\hat{y}_{test} - \hat{\mu}_{y|j}) \| \quad (22)$$

식(22)의 판정기법은 다음 식(23)이 성립하므로 식(24)의 판정법과 동일하다.

$$\hat{\mu}_{y|j} = N_P \hat{\mu}_{x|j} \quad (23)$$

$$\hat{j} = \arg \min_{j=1, \dots, n_c} \| W_P^t (\mathbf{x}_{test} - \hat{\mu}_{x|j}) \| \quad (24)$$

위의 판정식 식(24)는 포톤 카운팅 LDA는 N_P 가 무한히 큰 값을 가질 경우 Fisher LDA와 동일하다는 것과 일치한다.

3. 성능 평가

본 논문의 실험에서는 식(24)의 포톤 카운팅 LDA의 결과와 식(10)의 Fisher face, 그리고 식(25)의 Eigen face, 식(26)의 학습영상 평균과의 유클리드 거리를 이용한 결과와 비교한다.

$$\text{Eigen face : } \hat{j} = \arg \min_{j=1, \dots, n_c} \| W_{PCA}^t (\mathbf{x}_{test} - \hat{\mu}_{x|j}) \| \quad (25)$$

$$\text{Sample mean : } \hat{j} = \arg \min_{j=1, \dots, n_c} \| \mathbf{x}_{test} - \hat{\mu}_{x|j} \| \quad (26)$$

인식 성능은 다음과 같이 인식(detection) 확률과 허위(false alarm) 확률로 평가한다.

$$P_D(j) = \frac{\text{Number of decision for class } j}{\text{Number of test images in class } j} \quad (27)$$

$$P_F(j) = \frac{\text{Number of decision for class } j}{\text{Number of test images not in class } j} \quad (28)$$

IV. 실험

실험을 위하여 온라인상에서 공개된 ATT-ORL 데이터베이스^[17]를 사용하였다. ATT-ORL 데이터베이스는 총 40개의 인물(클래스)로 구성되어 있으며 각 클래스는 10개의 표정과 포즈가 다른 영상으로 구성되어 있다. 영상의 크기는 각각 92×112 화소이며 세그멘테이션이 되어있어 얼굴의 식별 성능을 평가하기 위하여 적합하다.

학습과정에서 각 클래스 당 0-2번의 3개의 영상을 이용하였고 학습된 영상 이외의 7개의 영상으로 인식을 테스트하였다.

학습과정은 오프라인 작업이므로 시간과 자원의 제한이 적다는 점을 감안하여 보유정보를 100% 활용할

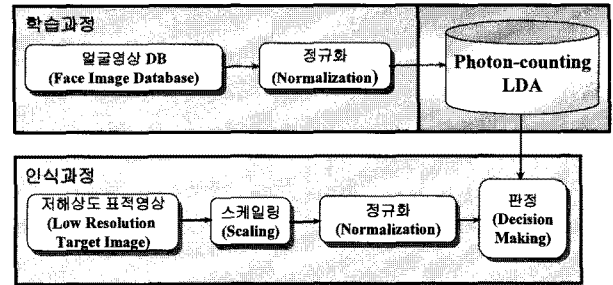


그림 1. 저해상도 얼굴영상 인식시스템 블록도
Fig. 1. Block diagram of the low resolution face recognition system.




그림 2. (a) 클래스 1-10의 80% 축소된 학습영상의 예, (b) 클래스 1-10의 25% 축소된 테스트 영상의 예

Fig. 2. (a) training image examples of class 1 to 10, with 80% resolution, (b) test image examples of class 1 to 10 with 25% resolution.

수 있지만 본 논문에서는 원 영상의 80%로 축소된 영상을 학습하였다. 테스트 영상은 10%에서 80%까지 5%씩 원영상의 축소를 통하여 해상도를 변화하였다. 영상의 획득 시 원거리일 경우 인접한 화소가 중첩된다는 점을 감안하여 양선형(Bi-linear) 보간법을 이용하여 영상을 축소하였다.

그림 1은 본 논문에서 제안하고 실험한 시스템의 블록도(Block Diagram)이다. 학습 과정에서 각 영상의 세기의 합이 1이 되도록 정규화(normalization)하였다. 그림 1의 포톤 카운팅 LDA는 식(16)을 통하여 계산되었다.

인식 과정에서 미지의 테스트 영상에 대하여 공간 해상도가 학습영상보다 적은 경우 최근접 이웃(Nearest Neighbor) 보간법을 통하여 확대하고 영상의 세기의 합이 1이 되도록 정규화하였다. 그림 1의 판정 과정은 식 (24)로 표현된다.

그림 2는 클래스 1부터 10까지 80%로 축소하여 크기가 73×89 화소인 학습영상과 선형보간법으로 25%로 축소하여 크기가 23×28 화소인 테스트 영상의 예이다.

Fisher face와 Eigen face의 경우 PCA 투영 이후 차원의 수는 고유치의 합이 전체 고유치의 합의 95%가 되도록 하였고 포톤 카운팅 LDA와 Fisher face의 경우 투영 후 최종 차원의 수는 $n_c - 1$ 로 하였다^[12~13].

그림 3과 그림 4는 각 클래스 당 학습영상의 수가 3개인 경우의 평균 인식확률과 평균 허위확률을 보여준

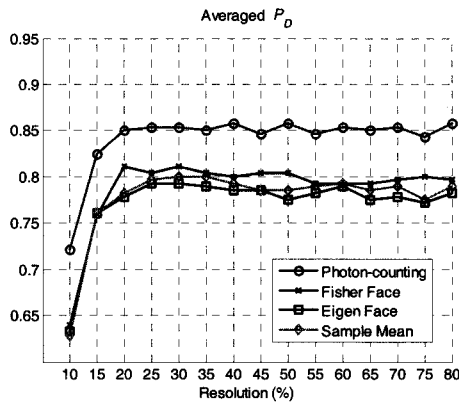


그림 3. 40개 클래스 대상으로 각 클래스 당 3개의 학습영상과 7개의 테스트 영상일 경우 평균 인식 확률

Fig. 3. Averaged probability of detection when $n_c = 40, n_j = 3, n_{test} = 7$.

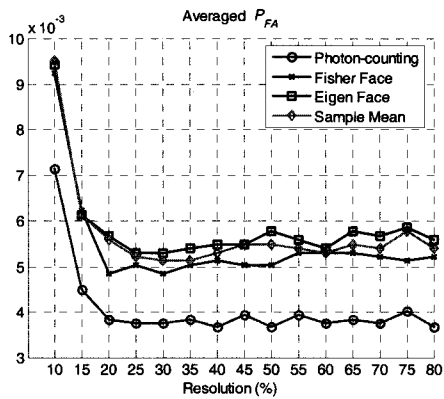


그림 4. 40개 클래스 대상으로 각 클래스 당 3개의 학습영상과 7개의 테스트 영상일 경우 평균 허위 확률

Fig. 4. Averaged probability of false alarm when $n_c = 40, n_j = 3, n_{test} = 7$.

다. PCA 차원의 수는 70으로 얻어졌다. 그리고 LDA에 의한 최종 차원의 수는 39이다.

그림 5와 그림 6은 각 클래스의 학습영상의 수가 5개이고 테스트 영상의 수가 5개인 경우의 평균 인식확률과 평균 허위확률을 보여준다. PCA 차원의 수는 104이고 LDA 차원의 수는 39이다. 그림 3과 그림 5를 비교하고 그림 4와 그림 6을 비교하면 학습 영상의 수가 증가하면 인식확률은 향상되고 허위확률은 감소함을 알 수 있다. 그림 3에서 포톤 카운팅 LDA의 인식확률이 Fisher LDA와 비교하여 6.25%정도 향상되었으며 그림 4에서 허위확률이 20%이상 감소되었다. 그림 3부터 그림 6까지 결과에 보이듯이 포톤 카운팅 LDA는 Fisher face를 포함한 다른 방법보다 우수한 결과를 보인다.




그림 5. 40개 클래스 대상으로 각 클래스 당 5개의 학습영상과 5개의 테스트 영상일 경우 평균 인식 확률

Fig. 5. Averaged probability of detection when $n_c = 40, n_j = 5, n_{test} = 5$.

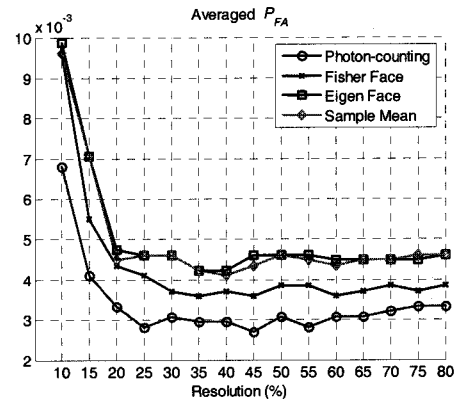


그림 6. 40개 클래스 대상으로 각 클래스 당 5개의 학습영상과 5개의 테스트 영상일 경우 평균 허위 확률

Fig. 6. Averaged probability of false alarm when $n_c = 40, n_j = 5, n_{test} = 5$.

V. 결 론

본 논문에서는 새로운 선형판별법인 포토 카운팅 LDA를 적용하여 왜곡과 저해상도에 의하여 손상된 얼굴영상의 인식을 연구하였다. 포토 카운팅 LDA는 차원의 축소에 의한 특징 추출 과정 없이 최적화된 투영을 이용한다.

본 논문에서는 40명의 얼굴의 10개의 변화를 대상으로 제안된 알고리즘의 성능을 평가하였다. 얼굴에 대한 변화가 10가지로 한정되어 있어 향후 더욱 다양한 변이에 대한 실험과 분석을 계획 중이다. 또한 원거리에 얻어지는 저해상도 영상의 얼굴검출 연구도 계획하고 있다.

참 고 문 헌

- [1] 조재수, 강현수, 김홍수, 김성득, *멀티미디어 신호 처리: 이론 및 실습*, 사이텍 미디어, 2006.
- [2] D. L. Swets and J. Weng, "Using discriminant eigenfeatures for image retrieval," *IEEE Trans. Pattern Analysis and Machine Intelligence*. Vol. 18, No.8, pp. 831-836, 1996.
- [3] P. N. Belhumer, J. P. Hespanha, and D. J. Kriegman, "Eigenfaces vs. Fisherfaces: recognition using class specific linear projection," *IEEE Trans. Pattern Analysis and Machine Intelligence*. Vol. 19, No. 7, pp. 711-720, 1997.
- [4] 김현철, 김대진, 방승양, "LDA 혼합 모형을 이용한 얼굴인식," *정보과학회논문지: 소프트웨어 및 응용*, 제32권 제8호, 789-794쪽, 2005년 8월.
- [5] 홍은혜, 고병철, 변혜란, "PCA와 LDA를 이용한 실시간 얼굴 검출 및 검증 기법," *정보과학회논문지: 소프트웨어 및 응용*, 제31권 제2호, 2004년 2월.
- [6] 장혜경, 오선문, 강대성, "PCA 기반 LDA 혼합 알고리즘을 이용한 실시간 얼굴인식 시스템 구현," *전자공학회논문지*, 제41권 SP편, 제4호, 473-478쪽, 2004년 7월.
- [7] 안병두, 고한석, "측면 포즈정규화를 통한 부분 영역을 이용한 포즈 변화에 강인한 얼굴 인식," *대한 전자공학회 논문지*, 제42권 SP편 제4호, 59-68쪽, July, 2005.
- [8] R. P. Wurtz, "Object recognition robust under translations, deformation, and changes in background," *IEEE Tans. Pattern Analysis and Machine Intelligence*. Vol. 19, No. 7, pp. 769-775, 1997.
- [9] X. Lu and A. K. Jain, "Deformation Modeling for Robust 3D Face Matching," *IEEE Tans. Pattern Analysis and Machine Intelligence*. Vol. 30, No. 8,

pp. 1346-1357, 2007.

- [10] S.-W. Lee, J. Park, and S.-W. Lee, "Low resolution face recognition based on support vector data description," *Pattern Recognition*, Vol. 39, pp. 1809-1812, 2006.
- [11] S. Hayashi and O. Hasegawa, "A detection technique for degraded face images," *Proceedings of the 2006 IEEE CVPR'06*, 2006.
- [12] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification 2nd ed.*, Wiley Interscience, New York, 2001.
- [13] K. Fukunaga, *Introduction to Statistical Pattern Recognition 2nd ed.*, Academic Press, Boston, 1990.
- [14] S. Yeom, B. Javidi, and E. Watson, "Three-dimensional distortion-tolerant object recognition using photon-counting integral imaging," *Optics Express*, Vol. 15, No.4. pp. 1513-1533, 2007.
- [15] S. M. Kay, *Fundamentals of Statistical Signal Processing*, Prentice Hall, New Jersey, 1993.
- [16] J. W. Goodman, *Statistical Optics*, Jonh Wiley & Sons Inc., 1985.
- [17] <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>.

저 자 소 개



염 석 원(정회원)

1995년 인하대학교 물리학과
학사 졸업

1997년 고려대학교 전자공학과
학사 졸업

1999년 고려대학교 전자공학과
석사 졸업

2006년 코네티컷 대학교 전자공학과 박사 졸업.

2007년~현재 대구대학교 정보통신공학부
전임강사

<주관심분야 : 신호처리, 영상처리, 광정보처리,
패턴인식, Navigation and Tracking>