

부분공간 기반 특징 추출기의 조명 변인에 대한 얼굴인식 성능 분석

(Face Recognition Evaluation of an Illumination Property of Subspace Based Feature Extractor)

김 광 수 [†] 부 덕 희 ^{**} 안 정 호 ^{***} 곽 수 영 ^{****} 변 헤 란 ^{*****}
 (Kwangsoo Kim) (Deokhee Boo) (Jungho Ahn) (Sooyeong Kwak) (Hyeran Byun)

요 약 오늘날 개인의 정보 보호 및 신분 확인을 위하여 생체 인식 분야 중에서 사람의 얼굴 인식기술이 많이 사용되고 있지만 조명, 자세, 표정 변화로 인하여 얼굴 인식의 성능 저하를 일으키는 문제가 있다. 본 논문에서는 얼굴 인식 결과에 큰 영향을 주는 요소인 조명 변화에 초점을 맞춰 D-LDA(Direct-Linear Discriminant Analysis)가 다른 기법들에 비해 덜 민감하게 수행할 수 있는 성질을 지녔음을 밝히고자 한다. 측면광과 역광등의 조명 변화와 농도의 변화를 고려하여 조명 변화를 갖는 테스트를 갖는 ORL, Yale, 포항공대 데이터베이스를 여러 특징 추출 알고리즘에 적용함으로써 클래스, 학습 데이터 그리고 테스트 데이터 수가 각기 다른 세 종류의 데이터베이스에서 모두 D-LDA가 적은 학습 데이터에서도 조명 변인에 가장 덜 민감하게 반응하는 좋은 인식 성능을 갖는 성질을 지녔음을 보여준다.

키워드 : 얼굴 인식, 특징 추출, PCA, LDA, D-LDA, 커널 D-LDA

Abstract Face recognition technique is very popular for a personal information security and user identification in recent years. However, the face recognition system is very hard to be implemented due to the difficulty where change in illumination, pose and facial expression. In this paper, we consider that an illumination change causing the variety of face appearance, virtual image data is generated and added to the D-LDA which was selected as the most suitable feature extractor. A less sensitive recognition system in illumination is represented in this paper. This way that consider nature of several illumination directions generate the virtual training image data that considered an illumination effect of the directions and the change of illumination density. As result of experiences, D-LDA has a less sensitive property in an illumination through ORL, Yale University and Pohang University face database.

Key words : face recognition, feature extraction, PCA, LDA, D-LDA, kernel D-DLA

1. 서론

신원 확인의 중요성이 증가되고 있는 요즘 가장 좋은

신원 확인 수단인 얼굴은 많은 인식 기법들이 제안되었고 상당한 가능성을 보여주었다. 그러나 조명변화, 포즈, 표정의 다형성으로 인해 얼굴 인식 작업은 여전히 어려운 문제이며 아직까지 만족할 만한 결과를 보이지 못하고 있다. 최근, FERET[1,2] 테스트는 조명변화와 자세 변화 등 두 가지의 중요한 문제가 존재한다는 것이 밝혀졌다. 이는 이들 문제들 중 하나가 대부분 존재하는 시스템들을 위하여 심각한 성능 저하의 원인이 될 수 있다는 것을 말해준다. 수집된 인식 대상의 데이터들로부터 얼굴 검출과 특징 추출의 과정을 거쳐 인식이 이루어지기까지 매 과정마다 언급한 조명 변화, 자세 변화 등의 많은 제약점들로 인해 실용적인 얼굴 인식 시스템을 구현하는 데에 어려움이 있으며 최종 결정을 하는 인식기의 성능을 최대화하기 위해서 정확한 얼굴 검출

· 본 연구는 학술진흥재단(KRF2004-005-H00005)의 지원을 받아 수행하였습니다.

† 정 회 원 : 현대자동차 CL사업부

kwangsoo.kim.kk@gmail.com

** 비 회 원 : 삼성전자 디지털프린팅사업부 연구원

dh.boo@samsung.com

*** 정 회 원 : 강남대학교 컴퓨터미디어공학부 교수

jungho@kangnam.ac.kr

**** 비 회 원 : 연세대학교 컴퓨터과학과

ksy2177@yonsei.ac.kr

***** 종신회원 : 연세대학교 컴퓨터과학과 교수

hrbyun@yonsei.ac.kr

논문접수 : 2004년 2월 5일

심사완료 : 2007년 5월 21일

과 특징 추출에 매우 의존적인 것은 당연하다.

따라서 본 논문에서는 인식 결과에 큰 영향을 주는 조명 변화에 초점을 맞춰 이에 강건히 대처하는 성질을 지니며 특징 추출에 가장 적합하게 쓰일 수 있는 알고리즘으로써 특히 얼굴 인식에 적합한 D-LDA(Direct-Linear Discriminant Analysis)의 성질을 밝히고자 한다.

2. 부분공간 기반의 특징 추출 기법

이미지가 시험될 수 있는 많은 무한 공간 중 본래 고차원 공간을 이용하기 보다는 개인의 얼굴을 좀 더 잘 기술하며 식별할 수 있는 새로운 저차원을 이루는 부분공간을 만들어 내는 것이 중요하다. 이러한 공간을 부분공간이라고 하며 가장 대표적인 두 부분 공간으로 PCA(Principle Components Analysis)의 고유 공간과 LDA(Linear Discriminant Analysis)의 Fisher 판별공간(선형판별공간)이 있다. PCA는 고차원 얼굴 이미지 공간에서 저차원 고유 공간으로 데이터를 표현하는 방법이고, LDA는 데이터들의 각 클래스 간 가장 좋은 분류를 갖는 공간을 찾아내는 방법이다. 즉, 클래스 간 가장 의미 있게 설명해 주기 위한 기준으로 판별분석에서는 클래스 간 분산(between-class scatter matrix: S_w)과 클래스 내 분산(within-class scatter matrix: S_b)의 비율을 사용하여 클래스 내 분산은 최소로 하고 클래스 간 분산을 최대화 하여 분류한다.

Michael Kirby가 처음으로 얼굴들의 특징이 저차원 공간에서 표현될 수 있는 아이디어를 제시했으며, 고유 공간 투영 사용의 예들은 [3,4]에서 볼 수 있다. Turk등 [5]은 얼굴 인식을 위한 고유 공간 투영을 연구하였으며 Belhumeur등[6]은 또한 다양한 빛 조건하에 여러 얼굴들을 학습시키고 테스트함으로써 얼굴은 식별하기 위해 Fisher 공간을 이용하였다.

LDA는 직접적으로 클래스들 간 구별을 다루나 PCA는 클래스 구조에 대한 어떤 특정한 관심 없이 전체적으로 데이터 주성분 분석을 중점적으로 다루기 때문에 직관적으로 LDA가 PCA보다 인식에 더 나은 성능을 지닌다고 여기고 있다. 그러나 실제로 얼굴과 같이 각 얼굴 이미지당 학습 샘플수가 적은 대상에서는 PCA가 LDA보다 우세한 결과를 보여준다[7]. 이러한 LDA의 문제를 해결하여 LDA가 갖는 특징을 살리기 위한 방법들이 계속적으로 연구되고 있다. LDA는 클래스당 적은 샘플 수의 문제로 샘플의 수가 샘플의 차원보다 작을 때 일어나며 이러한 환경하에, 샘플 분산행렬(scatter matrix)은 정칙행렬(singular matrix)이 되어 계산적 어려움을 갖게 되는 것이다. 최근, 많은 연구원들이 이 문제를 주시해왔고 여러 다른 방법들이 제시되어 그러한 문제를 풀어 나가고 있다. 여러 방법들 중 저차원 공간

이용을 위한 한번의 투영 대신 두 번의 투영을 이용하는 PCA+LDA 방법[8]도 있다. 3장에서는 이러한 LDA의 문제를 해결하기 위해 제안한 D-LDA방법에 대해 설명하겠다.

3. D-LDA(Direct-Linear Discriminant Analysis)

새로운 LDA 알고리즘인 D-LDA는 가장 분류 정보를 많이 포함하는 S_w 의 영공간을 버리기보다, 유용한 정보를 포함하지 않은 S_b 의 영공간을 버리자는 것이 주된 핵심이다. 이는 S_w 의 영공간에서 투영된 벡터들을 계산함으로써 시작한다. 영공간은 S_w 의 고유값이 0인 집합에 해당하는 고유벡터들로 생성될 수 있다. 이러한 부분공간이 존재하지 않는다면, S_w 는 비정칙행렬(non-singular matrix)이므로 $S_t(=S_b+S_w)$ 또한 비정칙행렬이다. 이러한 상황하에, 가장 분류가 뛰어난 벡터 집합으로써 행렬 $(S_b+S_w)^{-1}S_b$ 의 가장 큰 고유값들에 해당하는 고유벡터들을 선택할 수 있다. 그러나 그렇지 않은 상황에서는 적은 샘플 크기 문제가 발생하며 이러한 경우에 S_w 의 영공간의 투영 축으로써 변형된 샘플들의 S_b 를 최대화하는 벡터 집합을 선택한다. 모든 샘플들은 S_w 의 영공간에서 영인 한 점으로 모이므로 LDA의 목적을 만족할 수 있는 투영 벡터는 S_b 를 최대화할 수 있는 것이다.

3.1 클래스 내 분산 행렬의 영공간을 이용한 D-LDA

데이터 집합이 클래스당 M 개의 샘플로 K 개의 클래스를 이루고 있다고 하면 x_m^k 는 k 번째 클래스의 m 번째 샘플에서 추출된 특징 벡터를 나타내는 n 차원 열벡터이다.

$$\begin{aligned} \text{rank}(S_t) &\leq \text{rank}(S_b) + \text{rank}(S_w), \\ \text{rank}(S_t) &= \min(n, KM - 1) \\ \text{rank}(S_b) &= \min(n, K - 1) \\ \text{rank}(S_w) &= \min(n, K \times (M - 1)) \end{aligned} \quad (1)$$

D-LDA의 주된 관점은 S_w 의 영공간에서 분류 투영 벡터들의 집합을 결정하는 것이다. 그러므로 S_w 의 위수(rank)는 틀림없이 D-LDA의 중요한 초점이 된다. S_w 의 위수는 r 이다. $r = \min(n, K \times (M - 1))$. $r = n$ 이면,

$$\begin{aligned} K \times (M - 1) &\geq n \Rightarrow K \times M \geq n + K \\ &\Rightarrow K \times M - 1 \geq n + K - 1 \geq n \end{aligned} \quad (2)$$

따라서 S_w 이 비정칙 행렬이라면 S_t 또한 비정칙행렬이다. 이러한 상황하에, 행렬 $S_t^{-1}S_b$ 이 일반 LDA방법에서 계산될 때 어떠한 특이성 문제도 발생하지 않는다. 반면에, r 이 n 보다 작다면 적은 샘플 크기 문제가 발생한다. 이러한 경우에 최적 투영 벡터들을 유도하기 위한 새로운 방법이 D-LDA인 것이다.

그럼 1은 $r < n$ 일 때 최적 투영 벡터들을 유도하는 방법 보여준다. $T(x) = S_w x$, $x \in V$. S_w 의 위수가 $V(r < n)$ 의 차원보다

작기 때문에 $V_0 = span\{\alpha_i | S_w \alpha_i = 0, \alpha_i \in \mathbb{R}^n, i = 1, \dots, n-r\}$ 와 같은 부분공간 $V_0 \in V$ 이 존재한다. V_0 는 S_w 의 영공간이라 하고 $Q = [\alpha_1, \dots, \alpha_{n-r}]$ 라 하면, 먼저 모든 샘플 X 는 변형 QQ^T 를 통해 V 에서 그것의 부분공간 V_0 으로 변형된다. 그리고 나서, \tilde{S}_b (변형된 샘플로 형성된 새로운 행렬)의 가장 큰 고유값에 해당하는 고유벡터들이 가장 잘 분류하는 벡터로 선택된다.

LDA 방법은 모든 샘플들에 대해 가장 잘 분류하는 투영 축들의 집합을 결정하는 데 쓰임을 언급했다. 투영 후, 모든 투영된 샘플들은 최소 S_w 와 최대 S_b 형태를 갖는다. 어떠한 $\tilde{q} \in V_0$ 에 대해서도 $\tilde{q}^T S_b \tilde{q}^T = 0$ 을 만족하는 한 수정된 Fisher의 기준함수 $\tilde{F}(\tilde{q})$ 은 1로 최대화 될 것이다. 그러나 LDA를 수행하기 위해 Fisher의 기준함수에 의존만 할 것이 아니라 또 다른 기준을 더해야 함을 알려준다. 임의의 $\tilde{q} \in V_0$ 의 선택은 $\tilde{S}_w = 0$ 이 되도록 한다. 즉, $\tilde{S}_t = \tilde{S}_w + \tilde{S}_b = \tilde{S}_b$. \tilde{S}_w 은 확실히 0이기 때문에 V_0 에서 S_b 를 최대화 할 수 있는 투영 축들의 집합을 선택해야만 한다. 결국 V_0 에 있는 S_b 를 최대화하는 것은 V_0 에 S_t 를 최대화하는 것과 동일하다.

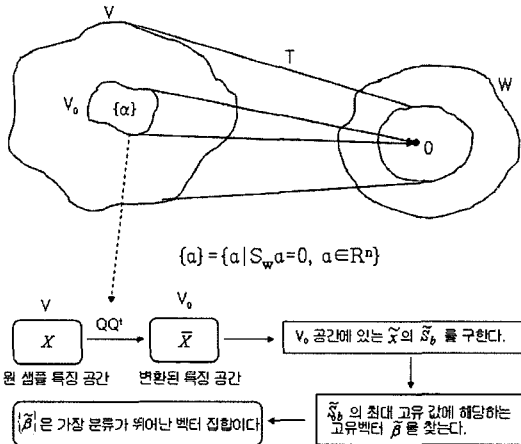


그림 1 투영 벡터 집합 결정 과정[9] (위 : V 는 원 샘플 공간, T 는 선형변환, W 는 V_0 은 S_w 의 영공간, 아래: 분류 벡터 결정 방법의 흐름도)

3.2 커널 D-LDA

앞서 설명한 특징 추출 알고리즘들은 선형 공간에서 수행한다. 그러나 대부분의 인식 대상 특히, 얼굴은 조명, 포즈 그리고 표정 변화 등에 의해 매우 복잡한 비선형 패턴을 이룬다. 비선형 특징들이 선형 공간에서의 특징 추출을 통한 한정된 결과를 해결하고자 패턴이 선형

을 이룰 수 있는 임의의 특징 공간에서 수행함으로써 입력 공간에서의 비선형 수행과 동일한 효과를 얻도록 한다. 임의의 특징 공간은 원 입력 공간보다 고차원으로 비선형 패턴을 가진 데이터들이 선형 패턴으로 이룰 수 있는 공간을 의미한다. 이러한 특징 공간은 무한대 차원으로 언급할 수 있는 매우 고차원이기 때문에 특징 공간에서의 축은 입력 공간의 축보다 훨씬 많으며 이것은 입력 공간에서의 축보다 많은 정보를 갖는 축이 훨씬 많아짐을 의미한다. 그러나 무한대 차원에 가까운 매우 고차원인 특징 공간으로의 사상 함수(Φ)를 찾는 것은 거의 불가능하다. 보통 데이터를 직접 특징 공간으로 사상하는 대신 특징 공간에서 데이터 간 내적 연산을 수행한 값을 출력하는 커널 함수를 이용하여 특징 공간에서의 데이터 분석을 수행할 수 있도록 커널을 도입하였다.

커널 D-LDA는 앞서 설명한 D-LDA 방법에 비선형 방법을 사용함으로써 선형 분류로 발생하는 많은 제한을 해결하도록 커널 기법을 도입하여 적용한 방법이다. 즉, 커널 D-LDA는 입력 공간 R^N 대신 특징 공간에서 D-LDA를 수행한다. 특징 공간 F 에서 S_b 와 S_w 를 각각 다음과 같이 나타낼 수 있다.

$$S_b = \sum_{k=1}^C (\Phi(\mu_k) - \Phi(\mu))(\Phi(\mu_k) - \Phi(\mu))^T \quad (3)$$

$$S_w = \sum_{k=1}^C \sum_{m=1}^{N_k} (\Phi(x_m^k) - \Phi(\mu_k))(\Phi(x_m^k) - \Phi(\mu_k))^T \quad (4)$$

투영된 데이터에 대해 D-LDA 방법을 통해 특징 공간에서 최적의 판별 기저 벡터들의 집합을 찾는 것이다. 임의의 사상 함수 Φ 를 이용하여 입력 공간에서 고차원 특징 공간 F 로의 비선형 사상을,

$$\Phi: z \in R^V \rightarrow \Phi(z) \in F \quad (5)$$

라 하면, 이는 다른 얼굴들이 선형적으로 분리 될 수 있다고 가정하는 것이다. 이러한 특징 공간으로의 수정된 S_b 와 S_w 를 가지고 D-LDA 과정을 동일하게 거치는 것이다.

4. 실험 및 결과 고찰

본 실험은 여러 특징 추출 기법 중에서 D-LDA가 다른 추출 기법에 비해 조명 변화에 강건히 대처할 수 있는 성질을 지니고 있음을 밝히고자 한다. 실험은 크게 두 부분으로 나누어 진행되었다. 첫 번째는 임의로 조명 변화를 준 가상의 이미지들을 생성하여 이들을 학습 데이터에 첨가시킨다. 이로써 얼굴 인식에 가장 문제가 되는 적은 학습 샘플 문제를 해결하며 전반적으로 모든 특징 추출 알고리즘이 다양한 조명에 대처하는 정도에 대한 평가를 한다. 두 번째는 일반 조명 환경의 학습 데이터에 조명 변화가 다양한 실험 데이터들을 생성하거나 학습 데이터와 구분 지어서 조명 변화에 가장 덜 민

감하게 대응하는 알고리즘을 밝히고자 성능을 평가한다.

4.1 실험 환경 및 데이터 전처리

본 논문에서 제안한 얼굴 인식 성능 향상 방법의 테스트 환경 Window XP, Pentium-IV 1.8 GHz, 512MB 에서 Microsoft Visual C++6.0과 MATLAB 6.5를 이용하여 구현하였다. 기실험 데이터는 ORL[10], Yale[11], 포항공대[12] 데이터를 사용하였으며, 가우시안 필터링을 통해 잡음을 제거하고 얼굴의 두 눈이 수평을 이루도록 수동적으로 찍어 얼굴 이미지를 회전시킨 후 이미지의 크기를 32*32로 축소하는 전처리를 하였다. 또한 보다 균일한 명암 분포를 갖도록 명암값을 재분배하는 히스토그램 평활화 과정을 거친 후 이미지의 배경 정보를 마스킹 처리를 하였다.

4.2 조명 변화를 지닌 가상 학습 이미지 결합을 통한 얼굴 인식 성능

4.2.1 얼굴 이미지의 조명 변화

실생활에서 얻을 수 있는 이미지에서 발생하는 조명 조건은 크게 일정한 밝기의 이미지, 정면광 이미지, 측면광 이미지, 역광 이미지, 전체적으로 어두운 이미지로 다섯 가지로 나누어 볼 수 있다. 본 실험에서는 일정한 밝기를 갖는 원 이미지에 여러 방향(좌우, 좌상, 좌하, 우상, 우하 등)의 측면광과 역광, 정면광 등의 성질을 지닌 조명을 각각 씌운 여러 개의 가상 이미지들을 생성하도록 한다. 조명 변화에 따른 가상이미지는 두가지 방법으로 생성한다.

첫 번째는 원 얼굴 이미지에 조명 강도 정도를 3단계로 변화시켜 가며 좌우 방향에서 비춰진 새로운 조명 이미지를 생성한다. x위치에 따라(왼쪽, 오른쪽) 화소 강도를 선형적으로 변화하게 함으로써 실제 조명을 씌운 듯한 이미지를 생성하도록 한다.

$$Illu(y,x) = I(y,x) + mx + \alpha, \quad m = \frac{-\alpha}{(width/2)}$$

I(y,x) : 원 이미지, Illu(y,x) : 변화된 이미지,
width=이미지 가로 길이 (6)

그림 2는 α값을 60, 80, 100으로 변화시키면서 좌우

방향에서 조명이 비춰진다는 가정하에 생성된 이미지를 보여준다. 두 번째는 여섯 방향에서 비춰져 형성할 수 있는 강도값을 추정한 조명 틀을 만들어 원 영상에 입히고 부분적으로 음영을 적용하는 방법이다. 조명틀은 측면광의 성질을 이용하여 비춰진 방향은 밝고 그 반대 쪽은 어두워짐을 가정하여 생성되는 것이다. 더불어 역광과 정면광의 성질을 지닌 가상 이미지를 포함 시킨다.

4.2.2 데이터 구성 및 실험 결과

학습과 실험 데이터 구성은 1 : 1 비율 즉, 각 클래스 당 각각 5개의 학습 데이터와 실험 데이터를 갖도록 하였으며, 10-fold cross validation으로 매 폴더마다 데이터를 랜덤하게 뽑아 구성하여 실험하였다. 가상 이미지를 첨가한 학습 데이터는 클래스 당 5개 이미지 각각에 8 종류의 조명을 변화시켰으므로 클래스 당 45개의 학습 데이터와 실험 데이터로 구성된다. 새로운 PCA, PCA+LDA, D-LDA 그리고 커널 D-LDA 알고리즘을 ORL 얼굴 데이터에 대해 원 학습 데이터와 다양한 조명 변화를 입힌 가상의 이미지들을 결합한 학습 데이터에 대한 인식 성능 평가 비교로 이루어진다. 인식기는 단순하고 빠르게 수행하는 1-NN(1-Nearest Neighbor) 분류기를 이용한다. 유사도 측정치는 MSE(Mean Square Error)을 적용한다.

PCA 변환에서 고유 벡터 개수 선택이 인식의 영향을 미친다. 그러므로 저차원의 좋은 성능을 낼 수 있는 적당한 고유 벡터 수를 결정하는 실험 또한 필요하다. 사용자가 경험적으로 고유 벡터 수를 고정하거나 하한 임계값을 정해 그 이상이 되는 고유값에 해당하는 고유 벡터 수 만큼을 선택할 수 있다. 표 1은 실험에서 사용된 각 알고리즘의 최적 기저수이다.

언급한 PCA, PCA+LDA, D-LDA, 커널 D-LDA 알고리즘이 조명에 강인하도록 가상 데이터를 첨가하여

표 1 각 알고리즘의 최적 기저 수

특징추출알고리즘	PCA	PCA+LDA	D-LDA	커널 D-LDA
기저수	60	39	30	39



(a)



(b)

그림 2 조명 변화를 통해 생성된 이미지의 예 (a) 왼쪽 조명 (b) 오른쪽 조명 (왼쪽: 원 이미지, 두 번째열부터 네 번째열까지 α = 60, 80, 100)

학습시킨 방법이 항상 좋은 성능을 보임을 알 수 있다. 데이터가 적은 상태에서는 PCA가 LDA보다 좋은 성능을 보이거나 가상 데이터로 인해 클래스마다 학습하는 데이터를 증가시키으로써 LDA가 좋은 분류 능력을 보였다. 또한 이미지를 나타내는 차원수 보다 적은 샘플로 발생하는 LDA의 근본적인 문제를 해결한 D-LDA가 분류에 매우 뛰어나게 특징을 추출함이 실험을 통해 확인할 수 있다. 그러나 뛰어난 분류 능력에도 불구하고 한정된 성공을 보이는 선형 특징 추출기인 D-LDA의 추출공간을 데이터들이 선형을 이룰 수 있는 공간으로 수정하여 그 공간에서 특징 추출을 한 커널 D-LDA가 D-LDA의 부족한 능력을 보완해 줌을 표 2가 보여준다. 즉, 가상 이미지를 통한 성능 향상이 비선형 데이터가 형성하는 공간에서의 선형 판별을 최적화 한 D-LDA에서는 이루어지지 않다가 선형을 이룰 수 있는 공간에서 최적 판별을 수행하므로 커널 D-LDA에서 다시 좋은 성능 향상을 보여주는 것이다.

표 2 전체 알고리즘 인식률

	PCA	PCA+LDA	D-LDA	커널 D-LDA
data	76.2%	74%	89.2%	90.85%
data with virtual	78.44%	79.65%	90%	91.5%

4.3 다양한 조명 변화에 대한 특징 추출 알고리즘들의 얼굴 인식 성능

조명에 강인할 수 있도록 조명 변화를 갖는 새로운 이미지를 각 알고리즘의 학습 과정에 첨가한 4.2절의 실험은 모든 알고리즘에서 향상된 성능을 보임을 확인할 수 있었다. 그러나 매번 가상 이미지 생성하여 이를 학습하는 과정은 많은 계산과 시간을 필요로 하여 과부하가 발생한다. 본 실험에서는 추가적인 가상 이미지의 학습과정으로 인한 부하없이 다양한 조명 변화를 갖는 데이터를 실험 데이터로 구성하여 조명 변화에 강건하게 대응하는 D-LDA의 성질을 밝혀내고자 한다.

4.3.1 데이터 구성 및 실험 결과

학습과 실험 데이터 구성은 약간의 조명 변화가 있는 ORL 데이터 경우 4.2절의 실험과 마찬가지로 1 : 1 비율의 학습/실험 데이터에 대한 실험과 실험 데이터에 여러 방향의 조명 변화에 대한 가상 이미지를 생성하여 실험 데이터에 첨가한 후의 성능을 평가하도록 하였다. 이 또한 10-fold cross validation으로 매 폴더마다 데이터를 랜덤하게 뽑아 구성하여 실험하였다. Yale 데이터와 포항공대 데이터의 경우 정면, 좌, 우, 상, 하 조명 변화를 갖는 데이터들만 추려 내어 각 클래스마다 특별한 조명 영향 없는 평범한 한 장의 정면 이미지로 학습을 수행하고, 조명 변화가 있는 실험 데이터를 yale 데

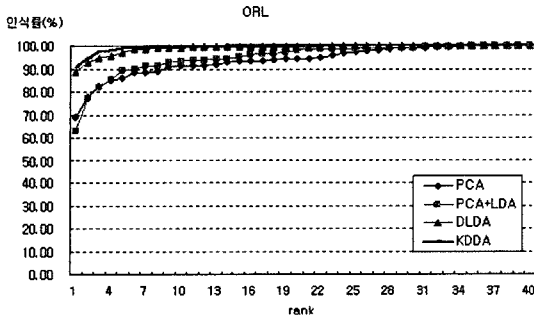
이터의 경우 클래스 당 2장, 포항공대 데이터의 경우 클래스 당 4장으로 구성하여 실험하였다. 인식기와 유사도 측정치 또한 4.2절의 실험과 동일하다.

클래스, 학습 데이터 그리고 실험 데이터의 수가 각각 다른 세 종류의 얼굴 데이터를 이용하여 다양한 조명 변화를 준 새로운 데이터에 대한 인식 성능 평가 결과 D-LDA가 조명에 덜 민감한 성질을 지니고 있음을 보인다. 클래스 당 학습 이미지가 하나인 Yale 데이터와 포항공대 데이터에서는 PCA+LDA 알고리즘은 행렬 값이 모두 0인 클래스 내 분산 행렬에서 0보다 큰 고유값에 해당하는 기저들이 존재하지 않기 때문에 적용할 수 없으므로 이를 제외한 나머지 세 알고리즘을 실험하며 그들 간 랭크 변화를 보았다. FERET의 얼굴 인식 성능 평가 방법론에 의하면 신원을 인증/검증 받고자 하는 테스트 이미지들이 데이터베이스에 저장되어 있는 이미지들과 유사도 계산 시 랭크를 n으로 결정하여 상위 n번째에 정답 이미지가 존재하면 인식되었다고 결정하는 것이 신뢰할 만한 성능 평가 방법임을 언급했다. 이러한 방법으로 최종 100%에 다다르게 되며 얼마나 빠르게 100%에 수렴하는지가 알고리즘의 인식 성능을 결정한다.

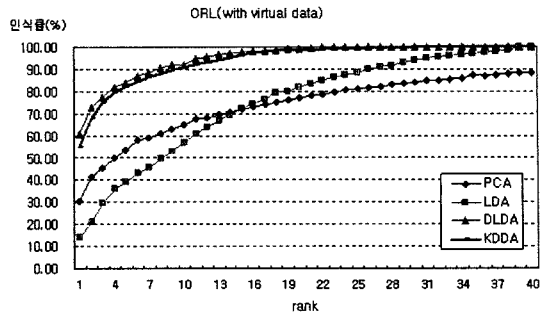
ORL 데이터의 경우 기존 실험 데이터에 대한 실험 그림 3(a)와 가상으로 조명 변화를 주어 생성된 이미지를 실험한 그림 3(b)에서 모두 D-LDA가 좋은 성능을 보임을 나타내며 특히 매우 다양한 조명 변화를 준 이미지에 대한 두 번째 실험 그림 3(b)의 경우 D-LDA가 두드러진 성능 변화를 보인다. 다른 데이터베이스에 비해 클래스 수가 매우 적은 Yale 데이터 또한, D-LDA가 랭크에 따라 매우 큰 폭으로 성능이 향상됨을 그림 3(c)에서 보여준다. 포항공대 데이터의 경우 D-LDA와 PCA간의 인식을 변화 차가 다른 두 데이터보다는 뚜렷하게 큰 차이를 보이지 않지만 적당한 랭크 범위 안에서 우월한 성능 결과를 그림 3(d)에서 보여주고 있다.

6. 결론


본 논문에서는 조명 변화에 따라 동일 얼굴들간 다양성으로 인식 성능 저하를 가져오는 조명에 초점을 맞춰 이 변화에 덜 민감하게 대응하는 성질을 지니며 특징 추출에 가장 적합하게 쓰일 수 있는, 특히 얼굴 인식에 적합함을 지닌 D-LDA의 성질을 밝혀냈다. 여러 방향의 조명을 고려하여 가상의 학습 이미지를 생성하며 가장 적합한 특징 추출기로 선택된 D-LDA에 결합함으로써 조명에 보다 강건히 대응할 수 있는 향상된 인식 시스템을 보였다. 이 방법은 측면광의 성질을 이용하여 6 방향의 조명 효과와 조명 농도의 변화 및 역광, 정면광을 고려한 가상의 학습/테스트 이미지들을 생성하여 생




(a)



(b)



(c)



(d)

그림 3 rank에 따른 인식률 변화 : (a)ORL 데이터 (b)데이터 + 가상 실험 데이터 (c)Yale 데이터 (d)포항공대 데이터

성된 학습 데이터들을 기존의 특징 추출기와 결합한 결과 모두 향상된 인식 결과를 보였으며, 그 중에 D-LDA와 커널 D-LDA와의 결합에서 높은 인식 결과를 얻을 수 있다. 또한 가상 학습 데이터를 첨가하여 세 종류의 데이터베이스의 테스트 데이터들로부터 여러 특징 추출 알고리즘을 적용함으로써 모두 D-LDA가 적은 학습 데이터에서도 조명 변화에 가장 좋은 결과를 주며 조명에 둔감한 성질을 지녔음을 보였다.

참 고 문 헌

[1] P.J.Phillips, P.Rauss, and S.Der, "FERET Recognition Algorithm Development and Test Report," Technical Report ARL_TR 995, U.S. Army Research Lab.
 [2] P.J.Phillips, H.Moon, P.Rauss, and S.A.Rizvi, "The FERET Evaluation Methodology for Face-Recognition Algorithms," in Proceedings, IEEE Conference on CVPR, 137-143, 1997.
 [3] M.Kirby and L.Sirovich, "Application of the Karhunen-Loeve procedure for the Characterization of human faces," IEEE trans, PAMI, 12(1), 103-108, 1990.
 [4] L.Sirovich and M.Kirby, "A low-dimensional procedure for the characterization of human faces,"

The journal of the optical society of America, 4 : 519-524, 1987.
 [5] M.A.Turk and P.Pentland, "Face recognition using Eigenfaces," Proc. of IEEE Conference on CVPR, 586-591, 1991.
 [6] P.N.Belhumeur, J.P.Hespanha and D.J.Kriegman, "Eigenfaces vs. fisherfaces: recognition using class specific linear projection," IEEE Trans. PAMI, 19(7), 711-720, 1997.
 [7] A.M. Martinez and A.C. Kak, "PCA versus LDA," IEEE Trans. on PAMI, vol. 23, 228-233, 2001.
 [8] K.Fukunaga, Introduction to Statistical Pattern Recognition, Academic Press, New York, 1990.
 [9] L.F.Chen, H.M. Liao, M.T. Ko, J.C. Lin, and G.J. Yu, "A new LDA-based face recognition system which can solve the small sample size problem," Pattern Recognition, vol.33, 1713-1726, 1997.
 [10] ORL FaceDatabase, <http://www.uk.research.att.com/facedatabase.html>
 [11] Yale Face Database, <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
 [12] Asian Face Image Database PF01, <http://nova.postech.ac.kr>

김 광 수

정보과학회논문지 : 소프트웨어 및 응용
제 34 권 제 3 호 참조



부 덕 회

2004년 연세대학교 컴퓨터과학과 석사
졸업. 2004년~현재 삼성전자 디지털미디어
어총괄 디지털프린팅사업부 연구원. 관심
분야는 영상처리, 컴퓨터 비전 및 패턴인
식

안 정 호

정보과학회논문지 : 소프트웨어 및 응용
제 34 권 제 1 호 참조



곽 수 영

2005년 연세대학교 컴퓨터과학과 석사
졸업. 2005년~현재 연세대 컴퓨터과학과
박사과정. 관심분야는 영상처리, 컴퓨터
비전 및 패턴인식

변 해 관

정보과학회논문지 : 소프트웨어 및 응용
제 34 권 제 1 호 참조