

# LDA와 Local MLP를 이용한 얼굴 인식

## Face Recognition using LDA and Local MLP

이대종, 최기선, 전명근

충북대학교 전기전자컴퓨터공학부

Dae-Jong Lee, Gee-Seon Choi, Myung-Geun Chun\*

Chungbuk National University

School of Electrical and Computer Engineering

E-mail : mgchun@chungbuk.ac.kr

### 요약

MLP는 뛰어난 학습능력으로 인하여 많은 분야에 성공적으로 적용되고 있다. 그러나, 학습 방법으로서 최급경사법에 근거한 오차역전파 알고리즘을 적용하기 때문에 학습시간이 오래 걸리는 단점이 있다. 또한 입력차원의 크기가 크거나 클래스간 학습데이터의 유사성이 클 경우 최적의 파라미터를 구하는데는 한계가 있다. 이러한 문제점을 해결하기 위해 본 논문에서는 LDA와 local MLP을 이용한 새로운 얼굴인식시스템을 제안하고자 한다. 제안된 방법은 우선 LDA 기법에 의해 차원이 축소된 얼굴의 특징벡터를 계산한다. 다음 단계로서 전체 학습영상을 사용하기 보다는 그룹별로 분할된 얼굴영상에 대해 MLP를 수행하므로 그룹별로 최적인 파라미터를 결정한다. 마지막 단계로 그룹별로 수행된 local MLP를 결합함으로써 전체 얼굴인식 시스템을 구성한다. 제안된 방법의 타당성을 보이기 위해 ORL 얼굴영상을 대상으로 실험한 결과 기존 방법인 PCA나 LDA에 비해 향상된 결과를 보임을 확인할 수 있었다.

### 1. 서 론

오늘날 우리는 급속도로 발전하는 정보화사회에 살고 있다. 이러한 정보화사회는 정보의 생성, 저장, 처리, 운반, 검색 기능이 상호 연결된 통신망 환경하에서 다양한 형태의 정보 서비스를 제공하고 있다. 그러나 인가 받지 않은 불법 사용자로 인한 정보시스템의 파괴, 개인 신상의 누설 및 유출, 불건전 정보의 유통 등과 같은 정보화의 역기능으로 인해 고통 받고 있다. 이에, 기존의 단순한 형태의 개인확인 및 검증방법의 한계를 극복하기 위해, 새로운 형태의 신분검증 방법에 대한 연구가 한창 진행중이다.

바이오메트릭스(Biometrics)는 개인의 신원확인 혹은 인증을 위해 생리학적이거나 행동학적인 특징들을 획득하여 연구하는 분야이다. 바이오메트릭스 가운데 얼굴인식은 자연스러우면서도 직접적인 생체인식 방법이며, 컴퓨터 비전,

영상처리, 패턴인식과 같은 다양한 분야에서 연구되어지고 있다. 그러나, 얼굴인식은 조명의 방향, 얼굴의 포즈, 얼굴 감정과 같은 큰 변동에 의해 매우 어려운 문제점을 가지고 있다. 얼굴인식을 위해 가장 잘 알려진 방법들은 eigenface와 Fisherface 방법이다. eigenface 방법은 주성분 분석기법(Principal Component Analysis)에 의해 변환된 특징벡터를 이용한다. 이 방법은 얼굴영상 공간을 저차원의 특징공간으로 선형적으로 투영하는 것을 기초로 하고 있다. 얼굴인식을 위한 eigenface 방법의 주된 문제점은 주성분 분석 기법이 조명이나 얼굴감정으로 인해 원하지 않는 변동을 보유하기 때문에 저차원으로의 차원축소에는 최적의 방법이지만 분류에 있어서는 그렇지 않다[1-2]. 이러한 eigenface 방법의 확장된 접근 방법이 많이 제시되었다[3-4]. 한편, Fisherface 방법은 주성분 분석 기법과 선형판별 분석법(Linear Discriminant Analysis)을 이용하며, 조명 방향이나 얼굴 포즈 및 감정과 같은 큰

변화에도 민감하지 않은 장점을 가지고 있다. 여기서 선형판별 분석법은 클래스간 분산 행렬(Between-Class Scatter Matrix)과 클래스내 분산 행렬(Within-Class Scatter Matrix)의 비가 최대화하는 통계적 방법으로, 선형판별 분석법과 관련된 다양한 얼굴인식 방법들이 있다[5-6]. 그러나 기존 방법들은 최종 인식을 위해 k-NN(k-nearest neighbor) 분류기를 적용하였다. k-NN 분류기의 경우 동일한 클래스 내의 특징벡터가 선형성을 갖는 경우 우수한 인식성능을 보이지만 비선형 특성을 갖는 경우에는 k-NN 분류기와 같은 분류기는 효과적이지 못하다.

이러한 문제점을 해결하기 위해 최종 얼굴인식을 위한 분류기로서 k-NN 대신 신경회로망 구조를 갖는 MLP를 적용하고자 한다. MLP는 뛰어난 학습능력으로 인하여 많은 분야에 성공적으로 적용되고 있다. 그러나, 학습 방법으로서 최급경사법에 근거한 오차역전파 알고리즘을 적용하기 때문에 학습시간이 오래 걸리는 단점이 있다. 또한 입력차원의 크기가 크거나 클래스간 학습데이터의 유사성이 클 경우 최적의 파라미터를 구하는데는 한계가 있다. 이러한 문제점을 해결하기 위해 본 논문에서는 LDA와 local MLP을 이용한 새로운 얼굴인식시스템을 제안하고자 한다. 제안된 방법은 우선 LDA 기법에 의해 차원이 축소된 얼굴의 특징벡터를 계산한다. 다음 단계로서 전체 학습영상을 사용하기 보다는 그룹별로 분할된 얼굴영상에 대해 MLP를 수행하므로 그룹별로 최적인 파라미터를 결정한다. 마지막 단계로 그룹별로 수행된 local MLP를 결합함으로써 전체 얼굴인식 시스템을 구성한다. 제안된 방법의 타당성을 보이기 위해 ORL 얼굴영상을 대상으로 실험한 결과 기존 방법인 PCA나 LDA에 비해 향상된 결과를 보임을 확인할 수 있었다.

본 논문의 구성은 다음과 같다. 2절에서 제안된 얼굴인식시스템에 대하여 설명하고, 3절에서는 각각 ORL 얼굴 데이터 베이스에 제안된 방법을 이용함으로서 얻어진 실험 결과를 나타낸다. 마지막으로 결론은 4절에서 기술되어진다.

## 2. 퍼지 Fisherface를 이용한 얼굴인식 방법

본 논문에서 제안된 얼굴인식 시스템을 그림 1에 나타냈다. 그림 1에서 보는 바와 같이 제안된 방법은 특징추출부와 모델형성부로 나누어진다. 얼굴영상에 대한 특징벡터는 주성분분석과

선형판별분석기법에 의해 행해진다. 모델형성부는 Local MLP에 의해 이루어지면 최종 인식은 MLP의 출력값중 최대값을 갖는 영상을 인식함으로써 이루어진다.

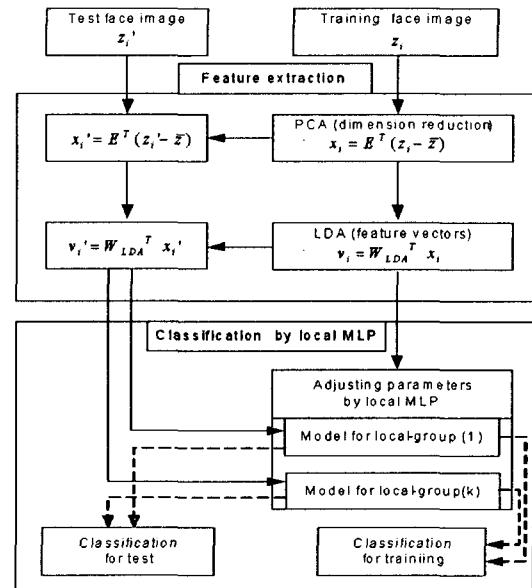


그림 1. LDA와 Local MLP을 이용한 얼굴인식 시스템

특징추출에 사용한 주성분분석기법과 선형판별분석기법을 이용한 얼굴의 특징추출 과정을 살펴보자 한다. 주성분 분석 기법(PCA)은 다변수 선형 데이터 분석에서 잘 알려진 기법이며 주된 개념은 데이터의 최대 분산 방향을 나타내는 상호직교 기저 벡터의 집합을 찾는 것을 목적으로 하며, 이때, PCA를 이용한 eigenface 방법은 다음과 같이 간략히 기술되어진다. 하나의 얼굴영상이 각각의 화소 값을 갖는 2차원 배열( $n \times n$ )이라고 가정하자. 영상  $z_i$ 는 연속적인 행들의 연결로  $n^2 \times 1$ 의 벡터로서 고려되어진다. 그러면  $N$ 개 얼굴영상의 학습 집합은  $Z = (z_1, z_2, \dots, z_N)$ 로 표시된다. 공분산 행렬을 정의하면 다음과 같다.

$$R = \frac{1}{N} \sum_{i=1}^N (z_i - \bar{z})(z_i - \bar{z})^T = \mathbf{\Phi}\mathbf{\Phi}^T \quad (1)$$

$$\bar{z} = \frac{1}{N} \sum_{i=1}^N z_i \quad (2)$$

그리면, 공분산 행렬의 고유치와 고유벡터가 계산되어진다. 여기서  $r$ 개의 가장 큰 고유치에

대응하는  $r$ 개의 고유벡터를  $E = (e_1, e_2, \dots, e_r)$ 라 하자. 얼굴영상의 집합  $Z$ 에 대해서, 그것들의 대응되는 특징벡터  $X = (x_1, x_2, \dots, x_N)$ 는 다음과 같이  $Z$ 를 PCA-변환된 공간으로 투영함으로서 얻어진다.

$$x_i = E^T(z_i - \bar{z}) \quad (3)$$

여기서  $x_i$ 는  $i$ 번째  $r \times 1$  벡터이다. 얼굴인식을 위한 거리 측정은 식 (4)와 같이 유clidean 거리를 사용한다. 이 거리 측정은 학습 집합의 영상들과 테스트 집합의 주어진 영상 사이에서 정의된다. 학습 영상  $z$ 와 주어진 테스트 영상  $z'$  사이의 거리 측정  $\epsilon(z, z')$ 은 다음과 같은 PCA에 의해 변환된 공간에서 정의된다.

$$\epsilon(z, z') = \|x - x'\| \quad (4)$$

여기서  $x$ 와  $x'$ 은 각각 얼굴 영상  $z$ 와  $z'$ 의 PCA-변환된 특징 벡터이다. 이러한, 주성분 분석 기법은 차원 축소에는 최적의 방법이 될 수 있으나, 변환된 특징 벡터들이 특정공간에서 서로 겹치는 현상으로 인해 데이터 분류에는 어려운 점이 있으며, 조명이나 보는 각도, 얼굴 감정과 같은 원하지 않는 변동을 보유하는 문제점을 가지고 있다.

선형판별분석법은 분류를 위해 최적의 투영을 찾는 방법 중의 하나로, 투영된 분산을 최대화하는 투영을 찾기보다는 클래스간 분산 (Between-Class Scatter Matrix) 행렬과 클래스내 분산(Within-Class Scatter Matrix) 행렬의 비가 최대가 되는 최적의 투영 행렬을 찾는 것이다. 또한, 분류는 투영된 공간에서 간소화되어지며, 최적 투영행렬  $W_{FLD}$ 를 계산하기 전에 클래스내 분산 행렬이 정칙이 되도록 주성분 분석 기법을 이용하여 영상공간을 저차원 공간으로 투영함으로서 수행할 수 있다. 주성분 분석 기법과 선형판별분석법을 이용한 Fisherface 방법은 다음과 같이 서술되어진다.  $N$ 개의 벡터를 갖는  $c$ 개의 클래스(얼굴인식인 경우 사람의 수) 문제를 고려할 때, 클래스간 분산 행렬은 다음 식과 같이 정의된다.

$$S_B = \sum_{i=1}^c N_i (\mathbf{m}_i - \bar{\mathbf{m}})(\mathbf{m}_i - \bar{\mathbf{m}})^T \quad (5)$$

여기서,  $N_i$ 는  $i$ 번째 클래스  $C_i$ 에서의 벡터의 수이며,  $\bar{\mathbf{m}}$ 은 모든 벡터들의 평균이다. 또한  $\mathbf{m}_i$ 는 클래스  $C_i$ 에서 PCA에 의해 변환된 벡터의 평균이다.

클래스내 분산 행렬은 다음 식과 같이 정의되어진다.

$$S_W = \sum_{i=1}^c \sum_{x_k \in C_i} (x_k - \mathbf{m}_i)(x_k - \mathbf{m}_i)^T = \sum_{i=1}^c S_{W_i} \quad (6)$$

여기서,  $S_{W_i}$ 는 클래스  $C_i$ 의 공분산 행렬이다. 최적의 투영 행렬  $W_{FLD}$ 는 다음 식과 같이 투영된 샘플의 클래스내 분산 행렬에 대한 클래스간 분산 행렬의 행렬식의 비를 최대화하는 정규직교 행들을 가진 행렬로서 선택되어진다.

$$W_{FLD} = \arg \max_w \frac{|W^T S_B W|}{|W^T S_W W|} = [w_1 w_2 \cdots w_m] \quad (7)$$

여기서,  $w_i$ 는 다음 식과 같이 가장 큰  $c-1$  개의 일반화된 고유치에 대응하는 일반화된 고유 벡터의 집합이다.

$$S_B w_i = \lambda_i S_W w_i, \quad i = 1, 2, \dots, m \quad (8)$$

그러나,  $S_B$ 의 rank가  $c-1$ 개의 영이 아닌 일반화된 고유값을 가지므로  $m$ 의 한계 값은  $c-1$ 개다. 유사하게  $S_W$ 의 rank도  $N-c$ 이다.  $N$ 이  $n^2$ 보다 보통 더 작은 얼굴 영상의 집합에 대해서, 클래스내 분산 행렬  $S_W$ 은 항상 비정칙이다. 이것은 투영 행렬이 적당히 선택되지 않는다면, 투영된 클래스내 분산 행렬은 영이 될 수 있다. 이러한 문제는 주성분 분석 기법을 이용함으로서 저차원 공간으로 영상 집합을 투영함으로서 해결할 수 있다. 어떤 얼굴 영상  $z_i$ 에 대한 특징 벡터들  $V = (v_1, v_2, \dots, v_N)$ 은 다음 식과 같이 계산되어질 수 있다.

$$v_i = W_{FLD}^T x_i = W_{FLD}^T E^T (z_i - \bar{z}) \quad (9)$$

마지막 단계인 최종 인증을 위해  $k$ NN( $k$ -nearest neighbor) 분류기를 적용하였다.  $k$ -NN 분류기의 경우 동일한 클래스 내의

특징벡터가 선형성을 갖는 경우 우수한 인식성 능을 보이지만 비선형 특성을 갖는 경우에는 k-NN 분류기와 같은 분류기는 효과적이지 못하다. 이러한 문제점을 해결하기 위해 본 논문에서는 최종 얼굴인식을 위한 분류기로서 k-NN 대신 신경회로망 구조를 갖는 Local MLP을 제안하고자 한다. 그림 2에서는 Local MLP을 이용한 얼굴인식시스템의 인식과정을 나타냈다.

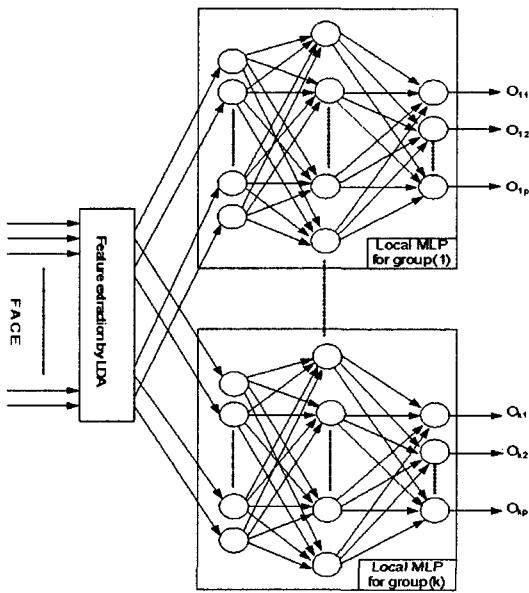


그림 2. Local MLP에 기반을 둔 얼굴인식

대규모 얼굴인식 시스템은 많은 양의 개별 얼굴영상들로 구성되어 있기 때문에 MLP에 의해 전체 얼굴영상에 최적인 파라미터를 찾는 데는 어려움이 있다. Local MLP는 전체 학습영상을 사용하기보다는 그룹별로 분할된 얼굴영상에 대해 독립적인 MLP를 수행하므로 그룹별로 최적인 파라미터를 결정하였다.

구체적인 설명을 위해, 인식하고자 하는 얼굴의 집합  $\Omega = \{w_1, w_2, \dots, w_c\}$ , MLP의 출력값  $O = \{o_1, o_2, \dots, o_c\}$ 라 기술한다. 우선,  $c$  개의 클래스의 집합을  $p$  개의 클래스를 갖는  $k$  개의 그룹으로 다음과 같이 분할한다.

- 첫번째 클래스 그룹 :  $\Omega_1 = \{w_1, w_2, \dots, w_p\}$ ,  
출력값 :  $O_1 = \{o_{11}, o_{12}, \dots, o_{1p}\}$
- 두번째 클래스 그룹 :  $\Omega_2 = \{w_{p+1}, w_{p+2}, \dots, w_{2p}\}$ ,  
출력값 :  $O_2 = \{o_{21}, o_{22}, \dots, o_{2p}\}$
- ... . . .
- $k$  번째 클래스 그룹:  
 $\Omega_k = \{w_{(k-1)p+1}, w_{(k-1)p+2}, \dots, w_{kp}\}$

$$\text{출력값} : O_i = \{o_{k1}, o_{k2}, \dots, o_{kp}\}$$

각각의 그룹별로 분할된 부영상을 대상으로 오차역전파 알고리즘에 의해 MLP의 파라미터를 결정한다. 마지막 인식단계에서는 그룹별로 수행된 local MLP를 결합한 후 식 (10)에 의해서 출력값 중에서 가장 높은 값을 갖는 클래스를 선택함으로써 이루어진다.

$$i_0 = (\arg \max(o_{ij}), \text{for } i=1, \dots, k, j=1, \dots, p) \quad (10)$$

### 3. 얼굴인식 실험 및 결과

제안된 방법의 타당성을 검토하기 위해 ORL [7] 얼굴 데이터베이스를 사용하였다. ORL 영상은 서로 다른 환경에서 40명으로부터 400개의 얼굴영상을 포함하고 있다. 각 개인에 대해서 얼굴영상의 수는 10이며, 이 영상들은 위치, 회전, 스케일, 얼굴 감정에서 변화를 주고 있다. 회전에서 변화는 최대 20도 회전하였고, 스케일에서 변화는 사람과 비디오 카메라 사이에 거리를 변화하였다. 또한 어떤 사람에 대해서는 안경 착용에 변화를 주었고, 서로 다른 시간에 영상을 얻었다. 각 영상들은 디지털화되고 0에서 255까지 그레이값을 가진 112×92 영상 크기에 의해 나타내어진다. ORL 얼굴 데이터베이스의 일부를 그림 5에서 나타냈다.



그림 3. ORL 얼굴 영상의 일부

인식 실험은 각 경우에 있어 임의의 선택된 영상에 대해서 10번 동안 반복적으로 수행하였다. 개인별 영상 10개중 학습을 위하여 5장을 이용하였고 나머지 5장을 이용하여 제안된 방법의 성능을 검증하였다. 특징추출을 위해 주성분 분석기법에 의해 45개의 eigenvector와 선형판별분석기법에 의해 30개의 discriminant 특징벡터를

선정하였다. MLP는 입력층과 은닉층, 출력층으로 3개의 층으로 구성하였다. 뉴런의 전달함수로서는 sigmoid 함수를 적용하였고, 은닉층의 뉴런의 개수는 40개로 설정하였다. MLP의 학습을 위해 사용되는 학습률은 많은 실험을 통하여 우수한 성능을 보이는 값인 0.008로 설정하였다. 또한 local MLP는 두 개로 구성하였으며, 각각 독립적인 MLP 모듈은 20명의 얼굴영상을 이용하여 구축하였다.

그림 4 및 표 1에서는 실험결과를 나타냈다. 그림 4 및 표 1에서 알 수 있는 바와 같이 본 논문에서 제안된 LDA+local MLP를 적용한 결과 기존의 PCA+kNN 방법에 비해 3%, LDA+kNN 방법에 비해 1.7% 향상된 결과를 보였다. 또한 LDA+local MLP 기법이 PCA+local MLP 방법에 비해 0.8% 향상된 결과를 나타냈다. 위 결과로부터 제안된 local MLP 기법의 유용성을 확인할 수 있다.

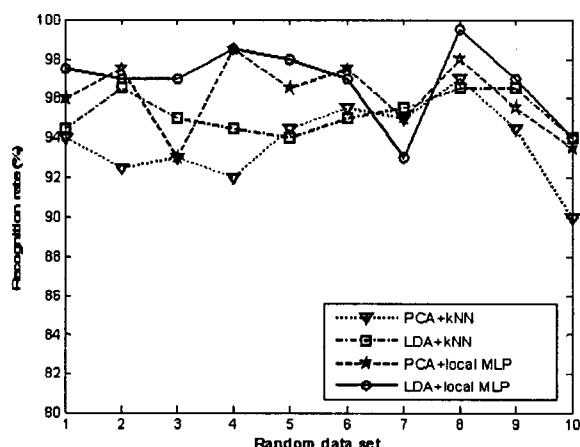


그림 4. 적용기법별 인식결과

표 1. 적용기법별 인식결과

Method		PCA+kNN	LDA+kNN	PCA+Local MLP	LDA+Local MLP
mean ± std (%)	Train	100 ± 0.00	100 ± 0.00	100 ± 0.00	99.5 ± 0.60
	Test	93.8 ± 1.99	95.2 ± 1.01%	96.1 ± 1.87%	96.9 ± 1.96%

#### 4. 결 론

본 논문에서는 LDA와 local MLP을 이용한 새로운 얼굴인식 시스템을 제안하였다. 제안된 방법은 우선 LDA 기법에 의해 차원이 축소된 얼

굴의 특징벡터를 계산한 후 다음 단계로서 전체 학습영상을 사용하기보다는 그룹별로 분할된 얼굴영상에 대해 MLP를 수행하는 local MLP 기법을 적용하였다. 제안된 방법의 유용성을 보이기 위해 ORL 얼굴영상을 대상으로 실험한 결과 기존의 PCA+kNN 방법에 비해 제안된 방법이 3%, LDA+kNN 방법에 비해 1.7% 향상된 결과를 보였다. 또한 LDA+local MLP 기법이 PCA+local MLP 방법에 비해 0.8% 향상된 결과를 나타냈다. 위 결과로부터 제안된 local MLP 기법의 유용성을 확인할 수 있다.

#### 5. 참 고 문 헌

- [1] M. Turk, A. Pentland, "Face recognition using eigenfaces", *Proc. IEEE Conf. On Computer Vision and Pattern Recognition*, pp. 586-591, 1991.
- [2] P. N. Belhumeur, J. P. Hespanha, D. J. Kriegman, "Eigenfaces vs. Fisherfaces: recognition using class specific Linear Projection", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 711-720, 1997.
- [3] H. C. Kim, D. Kim, S. Y. Bang, "Face recognition using the mixture-of-eigenfaces method", *Pattern Recognition Letters*, Vol. 23, pp. 1549-1558, 2002.
- [4] A. Pujol, J. Vitria, F. Llumbreras, J. J. Villanueva, "Topological principal component analysis for face encoding and recognition", *Pattern Recognition Letters*, Vol. 22, pp. 769-776, 2001.
- [5] C. Liu, H. Wechsler, Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition, *IEEE Trans. on Image Processing*, Vol. 11, No. 4, pp. 467-476, 2002.
- [6] H. Yu, J. Yang, A direct LDA algorithm for high-dimensional data-with application to face recognition, *Pattern Recognition*, Vol. 34, pp. 2067-2070, 2001.
- [7] ORL face database, <http://www.uk.research.att.com/facedatabase.html>