

논문 2005-42SP-5-7

얼굴인식을 위한 해마의 뇌모델링 학습 알고리즘 개발

(Development of Learning Algorithm using Brain Modeling of Hippocampus for Face Recognition)

오 선 문*, 강 대 성*

(Sun-Moon Oh and Dae-Seong Kang)

요 약

본 논문에서는 인간의 인지학적인 두뇌 원리인 대뇌피질과 해마 신경망을 공학적으로 모델링하여 얼굴 영상의 특징 벡터들을 고속 학습하고, 각 영상의 최적의 특징을 구성할 수 있는 해마 신경망 모델링 알고리즘인 HNMA(Hippocampal Neuron Modeling Algorithm)을 이용한 얼굴인식 시스템을 제안한다. 시스템은 크게 특징추출 부분과 학습 및 인식 부분으로 구성되어 있으며, 특징추출 부분에서는 PCA(Principal Component Analysis)와 LDA (Linear Discriminants Analysis)를 순차적으로 적용하여 분별력이 좋은 특징들로 구성한다. 학습부분에서는 해마 신경망 구조의 순서에 따라 입력되는 영상 데이터의 특징들을 치아 이랑 영역에서 호감도 조정에 따라서 반응 패턴으로 이진화 하고, CA3 영역에서 자기 연상 메모리 단계를 거쳐 노이즈를 제거한다. CA3의 정보를 받는 CA1영역에서는 신경망에 의해 학습되어 장기기억이 만들어 진다. 제안한 시스템의 성능을 평가하기 위하여 실험은 표정과 포즈변화 그리고 저 화질 이미지를 각각 구분하여 인식률을 확인하였다. 실험 결과, 본 논문에서 제안하는 특징 추출 방법과 학습 방법을 다른 방법들과 비교하였을 때, 학습시간비용과 인식률에서 우수함을 확인하였다.

Abstract

In this paper, we propose the face recognition system using HNMA(Hippocampal Neuron Modeling Algorithm) which can remodel the cerebral cortex and hippocampal neuron as a principle of a man's brain in engineering, then it can learn the feature-vector of the face images very fast and construct the optimized feature each image. The system is composed of two parts. One is feature-extraction and the other is learning and recognition. In the feature extraction part, it can construct good-classified features applying PCA(Principal Component Analysis) and LDA(Linear Discriminants Analysis) in order. In the learning part, it can label the features of the image data which are inputted according to the order of hippocampal neuron structure to reaction-pattern according to the adjustment of a good impression in the dentate gyrus region and remove the noise through the associate memory in the CA3 region. In the CA1 region receiving the information of the CA3, it can make long-term memory learned by neuron. Experiments confirm the each recognition rate, that are face changes, pose changes and low quality image. The experimental results show that we can compare a feature extraction and learning method proposed in this paper of any other methods, and we can confirm that the proposed method is superior to existing methods.

Keywords : Hippocampus, Brain Modeling, PCA(Principal Component Analysis),
LDA(Linear Discriminants Analysis), Face recognition

I. 서 론

전체적인 뇌의 기능 중에서 해마의 역할은 설치류와 원숭이와 인간의 해마 시스템은 과거 수십 년 동안 광범위하게 연구되었다. 쥐의 해마에서 장소 세포들의 발견 이후로 공간적 관점에 강하게 관련 있는 반면에, 원

승이와 인간에 있어서는 주로 에피소드식 기억에 관련이 있다. 1971년 초반에, Marr는 기억 강화에서의 해마의 결정적인 역할에 대한 이론을 제안했다. 그는 해마 시스템이 경험을 저장하고 분류화가 수행되는 신피질로 재수행하는 것을 제안했다. 이 분야에서 많은 의견 차이에도 불구하고, 해마가 신피질의 교사라는 생각이 많은 연구가들에 의해서 널리 채택되어왔다. 최근의 신경 생물학 모델들은 인간의 뇌에서 신피질을 표현한 구성에서 해마의 역할을 중요시 하고 있다. 공학부분에서 많이 응용되고 있는 신경망은 뇌의 학습-기억 활동을 모태로 다양한 분야에 응용되고 있다. 신경망에서의 학

* 정희원, 동아대 학교 전자공학과

(Dept. of Electronic Eng., Dong-A University)

※ “이 논문은 2005년도 동아대학교 지능형통합항만관리연구센터의 연구비 지원으로 수행되었습니다.”
접수일자: 2005년 3월 25일 수정완료일: 2005년 8월 8일

습은 실제 뇌 안에서 뉴런과 뉴런이 각각 시냅스로 연결되어 정보 전달 및 처리하는 과정으로 볼 수 있다. 따라서 신경망을 단편적으로 고려했을 때 신경망의 학습 과정은 실제 뇌에서의 시냅스를 표현하는 가중치 조절과 긴밀히 연관되어 있음을 알 수 있다. 시냅스의 기능과 구조를 신경망에 반영하는 것은 실제 뇌 안에서 발생하는 정보처리 과정을 설명하기에 적절하다.

기존의 얼굴인식에는 얼굴의 국부적인 특징을 이용한 방법, 얼굴 형판 정합에 기반한 방법, 인공신경망을 이용한 학습형 인식방법 등이 있었으나, 조명의 변화나 얼굴의 가려짐, 그리고 표정 변화를 갖는 얼굴 영상을 인식하기 위해서는 많은 영상을 학습해야만 한다. 따라서 이러한 영상 학습으로 인하여 방대한 메모리양과 계산 시간의 문제가 제기되는 것은 당연하다. 이런 문제점을 해결하기 위한 방법으로는 얼굴 영상 벡터를 하나의 벡터 공간상의 특징 벡터들로 변환하여, 질의 영상의 특징 벡터와 학습 영상의 특징 벡터들을 비교하는 얼굴인식 방법이 활발히 연구 되고 있다. 대표적으로 Eigenface 방법^[1]인 PCA (Principal Component Analysis)^[2], Fisherface 방법인 LDA (Linear Discriminants Analysis)^[3] 그리고 ICA (Independent Component Analysis)^[4]등이 있다. 여기서 training set의 크기가 작을 경우 PCA가 LDA보다 우수하며, 반면에 영상의 조명 변화가 큰 경우 LDA가 PCA보다 우수함이 보고되어 있다. 소개된 방법들 중 한가지만으로는 만족할 만한 인식률을 얻기 힘들다. 따라서 본 논문에서는 PCA방법과 LDA방법을 혼용하여 특징 벡터를 추출한다. 또한 특징벡터를 효율적으로 이용하기 위해 단순히 벡터거리 비교 방법을 쓰지 않고, 제안한 HNMA으로 학습 시킨 후 인식을 하게 된다.

II. 특징 계산

1. PCA

PCA는 평균과 분산까지의 통계적 성질을 이용한 2차 통계적 기법이다. PCA는 입력 자료에 대하여 최대 공분산의 각 방향을 가리키는 직교 정규화된 일련의 축들의 집합을 찾는다. 이는 입력 자료의 가장 중요한 축들을 찾아 효율적으로 자료의 차원을 줄일 수 있는 장점을 갖게 됨을 의미한다.

주어진 자료를 X 라 놓고, n 개의 관찰된 표본이 있다면 X 를 $X = [x_1, x_2, \dots, x_n]$ 과 같이 정의할 수 있다.

이때 X 의 각 표본 x_i 는 해당 표본을 구성하는

$x_i = [x_i(1), x_i(2), \dots, x_i(m)]^T$ 와 같이 m 개의 데이터로 구성되어 있다고 하고, 이때 T 는 행렬의 전치를 나타낸다. 만약 얼굴 영상의 경우라면 이때의 m 의 값은 해당 얼굴의 픽셀 수가 될 것이며 1차원 벡터로 나타낼 수 있다. 계산의 편리를 위해 X 의 각 행의 값의 평균을 0으로 만들어 주었다고 가정한다.

이때 주요 요인 축들은 $\frac{1}{n}XX^T$ 의 공분산 행렬의 고유벡터 값들이다. 이때 해당 고유값들은 그 축들의 분산 값을 나타낸다. 첫째 주요 축은 최대의 분산 값을 가지고, 둘째 주요 축은 첫 번째 축에 수직하며 그 다음으로 가장 큰 값을 가진다. 이러한 방법으로 나머지 축들이 구성된다. 따라서 $\frac{1}{n}XX^T$ 을 이용하여 공분산 행렬의 고유벡터와 고유값을 구한 후에 고유값을 크기에 따라 정렬하고 이때 고유벡터도 해당 고유값의 위치대로 정렬한다. 일반적으로 뒤쪽에서 어느 정도의 고유값들은 0 또는 0에 가까운 값을 가지게 되어 이를 버릴 수 있어 입력 데이터의 차원을 줄일 수 있다.

PCA로 데이터를 표현하는 방법은 다음과 같다. 우선 PCA로 데이터가 표현되는 것을 R 이라 놓고 이때 각 행이 원래 데이터의 표본에 매칭된다. 위에서 언급한 고유벡터가 열로 들어 있는 행렬을 V 라고 하였을 때 $R = X^T V$ 와 같이 R 을 구할 수 있다.

고유벡터 V 가 대칭적이고, 직교 정규화 되어 있으므로 $VV^T = I$ 의 성질을 가지며, 역으로 데이터를 변환하는 것은 $X^T = RV^T$ 와 같이 구할 수 있다.

2. LDA

선형 판별 분석인 LDA(Linear Discriminant Analysis)변환은 집단 내 데이터 분산을 나타내는 행렬 (with-in class scatter matrix)과 집단 간 데이터 분산을 나타내는 행렬(between class scatter matrix)을 고려하는 방법으로, 이는 데이터에 대해 평균 근처에서 집중 발생하고, 평균 근처에서부터 주위로 감소되는 밀도를 가진다는 특정한 가정 하에 집단의 탄당한 분리를 보증하는 방법이다^[5].

이 변환 방법은 집단 외 편차는 최대로 해주면서, 집단 내 편차를 최소로 하여, 데이터를 쉽게 나눌 수 있고, 집단 또한 쉽게 분리 할 수 있도록 한다. PCA 변환이 입력 데이터를 다른 공간으로 변환할 때, 입력 데이터의 모양과 위치가 변화하고, 집단간의 겹침이 발생하

는 단점을 가지는 반면에, LDA 변환은 입력 데이터의 위치가 변하는 것이 아니라, 주어진 클래스가 확실히 구별 될 수 있도록 판별 선을 그려주기 때문에 집단 간의 겹침이 발생하는 것을 막아줄 수 있다^[6].

식 (1)은 집단 내 데이터 분산을 나타내는 식이다.

$$S_b = \sum_{j=1}^c (\mu_j - \mu)(\mu_j - \mu)^T \quad (1)$$

식 (2)는 집단 간 데이터 분산을 나타내는 식이다.

$$S_w = \sum_{j=1}^c \sum_{i=1}^{n_j} (x_i^j - \mu_j)(x_i^j - \mu_j)^T \quad (2)$$

각각의 집단에 식 (3)을 적용하면 집단을 최적의 상태로 투영할 수 있는 고유벡터와 고유 값을 구할 수 있다.

$$S_b W = \lambda S_w W \quad (3)$$

이렇게 구해진 고유 벡터와 고유 값을 식 (4)에 적용하면, 집단의 판별 정도를 나타낼 수 있는 최적의 고유 벡터를 구할 수 있는데, 이는 각 집단을 이루는 데이터를 최적의 상태로 투영할 수 있게 해준다.

$$W_{opt} = \frac{\|W^T S_w W\|}{\|W^T S_b W\|} \quad (4)$$

3. 주성분의 LDA변환을 이용한 특징벡터 계산

본 논문에서는 특징계산을 위해 PCA 변환과 LDA 변환을 같이 사용하는 방법을 적용하였다. 이는 PCA 변환을 통해 학습 집단의 고차원 벡터의 데이터를 저차원 벡터의 형태로 변환해주고, 이 변환을 통해서 생성된 주성분을 LDA 변환하여, 원하는 수의 집단을 만들어 준다.

c 개의 클래스를 w_1, w_2, \dots, w_c , i 번째 클래스에 속한 얼굴 영상의 개수를 n_i , PCA를 적용하기 전과 후의 i 번째 클래스 평균을 각각 μ_i 와 $\tilde{\mu}_i$ 라고 하면, $Y_{ij} = W_{PCA}^T X_{ij}$, $\mu_i = \frac{1}{n_i} \sum_{j=1}^{n_i} X_{ij}$ 이므로, $\tilde{\mu}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} Y_{ij} = \frac{1}{n_i} \sum_{j=1}^{n_i} W_{PCA}^T X_{ij} = W_{PCA}^T \mu_i$ 가 된다. 따라서 Y_{ij} 의 within-class scatter matrix S_w 와 between-class scatter matrix S_B 는 식 (5)와 같다. 여기서 X_{ij} 와 Y_{ij} 는 W_{PCA} 에 의한 선형 변환 이전 및 이후의 i 번째 클래스에 속한 j 번째 얼굴 벡터를 나타낸다.

$$S_w = W_{PCA}^T S_w W_{PCA}, S_B = W_{PCA}^T S_B W_{PCA} \quad (5)$$

식 (6)을 적용하여 선형 변환 행렬 W_L 을 계산하게 된다. 여기서 W_L 의 각 열은 $(S_w)^{-1} S_B$ 의 가장 큰 $(C-1)$ 개의 고유치에 해당하는 고유벡터로서 구한다.

$$W_L = \underset{w}{\operatorname{argmax}} \left(\frac{W^T S_B W}{W^T S_w W} \right) \quad (6)$$

결과적으로 얼굴 영상 벡터 X_{ij} 를 $Z_{ij} = W_L^T W_{PCA}^T X_{ij}$ 에 의해 선형 변환된 Z_{ij} 로 표현되어 미리 구하여진 벡터들을 HNMA의 Input data로 이용한다.

III. 해마신경망 모델과 구현

1. 배경

브로드만 28지역인 내후각뇌(entorhinal) 피질은 우리 대뇌의 다양한 피질 지역에서 정보를 받아 해마 구조에 기억을 만들 수 있도록 제공한다.

그림 1을 보면 이 내후각뇌 피질은 관통 경로(perforant path)를 통해 치아-이랑(dentate gyrus)의 과립 세포(granule cell)들로 정보를 전달한다. 해마체는 그 구조를 크게 CA 지역과 피라미드 세포들로 구분할 수 있는데, 이끼 섬유 경로는 해마체의 CA3 영역에 있는 피라미드 세포들의 가지살들로 연결된다. CA3 영역의 피라미드 세포들은 두 방향으로 갈리는 줄기살들을 가지고 있다. 하나는 해마체에 머무르면서 CA1 영역의 피라미드 세포와 시냅스를 이루고 (이를 '쉐퍼(schaffer) 경로'라고 함), 다른 하나는 해마체를 떠난다. 마침내, CA1 피라미드 세포들의 줄기살들은 내

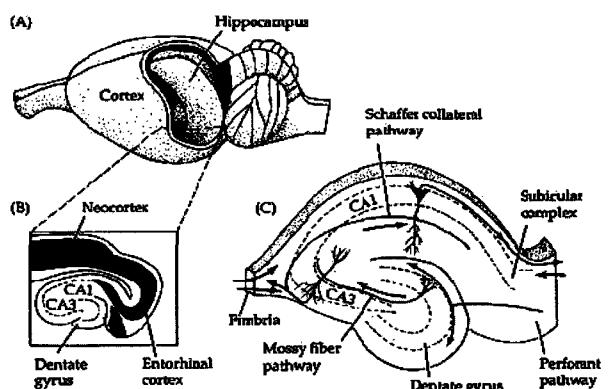


그림 1. 해마의 생물학적 구조

Fig. 1. biochemical construction of Hippocampus.

후각뇌 피질로 채 투사되는 해마이행체(subiculum complex)로 연결되고, 치아-이랑을 제외한 해마 구조의 모든 뉴런들은 대뇌 피질의 다른 지역으로 줄기살들을 보낸다. 따라서, 해마 구조는 뇌 전 영역의 기억 기능을 제어하기에 좋은 형태를 이루고 있다.

이끼 섬유와 CA3 피라미드 세포 사이의 시냅스에서의 장기 강화(long-term potentiation) 현상은 오직 이끼 섬유 줄기살들의 고주파 자극으로만 발생한다. 즉, 해마 조직의 다른 시냅스와 달리 이 지역의 장기 강화는 입력 자극의 강도에만 의존하는 비연관적인 형태이다. CA1 피라미드 세포의 연관된 장기 강화(associative LTP)는 시냅스전(前)의 고주파 입력과 다른 홍분 입력으로 인한 시냅스후(後) 세포의 동시적인 홍분 전위로부터 발생한다. 이 연관된 장기적 강화가 일어나는 지역의 NMDA 수용체들은 평소 Mg^{2+} 이온으로 막혀 있다가, K나 AMPA 수용체들에 의한 전위-변화로 Mg^{2+} 가 떨어져 나가게 되어, NMDA 수용체 통로를 통해 Na^+ 나 Ca^{2+} 의 세포 내 유입과 K^+ 의 세포 밖 유출이 가능해진다. 만약, 해마 조직의 NMDA 수용체를 차단시키면 시냅스후(後) 홍분 전위에 효과를 최소화시키므로, 관통 경로와 쉐퍼 곁가지들의 연관된 장기적 강화의 혼적은 사라진다.

이처럼, NMDA 수용체의 연관된 두 사건의 동시적 자극 성질을 고려하면, 우리가 맛있는 사과를 양파와 구분하여 인식할 수 있는 것은 사과의 맛과 색깔과 냄새 등이 사과라고 하는 이미지와 함께 학습되고, 기억되어 우리의 머리 속에 함께 저장되었기 때문이다. 이런 연관되어 기억된 정보를 차단시켜, 눈을 가지고, 코를 막고, 맛을 못 느끼게 하면, 우리는 지금 먹고 있는 아이스크림이 딸기 맛인지 초코렛 맛인지도 좀처럼 구분할 수 없다. 뇌의 해마 구조에서 형성되는 단기 기억은 짧은 시간 동안 제한된 양의 정보를 저장함으로써 순간순간으로 이루어지는, 과거가 되어지는 현재의 정신세계를 연속시키는 기능을 한다고 할 수 있다. 모든 기억이 장기 기억으로 굳히기 위해서는 반드시 단기 기억의 상태를 거쳐 가야 한다^[7].

2. 해마신경망 학습 알고리즘 구현

학습을 할 경우 일반 신경망이나 학습 알고리즘은 정확하지 못한 특징점 입력에 대해서 무조건적으로 반영하여 가중치 값의 정확도가 낮아질 수 있으나, HNMA는 연상메모리 학습으로 인한 노이즈 제거기능과 패턴 연상결과로 어느 정도 정확한 동일패턴을 단기 메모리

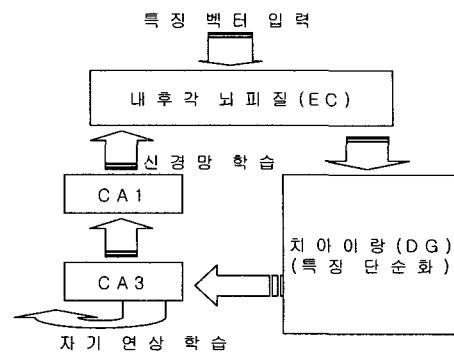


그림 2. 해마신경망 모델

Fig. 2. Hippocampal Neuron model.

영역에 빈도순으로 저장해 놓고 빠른 인식에 이용할 수 있으며, 단기기억에서 빈도수가 높은 패턴을 자동으로 선별하여 장기기억 메모리로 학습한 후, 보다 정확한 인식률에 사용할 수가 있다. 해마의 기능 중 가장 중요하고 강력한 것은 단기기억에서 장기기억으로의 확장에 있다. 해마의 역할은 방금 저장된 정보를 기억하고 필요한 정보와 그렇지 못한 정보를 분류하는 것이다. 필요한 정보의 경우, 해당 뉴런에 저장해두고 동일한 패턴이 입력되면 인식하게 되는 것이다. 단기 기억과 장기 기억으로 나누는 방법에 있어서 호감도 측정은 통계적 패턴 인식에 사용되는 방법을 사용하면 통계적으로 많이 나타나는 값들에 대해서 호감도를 높게 부여하는 것이다. 이러한 특징을 해마 신경망에도 도입한다면, 입력되는 중간에 입력받는 값들의 가중치를 사용하여 단기 기억을 할 것인지 장기 기억을 할 전인지를 결정할 수 있다. 이러한 결정 값을 해마기억 장소 분류 기준 값으로 사용할 수 있다. 전체 데이터 개수 대비 해당뉴런의 누적 개수가 문턱치를 만족하면 장기 기억 장소로 저장시키도록 한다.^{[8],[9]}

그림 2는 그림 1의 구조를 모델링한 것이며, 각 블록의 기능을 설명은 다음과 같다.

- 내후각뇌피질 : 해마와 신피질 사이에서 인터페이스를 구성하고 해마 신경망의 입력과 출력을 나타낸다.
- 치아이랑 : 내후각뇌피질에 직접 연결되는 치아이랑 구조는 그 모델에 동일한 객체의 다양한 특징 성분들을 과거 입력 패턴에서 동일성을 판단하여 특징을 단순화 시킨다. 특징 평균값에서 특징이 편차범위의 임계값을 넘으면 1, 아니면 -1로 특징을 이진화하여 재구성한다.
- CA3 : 어떤 사건을 기억해낼 때에는 연상 작용을 반

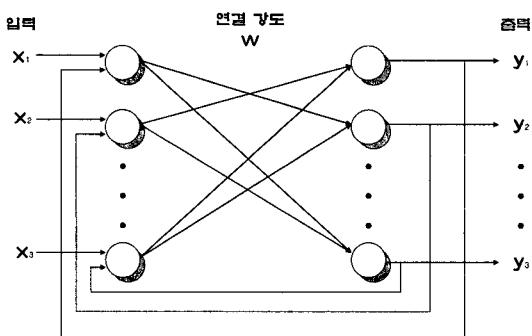


그림 3. 순환 연상 모델의 구조
Fig. 3. Structure of auto associate memory.

복합으로써 보다 나은 결과를 얻을 수 있으며, 이러한 순환 개념을 도입한 것이 순환 연상 메모리이다. 순환 연상 메모리는 그림 3에서 보는 바와 같이 출력이 입력에 궤환되는 동질 연상 메모리이다. CA3 영역은 치아이랑에 연결되고 이 후자 구조로부터 단순화된 정보를 받는다. CA3 영역에서는 자기 연상을 하며, 노이즈가 있는 특징 정보를 더욱 분별력 있게 정돈하는 역할을 한다. 과거에 학습된 특징들과 차이가 큰 특징이 입력 될 경우에는 새로운 패턴으로 분류한다.

본 논문에서는 순환 연상 메모리를 구현하기 위해 Hopfield 모델을 따른다. Hopfield 모델은 그림 3에서 보는 바와 같이 일반적인 순환 연상 메모리와 유사한 구조이지만 다음과 같은 차이가 있다.

- 최종 출력을 얻을 때까지 외부 입력을 계속 활용한다.
- 연결 강도 W 가 대칭구조이며, 대각 요소가 0이다.

$$W_{ij} = W_{ji}, W_{ii} = 0$$

따라서, Hopfield 연상 메모리에서 p 개의 패턴들을 저장하는 연결 강도 W 는 식 (7)과 같다.

$$W = \sum_{i=1}^p S^T(i)s(i) - pI \quad (7)$$

여기서, I 는 단위 행렬이다.

- CA1 : CA1 영역은 CA3영역에 연결되고 정보 처리의 마지막 단계를 나타낸다. 자기 연상된 CA3의 정보를 단층 신경망에 학습 시키며, 장기 및 단기 기억을 결정한다. 학습된 가중치에 반응하여 출력 값이 맞지 않을 경우 단기기억으로 패턴을 분류하여 저장하는 기능을 한다.

IV. 얼굴 인식 실험

1. 실험 자료

얼굴 인식 실험을 위하여 다음의 얼굴 영상 집합이 필요하다. 이 중 모델 집합과 학습 집합은 같이 공유를 하여도 무방하다.

- (1) 모델 집합(Model Set): PCA와 LDA 학습에 의하여 basis를 얻는데 사용되는 얼굴 집합
- (2) 학습 집합(Train Set): 얼굴 인식에 수행하여 미리 저장되는 얼굴 집합
- (3) 실험 집합(Test Set): 얼굴 인식에 입력으로 사용하는 얼굴 집합

(1) ORL 데이터베이스

ORL 데이터베이스^[10]는 40명에 대하여 그림 4와 같이 일정한 어두운 배경에서 얼굴 표정과 안경 착용 유무에 따라 각 10장씩 구성되어 있다. 특히 ORL 데이터베이스는 안경·수염 등이 있는 얼굴들이 많이 분포되어 있고 좌우 회전을 통해 변형된 얼굴 영상도 다소 존재한다.



그림 4. ORL Database의 예
Fig. 4. Some examples of ORL database.

(2) CMU AMP Face Expression Database

표정변화 실험을 위하여 CMU AMP Face Expression Database^[11]를 사용하였다. CMU 얼굴 DB (그림 5 참조)에서 정면 얼굴 영상을 사용하였고, 13명의 얼굴마다 각각 75가지의 표정변화들이 존재한다.



그림 5. CMU AMP Face Expression Database의 예
Fig. 5. Some examples of CMU AMP Face Expression Database.

(3) DAUFace 데이터베이스

자체 제작한 DAUFace 데이터베이스는 그림 6과 같

이 화상 통신용 저가의 CCD 카메라를 가지고 일정한 환경에서 다양한 포즈와 표정 변화로 검출된 얼굴 영상이다.



그림 6. DAUFace Database의 예
Fig. 6. Some examples of DAUFace database.

2. 실험 방법

본 논문의 실험에서는 HNMA의 성능의 객관적인 평가를 위하여 HMM^[12]과 SVM^[13] 그리고 BP신경망 알고리즘과 HNMA를 비교하는 방식으로 수행하였다. 앞 절에서 소개한 Database들을 사용하여 HNMA 학습 모델의 얼굴 인식 실험을 수행하였는데, 크게 세 개의 그룹으로 나누어 얼굴 인식 실험을 수행하였다.

첫째는 얼굴의 포즈에 따른 얼굴 인식 실험이다. 본 실험에서는 40명의 얼굴 영상에 대해 7가지의 포즈를 변화해가며 알고리즘별로 얼굴 인식 성능을 측정하였다. 이때 HNMA를 학습하기 위한 모델 집합은 ORL 데이터베이스를 사용하였다.

두 번째 실험은 표정변화에 따른 얼굴 인식 실험이다. 본 실험에서는 CMU AMP 데이터베이스의 영상을 사용하여 표정들을 변화해가며 알고리즘별로 얼굴 인식 성능을 측정하였다.

세 번째 실험은 자체 제작한 DAUFace 데이터베이스를 이용하여, 저가용 CCD카메라에서 약간의 포즈변화를 주면서 획득한 얼굴 영상의 인식성능을 측정하였다.

본 논문에서는 입력 얼굴 영상 및 학습을 위한 얼굴 영상은 영상 내의 얼굴의 크기와 위치를 맞추는 전처리 과정을 통하여 얼굴 인식이 제대로 수행되게 하였다. 얼굴 인식에서 가장 중요한 특징이라 할 수 있는 눈의 위치를 맞추도록 하였다. 그 뒤 영상을 축소하는 down sampling 과정에서 경계선들의 정보를 유지하기 위해 잘라낸 얼굴 영상에 번짐 효과(blurring)를 주고 64x64 픽셀 크기로 down sampling을 수행하였다. 마지막으로 영상을 gray level로 변환하였다.

3. 실험 결과

HNMA의 인식률을 비교를 위하여, n 개의 표본이 있

을 때, n-1 개의 표본으로 학습 하고 나머지 하나로 테스트하는 절차를 n번 반복하는 leaving one out 방법을 이용함으로써, 표본 내의 모든 경우가 테스트에 사용되어 신뢰성 있는 결과를 획득할 수 있다.

(1) basis 개수 변화에 따른 실험 결과

PCA와 LDA의 얼굴 인식 성능 분석을 위하여 ORL, CMU, DAUFace 데이터베이스를 이용하여, basis 수를 변화해 가며 얼굴 인식 실험을 수행하였다. 본 실험은 PCA와 LDA를 혼용한 basis 수의 변화에 따른 인식 성능을 비교하여, 해당 기법의 최적의 basis 수를 찾는다. 32, 64, 96, 128 개로 basis 수를 변화해가며 유클라디안 방법으로 인식률이 가장 우수한 것을 선택하도록 한다. 유클라디안 방법을 선택한 이유는 학습 알고리즘의 성능에 의존하지 않고 특정 벡터의 자체 분리도를 평가하기 위해서이다. 표 1을 보면 공통적으로 basis의 수가 32, 64, 128개일 때 보다는 96개일 때 인식 성능이 더 좋은 것을 알 수 있다.

클래스 분리도를 정량적으로 측정하기 위하여 PCA와 LDA를 혼용한 방법과 LDA 각각에 대하여 $\frac{W^T S_B W}{W^T S_w W}$ 값을 구하였다. 얼굴 데이터베이스에 대한 클래스 분리도 값을 표 2에 나타내었다.

표 2의 값이 클수록 클래스 내의 분산 값은 작고, 다른 클래스 간의 분산 값이 크기 때문에 각각의 얼굴 영상 클래스를 보다 잘 분리할 수 있다. 표 2를 살펴보면 PCA와 LDA의 혼용은 PCA 알고리즘을 이용하여 차원을 효과적으로 축소하고, 이러한 축소 특징 벡터 공간에 LDA를 적용함으로써 클래스 분리도가 상당히 향상되었다.

표 1. Basis 수 변화에 따른 인식 결과(%)

Table 1. Recognition result with change of basis number(%).

Database basis 갯수	ORL	CMU AMP	DAUFace
32개	84.03	88.34	87.95
64개	86.35	89.36	88.35
96개	91.34	92.62	91.78
128개	87.56	90.66	90.24

표 2. PCA와 LDA 혼용의 클래스 분리도 측정

Table 2. The class separability measurement of mixed method of PCA and LDA.

Database	LDA	PCA+LDA
ORL database	5.73×10^{17}	8.85×10^{18}
CMU database	8.52×10^{17}	9.24×10^{18}
DAUFace database	7.37×10^{17}	8.75×10^{18}

어, 인식률 크게 향상시킬 수 있음을 알 수 있다.

(2) 포즈변화에 따른 실험 결과

포즈변화에 따른 얼굴 인식 성능을 비교하기 위하여 ORL 데이터베이스의 40명의 영상에서 각각 10가지의 포즈를 HNMA학습에 이용하고, 학습에 이용하지 않은 나머지 1개의 영상들로 인식 성능을 측정하였다. 먼저 PCA와 LDA를 혼용한 특징 벡터 사용방법의 인식 성능을 확인하기 위하여, PCA, LDA, ICA를 단독으로 사용하여 계산한 특징 벡터들과 비교하였다. 그 결과는 표 3과 같다.

표 3에서와 같이 PCA와 LDA를 혼용한 것은 Nearest Neighbor 방법에서도 91.34%의 가장 높은 인식률을 보이고 있고, BP^[14]등과 같은 다른 학습 방법들에서도 단독으로 사용될 때보다 인식률을 향상시키는 것을 보면, PCA와 LDA를 혼용한 방법으로써 계산한 특징 벡터는 각종 학습 알고리즘의 좋은 학습 패턴으로 이용되어 질 수 있다는 것을 알 수 있다.

표 4에서 사람 수 옆의 숫자 1~5는 해당 번째까지 정답을 맞힌 것을 의미한다. 즉, 첫 번째 답까지를 정답으로 보았을 때의 인식률이 숫자 1에 해당되고, n 번째 답까지를 정답으로 보았을 때의 인식률이 숫자 n에 해당한다.

표 3. 학습 알고리즘과 특징 계산 방법에 따른 포즈 인식률 비교(%)

Table 3. Comparisons of pose recognition rates with learning algorithms and feature caculation method (%).

학습 방법 특징 계산 방법	Nearest Neighbor	BP	SVM	HMM	HNMA
PCA	87.85	90.66	90.89	91.96	92.42
LDA	89.04	90.74	91.85	92.34	93.03
ICA	88.65	90.15	91.51	92.09	92.15
PCA+LDA	91.34	93.21	93.88	94.21	97.94

표 4. 포즈변화에 따른 알고리즘별 얼굴 인식 실험 결과 (%)

Table 4. The simulation result of facial recognition with pose change.

인식순위	Nearest Neighbor	BP	SVM	HMM	HNMA
1	91.34	93.21	93.88	94.21	97.94
2	93.49	95.67	98.33	96.67	98.17
3	96.83	95.00	99.00	98.17	100.00
4	96.17	98.00	99.54	98.44	100.00
5	96.85	98.33	100.00	100.00	100.00

표 4의 경우를 보면 3번째 답까지를 포함한 인식에서는 모든 경우에서 HNMA는 100%의 인식률을 보이고 있다. 5번째 답까지를 포함한 인식에서는 SVM과 HMM이 100%의 높은 인식 성능을 보이고 있음을 알 수 있다.

(3) 표정변화에 따른 실험 결과

표정변화에 따른 얼굴 인식 성능을 비교하기 위하여 CMU 데이터베이스의 13명의 영상에서 각각 50가지의 포즈를 HNMA학습에 이용하고, 학습에 이용하지 않은 나머지 영상들로 인식 성능을 측정하였다. 먼저 PCA와 LDA를 혼용한 특징 벡터 사용방법의 인식 성능을 확인하기 위하여, PCA, LDA, ICA를 단독으로 사용하여 계산한 특징 벡터들과 비교하였다. 그 결과는 표 5와 같다.

표 6의 경우를 보면 PCA와 LDA를 통해서 계산한 특징 벡터가 HNMA에서 99.10%의 인식률을 보이고 있고, 나머지 학습 방법들도 93.55%이상의 높은 인식률을 보이고 있다.

표 5. 학습 알고리즘과 인식률 비교(%)

Table 5. Comparisons of recognition rates with learning algorithms(%).

학습방법 특징 계산방법	Nearest Neighbor	BP	SVM	HMM	HNMA
PCA	89.00	92.56	92.68	92.63	92.42
LDA	91.04	93.65	93.85	94.25	95.03
ICA	91.56	93.81	93.51	93.88	95.65
PCA+LDA	93.55	95.36	96.45	96.12	99.10

표 6. 학습 알고리즘과 특징 계산 방법에 따른 표정 인식률 비교(%)

Table 6. Comparisons of face expression recognition rates with learning algorithms and feature caculation method(%).

인식순위	Nearest Neighbor	BP	SVM	HMM	HNMA
1	93.55	95.36	96.45	96.12	99.10
2	93.00	98.81	98.17	99.04	100.00
3	94.33	99.00	99.33	100.00	100.00
4	98.67	100.00	100.00	100.00	100.00
5	100.00	100.00	100.00	100.00	100.00

(4) 자체 데이터베이스에서의 실험 결과

저화질 화상캠으로 획득한 얼굴 영상으로 구축한 DAUFace 데이터베이스를 이용하여 앞의 실험들과 같은 방법으로 성능을 확인 해 보았다. DAUFace 데이터베이스는 실시간 시스템에 적용할 때를 고려하여 비슷

표 7. DAUFace 데이터베이스를 이용한 알고리즘별 얼굴 인식 실험 결과(%)

Table 7. The simulation result of facial recognition using DAUFace database.

학습방법 특징계산방법	Nearest Neighbor	BP	SVM	HMM	HNMA
PCA	86.63	88.15	89.51	90.09	91.15
LDA	88.31	89.65	90.87	91.21	92.45
ICA	87.00	89.47	90.86	91.96	91.09
PCA+LDA	90.84	92.20	92.11	94.34	96.53

한 표정으로 약간의 포즈 변화를 주도록 하였다. 인식 결과는 표 7과 같다.

V. 결 론

PCA와 LDA는 모두 비교사 학습 기법으로 PCA는 조밀한 코딩, LDA는 드문 코딩에 의하여 인식에 있어 필요한 중복 신호 제거 효과를 갖기 때문에 얼굴 영상의 특징 벡터로써 많이 연구되어 왔다. 본 논문에서는 이 두 기법을 혼용하고, 해마신경망 학습 및 인식 모델을 설계하고 얼굴 인식 실험을 수행하여 인식 특징 및 성능을 분석하였고, 다른 학습 방법들과의 비교 실험을 통하여 보다 면밀한 분석을 수행하였다.

basis 수를 조절해가며 얼굴 인식을 수행한 실험에서 96개의 basis 갯수가 가장 성능이 좋은 것으로 보아 basis수가 너무 적거나 많을 경우 성능에 영향을 준다는 사실도 알 수 있었다. 그리고 얼굴 인식 실험을 통하여 학습방법들을 비교했을 때, 포즈와 표정에 따른 얼굴 인식 실험에서 HNMA가 97% 이상의 인식 성능을 나타내는 등, 소규모 인식에서 다른 학습 방법보다 높은 인식 성능을 보였다. 또한 계산량이 PCA와 LDA를 혼용한 방법이 훨씬 적으므로 단독으로 사용하였을 때 인식률을 측면에서 성능이 좋은 LDA보다 오히려 효과적인 결과를 얻었다. 그리고 인식 결과가 3~5번째 답까지 포함한 인식에서 HNMA가 다른 학습 방법보다 높은 인식률을 얻는 현상이 발견되었고, 이러한 점으로 인하여 HNMA가 우수하다라는 결론을 얻을 수 있었다.

참 고 문 헌

- [1] M.Turk and A.Pentland: "Eigenfaces for face recognition", J. Cognitive Neuroscience, vol.3, no.1, pp.71~86, 1991.
- [2] Kandel, E.R. et al., "Principles of Neural Science, 4th edition", McGraw-Hill, 2000.

- [3] Juwei Lu, K.N. Plataniotis, and A.N. Venetsanopoulos, "Face recognition using LDA based algorithms", IEEE Transactions on Neural Networks, vol.14, no.1, pp.195~200, January 2003.
- [4] Te-won Lee, "Independent Component Analysis Theory and Application", Kluwer Academic Publishers, 1998.
- [5] http://www.isip.msstate.edu/publications/reports/isip_internal/1998/linear_discrim_analysis/lda_theory.pdf
- [6] A.Martinez and A.Kak: "PCA versus LDA", IEEE Trans. On PAMI, 23(2):228~233, 2001.
- [7] 민병경, "민병경의 재미있는 뇌 과학 이야기", <http://mind21.net/scienceall-7.htm>.
- [8] 이케가야 유지, 이토이 시게사토, "해마", 은행나무, 2003.
- [9] Dayan, P. and Abbott, L.F., "Theoretical Neurosc ience", MIT press, 2001.
- [10] Homepage of the AT&T Laboratories at Cambridge : <http://www.uk.research.att.com/facedatabase.html/>
- [11] Homepage of the Advanced Multimedia Processing Lab in the Carnegie Mellon University : <http://amp.ece.cmu.edu/>
- [12] F. Samaria, "Face Recognition Using Hidden Markov Models", PhD thesis, University of Cambridge, 1994.
- [13] A. Nefian, "A Hidden Markov Model Based Approach for Face Detection and Recognition", PhD thesis, Univer sity of Georgia Institute of Technology. August 1999.

저 자 소 개



오 선 문(정회원)
2004년 동명정보대학교
컴퓨터공학과 학사 졸업.
2004년-현재 동아대학교
전자공학과 석사과정.
<주관심분야 : 영상처리, 패턴인
식, 신호처리>



강 대 성(정회원)
1984년 경북대학교
전자공학과 학사 졸업.
1991년 Texas A&M 대학교
전자공학과 석사 졸업.
1994년 Texas A&M 대학교
전자공학과 박사 졸업.
1995년~현재 동아대학교 전자컴퓨터공학부 부교수.
<주관심분야 : 영상처리, 비디오 색인 및 검색,
영상 압축>