

도심방범용 CCTV를 위한 실시간 얼굴 영역 인식 시스템

김영호[†], 김진홍^{‡‡}

요 약

본 논문에서는 인간 뇌의 내부에 존재하는 해마를 모델링한 해마 신경망을 사용하여 도시방범용 CCTV를 위한 얼굴영역 인식 시스템을 제안한다. 이 시스템은 특징추출 부분과 학습 및 인식 부분으로 구성되어 있으며, 특징 추출 부분은 PCA(Principal Component Analysis)와 LDA(Linear Discriminant Analysis) 사용하여 구성한다. 학습부분에서는 해마의 구조의 순서에 따라 입력되는 영상 데이터들의 특징을 치아 이랑 영역에서 호감도 조정에 의해 반응 패턴을 이진화 하고, 다음으로 CA3 영역에서의 자기 연상을 통해 영상에 포함되어 있는 노이즈를 제거하게 된다. 노이즈가 제거된 데이터는 CA1 영역에서 신경망을 통해 장기기억이 이루어진다. 제안한 시스템의 성능을 평가하기 위해 형태변화와 조명변화에 따른 인식률 실험을 실시하였다. 실험 결과, 본 논문에서 제안한 특징 추출 및 학습 방법을 다른 학습 방법들과 비교하였을 때, 우수한 인식률을 가짐을 확인하였다.

Development of Real-Time Face Region Recognition System for City-Security CCTV

Young Ho Kim[†], Jin-Hong Kim^{‡‡}

ABSTRACT

In this paper, we propose the face region recognition system for City-Security CCTV(Closed Circuit Television) using hippocampal neural network which is modelling of human brain's hippocampus. This system is composed of feature extraction, learning and recognition part. The feature extraction part is constructed using PCA(Principal Component Analysis) and LDA(Linear Discriminants Analysis). 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 a dentate gyrus and remove the noise through the auto-associative 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 shape change and light change. 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.

Key words: Real-Time Face Region Recognition(실시간 얼굴영역인식), City-Security CCTV(도시방범용 CCTV), Hippocampus(해마)

1. 서 론

최근 군포 여대생 사건의 범인 검거 과정에서의

CCTV 역할의 중요성이 대두 되면서 사생활 침해 논란이 여전한 가운데 CCTV가 강력범죄 해결 부분에서 일등공신 역할을 하고 있다. 따라서 본 논문에

* 교신저자(Corresponding Author): 김진홍, 주소: 부산광역시 북구 구포3동 산48-6(616-737), 전화: 051)330-7156, FAX: 051)335-1453, E-mail: jhkim@bit.ac.kr
접수일: 2009년 12월 17일, 수정일: 2009년 12월 23일

완료일: 2009년 12월 23일

[†] 정회원, 한국이미지시스템(주) 신기술연구소 소장
(E-mail: newkyh@hotmail.com)

^{‡‡} 정회원, 부산정보대학 컴퓨터정보계열 교수

서는 도시방범용CCTV를 위한 실시간 얼굴영역 인식시스템을 제안한다. 실시간 영역 추적은 무인감시, 스마트 룸, 객체기반 비디오 암축, 운전자 보조 시스템 등에 있어서 가장 중대한 작업 중 하나라고 할 수 있다.

기존의 영역 추적을 위한 방법은 3D 모델 기반의 방법, 영역 기반의 방법, 능동 윤곽선 기반의 방법, 특징 기반의 방법 등이 있는데, 물체의 움직임 변화가 적은 부분에서는 추적이 양호하지만, 이동 속도나 형태의 변화가 큰 물체의 추적에는 문제가 있었다. 이러한 문제를 해결하기 위하여 움직이는 물체가 어디로 이동할지를 예측하는 것이 필요하다. 우리는 인간 뇌의 내부에 존재하는 해마라는 영역을 모델링하여 물체의 이동 방향을 예측하여 얼굴영역을 인식하는 시스템을 제안한다[1-3].

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, 원숭이와 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 영역에서 많은 차이점에도 불구하고, 해마가 신피질의 교사라는 생각이 많은 연구가들에 의해서 널리 채택되어왔다. 최근의 신경생물학 모델들은 인간의 뇌에서 신피질의 표현의 구성에서 해마의 역할을 중요시

하고 있다. 공학부분에서 많이 응용되고 있는 신경망은 뇌의 학습-기억 활동을 모태로 다양한 분야에 응용되고 있다. 신경망에서의 학습은 실제 뇌 안에서 뉴런과 뉴런이 각각 시냅스로 연결되어 정보 전달 및 처리하는 과정으로 볼 수 있다. 따라서 신경망을 단편적으로 고려했을 때 신경망의 학습과정은 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. 그럼 1과 같이 생체 내의 시냅스는 뉴런 간의 정보 전달의 연결 통로로서 다양한 문자 단위의 물질을 분비 혹은 흡수한다. 시냅스를 통한 신경전달물질간의 이동은 시냅스에서 일어나는 신경물질의 전도과정(synaptic transmission)으로서 뉴런과 뉴런간의 의사소통 수단으로 이용된다. 시냅스가 갖는 신경 세포간의 의사소통 기능은 전기적 신호를 화학적 신호로 변화시키는 중간 단계이며, 실제 신경 세포 내에서 일어나는 생화학적 기작을 설명하는 데에 적합하다. 자극이 주어졌을 때 전시냅스에서 정보를 내포하고 있는 문자단위의 물질들이 활성화 되어 후시냅스로 진행되는 동안 문자 혹은 기질간의 다이나믹스는 연속적이며, 병렬적으로 발생한다.

헤브의 학습방법을 바탕으로 생성된 기존의 신경망들은 실제 뇌 모델에서의 그것과는 차이가 있다. 뇌에서는 실제로 해당 패턴 하나에 필요한 흥분 세포들의 정보만 저장된다. 일반적인 신경망 구조를 갖는 체제에서는 필요한 특징들만 저장할 수 없다.

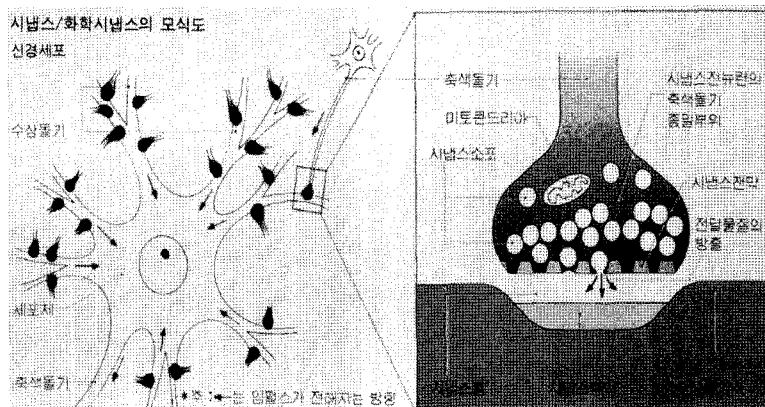


그림 1. 시냅스 모형

본 논문의 2장에서 특징을 계산하기 위해 사용한 PCA와 LDA에 대하여 설명한다. 3장에서 해마 신경망에 대해 설명하고 4장에서는 실험 및 결과에 대해 기술한다. 끝으로 5장에서 결론과 향후 과제에 대해서 기술한다.

2. 특징계산

2.1 PCA

PCA는 평균과 분산까지의 통계적 성질을 이용한 2차 통계적 기법이다.[4] 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. 그러나 PCA는 2차 통계 자료만을 사용하기 때문에 영상에서 가장 기본적인 특징이라 할 수 있는 경계선을 나타내기도 힘든 단점이 있다.

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.

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 이 때 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 정규화되어 있으므로 $V^T = V$ 의 성질을 가지며, 역으로 데이터를 변환하는 것은 $X^T = RV^T$ 와 같이 구할 수 있다.

본 논문에서는 고유값 크기의 내림차순으로 고유벡터를 정렬하고, 작은 값 d 이하의 고유치를 0으로 바꾸어 이들 고유벡터의 값을 무시하도록 하였다. 또한 구한 특징 벡터에서 조명 변화, 가려짐 등을 포함하는 가장 큰 고유값 몇 개에 해당하는 고유벡터를 제거하여 새로운 고유벡터를 구성하였다. 새롭게 만들어진 고유벡터를 해마신경망의 입력으로 사용한다.

2.2 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 타당한 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 발생하는 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.

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 고유값을 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.

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

2.3 주성분의 LDA변환을 이용한 특징벡터 계산

LDA 변환은 각 집단의 특징을 정확히 분류해주는 특성을 가지고 있기 때문에, 얼굴 관련 연구 중 특히 인식 관련 연구에서 많이 사용되어지고 있다. 하지만, 아래와 같은 세 경우에 대해서는 LDA 변환이 그리 좋지 않은 결과를 가짐을 알 수 있다.

- 1) 학습 집합에 없는 테스트 표본에 대해서
- 2) 학습 집합과 현저히 다른 테스트 표본이 주어졌을 때
- 3) 학습 집합에 있는 표본과 다른 배경을 가진 테스트 표본이 주어졌을 때

또한, LDA 변환은 집단 내 데이터 분산을 나타내는 행렬이 항상 하나(Singular)이기 때문에 기존의 방법론에서 직접 쓰일 수 없고, 또한 고차원의 영상 벡터가 입력으로 들어오면 방대한 계산으로 여러 가지 어려움을 초래하는 단점을 가진다. 따라서, 이러한 단점을 해결하기 위해서 PCA 변환으로 차원을 감소한 다음 LDA 변환을 이용하는 것은 LDA 변환 만 이용하는 것보다 더 나은 결과를 가질 수 있도록 한다.

본 논문에서도 얼굴 검출에 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.

within-class scatter matrix S_w 와 between-class scatter matrix S_b 는 식 (5)와 같다.

$$J(W) = \frac{W^T S_b W}{W^T S_w W} \quad (5)$$

$$\frac{d}{dW} [J(W)] = \frac{d}{dw} \left[\frac{W^T S_b W}{W^T S_w W} \right] = 0$$

$$[W^T S_w W] \frac{d[W^T S_b W]}{dW} - [W^T S_b W] \frac{d[W^T S_w W]}{dW} = 0$$

$$[W^T S_w W] 2S_b W - [W^T S_b W] 2S_w W = 0$$

$$\left[\begin{array}{c} W^T S_w W \\ W^T S_b W \end{array} \right] S_b W - \left[\begin{array}{c} W^T S_b W \\ W^T S_w W \end{array} \right] S_w W = 0$$

$$S_b W - JS_w W = 0 \quad S_w^{-1} S_b W - JW = 0$$

일반화한 고유값 문제 ($S_w^{-1} S_b W - JW = 0$)의 해법에 의해서 W 는 $S_w^{-1} S_b$ 의 고유벡터가 되므로 $S_w^{-1} S_b$ 의 고유벡터를 구하면 $W^* = S_w^{-1}(u_1 - u_2)$ 가 된다.

또한, 최대화 정리에 의하여 분자를 클래스간 평균의 차인 상수로 취급하면, 다음과 같은 최적화된 변환행렬 W^* 을 수식(6)을 구할 수 있다.

$$W^* = \operatorname{argmax} \left\{ \frac{w^T S_b w}{w^T S_w w} \right\} = S_w^{-1}(u_1 - u_2) \quad (6)$$

결과적으로 얼굴 영상 벡터를 Fisher's Linear Discriminant에 의해 선형 변환 표현되어 미리 구하여진 벡터들을 해마 신경망의 Input data로 이용한다.

3. 해마신경망 모델과 구현

해마의 기능 중 가장 중요하고 강력한 것은 단기 기억에서 장기기억으로의 확장에 있다. 해마의 역할은 뇌금 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 것인지를 결정할 수 있다. 이러한 결정 값은 해마기억 장소 분류 기준 값으로 사용할 수 있다. 전체 데이터 개수 대비 해당뉴런의 누적 개수가 문턱치를 만족하면 장기 기억 장소로 저장시키도록 한다[6].

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

내후각뇌피질(Entorhinal cortex) : 해마와 신피질 사이에서 인터페이스를 구성하고 해마 신경망 모델의 입력과 출력을 나타낸다.

치아이랑(Dentate gyrus) : 내후각뇌피질에 직접 연결되는 치아이랑 구조는 그 모델에 동일한 객체의

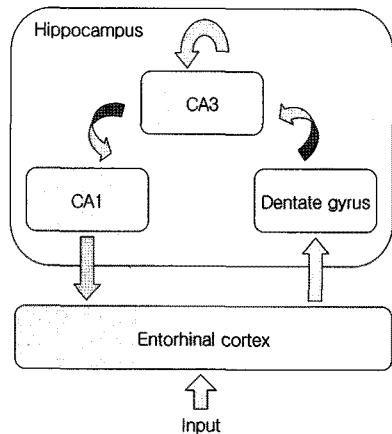


그림 2. 해마신경망 모델

다양한 특징 성분들을 과거 입력 패턴에서 동일성을 판단하여 특징을 단순화 시킨다. 패턴 평균값에서 편차율 범위의 임계수치를 넘으면 1, 그렇지 않으면 -1로 하여 특징의 동일성을 이진화 시킨다.

CA3: 어떤 사건을 기억해낼 때에는 연상 작용을 반복함으로써 보다 나은 결과를 얻을 수 있으며, 이러한 순환 개념을 도입한 것이 순환 연상 메모리이다 [6]. 순환 연상 메모리는 그림 4에서 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 특정 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

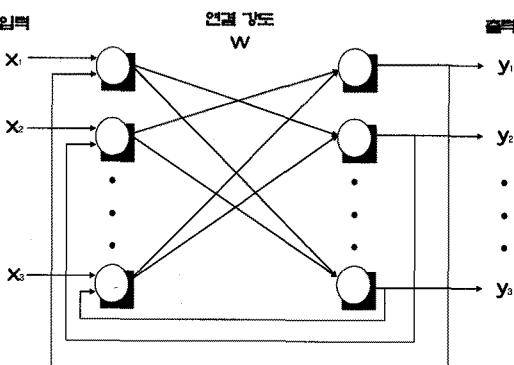


그림 3. 순환 연상 모델의 구조

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 단위행렬이다.

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.

4. 실험 및 결과

4.1 시스템 사양

본 시스템은 촬영부와 제어부로 구성된다.

1) 촬영부

1-1) Digital Camera

- 2/3" CCD progressive scan
- 1392(h) × 1040(v) 20 frames/sec
- 제어 : IEEE-1394, 12Pin Connector
- monochrome connection assembly

1-2) 렌즈

- Motorized Zoom Lens(MZCM12575)
- Focal length : 12.5~75mm
- Focus control : motorized
- Zoom ratio : 6x
- Iris Range : F1.8~close
- Iris control : motorized connection assembly

1-3) CDS

- 주변 밝기 입력용

- 보조조명 ON/OFF Control 용
- Dark resistance : 10Mohm 이상
- White resistance : 2Kohm 이하

1-4) 조명

- IR LED 조명
- 수명 400만회 이상
- 220V AC

1-5) 제어보드 I

- Serial communication control
- Motorized lens 제어
- CdS interface
- CDS 또는 Sensor
- Trigger sync. Detection

1-6) SMPS

- 제어보드 및 카메라 전원 공급
- Input 85~264V ~1.5A 50/60HZ
- Output 5V,3A 12V,1.2A
- Power 30W

1-7) 카메라 전원 커넥터

- 12P Hirose 커넥터
- 디지털 카메라 전원 공급용
- 설정 변경용
- 직렬 통신에 의한 원격 제어

1-8) 카메라 Data 커넥터

- 26P 커넥터
- 디지털 카메라 디지털 신호 전송용
- LVDS 전송 Twisted Pair

1-9) 카메라 배선

- 카메라 신호처리
- Twisted Pair
- S/B 0.08SQ*20Pair 외경 7.5mm

1-10) 카메라 하우징

- 재질 : 알루미늄 (aluminium)
- 사용온도 : Fan(14W) : On: 34°C Off: 26°C, Heater(30W) : On: 5°C Off: 15°C
- 입력전압 : AC220V, 50/60Hz
(AC24/110V option)

1-11) 렌즈 control

- 렌즈 제어 Channel : 3CH
(ZOOM, FOCUS, IRIS)
- 통신 제어 : Serial Port(RS232C-422), 절연형

2) 제어부

- 2-1) 얼굴영역 인식 제어기
- 산업용 PC
- CPU : Pentium 4 3.0G
- RAM : 512Mbyte 이상
- 얼굴영역 인식 : 0.5초이내
- 카메라 I/F : LVDS, 최대 50m
- I/O Port : USB X 6, Series × 6
- 영상저장 : 200 Gbyte HDD
- 사용 전원 : AC220V, 300W

2-2) 제어보드 II

- Auto Reboot
- Watchdog 가능
- 시스템 자동 전원 ON 가능

2-3) 영상 인식 프로그램

- 영상획득 및 영상인식부
- Image Acquisition Library
- Image Processing Library
- Plate Recognition Library
- Data Transfer Module
- Database Module

2-4) 영상 처리 프로그램

- 획득 영상 JPEG 파일 저장

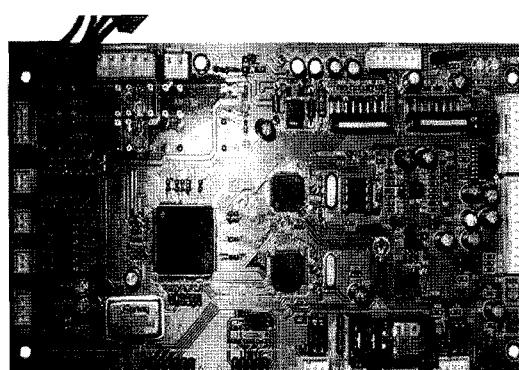


그림 4. 제어보드

- 얼굴영역 인식 정보 Database 저장
- 얼굴영역 정보 센터 전송
- 센터 서버 통신 상태 감시 및 각 모듈별 작동 상태 감시

4.2 실험 결과

본 논문의 실험에서는 해마 신경망의 성능을 객관적으로 평가하기 위해 HMM, SVM 그리고 BP 알고리즘과 비교하는 방식으로 수행하였다. 얼굴영역 인식은 다양한 방향과 어두울 때와 밝을 때의 영상을 활용하여 형태변화 및 조명변화 따른 인식률 변화 실험을 할 수 있도록 하였다.

형태변화에 따른 얼굴영역 인식은 PCA와 LDA를 함께 사용한 특징 벡터 계산 방법의 인식 성능을 평가하기 위해서, PCA, LDA 외에 ICA를 각각 단독으로 사용하여 계산한 특징 벡터들과 비교하였다. 결과는 표 1과 표 2와 같다.

표 1. 형태변화에 따른 인식률 비교(%)

학습방법 특징계산방법	HMM	SVM	BP	해마 신경망
PCA	89.63	89.56	89.76	89.53
LDA	91.45	90.53	90.51	92.36
ICA	89.78	90.44	90.63	92.83
PCA+LDA	93.39	93.47	92.34	95.76

표 2. 조명변화에 따른 인식률 비교(%)

학습방법 특징계산방법	HMM	SVM	BP	해마 신경망
PCA	91.54	91.38	91.46	91.42
LDA	93.36	92.67	92.45	94.03
ICA	92.68	92.36	92.51	94.65
PCA+LDA	95.26	95.35	94.26	97.78

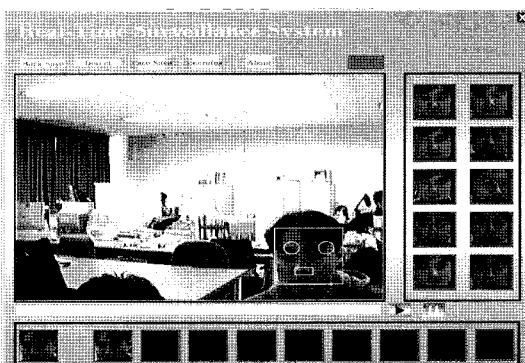


그림 5. 얼굴영역 검출 프로그램 테스트결과



그림 6. 시제품에 적용 감시기능 동작 화면

표 1과 표 2를 보면 PCA와 LDA를 함께 사용하여 특징을 계산한 것은 여러 학습방법들에서 가장 우수한 인식률을 보였다. 표 1은 형태변화에 따라 인식률을 비교해 높은 것이다. 표 1을 보면 특징계산방법을 PCA와 LDA를 함께 사용하고 학습방법을 해마신경망을 사용했을 때 95.76%의 높은 인식률을 보여 다른 신경망에 비해 형태변화에 강인한 것으로 나타났다. 그리고 표 2는 조명변화에 따라 인식률을 비교해 높은 것이다. 표 2를 보면 PCA와 LDA를 함께 사용했을 때 해마신경망에서 97.78%의 높은 인식률을 보였다. 따라서 형태변화와 마찬가지로 조명변화에서도 해마신경망과 PCA, LDA의 조합이 가장 강인한 것으로 나타났다.

5. 결 론

본 논문에서는 도시방법용CCTV에 사용할 솔루션을 위해 뇌의 한 부분인 해마를 모델링한 신경망을 사용하여 실시간으로 얼굴영역을 인식하는 시스템을 개발해 보았다. 특징계산방법으로 PCA와 LDA를 함께 사용하는 방식을 사용하였는데 PCA, LDA를 개별적으로 사용한 방법보다 우수한 성능을 보였으며, 개별적으로 사용했을 때 가장 우수한 성능을 가진 ICA보다도 높은 인식률을 보였다. PCA와 LDA를 함께 사용한 방법은 다른 신경망을 사용했을 때보다 해마 신경망을 사용 했을 때 더욱 좋은 성능을 가짐을 확인할 수 있었다. 조명변화와 형태변화에 따른 얼굴영역 인식 실험에서 해마 신경망이 95% 이상의 인식 성능을 나타내는 등 다른 학습 방법들보다 높은 인식 성능을 보였다. 이것으로 미루어보아 해마신경망이 다른 신경망들에 비해 우수하다는 결론을 얻을 수 있었다.

참 고 문 현

- [1] R. Chellappa and S. Sirohey, "Human and Machine Recognition of Face; A Survey," *IEEE Trans. on Image Processing*, Vol.83,

No.5, May 1995.

- [2] 김종복, 김영호, 강대성, "해마 신경망을 이용한 실시간 물체 인식 시스템 개발," *한국통신학회 논문지*, 제31권, 제2호, pp. 78-84, 2006.
- [3] 장혜경, 강대성, "실시간 얼굴인식 시스템을 위한 새로운 LINF 알고리즘의 제안," *대한전자공학회 논문지*, Sept 2005.
- [4] A. Martinez and A. Kak, "PCA Versus LDA," *IEEE Trans. on PAMI*, pp. 228-233, 2001.
- [5] Juwei Lu, K.N. Plataniotis, and A.N. Venetsanopoulos, "Face recognition using LDA based algorithms," *IEEE Trans. on Neural Networks*, Vol.14. No.1, pp. 195-200, Jan 2003.
- [6] M. Witter and H. Groenewegen, "A new look at the hippocampal connectional network," *In European Neuroscience Association, 1998.*



김 영 호

1999년 2월 동아대학교 전자공학과 학사
2002년 2월 동아대학교 전자공학과 석사
2006년 2월 동아대학교 전자공학과 박사

2009년~현재 한국이미지시스템(주) 신기술 연구소 소장
관심분야: 영상처리, 하드웨어시스템 구현



김 진 홍

1984년 동아대학교 전자공학과 학사
1987년 동아대학교 전자공학과 석사
2003년 동아대학교 전자공학과 박사

1997년~현재 부산정보대학 컴퓨터정보계열 교수
관심분야: 통신 및 신호처리, 영상인식