

논문 2006-43SP-4-5

연상기억과 뉴런 연결강도 모듈레이터를 이용한 해마 학습 알고리즘 개발

(Development of the Hippocampal Learning Algorithm Using Associate Memory and Modulator of Neural Weight)

오 선 문*, 강 대 성*

(Sun-Moon Oh and Dae-Seong Kang)

요 약

본 논문에서는 인지학에서 연구되고 있는 동질 연상 기억 현상과 장기 및 단기 기억 강화 조절 기능을 담당하는 해마의 두뇌 원리를 공학적으로 모델링한 MHLA(Modulatory Hippocampus Learning Algorithm)의 개발을 제안한다. 해마에서 중요시 하는 연관된 3단계 조직(DG, CA3, CA1)에 기반한 동질 연상 메모리를 구성하도록 하였으며, 장기 기억 학습에 모듈레이터(modulator)를 추가하여 학습 수렴 속도를 향상시켰다. 해마 구조에서 정보는 3단계 순서에 따라 치아 이랑 영역에서 통계적인 편차를 적용하여 호감도 조정에 따라서 반응 패턴으로 이진화 되고, CA3 영역에서 자기 연상 메모리를 하여 패턴이 재구성이 된다. CA3의 정보를 받는 CA1영역에서는 모듈레이터가 적용되는 신경망에 의해 장기기억 인식에 이용되는 연결n강도의 수렴이 빠르게 학습된다. MHLA의 성능을 측정하기 위하여 포즈 및 표정과 화질 상태에 따라 분류된 얼굴 영상에 PCA(Principal Component Analysis)를 적용하여 특징 벡터들을 계산하 MHLA로 학습한 후, 인식률을 확인하였다. 실험 결과, 제안한 학습 방법을 다른 방법들과 비교하였을 때, 학습시간비용과 인식률에서 우수함을 확인하였다.

Abstract

In this paper, we propose the development of MHLA(Modulatory Hippocampus Learning Algorithm) which remodel a principle of brain of hippocampus. Hippocampus takes charge auto-associative memory and controlling functions of long-term or short-term memory strengthening. We organize auto-associative memory based 3 steps system(DG, CA3, CA1) and improve speed of learning by addition of modulator to long-term memory learning. In hippocampal system, according to the 3 steps order, information applies statistical deviation on Dentate Gyrus region and is labelled to responsive pattern by adjustment of a good impression. In CA3 region, pattern is reorganized by auto-associative memory. In CA1 region, convergence of connection weight which is used long-term memory is learned fast by neural networks which is applied modulator. To measure performance of MHLA, PCA(Principal Component Analysis) is applied to face images which are classified by pose, expression and picture quality. Next, we calculate feature vectors and learn by MHLA. Finally, we confirm cognitive rate. The results of experiments, we can compare a proposed method of other methods, and we can confirm that the proposed method is superior to the existing method.

Keywords : Hippocampus, Neural Network, Synapse, Face Recognition, PCA(Principal Component Analysis)

I. 서 론

전체적인 뇌의 기능 중에서 설치류와 인간의 해마의 역할과 시스템은 과거 수십 년 동안 광범위하게 연구되었다. 주의 해마에서 장소 세포들의 발견 이후로 공간

적 관점에 강하게 관련 있는 반면에, 원숭이와 인간에 있어서는 주로 에피소드식 기억에 관련이 있다. 1971년 초반에, Marr는 기억 강화에서의 해마의 결정적인 역할에 대한 이론을 제안했다^[1]. 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 인간

* 정희원, 동아대학교 전자공학과
(Dept. of Electronic Eng., Dong-A University)
접수일자: 2005년11월9일, 수정완료일: 2006년6월19일

의 뇌에서 신피질의 표현의 구성에서 해마의 역할을 중요시하고 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. 생체 내의 시냅스는 뉴런 간의 정보 전달의 연결 통로로서 다양한 분자 단위의 물질을 분비 혹은 흡수한다. 시냅스를 통한 신경전달물질 간의 이동은 시냅스에서 일어나는 신경물질의 전도과정으로서 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 설명하는데에 적합하다^[2].

II. 해마의 생물학적 배경

2.1. 해마의 기능

Scoville 및 Milner(1957)이 측두부 손상에 의한 기억 장애를 보고한 이래 많은 연구의 결과에서 해마가 학습과 기억의 형성에 필수적인 역할을 함이 밝혀졌다^[3]. 또한 Bliss 및 Lomo(1973)가 해마에서 장기강화 현상을 관찰한 이후 많은 연구에서 해마는 가소성(plasticity)이 잘 일어나는 장소임을 밝혔다^[4]. 이 가소성이 학습 및 기억의 세포수준에서 기전으로 생각될 뿐 아니라 과도한 강화 효과로 경련발작의 유발되는 장소가 될 수 있음을 암시한다. 즉, 해마는 기억 및 학습에 필수적인 장소이며 또한 경련발작의 개시 장소이다.

2.2. 해마의 구조 및 역할

해마형성체는 주로 브로드만영역 28인 내후각뇌피질(entorhinal cortex)에서 구심섬유를 받는다. 내후각뇌피질의 외측부분에서는 해마이행부를 지나 치아이랑과립세포(granule cell)의 수상돌기와 해마의 CA1, CA2, CA3로 섬유를 보내며 이를 관통로(perforant path)라고 한다. 내후각뇌피질의 내측부분에서는 외측뇌실의 표면을 통해 백색총(alveus)으로 섬유를 보내며 해마이행부와 해마의 CA1에서 종지된다. 이 경로는 백

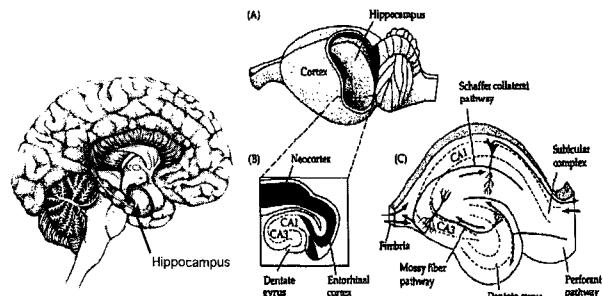


그림 1. 해마의 생물학적 구조

(a) 뇌에서 해마의 위치 (b) 해마의 구성

Fig. 1. Biochemical construction of Hippocampus.

(a) Hippocampus position in brain

(b) Hippocampus system

색로(alveolar path)라고 한다. 과립세포의 축삭은 이끼섬유(mossy fiber)가 되어 CA3 피라미드세포의 수상돌기에 시냅스를 이룬다. CA3 축삭의 곁가지(Schaffer collateral)는 CA1 피라미드세포의 수상돌기에 시냅스를 이룬다^[5].

2.3. 해마 신경에서의 기억

이끼섬유와 CA3 피라미드 세포 사이의 시냅스에서의 장기 강화(long-term potentiation) 현상은 오직 이끼섬유 줄기살들의 고주파 자극으로만 발생한다. 즉, 해마 조직의 다른 시냅스와 달리 이 지역의 장기 강화는 입력 자극의 강도에만 의존하는 비-연관적인 형태이다. CA1 피라미드 세포의 연관된 장기 강화(associative LTP)는 전 시냅스의 고주파 입력과 다른 홍분 입력으로 인한 후 시냅스 세포의 동시적인 홍분 전위로부터 발생한다^[6]. 이 연관된 장기적 강화가 일어나는 지역의 NMDA 수용체들은 평소 Mg²⁺ 이온으로 막혀 있다가, K⁺나 AMPA 수용체들에 의한 전위-변화로 Mg²⁺가 떨어져 나가게 되어, NMDA 수용체 통로를 통해 Na⁺나 Ca²⁺의 세포 내 유입과 K⁺의 세포 밖 유출이 가능해진다. 만약, 해마 조직의 NMDA 수용체를 차단시키면 후 시냅스 홍분 전위에 효과를 최소화시키므로, 관통 경로와 쉐퍼 곁가지들의 연관된 장기적 강화의 흔적은 사라진다. 'NMDA (N-Methyl-D-Aspartate) 수용체'는 지금까지 알려진 유일한, ①전위차와 ②리간드(ligand: 라틴어 '결합하는'이라는 뜻으로 수용체의 특정 부위에 달라붙는 화학적 물질을 의미함.)에 함께 제어되는 이온 통로이다. 즉, 약간의 탈분극(①)과 신경 전달 물질의 결합에 의한 활성 변화(②) 모두가 이 수용체 통로의 열림에 필요하다. 따라서 NMDA 통로는 평상시에 하나 이상의 Mg²⁺들이 세포 안쪽에서 통로 벽에 붙어

있다가, 종종 같은 세포 내의 K나 AMPA수용체들에 의하여 생긴 전위 변화로 떨어져 나간다. 또한, 이 NMDA 수용체는 적어도 두 개의 활성-변이 리간드(홍분성 아미노산 신경 전달 물질, 글라이신)들을 필요로 한다. (참고로, 글라이신 억제성 수용체는 척수에 현저하게 존재하며, 특히 피질/척수 경로에는 고농도로 존재한다. 반면에, NMDA 수용체는 대뇌 반구에 우세하게 분포하며, 더욱 재미있게 학습과 기억에 관계있는 해마(hippocampus)에 고농도로 존재한다. 반복과 각성이 중요한 학습과 기억의 특징을 전위차와 리간드(ligand)가 함께 제어한다는 NMDA 수용체의 특징과 유의하며 생각해보면 흥미롭다. 이처럼, NMDA 수용체의 연관된 두 사건의 동시적 자극 성질을 생각하건대, 우리가 맛있는 사과를 양파와 구분하여 인식할 수 있는 것은 사과의 맛과 색깔과 냄새 등이 '사과'라고 하는 이미지와 함께 학습되고, 기억되어 우리의 머릿속에 함께 저장되었기 때문이다.

III. 해마의 공학적 모델링

3.1 3단계 기본구조 모델링

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

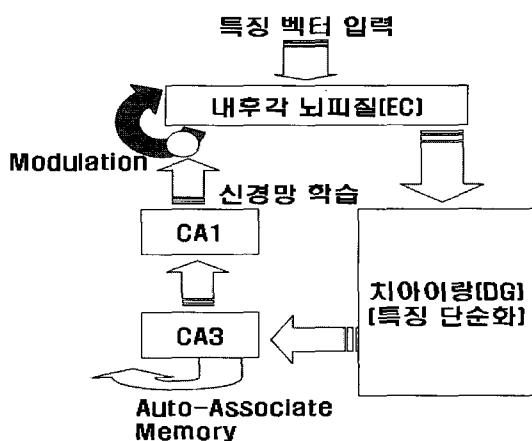


그림 2. 해마의 정보처리 기본 모델

Fig. 2. Hippocampal data process model.

신경망에도 도입한다면, 입력되는 중간에 입력받는 값들의 가중치를 사용하여 단기 기억을 할 것인지 장기 기억을 할 것인지를 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^[7].

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

- **내후각노피질** : 해마와 신피질 사이에서 인터페이스를 구성하고 해마 신경망 모델의 입·출력을 나타낸다.
- **치아이랑** : 내후각노피질에 직접 연결되는 치아이랑 구조는 그 모델에 동일한 객체의 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^[8]. 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. 따라서, Hopfield 연상 메모리에서 p 개의 패턴들을 저장하는 연결 강도 W 는 식 (1)과 같다^[9].

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

여기서, I 는 단위행렬이다.

CA1 : CA1 영역은 CA3영역에 연결되고 정보 처리의 마지막 단계를 나타낸다. 자기 연상된 CA3의 정보 중에서 빈도수가 높은 패턴을 모듈레이터가 추가된 신

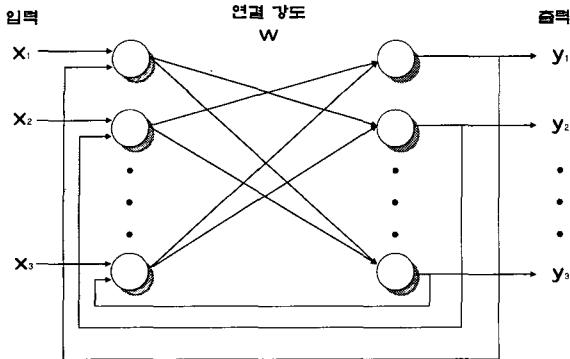


그림 3. 순환 연상 모델의 구조

Fig. 3. Structure of auto associate memory.

경망에 학습 시키며, 장기기억을 학습한다. 학습된 가중치에 반응하여 출력 값이 맞지 않을 경우 단기기억으로 패턴을 분류하여 새로 저장하는 기능을 한다. 장기기억 학습은 3.2절에서 상세히 설명하도록 한다.

3.2 장기기억 학습과 Modulation

단기기억에서 장기기억의 확장을 위해서 본 논문에서는 기존의 EC지역 외에도 해마지역의 구조를 도입하여 중요한 특징에 대한 가중치 부과를 통하여 인식률을 높이고 적응적으로 확장 가능한 신경망 학습 알고리즘을 제안한다. 3중 시냅스 메커니즘을 통해서 해마 지역은 CA1 전시냅스 뉴런과 EC 후시냅스 뉴런의 가중치의 모듈레이터 역할을 한다.

그림 4는 기존 신경망의 뉴런 연결성과 제안하는 해마 뉴런의 변조 모듈레이터를 도식화 한 것이다. \$A_M(t)\$는 뉴런 M의 활성이다. \$m_i(t)\$는 시냅스 i와 문턱치 함수 f의 뉴런 M의 변조 가중치이다. 뉴런 N의 활성 \$A_N(t)\$는 식 2에 따라 계산 된다^[10].

$$A_N(t+1) = \left(\sum_{i=1}^n m_i(t) A_M(t) w_i(t) x_i(t) \right) \quad (2)$$

\$m_i A_M(t)\$는 뉴런 M의 활동에 종속적인 변조 항이다. 그림 5에서 전시냅스와 후시냅스 뉴런의 활동에 따라서 변조 뉴런의 역할을 부가한다. 변조 뉴런 \$CA1_{mod}\$가 시냅스를 전시냅스 뉴런 \$EC_{pre}\$와 후시냅스 \$EC_{post}\$ 사이에서 조정한다고 하자. \$CA1_{mod}\$의 변조 역할은 다음 규칙에 따라 정해진다. 뉴런 \$CA1_{mod}\$가 활성화 되지 않았다면 식 2의 변조 항은 null이고, 결과적으로 변조 뉴런 \$CA1_{mod}\$에 비해서 후시냅스에 대한 전시냅스의 영향은 없다.

전시냅스 뉴런 \$EC_{pre}\$가 활성화 되지 않았다면 식 2

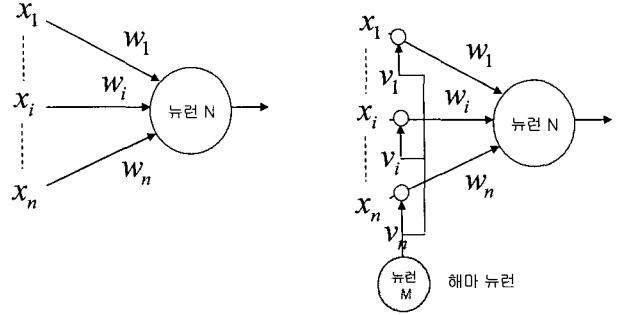


그림 4. 기존 신경망의 뉴런 연결성과 모듈레이터에 따른 해마 신경망의 뉴런 연결성

Fig. 4. Detail of a classical connectivity and a synaptic triad connectivity and the activity of the modulator neuron in the synaptic triad allows to modulate (excitatory or inhibitory) the synapses.

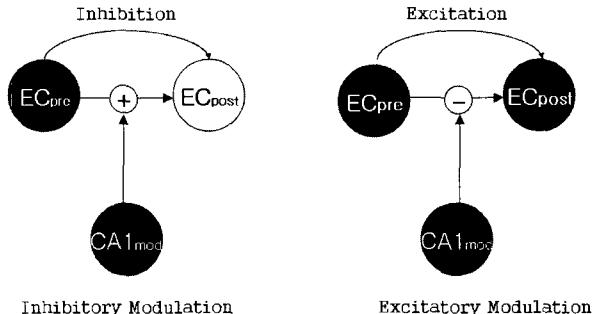


그림 5. 억제와 흥분 모듈레이션 연결

Fig. 5. Inhibitory and excitatory connections.

의 변조 항은 null이고, 결과적으로 변조 뉴런 \$CA1_{mod}\$에 비해서 후시냅스에 대한 전시냅스의 영향은 없다.

후시냅스 뉴런 \$EC_{post}\$ 활성화되지 않은 동안 전시냅스 뉴런 \$EC_{pre}\$가 활성화되면 시냅스는 억제된 것으로 고려되고 변조 뉴런 \$CA1_{mod}\$는 두 개의 뉴런 사이에서 억제 연결을 촉진하기 위해 학습을 할 것이다(변조 요소는 -1인 경향이 있다). 전시냅스가 활성화되지 않았다면 후시냅스 유닛에 전시냅스 유닛의 영향이 없는 것으로 고려된다. 결과적으로, 그러한 경우에는 학습이 이루어지지 않는다. 그림 6은 단일 패턴에 대한 해마 신경망의 전체 구조를 나타낸 것이다^[11].

이제 전시냅스 뉴런 \$E_i\$와 후시냅스 뉴런 \$E_j\$를 고려해보자. 이들 두 유닛들 사이의 연결의 가중치 \$W_{ij}(t)\$는 식 3에 따라 계산된다.

$$W_{ij}(t) = \frac{2}{1 + \exp(-\sum_{k \in CA1} m_k(t) c_k(t))} - 1 \quad (3)$$

\$m_k(t)\$는 \$CA1\$ 유닛 \$C_k\$와 뉴런 \$C_k\$의 활성 \$c_k(t)\$의 변조 요소이다. EC 유닛들 사이의 연결의 가중치는 완

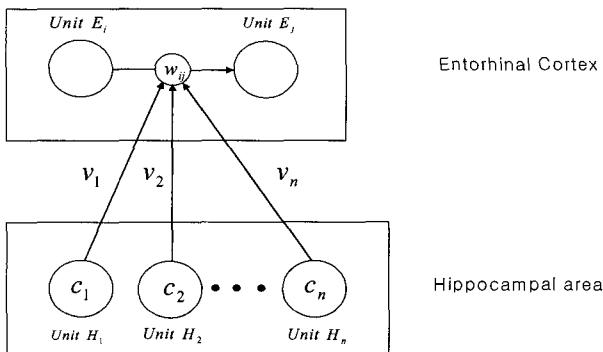


그림 6. 단일 패턴에 대한 해마 신경망의 구조

Fig. 6. Hippocampal neural structure of single pattern.

전히 CA1 활성에 종속된다. CA1에 활성이 없다면 EC에 측면의 상호작용도 없다. 동일한 부분으로 학습되는 각 패턴의 m_k 는 변조요소이고 변조된 가중치는 CA3 지역의 가중치를 입력되는 패턴의 중요도에 따라 실시간으로 흥분 또는 억제시킨다. 이와 같은 구조는 영상 검색에서 새로운 패턴의 입력 시 학습을 초기화시키는 기존 신경망의 시간 복잡성을 해결하고 입력되는 패턴에 대한 뉴런의 동적 확장이 가능하게 한다. 그림 6에서 전시냅스 뉴런 E_i 와 각자의 활성 $e_i(t)$, $e_j(t)$ 의 후시냅스 뉴런 E_j 를 다시 고려해보면, 학습은 다음과 같은 측면의 흥분과 억제를 고려할 것이다^[11].

if ($e_i(t) \geq s$) and ($e_j(t) < s$) then 뉴런 E_i 는

뉴런 E_j 를 억제

if ($e_i(t) \geq s$) and ($e_j(t) \geq s$) then 뉴런 E_i 는

뉴런 E_j 를 억제

if ($e_i(t) < s$) then 뉴런 E_i 는 뉴런 E_j 에 아무런

영향이 없다

변조 요소 m_i 는 식 4와 식 5에 의해서 업데이트된다 (bound between -1 and 1). 생성된 변조요소는 식 4와 같은 흥분 학습과 식 5의 억제 학습을 통하여 변조 가중치를 변화 시켜서 상대적으로 중요한 패턴은 장기 기억으로 학습시키고 불필요한 패턴의 가중치는 비활성화시킨다^[11].

$$\text{If } (e_j(t) < s), m_i(t+1) = m_i(t) + \alpha c_i(t) \left(\frac{e_j(t) - s}{s} \right) \quad (4)$$

$$\text{If } (e_j(t) \geq s), m_i(t+1) = m_i(t) + \alpha c_i(t) \left(\frac{e_j(t) - s}{1-s} \right) \quad (5)$$

$$s = \frac{2}{3}, \quad \alpha = 0.05 \text{이다.}$$

IV. 얼굴 인식 실험 및 결과

4.1. 실험 자료

(1) ORL 데이터베이스

ORL 데이터베이스^[12]는 Cambridge의 Olivetti Research Laboratory에서 1992년 4월부터 1994년 4월까지 획득한 얼굴 영상들로써(그림 7 참조), 40명에 대하여 일정한 어두운 배경에서 얼굴 표정과 안경 착용 유무에 따라 각 10장씩 구성되어 있다. ORL 데이터베이스는 안경·수염 등이 있는 얼굴들이 많이 분포되어 있고 좌우 회전을 통해 변형된 얼굴 영상도 다소 존재하기 때문에 난이도가 있는 얼굴 데이터베이스라고 할 수 있다. 본 논문에서는 ORL 데이터베이스의 영상을 64×64 크기로 정규화하여 실험한다.



그림 7. ORL Database의 예

Fig. 7. Some examples of ORL database.

(2) CMU AMP Face Expression Database

표정변화 실험을 위하여 CMU AMP Face Expression Database 얼굴 DB를 사용하였다. Carnegie Mellon University의 Advanced Multimedia Processing Lab^[13]에서 만든 얼굴 DB로 동일한 조명조건에서 정면 얼굴의 다양한 표정을 지원한다. 본 논문에서는 CMU 얼굴 DB에서 정면 얼굴 영상을 사용하였고, 13명의 얼굴마다 각각 75가지의 표정변화들이 존재한다. 그림 8은 CMU 얼굴 DB의 일부 얼굴 영상의 일부를 보여준다.



그림 8. CMU AMP Face Expression Database의 예

Fig. 8. Some examples of CMU AMP Face Expression Database.



그림 9. DAUFace Database의 예

Fig. 9. Some examples of DAUFace database.

(3) DAUFace 데이터베이스

제안한 시스템의 인식 성능 비교를 위해 자체 제작한 DAUFace 데이터베이스는 그림 9와 같이 화상 통신용 저가의 CCD 카메라를 가지고 일정한 환경에서 다양한 포즈와 표정 변화로 검출된 얼굴 영상이다. 각 얼굴 영상은 8-bit gray level의 64×64 크기로 되어있으며, 총 400개(20명 \times 20개)로 구성되어 있다. 대부분의 영상에서 0.00 mm 얼굴이 중앙에 위치하고 있으며, 전체의 90% 이상 얼굴이 포함되어 있다.

4.2. 실험 방법

얼굴을 표현한 후에는 특정 방법에 의하여 표현된 입력 얼굴 영상을 기준에 표현된 영상과의 비교 과정을 거치게 되는데 이것이 분류 과정이다. 이 분류 과정을 통하여 입력 얼굴 영상이 어느 얼굴의 범주에 속하는지를 결정하며 이것이 바로 얼굴 인식 시스템의 출력이 된다. 얼굴을 분류하는 방법은 Euclidean 거리 측정에 의한 특정 벡터의 거리를 측정하는 Nearest Neighbor 방법으로 구하거나, BP, SVM 등 각종 신경망과 HMM 같은 분류기를 이용하여 구할 수 있다. 그러므로 본 논문의 실험에서는 MHLA의 성능을 평가하기 위하여 주로 위와 같은 학습 방법들과 MHLA를 비교하는 방식으로 수행하였다.

Ⅲ장에서 소개한 MHLA 학습을 이용한 얼굴 인식 모델을 사용하여 얼굴 인식 실험을 수행한다. 앞 절에서 소개한 Database들을 사용하여 MHLA 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 MHLA를 학습하기 위한 모델 집합은 ORL 데이터베이스를 사용하였다. 두 번째 실험은 표정변화에 따른 얼굴 인식 실험이다. 본 실험에서는 CMU AMP 데이터베이스의 영상을 사용하여 13명의 얼굴 영상에 대해 75가지의 표정들 중에서 50가지의 표정들을 변화

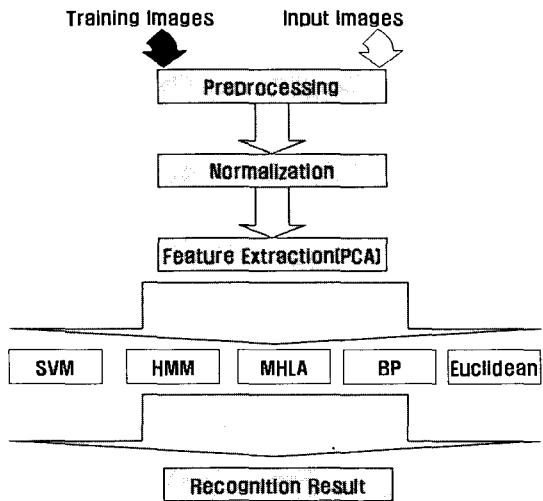


그림 10. 학습 알고리즘을 이용한 얼굴 인식 실험 순서도

Fig. 10. Flow chart of the facial recognition experiment using learning algorithm.

해가며 알고리즘별로 얼굴 인식 성능을 측정하였다. 세 번째 실험은 자체 제작한 DAUFace 데이터베이스를 이용하여, 저가용 CCD카메라에서 약간의 포즈변화를 주면서 획득한 얼굴 영상의 인식성능을 측정하였다. 20명의 얼굴 영상에 대해 각각 20개의 포즈 영상 중에서 15개를 학습에 이용하였다.

본 논문에서는 그림 10과 같은 순서로 얼굴 인식 실험을 수행하였다. 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. 얼굴 영상의 각 눈의 가운데 두 점을 영상 내 지정위치에 오도록 2D 유사 변환을 수행하였다. 그 뒤 배경의 영향을 없애기 위하여 윈도우 영역을 정의하여 얼굴을 잘라내었다. 영상을 축소하는 down sampling 과정에서 경계선들의 정보를 유지하기 위해 잘라낸 얼굴 영상에 번짐 효과(blurring)를 주고 64×64 픽셀 크기로 down sampling을 수행하였다. 마지막으로 영상을 gray level로 변환하였다.

전처리 이후의 영상은 PCA와 LDA 과정으로 학습된 basis를 이용하여 해당 얼굴 코딩으로 변환된다. 이 basis를 이용하여 코딩으로 변환하는 과정은 원래의 입력 공간의 subspace로 변환하는 과정으로 볼 수 있으며, 이것은 MHLA의 입력으로 사용되고, MHLA는 입력 얼굴 코딩을 학습된 얼굴 코딩들과 비교하여 가장 비슷한 얼굴을 찾아낸다.

4.3. 실험 결과

MHLA의 인식률 비교를 위하여, leaving one out 방법을 사용하였는데, leaving one out은 n 개의 표본이 있을 때, n-1 개의 표본으로 학습 하고 나머지 하나로 테스트하는 절차를 n번 반복하는 것으로써, 표본 내의 모든 케이스가 테스트에 사용되어 신뢰성 있는 결과를 획득할 수 있으나 연산 비용이 비싸다는 단점이 있다.

(1) CA3의 연상 메모리 성능 확인

해마에서 CA3영역의 연상 기억 성능을 평가하기 위해서 CMU AMP 데이터베이스 전체를 인식을 위한 training set으로 하여 실험을 하였다. 그림 11은 대표 얼굴의 Edge 영상이며, 그림 12에서 표정이 다른 얼굴 영상이 자기연상 수행 후에 대표 Edge영상으로 고쳐지는 것을 확인할 수 있다. 본 결과는 임의의 패턴이 CA3 연상과정으로 결과로 학습과정에 참여했던 패턴으로 연상이 정확히 되는 것을 보여준다.



그림 11. 각 얼굴의 고유 Edge 검출 영상

Fig. 11. Edge Detection Images of each face images.

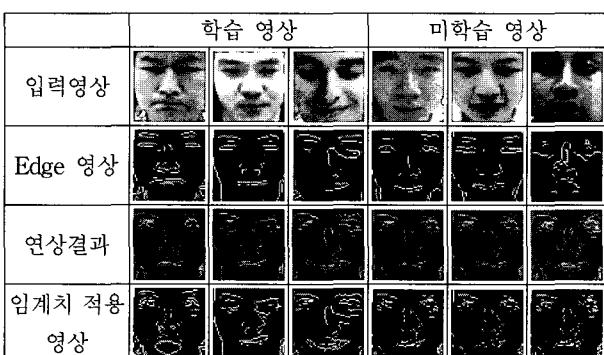


그림 12. 해마의 CA3의 연상기억모델 적용결과

Fig. 12. Result of Auto-associate of CA3 in Hippocampus.

(2) basis 개수 변화에 따른 실험 결과

PCA의 얼굴 인식 성능 분석을 위하여 ORL, CMU, DAUFace 데이터베이스를 이용하여, basis 수를 변화해가며 얼굴 인식 실험을 수행하였다. 본 실험은 PCA를 이용한 basis 수의 변화에 따른 인식 성능을 비교하여, 해당 기법의 최적의 basis 수를 찾는다. 32, 64, 96, 128 개로 basis 수를 변화해가며 유클라디안 방법으로 인식

표 1. Basis 수 변화에 따른 인식 결과(%)

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

Database basis 개수	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

률이 가장 우수한 것을 선택하도록 한다. 유클라디안 방법을 선택한 이유는 학습 알고리즘의 성능에 의존하지 않고 특징 벡터의 자체 분리도를 평가하기 위해서이다. 표 1을 보면 공통적으로 basis의 수가 32, 64, 128개 일 때 보다는 96개일 때 인식 성능이 더 좋은 것을 알 수 있다. 표 1을 보면 PCA는 자체만으로도 좋은 성능을 보이고 있지만, MHLA의 학습 성능을 평가하기 위하여 다른 학습 알고리즘과 비교를 통하여 성능을 평가하도록 한다. 학습 알고리즘의 입력으로써 basis를 최적의 개수인 96개로 정하도록 한다.

(3) 포즈변화에 따른 실험 결과

현재 SVM이나 HMM등과 같이 성능 좋은 분류기들을 응용한 연구들이 많지만, 이들 학습알고리즘 또한 영상전체를 입력 패턴으로 사용하진 않기 때문에, 계산된 입력 패턴이 주어져야 한다. 100% 분별력이 있는 패턴이 존재한다면 학습이 필요한 분류기 또한 필요하지 않겠지만, 현실에서는 그렇지 못하므로, 학습 알고리즘이 꾸준히 연구되어 오고 있으며, 그와 동시에 분별력이 우수한 특징패턴을 구성하는 것이 중요하다고 할 수 있다.

포즈변화에 따른 얼굴 인식 성능을 비교하기 위하여 ORL 데이터베이스의 40명의 영상에서 각각 10가지의 포즈를 MHLA학습에 이용하고, 학습에 이용하지 않은 나머지 1개의 영상들로 인식 성능을 측정하였다.

표 3에서 사람 수 옆의 숫자 1~5는 해당 번째까지 정답을 맞힌 것을 의미한다. 즉, 첫 번째 답까지를 정답으로 보았을 때의 인식률이 숫자 1에 해당하는 것이고,

표 2. 학습 알고리즘에 따른 포즈 인식률 비교(%)

Table 2. Comparisons of pose recognition rates with learning algorithms(%).

학습방법 특징계산법	Nearest Neighbor	BP	SVM	HMM	MHLA
PCA	91.34	93.21	93.88	94.21	97.94

표 3. 포즈변화에 따른 알고리즘별 얼굴 인식 실험 결과(%)

Table 3. The simulation result of facial recognition with pose change.

인식순위	Nearest Neighbor	BP	SVM	HMM	MHLA
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

n 번째 답까지를 정답으로 보았을 때의 인식률이 숫자 n에 해당한다. 이때의 실험 결과는 표 4와 같다.

표 3의 경우를 보면 MHLA에서 97.94%의 인식률을 보이고 있고, 나머지 학습 방법들도 91%이상의 높은 인식률을 보이고 있다. 3번째 답까지를 포함한 인식에서는 모든 경우에서 MHLA는 100%의 인식률을 보이고 있다. 5번째 답까지를 포함한 인식에서는 SVM과 HMM이 100%의 높은 인식 성능을 보이고 있음을 알 수 있다.

(4) 표정변화에 따른 실험 결과

표정변화에 따른 얼굴 인식 성능을 비교하기 위하여 CMU 데이터베이스의 13명의 영상에서 각각 50가지의 포즈를 MHLA학습에 이용하고, 학습에 이용하지 않은 나머지 영상들로 인식 성능을 측정하였다. 그 결과는 표 4와 같다.

표 4. 학습 알고리즘과 인식률 비교(%)

Table 4. Comparisons of recognition rates with learning algorithms(%).

학습방법 특징계산방법	Nearest Neighbor	BP	SVM	HMM	MHLA
PCA	93.55	95.36	96.45	96.12	99.10

표 5. 학습 알고리즘에 따른 표정 인식률 비교(%)

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

인식순위	Nearest Neighbor	BP	SVM	HMM	MHLA
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

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

표 5의 경우를 보면 MHLA에서 99.10%의 인식률을 보이고 있고, 나머지 학습 방법들도 93.55%이상의 높은 인식률을 보이고 있다.

(5) 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 비슷한 표정으로 약간의 포즈 변화를 주도록 하였다. 인식 결과는 표 6과 같다.

표 6의 결과를 보면 실시간 시스템의 적용에 학습 속도가 빠르고, 인식률이 우수한 MHLA를 적용할 경우 효과가 좋을 것으로 판단된다.

표 6. DAUFace 데이터베이스를 이용한 알고리즘별 얼굴 인식 실험 결과(%)

Table 6. The simulation result of facial recognition using DAUFace database.

학습방법 특징계산법	Nearest Neighbor	BP	SVM	HMM	MHLA
PCA	90.84	92.20	92.11	94.34	96.53

V. 결 론

PCA는 드문 코딩에 의하여 인식에 있어 필요한 중복 신호 제거 효과를 갖기 때문에 얼굴 영상의 특징 벡터로써 많이 연구되어 왔다. 본 논문에서는 PCA 방법을 이용하여 특징 값을 계산하고, MHLA를 모델링을 제안한 후 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 MHLA가 97% 이상의 인식 성능을 나타내는 등, 소규

모 인식에서 다른 학습 방법보다 높은 인식 성능을 보였다. 그리고 3~5 번 째 답까지를 포함한 인식에서 MHLA 가 다른 학습 방법보다 높은 인식률을 얻는 현상이 발견되었고, 이러한 점으로 인하여 MHLA가 우수하다라는 결론을 얻을 수 있었다.

본 논문에서 강조하고 싶은 내용은 얼굴 영상의 인식을 위한 특별한 시스템에 관한 설계방향이다. 기존의 시스템의 경우 조명의 변화나 얼굴의 가려짐, 그리고 표정 변화를 갖는 얼굴 영상을 인식하기 위해서 PCA, ICA, LDA등을 개별적으로 적용하였기 때문에 우수한 인식률을 기대하기 어려웠다. 본 논문에서는 정규화된 영상에 PCA를 이용하여 차원을 축소한 후 MHLA를 사용하여 학습한 후 인식을 가능하게 하였으며, 분석된 결과를 종합해 볼 때, 얼굴 인식에 있어서 PCA를 이용한 인식 방법에 있어서도 단순한 벡터 거리 비교 방법보다는 학습 알고리즘을 이용하였을 때, 인식 속도나 성능 면에서 우수하다고 할 수 있겠다. 또한 제안 시스템의 인식 성능을 비교하기 위하여 자체 제작한 DAUFace 데이터베이스와 얼굴인식과 검증에 보편적으로 사용되는 ORL 데이터베이스 그리고 CMU AMP 데이터베이스를 이용하여 실험하였다.

참 고 문 헌

- [1] Dayan, P. and Abbott, L.F., "Theoretical Neuroscience", MIT press, 2001.
- [2] Ventruglia, F. and Maio, V.D., "Synaptic fusion pore structure and AMPA receptor activation according to Brownian simulation of glutamate diffusion", Biological Cybernetics, Vol. 88, No. 3, 2003.
- [3] Wickelgren, W.A. "Webs, cell assemblies, and chunking in neural nets", Concepts Neurosci., Vol. 5, 1-53, 1992.
- [4] M. Witter and H. Groenewegen, "A new look at the hippocampal connectional network", in European Neuroscience Association, 1988.
- [5] 이케가야 유지, 이토이 시게사토, "해마", 은행나무, 2003.
- [6] Scoville WB, Milner B (1957) "Loss of recent memory after bilateral hippocampal lesions", J Neurol Neurosurg Psychiatry 20: 11-21.
- [7] Levitan, I. B. and Abbot, L. F., "Theoretical Neuroscience", MIT press, 2001.
- [8] Ventruglia, F. and Mario, B. D., "Stochastic fluctuations of the synaptic function, BioSystems", Vol. 67, pp. 287-294, 2002.

- [9] Witter M.P., Groenewegen H.J., Lopes de Silva F. H., Lohman A. H. M.(1989) "Functional organization of the extrinsic and intrinsic circuitry of the parahippocampal region", Prog Neurobiol 33: 161-253.
- [10] Qin YL, McNaughton BL, Skaggs WE., Barnes CA(1997) "Memory reprocessing in corticocortical and hippocampocortical neuronal ensembles", Phil Trans R Soc Lond B Biol Sci 352: 1525-1533.
- [11] McClelland, J., McNaughton, B., O'Reilly, R. "Why there are complementary learning systems in the hippocampus and neocortex", CMU Tech Report PDP.CNS. 94.1, March 1994.
- [12] Homepage of the AT&T Laboratories at Cambridge : <http://www.uk.research.att.com/facedatabase.html/>
- [13] Homepage of the Advanced Multimedia Processing Lab in the Carnegie Mellon University : <http://amp.ece.cmu.edu/>

저 자 소 개



오 선 운(정회원)
2004년 동명정보대학교
컴퓨터공학과 학사 졸업.
2006년 동아대학교
전자공학과 석사 졸업.
<주관심분야 : 영상처리, 패턴인식, 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>