

가중치 모듈레이터를 이용한 인공 해마 알고리즘 구현

Implementation of Artificial Hippocampus Algorithm Using Weight Modulator

추정호, 강대성*
(Jung-Ho Chu and Dae-Seong Kang)

Abstract : In this paper, we propose the development of Artificial Hippocampus Algorithm(AHA) which remodels 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 4 steps system (EC, DG, CA3, and CA1) and improve speed of learning by addition of modulator to long-term memory learning. In hippocampus system, according to the 3 steps order, information applies statistical deviation on Dentate Gyrus region and is labeled 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 a by neural network which is applied modulator. To measure performance of Artificial Hippocampus Algorithm, PCA(Principal Component Analysis) and LDA(Linear Discriminants Analysis) are applied to face images which are classified by pose, expression and picture quality. Next, we calculate feature vectors and learn by AHA. 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, Artificial Hippocampus Algorithm(AHA), PCA, LDA

I. 서론

인간의 뇌에 있는 해마(hippocampus)는 측두부 안쪽에 있는 측뇌실(lateral ventricle)의 하면을 따라서 달려있는 대뇌피질의 부분이다. 바닷속 생물인 해마(sea horse)와 유사한 형태여서 이름이 해마로 명명되었다. 구조학적으로 뇌속의 해마는 4개의 영역(dentate gyrus, hippocampus proper, subiculum, entorhinal cortex)으로 나뉘어 진다. 그 4가지 영역 비교적 단순한 층 구조(lamellar structure)와 흥분성 경로로 연결되어 있다.

전체적인 뇌의 기능에 있어서 설치류와 인간의 뇌 속 해마의 역할과 시스템은 넓게 과거 수십 년 동안 연구되었다. 쥐의 해마에서 장소 세포들의 발견 이후로 공간적 관점에 강하게 관련 있는 반면에, 원숭이와 인간에 있어서는 해마는 주로 에피소드식 기억에 관련이 있다. 1971년 초반에, Marr는 기억 강화에서의 해마의 결정적인 역할에 대한 이론을 제안했다. 그는 해마 시스템이 경험을 저장하고 분류화가 수행되는 신피질로 재 수행하는 것을 제안했다. 이 영역에서 많은 차이점에도 불구하고, 해마가 신피질의 교사라는 생각이 많은 연구가들에 의해서 널리 채택되어 왔다. 최근의 신경생물학 모델들은 인간의 뇌에서 신피질의 표현의 구성에서 해마의 역할을 중요시 하고 있다[1].

그리고 Scoville 및 Milner이 측두부 손상에 의한 기억 장애를 발견하고 보고한 다음부터 많은 연구의 결과보고에서 해마가 학습과 기억의 형성에 아주 필수적인 역할을 하고 있다는 것이 밝혀졌다. 또한 Bliss 및 Lomo가 해마에서 장기강화(long-term potentiation)를 관찰하여 발표한 이후 많은 연구에서 해마는 가소성(plasticity)이 가장 잘 일어나는 부분임이 밝혀졌

* 책임저자(Corresponding Author)

논문접수 : 2007. 1. 10., 채택학정 : 2007. 2. 17.

추정호, 강대성 : 동아대학교 전자공학과

(hardsteel@naver.com/dskang@dau.ac.kr)

※ 본 연구는 2006학년도 동아대학교 학술연구비(공모과제)에 의하여 연구되었음.

다. 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.

기존의 neural network는 오랜 기간 학습을 통해 훈련된 신경망에서, 패턴이 입력되었을 때 학습된 패턴과 비교하여 가장 근사한 학습 패턴을 찾는다. 이때 찾은 학습 패턴과 입력 패턴과의 차이가 기준치를 만족하는 경우 입력된 패턴을 인식하게 된다. 예를 들어, 사람이 처음 엄마라고 인식하는 것은 엄마의 얼굴, 음성, 체온, 느낌 등 수많은 정보를 통해 태어나자 마자 식별하게 되지만, 이들의 특징들과 “엄마”라는 단어와 조합되며 까지는 수많은 훈련 과정이 필요하다. 엄마에 관련된 정보를 아이에게 보여주며, “엄마”라고 오랜 기간 학습을 시켰을 때 엄마를 보고 인식하여 아이의 입에서 “엄마”라고 내뱉게 된다. 이렇게 공학적인 부분에서 많이 응용되고 있는 neural network는 뇌의 학습과 기억의 모태로 다양한 분야에 응용되고 있다[3].

본 논문에서는 인간의 뇌 속에 있는 해마를 뉴럴 네트워크에 적용하여 보다 빠르게 학습을 수행 할 수 있는 알고리즘을 제안한다. 인공 해마 알고리즘의 성능을 측정하기 위해 포즈 및 표정과 화질 상태에 따라 분류된 얼굴 영상에 PCA와 LDA를 혼합 적용하여 특징 벡터를 계산한 후 인공 해마 알고리즘으로 학습 시킨 후, 인식률을 확인하였다.

II. 생물학적인 해마

인간의 뇌에 있는 해마(hippocampus)는 측두부 안쪽에 위치하여 있다. 그리고 측뇌실(lateral ventricle)의 하면을 따라서 달려있는 대뇌피질의 부분이다. 그림 1은 인간의 뇌이고, 그 중 해마부분을 표시한 것이다.

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

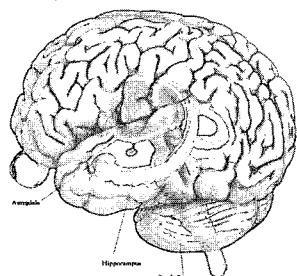


그림 1. 뇌 속 해마의 위치.

Fig. 1. Hippocampus position in brain.

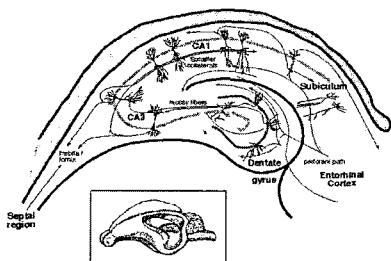


그림 2. 뇌 속 해마의 구조.

Fig. 2. Structure of hippocampus in brain.

수 있도록 제공한다. 그림 2를 보면 이 내후뇌피질은 관통 경로(perforant path)를 통해 치아이랑(dentate gyrus)의 과립 세포(granule cell)들로 정보를 전달한다. (이 과립 세포들의 줄기살들을 ‘이끼(mossy) 섬유’라고 한다.) 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(shaffer) 곁가지 경로’라고 함), 다른 하나는 해마체를 떠난다. 미침내, CA1 피라미드 세포들의 줄기살들은 내후각뇌 피질로 재 투사되는 해마이행체(subicular complex)로 연결되고, 치아이랑을 제외한 해마 구조의 모든 뉴런들은 대뇌 피질의 다른 지역으로 줄기살들을 보낸다. 따라서, 해마 구조는 뇌 전 영역의 기억 기능을 제어하기에 좋은 형태를 이루고 있다.

III. 생물학적인 해마의 뉴럴 네트워크화

1. 해마의 기본구조 뉴럴 네트워크화

해마에서 중요시 하는 연관된 4단계 조직은 entorhinal cortex(내후각뇌피질), dentate gyrus(치아이랑), CA3, CA1이다. 이들 영역들 간은 비교적 단순한 흥분성 경로로 연결되어 있고 해마의 가장 중요한 기능은 단기 기억으로 저장된 것을 장기 기억으로 전환하는 것이다. 해마는 방금 저장된 정보를 기억하고 자주 나오거나 유용하고 필요한 정보와 그렇지 못한 정보를 분류한다. 필요한 정보의 경우, 해당 뉴런에 저장이 되고 나중에 동일한 패턴이 입력되면 인식하게 한다. 단기 기억과 장기 기억으로 나누는 방법에 있어서 호감도 측정은 통계적으로 많이 나타나는 값들에 대해서 호감도를 높게 부여하는 것이다. 이러한 특징을 뉴럴 네트워크화시키면, 입력되는 중간에 입력받는 값들의

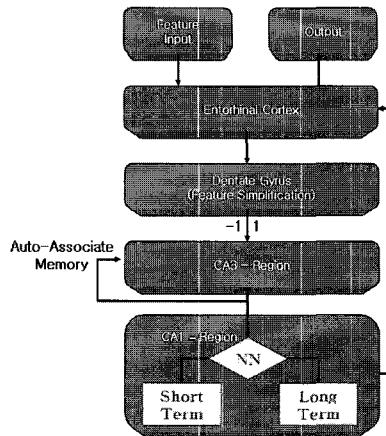


그림 3. 인공 해마 알고리즘의 정보처리.

Fig. 3. Data process of AHA.

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 해당 뉴런의 누적 개수가 문턱치를 만족하면 장기 기억 장소로 저장시키도록 한다[4].

기본적인 4개의 영역을 뉴럴 네트워크화로 모델링 하는 기본구조에 대해서 알아보겠다. 내후각뇌피질(entorhinal cortex)은 간단히 말하면 입력과 출력을 담당하는 부분으로 모델링 한다. 즉, 해마와 신피질 사이에서 인터페이스를 구성하고 인공 해마 알고리즘에서 입력과 출력을 담당하게 한다. 그리고 내후각뇌피질에 직접 연결되는 치아이랑(dentate gyrus) 구조는 입력되는 특징 정보들의 동일한 객체의 다양한 특징 성분들을 과거 입력 패턴에서 동일성을 판단하여 특징을 단순화 시킨다. 특징을 단순화 시킬 때 각각의 패턴들의 평균값에서 편차율 범위의 임계수치를 넘으면 1, 그렇지 않으면 -1로 하여 특징의 동일성을 이진화 시킨다. 이렇게 함으로서 CA3에서 행하게 될 순환 연상 메모리의 전처리 과정을 수행하게 된다. 이렇게 1, -1로 이진화 된 정보는 CA3로 넘어가게 된다. CA3에서는 인간의 뇌에서의 연상작용을 모델링하여 만들어진 순환 연상 메모리를 수행하게 된다. 인간은 어떤 사건을 기억하고 회상할 때 연상작용을 반복하면서 점점 그 기억을 뚜렷하게 하여 다시 떠오르게 만든다. 이처럼 CA3에서는 순환연상 메모리를 구현하기 위하여 Hopfield 모델을 적용한다.

CA3영역은 치아이랑과 연결되고, 치아이랑으로부터 이진정보들을 받아서 자기 연상을 하게 된다. 그렇게 함으로서 입력 패턴 속에 섞여있는 잡음을 분별력 있게 정한다. CA1영역은 CA3영역에 연결되고 정보 처리의 최종 단계를 처리하게 된다. 자기 연상되어 분별력이 강화된 정보 중에서 빈도수가 높은 패턴을 모듈레이터가 추가된 신경망에 학습시켜 장기 기억을 학습한다. 모듈레이터에 대해서는 다음 3.2절에서 자세히 알아보겠다. 학습된 연결 가중치에 반응하여 출력 값이 맞지 않는 경우는 단기기억으로 패턴을 분류하여 새로 저장하는 기능을 한다. 위와 같은 인공 해마 알고리즘의 기본적인 뉴럴 네트워크화 알고리즘을 그림 3로 구도화 해보았다.

2. 가중치 모듈레이터

해마의 가장 중요한 역할 중 하나인 단기기억을 장기기억

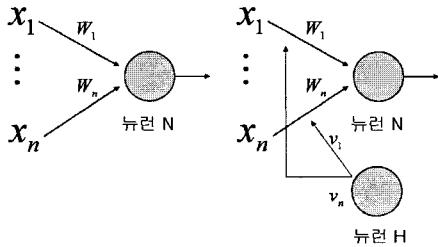


그림 4. 일반적인 뉴런연결과 모듈레이터가 첨가된 뉴런연결.
Fig. 4. General neuron connectivity and added modulator neuron connectivity.

Step 1: Compute weights to store P patterns

$$W = \sum_{i=1}^P S^T(i)S(i) - PI$$

Step 2: Determine update order

Step 3: Set initial output $y_i \leftarrow x_i$

Step 4: For each unit y_i

do Step 4-1 ~ 4-3

Step 4-1: Compute $NET_i = x_i + YW_i^T$

Step 4-2: Update intermediate output

$$y_i = \begin{cases} 1 & ; NET_i > 0 \\ y_i & ; NET_i = 0 \\ 0 & ; NET_i < 0 \end{cases}$$

Step 4-3: Test condition for goto Step 5

If y is converged, goto Step 5

else, change i according to predetermined or der and goto Step 4

Step 5: Initialize weights and counter

$w \leftarrow 0$ or small random, $k \leftarrow 1$

$p \leftarrow$ number of training pattern pairs

Step 6: Set learning rate α ($0 < \alpha \leq 1$) and β

Step 7: For each training pattern pair (X, d),
do Step 7-1 ~ 7-4 until $k=p$

Step 7-1: Compare output $NET = XW^T$

$$y = f(NET) = \begin{cases} +1 & ; NET > T \\ 0 & ; NET = T \\ -1 & ; NET < T \end{cases}$$

Step 7-2: Compare output and desired output

If $y=d$, $k \leftarrow k+1$ and goto Step 7

Step 7-3: Update weights

Compare ΔW^{k-1} and ΔW^k

If $\Delta W^{k-1} \leq 2\Delta W^k$

$$\text{Then, } \Delta W^k \leftarrow \alpha(d_k - y_k)X_k + \beta\Delta W^{k-1}$$

$$W \leftarrow W + \Delta W$$

$$\text{else } \Delta W^k \leftarrow \alpha(d_k - y_k)X_k$$

$$W \leftarrow W + \Delta W$$

Step 7-4: Increase counter and goto step 7 and $k \leftarrow k+1$

Step 8: Test stop condition

If no weights changed in Step 7-1~7-4, stop

else, $k \leftarrow 1$ and goto Step 7

그림 5. 인공 해마 알고리즘 pseudo code.

Fig. 5. Pseudo code for AHA.

으로 확장을 뉴럴 네트워크화 하기 위하여 중요하거나 반복되는 특징에 대하여 가중치를 부과함으로서 인식률을 높이고 적응적으로 확장 가능한 알고리즘을 제안한다.

그림 4는 일반적으로 사용하고 있는 뉴런의 연결과 모듈레이터가 첨가된 뉴런의 연결을 비교한 것이다. 이처럼 일반적인 연결강도에 가중치를 부과하는 형식이다. 간단히 설명하면 뉴런 H가 활성화 되면 입력에서 뉴런 N으로 가는 연결강도에 억제성이나 흥분성 가중치가 부과되고 뉴런 H가 비활성화 되면 가중치가 부과되지 않다.

뉴런 H의 활성화 비활성화 조건은 이전의 연결강도의 변화량과 현재의 연결강도 변화량을 비교하여 알 수 있다. 식2에서 말하는 것과 같이 이전의 연결강도 변화량이 현재의 연결강도 변화량의 두배 보다 작으면 활성화 되고 크면 활성화 되지 않는다. 단 연결강도의 변화량이 같은 부호일 때만 활성화되고, 다른 부호일 경우 모두 비활성화 된다.

$$\begin{aligned} |\Delta W^{k-1}| &\leq 2|\Delta W^k| : \text{뉴런 } H \text{ 활성화} \\ |\Delta W^{k-1}| &> 2|\Delta W^k| : \text{뉴런 } H \text{ 비활성화} \end{aligned} \quad (1)$$

활성화 되었을시 억제성과 흥분성 가중치의 조건은 이전의 연결강도가 음수이면 억제성 가중치가 부과되고, 양수이면 흥분성 가중치가 부과된다.

3. 전체적인 인공 해마 알고리즘 구현

3.1절과 3.2절에서 인공해마 알고리즘을 세부적으로 알아보았다. 본 절에서는 3.1절과 3.2절에서 알아본 인공 해마 알고리즘을 구현해 보겠다. 인공해마 알고리즘은 실수로 되어 있는 패턴의 평균을 구하고, 학습을 할 때 평균에서 각각의 패턴들의 편차를 계산해서 범위 안에 들어가면 1, 아니면 -1로 만든다. 이렇게 단순화 된 패턴을 그림 5의 pseudo code 순서로 학습시키는 알고리즘이다. 다시 정리하자면 패턴의 단순화(편차율 계산: 치아이랑), 패턴의 근접화(Hofiled 모델 학습: CA3), 인식률 향상(모듈레이터가 첨가된 퍼셉트론 학습: CA1)과 같은 순서로 수행한다. 인공 해마 알고리즘의 프로그램 구현은 VC++의 STL과 MFC를 사용하여 작성하였다.

IV. 특징 추출

사람의 뇌의 시냅스 수는 약 10^{14} 개이고, 사람의 일생은 대략 10^9 초이다. 만약 뇌의 학습이 교사 학습으로 이루어졌다면 초당 10bit 정도의 교사신호를 받아야 적어도 뇌가 동작할 수 있다고 말할 수 있다. 이는 실제로 불가능하며, 대부분의 뇌의 학습이 비교사 학습으로 이루어진다고 할 수 있다[6].

특히 시각계의 입력인 영상은 임의의 신호가 아니고, 제한된 복잡도 이내에서 처리 가능한 비교사 학습으로 구조화될 가능성이 높다. 사람의 시각 경로(visual pathway)에서 중복 신호 제거 기능을 갖고 있다는 연구가 발표되었으며, 중복 신호 제거 기능을 갖고 있는 비교사 학습으로서 PCA와 LDA는 얼굴 인식에 많이 쓰이고 있다[7].

LDA 변환은 각 집단의 특징을 정확히 분류해주는 특성을 가지고 있기 때문에, 얼굴 관련 연구 중 특히 인식 관련 연구에서 많이 사용되고 있다. 하지만, 학습 집합에 없는 테스트 표본, 학습 집합과 현저히 다른 테스트 표본, 학습 집합에 있

는 표본과 다른 배경을 가진 테스트 표본이 주어졌을 때에는 LDA 변환은 집단 내 데이터 분산을 나타내는 행렬이 항상 하나(singular)이기 때문에 기존의 방법론에서 직접 쓰일 수 없고, 또한 고차원의 영상벡터가 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[11-13].

본 논문에서도 얼굴 검출에 PCA 변환과 LDA 변환을 같이 사용하는 방법을 적용하였다. 이는 PCA 변환을 통해 학습 집단의 고차원 벡터의 데이터를 저차원 벡터의 형태로 변환해 주고, 이 변환을 통해서 생성된 주성분을 LDA 변환하여, 원하는 수의 집단을 만들어 준다.

c개의 클래스를 w_1, w_2, \dots, w_c , i번째 클래스에 속한 얼굴 영상의 개수를 n_i , PCA를 적용하기 전과 후의 i번째 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 (2)와 같다. 여기서 X_{ij} 와 Y_{ij} 는 W_{PCA}^T 에 의한 선형 변환 이전 및 이후의 i번째 클래스에 속한 j번째 얼굴 벡터를 나타낸다.

$$S_W = W_{PCA}^T S_W W_{PCA}, S_B = W_{PCA}^T S_B W_{PCA} \quad (2)$$

(3)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.

$$W_L = \arg \max_w \left(\frac{W^T S_B W}{W^T S_W W} \right) \quad (3)$$

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 인공 해마 알고리즘의 input data로 이용한다.

V. 실험 및 결과

1. 이미지 자료

본 논문에서 제안한 시스템의 인식 성능 비교를 위해 자체 제작한 DAUFace 데이터베이스는 그림 6과 같이 화상 통신용 저가의 CCD 카메라를 가지고 일정한 환경에서 다양한 포즈와 표정 변화로 촬영된 얼굴 영상이다. 각 얼굴 영상은 8-bit gray level의 64×64 크기로 되어있으며, 총 400개(20명 \times 20개)로 구성되어 있다.

표정변화 실험을 위하여 CMU AMP Face EXpression database 얼굴 DB를 사용하였다. Carnegie Mellon University의 advanced



그림 6. DAUFace database의 예.

Fig. 6. Some examples of DAUFace database.



그림 7. CMU AMP face EXpression database의 예.

Fig. 7. Some examples of CMU AMP face EXpression database.



그림 8. ORL database의 예.

Fig. 8. Some examples of ORL database.

Multimedia Processing Lab[14]에서 만든 얼굴 DB로 동일한 조명조건에서 정면얼굴의 다양한 표정을 지원한다. 본 논문에서는 CMU 얼굴 DB에서 정면 얼굴 영상을 사용하였고, 13명의 얼굴마다 각각 75가지의 표정변화들이 존재한다. 그림 7은 CMU 얼굴 DB의 일부 얼굴 영상의 일부를 보여준다.

ORL 데이터베이스[15]는 Cambridge의 Olivetti Research Laboratory에서 1992년 4월부터 1994년 4월까지 획득한 얼굴 영상들이다. 40명에 대하여 일정한 어두운 배경에서 얼굴 표정과 안경 착용 유무에 따라 각 10장씩 구성되어 있다. 안경·수염 등이 있는 얼굴들이 많이 분포 되어 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.

2. 실험수행 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 속하는 가를 결정하며 이것이 바로 얼굴 인식 시스템의 출력이 된다. 얼굴을 분류하는 방법은 euclidean 거리 측정에 의한 특징 벡터의 거리를 측정하는 nearest neighbor 방법으로 구하거나, BP, SVM 등 각종 신경망과 HMM 같은 분류기를 이용하여 구할 수 있다. 그러므로 본 논문의 실험에서는 인공 해마 알고리즘의 성능을 평가하기 위하여 주로 위와 같은 학습 방법들과 인공 해마 알고리즘을 비교하는 방식으로 수행하였다.

본 논문에서 사용한 시스템은 워크스테이션 HP xw8000 dual 2 GHz Xeon이고, 1GB 시스템메모리, Windows XP Professional with Service Pack 2이다. 그리고 α , β 는 각각 0.1이다.

5.1절에서 소개한 face image database들을 사용하여 인공 해마 알고리즘의 학습 모델의 얼굴 인식 실험을 수행하였는데, 크게 세 개의 그룹으로 나누어 얼굴 인식 실험을 수행하였다.

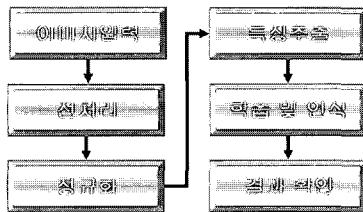


그림 9. 인공 해마 알고리즘을 이용한 얼굴인식 실험 순서도.
Fig. 9. Flow chart of the facial recognition experiment using AHA.

첫 번째 실험은 자체 제작한 DAUFace 데이터베이스를 이용하여 얼굴 영상의 인식성능을 측정하였다. DAUFace 데이터베이스 중에서 15개를 학습에 이용하였다. 두 번째 실험은 표정변화에 따른 얼굴 인식 실험이다. CMU AMP 데이터베이스의 영상을 사용하여 13명의 얼굴 영상에 대해 75가지의 표정들 중에서 50가지의 표정들을 변화해가며 알고리즘별로 얼굴 인식 성능을 측정하였다. 세 번째는 얼굴의 포즈에 따른 얼굴 인식 실험이다. 본 실험에서는 40명의 얼굴 영상에 대해 7가지의 포즈를 변화해가며 알고리즘별로 얼굴 인식 성능을 측정하였다. 이때 인공 해마 알고리즘을 학습하기 위한 모델 집합은 ORL 데이터베이스를 사용하였다.

본 논문에서는 그림 9과 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 64x64 픽셀 크기로 down sampling을 수행하였다. 마지막으로 영상을 gray level로 변환하였다.

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

3. 실험 결과

인공 해마 알고리즘의 인식률을 비교를 위하여, leaving one out 방법을 사용하였다.

3.1 포즈변화에 따른 실험 결과

포즈변화에 따른 얼굴 인식 성능을 비교하기 위하여 ORL 데이터베이스의 40명의 영상에서 각각 10가지의 포즈를 인공 해마 알고리즘의 학습에 이용하고, 나머지 1개의 영상들로 인식 성능을 측정하였다. 이때 실험 결과는 표 1과 같다.

표 2에서 사람 수 옆의 숫자 1~5는 해당 번째까지 정답을 맞힌 것을 의미한다. 즉, 첫 번째 답까지를 정답으로 보았을 때의 인식률이 숫자 1에 해당하는 것이고, n번째 답까지를 정답으로 보았을 때의 인식률이 숫자 n에 해당한다. 이때의 실험 결과는 표 2와 같다.

표 1. 학습 알고리즘에 따른 포즈 인식률 비교(%).

Table 1. Comparisons of pose recognition rates with learning algorithms(%).

	Nearest Neighbor	BP	SVM	HMM	AHA
PCA	87.25	90.25	90.75	92.25	92.5
LDA	89.00	90.75	91.75	92.25	93.25
PCA + LDA	91.25	93.25	94.00	94.25	97.75

표 2. 포즈변화에 따른 알고리즘별 얼굴 인식 실험 결과(%).

Table 2. The simulation result of facial recognition with pose change(%).

	Nearest Neighbor	BP	SVM	HMM	AHA
1	91.25	93.25	94.00	94.25	97.75
2	94.00	95.50	98.75	96.25	98.50
3	96.25	97.25	99.25	97.25	100.00
4	96.25	97.75	99.75	98.75	100.00
5	97.25	98.25	100.00	100.00	100.00

표 3. 학습 알고리즘과 인식률 비교(%).

Table 3. Comparisons of recognition rates with learning algorithms(%).

	Nearest Neighbor	BP	SVM	HMM	AHA
PCA	89.00	92.56	92.68	92.63	92.42
LDA	91.04	93.65	93.85	94.25	95.03
PCA + LDA	93.55	95.36	96.45	96.12	99.10

표 4. 학습 알고리즘에 따른 표정 인식률 비교(%).

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

	Nearest Neighbor	BP	SVM	HMM	AHA
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 2의 경우를 보면 인공 해마 알고리즘에서 97.75%의 인식률을 보이고 있고, 나머지 학습 방법들도 91% 이상의 높은 인식률을 보이고 있다. 3번째 답까지를 포함한 인식에서는 모든 경우에서 인공 해마 알고리즘은 100%의 인식률을 보이고 있다. 5번째 답까지를 포함한 인식에서는 SVM과 HMM이 100%의 높은 인식 성능을 보이고 있음을 알 수 있다.

3.2 표정변화에 따른 실험 결과

표정변화에 따른 얼굴인식 성능을 비교하기 위하여 CMU 데이터베이스의 13명의 영상에서 각각 50가지의 포즈를 인공 해마 알고리즘의 학습에 이용하고, 학습에 이용하지 않은 나머지 영상들로 인식 성능을 측정하였다. 그 결과는 표 3과 같다.

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

표 4의 경우를 보면 인공 해마 알고리즘에서 99.10%의 인

표 5. DAUFace를 이용한 알고리즘별 얼굴인식 실험 결과 (%)。

Table 5. The simulation result of facial recognition using DAU Face(%).

	Nearest Neighbor	BP	SVM	HMM	AHA
PCA	86.75	88.25	89.5	90.00	92.25
LDA	88.25	89.75	90.75	91.25	93.25
PCA + LDA	90.75	92.25	92.25	94.25	96.50

식률을 보이고 있고, 나머지 학습 방법들도 93.55% 이상의 높은 인식률을 보이고 있다.

3.3 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 5와 같다.

표 5의 결과를 보면 실시간 시스템의 적용에 학습 속도가 빠르고, 인식률이 우수한 인공 해마 알고리즘을 적용할 경우 효과가 좋을 것으로 판단된다.

VI. 결론

PCA는 드문 코딩에 의하여 인식에 있어 필요한 중복 신호 제거 효과를 갖기 때문에 얼굴 영상의 특징 벡터로써 많이 연구되어 왔다. 본 논문에서는 PCA 방법과 LDA방법을 혼용해서 특징 값을 계산하고, 인공 해마 알고리즘을 제안한 후 얼굴 인식 실험을 수행하여 인식 특징 및 성능을 분석하였고, 다른 학습 방법들과의 비교 실험을 통하여 보다 면밀한 분석을 수행하였다. 얼굴 인식 실험을 통하여 학습방법들을 비교했을 때, 포즈와 표정에 따른 얼굴 인식 실험에서 인공 해마 알고리즘이 97% 이상의 인식 성능을 나타내는 등, 소규모 인식에서 다른 학습 방법보다 높은 인식 성능을 보였다. 그리고 3~5번짜리 딥까지를 포함한 인식에서 인공 해마 알고리즘이 다른 학습 방법보다 높은 인식률을 얻는 현상이 발견되었고, 이러한 점으로 인하여 인공 해마 알고리즘이 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.



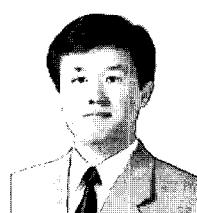
추 정 호

2006년 동아대학교 전자공학과(공학사).
2006년~현재 동아대학교 대학원 전자공학과 석사과정 재학중. 관심분야는 영상 처리, 패턴인식, 신호처리.

본 논문에서는 정규화된 영상에 PCA를 이용하여 차원을 축소한 후 LDA로 차원을 효과적으로 분류하였다. 그리고 인공 해마 알고리즘을 사용하여 학습한 후 인식을 가능하게 하였으며, 분석된 결과를 종합해 볼 때, 얼굴 인식에 있어서 PCA를 이용한 인식 방법에 있어서도 단순한 벡터 거리 비교 방법 보다는 학습 알고리즘을 이용하였을 때, 인식 속도나 성능 면에서 우수하다고 할 수 있겠다.

참고문헌

- [1] P. Dayan and L. F. Abbott, "Theoretical neuroscience," MIT press, 2001.
- [2] 민병경, "민병경의 재미있는 뇌 과학 이야기," <http://mind21.net/scienceall-7.htm>.
- [3] 이케가야 유지, 이토이 시게사토, "해마," 은행나무, 2003.
- [4] I. B. Levitan and L. F. Abbot, "Theoretical neuroscience," MIT press, 2001.
- [5] 오창석, 뉴로 컴퓨터 개론, 내하출판사], pp. 234-266, 2000.
- [6] G E. Hinton and Sejnowski, T. J. Edited, "Unsupervised learning: foundations of neural computation," MIT Press, Cambridge, Massachusetts, 1999.
- [7] 김우성, 박현진, 양현승, "비교사 학습을 이용한 얼굴 인식 모델의 실험 및 분석," 한국 과학재단, Tech Report 2002-76, 2002.
- [8] http://www.isip.msstate.edu/publications/reports/isip_internal/1998/linear_discrim_analysis/lde_theory.pdf
- [9] M.-H. Yang, "Kernel Eigenfaces vs. Kernel Fisherfaces: Face recognition using kernel methods," Automatic Face and Gesture Recognition, 2002. Proceedings. Fourth IEEE International Conference on, pp. 208-213, 2002.
- [10] A. Martinez and A. Kak: "PCA versus LDA," IEEE Trans. on PAMI, 23(2): 228-233, 2001.
- [11] D. W. Zhao, R. Chellappa, "Discriminant analysis of principal components for face recognition," Automatic Face and Gesture Recognition, 1998.
- [12] D. J. R. Beveridge and K. She, "Fall 2001 update to CSU PCAVersus PCA+ LDA comparison," <http://www.cs.colostate.edu/evalfacerec/papers.html>, 2001.
- [13] J. Yang and J.-Y. Yang, "Why can LDA be performed in PCA transformed space?", Pattern Recognition 36, pp. 563-566, 2003.
- [14] 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.
- [15] Homepage of the AT&T Laboratories at Cambridge: <http://www.uk.research.att.com/facedatabase.html/>



강 대 성

1984년 경북대학교 전자공학과(공학사).
1991년 Texas A&M 대학교 전자공학과(공학석사). 1994년 Texas A&M 대학교 전자공학과 (공학박사). 1995년~현재 동아대학교 전자공학과 교수. 관심분야는 영상 처리, 비디오 색인 및 검색, 영상 압축.