

신경회로망과 기억이론에 기반한 한글영상 인식과 복원

장재혁*, 박중양**, 박재홍***

The Hangeul image's recognition and restoration based on Neural Network and Memory Theory

Jae-hyuk Jang *, Joong-Yang Park **, Jae-Heung Park ***

요 약

본 논문에서는 문자인식과 복원을 위한 신경회로망 시스템을 제안한다. 제안하는 시스템은 인식부와 연상부로 구성되었다. 인식부에서는 ART 신경회로망의 인식성을 개선하기 위해 불 필요한 하향틀의 생성과 변화를 제한하여 효과적인 패턴인식이 가능한 모델을 제안하였다. 또한, 한글의 구조적인 특징을 능동적으로 적용할 수 있게 구성된 위치특징 추출 알고리즘을 적용하였다. 연상부에서는 Hopfield 신경회로망으로, 입력된 이미지 패턴의 복원이 가능한 모델을 구성하였다. 제안하는 시스템은 그 성능을 확인하기 위해 각 부분별 실험을 하였다. 그 결과 인식율이 개선되고 복원이 가능함을 보였다.

Abstract

In this study, it proposes the neural network system for character recognition and restoration. Proposes system composed by recognition part and restoration part. In the recognition part, it proposes model of effective pattern recognition to improve ART Neural Network's performance by restricting the unnecessary top-down frame generation and transition. Also the location feature extraction algorithm which applies with Hangeul's structural feature can apply the recognition. In the restoration part, it composes model of inputted image's restoration by Hopfield neural network. We make part experiments to check system's performance. respectively. As a result of experiment, we see improve of recognition rate and possibility of restoration.

▶ Keyword : 신경회로망, 단기기억, 문자인식, 이미지 복원 (Neural Network, shortterm Memory, Character recognition, Image restoration.)

• 제1저자 : 장재혁

• 접수일 : 2005.06.23, 심사완료일 : 2005.07.30

* 경상대학교 컴퓨터과학과 박사과정, ** 경상대학교 통계정보학과 교수, *** 경상대학교 컴퓨터과학과 교수

I. 서 론

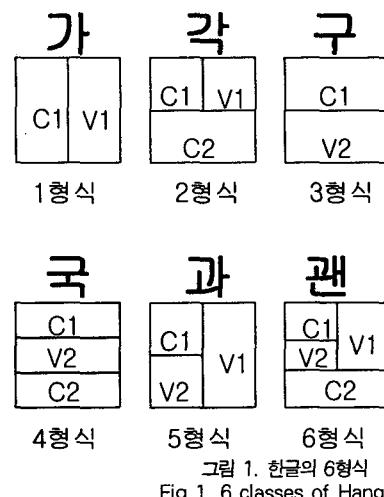
인간의 문자인식과 연상은 문자의 의미를 머릿속에 재구성하는 인지적인 과정이므로, 인식과 관련있는 변인들 중 사고능력으로서의 지능이 상당히 밀접한 상관을 가질 것임을 예상케 한다[15]. 단기기억은 인식 빌달을 유도하는 중요한 요인 중 하나로서 작동기억에 정보를 유지하기 위해 문자를 의미론적으로 재부호화 하는 능력을 말한다. 인식은 문자를 의미적으로 처리해야 하는 인지과정이기 때문에 단기기억은 인식에 많은 영향을 미친다. 특히 철자목록을 해독하고, 임시 기억소에 기본소를 저장하고, 임시 기억소에 저장된 기본소들을 단어로 결합하고 연상하는 과정이 중요 한데, 단기기억에 문제가 생기면 단어를 보았을 때 장기기억에서 인출된 단어들과 비교를 하는 동안 부분적으로 부호화된 단어들을 기억에서 유지하는데 어려움을 줄 수 있다 [16]. ART(Adaptive Resonance Theory) 신경회로망은 이미 배웠던 학습을 지우지 않으면서 새로운 학습을 할 수 있는 안정성과 적응성을 가진 신경회로망 모델이다[3]. 그러나, 학습 및 인식율의 개선을 위해서는 하향들의 변화를 제한할 수 있는 방법이 필요하다. Hopfield 신경회로망의 이산 모델과 연속 모델은 각종 최적화 문제의 응용에 훌륭하고 자극적인 영향을 주었다. 신경 연상 메모리에서는 패턴 짹을 학습함으로서 연상작용이 가능하다[12]. 연상 메모리는 자극패턴이 왜곡되었거나 불완전한 경우에도 연상작용을 이용하여 정확한 응답패턴을 생성할 수 있다. 제안된 시스템은 인간의 정보 인식과 연상 과정을 신경회로망에 응용하여, 패턴의 재 입력시 새로운 노드의 활성화를 방지하도록 한 인식부와 연상작용으로 패턴복원이 가능한 연상부로 구성하였다.

II. 한글구조의 특징

2.1 한글구조의 특징

한글의 6형식은 초성, 중성, 종성의 배치에 따라 분류되어 있다. 한글의 무게 중심은 모음, 즉 종모음과 횡모음에 분포되어 있는 것이 특징이다. 한글의 6형식 구조를 (그림 1)에 나타낸다. 한글은 6형식에 따라 자음과 모음의 위치가 정해진 글자이고 다음의 특징을 이용하여 인식에 적용할 수 있다.

- (1) 각 자소자들 중 수평 방향으로 횡모음이 가장 길다.
- (2) 3,4,5,6 형식 중 횡모음이 가장 왼쪽에서 시작한다.
- (3) 각 자소들 중 수직 방향으로 종모음이 가장 길다.
- (4) 1,2,5,6 형식 중 종모음이 가장 위쪽에서 시작한다.
- (5) 종성은 횡모음보다 왼쪽에 오지 않는다.



III. 인지이론

인간의 사물인지는 여러 단계를 거쳐 일어난다. 한 번의 학습과 습득으로 해당 사물에 대한 지식이나 정보가 인지되지는 것은 아니다. 학습을 통한 인식 후 기억(Memory)을 통하여 해당 사물에 대한 정확한 정보가 인지되어진다.

3.1 학습과 인식의 관계

인지이론에서 보면 학습과 인식은 서로 배타적인 것이 아니라 상호보완적인 것이다. 인식은 새로운 내용에 대한 학습을 통해 이전에 관련되지 않았던 뇌의 세포와 세포들 사이에 새로운 시냅스가 형성되며, 새로 형성된 시냅스는 많은 경우에 반복된 학습을 통해 더욱 강화되어 없어지지 않게 되는데 그 결과 새로운 인식이 생겨난다[10].

3.2 단기기억

기억은 저장되는 시간의 길이에 따라 감각기억(sensory memory), 단기기억(short-term memory: STM) 및 장기기억(long-term memory: LTM)으로 나누어 지며, 이 각각의 기억을 담당하는 뇌 부위는 서로 달리 존재하는 것으로 알려져 있다[1][2][17]. 본 논문에서는 ART 신경회로망의 증가분류 알고리즘 문제 극복에 유용한 것으로 가정된 단기기억을 살펴보며 그 내용은 다음과 같다. 단기기억은 뇌가 사고활동을 하는 동안의 내용으로서 약 30초 내지 수 분 동안 잊혀지지 않고 기억되는 것을 말한다. 단기기억에서 우리 뇌는 주어진 여러 환경 요소들을 최대한 파악하면서 최선의 결론을 내리고, 꼭 기억해야 할 것만 추후의 장기기억으로 넘겨 기억하는 일을 하게 된다. 단기기억 내용을 저장하고 활용하는 뇌의 부위로는 시상이나 변연계 부위, 대뇌피질에 있는 전두엽 영역등이 있으나, 이 경우 가장 핵심적인 역할을 하는 뇌 부위는 변연계를 구성하는 구조물 중의 하나인 해마(hippocampus)이다[5]. 이 해마에서 단기기억 내용을 운용하다가 필요한 경우 장기기억으로 전환시킨다. 많은 기억 대상들의 경우, 해마에서 장기기억으로 전환시키는데는 그 기억내용에 대한 반복적인 경험이 있어야 가능하다.

IV. ART 신경회로망

4.1 ART 신경회로망의 자율학습

ART 신경회로망은 뉴런들 간의 경쟁학습(competitive learning)에 의하여 자율적으로 패턴을 분류하는 네트워크 구조를 가진다. 클러스터에 대한 사전정보 없이 자율학습(unsupervised learning)에 의해 패턴을 분류하기 위하여 ART 신경회로망은 순차적 리더 알고리즘(sequential leader algorithm)과 유사한 형태로 동작한다[3][4]. 이 알고리즘은 첫 번째 입력패턴을 첫 번째 클러스터로 학습한다. 다음 패턴이 입력되면 첫 번째 클러스터와의 거리를 비교하여 사전에 주어진 임계 값보다 작으면 첫 번째 클러스터로 분류하고 그렇지 않으면 새로운 클러스터를 생성한다. 따라서 ART 신경회로망의 동작 알고리즘은 이러한 과정을 반복하여 자율적으로 입력패턴을 기준의 클러스터에 포함하거나 새로운 클러스터를 생성하는 과정을 반복한다.

4.2 ART 신경회로망의 문제점

ART 신경회로망은 증가분류 알고리즘을 사용하고 있다 [4][14]. 입력패턴이 변하는 경우 기억된 값은 항상 마지막으로 변형된 형태를 그 범주의 대표로 기억한다. 따라서 입력패턴이 감소하는 순서로 들어올 경우 가장 최근에 입력된 패턴이 기억되게 된다. 이럴 경우 그 전에 들어왔던 패턴이 다시 들어올 때에는 새로운 노드를 발생시킬 수 있다. 따라서 리셋트 횟수가 많아져 인식시간이 증가하게 되고, 새로운 패턴에 의한 부적절한 채코딩이 발생하게 된다. 또한 하나의 노드에 대한 하향틀의 변화가 자주 발생하게 되어 한번 학습한 패턴에 대한 새로운 노드의 활성화가 빈번하게 이루어져 부적절한 인식이 자주 발생한다[8]. 따라서 하향틀의 변화와 불 필요한 생성을 제한하면 학습 및 인식의 성능을 개선할 수 있다.

4.2.1 증가분류 알고리즘

입력패턴을

$$P_0 = 1111111111 \quad P_1 = 1111111110$$

$$P_2 = 1111111100 \quad P_3 = 1111111000$$

$$\begin{array}{ll} P_4 = 1111110000 & P_5 = 1111100000 \\ P_6 = 1111000000 & P_7 = 1110000000 \end{array}$$

라고 했을 때 $P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7$ 의 순서로 입력된다고 가정하자. 경계인수가 0.8일 때 P_0 가 입력되면 $|I|=10, |X|=10$ 이 되어 임의의 노드 R_j 에 기억된다. 그 후에 패턴 P_1 이 입력되면 전에 기억되었던 $|X|$ 는 없어버리게 되고 $|X|=9$ 가 되어 노드 R_j 로 학습되고, P_2 가 입력되면 $|X|=8$ 이 되어 역시 노드 R_j 가 활성화된다. 이렇게 반복하게 되면 패턴 P_6 에 이어 P_7 이 들어왔을 때 $|I|=3, |X|=3$ 이 되어 역시 리세트 시스템이 억제신호를 보내지 않게 된다. 따라서 노드 R_j 가 다시 활성화되어 패턴 P_7 을 기억하게 된다. 그 후에 학습했던 패턴 P_0 가 다시 입력되면 $|I|=10, |X|=3$ 이 되어 전에 학습되었던 노드 R_j 가 아닌 새로운 노드 R_k 로 학습된다. 따라서 패턴의 크기가 감소하는 순서로 입력될 경우, 한번의 입력에 가장 작은 패턴에 대한 학습이 완료된다. 최악의 경우에는 ART 신경회로망은 n 개의 입력패턴에 대해서 n 번 학습을 반복한 후에 학습이 종료된다. 이와 같은 문제점은 ART 신경회로망이 증가분류 알고리즘을 사용함으로 단순히 $(|X|/|I|) < \rho$ 가 되어 리세트 시스템이 동작을 하지 않고 계속적으로 하향틀의 변화가 일어나게 된다[8].

V. Hopfield 신경회로망

Hopfield 신경회로망은 심하게 손상된 패턴이 주어졌을 경우 이 패턴의 본래의 모습을 유추 할 수 있다. 상호 결합형 신경회로망인 Hopfield 신경회로망은 연상기억이나 최적화 문제를 푸는데 많이 사용된다.

51 학습

Hopfield 신경회로망의 학습에서 연결 하중 값은 패턴들에 따라 유일하게 결정된다(3). 하중 값은 식(1)과 같이 대

칭이며 식(2)와 같이 각 뉴런들 자신에 대한 연결선은 없다. 뉴런 i 에서 뉴런 j 로의 연결 하중을 W_{ij} 이라 하면

$$W_{ii} = 0 \quad \dots \quad (8)$$

(A_1, A_2, \dots, A_m) 과 같이 m 개의 패턴이 있다고 하면, 패턴 P 는 $A_P = (ap_1, ap_2, \dots, ap_m)$ 과 같이 표현되며 여기서 ap_i 는 p 번째 훈련벡터(training vector)의 i 번째 요소이다. 그러면 Hopfield 신경회로망에서 i 번째와 j 번째 뉴런간의 하중값은

$$W_{ij} = \sum_{p=1}^m (2a_{pi}-1)(2a_{pj}-1) \quad \dots \dots \dots \quad (3)$$

이다. 여기서 합(Σ)은 저장되는 모든 패턴들에 대해서 취해지고 $2a-1$ 항은 이진데이터를 양극성 데이터로 변환시킨다. 식(1)로 부터 W_{ij} 는 $apj = api$ 일 때 1 증가한다. 이러한 증가 또는 감소 과정은 모든 패턴들 내에 있는 모든 짹들 i, j 에 대해서 수행된다. 그리고 하나의 패턴이 신경회로망에 제공될 때마다 하나의 상태벡터가 발생된다. 신경회로망에 기억되는 견본패턴에 대응하는 신경회로망의 에너지 상태가 최소가 되도록 학습시키고자 한다. m 개의 훈련 벡터들의 주어진 집합 A_p 를 신경망에 기억시키려면 훈련 방정식인 식(1), (2), (3)을 이용한다.

5.2 갱신과정

Hopfield 신경회로망에서는 초기에 각 뉴런들에 대해서 하나의 상태가 할당되며 간신을 하기 위한 다음 뉴런은 임의로 선택된다. Hopfield 신경회로망에서는 비동기적으로 한 번에 하나씩 간신되며 이 방법은 뉴런에 가해지는 사건에 따라 상태를 바꾸는 생물학적 뉴런의 동작과 아주 비슷하다. 이 신경회로망의 간신과정은 다음과 같다(3). 뉴런 j 에 대한 자극은 식(4)이다

$$S_j = \sum_{i=1, i \neq j}^n u_i W_{ji} \quad \dots \dots \dots \quad (4)$$

여기서 u_i 는 뉴런 j 에 연결된 입력이며 뉴런 j 의 출력은 식(5)와 같다.

$$\begin{aligned} u_j &= 1 : \text{if } S_j \geq 0 \\ u_j &= 0 : \text{if } S_j < 0 \end{aligned} \quad \dots \quad (5)$$

이러한 뉴런 j 의 상태 변화는 이 뉴런의 입력 단에 연결된 다른 뉴런들의 상태가 변했기 때문에 발생한 것이다. 특정 뉴런의 개선 전 값은 그 뉴런의 개선시에는 고려되지 않으며 개선과정은 각 뉴런의 상태에 영향을 미친다. 개선과정은 뉴런들의 상태가 어떤 변화도 발생하지 않을 때까지 순차적으로 계속되며 궁극적으로 최소의 에너지 상태로 수렴됨이 보장된다.

5.3 수렴

수렴과정은 다차원 산악지형에서 가장 낮은 장소를 찾아가는 과정과 비슷하다. 국부 최소점(local minimum)에서 전역 최소점(global minimum)을 다시 찾아 가는 방법은 없으며 이렇게 하려면 볼쓰만 머신에서와 같이 잡음을 추가하여 신경회로망을 훈드는 방법을 사용하여야 한다. 그러나 신경회로망의 초기 위치를 다시 설정하여 다른 초기 위치에서 수렴과정이 시작되면 전역 최소점을 찾을 수는 있다. 먼저 단 하나의 뉴런이 개선됨에 따른 에너지의 변화를 살펴보기로 한다. 뉴런 j 에 의한 에너지는 식(6)으로 표현된다.

$$E = -\left(\frac{1}{2}\right) \sum_{i,i \neq j}^m W_{ij} u_i u_j \quad \dots \quad (6)$$

여기서 u_i 는 i 번째 뉴런의 출력이다. 식(5)에서 합은 뉴런 i 에 대해서만 취해지기 때문에 식(6)은 식(7)으로 나타낼 수 있다.

$$E_j = u_j \left[-\left(\frac{1}{2}\right) \sum_{i,i \neq j}^m W_{ij} u_i \right] \quad \dots \quad (7)$$

그러므로 뉴런 j 의 상태변화가 에너지의 변화량 ΔE_j 를 발생시킨다. 즉,

$$\Delta E_j = \Delta u_j \left[-\left(\frac{1}{2}\right) \sum_{i,i \neq j}^m W_{ij} u_i \right] \quad \dots \quad (8)$$

따라서 뉴런 j 와 관련된 에너지 변화는

$$\Delta E_j = -\left(\frac{1}{2}\right) \Delta u_j s_j \quad \dots \quad (9)$$

이다.

Hopfield 신경회로망의 전체 상태는 식(10)으로 표현되는 하나의 에너지 함수로 나타낼 수 있다.

$$E = -\left(\frac{1}{2}\right) \sum_j \sum_{i,i \neq j}^m W_{ij} u_i u_j \quad \dots \quad (10)$$

식(10)의 에너지 함수는 신경회로망에 의해 최소화 될 수 있는 하나의 목적함수이다. Hopfield 신경회로망의 연속적인 개선과정은 이 에너지 함수가 점차적으로 작아지는 하나의 수렴과정이며 결국 신경회로망은 국부적 또는 전역적인 에너지 최소상태로 안정된 상태에 도달한다. 이러한 안정상태에 도달하면 어떤 뉴런도 그들의 상태를 바꾸지 않는다. Hopfield 신경회로망에서 고려해야 할 중요한 사항은 하나의 주어진 입력패턴에 대하여 저장된 패턴이 아주 비슷하게 닮게 하는 기준과 이 신경회로망의 기억 용량에 관련되는 사항이다. Hopfield 신경회로망은 만일 패턴에 잡음이 인가된 경우나 부분적으로 훼손된 경우에도 메모리에 저장된 견본패턴과 충분히 닮았으면 정확한 패턴을 복원하는 기능을 갖고 있다. Hopfield 신경회로망은 주어진 입력으로부터 국부최소 에너지(local energy minima)를 찾는 에너지 공간상에 기술된다. 특정한 입력패턴이 주어지면 (에너지 공간의 특정지점) 신경회로망은 출력패턴을 찾는다. (국부최소점을 계산한다.) 이 때 Hopfield 신경회로망은 적절한 에너지 최소점 찾기 위해서 PE사이의 하중값을 조정하는 작업을 행한다. Hopfield 신경회로망은 연결된 PEs사이의 값이

둘다 양수 혹은 둘다 음수 즉, PEs사이의 값이 같은 부호를 갖는 경우에 연결강도를 양의 값으로 할당하고, PEs사이의 값이 다를 경우(Positive/negative) 음의 값을 할당한다. Hopfield 신경회로망은 연상메모리(associative)로 이루어진다. 일부분의 입력 정보로써 완전한 출력정보를 구성할 수 있게 된다. 이진 정보 “101”을 기억하고 있는 경우 불완전한 입력 “1?1”이 주어졌을 때 완전한 정보인 “101”에 해당하는 출력정보를 얻을 수 있다.

5.4 Hopfield 알고리즘

Hopfield 신경회로망의 학습 알고리즘은 다음과 같다 [3][11].

[단계1.] 이진값 in_0 에서 in_{N-1} 값을 갖는 in 이라 불리우는 길이 N 의 입력벡터가 주어진다.

[단계2.] out 이라 불리우는 in 벡터와 같은 형태의 출력벡터를 만든다.

```
for( i = 0; i = N-1; i++)
{
    outi = ini;
}
```

[단계3.] W 라 불리우는 weight matrix $N \times N$ 을 초기값이 모두 0 상태로 구성한다.

```
for( i = 0; i = N-1; i++)
{
    for( j = 0; j = N-1; j++)
    {
        Wij = 0;
    }
}
```

[단계4.] $i \neq j$ 인 W_{ij} 의 각 요소에 대한 적절한 값은 다음 식에 의해서 구한다.

$$W_{ij} = (2ini - 1)(2outj - 1)$$

이 식의 의미는 만약 ini 와 $outj$ 가 둘 다 1이거나 둘 다 0일 때 W_{ij} 요소에 1을 기억시킨다. 그렇지 않으면 W_{ij} 값은 -1이 된다.

```
for(i = 0; i = N-1; i++)
{
    for(j = 0; j = N-1; j++)
    {
        if(i ≠ j)
            Wij = (2ini - 1)(2outj - 1)
    }
}
```

VI. 제안된 시스템

6.1 제안된 시스템 구성

본 논문은 ART 신경회로망으로 구성된 인식부와 Hopfield 신경회로망으로 구성된 연상부로 나누어 구성했다. 인식부에서, ART 신경회로망은 패턴의 크기가 감소하는 순서로 들어올 경우에는 학습 및 인식율이 떨어지는 문제가 있다. 따라서 학습 및 인식율의 개선을 위해 하향틀의 변화를 제한할 수 있는 방법이 필요하다[14]. 따라서, 그 방법을 단기기억 이론에서 찾고자 하였다. 단기기억은 인지 과정을 수행할 때 잠시 정보를 유지하고 조작하는 체계적인 작업기억의 구실을 한다고 가정된다. 이 경우 가장 핵심적인 역할을 하는 뇌 부위는 변연계를 구성하는 구조물의 하나인 해마(hippocampus)이다.[5]. 이 해마에서 단기기억 내용을 운용하다가 필요한 경우 장기기억으로 전환 시킨다[15].

연상부에서는, 인식부에서 인식결과로 출력된 한글패턴을 견본패턴으로 입력하고 한글패턴의 방향성과 패턴영역의 크기 등 패턴영역의 변화에 따른 Hopfield 신경회로망의 실제 복원에 관한 실험을 분석하였다. (그림 2)는 제안된 시스템의 구조이다.

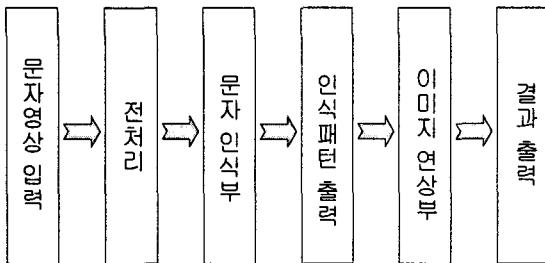


Fig 2. Structure of Proposed System

6.2 인식부 기억층(Memory Layer) 도입

본 연구의 인식부에서는 인간의 뇌 부위 변연계의 구조물인 해마(hippocampus)의 기능을 응용한 새로운 층을 추가함으로써 최초 활성화한 패턴의 크기를 기억하는 ML의 개념을 도입하고 하향들의 변화를 ML을 기준으로 해서 경계인수 범위 안에서만 가능하도록 제한한다.

제안된 인식부 시스템은 현재 학습되는 패턴과 같은 범주에 속하는 최초 패턴과의 일치도를 비교하여, 리세트 시스템이 동작하므로 입력패턴의 크기가 감소하더라도 ML이 최초 활성화 패턴의 크기를 기억하고 있어 하향들의 변화가 ML을 기준으로 경계인수 범위안에서만 가능하게 된다. 따라서, 기 학습된 패턴이 다시 들어오더라도 새로운 노드의 활성화를 방지하고, 학습이 완료되어 오인식율을 줄이게 된다.

6.3 수정된 ART 동작 알고리즘

[단계 1] : 경계인수 ρ 및 상, 하향 LTM 초기화

[단계 2] : 이진 입력벡터 X_i 가 제시된다.

[단계 3] : F2층의 출력 값을 구한다.

[단계 4] : 승리 뉴런 j 에 대한 경계인수 검사를 한다. 만일, 입력패턴과 승리 뉴런간의 유사도가 충분히 커서 경계인수 검사를 통과하면 같은 클러스터로 학습하기 위하여 단계 6으로 간다.

실패하면,

(Case 1) : F2층의 출력 노드중에서 활성화된 노드가 하나 이상 남아 있는 경우 단계 6으로 간다.

(Case 2) : F2층의 출력 노드중에서 활성화된 노드가 하나도 없는 경우 입력패턴을 새로운 클러스터로 생성하기 위하여 단계 5로 간다.

[단계 5] : 상향 및 하향 LTM 값을 수정하여 학습한다. 그리고 단계 2로 간다.

[단계 6] : F2층의 출력 노드 j 를 차단한다.

그리고, 단계 7로 간다.

[단계 7] : 출력 패턴이 최초 활성 패턴 인지 비교해서,

(Case 1) : 최초 활성 패턴이면 현재의 클러스터 탐색 과정에서 제외된다.

(Case 2) : 기 활성된 패턴이면 단계 3으로 간다.

6.4 입력패턴 세선화

세선화 알고리즘은 정보량의 압축, 물체의 길이, 위치특징 추출에 용이하다. (그림 3)의 중심점(p0)에서 "1"의 값을 갖고, 8개의 이웃(8-neighbor)값이 적어도 하나는 "0"의 값을 갖는 점을 기본으로 아래의 두 단계 알고리즘으로 세선화를 하게 된다[18].

p8	p1	p2
p7	p0	p3
p6	p5	p4

그림 3. 세선화 8개의 이웃(8-neighbor)값
Fig 3. Thinning 8-neighbor value

[단계 1] : 다음의 조건을 만족하는 중심점의 값을 지운다.

a) $2 \leq N(p0) \leq 6$

b) $S(p0) = 1$

c) $p1 \cdot p3 \cdot p5 = 0$

d) $p3 \cdot p5 \cdot p7 = 0$

$N(p0)$: $p0$ 의 이웃중에서 "0"이 아닌 값의 수

즉, $N(p0) = p1+p2+\dots+p8$

$S(p0)$: $p1, p2, \dots, p7, p8$ 의 순서로 진행될 때 "0"에서 "1"로 천이 되는 수

[단계 2] : a), b)의 조건은 변함 없으나 c), d)의 조건

이 다음과 같이 변하며 이 조건을 만족하는 점을 제거한다.

- a') $2 \leq N(p_0) \leq 6$
- b') $S(p_0) = 1$
- c') $p_1 \cdot p_3 \cdot p_7 = 0$
- d') $p_1 \cdot p_5 \cdot p_7 = 0$

VII. 실험

6.5 한글의 자모 위치특징 추출

제안된 자모 위치특징 추출 템플릿은 16×16 크기를 가지는 정사각형으로 세선화 과정에서 얻어진 골격선의 홍분성 픽셀에 위치 여부에 따라 자모의 위치특징을 추출할 수 있다.

[단계 1] : 세선화 된 입력 영상을 템플릿에 적용.
세선화 된 입력 영상을 $M_{16 \times 16}$ 이라 하면.

$$M_{16 \times 16} = (m_{ij}), m_{ij} = 0 \text{ (비적용 픽셀)} \quad (11)$$

$$m_{ij} = 1 \text{ (적용 픽셀)}$$

[단계 2] : 패턴의 각 픽셀 값과 매칭되는 입력영상의 픽셀값을 곱하여 0보다 클 경우 참.

위치특징 추출 템플릿을 $N_{16 \times 16}$ 라 하면.

$$N_{16 \times 16} = (n_{ij}), n_{ij} = \text{템플릿 각 픽셀값} \dots (12)$$

$$a_{ij} = m_{ij} \times n_{ij}$$

[단계 3] 각 픽셀이 참일 경우 해당 클래스에 누적값 k 를 추가.

$$\text{If } a_{ij} > 0 \text{ then } a_{ij} + k = b_{ij} \dots \dots \dots (13)$$

[단계 4] : 해당 픽셀 값이 경계값 이상일 경우 홍분으로 인식.

b_{ij} 를 새로운 픽셀값으로 인식 후.

$$\text{If } b_{ij} \geq B \text{ then 해당 픽셀 홍분 인식} \dots \dots \dots (14)$$

본 연구에서는 인식부와 연상부의 실험을 분리 수행하여 평가하였다.

7.1 인식부 실험 데이터

본 연구에서는 경계변수 변화에 따른 인식성능을 평가하기 위해 KSC5601로 표현될 수 있는 한글 6형식의 각 형식별 글자를 대상으로 총 2350글자를 16×16 의 크기로 패턴한 데이터를 광운대 인공지능 연구실로부터 제공받았으며, 이 데이터는 해상도 300dpi 트루 컬러로 스캐닝 된 후 이진화 과정을 거친것이다.

7.2 인식부 한글 인식

한글에 대한 인식 실험에서 〈표 1〉은 경계변수 변화에 따른 패턴 인식율과 클러스터 수를 나타내었다.

표 1. 경계변수 변화에 따른 패턴 인식율과 클러스터 수
Table 1. Recognition rate and cluster number by vigilance parameter change

경계변수	0.6	0.7	0.8	0.9
패턴인식율(%)	93.2	95.9	94.9	94.1
클러스터 수	2~16	3~19	5~24	4~26

〈표 1〉에서 보면, ART 신경회로망은 경계변수가 작을수록 클러스터 생성이 작아지고, 이에 따른 분류율도 정확하지 못하다. 반면, 경계변수의 값이 커질수록 클러스터 생성이 많아지고, 인식도 정확히 할 수 있음을 보였다. 그러나 경계변수가 1에 가까워질수록 클러스터 생성은 늘지만 인식은 일정수준에서 더 늘지 않음을 알 수 있다. 또한, 시스템의 과부하가 자주 발생한다. 따라서, 본 연구에서는 경계변수값이 0.7일 때 패턴 인식율이 가장 높았으므로 최적의 경계변수로 선택하였다. 그리고, 제안된 시스템의 효율성을 조사하기 위하여 본래의 ART 신경회로망을 이용하여 얻은 결과와 제안된 시스템의 결과를 비교하는 실험을 하였다. 실

험에서는 객관적 비교를 위해 제안된 시스템에서 적정변수로 선택한 경계변수 0.7을 사용하였으며, 입력패턴의 순서를 동일하게 사용하였다. <표 2>는 본래의 ART 신경회로망과 제안된 시스템의 성능을 비교하여 나타내었다.

표 2. 시스템 성능 비교
Table 2. Comparison of system performance

구 분	제안된 시스템		본래의 ART 신경회로망	
	유형 분류율	패턴 인식률	유형 분류율	패턴 인식률
인식률 (%)	97.7	95.9	94.2	90.1

7.3 연상부 실험

연상부에서는 인식부에서 출력된 한글패턴을 견본패턴으로 하여 한글패턴의 방향성과 패턴 영역의 크기 등 패턴영역의 변화에 따른 Hopfield 신경회로망의 복원 특성과 양호한 복원을 가능케하는 조건에 관해 실험, 분석하였다. 먼저 16X16크기의 임의 선정한 견본패턴 8개를 신경망에 학습시키고 견본패턴에 대한 복원성능에 관해서 실험하였다. 본 실험에서는 각 견본패턴들의 비트 수가 256개이므로 Hopfield 신경회로망을 구성하려면 256개의 뉴런이 필요하다. 8개의 견본패턴들은 Hopfield 신경회로망에 순서대로 입력된다. 그리고, 8개의 견본패턴들을 이용하여 하중값들이 계산되고 신경회로망에 저장된다. 이 과정은 일종의 학습과정에 해당한다[12]. 그리고 뉴런들간의 연결선들은 완전 연결된 구조이며 하중값들은 식 (1)에 의해 계산되어 저장된다. 시험패턴은 각 견본패턴들의 부분패턴들이며, 각 시험패턴들은 400회 이상 반복하여 개선하여, 복원하는 경우 local minima에 빠져 더 이상의 변화를 보이지 않았다. 하지만 다음의 표에서 보여 주듯이 수렴된 패턴과 견본패턴 간의 해밍거리를 비교해 보면 상당히 유사함을 알수 있다.

표 3. 견본패턴간의 해밍거리

Table 3. The Hamming distance between exemplar patterns

	답	등	운	공	길	팬	파	법
답	0	384	544	361	400	492	542	491
등	384	0	192	355	616	624	524	521
운	544	192	0	437	600	608	488	601
공	361	355	437	0	425	459	479	482
길	400	616	600	425	0	496	460	481
팬	492	624	608	459	496	0	444	479
파	542	524	488	479	460	444	0	433
법	491	521	601	482	481	479	433	0

표 4. 견본패턴과 시험패턴간의 해밍거리

Table 4. The Hamming distance between exemplar pattern and test pattern

	답	등	운	공	길	팬	파	법
답	84	332	524	301	392	446	526	469
등	94	96	288	339	560	576	606	507
운	524	288	104	381	528	568	448	573
공	301	339	381	112	349	435	473	474
길	392	560	528	349	128	468	448	451
팬	446	576	568	435	468	128	464	599
파	526	606	448	473	448	464	208	425
법	469	507	573	474	451	599	425	96

표 5. 견본패턴과 수렴패턴간의 해밍거리

Table 5. The Hamming distance of exemplar pattern and convergent pattern

	답	등	운	공	길	팬	파	법
답	58	384	498	303	342	462	520	481
등	384	12	180	355	628	636	520	529
운	498	180	9	432	597	617	479	608
공	303	355	432	117	430	526	504	479
길	342	628	597	430	0	496	460	481
팬	462	636	617	526	496	0	444	479
파	520	520	479	504	460	444	129	358
법	481	529	608	479	481	479	358	0

〈표 3〉에서 견본패턴간의 해밍거리를 보면 각 패턴은 완전 수렴됨을 알 수 있다. 〈표 5〉에서 견본패턴과 수렴된 패턴간의 거리를 보면 수렴패턴이 견본패턴과 완전히 수렴되지 않더라도 해밍거리가 적음을 알 수 있다. 수렴된 패턴과 견본패턴의 오차율은 평균 13% 이내였다. 〈표 4〉에서는 시험패턴과 견본패턴의 유사도와 복원의 상관관계를 알 수 있는데, 유사도가 높을수록 복원이 잘 되었으며, 시험패턴과 견본패턴의 해밍거리가 가장 먼 (화)패턴의 경우 수렴된 패턴과 견본패턴간의 해밍거리 또한 멀다는 것을 알 수 있다. 또한, 〈표 4〉와 〈표 5〉를 보게 되면 비트수가 많거나, 견본패턴과 시험패턴의 해밍거리가 적을수록 본래의 이미지를 정확하게 복원함을 알 수 있다.

VII. 결론

본 연구의 인식부에서는 단기기억 내용을 저장하고 활용하는 뇌의 부위인 해마(hippocampus)의 기능을 응용하여 시스템을 구성하였다.

인식부의 ART 신경회로망은 4.2절에 언급한 문제점 때문에 타 신경망에 비해 인식분야에 비교적 덜 사용되었다. 그러나 〈표 1〉과 〈표 2〉에서보면, 제안된 시스템은 기존의 시스템보다 상당히 개선된 인식성능을 보였다. ART 신경회로망은 경계 변수값의 변화에 따라 생성되는 클러스터의 수가 다르게 되는데 경계 변수값이 작게 되면 클러스터의 반경이 커짐에 따라 하나의 클러스터가 많은 패턴을 수용하게 된다. 반대로 경계 변수값이 크게 되면 클러스터의 반경이 작아지므로 많은 클러스터가 생성된다. 이 경우 다양한 패턴들을 저장할 수 있지만 인식에 있어서 비교해야 할 후보 클래스의 개수가 너무 많기 때문에 속도의 저하를 가져온다. 따라서 본 연구에서는 최적의 경계 변수값으로 0.7을 선택하였다. 패턴 인식율은 입력패턴에 대해 각 경계 변수별 상이한 인식율을 보였으나 최고 95.9%로 나타나 제안된 시스템 인식부의 효용성을 입증하였다. 연상부에 대한 실험에서는 한글의 경우 유사 패턴이 많기 때문에 완전히 복원되지는 못하였으나, 400회 이상 갱신, 수렴된 후에는 테스트 패턴들이 견본패턴과 비슷한 모양으로 복원되었다. 이 유사도를 측정하기 위해 해밍거리를 이용하였다. 〈표 4〉와 〈표 5〉를 보게 되면 비트수가 많거나, 견본패턴과 시험패턴의

해밍거리가 적을수록 본래의 이미지를 정확하게 복원함을 알 수 있다. 위 실험사실들로 보면 견본패턴들의 해밍거리로 계산되는 유사도가 클수록 부분패턴에 대응하는 견본패턴들의 복원성공률은 낮아진다. 견본패턴들을 구별할 수 있는 최소한의 정보들로 구성된 부분패턴만 입력되면 대응하는 견본패턴을 정확하게 복원할 수 있다. 따라서, Hopfield 신경회로망은 견본패턴들이 부분별로 서로 닮아서 직교성이 낮은 경우는 인가되는 잡음량과, 부분패턴의 모양에 상관없이 복원성능이 비교적 낮음을 알 수 있다. 결국 고등동물의 경우와 마찬가지로 Hopfield 신경회로망은 전혀 닮지 않은 정보들의 인식 및 복원에 대해서는 우수한 동작을 가졌지만 서로 닮은 부분이 있는 정보들의 인식 및 복원의 결과는 부족함을 확인하였다.

본 연구에서는 인간의 인식과 연상에 관한 과정을 신경회로망을 통해 구현하여 ART 신경회로망의 성능을 개선하였다. 그러나 Hopfield 신경회로망의 경우, 그 효용성은 어느정도 입증되었으나 경우 닮은 부분, 즉 직교성이 낮은 패턴의 경우 유사도를 제한하거나 조정할 수 있는 연구가 추후 이루어져야 하며, 또한 각 신경회로망 간의 변환 문제나 통합 부분에 대해서는 더 많은 연구가 필요하다.

참고문헌

- [1] Anderson J.R. "Cognitive psychology and its implication(3rd)", New York Freeman, 1990
- [2] Baddeley A. "Your memory' A user's guide", London, Prion, 1996
- [3] G.A. Carpenter and S. Grossberg, "Pattern Recognition by Self-Organizing Neural Networks", PP, 316~423, 523, 1991.
- [4] G.A. Carpenter and S.Grossberg, "The ART of Adaptive Pattern Recognition by a If-organizing Neural Network," IEEE Computer, Vol. 21, NO. 3, PP. 77~88, 1988.
- [5] Horn, R.L. Classroom learning & teaching, New York, Longman, 1995

- [6] J. J. Hopfield "Neural Network and Physical Systems with Emergent Collective Computational abilities", Proceeding of The Neural Academy Science, 1982
- [7] J. J. Hopfield and D.Tank, "Neural computation of decisions in optimization problems", Biological Cybernetics, vol. 52, 1995.
- [8] Martin T. Hagan, Howard B. emuth, "Neural Network Design", PWS, 1995.
- [9] Nasser M.Nasraba and C.Y.Choo, "Hopfield Network for Stereo Vision Correspondence", IEEE Trans, on Neural Networks, vol.3, no.1, P5~13, Jan, 1992.
- [10] 길이만, "뇌정보 처리에 기초한 인공 신경회로망", 교육부 교육월보, 제 192호, 34-38
- [11] 김연숙, "퍼지 이론을 이용한 한국어 및 일어 화자 인식에 관한 연구", 한국OA학회 논문집, 제 5권 3호, 2000. 9
- [12] 박성철, "유전 알고리즘과 계층적 흡필드 신경망에 의한 잡영이 혼합된 한글 자모인식에 관한 연구", 광운대학교 석사학위 논문, 1996.
- [13] 이기희, "선형 변환망을 이용한 화자적응 음성인식". 한국OA학회 논문집, 제5권 2호, 2000. 6.
- [14] 이남일, "확장된 ART 신경회로망을 이용한 자동 지문 인식 시스템", 경북대학교 박사학위 논문, 1993.
- [15] 이성영, "읽기기능의 개념정립을 위한 시론", 서울대학교 석사학위 논문, 1990.
- [16] 이진숙, "읽기 장애아에 있어서 움운중심 및 의미중심 범주화자극제시 조건이 단어회상에 미치는 효과에 관한 일 연구", 이화여자대학교 석사학위 논문, 1993.
- [17] 이재호, "인간기억의 구조와 과정", 한국인지 과학회, 제 1회 인지과학학술강좌 자료집, 110-138, 1996
- [18] 장래복, "신경회로망을 이용한 인쇄체 한글 인식에 관한 연구", 성균관 대학교 과학기술 논문집, 243-258, 1992
- [19] 조주연, "학습 및 기억에 대한 인지과학적 발견의 교육적 적용", 초등교육 저널, Vol 12, 5-27, 1998

저자 소개

장재혁



1995년 2월 안동대학교 미술학과
(학사)

2003년 2월 광운대학교 멀티미디어
학과 (공학석사)

2003년 3월~현재 경상대학교 컴퓨
터과학과 박사과정

박중양



1982년 연세대학교 응용통계학과
(학사)

1984년 한국과학기술원 산업공학과
(공학석사)

1994년 한국과학기술원 산업공학과
(공학박사)

1989~현재 경상대학교 통계정보학과
교수



박재홍

1978년 충북대학교 수학교육과
(학사)

1980년 중앙대학교 전산학과
(공학석사)

1989년 중앙대학교 전산학과
(공학박사)

1983년~현재 경상대학교 컴퓨터과
학과 교수