

다중 판별자를 가지는 동적 삼차원 뉴로 시스템

(A Dynamic Three Dimensional Neuro System with
Multi-Discriminator)

김 성 진 ^{*} 이 동 형 ^{**} 이 수 동 ^{***}
(Seong Jin Kim) (Dong Hyung Lee) (Soo Dong Lee)

요약 오류역전파 방법을 이용하는 신경망들은 패턴들의 학습시간이 매우 오래 걸리고 또한 추가학습과 반복학습의 한계를 가지며, 이런 단점을 보완할 수 있는 이진신경망(Binary Neural Network, BNN)이 Aleksander에 의해 제안되었다. 그러나 BNN도 반복학습에 있어서는 단점을 가지고 있으며, 일반화 패턴을 추출하기 어렵다.

본 논문에서는 BNN의 구조를 개선하여 반복학습과 추가학습이 가능할 뿐 아니라, 특징점들까지 추출할 수 있는 다중 판별자를 가지는 삼차원 뉴로 시스템을 제안한다.

제안된 모델은 기존의 BNN을 기반으로 하여 만들어진 이차원 특징을 가지는 Single Layer Network (SLN)에 귀환회로가 추가되어 특징점들을 누적할 수 있는 삼차원 신경망이다. 학습을 통해 누적된 정보는 판별자의 각 신경세포에 임계치를 조정함으로써 일반화 패턴을 추출할 수 있다. 그리고 생성된 일반화 패턴을 인식에 재사용함으로써 반복학습의 효율성을 높였다. 최종 판정 단계에서는 Maximum Response Detector(MRD)를 이용하였다.

본 논문에서 제안한 시스템을 평가하기 위하여 NIST에서 제공하는 숫자 자료를 이용하였으며, 99.3%의 인식률을 얻었다.

키워드 : 신경망, 3-D 신경망, 패턴 인식, 이진신경망, 다중 판별자

Abstract The back propagation algorithm took a long time to learn the input patterns and was difficult to train the additional or repeated learning patterns. So Aleksander proposed the binary neural network which could overcome the disadvantages of BP Network. But it had the limitation of repeated learning and was impossible to extract a generalized pattern.

In this paper, we proposed a dynamic 3 dimensional Neuro System which was consisted of a learning network which was based on weightless neural network and a feedback module which could accumulate the characteristic. The proposed system was enable to train additional and repeated patterns. Also it could be produced a generalized pattern by putting a proper threshold into each learning-net's discriminator which was resulted from learning procedures. And then we reused the generalized pattern to elevate the recognition rate. In the last processing step to decide right category, we used maximum response detector.

We experimented using the MNIST database of NIST and got 99.3% of right recognition rate for training data.

Key words : 3-D Neural Network, Pattern Recognition, BNN, Multi Discriminator

1. 서 론

* 본 연구는 2004년도 울산대학교 교내연구비를 지원받았음

+ 정 회 원 : 울산대학교 컴퓨터공학과

sjkim326@mail.ulsan.ac.kr

++ 정 회 원 : 한국폴리텍VII울산대학 정보통신시스템학과 교수

sunhook@dreamwiz.com

+++ 정 회 원 : 울산대학교 컴퓨터정보통신공학부 교수

sdlee@mail.ulsan.ac.kr

논문접수 : 2006년 9월 28일

심사완료 : 2007년 5월 11일

정보화 산업의 발전과 더불어 문서의 입력 및 처리와 관련한 문서인식 시스템에 대한 필요성이 점점 증가하고 있으며, 이에 관련된 연구도 활발히 진행 중이다[1].

문서 인식은 일반적으로 오프라인 인식을 의미하며 다시 인쇄체 인식과 필기체 인식으로 분류된다. 그리고 필기체 인식은 다시 PDA등에서 이용하는 온라인 인식과 차량 번호판 인식과 같은 오프라인 인식 등이 있다.

패턴인식 시스템에 사용되는 대표적인 모델로는 원형 정합을 이용한 방법, 확률 통계적인 방법, 구조적 방법, 신경회로망을 이용한 방법 등이 있고, 그 중 신경회로망을 이용한 인식방법이 우수하다고 알려져 있다[2]. 그러나 기존의 신경회로망(Weighted Neural Network)을 이용한 방법들은 인식률을 높이기 위해 전 처리 과정 중에 많은 변형을 사용함으로써 과정이 복잡해지고, 연 결강도를 보정하기 위한 반복계산 등으로 인해 학습 시간이 많은 시간이 요구된다. 또한 기존에 학습된 패턴과 유사한 학습 패턴을 학습시키면 일반화 패턴의 정확도를 떨어뜨리며, 추가 학습을 할 경우에는 추가되는 학습 패턴을 포함한 전체를 처음부터 다시 재학습해야 하는 등의 문제점이 있다[3].

본 논문에서는 기존의 신경회로망이 가지는 단점을 해결할 수 있는 Aleksander와 Stonham이 제안한 BNN (Binary Neural Network)[4,5]의 원리에 바탕을 둔 Lee의 WNN(Weightless Neural Network)[6]의 구조를 이용하여 특징점까지 누적할 수 있는 삼차원 이진 신경망 모델을 제안하고 있다. 제안된 모델은 내부적으로 Bledsoe와 Browning이 제안한 N-Tuple 기법[7]을 사용하였으며, 복잡한 전처리 과정이 필요 없고, 한 번의 학습으로 학습이 가능하며 하드웨어적으로 구현하기가 용이하다는 장점이 있다. 제안된 삼차원 신경회로망은 WNN의 기본적 개념을 이용하여 추가학습이 가능하다는 장점을 가질 뿐 아니라, 귀환 방법을 적용함으로써 특징점 누적이 가능한 동적 특성을 지니는 모델[8]이며 인식 효율을 높이기 위하여 범주별로 판별자를 사용하였다.

제안된 모델의 평가를 위하여 NIST의 MNIST[9] 데이터베이스에서 임의로 1000자를 추출하여 학습과 인식에 사용하였다.

본 논문에서 제안된 시스템은 오프라인 필기체 숫자 인식이나 얼굴 인식 등과 같이 인식 범주가 몇 개로 한정되고 정확한 인식을 요구할 때 매우 유용하다.

본 논문의 구성은 다음과 같다. 2장에서는 이진신경망의 기본원리에 대하여 간단히 정리하고, 3장에서 삼차원 신경회로망 패턴인식기의 동작과 학습 및 인식알고리즘에 대하여 소개하며, 4장에서 제안된 모델을 사용하여 MNIST의 자료에 대하여 실험하고, 마지막 5장에서 결론과 향후 연구방향을 제시하였다.

2. 이진 신경망의 원리

이진 신경망[10,11]은 램(RAM)의 원리를 이용하여 학습한다. 각 램은 그림 1의 구조와 같이 N-tuple[12]로 샘플링 된 N개의 노드에 연결되어 있으며, 그 노드를 각 램의 주소로 이용하여 지정된 램 번지가 활성화된다.

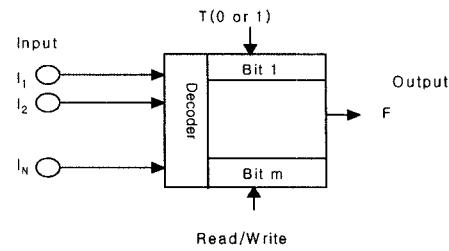


그림 1 2진 신경 세포

따라서 입력 패턴이 R개의 노드를 가질 경우 이를 학습하기 위해서는 완전 연결일 경우에는 R/N개의 램이 필요하며, 이들을 조합하여 한 범주의 인식 판별자를 구성함으로써 각 램의 크기는 $2N$ bit가 된다.

그림 1에서 T값은 1일 경우 학습을 0일 경우 인식을 의미하며, Read/Write신호는 RAM에 읽기와 쓰기를 제어하는 신호이다.

학습 단계에서는 T=1로 설정하고 Write 신호를 준 후, 입력층으로부터 임의의 N-tuple의 노드를 추출하며, 추출된 tuple을 이용하여 조합된 2진 입력값이 기억층의 디코더에 전달되고, 식 (1)에 의해 주소 정보가 해석되어 정해진 주소의 비트가 1로 설정된다.

$$\text{Address} = 2^N + 2^{N-1} + \dots + 2^1 \quad (1)$$

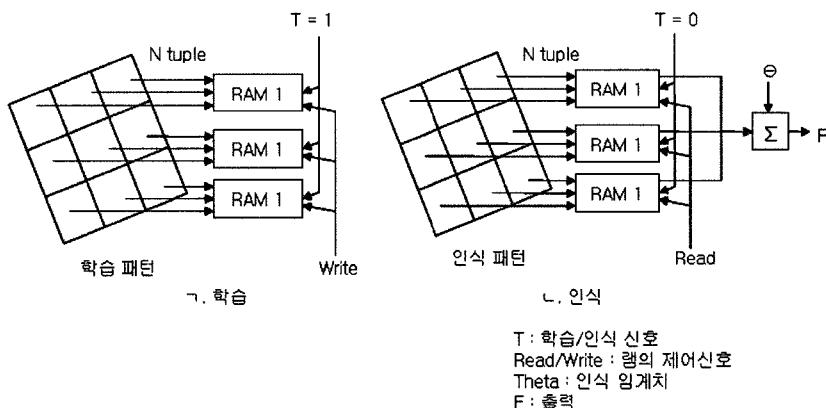
입력층에서 기억층으로 전달된 2진 값이 디코더에 의해 주소 정보화되어 램의 내부 Bit를 선택하게 되며, 선택된 위치의 주소에 정보를 기록함으로써 학습된다.

인식 단계에서는 T=0로 설정하고, Read 신호를 준 후, 학습 때와 동일한 방법으로 조합된 tuple을 이용하여 디코더의 입력값을 만들고, 이를 이용하여 2진 입력의 주소에 해당하는 Bit에 기억된 값을 출력함으로써, 선택된 비트의 정보에 따라서 그 입력 tuple의 값을 출력하고, 그 값들을 조절하여 패턴의 학습 여부를 결정한다[8].

그림 2에서와 T 신호는 학습과 인식을 결정할 수 있는 신호로써 1일 경우 학습을 0일 경우 인식을 의미하며, Θ는 인식단계에서 사용하는 변수로써 그 결과의 합이 임계치(Θ 값)를 넘었을 경우 그 입력패턴은 학습되었다는 것을 의미한다.

그 값이 같이 3×3 의 입력 패턴일 경우, 입력 노드의 총 개수는 9이며, tuple의 노드 수를 3으로 처리할 경우에는 세 개의 tuple이 만들어지고, 각 램의 디코드 입력은 3비트가 된다. 그리고 필요한 램은 3개이며 각 램은 000~111의 주소를 가진다. 최종적으로 하나의 판별자는 3개의 램으로 구성됨으로써 입력 패턴을 처리할 수 있다.

단층 구조로 된 퍼셉트론에서의 인식 구분 영역은 선형적이므로 비선형적인 영역의 인식을 위해서는 다층 구조를 가져야 한다는 제약이 따르지만, WNN에서는



하나의 판별자로도 비선형으로 구분되는 영역을 학습시킬 수 있는 장점이 있다. 또한 WNN은 학습된 정보로부터 일반화된 패턴을 생성시킬 수 있다. 이것은 입력 노드 중에서 부분적인 정보를 독립된 복수 개의 2진 신경세포에 분산 저장시킴으로써, 분산 저장된 정보를 다시 조합할 때 만들어지는 경우의 수만큼 새로운 패턴이 생성되기 때문이다.

그림 3과 같이 3개의 패턴을 그림 2의 WNN에 학습시켰을 경우 각 2진 신경세포에 학습되어진 내부 상태는 그림 4와 같으며, 이것은 그림 5와 같은 5가지의 패턴을 추가 학습시켰을 때에도 변화되지 않는다.

따라서 그림 4의 상태는 그림 5에서 보이는 새로운 패턴을 스스로 생성하여 학습된 일반화 패턴으로 기억하고 있는 결과가 되어 이 5가지 패턴은 학습을 시키지 않아도 인식된 것으로 처리한다.

그러나 위와 같이 일반화된 패턴들의 결과가 오히려 단점이 될 수도 있으며, 학습시키지 않은 패턴들에 대한 오인식의 원인이 된다.

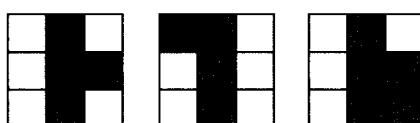


그림 3 학습 패턴

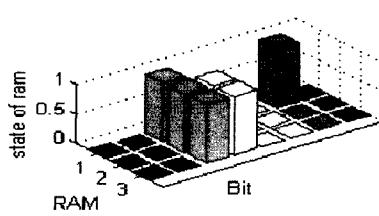


그림 4 2진 신경회로망의 내부 상태

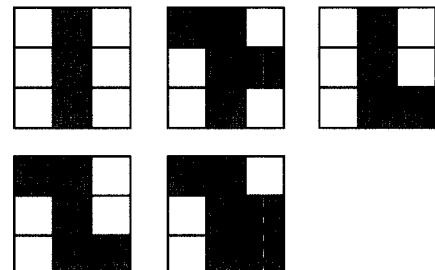


그림 5 일반화 패턴

3. Dynamic Three Dimensional(3-D) Neuro System

3.1 시스템 구조

인간은 경험을 통해 누적된 지식으로부터 주의 집중 기능과 망각 기능을 통해 하나의 일반화된 패턴(Generalized Pattern)을 생성할 수 있는 능력을 지니고 있다 [13].

3-D 신경회로망은 정보의 기억 소자 단위를 비트 단위로 하지 않고 학습의 반복 회수를 기억할 수 있는 바이트로 구성된 램을 사용하고, 내부적으로 연산기를 두어 신경세포 내부에 기억된 정보를 귀환하여 연산할 수 있도록 하였다. 이러한 구조로 인해 3-D 신경회로망은 단위소자를 연산 처리 가능하게 함으로써 기존의 학습된 정보를 유지하면서 새로운 정보를 추가할 수 있는 추가 학습이 가능하고, 동일한 범주의 정보에 대해서는 반복 학습 회수에 따라 학습 정도가 점점 누적되는 반복 학습도 가능하다.

반복 학습에 의해 누적된 정보로부터 공통된 특징에 대해서는 주의 집중 기능과 불필요한 정보에 대해서는 망각 기능을 사용하여 일반화된 패턴을 생성해 낼 수 있다. 즉 추가 학습과 반복 학습에 따라 누적된 각 램에

기억된 값 중에서 임계치 이상을 기억하고 있는 부분만으로 재구성한 일반화된 패턴을 추출할 수 있다.

3.1.1 3-D 신경세포

그림 6에서 신경세포의 구조를 보이고 있으며, 이 때 T 값은 입력 패턴에 대응하는 원형 패턴의 픽셀 값을 의미하고, 입력패턴의 내용과 동일한 내용으로 기억시키려면 $T=1$ 로 하면 된다. 판별자의 기본 구성 요소인 신경세포의 학습은 입력으로부터 N -Tuple만큼의 픽셀을 랜덤하게 선택하여 디코더에서 주소정보화 한 후, 선택된 램 내부에 기억된 값을 귀환시켜 학습정보 T 와 연산한 후, 그 결과를 다시 기억시킨다.

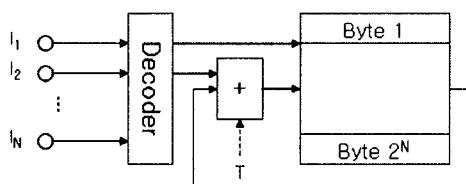


그림 6 3-D 신경세포

인식은 학습에서의 입력과정과 동일한 순서로 N -Tuple 만큼의 픽셀을 선택하여 디코더에서 주소정보화한 후, 신경세포의 해당 램에 저장되어 있는 값을 가져온다. 이 때 출력은 학습의 반복 회수 값을 나타내기 때문에 학습경험이 많은 패턴에 대해서는 상대적으로 높은 값이 출력된다.

3.1.2 판별자

판별자는 그림 7과 같이 N 개의 입력을 받는 K 개의 신경세포와 Summing Device(Σ)로 구성되며, 판별자의 기능은 하나의 패턴 범주를 기억하기 위해서이다.

각 신경세포의 입력은 입력 이미지와 랜덤 매칭 방법

으로 각각 연결되어 있다. N 개의 입력을 가지는 판별자는 $2^N(K)$ 개의 신경세포로 구성된다. 예를 들어 4×4 픽셀 입력이미지에 대하여 각 신경세포 당 4개씩의 입력을 가지는 판별자를 구성하면, 전체 2^4 개의 신경세포로 구성할 수 있고, 입력이미지의 각 픽셀은 판별자에 대한 입력으로 각각 4번씩 입력패턴으로 사용되어진다. Summing Device(Σ)는 각 신경세포로부터 출력을 더하여 그 합계를 출력하는 함수를 이용하여, 그 출력값(R)이 클수록 입력으로 들어온 패턴이 학습된 패턴과 유사함을 의미한다. 즉 R 값이 정해진 임계치보다 크면 인식됨을 의미한다.

3.1.3 다중 판별자

본 논문에서 설계한 숫자 인식시스템과 같이 다양한 카테고리를 분류하는 시스템은 여러 개의 판별자를 사용하여야 높은 인식률을 보인다. 이처럼 다중 판별자를 사용한 대표적인 예로는 WISARD(Wilkie, Stonnen and Aleksander's Recognition Device)[2,6,7] 시스템이 있으며, 제안된 모델의 구조는 그림 8과 같다.

다중 판별자(Multi-discriminator)는 각 카테고리 정보를 기억하고 있는 판별자와 각 판별자의 출력으로부터 가장 큰 값을 선택하는 Maximum Response Detector (MRD)로 구성된다. MRD에서는 여러 출력값들 중 가장 큰 것을 찾아 출력한다. 이 MRD로부터 나오는 출력이 인식된 카테고리로 결정된다.

3.2 패턴 인식

원형 이론[14]에 의하면 인간은 이미지를 주어진 그대로 학습 받아 기억하기보다는 이를 이미지를 원형으로 변화시켜 Long-Term Memory(LTM)에 Random-Mapping 방식으로 수용하여 기억하고, 미지의 입력 패턴의 인식 시에는 이렇게 구축한 원형과 외부의 대상을 끊임없이

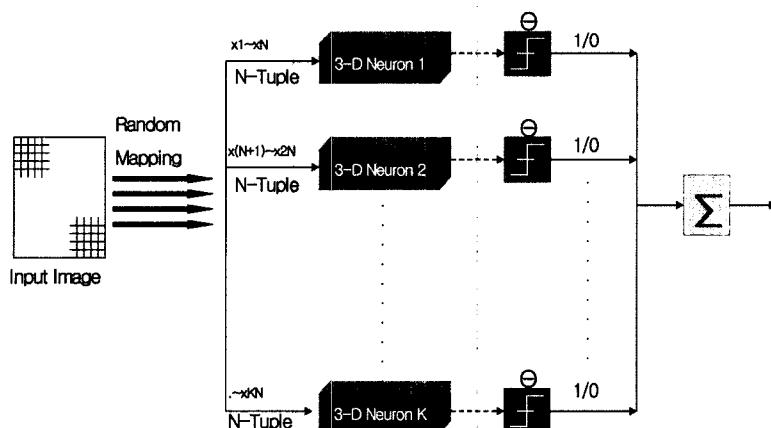


그림 7 범주별 판별자 구조도

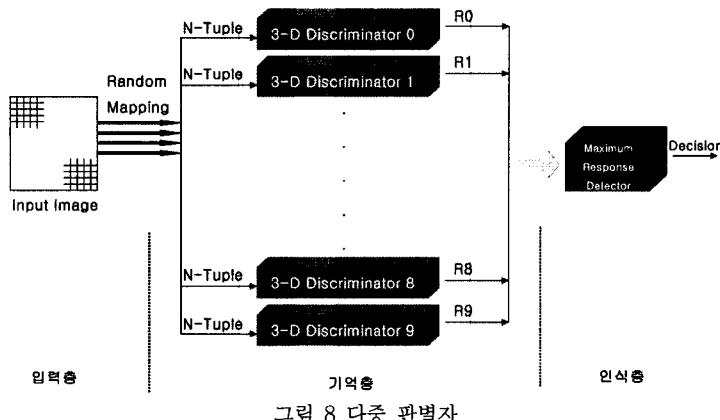


그림 8 다중 판별자

비교해 가며 자신이 만족을 느낄 때까지 프로세싱을 계속 수행한 후 결론을 내린다.

본 논문의 패턴 인식기는 원형 이론을 바탕으로 한 학습 방법으로써, 내부적으로 학습망과 인식망의 이중망 구조로 구성되어 있다. 즉 미지의 입력 패턴을 인식할 때 학습망에서 학습 받은 내부 상태와 외부의 입력을 귀환을 통해서 끊임없이 비교하면서 변형을 제거시켜 가며 원형 패턴으로 만들어간다. 최종적으로 귀환 루프를 통해서 전처리된 원형을 인식망에서 인식하여 결론을 내린다. 또한 인식망에서 내린 결론을 학습망의 입력에 귀환시켜 하나의 대상을 만족할 때까지 반복 인식이 가능하다. 즉, 귀환 기법을 사용한 시스템의 동작은 프로세스가 진행됨에 따라 자체의 지능에 의해 자신의 동작을 수정해 나가는 능력을 가지고 제어되어진다.

패턴 인식기의 구조는 전후관계의 영향을 고려해 학습망과 인식망의 이중망 구조로 구성하였으며, 학습망과 인식망 사이에 귀환선로를 두어 서로 정보 전달이 가능하게 하였다. 인식망에서 생성된 결과물이 학습망의 프로세스에 관여하게 함으로써 전단의 결론을 점점 증폭시켜가며 강력한 결론(Strong Decision)으로 유도시킨다.

이러한 인식 과정의 전체적인 모델을 그림 9에 보이고 있으며, 미지의 입력을 학습망의 출력 매트릭스에서 원형 패턴으로 재인식 시킬 수 있고, 앞과 같이 전처리된 패턴을 인식망에서 인식하게 함으로써 강력한 결론을 내릴 수 있다. 또한, 학습망의 출력과 인식망의 입력사이에 귀환 루프를 두어 시스템 모델이 만족할 만한 결론을 얻을 때까지 프로세싱을 수행시키며, 어느 정도 기다려도 만족할 만한 결론을 내릴 수 없을 때는 억지로 결론을 내리는 대신 새로운 시도를 가지고 처음부터 다시 하여 시스템 신뢰도를 높이고 유통성을 지니도록 하였다.

3.2.1 학습망

그림 10에서 보인 학습망은 2차원배열의 입력층과 다

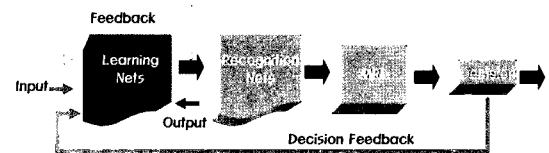


그림 9 패턴 인식기

수의 판별자로 구성된 기억층, 그리고 입력층과 동일한 크기의 2차원 배열인 출력층으로 구성된다. 입력이미지는 28×28 크기의 흑백 이미지를 사용하였고, 8-Tuple Method를 사용해 입력층과 출력층에서 랜덤하게 각 4 픽셀 총 8픽셀을 조합하여 신경세포의 입력 주소정보로 사용하였다.

기억층의 판별자는 2^8 Byte 크기의 784개의 램으로 구성된다. 각 신경세포에 있는 귀환회로의 연산기는 귀환된 램의 내부 값과 원형이미지로부터 입력된 정보를 연산하여 다시 램에 누적하여 기억시킨다. 학습은 다음 과정을 반복 수행한다.

1. 신경세포 벡터를 생성하고 내부 기억을 초기화한다.
2. 학습일 경우 원형 패턴을 결정하고 학습된 정보를 램으로 읽어 들인다. 원형 패턴(Prototype Pattern)의 결정으로 신경세포가 결정된다.
3. 입력층과 출력층에 각각 입력(학습) 이미지와 원형이미지를 저장한다.
4. 입력 데이터의 해당 범주의 판별자에 원형 타입 정보를 기억시킨다. 주어진 신경망은 지도학습으로써 각 입력 데이터의 원형 정보를 같이 입력된다.
5. 연산기를 이용하여 주어진 입력데이터의 학습여부를 판단한다.
6. 만약 학습한다고 결정되면 학습한다. 그렇지 않으면 다시 2로 이동한다. 학습은 지정된 신경세포에 주소화된 디코더 정보를 이용하여 누적한다.

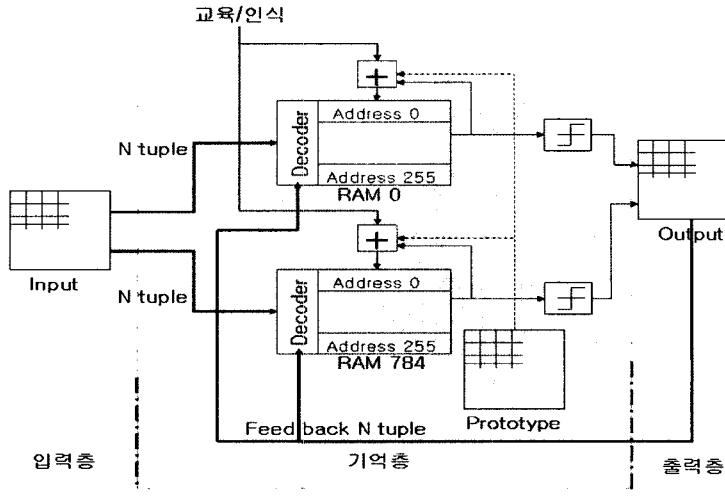


그림 10 학습망

7. 일반화 패턴을 추출하여 입력패턴을 만들고 3으로 이동한다.

단계 1에서 원형이미지의 크기가 28×28 이므로 램은 원형이미지의 픽셀수(784) 만큼 생성한다. 그리고 입력 패턴에서 N개의 튜플로 추출하기 위하여 식 (2)를 사용 한다.

$$\text{NumofImage} = \left\lceil \frac{\text{TotalPixel}}{N} \right\rceil \quad (2)$$

주어진 식 (2)에서 NumofImage는 생성할 이미지의 개수를 의미하며, TotalPixel은 원형이미지 혹은 학습 이미지의 전체 픽셀수를 나타낸다. 식 (2)에서는 전체 픽셀수를 N으로 나누었을 때, 나누어떨어지지 않는 것 까지 고려하였다. 생성된 이미지의 각 픽셀은 램의 주소를 생성할 수 있다. 이와 같은 이미지 사상표는 각 실 험에서 항상 랜덤하게 설정되기 때문에 초기화 단계에서 새로운 값을 생성한 후 실험이 끝날 때까지 유지되어야 한다.

단계 2에서는 특정 범주별로 원형 타입을 읽어 저장 한다. 이 단계에서는 학습 횟수의 표준화를 위하여 방법이 고려되어야 한다. 만약 특정 범주의 학습패턴이 많을 경우, MRD에 의하여 누적값을 이용하므로 항상 그 값이 최고값으로 판정된다.

제안된 시스템에서는 원형 패턴의 각 픽셀 값을 모두 합한 후, 그 합의 역수를 이용하였다.

$$\text{accValue} = \frac{1}{\sum_{i,j} \text{prototypeImage}(i,j)} \quad (3)$$

식 (3)에서 accValue는 표준화를 위하여 사용된 누적 값의 역수를 취한 값이다.

단계 4에서는 학습에서 각 램의 제어 입력 T를 결정 하기 위하여 원형이미지를 이용한다.

단계 5에서 임계치를 결정하여 임계치에 따라서 학습 여부를 판단한다. 임계치를 결정하는 것은 식 (4)에 보인다.

$$\text{Threshold} = \frac{\sum_{i,j} \text{GenImage}(i,j)}{\sum_{i,j} \text{PrototypeImage}(i,j)} \times 100 (\%) \quad (4)$$

GenImage : 생성된 이미지,

PrototypeImage : 원형이미지

임계치를 결정하기 위하여 식 (4)를 이용한다. 정해진 임계치에 따라서 귀환되는 값과 새로이 생성된 값을 비교하여 학습 여부를 판단한다. 임계치를 결정하기 위하여 원형이미지에서 픽셀들의 합과 생성된 이미지의 합을 이용하였다. 임계치를 학습 데이터 개수(각 범주별로 100개씩)로 하였을 경우에는 각각의 이미지들이 모두 다르기 때문에 모두 학습이 되며, 임계치를 줄였을 경우에는 유사정도에 따라서 학습되는 문자 개수가 줄어든다.

학습망에서 학습은 원형 이미지와 필기체 이미지를 대상으로 한다. 학습망은 외부의 학습을 통해서 점진적으로 각 카테고리 이미지 정보를 학습, 흡수(Perception) 할 수 있게 된다. 이렇게 생성된 정보는 차후 일반화된(Generalized) 집합으로 동작시켜 인식 시에 사용된다.

3.2.2 인식망

오프라인 필기체 문자 인식은 유사한 문자, 필기체 문자의 변형 등으로 인하여 단순히 문자 패턴의 형상만으로는 정확한 식별이 곤란한 경우가 많다. 이러한 문자들을 정확히 인식하기 위해서는 내부적으로 원형패턴으로 유도할 수 있는 인식 시스템이 필요하다. 이러한 문맥을

고려한 인식망을 설계하기 위하여 그림 9와 같이 2차원 배열의 입력층과 WNN기반의 판별자로 구성되는 기억층, 그리고 각 판별자로부터 가장 큰 반응을 구하는 인식층 MRD로 구성하였으며, 입력이미지는 학습망의 출력층의 입력으로 사용되어지는 28×28 크기의 원형 이미지를 사용하였고, 4-Tuple 기법을 사용해 램의 입력 주소 정보로 추출하는데 사용하였다. 각 판별자는 784개의 램으로 구성되어진다. 인식층의 학습은 입력에 원형 패턴을 보이고 해당 램에 '1'을 가해 해당 판별자가 원형을 수용하도록 한다.

- 인식 과정은 다음의 과정을 반복 수행한다.
1. 미지의 입력 패턴을 입력층과 출력층에 넣는다.
 2. 각 판별자들의 출력값을 MRD를 이용하여 인식층에서 결론을 내린다.
 3. 인식층에서 최대 응답을 보인 학습망에서의 출력 패턴을 다시 재입력 한다.
 4. 정해진 회수만큼 귀환(Feedback)을 하지 않았으면 단계 2로 간다.
 5. 인식망에서 최종 출력값을 구한다.
 - 1) 구해진 결과가 기준치(Threshold)보다 크면 최종 결론을 내리고 종료한다.
 - 2) 주어진 기준치를 넘지 못하면 프로세스 6으로 간다.
 6. 처음 인식 사이클에서 인식망에서 내린 최대 응답의 바로 다음 응답을 내린 판별자를 선택하여 그 판별자와 인식망의 조합으로 프로세스 1부터 다시 시도한다.
 7. 제시도 후 최종 응답이 기준치 이하이면 '인식불가' 판정을 내리고 종료한다.

4. 실험 및 결과

4.1 학습과 인식 실험

실험에 사용된 것은 MNIST의 NIST 숫자데이터로서 크기는 28×28 픽셀의 크기로 정규화되어 있으며, 각 숫자 당 100개의 데이터를 임으로 추출하여 실험하였다. 제안된 시스템은 보다 나은 인식을 위하여 숫자의 형태를 수정하는 전처리과정이 불필요하다는 특징을 지니며, 필요에 따라 전처리를 할 경우 더 좋은 인식률을 가진다.

실험에 사용된 입력데이터의 원형 데이터를 그림 11에 보이고 있으며, 학습과 인식에 사용되는 숫자를 그림 12에 보인다.

표 1은 임계치를 조절하였을 때, 학습된 숫자와 유사 정도를 비교하여 각 판별자에 학습하는 것을 보이고 있

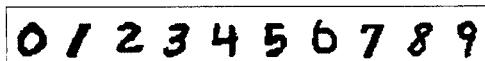


그림 11 학습에 사용된 원형 이미지

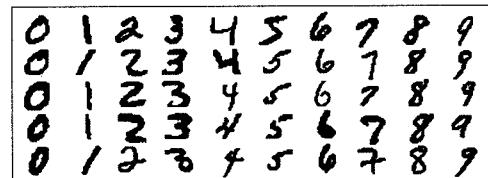


그림 12 학습과 인식에 사용된 데이터 이미지 예제

표 1 임계치에 따른 각 학습문자 수

숫자 임계치	0	1	2	3	4	5	6	7	8	9
100	100	100	100	100	100	100	100	100	100	100
30	41	23	44	40	37	42	35	33	35	33
5	22	12	22	21	20	21	19	16	20	19

표 2 임계치에 따른 학습 문자수에 따른 인식

숫자 임계치	0	1	2	3	4	5	6	7	8	9	인식 문자
100	100	100	100	97	100	99	100	98	100	99	993
30	98	72	95	90	86	85	88	90	89	73	866
5	97	56	87	68	74	80	88	63	80	87	780

다. 표 1에서 보이는 바와 같이 임계치를 조절하여 학습할 수 있으며, 임계치가 낮을수록 각 판별자에 학습 되는 학습 문자수가 줄어드는 것을 볼 수 있다. 그러나 임계치가 낮아질수록, 유사한 문자에 대하여 학습하지 않고 통과함으로 학습회수는 줄어들지만, 오인식 가능성이 높아진다.

표 2는 임계치를 조절하여 학습 하였을 때, 학습된 전체 문자의 인식률을 보이고 있다. 표에서와 같이 모두 학습하였을 경우에는 1000개의 글자 중에서 993자를 인식하여 99.3%의 인식률을 가지며, 7개를 오인식 한다. 오인식을 가지는 이유는 램이 포화상태에 이르러 정확한 값을 추출하기 어렵기 때문이다[15]. 임계치를 30으로 하여 유사한 패턴에 대하여 통과할 경우에는 86.6%, 임계치를 5로 거의 통과시키면 78.0%의 인식률을 얻었다. 표에서와 같이 각 램에 누적된 값들이 포화 상태가 될 경우에는 오인식된다. 그림 13은 오인식된 문자를 보인다.



그림 13 오인식 문자

표 3은 그림 13에서 오인식된 문자의 인식 결과이며, 첫 번째 글자는 7로 학습되어 있으나 9자로 인식하였으며 순서대로 오인식된 결과를 보인다.

표 3 인식된 결과

학습 숫자	7	5	3	7	9	3	3
인식된 숫자	9	6	9	8	0	9	5

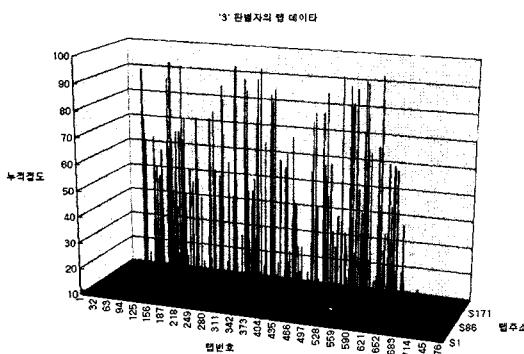


그림 14 '3' 판별자의 램에 저장된 데이터

그림 14는 학습과정을 마친 각 판별자들의 내부 상태를 나타내며, 예제로 '3' 판별자의 784개의 램의 내부 상태를 나타내었다. X축은 판별자 내부의 1에서부터 784까지의 신경세포들을 의미하며, Y축은 각 신경세포들의 0에서부터 255까지의 램 주소를 의미하고, Z축은 학습 과정동안 각 신경세포들의 램 주소에 기억된 학습정보량을 의미한다.

각 판별자 내부 램에 누적된 합은 동일한데, 이로 학습정보가 누적됨을 알 수 있다. 그래프가 높은 부분은 여러 번 학습된 부분이며, 다른 부분보다 강한 특징점에 해당한다.

이 중에서 어느 정도 이상의 높이에 해당하는 부분만으로 패턴을 재구성하면 학습된 여러 개의 패턴 중에서 특징점을 찾아 낼 수 있다.

각 판별자의 내부 상태는 각각 다른 상태를 지니고 있음을 볼 수 있는데, 먼저 Y축의 신경세포 번호가 다른 이유는 판별자에 저장할 신경세포번호를 선택하는 정보가 각각 다른 원형이미지에 의해서 결정되기 때문이다. 즉 원형이미지의 픽셀 값이 0인 경우는 해당 신경 세포에 정보를 기억하지 않기 때문에 Z축의 값은 0인 상태로 있게 되고, 픽셀 값이 1인 부분의 해당 신경세포에만 학습된 값이 쌓이게 된다. Z축에서 총합이 다른 이유는 학습된 패턴 회수가 다르기 때문이다. 마지막으로, 그림과 있는 램 주소가 틀린 이유는 입력으로 사용되어지는 필기체 이미지와 원형 이미지에 의해서 결정되어지기 때문이다.

그림 15와 16은 램에 인식된 숫자의 일반화 된 문자를 보이는 것이다. 그림 15는 원형 패턴의 학습 과정에서 누적된 값으로부터 추출한 이미지로써 픽셀 값이 진



그림 15 원형 패턴의 픽셀 중요도



그림 16 학습된 데이터의 일반화 패턴

할수록 중요도가 높다는 것을 의미 하여, 망의 구성이 특정 픽셀의 중요도를 저절로 결정하기 때문에 임의로 조절할 수는 없다. 그림 16에는 특정 임계치를 이용하여 입력된 숫자의 일반화 정도를 구할 수가 있다.

오인식이 발생할 경우에는 판별자의 내부 저장 상태를 보고 실험을 통하여 기준치를 지정 해줌으로써 오인식 발생을 줄일 수 있다.

결과적으로 임계치가 작으면 학습 회수가 작은 잡음까지도 출력하게 되어 오인식이 줄어들지 않고, 임계치가 높아질수록 강한 공통점만 선택함으로써 잡음이 제거된 일반화 패턴을 추출할 수 있다. 반면에 임계치가 너무 크면 공통 특징점까지 제거해서 인식률도 줄어들었다.

4.2 학습하지 않은 패턴에 대한 인식 실험

표 4에는 주어진 전체 데이터에서 앞에서 10개씩만 학습한 후, 학습하지 않은 문자에 대하여 귀한 시키지 않은 패턴들의 인식률을 보이고 있다. 표에서 보이는 바와 같이 원형 패턴에서 학습 여부를 결정짓는 픽셀들에 의하여 결정되는 램에 '1'자처럼 중복되는 픽셀들이 많은 패턴들은 학습하지 않고도 매우 높은 인식률을 보이며, 반대로 '5'자와 같이 중복되는 픽셀이 많이 없을 경우에는 낮은 인식률을 보인다. 본 신경망의 특성상 단순히 패턴을 누적함으로 반복되는 픽셀이 아니라, 튜플 방법에 의하여 결정되는 램 주소이기 때문에 어떤 픽셀들의 중복인지는 알 수 없다.

학습된 문자에 대하여는 100글자를 모두 인식하였고, 학습되지 않은 문자에 대하여 754(83.8%)자를 인식하였다. 학습 패턴의 수가 작을 경우에는 학습되어진 패턴들은 정확하게 인식되며, 학습되어지지 않은 패턴들은 일반화 패턴들과 비교하여 그 일반화 패턴과 유사한 패턴으로 결정되었다.

표 4 학습 문자에 따른 학습되지 않은 문자에 대한 인식

숫자 학습회수	인식	0	1	2	3	4	5	6	7	8	9	합
10	학습문자	10	10	10	10	10	10	10	10	10	10	100
	비학습문자 (각 90개)	84	87	81	73	81	58	73	71	56	67	754

이 실험을 통하여 패턴들을 전처리함으로써 입력 패턴들의 수를 줄이거나 패턴 특징들을 추출함으로써 작은 수의 학습으로도 매우 높은 인식률을 가질 수 있다 는 것을 보인다.

5. 결 론

본 논문에서는 추가학습과 반복학습이 가능한 3-D 뉴로 시스템에 귀환 기법이 통합된 모델(3-D Neuro System With Feedback)을 제안하고 있으며, 성능을 검정하기 위하여 MNIST에서 제공되는 필기체 숫자 자료를 이용하여 실험 하였다. 3-D 뉴로 시스템으로 구성되는 학습망의 학습된 정보로부터 일반화된 패턴을 추출할 수 있었고, 이렇게 도출된 일반화 패턴을 기반으로 귀환 과정을 통해 미지의 입력 이미지를 원형 이미지로 재인식 시킬 수 있었다. 학습망의 결과 데이터를 인식망의 입력으로 하여 최종 결론을 내리도록 하였다. 이러한 시스템 구성은 인간의 패턴인식 과정과 매우 유사하며, 인간심리와 같이 학습된 문자의 일반화 패턴과 더 유사한 패턴으로 오인식 하는 결과를 도출했다.

MNIST 데이터에 대해서 인식률을 조사하였고, 그 결과로 학습 데이터에 대해서는 99.3%의 인식률을 얻었다.

육안으로도 구별하기 힘들 정도의 구조적으로 유사한 이미지의 경우나 입력 정보 피셀수가 지나치게 많거나 너무 적은 경우에 오인식이 발생 하였는데, 이러한 오인식을 줄이기 위한 연구와 하나의 문자만을 인식하는 문자 인식 시스템 보다는 궁극적으로는 문서를 인간 수준으로 인식할 수 있는 시스템을 개발하기 위한 연구가 진행되어야 할 것이다. 그리고 최종적으로 인간의 뇌와 유사하게 동작할 수 있도록 하나의 판별자만을 이용하여 완전하게 인식할 수 있는 시스템으로의 연구를 진행 중이다.

참 고 문 헌

- [1] 이성환, “오프라인 필기체 문자인식 기술의 현황”, 한국정보과학회지, 제11권 제5호, 1993년 10월.
- [2] 이성환, “패턴인식의 원리”, 홍릉과학출판사, 1994.
- [3] Amari and Mori, “Introduction to Neural Network,” Treecaps WS, 1991.
- [4] I. Aleksander and H. Morton, “An Introduction to Neural computing,” Chapman & Hall, 1990.
- [5] Aleksander, I., Thomas, W. V., and Bowden, P. A. 1984 "WISARD a radical step forward in image recognition," Sensor Review, July 1984, 120-124.
- [6] Lee, S. D, "Dynamics of Feedback for Artificially Intelligent Pattern Recognition," MSc. Dissertation, Brunel Univ., England, 1981.
- [7] W. W. Bledsoe and I. Browning, "Pattern Recognition and Reading by Machine," Proc. Eastern Joint Computer Conference, Boston, pp. 232-255, 1959.
- [8] 김성진, 권영철, 이수동, “RAM을 이용한 경험유관측 적신경망모델”, 대한전자공학회, 제41권, CI편, 제2호, 2004.
- [9] Yann LeCun, NEC Research Institute, <http://yann.lecun.com/exdb/mnist/index.html>.
- [10] J. Austin, "A review of RAM based neural networks," pp. 58~66. Microelectronics for Neural Networks and Fuzzy Systems, IEEE. 1994.
- [11] I. Aleksander T. J. Stonham, "Guide to pattern recognition using random-access memories," Computers And Digital Techniques, 2(1):29~40, 1979.
- [12] W W Bledsoe I. Browning. "Pattern recognition and reading by machine," In Proc. Joing Comp. Conference, pp. 255~262, 1959.
- [13] Peter Russel, “인간의 두뇌”, 학습과학사, 1996.
- [14] 신현정, “개념과 범주화”, 아카넷, 2000.
- [15] E. C. D. B. Filho, M. C. Fairhurst and D. L. Bisset, "Analysis of Saturation Problem in RAM-Based Neural Network," pp. 345~346. Electronics Letters, Vol. 28, No. 4, February 1992.



김 성 진

1996년 울산대학교 컴퓨터공학과(학사)
1998년 울산대학교 컴퓨터공학과(석사)
2000년~2004년 (주)팜캐스트 기술팀장
2002년 울산대학교 컴퓨터공학과(박사수료). 2005년~현재 울산대학교 객원교수
관심분야는 신경망, 뉴로퍼지 시스템



이 동 형

1996년 울산대학교 컴퓨터공학과(학사)
1998년 울산대학교 컴퓨터공학과(석사)
2000년 울산대학교 컴퓨터공학과(박사수
료). 2001년~현재 한국폴리텍VII 울산대
학 정보통신시스템 조교수. 관심분야는
인공지능, 신경망, 뉴로퍼지 시스템, 지능

형 로봇



이 수 동

1969년 서울대학교 전자공학과(석사). 1980
년 Brunel University(석사). 1984년
Brunel University(박사). 1976년~2004
년 울산대학교 컴퓨터 정보통신 공학부
교수. 2005년~현재 울산과학대학 학장.
관심분야는 인공지능, 신경망, 소프트 콤

퓨팅