

# 적응적 가중치를 이용한 RAM 기반 누적 신경망

이동형<sup>†</sup>, 김성진<sup>\*\*</sup>, 권영철<sup>\*\*\*</sup>, 이수동<sup>\*\*\*\*</sup>

## 요 약

RAM 기반 신경망은 빠른 처리 속도와 하드웨어 구현의 용이성 등의 장점을 가지고 있지만 반면에 메모리의 포화 문제, 반복학습, 일반화 패턴 추출의 어려움 등의 단점도 가지고 있다. 이런 단점을 극복하기 위해 누적 다중 판별자를 가지는 3차원 뉴로 시스템(3DNS) 등이 제안되었지만 메모리 포화 문제는 해결하지는 못하였다. 본 논문에서는 메모리 포화 문제를 해결하기 위하여 적응적 가중치를 가지는 AWN(Adaptive Weight Neuron)을 사용한 적응적 가중치 누적 신경망(AWCNN)을 제안한다. 제안된 모델은 AWN으로 3DNS를 개선하여 인식률과 메모리 포화 문제 해결을 향상하였다. 제안된 시스템의 평가는 전처리 과정 없이 NIST의 MNIST에서 제공하는 자료를 이용하여 실험하였다. AWCNN은 3DNS보다 1.5%이상의 향상된 인식률을 보였고 일반화 패턴을 이용한 인식에서는 모든 입력 패턴의 교육된 것과 비슷한 성능을 얻었다.

## A RAM-based Cumulative Neural Net with Adaptive Weights

Dong hyung Lee<sup>†</sup>, Seong Jin Kim<sup>\*\*</sup>, Young Chul Kwon<sup>\*\*\*</sup>, Soo Dong Lee<sup>\*\*\*\*</sup>

### ABSTRACT

A RAM-based Neural Network(RNN) has the advantages of processing speed and hardware implementation. In spite of these advantages, it has a saturation problem, weakness of repeated learning and extract of a generalized pattern. To resolve these problems of RNN, the 3DNS model using cumulative multi discriminator was proposed. But that model does not solve the saturation problem yet. In this paper, we proposed a adaptive weight cumulative neural net(AWCNN) using the adaptive weight neuron (AWN) for solving the saturation problem. The proposed nets improved a recognition rate and the saturation problem of 3DNS. We experimented with the MNIST database of NIST without preprocessing. As a result of experimentations, the AWCNN was 1.5% higher than 3DNS in a recognition rate when all input patterns were used. The recognition rate using generalized patterns was similar to that using all input patterns.

**Key words:** AWCNN(적응적가중치누적신경망), 3DNS(삼차원동적뉴로시스템), BNN(이진신경망), saturation problem(포화문제), multi discriminator(다중판별자)

## 1. 서 론

패턴인식 분야는 일상생활 중 접할 수 있는 여러

종류의 대상, 즉 각종 문서, 차량 번호, 얼굴 등을 보았을 때 다양한 범주 중에 하나의 범주로 인식하여 판단하는 인간의 능력을 기계로 구현하는 분야로 매

※ 교신저자(Corresponding Author): 이수동, 주소: 울산광역시 동구 봉수로 101(682-715), 전화: 052)290-1590, FAX: 052)290-1519, E-mail: sdlee@ulsan.ac.kr

접수일: 2009년 8월 10일, 수정일: 2009년 10월 1일

완료일: 2009년 10월 26일

<sup>†</sup> 정회원, 한국폴리텍 VII대학 울산캠퍼스 정보통신시스템 과 부교수

(E-mail: sunhook@dreamwiz.com)

<sup>\*\*</sup> 정회원, 울산대학교 컴퓨터정보통신공학부 객원교수 (E-mail: sjkim326@mail.ulsan.ac.kr)

<sup>\*\*\*</sup> 거제대학 컴퓨터정보계열 교수

(E-mail: yckwon@koje.ac.kr)

<sup>\*\*\*\*</sup> 울산대학교 컴퓨터정보통신공학부 교수

우 활발하게 연구가 진행 중이다.

패턴인식의 대표적인 모델로는 원형 정합을 이용한 방법, 확률 통계적인 방법, 구조적 방법, 신경 회로망 등이 있으며[1], 이 중 신경회로망이 우수하다고 알려져 있다. 대표적인 신경회로망인 오류역전파 방법은 많은 학습 시간과 추가학습이 일어나면 처음부터 다시 재학습이 요구되는 단점과 기존에 학습된 패턴과 유사한 학습 패턴을 학습시키면 일반화 패턴의 정확도가 낮아지는 문제점 등을 가지고 있다[2]. 이런 문제점들을 해결하기 위해 Aleksander와 Stonham이 메모리 구조의 형태를 갖고 있는 RAM 기반의 WNN (Weightless Neural Network, BNN)을 제안하였다[3-6]. WNN은 빠른 학습 및 뛰어난 처리 속도, 그리고 하드웨어 구현의 용이성 등의 장점이 있지만 반면 반복 학습, 일반화 패턴 추출, 메모리 포화 문제[7]등의 단점도 가지고 있다. 반복 학습 및 일반화 패턴 추출의 단점을 해결하기 위해 Feedback 기법[8]과 3-D 기법[9,10]을 제안하여 특징점을 누적할 수 있는 동적 특성을 갖는 모델[11]이 제안되었으며, 그리고 신경소자의 메모리 포화 문제를 해결하기 위해 적응적 가중치[12] 및 제한적 가중치[13], 다중 판별자[4,14] 등이 연구되었다. 추가 및 반복 학습이 가능한 경험유관 축적 신경망(Experience Sensitive Cumulative Neural Network: ESCNN)[10]과 동적 3차원 뉴로 시스템(3-D Neuro System: 3DNS)[11]은 다중 판별자를 이용하여 메모리 포화 문제를 어느 정도 해결했지만 각 판별자의 학습패턴 개수가 일정량 이상이면 인식률이 급격하게 떨어지는 문제점을 가지고 있다. 학습량의 다양한 변량에도 개선된 WNN의 기능과 메모리 포화 문제를 해결할 수 있는 연구가 필요하다라고 생각된다.

본 논문에서는 삼차원 뉴로 시스템을 개선하여 추가 및 반복 학습이 가능하고 용이한 일반화 패턴의 추출 그리고 메모리 포화 문제를 극복할 수 있는 적응적 가중치를 이용한 누적 신경망을 제안한다. 제안된 모델은 학습을 통하여 각 범주에 대한 누적된 정보를 가지는 판별자와 정규화된 가중치 정보를 가지는 적응적 가중치 뉴런(AWN)을 만들어 각 신경세포들의 일반화 패턴을 생성하여 인식률을 높였다. 그리고 인식 단계에서 3DNS의 귀환회로를 제거하여 인식 시간에 대한 효율성을 높였다. 제안된 시스템을

평가하기 위해 NIST의 MNIST[15] 데이터베이스에서 제공하는 오프라인 필기체 숫자를 임의로 추출하여 학습과 인식에 사용하였다.

본 논문의 구성은 2장에서는 동적 3차원 뉴로 시스템에 대하여 설명하고, 3장에서는 적응적 가중치를 이용한 램 기반 누적신경망에 관해 소개하며, 4장에서는 제안된 모델과 3DNS를 사용하여 MNIST의 자료를 이용하여 실험 비교하며, 마지막 5장에서는 결론 및 향후 연구방향을 제시하였다.

## 2. 동적 3차원 뉴로 시스템

Bit 주소 정보를 가지는 이진 신경망(BNN)의 신경세포를 Byte 단위로 변환한 동적 3차원 뉴로 시스템(3DNS)은 그림 1과 같이 N개의 입력에 대하여  $2^N$  Byte 크기인 RAM으로 구성된다[11]. 내부적으로 귀환회로를 두어 신경세포 내부에 기억된 정보를 귀환하여 연산할 수 있도록 되었다.

T값은 입력 패턴에 대응하는 원형 패턴의 픽셀 값이며, T=1이면 입력 패턴의 내용과 동일한 내용으로 기억시킨다. 학습은 입력층으로부터 N-tuple [16,17] 기법을 이용하여 N개의 노드로 샘플링하여, 랜덤하게 선택된 디코더기에 의해 (1)식과 같은 이진수 형태의 주소로 정보화된다[10]. 선택된 램 내부에 기억된 값을 귀환시켜 학습정보 T와 연산한 후, 그 결과를 다시 0 또는 1을 누적하여 학습이 이루어진다.

$$\text{Address} = 2^N + 2^{N-1} + \dots + 2^1 \tag{1}$$

인식 단계는 학습 과정과 같이 N-tuple의 픽셀을 선택하여 랜덤하게 선택된 디코더에 주소화한 후, 기억 정보가 저장된 신경세포의 해당 램 값을 가져온다. 해당 램을 통해 생성된 정보가 일정한 값 이하이면 입력으로 다시 귀환하여 만족할 만한 결론을 얻을




그림 1. 3DNS 신경세포




그림 2. 3DNS 패턴 인식기




그림 3. 신경회로망의 판별자

때까지 반복 수행한다. 그림 2는 3DNS의 패턴 인식기 구성도이다[11].

3DNS는 각 신경세포에 전체의 입력 노드로부터 N개의 노드씩 연결됨으로 입력 노드 전체를 기억하기 위해서는 그림 3과 같이 복수개의 이진 신경세포로 구성된 판별자(Discriminator)를 사용하며, 하나의 인식 범주에는 독립된 하나의 판별자를 할당한다 [11]. 입력의 전체 노드 수가 R개이고, N-tuple을 사용할 경우 필요한 판별자 크기(K)는 (2)식과 같다[9].

$$K = (R/N) \times 2^N \text{ (Byte)} \quad (2)$$

또 인식 범주의 개수가 L개일 경우 전체에 필요한 램의 크기(T)는 (3)식과 같다.

$$T = K \times L \\ = (R/N) \times 2^N \times L \text{ (Byte)} \quad (3)$$

### 2.1 다중 판별자

다범주에 대한 패턴 인식의 경우 인식률을 높이기 위해서는 다중 판별자를 사용한다. 이를 사용한 예로는 WISARD(Wilkie, Stonnen and Aleksander's Recognition Device)[4,14] 시스템과 경험 유관 누적 이진신경망[9] 등이 있으며 그림 4는 동적 3차원 뉴로 시스템의 다중 판별자를 보여주고 있다.

학습 단계에서 각 범주별 학습이 이루어지면서 판별자의 램에 값을 할당한다. 인식 단계에서는 그림 4와 같이 학습된 판별자의 응답값인 R값의 최대값인 MRD(Maximum Response Detector)를 구하여 선택된 MRD의 판별자 범주로 패턴이 인식된다.

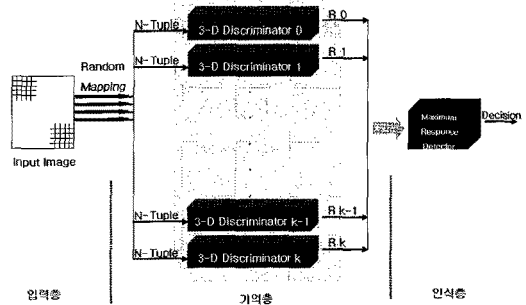


그림 4. 다중 판별자

## 3. 적응적 가중치를 이용한 램 기반 누적 신경망

인간은 수많은 경험을 통하여 부분적이면서 단편적인 지식들을 축적하여 하나의 일반화된 공통적인 특징들을 추출하여 기억을 형성한다. 이는 누적된 정보를 이용하여 일반화 및 반복 학습에 의해 강하게 반응하면 더욱 강하게 기억되고 적게 반응되면 일반화 정보에서 누락되어 망각된다. 제안된 신경망은 학습을 통하여 교육된 정보들이 누적으로 표현되고, 일반화 및 반복 학습은 임의의 임계값보다 높은 누적 정보들로 만들어지고 임계값보다 낮은 정보들은 제거되면서 망각 기능을 구현한다[9].

그림 5와 같이 3DNS의 신경세포를 1바이트 단위에서 2바이트인 half word 단위로 변환하여 신경세포의 누적값을 최대 65536까지 기억할 수 있는 램을 사용하였고, 내부적으로 연산기를 두어 신경세포 내부에 기억된 정보를 귀환하여 연산할 수 있도록 하였다.

학습은 3DNS와 같은 프로세스로 진행되면서 메모리 포화 문제를 해결하기 위하여 적응적 가중치 신경 단위(Adaptive Weight Neuron: AWN)를 별도로 추가한다. AWN은 각 범주별 입력 패턴의 원형을 그대로 누적하여 정규화 처리를 하면서 적응적 가중

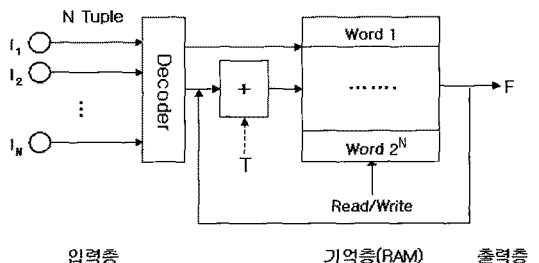


그림 5. 누적 신경망 신경세포

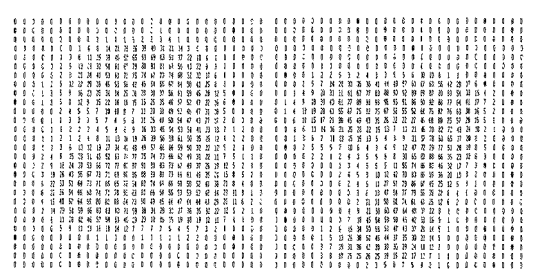
치를 가지는 것으로 인식 단계에서 재활용된다.

인식은 학습에서와 동일한 순서로 N-Tuple의 픽셀을 선택하여 디코더에서 주소정보화한 후, 신경세포의 해당 램에 저장되어 있는 값을 가져온다. 이때 출력은 학습의 누적 회수 값을 나타내기 때문에 반복 학습이 많이 이루어진 패턴에 대해서는 상대적으로 높은 값이 출력된다. 그리고 출력값 F에 적응적 가중치 신경 단위인 AWN과 입력 패턴을 재사용하여 각 범주별 응답 신호의 특성을 높여주는 시스템인 적응적 가중치 누적 신경망(Adaptive Weights Cumulative Neural Net: AWCNN)을 제안한다.


### 3.1 적응적 가중치 신경 단위(Adaptive Weight Neuron)

적응적 가중치 신경 단위(AWN)는 학습 과정에서 발생하는 학습 정보를 이용하여 생성된다. AWN은 학습하는 동안 범주별 교육 패턴의 신경 단위로 정규화된 값들의 누적합으로 생성되며, 이후 적응적으로 갱신된다.

이런 과정은 각 범주별 패턴에 대한 공통 특징점의 중요도를 일정하게 유지하면서 범주별 특징점에 대한 최적의 가중치를 생성한다. 그림 6의 (a)와 (b)는 숫자 2와 7에 대한 100회, 1000회 학습을 통한 비정규화된 교육 샘플들의 누적합을 보여주고 있다.



(a) 100개 교육 누적 분포



(b) 1000개 교육 누적 분포

그림 6. 교육 누적 분포




그림 7. AWN을 이용한 응답값

그림 7은 인식하는 동안 판별자를 통하여 만들어진 GenImage와 AWN의 응답값 R을 구하는 과정을 보여주고 있다. 학습이 시작할 때 AWN은 0으로 초기화하여 0과 1사이의 값을 갖는다. 그리고 인식하는 동안 범주별 같은 AWN들을 이용하여 MRD를 구한다.

### 3.2 적응적 가중치 누적 신경망의 MRD 기법

다중 판별자를 가지는 램 기반 신경망에서 인식 판별을 결정하는 방법으로 MRD (Maximum Response Detector) 기법이 주로 사용된다. 램 기반 다중 판별자를 가지는 신경망의 일반적인 MRD 방법은 판별자를 통하여 생성된 입력 이미지의 각 범주별 신경세포들의 합인 응답(R(k))값들을 비교하여 최고의 응답값 두 개를 선택한 후 그 차(d=R<sub>best</sub>(k)-R<sub>best-1</sub>(k))를 구한다. 차를 이용하여 상대적 신뢰도 C=d/R<sub>best</sub>(k)를 구한 후 신뢰도 C의 범위에 의해 인식 범주를 선택적으로 결정한다[6]. 그러나 학습량이 판별자의 포화 상태 이상이면 차이 d가 신뢰값 이하가 되기 때문에 인식률이 급격하게 떨어진다. 이런 문제점을 해결하기 위해 본 논문에서는 적응적 가중치 신경단위인 AWN을 이용한 마스크 기법의 AWN MRD 방식을 제안한다. AWN MRD는 두 개의 마스크를 사용한다. 첫 번째는 교육하는 동안 학습되는 이미지들의 정규화된 각 픽셀의 누적값으로 생성되는 AWN 마스크이고 두 번째는 판별자에 의해 만들어진 생성 이미지(GenImage)의 마스크이다.

그림 8에서 I(i)값은 인식 입력 이미지이고, A(i)는




그림 8. AWN MRD 기법

교육된 이미지의 정규화된 누적 이미지, G(i)는 판별자를 통한 생성된 이미지이다. 각 범주별 응답값  $F(i) = I(i) \times A(i) \times G(i)$ 이며 F(i)의 전체 합, 즉  $R(k) = \sum_i F(i) \times 100$ 이다.

3.3 학습과 인식

전처리 과정 없이 랜덤하게 입력을 받아 처리하는 적응적 가중치 누적 신경망의 패턴 인식기는 그림 9와 같이 구성되어 있다.

학습망에서는 N-Tuple 방법인 (1)식을 이용하여 입력 주소 정보를 생성한 후 램으로 구성된 다중 판별자의 해당 주소에 정보를 가지고 온다. 만약 학습망에서 (4)식의 임계값 이하이며 귀환회로를 사용하여 램의 내부 값과 원형이미지의 입력된 정보를 연산하여 램에 누적하여 기억시킨다. 학습 여부의 판단은 원형이미지의 픽셀들의 합과 학습된 판별자에서 생성된 생성이미지의 유효값들의 합이 100%이하이면 학습을 진행한다.

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

GenImage : 생성된 이미지 유효 픽셀 합,  
 PrototypeImage : 원형이미지 픽셀 합,  
 M : 사상 매칭 개수, P : 이미지 총 픽셀의 개수

여기서 M은 생성 및 원형 이미지의 매칭 개수이고, P는 이미지들의 총 픽셀 개수이다. 임계값에 따라 학습되는 패턴의 유사도가 결정되며, 이는 학습량과 메모리 포화도에 영향을 줄 수 있다.

인식망에서는 각 범주별 판별자에 의하여 생성된 이미지를 (4)식에 적용하여 임계값 이상인 범주를 찾아 생성된 이미지를 정규화 시킨다. 그리고 생성된 정규화 이미지와 입력 이미지 그리고 AWN을 이용




그림 9. AWCNN 인식 시스템




그림 10. AWCNN 구성도

하여 입력 이미지의 변형 및 노이즈를 제거한다. 이를 이용하여 입력 이미지와 원형이미지의 유사도를 결정하여 인식한다. 인식 단계에서 MRD 값이 임계값보다 작으면 기준 이하로 판단하여 '인식불가' 판정을 내리고 오인식으로 종료한다.

4. 실험 및 고찰

본 논문의 제안 시스템은 RAM 기반 신경망의 가장 큰 문제점인 학습량의 집합이 증가함에 따른 메모리 포화 문제와 그로 인한 인식을 저하를 가중치를 이용하여 해결하려 한다. 실험에서는 3DNS와 AWCNN를 비교하여 보았다. 기존의 RAM 기반 신경망은 신경세포가 1바이트 단위이므로 최대 학습량이 256개이지만 AWCNN의 신경세포는 2바이트 단위의 워드로 65536개까지 학습이 가능하다. 실험에 사용된 데이터는 전처리 과정 없이 28x28픽셀의 고정된 크기이며 무작위로 입력받아 정규화를 취한 후 처리하였다. NIST의 오프라인 필기체 숫자 데이터 [15]를 임의로 각 숫자마다 50개, 100개, 200개씩 추출하여 AWCNN과 3DNS를 비교하였고 AWCNN은 500개 및 1000개까지 실험하여 보았다. 그림 11은 실험에 사용된 원형 이미지이고, 그림 12는 학습과 인식에 사용된 데이터 이미지 샘플들이다.

표 1은 3DNS의 임계값을 100으로 처리한 평균 오인식률을 나타낸 것이다. 사용되는 데이터가 임의로 선택되어 학습됨으로 인식률이 약 ±2% 정도 차이가 발생되지만 각 숫자마다 평균 오인식은 200개 학습



그림 11. 학습에 사용된 원형 이미지




그림 12. 학습에 사용된 데이터 이미지 샘플

표 1. 3DNS 평균 오인식률 단위(%)

숫자 학습량	0	1	2	3	4	5	6	7	8	9	평균
200	5.3	0	10.2	1.3	8	18.2	1.3	0.3	2.7	2.5	5
100	2	0	6.0	0.3	6	11.3	0.7	1.3	1.0	0	2.9
50	0	0	1.3	0	0	6.7	0	0.7	1.3	0	1




그림 13. 3DNS 100개 학습에 대한 오인식 이미지들

일 경우 5%, 100개 일 때 2.9%, 50개 일 때는 1%의 오인식이 되며, 학습량이 50미만인 경우 0%로 오인식이 된다.

#### 4.1 AWCNN 실험

적응적 가중치 단위인 AWN을 이용한 AWCNN 인식 시스템은 판별자에서 나오는 생성된 이미지와 입력 이미지를 (4)식에 의해 범주별 응답값에 대한 임계값을 구한다. 그리고 임의의 임계값 이상인 범주의 응답값 R(k)값에 AWN을 이용하여 MRD를 구하였고 이를 최종 인식 범주로 결정한다. 임계값 이상의 값들을 선택하였기 때문에 임계값 이하인 범주의 응답값 R(k)은 구할 필요가 없다. 이는 모든 범주의 R(k)값을 구하는 일반적인 모델에 비해 상대적으로 빠른 인식 시간을 갖는다. 그리고 AWCNN은 인식 단계에서 귀환회로를 사용하지 않기 때문에 한 번의 처리로 모든 인식 판별이 가능함으로 3DNS보다 인식 시간의 향상성을 가진다. 표 2는 AWCNN을 사용한 오인식률을 보여준다. 각 숫자당 200개 학습일 경우 평균 오인식률은 3.8%, 100개 일 때 1.7%, 50개 일 때는 0.7%의 오인식이 되며, 500개 및 1000개 학습일 때 9.4%와 12.9%로 오인식이 나타난다. AWCNN

표 2. AWCNN 평균 오인식률 단위(%)

숫자 학습량	0	1	2	3	4	5	6	7	8	9	평균
1000	6.7	0	33.2	3.7	15.4	26.5	2.5	0.3	27	13.6	12.9
500	4.8	0	31.6	0.4	8.6	21.8	1.2	0.2	15	10.6	9.4
200	2.8	0.2	6.3	0.2	4.8	11.2	0.5	0.5	5.2	6.7	3.8
100	0.7	0	4.7	0	3.3	4.7	0	0	3.0	0.7	1.7
50	0	0	1.3	0	0	3.3	0	0	2.7	0	0.7




그림 14. AWCNN 100개 학습에 대한 오인식 이미지들

의 인식률을 3DNS와 비교하여 보면 하나의 범주에 100개 이하의 교육이 이루어질 경우 평균 약 1%이하의 향상된 인식률을 보이지만 100개 이상인 경우는 1% 이상의 높은 인식률을 얻었다.

#### 4.2 일반화 패턴 실험

AWCNN의 일반화 패턴은 학습을 통하여 이루어진다. 학습에서 누적된 특징점을 추출하여 교육된 정보의 일반화 패턴을 생성한 후 인식에서 재사용하며, 그림 9와 같은 시스템으로 이루어진다. 표 3은 학습에 대한 일반화 패턴의 학습량을 보여준다. 학습량 범위가 증가함에 따라 램에 기억되는 학습수 비율은 그림 16과 같이 감소된다. 이는 초기에는 다양한 형태의 학습 입력 패턴이 학습되기 때문에 같은 비율로 학습되지만 학습 입력 패턴량이 증가되면서 판별자의 누적값에 의해 일반화 패턴이 생성되고 생성된 일반화 패턴으로 학습 유무를 판단하여 학습을 진행시킨다. 그리고 일반화 패턴이 생성된 후 추가 및 반복학습에 의해 적응적으로 가중치가 조절되면서 일반화 패턴을 재구성한다. 범주별 일반화 학습 개수를 비교하여 보면 50개일 경우는 81.4%의 교육으로 일반화를 취하지 않은 비일반화된 인식률과 비슷한 결과를 얻었고, 1000인 경우에는 단지 27.1%의 교육을 통하여 일반화를 취하지 않은 인식 결과값과 비슷한 인식률을 얻었다. 표 4는 일반화 패턴을 이용하여 각 숫자당 오인식률을 나타내었다. 그림 15는 1000개 학습에 대한 숫자 7의 교육 일반화 패턴을 보여주고 있다. 숫자 7에 대한 AWCNN의 일반화 패턴은 1000개의 학습 입력에 대하여 139개만의 교육으로 일반

표 3. AWCNN을 이용한 일반화 패턴 학습개수 비율

단위(%)

학습량 범위 \ 숫자	0	1	2	3	4	5	6	7	8	9	평균
1000	17.3	7.9	56.6	39.4	22.8	40.4	13.6	13.9	48.5	10.8	27.1
500	26.6	12.4	69.2	50	35.2	42.2	22.4	22.4	57	18.4	35.5
200	47	25.5	58	58.5	49	54.5	36.5	39.5	76	41	48.5
100	64	36	72	67	65	78	55	55	93	58	64.3
50	82	48	86	84	86	90	80	80	90	88	81.4

표 4. AWCNN을 이용한 일반화 패턴 평균 오인식률

단위(%)

학습량 범위 \ 숫자	0	1	2	3	4	5	6	7	8	9	평균
1000	6.4	0	30.3	1.6	11.3	31.2	5.1	0.3	17.3	14.6	11.8
500	5.2	0	28.4	0.6	8	28.8	2.8	0	11.8	8.2	9.3
200	2.5	0	10	0.5	9	17	2.5	0	4	2.5	4.8
100	0	0	7	0	7	11	1	0	0	0	2.6
50	0	0	2	0	0	4	0	2	0	0	0.8




그림 15. 1000개 학습량에 대한 7의 교육 일반화 패턴

화 패턴을 생성한다. 이를 이용하여 1000개를 인식하면 3개만 오인식이 발생된다. 그림 16은 입력되는 교육 패턴을 모두 교육한 비일반화와 일반화 처리한 일반화 오인식률을 나타낸 것이다.

일반화 패턴으로 처리된 시스템은 학습개수의 범




그림 16. 일반화 패턴을 이용한 학습량 대 인식률

위가 증가함에 따라 기억되는 학습수는 작아진다. 그러나 인식에 대한 오인식률은 학습 개수에 상관없이 비슷한 값을 갖는다. 이는 일반화 패턴으로 학습하지 않은 패턴에 대하여도 인식이 가능하며, 이를 이용한다면 램 기반 신경망의 메모리 포화 문제의 해결하는 방안이 제시될 수 있다.

### 5. 결 론

대부분의 램 기반 신경망은 빠른 학습 및 인식 시간과 하드웨어 구현의 용이성을 갖고 있지만 추가학습 및 반복학습, 그리고 일반화 패턴의 추출, 메모리 포화 문제 등의 단점을 가지고 있다. 이런 단점을 개선한 ESCNN과 3DNS는 누적 다중 판별자를 사용하여 추가 및 반복 학습 그리고 일반화 패턴 생성 등의 문제점을 해결하였다. 3DNS는 귀환회로를 추가하여 미지의 입력 이미지를 원형 이미지로 재인식시켜 일반화 패턴을 재구성하는데, 이는 일반화 패턴을 강제적으로 수렴함으로써 유사한 패턴의 결과값으로 오인식이 발생하는 경우가 있다. 또한 학습 개수가 증가함에 따라 메모리 포화 문제 및 바이트 단위의 신경세포를 사용함으로써 누적 개수가 256까지만 학습되는 학습량의 문제점 등이 있다.

본 논문에서는 추가학습 및 반복학습이 가능하며,

램 기반 신경망의 가장 큰 문제점인 판별자의 메모리 포화 문제를 극복하기 위해 적응적 가중치를 이용한 누적 신경망(AWCNN)을 제안하였다. 성능을 검증하기 위하여 NIST에서 제공하는 오프라인 필기체 숫자 자료를 이용하였다. 인식률에서 3DNS와 비교하여 보면, 하나의 범주에 학습량이 적은 경우에는 거의 비슷한 인식률을 갖지만 100개 이상일 경우에는 1%이상의 더 높은 성능을 가졌다. 그리고 한 범주에 대한 학습량이 1000개일 경우에도 높은 인식률을 보였다. 그리고 인식 단계에서 귀환회로 제거 및 일정한 임계값 이상의 판별자들만 선택적으로 판별하기 때문에 인식 시간이 3DNS보다 단축되었다.

일반화 패턴 생성에서는 학습 단계에서 귀환회로를 사용하여 학습 여부를 판단하여 학습하였고 인식 단계에서는 귀환회로 없이 입력 이미지와 적응적 가중치 신경세포인 AWN을 사용하여 최소의 교육을 통하여 전체 교육과 같은 비슷한 성능을 보였다. 이는 메모리 포화 문제의 해결 방안이 될 수 있다. 앞으로의 연구 방향은 본 알고리즘에 맞는 전처리 과정 삽입 및 MRD 방법을 보완하여 많은 범주를 갖고 있는 필기체 한글 및 한자로의 확장과 하드웨어 구현이 요구된다.

## 참 고 문 헌

- [1] 이성환, "오프라인 필기체 문자인식 기술의 현황," 한국정보과학회지, 제11권, 제5호, pp. 51-65, 1993.
- [2] Amari and Mori, "Introduction to Neural Network," *Treecaps WS*, 1991.
- [3] I. Aleksander and H. Morton, "An Introduction to Neural computing," Chapman & Hall, 1990.
- [4] I. Aleksander, W. V. Thomas, and Bowden, P. A., "WISARD a radical step forward in image recognition," *Sensor Review*, pp. 120-124, 1984.
- [5] I. Aleksander and T. J. Stonham, "Guide to pattern recognition using random-access memories," *Computers and Digital Techniques*, Vol.2, pp. 29-40, 1979.
- [6] I. Aleksander, T. J. W. Clarke and A. P. Braga, "Weightless Neural System: A Unified Approach to Their Analysis and Design," *ICONIP '94 Tutorial*, 1994.
- [7] E. C. D. B. Filho, M. C. Fairhurst, and D. L. Bisset, "Analysis of Saturation Problem in RAM-Based Neural Network," *Electronics Letters*, Vol.28, No.4, pp. 345-346, 1992.
- [8] S. D. Lee, *Dynamics of Feedback for Artificially Intelligent Pattern Recognition*, MSc. Dissertation, Brunel Univ., England, 1981.
- [9] 권영철, "경험 유관이진신경망," 울산대학교, 1995.
- [10] 김성진, 권영철, 이수동, "RAM을 이용한 경험 유관축적신경망모델," 대한전자공학회, 제41권, CI편, 제2호, pp. 1251-1254, 2004.
- [11] 김성진, 이동형, 권영철, 이수동, "다중판별자를 가지는 동적 삼차원 뉴로 시스템," 한국정보과학회, Vol.34, No.7, pp. 585-594, 2007.
- [12] E. do Valle Simoes, L.F. Uebel, Y. Ueno, and D.A. Couto Barone, "The Adaptive Weight Using Ram," *In: 1997 INTERNATIONAL CONFERENCE ON SYSTEMS CMAN AND CIBERNETICS, 1997. PROCEEDINGS. EUA.*, v.5. pp. 4053-4056. 1997.
- [13] T.M. Jorgensen, "A RAM-based neural net with inhibitory weights and its application to recognising handwritten digits," *Neural Networks for Identification, Control, Robotics, and Signal/Image Processing, 1996. Proceedings., International Workshop on.*, pp. 228-236, 1996.
- [14] Wickert, I. and Franca. F.M.G., "AUTOWISARD : Unsupervised modes for the WISARD," *Proc of IWANN 2001, Granada, Spain, Lecture Notes in Computer Science*, Vol.2084, pp. 435-441, 2001.
- [15] Yann LeCun, NEC Research Institute, <http://yann.lecun.com/exdb/mnist/index.html>.
- [16] W. W. Bledsoe and I. Browning, "Pattern Recognition and Reading by Machine," *Proc. Eastern Joint Computer Conference, Boston*, pp. 232-255, 1959.



[17] W. W. Bledsoe and C.L. Bisson, "Improved memory matrices for the N-tuple pattern recognition method," *IRE Trans. Electronic Computers*, Vol.EC-11, pp. 414-415, 1962.



**이 동 형**

1996년 울산대학교 컴퓨터공학과 공학사  
 1998년 울산대학교 컴퓨터공학과 공학석사  
 2000년 울산대학교 컴퓨터공학과 박사수료

2001년~현재 한국폴리텍 VII대학 울산캠퍼스 정보통신 시스템과 부교수  
 관심분야 : 신경망, 뉴로퍼지 시스템, 지능형 로봇



**김 성 진**

1996년 울산대학교 컴퓨터공학과 공학사  
 1998년 울산대학교 컴퓨터공학과 공학석사  
 2009년 울산대학교 컴퓨터공학과 공학박사  
 2005년~현재 울산대학교객원교수

2000년~2004년 (주)팍캐스트 기술팀장  
 관심분야 : 신경망, 뉴로퍼지 시스템



**권 영 철**

1981년 울산대학교 전기과 학사  
 1981년 한국전력공사 전산실  
 1984년 현대중공업 전산실  
 1987년 울산대학교 전산기학과 공학석사  
 1995년 울산대학교 전산기공학과 공학 박사

1990년~현재 거제대학 컴퓨터정보계열 교수  
 관심분야 : 신경망, 뉴로 퍼지 시스템



**이 수 동**

1969년 서울대학교 전자공학과 석사  
 1980년 Brunel University 석사  
 1984년 Brunel University 박사  
 1976년~2004 울산대학교 컴퓨터 정보통신공학부 교수  
 2005년~현재 울산과학대학 총장

관심분야 : 인공지능, 신경망, 소프트 컴퓨팅