

논문 2004-41CI-2-10

RAM을 이용한 경험유관축적 신경망 모델

(Experience Sensitive Cumulative Neural Network Using RAM)

김 성 진*, 권 영 철**, 이 수 동***

(Seong-Jin Kim, Young-Chul Kwon, and Soo-Dong Lee)

요 약

제안된 경험 유관 축적 신경회로망은 입력 패턴의 교육 회수를 누적시킬 수 있는 구조를 가지고 있어, 누적된 교육을 통한 공통된 경험에 대해서는 강한 반응을 보이는 주의 집중 기능을 가진다. 그리고 잡음이 많은 패턴에 대하여 선행처리 과정을 거치지 않고 바로 교육을 시켜도 상대적으로 유용한 정보를 누적시켜 일반화 패턴을 추출할 수 있다. 본 논문에서는 추가 교육뿐만 아니라 반복 교육도 가능한 경험 유관 축적 신경회로망 모델을 제안하고, 이 신경회로망이 가지는 기본 특성인 망각 및 주의 집중기능에 대하여 기술하였으며, 또한 교육된 정보로부터 일반화 패턴의 추출 과정과 일반화 패턴의 생성 및 반복 교육에 관한 것을 기술하였다.

Abstract

In this paper, Experience Sensitive Cumulative Neural Network (ESCNN) is introduced, which can cumulate the same or similar experiences. As the same or similar training patterns are cumulated in the network, the system recognizes more important information in the training patterns. The functions of forgetting less important information and attending more important information resided in the training patterns are surveyed and implemented by simulations. The system behaves well under the noisy circumstances due to its forgetting and/or attending properties, even in 50 percents noisy environments. This paper also describes the creation of the generalized patterns for the input training patterns.

Keywords : Neural Network, WNN, Weightless Neural Network, ESCNN

I. 서 론

지금까지 제안된 대부분의 신경회로망은 지식을 각 뉴런 사이의 연결자에 분산 저장시키는 구조로 되어 있기 때문에 대단위의 병렬 계산이 필요하다. 또한 오류 역전파 알고리즘은 교육 패턴에 대하여 인식시킨 출력과 의도한 출력과의 오차를 계산한 다음 오차가 허용 범위

이내로 될 때까지 각 연결 강도를 보정하여 오차를 줄여 나가는 방법으로 학습이 이루어지기 때문에 학습 과정에서 많은 반복 계산이 요구되며, 새로운 패턴을 학습시키고자 할 때, 이미 학습이 된 패턴들을 재학습시켜야 하는 단점을 가진다.

반면에 Aleksander와 Stonham은 동일한 범주에 대해서도 추가학습이 가능한 2진 신경망 모델(Weightless Neural Network : WNN)을 제안하였다^[1-2]. WNN은 2진 정보를 처리할 수 있는 모델로서 입력패턴에서 N-tuple 방법^[3-4,7-8]을 이용하여 추출한 N개의 입력 노드로부터 입력된 2진 정보를 주소 정보로 하여 각 램들의 해당 주소에 의도한 교육 정보를 기억시키는 방법에 의해 학습이 이루어진다. 이는 현재 사용 중인 디지털 컴퓨터의 기억 소자인 램의 원리를 이용한 것이기 때문에 하드웨어

* 정회원, 울산대학교 대학원 컴퓨터공학과
(Dept. of Computer Engineering, Ulsan Univ.)

** 정회원, 거제대학 컴퓨터정보계열
(Dept. of Computer & Information, Koje College)

*** 정회원, 울산대학교 컴퓨터·정보통신공학부
(School of Computer & Information technologies, Ulsan Univ.)
접수일자: 2003년9월19일, 수정완료일: 2004년3월2일

적으로 구현하기가 용이하며, WISARD^[5,9]를 통하여 그 장점이 입증되었다. Lee는 WNN을 이용한 Digital Learning Network^[6,10]으로 순서 제어가 가능한 동적 특성을 가진 모델을 제안하였다. 그러나 이 모델 또한 다른 신경회로망 모델과 같이 같은 이미지를 여러 번 반복 교육할 경우에 한 번 교육된 내용과 동일하게 기억되어 반복 교육이 되지 않는 단점을 가지고 있다.

본 논문에서는 동일한 범주에 대하여 추가 교육이 가능할 뿐만 아니라, 동일한 내용의 반복된 경험에 대해서 더욱 강하게 반응 할 수 있는 신경망인 경험유관 축적 신경회로망 (Experience Sensitive Cumulative Neural Network :ESCNN) 모델을 제안하였다.

II. 2진 신경회로망 모델

WNN의 구성 요소인 2진 신경세포는 그림 1과 같이 $2^N(=m)$ bit를 가지는 램으로 구성되어 있다.

학습은 다음과 같은 과정으로 이루어진다. 입력층으로부터 임의의 N-tuple의 노드를 추출하며, 추출된 tuple을 이용하여 조합된 2진 입력값이 기억층의 디코더에 전달되며, 디코더에 의하여 주소 정보가 번역되어 정해진 주소의 비트가 1이 된다. 즉, 입력층에서 기억층으로 전달된 2진 값이 디코더에 의해 주소 정보화되어 램의 내부 Bit를 선택하게 되며, 선택된 위치의 램 데이터에 1을 기록함으로써 학습이 이루어진다.

인식 때에는 교육 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 패턴이 학습되어진 것인지를 판별한다.

2진 신경세포의 각 입력 노드들은 퍼셉트론에서 하나의 입력 노드와 대응하는 것으로, 2진 신경세포를 퍼셉트론의 노드와 비교하기 위하여 그림 2에서 퍼셉트론의 구조를 보인다.

WNN의 램은 N-tuple로 샘플링 된 N개의 노드와 연결되어 있으며, 그 노드를 각 램의 주소로 이용한다.

따라서 입력 패턴이 R개의 노드를 가질 경우 이를 학습하기 위해서는 R/N개의 램이 필요 되며, 이들을 조합하여 한 범주의 인식 판별자를 구성한다. 각 램의 크기는 2^N 이 된다.

예를 들어, 그림 3에서와 같이 3x3의 입력패턴일 경우,

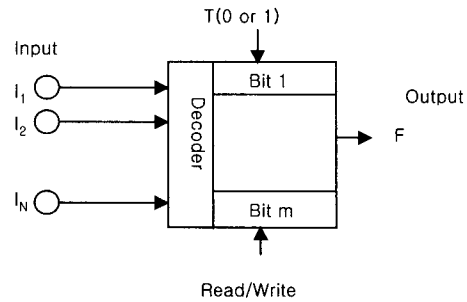


그림 1. 2진 신경 세포.
Fig. 1. Binary Neuron Cell.




그림 2. 퍼셉트론.
Fig. 2. Perceptron.




그림 3. 2진 신경회로망의 판별자.
Fig. 3. Discriminators of WNN.

입력 노드의 개수는 9이며, tuple의 노드 수를 3으로 처리할 경우 세 개의 tuple이 만들어지고, 각 램의 디코더 입력은 3 비트가 된다. 그리고 필요한 램의 개수는 tuple의 개수와 같이 3개가 된다. 결국, 램 하나는 $2^3(000\sim111)$ 주소를 가지며, 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 판별자라도 비선형으로 구분되는 영역을 학습시킬 수 있는 장점을 가진다. 또한 WNN은 교육된 정보로부터 일반화 패턴을 생성시킬 수 있는 특성을 가지고 있다. 이것은 입력 노드 중에서 부분적인 정보를 독립된 복수 개




그림 4. 교육 패턴.
Fig. 4. Training Patterns.




그림 5. 2진 신경회로망의 내부상태.
Fig. 5. Internal State of WNN.




그림 6. 일반화 패턴.
Fig. 6. Generalized Patterns.

의 2진 신경세포에 분산 저장시킴으로써 분산 저장된 정보를 다시 조합할 때 만들어지는 경우의 수만큼 새로운 패턴이 생성되기 때문이다.

그림 4와 같이 3개의 패턴을 그림 3의 WNN에 교육시켰을 경우 각 2진 신경세포에 교육되어진 내부 상태는 그림 5와 같으며, 이것은 그림 6과 같은 5가지의 패턴을 추가 교육시켰을 때에도 변화되지 않는다.

따라서 그림 5의 상태는 그림 6에서 보이는 새로운 패턴을 스스로 생성하여 교육된 일반화 패턴으로 기억하고 있는 결과가 되어 이 5가지 패턴은 교육을 시키지 않아도 인식된 것으로 처리한다.

그러나 위와 같이 일반화된 패턴들의 결과가 오히려 단점이 될 수도 있으며, 학습시키지 않은 패턴들에 대한 오인식의 원인이 될 수도 있다. 이를 개선하기 위하여 본 논문에서는 입력패턴들을 축적 할 수 있는 개선된 신경망을 제안한다.

III. 경험 유관 축적 신경망

인간은 수많은 경험을 통하여 부분적인 경험을 계속 누적해 가는 추가 학습 능력을 가지며 특징이 유사한 내용에 대한 반복된 경험은 다른 경험의 내용보다 더욱 강하게 기억한다. 이러한 기능을 위해서 신경회로망 모델은 기존 교육된 정보를 유지하면서 새로 교육된 정보를 중첩할 수 있는 추가 교육 기능과 중첩되는 부분에 대해서는 중첩되지 않는 부분보다 더 크게 반응하여 공통된 특징에 주의 집중하고 나머지 부분은 상대적으로 망각하는 기능을 가져야 한다.

이 두 가지 기능을 가지고 있는 모델은 잘못된 교육 내용에 대해서 정상적인 자료의 반복 교육을 통하여 상대적으로 반응율을 낮춤으로써 결과적으로는 그 내용이 지워지는 효과를 나타내므로 비교적 잡음이 많은 패턴에 대해서도 선행처리 과정을 거치지 않고 직접 교육 패턴으로 사용할 수 있다.

반면에 지금까지 제안된 오류 역전파 알고리즘을 사용한 대부분의 일반 신경회로망에서는 교육시키고자 하는 전체의 내용이 한 번의 교육과정에 의해 수행되어야 하며, 추가 교육 때에는 추가된 교육 내용을 포함한 전체의 내용을 가지고 처음부터 다시 교육을 시켜야 한다. 특히 동일한 내용의 교육 패턴은 반복 교육에도 불구하고 더 이상 교육이 이루어지지 않는다.

본 논문에서 제안한 가중치를 가진 ESCNN의 신경세포는 그림 3에서 보이는 WNN의 구조를 발전시켜, 정보의 기억 소자 단위를 0또는 1의 값을 가지는 Bit로 하지 않고 Byte 단위로 구성된 램을 사용하여 학습 패턴의 교육에서 반복 회수를 기억할 수 있게 한다.

여기에서 가중치라는 것은 퍼셉트론의 각 노드와 기억층간의 weight를 의미하는 것이 아니라, 램에 기억된 데이터의 증가를 뜻한다. 즉, 퍼셉트론의 경우 각 노드와 은닉층 혹은 은닉층과 출력층 사이의 값의 수정에 따라서 학습이 되지만, WNN의 경우 최종적으로 램에 기억된 값에만 의존한다. 제안된 모델은 기억할 수 있는 값을 단순히 0과 1이 아닌 학습 회수를 기억할 수 있도록 하는 구조로 되어 있으며, 이를 가중치를 가지는 WNN이라 하였다.

그림 7에서 ESCNN 신경 세포의 학습은 입력으로부터 추출한 N개의 노드를 조합한 2진 값의 주소 정보가 디코더의 입력으로 들어가고, 디코더에 의해 선택된 램




그림 7. 판별자의 내부 기억 상태.
Fig. 7. Internal State of the Discriminator.

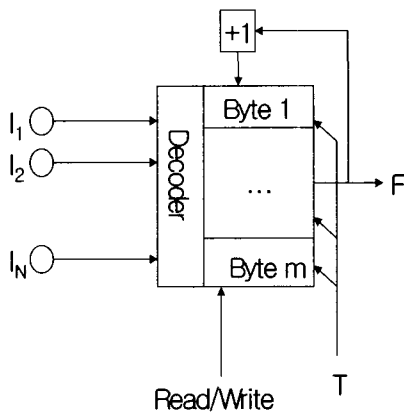


그림 8. ESCNN 신경세포.
Fig. 8. A Cell of ESCNN.




그림 9. 생성 패턴.
Fig. 9. Generalized Pattern.

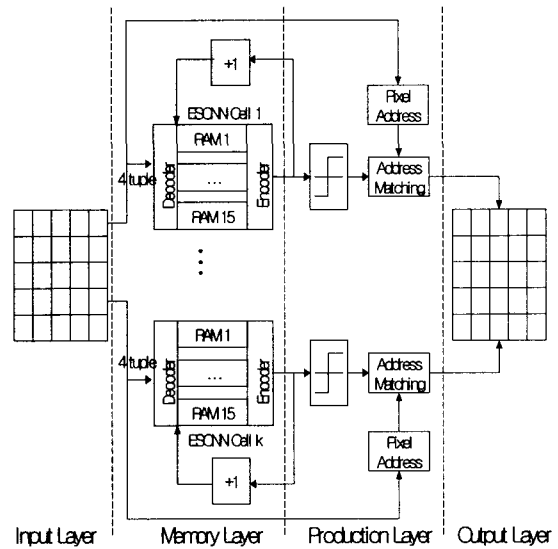


그림 10. ESCNN 판별기 구성도.
Fig. 10. Discriminator Structure of ESCNN.

의 내용은 기존의 기억된 값을 1씩 증가시킨다. 귀환 회로의 사용은 선택된 램의 내용과 번지를 기억하여 지정된 램의 값을 증가시키고, 선택된 램의 값을 이용하여 학습 회수를 기억하기 위하여 사용하였다. 따라서 각 디코더에 의해 선택되어진 램의 값은 교육 전의 값에 1씩 증가된 값을 기억시킴으로써 동일한 교육 패턴에 대해서도 반복 교육이 가능해 지게 되는 것이다. 즉 같은 입력 패턴에 대하여 램에 저장되어진 값은 1이 아니라, 입력 패턴의 학습 회수에 의해 결정되는 것이다. 기존의 WNN에서는 교육의 반복 회수와는 상관없이 한번이라도 교육이 되었으면 1을 그렇지 않으면 0을 출력하는 것에 반해, ESCNN은 교육의 반복 회수 값을 출력하기 때문에 교육 경험이 많은 패턴에 대해서는 상대적으로 큰 반응을 하는 주의 집중 기능을 가지고 있다.

그림 4의 입력 패턴들을 학습 시켰을 경우 ESCNN의 판별자의 내부 기억 상태는 그림 8과 같이 학습 회수가 저장되어 있다. 반면에 WNN은 그림 5에서와 같이 학습 회수와는 관계없이 단지 0이나 혹은 1이 저장되어 있음을 알 수 있다. 이를 이용하여 생성된 패턴을 그림 9에서 보이고 있다.

본 논문에서 제안된 ESCNN의 그림 11의 시스템 모델은 하나의 범주를 인식시키기 위한 것이며, 구성은 2차원 배열의 입력층(Input Layer)과 2진 신경세포로 구성된 기억층(Memory Layer), 기억된 정보로부터 일반화 패턴을 추출하는 생성층(Production Layer), 그리고 생성된 패턴을 저장하기 위한 입력층과 동일한 크기의 2차원 배열인 출력층(Output Layer)으로 구성되어 있다.

제안된 시스템을 실험하기 위한 입력 패턴은 1Bit 혹은 백 이미지 정보를 사용하였으며, 4-tuple method를 사용하여 한 번에 4개의 픽셀을 조합하여 신경세포의 입력 주소 정보로 사용하였다. 기억층에서는 2진 신경세포의 램 크기를 8 Bit으로 구성하여 최대 255까지 기억할 수 있도록 하였다. 각 신경세포에 있는 귀환 회로의 연산기는 귀환된 램의 내부 값과 교육/생성 단자에서 입력된 교육 정보 1을 가산하여 다시 램에 기억시킨다. 따라서 램과 연산기는 계수기로 동작하여 교육의 반복 회수가 기억되어지도록 되어있다.

IV. 구현 및 실험

1. 시스템 구현

생성층의 동작은 4 Bit 카운터에서 각 신경세포에게 주소 정보를 순차적으로 출력하고, 그에 의하여 선택된 램에 기억되어 있는 값이 특정 값보다 크면 Latch 회로를 구동하며, 회로는 그 때의 카운터 출력 정보를 보관한다. 여기서 생성된 출력 정보는 입력층의 정보와 동일한 의미의 패턴 정보이다. 출력층은 Latch로부터 출력된 패턴 정보를 누적하여 보관한다. 학습 과정은 교육/생성 제어 단자를 1로 하고 입력층으로부터 4픽셀씩 조합된 정보가 각 신경세포에 전달되며, 신경세포에서는 Decoder에 의하여 선택된 램의 값이 귀환 회로 및 가산 회로를 통하여 1이 증가되어 다시 램에 기억됨으로써 학습이 이루어진다.

생성 과정은 먼저 카운터 및 출력층의 값을 0으로 초기화시킨 후 교육/생성 제어 단자를 0으로 하면 반전 회로에 의하여 카운터가 동작된다. 초기치 0에서부터 1씩 증가하면서 카운터가 가질 수 있는 최고치까지의 패턴 정보를 신경세포의 Decoder 및 생성층의 Latch에 출력한다. 신경세포에서는 Decoder에 의하여 선택된 램의 저장된 값을 출력한다. 생성층에서는 램의 출력값이 θ_{GEN} 보다 크면 Latch 회로를 구동하며, Latch 회로는 그 때의 카운터 출력값을 기억하면서 출력층에 전달한다. θ_{GEN} 값은 축적된 값으로부터 일반화 패턴을 추출하기 위한 파라미터이다.

출력층에서는 Latch 회로에서 출력된 패턴 정보를 누적하여 보관한다. 하나의 일반화 패턴의 생성 과정은 처음 카운터 값이 0에서부터 1씩 증가하면서 최고치까지 한 번만 순환하면 된다.

동적 특성 실험은 일반화 특성 실험에서 도출된 출력층의 일반화 패턴을 입력층으로 복사하여 재교육을 시킨 후 다시 일반화 패턴을 추출하는 방법으로 재교육의 회수에 따라 잡음이 제거되어지는 과정에 대하여 실험한다.

2. 일반화 특성

ESCNN이 가지고 있는 일반화 패턴의 생성에 관한 실험은 다음과 같이 3가지 형태로 나누어 실험하였다.

첫 번째로는 원형 패턴은 교육시키지 않고 임의의 잡음이 섞인 패턴만으로 교육을 시킨 후 일반화 특성에 따라 원형을 재생할 수 있는 기능에 대하여 실험하였으며,

두 번째 방법은 부분적으로 서로 다른 잡음이 섞인 패턴을 원형 패턴과 같이 교육을 시킨 후 일반화 특성에 따라 원형 패턴을 분리할 수 있는 기능에 대하여 실험하였으며, 마지막으로 일반화 특성에 필요한 추가 교육 및 반복 교육의 기능에 대하여 실험한 결과를 기술하였다.

일반화 특성에 대한 첫 번째 실험으로 사용할 원본 이미지를 만들기 위하여 이미지 관련에 많이 이용되는 lenna 이미지를 사용하였으며, 먼저 512x512 크기의 원본을 2진 이미지로 만든 후 64x64의 크기로 축소하여 그림 11과 같은 원형 패턴 이미지를 만들었다.

원형 패턴은 교육시키지 않고 잡음이 섞인 패턴만을 각각 20개씩 교육을 시킨 후 교육된 내용으로부터 θ_{GEN} 값에 따라 추출된 일반화 패턴을 보여 주기 위하여 이미지 처리 툴인 photo shop ver 5.0을 이용하여 잡음을 추가하여, 그림 12, 13, 14와 같은 잡음이 섞인 이미지를 생성하였으며, 세 개씩 예를 보인다.



그림 11. 원형패턴.
Fig. 11. Original Pattern.



그림 12. 10% 잡음이 있는 샘플 3개.
Fig. 12. 3 Samples of 10% Noisy Patterns.




그림 13. 30% 잡음이 있는 샘플 3개.
Fig. 13. 3 Samples of 30% Noisy Patterns.



그림 14. 50% 잡음이 있는 샘플 3개.
Fig. 14. 3 Samples of 50% Noisy Patterns.

표 1. 10 % 잡음을 가지는 패턴의 램 저장 자료.
Table 1. the RAM Data of 10% noisy patterns.

RAM	0	1	2	3	4	5	6	7
1	1	0	0	0	16	1	1	1
2	0	0	0	0	0	0	0	0
3	20	0	0	0	0	0	0	0
4	0	0	0	0	0	0	0	3
5	1	0	18	1	0	0	0	0
~								
1023	17	0	0	0	0	0	0	0
1024	0	0	3	0	0	0	17	0

RAM	8	9	A	B	C	D	E	F
1	0	0	0	0	0	0	0	0
2	1	0	0	0	19	0	0	0
3	0	0	0	0	0	0	0	0
4	0	0	0	0	0	3	0	14
5	0	0	0	0	0	0	0	0
~								
1023	3	0	0	0	0	0	0	0
1024	0	0	0	0	0	0	0	0




그림 15. 10% 잡음 이미지의 θ 값에 따른 추출 패턴.
Fig. 15. Generalized Pattern of 10% Noisy Patterns.




그림 16. 30% 잡음 이미지의 θ 값에 따른 추출 패턴.
Fig. 16. Generalized Pattern of 30% Noisy Patterns.




그림 17. 50% 잡음 이미지의 θ 값에 따른 추출 패턴.
Fig. 17. Generalized Pattern of 50% Noisy Patterns.




그림 18. 반복 교육.
Fig. 18. Repeated Training.

각각 잡음이 있는 이미지 20개를 반복하여 ESCNN에 학습시켜 일반화 이미지를 구하여, 그림 15, 16, 17에 보이고 있다.

모의실험을 하기 위하여 Matlab Ver 5.2를 사용하였으며, 사용되는 램의 개수는 1024개이고 각 램은 16비트로 만들어 졌다.

실험 결과는 다음과 같다.

첫째, 하나의 신경세포 즉, 각 램에 있는 값의 합은 모두 동일하다. 이것은 교육 패턴의 수를 의미하여, 각 교육 패턴에 대하여 누적되고 있음을 보여준다.

둘째, 시스템에 학습 되어진 값들에서 큰 값은 여러 번 교육된 정보를 의미하며, 이것은 다른 부분보다 강한 특징점에 해당한다. 따라서 어느 정도 이상의 높이에 해당하는 부분만으로 패턴을 재구성하면 교육된 여러 개의 패턴 중에 공통된 특징점을 찾아낼 수 있다.

셋째, θ_{GEN} 값이 작을 경우에는 교육된 회수가 작은 잡음까지도 출력하게 되어 잡음이 제거되지 않지만, 값이 커질수록 강한 공통점만 선택함으로써 잡음이 제거되고 원형에 가까운 패턴을 추출할 수 있다. 반면에 너무 큰 값에 대해서는 특징점까지 제거된다는 약점이 있다.

3. 반복 교육 특성

일반화 특성의 두 번째 실험으로는 반복 교육 기능에 대한 실험을 하였다. ESCNN의 일반화 특성은 근본적으로 반복 교육의 기능을 가지고 있다. 반복 교육은 교육 패턴이 기존에 교육된 내용과 동일할 경우에 그 정보가 누적되어지는 기능을 가지고 있어야 가능해지며, 이것은 일반 신경회로망에서는 구현할 수 없는 것이다.

잡음이 30% 섞인 교육용 패턴 30개를 이용하여, 처음 5개를 교육시킨 후 θ_{GEN} 의 값을 결정 후 일반화 패턴을 추출한 후, 다른 5개의 추가 패턴을 이용하여 재교육시키는 방법으로 교육 패턴 수를 증가시키면서 추출한 일반화 패턴을 그림 18에 나타내었다.

그림에서와 같이 교육 패턴 수가 증가할수록, 보다 정확한 원형 패턴을 재생할 수 있다는 것을 알 수 있으며, 따라서 ESCNN의 반복 교육 기능을 확인 할 수 있다. 위와 같은 기능은 인간이 동일한 사안에 대해서도 경험이 많을수록 보다 정확한 지식을 기억하고 있는 것과 동일하게 해석할 수 있다.

V. 결론

대부분의 신경회로망은 지식이 각 노드간의 연결 강도에 저장되므로 학습 과정에 있어서 연결 강도가 일정한 값을 유지할 때까지 대량의 반복 계산이 필요하다. 또 오류역전과 알고리즘에 의하여 수정된 연결 강도가 최적의 값인지에 대한 보장도 없을 뿐만 아니라 인식 때에도 인식 결과에 대해 예측이 불가능하다. 그 외에도 교육된 내용과 일치하는 교육 패턴에 대해서는 더 이상 교육이 되지 않을 뿐만 아니라, 동일 영역의 추가 교육은 기존에 교육된 내용을 파괴시킴으로 결과적으로는 불가능하며, 다시 처음부터 추가 교육 내용을 포함한 전체의 내용을 가지고 새로 교육을 해야 한다

제안된 ESCNN은 기존의 WNN에 가중치를 부과하여 교육 회수를 누적할 수 있는 구조를 가지고 있어, 반복 교육된 내용에 대하여는 한 번 교육된 내용에 비하여 교육된 정도를 높일 수 있어 공통된 경험에 대해서 더욱 강하게 반응을 하는 주의 집중 기능을 보인다. 따라서 비교적 잡음이 많은 패턴에 대해서도 선행처리 과정을 거치지 않고 바로 교육을 시켜도 상대적으로 잡음 성분의 낮은 반복도로 인해 비교적 정확한 인식을 가능하게 하며, 공통된 경험으로 구성된 일반화 패턴을 스스로 조직할 수 있는 기능을 가지고 있다. 그리고 현재 사용 중인 디지털 컴퓨터의 특성을 그대로 이용하여 하드웨어로 구현이 가능하며, 교육과정도 단 한번의 계산과정으로 이루어지기 때문에 빠른 처리속도를 가진다. 뿐만 아니라 현재 기억하고 있는 상태를 유지하면서 추가 교육 내용을 누적할 수 있어 추가 교육이 가능하다. 또한 동일한 범주의 교육 내용에 대해서는 반복 교육 회수에 따라 교육 정도가 점점 높아져 다른 범주의 것보다 강한 반응을 하는 반복 교육도 가능하며, 반복 교육에 의하여 누적된 내용으로부터 공통된 특징에 대한 주의 집중 기능과 불필요한 정보에 대해서는 망각 기능을 통하여 일반화 패턴을 도출할 수 있다.

참고 문헌

- [1] Arbib, "Brains, Machines and M. A. Mathematics Chapter 1. A Historical Perspective", Springer Verlag, pp. 1-14, 1987.
- [2] C. V. Negoita, Expert Systems and Fuzzy System, The Benjamin Cummings, 1985.

[3] R. A. Frost, Introduction to Knowledge Base Systems, Collins, London, 1986.

[4] I. Aleksander and H. Morton, "An Introduction to Neural computing", Ch10, Chapman & Hall, 1990.

[5] I. Aleksander and R. C. Albrow, "Adaptive Login Circuits", 1st National Symposium on Login Design at the British, pp.65-71. 1967.

[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] J. R. Ullmann, "Experiments with the N-tuple method of pattern recognition", IEEE Trans, Computers, pp. 1135~1137, 1969.

[8] A. Badii, M. J. Binstead, A. J. Jones, T. J. Stonham and C. L. Valenzuela, Neural Computing Architectures : Ch 10. Applications of N-tuple sampling and genetic algorithms to speech recognition", The MIT Press, pp. 172 ~216, 1989.

[9] I. Aleksander, W. V. Thomas and P. A. Bowden, "WISARD : A Radical Step Forward in Image Recognition", Sensor Review, pp. 120 ~124, 1984.


[10] S. D. Lee, "Dynamics of Feedback for Artificially Intelligent Pattern Recognition", Msc. Dissertation Brunel Univ. U. K., 1981.

저 자 소 개



김 성 진(정회원)
 1996년 울산대학교
 컴퓨터공학과 공학사
 1998년 동 대학원
 컴퓨터공학과 공학석사
 2002년 동 대학원
 컴퓨터공학과 박사수료

<주관심분야 : 신경망, 뉴로퍼지 시스템>



이 수 동(정회원)
 1969년 서울대학교
 전자공학과 공학석사
 1980년 Brunel University
 공학석사
 1984년 Brunel University
 공학박사

1976년~현재 울산대학교 컴퓨터정보통신공학부
 교수.

<주관심분야 : 인공지능, 신경망, 소프트 컴퓨팅>



권 영 철(정회원)
 1987년 울산대학교 전기 및
 전자공학과 공학석사
 1995년 동 대학원 전자계산기
 공학과 공학박사
 1990년~현재 거제대학교 컴퓨터
 정보계열 교수

<주관심분야 : 인공지능, 신경망>