

# 다중 신경망을 이용한 영상 분류기에 관한 연구

## A Study on an Image Classifier using Multi-Neural Networks

朴 秀 峰\*, 朴 鍾 安\*\*  
(Soo-Bong Park\*, Jong-An Park\*\*)

### 요 약

본 논문에서는 신경망 학습에 의한 영상분류 알고리즘을 개선하였으며, 이것은 입력패턴 생성부와 분류를 위한 역전파 알고리즘에 의한 광역신경망으로 구성된다. 입력패턴을 위한 특징값으로는 자기조직화 형상지도 학습에 의해 얻은 코드북 데이터를 특징벡터로 이용한다. 이것은 입력벡터로서 원영상에 충실하면서 입력 뉴런수를 감소시킨다. 분류기에 사용된 광역망 알고리즘은 가중치와 유닛 오프셋 제어가 가능하도록 역전파 알고리즘에 제어부와 어드레스 메모리부를 삽입하였다. 실험결과 이들 분류기는 학습시 국소최소점에 빠지지 않게 되며, 대규모 신경망을 구현하고자 할 때 망구조를 간단히 할 수 있다. 또한 이것은 동작속도를 크게 개선할 수 있다.

### ABSTRACT

In this paper, we improve an image classifier algorithm based on neural network learning. It consists of two steps. The first is input pattern generation and the second, the global neural network implementation using an improved back-propagation algorithm. The feature vector for pattern recognition consists of the codebook data obtained from self-organization feature map learning. It decreases the input neuron number as well as the computational cost. The global neural network algorithm which is used in classifier inserts a control part and an address memory part to the back-propagation algorithm to control weights and unit-offsets. The simulation results show that it does not fall into the local minima and can implement easily the large-scale neural network. And it decreases largely the learning time.

### I. 서 론

양자화된 영상정보를 처리하는 디지털 영상 처리는 처리 방법이나 응용 분야에 따라 화질개선, 정보의 압축 및 복원, 영역분할, 패턴인식, 구조분석, 물체 인식 등을 다루게 된다. 특히 영상인식은 인간의 시각기관을 통하여 입력되는 영상정보를 기계에 의해서 입력하고 추출된 특징에 의거하여 통계적 패턴 분류법에 따라 전 화면 또는 부분 화면을 분류할 수 있도

록 변환 처리하는 과정으로 인식작업의 자동화로써 뿐만 아니라 위험한 작업의 대체로써 많은 연구가 진행되고 있다.<sup>1,3)</sup> 이와같은 인식시스템에서 영상의 특징을 추출하는 작업은 처리하고자 하는 영상을 분석하고 인식하는데 있어서 매우 중요한 요소이다. 이들 요소를 결정하는 영상데이터는 입력된 연속신호의 영상을 공간좌표상에서 샘플링하여 일정한 2차원 배열로 구성하고 이들 샘플링된 각 화소점의 밝기를 농도에 따라 양자화하여 처리하게 되는데, 2차원으로 양자화된 영상신호의 정보량은 분할된 2차원 배열의 크기나 밝기에 대한 양자화 크기에 따라 다르게 색도 적용 등에 따라 다르게 된다. 512\*512 화소와 RGB 3 색으로 영상을 구성하고 각 농도를 8 비트로 하는

\*동신대학교 정보통신공학과

\*\*조선대학교 전자공학과

접수일자: 1994년 9월 27일

경우 영상 1매를 저장하는 데는 약 6M 비트 메모리 용량이 필요하게 된다. 그러나 영상을 허용 손실범위 이내에서 압축하여 이용한다면 메모리용량은 크게 감소될 것이다. 이와같은 영상 정보의 압축은 영상이 가지고 있는 수 많은 정보의 중복성을 제거하여 정보량을 최소로하므로써 영상정보를 저장하는 메모리를 최소화시키거나 영상정보를 전송하는데 필요한 대역을 최소화시킨다는 것이다. 영상정보의 복원은 변환된 모델과 평가기준을 고려하여 원래 영상을 복원시키는 것을 의미한다. 이것은 객관적인 수학적 정의에 의하여 가정 영상에 대한 변환모델로부터 이상적인 최적 영상을 추적하는 과정이다. 이와같은 영상정보의 압축 및 복원기술은 패턴인식 분야에서 패턴분류를 위한 특징값 추출에 이용이 가능하다. 이와같은 인식작업에서 자주 사용되는 특징에는 영역의 기하학적 특징(연결성, 크기, 형상 등)과 농도 통계량을 나타내는 텍스처 특징이 있으며, 최근에는 영상처리에서 인식패턴을 분류하는데 성능 개선을 위해 신경망의 응용이 광범위하게 고찰되고 있다. 이들 신경회로망은 구조의 단순성에 비하여 강력한 분류기능과 인식능력을 갖는 병렬 분산 정보처리 구조로써 영상의 압축이나 인식에서의 효율성이 증대되고 있다. 특히 오차역전파 학습에 의한 다층 신경망분류기가 제안된 이래 신경망분류기는 임의의 입-출력 데이터에 근사화 될 수 있는 능력을 갖는 분류기로써 기존의 분류기와는 달리 그 분류능력이 뉴런이라 불리는 다수의 간단한 처리소자 간의 연결 가중치들에 의해 실행되며 우수한 적응학습 능력 등의 특성을 가지므로 패턴인식 분야에서 많은 각광을 받고있다.<sup>4,6)</sup>

본 논문에서는 영상 패턴을 분류하기 위해 신경망 압축 알고리즘을 이용하여 입력패턴을 생성하고 가중치 및 오프셋제어가 가능한 역전파 알고리즘을 구성하여 인식을 수행하는 다층 신경망 패턴분류 모델을 구성한다. 패턴 분류를 위한 특징값으로는 자기조직화 형상지도 알고리즘을 응용하여 큰 영상벡터 양자화에 대해서도 모든 노드에 균일 학습을 실행하므로써 특징 벡터로서의 정확도를 추구하며, 분류 기능을 위한 역전파 학습 모델은 알고리즘에 제어부와 어드레스 메모리부를 삽입하여 입력층과 은닉층 및 출력층간의 가중치와 유니트 오프셋제어를 가능하도록 구성한다. 이를 위하여 제 2장에서는 영상인식을 위한 일반적 시스템에 대하여 서술하고 제 3장에서는

신경망에 의한 특징추출과 분류알고리즘을 제안한다. 그리고 제 4장에서 제안된 알고리즘에 대한 시뮬레이션 결과를 고찰한 후 제 5장에서 결론을 맺는다.

## II. 영상인식 시스템

최근 다량의 영상정보를 처리하거나 전송 및 저장에 대한 필요성이 증대됨에 따라 이들 영상정보의 분석과 응용에 많은 관심이 고조되고 있으며 특히 패턴인식 분야에서 새로운 알고리즘을 개발하기 위한 연구활동이 활발하게 진행되고 있다. 또한 이것은 현 컴퓨터 구조상의 한계극복과 더불어 인공지능 실현을 위한 모델로 강력한 패턴분류 기능을 갖는 신경회로망에 의해 뒷받침되고 있다.<sup>4,6)</sup> 일반적으로 클러스터링 혹은 패턴인식이란 데이터 집합들의 상호 유사한 정도에 따라 각각의 클래스로 분류하는 것으로 정의할 수 있다. 이들 인식 방법중 원형 정합법과 통계적 방법은 국소영상 간격이 세세한 영상에 대해서는 화소의 다양성과 인식속도 등에 어려움이 있으며, 구조적 방법은 인식 구조 규칙을 형성하는 것이 쉽지 않다는 문제점이 있다. 이러한 문제점들에 대한 해결 방안으로 패턴인식에 신경망 모델을 이용하는 방법이 많이 사용되고 있다. 본 연구에서도 신경회로망의 응용에서 큰 장점을 보이고 있는 분류기능을 특징벡터에 의해 패턴인식에 적용하여 봄으로써 인식과정에 대한 신경회로망의 광범위한 응용에 대하여 고찰하고자 한다.

일반적인 패턴인식 처리과정으로는 카메라에 의해 입력된 영상으로부터 특징벡터를 추출하여 신경회로망에 입력하므로써 학습을 수행하게 되며 학습을 마친 영상은 코딩화 되어있는 표준패턴과 비교하여 가장 유사도가 높은 영상을 특정 영상으로 인식하게 된다. 그러나 카메라로 입력된 입력영상은 고립된 화소나 잡음으로 인하여 정확한 특징 추출이 어렵게 되는 경우가 발생하여 이들 데이터를 그대로 신경망에 학습시킬 경우 혼란을 일으킬 우려가 있어 전처리 과정으로서 잡음제거를 위한 평활화를 수행한다. 이 경우 신경망은 인간의 시각 정보와 동일한 환경속에서 인식이 가능토록 처리되므로 입력 데이터에 대한 전처리는 최소화한다.

이와같이 입력영상 데이터는 전처리 후 신경망 학습에 적합하도록 특징 추출을 수행하게 되는데, 이것은

전화소 데이터를 입력성분으로 사용하지 않고 입력 영상에 대한 특징성분을 추출하여 이용한다는 것이다. 이와같은 알고리즘을 사용하면 입력화소를 그대로 데이터로 사용할 경우보다 입력층 패턴수를 줄일 수 있게 되어 신경망 구현이 간단하고 훈련 시간을 크게 감소시킬 수 있을뿐만 아니라 특징 추출을 거친 후의 입력정보가 원래의 영상정보 자체의 특징을 나타내는 데 보다 더 효과적이다. 이와같은 원리는 한글과 같은 조합형 문자인식에도 적용이 가능하다.<sup>10)</sup>

인식학습시 사용되는 신경 회로망은 다층망 구조가 일반적인데 각 층의 신호는 상층으로만 향하는 피드-포워드형 회로망이다. 각 노드는 하층 노드의 출력과 연결강도와의 내적합에 의하여 결정되고, 이것은 비선형 단조증가 특성을 갖는 시그모이드 함수에 의해 상층으로 출력된다. 신경회로망의 학습에는 정규화된 델타법의 역전파 학습법을 이용하기도 하는데 이때 활성화함수로 선형함수를 사용하면 다층망이 등가의 단층망으로 변형이 가능하므로 다층구조의 장점을 살릴 수 없기때문에 미분가능한 시그모이드함수를 사용한다. 시그모이드 함수를 사용하는 특징은 첫째로 출력이 단순히 0과 1사이의 값으로 사상이어 결과를 예측할 수 있고 둘째로는 미분이 가능하며 그 결과의 형태가 매우 간단하므로 각 연결선에 대해 전이함수를 쉽게 얻을 수 있다는 점이다. 그리고 셋째로는 자동적인 이득제어 기능이 있어서 입력 값이 작으면 크게 변하고 클때는 작게 변하는 특성을 갖는다.

이와같이 병렬분산 정보처리 구조를 갖는 신경회로망은 구조의 단순성에 비하여 강력한 분류기능과 인식능력을 갖는다. 그러나 이와같은 장점에도 불구하고 다층 퍼셉트론의 오차 역전파 학습에서 제기되고 있는 학습 속도와 최적해 문제는 연구대상이 되고 있다. 본 연구에서는 이들 문제점을 개선하기 위하여 신경망 분류기에서의 고속정보 형성을 위한 학습 알고리즘 구성과 입력영상으로부터 입력패턴을 생성하기 위한 벡터양자화에 근거한 특징추출에 대하여 고찰한다.

### III. 특징추출과 분류 알고리즘 설계

#### 1. 자기조직화 학습망에 의한 특징벡터

영상정보에 대한 압축기술이 패턴인식을 위한 특징값 추출에 이용되며, 신호의 압축 방법으로는 벡터

양자화 기법이 영상의 화질을 적절히 유지하면서도 압축률이 좋은 특성 때문에 전송 및 저장용 목적으로 하는 영상 데이터의 압축에 널리 이용되고 있는데, 영상분류에서 입력영상의 특징벡터로서 이용이 가능하다.<sup>7)</sup> 벡터양자화 기법중에서 가장 기본적인 K-means 알고리즘은 정해진 수의 코드워드 중 평균자승오차가 최소가 되는 코드워드를 찾는 일련의 반복과정이다. K 개의 코드워드를 갖도록 할 때 임의로 K개의 코드워드를 초기화한 후 입력벡터와 거리가 최소가 되는 노드를 찾아 각 노드에 할당되는 입력벡터들의 평균으로 새로운 코드워드를 결정하며, 코드워드의 전체 변화를 추적하여 임계값 이하일 때까지 반복적으로 수정을 가하는 알고리즘이다. 그러나 이와같은 벡터 양자화 방법은 코드북 발생과 코드화시에 많은 계산량이 필요하므로 실시간 처리에 제한이 따르게 되어 최근에는 신경 회로망의 병렬처리 특성과 환경 변화에 적응적인 학습 특성을 이용해 기존의 벡터 양자화를 더욱 빠르고 유연성 있게 처리할 수 있는 방법이 제안되고 있다.<sup>8,9)</sup> 병렬처리 구조의 신경망을 이용하면 각 트레이닝 데이터를 학습시켜 코드북을 설계하고, 설계된 코드북은 공간적 배열로 검색시 실시간 내에 처리할 것으로 기대되며, 전체 트레이닝 데이터를 배치 형태로 취급하여 코드북을 설계하는 LBG 알고리즘에 비해 성능 향상의 가능성도 기대된다.

본 연구에서 입력영상으로부터 특징벡터를 생성하기 위해 이용된 벡터 양자화 기법은 Kohonen에 의해 발표된 자기 조직화 형상지도(Self-organizing feature map) 알고리즘을 이용한다. 이것은 입력벡터와 초기화된 코드워드간의 유클리드 거리를 계산하여 출력 노드를 결정하며 처음에는 출력 노드를 중심으로 전체 노드에 걸쳐 학습이 되도록 하지만 시간이 지남에 따라 이웃반경을 줄여 가면서 유사한 벡터들끼리 공간적으로 가까운 노드에 서로 모여 적응적으로 학습되기 때문에 영상의 수가 증가함에 따라 K-means 알고리즘에서와 같이 설계시간에 크게 구애받지 않으며, 코드북 검색에도 부분탐색으로 많은 시간을 절약할 수 있다. 이와같은 벡터 양자화 기법에 따라 설계되는 코드북의 형성 순서는 가중벡터의 임의의 초기화로 시작하여 트레이닝 데이터와 가중벡터와의 거리계산을 수행한 후 최소의 유클리드거리를 갖는 노드를 선택한다. 그리고 선택된 노드의 가중치와 이웃 반경내에 있는 노드의 가중치를 조정하

는데, 이와같은 공정은 전왜곡의 변화가 임계값이하 일 때까지 반복하여 특징벡터를 추출한다.

2. 가중치-오프셋 제어 신경망에 의한 분류 알고리즘

영상 및 음성인식에 응용되는 오차 역전파 알고리즘은 원하는 출력과 다층 피드-포워드 퍼셉트론의 실제 출력사이의 평균자승 오차를 최소화하도록 고안된 오차 함수의 급하강법 알고리즘이며 연속적인 차분 비선형 특성을 요구한다. 층사이에는 단층 퍼셉트론과 유사한 피드-포워드망이 형성되며 중간층과 각 유닛의 입-출력 특성을 비선형으로 동작하게 하므로써 네트워크의 능력을 향상시킨다. 그러나 국소해의 문제나 중복 학습 방식에 의한 계산량의 증가 등 많은 문제점이 존재하며 이를 개선하기 위해 델타 규칙이 많이 이용되고 있다. 그러나 개선된 오차 역전파 학습 알고리즘에도 불구하고 학습 속도는 여전히 느리며 손실함수의 기복이 심하여 여러 극소점이 존재하게 되면 최적해에 대한 수렴이 어렵게 된다. 또한 입-출력 패턴과 파라메타의 변동에 따라 학습 효율이 크게 변한다.

본 연구에서는 오차 역전파 학습모델에서 제기되고 있는 학습 속도와 최적해 문제를 개선하여 영상분류를 위한 학습알고리즘에 응용한다. 개선된 신경망 모델은 입력층과 은닉층 그리고 출력층간의 가중치 및 유닛 오프셋에 대한 제어가 용이하도록 그림 1과 같이 구성하였다.




그림 1. 제안된 신경망 구조  
Fig. 1. Structure of the proposed neural-network

이것은 신호 패턴에 대한 입력층, 은닉층에 대한 제어부, 그리고 은닉층과 출력층사이의 어드레스 메모리부를 도입하여 구현된다. 입력층은 입력 패턴을

분석하여 은닉층의 오프셋 제어와 가중치를 제어할 수 있도록 프로그램에 전달하는 역할을 하고, 제어부는 입력층으로부터 패턴 정보를 받아 입력층과 은닉층간의 가중치 제어와 은닉층의 유닛 오프셋을 제어하여 통과된 은닉층의 출력 정보를 어드레스 메모리로 보내며 은닉층의 중간 제어 출력을 생성시킨다. 그리고 어드레스 메모리부는 저장된 은닉층의 출력 벡터를 입력 패턴과 대비하여 기억을 하고 학습이 종료되면 기억된 학습 정보를 해당된 출력층에 전송하여 학습을 마무리하는 역할을 한다.




그림 2. 가중치 및 오프셋 제어 학습 순서도  
Fig. 2. Learning flowchart based on weights and offsets control

이와같은 학습 모델에 대한 알고리즘 순서도는 그림 2와 같으며 크게 2단계로 구분된다. 먼저 주어진 입-출력 벡터에 대해 가중치 및 유닛 오프셋을 제어하여 은닉층의 출력 제어 패턴을 생성하게 되는데 여기서는 병렬 분산적인 기억구조가 도입된다. 다음으로는 학습된 정보를 어드레스 메모리에 기억을 시킨후 최종 출력을 통해 학습을 마무리한다. 이와같은 학습동작은 다음과 같은 순서로 구현된다.

- 1) 네트워크의 상태에 영향을 미치는 초기 가중치  $[W_i(t)]$  ( $0 \leq i \leq N-1$ )와 오프셋  $[\theta]$ 를 초기화 한다. 초기화 후 학습 패턴을 결정하고 다음으로 입력층과 은닉층간의 가중치를 초기화 한다. 여기서  $W_i(t)$ 는 시간 t일 때 입력 i로 부터의 가중치를 나타낸다.
- 2) 이진 입력 벡터가 2개일 때 은닉층을 제어하여 출력할 수 있는 은닉층 유닛 오프셋의 최대값  $U_{max}$

는 식(1)과 같다. 이 최대값은 입력 패턴에 의해 결정이 되며 학습에 있어서 매우 중요한 제어 변수이다.

$$U_{\max} = \sum_{i=1}^k [I_p + J] \quad (1)$$

여기서  $\sum I_p$ 는  $I_p > 0$ 인 입력패턴이 k개 일 때의 입력 패턴의 총합이고 J는 0보다 작은 패턴의 총합이다.

3) 은닉층의 최대 유닛 오프셋이  $[\sum I_p + J]$ 이고 입력 패턴 벡터의 총합이  $\sum I_{(M,M)}$ 일 때 은닉층 출력을 위한 오프셋의 제어 조건은 아래의 식 (2)-(3)과 같다

$$\sum_{i=1}^k [I_p + J] + P \leq \sum I_{(M,M)} \quad (2)$$

여기서 P는 은닉층의 출력을 1로 하기 위한 제어값이다.

$$\sum_{i=1}^k [I_p + J - Q] > \sum I_{(M,M)} \quad (3)$$

여기서  $I_{(M,M)}$ 는 입력패턴이며 Q는 은닉층의 출력을 0으로 하기 위한 제어값이다.

4) 은닉층의 오프셋 제어가 가능하도록 은닉층 뉴런수를 설정한다. 제어가능한 은닉층의 최대 제어 출력에 대한 패턴 생성은 출력 패턴의 벡터 열에 비례하여 증가하는데, 출력층의 출력 벡터열이 n 열이면  $2^n$ 에 해당하는 은닉층의 제어 패턴을 생성시킨다.

5) 입력층과 은닉층사이의 학습을 통해 학습된 은닉층의 출력 데이터는 각각의 입력 패턴에 대응하여 학습이 종료할 때까지 어드레스 메모리에 임시로 저장된다. 학습시 은닉층 오프셋의 제어 조건에 따라 은닉층은 1 또는 0 을 출력할 수 있도록 한다.

6) 학습된 패턴은 어드레스 메모리부의 번지내에 입력 패턴과 대비하여 저장된다. 학습 패턴에 대한 데이터의 저장은 모든 패턴이 학습될 때까지 유지된다.

7) 학습이 종료되면 어드레스 메모리에 저장된 데이터는 출력 뉴런의 임계값을 통해 출력된다.

이와같은 알고리즘의 특성은 일반적인 역전파 모델이 입-출력 패턴의 교차신호에 의해 가중치 및 임계값을 자동 생성하는 데 비해 제안된 모델에서는 제어부와 직렬적인 메모리부를 도입하여 이중적인 메모

리 구조를 지나게 하므로써 메모리 구조면에서 직·병렬적인 처리를 동시에 수행하게 하여 가중치와 임계값을 제어하게 된다.

이와같은 알고리즘은 일반 역전파에 비해 학습속도가 크게 개선된다. 그림 3은 비선형 분리특성을 나타내는 XOR 예에 대한 수렴속도를 비교한 것이다.

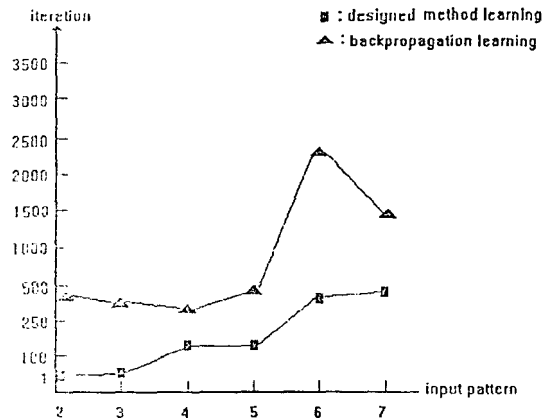


그림 3. XOR의 예를 통한 수렴속도 비교  
Fig. 3. Comparison of convergence speed using example of XOR

#### IV. 시뮬레이션 및 고찰

제안된 방법의 성능평가를 위하여 먼저 영상인식의 특징값으로 자기조직화 형상지도에 의한 벡터 양자화기로 코드북을 생성하였다. 그리고 주어진 입-출력 벡터에 대해 가중치 및 유닛 오프셋을 제어하여 은닉층의 출력 제어패턴을 생성하고 학습된 정보를 어드레스 메모리에 기억시킨후 최종 출력을 통해 학습을 마무리하도록 구성하였다. 이와같은 영상인식 알고리즘에 대한 개략적인 순서도는 그림 4와 같이 구성된다.

먼저 입력영상으로서 256×256 크기의 LENA 영상으로부터 임의의 트레이닝 벡터를 취하여 자기조직화 학습망에 의해 코드북을 설계하였으며, 실험에서 비트율을 동일 조건으로 하여 코드북의 코드워드




그림 4. 시뮬레이션 순서도  
Fig. 4. Simulation flowchart

를 16에서 256까지 가변시킬 경우에 생성되는 분류기  
로의 입력패턴에 대한 RMSE와 PSNR을 식(4)와  
식(5)에 의하여 구하면 표 1과 같다.

$$RMSE = \sqrt{\frac{1}{M \times N} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (x_i - y_j)^2} \quad (4)$$

$$PSNR = 10 \log_{10} \frac{255^2}{\frac{1}{M \times N} \times \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (x_i - y_j)^2} \quad (5)$$

표 1. 코드북 크기 변화에 따른 RMSE  
Table 1. Signal-to-Noise Ratio according to a codebook  
size

codebook size	16	32	64	128	256
RMSE	14.879	13.346	11.858	11.067	10.574
PSNR	24.679	25.689	26.650	27.250	27.646

신경망 구조에 적용된 표 1에서의 결과는 전통적인  
컴퓨터 구조를 바탕으로 얻은 K-means에 의한 결과  
보다 코드워드가 공간적으로 정리되는 배열특성을  
갖는다. 입력영상의 특징벡터로써 생성되는 코드북  
을 입력패턴으로 가중치와 유니트오프셋 채어가 가  
능한 신경망에 의한 패턴분류기의 실험결과를 다음

과 같다. 실험은 은닉층 뉴런수, 학습비, 그리고 시그  
모이드 함수비의 변화에 따른 학습결과와 평균자승  
오차를 SUN 워크스테이션상에서 구하도록 하였으  
며, 이때 코드북은 입력영상 으로부터 16\*8 마스크를  
기준벡터 로하여 추출한다. 은닉층 뉴런수 변화에 따  
른 학습결과는 표 2에서와 같으며 학습비를 0.5, 기준  
오차를 0.1, 그리고 시그모이드 함수비를 0.5로 일정  
하게 하고 은닉층 뉴런수를 2~16으로 변화시키는 경  
우에 대한 학습횟수와 그에따른 평균자승오차를 구  
하였다. 여기서 학습횟수는 2000회로 제한하였으며  
이 범위에서 기준오차내에 이르지 못하면 수렴치 않  
은 것으로 분류하였다.

표 2. 은닉층 뉴런수 변화에 따른 분류 결과  
Table 2. classification results according to the neuron  
number of the hidden layer

results para.	hidden layer neurons	classification results	
		iteration	R M S E
learning rate = 0.5	2	2000	0.28212115
	4	141	0.07495150
	6	99	0.07128717
	8	108	0.06869702
sigmoid rate = 0.5	10	125	0.07112697
	12	151	0.06546418
	14	153	0.06715247
	16	240	0.06857435

표3은 학습비 변화에 따른 학습결과이다. 기준오차  
를 0.1, 시그모이드 함수비를 0.5, 그리고 은닉층 뉴  
런수를 8로하여 학습비를 0.1~0.9사이로 변화시키는  
경우에 얻게되는 학습결과이며, 학습횟수는 학습비

표 3. 학습비 변화에 따른 분류 결과  
Table 3. classification results according to the learning  
rate

results para.	learning rate	classification results	
		iteration	R M S E
hidden layer neurons = 8 sigmoid rate = 0.5	0.1	2000	0.22285425
	0.2	2000	0.20891713
	0.3	2000	0.20254970
	0.4	201	0.07461488
	0.5	108	0.06869702
	0.6	123	0.07257368
	0.7	265	0.07064936
	0.8	297	0.06757792
	0.9	694	0.05807253

에 따라 큰폭으로 변화되었으나 평균오차는 큰 차이가 없었다.

시그모이드 함수비 변화에 따른 학습결과는 표 4와 같다. 이들 결과는 학습비율 0.5, 기준오차를 0.1, 그리고 은닉층 뉴런수를 8로 하고 시그모이드 함수비를 변화시키는 경우에 대한 학습횟수와 그에 따른 평균 자승오차이다. 최소 학습횟수는 시그모이드 함수비가 0.5인 경우에 얻게되며 이때의 자승오차도 학습횟수에 비해 크게 감소됨을 알 수 있었다.

표 4. 시그모이드비 변화에 따른 분류 결과  
Table 4. classification results according to the sigmoid rate

results para.	sigmoid rate	classification results	
		iteration	R M S E
hidden layer neurons = 8 learning rate = 0.5	0.1	1889	0.07352579
	0.2	462	0.07332024
	0.3	210	0.07299393
	0.4	120	0.07342152
	0.5	108	0.06869702
	0.6	438	0.06210851
	0.7	475	0.05077242
	0.8	2000	0.25094351
	0.9	2000	0.72264397

이들 결과를 비교-분석하기 위하여 각 파라미터 변화에 따른 학습속도를 나타낸 것이 그림5~그림7과 같다.

은닉층의 뉴런수는 학습속도에 직접적인 영향을 주는데 그림 5에서와 같이 수렴에 이르지 못하는 경우를 제외하면 뉴런수가 많을수록 시냅스에 대한 계산량이 많아지므로 수렴속도는 길어지게 된다. 또 그림 6에서와 같이 학습비의 변화에 따라서도 학습속도는 크게 좌우되는데 학습비가 클수록 학습속도는 증가되었으며, 학습비와 시그모이드 함수비가 0.5일때 최적치가 존재하였고 너무 크거나 작은 함수비에 대해서는 수렴에 문제가 발생하였다. 그리고 그림 7에서와 같이 시그모이드 함수비가 0.1 일때 1889회로 수렴하였으나 학습시간이 많이 걸렸으며, 시그모이드 함수비가 0.8 과 0.9에서는 수렴하지 못하였다.

이들 학습결과로부터 입력영상 분류기에 대한 입력뉴런수를 32개, 출력뉴런수를 8개, 패턴수를 16개, 은닉층의 뉴런수를 8로하여 기준오차 0.1의 범위내에서 학습시킬 때 학습횟수가 108로 나타나 가장 빠른

수렴속도를 나타내었다.

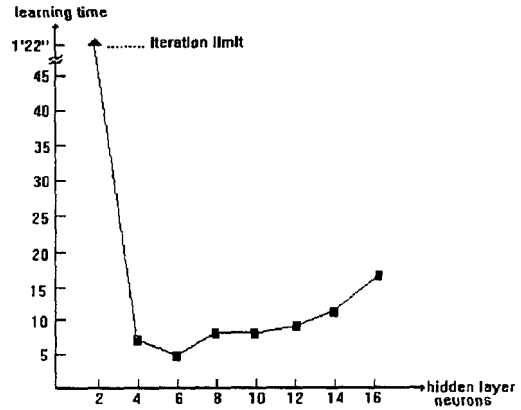


그림 5. 은닉층 뉴런수에 따른 수렴속도 변화  
(학습비 = 0.5, 시그모이드함수 = 0.5)  
Fig. 5. Learning-time variation according to the neuron number of the hidden-layer  
(learning rate = 0.5, sigmoid rate = 0.5)




그림 6. 학습비에 따른 수렴속도 변화  
(은닉층 뉴런수 = 8, 시그모이드함수비 = 0.5)  
Fig. 6. Learning-time variation according to the learning rate (hidden layer neurons = 8, sigmoid rate = 0.5)




그림 7. 시그모이드비에 따른 수렴속도 변화 (학습비=0.5, 은닉층뉴런수=8)  
 Fig. 7. Learning-time variation according to the sigmoid rate (learning rate=0.5, hidden layer neurons=8)

V. 결 론

본 논문에서는 패턴인식을 위한 영상 분류기에 대하여 고찰하였다. 특징패턴 생성과 분류를 위한 학습 알고리즘에 개선된 다중신경망을 이용하였고 이를 영상분류에 적용함으로써 제안된 알고리즘의 효율성을 입증하였다.

패턴분류를 위한 특징값으로는 자기조직화 형상지도 학습시 모든 노드가 일정하게 학습될 수 있도록 한 알고리즘을 응용함으로써 큰영상 벡터 양자화에 대해서도 원신호에 충실한 2차 입력패턴을 얻도록 하였다. 분류기로써 학습모델은 역전파 알고리즘에 제어부와 어드레스 메모리부를 삽입하여 가중치와 유니트 오프셋 제어를 가능하도록 구성하였다. 이와같은 영상패턴 분류기는 학습패턴에 대한 선형분리가 가능하므로 국소최소점에 빠지지 않으며, 영상패턴 분류기와 같은 대규모 신경망을 구현하고자 할 때 신경망구조를 간단히 할 수 있으며 분류속도를 개선할 수 있다.

참 고 문 헌

1. U. Ramer, "Extraction of Line Structures from Photographs of Curved Objects," Computer Graphics Image Proc. vol. 4. pp 81-103, 1975.

2. W. A. Perkins, "A Model Based Vision System for Industrial Parts." IEEE Trans. Comput. vol. c-27, pp 126-143, 1978.  
 3. K. Fukushima, "Analysis of the Process Visual Pattern Recognition by the Neocognition," Neural Network, vol. 2, pp. 413-420. 1989.  
 4. K. Fukushima, "A Neural Network Model for Selective Attention in Visual Pattern Recognition," Biological Cybernetics, 55(1), pp. 5-15, 1986.  
 5. K. Fukushima, S. Miyake and T. Ito, "Neocognitron: A Neural Network Model for a Mechanism of Visual Recognition," IEEE Trans., SMC, 13, 5, pp. 826-834, 1983.  
 6. A. C. C. Coolen and F. W. Kuijk, "A Learning Mechanism for Invariant Pattern Recognition in neural Network," Neural Networks vol. 2 pp. 495-506, 1989.  
 7. A. K. Krishnamurthy, S. C. Ahalt, D. E. Melton, and P. Chen, "Neural Network for Vector Quantization of Speech and Images", IEEE J. on Selected Areas in Communications, vol. 8, No. 8, pp. 449-1457, 1990.  
 8. T. Kohonen, "Self-organized Formation of Topologically Correct Feature Maps", Biological Cybernetics. 43. pp. 59-69, 1982.  
 9. K. K. Truong, "Multilayer Kohonen Image Codebooks With a Logarithmic Search Complexity", IEEE ICASSP, vol. 4. pp. 2789-2792, 1991.  
 10. 김용성, 조성환, 이근영, "역전파 알고리즘과 사전을 이용한 필기체 영문자 인식", 한국통신학회 논문지, vol. 18 No. 2, pp. 157-167, 1993.

▲朴 鍾 安(Jong An Park:終身會員) 1952년 7월 7일생  
 1975년 2월: 조선대학교 공과대학 전자공학과(공학사)  
 1986년 2월: 조선대학교 대학원 전기공학과(공학박사)  
 1983년 8월~1984년 8월: 미국 Massachusetts 주립대학 객원교수  
 1990년 3월~1991년 3월: 영국 Surrey대학교 전자&공학과 객원교수  
 1975년 3월~현재: 조선대학교 공과대학 전자공학과 교수



※주관심분야: 디지털 신호처리, 패턴인식



▲ **朴 秀 峰**(Soo-Bong Park:正會員) 1954년 2월 20일 생



1982년 2월 : 조선대학교 공과대  
학 전자공학과(공학  
사)

1984년 2월 : 조선대학교 대학원  
전자공학과(공학석  
사)

1990년 9월~현재 : 조선대학교 대  
학원 전기공학과 박  
사과정 수료

1986년~현재 : 동신대학교 정보통신과 조교수

※주관심분야 : 디지털 신호처리, 컴퓨터 비전, 신경  
회로망등