

論文96-33B-3-20

동적 경쟁학습을 수행하는 병렬 신경망

(Parallel Neural Networks with Dynamic Competitive Learning)

金 鍾 完 *

(Jong Wan Kim)

요 약

본 논문에서는 동적 경쟁학습을 수행하는 새로운 병렬 신경망을 제안한다. 기존의 학습 방법들은 주어진 입력패턴의 모든 차원을 사용한다. 하지만 특정 차원은 패턴의 분류에 기여하지 않을 수도 있다. 제안된 시스템은 입력 성분 자체의 정보를 이용하기 위해 감소된 입력차원을 사용하는 병렬 신경망이다. 병렬 신경망을 통합하여 인식 클래스를 결정하기 위하여 합의방식을 개발하였다. 개별 신경망은 학습시에 동적으로 출력뉴런을 생성하는 경쟁학습을 수행한다. 제안된 동적 경쟁학습은 생성되는 출력뉴런마다 클래스 임계치를 갖는다. 이 클래스 임계치를 학습중에 동적으로 변경시킴으로써 제안된 신경망은 입력패턴들의 분포를 적절하게 반영하게 된다. 원격 탐사 데이터와 음성 데이터에 적용하여 실험한 결과 제안된 방법은 기존의 학습 방법들에 비하여 우수한 성능을 보였다.

Abstract

In this paper, a new parallel neural network system that performs dynamic competitive learning is proposed. Conventional learning methods utilize the full dimension of the original input patterns. However, a particular attribute or dimension of the input patterns does not necessarily contribute to classification. The proposed system consists of parallel neural networks with the reduced input dimension in order to take advantage of the information in each dimension of the input patterns. Consensus schemes were developed to decide the collective classification using parallel neural networks. Each network of parallel neural networks performs a competitive learning that dynamically generates output neurons as learning proceeds. Each output neuron has its own class threshold in the proposed dynamic competitive learning. Because the class threshold value dynamically is changed during the learning phase, the proposed neural network adapts properly to the input pattern distribution. Experimental results with remote sensing and speech data indicate the improved performance of the proposed method compared to the conventional learning methods.

1. 서 론

최근에 경쟁학습(competitive learning)은 빠른 학습속도와 하드웨어 구현의 용이성 등의 장점때문에 패턴인식 문제를 해결하기 위하여 폭넓게 사용되고 있다

[1-4]. 단순 경쟁학습(Simple Competitive Learning : SCL)은 입력벡터와 가장 유사한 대표벡터(reference vector)를 가지는 승자뉴런(winner neuron)만을 학습시키는 방법이다 [1]. 하지만 이 알고리즘은 승자뉴런만을 계속 학습시키므로 초기 대표벡터의 분포에 따라 전혀 학습이 안되는 뉴런이 생기는 등의 문제가 발생하였다. 이를 해결하기 위한 여러 시도가 있었다.

* 正會員, 大邱大學校 電子計算學科

(Dept. of Computer Science, Taegu University)

接受日字: 1995年7月11日, 수정완료일: 1996年2月13日

먼저, Kohonen은 승자뉴런과 위상적으로 인접한 이웃뉴런들의 대표벡터들도 함께 학습시키는 자기 조직화 특징 지도(Self-Organizing Feature Map : SOFM) 알고리즘을 제안하였다¹²⁾. 이 방식은 단순 경쟁학습에 비하여 학습의 안정화를 이루지만 추가적인 계산이 요구된다. 즉 승자뉴런의 이웃을 계산하고 이들의 가중치들도 승자뉴런과 함께 학습시켜야 한다.

Ahalt등은 빈번하게 승자가 되는 출력뉴런들에 벌을 줌으로써 승리율(winning rate)을 낮추어 모든 출력뉴런들이 고르게 학습되도록 하는 공평 경쟁학습(Frequency-Sensitive Competitive Learning : FSCL) 알고리즘을 제안하였다¹³⁾. 이 방법은 승리율의 조성이 데이터에 따라 일정하지 않다는 단점이 있다.

또한 Grossberg와 Carpenter는 ART(Adaptive Resonance Theory) 모델을 제안하였다¹⁵⁾. ART는 입력패턴의 분포에 따라 출력층의 차원을 동적으로 확장하면서 대표벡터들을 학습시킨다. 하지만 입력벡터와 대표벡터들간의 유사성(similarity)을 검사하기 위한 경계치(vigilance factor)의 선정이 어렵다.

기존의 경쟁학습 알고리즘들은 고정된 구조의 신경망을 사용하므로 대표벡터들의 초기값이 미리 정해진다. 이 경우에는 초기 대표벡터들에 의해 학습 알고리즘이 영향을 받게 된다. 한편 신경망들은 일반적으로 주어진 입력패턴의 모든 성분들을 사용한다. 하지만 문제에 따라서는 입력패턴의 특정 차원 성분이 인식에 더 어렵게 만드는 경우도 있다.

이에 본 논문에서는 동적 경쟁학습을 수행하는 병렬 신경망을 제안한다. 제안된 신경망은 클래스내 분산(intra-class variance)을 최소화 하면서 출력뉴런을 동적으로 생성하는 경쟁학습을 수행하고, 병렬 신경망의 학습을 위해 감소된 입력 차원을 사용하고 개별 신경망들의 인식결과를 통합하기 위하여 합의방식(consensus scheme)을 개발하였다.

제안된 신경망은 기존의 신경망들과는 차이가 있다. 첫째, 학습을 진행하면서 출력뉴런의 대표벡터를 지정함으로써, 미리 정해진 초기 대표벡터를 사용하여 학습하는 방식에 비하여 임의의 분포를 가지는 패턴인식에 유리하다. 둘째, 동일한 입력벡터들을 사용하고 신경망 학습인자들을 다양하게 변경함으로써 인식률을 향상시키려는 기존의 다중 신경망 방법들과는 달리, 입력패턴 자체의 차원별 특성을 이용하여 다른 입력벡터들을 동일한 규칙으로 학습시키므로 학습이 단순하고 패턴 분

류능력이 향상된다. 셋째, 제안된 방법에서는 어떠한 학습 규칙들도 각 신경망의 학습 알고리즘으로 사용이 가능하다. 본 논문에서는 기존의 학습규칙들 중에서 학습시간이 빠르고 구조가 단순한 경쟁학습 알고리즘을 개별 신경망의 학습규칙으로 사용한다.

본 논문의 II장과 III장에는 제안된 병렬 신경망과 동적 경쟁학습 알고리즘을 기술하고, IV장에서는 실험 결과를 보이고, V장에서 결론을 맺는다.

II. 감소된 입력 차원을 사용한 병렬 신경망

기존의 신경망들은 주어진 입력패턴의 모든 차원 성분을 이용한다. 그러나 입력 패턴의 모든 차원 성분이 패턴의 분류에 기여하는 것은 아니며, 문제에 따라서는 특정 차원 성분은 인식에 도움이 되지 못하고 인식을 어렵게 만들기도 한다^{16, 17)}. 또한 입력벡터의 차원 성분별로 인식에 기여하는 정도도 다를 수 있다. 하지만 패턴분류에 각 성분의 기여도를 미리 알아내는 것은 어렵다. 기여도를 계산하는 단순한 방법은 학습시에 한 차원 성분이 감소된 새로운 데이터 집합을 사용하고, 인식률을 계산하는 것이다.

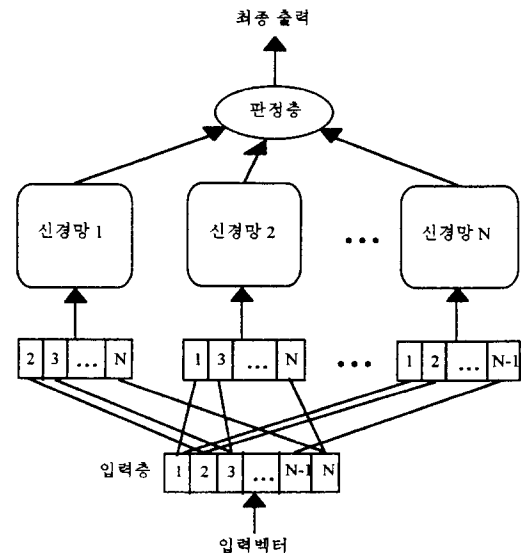


그림 1. 제안된 병렬 신경망

Fig. 1. The proposed parallel neural networks.

기존 방법의 단점을 극복하기 위하여, 주어진 입력패턴의 N차원 성분들을 순서대로 1개씩 제외시킨 N-1

입력 크기를 가지는 N개의 신경망들을 병렬 학습시키고 인식에 사용한다. 그림 1은 감소된 입력 차원을 사용하는 제안된 병렬 신경망을 보여준다.

N개의 신경망들의 전체 인식률들은 다를 것으로 기대된다. 게다가 각 신경망의 클래스별 인식률도 서로 다르다. N개의 병렬 신경망들을 사용한 클래스 판정은 임의의 개별 신경망에 의해 이루어지는 결정보다 오차가 작을 것이다^[8]. 기존의 다중 신경망들에서는 합의 이론(consensus theory)에 의거하여 각 신경망에 가중치를 두어 그 결과를 가중 합산(weighted sum)하는 방식도 사용하였다^[8, 9]. 이와 달리 본 논문에서는 N개의 신경망들을 결합하여 인식 클래스를 결정하기 위하여 간단하고 효율적인 3가지 합의방식(consensus scheme)을 사용한다.

먼저, 합의방식 1은 입력 패턴의 클래스로 사용된 신경망별 전체 인식률을 합하여 가장 큰 값을 가지는 클래스로 결정하였다. 이 방식은 클래스 결정이 보다 많은 신경망들에 의해 이루어지는 일종의 다수결 방식이다^[8, 10, 11].

두번째로, 합의방식 2는 사용된 N개의 신경망 중에서 전체 인식률이 가장 좋은 신경망만을 사용한다. 이 방법은 특정 차원이 패턴 분류능력을 감소시키는 현상을 실제로 이용하여 패턴인식에 바람직한 성분들만을 사용한다.

세번째로, 합의방식 3은 합의방식 1과 합의방식 2를 혼합한 방식이다. 이 방법은 각 클래스별로 최고 인식률을 가지는 신경망들만을 사용한다. 즉 인식에 기여하지 않는 신경망은 클래스 판정시에 사용하지 않는 방법이다.

제안된 방법은 몇가지 측면에서 기존의 다중 신경망들과는 구별된다. 첫째, 동일한 입력패턴들을 사용하여 초기 대표벡터, 훈련 데이터의 학습순서, 학습률등의 신경망 학습인자들을 다양하게 변경해 가면서 인식률 향상을 꾀하는 기존의 다중 신경망 방법들^[8, 10, 11]과는 달리, 입력패턴 자체의 차원별 특성을 최대한 살려 다른 입력벡터들을 동일한 규칙으로 학습시키는 모델이므로 학습이 단순하고 패턴 분류능력이 향상된다. 둘째, 제안한 방법은 단순 연결을 통하여 각 신경망에 다른 입력벡터들을 사용한다. 반면에 Benediktsson등과 Cho등이 제안한 다단계(multi-stage) 신경망 방법들은 다른 단계별 신경망들에 대하여 다른 입력벡터들을 사용한다^[9, 12]. 그러나 이 방법들에서는 원래

입력을 비선형적으로 변환시킨 입력이 다음 단계에 제시되므로 계산시간이 더 소요된다. 셋째, 제안된 방법에서는 어떠한 학습 규칙들도 각 신경망의 학습 알고리즘으로 사용이 가능하다. Cho등은 학습 시간을 단축하기 위하여 경쟁학습을 사용하였다^[12]. 본 논문에서도 기존의 학습규칙들 중에서 학습시간이 빠르고 구조가 단순한 경쟁학습 알고리즘을 개별 신경망의 학습규칙으로 사용한다.

III. 동적 경쟁학습 알고리즘

본 장에서는 제안된 병렬 신경망을 위한 새로운 학습 방법을 제시한다. 병렬 신경망의 개별 신경망들은 기존의 경쟁학습 규칙에 출력뉴런 생성 검사가 결합된 동적 경쟁학습 알고리즘을 사용하여 학습이 이루어진다. 따라서 각 개별 신경망은 크기가 고정된 입력층과 정해진 최대 개수에 도달할 때까지 가변적으로 증가하는 출력층을 가지는 2층(two-layer) 구조로 구성된다. 각 개별 신경망의 구조는 그림 2와 같다.




그림 2. 병렬 신경망의 개별 신경망 구조
Fig. 2. The architecture of individual network of parallel neural networks.

제안된 신경망의 학습 규칙은 클래스내 분산을 줄이는 방향으로 동적으로 출력뉴런들을 증가시켜 가면서 출력층 뉴런들을 자율 구성한다^[13]. 학습 과정은 다음과 같다.

- 단계1. 신경망 변수들을 초기화시킨다.
- 단계2. 새로운 패턴 $x(t)$ 를 입력한다 (이때 t 는 학습 회수를 의미).
- 단계3. 입력벡터와 모든 출력층의 대표벡터들과의 거리를 계산한다.
- 단계4. 최소 거리를 가지는 승자뉴런 j 의 대표벡터 w_j 를 선정한다.

단계5. 입력벡터가 승자뉴런의 대표벡터를 갱신할 것인지 여부를 결정한다.

즉 입력벡터와 승자뉴런과의 분산 $S_i(t)$ 를 계산하여 전 상태 분산과의 변화량 ΔS_i 를 계산한다. 또한 분산 변화량과 출력뉴런의 카운터 F_j 를 사용하여 승자뉴런 j 의 클래스 임계치 $\sigma_j(t)$ 를 계산한다.

$$S_i(t) = [x(t) - w_i(t)]^2 \quad (1)$$

$$\Delta S_i = S_i(t) - S_i(t-1) \quad (2)$$

$$\sigma_j(t) = \sigma_j(t-1) + \Delta S_j / F_j \quad (3)$$

분산 변화량과 갱신된 클래스 임계치의 크기를 비교하여 입력 패턴이 선택된 출력뉴런에 속할 것인지를 검사한다.

If $\Delta S_i \leq \sigma_j(t)$, then 단계7로 분기 (4)

else 단계6으로 분기

단계6. 입력벡터를 새로운 출력뉴런 k 로 생성하고, 단계8로 분기한다.

$$w_k(t) = x(t) \quad (5)$$

단계7. 출력뉴런 j 의 대표벡터를 갱신한다.

$$F_j = F_j + 1 \quad (6)$$

$$\Delta w_j = a(t) [x(t) - w_j(t)] \quad (7)$$

이때 학습률 $a(t) = a_0 \cdot (1/t)$ 를 나타낸다 (a_0 는 학습률 초기값).

단계8. 단계2로 분기하여 반복 수행한다.

제안된 학습 방법은 기존의 경쟁학습 알고리즘들과 다음의 면에서 다르다. 첫째, 일반적으로 경쟁학습 알고리즘들의 성능은 초기 대표벡터값에 의해 영향을 받는다. 제안된 신경망에서는 입력패턴이 학습된 출력뉴런의 클래스 임계치안에 들어오면 대표벡터를 변경함으로써 학습을 시키고, 그렇지 않으면 입력패턴을 새로운 출력뉴런으로 생성한다. 즉 생성된 출력뉴런의 대표벡터로 입력패턴을 사용하는 것이다. 이렇게 하면, 유사한 입력패턴들이 서로 다른 출력뉴런으로 중복 학습되는 현상을 막고, 출력뉴런마다 고유한 클래스 임계치를 가지게 되어 학습패턴을 수용할 수 있는 능력이 출

력뉴런마다 다르게 되므로, 임의의 분포를 가지는 패턴 인식에 적합하게 된다. 둘째, 양방향 학습을 수행하는 ART 모델과 달리 전방향(feedforward) 학습만을 수행하고, 학습 패러미터로서 클래스 임계치 1개만을 사용하므로 다수의 패러미터를 사용하는 ART2에 비하여 단순하다. 셋째, 제안된 방법은 어떠한 경쟁학습 알고리즘과도 결합할 수 있다. 예를 들어, 제안된 방법을 단순 경쟁학습(SCL)에 적용시키면, 동적 단순 경쟁학습(Dynamic Simple Competitive Learning : DSCL)이라 부른다.

IV. 실험 결과

제안된 동적 경쟁학습 신경망을 병렬로 학습시킴으로써 이들의 상호 협력 효과(synergism)를 보이기 위한 실험을 수행하였다. 상호 협력 효과는 대표적인 경쟁학습 알고리즘들인 단순 경쟁학습(SCL), 공평 경쟁학습(FSCL) 알고리즘들과 비교되었다. 본 논문에서는 원격 탐사 데이터와 음성 데이터를 실험 데이터로 사용하였다.

1. 실험 데이터 및 시뮬레이션

첫번째 실험 데이터로 미국 중부 지방의 평원 지역을 항공촬영한 8-밴드 8-클래스 원격 탐사 데이터를 사용하였다¹²¹. 그러므로 신경망의 입력들은 8차원 0에서 255사이의 정수값을 가지며, 8개의 클래스들은 풀밭, 옥수수, 귀리, 붉은 클로버, 콩, 밀, 공터, 호밀 등의 지역을 나타낸다. 학습은 클래스당 200개, 테스트는 클래스당 375개의 서로 다른 입력패턴으로 수행되었다. 따라서 전체 학습 및 테스트 패턴들의 수는 각각 1600 및 3000이다.

두번째 실험 데이터로 8개의 한국어 단모음(아, 에, 어, 예, 오, 우, 으, 이)를 사용하였다. 음성 데이터는 일반 실험실 환경에서 서로 다른 3명의 남성화자로 부터 발음된 샘플들을 전처리하여 12개의 셉스트럼(cepstrum) 계수와 전체 에너지를 얻는다¹⁴¹. 12개의 셉스트럼 계수와 전체 에너지를 포함한 13차원의 벡터가 신경망의 입력으로 사용된다. 음소당 600개의 특징벡터와 음소당 1200개의 또다른 특징벡터가 신경망의 학습 및 테스트를 위하여 각각 사용된다. 따라서 전체 학습 및 테스트 데이터의 수는 각각 4800 및 9600이다.

각 신경망은 80개의 출력뉴런들을 사용하였다. 즉 표

준 SCL과 FSCL은 80개의 출력뉴런들을 사용하고, 대표벡터들의 초기화는 각 클래스에 속하는 처음 10개 색의 패턴을 선택함으로써 수행되었다. 제안된 방법에서는 출력뉴런들의 최대 개수가 80으로 제한되고, 초기 클래스 임계치로 원격 탐사 데이터 실험에서는 0.5, 한국어 단모음 데이터의 경우에는 0.01이 사용되었다. 학습률은 초기값 0.9를 가지면서 선형 감소하는 값을 공통적으로 사용하였다.


2. 실험결과 및 분석

본 논문에서는 성능평가를 위해 대표적인 경쟁학습 알고리즘들인 SCL, FSCL 알고리즘들과 동적 경쟁학습 방법들인 DSCL(dynamic SCL), DFSCL(dynamic FSCL)등과 동적 경쟁학습 알고리즘을 사용하는 병렬 신경망 학습방법들 PDSCL(parallel DSCL), PDFSCL(parallel DFSCL)등을 비교하였다. 각 실험은 독립적으로 수행되었다. 즉, 먼저 학습회수(epoch)가 10인 실험을 수행하고, 학습회수 100과 1000인 실험을 새로 수행하였다. 그러므로 각 방법들에 대해 모두 3번의 실험이 수행되었다. 또한 학습회수 10, 100, 1000에서의 평균 인식률도 계산하였다.

그림 3은 원격 탐사 학습 데이터와 테스트 데이터에 대한 SCL, DSCL, PDSCLs(PDSCL1, PDSCL2, PDSCL3)의 인식률 그래프를 보여준다. 그래프에서 PDSCL1, PDSCL2, PDSCL3은 각각 동적 단순 경쟁학습 알고리즘과 합의방식 1, 합의방식 2, 합의방식 3을 사용하는 병렬 신경망 방법을 의미한다. 다음에 나오는 PDFSCLs도 마찬가지로 의미를 갖는다. 그림 4는 원격 탐사 학습 데이터와 테스트 데이터에 대한 FSCL, DFSCL, PDFSCLs의 인식률 그래프를 보여준다. 그림 3과 4를 관찰하면, 평균적으로 표준 방법들(SCL, FSCL)에 비하여 동적 경쟁학습 신경망들(DSCL, DFSCL)의 인식률이 좋으며, 이들을 병렬로 결합시킨 신경망들(PDSCLs, PDFSCLs)은 인식률이 보다 더 향상됨을 알 수가 있다. SCL 알고리즘의 경우에는 합의방식 1을 적용한 결과가 우수하며, FSCL 알고리즘의 경우에는 합의방식 3을 적용한 결과가 가장 우수하다.

그림 5와 6은 각각 한국어 단모음 학습 데이터와 테스트 데이터에 대한 (SCL, DSCL, PDSCLs), (FSCL, DFSCL, PDFSCLs)의 인식률 그래프를 보여준다. 그림 5와 6을 살펴보면, 원격 탐사 데이터 실험에


서와 비슷한 결과를 알 수가 있다.



(a) 학습 데이터 (b) 테스트 데이터

그림 3. SCL 알고리즘에 적용한 원격 탐사 데이터의 인식률 비교

Fig. 3. Classification accuracies applying to SCL algorithm for remote-sensing data.




(a) 학습 데이터 (b) 테스트 데이터

그림 4. FSCL 알고리즘에 적용한 원격 탐사 데이터의 인식률 비교

Fig. 4. Classification accuracies applying to FSCL algorithm for remote-sensing data.

특히 SCL 알고리즘의 경우에는 합의방식 2를 적용한 결과가 우수하며, FSCL 알고리즘의 경우에는 합의방식 3을 적용한 결과가 가장 우수하다.




(a) 학습 데이터 (b) 테스트 데이터

그림 5. SCL 알고리즘에 적용한 한국어 단모음 데이터의 인식률 비교

Fig. 5. Classification accuracies applying to SCL algorithm for Korean monophthongs data.

실험 결과들을 관찰해보면 전체적으로 표준 경쟁학습 알고리즘들(SCL, FSCL)에 비해 동적으로 출력뉴런을 생성하는 알고리즘은 인식률을 향상시키고, 입력 성분이 감소된 병렬구조의 동적 경쟁학습 신경망은 보다 더 향상된 인식 능력을 가지고 있음을 알 수 있다.

기본적으로 동적 경쟁 학습은 입력패턴들의 분포 특성을 반영하므로 입력벡터의 일부 차원 성분이 제거되면, 신경망의 성능 변화폭이 정적 신경망에 비하여 커지기 쉽다. 따라서 실험 데이터와 적용할 학습 알고리즘에 따라서 특정 합의방식이 항상 유리하다고 말하기 어렵다. 특히 동적 경쟁 학습 신경망을 병렬 학습시키면, 클래스별로 높은 인식률을 갖는 신경망들만을 사용하는 합의방식 3이 대체로 우수한 결과를 보이는 경향이 있다.



(a) 학습 데이터 (b) 테스트 데이터

그림 6. FSCL 알고리즘에 적용한 한국어 단모음 데이터의 인식률 비교

Fig. 6. Classification accuracies applying to FSCL algorithm for Korean monophthongs data.

V. 결론

본 논문에서는 새로운 병렬 경쟁 학습 신경망을 제안하였다. 제안된 병렬 신경망의 개별 신경망은 동적 경쟁 학습과 감소된 입력 차원 성분을 사용하여 학습된다. 개별 신경망은 다른 입력벡터를 사용하여 동적으로 출력 뉴런을 생성하면서 학습이 이루어진다. 학습이 종료 되면 상위의 판정층이 개별 신경망들의 인식 결과를 종합하여 최종 분류를 수행한다. 각 신경망은 감소된 입력 성분을 사용하여 병렬로 학습하고, 개별 신경망이 최대 크기의 출력 뉴런에 도달할 때까지는 생성된 출력 뉴런들에 대해서만 학습을 수행하므로 학습 시간은 단축된다. 이는 테스트 단계에서만 병렬처리가 이루어지는 다단계 신경망^[9, 12]과 학습이 병렬로 이루어지지만 모든 신경망들의 계산 결과를 고려한 학습을 수행하는 복수 경쟁 학습 신경망^[15]과는 달리 학습이 완전히 독립적으로 병렬로 수행되기 때문이다. 기존의 경쟁 학습 알고리즘들은 미리 지정된 초기 대표벡터들을 사용하므로 인식 성능이 이들의 영향을 받는다. 이에 본 논문에서는 가변적으로 출력층의 뉴런들을 생성하면서 초기 대표벡터를 지정하였다. 이렇게 하면 학습 패턴들의 분포에 어느 정도 무관하게 학습이 이루어지게 된

다.

제안한 바와 같이 병렬 신경망을 구축하는데는 비용이 증가한다. 하지만 제안된 병렬 신경망의 개별 신경망들은 감소된 차원을 사용하여 독립적으로 학습되고 테스트시에만 결합시키므로 수행 시간이 감소한다. 또한, VLSI 설계 기술이 발전함에 따라 알고리즘 설계에서 하드웨어 비용보다는 인식률과 처리속도가 더 중요한 요소로 인식되는 추세이다.

제안된 방법은 원격 탐사 데이터와 한국어 단모음 데이터를 사용하여 SCL, FSCL 등에 적용하여 실험하였다. 실험 결과들은 특정한 알고리즘에 어떠한 합의 규칙이 적합한지 미리 알기는 어렵지만, 제안된 병렬 경쟁 학습 신경망은 동적 구조의 경쟁 학습 신경망과 입력 성분이 감소된 병렬 신경망을 결합시킴으로써 상승 효과를 일으켜 인식률을 보다 더 향상시킴을 보여준다. 향후 연구과제로는 입력 성분을 감소시킬 수 있는 뚜렷한 기준 및 더 좋은 합의방식의 발견 등이 필요하다.

참고 문헌

- [1] Zurada, J.M., Introduction to Artificial Neural Systems, West Publishing Company, St. Paul, 1992.
- [2] Kohonen, T., Self-Organization and Associative Memory (3rd ed.), Springer-Verlag, Berlin, 1989.
- [3] Ahalt, S.C., Krishnamurthy, A.K., Chen, P., and Melton, D.E., "Competitive Learning Algorithms for Vector Quantization," Neural Networks, Vol. 3, pp. 277-290, 1990.
- [4] Lee, J.C., Sheu, B.J, Fang, W.C., and Chellappa, R., "VLSI Neuroprocessors for Video Motion Detection," IEEE Trans. on Neural networks, Vol. 4, pp. 178-191, 1993.
- [5] Carpenter, G. and Grossberg, S., "A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine," CVGIP, Vol. 37, pp. 54-115, 1987.
- [6] Kim, J.W., Ahn, J.S., Kim, C.S., Hwang, H.Y., and Cho, S.W., "Multiple Neural Networks using the Reduced

- Input Dimension," Proc. of 19th IEEE ASSP Conference, Adelaide, Vol. II, pp. 601-604, 1994.
- [7] Guo, Z. and Uhrig, R.E., "Using Genetic Algorithms to Select Inputs for Neural Networks," in Proc. of Int'l Workshop on Combinations of Genetic Algorithms and Neural Networks, pp. 223-234, 1992.
- [8] Lincoln, W. and Skrzypek, J., "Synergy of Clustering Multiple Back Propagation Networks," Advances in Neural Information Processing Systems 2, Morgan Kaufmann, San Mateo, CA, pp. 650-659, 1989.
- [9] Benediktsson, J.A., Sveinsson, J.R., Ersoy, O.K., "Parallel Consensual Neural Networks," Proc. of IEEE Int'l Conf. on Neural Networks, San Francisco, CA, Vol. 1, pp. 27-32, Mar., 1993.
- [10] Hansen, L.K. and Salamon, P., "Neural Network Ensembles," IEEE Trans. on PAMI, Vol. 12, No. 10, pp. 993-1001, 1990.
- [11] Hoffman, J., Skrzypek, J., and Vidal, J.J., "Cluster Network for Recognition of Handwritten, Cursive Script Characters," Neural Networks, Vol. 6, pp. 69-78, 1993.
- [12] Cho, S., Ersoy, O.K., and Lehto, M.R., "Parallel, Self-Organizing, Hierarchical Neural Networks with Competitive Learning and Safe Rejection Schemes," IEEE Trans. on Circuit and Systems, Vol. 40, No. 9, pp. 556-567, 1993.
- [13] Kim, J., Ahn, J., Kim, C.S., Hwang, H., and Cho, S., "A New Competitive Learning Algorithm with Dynamic Output Neuron Generation," Proc. of Int'l Conf. on Neural Networks, Orlando, Vol. II, pp. 692-697, Jun., 1994.
- [14] Shafer, R.W. and Rabiner, L.R., "Digital Representations of Speech Signals," in Waibel, AA. and Lee, K. eds Readings in Speech Recognition, Morgan Kaufman, San Mateo, CA, pp. 49-64, 1990.
- [15] Cheng, Y., "Clustering with Competitive Self-Organizing Maps," Proc. of IJCNN, Baltimore, Vol. IV, pp. 785-790, 1992.

 저 자 소 개



金 鍾 完(正會員)

1964년 11월 13일생. 1987년 2월 서울대학교 컴퓨터공학과 졸업(학사). 1989년 2월 서울대학교 대학원 컴퓨터공학과 졸업(석사). 1994년 8월 서울대학교 대학원 컴퓨터공학과 졸업(박사).

1991년 3월 ~ 1995년 2월 서울대학교 연구처 조교.
1995년 3월 ~ 현재 대구대학교 전자계산학과 전임강사. 주관심분야는 신경회로망, 지능정보 시스템, 패턴인식