

論文96-33B-2-18

가변 출력층 구조의 경쟁학습 신경회로망을 이용한 패턴인식

(Pattern Recognition Using Competitive Learning Neural Network with Changeable Output Layer)

鄭聖燁*, 趙成元*

(Seongyeob Jeong and Seongwon Cho)

요약

본 논문에서는 출력뉴런을 동적으로 생성하면서 초기 가중치벡터는 학습패턴으로부터 선정하는 지도방식의 새로운 경쟁학습 신경회로망을 제안하고, 이를 Dynamic Competitive Learning (DCL)이라 하였다. DCL은 등수의 한계(Limit of Grade:LOG)라는 파라메타를 도입하여 새로운 출력뉴런의 생성여부를 결정하며, 학습을 수행하기 위해 선정된 뉴런이 반드시 승자에만 해당되지는 않는다는 점에서 기존의 경쟁학습과 개념적으로 큰 차이를 두고 있다. 즉, LOG의 범위내에 속하면서 올바른 분류를 할 수 있는 뉴런들이 존재하면, 그 중 최소등수의 뉴런에 대해 학습을 수행하고, 그렇지 않은 경우 주어진 입력벡터로부터 새로운 출력뉴런을 생성한다. 제안된 신경회로망은 기존의 가변구조 신경회로망에 비해 학습자가 지정해주어야 하는 파라메타의 수가 적고 동시에 조정이 용이하다는 특징을 가지고 있으며, 원격 탐사 데이터와 필기체 숫자인식과 같은 패턴인식에 적용한 결과, 기존의 경쟁학습에 비해 우수한 성능을 보였다.

Abstract

In this paper, a new competitive learning algorithm called Dynamic Competitive Learning (DCL) is presented. DCL is a supervised learning method that dynamically generates output neurons and initializes weight vectors from training patterns. It introduces a new parameter called LOG(Limit of Grade) to decide whether or not an output neuron is created. In other words, if there exist some neurons in the province of LOG that classify the input vector correctly, then DCL adjusts the weight vector for the neuron which has the minimum grade. Otherwise, it produces a new output neuron using the given input vector. It is largely different from the previous competitive learning neural networks that the selected neuron for learning is not limited only to the winner and the output neurons are dynamically generated in the training process. In addition, the proposed algorithm has a small number of parameters, which are easy to be determined and applied to the real problems. Experimental results for pattern recognition of remote sensing data and handwritten numeral data indicate the superiority of DCL in comparison to the conventional competitive learning methods.

I. 서론

* 正會員, 弘益大學校 電氣·制御工學科

(Dept. of Electrical & Control Eng., Hong-Ik Univ.)

接受日字: 1995年6月13日, 수정완료일: 1996年1月12日

문자인식, 음성인식을 비롯한 패턴인식은 실세계의 대상물을 묘사한 패턴을 구체적인 부류로 분류하여 인식하는 것으로 이러한 능력을 기계에게 부여할 수 있

다면, 인간과 기계 사이의 자연스러운 인터페이스를 구현할 수 있음과 동시에 수많은 작업의 자동화가 가능하기 때문에, 이를 실현하기 위한 연구가 다양하게 진행되고 있다. 패턴인식의 대표적인 접근 방법으로는 크게 통계적 방식, 구문론적 방식, 신경회로망 방식의 세 가지가 있으며, 이 중 병렬처리(parallel processing), 강인함(robustness), 일반화능력(generalization) 등의 장점을 가진 신경회로망 방식이 근래에 와서 각광받고 있다. 가장 대표적인 신경회로망으로 알려진 Backpropagation(BP)은 학습자가 학습패턴과 원하는 값을 함께 가르쳐 주는 지도학습(supervised learning)을 사용하는 알고리즘으로, 많은 계산시간과 더불어 학습패턴에 대한 지나친 편향으로 신경회로망의 가장 큰 장점 중 하나인 일반화능력이 문제시되어 왔고, 따라서 최근에는 경쟁학습으로 대표되는 비지도학습(unsupervised learning)에 관한 연구가 활발히 진행되고 있다.

하지만, 비지도학습을 사용하는 Simple Competitive Learning(SCL), Frequency Sensitive Competitive Learning(FSCL), Kohonen의 Self-Organizing Feature Map(SOFM)과 비지도방식의 경쟁학습을 지도방식으로 수정한 Learning Vector Quantization(LVQ)을 비롯한 일반적인 경쟁학습 알고리즘들은 고정구조의 신경회로망을 사용하므로, 학습 전 미리 정해야 하는 출력뉴런의 수와 초기 가중치벡터들의 분포에 따라 학습성능이 지나치게 좌우되는 문제점을 가지고 있다. 이에 반해, Carpenter와 Grossberg의 Adaptive Resonance Theory (ART)는 가변구조의 신경회로망을 도입한 가장 대표적인 모델로서, 기존에 학습되었던 것이 새로운 학습에 의해 지워지지 않도록 새로운 지식을 자동적으로 전체 지식베이스에 일관성 있는 방법으로 통합하는 유연성(plasticity)을 가지고 있다. 비지도학습의 이 모델은 인간의 학습형태를 가장 잘 모방하였다고는 하나, 그 구조 및 학습 알고리즘이 복잡하고 다수의 학습 파라메타들의 적절한 조절이 어려워 실제 문제에 적용시키기가 용이하지 않다.

따라서, 본 논문에서는 출력뉴런을 학습과정중에 동적으로 생성하면서 초기 가중치벡터는 학습패턴으로부터 선정하는 지도방식의 새로운 경쟁학습 신경회로망을 제안하고, 이를 Dynamic Competitive Learning (DCL)이라 하였다. DCL은 출력뉴런의 생성여부를

결정하기 위해 등수의 한계(Limit of Grade:LOG)라는 새로운 학습 파라메타를 도입하였으며, 차기등수의 뉴런에 대해서도 학습을 수행할 수 있다는 점에서 기존의 경쟁학습과 개념적으로 큰 차이를 두고 있다. 구조면에서는 출력층이 가변인 것을 제외하면 일반적인 경쟁학습 신경회로망과 동일하고, ART를 비롯한 가변구조 신경회로망에 비해 학습자가 지정해 주어야 하는 파라메타의 수가 적고 동시에 조정이 용이하다는 이점을 가지고 있다.

II. 대표적인 경쟁학습 신경회로망

1. Simple Competitive Learning(SCL)

SCL은 비지도방식을 사용하는 경쟁학습 알고리즘의 가장 간단한 형태로서 학습규칙이 단순하고 하드웨어 구현시 구조가 간단하여 널리 이용되고 있다. 이 방법은 입력벡터와 출력뉴런들간의 유 кл리디안 거리를 계산한 후, (식 1)과 같이 거리가 가장 작은 뉴런을 승자뉴런 c 로 선정하여 학습을 수행한다. 학습규칙은 (식 2)와 같고, $\alpha(t)$ 는 시간에 따라 단조감소하는 학습률을 나타낸다.

$$\| \mathbf{x} - \mathbf{w}_c \| = \min_i \| \mathbf{x} - \mathbf{w}_i \| \quad (1)$$

$$\mathbf{w}_i(t+1) = \begin{cases} \mathbf{w}_i(t) + \alpha(t) \cdot [\mathbf{x}(t) - \mathbf{w}_i(t)] & , \text{ if } i=c \\ \mathbf{w}_i(t) & , \text{ if } i \neq c \end{cases} \quad (2)$$

하지만 이 알고리즘은 매번 승자뉴런에 대해서만 학습을 진행하는 승자독점(winner-take-all)의 학습형태를 취하므로 초기 가중치벡터들의 분포에 따라 학습이 전혀 또는 거의 이루어지지 않는 미학습 뉴런(dead neuron)이 생기는 문제가 발생하였다.

2. Frequency Sensitive Competitive Learning(FSCL)

FSCL은 SCL의 미학습 뉴런 문제를 보완하기 위해 제안된 알고리즘으로, 승리의 빈도가 높은 뉴런에 대해 양심(conscience)을 부여하여 이후에 타 뉴런이 승자가 될 확률을 높여주는 것을 기본 개념으로 한다. 즉, 모든 출력뉴런들의 승자가 되는 횟수를 계산한 후, 자주 승리하는 뉴런에게 벌(penalty)을 주어 모든 출력뉴런들이 평균적으로 비슷한 횟수만큼 학습하게 하는 것이다. 학습규칙은 SCL과 동일하나, (식 3)에 나타낸 바와 같이 승자뉴런의 선정시 양심에 해당하는 ρ_i

가 추가된다. 가장 간단한 양심의 형태로는 (식 4)를 사용할 수 있고. 이때 n_i 는 출력뉴런 i 가 승자인 빈도 수를 의미한다.

$$c = \arg \min_i \{ \rho_i \cdot \| \mathbf{x} - \mathbf{w}_i \| \} \quad (3)$$

$$\rho_j = \frac{n_j}{\sum n_i} \quad (4)$$

이 방식은 주어진 입력벡터들의 대표벡터를 효과적으로 계산하는 능력을 가지므로 Vector Quantization(VQ)과 같이 입력벡터와 대표벡터간의 오차를 줄이는 문제에 효과적인 것으로 알려져 있으나. 학습할 데이터의 특성에 따라 양심의 정도를 조절하는 것이 어렵다는 문제점도 내포하고 있다.

3. Self-Organizing Feature Map(SOFM)

SCL, FSCL이 승자독점 형태의 학습을 수행하는데 반해, Kohonen의 SOFM은 승자뉴런과 위상적으로 이웃한 뉴런들도 함께 학습함으로써, 인간의 두뇌와 마찬가지로 유사한 입력패턴들을 인접한 출력뉴런들간에 기하학적인 관계로 형성하게 된다. 승자뉴런의 선정은 SCL의 경우와 동일하고, 학습규칙은 (식 5)와 같다. 이때, $N_c(t)$ 는 승자뉴런 c 를 포함한 이웃뉴런(neighbor neuron)들의 집합을 의미하며, 시간에 따라 서서히 감소하는 형태를 가진다.

$$\mathbf{w}_i(t+1) = \begin{cases} \mathbf{w}_i(t) + \alpha(t) \cdot [\mathbf{x}(t) - \mathbf{w}_i(t)] & , \text{ if } i \in N_c(t) \\ \mathbf{w}_i(t) & , \text{ if } i \notin N_c(t) \end{cases} \quad (5)$$

이와 같이 승자뉴런 이외에도 이웃뉴런들까지도 학습에 참여시킴으로써 가중치벡터는 학습패턴과 유사한 분포를 가지게 된다. 이 방법은 SCL에 비해 초기 가중치벡터의 영향을 적게 받고 더욱 안정된 학습을 진행하며, 음성 타자기와 최적화 문제 등에서 좋은 성능을 나타내기도 하였다. 하지만, SCL이나 FSCL과 마찬가지로 학습 전 미리 정해주어야 하는 출력뉴런의 수에 따라서는 학습성능이 크게 변한다.

4. Learning Vector Quantization(LVQ)

비지도방식의 경쟁학습을 지도방식으로 수정한 LVQ는 고전적인 Vector Quantization(VQ) 방식을 도입한 알고리즘으로 Kohonen에 의해 제안되었다. VQ는 이전부터 알려진 패턴분류 기법이며, 패턴공간을 유한 개의 참조벡터(reference vector)로 양자화하는 것이다. LVQ는 이러한 VQ 기법을 발전시킨 것으로서 참

조벡터를 뉴런들간의 가중치벡터에 대응시키고, 지도학습을 이용함으로써 적절한 참조벡터를 구하는 방법이다. (식 6)의 학습규칙에서 보는 바와 같이 입력벡터가 올바르게 분류되었을 때와 그렇지 않은 경우로 나누어 학습을 진행한다.

$$\mathbf{w}_c(t+1) = \mathbf{w}_c(t) + \alpha(t) \cdot [\mathbf{x}(t) - \mathbf{w}(t)] \quad \text{if } \mathbf{x} \text{ is classified correctly}$$

$$\mathbf{w}_c(t+1) = \mathbf{w}_c(t) - \alpha(t) \cdot [\mathbf{x}(t) - \mathbf{w}(t)] \quad \text{if the classification of } \mathbf{x} \text{ is incorrectly}$$

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) \text{ for } i \neq c$$

이 방법은 간단한 학습 알고리즘으로 고도의 패턴분류가 가능하나, 일반적인 경쟁학습과는 달리 음(negative)의 학습 부분을 포함하고 있으므로, 이를 패턴분류에 적용할 경우 초기 가중치벡터와 초기 학습률의 적절한 선택이 요구되고, 그렇지 않을 경우 안정성(stability)에 있어서의 문제가 발생할 수 있다. Kohonen은 이 알고리즘을 수정하여 LVQ2, LVQ2.1, LVQ3를 제안하기도 하였다.

5. Adaptive Resonance Theory(ART)

Carpenter와 Grossberg가 제안한 ART는 통계적 방식에서 사용되는 순차적인 리더 클러스터링 알고리즘(sequential leader clustering algorithm)을 도입한 모델로서, 학습패턴의 분포에 따라 출력뉴런을 동적으로 생성하면서 학습을 수행한다. 이때, (식 7)과 같은 정합검사를 통해 입력벡터와 저장된 가중치벡터와의 유사성(similarity)을 계산하며, 이 값을 경계치파라메타(vigilance parameter)와 비교함으로써 출력뉴런의 생성여부를 판단한다. 여기서 \mathbf{x} 는 입력벡터, t 는 하향(top-down) 가중치벡터, N 은 입력뉴런의 수, ρ 는 경계치 파라메타를 나타낸다.

$$\begin{aligned} \| \mathbf{x} \| &= \sum_{i=0}^{N-1} x_i \\ \| t \cdot \mathbf{x} \| &= \sum_{i=0}^{N-1} t_i x_i \\ \frac{\| t \cdot \mathbf{x} \|}{\| \mathbf{x} \|} &\geq \rho \end{aligned} \quad (7)$$

ART의 동작 알고리즘은 완벽한 입력패턴에 대해서는 잘 동작하지만 작은 잡음이 첨가되어도 문제가 발생하는 단점이 있다. 따라서, 잡음에 대한 강한 특성을

갖도록 보완해야 할 필요가 있는데, 이를 위하여 가중치를 보다 서서히 조정하고 학습중에 경계치 파라메타의 값을 변경하는 방법 등이 사용되고 있다. 또한, 이 모델은 입력패턴이 이진수인 경우에만 처리가 가능하고, 아날로그 데이터도 처리할 수 있도록 제안된 ART2는 경계치 파라메타 이외에도 다수의 파라메타들을 추가로 가지게 되므로 적절한 학습을 수행하는 것 이 용이하지 않다. 따라서, 최근에는 ART 모델에 대한 최적화된 학습 파라메타들의 값을 찾기 위해 유전자 알고리즘(Genetic Algorithm:GA)이 사용되기도 하였다.

III. Dynamic Competitive Learning 신경회로망

1. 기본 개념 및 사용되는 용어

본 논문에서 제안한 DCL 신경회로망은 일반적인 경쟁학습 신경회로망과 마찬가지로 입력층과 출력층의 2 층으로 이루어져 있으나 출력층의 뉴런들을 학습과정 중에 동적으로 생성하며, 전방향(feedforward)으로만 가중치를 변경한다. 학습 알고리즘은 하나의 입력벡터에 대해 하나의 가중치벡터만이 생성된다는 측면에서 SCL과 유사하나, 차기등수의 뉴런도 학습을 수행할 수 있다는 점에서 기존의 경쟁학습과 개념적으로 큰 차이를 두고 있다. 즉, 대부분의 경쟁학습은 승자뉴런 또는 승자뉴런을 포함한 이웃뉴런에 대해서 학습을 수행하므로, 차기등수의 뉴런이 학습할 수 있다는 것은 출력뉴런을 동적으로 생성하는 것과 더불어 DCL의 가장 큰 특징이라고 할 수 있다.

제안된 방법은 학습과정중에 출력뉴런을 생성하는 지도방식의 경쟁학습 신경회로망으로, 등수의 한계라는 새로운 학습 파라메타를 도입하여 출력뉴런의 생성여부를 결정한다. 즉, 등수의 한계를 넘지 않으면서 올바른 분류를 할 수 있는 승자 또는 차기등수의 뉴런들이 존재하면 그 중 최소등수의 뉴런을 선정하여 학습을 수행하고, 그렇지 않은 경우 주어진 입력벡터를 이용하여 새로운 출력뉴런을 생성한다. 여기서, 각 클래스별 등수의 한계는 학습이 진행됨에 따라 단조증가하는 형태를 취하여 생성되는 출력뉴런의 수가 발산되는 것을 방지한다.

본 논문에서 제안된 신경회로망에서 사용되는 용어를 정리하면 다음과 같다.

t	: 현재의 학습시점(iteration)을 나타내는 변수
n	: 현재까지 생성된 전체 출력뉴런의 수
J	: 학습패턴에 대한 전체 클래스수
j	: 클래스의 번호를 나타내는 인덱스. $1 \leq j \leq J$
I	: 출력뉴런의 번호를 나타내는 인덱스. $1 \leq i \leq n$
x_j	: 학습패턴중 클래스 j 에 속하는 입력벡터
LOG_j	: 출력뉴런의 생성기준인 각 클래스별 등수의 합계
ϵ	: LOG 파라메타의 gain
n_j	: 생성된 출력뉴런들 중 클래스 j 로 지정된 뉴런의 수
w_i	: 출력뉴런 i 에 대한 가중치벡터
u_i	: 출력뉴런 i 의 레이블, 즉 소속 클래스
u	: 전체 출력뉴런에 대한 레이블벡터. $u = [u_1, u_2, \dots, u_n]^T$
c_r	: r 등에 해당하는 출력뉴런(단, 승자는 1등 으로 가정)

$\alpha(t)$: 학습시점 t 일 때의 학습률
이 가운데 u_i 는 출력뉴런의 생성시 지정되는 출력뉴런의 소속 클래스, 즉 레이블을 나타내고, ϵ 은 각 클래스별 LOG 파라메타의 값을 조절하기 위한 gain을 나타낸다.

2. DCL 신경회로망의 학습 알고리즘

학습 알고리즘은 파라메타들의 초기화에 이어, 등수의 한계를 넘지 않으면서 올바른 분류를 할 수 있는 최소 등수의 뉴런 설정 및 가중치벡터의 생성, 또는 입력벡터를 이용한 새로운 출력뉴런의 생성 과정을 거쳐, 파라메타의 조정 순으로 이루어진다. 모든 학습을 수행한 후 재레이블링(relabeling) 과정을 거쳐 최종적인 가중치벡터와 레이블벡터 u 를 얻을 수 있으며, 구체적인 알고리즘은 다음과 같다.

Step 0. Initialize parameters:

$t=0, n=0$
 $\alpha(0) \in (0,1)$
 $n_j=0$ for $j=1, 2, \dots, J$
 $\text{LOG}_j=1$ for $j=1, 2, \dots, J$

Step 1. While stopping condition is false, do Steps 2-8.

- Step 2. For each training input vector x_j , do
 Steps 3-7.
- Step 3. For $r=1 \cdots LOG_j$
- Find
 $\|x_j - w_c\| = \min\{\|x_j - w_i\|\}$
 - If $u_{c_r} = j, i \neq c_r$, update the weight vector and go to Step 5:
- $$w_{c_r}(\text{new}) = w_{c_r}(\text{old}) + \alpha(t) \cdot [x_j - w_{c_r}(\text{old})]$$
- Next r.
- Step 4. If $u_{c_r} \neq j$ for all r, then create a new output neuron and initialize the weight vector:
 $n = n+1, n_j = n_j + 1$
 $w_n(\text{new}) = x_j, u_n = j$
- Step 5. Adjust limit of grade LOG_j .
- Step 6. Reduce learning rate $\alpha(t)$.
- Step 7. Next t:
- Step 8. Test stopping condition:
 The condition may specify a fixed number of iterations.
- Step 9. Relabeling.

위와 같은 학습을 수행하는 DCL은 (Step 3)에서 알 수 있듯이, 학습할 뉴런을 선정하는 데 있어서 등수의 한계라는 파라메타를 이용하고, 이렇게 하여 선정된 뉴런은 반드시 승자에게만 제한되지는 않는다. 따라서, 등수의 한계 내에 속하면서 올바른 분류를 할 수 있는 승자 또는 차기등수의 뉴런이 선정될 수 있으면 비록 승자가 아니라 할지라도 학습을 진행하고, 그렇지 않으면 주어진 입력벡터를 이용하여 새로운 출력뉴런을 생성한다. 하지만, 입력벡터 x_j 를 이용하여 클래스 j로 지정된 생성뉴런은 이후의 학습에 의해서도 불변하는 레이블을 가지게 되어, 차기등수의 뉴런에 대해서도 학습이 가능한 DCL의 특성상 일부 뉴런들의 레이블은 학습 후에 잘못 지정되어 있을 수 있다. 따라서, 모든 학습이 끝난 후에 (Step 9)의 재레이블링 과정을 거친 새로운 레이블벡터 u 를 얻음과 동시에, 미학습 뉴런 (dead neuron)들을 제거하는 역할을 수행한다.

DCL은 출력뉴런의 생성기준으로 LOG 파라메타를 이용하고, 생성뉴런수의 발산을 방지하기 위해 시간에

따라 단조증가하는 형태를 갖는다. 이에 대한 형태로서 (식 8)이나 (식 9)를 사용할 수 있다(단, 소수점 이하 버림). 식에서 보는 바와 같이, LOG 파라메타를 출력 뉴런수와 연계시킴으로써 DCL은 학습의 초기부분에서 대부분의 출력뉴런을 생성한다. (단, $0 < \epsilon \leq 1.0$)

$$LOG_j = 1 + \epsilon \cdot n_j \quad (8)$$

$$LOG_j = 1 + \epsilon \cdot n \quad (9)$$

이때, gain ϵ 의 값을 변화시켜 생성되는 출력뉴런의 수를 조절할 수도 있으며, 일반적으로 ϵ 이 1에 가까울수록 적은 수의 출력뉴런이 생성되어 학습패턴에 대한 인식률은 낮아진다. 반대로, ϵ 이 0에 근접한 경우 상대적으로 많은 수의 출력뉴런을 가지게 되고, 학습패턴에 대한 인식률은 높아지는 특성을 보인다. 하지만, 일반적인 경쟁학습의 경우와 마찬가지로, 많은 수의 출력뉴런을 가진다고 해서 반드시 우수한 성능을 얻을 수 있는 것은 아니므로, LOG 파라메타의 형태 및 gain 값을 적절하게 조절하여 좋은 성능을 기대할 수 있다. 특히, (식 9)에서 $\epsilon = 1.0$ 으로 할 경우, LOG 파라메타가 생성뉴런 전체를 고려하게 되어, 학습패턴의 클래스수와 동일한 수의 출력뉴런을 생성하게 된다.

3. DCL 신경회로망의 특징

DCL은 SCL, FSCL, SOFM, LVQ를 비롯한 기존의 경쟁학습 신경회로망에서 사용되는 고정구조 대신 ART와 같은 가변구조의 신경회로망을 이용하여, 출력 뉴런을 학습과정중에 동적으로 생성한다. 따라서, 학습 성능에 큰 영향을 미치는 출력뉴런의 수와 초기 가중치벡터를 학습 전에 미리 정할 필요가 없다. ART 모델은 가변구조의 신경회로망을 사용한다는 측면에서 제안된 방법과 유사하나, 상향(bottom-up)과 하향(top-down) 가중치벡터를 동시에 가지므로 양방향의 학습을 수행하고, 실수입력에 대해서도 처리가 가능한 ART2의 경우에는 다수의 학습 파라메타들을 추가로 가지게 되어 실제 구현이 쉽지 않다. 이에 반해, DCL은 전방향으로만 학습을 수행하고, 학습 파라메타도 등수의 한계 하나만을 추가로 이용하여 알고리즘이 훨씬 단순해진다.

제안된 신경회로망은 학습을 수행할 뉴런의 선정 또는 새로운 출력뉴런의 생성 기준으로 등수의 한계라는 새로운 파라메타를 도입하였다. 즉, 등수의 한계 내에 속하면서 올바른 분류를 할 수 있는 뉴런이 존재하면

그 중 최소 등수의 뉴런을 선정하여 학습을 진행하고, 그렇지 않은 경우 입력벡터를 사용하여 새로운 출력뉴런을 생성한다. 이와 같이 주어진 입력을 통해 출력뉴런을 생성하는 DCL의 특성은 미학습 뉴런의 발생 확률을 작게 하며, 이때 각 클래스별 등수의 한계는 시간에 따라 단조증가하는 형태를 취하여 생성되는 출력뉴런수의 발산을 방지한다. 등수의 한계를 조절하기 위한 LOG 파라메타의 형태와 gain값은 학습 전 미리 정해지며, 이를 변화시켜 생성뉴런의 수를 증감시킬 수도 있다.

이와 같은 특성으로 인해 DCL의 가중치벡터 분포는 기존의 방법에 비해 상대적으로 오인식률이 높은 부분, 즉 각 클래스들의 인접부분에 좀 더 많이 할당될 수 있다. 하지만, 이것은 학습성능을 저하시키도록 작용할 수도 있으므로, 모든 학습이 끝난 후 출력뉴런의 재레이블링 과정을 거쳐 인접부분 출력뉴런들의 일부를 제거하거나, 소속 클래스를 다시 지정해줄 수 있다. 즉, 재레이블링 과정을 거쳐, 클래스들의 인접부분이 완전한 임의 분포에 가까울수록 그 부분에 할당되는 출력뉴런을 제거해 주고, 반대로 어느 정도의 규칙성을 가지고 있다면 그대로 두어 인식성능을 향상시킬 수 있다. 이때, 레이블링 및 학습률은 비지도방식을 사용하는 일반적인 경쟁학습 신경회로망의 경우와 동일한 방식을 적용할 수 있다. 학습과정에서 단조감소하는 학습률의 초기값은, 주어진 입력에 의해 출력뉴런을 생성하는 DCL의 특성상 비교적 작은 값($0 < \alpha(0) < 0.5$)을 사용하는 것이 유리하다.

IV. 원격탐사 데이터의 패턴인식

1. 개요

본 절에서는 제안된 신경회로망에 대한 실제 패턴인식 문제로의 적용 가능성을 타진해 보기 위해, 최근 패턴인식 분야로서 응용빈도가 높아지고 있는 원격탐사 데이터(remote sensing data)에 대한 시뮬레이션을 수행하고, 이를 비지도방식의 FSCL, SOFM 신경회로망과 비교하여 우수성을 확인한다.

2. 원격탐사 데이터

원격탐사란 대상물의 특성을 전자파에 의한 간접적인 방법으로 수집하여 처리 및 분석하는 기술이다. 이렇게 얻어진 데이터는 광범위한 지역의 공간적(spatial),

분광적(spectral) 정보이며, 인공위성 또는 항공기에 탑재된 센서를 이용하여 주기적으로 수집되므로 원하는 시기의 정보가 사용자에게 효과적으로 제공된다. 수집된 정보는 처리 및 분석 과정을 거쳐 지형정보, 국토정보, 환경정보, 식생정보, 자원정보 등의 추출에 이용된다.

실험에 사용한 데이터는 Flight Line C1(FLC1)으로 불리는 다중분광 지상관측 원격탐사 데이터(multi-spectral earth observational remote sensing data)로서, 미국 인디애나주 Tippecanoe County 남부지역의 농작물 재배지역을 촬영한 것이다. 이 데이터들은 256 명암수준(gray level)으로 표현되고, 8개의 클래스가 8개의 주요 농산물을 대표하도록 선택되었다. 각 클래스는 학습을 위한 200개와 테스트를 위한 375 개의 패턴을 가지며, 하나의 패턴은 8차원으로 구성된다.

3. 실험 및 결과

제안된 DCL 신경회로망은 학습횟수(epoch) 50에서 100까지 10씩 증가시키면서 6단계로 학습하였고, 비교실험을 수행한 FSCL의 출력뉴런수는 6단계로 나누어 실험한 DCL의 최대 생성뉴런수와 동일한 89개로 하였으며, SOFM에 대해서는 약간 크거나 같은 규모로 정방형의 이웃뉴런을 구성할 수 있는 10×10 으로 하였다. 이때, FSCL, SOFM의 초기 학습률은 0.9, 제안된 방법에 대해서는 0.3이고, 학습률은 시간에 따라 단조감소하는 형태로써 (식 10)을 사용하였다. DCL의 LOG 파라메타 형태는 (식 8)을 사용하였고, 이때 ϵ 은 0.2로 하였다. 인식결과는 DCL의 경우 (표 1), FSCL과 SOFM의 경우는 (표 2)에 나타내었다.

$$\alpha(t) = \alpha(0) \cdot \left(1 - \frac{t}{\text{Number of Iterations}}\right) \quad (10)$$

표 1. DCL의 인식률

Tabel 1. Recognition rate for DCL.

Epoch	생성뉴런수	학습(%)	테스트(%)
50	82	97.938	93.9
60	84	97.875	93.7
70	84	97.688	93.9
80	82	97.438	93.933
90	89	97.688	93.867
100	84	97.438	93.833
평균	84.1675	97.667	93.856

표 2. FSCL, SOFM의 인식률
Tabel 2. Recognition rate for FSCL, SOFM.

Epoch	FSCL		SOFM	
	학습(%)	테스트(%)	학습(%)	테스트(%)
50	94	91.733	92.688	92.267
60	94.75	92.167	92.75	90.267
70	93.125	91.333	92.438	90.2
80	95.312	92.733	92.625	92
90	93.25	91.767	92.5	91.1
100	94.312	93.567	93.062	91.2
평균	94.125	92.217	92.677	91.172

V. 필기체 숫자인식

1. 개요

일반적으로 패턴인식 시스템은 크게 두 부분으로 나눌 수 있다. 첫번째는 주어진 패턴에 대해 최대한의 정보를 제공할 수 있는 파라메타를 계산하는 특징추출 부분이고, 두번째는 추출된 특징을 이용하여 인식하는 분류기(classifier) 부분이다. 이 중 분류기 부분은 전자에 비해 상당한 진척을 보이고 있으나, 특징추출 부분은 일반적인 접근이 어렵다고 알려져 있다. 따라서, 패턴인식의 가장 어려운 문제점은 적합한 방법으로 주어진 패턴을 기술할 수 있는 특징을 추출하는 것이며, 특히 문자인식의 경우 회전(rotation), 위치(translation), 크기(scaling) 등에 불변하는(invariant) 특징을 찾는 것이 중요하다. 이에 본 논문에서는 문자인식 및 형상구별(shape discrimination) 분야에서 널리 사용되고 있는 푸리에 기술자(Fourier descriptor)를 이용하여 필기체 숫자인식 시스템을 구현하였으며, LVQ, SOFM과의 비교실험을 통해 제안된 신경회로망의 우수성을 타진해 보았다.

2. 데이터 획득 및 특징추출

본 실험에서 사용한 데이터는 홍익대학교 남녀학생 100명에 의해 작성된 다양한 위치, 크기, 방향의 필기체 숫자들을 CCD 카메라와 image grabber를 이용하여 획득한 128×128 픽셀, 128 명암수준(gray level)의 숫자영상이며, 그 예를 (그림 1)에 나타내었다. 전처리 과정으로써, 이진화(thresholding)를 거친 흑백영상으로부터 숫자의 윤곽선을 따라 14개의 푸리

에 기술자를 계산하였고, 회전, 위치, 크기에 불변하는 12차원의 특징벡터들을 추출하여 신경회로망의 입력으로 사용하였다.



그림 1. 128×128 의 숫자영상
Fig. 1. 128×128 numeral image.

3. 실험 및 결과

학습회수, 출력뉴런수 및 학습률과 LOG 파라메타의 형태는 원격탐사 데이터의 경우와 동일하게 하였고, DCL, LVQ, SOFM의 초기 학습률은 각각 0.3, 0.4, 0.9이다. 특히, LVQ는 지도학습이라는 측면에서 DCL과 동일하나, 음의 학습을 포함한 학습규칙을 사용하여 학습률과 가중치벡터의 초기치에 따라 학습성능이 크게 좌우된다. 따라서 본 실험에서는 학습패턴에 의해 가중치벡터를 초기화하고, 수차례의 시뮬레이션을 통해 0.4의 초기 학습률을 설정하였다. DCL, LVQ 및 SOFM의 인식결과는 (표 3)~(표 4)에 나타내었다.

표 3. DCL의 인식률

Tabel 3. Recognition rate for DCL.

Epoch	생성뉴런수	학습(%)	테스트(%)
50	110	97.4	84.4
60	110	97.6	84.6
70	110	97.8	84.6
80	110	97.8	84.4
90	111	97.8	84.6
100	111	97.8	84.6
평균	110.333	97.7	84.533

표 4. LVQ, SOFM 인식률

Tabel 4. Recognition rate for LVQ, SOFM.

Epoch	LVQ		SOFM	
	학습(%)	테스트(%)	학습(%)	테스트(%)
50	92.2	83.4	85.6	76.8
60	92	82.2	86.4	76
70	91.8	82.6	86.2	75.2
80	91.6	82.6	85.8	79.2
90	91.8	82.6	86.6	78.2
100	92	82.8	86.8	79.2
평균	91.9	82.7	86.233	77.433

IV. 결 론

본 논문에서는 출력뉴런의 수를 학습 전 미리 정하지 않고 등수의 한계(Limit of Grade:LOG)라는 파라메타를 도입하여 동적으로 생성하면서 초기 가중치 벡터를 학습패턴으로부터 선정하는 지도방식의 새로운 경쟁학습 신경회로망을 제안하여, 이를 Dynamic Competitive Learning (DCL)이라 하였다. DCL의 대표적인 특징으로는 일반적인 경쟁학습 알고리즘의 인식률에 큰 영향을 미치는 출력뉴런의 수를 미리 정하지 않는다는 점과 학습 알고리즘 자체가 가중치벡터의 초기화과정을 포함하고 있다는 점, 기존의 가변구조 신경회로망에 비해 구조와 학습 알고리즘이 간단하고 파라메타의 수가 적다는 것 등을 들 수 있다. 또한, 출력뉴런의 생성시 입력벡터를 이용하므로 미학습 뉴런(dead neuron)의 발생 확률이 적어지고, LOG 파라메타의 형태와 gain값을 조절하여 생성되는 출력뉴런의 수를 증감시킬 수 있다. 이는 주어진 패턴의 분포특성에 따라 변할 수 있어야 하고, 적절한 값을 선택하여 보다 우수한 인식률을 얻을 수 있을 것이다.

이와 같이 제안된 신경회로망의 성능평가를 위해 원격탐사 데이터와 128×128 의 필기체 숫자 데이터에 대한 실험을 수행하였고, 그 결과 비교실험으로 사용한 FSCL, LVQ, SOFM보다 우수한 성능을 확인할 수 있었다.

참 고 문 헌

- [1] S.-T. Bow, Pattern Recognition and

- Image Processing, Dekker, 1992.
- [2] G. A. Carpenter and S. Grossberg, "A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine", Computer Vision, Graphics, and Image Processing, 1987.
- [3] S. Cho, O. K. Ersoy, and M. R. Lechto, "Parallel, Self- Organizing, Hierarchical Neural Networks with Competitive Learning and Safe Rejection Schemes", IEEE Trans. on Circuits and Systems, vol. 40, no. 9, Sep. 1993.
- [4] L. Fausett, Fundamentals of Neural Networks, Prentice Hall, 1994.
- [5] J. A. Freeman and D. M. Skapura, Neural Networks: Algorithms, Applications and Programming Techniques, Addison-Wesley, 2nd Edition, 1992.
- [6] R. C. Gonzalez, Digital Image Processing, Addison-Wesley, 2nd Edition, 1987.
- [7] G. H. Granlund, "Fourier Preprocessing for Hand Print Character Recognition", IEEE Trans. on Comput., vol. c-21, no. 2, Feb. 1972.
- [8] R. Hecht-Nielsen, "Counterpropagation Networks", Applied Optics, vol. 26, no. 23, Dec. 1987.
- [9] T. Kohonen, Self-Organization and Associative Memory, Springer-Verlag, 3rd Edition, 1989.
- [10] T. Kohonen, "The Self-Organizing Map", Proc. IEEE., vol 78, no.9, Sep. 1990.
- [11] M. T. Y. Lai and C. Y. Suen, "Automatic Recognition of Characters by Fourier Descriptors and Boundary Line Encodings", Pattern Recognition, vol. 14, 1981.
- [12] T. Masters, Signal and Image Processing with Neural Network, Willey, 1994.
- [13] N. R. Pal, J. C. Bezdek, and E. C.-K. Tsao, "Generalized Clustering Networks and Kohonen's Self-Organizing Scheme", IEEE Trans. on Neural Networks, vol. 4, no. 4, July 1993.

- [14] E. Persoon and K.-S. Fu, "Shape Discrimination Using Fourier Descriptors", IEEE Trans. on System, Man, and Cybernetics, vol. SMC-7, no. 3, March 1977.
- [15] W. K. Pratt, Digital Image Processing, John Wiley & Sons, Inc., 2nd Edition, 1991.
- [16] H. Ritter, T. Martinetz, and K. Schulten, Neural Computation and Self-Organizing Maps, Addison-Wesley, 1992.
- [17] S. S. Soliman, Continuous and Discrete Signals and Systems, Prentice-Hall, 1990.
- [18] P. D. Wasserman, Neural Computing: Theory and Practice, ANZA Research, Inc., 1989.
- [19] C. T. Zahn and R. Z. Roskies, "Fourier Descriptors for Plane Closed Curves", IEEE Trans. on Comput., vol. c-21, no. 3, March, 1972.
- [20] J. M. Zurada, Introduction to Artificial Neural Systems, West Publishing Company, 1992.
- [21] 김종완, "동적으로 출력뉴런이 생성되는 병렬 경쟁 학습 신경회로망을 사용한 패턴인식", 서울대학교 박사학위 논문, 1994
- [22] 석진욱, "신경회로망의 하드웨어 구현을 위한 알고리즘 개발과 그 적용에 관한 연구", 홍익대학교 석사학위 논문, 1994

저자소개

鄭 聖 樊(正會員)

1970년 5월 6일생, 1994년 2월
홍익대학교 전기·제어공학과 졸업,
1996년 2월 홍익대학교 대학원 전기·제어공학과 졸업예정



趙 成 元(正會員) 第32卷 B編 第1號 參照