

# 퍼지 RBF 네트워크의 학습 성능 개선

김 광 백<sup>\*</sup>

## 요 약

본 논문에서는 퍼지 RBF 네트워크의 학습 성능을 개선하기 위하여 Delta-bar-Delta 알고리즘을 적용하여 학습률을 동적으로 조정하는 개선된 퍼지 RBF 네트워크를 제안한다. 제안된 학습 알고리즘은 일반화된 델타 학습 방법에 퍼지 C-Means 알고리즘을 결합한 방법으로, 중간층의 노드를 자가 생성하고 중간층과 출력층의 학습에는 일반화된 델타 학습 방법에 Delta-bar-Delta 알고리즘을 적용하여 학습률을 동적으로 조정하여 학습 성능을 개선한다.

제안된 RBF 네트워크의 학습 성능을 평가하기 위하여 컨테이너 영상에서 추출한 40개의 식별자를 학습 데이터로 적용한 결과, 기존의 ART2 기반 RBF 네트워크와 기존의 퍼지 RBF 네트워크 보다 학습 시간이 적게 소요되고, 학습의 수렴성이 개선된 것을 확인하였다.

## Learning Performance Improvement of Fuzzy RBF Network

Kim Kwang-Baek<sup>\*</sup>

## ABSTRACT

In this paper, we propose an improved fuzzy RBF network which dynamically adjusts the rate of learning by applying the Delta-bar-Delta algorithm in order to improve the learning performance of fuzzy RBF networks. The proposed learning algorithm, which combines the fuzzy C-Means algorithm with the generalized delta learning method, improves its learning performance by dynamically adjusting the rate of learning. The adjustment of the learning rate is achieved by self-generating middle-layered nodes and by applying the Delta-bar-Delta algorithm to the generalized delta learning method for the learning of middle and output layers. To evaluate the learning performance of the proposed RBF network, we used 40 identifiers extracted from a container image as the training data. Our experimental results show that the proposed method consumes less training time and improves the convergence of learning, compared to the conventional ART2-based RBF network and fuzzy RBF network.

**Key words:** Fuzzy RBF Network(퍼지 RBF 네트워크), Delta-bar-Delta Algorithm(Delta-bar-Delta 알고리즘), Rate of Learning(학습률), ART2-based RBF Network(ART2 기반 RBF 네트워크)

## 1. 서 론

RBF 네트워크는 빠른 학습 시간, 일반화(generality), 단순화(simplicity)의 특징으로 학습 데이터를 분류하는 작업과 비선형 시스템 모델링 등에 적용되고 있다[1]. 기존의 오류 역전파 학습 알고리

즘과 같은 다층 퍼셉트론(Multilayer Perceptron)의 연결 가중치들이 지역 최소화에 위치하여 학습 패턴들이 잘 분류되지 않는 경우를 방지할 수 있으며 학습 시간을 단축시킬 수 있다[2]. RBF(Radial Basis Function) 네트워크의 중간층은 클러스터링 하는 층이다. 즉, 이 층의 목적은 주어진 자료 집합을 유사한

※ 교신저자(Corresponding Author) : 김광백, 주소 : 부산광역시 사상구 폐법동 산1-1번지(617-736), 전화 : 051)309-5052, FAX : 051)999-5652, E-mail : gbkim@silla.ac.kr

접수일 : 2005년 2월 7일, 완료일 : 2005년 5월 9일

<sup>\*</sup> 종신회원, 신라대학교 컴퓨터공학과

클러스터들(homogeneous clusters)로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터 내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터로 분류하고 정해진 반경 내에 존재하지 않으면 다른 클러스터로 분류한다[3]. 그러나 정해진 반경 내에서 클러스터링 하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 중간층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다. RBF 네트워크는 학습이 완료된 상태, 즉 연결 강도가 특정 값으로 고정된 상태에서 새로운 패턴을 학습시키게 되면 이미 설정된 모든 연결 강도에 영향을 주므로 RBF 네트워크를 다시 학습 시키는데 상당한 학습 시간이 소요되는 단점과 RBF 네트워크에 학습되지 않은 전혀 새로운 형태의 패턴들이 들어오는 경우 이전에 학습된 유사한 패턴으로 분류하여 인식률을 저하시킨다[4]. 따라서 본 논문에서는 RBF 네트워크의 학습 구조를 개선한다. 제안된 학습 구조에서 입력층과 중간층 간의 연결구조는 퍼지 C-Means의 구조와 같다. 제안된 학습 구조는 전체적으로 완전 연결 구조이나 출력층에서 목표 벡터와 출력 벡터를 비교하여 역전파시킬때는 대표 클래스와 연결된 가중치만을 역전파시켜 연결 가중치를 조정하므로 새로운 패턴들이 이전에 학습 패턴으로 분류되는 부분을 개선한다. 그리고 중간층의 대표 클래스와 연결된 출력층의 노드만이 일반화된 델타 방법을 적용하여 지도 학습으로 수행한다. 이때 학습 시간을 단축하기 위하여 Delta-bar-Delta 방법을 적용하여 학습률을 동적으로 조정한다. 따라서 본 논문에서 제안된 학습 방법의 학습 성능을 분석하기 위하여 컨테이너 영상에서 추출한 식별자에 적용하여 기존의 ART2(Adaptive Resonance Theory 2) 기반 RBF 네트워크와 퍼지 RBF 네트워크 그리고 제안된 학습 방법 간의 학습 성능을 비교 분석한다.

## 2. 관련 연구

### 2.1 ART2 기반 RBF 네트워크

ART2 기반 RBF 네트워크는 중간층을 생성하는 과정에서 경계 변수의 설정에 따라 중간층의 노드 수가 결정된다. 경계 변수는 클러스터들을 분류하는 반지름 값이다. 경계 변수를 적게 설정하면 입력 패

턴과 저장 패턴 사이에 약간의 차이만 있어도 서로 다른 패턴으로 분류하여 새로운 클러스터를 생성하고 경계 변수를 크게 설정하면 입력 패턴과 저장 패턴 사이에 많은 차이가 있어도 같은 패턴으로 분류한다. 또한 ART2의 연결 가중치 변화는 모든 입력 패턴의 평균값을 취함으로써 클러스터 생성에 고르게 반응하게 된다. 그러나 ART2의 연결 가중치는 입력 패턴이 들어오는 경우 특징이 서로 다른 기존의 클러스터가 갱신되는 경우가 발생한다. 그 원인은 입력 벡터가 연결 가중치 벡터와의 평균에 의해 가중치의 특징을 감소시키기 때문이다[5]. 따라서 ART2 기반 RBF 네트워크에서는 경계 변수의 설정과 가중치 조정에 따라 학습과 인식 성능이 달라지는 문제점이 있다[6].

### 2.2 퍼지 C-Means 기반 RBF 네트워크

퍼지 C-Means 기반 RBF 네트워크는 중간층을 생성하기 위하여 퍼지 C-Means 알고리즘을 적용한다. Bezdek이 제안한 퍼지 C-Means 알고리즘은 어떤 패턴이 오직 한 클러스터에만 속한다고 보는 Hard C-Means 알고리즘에 퍼지 이론의 특성을 포함시켜, 복수개의 클러스터에 서로 다른 정도로 속한다고 정의하는 클러스터링 알고리즘이다[7]. 따라서 RBF 네트워크에 이 알고리즘을 적용할 경우에는 한 패턴의 특징이 복수개의 클러스터에 분산되므로 학습 시간이 많이 소요되는 단점이 있다. 일반적으로 문자 인식에 있어서 입력 패턴은 이진 패턴을 사용한다. 따라서 0과 1로 구성된 학습 패턴을 퍼지 C-Means 알고리즘을 적용할 경우에는 정확히 입력 패턴들을 분류하기 어렵고 다른 클러스터링 알고리즘에 비해 학습 시간이 많이 소요된다[8]. 따라서 본 논문에서는 퍼지 C-Means 기반 RBF 네트워크의 학습 성능을 개선하기 위하여 중간층과 출력층 사이의 연결 강도를 조정하는 과정에서 학습률을 동적으로 조정하여 학습 시간을 단축하기 위하여 Delta-bar-Delta 알고리즘을 적용한다.

### 2.3 Delta-Bar-Delta 알고리즘

오류 역전파 알고리즘의 학습 성능 개선을 위해 학습률을 동적으로 조정하는 방법 중에는 Jacobs 등에 의해 제안된 delta-bar-delta 알고리즘이 대표적

이다[9]. 학습률은 연결 가중치의 변화량을 조정하는 파라미터로서 학습 과정에 있어서 연결 가중치가 올바른 극소점에 도달하지 못하고 진동하는 경우를 방지하기 위하여 사용되는 파라미터이다.

delta-bar-delta 알고리즘은 총 오차 자승합의 변화량이 미세한 경우에는 학습률을 크게 조정하고, 하나의 극소점에 가까워졌을 때는 학습률을 적게 조정하여 학습 성능을 개선한다[10]. 다층 신경회로망이 입력층  $i$ , 은닉층  $j$ , 출력층  $k$ 로 구성될 때, delta-bar-delta 알고리즘은 식(1)과 같은 연결강도의 변화를 갖는다.

$$w_{kj}(t+1) = w_{kj}(t) - \alpha_{kj}(t+1) \frac{\partial E}{\partial w_{kj}} \quad (1)$$

$$= w_{kj}(t) + \alpha_{kj}(t+1) \delta_k z_j$$

식(1)에서  $\alpha_{kj}$ 는 학습률,  $\delta_k$ 는 출력층 오차이며,  $z_j$ 는 은닉층 뉴런의 출력이다. 각 출력층 뉴런에서 delta는 식(2)와 같으며, 각 은닉층 뉴런에서 delta는 식 (3)과 같다.

$$\Delta_{kj} = \frac{\partial E}{\partial w_{kj}} = -\delta_k z_j \quad (2)$$

$$\Delta_{ji} = \frac{\partial E}{\partial w_{ji}} = -\delta_j x_i \quad (3)$$

delta-bar-delta 규칙은 각 출력 뉴런에 대하여 현재의 정보를 식 (4)와 같이 delta-bar를 형성하기 위하여 파생된 과거의 정보를 조합하여 이용한다.

$$\bar{\Delta}_{kj}(t) = (1-\beta)\Delta_{kj}(t) + \beta\bar{\Delta}_{kj}(t-1) \quad (4)$$

식(4)에서 파라미터  $\beta$ 의 값은  $0 < \beta < 1$  사이의 고정된 상수이다. delta와 delta-bar 변화에 대한 학습률의 변화는 다음과 같다. 만약 연결강도의 변화가 연속된 학습과정에서 같은 방향으로 이루어진다면 학습률은 증가한다.  $\bar{\Delta}_{kj}(t-1)$ 과  $\Delta_{kj}(t)$ 가 같은 부호에서 발생하면, 이 때 학습률은 증가해야 한다. 또한 만약  $\bar{\Delta}_{kj}(t-1)$ 과  $\Delta_{kj}(t)$ 의 부호가 반대 부호를 가지면 학습률은 현재값의  $(1-\gamma)$ 의 비율로 감소한다. 이러한 가변 학습률은 각 층에 대하여 다음과 같은 식으로 표현할 수 있다.

$$\alpha_{kj}(t+1) = \alpha_{kj}(t) + k \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) > 0$$

$$= (1-\gamma)\alpha_{kj}(t) \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) < 0$$

$$= \alpha_{kj}(t) \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) = 0$$

(5)

$$\alpha_{ji}(t+1) = \alpha_{ji}(t) + k \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) > 0$$

$$= (1-\gamma)\alpha_{ji}(t) \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) < 0$$

$$= \alpha_{ji}(t) \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) = 0$$

(6)

### 3. 개선된 퍼지 RBF 네트워크

RBF 네트워크의 중간층은 학습 패턴들을 클러스터링하는 층이다. 이 중간층의 목적은 주어진 학습 패턴들을 유사한 클러스터들로 분류하는 것이다. 여기서 유사하다는 것은 학습 패턴들에 대한 특징 벡터 공간 사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터에 속하고 정해진 반경 내에 존재하지 않으면 다른 클러스터에 속한다. 정해진 반경 내에서 클러스터링하는 것은 잘못된 클러스터를 선택하여 출력층의 입력값으로 구성하므로 RBF 네트워크의 학습 성능을 저하시킨다. 또한 학습 과정에서 중간층의 노드는 그 노드의 목표 벡터를 알 수 없기 때문에 출력층 노드의 오차를 역으로 중간층 노드들로 책임 분담(credit assignment)하는 방법을 사용하므로 정체 현상이 일어나서 학습 시간이 많이 소요되고 학습 패턴들의 특징이 감소하는 경우가 발생하여 인식률을 저하시킨다. 따라서 본 논문에서는 중간층에 퍼지 C-Means 알고리즘을 적용하여 소속도가 가장 큰 노드를 승자 노드로 선택하여 출력층으로 전달하는 학습 구조를 제안한다. 그리고 중간층과 출력층 사이의 학습으로는 일반화된 델타 학습 방법을 적용하고 학습 시간을 개선하기 위하여 Delta-Bar-Delta 알고리즘을 적용한다. 제안된 학습 모형은 그림 1과 같다. 그림 1에서 실선은 중간층에서 승자 노드로 선택되어 출력층으로 전달되는 것을 의미한다.




그림 1. 제안된 학습 모형

제안된 퍼지 RBF 네트워크의 학습 방법은 다음과 같이 요약할 수 있다.

1. 입력층과 중간층의 연결 구조는 퍼지 C-Means 알고리즘과 같고, 퍼지 C-Means 알고리즘의 출력층이 제안된 학습 구조의 중간층이다.
2. 중간층의 노드는 각 클래스를 의미한다. 따라서 전체적으로는 완전 연결 구조이나 목표 벡터와 실제 출력 벡터와 비교하여 역전파시킬 때는 대표 클래스와 연결된 가중치만 역전파 하는 승자 노드 방식을 채택한다.
3. 중간층의 승자노드는 퍼지 C-Means 알고리즘에서 속속도가 가장 큰 중간층의 노드를 승자 노드로 선정한다.
4. 중간층과 출력층 사이의 학습 구조로는 일

반화된 델타 학습 방법을 적용하여 지도 학습으로 동작한다.

5. 학습 성능을 개선하기 위하여 일반화된 델타 학습에 Delta-bar-Delta 알고리즘을 적용하여 학습률을 동적으로 조정하는데 목표 벡터와 출력 벡터의 차이가 0.1 보다 적으면 정확성으로 정의하고 크면 부정확성으로 정의하여 총 패턴의 정확성의 수가 부정확성의 수보다 크거나 같은 경우에만 Delta-bar-Delta 알고리즘을 적용한다. 그 이유는 학습 과정에서 경쟁 단계로 인하여 조기 포화 현상(premature saturation)이 발생하여 오류가 거의 일정하게 유지되면서 학습이 진전되지 않거나 진동하는 부분을 방지하기 위해서이다. 따라서 제안된 퍼지 RBF 네트워크의 학습 알고리즘은 그림 2와 같다.

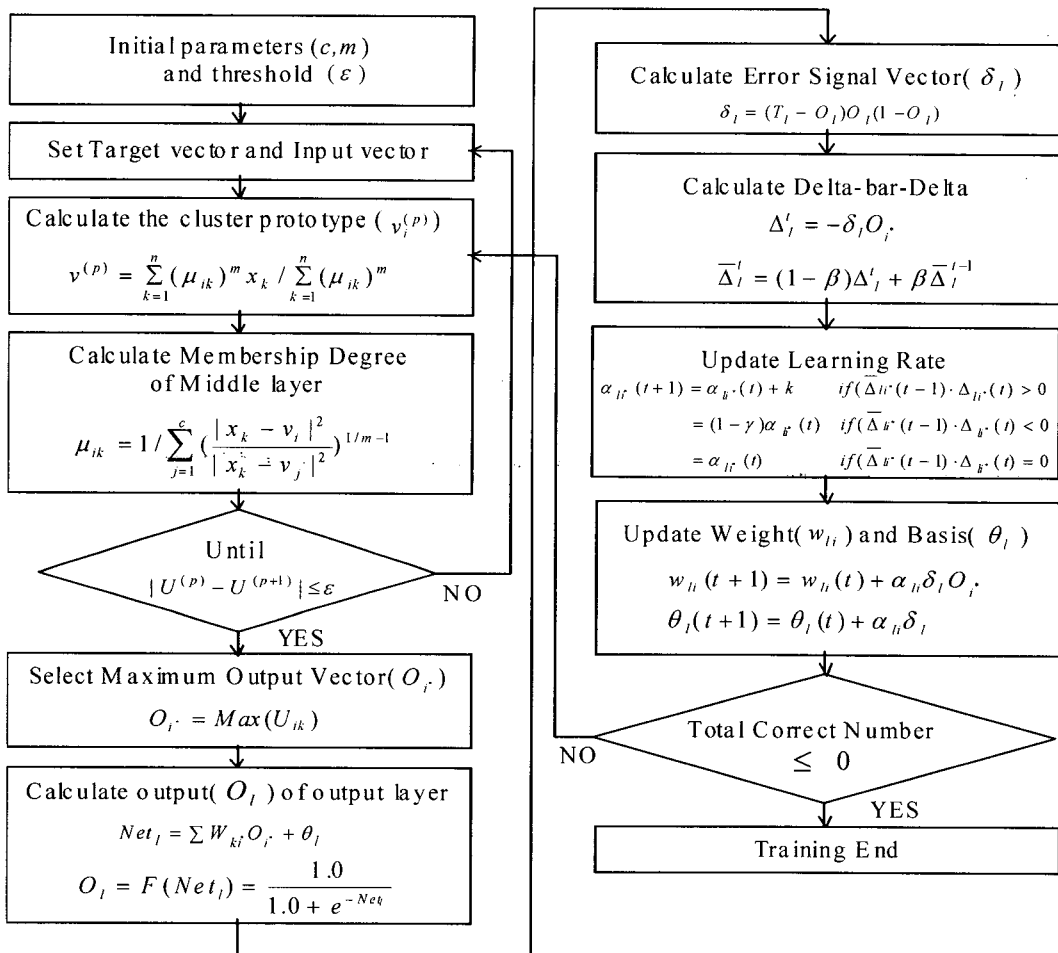


그림 2. 제안된 퍼지 RBF 네트워크 학습 알고리즘

### 4. 실험 및 결과 분석

제안된 학습 알고리즘의 학습 성능을 분석하기 위하여 Intel Pentium-IV 2GHz CPU와 512MB RAM 이 장착된 IBM호환 PC상에서 비주얼 C++ 6.0.0으로 구현하였다. 제안된 학습 알고리즘의 성능을 평가하기 위하여 컨테이너 영상에서 추출한 70개의 숫자 식별자 중에서 40개를 선택하여 ART2 기반 RBF 네트워크, 퍼지 RBF 네트워크와 생성된 중간층 노드 수와 학습의 반복횟수를 비교 분석하였고 학습된 40개의 숫자 식별자와 학습되지 않은 30개의 숫자 식별자에 대해 인식 개수를 비교 분석하였다. 컨테이너 식별자를 추출하기 위해 [11]의 방법을 적용하여 개별 숫자 식별자를 추출하였다. 먼저 컨테이너 영상에서 Canny 마스크를 적용하여 에지를 검출하였다. 검출된 에지 정보에서 영상 획득 시 외부 광원에 의해 수직으로 길게 발생하는 잡음들을 제거하기 위하여 퍼지 추론을 적용하여 잡음을 제거한 후에 컨테이너 식별자 영역을 추출 및 이진화 하였다. 이진화된 식별자 영역을 윤곽선 추적 알고리즘을 적용하여 개별 식별자를 추출하였다. 그림 3의 (a)는 추출된 식별자 영역이고 그림 3의 (b)는 윤곽선 추적에 의한 개별 식별자 추출 결과이다.

컨테이너 영상에서 추출 및 정규화된 패턴들 중에서 40개의 숫자 패턴을 선택하여 학습 패턴으로 구성하였고 학습 패턴의 예는 그림 4와 같다.

숫자 식별자 분류 실험에 사용된 제안된 학습방법의 파라미터는 표 1과 같다. 여기서  $\epsilon$ 는 0.1로 설정하였다. 표 1에서  $\alpha$ 는 학습률,  $\mu$ 는 모멘텀 계수,  $k$ ,  $\gamma$ ,  $\beta$ 는 delta-bar-상수이다.

표 2에서 Epoch수는 학습 반복 횟수이고, TSS는 총 오차자승 합이다. 그리고 ART2기반 RBF 네트워크와 퍼지 RBF 네트워크에서 학습률과 모멘텀을 각각 0.5와 0.6으로 설정하였고 제안된 퍼지 RBF 네트워크에서는 초기 학습률을 0.5로 설정하여 총 패턴의




그림 4. 컨테이너 숫자 식별자 학습 패턴의 예

표 1. 퍼지 RBF 네트워크의 파라미터

파라미터	$\alpha$	$\mu$	$k$	$\gamma$	$\beta$
학습방법					
제안된 퍼지 RBF 네트워크	0.5	0.6	0.05	0.2	0.7

표 2. 각 학습 알고리즘에 대한 학습 결과

평가방법	중간층 노드수	Epoch수	TSS
학습 방법			
ART2 기반 RBF 네트워크	13	950	0.067065
퍼지 RBF 네트워크	10	822	0.072591
제안된 퍼지 RBF 네트워크	10	526	0.065005

정확성의 수가 부정확성의 수보다 크거나 같으면 Delta-bar-Delta 알고리즘을 적용하였다. 그리고 모멘텀은 0.6으로 설정하였다. 표 2에서 학습 판정은 총 패턴의 부정확성의 수가 0보다 적거나 같은 경우에만 학습을 종료하였다.

표 2에서 알 수 있듯이 제안된 퍼지 RBF 네트워크가 ART2 기반 RBF 네트워크와 기존의 퍼지 RBF 네트워크 보다 학습 속도가 개선되었다. ART2 기반 RBF 네트워크는 ART2의 단점인 경계변수 설정에 따라 중간층의 노드의 수가 증가하거나 감소하였다. 따라서 표 2에서는 경계 변수를 0.15로 설정하는 것이 최적으로 나타났다. 퍼지 RBF 네트워크와 제안된 퍼지 RBF 네트워크에서는 퍼지 C-Means 알고리즘을 중간층으로 적용하므로 중간층의 노드의 소속도




그림 3. 개별 식별자 추출 결과 : (a) 추출된 식별자 영역, (b) 추출된 개별 식별자

에 따라서 클러스터를 생성하므로 ART2 기반 RBF 네트워크보다 중간층의 노드가 적게 생성되었다. 그러나 학습 패턴이 이진 패턴으로 구성되므로 퍼지 RBF 네트워크에서는 중간층의 노드를 클러스터링하는 과정에서 학습 시간이 비교적 많이 소요되었다. 제안된 퍼지 RBF 네트워크에서는 학습 과정에서 경쟁 단계에 해당하는 조기 포화 현상을 줄이기 위하여 학습률을 동적으로 조정하므로 기존의 퍼지 RBF 네트워크 보다 학습 시간이 적게 소요되었다.

그림 5는 기존의 방법들과 제안된 방법들 간의 오차 제곱 합 곡선을 나타내었다.

그림 5에서와 같이 제안된 방법이 기존의 방법들보다 초기의 수렴 속도가 빠르고 학습 시간이 적게 소요되는 것을 확인할 수 있다.

표 3은 학습된 40개의 숫자 식별자와 학습되지 않은 30개의 숫자 식별자에 대한 각 알고리즘간의 인식 개수를 나타내었다. 표 3의 결과에서 알 수 있듯이 ART2 기반 RBF 네트워크가 기존의 퍼지 RBF 네트워크와 제안된 퍼지 RBF 보다 인식 성능이 낮은 것을 확인할 수 있다. 컨테이너 영상의 식별자들은 컨테이너 표면의 훼손과 컨테이너 내부의 상품을 보호하기 위해 만들어 놓은 굴곡에 의하여 식별자의 형태가 다양하기 때문에 ART2 기반 RBF 네트워크를 적용하여 인식하는 경우에는 학습된 숫자 패턴에 대해서는 모두 인식하였으나 학습되지 않은 숫자 패턴에 대해서는 30개의 숫자 패턴에 대해 28개가 인식되었다.

ART2 기반 RBF 네트워크는 중간층을 생성하여 입력층과 중간층간의 연결 가중치를 조정할 때 입력 패턴과 연결 가중치간의 평균값을 이용한다. 따라서 중간층 노드의 연결 가중치의 특징이 감소하기 때

표 3. 각 알고리즘에 대한 인식 결과

평가방법 \ 학습 방법	학습된 40개의 패턴에 대한 인식 수	학습되지 않은 30개의 패턴에 대한 인식 수
ART2 기반 RBF 네트워크	40	28
퍼지 RBF 네트워크	40	29
제안된 퍼지 RBF 네트워크	40	30

문에 숫자 식별자가 변형된 경우에는 인식되지 않았다. 기존의 퍼지 RBF 네트워크는 중간층을 생성하는 방법으로 퍼지 C-Means 알고리즘을 적용한다. 기존의 퍼지 RBF 네트워크의 학습은 모든 학습 패턴에 대해 중간층을 생성한 후에 입력층에 부터 출력층으로 학습이 이루어진다. 따라서 중간층과 출력층간에는 완전 연결 구조 형태로 학습이 진행되므로 목표값과 출력층의 실제 출력값의 오차를 책임 분담하기 때문에 학습 패턴들의 특징들이 감소하는 경우가 발생하므로 제안된 퍼지 RBF 네트워크 보다 인식 성능이 낮았다. 제안된 퍼지 RBF 네트워크에서는 학습 구조로 퍼지 C-Means 알고리즘을 적용하여 중간층을 생성하고 소속도가 큰 노드를 승자 노드로 선택한 후 승자 노드로 선택된 중간층의 노드만이 출력층으로 전달되어 학습한다. 따라서 중간층의 승자 노드에서 정확히 분류되지 않은 패턴에 대해서는 중간층의 승자 노드와 출력층 노드간의 학습에 의해서 각 학습 패턴들의 특징을 정확히 분류하므로 기존의 학습 알고리즘보다 인식 성능이 향상되었다.

### 5. 결론 및 향후 연구 방향

기존의 퍼지 RBF 네트워크는 중간층으로 퍼지 C-Means 알고리즘을 적용한다. 퍼지 C-Means 알고리즘은 복수개의 클러스터에 서로 다른 정도로 속한다고 정의하는 클러스터링 알고리즘이다. 따라서 RBF 네트워크에 퍼지 C-Means 알고리즘을 적용할 경우에는 한 패턴의 특징이 복수개의 중간층 클러스터에 분산되므로 학습 시간이 많이 소요되는 단점이 있다. 또한 기존의 퍼지 RBF 네트워크의 학습은 모든 학습 패턴에 대해 중간층을 생성한 후에 입력층에

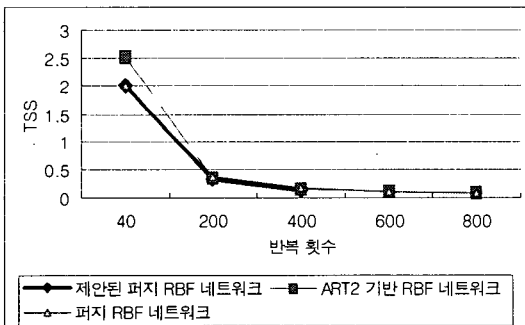


그림 5. 학습 방법에 따른 TSS의 변화율

부터 출력층으로 학습이 이루어진다. 따라서 중간층과 출력층간에는 완전 연결 구조 형태로 학습이 진행되므로 목표값과 출력층의 실제 출력값의 오차를 책임 분담하기 때문에 학습 패턴들의 특징들이 감소하여 인식률이 저하되는 경우가 발생한다.

본 논문에서는 퍼지 RBF 네트워크의 학습 성능을 개선하기 위하여 Delta-bar-Delta 알고리즘을 적용하여 학습률을 동적으로 조정하는 개선된 퍼지 RBF 네트워크를 제안하였다. 또한 RBF 네트워크의 학습 구조도 개선하였다. 제안된 학습 구조에서 입력층과 중간층 간의 연결구조는 퍼지 C-Means 알고리즘을 적용하였다. 제안된 학습 구조는 전체적으로 완전 연결 구조이나 출력층에서 목표 벡터와 출력 벡터를 비교하여 역전파시킬 때는 대표 클래스와 연결된 가중치만을 역전파시켜 연결 가중치를 조정하므로 새로운 패턴들이 이전에 학습된 패턴으로 분류되는 부분이 개선되었고 출력층 노드들의 오차를 역으로 중간층 노드들로 책임 분담하는 방법을 사용하여 정체 현상이 일어나는 부분을 개선하였다. 그리고 중간층의 대표 클래스와 연결된 출력층의 노드만을 일반화된 델타 방법에 적용하였다. 또한 학습 시간을 단축하기 위하여 Delta-bar-Delta 방법을 적용하여 학습률을 동적으로 조정하였다. 본 논문에서 제안된 학습 방법의 학습 성능을 분석하기 위하여 컨테이너 영상에서 추출한 식별자 분류에 적용한 결과, 기존의 ART2 기반 RBF 네트워크와 퍼지 RBF 네트워크보다 학습 성능이 개선됨을 확인하였다.

## 참 고 문 헌

- [1] M. L. Kothari, S. Madnani, and R. Segal, "Orthogonal Least Square Learning Algorithm Based Radial Basis Function Network Adaptive Power System Stabilizer." *Proceeding of IEEE SMC*, Vol. 1, pp. 542-547, 1997.
- [2] 황영섭, 방승양, "RBF 신경망 분류기의 효율적 구성 방법." *한국정보과학회논문지*, Vol. 21, No. 5, pp. 451-460, 1997.
- [3] C. Panchapakesan, D. Ralph, and M. Palaniswami, "Effects of Moving the Centers in an RBF Network." *Proceedings of IJCNN*, Vol. 2, pp. 1256-1260, 1998.
- [4] K. B. Kim, S. W. Jang, and C. K. Kim, "Recognition of Car License Plate by Using Dynamical Thresholding Method and Enhanced Neural Networks," *Lecture Notes in Computer Science, LNCS 2756*, pp. 309-319, 2003.
- [5] 김광백, 김영주, "명암도 변화와 HSI 정보와 개선된 ART2 알고리즘을 이용한 차량 번호판 인식," *퍼지 및 지능시스템학회논문지*, 제11권, 제5호, pp. 379-387, 2001.
- [6] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithm*, Plenum Press, New York, 1981.
- [7] K. B. Kim, Y. H. Joo, and J. H. Cho, "An Enhanced Fuzzy Neural Network," *Lecture Notes in Computer Science, LNCS 3320*, pp. 176-179, 2004.
- [8] 김광백, 윤홍원, 노영욱, "컬러 정보와 퍼지 C-Means 알고리즘을 이용한 주차관리시스템 개발," *한국지능정보시스템학회 논문지*, 제8권, 1호, pp. 87-102, 2002.
- [9] R. A. Jacobs, "Increased rates of convergence through learning rate adaptation," *IEEE Transactions on Neural Networks*, Vol. 1, No. 4, pp. 295-308, 1988.
- [10] K. B. Kim and C. K. Kim, "Performance Improvement of RBF Network using ART2 Algorithm and Fuzzy Logic System," *Lecture Notes in Artificial Intelligence, LNAI 3339*, pp. 853-860, 2004.
- [11] K. B. Kim, "Recognition of Identifiers from Shipping Container Images using Fuzzy Binarization and Neural Network with Enhanced Learning Algorithm," *Applied Computational Intelligence, World Scientific*, pp. 215-221, 2004.



김 광 백

1999년 부산대학교 전자계산학과(이학박사)

1996년~1997년 동의공업대학 사무자동화과 전임강사

1997년~현재 신라대학교 컴퓨터공학과 부교수

1999년~2000년 Biomedical Fuzzy Systems Association Associate Editors (Japan)

2003년~현재 한국 퍼지 및 지능시스템학회 기획 이사 및 논문지 편집위원

2005년~현재 한국멀티미디어학회 조직이사 및 논문지 편집위원

2005년~현재 한국지능정보시스템 이사 및 운영위원

2005년~현재 한국해양정보통신학회 인공지능 및 지능정보시스템 분과위원장 및 논문지 편집위원

관심분야: Fuzzy Neural Networks, Medical Image Processing, Support Vector Machines, Medical Informatics and Biomedical System.