

상대유사도를 이용한 새로운 무감독학습 신경망 및 경쟁학습 알고리즘

A New Unsupervised Learning Network and Competitive Learning Algorithm Using Relative Similarity

류영재 · 임영철

Young-Jae Ryoo and Young-Cheol Lim

전남대학교 전기공학과 및 지역협력연구센터

요 약

본 논문에서는 패턴분류문제를 해결하기 위한 새로운 무감독학습 신경망 및 경쟁학습 알고리즘을 제안한다. 제안하는 신경망은 입력 데이터의 군집을 분류하기 위한 거리측도로서 군집들 상호간의 상대유사도(relative similarity)를 기반으로 하고 있다. 이러한 까닭에 제안하는 신경망과 알고리즘을 상대유사 신경망(relative similarity network; RSN) 및 학습 알고리즘이라 이름한다. 상대유사도를 정의하고 가중벡터 학습규칙을 구성함으로써, RSN의 구조를 설계하고 학습알고리즘을 구현하기 위한 의사코드를 기술한다. 일반적인 패턴분류에 RSN을 적용한 결과, 초기 학습률이 없음에도 불구하고 기존의 경쟁학습 신경망인 WTA이나 SOM과 동등한 성능을 나타내었다. 반면 기존 경쟁학습 신경망의 분류성능이 저하되었던 군집의 경계가 불분명한 패턴, 그리고 군집의 밀집도와 군집의 크기가 다른 패턴들에 대한 실험에서는 기존의 경쟁학습망보다 효과적인 분류결과를 나타내었다.

ABSTRACT

In this paper, we propose a new unsupervised learning neural network and competitive learning algorithm for pattern classification. The proposed network is based on relative similarity, which is similarity measure between input data and cluster group. So, the proposed network and algorithm is called relative similarity network(RSN) and learning algorithm. According to definition of similarity and learning rule, structure of RSN is designed and pseudo code of the algorithm is described. In general pattern classification, RSN, in spite of deletion of learning rate, resulted in the identical performance with those of WTA, and SOM. While, in the patterns with cluster groups of unclear boundary, or patterns with different density and various size of cluster groups, RSN produced more effective classification than those of other networks.

1. 서 론

신경회로망의 우수한 점의 하나는 데이터를 분류할 수 있는 능력을 가졌다는 것이다. 이러한 능력 때문에 신경회로망은 영상인식을 위한 패턴분류 뿐만 아니라 문자인식, 시각제어 등에도 널리 적용되고 있다[1,2]. 다양한 신경망의 종류 중 패턴분류에 사용되는 신경망은 무감독학습 신경망, 또는 자율학습 신경망이라고 하며, 경쟁학습 알고리즘을 이용하므로 경쟁학습 신경망이라고도 한다.

현재까지 다양한 무감독 신경망 또는 경쟁학습 알고리즘이 제안되어 데이터의 패턴분류에 사용되고 있다[3,4]. 그중 가장 대표적인 경쟁학습 신경망의 하나로 승자전취(Winner-Take-All; WTA)[5] 알고리즘을 들 수 있다. 일반적으로 무감독학습 신경망의 학습규칙은 전방향에 대해서는 Hebb 규칙이, 역방향에 대해

서는 경쟁학습이 사용된다. WTA는 경쟁학습하는 동안 주어진 입력벡터와 가장 유사한 가중벡터를 가진 승자세포만 학습에 참여시킨다. 따라서 승자세포로 선택되지 못한 세포는 학습에 참여할 수 없게되어 필요 없는 세포가 된다. 이러한 세포는 실제 시스템을 구현할 때 불필요한 메모리로 남게 되어 그 효율성이 떨어지며, 시스템의 분류성능을 저하시킨다.

Kohonen은 SOM(Self-Organizing Map)[6,7]을 제안하여 승자세포 뿐만 아니라 주위의 이웃하는 세포도 학습에 참여시킴으로써 WTA의 단점을 극복하고자 노력하였다. SOM은 주어진 입력 데이터에 대해 가장 가까운 승자세포를 찾고 이웃(neighbor)세포를 결정하여 학습에 참여시킨다. 이때 승자세포와 이웃세포는 이웃함수(neighbor function)와 학습횟수에 따른 학습률의 조절을 통해 결정한다. 따라서 SOM의 성능은 이웃함수의 결정과 초기 학습률의 선택에 따라 많

은 영향을 받게 된다. 그런데 이러한 이웃함수와 초기 학습률은 분류하고자 하는 패턴의 복잡성과 개수에 따라 그 선택이 일정하지 않다는 난점을 가지고 있다. 특히 군집들 간의 데이터가 겹쳐져 경계가 불분명한 패턴분류에서는 그 문제점이 더욱 심각해진다. 군집의 경계가 불분명하면 이웃세포의 범위를 적절히 결정하기가 어렵게 된다. 이로인해 이웃하는 서로 다른 군집을 동일한 군집으로 판단하게 되는 오류를 발생하여 분류성능을 현저하게 저하시킨다.

또한 WTA이나 SOM은 군집에 포함하는 기준인 유사도로서 Euclidean 거리의 역수를 사용한다. 분류하고자 하는 군집들이 적절하게 분산되어 있는 경우, Euclidean 거리는 입력벡터와 군집의 중심벡터인 두 벡터간의 각도와 위치에 종속하는 거리측도를 제시할 수 있다. 그러나 전체군집이 밀집도가 높은 군집과 낮은 군집이 혼합되어 있는 경우, 또 면적이 큰 군집과 작은 군집이 혼재된 패턴의 경우, 그 군집을 정밀하게 분류할 수 있는 분해성능이 저하된다.

따라서, 이 논문에서는 초기 학습률의 설정이 필요 없으면서 군집의 경계가 불분명한 패턴, 서로 다른 밀집도의 군집이 혼합된 패턴, 그리고 크기가 다른 군집이 혼합된 패턴들을 적절히 분류할 수 있는 신경망과 학습알고리즘을 제안하고자 한다. II장에서는 제안하는 신경망에서 입력 데이터에서 군집을 분류하기 위한 거리측도로 군집 상호간의 상대적인 유사도 (relative similarity)를 정의하고 가중벡터의 학습규칙을 기술한다. 상대유사도는 모든 군집의 중심벡터가 거리측도에 참여할 수 있도록 Euclidean 거리를 각 군집간에 상대적인 개념으로 확장한 것이다. 입력패턴에 의한 소속 군집과의 상대유사도는 신경망의 출력값으로 나타나며 이를 가중벡터의 학습규칙에 참여하도록 한다. 이러한 까닭에 본 논문에서는 이 신경망과 그 근간을 이루는 알고리즘을 상대유사 신경망 (Relative Similarity Network; RSN) 및 학습 알고리즘이라 이름하고 III장에서 이를 다룬다. RSN의 기본적인 구조는 일반화된 거리측도인 Euclidean거리를 얻어내는 부분과 상대유사도를 출력하는 부분으로 이루어져 있다. IV장에서는 군집의 크기, 밀집도가 다르고, 경계가 불분명한 군집 등의 다양한 패턴들에 대하여 RSN의 성능을 비교 평가해본다.

2. 상대유사도를 이용한 신경망

2.1 상대유사도의 정의

본 논문에서는 P 개의 패턴으로 구성된 데이터 집합 X 를 M 개의 군집 Y 로 분류하는 문제를 다룬다. 일반

적으로 학습을 진행함에 따라 군집 Y 에 연결된 연결강도는 각 군집의 중심으로 이동하게 된다. 신경망은 입력된 데이터가 각 군집에 얼마나 유사한지를 출력으로 나타내며, 입력 데이터를 가장 큰 출력을 내는 군집으로 분류한다. 일반적인 경쟁학습 신경망에서 유사도는 Euclidean 거리 제곱의 역수 $s(\mathbf{x}^h, \mathbf{w}_j)$ 가 사용된다. j 번째 출력에 연결된 가중벡터 \mathbf{w}_j 와 h 번째 입력 패턴 \mathbf{x}^h 에 의한 유사도는 다음과 같이 정의되며, 이는 두 벡터의 각도 유사도와 거리 유사도를 측정하게 된다.

$$s(\mathbf{x}^h, \mathbf{w}_j) = \frac{1}{\|\mathbf{x}^h - \mathbf{w}_j\|^2} \quad (1)$$

분류하고자 하는 군집들이 적절하게 분산되어 그 구분이 뚜렷한 경우, Euclidean 거리는 입력벡터와 군집의 중심벡터인 두 벡터간의 각도와 위치에 따른 거리측도를 제공함으로서 분류의 기준이 될 수 있다. 그러나 전체군집이 밀집도가 높은 군집과 낮은 군집으로 혼합되어있는 경우, 밀집도가 높은 군집에서는 세밀한 분류를, 낮은 군집에서는 대략적인 분류를 하여야 한다. 즉, 입력벡터에 대하여 모든 군집의 중심벡터를 고려할 수 있는 거리측도가 필요하게 된다. 본 논문에서 제안하는 상대유사도는 모든 군집의 중심벡터가 거리측도에 참여할 수 있도록 Euclidean 거리를 각 군집간에 상대적인 개념으로 확장한다. 상대유사도는 현재 입력패턴이 소속한 군집과 소속하지 않은 군집의 유사한 정도를 상대적으로 비교한 것이라고 할 수 있다.

다음과 같은 N차원의 벡터 \mathbf{x} 로 구성된 P 개의 입력 패턴 X 를 M 개의 군집 Y 로 분류하고자 하는 문제를 다루어 본다.

$$\begin{aligned} \mathbf{x} &= [x_1, x_2, \dots, x_i, \dots, x_N]^T, x_i \in R, \\ X &= [x^1, x^2, \dots, x^h, \dots, x^P], x^h \in x. \end{aligned} \quad (2)$$

M 개의 출력 $Y = [y_1, y_2, \dots, y_j, \dots, y_M]^T$ 에 연결되는 가중벡터가 다음과 같이 존재한다.

$$\begin{aligned} \mathbf{W} &= [\mathbf{w}_1, \dots, \mathbf{w}_j, \dots, \mathbf{w}_M]^T, \\ \mathbf{w}_j &= [w_{j1}, \dots, w_{ji}, \dots, w_{jN}]. \end{aligned} \quad (3)$$

M 개의 군집 중에 j 번째 군집에 해당하는 상대유사도는 상대적 거리에 의해 정의된다. 상대적 거리는 식 (4)와 같이, 소속한 j 번째 군집의 가중벡터 \mathbf{w}_j 에 의한 Euclidean 거리 d_j 와 소속하지 않은 타 군집 k 번째 군집 \mathbf{w}_k 의 Euclidean 거리 d_k 의 상대적인 비를 나타낸다.

$$R_j = \left[\sum_{k=1}^M \frac{\|x - w_k\|^q}{\|x - w_j\|^q} \right]^{1/q} = \left[\sum_{k=1}^M \left(\frac{d_j}{d_k} \right)^q \right]^{1/q} \quad (4)$$

$$= \left[\sum_{k=1}^M (r_j)^q \right]^{1/q},$$

상대적 거리 R_j 는 입력된 벡터 x 와 선택된 j 번째 군집의 가중벡터의 거리가 입력벡터와 다른 모든 가중벡터의 거리에 비해 가까운 정도를 상대적으로 나타낸다. 따라서 입력된 벡터와 선택된 군집의 가중벡터의 거리가 타 군집보다 가까우면 적은 값을 멀면 큰 값을 나타낸다.

상대유사도(relative similarity)는 입력벡터와 가중벡터의 상대적 거리와 반비례적인 관계를 이용하여 식(5)과 같이 정의하며, 신경망의 출력 y_j 는 상대유사도를 출력값으로 나타낸다.

$$y_j = r(x^h, w) = R_j^{-q}. \quad (5)$$

이때 출력 y_j 는 다음과 같은 특성을 갖는다.

$$y_j \in [0, 1]. \quad (6)$$

$$\sum_{j=1}^M y_j = 1 \quad (7)$$

즉, 출력 y_j 는 $[0, 1]$ 사이에 존재하며 출력의 합은 1이 된다. 따라서 입력벡터와 선택된 군집의 유사도인 출력이 정규화되어, 입력된 벡터가 학습규칙에 참여하는 정도를 결정하는데 직접 적용될 수 있음을 보여준다.

2.2 가중벡터의 학습규칙

군집을 분류하는 기본적인 방법은 군집에 소속한 입력 데이터들의 중심으로 군집을 형성하는 가중벡터들을 선택하는 것이다. 하지만 입력패턴의 분포는 알 수 없으므로 선택된 군집에 소속하는 입력 데이터의 경계를 찾기는 쉬운 일이 아니다. 따라서 모든 입력 데이터를 가중벡터의 학습에 참여시켜야 하며, 학습에 참여하는 정도는 입력된 패턴이 선택된 군집에 얼마나 유사한지에 따라 결정되어야 한다. 식 (8)은 이와 같은 사실을 기반으로 가중벡터를 결정하는 방법을 나타내었다. 입력 데이터 x^h 는 가중벡터 w_j 에 유사한 정도를 나타내는 신경망의 출력 y_j 에 의존하여 가중벡터 w_j 에 미치는 영향이 달라진다.

$$w_j = \frac{\sum_{h=1}^P y_j^h x^h}{\sum_{h=1}^P y_j^h}. \quad (8)$$

식(8)을 k 번째 가중벡터를 결정하기 위한 식으로 변형하면 다음과 같다.

$$w_j(k) = w_j(k-1) + \frac{\sum_{h=1}^P y_j^h \{x^h - w_j(k-1)\}}{\sum_{h=1}^P y_j^h}. \quad (9)$$

가중치 변화량을 나타내면 다음과 같다.

$$\Delta w_j = \frac{\sum_{h=1}^P y_j(x - w_j)}{\sum_{h=1}^P y_j^h} = \frac{w_{uj}}{w_{lj}} \quad (10)$$

식(10)에 의하여 학습을 진행시키면 군집을 형성하는 가중벡터들은 입력패턴으로 구성된 군집들의 중심으로 이동하게 된다. 이때 가중벡터의 변경은 기본적으로 입력벡터와 가중벡터의 차에 의하여 이루어진다. 입력된 벡터에 의해 선택된 군집은 상대유사도를 신경망의 출력으로 나타내고, 이 출력의 유사도에 따라 가중벡터의 학습에 영향을 주게 된다. 이는 SOM이 가장 강한 유사도를 갖는 소자뿐만 아니라 이웃하는 소자를 학습에 참여시키는 것과 유사하다. SOM은 이웃하는 소자를 학습에 참여시키기 위한 이웃함수를 결정해야 하며, 이를 위해 특별한 함수를 설정하고, 초기 파라미터를 결정하여야 한다. 초기 파라미터는 학습결과에 큰 영향을 미치므로 많은 시행착오를 거쳐야하는 불편한 점을 가지고 있다. 반면 본 논문에서 제안하는 방식은 입력패턴의 유사도를 나타내는 출력값이 학습에 참여하는 정도를 결정하게되어, 특별한 파라미터의 설정이 필요없게 된다.

3. 상대유사도를 이용한 경쟁학습 알고리즘

3.1 상대유사 신경망(RSN)의 구조

일반적으로 신경망은 신경소자를 이루는 활성함수, 결선을 이루는 연결강도 또는 가중벡터, 그리고 연결강도를 조절하는 학습규칙으로 구성된다. 상대유사 신경망의 구조를 살펴보면 그림 1과 같이 입력층, 은닉층, 그리고 출력층으로 구성되어 있다. 입력층에서 은닉층의 관계는 기존의 경쟁망인 instar 규칙망과 유사한 구조로 이루어져 있다. 은닉층에서 출력층의 구조는 상대유사도를 산출하는 과정으로 이루어져 있으며, 이는 SOM에서 이웃함수를 이용하여 학습에 참여할 신경소자를 선정하는 과정과 유사한 구조라고 할 수 있다.

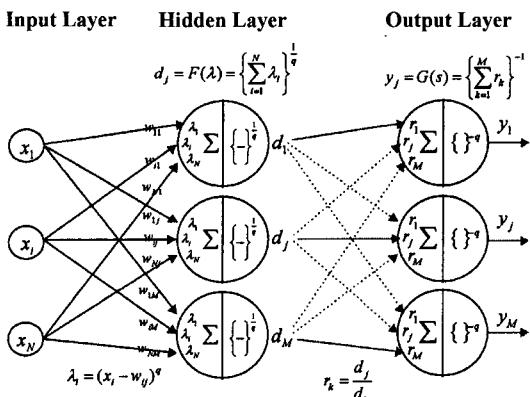


그림 1. 상대유사도 신경망의 구조
Fig. 1. Structure of relative similarity network

입력층에서 은닉층으로 전달과정을 살펴보면, 이는 입력데이터를 이용하여 Euclidean 거리값을 산출하는 과정이다. 입력층에서 은닉층으로 결선과정에서는 식(11)과 같이 입력데이터와 가중벡터와의 차를 전달한다. 이를 전달받은 은닉층 신경소자는 식(12)와 같은 활성함수를 이용하여 Euclidean 거리를 구한다. 은닉층에서 출력층으로 전달과정을 보면, 은닉층 출력의 Euclidean 거리를 이용하여 결선과정에서는 식(13)과 같이 타 Euclidean거리와 비를 구하고, 출력층 신경소자의 활성함수에 의해서는 식(14)와 같이 모든 출력소자의 가중벡터와 비교하여 상대유사도를 구한다.

$$\lambda_j = (x_i - w_{ij})^q. \quad (11)$$

$$d_j = F(\lambda) = \left\{ \sum_{i=1}^N \lambda_i \right\}^{1/q}. \quad (12)$$

$$r_j = \frac{d_j}{d_k}. \quad (13)$$

$$y_i = G(r) = \left\{ \sum_{k=1}^M r_k \right\}^{-1}. \quad (14)$$

3.2 알고리즘 의사코드(Pseudocode)

상대유사도 신경망과 알고리즘을 구현하기 위한 구체적인 의사코드는 그림 2와 같다. 이 논문에서 epoch는 하나의 입력에 의하여 학습이 완료된 순간을, iteration은 모든 입력패턴에 의해 1회 학습이 완료된 순간을 칭한다.

초기에는 가중벡터의 값은 -1과 1사이에 존재하는 임의의 실수값으로 입력한다. 학습은 각 가중치의 변화가 일정값 이하로 나타나 더 이상 학습이 필요없는

```

Wij : Weights ← -1.0 과 1.0 사이 임의의 실수
{ 가중벡터 초기화 }

DO UNTIL 종료검사 만족할 때까지
Wuj, Wlj ← 0
{ 부분 가중벡터의 초기화 }

DO FOR 입력패턴개수 만큼 반복
x ← Input
{ 입력벡터 설정 }

{ 전향 전파 }
DO FOR 출력소자개수 만큼 반복
{ 은닉층 전파 }
dj ← dj + (xj - w0j)2
{ 제곱Euclidean 거리 산출 }

DO FOR 출력소자개수 만큼 반복
{ 출력층 전파 }
rj ← rj + dj / dk
{ 상대적거리 산출 }
yj ← 1 / rj
{ 상대유사도 산출 }

DO FOR 출력소자개수 만큼 반복
{ 부분 가중벡터 변경 }
Wuj ← Wuj + yj(x - wuj)
Wlj ← Wlj + yj

DO FOR 출력소자개수 만큼 반복
{ 전체 가중벡터 변경 }
Wi ← Wi + Wuj / Wlj

```

그림 2. 상대유사도 신경망 알고리즘의 의사코드
Fig. 2. Pseudo code of algorithm for relative similarity network

종료조건이 나타날 때까지 반복한다. 모든 입력패턴에 대하여 학습을 수행하는 iteration과정에서는 먼저 부분 가중벡터 (W_{uj} , W_{lj})의 값을 초기화시킨다.

전방향 전파과정으로 입력세포에 패턴이 전달되면, 입력층에서 은닉층 전파와 은닉층에서 출력층 전파가 이루어진다. 은닉층에서는 입력벡터와 가중벡터에 의하여 출력소자 개수만큼의 Euclidean 거리의 제곱을 계산한다. 출력층에 전달된 Euclidean 거리의 제곱을 이용하여 출력소자 개수만큼의 상대유사도를 출력한다.

각 출력소자에 연결된 가중벡터를 얻기 위해 먼저 식 (11)에서와 같이 부분 가중벡터를 계산한다. 가중벡터는 모든 입력패턴의 학습이 완료된 시점에서 변경되며, 이 때 1회 iteration의 학습을 마친 것으로 한다. 반면 부분 가중벡터는 각 입력벡터가 입력될 때마다 변경하며, 이를 1회 epoch라고 한다.

$$\begin{aligned} \Delta w_j &= \frac{w_{uj}}{w_{lj}} \\ \Delta w_{uj} &= y_j(x - w_j) \\ \Delta w_{lj} &= y_j. \end{aligned} \quad (15)$$

입력패턴 개수만큼 P 번의 epoch가 수행되면 부분 기중벡터를 이용하여 가중벡터를 변경함으로써 1회 iteration의 학습을 완료한다.

4. 성능비교 실험

4.1 4개의 구형 및 타원형 군집의 분류

입력패턴을 분류하는 문제로 그림 3과 같이 구형 군집과 타원형 군집으로 구성된 4개의 군집을 분류하는 문제를 다룬다. 구형 군집의 중심은 $(1, -1)$, $(-1, 1)$ 에 있고, 각각 300개의 데이터가 반경거리 1 이내에서 random한 값을 가진다. 타원형 군집은 중심이 $(1, 1)$, $(-1, -1)$ 에 존재하고, 각각 300개의 데이터가 장축

으로는 반경거리 1 이내에서 단축은 반경거리 0.5 이내에서 random하게 위치하는 분포를 가진다.

기존의 경쟁학습망인 WTA, SOM에 의한 분류와 RSN에 의한 분류 모두 적절히 4개의 군집을 분류하였다. 이와같이 군집의 분류가 분명한 패턴의 경우, RSN은 WTA이나 SOM과 동등한 성능을 가짐을 알 수 있다.

4.2 군집의 경계가 불분명한 패턴의 분류

패턴을 분류한데 있어 어려운 문제는 그림 4와 같이 군집의 경계가 겹쳐져서 불분명한 군집을 분류하는 경우이다. 4개의 군집은 중심 $(-1, -1)$, 가로 0.4, 세로 0.6인 직사각형 내에 random하게 위치한 300개의 데이터 군집 I, 중심 $(-0.5, -0.5)$, 가로세로 1인 정사각형 내에 random하게 위치한 300개의 데이터 군집 II, 중심 $(0.5, 0.5)$, 가로세로 0.7인 정사각형 내에 random하게 위치한 300개의 데이터 군집 III, 중심 $(1, 1)$, 그리고 가로세로 0.7인 정사각형 내에 random하게 위치한 300개의 데이터 군집 IV로 구성되었다. 그림 4와 같이 군집 I과 군집 II의 경계가 겹

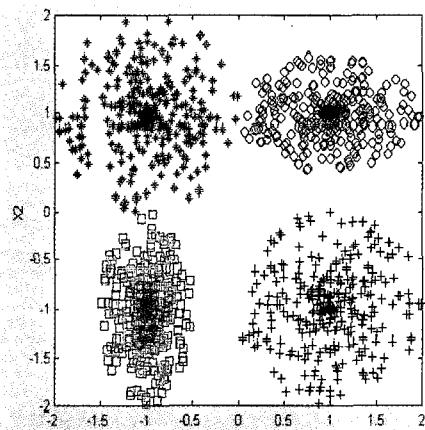


그림 3. 패턴 I의 데이터
Fig. 3. Data of pattern I

표 1. 패턴 I의 군집분류 결과
Table 1. Clustering results for pattern I data

Pattern I	RSN		WTA		SOM	
	50 iter.	$\alpha=0.01, 100$ iter.	Corr.	%	Corr.	%
Class I	300	100	300	100	300	100
Class II	300	100	300	100	300	100
Class III	300	100	300	100	300	100
Class IV	300	100	300	100	300	100

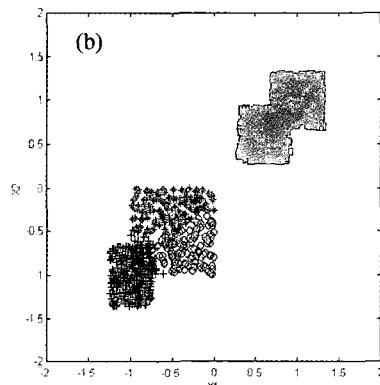
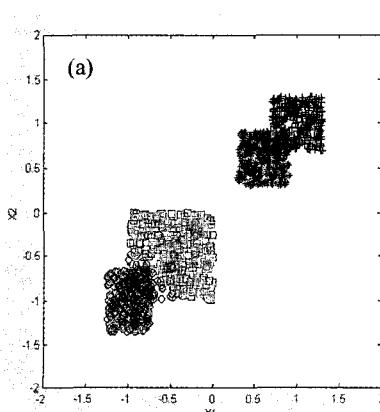


그림 4. 패턴 II의 군집분류 결과
Fig. 4. Results of cluster classification for pattern II, (a) RSN, (b) SOM

쳐지고 군집 III과 군집 IV의 경계가 겹쳐져, 군집간의 경계가 불분명하기 때문에 군집을 분류하기가 어렵다. 이는 군집이 겹쳐진 경우 동일한 군집으로 인식될 수 있기 때문이다. SOM의 경우 분류결과를 보면 적은 면적을 가지면서 서로 겹쳐져 있는 군집 III과 군집 IV를 동일한 군집으로 인식하였다. 군집 II는 그 면적이 크기 때문에 두 개의 서로 다른 군집으로 분류되었다. 반면 RSN은 데이터 서로의 상대적 유사도를 이용하여 군집을 분류하기 때문에 군집의 경계가 겹쳐있더라도 정확한 분류를 행한다. 이와같이 RSN은 경계가 불분명한 군집의 분류문제에서 우수한 성능을 나타낸다. 표 2는 군집분류 결과를 나타내었는데, 각 신경망에 의해 각 군집으로 분류된 총 데이터 개수를 'Total'로, 이것 중 올바른 데이터의 개수를 'Correct'로 나타내었다. SOM의 경우 군집 IV로 분류한 데이터의 개수는 600개이지만 올바른 데이터는 300개만 해당된다.

4.3 큰 군집과 작은 군집이 혼합된 패턴의 분류

패턴분류에 있어서 또 다른 어려운 문제는 크기가

큰 군집과 작은 군집이 혼재된 경우이다. 이러한 패턴의 경우 면적의 크기로 분류한다면, 큰 군집은 여러 개의 군집으로 분할되고 여러 개의 작은 군집은 동일한 군집으로 인식되는 오류를 발생한다. 하지만 정확한 패턴분류를 한다면 군집의 크기에 관계없이 상호 유사도가 강한 데이터를 동일한 군집으로 분류할 것이다.

실험 패턴의 4개 군집은 그림 5와 같이 큰 면적을 가진 사각형의 군집 I과 작은 원형 군집 II, 작은 타원형 군집 III, 그리고 중간 크기의 계란형 군집 IV으로 구성하였다. SOM을 이용하여 이와같은 패턴의 군집을 분류하면, 면적이 큰 군집 I은 두 개의 군집으로 분리되고, 작은 군집 II와 군집 III은 동일한 군집으로 인식된다. 면적을 기반으로 공간을 분할한다면 이와같은 분류가 합당한 방법이지만, 크기에 관계없이 상호 유사성이 강한 데이터를 동일한 군집으로 분류해야 한다면 이와같은 분류방법은 잘못된 것이다. 따라서 데이터는 상호 유사도를 기반으로 분류되어야 하며, 데이터간의 거리가 가까우면 상대적으로 큰 유사도를 갖게 하는 방법이 유리하다. RSN은 상대유사도를 적용

표 2. 패턴 II의 군집분류 결과
Table 2. Clustering results for pattern II data

Pattern II	RSN		SOM		SOM	
	500 iter.	Cor.	$\alpha=0.1$, 500 iter.	Cor.	$\alpha=0.01$, 2000 iter.	Cor.
	Tot.	Cor.	Tot.	Cor.	Tot.	Cor.
Class I	344	300	359	300	355	300
Class II	256	256	141	141	136	136
Class III	239	239	100	0	109	0
Class IV	363	300	600	300	600	300

표 3. 패턴 III의 군집분류 결과
Table 3. Clustering results for pattern III data

Pattern III	RSN		WTA		SOM	
	500 iter.	Cor.	$\alpha=0.01$, 1000 iter.	Cor.	$\alpha=0.01$, 1000 iter.	Cor.
	Tot.	Cor.	Tot.	Cor.	Tot.	Cor.
Class I	300	300	114	114	134	134
Class II	293	293	83	0	166	0
Class III	300	300	103	103	600	300
Class IV	307	300	900	300	300	300

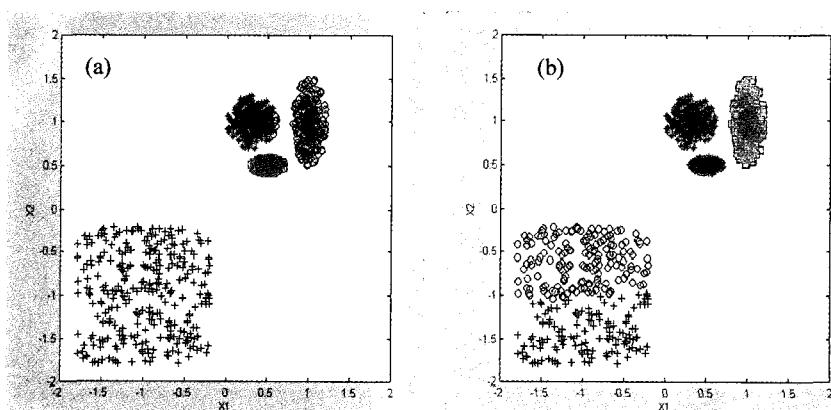


그림 5. 패턴 III의 군집분류 결과
Fig. 5. Results of cluster classification for pattern III. (a) RSN, (b) SOM

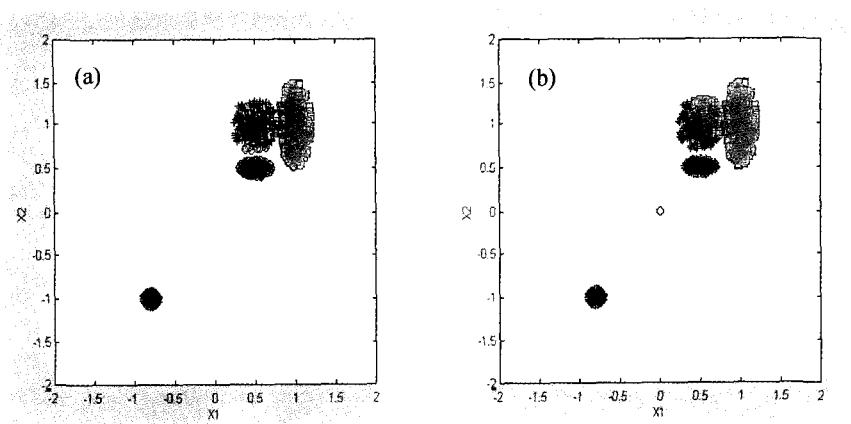


그림 6. 패턴 IV의 군집분류 결과
Fig. 6. Results of cluster classification for pattern IV, (a) RSN, (b) SOM

표 4. 패턴 IV의 군집분류 결과
Table 4. Clustering results for pattern IV data

Pattern IV	RSN		WTA		SOM	
	Tot.	Cor.	Tot.	Cor.	Tot.	Cor.
Class I	300	300	300	300	348	300
Class II	285	285	0	0	158	158
Class III	297	279	0	0	142	0
Class IV	318	300	900	300	552	300

함으로써 패턴의 크기에 관계없이 분류할 수 있음을 보여준다.

4.4 밀집된 군집에서 먼 거리에 군집이 존재하는 경우의 분류

패턴분류에 있어서 군집이 밀집되어 있더라도 그 크기와 군집의 형태가 정확하다면 그 분류는 쉽게 해결된다. 하지만 밀집된 군집에서 먼 거리에 군집이 존재하면, 군집을 분류할 수 있는 성능은 저하되는 문제점이 있다.

그림 6은 3개의 군집이 밀집되어 있는 반면 1개의 군집은 먼 거리에 위치해 있어 신경망이 분류하는데 어려움이 있는 군집의 분포를 가지고 있다. 이와같은 패턴에 있어서도 SOM의 분류성능에 비해 RSN이 우수함을 알 수 있다.

5. 결 론

기존의 경쟁학습망인 SOM은 군집의 데이터가 서로 이웃하여 경계가 불분명한 패턴분류에서 성능이 현

저하게 저하되는 문제점을 가지고 있다. 또 WTA이나 SOM은 전체군집이 밀집도가 높은 군집과 낮은 굽집이 혼합되어있는 패턴의 경우, 또 면적이 큰 군집과 작은 군집이 혼재된 패턴의 경우, 군집을 정밀하게 분류할 수 있는 분해성능이 저하된다. 본 논문에서는 이러한 문제를 극복하기 위해 입력벡터에 대해 모든 군집의 중심벡터를 고려할 수 있는 상대유사도를 정의하였다. 상대유사도인 신경망의 출력값은 가중벡터를 변경하는 학습에 참여하는 정도로 사용하여 기존 신경망의 학습률을 대체하였다. 상대유사도와 가중벡터를 변경하는 학습규칙을 바탕으로 상대유사 신경망(RSN)의 구조를 설계하고, 알고리즘을 구현하기 위한 구체적인 의사코드를 기술하였다. 제안한 RSN의 분류성능을 실험하기 위하여 다양한 패턴에 대하여 시뮬레이션을 행하였다. 군집의 분류가 뚜렷한 패턴의 경우, RSN은 WTA이나 SOM과 동등한 성능을 나타내었다. 반면 군집의 경계가 불분명한 패턴, 면적이 다른 군집이 혼합된 패턴, 그리고 밀집도 높은 군집과 낮은 군집이 혼합된 패턴의 경우 RSN이 다른 경쟁학습 신경망보다 효과적인 분류결과를 나타내었다. 향후 제안된 RSN이 영상분류 및 문자인식 등과 같은 분야에 적용된다면 보다 효과적인 결과를 얻어낼 것으로 예상한다.

참고문헌

- [1] R. Desimone, *Neural Networks for Vision and Image Processing*, G. A. Carpenter and S. Grossber, Eds, Cambridge, MA: MIT Press, 1992.
- [2] Young-Jae Ryoo and Young-Cheol Lim, "Neuro-Fuzzy Control System for Vision-Based Autonomous

- Vehicle," 1999 IEEE *Int. Fuzzy Systems Conf. Proc.*, pp. III.1643-III. 1648, 1999.
- [3] Laurene Fausett, *Fundamentals of Neural Networks Architectures, Algorithms, and Applications*, Prentice Hall, 1994.
- [4] James A. Freeman and David M. Skapura, *Neural Networks Algorithms, Applications, and Programming Techniques*, Addison Wesley, 1992.
- [5] J. P. F. Sum, C. -S. Leung, K. S. Tam, G. H. Young, W. K. Kan, and L. Chan, "Analysis for a Class of Winner-Take-All Model," *IEEE Trans. on Neural Networks*, Vol. 10, No. 1, pp. 64-71, 1999.
- [6] T. Kohonen, *Self-Organizing Maps*, Springer-Verlag, 1995.
- [7] Helge Ritter, Thomas Martinetz, and Klaus Schulten, *Neural Computation and Self-Organizing Maps*, Addison Wesley, 1992.



류 영재 (Young-Jae Ryoo)

1991년 : 전남대학교 전기공학과(공학사)
1993년 : 전남대학교 전기공학과(공학석사)
1998년 : 전남대학교 전기공학과(공학박사)
현재 : 전남대학교 고품질전기전자부품 및시스템연구센터
관심분야 : 신경망 및 퍼지이론, 지능제어시스템, 자율주행시스템



임 영철 (Young-Cheol Lim)

1975년 : 전남대학교 전기공학과(공학사)
1977년 : 고려대학교 전기공학과(공학석사)
1990년 : 고려대학교 전기공학과(공학박사)
현재 : 전남대학교 전기공학과 교수
전남대학교 고품질전기전자부품 및시스템연구센터 소장
관심분야 : 퍼지, 신경망, 지능 제어계측, 전력전자