

적응적 탐색 전략을 갖춘 계층적 ART2 분류 모델

(Hierarchical ART2 Classification Model
Combined with the Adaptive Searching Strategy)

김 도 현 [†] 차 익 영 [‡]
(Do-Hyun Kim) (Eui-Young Cha)

요약 본 연구에서는 ART2 신경회로망의 성능을 개선하기 위한 계층적 구조를 제안하고, 구성된 클러스터에 대하여 적합도(fitness) 선택을 통한 빠르고 효과적인 패턴 분류 모델(HART2)을 제안한다. 본 논문에서 제안하는 신경회로망은 비지도 학습을 통하여 대략적으로 1차 클러스터를 형성하고, 이 각각의 1차 클러스터로 분류된 패턴에 대해 지도학습을 통한 2차 클러스터를 생성하여 패턴을 분류하는 계층적 신경회로망이다. 이 신경회로망은 이용한 패턴분류 과정은 먼저 입력패턴을 1차 클러스터와 비교하여 유사한 몇 개의 1차 클러스터를 적합도에 따라 선택한다. 이때, 입력패턴과 클러스터들간의 상대 측정 거리비에 기반한 적합도 함수를 도입하여 1차 클러스터에 연결된 클러스터들을 Pruning 함으로써 계층적인 네트워크에서의 속도 향상과 정확성을 추구하였다. 마지막으로 입력패턴과 선택된 1차 클러스터에 연결된 2차 클러스터와의 비교를 통해 최종적으로 패턴을 분류하게 된다. 본 논문의 효율성을 검증하기 위하여 22종의 한글 및 영어 글꼴에 대한 숫자 데이터를 다양한 형태로 변형시켜 확장된 테스트 패턴에 대하여 실험해 본 결과 제안된 신경회로망의 패턴 분류 능력의 우수함을 증명하였다.

키워드 : ART2, HART2, 계층적 신경회로망, 적합도 선택

Abstract We propose a hierarchical architecture of ART2 Network for performance improvement and fast pattern classification model using fitness selection. This hierarchical network creates coarse clusters as first ART2 network layer by unsupervised learning, then creates fine clusters of the each first layer as second network layer by supervised learning. First, it compares input pattern with each clusters of first layer and select candidate clusters by fitness measure. We design a optimized fitness function for pruning clusters by measuring relative distance ratio between a input pattern and clusters. This makes it possible to improve speed and accuracy. Next, it compares input pattern with each clusters connected with selected clusters and finds winner cluster. Finally it classifies the pattern by a label of the winner cluster. Results of our experiments show that the proposed method is more accurate and fast than other approaches.

Key words : ART2, Hierarchical Neural Network, Pruning Strategy, Fitness Selection

1. 서론

인간의 두뇌에 대한 탐구와 이를 컴퓨터를 통해 구현한 신경회로망은 전통적인 인공지능 기법으로 해결할 수 없었던 문제들의 해결 가능성을 보여 주었으며 문자

인식, 패턴 분류, 음성 분석, 로봇 공학, 서명 인식 등 산업 전반에 걸쳐 효과적으로 이용되면서 특히 문자 인식, 음성 인식 등의 패턴 인식에서 신경회로망은 그 강력함을 발휘하고 있다[1-4].

클러스터링을 이용한 패턴 인식은 전처리 및 특징 추출 과정, 학습 과정, 식별 과정으로 구성된다. 전처리 및 특징 추출 과정에서는 입력패턴에 대한 잡영 제거 및 효과적인 특징들을 추출[5,6]하여 입력벡터를 구성함으로써 패턴 학습기의 입력 벡터를 만들어주고, 학습 과정을 통해서 입력 벡터들을 유사한 특징에 따라 클러스터링 함으로써 참조모델(reference model)을 생성하며, 식

본 연구는 부산대학교 컴퓨터 및 정보통신연구소의 지원으로 수행되었음

† 학생회원 : 부산대학교 전자계산학과
unlimmit@hanmail.net

‡ 종신회원 : 부산대학교 전자계산학과 교수
eycha@harmony.cs.pusan.ac.kr

논문접수 : 2002년 5월 8일

심사완료 : 2003년 3월 17일

별 과정에서는 입력패턴을 참조모델내의 각 1) 참조패턴과 비교하여 입력패턴과 가장 유사한 참조패턴에 속하는 부류로 입력패턴을 분류함으로써 패턴 인식이 이루어지게 된다. 이때, 참조패턴의 개수가 많아지면 비교해야 할 노드가 많아짐에 따라 탐색 시간이 오래 걸리게 되며, 반대로 참조패턴이 너무 작게 형성되면 입력패턴의 변형을 충분히 반영하기 힘들게 되어 인식률이 낮아지는 경향이 있다. 이런 경우, 일단 적절한 임계치에 의해 참조 패턴을 충분히 형성시킨 다음 불필요한 탐색 노드를 사전에 가지치기(pruning)함으로써 효율적으로 탐색 시간을 줄이는 방법을 사용하였다. 이때의 참조 모델에서의 참조패턴 노드는 일반적으로 트리(tree) 등과 같이 위상적 구조(Hierarchical structure)로 설계되고, 설계된 노드에 대한 방문 방법은 다음과 같이 구분지을 수 있다[17].

- Full Search - 모든 하위 노드에 대한 탐색을 수행 한다.
- Greedy Search - 각각의 하위 노드 중 가장 가능성 있는 하나의 노드만을 계속 방문한다.
- Local Search - 각각의 하위 노드에서 가장 가능성 있는 노드에 대해서는 그 아래의 모든 하위 노드를 방문하고, 그렇지 않은 노드에 대해서는 그 아래의 모든 하위 노드 중 가능성 있는 하나의 노드만 방문한다.
- Global Search - 각 노드 계층에서 n개의 노드만 방문한다.

이와 같은 하위 노드 탐색 전략은 대형의 노드 구조에서 빠른 탐색을 가능하게 하지만, 각각의 노드들이 나타내는 패턴들간의 유사도 등을 고려하지 않고 단지 탐색 전략에 따라 방문하는 노드들의 개수가 고정적이므로, 입력패턴과 비교해야 할 노드를 충분히 방문하지 못하여 인식률이 저하되거나 불필요한 노드를 방문하게 되는 등의 비효율적인 면이 있다.

한편, 유사한 특징을 가지는 입력패턴을 분류하는 방법에는 통계적인 방법으로 Hierarchical Clustering[7], K-means Clustering 등이 있으며, 신경망을 이용하는 방법으로 코넨 자기조직화 지도 네트워크(Kohonen SOFM : Self-Organizing Feature Map Network)[8], ART2(Adaptive Resonance Theory)[11,12], LVQ (Learning Vector Quantization)[8] 등의 방법이 사용되고 있으며 최근에는 이러한 단일 네트워크의 구조를

1) 여기서 참조패턴이란 입력패턴 집합이 클러스터링되었을 때 생성된 각 클러스터의 중심 패턴을 말하며, 따라서 참조패턴 벡터는 클러스터의 중심 벡터를 말한다.

Decision Tree에 기반한 방법과 연계하여 NTN(Neural Tree Network)를 구성하는 방법도 시도되고 있다 [15-17].

본 논문에서는 빠르고 적응적인 학습 구조를 가지고 있는 ART2 신경회로망을 계층적으로 결합한 구조를 제안하며, 이때 생성된 참조 클러스터를 적합도(fitness)에 따라 선택하여 비교함으로써 패턴 인식을 빠르고 정확하게 수행할 수 있도록 하였다.

본 논문의 구성은 다음과 같다. 2장에서는 ART2 신경회로망에 대해 살펴보며 3장에서는 제안하는 계층적인 ART2 신경회로망(HART2)에 대해 설명한다. 4장에서는 실험을 통한 검증과 분석을, 5장에서는 결론 및 향후 연구 방향을 제시한다.

2. ART2(Adaptive Resonance Theory) Neural Network

ART 신경회로망 모델은 1976년 보스턴 대학의 스텝hen 그로스버그(Stephen Grossberg)가 경쟁학습(Competitive Learning)의 약점인 안정성을 보강하여 제안한 모델이다[12]. ART에 의거한 신경망 모델들은 ART1과 ART2로 불리는 두 개의 네트워크가 있다. ART1 신경회로망은 입력패턴이 이진수(binary)인 경우에만 처리가 가능하고, ART2 신경회로망은 아날로그 입력 데이터에 대해서도 처리가 가능하다. ART 신경회로망은 다음과 같은 특징을 갖는다.

2.1 ART 신경회로망의 특징

- 비지도 학습 - ART는 입력패턴에 대하여 목표값 없이 비지도 학습을 통해 군집화하는 클러스터링 방법이다.
- 실시간 학습 - 비교적 빠른 학습 방법으로 실시간으로 학습할 수 있다.
- 동적 구조 - 주어진 입력 패턴과 ART 클러스터간의 유사도에 대해 Vigilance Test를 거쳐 새로운 클러스터를 생성하거나 기존의 클러스터로 통합하는 클러스터 생성 규칙을 사용한다.
- Stable-Plastic 네트워크 - 사전에 학습한 패턴들을 안정적으로 유지하며 사전에 학습한 적이 없는 새로운 패턴을 처리할 수 있는 능력을 가지고 있다. 즉, 기존의 클러스터에 영향을 미치지 않으면서 학습을 수행할 수 있다.

2.2 ART 학습 알고리즘

ART1 신경회로망은 이진수로 된 입력만을 받아들일 수 있기 때문에 주어진 입력 데이터를 이진 패턴으로 처리한 후에야 처리가 가능한 제한점을 가지고 있다.

대신, ART2 신경회로망은 이진 패턴뿐만 아니라 아날로그와 같은 연속적인 패턴에 대해서도 적용 가능한 확장 모델이다. ART2 신경회로망의 학습 알고리즘은 다음과 같다.

(1) k번째 입력패턴을 x_k , 신경회로망의 i번째 클러스터의 중심값을 w_i 라 하자.

(2) 새로운 입력 패턴 x_k 에 대해 최소 거리(minimum distance)를 가지는 클러스터 j^* 을 승자 클러스터로 선택한다. 일반적으로 입력 패턴과 클러스터 중심패턴과의 거리는 유clidean 거리로 계산한다.

$$\|x_k - w_{j^*}\| = \min \|x_k - w_i\| \quad (1)$$

(3) 입력 패턴에 대한 Vigilance Test를 수행한다. 만약 입력 패턴이 승자 클러스터의 중심 반경 ρ (Vigilance Parameter) 이내에 들어오면 이 입력 패턴은 승자 클러스터와 유사한 패턴임을 의미하여 이 입력 패턴을 승자 클러스터에 포함시키고 그 클러스터의 중심값을 수정한다. 여기서, ρ 는 임의의 입력 패턴과 저장된 클러스터 패턴과의 일치 허용도로 정의한다.

$$w_{j^*}^{new} = \frac{x_k + w_{j^*}^{old} \cdot \|Cluster_{j^*}^{old}\|}{\|Cluster_{j^*}^{old}\| + 1} \quad (2)$$

만약 입력 패턴이 승자 클러스터의 중심 반경보다 크면 이 입력 패턴은 기존의 클러스터와는 상이한 패턴임을 의미하며 이 입력 패턴으로 새로운 클러스터를 생성한다.

(4) 모든 입력이 제시될 때까지 (1)~(3)의 과정을 반복 수행한다.

표 1 ART2 학습 알고리즘

```

입력패턴 집합 X={x1, x2, ..., xN}
클러스터 집합 C={w1, w2, ..., wc}
N : 입력패턴 수, c : 클러스터 수 (c=0), T : 총 반복회수,
For t=1,2,3,...,T
{
    For k=1,2,3,...,N
    {
        if c=0
            c = c+1, wc = xk
        else
            a. 승자 클러스터 선택 ( find winner cluster )
            \|xk - wj*\| = min \|xk - wi\|}, (1 ≤ i ≤ c)
            b. Vigilance Test 수행
            if \|xk - wj*\| < ρ
                wj*^{new} = \frac{x_k + w_{j*}^{old} \cdot \|Cluster_{j*}^{old}\|}{\|Cluster_{j*}^{old}\| + 1}
            else // \|xk - wj*\| ≥ ρ
                c = c+1
                wc = xk
        }
        if Ct = Ct-1 then stop
    }
}

```

(5) 지정된 회수의 학습을 반복 수행하거나 신경망의 클러스터 중심값이 각각 변함이 없으면 학습을 종료한다.

3. Hierarchical ART2 Network

3.1 Hierarchical ART2(HART2) 구조

ART2 신경회로망의 구조는 vigilance parameter ρ 에 의해 결정된다. 즉, ρ 값이 크게 되면 클러스터의 반경이 커지게 됨으로써 하나의 클러스터가 많은 패턴을 수용하게 되어 클러스터의 개수는 작아지는 반면 다양한 패턴들을 저장할 수 있게 된다. 반대로, ρ 값이 작게 되면 클러스터의 반경이 작아지므로 많은 클러스터가 생성되어 다양한 패턴들을 저장할 수 있지만 학습 및 인식에 있어서 비교해야 할 클러스터의 개수가 너무 많기 때문에 속도의 저하를 가져온다.

본 논문에서는 이러한 vigilance parameter의 특성을 고려하여 2층의 클러스터로 구성된 Hierarchical ART2 (이하 HART2)를 고안하였다.

HART2는 2층의 클러스터로 구성되어 있으며 입력층과 연결된 1차 클러스터와 이 클러스터 각각에 연결된 2차 클러스터들로 구성되어 있다. 이때, 1차 클러스터들은 기존의 ART2 학습 알고리즘에 의해 생성되는 중심 참조 벡터 패턴(centroid reference vector pattern)으로써 입력 패턴 집합을 대표하는 대표 패턴들이다. 우리는 이러한 각각의 1차 클러스터들에 의해 분류되는 입력 패턴들을 다시 지도 학습에 의해 좀 더 세부적으로 분류하여 2차 클러스터를 형성하였다. 즉, HART2는 1차 클러스터를 통해 입력 패턴의 형태를 대략적으로 분류하고 각각의 1차 클러스터에 연결된 2차 클러스터를 통해 다양한 형태의 패턴을 대표하게 된다.

3.2 ART2 지도 학습 알고리즘

HART2의 1차 클러스터의 생성은 기존의 ART2방법과 동일한 방법을 사용하여 비지도 학습으로 생성된다. 이때 생성되는 클러스터는 대략적으로 입력 패턴의 유형을 분류하게 된다. 각각의 1차 클러스터는 거기에 속한 입력 패턴 멤버들을 다시 2차 클러스터로 분류하는

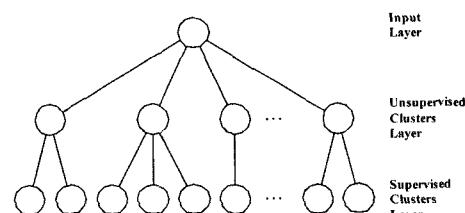


그림 1 Hierarchical ART2의 구조

데 이때에는 ART2 학습 알고리즘을 지도학습으로 변형하여 세부적으로 분류한다. ART2의 지도학습 알고리즘은 비지도 학습과 유사하지만 Vigilance Test를 통한 입력 패턴이라 할지라도 입력 패턴이 승자 클러스터와 다른 클래스일 경우에는 새로운 클러스터를 생성한다는 점이 다르다. ART2 지도학습 알고리즘은 다음과 같다.

(1) k번째 입력패턴을 x_k , 신경회로망의 i번째 클러스터의 중심값을 w_i 라 하고 LX_k , LC_i 를 각각 입력 패턴 x_k 와 클러스터 중심값 w_i 의 해당 클래스를 나타내는 Label이라 하자.

(2) 새로운 입력 패턴 x_k 에 대해 최소 거리(minimum distance)를 가지는 클러스터 j^* 을 승자 클러스터로 선택한다.

(3) 입력 패턴에 대한 Vigilance Test를 수행한다. 만약 입력 패턴이 승자 클러스터의 중심 반경 ρ (Vigilance Parameter) 이내에 들어오고 입력 패턴과 승자 클러스터가 같은 클래스일 때 이 입력 패턴을 승자 클러스터에 포함시키고 그 클러스터의 중심값을 수정한다.

그렇지 않은 경우는 현재 입력 패턴 x_k 를 새로운 클러스터로 할당한다.

(4) 모든 입력이 제시될 때까지 (1)~(3)의 과정을 반복수행한다.

(5) 지정된 회수의 학습을 반복 수행하거나 신경망의

표 2 지도 ART2 학습 알고리즘

```

입력패턴 집합 X={x1, x2, ..., xN}
클러스터 집합 C={w1, w2, ..., wc}
N : 입력 패턴 수, c : 클러스터 수(c=0), T : 총 반복회수,
LX : 입력 패턴의 클래스 Label, LC : 클러스터의 클래스 Label
For t=1,2,3,...,T
{
    For k=1,2,3,...,N
    {
        if c=0
            c = c+ 1 , wc = xk, LCc = LXk
        else
            a. 승자 클러스터 선택 (find winner cluster)
                ||xk - wj*|| = min ||xk - wi|| , (1 ≤ i ≤ c)
            b. Vigilance Test 수행
                if ||xk - wj*|| < ρ && LCj* = LXk
                    wj*new = (xk + wj*old * ||Clusterj*old||) / (||Clusterj*old|| + 1)
                else // ||xk - wj*|| ≥ ρ
                    c = c+ 1, wc = xk, LCc = LXk
    }
    if Ct = Ct-1 then stop
}

```

클러스터 중심값이 각각 변함이 없으면 학습을 종료한다.

3.3 템색 전략(Searching Strategy)

ART2 신경회로망의 클러스터의 수는 vigilance parameter ρ 값에 의해 좌우된다. 이때, 클러스터의 개수가 많아지면 비교해야 할 클러스터가 너무 많기 때문에 학습 및 인식 속도의 저하를 가져온다. 따라서, 본 연구에서 제안한 HART2 신경회로망은 입력 패턴과 유사한 몇 개의 1차 클러스터를 선택한 후 이 클러스터에 연결된 2차 클러스터와의 비교만 수행함으로써 인식률을 저하시키지 않으면서 속도를 개선할 수 있도록 하였다. 이때, 입력 패턴과 유사한 1차 클러스터를 선택하는 방법으로 각각의 1차 클러스터에 대한 적합도(fitness)를 다음의 세 가지 방법으로 계산하여 적용하였다.

3.3.1 2-WC(winner classifier)에 의한 선택

입력 패턴과 각각의 1차 클러스터와의 거리를 구한 후 이를 정렬하여 가장 유사한 2개의 1차 클러스터만 선택되며, 가장 가까운 1차 클러스터에 연결된 각각의 2차 클러스터 모두와, 두 번째로 가까운 1차 클러스터에 연결된 2차 클러스터 중 입력 패턴과 가장 가까운 클러스터 1개가 후보 클러스터가 된다. 최종적으로 패턴 분류는 선정된 후보 클러스터들 중 가장 빈도가 높은 클래스로 입력 패턴을 분류한다.

3.3.2 순위에 의한 선택

입력 패턴과 각각의 1차 클러스터와의 거리를 구한 후 이를 정렬하여 가장 유사한 k개의 1차 클러스터를 선택하고 이 클러스터에 연결된 각각의 클러스터를 후보 클러스터로 선정한다. 예를 들어, 클러스터의 선택 비율을 p라 하고 c개의 1차 클러스터가 있을 때, 입력 패턴과의 거리가 가장 가까운 c×p 개의 1차 클러스터만 선택되며, 선택된 클러스터에 연결된 각각의 클러스터를 후보 클러스터로 선정한다. 패턴 분류는 2-WC에 의한 선택 방법인데 달리, 선정된 후보 클러스터들과 입력 패턴과의 거리를 구하여 가장 가까운 거리에 있는 후보 클러스터의 클래스로 입력 패턴을 분류한다.

3.3.3 상대 거리비에 의한 선택

입력 패턴과 각각의 1차 클러스터와의 거리를 구한 후 최대 거리 및 최소 거리를 산출하여 그 거리가 일정 비 이내에 있는 1차 클러스터를 선택하고 이 클러스터에 연결된 각각의 클러스터를 후보 클러스터로 선정한다. 예를 들어, 클러스터의 선택 비율을 p라 하고 입력 패턴과 c개의 1차 클러스터와의 최소 거리가 d_{min} , 최대 거리가 d_{max} 라 할 때, 아래 식에 의해 정의되는 거리가 d 이하인 1차 클러스터만 선택되며, 선택된 클러스터에 연결된 각각의 클러스터를 후보 클러스터로 선정한다.

최종적으로 선정된 후보 클러스터들과 입력 패턴과의 거리를 구하여 가장 가까운 거리에 있는 후보 클러스터의 클래스로 입력 패턴을 분류한다.

$$\| w_i - x_k \| \leq d_{threshold} \quad (3)$$

$$d_{threshold} = d_{min} + (d_{max} - d_{min}) \times p \quad (4)$$

이와 같이 거리비에 의한 방법을 통해 클러스터를 선택하면 순위에 의한 방법보다 더욱 더 적응적으로 클러스터를 선택할 수 있다. 표에서 5개의 1차 클러스터가 있으며 클러스터 선택 비율이 0.5이일 때 두 가지 방법에 의하여 선택되는 1차 클러스터를 비교하고 있다.

표 3 1차 클러스터 선택 방법 비교 1

클러스터	C1	C2	C3	C4	C5
입력 패턴과의 거리 (예)	1	8	7	9	8
2 WC 에 의한 선택 (2개 고정)	순위 비교	1위	3위	2위	5위
순위에 의한 선택 ($5 \times 0.5 = 2.5 > 2$ 개)	선택 여부	(○)	(x)	(○)	(x)
거리비에 의한 선택 ($1+(9 \cdot 1) \times 0.5 = 5$)	거리 비교	1<5	8>5	7>5	9>5
	선택 여부	(○)	(x)	(x)	(x)

표 4 1차 클러스터 선택 방법 비교 2

클러스터	C1	C2	C3	C4	C5
입력 패턴과의 거리 (예)	2	3	2	3	8
2 WC 에 의한 선택 (2개 고정)	순위 비교	1위	3위	1위	3위
순위에 의한 선택 ($5 \times 0.5 = 2.5 > 2$ 개)	선택 여부	(○)	(x)	(○)	(x)
거리비에 의한 선택 ($2+(8 \cdot 2) \times 0.5 = 5$)	거리 비교	1≤5	3≤5	2≤5	3≤5
	선택 여부	(○)	(○)	(○)	(○)

3.4 패턴 인식

순위 또는 거리비에 의하여 선택된 1차 클러스터는 입력 패턴과 유사한 패턴임을 의미하여 이 1차 클러스터에 연결된 2차 클러스터도 마찬가지로 입력 패턴과 유사한 패턴이 된다. 반대로 1차 클러스터로 선택되지 않은 클러스터는 입력 패턴과 유사하지 않은 패턴이며, 따라서 이 클러스터에 연결된 2차 클러스터도 입력 패턴과 유사하지 않은 클러스터로 구성되어 있다. 따라서 많은 수의 클러스터를 생성하여 모두를 입력 패턴과 비교하기 위한 후보 클러스터로 선택하지 않고 가능성 없는 클러스터는 1차 클러스터에서 가지치기(pruning)가 되어 탐색 공간을 축소함으로써 빠른 인식을 수행할 수 있게 된다. 이때 입력 패턴과 가장 가까운 1차 클러스터 하나만을 선택하는 것보다 클러스터 선택 비율(p)을 두어 전체에서 어느 정도의 클러스터를 선택함으로써 1차

클러스터에서의 오분류의 위험을 감소시킬 수 있다.

4. 실험 및 결과 분석

4.1 실험 데이터 구성

본 논문에 사용된 실험 데이터는 22개의 2)한글 영문 조합 글꼴로 총 220개의 Gray-level 숫자 영상 파일을 기본 데이터로 하였으며, 입력 데이터의 다양한 입력 변형을 포함할 수 있도록 기본 입력 데이터를 위치이동(4), 경사왜곡(4), 세선화(1), 중간값 필터링(1), 좌우 5°, 10° 회전(4), 모폴로지 확장, 가로확대축소(2), 세로 확대축소(2), 가로세로확대축소(2), 5% Salt&Pepper Noise 추가, Zero-mean Uniformly Distribution Noise를 추가하여 변형한 총 5280개의 3)변형 데이터를 생성하였으며, 그 중 임의로 선택한 1760개의 데이터를 학습에 사용하고 나머지 3520개의 데이터를 인식 테스트를 위해 사용하였다.

4.2 정규화를 이용한 패턴 벡터 생성

숫자 이미지 데이터로 입력 패턴을 생성하기 위한 전처리 과정으로서 다양한 크기의 입력 이미지에 대한 정규화는 문자 영상에 대한 효율적인 패턴벡터를 생성하는데 중요한 역할을 한다. 본 논문에서는 이와 같은 정

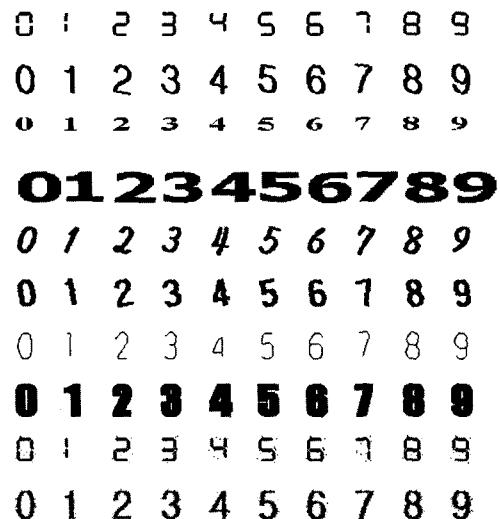


그림 2 숫자 이미지 데이터 예

2) 굵립, 궁서, 돌움, 명조, 바탕, 산세리프, 샘풀, 시스템, 신명조, 안상수, 중고딕, 편기, 휴먼옛체, Arial, Courier, Fixdays, Impact, LED, Orbit-B, Symbol, Times New Roman, Verdana

3) 22종 × 24(23가지 변형+원형) × 10 ≈ 5280개

규화 방법으로써 문자 회의 굵기를 일정하게 조정한 회 정규화 방법[3]에 의하여 다양한 크기의 문자 이미지를 15×25 로 정규화하여 문자 영상을 개선하고, 0~255의 픽셀값을 0~1 사이의 부동소수점 값으로 Scaling하여 입력 패턴 벡터를 생성하였다.

4.3 실험 방법

실험 방법은 입력 패턴과의 비교 대상이 되는 후보 클러스터를 선택하는 탐색 전략에 따라 다음의 4가지로 구분하여 실험하였으며 그림 3에서는 각각에 대한 후보 클러스터가 선택되는 방법을 보여준다.

(1) Method 1 (First layer Search : 1L)

기존의 ART2 기법으로 모든 1차 클러스터를 후보 클러스터로 설정하여 입력 패턴과 이 후보 클러스터들과의 비교만 수행하여 패턴을 인식한다.

(2) Method 2 (Second layer Full Search : 2L ALL)

생성된 HART2의 모든 2차 클러스터를 후보 클러스터로 설정한다. 이때, 2차 클러스터의 클래스는 학습 과정에서 설정된다.

(3) Method 3 (Second layer 2-Rank Search : 2L RANK2)

2-WC(winner classifier)에 의한 적합도 적용 방법이다.

(4) Method 4 (Second layer k-Rank Search : 2L RANK)

순위(Rank)에 의한 적합도 적용 방법이다.

(5) Method 5 (Second layer MinMax Distance Ratio Search : 2L MINMAX)

상대 거리비에 의한 적합도 적용 방법이다.

4.4 실험 결과

신경회로망의 구조를 형성하기 위해서 Vigilance parameter(ρ)를 100~150로 다양하게 변화시켜 1차 클러스터의 개수(C1)를 91~15개까지 생성하였다. 또한, 클러스터 선택 비율은 0.3으로 하였으며 따라서 2L_RANK에서는 전체 1차 클러스터 개수의 30%를 선택하게 하였고, 2L_MINMAX의 방법에서는 최대 최소 거리에 따라 30%이내의 모든 클러스터를 선택하게 하였다.

4.4.1 클러스터 선택 개수

표 5~6, 그림 4~5는 탐색 전략에 의해 선택되는 1차 클러스터의 평균 개수와 이에 따른 후보 클러스터의 평균 개수를 나타내고 있다. 표 5에서 알 수 있는 바와 같이 1L, 2L_ALL의 방법은 생성된 신경회로망의 1차 클

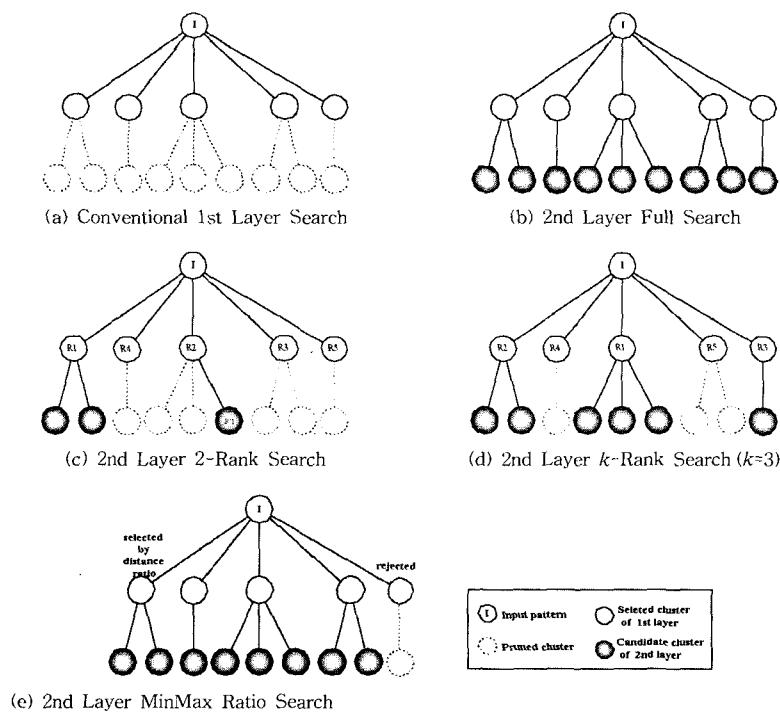


그림 3 탐색 전략별 후보 클러스터 선택 방법

러스터 전체(C1)을 선택하고 있으며, 2L_RANK2의 방법은 항상 2개의 1차 클러스터를 선택하고 있다. 2L_RANK의 방법은 항상 순위별 특정 개수의 클러스터($91 \times 0.3 > 28$, $68 \times 0.3 > 21$, $46 \times 0.3 > 14$, $35 \times 0.3 > 11$, $25 \times 0.3 > 8$, $15 \times 0.3 > 5$)를 선택하는 모습을 볼 수 있으며, 2L_MINMAX의 방법은 입력 패턴과 1차 클러스터와의 최소최대 거리비에 따라 가변적인 개수의 1차 클러스터가 선택됨을 알 수 있다. 1차 클러스터의 개수는 일반적으로 vigilance parameter의 값이 커질수록 감소하게 되므로 그림 4에서 알 수 있는 바와 같이 입력패턴과 비교되는 1차 클러스터의 수가 감소하는 것을 알 수 있다. 하지만 최종적으로 입력 패턴과 비교되는 후보 클러스터인 2차 클러스터의 개수는 그림 5에서와 같이 일정한 개수를 유지하는 것을 알 수 있으며, 2층의 HART2 신경망 구조를 구성함으로써 vigilance para-

meter의 값에 큰 영향을 받지 않고 일정한 개수의 클러스터를 생성하는 것을 알 수 있다.

4.4.2 인식 시간

표 7, 그림 6은 각각의 방법에 따른 전체 패턴 인식 시간을 보여준다. 1L의 방법은 입력 패턴과 1차 클러스터와의 비교만을 수행하기 때문에 당연히 가장 빠르게 수행됨을 알 수 있으며, 2L_RANK2의 방법은 항상 2개의 1차 클러스터만을 선택하기 때문에 다른 방법에 비해 좀 더 빠르게 수행되며, 2L_MINMAX의 방법이 2_RANK의 방법보다 적은 수의 1차 클러스터를 선택함으로 상대적으로 빠르게 수행됨을 알 수 있다.

4.4.3 인식률

표 8은 각각의 방법에 따른 전체 패턴 인식률을 보여준다. 1L의 방법은 1차 클러스터만을 비교하므로 1차 클러스터의 개수에 의해 인식률의 차이가 많이 변화되

표 5 1차 클러스터 평균 선택 개수

클러스터 개수 (개)	$\rho=100$ C1(91) C2(152)	$\rho=110$ C1(68) C2(145)	$\rho=120$ C1(46) C2(138)	$\rho=130$ C1(35) C2(131)	$\rho=140$ C1(25) C2(142)	$\rho=150$ C1(15) C2(157)
1L						
2L_ALL	91	68	46	35	25	15
2L_RANK	28	21	14	11	8	5
2L_RANK2	2	2	2	2	2	2
2L_MINMAX	10.076	7.808	5.751	4.749	3.968	2.3262

표 6 후보 클러스터 (2차) 평균 개수

클러스터 개수 (개)	$\rho=100$ C1(91) C2(152)	$\rho=110$ C1(68) C2(145)	$\rho=120$ C1(46) C2(138)	$\rho=130$ C1(35) C2(131)	$\rho=140$ C1(25) C2(142)	$\rho=150$ C1(15) C2(157)
2L_ALL	152	145	138	131	142	157
2L_RANK	49.164	45.127	42.908	41.859	48.324	61.298
2L_RANK2	2.707	2.942	4.555	4.946	6.907	12.739
2L_MINMAX	16.291	16.036	17.267	18.038	23.966	33.541

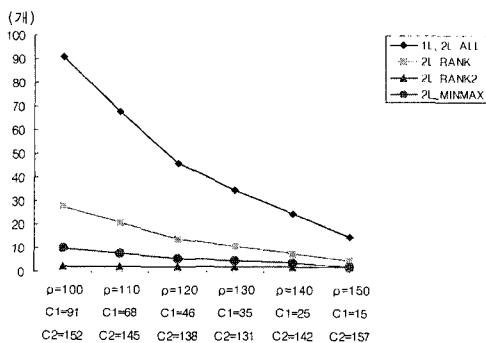


그림 4 1차 클러스터 평균 선택 개수

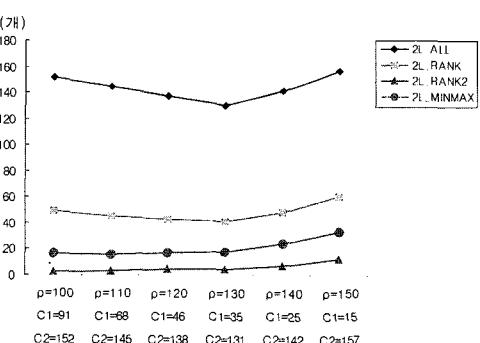


그림 5 후보 클러스터 평균 개수

표 7 전체 패턴인식 시간

시간(ms)	$\rho=100$ C1(91) C2(152)	$\rho=110$ C1(68) C2(145)	$\rho=120$ C1(46) C2(138)	$\rho=130$ C1(35) C2(131)	$\rho=140$ C1(25) C2(142)	$\rho=150$ C1(15) C2(157)
1L	4401	2776	1182	969	847	422
2L_ALL	7436	7060	7524	7343	6943	8318
2L_RANK	7535	5934	4535	3781	3134	3543
2L_RANK2	5271	3577	2010	1266	1076	1149
2L_MINMAX	5555	3944	2489	2077	1682	1870

표 8 전체 패턴 인식률(%)

인식률(%)	$\rho=100$ C1(91) C2(152)	$\rho=110$ C1(68) C2(145)	$\rho=120$ C1(46) C2(138)	$\rho=130$ C1(35) C2(131)	$\rho=140$ C1(25) C2(142)	$\rho=150$ C1(15) C2(157)
1L	95.455	92.301	90.938	90.54	94.545	72.017
2L_ALL	96.136	94.972	93.665	93.523	95.142	95
2L_RANK	96.136	94.972	93.636	93.892	95.227	95
2L_RANK2	91.25	85.852	85.284	90.71	90.682	94.489
2L_MINMAX	96.193	95	93.693	94.432	95.597	94.886

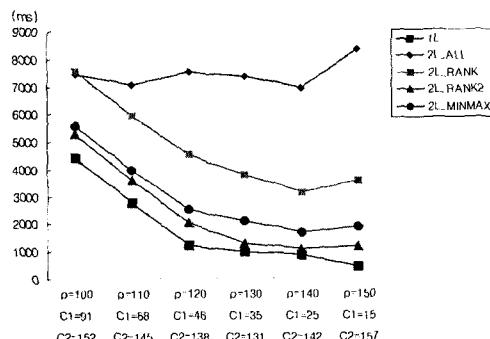


그림 6 전체 패턴인식 시간

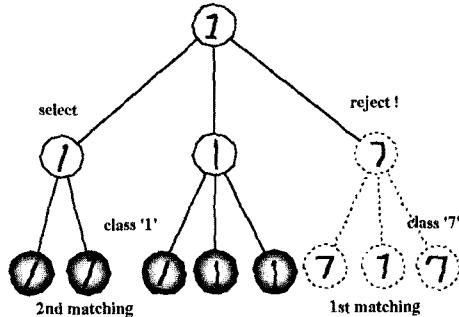


그림 7 신경회로망의 generalization 능력

는 것을 알 수 있으며 이는 vigilance parameter의 영향을 많이 받는다는 것을 알 수 있다. 2L_ALL과 2L_RANK의 방법은 대체적으로 우수한 인식률을 보이고 있음을 알 수 있다. 일반적으로 2L_ALL의 방법이 가장 좋은 인식률을 기록할 것으로 예상되지만 본 실험에서와 같이 2L_RANK, 2L_MINMAX에 의한 방법이 2L_ALL보다 더 좋은 인식률을 기록한 이유는, 1차 클러스터에 의해 후보 클러스터들의 일부가 제외됨으로써, 클러스터의 클래스를 결정짓는 과정에서의 오류를 줄일 수 있기 때문이다. 즉, 그림 7에서 볼 수 있는 바와 같이 class '1'인 입력 패턴이 있을 때, 2L_ALL의 방법에서는 모든 2차 클러스터 중에서 입력 패턴과 가장 유사한 클러스터(1st matching cluster)를 찾기 때문에 입력 패턴이 class '7'로 오분류될 수 있지만 2L_MINMAX에서는 효율적으로 1차 클러스터를 선택하여 2차 클러

스터들을 pruning함으로써 다음으로 가장 가까운 2차 클러스터(2nd matching cluster)에 의해 입력 패턴이 분류되므로 올바른 인식률을 유도하는 일반성(generalization)을 가지게 된다.

결론적으로 1L에 의한 방법은 상대적으로 가장 수행 속도가 빠르지만 인식률이 저조함이 나타났으며, 2L_ALL에 의한 방법은 인식률은 매우 우수하지만 가장 느리게 수행되며 2L_RANK에 의한 방법과 2L_MINMAX에 의한 방법은 수행속도와 인식률 면에서 매우 우수한 성능을 나타냄을 알 수 있으며 특히 거리비에 의하여 1차 클러스터를 선택하는 2L_MINMAX의 방법이 속도 및 인식률에서 가장 우수한 성능을 나타내었다. 또한 2층의 신경회로망 구조를 구성함으로써 vigilance parameter의 값에 관계없이 오분류의 위험을 줄이고 보다 일반성을 가진다는 것을 알 수 있다.

5. 결론 및 향후 연구 방향

본 논문에서는 2개의 ART2 신경회로망을 연결한 계층적 신경회로망을 구현하였다. 1차 신경망층은 입력 패턴에 대한 비지도 학습을 수행하여 대략적인 패턴을 대표하는 클러스터로 구성되어 있으며, 각각의 1차 클러스터에 연결된 2차 신경망층은 지도 학습을 수행하여 세부적인 학습 패턴을 대표하는 클러스터로 구성되어 있다. 이와 같이 형성된 신경회로망에서 1차 클러스터를 순위 및 거리비에 의해 부분적으로 선택하고, 선택된 1차 클러스터에 연결된 2차 클러스터를 후보 클러스터로 설정함으로써 인식의 효율성을 추구하였다.

다양한 글꼴 및 변형에 의한 실험 데이터를 바탕으로 분류 인식 테스트를 수행한 결과, 많은 수의 참조패턴이 형성된 경우라 할지라도 전체 노드 탐색 방법에 비해 1차 클러스터층에서 불필요한 하위 참조패턴들이 거리비에 의해 적응적으로 제거됨에 따라 인식률의 저하 없이 오히려 올바른 인식을 유도하는 일반성(generalization)을 가지게 되었으며, 인식 속도면에서는 1.3~4.4배 정도의 속도향상을 가져왔다.

하지만 입력패턴과 참조패턴과의 거리비를 계산하는 과정에서 소요되는 연산시간이 다른 노드를 방문하는 시간보다 클 경우는 오히려 속도가 느려질 우려가 발생하므로, 이러한 시간 비용을 최대한 줄이기 위한 방법에 대한 연구와 함께, 1차 클러스터를 선택하는 또 다른 방법으로 페지 멤버쉽 값을 적용하는 방법에 대한 연구, 그리고 각각의 클러스터층에 적용하는 새로운 비지도/지도 학습 알고리즘의 개발에 대한 연구를 수행할 것이다. 또한 숫자 데이터뿐만 아니라 영어 및 한글 문자에 대한 검증도 수행되어야 할 것으로 생각된다.

참 고 문 헌

- [1] Simon Haykin, 'Neural Networks A Comprehensive Foundation,' PRENTICE HALL, 1999.
- [2] Lefteri H. Tsoukalas, Robert E. Uhrig, 'Fuzzy and Neural Approaches in Engineering,' Wiley Interscience publication, 1997.
- [3] B. D. Ripley, 'Pattern Recognition and neural networks,' Cambridge, 1996.
- [4] 김대수, '신경회로망 이론과 응용 (I), (II)', 하이테크 정보, 1994.
- [5] 김도현, 강동구, 강민경, 차의영, '문자 인식을 위한 효율적인 획 정규화', 한국 정보처리학회 추계학술대회 상권, 2001년.
- [6] 박창순, 김두영, "오프라인 필기체 숫자 인식을 위한 다양한 특징들의 비교 및 인식률 개선 방안", 한국 정보처리학회 논문지, 제3권 4호, 1996년 7월.
- [7] Sergios Theodoridis, Konstantinos Koutroumbas, 'Pattern Recognition,' ACADEMIC PRESS, 1999.
- [8] Teuvo Kohonen, "The Self Organizing Map," Proceeding of the IEEE, Vol.78, No.9, pp.1464 1480, Sep. 1990.
- [9] Nikhil R. Pal, James C. Bezdek, "Generalized Clustering Networks and Kohonen's Self Organizing Scheme," IEEE Transaction on Neural Networks, Vol.4, No.4, pp.549 557, July 1993.
- [10] Jing Wu, Hong Yan, "Combined SOM and LVQ Based Classifiers for Handwritten Digit Recognition," Proceeding of the IEEE on Neural Networks, Vol.6, pp.3074 3077, 1995.
- [11] G. A. Carpenter, S. Grossberg, "ART2: Self Organization of Stable Category Recognition Codes for Analog Input patterns," Applied Optics, Vol. 26, No. 23, 1987, pp.4919 4930.
- [12] G. A. Carpenter, S. Grossberg, "The ART of Adaptive Pattern Recognition by a Self Organizing Neural Network," Computer, Vol. 21, No.3, 1988, pp.77 88.
- [13] Pham, D.T. Sukkar, M.F., "Supervised adaptive resonance theory neural network for modelling dynamic systems," Systems, Man and Cybernetics, Vol. 3 , 1995, pp.2500 2505.
- [14] Sorheim, E., "A combined network architecture using ART2 and back propagation for adaptive estimation of dynamical processes," System Sciences, Proceedings of the Twenty Fourth Annual Hawaii International Conference on, Vol. 1, 1991, pp.468 475.
- [15] A. Sanker, R.J.Mammone, "Neural Tree Networks," in Neural Networks : Theory and Applications, Academic Press, 1991.
- [16] A. Sanker, R.J.Mammone, "Growing and pruning neural tree networks," IEEE transaction Computer, Vol.42, pp.291~299, 1993.
- [17] Behnke, S.; Karayannidis, N.B., "Competitive neural trees for pattern classification Neural Networks," IEEE Transactions on Neural Networks, Vol.9, No.6, pp. 1352 1369, Nov 1998.



김 도 현

2001년 부산대학교 전자계산학과 졸업(학사). 2001~현재 부산대학교 대학원 전자계산학과 석사 재학중. 관심분야는 신경회로망, 문자/패턴인식, 영상처리, 컴퓨터비전



차 의 영

1979년 경북대학교 전자공학과 졸업(학사). 1982년 서울대학교 대학원 전자계산학과(이학석사). 1998년 서울대학교 대학원 컴퓨터공학과(공학박사). 1981년~1985년 한국전자기술연구소 연구원. 1995년~1996년 University of London 방문 교수. 1985년~현재 부산대학교 전자계산학과 교수. 관심분야는 컴퓨터비전, 신경회로망 이론, 웨이블릿, 위터마킹