

구조적응 자기조직화 신경망 : 한글 문자인식에의 적용

이 경미○ 조 성배 이 일병
연세대학교 전산과학과

Structure-Adaptive Self-Organizing Neural Network : Application to Hangul Character Recognition

Kyoungmi Lee Sung-Bae Cho Yillbyung Lee
Dept. of Computer Science, Yonsei University
TEL: 02-361-2713
FAX : 02-365-2579
E-mail: lucky@csai.yonsei.ac.kr

요 약

코호넨의 SOFM(Self-Organizing Feature Map)은 빠른 점증 학습이 가능하여 다중 퍼셉트론의 단점 을 보완할 수 있는 패턴분류기로 부각되고 있다. 그러나 기본적으로 고정된 크기와 구조의 네트워크를 사용하기 때문에 실제 문제에 적용하기가 쉽지 않다는 문제가 있다. 본 논문에서는 패턴에 대한 사전 정보없이 복잡한 패턴공간을 적용적으로 분할하기 위해 구조적용되는 자기조직화 신경망을 소개하고 이를 인쇄체 한글 문자의 인식에 적용한 결과를 보여준다. 여기에서 제안하는 신경망은 SOFM의 각 셀이 좀더 자세한 SOFM으로 확장될 수 있도록 하며, 확률분포가 0인 셀을 제거함으로써 패턴 공간에 보다 균사한 분류를 가능하게 한다. 실제로 이러한 방식이 한글과 같은 복잡한 분류 문제에서 어떻게 작동하는지 설명하고, 한글 완성형 2350자에 대해 실험한 결과를 보여준다.

I. 서 론

패턴 분류는 입력 패턴으로부터 중요한 특징이나 속성을 추출하여 그것이 어떤 부류에 속하는지 결정하는 것이다. 이제까지 다양한 패턴분류 알고리즘의 개발과 더불어 이를 문자인식에 적용하는 연구사례가 꾸준히 보고되어 왔으며 요즘에는 상용화된 문자인식시스템도 많이 등장하고 있다. 특히 국내외 경우에도 한글 문자인식은 1970년대 이후부터 꾸준히 연구되어 원형 정합법, 통계적 방법, 구문론적 방법 등이 널리 연구되고 있다. 최근에는 인간 두뇌의 구조를 모방한 신경망 모델을 이용하여 한글 문자를 인식하고자 하는 연구가 활발히 이루어지고 있다.

이러한 신경망은 학습 방법에 따라 지도 학습과 비지도 학습으로 나눌 수 있으며, 특히 지도학습 신경망으로 Hopfield 신경망, Hamming 신경망 및 다중 퍼셉트론 등이 널리 쓰여왔다. 이중에서 문자인식 분야에서는 다중 퍼셉트론으로 학습시킨 신경망을 이용하는 연구가 활발히 이루어지고 있다.[7],[10] 그러나 많은 경우에 학습 데이터를 여러번 반복하여 학습하여도 수렴이 보장되지 않아 몇번의 반복 학습으로 패턴을 제대로 표현할 수 있을지라고 예상하기 어렵다. 반면, 코호넨의 SOFM[6]은 대표적인 비지도 학습 신경망으로 학습 과정 중에 소속 부류에 대한 정보없이 자기 조직화하여 유사한 패턴끼리 부류를 형성함으로 베티 양자화나 패턴을 분류하는데 사용될 수 있다. 비지도 학습은 패턴인식의 중요한 분야이지만, 지도 학습에 비해 상대적으로 용용 연구가 적었다.

신경망 모델을 한글 문자인식에 이용할 경우에는 한글에는 인식대상의 문자수가 많고, 유사한 형태의 문자가 많으며 또 문자의 형태가 복잡한 것부터 단순한 것까지 혼합되어 있어서 기존의 모델을 그대로

적용하기가 어렵다는 문제점이 있다. 따라서 본 논문에서는 이와 같은 문제를 해결하기 위해서 결정경계가 복잡한 문제에 대해서 패턴 공간에 대한 사전 지식없이 적용적으로 구조를 변경시키는 구조적용 자기조직화 신경망[9]을 소개하고 이를 한글 문자인식에 적용하였다.

본 논문의 구성은 다음과 같다. 우선 II 장에서 SOFM에 대해서 어떻게 패턴이 분류되는지 살펴 보고 실제 적용에 있어서의 문제점을 제기한다. 그 다음 본 논문에서 제시하는 구조적 자기적용 신경망과 그 학습 알고리즘을 III 장에서 소개하고, IV 장에서는 한글 문자인식에 어떻게 적용되는지 예를 통해 살펴 본다. 끝으로 V 장에서 구조적 자기적용 신경망을 인쇄체 한글 문자 인식에 적용한 실험 결과와 제안된 신경망을 사용하였을 때의 혼동률과 그양상을 살펴본다.

II. SOFM에 의한 패턴 분류

SOFM은 n -차원의 입력 벡터들이 입력 공간 \mathbb{R}^n 에서 정렬해 있는 모양이 저차원(예를 들면 2차원)으로 배열된 유니트들의 반응으로 그대로 반영되어 나타난다. (그림 1)에서 보는 바와 같이 SOFM의 구조는 입력층과 경쟁층, 두 개의 층으로 이루어져 있는데, 입력 층은 n -차원의 입력 노드들로, 경쟁층은 코호넨 유니트(출력 노드)로 구성되어 있다. 모든 연결은 입력층에서 경쟁층의 방향으로 완전 연결되어 있으며, 각 연결은 연결강도 값을 갖고 있다. 또한 경쟁층의 유니트는 그들의 이웃들과 서로 연결되어 있다. 각 유니트와 입력 벡터사이에 연결된 연결강도 벡터들은 부류의 중심에 해당하는 것으로 각 유니트가 일종의 부류를 대표한다고 볼 수 있다.

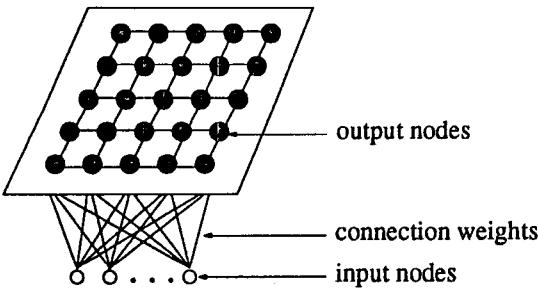


그림 1: SOFM의 구조

$X(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T \in \mathbb{R}^n$ 를 입력 벡터라 하고, $m_i(t) = [m_{i1}(t), m_{i2}(t), \dots, m_{in}(t)]^T \in \mathbb{R}^n$ 를 연결강도 벡터라고 하자. SOFM의 학습에서 각 유니트는 연결강도와 입력벡터 사이의 거리를 계산하여 가장 가까운 가중치를 가지는 유니트를 승자유니트 c 로 선택한다. 이때 거리로는 보통 유clidean 거리(Euclidean distance)를 사용한다.

$$\|x - m_c\| = \min_i \|x - m_i\|$$

승자유니트를 결정하고 난 후에는 승자유니트와 그의 이웃들만이 그들의 연결강도 벡터를 다음과 같이 조정할 수 있다.

$$m_i(t+1) = \begin{cases} m_i(t) + \alpha(t)[x(t) - m_i(t)], & i \in N_c(t) \\ m_i(t), & i \notin N_c(t) \end{cases}$$

학습률($0 < \alpha(t) < 1$)은 초기에 1에 가까운 값을 주고 시간이 지남에 따라 줄어가며, 이웃의 범위인 $N_c(t)$ 도 승자노드 c 의 이웃으로 초기에 크게 잡아 점차 줄여간다. 이웃의 모양은 보통 사각형 혹은 육각형으로 정의하며 본 연구에서는 사각형의 모양을 이용하였다.

이제 SOFM이 폐인 분류에 어떻게 사용될 수 있는지 살펴보자. R_1, R_2, \dots, R_M 을 M 개의 부류라 하자. SOFM은 모든 입력폐인에 대해 다음의 배정을 학습시켜야 한다.[5]

$$X \longrightarrow R_i$$

SOFM을 사용할 경우 이처럼 M (경쟁층의 유니트 수)을 미리 정해야 한다. M 은 최종 분류 후의 부류수에 가까운 것을 선택하는 것이 바람직하지만, 부류의 수는 폐인 공간에 매우 의존적이어서 미리 정확하게 알 수 없다. 이러한 성질은 대부분의 분류기가 갖고 있는 문제점이다.

SOFM의 가장 중요한 특성 중의 하나는 벡터 공간 \mathbb{R}^n 과 위상 구조 S 사이에 위상보존 사상(topology preserving mapping)을 한다는 것이다. 즉, 경쟁층에서 인접하는 승자 유니트들은 입력벡터 공간에서도 인접하는 입력벡터에 해당함으로써 경쟁층 내의 승자 유니트의 위치는 입력벡터에 대한 정보를 제공한다. 벡터 X_1 과 X_2 가 경쟁층에서의 r_1 과 r_2 위치에 있는 승자 유니트에 해당한다면, r_1 과 r_2 는 가까워지고 마침내 일치하게 된다. 따라서 위상보존 사상은 n -차원의 입력 공간을 2-차원으로 차원을 줄이면서 입력공간내 위상 관계를 보존한다. 그런데 SOFM의 구조((그림 2)의 (a))를 보면, 실제로는 떨어져 있는 유니트들이 직접적으로 연결되는 경우가 있다. 이는 SOFM이 경쟁층의 유니트 사이의 위상을 미리 정하고 있기 때문에 발생하는 문제이다. 이와 같이 미리 고정된 연결로 복잡한 폐인 공간을 잘 분류하기는 쉽지 않다. [1],[2],[3],[4]

SOFM이 가지고 있는 또 하나의 중요한 특징은 분포보존 사상(distribution preserving mapping)이다. 분포보존이란 $P(X)$ 를 \mathbb{R}^n 에 대한 확률 분포라 하면, $P(X)$ 를 따르는 벡터에 대해 각 유니트는 같은 확률로 사상이 됨을 의미한다. 즉, \mathbb{R}^n 내 벡터들의 상대

적인 밀도는 $P(X)$ 에 근사한다. 그러나 SOFM은 경쟁층 사이의 연결관계를 미리 정하고 있어 확률이 0인 유니트도 존재하게 될 수 있으므로 폐인에 근사하게 분류한다고 할 수 없다.[1],[2],[3],[4]

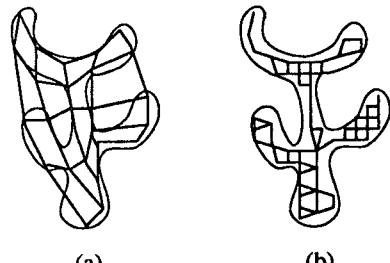


그림 2: 확률분포에 대한 조직화의 예

III. 구조적용 자기조직화 신경망

본 논문에서는 폐인분류에 있어서 SOFM의 제한점을 해결하기 위해서 SOFM의 구조가 폐인공간에 적응적으로 변형되는 구조적용 자기조직화 신경망((그림 2)의 (b))을 사용하여 한글 문자인식에 적용하였다. 결과적으로 본 신경망은 SOFM에 구조적용 능력을 부여하여 제안된 신경망의 구조 및 크기를 자동적으로 찾아내도록 함으로써 복잡한 경쟁 경계를 갖는 폐인 분류에 적합하다는 장점을 갖는다. 구조적용 자기조직화 신경망에 의한 전체 인식과정을 (그림 3)에 나타내었다.

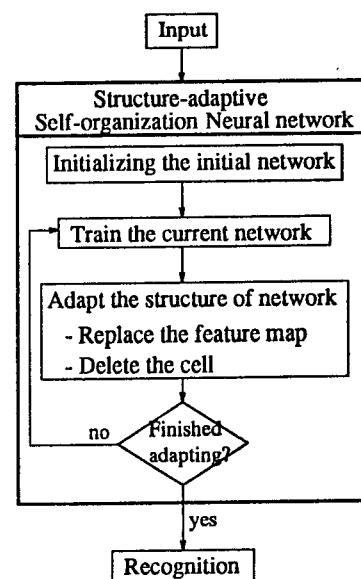


그림 3: 구조적용 자기조직화 신경망에 의한 학습 및 인식 과정

3.1 신경망의 구조

구조적용 자기조직화 신경망은 각 셀에 대한 격자 표기가 서로 다르다는 점을 제외하고는 SOFM의 구조와 거의 동일하다. 신경망의 각 셀은 폐인 공간의 부분 영역을 대표한다. (그림 4)는 모든 셀이 동일한 갯수의 인접 영역을 갖는 SOFM과 달리 제안된 신경망은 각 셀의 인접 영역 수가 다름을 보여주고 있다. 따라서 연결 셀들이 모두는 위상학적 구조도 서로 다르다.

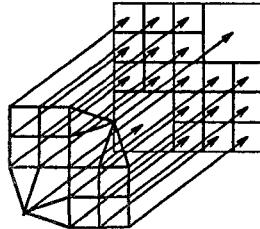


그림 4: 제안된 신경망의 네트워크 구조

하지 않은 셀이 과도하게 학습되는 문제를 방지하는 효과도 얻을 수 있다.

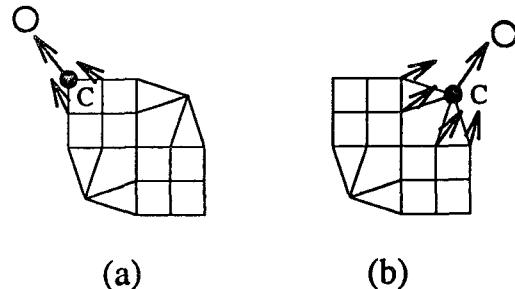


그림 6: 적응학습 : 직접 연결된 셀만을 이웃집합으로 한 경우이다. (a) 승자유니트 C의 이웃집합내의 셀은 2개로 학습에 참여하는 셀은 모두 3개이다, (b) 승자유니트 C의 이웃집합내의 셀은 4개로 학습에 참여하는 셀은 모두 5개이다.

제안된 신경망은 적은 수의 간단한 네트워크로 시작하여 그 구조가 계속해서 능동적으로 변형되므로 위상학적 이웃집합에 대해 적절히 정해야 한다. 위상학적 이웃집합에 대한 개념은 포유동을 뇌의 2차원 신경충의 셀 사이에서 측면 상호작용(lateral interaction)에 대한 연구에 입각한 것이다. 제안된 신경망의 위상학적 이웃관계는 신경셀의 상호연결 위상에서 찾아볼 수 있다. 두 신경셀이 연결되어 있다면, 이에 해당하는 영역도 인접해 있는데, (그림 5)는 제안된 신경망에서의 이웃집합을 보여주고 있다. 이때, 커다란 셀과 작은 셀은 서로 다른 격자를 가지고 있지만 셀과 셀사이의 연결은 모두 동일함을 원칙으로 한다.

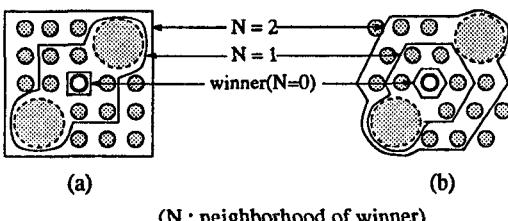


그림 5: 위상학적 이웃집합 : (a) 사각형, (b) 육각형

3.3 형상지도 대치

현재의 네트워크에 대한 학습을 마치면, 제안된 신경망은 형상지도를 대치한다. 학습과정에서 서로 다른 패턴이 같은 부류에 포함되는 셀을 형상지도가 삽입될 셀 q 로 결정한다. q 는 많은 오분류가 일어나는 입력벡터 공간에 위치한다. 따라서 현재의 네트워크에서는 올바른 연결강도를 찾을 수 없다. 이는 또한 q 가 대표하는 영역에 대해 주변의 영역보다 낮은 해상도(coarse resolution)를 갖게 한다. 서로 다른 부류의 입력벡터가 같은 셀로 같은 확률로 사상된다면 이들을 구별하기는 어렵다. 실제로 SOFM을 사용하면 승자벡터가 충분히 다른 경우라도 항상 구별할 수 있는 것은 아니다.

제안된 신경망의 형상지도 대치는 이러한 문제를 해결해 준다. 서로 다른 부류의 입력벡터가 포함된 셀을 형상지도로 대치함으로써 다른 셀과 다른 확률로 사상되고, 결국 상세분류의 효과를 갖게된다.

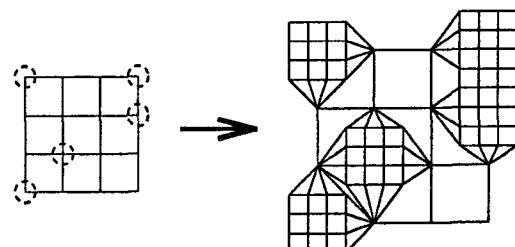


그림 7: 형상지도의 대치

3.2 적응학습

SOFM이 다른 경쟁학습 신경망들과 다른 중요한 차이점은 승자유니트와 그 위상학적 이웃집합 내 모든 셀이 학습한다는 점이다. SOFM은 같은 반경내에 포함된 이웃 셀들의 수가 모두 같기 때문에 학습에 참가하는 셀들의 수 역시 모두 같다. 반면, 제안된 신경망은 어떤 셀이 승자유니트이나에 따라 학습에 참가하는 셀들의 수가 달라진다. 또한 현재 신경망에 대한 학습과 구조 적응이 반복해서 수행된다. 현재 신경망에 대한 학습을 마치면 적응에 필요한 셀들이 찾아지고 다음 단계에서 설명한 형상지도 대치나 셀 제거를 수행하면 된다. 이 때, 새로 추가된 셀들은 기존의 셀에 비해 학습의 기회가 적으므로 추가된 셀을 승자유니트로 선택한 입력벡터에 대해서는 학습 횟수를 늘려준다. 이런 차별 학습은 적응되지 않은 셀의 학습 횟수를 상대적으로 줄임으로써 전체 학습 시간을 줄일 뿐만 아니라 적응

그럼 과연 어떻게 대치할 것인가? q 가 대표하는 영역은 형상지도가 대치됨으로써 다시 작은 영역으로 나뉘어진다. 나뉘어진 영역을 대표하는 셀들은 그 인접영역과 연결된다. 따라서 서로 다른 크기의 영역을 대표하는 셀들은 서로 연결될 수 있다. 새로 대치된 형상지도의 셀들은 대치된 영역의 중심에 해당한다. 이 셀들의 벡터값은 원래의 셀 q 와 직접연결된 이웃셀들에 의해 결정된다. (그림 8)의 (b)는 q 에 대치되는 특징지도가 2×2 인 경우를 보여주고 있다. 이 경우 새로 생성된 셀 c 의 벡터값은 $\frac{n_1+n_2+2\times q}{4}$ 이다.

형상지도가 대치되고 나면 원래의 q 와 이웃들과의 연결은 없어지고 새로운 구조의 신경망이 구성된다.

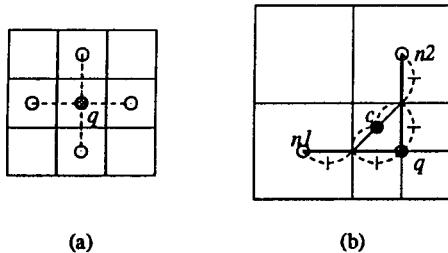


그림 8: 대치 행상지도의 벡터값 결정

3.4 셀 제거

지금까지는 제안된 신경망의 대치를 통해 네트워크 구조를 확장시켰다. 각 셀들은 영역을 대표하면서 초기 n -차원의 구조를 계속 유지하게 된다. 또한 각 셀들은 직접, 간접으로 모두 연결되어 있다. 그러나 만약 연결되어 있지 않은 영역이 있다면 그곳에는 문제가 발생한다. $P(X)$ 가 0이거나 edge가 매우 긴 경우, \Re^n 에 대한 진정한 위상보존 사상이 이루어진다고 볼 수 없기 때문이다.

이에 대한 해결책은 네트워크 구조에서 연결되어 있지 않은 셀을 찾아 지우는 것이다. $P(X)$ 가 0인 셀을 찾아야겠지만, $P(X)$ 가 주어지지 않으므로 $P(X)$ 에 근사하는 입력벡터를 계산함으로써 결정한다. 이를 위한 일반적인 방법은 오랫동안 승자벡터로 선택되지 않은 셀이 $P(X)$ 가 0일 확률이 높으므로 이 셀을 제거한다. 이는 현재 학습된 네트워크에서 각 셀이 승자벡터로 선택된 수를 계산함으로써 알 수 있다. 이 값은 매 주기마다 네트워크에 대해 계산되고 승자벡터로 적게 선택된 셀을 찾아 연결된 모든 edge들과 함께 제거한다. (그림 9)는 그러한 과정을 보여주고 있다.

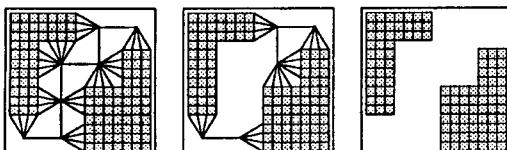


그림 9: 셀 제거

3.5 인식

구조적용이 끝나면 주어진 패턴의 분류에 적합한 네트워크의 구조 및 크기를 자동적으로 찾게된다. 입력패턴은 최종 신경망의 각 노드에 사상되면서 분류된다. 즉 가장 많은 출력을 갖는 패턴을 그 노드를 대표하는 패턴으로 선택한다.

IV. 한글 문자인식에의 적용 예

이제 앞에서 설명한 신경망이 어떻게 문자인식에 적용되는지 간단한 예와 함께 살펴보자. 여기에서 신경망은 2×2 의 행상지도로부터 시작하고 대치 행상지도도 2×2 를 사용하며, ‘인’, ‘공’, ‘지’, ‘능’이라는 4개의 부류를 분류한다고 가정하자. (그림 10)은 이 4개

의 부류에 대해 신경망이 적용되어가는 과정을 보여준다. 첫번째 그림에서 동그라미가 표시된 셀들은 행상지도가 대치되어야 할 셀들로 각각 {‘인’, ‘지’}와 {‘공’, ‘능’}의 클래스가 포함되어 있다. 여러 개의 클래스를 포함한 셀들은 행상지도 대치에 의해 구조가 적용되어 이를 통해 구성된 클래스가 새로운 네트워크에 대해 다시 학습을 수행한다. 이런 방법으로 하나의 셀에 서로 다른 문자가 포함되면 행상지도를 대치함으로써 상세분류의 효과를 얻는다.

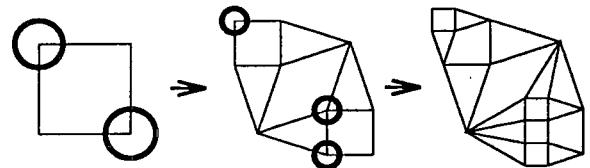


그림 10: 적용 예(1) : 행상지도의 대치

다음으로 셀제거가 한글인식 네트워크의 구조에 어떠한 영향을 주는지 살펴보자. (그림 11)은 셀의 제거에 의해 이 문제가 해결되는 과정을 보여준다. 여기에서 X 표 셀들은 승자노드로 선택된 수가 0인 노드들로 {‘인’, ‘지’}와 {‘공’, ‘능’}의 경계선에 해당된다. 두 번째 그림에서는 이러한 셀들을 제거함으로써 네트워크가 두개로 나뉘어짐을 보여준다. 나뉘어진 상속의 네트워크에서 세 개의 셀을 제거함으로써 {‘인’}과 {‘지’}를 각각 인식하는 부문네트워크가 생성된다.

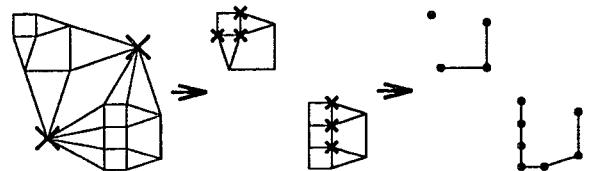


그림 11: 적용 예(2) : 셀 제거

(그림 12)는 패턴 공간 상에서 패턴의 분포를 분류한 것이다. 여기서 서로 다른 패턴이 포함되어 있는 영역({‘공’, ‘능’})은 그 영역에서 가장 많이 포함된 패턴({‘능’})을 대표 패턴으로 정한다.

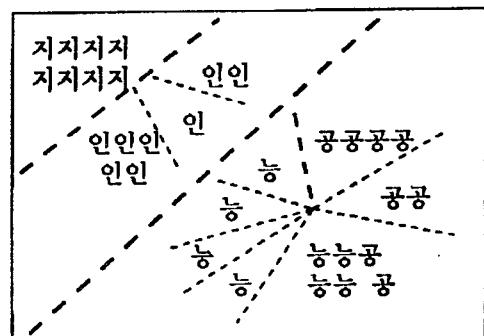


그림 12: 적용 예(3) : 인식

V. 실험 결과 및 토의

5.1 실험 결과

제안한 자기조직화 신경망은 SUN Sparc 10 Workstation 상에서 C 언어를 사용하여 구현하였다. 이 신경망의 기본 위상은 사각형이며, 8×8 의 2차원 형상지도에서 시작하여 2×2 의 대칭 형상지도로 확장되도록 하였다. 사용된 실험 데이터는 <표 1>과 같이 크기와 스캔 해상도가 다른 6 종류의 인쇄체 한글로 구성되었다. 실험 대상 문자로는 한글 완성형 코드 2350 자를 대상으로 하였다.

판트	명조체
크기	10, 11 points
스캔해상도	200, 300, 400 dpi

표 1: 실험 데이터

학습 데이터의 수집 방법은 HWP 편집기에서 작성한 각 한글 데이터를 레이저 프린터 LP 1220으로 출력한 후 이를 UMAX UC630 스캐너를 통해 입력하였고, 테스트 데이터는 UMAX VISTA-T630 스캐너를 통해 입력하였다. 수집한 각각의 한글 데이터는 선형 정규화 방법을 이용하여 (그림 13)과 같이 32×32 의 크기로 정규화한 다음 이로 부터 추출된 80 차원의 망 특징(mesh feature)[10]을 제안한 신경망의 입력벡터로 사용하였다.

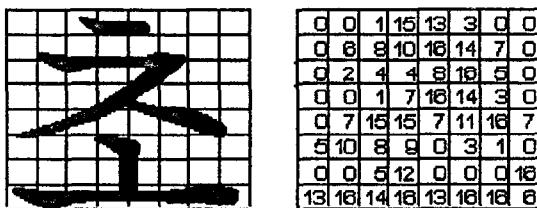


그림 13: 망 특징의 예

(그림 14)는 최종 학습된 네트워크의 일부분으로 전체 네트워크의 셀의 개수는 4347개였다. <표 2>는 각각의 데이터에 대한 인식률을 보여주고 있는데 평균적으로 97.40%의 인식률을 얻었다.

10 point	200 dpi	99.61%
	300 dpi	98.72%
	400 dpi	97.32%
11 point	200 dpi	97.27%
	300 dpi	96.25%
	400 dpi	95.20%

표 2: 실험 결과

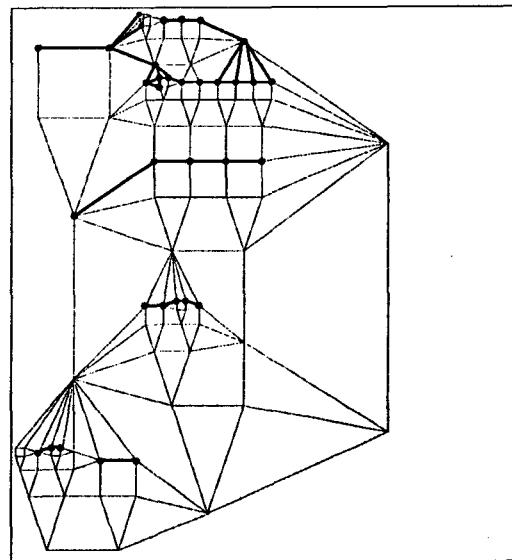


그림 14: 최종 네트워크의 일부분

으로 나눌 수 있는데, 수평모음과 수직모음의 혼동률(각각 43.56%, 51.48%)은 비슷하게 나타났고 복합모음의 혼동률(4.95%)은 상대적으로 낮았다.

제안된 신경망을 사용하였을 때는 대부분 같은 유형의 글자끼리 혼동을 일으킨다.(<표 3>) (그림 16)은 각 유형별 혼동률을 보여주는데, 특히 유형 4와 유형 5가 많은 혼동을 일으킨다. 또 다른 유형의 글자과 혼동을 일으키는 경우는 비교적 적었는데, 모두 유형 4와 유형 6의 글자로 다음과 같다.

- 월, 월
- 월, 월
- 꽝, 꽝

입력	출력						
	1	2	3	4	5	6	혼합
1	100						
2		100					
3			100				
4				98.14			1.86
5					100		
6						98.14	1.86

표 3: 유형별 혼동표(단위는 %)

5.2 결과 분석 및 토의

한글은 초성(Consonant : C1)-중성(Vowel : V)-종성(Consonant : C2)의 조합으로 이루어진다. (그림 15)는 제안한 신경망을 사용하였을 때 서로 구분되지 않아 발생하는 혼동율 혼동형태별로 보여준 것으로 중성에 의한 혼동이 가장 많음을 알 수 있다. 중성은 다시 그 형태에 따라 수직모음, 수평모음, 복합모음

VI. 결론

본 논문에서는 구조적용 자기조직화 신경망을 소개하고 이를 위한 학습 알고리즘을 제안하였다. 제안된 구조적용 자기조직화 신경망의 기본 개념은 기존의 SOFM에서 구조를 적용해

으로 변형시키면서 패턴공간을 분할하는 것이다. 고정된 구조에 적용 능력을 부여함으로써 패턴분류에 적합한 네트워크의 구조 및 크기를 자동으로 찾아내는 장점을 갖는다. 다중 크기, 다중 스펜 해상도의 한글 문자 인식 문제에 제안한 신경망을 적용한 결과 한글 문자인식에 적절한 신경망구조를 찾아낸을 볼 수 있다.

실험에 있어서 개선할 점으로는 학습에 있어서 보다 빠른 숫자유니트 선택을 통해 학습 시간을 줄이는 것이고, 서로 구분되지 않아 혼동을 일으키는 문자들을 구분하기 위한 학습 알고리즘의 보완이 요구된다. 여기서 구현한 구조적용 자기조직화 신경망을 보다 발전시키는 연구로서 다중 글자체의 글자를 인식할 수 있도록 확장하는 것이 필요하다.

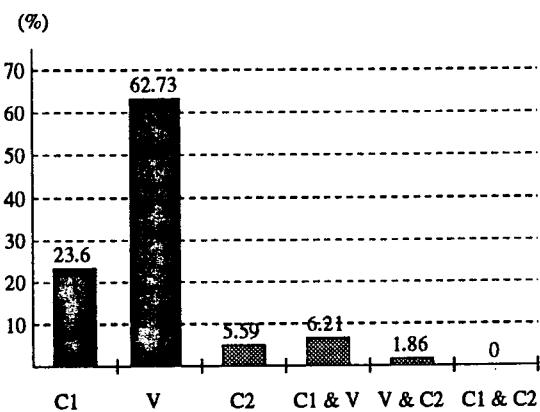


그림 15: 혼동형태별 혼동률

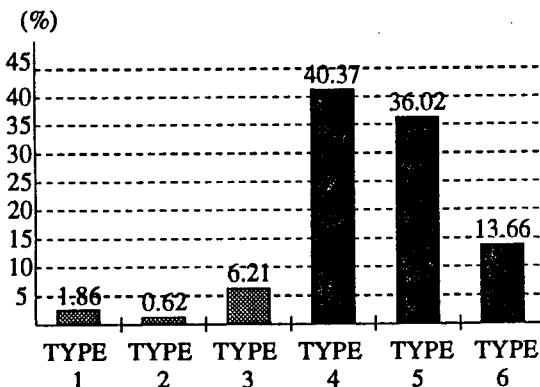


그림 16: 한글의 유형별 혼동률

a Two-Dimensional Feature Map", IJCNN, Vol. I, pp450-455, 1993.

- [2] B. Fritzke, "Supervised Learning with Growing Cell Structures", NIPS 6, pp255-262, 1993.
- [3] B. Fritzke, "Unsupervised Clustering with Growing Cell Structures, IJCNN, Vol. II, pp531-536, 1991.
- [4] B. Fritzke, "Let it grow - Self-Organizing feature maps with problem dependent cell structure", Artificial Neural Networks 1, pp403-408, 1991.
- [5] J. Koh, M. Suk and S. M. Bhandarkar, "A Multilayer Self-Organizing Feature Map for Range Image Segmentation", Neural Network, Vol. 8, No. 3, pp67-86, 1995.
- [6] T. Kohonen, "The Self-Organizing Map", Proceedings of the IEEE, pp1464-1480, 1990.
- [7] 권재욱, 조성배, 김진형, "신경망 기법을 이용한 다중 크기 및 다중활자체 한글문서의 인식", 제3회 영상 처리 및 이해에 관한 워크샵 발표 논문집, pp129-136, 1991
- [8] 김우태 외, "인쇄체 한글 문자인식을 위한 특징성능의 비교", 한국정보과학회 논문지, 제30권 8호, pp1103-1111, 1993.
- [9] 이경미, 조성배, 이일병, "패턴분류를 위한 구조적용 자기조직화 신경망", 한국정보과학회 추계 학술 대회 발표 논문집, 서울, 1995년 10월(예정).
- [10] 조성배, 김진형, "인쇄체 한글문자의 인식을 위한 계층적 신경망", 한국정보과학회 논문지, 제17권 5호, pp306-315, 1990.

참고 문헌

- [1] J. Blackmore and R. Miikkulainen, "Incremental Grid Growing: Encoding High-Dimensional Structure into