

Unification of Kohonen Neural Network with the Branch-and-Bound Algorithm on Pattern Clustering

Chang-Mok Park and Gi-Nam Wang

Department of Industrial Engineering

Ajou University, Suwon 441-749, Korea

(Fax) 0331-214-0942 (Tel) 0331-219-2429

(Email Add: gnwang@madang.ajou.ac.kr)

Abstract.

Unification of Kohonen Neural Network with the branch-and-bound algorithm is presented for clustering large set of pattern. A two-step identification procedure is developed for pattern recognition : coarse and fine identification. The coarse identification is designed for finding a class of object while the fine identification procedure is to identify a specific object. The Branch-and-Bound search technique is employed for designing coarse neural network learning paradigm. We have explored the application of Kohonen Neural Network on coarse identification and presented the very promising results.

I. Introduction

자동 인식은 로보트 제어, 부품 인식 등과 같은 자동 생산 시스템과 우편 번호 인식 시스템과 같은 분야에서 다양하게 적용되고 있다. 이런 적용과정에서 몇 백 혹은 몇 천 개의 패턴을 인식하기 위해서 본 연구에서는 신경망에 의한 2단계 인식을 기반으로 하는 물체 인식 방법을 제안한다. 제안된 방법은 패턴의 종류가 매우 많은 경우에 있어 먼저 전체 패턴의 종류를 유사성에 의하여 소 그룹으로 분할하고 해당 그룹을 인식하는 Coarse identification Neural Network 과 그룹 내의 해당 패턴을 인식하는 Fine Identification Neural Network 으로 구성되어 있다. 먼저 전체 모든 종류의 패턴을 두개의 그룹으로 분할 시켜 각 그룹의 해당 Reference 패턴들에 대해서 2진화 그룹을 계속 계층적으로 구성하여 가고 계층적 2진화 그룹을 형성한 뒤, On-Line 상에서 입력된 패턴에 대한 해당 소 그룹을 찾아가는 방법으로는 미리 형성된 계층적 2진화 그룹을 Branch and Bound Search 방법을 사용하여 찾아 가는 방법을 사용하였다.

II Literature Review and Background Information

(1) 통계적 접근 방법

Correlation(상관관계)는 대부분의 패턴 인식에서 잘 사용되어 진다. 하지만, 이상적인 상황에서 상관관계를 이용한 패턴 인식이 효율적이지만, 상관관계는 패턴의 왜곡 현상에 매우 민감하다. 특히 패턴의 회전, 위치 변동 등의 영향 때문에 인식률을 많이 저하시킨다. 그런 이유로 특성 추출 단계에서, 위치 변동, 크기, 회전 등에 덜 영향을 받는 방법이 연구 되어지고 있다.

(2) 신경망에 의한 접근 방법

신경망은 학습 과정이라는 것을 가지고 있으며, 각 군집에서 군집을 잘 표현해주는 패턴들을 통해서 학습을 하게 된다. 이러한 학습 과정을 통해 일반화(Generalization)와 특성화(Specialization) 과정이 수행되어

진다. 신경망에서는 많은 입력 정보들을 연속적으로 분류하여 특정 문제 영역에 대한 독특한 네트워크를 구조를 가지게 되는데 몇 가지 예를 고찰해보면 다음과 같다. Fukushima 은 필기체 인식을 위해서 Neocognitron model [1]을 제안하였다. 네오코그니트론은 많은 셀(Cell)들로 이루어진 층들이 여러개 모여 구성된 계층적 다층 네트워크이다. Carpenter and Grossberg 은 ART(Adaptive Resonance Theory)를 영문자 인식에 적용했다 [1]. ART 네트워크는 자동 학습 시스템(Autonomous learning system)의 구축에 적당하다. 그것은 입력 패턴을 자동적으로 분류하고 이미 알려진 패턴들을 즉시 회상할 수 있다. 최근에 적용도가 높은 인식 방법이 Rajavelu, Musavi and Shirvaike 에 의하여 개발되었다. 이들은 특성 추출에 Walsh Transformation 을 사용하였고, 인식을 위해서 Backpropagation Neural Network [1] 을 사용하였다. 이 방법으로 인식 속도와 정확도가 많이 향상되었다. 이러한 많은 신경망을 이용한 패턴 인식 접근 방법이 있지만, 아주 많은 양의 Pattern 일 경우 예를 들면 다양한 모양과 크기를 가진 몇천 가지 패턴, 중국 문자, 한국 문자 등을 효율적으로 정확하게 인식하기 위한 학습 방법과 분류 방법을 제시하는 것은 거의 없는 실정이다.

III. Proposed Methodology

전형적인 패턴 분류 알고리즘은 두개의 부분으로 나누어 질 수 있다 [2]. 첫번째로 입력 데이터는 전처리 과정을 통해서 특성이 추출 된다. 두 번째로 이 특성과 참고 특성들(reference features)과 비교하여 가장 근접한 패턴을 결정한다.

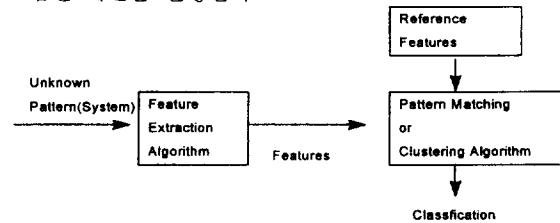


Figure 1. General Description of Pattern Classification

본 연구에서는 전처리 과정으로써 Walsh Transformation 을 사용한다. Walsh Transformation 을 사용한 이유는 Fourier Transformation이나 다른 전처리 과정에 비하여 상대적으로 계산속도가 빠르기 때문이다. 물론 Walsh Transformation에서도 Walsh Coefficient 의 수에 따라 계산 속도가 다르지만 다른 전처리 과정에 비하여 계산 속도의 감소를 기대할 수 있어 실제 온라인 적용에 장점이 있기 때문이다. 패턴 인식 과정은 우선 인식할 전체 패턴의 참고 특성(reference feature)을 획득한 후 유사성에 따라 분할하여 소 그룹을 형성하는 과정이다. 소그룹 형성 과정은 참고 특성들을 각각의

부분 그룹으로 분류하여 계층적으로 이진화된 그룹을 계속 형성하여 나가는 방법이다. 이와 같이 학습된 후 새로운 패턴이 들어올 경우 어떤 부분 그룹인가를 Branch and Bound Neural Network 를 이용하여 찾은 후 찾은 그룹 내에서 정확한 패턴을 인식한다. 본 연구에서는 부분 그룹으로 나누는 방법에 중점을 두었다. 왜냐하면, 많은 패턴들이 작은 부분으로 나누어 지면, 그 그룹내에서 정확한 패턴을 찾는 것은 기존의 Neural Network Model(예를 들면 Backpropagation Model)을 이용하면 충분히 만족한 결과를 얻을 수 있다고 사료 되기 때문이다.

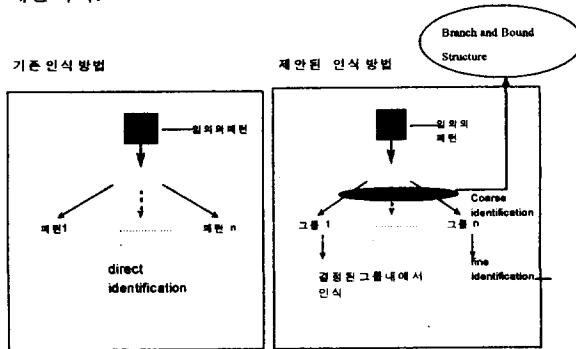


Figure 2 인식방법과 제안검사방법의 관계

1. Preprocessing for Feature Extraction

전처리 과정(Preprocessing)은 패턴의 형상을 묘사하기 위한 의미 있는 특성을 추출하는 과정이다. 이는 의미 있는 특성을 추출하여 저장 공간을 절약하게 하며, 계산량을 줄여 주게 한다. 사용된 Walsh Transformation 은 구분적 상수 함수로서 통신, 신호 처리, 시스템 분석, 제어 등에 사용되어 진다. 다른 변화 기술과 비교하면, Walsh 변환은 계산 시간을 줄일 수 있다.

$$w(u) = \frac{1}{N} \sum_{x=0}^{N-1} f(x) \prod_{i=0}^{n-1} (-1)^{b_i x + u_i}$$

다음은 웨이트의 $f(x)$ 의 오른쪽 식의 값을 표현한 것이다.

$w(0) \rightarrow$	1	1	1	1	1	1	1
$w(1) \rightarrow$	1	1	1	-1	-1	-1	-1
$w(2) \rightarrow$	1	1	-1	-1	1	1	-1
$w(3) \rightarrow$	1	1	-1	-1	-1	-1	1
$w(4) \rightarrow$	1	-1	1	-1	1	-1	-1
$w(5) \rightarrow$	1	-1	1	-1	-1	1	-1
$w(6) \rightarrow$	1	-1	-1	1	1	-1	1
$w(7) \rightarrow$	1	-1	-1	1	-1	1	-1

Figure 3. Sequence-Ordered Walsh Function to N=8

$f(x)$: 어떤 신호의 정도를 나타낸다. 예를 들면 영상에서 영역 x 에서의 Grayscale 값을 나타내는 것이다.

$b_k(z)$: z 를 이진수로 나타냈을 때 k 번째의 수를 나타낸다.

패턴(예를 들면 영상, 전기적 신호 등)들의 분포 정도는 $W(u)$ 값에 나타나고, $W(0)$ 일 경우 전체 영역을 8개의 구간으로 나누어 8개의 영역간의 평균을 나타내게 되는 것이고, $W(1)$ 은 8개의 영역에서 처음 4개 구간과 나중 4개 구간의 변화 정도를 나타내며, 이와 같이 u 값이 증가할수록 세밀한 변화 정도를 측정하게 된다. 계산 시간은 Walsh 함수의 수에 따라 결정되며, 수가 증가할수록 표현의 정밀도가 증가한다. 그러므로

패턴의 복잡도에 따라 Walsh 변환의 Coefficient 를 증가 시키게 된다. 본 연구에서도 각 부분 그룹 안의 패턴들의 유사성이 클 경우 Coefficient 를 증가 시켜주어야 한다.

2. Branch and Bound Learning Scheme

본 연구에서 사용된 Branch and Bound Neural Network 는 Kohonen Network 를 기반으로 하며 계층적인 이진화 나무 구조를 갖고 전체의 많은 패턴을 유사성에 따라 소 그룹으로 형성하여 소그룹의 대표 Vector 를 찾는 과정이다.

2.1 Kohonen Network

본 연구에서 Kohonen 신경망을 근간으로 하고 있는데 일반적으로 Kohonen 신경 망은 2 개의 층으로 이루어져 있다.[2] 네트워크의 첫번째 층은 입력 층이고 두 번째 층은 경쟁 층인데 2 차원의 격자로 되어있다. 그럼 4에서처럼 Y 가 경쟁 층이고 X 가 입력 층이다. 층 내의 뉴런의 연결 강도 벡터는 임의 값을 가지면서 적합하게 초기화되어야 한다. 또 연결 강도 벡터와 입력 벡터가 통상 0에서 1 사이의 정규화된(normalized)값을 사용한다.

Kohonen의 학습에서 각 뉴런은 연결 강도 벡터와 입력 벡터가 얼마나 가까운가를 계산한다. 그리고 가장 가까운 뉴런이 승리하게 되고, 승자와 그 이웃들만이 그들이 연결 강도를 조정할 수 있다. 본 연구에서의 Kohonen은 2 개의 경쟁 뉴런을 가지고 있으므로 승자만이 자신의 연결 강도를 조정하게 된다.

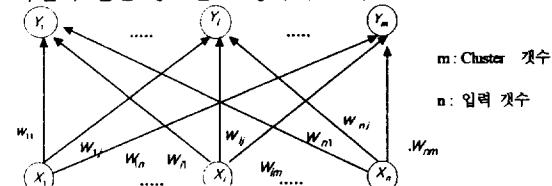


Figure 4. Kohonen self-organizing map

Figure 4 은 Kohonen 신경 망을 나타낸 그림으로 Hamming Net이나 Hopfield Net 이 Binary 입력인데 반해 연속적인 실수의 값을 입력으로 한다. 또한 자율적인 신경 망으로 BP(Backpropagation)신경 망과 달리 목표치가 없이 입력과 가장 근사한 weight 가 자율적으로 수정하도록 하고 연속적으로 값이 입력되므로 실시간 학습 처리가 가능하다.

Figure 4 처럼 연속되는 n 개의 입력에 대해 m 개의 cluster 수로 나누어짐을 보여 주고 있고 이러한 연속적으로 입력되는 신호의 반복적인 계산으로 clustering 이 수행되면서 원하는 cluster 수를 결정한다. 일반적으로 먼저 입력되는 신호 n 개에 대한 연속적인 수집을 하고 초기 weight, Learning rate, 임의의 Cluster 수를 결정한다. 하지만, 본 연구에서는 Branch and Bound 구조에서 각 노드에는 cluster 갯수가 두개인 Kohonen 신경 망이 존재하므로 cluster의 갯수를 결정할 필요가 없고 결국 마지막의 부분 그룹의 갯수는 Branch and Bound 알고리즘에 의해 결정되는 것이다.

Kohonen 신경망에서는 다음과 같은 방법으로 각 Cluster의 중심벡터와 입력벡터간의 거리(D)를 구한다.

$$D(j) = \sum_i (w_{ij} - x_{ij})^2$$

D 가 결정이 되면 D 가 최소가 되는 node j 의

weight 를 다음 식과 같이 수정한다.

$$w_{ij}(\text{new}) = w_{ij}(\text{old}) + \alpha \cdot [x_i - w_{ij}(\text{old})]$$

승자 연결 강도 벡터는 기하학적으로 입력 패턴에 가장 가깝다. 코호넨의 학습은 단순히 연결 강도 벡터와 입력 패턴 벡터의 차이를 구한 다음 그것의 일정한 비율을 원래의 연결 강도 벡터에 더하는 것이다.

이와 같이 반복적으로 weight 를 수정하여 최종적인 weight 가 결정되면 이때의 weight 를 적용하여 각 패턴의 cluster 를 결정한다. 여기서 α 는 Learning rate 이고 반복 학습을 하면서 조금씩 줄여 나간다. 이와같이 반복적으로 weight 를 수정하여 최종적인 weight 가 결정되면 이때의 cluster 를 결정하고 다음 단계에서의 구조를 결정하는 분산 변수, 중심 벡터, node 수를 결정한다. 여기서 cluster 의 수의 증가는 곧 Node 수의 증가를 의미하고 cluster 내의 분산을 감소시키며 학습할 연결부가 많아져 복잡한 입력 신호에 적합한 장점이 있지만 학습 시간이 길어지는 단점을 유발한다. 따라서 일반적인 Kohonen 모델에서는 cluster 수 m 을 결정하는 것은 상당히 중요한 의미를 갖는다. 그리고 weight 를 수정해나가는데 있어서 Cluster 의 갯수가 2 이상이면, weight 를 수정 할 때 어느 정도 범위 안의 weights 를 수정해야 하는 것을 결정해야 한다. 하지만, 본 연구에서는 cluster 갯수가 2 이므로 Neighborhood parameter(R) 은 0 이 되고, 어느 cluster 가 승자인지 결정되면, 승자의 weight 를 수정하면 되는 것이다.

2.2 Branch and Bound Method(분지 한계법)과 Kohonen Neural Network 의 접목

분지 한계법은 Figure 5 처럼 원 영역에서 두 갈래의 영역으로 나누고 각 영역을 원 영역으로 하여 다시 두 갈래의 영역으로 나누면서 한계 전략 즉 어떤 상황에서 분기를 멈출 것 인가를 참고로 분기를 멈추고 n 개의 해 영역으로 문제를 결정짓는 것으로 대략 요약할 수 있다. [5]

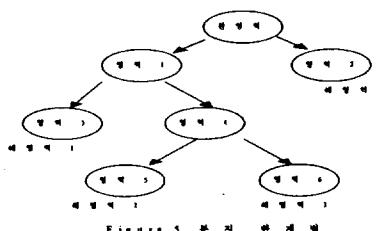


Figure 5 분지 한계법

위와 같은 분지 한계 법을 패턴인식의 Coarse Identification 에 응용하기 위해서 다음과 같은 형태로 구성한다.

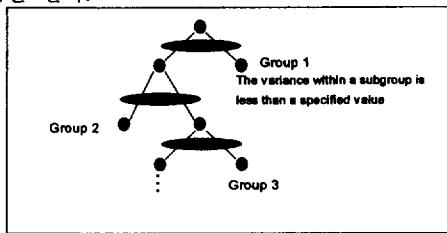


Figure 6. Hierarchical clustering(unsupervised Kohonen learning algorithm)

각 계층에 존재하는 Kohonen 모델은 cluster 갯수가 2 이므로 다음과 같은 구조를 가질 것이다.

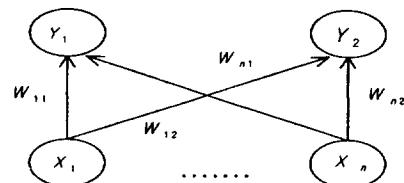


Figure 7 각 계층의 Kohonen 구조 (cluster 갯수 2)

Kohonen 모델에서는 초기 Weight 를 만들어 준 후 학습을 하게 되는데, 일반적으로 패턴들중 Euclidean Distance 가 큰 쌍들을 초기 Weight 로 구성하여, 학습 효율을 좋게하는 방법이 쓰여지고 있다. 본 분지한계법에 사용된 Kohonen 모델에서는 Euclidean Distance 가 먼 두개의 입력 벡터를 랜덤하게 추출하여 초기 Weight 로 해준 후 학습을 하게 된다.

이렇게 하여 각 계층에서 Kohonen 학습 방법에 따라 안정된 Weight Vector 가 얻어지고 이 Weight 들이 계층적 구조의 각 node 에 저장 되며, 각 부분 그룹의 분산이 필요한 만큼 작아지면, 더 이상의 분기를 하지 않고, 안정된 분기 구조와 Weight vector 들을 가진 계층적 구조가 형성되고 이를 이용해 새로운 입력 패턴들에 대해서 어느 분류에 속하는 가를 결정하게 된다.

위와 같은 분기 탐색 법을 사용하면, 각 계층에서 두개의 선택 영역만이 존재하므로 잘못된 분류를 할 위험을 줄일 수 있다.

III. Proposed Algorithm

단계 1: Walsh Transformation 을 이용하여 참고 패턴들의 특성을 추출한다.

단계 2 : Branch and Bound Network 을 훈련 시킨다.

a. root node 의 전체 패턴을 두개의 부분 그룹 으로 나눈다. 이때의 Weight 을 저장한다.

b. 두 개의 부분 그룹 내에서 그룹 내의 분산 값을 계산한다.

c. 두개의 그룹 내에서 그룹 내의 분산 값이 특정 값보다 작아 졌는지 Test 한다.

d. 두개의 그룹 내의 분산 값이 특정 값보다 클 경우 새로운 rootnode 를 만들고 step a 로 간다. 그룹 내의 분산 값이 특정 값보다 작은 쪽은 분기를 멈춘다.

e. 각 node 에 안정된 Weight vector 가 구해진다

단계 3 : 각각의 소 그룹 내에서 Fine Identification 을 위해서 Backpropagation 을 학습한다.

단계 4 : (Recall 단계) 패턴 분류를 하기 위한 대상 패턴들을 분류

참고로 Branch and Bound Neural Network 을 위해서 각 node 에는 다음과 같은 정보들이 저장되게 된다.

struct nodetype

{

float EachVector[CLU][MAX_ROW][MAX_COL]; 뿌리패턴들 중 Cluster 0(왼쪽) 과 Cluster 1(오른쪽) 에 해당하는 Vector 들.

float Weight[CLU][MAX_COL]; 현 노드의 안정된 Weight

float Variance[CLU]; Cluster 0 과 Cluster 1 각각의 분산

int quantity/CLU; Cluster 0 과 Cluster 1 각각의 폐턴 갯수.

int left; Cluster 0 이 다시 tree 를 형성하는 노드 포인터

int right; Cluster 1 이 다시 tree 를 형성하는 노드 포인터
};

IV. Experimental result and system performance

본 연구의 알고리즘을 구현하기 위해서 만든 프로그램을 사용하여, 32 개의 폐턴(영상)들에 대해서 실험 과정을 설명하고, 실제 많은 폐턴들을 만들어 내서(640 개) Branch and Bound Neural Network 를 학습 시킨 후 noise 를 5%, 10%, 20% 증가시킨 폐턴을 다시 입력 했을 때에 얼마나 정확히 부분 그룹을 찾아 나가는 가의 성능을 평가한다. Fine Identification 에서는 각 소 그룹에 5 ~ 10 정도의 폐턴이 구성되어지므로 기존의 Backpropagation 으로 정확히 제품 유형(폐턴)을 찾을 수 있기 때문에 본 실험에서는 생략했다. 실험에 사용된 폐턴들은 각각 픽셀에 0 혹은 255 값을 갖는 이진 영상을 사용하였고, 그 모양은 볼트 모양으로 하였다.

1. Branch and Bound Neural Network 을 위하여 사용된 프로그램과 실행 예

실험에 사용된 영상들은 다음과 같은 영상들이다.

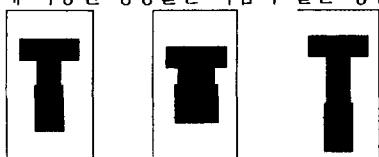


Figure 11. 실험에 사용된 영상 예

결과를 종합하여 그림으로 나타내면 다음과 같다.

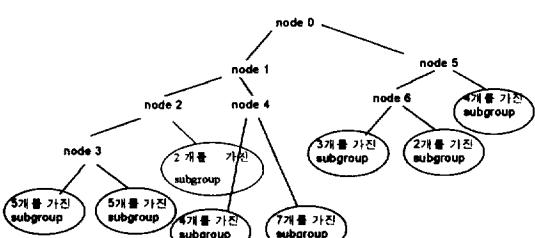


Figure 13. 참고 폐턴의 분류 결과

이 결과에서 32 개의 폐턴들은 Branch and Bound learning mechanism 을 이용해서 각 그룹의 분산이 0.02 이하인 7 개의 subgroup 으로 나누어졌다.

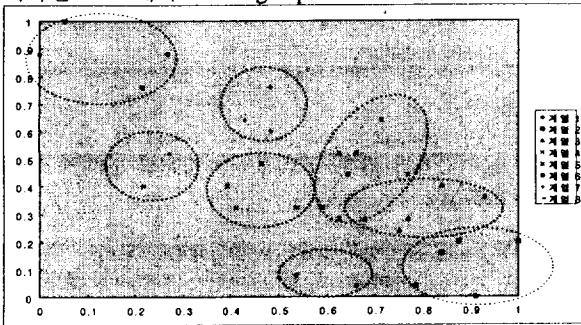


Figure 14. 32 개의 폐턴의 분류 모습

위 그림은 32 개의 폐턴들이 어떤 형태로 분류되었는

가를 2 차원 그래프 상에서 보여 준다. X 축은 Nomalization 된 W(0) 의 값이 되고, Y 축은 마찬가지로 0에서 1 구간의 값으로 축소된 W(1) 의 값을 나타내고 있다.

이제 실제 640 개의 영상을 학습 시킨 후 노이즈를 첨가한 똑같은 영상들을 분류하여 그 인식율을 살펴보자. Noise 를 첨가한 영상의 모습은 다음과 같다.



Figure 15. Noise 를 첨가한 영상의 예

노이즈없는 이러한 640 개의 영상을 학습한 후, 똑같은 영상에 노이즈를 첨가하여 폐턴 분류를 한 결과 98%의 인식율을 보였다. 영상이 많은 관계로 Walsh 변환 계수는 16 으로 늘었다.

위와 같이 노이즈를 5% 증가시킨 후 인식율은 98 ~ 99%를 보였다. 마찬가지로 노이즈를 15%, 20% 주어 인식율을 테스트 한 결과 15% 인 경우 인식율은 98%였고, 노이즈가 20% 인 경우는 인식율이 95%였다.

V. Conclusion

본 연구에서는 두 가지 단계를 가지고 있는 인식 방법(Coarse Identification and Fine Identification)에서 첫 번째 단계인 Coarse Identification 을 위한 효율적인 분류 방법을 제시하였다. 이 분류 방법에는 Kohonen Neural Network Model 을 근간으로 하여 Branch and Bound Algorithm 를 접목하여, 자동으로 Cluster 갯수를 결정하고, 분류에 있어서의 오류를 줄일 수 있는 모델을 제시하였다.

그러나 전처리 과정에서 Walsh Transformation 의 계수를 결정하는 것은 아직까지 경험적인 방법의 수준을 벗어나지 못하고 있고, Branch and Bound 방법을 사용하는데 있어서, 한계 전략인 한계 분산을 결정하는 것도 경험적인 방법에 의할 수 밖에 없었다. 그러므로 전체의 분산과 각 부분 그룹의 적당한 폐턴 수를 고려한 한계 분산을 결정하는 단계가 연구되어야 될 과제이다.

References

- [1] 김대수 “신경망 이론과 응용(I)”, 하이테크 정보, 1993
- [2] Laurene Fausett, “Fundamentals of Neural Networks”, PRENTICE HALL, 1994
- [3] Rafael C. Gonzales & Richard E. Woods “Digital Image Processing”, Addison-Wesley Publishing Company, 1992.
- [4] 박선호 “Turbo C 수치 해석”, 영진출판사, 1993.
- [5] Richard P. Lippmann, An Introduction to Computing with Neural Nets, IEEE ASSP Magazine April (1987).