

스펙트럴분석 및 복합 유전자-뉴로-퍼지망을 이용한
이동, 회전 및 크기 변형에 무관한 패턴인식
(Translation, Rotation and Scale Invariant Pattern Recognition
using Spectral Analysis
and a Hybrid Genetic-Neural-Fuzzy Networks)

이상경 , 장동식

고려대학교 산업공학과

Abstraction

This paper proposes a method for pattern recognition using spectral analysis and a hybrid genetic-neural-fuzzy networks. The feature vectors using spectral analysis on contour sequences of 2-D images are extracted, and the vectors are not effected by translation, rotation and scale variance. A combined model using the advantages of conventional method is proposed, those are supervised learning BP, global searching genetic algorithm, and unsupervised learning fuzzy c-method.

The proposed method is applied to 10 aircraft recognition to confirm the performance of the method. The experimental results show that the proposed method is better accuracy than conventional method using BP or fuzzy c-method, and learning speed is enhanced.

1. 서론

정보화 시대에 살고 있는 우리들은 방대한 정보의 범람 속에서 외부로부터 끊임없이 정보를 받아들이고 이를 처리하여 대처해 가면서 생활을 영위한다. 외부로부터의 정보는 인간의 오각인 시각, 청각, 촉각, 미각, 후각이라 불리는 감각기관들을 통해 받아들여지며, 이는 대뇌로 전달되어 처리된다. 이와 같이 외부정보를 두뇌에서 처리하는 과정을 패턴인식(pattern recognition)이라 한다. 패턴은 사람이 인식하려는 정보를 물리적으로 표현한 대상물로 정의할 수 있으며, 인식(recognition)은 대상물의 존재를 아는 인지(cognition)의 과정에서 한 걸음 더 나아가 구체적인 의미나 정보내용을 판정하는 과정을 의미한다. 그러나, 보통 패턴인식이라 할 때 컴퓨터를 중심으로 한 기계에 의한 자동인식을 가리키며, 대상으로 하는 감각기관도 시각과 청각을 지칭하는 경우가 일반적이다[1][2].

패턴인식 분야는 문자인식, 음성인식, 영상인식으로 크게 나눌 수 있는데, 본 연구에서는 영상인식을 대상으로 한다. 영상인식 대상은 크게 2차원 영상과 3차원 영상으로 나누어 볼 수 있는데, 본 연구는 2차원 영상을 대상으로 한다. 2차원 영상인식의 응용분야는 화면영상이 모두 대상이 될 수 있으며, 사진, 도면, 현미경, X-ray화상, 원격감지 데이터, 지문인식과, 물체표면 검사, 항공사진 자동인식, 화폐인식등의 광범위한 분야를 가지고 있다[2]-[4].

일반적인 영상 패턴인식의 절차는 대상물체에 대해 카메라, 스캐너 등을 이용하여 관측데이터를 획득한 후, 획득된 자료는 다소의 불필요한 정보를 가지고 있으므로 컴퓨터에서 인식을 위한 필요한 자료만을 얻어내는 전처리를 하고, 그 다음에 인식에 필요한 특징을 얻어내고, 이 특징을

비교하여 패턴을 식별하는 단계를 거치게 되는데 본 논문에서는 특징추출과 이를 이용한 식별 알고리즘에 대한 개선방안이 제시되었다[1].

패턴인식 시스템 구축시 고려할 사항으로는 첫째, 대상 영상이 회전, 크기변화, 평면이동 및 잡음 삽입시도 인식이 가능해야 한다. 둘째, 학습 및 인식속도가 빨라야 한다. 셋째, 많은 수의 모델을 다룰 수 있어야 한다. 넷째, 영상의 일부가 가려지거나 서로 겹쳐진 경우에도 인식이 가능해야 한다. 다섯째, 물체 형태의 복잡도에 상관없이 인식이 가능해야 한다. 물체가 다각형일 수도 있고, 원만한 곡선으로 되어 있을 수도 있으므로 이에 대한 종속성이 없어야 한다. 이러한 것들에 대한 연구가 꾸준히 진행되고 있으나 아직까지의 연구는 상기 조건을 모두 만족하는 완벽한 연구 결과는 없고, 부분적인 개선을 위한 연구가 계속 진행되고 있다[5]-[9].

대상 영상의 기하학적인 변형에 무관한 특징벡터를 추출하기 위해서 외곽선 정보를 이용하는 방법과 대상 영상 전체의 정보를 이용하는 방법이 시도되고 있다[6][10].

대상 영상 전체의 정보를 이용하는 방법은 복소-대수 사상과 푸리에 변환 혹은 2차신경망과 결합하는 방법[11][12], 크기와 회전 변형에 무관한 인식 문제가 3차의 문제임에 착안하여 3차의 신경망 모델을 이용하는 방법[8]등이 있다. 이 방법들의 장점은 경계선 정보가 필요 없다는 점이 있으나, 복소-대수 사상 방법은 물체의 중심이동에 취약한 단점이 있고, 3차 신경망을 이용하는 방법은 3차 신경망의 복잡도가 너무 높아서 현실적으로 구현하는데 많은 어려움이 있다.

외곽선의 특징에 의한 방법에는 곡률함수, 호의길이 s 와 내부각 ϕ 로 구성된 (ϕ, s) , 대상의 중심에서 외곽선까지의 거리 L 과 기준점과의 각도 ϕ 로 구성된 (L, ϕ) 를 이용하는 방법이 제시되었는데[13], 이는 지역적 특징을 이용하므로 부분 패턴으로부터도 분류인식을 할 수 있는 부분모양 인식기능이 있고, 패턴의 잡음이나 변형은 지역적으로 발생하므로 잡음이나 작은 변형에 강한 장점이 있다. 그러나 대표지역 특징의 선정 방법이 명확하지 않고 지역특징에 기반을 둔 인식 시스템은 계산량이 많아 긴 시간이 소요되는 등의 단점이 있다.

외곽선에 대한 퓨리어 기술자[14], 모멘트불변자[15]등을 이용한 방법은 외곽선 전체 특징이나 그에 상당하는 표현법에 기반을 둔 방법으로 학습에 필요한 패턴벡터의 길이가 적게 소요되므로 실용적인 분류인식기를 설계할 수 있는 장점이 있다. 따라서 본 연구에서는 이중 퓨리어 방법을 이용하는 스펙트럴 분석에 의한 특징 추출방안을 제안했다. 이 방법은 대상 영상에 대한 외곽선을 구하고, 외곽선을 원점으로 이동한 후, 정규화된 Magnitude Sequence 생성과 이에 대한 스펙트럼 분석으로 위치변화, 크기변화, 회전에 무에곡(invariant)특성을 갖는 벡터를 추출하는 것이다.

다음은, 패턴인식시스템의 분류기에 대한 연구로서, 이 분야는 최근 퍼지 및 신경망을 이용한 방법이 전통적인 통계적 방법의 한계성을 극복할 수 있어 많이 연구되고 있다.[16]-[20]

신경망을 학습에 이용할 때는 학습이나 분류의 능력을 높이기 위하여 입력층과 출력층사이에 한 개 이상의 은닉층을 갖는 다층구조를 혼히 사용한다. 이때 혼히 쓰이는 후향전파 알고리즘은 기울기 하강법에 해당하는 결정론적 알고리즘으로 국소 최적점을 만났을 때 이를 벗어나기 어렵다[16]. 이 문제를 해결하기 위한 지금까지의 연구의 중점은 학습파라메터를 변경시키거나 은닉층의 노드수를 변경하는 방법[17]이 주를 이루어 왔으며, 최근에 초기 연결가중치를 전역최적해 가까이 설정함으로써 전역 최적해로의 수렴 확률과 학습 속도를 동시에 개선하려는 유전 알고리즘에 의한 초기연결가중치의 최적화에 대한 연구가 보고되고 있다[18]. 그러나 이 방법은 유전자 알고리즘의 유전인자를 이진수로 표현하므로 역전파 알고리즘과 유전자 알고리즘을 반복 적용할 때 실수를 이진수로, 또 이진수를 실수로 변환시켜 하며, 이때 실수 값에서 소수점이하는 이진수로부터 정확히 알 수 없으므로 근사치를 사용해야 하며, 연결가중치가 작은 값에서 큰 폭의 값으로 변함에 따라 유전인자의 수를 변경시켜 주어야 하는 어려움이 발생한다. 그러므로 본 논문에서는 실수로된 유전인자를 사용하여 이러한 문제를 해결하는 하나의 방안을 제안하였다. 또한, 분류의 정확성을 향상시키기 위해 역전파 알고리즘을 이용하여 충분한 학습을 실시하여 신경망의 최종 연결가중치를 결정한 다음, 역전파 신경망의 출력값을 다시 비감독 군집화 기법인 퍼지 c-방법[19]의 입력값으로 사용하여 학습을 실시한 후, 패턴분류에 사용하는 복합 유전자-뉴로-퍼지망의 식별기를 구성하는 방안을 제안하였다.

본 논문의 구성은 2장에서는 인식에 필요한 불변특징벡터의 추출과정을 설명한다. 3장에서는 학습 및 분류에 사용한 복합 뉴로·퍼지망에 대한 설명, 4장은 실험 및 결과분석 부분으로 항공기 모형을 인식하는데 본 알고리듬을 적용하여 분석하였다. 5장은 결론 및 앞으로의 연구과제를 제시했다.

2. 스펙트럴 분석에 의한 불변특징벡터추출

불변특징벡터란 대상영상을 대표하는 유판선 상에서 정의되는 값으로 물체가 회전(rotation), 크기변화(scaling), 평면이동(translation)되어도 크기가 변하지 않는 벡터를 말한다. 본 논문에서 제시하는 불변특징벡터의 획득절차는 입력물체 영상에 대한 외곽선추출, 외곽선 중심을 원점으로 이동, 정규화된 Magnitude Sequence생성, 스펙트럼 분석의 과정을 거친다.

2.1 외곽선 추출

입력영상 전체에 대해 배경으로부터 물체를 분리하는 경계선을 찾음으로서 외곽선이 얻어지며, 외곽선이란 대상물(object)과 배경(background)의 gray level의 불연속성이 존재하는 경계면에서의 화소들의 집합을 뜻한다. 본 논문에서 사용한 외곽선 추출방법은 외곽선 추적(contour following)알고리듬이며[4] 이는 대상물 둘레에 있는 임의의 한 점을 출발점으로 하여 본래 명암(grey-level)영상에서 단계적으로 대상물의 외곽선을 찾아가는 방법이다. 외곽선 벡터(\vec{c})는 식(2-1)이 된다.

$$\vec{c} = [c(n)] , c(n) = a(n) + jb(n) , n = 0,1,2, \dots, N \quad (2-1)$$

2.2 외곽선 중심을 원점으로 이동

물체의 중심을 구하여 중심을 원점으로 이동하면 위치변동 무의존(translation invariant)한 특성을 얻는다. 외곽선의 중심($c_{g.c.}$)을 구하는 식은 식(2-2), 중심을 원점으로 이동한 벡터(\vec{c}') 식은 식(2-3)을 이용하면 된다.

$$c_{g.c.} = a_{g.c.} + jb_{g.c.}, a_{g.c.} = \frac{1}{N+1} \sum_{n=0}^N a(n), b_{g.c.} = \frac{1}{N+1} \sum_{n=0}^N b(n) \quad (2-2)$$

$$\vec{c}' = [c'(n)], c'(n) = c(n) - c_{g.c.}, n = 0,1,2, \dots, N \quad (2-3)$$

2.3 정규화된 Magnitude Sequence(NMS)의 생성

외곽선 상의 고정출발점(fixed starting point)에 기초해서 시계방향의 외곽선에 대한 magnitude(\vec{r})는 식 (2-4)에 의해 구해진다. 이러한 magnitude sequence를 Euclidean norm을 사용해서 정규화(normalize)하면 각 외곽선에 대해서 크기불변(scale invariant) power spectral density(PSD)를 얻어 진다[4]. 정규화된 magnitude sequence (\vec{r}')는 식(2-5)에 의해 계산된다.[20]

$$\vec{r} = [r(n)], r(n) = |c'(n)| = \sqrt{a'^2(n) + b'^2(n)}, n = 0,1,2, \dots, N \quad (2-4)$$

$$\vec{r}' = \frac{\vec{r}}{|\vec{r}|} = [\frac{r(n)}{|\vec{r}|}], |\vec{r}'| = \sqrt{r'^2(0) + r'^2(1) + r'^2(2) + \dots + r'^2(N)} \quad (2-5)$$

2.4 Power Spectral Density(PSD)의 생성

PSD의 결과는 외곽선의 회전불변(rotation invariant)값을 갖게 된다[4]. power spectrum 혹은 power spectral density는 단위 주파수(unit frequency interval)에 대한 크기(power)를 말하며 이것은 discrete Fourier transform(DFT)을 이용하여 구할 수 있다. \vec{r} 의 DFT는 식(2-6), power spectral estimate(periodogram) $P(k)$ 은 식 (2-7)에 의해 계산되고, 2-D에서 rotation이란 외곽선의 시작점의 이동을 의미하며, 만약 d points 이동한 Fourier coefficients($|F_d(k)|$)는 식 (2-8,9)에 의해 계산되며, 식 (2-9)와 같이 이동불변이다[20].

$$F(k) = \sum_{n=0}^N r'(n) \exp\left(-\frac{j2\pi kn}{N+1}\right), \quad -\frac{N}{2} \leq k \leq \frac{N}{2} \quad (2-6)$$

$$P(k) = \frac{1}{N+1} |F(k)|^2, \quad -\frac{N}{2} \leq k \leq \frac{N}{2} \quad (2-7)$$

$$F_d(k) = \exp\left(\frac{j2\pi kd}{N+1}\right) F(k), \quad -\frac{N}{2} \leq k \leq \frac{N}{2} \quad (2-8)$$

$$|F_d(k)| = |F(k)|, \quad -\frac{N}{2} \leq k \leq \frac{N}{2}$$

$$P_d(k) = \frac{1}{N+1} |F_d(k)|^2 = \frac{1}{N+1} |F(k)|^2 = P(k), \quad -\frac{N}{2} \leq k \leq \frac{N}{2} \quad (2-9)$$

3. 복합 유전자-뉴로-퍼지망 분류기

패턴인식 시스템의 분류기는 학습시 국소 최적점에 빠지지 않고 전역 최적점으로 수렴해야만 하며, 또한 수렴속도는 빠르고, 잡음(noise)에 강한 높은 인식률을 보장해야 하는 점에 착안하여 BN(Backpropagation Networks), FCM(Fuzzy C-Means), GA(Genetic Algorithm)의 단점을 보완하고, 장점을 살리는 복합망을 구성하여 분류기로 사용하였다.

3.1 패턴인식을 위한 역전파 신경망구조

신경회로망 모델은 병렬처리, 분산지식표현, 학습능력, 결합극복능력등의 특성을 가지고 있으므로 학습과 기억을 통하여 동적인 인식 시스템 구축이 가능하다[16]. 본 논문에서 사용한 다층 퍼셉트론이란 그림(3-1)과 같은 입력층과 출력층 사이에 중간층(은닉층)이 존재하는 퍼셉트론 구조이다.

일반적으로 다층퍼셉트론에 사용되는 역전파(Back Error Propagation : BEP)알고리즘의 학습 단계는 각 입력패턴에 대해 출력을 산출하는 전향적(forward)진행과, 기대출력과 실제출력사이에서 발생하는 오차를, 역으로 진행시켜 이 오차를 최소화하는 방향으로 층과 층사이의 연결강도(weight)를 변화, 조절하는 후향적(backward)진행으로 나눌 수 있다. 이에 사용된 오차 기준함수는 식(3-1)과 같다.

$$E = \sum_{p=1}^m \sum_{j=1}^n (t_{pj} - o_{pj})^2 \quad (3-1)$$

여기서 t 는 기대 출력값(target value)이고 o 는 실제 Sigmoid를 통한 출력 뉴런의 출력값을 나타낸다. P 는 학습 패턴을 나타내는데 m 개의 패턴이 존재함을 의미한다. 또 출력 뉴런의 개수는 n 개를 나타낸다.

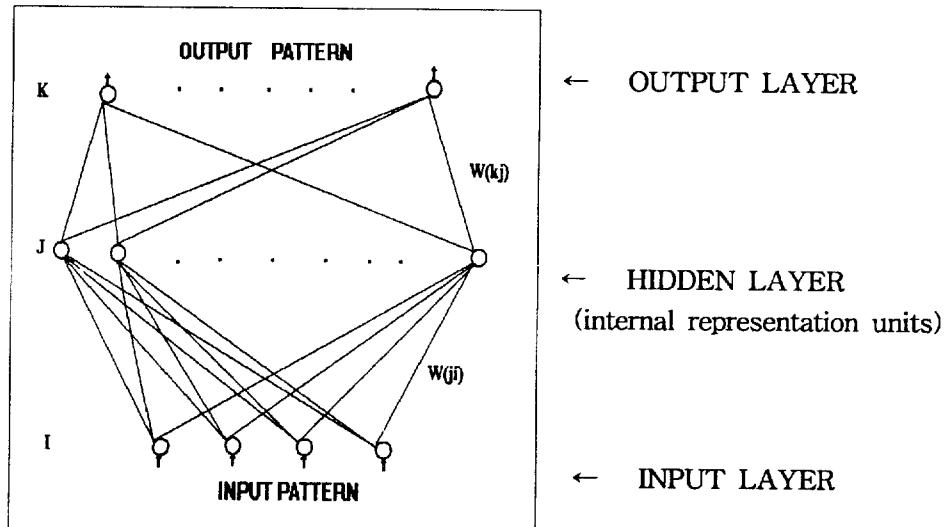


그림 3-1 다층퍼셉트론의 구조
fig.3-1 Structure of multi-layer perceptron

감독제어형 학습방식을 이용하고 있는 BEP학습 알고리즘은 정확한 패턴분류능력이 있어 패턴 인식에서 가장 많이 사용하는 신경회로망이지만, 이 알고리즘은 수렴에 실패하거나 지역최소점 (local minimum)에 빠질 가능성이 있고, 학습이 완료되기까지 많은 횟수의 반복 학습이 필요하여 긴 학습시간이 요구된다[16].

3.2 최적의 연결가중치 초기화를 위한 유전 알고리즘

유전 알고리즘은 1973년 John Holland에 의하여 처음으로 제안된 것으로서 자연계의 진화 과정을 지배하는 적자 생존 (survival of the fittest)의 원리 및 유전 정보의 교환에 의한 세대 교체의 원리를 이용한 적응 탐색 (adaptive search) 방법론에 속하는 발견적 해법으로 전역적인 탐색을 통해 최적화 문제 등을 해결할 수 있는 탐색방법의 하나이다. 유전 알고리즘은 평가함수, 유전 연산자 그리고 문제의 해를 표현하는 염색체로 구성되며, 이 염색체를 점진적으로 개선시켜 나감으로써 최적의 해를 얻게 된다[21].

유전 알고리즘을 이용한 초기 연결가중치의 최적화에 대한 지금까지의 연구는 염색체가 가지는 유전 인자의 값을 이진수로 처리한 후 인코딩(encoding)과정을 통해 실수값으로 변환하여 사용하였다[18][21]. 그러나 이 방법은 BEP알고리즘과 유전자 알고리즘을 반복 적용함에 있어 실수를 이진수로, 또 이진수를 실수로 변환시켜야 하는 번거로움이 있고, 또한 변환과정중 실수 값에서 소수점이하는 이진수 값으로 정확히 표현하는데 한계가 있어 근사치를 설정해야 하는 문제가 발생된다. 그러므로 본 논문에서는 실수로 된 유전인자가 사용되었다.

본 논문에서 사용한 연산자로서는 돌연변이(mutation), 교차(crossover) 그리고 역(inverse)이 사용되었다. 돌연변이는 초기모집단에 대한 평가를 실시한 후 적합도를 평가하여 일정한 상위 집단에 대한 연산을 다음의 식 (3-2)와 같이 실시하여 자손 문자열을 생성했다. 이 방법은 반복 횟수를 무한대로 할 때 최적값에 수렴함이 증명되었다[22].

$$X^{T+1} = X^T + N(0, \sigma) \quad (3-2)$$

여기서 $\begin{cases} X^{T+1} : \text{부모 (parent) 문자열 (연결가중치)} \\ X^T : \text{자손 (offspring) 문자열} \\ X : \text{탐색영역 (searchspace)} \\ N(0, \sigma) : \text{gaussian random number} \end{cases}$

역은 돌연 변이를 실시한 후 최적의 부모문자열에서 임의의 구간 내에 있는 가중치의 순서를 역으로 바꾸어서 새로운 문자열이 생성되었다. 교차는 두 가지 방법을 적용했는데 초기단계에서는 모집단의 염색체를 쌍으로 구성하여 염색체내에 있는 유전인자 정보의 일부를 서로 교환하여 새로운 염색체가 생성되었고, 연결가중치의 중간평가 단계에서는 돌연변이 및 역을 실시한 후 최적의 부모 문자열을 가지고 새로운 문자열이 식(3-3)과 같이 생성되었다.

$$X^{T+1} = X1^{T+1} \text{ crossover } X2^{T+1} \quad (3-3)$$

여기서 $X1^{T+1} = c_1 \cdot X^T + c_2 \cdot X_i^T$, $X2^{T+1} = c_1 \cdot X^T + c_2 \cdot X_i^T$, $c_1, c_2 \geq 0$, $c_1 + c_2 = 1$, $X_i = X$ 의 역

이상의 연산자를 사용하여 생성된 자손 문자열의 평가함수(MSE)를 계산하여 자손이 작으면 부모를 대신하고, 그렇지 않으면 부모 문자열이 그대로 남는다. 적용 절차는 다음과 같다.

[단계1] 모집단(Population)의 염색체(연결가중치)들을 초기화한다. 이 경우 연결가중치 수만큼의 실수를 할당하여 초기 값을 가진 모집단을 만든다.

[단계2] 모집단에 있는 각 염색체를 이용하여 적합도(MSE)를 평가한다.

[단계3] 현 모집단의 염색체들을 자기복제, 교차, 돌연변이, 역등을 적용시켜 새롭게 생성된 염색체들을 만든다.

[단계4] 새롭게 만들어진 염색체들을 평가하여 보다 높은 적합도를 가진 것들로 새로운 모집단들을 만든다.

[단계5] 임의로 정한 종료조건이 되었으면 프로그램이 끝나게 되고 그렇지 않은 경우에는 [단계3]으로 돌아가서 반복적인 작업을 계속한다.

3.3 신경망 출력패턴 분류를 위한 퍼지 클러스터링

최근 퍼지 집합이론이 데이터 취득(data acquisition), 특징량 추출(feature extraction), 패턴분류(pattern classification)등으로 구성되는 일반적인 패턴 분류체계에 존재하는 여러 불확실성들을 효과적으로 처리할 수 있고, 빠르게 수렴하는 장점 때문에 많이 사용된다.

패턴 분류를 위한 클러스터링 방법에는 계층적인 방법, 그래프를 이용하는 방법, 목적함수를 이용하는 방법[23]이 있는데, 목적함수를 이용하는 방법(objective function method)이 클러스터링 범주화의 가장 정밀한 정형화 방법을 제시하므로 본 논문에서 이용되었다. 이 알고리즘은 유사척도(similarity measure)로서 특정 내적 노음자(inner product norm metric)를 사용하여 정의된 목적함수가 근사적 최소 값이 되도록 퍼지분할 U 와 클러스터의 중심값(도는 원형) V를 반복계산법에 의해 구하는 최적화 퍼지 클러스터링 알고리즘으로써 최소화되는 목적함수 (또는 퍼지 c-means functional)는 식(3-4)와 같다[24].

$$\text{Min } z(U, v) = \sum_{i=1}^c \sum_{k=1}^n (\mu_{ik})^m \|x_k - v_i\|^2, \quad v_i = \frac{1}{\sum_{k=1}^n \mu_{ik}} \sum_{k=1}^n (\mu_{ik})^m x_k, \quad m > 1 \quad (3-4)$$

여기서 $X = \{x_1, \dots, x_n\}$ 는 임의의 유한 집합이고, V_{cn} 은 $c \times n$ 행렬 집합이며 ($2 \leq c < n$), v_i 는 멤버십에 의한 x_k 의 m -가중치 평균이다. 큰 멤버십을 가진 x_k 는 작은 멤버십을 가진 것보다 v_i 에 더 많은 영향을 끼친다. 이것은 m 의 크기에 좌우된다. $U = [\mu_{ik}]$ 는 $U \in V_{cn}$ 이고, 다음의 ①②③조건을 만족하는 퍼지 c -분할을 따른다.

$$\textcircled{1} \quad \mu_{ik} \in [0, 1], \quad 1 \leq i \leq c, \quad 1 \leq k \leq n, \quad \textcircled{2} \quad \sum_{i=1}^c \mu_{ik} = 1; \quad 1 \leq k \leq n, \quad \textcircled{3} \quad 0 < \sum_{i=1}^n \mu_{ik} < n; \quad 1 \leq i \leq c$$

식 (3-4)는 분석이 어려운 문제이므로 이에 미분을 적용시켜 지엽적 최적화의 필요 요건을 이

끌어 낸다. 목적함수를 v_i 와 μ_{ik} 에 대하여 미분하고 $\sum_{i=1}^n \mu_{ik} = 1$ 의 조건을 적용하면 식(3-5)을 얻을 수 있다.

$$v_i = \frac{1}{\sum_{k=1}^n (\mu_{ik})^m} \sum_{k=1}^n (\mu_{ik})^m x_k ; i=1, \dots, c \quad (3-5)$$

여기서

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{(m-1)}}}, \quad d_{ik} = d(x_k, v_i) = \|x_k - v_i\| = \left[\sum_{j=1}^p (x_{kj} - v_{ij})^2 \right]^{\frac{1}{2}}$$

위의 식(3-4)과 (3-5)는 분석적인 방법으로 해결할 수 없음이 알려졌다. 그러나 초기데이터 위치에서 시작하는 목적함수의 최소 극값을 구하는 반복 알고리즘이 알려졌다. 가장 대표적인 알고리즘은 c-means 알고리즘(Fuzzy c-Means Algorithm : FCM)이다[23].

본 논문에서 U, V를 구하기 위해 사용된 FCM 알고리즘의 절차는 다음과 같다.

[단계 1] 매개변수 c , m , A 를 선택한다. 클러스터의 개수 c 는 $2 \leq c \leq n$, n 은 데이터 개수로 신경망의 패턴수×패턴별 표본 수이며, 지수가증치 m 은 $1 \leq m \leq \infty$, $\|x - v_i\| = (x - v_i)^T A (x - v_i)$ 인 내적노음자 $A \in W_{pp}$ 는 대칭적이고 positive definite 인(p, p) 행렬이다. 여기서 p 는 신경회로망의 출력 노드 수이다.

[단계 2] 퍼지 분할 $U^{(0)}$ 를 초기화한다.

[단계 3] $U^{(b)}$ 를 이용하여 클러스터 중심값 $\{v^{(b)}\}$ 들을 다음 식에 의해 구한다.

$$v_{il} = \frac{1}{\sum_{k=1}^n (\mu_{ik})^m} \sum_{k=1}^n (\mu_{ik})^m x_{kl} ; l=1, \dots, p$$

단, b 는 반복 계산횟수

[단계 4] If ($x_k \neq v_i^{(b)}$) 이면 식 (3)으로 부터 새로운 멤버십 행렬 $U^{(b+1)}$ 를 구한다.

else

$$\mu_{ik} = \begin{cases} 1, & \text{for } i=k \\ 0, & \text{for } i \neq k \end{cases}$$

[단계 5] $\|U^{(b+1)} - U^{(b)}\| < \epsilon$ 이 만족되면 중지하고, 만족되지 않으면 [단계3]부터 다시 반복한다. 여기서, $\|\cdot\|$ 는 행렬 노음(matrix norm)이다.

새로운 입력 패턴의 종류를 분류하고자 할 때 각 클래스에 소속되는 정도를 구한 후 그 소속 정도가 가장 큰 클래스에 속하는 것으로 분류하게 되는데 소속 정도를 계산하기 위해서는 식 (3-6)이 이용된다.

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{\frac{2}{(m-1)}}} ; i=1, \dots, c ; k=1 \quad (3-6)$$

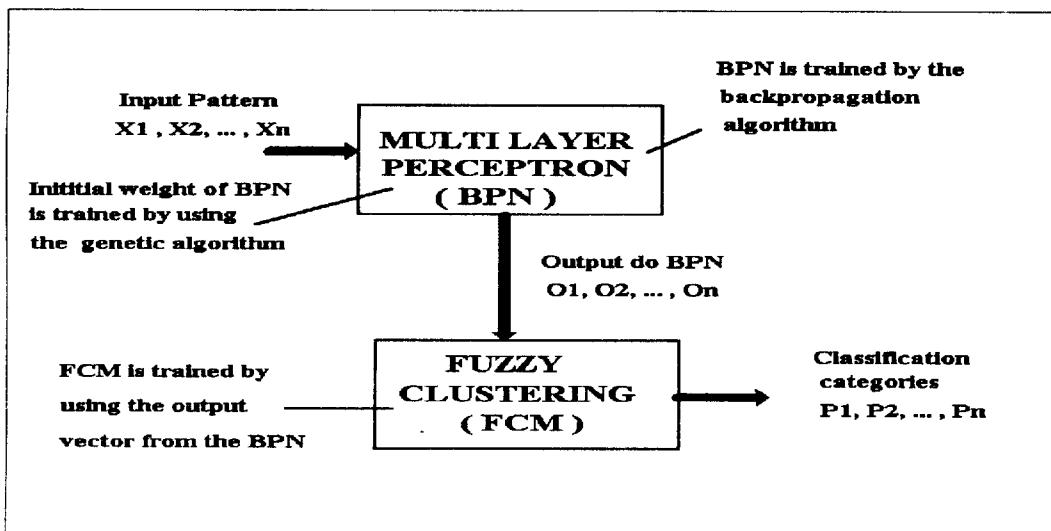
FCM은 비감독형 클러스터링 기법중의 한 종류이며, 인식 공간상에서 패턴 벡터들의 위치와 분산을 고려하지 않고 동일한 크기의 클러스터로 분할되는 특성을 가진다. 따라서 FCM을 패턴매칭 문제에 적용될 때의 제한점은 입력패턴들이 잘 분리된 클래스로 되어 있어야 한다는 점이다.

3.4 제안된 복합 유전자-뉴로-퍼지 분류기

역전파 신경망을 이용한 패턴인식은 구현이 쉽고 비교적 좋은 학습성능때문에 가장 많이 사용되고 있으나, 역전파 알고리즘의 일반적인 단점으로는 지역최소값(local minima)으로 인해 오분류를 일으킬 수 있다는 점과 학습의 수렴 속도가 늦다는 것이다. 또한, FCM등의 퍼지클러스터링 이론이 데이터 취득(data acquisition), 특징량 추출(feature extraction), 패턴분류(pattern classification)등으로 구성되는 일반적인 패턴 분류체계에 존재하는 여러 불확실성들을 효과적으로 처리할 수 있고, 빠르게 수렴하는 장점 때문에 많이 사용되고 있으나, FCM은 비감독형 클러스터링 기법중의 한 종류이며, 인식 공간상에서 패턴 벡터들의 위치와 분산을 고려하지 않고 동일한 크기의 클러스터로 분할되는 특성으로 패턴매칭 문제에 적용될 때의 제한점은 입력패턴들이 잘 분리된 클래스로 되어 있어야 한다는 것이다.

본 연구에서는 역전파 알고리즘, 퍼지클러스터링의 단점을 개선하고, 장점을 이용하기 위하여 역전파 알고리즘, 유전 알고리즘, FCM을 이용하는 다음3과 같은 결합모델이 제안되었다. 첫째, 전역적인 탐색을 수행하는 유전자 알고리즘을 이용하여 오차가 지역적인 최소값을 갖지 않도록 하는 최적의 초기 연결가중치를 제공하도록 하였다. 둘째, 결정론적 기울기 하강법인 역전파 알고리즘을 이용하여 충분한 학습을 실시한 후, 신경망의 최종 연결가중치를 결정한 다음, 역전파 신경망의 출력값을 다시 비감독 군집화 기법인 FCM의 입력값으로 사용하여 클러스터의 중심벡터를 구하여, 패턴분류에 사용하므로 잡음(noise)에 강한 식별기를 구성하였다.

제안된 복합 유전자-뉴로-퍼지망(hybrid genetic-neural-fuzzy networks : HGNFN)의 블럭 다이어그램은 그림 (3-2)와 같고, 학습 진행절차는 그림 (3-3)과 같다.



그림(3-2) 복합 유전자-뉴로-퍼지망의 블럭 다이어그램
fig(3-2) Hybrid genetic-neural-fuzzy networks (HGNFN) block diagram

4. 실험결과

4.1 실험시스템 구성 및 실험자료 구축

본 연구에서의 실험에 사용한 영상입력장치는 평면영상입력기인 ‘HEWLETT PACKARD’의 칼라그레이 스캐너 (SCANJET II C)을 사용하였다. 컴퓨터는 IBM PC 486DX-66 기종을 사용하였다. 학습 및 실험데이터는 그림 (4-1)과 같이 10종류의 항공기[20]에 대한 사진을 스캐너로 입

```

Procedure GA + BP + FCM
// p(t) : chromosome, weight vector
Begin
    t=0;
    p(t)의 초기화; // 모집단 초기화
    p(t)에 대한 BEP의 전향적 진행;
    p(t)에 대한 MSE 평가;
    t=t+1;
    Repeat // 유전 알고리즘 학습
        p(t-1)로부터 p(t)를 선택복제;
        p(t)재구성 by 돌연변이, 역, 교차연산 ;
        p(t)에 대한 BEP의 전향적 진행;
        p(t)에 대한 MSE 평가;
        t=t+1
    Until (종료조건)
    Repeat // 역전파 알고리즘 학습
        p(t)에 대한 BEP의 전향적-후향적진행(BPN학습);
        p(t)에 있는 구조들의 재구성;
        p(t)에 있는 MSE 평가;
        t=t+1;
    Until(종료조건)
    o(t)를 FCM에 입력; // o(t)=BPN의 출력
    Repeat // FCM학습
        o(t) 에 대한 FCM 학습;
    Until(종료조건)
End

```

그림(3-3) 복합 유전자-뉴로-퍼지망의 학습 알고리즘

fig.(3-3) Hybrid Genetic-Neural-Fuzzy Networks(HGNFN) learning algorithm

력을 받아 외곽선을 구하여 학습에 사용했다. 외곽선에 대한 회전, 이동, 크기변화 및 잡음(noise)에 대한 식별기의 성능을 측정하기 위하여 실험 패턴 벡터는 3,240개(10기종×36각도×3크기변화×3종류 잡음)를 사용했다. 즉, 회전에 대해서는 360도를 10도씩 36분할, 크기변형에 대해서는 원형을 100%, 80 %, 60%로 변경시킨 3단위, 잡음에 대해서는 식(4-1)에 3종류의 잡음 10dB, 15dB, 20dB를 대입해서 구한 자료를 구축하여 실험하였다.

$$S_s = \frac{S_s}{10^{0.1SNR}} \quad (4-1)$$

여기서 $S_s = \frac{1}{N+1} \sum_{n=0}^N |c'(n)|^2$ 은 Signal power이며, $c'(n)$ 은 외곽선 벡터의 n번째 요소이다. SNR은 사전에 정의된 신호대 잡음비(signal to noise ratio : dB)이다.

4.2 학습 및 인식 실험

상기 데이터에 대한 학습 및 인식에 대한 실험을 그림 (4-2)의 절차에 의해 실시하였다. 실험 결과는 그림(4-3)에 학습시 유전자 알고리즘을 사용한 경우와 사용하지 않은 경우에 대한 비교를

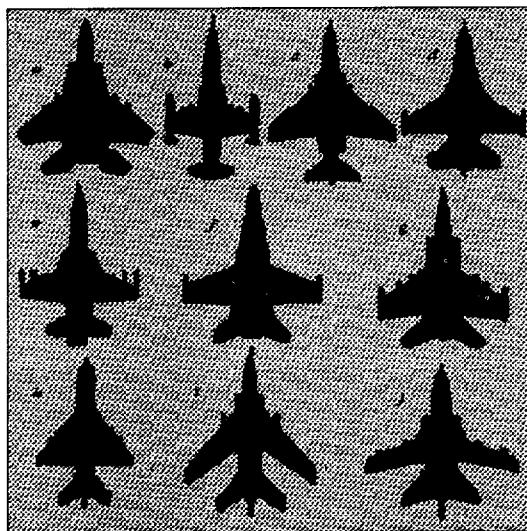


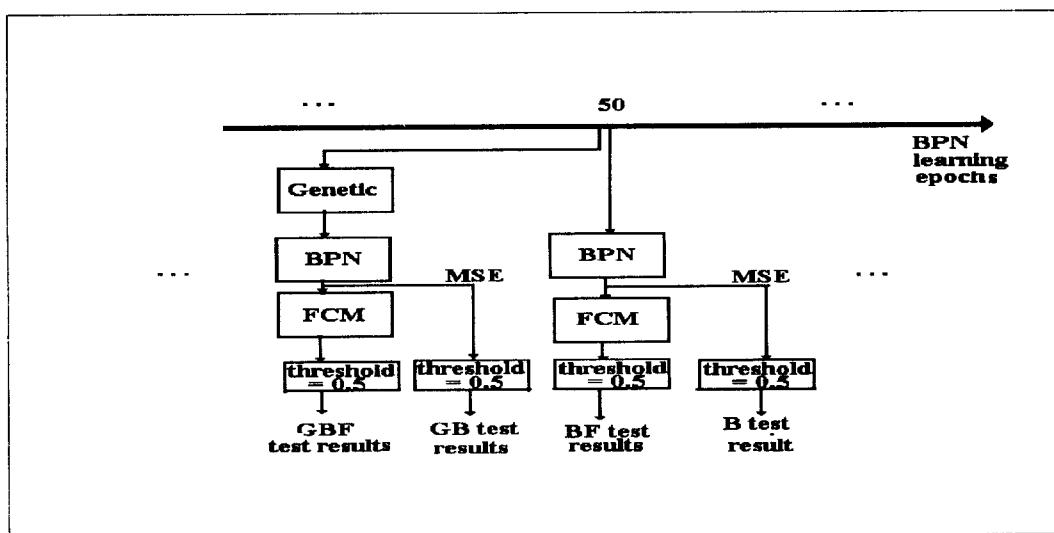
그림 (4-1) 모의 실험에 사용한 10종류의 항공기 모형

fig.(4-1) Ten modern combat aircraft used simulation

(a.F-15, b.F-104, c.F-4, d.F-16, e.F-5, f.F/A-18, g.Mig-25, h.Mig-21,
i.Nanzang Q-5, j.Tornado IDS)

MSE(mean square error)를 기준으로 보였고, 그림 (4-4)에는 결합모델별 인식률에 대한 결과를 비교하였다. 이때 유전자 알고리즘의 파라메타, 신경회로망의 노드 수 및 파라메타, 퍼지 클러스터링 알고리즘의 파라메타는 결합방법의 차이 이외는 동일한 조건에서 실험하였다.

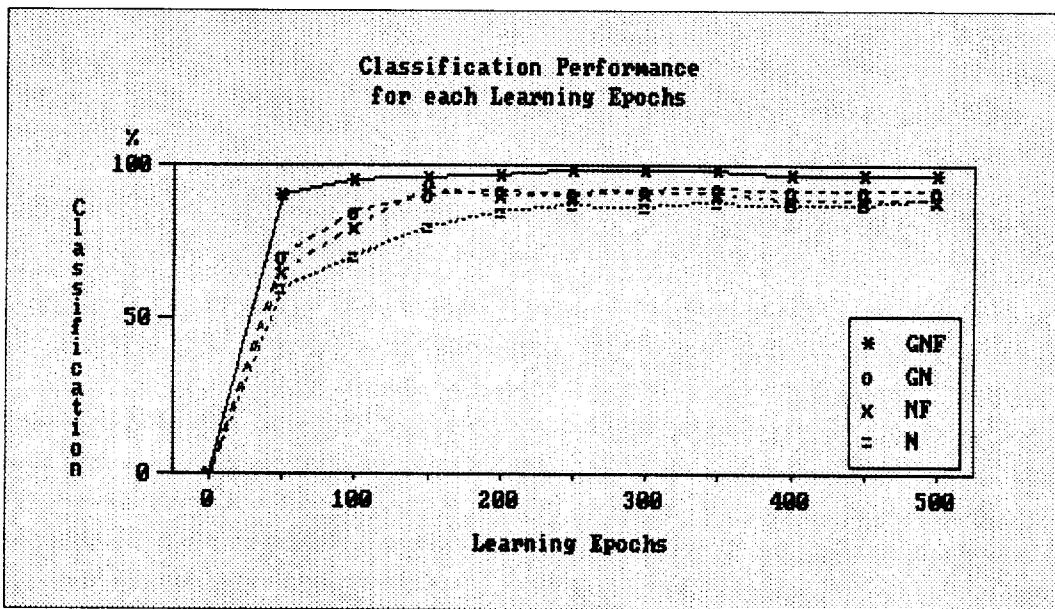
그림 (4-2)에서 threshold는 출력값에 대한 분류판정시 기준으로 설정한 값이며, 결합방식에서 GBF는 “유전자 알고리즘 + 역전파알고리즘 + 퍼지클러스터링 알고리즘”을 결합한 경우이며, GB는 “유전자 알고리즘 + 역전파 알고리즘”, BF는 “역전파알고리즘 + 퍼지클러스터링 알고리즘”, B는 “역전파 알고리즘”만 사용한 경우이다. 관측자료는 역전파알고리즘을 기준으로 하여 요구하는 목표에 수렴(MSE)하는 학습시간 및 반복횟수를 측정하였고, 학습을 50 반복횟수(epochs)마다 멈추면서 연결가중치를 비롯한 학습파라메타를 기억시킨 다음 학습을 모두 마친 후 epochs 별로 수집하였다.



(G: genetic algorithm, B : backpropagation networks, F: fuzzy c-means algorithm)

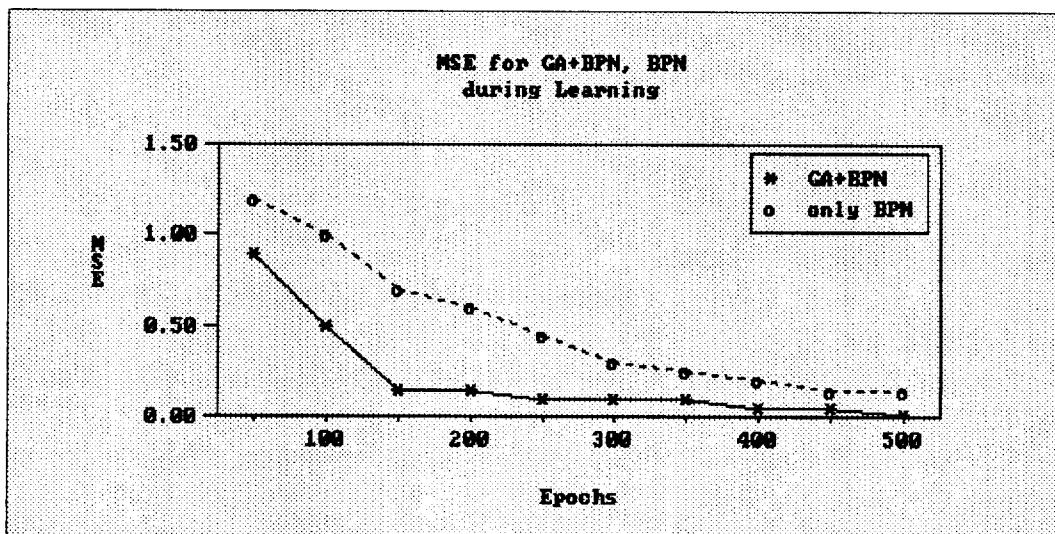
그림(4-2) 실험간 시스템 성능측정을 위한 추적 구조

fig. (4-2) Simulation monitor system structure



그림(4-3) 수렴률에 대한 성능비교
fig.(4-3) comparison of performance on convergency

그림(4-3)은 역전파 알고리즘과 초기 연결 가중치를 유전자 알고리즘을 적용하여 최적화 시킨 값을 결합한 경우(GA+BPN)와 역전파 알고리즘만 사용한 경우(only BPN)에 대한 비교표이다. 초기 연결가중치를 최적화 시킨 경우 150회 정도에서 만족할 수준에 수렴하였고, 역전파 알고리즘만 사용시 500회 이상 학습시 요구수준에 도달했다. 유전자 학습을 위한 시간을 고려하더라도 시간 측면에서도 결합모델이 양호한 결과를 얻었다.



그림(4-4) 인식률에 대한 성능비교(각 점은 3,240개의 실험데이터에 대한 평균값)
fig.(4-3) comparison of classification performance
(each point is an average of 3,240 test data)

그림 (4-4)는 결합 모델별로 인식률에 대한 비교표이다. 그림에서의 범례의 결합방식은 앞에서 설명한 내용과 같다. 이 그림에서 알 수 있듯이 “유전자 알고리즘+역전파알고리즘+퍼지클러스터

링 알고리즘”을 결합한 모델이 가장 양호한 인식률을 보였고, 역전파 알고리즘을 단독으로 사용한 경우가 가장 저조했다. 결합모델의 경우 영상의 위치, 크기, 회전 변화에 대한 인식률은 최고 100%에 접근하였으며, 잡음비 15dB에서는 98%였다. 상기 결과를 통해 인식알고리즘의 적절한 결합의 유용성을 알 수 있었다.

5. 결론 및 향후 연구과제

본 연구에서는 2차원 영상을 인식하는데 있어서 역전파 학습 알고리즘에 유전 알고리즘, 퍼지 클러스터링(FCM)의 장점을 결합한 복합 뉴럴-퍼지망을 제안하였다. 대상 물체에서 획득되는 영상정보로부터 대상 물체의 종류를 인식하기 위해서는 획득된 영상의 위치, 크기, 또는 회전에 무관하게 대상 물체를 식별해야 하며, 영상획득시 불가피하게 수반되는 잡음 속에서도 대상 물체를 식별할 수 있어야 한다. 이를 위해 본 연구에서는 스펙트럼 분석기법을 포함한 일련의 사전처리 과정을 통해 영상의 위치, 크기 회전으로 인한 영향, 그리고 잡음으로 인해 외곽선의 일부가 손상된 패턴벡터를 추출한 후, 이 패턴 벡터를 역전파 신경회로망의 입력벡터로 사용하였으며, 다시 역전파 신경망의 출력베타를 FCM의 입력벡터로 사용하는 방법을 제안하였다. 이때 신경망의 최적화된 최초 연결가중치를 유전 알고리즘을 이용해서 구했다.

제안된 시스템의 성능 평가를 위한 컴퓨터 모의 실험 대상은 10대의 최신 항공기로써, 잡음이 없는 상태로 훈련을 실시한 후, 각 항공기에 대해 추출된 외곽선을 확대, 축소, 회전하거나, 가우시안 분포를 갖는 잡음을 다양한 신호대 잡음비로 더하여 총 3,240개의 실험용 항공기 영상을 만들었다. 이 실험용 영상들을 사용하여 인식실험을 한 결과 “유전자 알고리즘+역전파알고리즘+퍼지클러스터링 알고리즘”을 결합한 모델이 가장 양호한 인식률을 보였고, 역전파 알고리즘을 단독으로 사용한 경우가 가장 저조했다. 결합모델의 경우 영상의 위치, 크기, 회전 변화에 대한 인식률은 최고 100%에 접근하였으며, 잡음비 15dB에서는 98%였다. 또한 학습속도도 10%이상 단축되었다. 상기 결과를 통해 인식 알고리즘의 적절한 결합의 유용성을 알 수 있었다.

향후 연구할 내용은 본 논문에서 사용한 스펙트럴 분석은 대상 물체의 외곽선 추출이 가능한 경우를 전제로 했는데 대상에 따라 외곽선 추출이 어려운 경우가 있고, 외곽선이 물체를 대표하지 못하는 경우가 있으므로 이에 대한 연구가 요구된다.

[참고문헌]

1. 오영환 ; “패턴인식론”, 정의사, 1991.
2. C H Chen, L F Pau, P S Wang ; “Handbook of Pattern Recognition & Computer Vision”, Wold Scientific, 1993.
3. R.O. Duda and P.E. Hart ; “Pattern Classification and Scene Analysis”, John Willey & Sons, New York, 1973
4. Rafael C. Gonzalez & Richard E. Woods ; “Digital Image Processing”, Addison-Wesley Publishing Company, Inc., 1992.
5. Scott E. Fahlman ; “Faster-learning variations on back propagation : an empirical study”, Proceedings of the connectionist Models Summer School, pp.38-51, June 1988
6. Maurice Maes ; “Polygonal Shape Recognition Using String Matching Techniques”, Pattern Recognition, Vol 24, No.5, pp. 433-440, 1991
7. H.C. Liu and M.D. Srinath ; “Partial Shape Classification Using Contour Matching in Distance Transformation” ; IEEE Trans. on PAMI. Vol.12. No.11, pp.1072-1079, Nov. 1990
8. Lilly and M.B. Reid ; “Robust Position, Scale, and Rotation Invariant Object Recognition Using Higher-Order Neural Networks”, Pattern Recognition, Vol.25, No.9, pp. 975-985, 1992
9. Whoi-Yul Kim and Po Yuan ; “A Practical Pattern Recognition System for Translation,

Scale and Rotation Invariance", Proceedings 94 IEEE CSC

10. Alejandro Blumenkrans ; "Two-dimensional object recognition using a two dimensional polar transform", Pattern Recognition, Vol.24, No.9, pp.879-890, 1991.
11. 김종오, 진성일 ; "Log-polar mapping에 기반한 크기와 회전에 불변인 2차원 물체 영상인식", 2회 신경회로망 연구회 학술대회 논문집, pp.36-41, Jun .1991
12. 권희용 ; "복소-대수 사상과 수정된 이차 신경망을 이용한 회전 및 크기변형에 무관한 패턴 인식", 서울대학교 대학원, 박사학위 논문, 1993.
13. 진성일 ; "Target recognition using neural networks", 신경회로망 응용 웹샵, pp.111-126, 1989.
14. C.C. Lin and R.Chellappa ; "Classification of partial 2-D shapes using Fourier descriptors", IEEE Trans. on PAMI, Vol.9, No.5, pp. 686-690, Sep.1987.
15. A.Khotanzad and Y.H.Hong ; "Invariant image recognition by Zernike moments", IEEE Trans. on PAMI, Vol.12, pp.489-497, May. 1990
16. J.A. Freeman and D.M. Skapura ; "Neural Networks", Addison-Wesley Publishing Company, Inc., 1991
17. Y.Hirose,K.Yamashita, and S.Hijiya ; "Back propagation algorithm which varies the number of hidden units", Neural Networks, Vol.4. No.1 pp61-66, 1991.
18. Vittorio Maniezzo ; "Genetic Evolution of the Topology and Weight Distribution of Neural Networks", IEEE Trans. on Neural Networks, Vol. 5, No. 1 pp.39-53, Jan. 1994.
19. James C. Bezdek, Richard, Michael, William ; "Convergence Theory for Fuzzy c-Means : Counterexample and Repairs", IEEE Trans. on Syst.,Man,Cybern., Vol. SMC-17, No.5, pp.873-877, Sep./Oct. 1987.
20. Byungho Cho ; "Rotation, translation and scale invariant 2-D object recognition using spectral analysis and a hybrid neural network", Florida Institute of Technology Melbourne, U.S.A. Phd. Thesis 1993.
21. Goldberg, D. E. ; "Genetic Algorithm in Search, Optimization and Machine Learning", Addison-Wesley, Reading, Massachusetts, 1989.
22. Michalewicz, Z. ; "Genetic Algorithms + Data Structures = Evolution programs", Springer -Verlay, 1994.
23. H.-J.Zimmermann ; "Fuzzy set theory and its applications" , Kluwer Academic Publishers, 1991
24. Michael J. Sabin ; "Convergence and Consistency of Fuzzy c-Means/ ISODATA Algorithms", IEEE Trans. on PAMI, Vol.9, No.5, pp. 661-668, Sep.1987.