

## 유연 생산 자동화를 위한 Robust 패턴인식 시스템\*

The Robust Pattern Recognition System for Flexible Manufacture Automation\*

위영량\*\* · 김문화\*\* · 장동식\*\*

Young-ryang Wi\*\* · Mun-hwa Kim\*\* · Dong-sik Jang\*\*

### Abstract

The purpose of this paper is to develop the pattern recognition system with a 'Robust' concept to be applicable to flexible manufacture automation in practice. The 'Robust' concept has four meanings as follows. First, pattern recognition is performed invariantly in case the object to be recognized is translated, scaled, and rotated. Second, it must have strong resistance against noise. Third, the completely learned system is adjusted flexibly regardless of new objects being added. Finally, it has to recognize objects fast.

To develop the proposed system, contouring, spectral analysis and Fuzzy ART neural network are used in this study. Contouring and spectral analysis are used in preprocessing stage, and Fuzzy ART is used in object classification stage. Fuzzy ART is an unsupervised neural network for solving the stability-plasticity dilemma.

### 1. 서 론

패턴인식에 관한 연구는 30~40년 전부터 활발해지기 시작했으며, 문자인식, 서명인식, 지문인식, 얼굴인식, 음성인식, 의료영상의 인식 등의 분야에 적용되고 있다[18]. 그리고 최근에는 공장의 생산자동화에도 적용되고 있다. 패턴인식의 현실 적용시 대상물체나 영상획득장비의 움직임으로 인해 획득된 영상은 이동, 크기, 회전등의 기하학적인 변형과 공장환경에서 흔히 나타나는 전기적 잡음(Noise)과 기계적 진동에 의한 다양한 잡음을 갖게 된다[16]. 또한 기업의 생산시스템이 단품종 소량생산으로 바뀌어감에 따라 인식 시스템이 식별해야 할 대상물체는 차

주 변경되고 추가되므로 인식 시스템은 변경되는 내용에 맞게 다시 설계되고 인식에 필요한 정보 또한 다시 입력되어야 한다. 그리고 생산 자동화를 위한 인식시스템에서는 생산 흐름의 연속성을 위해 실시간 처리 능력이 요구된다.

물체의 기하학적인 변형에 무관하게 패턴을 인식하는 불변패턴인식(Invariant Pattern Recognition)에 대한 연구는 1960년대 초에 시작되어 80년대 후반에 활발해졌다. 불변 패턴인식은 복잡하고 어려운 문제로 인식되고 있으며, 다양한 방법들이 문제의 해결에 사용되어 왔다.

Wood(1996)는 불변패턴인식의 주된 접근 방법을 두 가지로 분류하고 있는데, 첫 채는, 전처리 단계에서 대상패

\* 본 연구는 1996년도 한국 학술진흥재단의 공모과제 연구비에 의해 수행되었음.

\*\* 고려대학교 산업공학과

턴으로부터 불변특징벡터를 추출한 후에 인식 단계에서 그 특징벡터를 입력값으로 하여 패턴을 식별하는 방법이다. 전처리 단계에서는 푸리어 변환(Fourier Transform), 모멘트(Moment), 특정 목적에 맞는 수학적 방법 등이 사용되고, 인식 단계에서는 MLP(Multi-Layer Perceptron)등의 신경망이 이용된다. 둘째는, 위의 두 가지 단계를 결합한 것으로 신경망을 이용하여 불변 특징을 갖는 매개 변수를 유도하여 바람직한 인식 결과를 얻어내는 것이다. 여기에서는 하이-오더(Higher-Order) 신경망과 네오커그니트론(Neocognitron), 여러 개의 신경망을 결합한 복합망 등이 사용된다[10].

Aishang(1996)은 전처리 단계에서 FFT(Fast Fourier Transform)를, 인식 단계에서 신경-유전자-퍼지 복합망을 사용하여 이동, 크기, 회전에 무관하고 잡음에 강한 불변 패턴인식 방법을 발표하였는데, 이 연구는 Wood의 분류 방법 중에서 첫 번째를 사용한 대표적 예이다[16].

Spirkovska(1992)는 하이-오더 신경망을 이용하여 기하학적인 변형에 무관한 불변패턴인식 방법을 제안하였다 [11]. 하이-오더 신경망은 입력패턴의 사전정보를 이용하여 신경망 구조를 직접적으로 구성하기 때문에 학습이 미리 이루어지는 특징과 기하학적인 변형에 대해 불변 특징을 학습할 필요가 없다는 장점이 있다. 그러나 신경망을 구성하기 전에 패턴에 대한 여려 가지 성질과 사전 정보를 미리 알지 못하면 사용하기 어렵고, 입력패턴의 수가 많아짐에 따라 뉴런(Neuron)의 연결 가중치(Weights)에 대한 계산량이 급속도로 증가한다. 그리고 인식 가능한 패턴의 종류가 고정적이다.

Fukushima(1991)는 네오커그니트론을 이용하여 문자에 대한 불변패턴인식 방법을 발표하였다[1]. 네오커그니트론은 필기체 인식 때에 발생하는 왜곡과 기하학적인 변형에 영향을 받지 않고 인식 성능을 개선하기 위한 방법으로 제안되었다. 그러나 인식의 성능은 우수하나 수천개

의 뉴런과 수백 개의 연결이 미리 고정된 구조를 갖고 있어 계산량이 너무 많다.

Wang(1996)은 3개의 2차원 레이어(Layer)로 구성된 특징추출 신경망을 이용하여 불변특징벡터를 추출하고 2개의 레이어로 구성된 전향신경망을 이용하여 기하학적인 변형에 무관하게 패턴을 인식하는 복합망을 제안하였다 [14]. 그러나 이것도 역시 구조가 복잡하고 계산량이 많으며 고정된 패턴에 대한 분류만 가능하다.

이상에서 살펴본 바와 같이 기하학적인 변형을 고려한 불변패턴인식에 관한 연구는 많이 진행되어 왔으나 기하학적인 변형과 잡음, 실시간 인식, 패턴의 종류 변화에 무관한 인식을 동시에 고려한 연구는 이루어지지 않고 있다.

본 연구의 목적은 유연 생산 자동화(Flexible Manufacture Automation)를 위한 Robust한 개념의 패턴인식 시스템을 개발하는 것이며, Robust 방식에 대한 정의는 다음과 같은 조건을 만족하는 것으로 간주한다. 첫째, 대상 물체의 위치이동, 회전이동, 크기변화에 무관하게 인식이 가능해야 한다. 둘째, 영상획득 및 처리과정에서 발생하는 잡음에 대해 강해야 한다. 셋째, 실시간 적용이 가능하도록 인식 시간이 빨라야 한다. 마지막으로 대상 물체의 종류의 변화에 무관하게 인식이 가능해야 한다.

그림 1.1은 연구된 불변패턴인식 시스템의 정보 흐름을 나타내고 있다. 이 시스템은 전처리 단계에서 불변특징벡터를 추출해내고 그 특징벡터를 입력으로 하는 신경망을 이용하여 대상 물체를 식별하는 방법을 사용하고 있다. 전처리 단계에서는 기하학적인 변형에 무관한 불변 특징벡터 추출과 잡음 제거를 위해 영상의 이진화와 윤곽선 추출, 윤곽선의 각 화소(Pixel)와 패턴의 중심과의 거리에 대한 스펙트럼 분석 결과를 사용하였다. 그리고 특징벡터에 대한 정규화에 의해 패턴에 대한 변별력을 향상시켰다. 식별 및 분류 단계에서는 시스템의 실시간 인

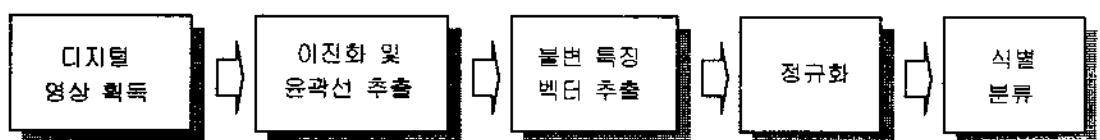


그림 1.1. Robust 패턴인식 시스템 흐름도

식과 패턴의 종류 변화에 무관한 인식을 위해 브론 학습 속도와 과거의 학습된 패턴에 대한 기억을 유지하면서 재 학습이 가능한 특성을 가진 Fuzzy ART를 이용하였다.

## 2. 불변특장벡터 추출

## 2.1 이진화 및 윤곽선 추출

256수준의 명암도를 갖는 디지털 영상으로부터 식별기의 입력값이 되는 불변특징벡터를 구하기 위하여, 첫 번째 단계로 본 연구에서는 영상의 이진화를 이용하였다. 영상의 이진화란 영상을 계수화하는 방법중에서 특수한 경우로 명암도를 0과 1의 수준으로 제한하는 것이다. 이러한 이진화의 방법은 대상이 되는 물체를 배경과 분리하기 위해서 자주 사용한다. 이진화가 이루어진 영상은 물체는 1의 값을 갖는 검은색으로 배경은 0의 값을 갖는 흰색으로 표현된다. 256명암도를 갖는 디지털 영상을 0과 1의 값을 갖는 이진 영상으로 표현하기 위해서 저장된 디지털 영상을 256명암도 값의 수준에 따른 나타나는 명암값의 빈도수로 히스토그램을 그린 후에 배경과 물체를 구분할 수 있는 적절한 명암값, 즉 임계값을 선택하여 임계값보다 크면 1로 작으면 0으로 표현한다. 임계값을 구하는 방법은 p-타일법, 모드법, 미분 히스토그램법, 판별 분석법, 가변 역치법등이 있다[17]. 본 연구에서는 영상의 히스토그램이 두 개의 극을 갖는 분포의 모양을 하고 있기 때문에 모드법을 사용하여 영상을 이진화하였다. 이진화의 과정은 다음과 같다.

if  $f(x, y) \leq T$       then  $f(x, y) = 1$   
 if  $f(x, y) > T$       then  $f(x, y) = 0$

단,  $T$ 는 임계값이고,  $f(x, y)$ 는 좌표 평면상에서  $(x, y)$  좌표에서의 명암값이다.

다음 단계는 이전화된 영상으로부터 윤곽선을 추출하는 과정이다. 윤곽선이란 물체의 경계가 되는 부분을 연결시킨 화소의 집합으로 영상 처리 과정에서 중요한 특징중의 하나이다. 윤곽선을 추출하는 작업은 먼저 경계에 해당하는 부분의 화소에 대한 위치 정보를 추출하고 이를 화소의 위치 정보를 폐곡선으로 통합하는 일로 구성된다. 윤곽선에 대한 정보를 얻는 방법에 대해서는 많은

연구가 이루어지고 있는데 이중에서 Duda등이 제안한 Turtle 알고리즘이 빠른 처리 시간과 쉬운 프로그램의 구현 때문에 많이 사용되고 있다. Turtle 알고리즘은 임의의 대상 물체의 한 점에서부터 출발하여 물체의 경계를 찾은 다음, 시계방향으로 윤곽선을 추적하여 처음 출발점에 되돌아오면 추적을 멈춘다. 이 알고리즘에 의한 구현은 단일 경로를 갖는 폐곡선을 형성한다[16]. 본 연구에서는 물체의 외양을 표현하는 윤곽선 추출이 목적이기 때문에 구현이 쉽고 속도가 빠른 장점이 있는 Turtle 알고리즘을 사용하였다. Turtle 알고리즘의 기본적인 처리 절차는 그림2.1과 같다.

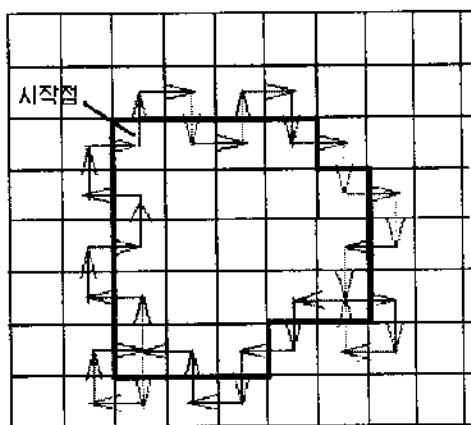


그림 2-1. Duda & Hart 유판선 추출 알고리즘

그림 2.2는 실제 F15 비행기를 대상으로 영상의 이진화와 유크서를 추출하는 과정을 묘사한 것이다.

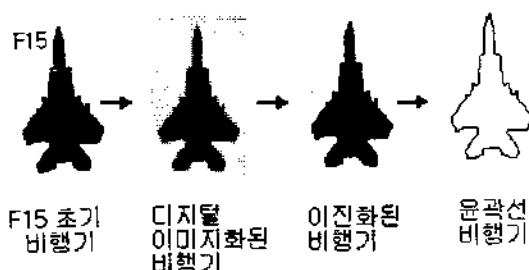


그림 2.2. 비행기의 유클선 추출 절차

## 2.2 불변특징벡터의 추출

변형에 불변인 특징벡터란 물체가 회전, 크기 변화, 위치 이동되어도 변하지 않는 특성을 갖는 벡터를 말한다. 특징 추출은 대상으로 하는 패턴의 특성에 크게 의존하므로 패턴의 성격을 깊이 규명할 필요가 있다. 본 연구에서는 폐곡선을 이루는 윤곽선을 구할 수 있는 2차원 평면상의 영상패턴을 대상으로 한다.

먼저 위치 이동에 불변인 특징벡터를 구하는 과정을 살펴보면, 대상 물체의 윤곽선을 구한 후, 윤곽선 화소로부터 중심까지의 거리(Central distance)를 사용한다. 거리벡터는 윤곽선의 좌표 중심( $x_c, y_c$ )으로부터 윤곽선의 각 화소까지의 거리로 구성된다. 식(2.1)은 거리벡터( $\vec{d}$ )를 나타낸 것이다.

$$\vec{d} = \{d_0, d_1, \dots, d_p, \dots, d_{N_o-1}\} \quad (2.1)$$

$$d_i = \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2}, \quad x_c = \frac{1}{N_o} \sum_{i=0}^{N_o-1} x_i, \quad y_c = \frac{1}{N_o} \sum_{i=0}^{N_o-1} y_i$$

식(2.1)에서 벡터의 원소를 정의해 주고 있는 윤곽선상의 좌표와 중심 좌표의 관계는, 윤곽선 각 화소의 좌표의 이동과 중심 좌표의 이동은 같은 방향, 같은 크기로 일어나므로 결국 위치 이동에 불변임을 알 수 있다. 따라서 거리벡터( $\vec{d}$ )는 물체의 위치 이동에 영향을 받지 않게 된다.

두 번째로 회전 변화에 무관한 불변특징벡터를 얻기 위해서 FFT(Fast Fourier Transform)를 이용한 스펙트럴 분석을 사용하였다. 따라서 일차적으로 윤곽선의 거리벡터를 이루는 원소 N\_o개를 N개의 일정한 크기로 샘플링하여야 한다. 이때 N의 크기는 2의 제곱으로 하여 FFT에 적용이 가능하도록 하였다. 샘플링에서 얻은 N개의 거리에 대한 벡터 값을 이용하여 회전 변화에 무관한 특징벡터를 얻는다.

회전에 무관한 특징벡터는 FFT의 결과를 이용하여 신호를 여러 가지 주파수대로 분해하여 분석하는 방법인 스펙트럴 분석(Spectral analysis)을 이용하여 얻는다. 스펙트렐이란 주파수의 크기에 따라 순서로 배열해 놓은 것으로서 신호 안에 주파수의 성분이 얼마나 포함되어 있는지를 나타내는 것이다. 먼저 스펙트렐 분석에서 사용되는 푸리어 계수를 DFT(Discrete Fourier Transform)를 이

용하여 구해보면 다음과 같다.

$$F(k) = \frac{1}{N} \sum_{i=0}^{N-1} r_i \exp(-j(\frac{2\pi}{N})ki), \quad k = 0, 1, \dots, N-1 \quad (2.2)$$

여기에서  $r_i$ 는 i 번째의 거리벡터 값이며 F(k)는 실수부 R(k)와 허수부 I(k)로 이루어진다.

$$F(k) = R(k) + jI(k), \quad k = 0, 1, \dots, N-1 \quad (2.3)$$

그리고 F(k)의 진폭 스펙트럼(Amplitude spectrum)과 파워 스펙트럼(Power spectrum)은 식(2.4), 식(2.5)을 이용하여 다음과 같이 구한다.

$$|F(k)| = \sqrt{R^2(k) + I^2(k)}, \quad k = 0, 1, \dots, N-1 \quad (2.4)$$

$$P(k) = |F(k)|^2 = R^2(k) + I^2(k), \quad k = 0, 1, \dots, N-1 \quad (2.5)$$

진폭 스펙트럼은 대상으로 하고 있는 신호 안에 각 주파수의 성분이 어느 정도 포함되어 있는 기울기 나타내는 것이고 파워 스펙트럼은 진폭 스펙트럼을 자승한 것으로서 제곱근을 계산하는 시간을 절약하고, 진폭 스펙트럼보다 잡음 성분을 약화시키는 성질을 보유하고 있다.

2차원 물체의 회전은 그림 2.3에서 보는 것처럼 윤곽선의 출발점의 변화로써 볼 수 있다. 그러므로 윤곽선의 푸리어 변환 계수를 d점(화소)만큼 환 이동한 것을  $F_d(k), k=0, 1, \dots, N-1$ 로 표현할 때, 다음 식들에서 볼 수 있는 것과 같이 위상 변화만 야기할 뿐 진폭(Magnitude)변화는 식(2.6), 식(2.7)에서 볼 수 있는 바와 같이 발생하지 않는다.

$$F_d(k) = \exp(j\frac{2\pi k d}{N}) F(k), \quad k = 0, 1, \dots, N-1 \quad (2.6)$$

$$|F_d(k)| = |F(k)|, \quad k = 0, 1, \dots, N-1 \quad (2.7)$$

$$P_d(k) = |F_d(k)|^2 = |F(k)|^2 = P(k), \quad k = 0, 1, \dots, N-1 \quad (2.8)$$

이상의 결과는 파워 스펙트럼에서도 마찬가지로 적용된다. 식(2.8)과 그림 2.3에서 볼 수 있듯이 영상의 회전은 푸리어 계수의 위상 변화만을 야기할 뿐 파워 스펙트

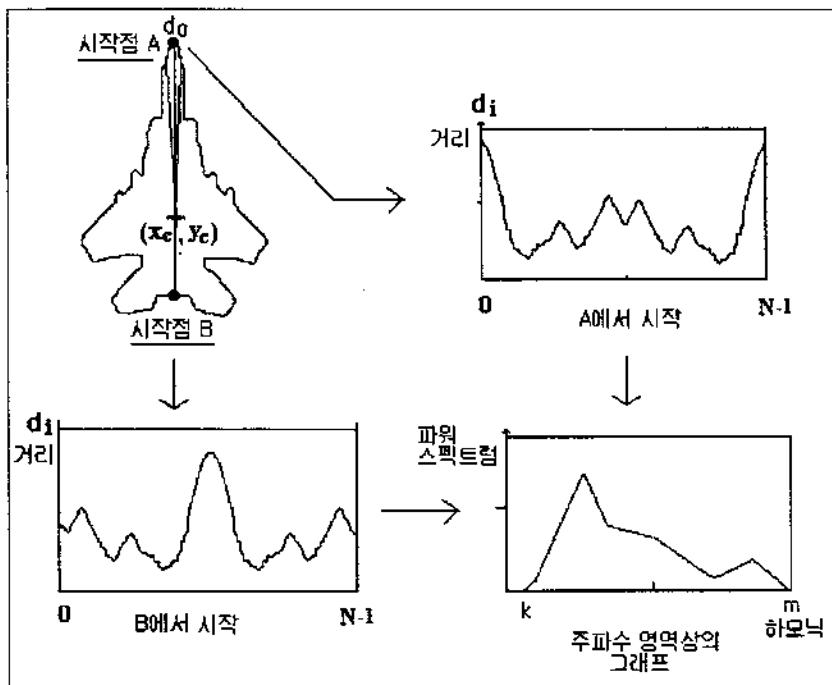


그림 2.3. 회전 이동에 대한 출발점 변화와 FFT 결과

럼은 일정하다.

이상에서 기술된 DFT 대신에, 삼각함수의 주기성을 이용하여 계산 시간이 빠른 FFT를 이용하는데 있어서, FFT가 일반적으로 데이터 점수에 제약이 있으므로 2의  $n$ 제곱( $2^n$ )으로 데이터의 수를 취하여 FFT의 사용상 제약이 없게 하였다. 본 연구에서는 FFT-Cooley Turkey 알고리즘을 사용하였다[10].

마지막으로 크기 변화에 무관한 특징벡터를 얻기 위한 절차는 다음과 같다. 스펙트럴 분석의 결과로 주파수 영역의 각 하모닉별로 파워 스펙트럼의 크기를 얻게 된다. 본 논문에서는 각 하모닉의 파워 스펙트럼 중에서 패턴의 성질을 대표하는 하모닉대를 선정하여 사용한다. 크기에 불변인 특징벡터를 얻기 위한 식은 다음과 같다.

$$p' = \frac{p}{|p|} = \left\{ \frac{p_k}{|p|}, \frac{p_{k+1}}{|p|}, \dots, \frac{p_m}{|p|} \right\} \quad (2.9)$$

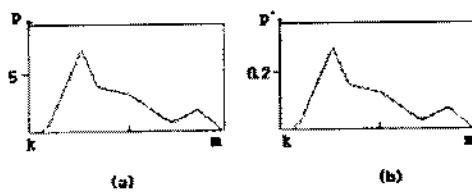
여기서

$$p = \{p_k, p_{k+1}, \dots, p_m\} \quad |p| = \sqrt{p_k^2 + p_{k+1}^2 + \dots + p_m^2}$$

$k$  = 하모닉의 시작 Index,  $m$  = 하모닉의 끝 Index

$$p_k = k\text{하모닉의 파워 스펙트럼}$$

위의 식 (2.9)를 보면 특징벡터로 선정된  $k$ 부터  $m$ 하모닉까지의 파워 스펙트럼을 모두 더한 총합을 구하여 그 총합으로 각 하모닉의 파워 스펙트럼을 나누어준다. 그러면 크기의 변화에 불변인 특징벡터를 얻게 된다. 그림 2.4는 크기 변화에 불변인 특징벡터를 그래프로 그린 것이다.



(a) 회전에 불변인 파워 스펙트럼 그래프  
(b) 크기 불변인 파워 스펙트럼 그래프

그림 2.4. 크기 변화에 불변인 특징벡터 그래프

### 2.3 스펙트럼 분석을 이용한 입력 벡터 산출

앞 절에서 설명된 것처럼 인식 시스템의 입력 값으로 사용되는 불변특징벡터는 FFT를 이용하여 구한다. FFT를 이용할 경우에 필요한 파워 스펙트럼의 하모닉(Harmonic) 성분은  $2^n$  개이므로 본 연구에서는 실험 대상인 비행기에서 FFT를 사용하기 위해 필요한 윤곽선의 화소수를 조사하였다. 비행기의 윤곽선의 화소수는 표 2.1과 같고 그 결과 샘플의 수는  $2^{10}=1024$ 로 정하였다.

표 2.2을 보면 파워 스펙트럼은 0주파수 하모닉에 94.2174%, 1~N/2사이의 하모닉에 5.7826%가 분포되어 있다. 그런데 0주파수 하모닉은 DC성분으로 제외하면 실제로 패턴을 대표할 수 있는 특징벡터는 모두 1과 N/2사이에 존재한다. 그러나 1과 N/2사이의 특징벡터의 크기는 인식 시스템에서 사용하기에는 너무 크고, 또한 많은 잡음이 들어 있다. 그러므로 1~N/2에서 패턴을 대표할 수 있는 특징벡터를 찾아야 한다. 본 논문에서는 실제로

표 2.1. 실험에 사용된 비행기의 윤곽선 화소수

비행기	윤곽선 화소수	비행기	윤곽선 화소수	비행기	윤곽선 화소수
F4	700	F16	644	Mig21	616
F5	708	F18	706	Mig25	774
F15	690	Mig19	864	Mig29	706

그리고 1024개의 하모닉 성분 중에서 물체의 특징을 대표할 수 있는 중요한 특징벡터, 즉 하모닉 성분을 구하기 위해 스펙트럼 분석을 실시하였다. 실험 대상인 9종류의 비행기의 파워 스펙트럼의 분포를 구해보면 표 2.2와 같다.

각 주파수별로 모든 데이터를 획득하여 그래프화 하였다. 그림 2.5는 하모닉 17을 넘어서면서부터 각 패턴사이의 차이가 사라짐을 보여준다. 실제로 1과 20사이의 하모닉에 대한 평균과 표준 편차를 구해보면 표 2.3과 같다. 표

표 2.2. 파워 스펙트럼 분포(A: 0주파수 하모닉(DC), B: 1~N/2 하모닉)

구분	F4	F5	F15	F16	F18	Mig19	Mig21	Mig25	Mig29
A	94.2074	93.4563	95.1506	94.2458	94.3237	93.4241	92.9913	94.2277	95.7650
B	5.7926	6.5437	4.8494	5.7542	5.6763	6.5759	7.0087	5.7723	4.2350

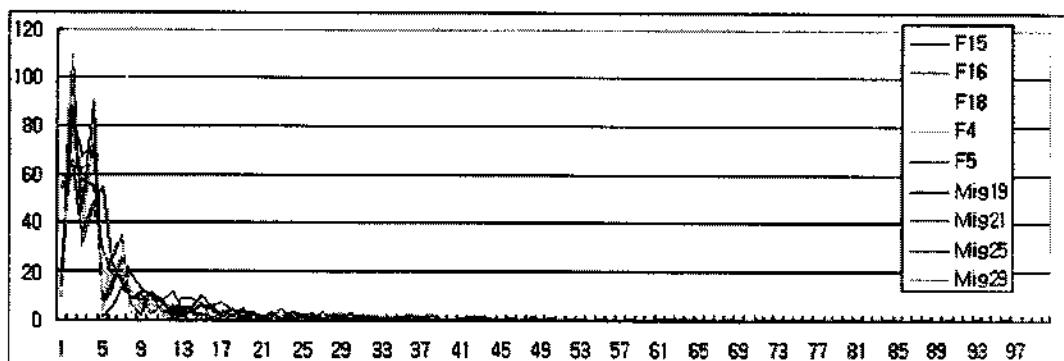


그림 2.5. FFT 직후의 1~100하모닉의 파워 스펙트럼

표 2.3 하모닉의 평균과 표준편차

하모닉	평균	표준편차	하모닉	평균	표준편차	하모닉	평균	표준편차
1	21.51864	13.88036	8	9.49179	4.43003	15	4.06812	3.07288
2	84.52490	13.96201	9	7.76936	3.47647	16	3.27071	2.23454
3	47.64549	13.17394	10	9.47848	3.10986	17	2.47498	1.97677
4	68.41964	16.05635	11	4.77486	2.57740	18	2.82890	1.15713
5	15.60510	17.14339	12	4.08743	3.36519	19	2.18239	1.33500
6	18.73150	8.192927	13	3.51859	2.39396	20	1.71545	1.35607
7	23.57232	7.72758	14	4.11987	1.88993			

2.3에서 보면 실제로 표준 편차가 18을 넘어서면서부터 1.5이하로 떨어짐을 볼 수 있다. 이 수치는 가장 큰 파워 스펙트럼을 갖는 2하모닉의 표준 편차에 비해 약 8% 정도이고 또 평균도 2하모닉에 비해 약 3%에 불과하므로 전체 패턴의 대표 패턴이 되는 특징이 없는 것으로 무시할 수 있다. 즉 하모닉 18에서부터 각 패턴사이의 차이가 명확하지 않으므로 잡음성분으로 간주할 수 있다. 그러므로 본 연구에서는 1~17사이의 주파수 하모닉만을 특징벡터로 추출하였다.

#### 2.4 불변특징벡터의 정규화

본 절의 내용은 추출된 특징벡터를 인식 시스템의 입력값으로 알맞게 정규화하는 것이다. 1~17하모닉 사이의 파워 스펙트럼값들을 가공하지 않고 식별기의 입력값으로 사용할 경우 Fuzzy ART 인식 시스템은 경계값 0.96의 값에서 9종의 비행기를 식별할 수 있었다. 그러나 잡

음 추가시와 경계값 변동시에는 식별 능력이 급격히 떨어지는 현상을 보였다. 그러므로 위의 특징벡터들에 대한 정규화 과정이 필요하다.

인식에 사용되는 패턴의 특징값으로 추출된 불변특징 벡터는 각 하모닉에 대한 파워 스펙트럼의 분포를 상대비교평가한 것이다. 이 값은 여러 입력패턴에 대해 하모닉별로 각기 다른 분포를 한다. 그림 2.6은 3개의 서로 다른 비행기에 대한 불변특징벡터를 하모닉에 대해 격은 선 그래프로 표현한 것이다. 이 그림에서 각 비행기의 파워 스펙트럼은 비슷한 경향을 나타내고 있다. 아는 하모닉간의 크기 불변인 특징벡터를 구하는 과정에서 전체 파워 스펙트럼의 합을 기준으로 모든 하모닉에 대해 동일한 평가기준을 적용한 결과이다. 이러한 평가기준보다 하나의 하모닉에 대한 패턴간의 차를 크게 하도록 하모닉별 독립 평가기준을 적용하여 각 하모닉의 값을 0과 1사이의 값으로 하는 방법이 있다. 이를 불변특징벡터의 정

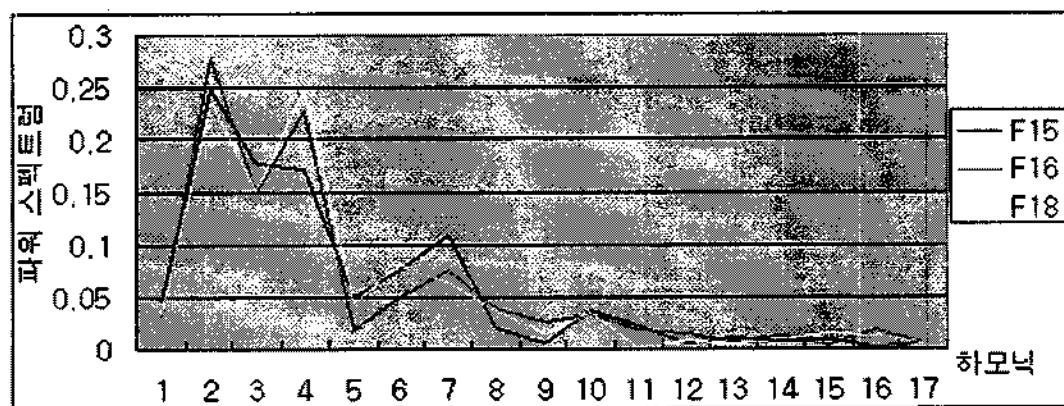


그림 2.6 초기 파워 스펙트럼 그래프

규화라 한다. 그림 2.7은 그림 2.6에 표현된 동일한 비행기에 대한 정규화된 불변특징벡터값을 표현한 것이다. 그림 2.6과는 달리 3종의 비행기가 나타내는 패턴이 확연히 다름을 보여준다.

독립적으로 나타나며 하모닉 간의 어떠한 연관성도 없음을 의미한다. 이러한 가정하에  $m$ 개 하모닉에 대한 불변 특징벡터의 신뢰구간은 입력패턴의 종류별 대표 영상으로부터 다음과 같이 구해진다.

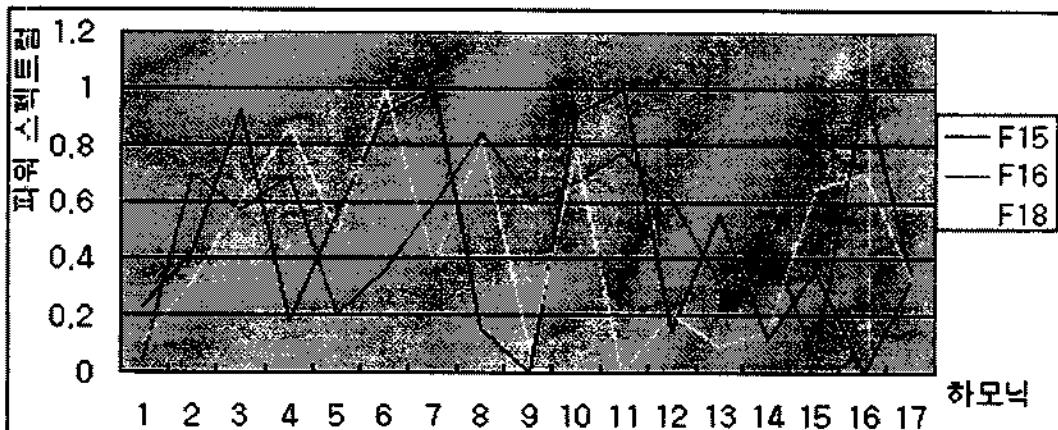


그림 2.7 정규화된 파워 스펙트럼 그래프

정규화 과정은 식 (2.10)과 같이 표현된다.

$$z = \begin{cases} ax+b & , L \leq x \leq U \\ 1 & , x > U \\ 0 & , x < L \end{cases} \quad (2.10)$$

이 식에서  $a, b$ 를 결정하기 위해 입력패턴에 대한 모평균의 신뢰구간 개념을 적용한다. 정상적인 입력패턴으로부터 얻어진 불변특징벡터값은 평균을 중심으로 확률분포를 한다. 이때 대부분의 입력패턴이 포함되는 정상적인 범위의 결정은 모평균과 모분산에 의해 결정된다. 정상적인 범위의 상한값을  $U$ , 하한값을  $L$ 이라 하고 정규화된 값은 상한값에 대해 1.0을 하한값에 대해서는 0.0을 가지도록 하는  $a, b$ 는 다음과 같이 결정된다.

$$a = \frac{1}{U-L}, \quad b = \frac{-L}{U-L} \quad (2.11)$$

입력패턴을 표현하는 불변특징벡터의  $m$ 개 하모닉에 대한 값이 각기 서로 독립인 분포를 있다고 가정할 때, 이 가정은 매 입력패턴의 회전, 크기변화, 위치이동, 잡음 등의 변화에 의한 불변특징벡터의 변화가 패턴에 관계없이

$n$ 개의 대표패턴에 대한 불변특징벡터  $f_j$ 가 주어졌을 때 입력패턴의 불변특징벡터에 대한 모평균벡터  $\mu_f$ 의 신뢰구간은  $f_j s^2$ 와  $t$ -분포 함수에 의해 식 (2.12)와 같이 구해진다.

$$\begin{aligned} L &= \bar{f} - t_{\alpha/2, n-1} \sqrt{\frac{s^2}{n}} \\ U &= \bar{f} + t_{\alpha/2, n-1} \sqrt{\frac{s^2}{n}} \end{aligned} \quad (2.12)$$

$$\text{단, } \bar{f} = \frac{1}{n} \sum_{i=1}^n f_i, \quad s^2 = \frac{1}{n-1} \sum_{i=1}^n (f_i - \bar{f})^2$$

구해진 모평균 신뢰구간의 상한값과 하한값을 식 (2.10)에 대입하면 정규화된 벡터는 식 (2.13)으로 표현된다.

$$z = (z_1, z_2, \dots, z_j, \dots, z_m) \quad (2.13)$$

$$\text{단, } z_j = \begin{cases} 0.5 + \sqrt{n}(f_j - \bar{f})/2t_{\alpha/2, n-1}s_j & , L \leq f_j \leq U \\ 0 & , L > f_j \\ 1 & , U < f_j \end{cases}$$

식 (2.13)은 신뢰구간의 상한값에 해당하는 입력패턴의

하모닉을 1.0으로 하한값을 0.0으로 평하는 특성을 지니고 있다. 즉 하모닉별 입력패턴이 0과 1 사이에 분포하도록 한 것이다. 이는 Fuzzy ART 인식시스템의 분류 방법이 기본적으로 입력벡터의 거리차를 이용하는 것이므로 그림 2.6과 2.7의 경우와 같이 분류능력을 향상시키는 효과를 가져온다.

그리고 이 방법은 잡음제거의 효과도 가지고 있다. 유의수준을 조절함에 따라 입력패턴의 정상범위를 좁힐거나 넓힐 수 있는데, 이는 입력패턴이 대표패턴과 다르게 나타나는 허용정도를 결정하는 수준이된다. 즉 유의수준을 높이면 잡음의 허용을 적게 하는 결과를 가져오고 이는 정당한 패턴의 변화 정보를 제거하는 오류를 낳게 된다. 반면 유의수준을 너무 낮추면 대부분의 입력을 허용하게 되어 입력패턴간의 차이가 적게 표현되는 단점이 있다. 그림 2.6은 정규화되지 않은 파워 스펙트럼에 대한 그라프이고 그림 2.7은 유의수준 0.01수준에서 정규화된 파워 스펙트럼의 그래프이다. 두 개의 그림에서 볼 수 있는 것처럼 무정규화된 그래프의 경우 비행기의 종류를 분류하기 어렵지만 정규화된 파워 스펙트럼의 경우 비행기의 종류가 그래프상으로도 육안 식별이 가능함을 알 수 있다.

### 3. Fuzzy ART를 이용한 인식 시스템 구현

#### 3.1 인식 시스템의 개요

인식 시스템이란 미지의 대상 패턴이 입력되었을 때, 그 패턴이 어떤 것인지를 판별하는 시스템이다. 패턴인식 시스템의 목적은 미리 관측된 데이터를 가공하여 식별에 필요한 정보 체계를 만든 후, 그 정보에 근거하여 실제로 측정된 데이터와 가장 유사한 측정치의 값을 찾아서 패턴을 식별 및 분류하는 일이다. 따라서 패턴인식 시스템의 식별 능력이 시스템의 성능을 결정한다고 할 수 있다. 일반적으로는 인식 시스템의 학습속도가 빠르면서 동시에 높은 식별 능력을 보장할 때 좋은 시스템이라 할 수 있다. 초기의 패턴인식에서는 통계적인 방법과 구문론적인 방법 등이 주로 사용되어 왔으나, 현재는 대부분의 인식 시스템에서 인간의 두뇌 활동에 근거한 신경망 이론을 사용하고 있다. 그리고 이러한 신경망을 이용한 패턴인식 시스템은 문자인식과 음성인식, 영상처리 등의 여러

분야에서 성공적인 결과를 얻고 있다[15].

현재 가장 많은 분야에서 응용되고 있는 신경망 모델은 역전파(Backpropagation) 학습 규칙을 사용하는 다층 퍼셉트론 모델이며 그밖에 흡필드(Hopfield) 신경망, Kohonen의 SOFM(Self Organizing Feature Map) 등이다.

본 연구에서는 유연 생산 자동화에 사용이 가능한 즉, 복잡하고 다변화하는 공장에서 자동화 시스템 구축시에 가장 적합한 신경망 모델로서, 온라인상으로 빠르게 학습할 수 있고 과거의 학습된 내용을 기억하면서 새로운 내용을 계속하여 학습하고, 정보를 축적해 나갈 수 있는 Fuzzy ART(Adaptive Resonance Theory) 신경망 모델을 사용하였다.

#### 3.2 ART 신경망 모델

##### 3.2.1 ART 모델의 개요

ART 신경망 모델은 1976년에 S. Grossberg에 의해 처음으로 제안된 후에, 1987년에 S. Grossberg와 G. Carpenter 부부에 의해 ART1이라는 구체적인 모델로 발전하여서 최근까지 활발하게 연구가 진행되고 있는 분야이다[2][4][5][6][7][8][13].

ART 모델과 기존의 다른 신경망들과의 가장 큰 차이점은 ART 구조는 있을 수 있는 불안정(Nonstationary) 환경에서 자신의 기억 용량을 전부 소모할 가지 패턴의 연속적인 입력에 대해 실시간으로 빠르고 안정되게 배울 수 있는 구조라는 점이다. 다른 신경망 모델들은 이러한 환경에서 불안정하게 되거나 선택된 패턴의 입력에 대해 조정된 안정(Stationary) 환경에서 비실시간으로 학습되어야 한다. 예를 들어 자기 안정화하지 않은 신경망의 경우 제한되지 않은 너무 많은 입력들이 주어지면 새로운 학습이 기존의 학습된 기억을 전부 지워버리고 처음부터 새로운 학습을 시작하게 된다. 이것을 방지하기 위해 다른 신경망에서는 입력 패턴의 수를 제한하거나 학습된 기억이 지워지기 전에 학습을 멈춘다[5].

그러나 입력 패턴의 수를 제한하는 것은 많은 실시간 응용에서 가능하지 않다. 특히 자체 안정화가 없는 시스템에서는 어떻게 입력 패턴이 유사한지 또는 새로운 것인 지의 여부를 외부 교사에 의해 지시를 받아야 한다. 따라서 자체 안정화가 없는 신경망 모델은 외부 교사가

없는 환경에서 자발적으로 학습이 이루어지지 않는다. 외부 교사를 필요로 하는 신경망에서는 학습 과정이 기대되는 출력과 실제 출력사이의 오차에 의해 이루어진다. 이러한 방법은 정해진 환경에서 느린 속도로 학습이 이루어지게 된다. 만약 학습 속도를 빠르게 하게되면 불안정한 발전을 하거나 국부 최소화(Local minima)에 빠지기 쉽다. SA(Simulated Annealing)이나 Boltzman Machine은 이러한 국부 최소화를 방지하고 전역 최소화(Global minima)를 얻기 위해 내부 시스템 잡음을 사용하고 외부에서 이 과정을 조절하는 매개 변수를 사용한다[9]. 대조적으로 ART 모델은 불일치가 아닌 근사 일치(Accurate match)에 의해 학습이 이루어진다. 이것은 빠르고 안정된 학습을 가능하게 하면서 외부의 잡음에 대해 시스템의 기억 부분을 보호한다[5].

그 동안 ART 모델을 여러 가지 형태로 변형하거나 확장하기 위한 연구가 많이 진행되어 왔다. ART1은 0과 1의 이진값만을 처리하기 위한 가장 간단한 모델이며, ART2는 아날로그값을 처리할 수 있는 모델이다. ART3은 부분적으로 압축되거나 분산된 패턴인식 코드에 대한 병렬 탐색이 가능한 모델로 ART1이나 ART2에 비해 시냅스 동작에 가깝다. 그리고 ART1을 상하나 좌우로 연결하여 지도학습(Supervised learning) 형태로 구성한 것이 ARTMAP이며, 페지 이론을 ART1 모델에 적용하여 아날로그와 이진 데이터를 모두 처리할 수 있도록 한 모델이 Fuzzy ART이다. 또한 ARTMAP에 Fuzzy ART를 적용하여 만든 Fuzzy ARTMAP도 등장하였다[2][4][5][6][7][8][13].

### 3.2.2 ART1 모델의 기본구조

ART1 모델의 기본적인 구조는 주의 서브시스템(Attentional subsystem)과 적응 서브시스템(Orienting subsystem)으로 구성되어 있다. 주의 서브시스템은 학습된 패턴과 유사한 입력에 대하여 기존의 안정된 내부의 상태를 유지하고, 유사성이 없는 입력에 대해서는 적응적으로 반응하여 새로운 카테고리를 생성하지는 못한다. 적응 서브시스템은 입력 패턴에 대한 경계값 검사(Vigilance test)를 하여 유사한 패턴의 경우에는 주의 서브 시스템이 정상적으로 작동하도록 하고, 유사하지 않은 패턴의 경우에는 주의 서브 시스템을 차단시켜, 새로운 카테고리

가 생성되도록 한다. 따라서 ART1 모델은 새로운 입력 패턴과 카테고리로 기억된 패턴과의 유사도에 따라 기존의 카테고리에 포함하거나 또는 새로운 카테고리를 생성한다.

주의 서브시스템은 비교층(Comparison layer) F1과 인식층(Recognition layer) F2로 구성되는데 단기 메모리인 STM(Short Term Memory)에 활성화된 패턴을 저장한다. 그리고 F1층과 F2층 사이에 존재하는 장기 메모리인 LTM(Long Term Memory)에는 학습이 이루어진 패턴이 저장된다. LTM은 F1층과 F2층 사이에 상향길과 하향길로 존재하는데 상향 또는 하향 패턴들이 이길을 통과하면서 기존의 기억된 값들과 곱해진 다음, 곱해진 값의 합을 구하는 형태로 패턴을 학습한다. 이득 제어(Gain control)는 F1층이 하향 패턴과 상향 패턴을 구별할 수 있도록 해준다. 적응 서브시스템은 입력 패턴인 상향 패턴과 학습된 하향 대표패턴(Top-Down template)과의 불일치가 발생하는 경우에 F2층에 리셋 신호(Reset signal)를 보내어 F2층 노드의 활성화를 억제한다.

ART1은 경쟁학습에 의하여 자율적으로 패턴을 분류하는 신경망으로 기본 알고리즘은 다음과 같다. 신경망에 첫 번째 입력 패턴이 들어오면 그 입력을 첫 번째 카테고리로 학습한다. 그후에 두 번째 입력 패턴이 들어오면 첫 번째 카테고리와의 거리를 비교하여 사전에 주어진 경계값(Vigilance value)보다 작으면 첫 번째 카테고리로 분류하고 그렇지 않으면 두 번째 카테고리로 분류한다. 그 다음 입력 부터는 입력값들이 경쟁학습을 통하여 자신의 카테고리를 정하고 그 카테고리와의 거리 값과 경계값을 비교하여 새로운 카테고리를 만들거나 기존의 카테고리에 포함되도록 한다. 따라서 ART1 모델은 위의 과정을 반복하여 자율적으로 입력 패턴을 기본의 카테고리에 포함시키거나 새로운 카테고리로 생성되도록 한다.

### 3.2.3 Fuzzy ART 신경망의 기본구조 및 알고리즘

Fuzzy ART 모델은 ART1과 매우 유사한 특징을 갖는다. 그 이유는 Fuzzy ART가 ART1 모델의 이진값만을 처리하기 위한 신경망 구조를 발전시켜 실수값(Analog)을 처리할 수 있도록 만들어졌기 때문이다. 예를 들면, ART1에서 사용되는 논리합 연산자  $\wedge$ 를 벼지 집합 이론의 최소화 연산자  $\wedge$ 로 대체하여 사용함으로써 페지 연산자가

갖는 특성인 0과 1사이의 값을 처리할 수 있도록 하였다. 표 3.1은 ART1과 Fuzzy ART 사이의 유사성을 정리한 것으로 어떻게 Fuzzy ART의 카테고리 선택, 경계값 검사, 고속학습이 ART1과 유사한가를 보여준다.

표 3.1 ART1과 Fuzzy ART의 유사성

항목	분류	ART1	Fuzzy ART
카테고리 선택		$T_j = \frac{ I \cap W_j }{\alpha +  W_j }$	$T_j = \frac{ I \wedge W_j }{\alpha +  W_j }$
경계값 테스트		$\frac{ I \cap W_j }{ I } \geq \rho$	$\frac{ I \wedge W_j }{ I } \geq \rho$
고속 학습		$W_j^{(new)} = I \cap W_j^{(old)}$ CAP: 논리합 연산자	$W_j^{(new)} = I \wedge W_j^{(old)}$ $\wedge$ : 폐지 최소값 연산자

Fuzzy ART의 기본적인 구조는 입력층인 F0 층, 비교층인 F1 층, 출력층인 F2 층으로 구성되어 있다. 입력층(F0)에서는 입력되는 값들에 대한 전처리를 해준다. 즉, 입력벡터의 실수값들을 Fuzzy ART에 알맞게 0과 1사이의 값으로 변환하는 작업이 수행된다. 또한, 필요한 경우에 상보 부호화(Complement coding)와 작업도 이루어진다. 비교층(F1)과 출력층(F2)에서는 ART1에서와 같은 작업이 이루어진다. 차이점은 앞 절에서 설명한 바와 같이 논리합 연산자( $\cap$ )가 폐지 집합 이론의 폐지 최소값 연산자( $\wedge$ )로 바뀐다는 것이다. Fuzzy ART의 기본적인 구조는 그림 3.1과 같다.

다음은 Fuzzy ART의 알고리즘이다.

#### 〈단계 1〉 매개변수(Parameter)의 값 초기화

선택 매개변수  $\alpha > 0$

학습률(Learning Rate) 매개변수  $\beta \in [0, 1]$

경계값 매개변수  $\rho \in [0, 1]$

#### 〈단계 2〉 연결 강도(Weights) 초기화

각각의 F2층의 카테고리 노드  $j(j=1, 2, 3, \dots, N)$ 에 대하여, LTM 또는 연결강도 벡터  $w_j(w_{j1}, w_{j2}, \dots, w_{jM})$ 의 값을 초기화한다.

#### 주의 서브 시스템 적용 서브 시스템

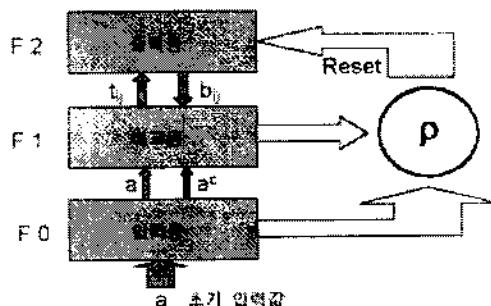


그림 3.1. Fuzzy ART의 기본구조

$$w_{ji}(0) = w_{j1}(0) = \dots = w_{jM}(0) = 1$$

F2층의 카테고리는 초기에는 비수용(Uncommitted)되었다고 한다. 그리고 첫 번째 입력에 의해서 첫 번째 카테고리가 부호화(Coding)되면 수용(Committed)되었다고 한다. Fuzzy ART의 연결강도 벡터, 또는 원형(Prototype) 벡터는  $w_j$ 는 ART1의 상향 연결강도 벡터( $b_j$ )와 하향 연결강도 벡터( $t_j$ )를 모두 포함하게 된다.

#### 〈단계 3〉 입력 벡터의 초기화

원시 입력 데이터가 들어왔을 때, 그 값을 Fuzzy ART의 입력 데이터 형식에 맞도록 0과 1사이의  $a = (a_1, a_2, \dots, a_M)$  벡터 입력값으로 변환해야 한다. F0 층에서는 아래 식(3.8)과 같이 실질적인 상보 부호화를 통해 원래 입력값을 입력 벡터 I로 변환한다.

$$I = (a, a^c) = (a_1, a_2, \dots, a_M, a_1^c, a_2^c, \dots, a_M^c) \quad (3.8)$$

여기에서  $a_i^c = 1 - a_i$ 이고 상보 부호화 입력 벡터 I는 2M차원을 갖는다.

#### 〈단계 4〉 카테고리 선택

각 입력 벡터 I에 대하여 F2층의 노드  $j$ 의 선택함수  $T_j$ 는 다음과 같이 구해진다.

$$T_j(I) = \frac{|I \wedge W_j|}{\alpha + |W_j|} \quad (3.9)$$

$$(a \wedge b)_j = \min(a_j, b_j), \quad |p_j| = \sum_{i=1}^M |p_{ij}|$$

최종적인 카테고리의 선택은 식 (3.9)에서 구한  $T_j$  중에서 최대값을 갖는 노드  $j$ 가 된다.

$$T_j = \max\{T_j : j = 1, 2, \dots, N\} \quad (3.10)$$

선택된 최대값  $T_j$  중에서 2개 이상이 같을 경우,  $j$ 의 값이 작은 순서로 선택한다.

**〈단계 5〉 적응공명(Resonance) 또는 재설정(Reset)**  
적응공명은 선택된 카테고리 노드에 대해 다음의 경계값 검사를 만족하면 발생한다.

$$\frac{|I \wedge W_j|}{|I|} \geq \rho \quad (3.11)$$

적응공명이 발생한 상태에서만 Fuzzy ART는 입력값에 대한 학습을 진행한다.

재설정은 식 (3.11)의 경계값 검사를 만족하지 않은 경우에 선택된 카테고리가 입력 패턴과 서로 다르기 때문에 새로운 카테고리를 다시 선택하도록 하는 과정이다. 시스템은 재설정이 발생할 경우 선택된 카테고리에 대한  $T_j$ 값을 0으로 설정한다. 그리고  $T_j$ 를 제외한 다른 노드 중에서 단계 3의 카테고리 선택을 통하여 새로운 카테고리를 선택하고 경계값 검사를 실시한다. 선택된 카테고리가 경계값 검사를 만족하면 적응공명 상태가 되어 다음 단계인 학습으로 넘어간다. 수용된 모든 카테고리를 탐색했을 때, 경계값 검사를 만족하는 카테고리가 존재하지 않으면 새로운 카테고리를 생성하고 〈단계 3〉으로 돌아가서 입력값을 받는다.

### 〈단계 6〉 학습

학습은 적응공명의 상태에서 발생하고 다음의 식과 같다.

$$w_j^{(\text{new})} = \beta(I \wedge w_j^{(\text{old})}) + (1 - \beta)w_j^{(\text{old})} \quad (3.13)$$

$\beta=1$ 인 경우에는 고속학습(Fast learning)을 하고,  $0 < \beta < 1$ 인 경우에는 저속학습(Slow learning)을 한다. 만약 임의의 노드가 사전에 입력 패턴에 의해 선택되어 관련된

연결강도가 학습이 되었으면 이 노드는 수용되었다고 하고, 노드가 사전에 입력 패턴에 의해 선택된 적이 없으면 비수용되었다고 한다. 학습이 완료되면 〈단계 3〉으로 되돌아가서 새로운 입력 패턴을 받는다.

F2층의 수용된 노드로부터 연결된 하향 연결강도 벡터를 대표 패턴이라 부른다. 입력 패턴들은 훈련을 통해 유사성이 있는 패턴 그룹 즉 카테고리로 분류가 되는데, 이를 카테고리를 대표하는 것이 대표 패턴이다. 입력 패턴들의 그룹이 반복적으로 제공되어 더 이상 연결강도의 값이 변경되지 않을 때, 연결강도는 안정되고 학습은 끝이 난다. 학습이 끝난 후 사전에 훈련된 입력 패턴이 다시 제공되면 곧바로 F2층의 노드가 선택되고 연결강도의 갱신은 발생하지 않는다. 앞의 상황에서 새로운 입력 패턴이 제공되어 F2층의 선택된 노드가 사전에 수용되지 않은 노드이면, 새로운 카테고리가 형성되고 이미 형성된 카테고리에는 영향을 주지 않는다. 또한 선택된 노드가 사전에 수용된 노드일 경우에는 선택된 카테고리만 학습이 이루어지고 다른 카테고리에는 영향을 주지 않는다.

## 4. 실험 및 고찰

### 4.1 실험 시스템 및 자료 구성

본 연구의 실험 시스템의 구성은 다음과 같다. 먼저 영상을 획득하기 위한 입력부와 획득된 아날로그 영상을 디지털 영상으로 변환하여 저장하는 비전 보드와 인식 시스템으로 이루어진 식별부이다. 입력부에서는 CCD 카메라를 이용하여 영상을 획득하고 식별부에서 Raptor 영상 처리 보드를 통하여 디지털 영상으로 변환한 후에 인식 시스템으로 영상을 전송한다. 인식 시스템은 영상의 이진화와 윤곽선 추출, 불변 특징 벡터의 추출과 정규화. 그리고 Fuzzy ART를 이용한 인식을 담당한다. Fuzzy ART에서는 선택 매개변수  $\alpha$ 값은 0.1로 하였고, 학습률  $\beta$ 값은 1로 하여 고속학습을하도록 하였다. 시스템 하드웨어로는 Raptor 영상처리 보드를 부착한 팬티엄150 PC를 사용하였다.

실험 자료는 동일한 영상에 대한 반복 실험과 다양한 실험이 가능하도록 CCD 카메라를 이용하여 획득한 영상 데이터를 윈도우95 운영체제에서 사용하는 BMP형식의 파일로 변환하여 저장하였다. 실제로 실험에 사용한 9종

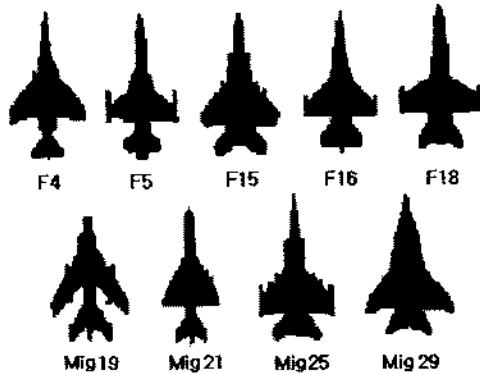


그림 4.1. 실험에 사용된 비행기

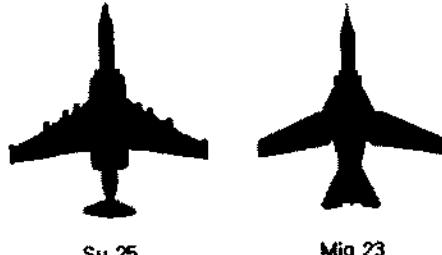


그림 4.2. 추가된 비행기



후크 스패너



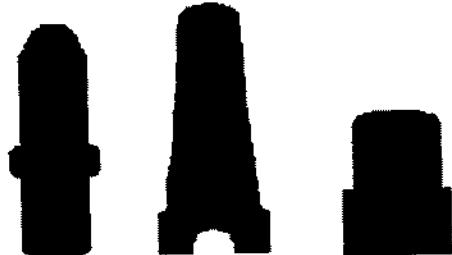
튜브 커터



단구 스패너



양구 스패너



철형편치 나사편치

원형편치



자석호무

돛도편치 삼발편치

그림 4.3. 실험에 사용된 공구류

의 비행기는 그림 4.1과 같다. 본 연구에서 비행기를 실현 대상으로 선택한 이유는 비행기가 크기 변화가 심하고 이동 방향 또한 일정하지 않아 회전 변형이 심하므로 본 연구의 실험 대상으로 선정되었다. 그리고 비행기 외

에도 스캐너, 커터, 편치등의 공구류가 실험 대상으로 선정되었다.

본 연구에서는 그림 4.1의 비행기에 대해서 각각 0.6, 0.8, 1.5, 2.0씩 4번의 크기변환과 30dB, 35dB, 40dB씩 3

번의 잡음 추가, 그리고 30도씩 12번의 회전 변형을 추가한 총 1296(3잡음×4크기×12회전×9종류)개의 영상 패턴을 시스템을 훈련시키기 위한 실험 데이터로 사용하였다. 그리고 시스템이 안정된 후에 새로운 입력 패턴에 대해 안정된 학습을 하며 안정된 식별 능력을 온라인 상으로 얻을 수 있는지를 실험하기 위한 대상으로 Su-25와 Mig23 비행기를 선정하였다. Su-25와 Mig 23은 그림 4.2에 나타나 있다. 마지막으로 11개의 비행기에 대한 학습을 완료한 후에 재학습 실험을 위해 1440개(3잡음×4크기×12회전×10종류)의 공구류 데이터를 수집하였다. 실험에 사용된 공구류의 영상은 그림 4.3에 나타나 있다.

#### 4.2 인식률 및 학습 속도 실험

본 연구에서는 Fuzzy ART를 이용한 인식 시스템의 입력값으로 FFT 변환을 이용하여 구한 주파수 도메인상의 각 하모닉에 대한 파워 스펙트럼을 정규화 한 값을 사용하였다. 표 4.2에서는 정규화 과정을 거치지 않고 0과 1 사이의 값으로 변환을 한 후에 Fuzzy ART 인식 시스템에 입력한 경우와 정규화를 하여 입력한 경우에 대한 비교이다. 결과를 살펴보면 입력값에 대해 정규화한 경우에 전체적인 특징과 함께 각 하모닉 대별로 패턴간의 차이를 증가시켜주기 때문에 0.56의 경계값에서 99.2%의 높은 인식율을 보이게 되었다. 그리고 무정규화의 경우 0.99의 경계값에서 96.9%의 인식율을 보이게 되었다. 그러나 이 경우에는 0.99의 경계값을 찾는데 28회의 반복 실험이 필

요하게 됨을 알 수 있고 또한 경계값의 크기의 변화에 따라 인식율이 급격히 변화함을 알 수 있다. 그러나 정규화를 거친 입력값에 대하여 0.5~0.6 사이의 어떤 값에 대해서도 94% 이상의 높은 인식율 가지고 갖게 됨을 알 수 있다. 또한 각각의 경계값에서 한번의 반복(Epoch)으로 모든 학습이 이루어짐으로 정확한 경계값에 대한 정보가 주어지게 되면 한번의 반복으로 모든 패턴에 대한 학습을 완료하게 된다. 본 실험에서는 경계값을 0과 1사이의 중간값인 0.5를 기준으로 하여 각 패턴에 대한 식별 능력이 없을 때는 0.02씩 증가시켜 가면서 실험을 하고, 각 패턴에 대한 식별 능력은 있으나 잡음에 약하여 같은 패턴에 대해 식별 오류가 존재하는 경우에는 0.02씩 감소하면서 실험하였다. 즉 입력 패턴의 종류보다 적은 수의 출력노드가 생성되면 0.02씩 증가시키고, 더 많은 수의 출력노드가 생성되면 0.02씩 감소시킨다. 그리하여 가장 높은 인식율을 갖는 경계값에서 0.01을 증가 및 감소시켜서 인식율을 구한 후에, 최고 인식율을 갖는 경계값을 최적 경계값으로 정하였다.

표 4.1에 나타난 Fuzzy ART를 이용한 인식 시스템의 속도와 인식율을 살펴보면 학습 시에 올바른 경계값을 찾은 후에는 한번의 반복으로 99% 이상의 인식율을 얻게 됨을 볼 수 있다. 이는 지도학습을 하는 BPN (Backpropagation Neural Network)의 경우에 최적해를 찾는 과정 까지 100회 이상의 반복실험이 필요한 것과 비교할 때, 상대적으로 빠른 학습속도를 갖게 됨을 의미한다. 또한 무

표 4.1. 입력값의 무정규화와 정규화시 인식률 비교

반복횟수 (경계값)	무정규화 (%)	반복횟수 (경계값)	정규화 (%)
1 ( $\rho=0.50$ )	0.0	1 ( $\rho=0.50$ )	94.8
22 ( $\rho=0.92$ )	0.0	2 ( $\rho=0.52$ )	96.7
23 ( $\rho=0.94$ )	22.2	3 ( $\rho=0.54$ )	97.1
24 ( $\rho=0.96$ )	44.4	4 ( $\rho=0.56$ )	99.2
25 ( $\rho=0.98$ )	87.97	5 ( $\rho=0.58$ )	98.7
26 ( $\rho=1.00$ )	0.67	6 ( $\rho=0.60$ )	97.3
27 ( $\rho=0.97$ )	66.7	7 ( $\rho=0.55$ )	97.8
28 ( $\rho=0.99$ )	96.9	8 ( $\rho=0.57$ )	98.7

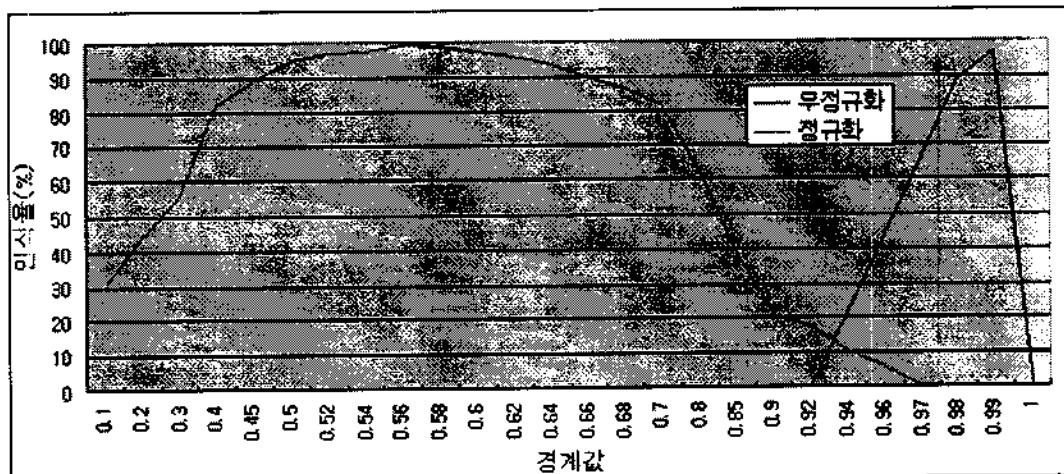


그림 4.4. 무정규화와 정규화의 안정된 인식률 범위 비교

정규화와 정규화시의 인식률에 대한 안정적인 경계값의 범위를 살펴보면 그림 4.4와 같다. 입력 패턴 데이터에 대한 정규화를 한 경우에는 그림에서처럼 0.48~0.66의 넓은 범위에서 90% 이상의 높은 인식률을 보이고 있다. 그러나 무정규화의 경우에는 경계값 0.99에서 90% 이상의 높은 인식률을 보이지만 그 밖의 범위에서는 인식률이 90% 이하로 급격히 감소함을 알 수 있다.

다음 표 4.2는 스캐너와 커터, 편치 등의 공구류에 대한 개발된 인식 시스템의 실험 결과이다. 스캐너의 경우 4가지 종류에 대해 0.58~0.8의 경계값에서 100%의 인식율을 보이고 있다. 그리고 편치의 경우도 6개의 종류에 대해 0.48의 경계값에서 역시 100% 인식율을 보이고 있다.

#### 4.3 인식 시스템이 안정된 후의 새로운 패턴에 대한 재학습

본 실험에서는 먼저 9대의 비행기를 학습하여 안정된 인식 시스템에 Su-25 비행기 한 대를 추가하여 인식 시스템을 가동하였다. 그 결과는 표 4.3과 같다. 표 4.3을

보면 시스템이 아무런 수정 없이 그대로 사용되면서 Su-25에 대한 학습이 온라인 상으로 진행되면서 패턴이 분류됨을 알 수 있다. 또한 Su-25에 대한 학습 후에 다시 Mig23을 다른 10대의 비행기와 함께 시스템에 입력하였다. 그 결과 기존의 시스템이 Mig23에 대해서도 온라인 학습과 동시에 Mig23에 대한 분류를 함을 알 수 있다.

다음으로 본 연구에서는 Su-25과 Mig23에 대한 재학습을 완료한 인식 시스템에 다시 스캐너(4종류)와 편치(6종류)의 입력 데이터를 기존의 11대의 비행기 패턴에 대한 데이터와 함께 입력하였다. 그 결과는 표 4.4와 같다. 표 4.4를 보면 전혀 새로운 종류의 패턴이 입력되는 경우에도 인식 시스템의 수정 없이 각 패턴을 식별하고 그 패턴에 대한 학습이 이루어짐을 볼 수 있다.

마지막으로 무정규화시에 대한 재학습의 결과를 살펴보면 무정규화시에는 새로운 공구가 추가되면 90%이하의 인식률로 떨어짐을 볼 수 있다. 무정규화와 정규화의 재학습의 결과가 다른 이유는 앞의 그림 4.4에서 보는 것처럼 정규화시에는 넓은 경계값의 범위에서 90%

표 4.2. 공구류에 대한 실험 결과

종류 (개수)	반복 횟수	경계값 (%)	최고 인식률	입력 노드
스캐너 (4개)	4	0.58 ~ 0.8	100 %	12개
편치 (6개)	5	0.48	100 %	14개

표 4.3. 비행기를 추가한 경우의 실험 결과

추가된 패턴	종류의 개수	반복횟수	경계값 ( $\rho$ )	최고 인식율(전체)
Su-25	10	1	0.56	99.31 %
Mig 23	11	1	0.56	99.37 %

표 4.4. 공구류를 추가한 경우의 실험 결과

추가된 패턴	종류의 개수	반복횟수	경계값 ( $\rho$ )	최고 인식율(전체)
펀치(6종류)	17	1	0.56	94.1 %
스캐너(4종류)	15	1	0.56	94.5 %

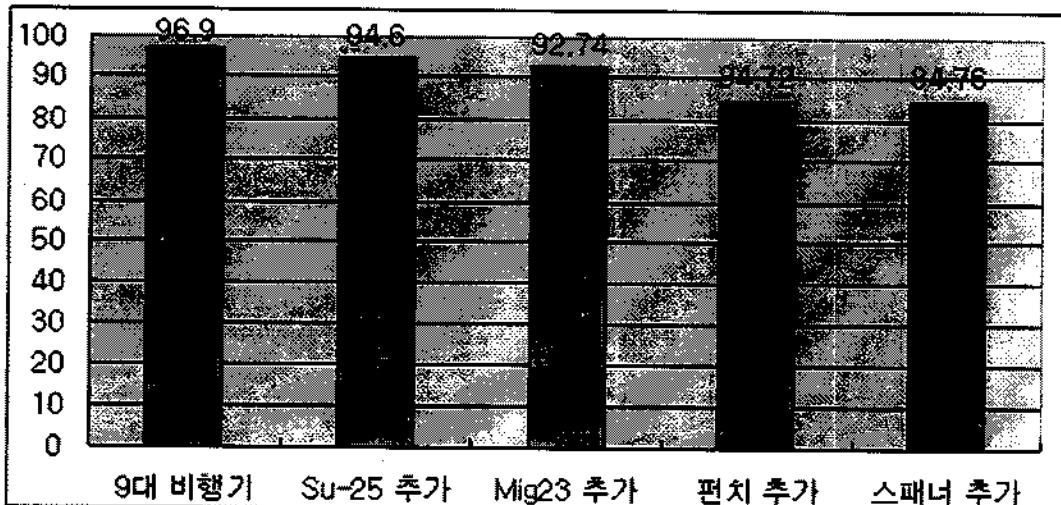


그림 4.5. 무정규화시 추가된 패턴에 대한 재학습 인식율 실험 결과

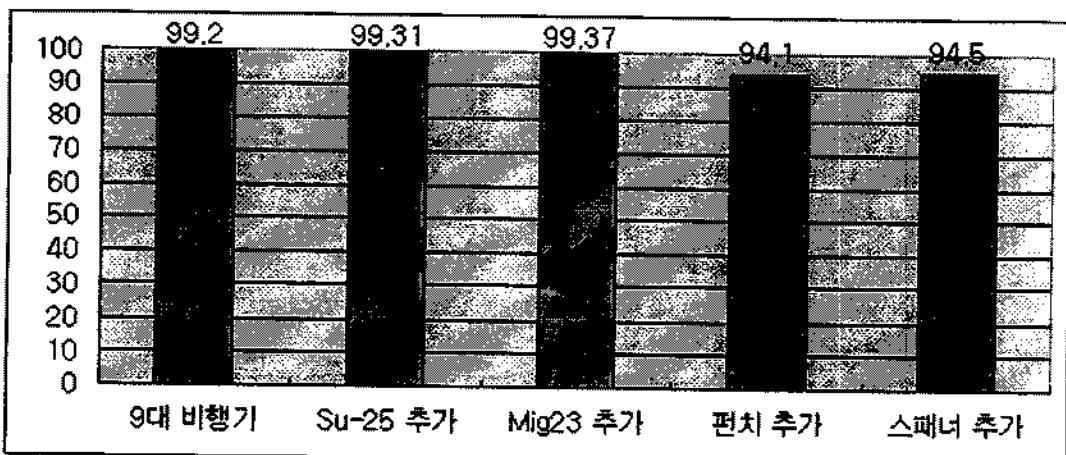


그림 4.6. 정규화시 추가된 패턴에 대한 재학습 인식율 실험 결과

이상의 높은 인식율을 보이지만 무정규화시에는 아주 좁은 범위의 경계값에서 인식율이 90%를 넘어가기 때문에 비행기와 전혀 다른 공구류가 추가 될시에 인식율이 90%이하로 저하됨을 알 수 있다. 다음 그림 4.5는 무정규화시에 재학습 결과를, 그림 4.6은 정규화시에 재학습의 결과를 나타낸 것이다.

## 5. 결론 및 향후과제

본 연구에서는 패턴인식 시스템이 유연 생산 자동화에 현실적으로 사용될 수 있는 방법에 대한 연구를 수행하였다. 다양한 실험 결과가 보여주는 것처럼 실제 공장에서 발생할 수 있는 기하학적인 물체의 변형, 인식해야 할 대상 물체의 종류의 추가, 실시간 인식, 그리고 잡음 등이 발생되는 다양한 환경에서 본 시스템은 적용될 수 있음을 보여 주었다.

패턴의 불변특징벡터를 찾기 위한 방법으로 이진화와 윤곽선 추출시에 가장 간단하고 쉽게 구현되는 일반적인 방법들을 사용하였으며, 불변인 특징벡터를 추출하기 위해서도 역시 가장 일반적으로 사용되는 FFT를 이용한 스펙트럼 분석을 사용하였다. 그러나 기존연구와는 달리 축출된 데이터를 정규화하는 방법을 이용함으로써 불변특징벡터를 찾는 획기적인 방법을 제안하였다. 또한 인식 단계에서는 Fuzzy ART를 이용하여 물체의 종류 변화에 상관없이 실시간으로 인식 시스템이 적용될 수 있도록 하였다. 본 연구에서 실험한 비행기의 경우에 최적 경계값을 찾는데 8회의 실험을 해야 했지만, 최적 경계값을 찾은 후에는 한번의 반복으로 99.2%의 인식율을 달성할 수 있었다. 그리고 학습이 완료되어 사용중인 인식 시스템에 새로운 비행기가 추가되어도 그 인식율이 떨어지지 않음을 볼 수 있다. 그리고 정규화를 한 경우에 비행기와 전혀 다른 패턴인 스캐너와 편치의 경우에도 그 특징벡터의 크기가 같지 않음에도 불구하고 새로 입력되었을 때, 그 물체에 대해 인식이 가능함을 보여주었다. 그리고 전혀 새로운 종류의 패턴들이 입력되어도 인식율이 94%이상을 유지함을 볼 수 있었다. 그러나 무정규화를 한 경우에는 전혀 새로운 종류의 편치나 스캐너가 추가될때에 90%이하로 인식율이 떨어짐을 알 수 있다.

본 연구의 결론을 요약하면, 제안된 시스템이 기하학적인 변형과 잡음에 무관하게 패턴을 인식하고 또, 비슷한 특징을 가진 같은 종류의 패턴에 대해서는 학습이 완료된 후에도 새롭게 온라인 상으로 재학습이 가능하다는 사실과 또한 전혀 다른 새로운 종류의 패턴이 입력되었을 때에도 식별이 가능하다는 사실이다. 그러나 전혀 다른 새로운 종류의 패턴들이 4~6개 들어왔을 때 인식율이 저하됨을 볼 수 있었다.

따라서 본 연구의 향후 과제로는 Fuzzy ART 시스템이 전혀 새로운 종류의 패턴이 들어왔을 때에도 적용 가능하도록 하는 것과 기하학적인 변형에 불변인 특징벡터를 구하는 방법에서 현재의 2차원이 아닌 3차원 정보의 획득 시에 어떻게 3차원 상에서 불변인 특징벡터를 빠르고 간단하게 찾을 수 있는가 하는 것이다.

## 참고문헌

- [1] A. S. Pandya, R. B. Macy, *Pattern Recognition with Neural Networks in C++*, CRC Press Inc. 1996.
- [2] Cheng-Jian Lin and Chin-Teng Lin, "Reinforcement Learning for an ART-Based Fuzzy Adaptive Learning Control Network", *IEEE Trans. Neural Networks*, vol. 3, NO. 3, pp.709-731, 1996.
- [3] C. S. Burrus and T. W. Parks, *DFT/FFT and Convolution algorithms*, John Wiley & Sons, 1985.
- [4] G. A. Carpenter and S. Grossberg, "A massively parallel architecture for a self-organizing neural pattern recognition machine", *Computer vision, Graphics, and Image processing*, vol. 37, pp.54-115.
- [5] G. A. Carpenter, S. Grossberg and D. B. Rosen, "Fuzzy-ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system", *Neural Networks*, vol. 4, pp.759-771, 1991.
- [6] G. A. Carpenter, S. Grossberg and J. H. Reynolds, "ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network", *Neural Networks*, vol. 4, pp. 565-588, 1991.
- [7] G. A. Carpenter, S. Grossberg, and J. H. Reynolds,

- , "A Fuzzy ARTMAP Nonparametric Probability Estimator for Nonstationary Pattern Recognition Problems", *IEEE Trans. Neural Networks*, vol. 6, pp. 1330-1336, 1995.
- [8] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, "Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps", *IEEE Trans. Neural Networks*, vol. 3, pp.698-713, Sept. 1992.
- [9] J. A. Freeman and D. M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*, Addison-Wesley press, 1991.
- [10] Jeffrey Wood, "Invariant pattern recognition: A Overview", *Pattern Recognitions*, Vol. 29, No. 1, pp. 1-17, 1996.
- [11] L. Spirkovska and M. Reid, "Robust position, scale and rotation invariant object recognition", *Pattern Recognition Lett.* 15(6), 631-635, June 1992.
- [12] R. Jain, R. Kasturi, B. G. Schunck, *MACHINE VISION*, McGraw-Hill Inc., 1995.
- [13] S. Grossberg, "Adaptive pattern classification and universal recording: I. parallel development and coding of neural feature detectors", *Biological Cybernetics*, vol 23, pp.121-134, 1976.
- [14] Shuenn-shyang Wang, Wen-gou Lin, "A new Self-Organizing Neural Model for invariant pattern recognition", *Pattern Recognition*, Vol. 29, No. 4, pp. 667-687, 1996.
- [15] S. Y. Kung, *Digital Neural Networks*, Prentice-Hall Inc., 1993.
- [16] 이상경, "스펙트럴 분석 및 신경-유전자-퍼지 복합 망을 이용한 이동, 크기 및 회전 변형에 무관한 패턴인식", 고려대학교 대학원 박사학위 논문, 1996.
- [17] 일본공업기술센터, 컴퓨터 화상 처리 입문, 기전 연구사, 1993.
- [18] 장동식, 컴퓨터비전시스템의 기술현황 및 응용, ie 매거진, 4(3), 65-74, 1997.