

결정규칙의 자동생성을 위한 패턴공간의 재귀적 퍼지분할

Recursive Fuzzy Partition of Pattern Space for Automatic Generation of Decision Rules

김 봉 근*, 최 형 일*
Bong Keun Kim*, Hyeong Ill Choi*

요 약

본 논문에서는 패턴분류기를 위해 효과적인 퍼지규칙을 자동으로 생성하기 위한 새로운 방법을 제안한다. 퍼지규칙은 특징공간에 대해 가상구체를 재귀적으로 정의함으로써 추출되고, 가상구체는 패턴 클래스의 중심벡터와 클래스에 속하는 모든 패턴을 충분히 포함할 수 있는 경계거리로 정의된다.

특징공간을 분할하기 위해 가상구체를 이용하는 방법은 기존에 많이 사용되고 있는 가상사각형 형태의 분할 방법에 비해 클래스의 형태를 효과적으로 표현할 수 있으므로 패턴 분류기의 정확성을 향상시킬 수 있고, 퍼지규칙의 전제부를 매우 간단하게 표현할 수 있을 뿐만 아니라 재귀적 가상구체의 정의를 통해 추출되는 퍼지규칙들이 계층적인 구조를 갖을 수 있게 함으로써 입력되는 패턴의 신속한 분류를 가능하게 한다. 본 논문에서는 제안된 방법을 기존의 가상사각형을 이용한 퍼지규칙 추출 방법과 비교한다.

ABSTRACT

This paper concerns with automatic generation of fuzzy rules which can be used for pattern classification. Feature space is recursively subdivided into hyperspheres, and each hypersphere is represented by its centroid and bounding distance. Fuzzy rules are then generated based on the constructed hyperspheres.

The resulting fuzzy rules have very simple premise parts, and they can be organized into a hierarchical structure so that classification process can be implemented very rapidly. The experimented results show that the suggested method works very well compared to other methods.

I. 서 론

퍼지 이론은 패턴 인식 분야 뿐만 아니라 퍼지 제어(fuzzy control)등과 같은 분야에 중요한 역할을 하며 실제


* 숭실대학교 대학원 전자계산학과

※ 본 논문은 1994년도 숭실대학교 교내학술연구비 지원에 의하여 연구되었음.

응용에서는 대부분 퍼지규칙(fuzzy rule)을 이용하고 있다. 이러한 퍼지규칙은 대부분 인간 전문가(human expert)의 경험적 지식(heuristic knowledge)에 의해 수작업으로 정의되어 사용되고 있으며, 퍼지규칙을 생성하기 위해서는 특징공간(feature space)상에 분포된 자료들을 분석하고 분석된 결과를 기초로 하여 퍼지 집합을 생성하는 작업을 수행한다. 그러나 인간 전문가에 의한 퍼지규칙의 획득은 모델링하고자 하는 시스템이 매우 복잡하거나 규칙 베이스(rule base)의 갱신을 빈번히 요구하는 경우에는 그 때마다 인간 전문가가 퍼지규칙의 생성 및 갱신을 수행한다는 것은 매우 번거로운 일이 아닐 수 없다. 따라서 이러한 퍼지규칙을 자동으로 생성하는 체계적인 방법에 대한 연구가 주된 관심사가 되고 있다.

지금까지 퍼지규칙을 자동으로 생성하는 방법은 실제 수치 자료들의 학습(learning)에 의해 퍼지규칙을 생성하는 것이 대부분이다. 여기에는 신경망의 자기조정 및 학습기능을 퍼지규칙의 생성 및 조율(tuning)에 도입하는 방법과 자료 분포 공간에 대한 퍼지 군집화(fuzzy clustering)에 의해 서로 유사한 특성을 지닌 집단(cluster)들로 분할하고 각 집단에 속한 자료들의 특성을 분석하여 퍼지규칙을 생성하는 방법이 있다. 이러한 방법은 퍼지 이론과 신경망 이론의 학습 속성을 이용하는 것으로서 매우 설득력있는 방법이지만 학습과정에서 많은 계산 시간을 요구한다는 단점이 있다.

따라서 학습과정에서 요구되는 계산 시간을 줄이기 위해 단순한 형태의 공간분할 방법들[1-7]이 제안되었다. 이들 문헌에서는 퍼지규칙을 생성하기 위해 일반적으로 두 가지 단계를 거치게 된다. 첫째는 주어진 특징공간으로부터 특징 부공간으로의 분할(partition)과정이고, 두번째는 각 부공간에 대해 퍼지규칙을 확인(identify)하는 단계이다. 그러면 주어진 다차원 특징공간의 분할에 의해 생성되는 부공간(subspace)은 퍼지규칙으로 변환될 수 있다. 결국, 주어진 특징공간은 입력자료의 특성과 분포에 의해 적절히 분할되어야 하며, 분할된 부공간에 대해 효과적인 퍼지규칙의 표현이 이루어져야 한다. (그림 1)은 기존에 제안된 대표적인 공간분할 방법들을 보여 주고 있다.



(그림 1) 기존에 제안된 공간분할 방법들

(그림 1-a)는 가장 단순한 형태의 분할 방법으로서 같은 크기를 갖는 다수의 부공간으로 분할하는 방법이다. 이 방법을 이용하는 경우에는 m 차원 특징공간에 대해 얻어진 부공간의 수는 각 특징축의 분할 수 K 에 대해 K^m 개가 된다. 따라서 K 가 작으면 생성되는 퍼지규칙의 수는 적지만 분류성능이 저하될 것이고 K 가 크면 분류성능은 향

상될 수 있지만 생성될 퍼지규칙의 수가 많아진다는 문제가 있다. 결국, 어떠한 K 로도 만족할 만한 결과를 기대하기는 어렵다.

(그림 1-b)와 같은 방법[2]은 K 를 적은 수에서 큰 수로 증가시켜 가면서 공간을 분할하는 방법이다. 이 방법은 점진적세밀화(corase-to-fine) 방법으로서 분류성능이 공간분할 결과에 덜 민감하다는 장점이 있다. 그러나 이 방법은 앞의 방법에 비해 더 많은 퍼지규칙이 생성된다는 단점을 가지게 된다. 이러한 문제를 해결하기 위해 [3]과 [4]에서는 기억상실 알고리즘(forgetting algorithm)과 유전자 알고리즘(genetic algorithm)에 의해 불필요한 퍼지규칙들을 제거함으로써 어느 정도 퍼지규칙의 수를 줄이는 방법을 제시하고 있다. 그러나 그 계산과정이 매우 복잡하고 많은 시간을 요구한다는 데에 문제가 있다.

퍼지규칙의 수를 줄이고 효과적으로 특징공간을 분할하기 위해 (그림 1-c)와 같은 방법[5]이 제안되었다. 그러나 이 방법은 분할방법이 격자(grid)방식을 탈피하지 못하고 있고, 특징공간 내에 존재하는 패턴의 분포와는 무관하게 사진트리(quad-tree)방식과 유사한 방법으로 공간을 분할함으로써 분할된 부공간들이 주어진 패턴 클래스들의 형태를 정확히 묘사하지는 못한다. 그러므로 생성되는 퍼지규칙의 수는 (그림 1-d)와 같은 방법[1]에 비해 많아진다는 단점이 있다.

(그림 1-d)에서 볼 수 있는 것과 같은 방법[1]은 주어진 클래스에 속한 패턴들을 최대로 포함하는 최소 가상사각형을 활성화영역(activation region)으로 정의하고 활성화영역간에 중복이 존재하는 경우에 이 중복영역을 억제영역(inhibition region)이라고 정의하였다. 억제영역에 대해서는 더이상 억제영역이 나타나지 않을 때 까지 재귀적으로 활성화영역과 억제영역을 정의함으로써 중복을 해결하기 위한 방법을 제시하였다. 이 방법은 퍼지규칙을 자동으로 획득하기 위해 신경망을 이용하는 방법보다 효과적이고 보다 신속한 학습이 가능한 것으로 생각 된다.

생성된 퍼지규칙은 각각에 대응되는 부공간을 표현하고 있으므로 입력된 패턴이 어느 부공간에 속하는지를 확인하는 것은 퍼지규칙을 이용하여 패턴을 분류하는 문제와 동일하다. 그러나 생성된 퍼지규칙의 수가 많은 경우에 패턴을 분류하기 위해 모든 퍼지규칙을 일일이 적용하는 것은 비교적 빠른 결정을 요구하는 패턴인식과 같은 응용분야에 적합하지 못하다. 따라서 퍼지 패턴 분류기는 입력된 패턴을 가급적 빠르고 정확하게 분류할 필요가 있다. 또한, 생성된 퍼지규칙이 패턴 분류를 위해 적용될 때, 그 퍼지규칙의 전제부에 표현되어 있는 모든 항목에 대해 평가가 이루어진다. 이러한 평가의 결과는 곧 결론부에 대한 확신도를 의미하며, 결론부의 확신도는 입력된 패턴이 어떤 클래스로 분류될 수 있는가를 결정할 수 있도록 한다. 따라서 가능한한 퍼지규칙의 전제부는 간략하게 표현될 수 있어야 한다.

기존의 대부분의 방법은 퍼지규칙의 전제부의 각 항목에 포함된 언어적 변수(linguistic variable)들에 대한 귀속함수는 각 특징축의 범위에 기초하여 정의하고 있다. 그러나 퍼지규칙의 이러한 표현방법은 주어진 특징공간의 차원이 매우 큰 경우에는 그 만큼 전제부의 항목이 필요하게 되어 퍼지규칙이 매우 방대한 크기의 전제부를 정의하고 있는 형태를 가지게 될 것이다. 따라서 패턴 분류를 위해 방대한 크기의 전제부를 평가하는 것은 시간소모적인 일이라고 할 수 있다. 특히, 가상사각형으로 정의되는 부공간에 대한 귀속함수는 부공간 내 패턴의 공간적 분포를 고려한 것이라기 보다는 가상사각형의 형태적인 특성에 의존적이라는 문제가 있다.

본 논문에서는 분할된 부공간을 중심벡터(centroid)와 경계거리(bounding distance)만으로 표현할 수 있는 가상구체(hyper-sphere)로 정의함으로써 주어진 클래스를 보다 정확히 묘사할 수 있고, 퍼지규칙의 전제부를 보다 간결하게 표현하여 전제부에 대한 평가가 신속하게 이루어질 수 있도록 하며, 추출된 퍼지규칙들이 계층적인 구조를 갖도록 함으로써 패턴 분류를 보다 신속하게 할 수 있도록 한다.

2장에서는 가상구체의 정의와 재귀적 공간분할 방법에 대해 설명하고 가상구체로부터 추출될 수 있는 퍼지규칙의 표현방법과 추론과정에 대해 기술한다. 3장에서는 제안된 방법에 대한 실험결과를 보여주고 있다.

II. 재귀적 공간분할과 퍼지규칙의 추출

이 장에서는 가상구체를 이용한 퍼지 공간 분할 방법과 분할된 부공간에 대해 어떻게 퍼지규칙을 추출하고 표현하는지에 대해 기술하며, 패턴을 분류하기 위해 필요한 퍼지규칙의 추론과정에 대해 기술한다.


2.1 가상구체의 정의

m 차원 입력 패턴 $x = (f_1, f_2, \dots, f_m)$ 를 n 개의 클래스 중 하나로 분류하는 패턴분류 문제에 대해 퍼지규칙은 분할된 부분공간에 대해 정의되므로 본 논문에서는 공간분할을 위해 먼저 클래스 i 에 대한 모든 입력패턴 $X_i = \{x_1, x_2, \dots, x_N\}$ 에 대해 가상구체 HS_i 를 정의한다.

$$HS_i = \{C_i, B_i\}, \tag{1}$$

where, C_i : centroid of i -th class
 B_i : bounding distance of i -th class

(식 1)에서 우리는 C_i 를 클래스 i 의 중심벡터, 그리고 B_i 를 경계거리(bounding distance)라고 부르기로 한다. C_i 는 클래스 i 에 속한 모든 패턴들의 평균벡터를 취함으로써 얻어질 수 있고, B_i 는 C_i 와 클래스에 속한 모든 패턴과의 거리중에서 잡음(noise)을 제외한 모든 패턴을 포함할 수 있는 최소거리로 정의할 수 있다. (그림 2)는 각 클래스에 속한 패턴들에 의해 가상구체가 어떻게 정의될 수 있는지를 보여주고 있다.



(그림 2) 가상구체의 정의(중심벡터와 경계거리의 결정)

(그림 2)와 같은 가상구체 정의에서 B_j 는 잡음이라고 생각되는 패턴을 포함하여 결정되었지만 실제로는 B_j^* 와 같이 결정되는 것이 바람직할 것이다. 이렇게 잡음으로 생각되는 패턴의 영향으로 가상구체의 크기가 현저하게 달라질 수 있는 문제를 해결하기 위해 (알고리즘 1)을 이용하여 B_i 를 결정한다.


(알고리즘 1) 가상구체의 경계거리 결정

- 단계 1: 클래스 i 에 속한 모든 패턴 $X_i = \{x_1, x_2, \dots, x_N\}$ 에 대해 C_i 와의 거리에 대한 히스토그램을 작성한다.
- 단계 2: 최대거리를 K_i 이라 하고, 히스토그램 면적의 $t\%$ 에 해당되는 거리를 T_i 라고 한다.
- 단계 3: 만일 $(K_i - T_i)/K_i \leq \omega$ 를 만족하면, $B_i = K_i$ 으로 한다. (단, $\omega \geq 0$ 이다.)
- 단계 4: 아니면, $B_i = T_i$ 로 한다.

(알고리즘 1)에서 K_i 는 클래스 i 에 속하는 모든 패턴을 포함하는 최대거리를 의미하고, T_i 는 클래스 i 에 속하는 모든 패턴들 중에서 잡음으로 생각되는 패턴을 제외한 다른 모든 패턴을 포함할 수 있는 최소거리를 의미하고 있다. 그러나 어떤 패턴을 잡음으로 취급하기 위해서는 그 패턴이 다른 패턴들과 충분히 떨어져 있어서 공간적 이질성을 가지고 있어야만 한다. 만일 히스토그램의 면적에 대한 임계치 t 를 충분히 크게 주었음에도 불구하고 K_i 와

T_i 의 차이가 크다면 거리 T_i 와 K_i 사이에 존재하는 패턴들을 잡음으로 취급할 수 있다. 따라서 (알고리즘 1)에서는 거리의 비율에 대한 임계치 ω 를 잡음패턴을 구분하는 데 사용하고 있다.

주어진 클래스에 대한 가상구체의 정의는 기존의 가상사각형을 이용한 표현방법에 비해 두 가지 중요한 장점을 가지고 있다. 첫째는 클래스의 형태를 보다 정확히 묘사할 수 있다는 것이고, 둘째는 패턴의 귀속값을 보다 정확히 계산할 수 있는 형태를 갖는다는 것이다. 이것을 설명하기 위해 (그림 3)은 2차원 특징공간 상에서 가상사각형의 표현과 가상구체의 표현 방법을 비교하고 있다.



(그림 3) 클래스 i 의 가상사각형 표현과 가상구체 표현

(그림 3-a)와 같은 가상사각형 표현은 주어진 클래스에 속한 패턴들의 각 차원에 대한 투영(projection) 결과로부터 모든 패턴을 포함할 수 있는 범위를 찾아냄으로써 주어진 클래스를 표현한다. 그러나 클래스내의 패턴분포를 고려하지 않고 단지 최소-최대 값만으로 범위를 표현하고 있으므로 주어진 클래스의 패턴 분포가 한쪽으로 집중되어 있다면, 각 차원에 대한 귀속함수는 적절히 조절되어야 할 필요가 있다. 만일, 범위가 패턴분포의 중심으로 부터 같은 거리의 최소-최대값을 갖고 표현된다면 가상구체에 의한 표현 방법에 비해 불필요한 공간을 포함하게 되므로 보다 밀도있는 표현이 어렵다. 또한 중복이 발생하는 경우에는 실제로 중복되지 않는 영역조차도 중복영역으로 포함되어 상대적으로 중복영역의 크기가 커진다는 단점이 있다.

일반적으로 임의의 패턴 x_1 과 x_2 가 주어진 클래스에 속할 귀속값은 클래스의 중심벡터로부터의 거리(distance)에 기초한다고 할 수 있다. 그러나 (그림 3-a)와 같이 귀속함수가 정의되는 경우에는 가상사각형의 특성에 의해 서로 다른 거리에 존재하는 패턴 x_1 과 x_2 가 같은 귀속값을 가지게 된다. 이에 반해 (그림 3-b)와 같은 가상구체 표현에서는 주어진 패턴 x_1 과 x_2 의 귀속값이 다르게 나타날 수 있다. 따라서 가상구체 표현은 가상사각형 표현에 비해 패턴의 귀속값을 보다 정확히 나타낼 수 있고 이것은 패턴분류의 정확성과 밀접한 관련이 있다고 할 수 있다. 특히, 클래스내의 패턴들이 가우시안 분포를 갖는 경우에는 가상구체가 가상사각형 보다 주어진 클래스의 형태를 보다 효과적으로 표현한다고 말할 수 있다.

결국, 주어진 클래스의 표현과 분류의 정확성을 고려할 때 우리는 가상사각형 보다는 가상구체를 주어진 클래스에 대한 공간적인 표현방법으로서 사용하는 것이 바람직하다고 생각한다.

2.2 재귀적 공간 분할


주어진 특징공간상에 정의된 가상구체들은 특징공간을 분할하기 위해 사용될 수 있으며, 가상구체들이 점유하고 있는 부공간의 유형에는 크게 두가지가 있을 수 있다. 첫째는 어떤 하나의 클래스에 대해 정의된 가상구체가 다른 클래스에 대해 정의된 가상구체들과 어떤 공간을 공유하는 경우이고, 두번째는 그렇지 않은 경우이다.

만일 첫번째 경우와 같이 클래스 i 에 대해 정의된 가상구체 HS_i 가 클래스 j 에 대해 정의된 가상구체 HS_j 와 어떤 영역을 공유한다면 공유되는 영역을 중복영역(overlapped region) OR_{ij} 라고 하고, HS_i 에서 중복영역 OR_{ij} 를

제외한 나머지 영역, 즉 단순히 클래스 i 에 속한 패턴만을 포함하고 있는 영역을 단순영역(simple region) SR_i 이라고 한다. 따라서 단순영역 SR_i 는 (식 2)와 같이 표현될 수 있다.

$$SR_i = HS_i - OR_{ij} \tag{2}$$

where, $OR_{ij} = HS_i \cap HS_j$



(그림 4) 복합중복의 예


그리고 단순영역이지만 가상구체가 중복영역을 포함하고 있지 않은 영역을 완전단순영역(complete simple region) CSR_i 이라고 부르기로 한다.

중복영역에는 두개의 가상구체에 의해 형성되는 단순중복(simple overlap)과, 세개 이상의 가상구체에 의해 형성되는 복합중복(complex overlap)이 있을 수 있다. (그림 4)는 복합중복을 보여 주고 있다.

(그림 4)에서는 클래스 i 와 j , 그리고 클래스 k 에 대한 가상구체들에 의한 중복영역 $OR_{ijk}^{(L)}$ 을 나타내고 있다. 중복영역 $OR_{ijk}^{(L)}$ 은 클래스 i 와 j , 그리고 클래스 k 에 대한 가상구체들에 의해 형성되고 있으며, 중복영역의 형태는 두개의 클래스에 의해 형성되는 것 보다 복잡해지게 된다.

본 논문에서는 이러한 복합중복을 단순중복으로 문제를 단순화 시킴으로써 복합중복의 문제를 해결하고자 한다. 즉, (그림 4)과 같은 복합중복은 클래스 i 와 클래스 j 간의 단순중복, 클래스 i 와 클래스 k 간의 단순중복, 그리고 클래스 i 와 클래스 k 간의 단순중복으로 분리될 수 있다.

그러나 실제로 단순중복에는 세가지 유형이 있을 수 있다. 첫째는 클래스 i 와 클래스 j 를 구성하고 있는 패턴이 중복영역에 공존하고 있는 경우이고, 두번째는 클래스 i 와 클래스 j 중에서 단지 하나의 클래스에 속한 패턴들만




(그림 5) 중복영역의 세가지 유형

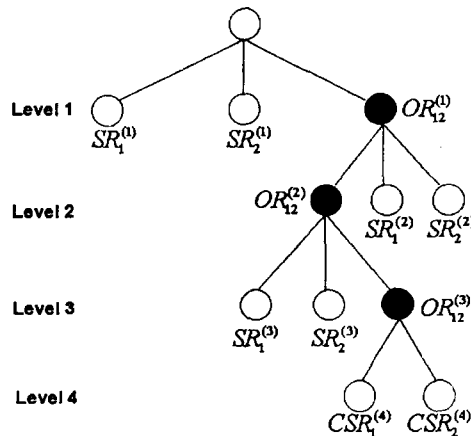
확인되는 경우이며, 세번째는 중복영역에 속한다고 확인되는 패턴이 하나도 없는 경우이다. (그림 5)는 중복영역의 세가지 유형을 보여 주고 있다.

(그림 5-a)는 중복영역에 두개의 클래스에 속하는 패턴들이 공존하는 경우이고, (그림 5-b)는 중복영역에 속하는 패턴들이 단지 한 클래스에 속한 패턴들로 이루어진 경우이고, (그림 5-c)는 중복영역에 속하는 패턴들이 하나도 없는 경우를 보여주고 있다. 유형 1과 2의 중복영역은 어떤 패턴들을 포함하고 있으므로 중복영역에 속한 패턴들을 식별하기 위해서는 다시 공간분할이 이루어져야 한다. 즉, 재귀적인 공간분할이 요구된다고 할 수 있다. 그러나 유형 3의 중복영역에는 어떠한 패턴도 포함되어 있지 않으므로 실제로 아무런 의미도 가지지 못한다. 따라서 유형 3의 중복영역은 무시된다.

재귀적 공간 분할은 먼저 주어진 특징공간을 편의상 레벨 1로 하고 각 클래스에 대해 가상구체를 정의하는 것으로 시작한다. 그런 다음 중복영역에 속한 패턴들로 구성된 특징공간을 레벨 2로 하고 이 특징공간에 대해 다시 가상구체를 정의한다. 만일 레벨 2의 가상구체 정의에 대해서도 역시 중복영역이 나타나면 이 중복영역에 속한 패턴들로 구성된 특징공간을 레벨 3으로 한다. 재귀적 공간분할은 이와 같이 레벨을 증가시키면서 중복영역이 나타나지 않을 때 까지 가상구체를 재귀적으로 정의하는 것을 의미한다. (그림 6)은 재귀적 공간분할이 어떻게 일어나는지를 도식으로 보여 주고 있고, (그림 7)은 (그림 6)에서 보여주는 재귀적인 공간분할 과정을 계층적으로 표현하고 있다.



(그림 6) 중복영역에 대한 가상구체의 재귀적 정의




(그림 7) 재귀적 공간 분할(그림 6)의 계층적인 표현

(그림 6)에서 가상구체간에 중복이 존재하게 되면 중복은 가상구체의 재귀적인 정의를 통해 해결된다. 그렇게 하기 위해서는 중복영역에 속한 패턴들로 특징공간을 구성하여야 하며, 각 레벨에서 중복영역에 포함된 패턴의 확인은 (규칙 1)을 이용하여 매우 간단히 이루어질 수 있다.

(규칙 1) 레벨 L 에서, 만일 두 클래스의 중심벡터를 C_i, C_j 라 하고 경계거리를 B_i, B_j 라 할때, 각 중심벡터와 임의의 패턴 x 에 대한 거리 D_{ix} 와 D_{jx} 에 대해, $D_{ix} < B_i$ 이고 $D_{jx} < B_j$ 임을 만족하면 패턴 x 는 중복영역 $OR_{ij}^{(L)}$ 에 속한다.


예를 들어, (그림 8)과 같은 경우에 패턴 x 는 (규칙 1)을 만족한다. 따라서 패턴 x 는 중복영역 $OR_{ij}^{(L)}$ 에 속하는 것으로 확인될 수 있다.



(그림 8) 중복영역 $OR_{ij}^{(L)}$ 에 속하는 패턴 x 의 확인

2.2.1 재귀적 공간 분할의 중지

재귀적 공간 분할은 반드시 중단되는 시점이 있어야 한다. 물론 어떤 분할 단계에 대해 중복영역이 나타나지 않으면 분할은 중지되어야 한다. 그러나 중복영역이 존재한다고 하더라도 중복영역에 속한 패턴의 수가 임계치 이하이고 중복정도가 매우 심한 경우에는 분할의 중단을 고려할 수 있다.



(그림 9) 가상구체 $HS_i^{(L)}$ 와 $HS_j^{(L)}$ 에 의한 중복영역

예를 들어, (그림 9)와 같이 주어진 두 클래스 i, j 에 속한 패턴들이 중복영역 $OR_{ij}^{(L)}$ 에 넓고 고르게 분포하고 있으며 중복영역에 속한 패턴의 수가 적은 경우에는 다음 레벨에서 정의되는 가상구체들 간의 중복정도가 매우 심하게 나타나게 된다. 이러한 경우에는 지속적인 분할에도 불구하고 중복영역의 크기는 천천히 줄어들게 되어 생성되는 퍼지규칙의 신뢰도는 저하되고 퍼지규칙의 수는 증가하게 된다는 문제가 있다.

중복정도를 측정하기 위해 우리는 클래스 i 와 j 간의 중복 정도를 측정하기 위한 척도를 (식 3)와 같이 정의한다.

$$OVL_{ij} = \max\left\{0, 1 - \frac{D_{ij}}{B_i + B_j}\right\} \quad (3)$$

(식 3)에서 $B_i + B_j$ 는 두 가상구체 $HS_i^{(L)}$ 과 $HS_j^{(L)}$ 의 경계거리의 합을 의미하고 D_{ij} 는 C_i 와 C_j 간의 거리를 의미한다. 그러므로 만일, $(B_i + B_j) = D_{ij}$ 이면 OVL_{ij} 는 0이 되며, 만일 $D_{ij} = 0$ 이면 OVL_{ij} 는 1이 된다. 따라서 OVL_{ij} 는 두 가상구체간의 중복정도를 측정하는데 사용될 수 있으며, 분할 중지 조건은 (규칙 2)와 같이 정리될 수 있다.

(규칙 2) 만일 레벨 L 에서 중복영역 $OR_{ij}^{(L)}$ 에 속한 패턴의 수 $Num(OR_{ij}^{(L)})$ 가 임계치 $Th1$ 보다 적고, OVL_{ij} 가 임계치 $Th2$ 보다 크면 분할을 중지한다.

분할이 중지되었다 하더라도 (규칙 2)를 만족하는 중복영역에는 둘 또는 세개 이상의 클래스에 속한 패턴들이 존재하고 있으므로 분할 중지된 중복영역에 대한 퍼지규칙을 추출하기 위해서 본 논문에서는 직접적인 방법(direct method)[7]을 사용한다. 직접적인 방법에 의해 생성되는 가상구체의 수는 주어진 패턴들의 수와 같으며, 주어진 패턴의 수가 적은 경우에는 주어진 각각의 패턴들로 부터 직접 가상구체를 정의하는 것이 계속적인 분할을 시도하는 것에 비해 단순하고 효과적인 방법이라고 할 수 있다. 결국, 레벨 L 의 분할중지된 중복영역에 대해, 클래스 i 에 속하는 어떤 패턴 x 에 대한 가상구체 $HS_i^{(L)}$ 의 중심벡터 C_i 는 x 자신이 되고, 경계거리 B_i 는 x 로 부터 임의의 거리 δ 로 주어질 수 있다. 그러면 (식 1)과 같은 가상구체를 정의할 수 있으며, 정의된 가상구체는 완전단순영역이 된다.

2.2.3 특징 선택

각 패턴은 m 개의 특징들에 의해 m 차원 벡터로 표현되고, 재귀적 공간 분할은 다차원 특징공간상에 가상구체를 재귀적으로 정의함으로써 이루어진다. 그러나 만일 주어진 패턴들의 차원이 매우 방대한 경우에는 많은 계산 시간이 요구된다. 따라서 속도를 요구하는 패턴분류기에서는 주어진 특징공간의 차원들 중에서 가장 구분력(discriminant power)이 뛰어난 특징들만으로 공간을 구성함으로써 속도의 향상을 꾀할 수 있다. 기존의 가상사각형 형태를 이용하는 분할방법은 주어진 특징공간에 대한 재귀적인 분할은 동일한 특징공간 상에서 이루어지도록 하고 있다. 그러나 일반적으로 재귀적 분할이 이루어지는 부공간들은 상위 레벨의 특징공간과는 서로 다른 구성원으로 이루어져서 가장 구분력이 뛰어난 특징 또한 달라질 수 있다. 따라서 각 레벨에 대해 분류하기에 가장 적절한 특징을 선택하고 선택된 특징들로 특징공간을 구성하는 것은 패턴 분류기의 요구된 정확성의 범위에서 가급적 신속한 분류를 위해 중요하다고 할 수 있다.

제안된 방법은 각 레벨마다 주어진 패턴들을 가장 잘 구분할 수 있는 특징들을 선택하여 구성할 수 있으므로 주어진 특징공간을 보다 효과적으로 분할 할 수 있게 된다. 즉, 생성되는 부공간의 수를 줄일 수 있으며, 분류의 정확성도 증가하게 된다. 본 논문에서는 구분력이 높은 특징을 선택하기 위해 패턴인식 분야에서 널리 사용되는 Fisher의 분석방법을 이용한다. Fisher의 척도는 (식 4)과 같다.

$$FD_j = \frac{\text{between class variance}}{\text{within class variance}} = \frac{\sigma_j^2}{\sum_{i=0}^* \sigma_{ij}^2 / n} \quad (4)$$

(식 4)에서 FD_j 는 j 번째 특징에 대한 Fisher의 분석값이고, σ_j^2 은 클래스 i 의 j 번째 특징에 대한 분산(variance)을 의미하며, σ_{ij}^2 은 모든 패턴의 j 번째 특징에 대한 분산을 나타낸다. 따라서 각 특징에 대한 Fisher의 분석값들을 내림차순으로 정렬(sorting)하고 앞에서 부터 몇개의 특징을 선택하여 특징공간을 구성한다.

2.3 퍼지규칙의 표현

레벨 L 의 어떤 특징공간상에 가상구체가 정의되면 앞에서 언급한 바와 같이 특징공간은 단순영역과 중복영역 그리고 완전단순영역으로 분할된다. 따라서 패턴 분류를 위해 필요한 결정규칙은 각 영역들에 해당하는 부공간에 대해 퍼지규칙을 추출함으로써 얻어질 수 있다.

각 영역들 중 가장 단순한 형태는 완전단순영역이다. 레벨 L 에서 클래스 i 에 대한 완전단순영역 $CSR_i^{(L)}$ 의 퍼지규칙은 (식 5)와 같이 표현될 수 있다.

$$IF\ x\ belongs\ to\ CSR_i^{(L)}\ THEN\ x\ is\ class\ i. \quad (5)$$

(식 5)는 만일 입력패턴 x 가 완전단순영역 $CSR_i^{(L)}$ 에 속하면 x 는 클래스 i 로 분류될 수 있다는 것을 의미하며, $CSR_i^{(L)}$ 는 완전단순영역에 대한 언어적 변수(linguistic variable)가 된다.

마찬가지로 레벨 L 에서 클래스 i 에 대한 단순영역 $SR_i^{(L)}$ 의 퍼지규칙은 (식 6)과 같이 표현될 수 있다.

$$IF\ x\ belongs\ to\ SR_i^{(L)}\ THEN\ x\ is\ class\ i. \quad (6)$$

단순영역 $SR_i^{(L)}$ 은 (식 2)와 같이 가상구체 $HS_i^{(L)}$ 로 부터 중복영역 $OR_{ij}^{(L)}$ 을 제외한 나머지 영역을 의미하고 있으며, j 는 $HS_i^{(L)}$ 와 함께 중복영역을 형성하는 모든 가상구체와 관련된 클래스명(class label)을 말한다.

또한, 중복영역 $OR_{ij}^{(L)}$ 에 대한 퍼지규칙은 (식 7)과 같이 표현될 수 있다.

$$IF\ x\ belongs\ to\ OR_{ij}^{(L)}\ THEN\ x\ is\ class\ i\ OR\ class\ j. \quad (7)$$

(식 7)은 입력패턴 x 가 레벨 L 에서 중복영역 $OR_{ij}^{(L)}$ 에 속하면 x 는 클래스 i 또는 클래스 j 로 분류될 수 있음을 의미하고 있다. 그러나 만일 레벨 $L+1$ 의 특징공간에 대한 재귀적 공간분할에 의해 중복영역이 확인되지 않고 완전단순영역만 확인된 경우에, (식 7)은 (식 8)과 같이 다시 표현될 수 있다.

$$\begin{aligned} &IF\ x\ belongs\ to\ OR_{ij}^{(L)}\ THEN \\ &\quad IF\ x\ belongs\ to\ CSR_i^{(L+1)}\ THEN\ x\ is\ class\ i \\ &\quad IF\ x\ belongs\ to\ CSR_j^{(L+1)}\ THEN\ x\ is\ class\ j. \\ &END\ IF. \end{aligned} \quad (8)$$

$$\begin{aligned} &IF\ x\ belongs\ to\ SR_i^{(1)}\ THEN\ x\ is\ class\ i \\ &IF\ x\ belongs\ to\ SR_j^{(1)}\ THEN\ x\ is\ class\ j \\ &IF\ x\ belongs\ to\ OR_{ij}^{(1)}\ THEN \\ &\quad IF\ x\ belongs\ to\ SR_i^{(2)}\ THEN\ x\ is\ class\ i \\ &\quad IF\ x\ belongs\ to\ SR_j^{(2)}\ THEN\ x\ is\ class\ j \\ &\quad IF\ x\ belongs\ to\ OR_{ij}^{(2)}\ THEN \\ &\quad\quad IF\ x\ belongs\ to\ SR_i^{(2)}\ THEN\ x\ is\ class\ i \\ &\quad\quad IF\ x\ belongs\ to\ SR_j^{(2)}\ THEN\ x\ is\ class\ j \\ &\quad\quad IF\ x\ belongs\ to\ OR_{ij}^{(2)}\ THEN \\ &\quad\quad\quad IF\ x\ belongs\ to\ CSR_i^{(3)}\ THEN\ x\ is\ class\ i \\ &\quad\quad\quad IF\ x\ belongs\ to\ CSR_j^{(3)}\ THEN\ x\ is\ class\ j \\ &\quad\quad\quad END\ IF. \\ &\quad\quad\quad END\ IF. \\ &\quad\quad\quad END\ IF. \\ &\quad\quad\quad END\ IF. \end{aligned}$$

(그림 10) 재귀적 공간 분할(그림 6)과 추출된 퍼지규칙의 예

(식 8)은 퍼지규칙이 중첩구조를 갖을 수 있음을 나타내고 있으며, 퍼지규칙의 중첩구조는 패턴의 신속한 분류를 가능하게 한다. 물론 레벨 $L+1$ 의 특징공간에 대한 재귀적 공간분할에 의해 다시 중복영역이 확인된 경우에는 퍼지규칙의 중첩이 확대된다. 예를 들면, (그림 6)과 같은 공간분할 과정에서 추출된 퍼지규칙은 (그림 10)과 같이 나타날 수 있다.

(그림 7)과 같이 재귀적 공간 분할과정에서 추출된 퍼지규칙(그림 10)은 패턴분류의 결정론적인 방법에서 주로 사용하고 있는 결정트리(decision tree)와 매우 유사한 구조를 갖게 된다.


2.4 퍼지규칙의 추론

일반적으로 주어진 입력패턴 x 가 클래스 i 에 속하는 정도를 나타내는 귀속값은 가상구체 $HS_i^{(L)}$ 의 중심벡터 C_i 로부터 x 까지의 거리 D_{ix} 에 의해 결정될 수 있다. 따라서 (식 5)와 같은 퍼지규칙에서 가상구체내에 중복영역이 나타나지 않는 완전단순영역에 대해 입력패턴 x 가 클래스 i 에 속하는 정도를 나타내는 귀속값을 계산하기 위해 (식 9)와 같은 귀속함수를 정의한다.

$$m_A(x) = \max\left\{0, 1 - \frac{D_{ix}}{B_i * \alpha}\right\}, \quad \text{where, } 1 \leq \alpha \leq 2 \quad (9)$$

(식 9)에서 A 는 $CSR_i^{(L)}$ 을 의미하며, 파라미터 α 는 가상구체의 크기를 조절하여 줌으로써 귀속값의 결정에 민감한 정도를 나타내는 파라미터이다. 이러한 파라미터를 사용하는 이유는 패턴분류의 일반화 능력을 고려하여야 하기 때문이다. 예를 들어, 어떤 입력패턴 x 가 어떠한 가상구체에도 속하지 않는다면 어떤 클래스로도 분류되지 않게 된다. 그러나 학습자료(training data)와 평가자료(test data)는 다소 다를 수 있으므로 학습자료의 부족으로 인해 발생할 수 있는 분류능력의 저하를 방지하여야 한다. 결국, 파라미터 α 는 가상구체의 크기를 조절하여 줌으로써 이러한 미분류(not-classified)의 가능성을 최소화 하기 위한 것이다.


완전단순영역에 대해 1차원인 경우의 귀속함수는 (그림 11)과 같이 표현될 수 있다.



(그림 11) 1차원인 경우, 완전단순영역에 대한 귀속함수

(그림 11)에서 볼 수 있는 것과 같이 귀속값은 클래스의 중심벡터 C_i 로부터 멀어질 수록 감소하는 형태를 갖게 된다. 물론, 귀속함수의 형태는 사다꼴이나 시그모드형태를 가질 수 있지만 여기서는 가장 간단한 삼각형 형태의 귀속함수를 사용하기로 한다.

(식 6)과 같이 퍼지규칙의 전제부의 항이 단순영역으로 표현되는 경우에 주어진 입력패턴 x 가 클래스 i 에 속하는 정도를 나타내는 귀속함수는 클래스 i 의 가상구체로부터 중복영역을 제외한 나머지 영역에 대해 정의되어야 한다. (그림 12)는 클래스 i 에 대한 단순영역이 클래스 i 와 클래스 j 의 중복영역 $OR_{ij}^{(L)}$ 을 제외한 나머지 영역으로 정의되는 경우에 단순영역에 대한 귀속함수가 어떻게 정의될 수 있는지를 보여 주고 있다.



(그림 12) 중복이 있는 단순영역에 대한 귀속함수의 결정

(그림 12)에서 M_i 는 단순영역의 가상적인 중심점들을 나타내며, 가상구체 $HS_i^{(L)}$ 의 중심벡터 C_i 로 부터 임의의 거리만큼 떨어져 있는 모든 점들을 총칭해서 M_i 라고 한다. 그러면 C_i 와 M_i 사이의 거리 D_{iM_i} 와 D_{jM_i} 는 (식 10)에 의해 결정될 수 있다.

$$D_{iM_i} = (B_i * \alpha) - \frac{(D_{ij} + (B_i * \alpha)) - (B_i * (2 - \alpha))}{2} \quad (10)$$

$$D_{jM_i} = D_{ij} + D_{iM_i}$$

그러면 (그림 12)와 같이 입력패턴 x 가 단순영역에 속할 귀속값은 $1 - (b)/(a)$ 와 $1 - (d)/(c)$ 중에서 최소값을 갖는 것으로 결정될 수 있다. 결국, 클래스 i 의 단순영역에 대한 귀속함수는 (식 11)과 같이 정의된다.

$$m_{SR_i^\omega}^j(x) = \min\{\max\{0, V1\}, \max\{0, V2\}\}$$

$$V1 = 1 - \frac{D_{ix} - D_{iM_i}}{(B_i * \alpha) - D_{iM_i}} \quad (11)$$

$$V2 = 1 - \frac{D_{jM_i} - D_{jx}}{D_{jM_i} - (B_j * (2 - \alpha))}$$

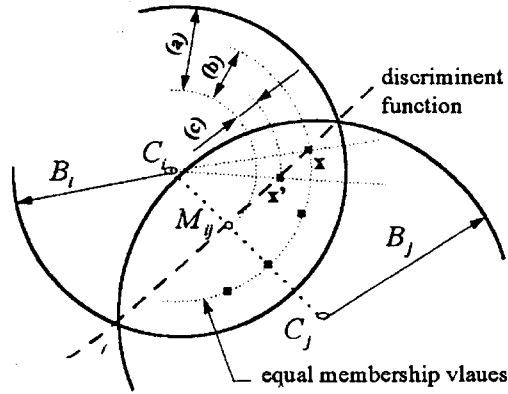
(식 11)에서 $V1$ 은 C_i 와 M_i 로 부터 결정될 수 있고, $V2$ 는 C_j 와 B_j 로 부터 결정될 수 있다. 따라서 두 귀속값 $V1$ 과 $V2$ 의 최소값이 최종적으로 입력패턴 x 가 클래스 i 에 속하는 정도를 나타내는 귀속값이 된다. 이때, 귀속값의 분포는 (그림 12)과 같은 경우에 M_i 로 부터 멀어질 수록 그리고 B_j 에 가까울 수록 작아진다고 할 수 있다.

그러나 단순영역의 형태는 하나이상의 중복영역과 관련되어 있으므로 최종적으로 클래스 i 의 단순영역에 대한 귀속함수는 (식 12)과 같이 정의될 수 있다.

$$m_{SR_i^\omega}(x) = \min\{m_{SR_i^\omega}^j(x), \text{ for all } j \in \Lambda\} \quad (12)$$

(식 12)에서 Λ 는 클래스 i 와 관련되어 중복영역을 형성하는 모든 클래스의 집합을 의미한다.

또한, (식 7)과 같은 퍼지규칙의 중복영역 $OR_{ij}^{(L)}$ 에 대해 입력패턴 x 가 클래스 i 또는 클래스 j 에 속하는 정도를 나타내는 귀속함수는 (식 13)와 같이 나타낼 수 있으며, (그림 13)은 (식 13)이 어떻게 결정되고 있는지를 그림으로 보여 주고 있다.



(그림 13) 중복영역 $OR_{ij}^{(L)}$ 에 대한 귀속함수의 결정

(그림 13)은 중복영역에 속한 임의의 특징벡터에 대해 귀속값이 어떻게 구해질 수 있는지 그 예를 보여주고 있다. (그림 13)에서 굵은 점선으로 표시되어 있는 것은 (식 9)에 의해 계산된 값이 동일한 면을 나타내며, (a)는 (식 13)의 분모항과 같고, (b)와 (c)는 식(13)에서 분자항과 같다. 그러므로 (식 13)에 의해 x' 와 x 에 대한 귀속값은 각각 $1-(c)/(a)$ 와 $1-(b)/(a)$ 가 된다. 즉, x' 는 x 보다 중복영역에 속할 귀속값이 더 크게 된다. 또한, (그림 13)에서 C_i 에서 x 까지의 거리와 같은 거리에 있는 중복영역내의 모든 점들은 같은 귀속값을 갖게 된다. 그러므로 귀속값의 분포는 M_{ij} 를 기준으로 M_{ij} 으로부터 멀어질 수록 작아지게 된다.

$$m_{OR_{ij}^{(L)}}(x) = \begin{cases} \max\{0, 1 - \frac{D_{ix} - D_{iM_{ij}}}{(B_i * \alpha) - D_{iM_{ij}}}\}, & \text{if } m_i(x) < m_j(x) \\ \max\{0, 1 - \frac{D_{jx} - D_{jM_{ij}}}{(B_j * \alpha) - D_{jM_{ij}}}\}, & \text{otherwise} \end{cases} \quad (13)$$

(식 13)에서 $I = CSR_i^{(L)}$ 이고, $J = CSR_j^{(L)}$ 임을 나타내며, (그림 13)의 M_{ij} 는 (식 14)에 의해 결정된다.

$$M_{ij} = S_j C_i + S_i C_j \quad (14)$$

$$S_i = \frac{B_i}{B_i + B_j}, \quad S_j = \frac{B_j}{B_i + B_j}$$

(식 7)에 의해 주어진 퍼지규칙에 대한 귀속값은 x 가 중복영역 $OR_{ij}^{(L)}$ 에 속할 귀속값에 의해 결정될 수 있다. 따라서 (식 7)이 (식 8)과 같이 확장될 때 (식 7)과 같은 퍼지규칙은 중첩구조를 갖는 퍼지규칙에서 결론부가 없는 퍼지규칙이 되므로 단지 하위의 퍼지규칙을 평가할지의 여부를 결정하는 수단으로 사용된다. 따라서 하위 퍼지규칙의 평가여부를 판단하기 위한 함수 $F(\cdot)$ 는 (식 15)와 같이 중복영역에 대한 귀속값에 대해 임계치 ϕ 를 적용함으로써 결정될 수 있다.

$$F(m_{OR_i^L}(x)) = \begin{cases} 1, & \text{if } m_{OR_i^L}(x) > \varphi \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

(식 15)와 같은 함수의 값이 1이면, 하위 퍼지규칙에 대한 평가는 이루어진다. 그러나 만일 값이 0이면 하위 퍼지규칙에 대한 평가는 무시된다.

그러면 최종적인 결과 $d(x)$ 는 모든 퍼지규칙들 중에서 평가가 이루어진 퍼지규칙(식 5와 6의 형태를 갖는)에 대한 귀속값이 최대값을 갖는 클래스명(class label)을 취함에 의해 (식 16)과 같이 결정될 수 있을 것이다.

$$d(x) = \underset{L=1, \dots, i \in \Sigma}{MAX_i} \{m_{R_i^L}(x)\} \quad (16)$$

where, Σ : a set of class label of tested fuzzy rules

(식 16)에서 R_i^L 은 레벨 L 에 대해 생성된 퍼지규칙들 중에서 결론부가 클래스 i 로 주어진 모든 퍼지규칙들을 의미한다.

결국, 제안된 방법은 주어진 패턴공간에 가상구체를 정의함으로써 전체적인 패턴분류의 정확성을 향상시킬 수 있으며, 퍼지규칙의 전체부를 단순하게 표현할 수 있다. 또한, 퍼지규칙들이 중첩된 구조를 가지도록 함으로써 패턴분류를 위한 시간을 절약할 수 있다는 장점을 가지게 된다.

III. 실험 및 결과

본 논문에서는 제안한 방법을 검증하기 위해 Iris 데이터와 난수발생기를 이용하여 임의로 생성한 패턴들을 이용하였으며, 제안된 방법을 기존에 가장 효과적이라고 생각되는 Abe[1]의 방법과 비교하기 위해 Abe의 방법과 제안된 방법을 C언어를 사용하여 IBM-PC/486 50MHz 컴퓨터상에 구현하였고 이 두가지 방법에 각각 Iris 데이터와 임의의 데이터를 적용하였다. Iris 데이터는 4차원 특징벡터를 갖는 총 50개의 패턴들로 구성되며, 이 중 25개 패턴은 퍼지규칙의 추출을 위해 사용하였으며, 나머지 25개의 패턴은 실험결과를 얻기 위해 사용하였다. 또한, 임의로 생성된 데이터는 퍼지규칙의 추출과 실험결과를 얻기 위해 8차원 특징벡터로 구성된 2050개의 패턴을 생성하였다. 이 중 1350개와 700개는 각각 퍼지규칙의 추출과 실험에 사용되었다. (그림 14)는 실험에 사용된 700개의 패턴에 대한 2차원적인 분포를 보여주고 있다.


제안된 방법을 실험하기 위해 가상구체의 경계거리를 결정하기 위한 임계치 t 는 100%로 하였고, 분할중지 조건을 확인하기 위한 임계치 $Th1$ 과 $Th2$ 는 각각 7과 0.9로 주었다. 또한, 민감 파라미터 α 가 분류율에 어떠한 영향을 미치는지를 확인하기 위해 파라미터 α 를 변화시키면서 분류율이 어떻게 변하는지를 실험하였다. (표 1)은 민감 파라미터 α 가 분류율에 어떠한 영향을 미치는지를 보여주고 있다.

(표 1)에 나타난 것과 같이 민감 파라미터 α 가 작은 경우보다는 클 수록 분류율이 향상되는 것을 보이고 있다. 그러나 만일 민감 파라미터 α 가 어느정도 이상 커지면 오히려 분류율의 저하를 초래하게 된다. 따라서 실험을 통해 적절한 값을 찾아내는 것이 필요할 것으로 생각된다.

(표 2)는 제안된 방법과 Abe[1]의 방법을 이용하여 추출된 퍼지규칙의 수와 분류율을 비교하고 있다.

(표 2)에서 제안된 방법으로 추출된 퍼지규칙의 수는 Abe의 방법에 비해 많아 보인다. 이것은 분할 중지 조건에 의해 직접 퍼지규칙을 추출하였기 때문이다. 따라서 만일 직접적인 방법으로 퍼지규칙을 생성하지 않는다면 생성되는 퍼지규칙의 수는 Abe의 방법에 비해 적어질 것이라고 기대한다. 그러나 실험에서 직접적인 방법을 이용하게 된 것은 주어진 패턴들로 부터 퍼지규칙을 추출하는 데 소요되는 시간을 단축하고 불필요한 퍼지규칙을 생성하지 않기 위해서다.

학습에 필요한 시간은 구현상의 문제로 인해 정확히 측정하지는 못하였지만 제안된 방법은 퍼지규칙이 계층적인 구조를 갖도록 허용하고 있으므로 실제로 분류를 위해 필요한 시간은 Abe의 방법에 비해 크게 단축될 수 있을



(그림 14) 제안된 방법의 실험에 사용된 데이터의 예

(표 1) 민감 파라미터 α 의 변화에 따른 분류율

α	분류율(%)	
	Iris 데이터	임의생성 데이터
1.50	88.00	99.29
1.30	92.00	99.71
1.20	96.00	99.71
1.10	100.00	99.57
1.05	96.00	99.57
1.00	92.00	99.43

(표 2) 제안된 방법의 성능 비교

항 목	제안된 방법		Abe의 방법	
	Iris 데이터	임의데이터	Iris데이터	임의데이터
퍼지규칙의 수	7	41	6	34
미분류율	0.0 %	0.14 %	4.0 %	0.57 %
오분류율	0.0 %	0.29 %	4.0 %	1.14 %
분류율	100.0 %	99.57 %	92.0 %	98.29 %

것이라고 생각된다. 전체적인 분류율은 (표 2)와 같이 Abe의 방법에 비해 분류율이 크게 향상된 것을 알 수 있었다.

제안된 방법은 기존에 제안되었던 가상사각형 형태의 공간분할과 퍼지규칙 추출 방법에 비해 많은 장점을 가지고 있지만 제안된 방법은 전통적인 패턴분류기에서 사용되고 있는 군집화(clustering)와 같은 방법들에 비해 일반화 능력이 민감 파라미터 α 에 의해 제한되었다는 단점이 있다. 이것은 퍼지규칙을 추출하기 위해 공간분할을 시도하는 대부분의 방법이 갖고 있는 문제점으로서 향후 이에 대한 연구가 심도있게 이루어져야 할 것으로 생각된다.

IV. 결 론

본 논문에서는 가상구체를 이용하여 패턴분류를 위해 효과적인 퍼지규칙을 생성하기 위한 새로운 방법을 제안하였다. 가상구체는 패턴 클래스의 중심벡터와 클래스에 속하는 모든 패턴을 충분히 포함할 수 있는 경계거리로 정의되며, 어떤 패턴이 가상구체에 속하는 정도를 나타내는 귀속함수는 중심벡터와 경계거리에 의해 표현된다. 그러므로 퍼지규칙은 이들 가상구체에 대해 생성될 수 있고 두개의 가상구체에 의해 중복된 패턴들에 대해서는 중복을 해결하기 위해 재귀적인 가상구체의 정의가 이루어진다.

가상구체에 의해 추출된 퍼지규칙은 기존의 가상사각형을 이용한 방법에서 각 차원의 범위를 가지고 표현하는

퍼지규칙에 비해 퍼지규칙의 전체부를 매우 간단하게 표현할 수 있고, 클래스의 분포를 충분히 고려함으로써 생성되는 퍼지규칙의 정확성을 향상시킬 수 있다는 장점을 가진다. 또한, 두개의 가상구체에 의해 중복된 패턴들에 대한 재귀적 가상구체의 정의로 부터 퍼지규칙의 계층적 표현이 이루어지며, 따라서 입력되는 패턴의 신속한 분류가 가능하게 된다. 본 논문에서는 제안된 방법의 장점을 증명하기 위하여 기존의 가상사각형을 이용한 퍼지규칙 생성 방법과 비교하였다.

참 고 문 헌

1. Shigeo Abe and Ming-Shong Lan, "A Classifier Using Fuzzy Rules Extracted Directly from Numerical Data", *Proceeding of 2rd IEEE Conference on Fuzzy Systems*, 1993, pp. 1191-1198.
2. Hisao Ishibuchi, Ken Nozaki, and Hideo Tanaka, "Pattern Classification by Distributed Representation of Fuzzy Rules", *Proceeding of IEEE Conference on Fuzzy Systems*, 1992, pp. 643-650.
3. Ken Nozaki, Hisao Ishibuchi, and Hideo Tanaka, "Selecting Fuzzy Rules with Forgetting in Fuzzy Classification Systems", *Proceeding of IEEE Conference on Fuzzy Systems*, 1994, pp. 618-623.
4. Hisao Ishibuchi, Ken Nozaki, Naohisa Yamamoto, and Hideo Tanaka, "Acquisition of Fuzzy Classification Knowledge Using Genetic Algorithms", *Proceeding of IEEE Conference on Fuzzy Systems*, 1994, pp. 1963-1968.
5. Hisao Ishibuchi, Ken Nozaki, and Hideo Tanaka, "Efficient Fuzzy Partition of Pattern Space for Classification Problems", *Proceeding of the 2nd International Conference on Fuzzy Logic & Neural Networks*, 1992, pp. 671-674.
6. Ming-Shong Lan, Hiroshi Takenaga, and Shigeo Abe, "Character Recognition using Fuzzy Rules Extracted from Data", *Proceeding of IEEE Conference on Fuzzy Systems*, 1994, pp. 415-420.
7. Wen Wei and Jerry M. Mendel, "A Fuzzy Classifier That Uses Both Crisp Samples and Linguistic Knowledge", *Proceeding of 3rd IEEE Conference on Fuzzy Systems*, 1994, pp. 792-797.