

論文96-33B-2-14

퍼지 신경망을 이용한 퍼지 추론 시스템의 학습 및 추론

(Learning and inference of fuzzy inference system with fuzzy neural network)

張大植*, 崔瀠一*

(Dae Sik Jang and Hyung Il Choi)

요약

퍼지 추론은 애매 모호한 문제를 정량적으로 표현하고 해결할 수 있어 매우 유용하게 사용된다. 그러나 대부분의 지식 베이스 추론 시스템에서와 마찬가지로 규칙의 생성에 많은 어려움이 있고 동적으로 변화하는 환경에 적응할 수 있도록 하는 학습 능력이 없다. 본 논문에서는 이러한 문제를 해결하기 위해 퍼지 연상 기억장치(FAM : Fuzzy Associative Memory)를 기반으로 하는 퍼지 추론 시스템을 제안한다. 본 논문에서 제안하는 퍼지 추론 시스템은 크게 학습 단계와 추론 단계의 두 단계로 구성되는데 학습 단계에서는 퍼지 소속 함수의 결정을 통해 시스템의 기본 구조를 초기화하고 이를 바탕으로 퍼지 연상 기억장치의 학습 기능을 이용하여 퍼지 규칙을 조건부와 결론부를 연결하는 가중치의 형태로 생성한다. 그리고 추론 단계에서는 구성된 퍼지추론 망을 통하여 실제 추론을 수행한다. 본 논문에서 제안하는 추론 시스템을 패턴 분류 문제의 해결에 적용하고 그 결과를 실험으로 보인다.

Abstract

Fuzzy inference is very useful in expressing ambiguous problems quantitatively and solving them. But like the most of the knowledge based inference systems, it has many difficulties in constructing rules and no learning capability is available. In this paper, we propose a fuzzy inference system based on fuzzy associative memory to solve such problems. The inference system proposed in this paper is mainly composed of learning phase and inference phase. In the learning phase, the system initializes its basic structure by determining fuzzy membership functions, and constructs fuzzy rules in the form of weights using learning function of fuzzy associative memory. In the inference phase, the system conducts actual inference using the constructed fuzzy rules. We applied the fuzzy inference system proposed in this paper to a pattern classification problem and show the results in the experiment.

I. 서 론

인간의 두뇌는 정량적인 자료를 바탕으로 하는 명확한 지식보다 정성적인 표현을 바탕으로 하는 애매 모

* 正會員, 崇實大學校 電子計算學科

(Soong Sil University, Dept. of Computer Science)

※ 본 논문은 한국과학재단의 1995년도 핵심 전문 연구비에 의하여 연구되었음

接受日字: 1995年6月11日, 수정완료일: 1995年12月16日

호한 지식들을 통해 쉽게 의사 결정을 수행할 수 있다는 특징을 가지고 있다. “온도가 낮으면 난로의 온도를 조금 높인다”, “기후가 건조하면 가습기의 습도를 높인다.” 등의 지식들은 모두 명확하게 정량적으로 표현될 수 없는 지식들이다. 퍼지 추론은 이러한 애매 모호한 지식들을 정량적으로 표현하고 이를 통해 적절한 의사 결정을 수행할 수 있는 수단으로 제어 문제, 패턴 분류 문제 등 여러 분야에서 활용되고 있다^[1].

퍼지 추론은 언어적 변수들의 결합으로 이루어지는 퍼지 규칙을 이용하여 몇 개의 퍼지 명제들로부터 어

면 하나의 퍼지 명제를 이끌어 낼 수 있는 연역적인 추론 방법이다. 예를 들어 $A_i \rightarrow B_i$ 라는 퍼지 규칙에 대해 임의의 입력 A' 이 전제부 조건 A_i 를 어느 정도 만족할 때 퍼지 추론은 결론부 B_i 로부터 퍼지 결론 B' 을 유도한다. 퍼지 규칙의 조건부가 여러 퍼지 집합으로 이루어질 경우에는 조건부를 이루는 퍼지 집합들의 논리곱을 통해 조건부의 만족도를 계산한다. 따라서 입력 특징값들에 대한 조건부의 만족도는 조건부를 이루는 각 퍼지 집합들의 만족도의 최소값으로 계산되며 이렇게 구해진 조건부의 만족도는 결론부 퍼지 집합과의 논리곱을 통하여 결론부의 만족도를 유도하게 된다^[2]. 이와 같이 개별적 퍼지 규칙들에 의해 얻어진 부분적인 결론들은 논리합 연산에 의해 결합되어 역퍼지화 과정을 거쳐 유용한 결론을 얻게 된다. 그림 1은 이러한 추론 과정을 간략하게 표현하고 있다. 그림 1에서 보는 바와 같이 3개의 특징 A, B, C로부터 입력되는 값들은 조건부를 이루는 각 퍼지 집합(A_i, B_j, C_k)들에 의해 퍼지화되고 이 값들은 논리곱 연산에 의해 결합되어 결론부 D_i 의 빛금친 부분을 유도한다. 이렇게 유도된 부분적인 결론들은 최종적으로 논리합 연산에 의해 결합되어 D' 의 빛금친 부분을 유도하고 역퍼지화되어 의미 있는 결론을 얻게 된다.

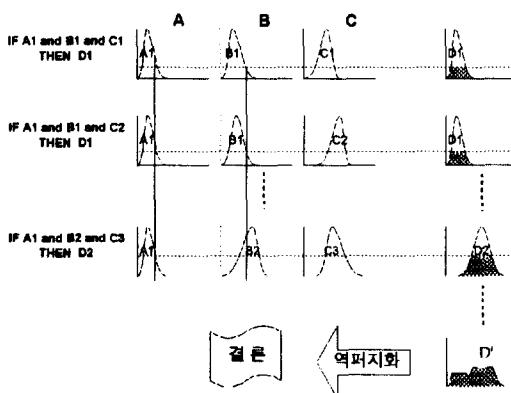


그림 1. 퍼지 추론의 기본 모델

Fig. 1. Basic model of fuzzy inference.

퍼지 추론은 부정확하고 애매한 특성이나 규칙 등을 쉽게 표현할 수 있고 입력 정보의 오류에 크게 영향을 받지 않으며 비교적 적은 수의 규칙으로 원하는 문제를 해결할 수 있다는 장점을 가지고 있다. 그러므로 많은 분야에서 유용하게 사용되고 있지만 다음과 같은 근본적인 문제점들을 해결해야 할 과제로 남기고 있다.

첫째, 퍼지 추론에서는 대부분의 전문가 시스템에서와 마찬가지로 인간 전문가의 지식을 바탕으로 퍼지 규칙을 생성한다. 그런데 인간 전문가의 지식을 적절하게 퍼지 소속 함수로 표현하고 규칙화할 수 있는 직관적이면서 타당한 방법이 없다. 둘째, 퍼지 규칙을 적응적으로 생성할 수 있는 학습 기능이 없다. 이로 인하여 동적으로 변화하는 환경에서 적응적으로 대처할 수 있는 추론 시스템의 구성이 불가능하다. 즉, 시스템의 환경이 바뀔 때마다 인간 전문가의 지식으로부터 소속 함수를 결정하고 이를 바탕으로 경험적으로 규칙을 생성해야 하는 지루하고 부정확한 과정을 반복할 수밖에 없다.

그러므로, 소속 함수를 인간 전문가의 도움 없이 시스템이 자동으로 추출하고 학습 기능을 통해 동적으로 변화하는 환경에 쉽게 적응할 수 있는 퍼지 추론 시스템의 개발이 요구된다.

앞에서 언급한 퍼지 추론에 있어서의 문제점들을 해결하기 위해 여러 가지 방법으로 연구가 진행되고 있다. 예를 들면 퍼지 패턴 공간의 분할을 통하여 퍼지 규칙의 자동 생성에 이용하고자 하는 퍼지 공간 분할 방법^[3], 전통적인 경사법을 이용하는 방법^{[4][5]} 등이 그것이다. 최근에는 신경망의 학습 기능과 적응성을 이용하고자 하는 연구^{[1][6][7][8]}가 활발히 진행되고 있는데 대부분 오류 역전파(error back propagation) 알고리즘과 같은 복잡한 학습 방법을 사용하고 있다.

본 논문에서는 기존의 퍼지 추론이 가지고 있는 문제점을 해결하고자 비교적 간단한 형태의 인공 신경망 모델인 연상 기억장치(associative memory)와 퍼지 집합 이론을 결합시킨 퍼지 연상 기억장치(fuzzy associative memory)라고 하는 기존의 퍼지 신경망 모델을 이용하여 효율적이고 적응적으로 퍼지 규칙을 생성하고 학습을 수행할 수 있는 퍼지 추론 시스템을 제안하고 이를 “퍼지 연상 기억장치에 기반한 추론 시스템”이라 한다.

퍼지 연상 기억장치에 기반한 추론 시스템은 그림 2와 같은 구조를 가지고 있으며 크게 학습 단계와 추론 단계의 두 단계로 이루어진다. 학습 단계는 다시 소속 함수 결정 단계와 퍼지 규칙 생성 단계로 나누어지며 소속 함수 결정 단계에서는 입력 특징들의 빈도수 분포를 나타내는 히스토그램(histogram)을 작성하고 이를 분석하는 방법으로 소속 함수를 결정하고 퍼지 규

칙 생성 단계에서는 퍼지 연상 기억장치의 학습 기능을 이용하여 각 퍼지 규칙 쌍들의 신뢰도를 가중치 행렬의 형태로 학습한다. 소속 함수 결정 단계와 퍼지 규칙 생성 단계를 통하여 추론 시스템의 학습이 완료되면 추론 단계에서는 실제적으로 문제를 해결하기 위해 전처리 단계를 통하여 입력 특징값들을 퍼지화하고 결합한 다음 학습 단계에서 만들어지는 퍼지 규칙을 통해 추론을 수행한다.

1장에서는 연구 동기와 퍼지 추론 시스템의 개요를 설명하였고 2장에서는 퍼지 연상 기억장치에 기반한 추론 시스템의 기본 구조에 대해 설명하고 3장에서는 본 논문에서 제안하는 퍼지 연상 기억장치에 기반한 추론 시스템의 학습에 대해 설명한다. 그리고, 4장에서는 실험 결과를 보이고 결론을 서술한다.

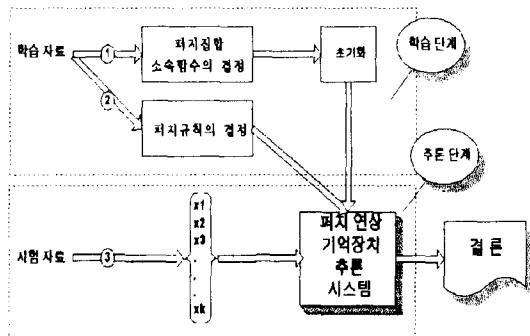


그림 2. 시스템의 개요

Fig. 2. System overview.

II. 퍼지 연상 기억장치에 기반한 추론 모델

인간의 두뇌는 반복되는 학습을 통해 서로 관련된 개념들을 연결하고 이를 연상 작용을 통해 기억해 낼 수 있는 연상 기억 기능을 가지고 있다. 예를 들면 여러 친구들 중에서 자주 연락하는 친한 친구의 전화번호를 기억하고 그 친구와 전화번호가 연결되어 필요할 때 연상해 낼 수 있는 기능이다. 이러한 두뇌의 생물학적인 기능을 모방하여 학습을 통해 관련된 개념들을 서로 연결하고 연상해 낼 수 있는 구조를 갖는 신경망 모델이 연상 기억장치이다.

연상 기억장치는 그림 3과 같이 입력층과 출력층으로 나누어지며 입력층의 각 입력노드들(A_1, A_2, \dots, A_n)과 출력층의 각 출력노드들 (B_1, B_2, \dots, B_m) 그리고 이들을 연결하는 가중치들($w_{11}, w_{12}, \dots, w_{mn}$)로 구성된다. 각각의 입력 출력노드들은 하나의 개념을 표현하고 있

으며 이들을 연결하는 간선 w_{ji} 는 개별적 개념들의 연결성을 의미하여 w_{ji} 가 큰 값을 가지면 A_i 와 B_j 가 상호 연결되는 정도가 크다는 것을 의미한다. 이러한 연상 기억장치의 입출력 구조를 수학적으로 표현하면 다음과 같다. 입력 벡터 $X = (x_1, x_2, \dots, x_n)$, 출력 벡터 $Y = (y_1, y_2, \dots, y_m)$ 가 주어질 때

$$XW = Y \quad (1)$$

$$\sum_{i=1}^n x_i w_{ji} = y_j \quad (j = 1, 2, \dots, m)$$

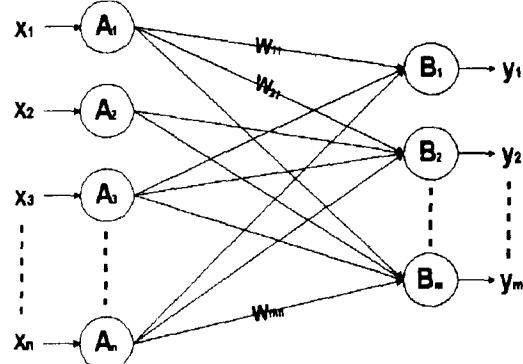


그림 3. 연상 기억장치의 기본 모델

Fig. 3. Basic model of associative memory.

(1)에서 보는 바와 같이 입출력층의 노드들과 간선들을 표현하기 위한 수학적 모델로 행렬을 사용하면 행렬 곱셈 연산으로 연상 기능을 표현할 수 있다. 여기서 X 가 $1 \times n$ 의 일차원 행렬, 즉 벡터이고 Y 도 역시 $1 \times m$ 의 벡터이며, W 는 $n \times m$ 의 이차원 행렬로 구성된다. 행렬 W 의 한 원소 w_{ji} 는 i 번째 입력노드와 j 번째 출력노드 사이의 상관관계를 나타내는 것으로 w_{ji} 의 값에 따라 각 입력노드들 사이의 연결성이 결정된다. 이와 같이 개념들을 연결하고 추론을 수행할 수 있는 연상 기억장치는 BAM(Bidirectional Associative Memory), Hopfield Network 등에 응용되어 주로 패턴 분류와 같은 비결정적인 문제를 해결하는데 효과적으로 이용되어 왔다^{[9][10]}.

퍼지 연상 기억장치는 이러한 연상 기억장치 신경망 모델에 퍼지 집합 이론을 결합한 것으로 각 노드들이 나타내는 기본 개념을 퍼지 집합으로 표현하고 노드들 간의 연결성을 통해 이를 퍼지 집합들 간의 사상을 나타낸다. 따라서 퍼지 연상 기억장치의 각 노드들은 퍼지 집합으로 정의되고 입력 퍼지 집합들의 소속 함수 값으로부터 출력 퍼지 집합의 소속 함수값을 연상해

내는 기능을 가지고 있다. 즉, 입력 특징값들이 입력층의 퍼지 집합들의 소속 함수를 만족하는 정도만큼 이에 대응되는 출력층의 퍼지 집합들의 소속 함수에 대한 만족도를 연상해 낸다. 그리고 퍼지 집합으로 구성되는 각 노드들을 연결하는 간선들의 연결성을 통해 입력 퍼지 집합들과 출력 퍼지 집합들 사이의 결합 정도가 결정된다^[11]. 그림 4는 퍼지 연상 기억장치의 기본적인 구조를 설명하고 있다.

그림 4에서 보는 바와 같이 퍼지 연상 기억장치는 연상 기억장치 신경망 모델과 매우 유사한 형태를 가지고 있지만 퍼지 연상 기억장치의 각 노드들은 퍼지 집합으로 구성되고 입력층의 퍼지 집합과 출력층의 퍼지 집합의 결합 정도를 결정하는 가중치의 학습과 입력 퍼지 집합의 만족도에서 출력 퍼지 집합의 만족도를 이끌어 내는 연상 방법에 있어서 연상 기억장치와 다르게 퍼지 집합 연산자인 퍼지 최대 연산자와 퍼지 최소 연산자를 사용한다

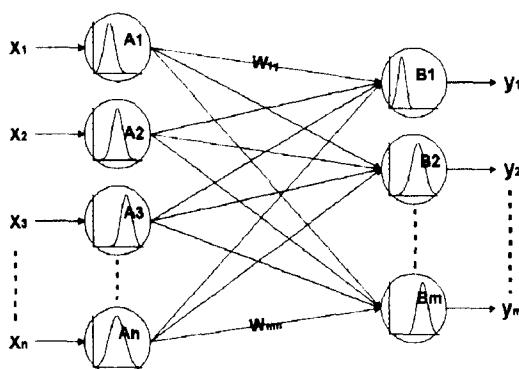


그림 4. 퍼지 연상 기억장치
Fig. 4. Fuzzy associative memory.

연상 기억장치 신경망 모델에서는 입력 벡터 X 와 출력 벡터 Y , 그리고 이들을 연결하는 연결 행렬 W 가 있을 때 (1)과 같이 행렬 곱셈 연산을 통하여 입력 벡터 X 로부터 출력 벡터 Y 를 연상해 내었는데 퍼지 연상 기억장치에서는 행렬 곱셈 대신 퍼지 최소 연산자를 사용한다. 입력층이 n 개의 퍼지 집합 A_1, A_2, \dots, A_n 으로 구성되고, 출력층이 m 개의 퍼지 집합 B_1, B_2, \dots, B_m 으로 구성되어질 때, 입력 벡터 $X = (x_1, x_2, \dots, x_n)$ 과 출력 벡터 $Y = (y_1, y_2, \dots, y_m)$ 간의 연상 작용은 (2)와 같이 정의된다.

$$y_j = \max \{ \min(\mu_{A1}(x_1), w_{j1}), \min(\mu_{A2}(x_2), w_{j2}), \dots, \min(\mu_{An}(x_n), w_{jn}) \} \wedge \mu_{Bj} \quad (2)$$

μ_{Ai} : 입력 퍼지 집합 A_i 의 소속 함수
 μ_{Bj} : 출력 퍼지 집합 B_j 의 소속 함수

이와 같이 퍼지 연상 기억장치는 입력 퍼지 집합과 출력 퍼지 집합을 연결하는 가중치를 통해 퍼지 집합들 간의 상호 연결성을 정의한다. 본 논문에서 제안하는 추론 시스템에서는 퍼지 연상 기억장치를 퍼지 규칙의 표현을 위한 기본 모델로 사용한다. 즉, 퍼지 연상 기억장치의 각 입력노드는 퍼지 규칙의 조건부를 나타내고 각 출력노드는 퍼지 규칙의 결론부를 나타내도록 한다. 그리고, 조건부는 하나의 퍼지 집합뿐 아니라 여러 퍼지 집합들의 조합으로 구성될 수 있다. 또한, 가중치 w_{ji} 는 i번째 조건부와 j번째 결론부로 이루어지는 퍼지 규칙의 가중치를 의미하고, 이는 추론시 퍼지 규칙의 i번째 조건부의 만족도로부터 j번째 결론부의 만족도를 이끌어 내는 신뢰도를 결정하게 된다. 규칙의 조건부가 여러 입력 특징들로 구성되는 경우에는 논리곱을 통해 이들을 결합한다. 그림 5는 이처럼 퍼지 연상 기억장치를 이용하여 본 논문에서 제안하는 퍼지 추론 시스템의 기본 구조를 보여주고 있다.

그림 5에서 보는 바와 같이 3개의 특징 X_A, X_B, X_C 가 주어지고, 이를 각각에 대해 n_1, n_2, n_3 개의 퍼지 집합이 있을 때, 각 퍼지 집합의 조합으로 이루어지는 조건부의 갯수 n 은 $n_1 \times n_2 \times n_3$ 의 값을 가지게 된다. 그리고, 결론부가 m 개의 퍼지 집합으로 구성된다면 조합 가능한 퍼지 규칙의 갯수는 총 $n_1 \times n_2 \times n_3 \times m$ 개가 된다. 그림 5에서 D는 각 퍼지 집합을 이루는 소속 함수들의 유용도를 나타내는 척도로써 0과 1사이의 값을 가지며 1에 가까운 값을 가질수록 결론을 명확하게 이끌어 낼 수 있는 퍼지 집합이라는 것을 의미한다. D의 값은 추론시 각 소속 함수에 곱해져서 소속 함수의 유용도가 추론에 반영될 수 있도록 한다. w_{ji} 는 i번째 조건부와 j번째 결론부로 이루어지는 퍼지 규칙의 신뢰도를 나타낸다. 따라서 퍼지 규칙은 그림 5에서 보는 바와 같이 일반적인 퍼지 규칙과 달리 조건부와 결론부를 연결하는 가중치 w_{ji} 를 포함한 형태를 가진다. 이와 같이 퍼지 규칙이 구성되면 서론에서 설명한 일반적인 퍼지 추론 방법과 퍼지 연상 기억장치의 연상 방법을 결합한 형태로 추론을 수행한다. 일반적인 퍼지 추론에서는 그림 1에서와 같이 어떤 임의의 입력 특징값들에 대해 조건부의 만족도가 조건부의 각 퍼지 집합을 구성하는 소속 함수값들의 최소값

으로 결정되고 결론부 퍼지 집합과 논리곱을 통해 퍼지 규칙의 만족도를 구하게 된다. 그리고 각각의 개별적 퍼지 규칙들에 대한 만족도가 논리합으로 결합되어 전체적인 결론에 이르게 된다.

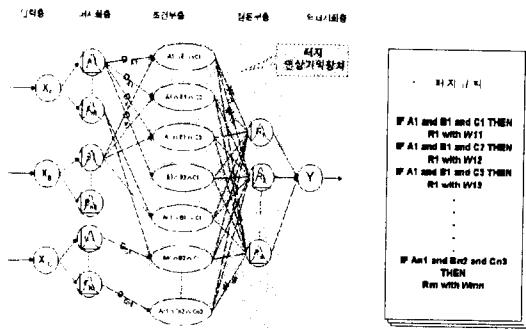


그림 5. 퍼지 연상 기억장치에 기반한 추론 시스템의 기본 모델

Fig. 5. Basic model of inference system based on fuzzy associative memory.

본 논문에서는 퍼지 연상 기억장치를 이용하여 일반적인 추론 방법에 조건부와 결론부를 연결하는 가중치 행렬이 개입되어 각 규칙의 신뢰도에 영향을 미친다. 그리고, 조건부를 구성하는 각 입력 퍼지 집합의 유용도를 반영하여 좀 더 명확히 추론을 수행할 수 있다. i 번째 조건부와 j번째 결론부로 이루어지는 어떤 퍼지 규칙에 대해서 i번째 조건부의 만족도는 조건부를 구성하는 퍼지 집합들에 대한 소속 함수값에 유용도 D를 곱한 다음 이들의 최소값으로 결정된다. 그리고, 이렇게 구해진 i번째 조건부의 만족도는 w_{ij} 와 논리곱 연산을 수행한 후, j번째 결론부와 논리곱으로 결합된다. 이러한 부분적인 결론들은 일반적인 퍼지 추론에서와 마찬가지로 논리합으로 결합되어 하나의 결론을 유도 한다. 신뢰도 w_{ij} 가 1의 값으로 최대값을 가지게 되면 조건부의 만족도가 결론부의 만족도와 그대로 결합되고 만약 w_{ij} 가 0의 값으로 최소값을 가지게 되면 조건부의 만족도가 결론부의 만족도와 전혀 결합되지 않아 그 퍼지 규칙은 전체적인 결론에 아무런 영향을 미치지 못한다. 따라서 가중치 w_{ij} 를 통해 각 퍼지 규칙의 결론에의 기여도를 나타내게 된다. 이러한 추론 과정을 그림 6에서 설명하고 있다.

그림 6에서는 조건부가 A와 B의 두 퍼지 집합의 논리곱으로 구성되고 결론부 퍼지 집합이 C와 같이 구성되는 퍼지 규칙의 예를 보여주고 있다. 입력 특징값들

이 각각 A와 B의 소속 함수에 의해 퍼지화되면 이 값들은 각 소속 함수들의 유용도 D_A , D_B 와 곱해지고, 그 결과가 논리곱에 의해 결합되고 다시 퍼지 규칙의 신뢰도 W와 논리곱 연산을 수행한다. 그리고 그 결과를 결론부 퍼지 집합 C의 소속 함수와 논리곱으로 결합하여 부분적인 결론을 얻는다.

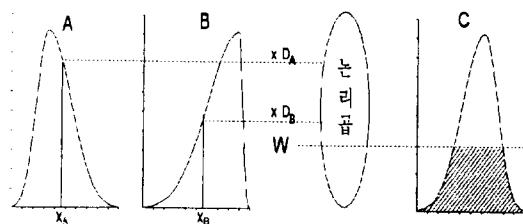


그림 6. 퍼지 연상 기억장치를 이용한 추론의 기본 모델

Fig. 6. Basic model of inference using fuzzy associative memory.

이러한 퍼지 연상 기억장치를 이용한 추론을 수학적으로 표현하면 (3)과 같이 표현된다.

$$y_k = \min(\min(\mu_A(x_A) \times D_A, \mu_B(x_B) \times D_B), w_k) \quad (3)$$

x_A : 퍼지집합 A에 대한 입력특징값,

x_B : 퍼지집합 B에 대한 입력특징값

μ_A : 퍼지집합 A의 소속함수,

μ_B : 퍼지집합 B의 소속함수

y_k : k번째 규칙의 부분적인 결론,

w_k : k번째 규칙의 신뢰도

\wedge : 조건부의 만족도와 결론부 퍼지 소속 함수와의 논리곱

(3)에서 집합의 형태로 얻어지는 각 퍼지 규칙에 의한 부분적인 결론들은 논리합으로 결합되어 최종적인 결론에 이르게 된다. 이와 같이 퍼지 연상 기억장치를 퍼지 추론에 응용함으로써 퍼지 추론에서의 규칙 생성과 학습에서의 문제점들을 해결할 수 있으며 조건부와 결론부의 연결성을 나타내는 가중치 행렬을 통해 좀 더 세밀하고 정확하게 퍼지 추론을 수행할 수 있다. 그러나, 퍼지 연상 기억장치는 기본적으로 입력총을 이루는 퍼지 집합들과 출력총을 이루는 퍼지 집합 및 소속 함수가 정의되고 입력총과 출력총을 연결하는 가중치

행렬이 정의되어 있는 경우에 퍼지 추론에 적용될 수 있다. 따라서, 입출력총의 퍼지 집합 즉, 퍼지 규칙의 조건부와 결론부를 이루는 각 퍼지 집합들을 정의하고, 이들 각각의 소속 함수 및 이들 간의 연결성을 나타내는 가중치 행렬을 결정하는 단계가 별도로 필요하다. 3장에서는 퍼지 연상 기억장치에서 가장 핵심적인 요소라고 할 수 있는 각 퍼지 집합들과 그들의 소속 함수를 결정하고 이를 바탕으로 가중치 행렬의 학습을 통해 퍼지 규칙을 생성하는 방법을 설명한다.

III. 퍼지 연상 기억장치에 기반한 추론 시스템의 학습

앞장에서 설명한 바와 같이 퍼지 연상 기억장치는 퍼지 추론 규칙을 표현하기에 매우 적절한 구조를 가지고 있으며, 이를 이용하여 효과적인 추론 시스템을 구축할 수 있다. 퍼지 연상 기억장치를 이용하여 추론 시스템을 구축하는데 있어서 가장 중요한 핵심이라고 할 수 있는 부분이 퍼지 규칙의 자동 생성인데, 이를 위해서는 다음 사항들을 고려하여야 한다.

- (1) 각 특징 및 결론을 몇 개의 퍼지 집합으로 나눌 것인가?
- (2) 각 퍼지 집합에 대한 소속 함수를 어떻게 결정 할 것인가?
- (3) 최적의 퍼지 규칙을 어떻게 생성할 것인가?

이러한 고려 사항들은 퍼지 추론에 있어서의 고전적인 문제들로 대부분 인간 전문가의 경험적 지식에 의존하여 결정되고 사용되어 왔다. 본 논문에서는 크게 두 단계에 걸쳐 -퍼지 소속 함수의 결정 단계와 퍼지 규칙의 생성 단계- 이러한 문제들을 인간 전문가에 의존하지 않고 학습을 통해 자동으로 해결할 수 있는 방법을 제안한다.

퍼지 소속 함수는 퍼지 규칙을 이루는 각 퍼지 집합을 특징짓는 함수로 퍼지 집합의 원소들이 그 퍼지 집합에 소속되는 정도를 나타낸다. 소속 함수 결정 단계는 특징 공간을 몇 개의 퍼지 집합으로 나눌 것인가를 결정하고 이들 각 퍼지 집합에 적절한 소속 함수를 할당하는 작업으로, 본 논문에서는 학습 자료들의 빈도수 분포를 분석하는 방법을 제안한다. 그리고, 퍼지 규칙의 생성 단계에서는 결정된 퍼지 소속 함수들로 퍼지 연상 기억장치의 기본 구조를 구성하고 “헤비안 학습(hebbian - learning)”을 응용한 퍼지 연상 기억장

치의 학습 기능을 이용하여 각 퍼지 규칙의 신뢰도를 결정함으로써 필요한 규칙을 생성한다.

1. 퍼지 소속 함수의 결정

퍼지 소속 함수는 퍼지 규칙에서 가장 기본이 되는 부분으로 매우 중요한 역할을 하고 있다. 대부분의 경우 퍼지 소속 함수는 전문가의 주관적인 판단에 의해 그림 7과 같은 기본적인 형태들로 구성되어 진다. 그러나 전문가의 주관적인 판단만으로는 정확한 퍼지 소속 함수를 결정할 수 없고, 복잡한 문제의 경우 그림 7과 같은 기본형만으로는 적합한 퍼지 소속 함수를 표현하지 못할 경우가 많다. 따라서, 본 논문에서는 소속 함수의 형태를 그림 8과 같이 좀 더 일반적인 형태로 정의하고 입력 특징값들의 빈도수 분포를 분석하여 퍼지 소속 함수를 결정하는 방법을 제안한다.

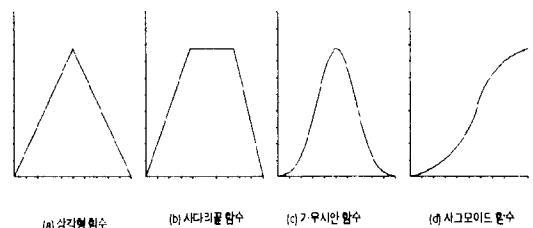


그림 7. 일반적인 소속 함수의 기본 유형

Fig. 7. Basic types of general membership functions.

본 논문에서 제안하는 그림 8과 같은 소속 함수의 유형은 사다리꼴 함수와 시그모이드(sigmoid) 함수를 결합한 형태로 두개의 시그모이드 함수와 하나의 1의 값을 갖는 상수 함수로 소속 함수가 구성되어지며 (4), (5)와 같이 정의된다.

$$G(x, C, L, R, M) = \dots \quad (4)$$

$$\begin{cases} S(x, C-L, C-L/2, C) & \text{if } x < C \\ 1 & \text{if } C \leq x < C+M \\ 1-S(x, C+M, C+M+R/2, C+M+R) & \text{if } x \geq C+M \end{cases}$$

$$S(x, \alpha, \beta, \gamma) = \begin{cases} 0 & \text{if } x < \alpha \\ 2((x-\alpha)/(\gamma-\alpha))^2 & \text{if } \alpha \leq x < \beta \\ 1-2((x-\gamma)/(\gamma-\alpha))^2 & \text{if } \beta \leq x < \gamma \\ 1 & \text{if } x \geq \gamma \end{cases} \quad (5)$$

C : 좌측 시그모이드 함수값이 최대가 될 때의 x값

L : 좌측 시그모이드 함수의 밑변의 길이

R : 우측 시그모이드 함수의 밑변의 길이

M : 상수 함수의 길이

본 논문에서 정의하는 소속 함수 (G)는 좌측 및 우측

의 시그모이드 함수를 독립적으로 조율할 수 있고 넓은 구간에 걸쳐 1의 값을 갖는 상수 함수로 확장될 수도 있다. 즉, 각 시그모이드 함수의 인수 C, L, R, M을 적절히 조절함으로써 다양한 소속 함수를 표현하고 각 퍼지 집합에 해당하는 소속 함수를 결정할 수 있다.

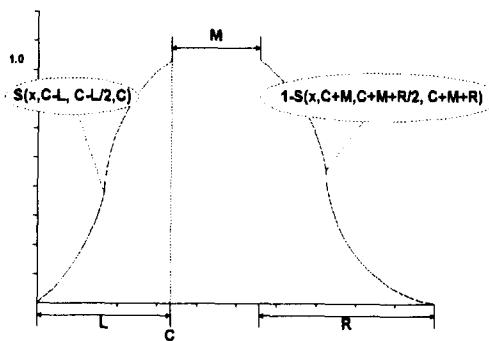


그림 8. 소속 함수 G

Fig. 8. Member function G.

본 논문에서는 k 개의 입력 특징과 하나의 출력값 ($x_1, x_2, x_3, \dots, x_k : y$)의 형태로 하나의 학습 자료를 표현하고, k 개의 특징들과 출력값 y 에 대한 학습 자료들의 빈도수 분포를 분석하여 조건부와 결론부를 이루는 소속 함수 G 의 인수들을 결정함으로써 추론의 기본이 되는 퍼지 집합들을 구성한다. 즉, k 개의 각 특징에 속하는 소속 함수들의 퍼지 집합들을 조합하여 조건부를 구성하고 출력값들에 대한 소속 함수들로 결론부 퍼지 집합을 구성한다. 이를 위해 학습 자료들을 k 개의 특징과 출력값으로 분류하고 이들 각각에 대한 빈도수 분포를 히스토그램 형태로 표현한다. 그리고, 소속 함수 G 가 히스토그램과 가장 유사한 형태가 되도록 인수들을 조절하여 소속 함수의 기본 구조를 형성한 후, 각 특징과 출력값에 대한 소속 함수를 결정한다. 학습 자료들의 히스토그램은 학습 자료들이 어떠한 형태로 분포되어 있는가를 잘 나타내므로 빈도수가 높은 마루(peak) 부분에서는 소속 함수값을 높게 하고 빈도수가 적은 골(valley) 부분에서는 소속 함수값이 낮게 되도록 인수들을 조절한다. 이러한 과정을 통하여 주어진 학습 자료들의 빈도수 분포로부터 퍼지 집합을 결정하고 이에 해당하는 소속 함수 G 를 적합시키고 조율하는 과정을 상세히 설명하면 다음과 같다.

먼저, 학습 자료들을 각 특징과 출력값으로 분류하고 분류된 자료들의 빈도수 분포를 나타내는 히스토그램 H_i 로 구성한다. 여기서 H_i 는 i 가 k 보다 작거나 같은

경우 i 번째 특징에 대한 히스토그램을 나타내고, i 가 $k+1$ 인 경우 출력값들에 대한 히스토그램을 나타낸다. 그리고, 이들 각 히스토그램의 가로축은 특징값 또는 출력값을 나타내고 세로축은 이들 특징값이나 출력값들의 빈도수를 나타낸다. 그림 10의 (a)는 히스토그램 H_i 의 한 예를 보여준다. 그림 10에서 보는 바와 같이 히스토그램은 일반적으로 여러개의 마루와 골로 이루어지며 사용되는 특징이 좀 더 명확하고 구분력이 좋을수록 높은 마루와 깊은 골을 갖는 히스토그램이 만들어진다. 히스토그램의 마루와 골은 지역적 최대값(local maxima)과 지역적 최소값(local minima)에 의하여 확인될 수 있다. 그러나 대부분의 히스토그램은 너무 많은 지역적 최소값과 최대값을 포함하는 유통불통한 형태를 가진다. 따라서 히스토그램에 대한 평활화 작업(smoothing)을 수행하여 히스토그램의 전체적인 구조를 나타내는 높은 마루와 깊은 골만을 확인한 후, 확인된 마루를 $P_{i,j}$ 그리고 그 양쪽의 골들을 $V_{i,j}^L$ 와 $V_{i,j}^R$ 로 표현한다. 위의 표현에서 아래첨자 i,j 는 각각 i 번째 히스토그램, j 번째 마루 또는 골을 표시하는 색인이며, 윗첨자 L 은 마루에 대한 좌측 골을 나타내고 R 은 우측 골을 나타낸다. 이제 찾아진 마루 $P_{i,j}$ 를 중앙값으로 하는 소속 함수 $G_{i,j}$ 를 (6)과 같이 구성한다. 그림 10의 (b)는 이러한 처리 과정을 통하여 만들어진 소속 함수 $G_{i,j}$ 들을 보여준다.

$$G_{i,j} = G(x, C_{i,j}, L_{i,j}, R_{i,j}, M_{i,j}) \quad (6)$$

$$C_{i,j} = P_{i,j}, \quad L_{i,j} = P_{i,j} - V_{i,j}^L$$

$$R_{i,j} = V_{i,j}^R - P_{i,j}, \quad M_{i,j} = 0$$

각 특징에 대한 초기 소속 함수들이 만들어지면, 이들이 얼마나 유용한가를 나타내는 척도를 정의하고 정의된 척도에 의하여 계산된 유용도를 추론 과정에 활용할 수 있다. 어떤 퍼지 집합이 결론을 유도하는데 매우 좋은 퍼지 집합이라면 그 퍼지 집합은 결론부를 구성하는 퍼지 집합들을 잘 구분해 내어 명확한 결론을 유도할 수 있고 그렇지 못하다면 결론의 유도를 불명확하게 만들 것이다. 따라서, 본 논문에서는 조건부의 각 특징에 해당하는 퍼지 집합들의 소속 함수들이 결론부 퍼지 집합의 각 소속 함수들을 구분하는 정도를 나타내는 유용도 $D_{i,j}$ 를 (7)과 같이 계산하여 추론시 각 퍼지 집합에 대한 가중치로 사용한다. 소속 함수 $G_{i,j}$ 의 유용도를 나타내는 $D_{i,j}$ 는 0과 1사이의 값을 갖

게 되며, $G_{i,j}$ 가 다른 결론을 유도하는 인접한 소속 함수들과 중복되는 영역이 크다면 0에 가까운 값을, 중복되는 영역이 작다면 1에 가까운 값을 갖게 된다. 여기서 소속 함수 $G_{i,j}$ 와 인접한 소속 함수들 사이의 중복 정도는 $G_{i,j}$ 의 면적 $\text{area}(G_{i,j})$ 과 $G_{i,j}$ 와 중복되는 $G_{i,k}$ 의 면적 $\text{area}(G_{i,j} \cap G_{i,k})$ 의 비율로 계산되고, 각 소속 함수가 유도하는 결론값들 간의 유사도는 $A_{i,j,k}$ 에 의해 계산되며, λ 는 정규화를 위하여 사용되는 인수이다. 즉, i번째 특징의 j번째 소속 함수에 의한 결과와 k번째 소속 함수에 의한 결과의 유사도가 높을수록 $A_{i,j,k}$ 는 작은 값을 갖게 된다. 이처럼 입력 퍼지 집합들의 유용도를 퍼지 추론에 반영함으로써 부적절한 특징들이 퍼지 추론에 미치는 영향을 줄이고 좋은 특징들의 영향을 강화하여 더욱 정확하게 퍼지 추론을 수행할 수 있다.

$$D_{i,j} = 1 - \frac{1}{N_i-1} \times \sum_{k \neq j} \left\{ \frac{\text{area}(G_{i,j} \cap G_{i,k})}{\text{area}(G_{i,j})} \times \frac{\lambda - A_{i,j,k}}{\lambda} \right\} \quad (7)$$

$$A_{i,j,k} = |\text{mean}(G_{i,j}) - \text{mean}(G_{i,k})|$$

$\text{mean}(G)$ = G를 구성하는 입력 자료들이 유도하는 결과값들의 평균

$$\lambda = \{ \max_j \text{mean}(G_{i,j}) \} - \{ \min_j \text{mean}(G_{i,j}) \}$$

N_i = 특징 i에 대한 소속 함수의 개수

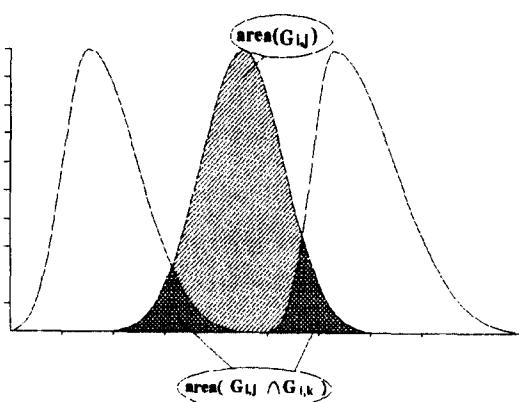


그림 9. 퍼지 집합의 유용도 계산

Fig. 9. Usability Calculation of a fuzzy set.

이와 같이 특징 또는 출력값에 대한 소속 함수들의 초기 인수들이 결정되면 이들을 퍼지 집합 개념에 알맞도록 적절히 조절할 필요가 있다. $G_{i,j}$ 들은 한정된 학습 자료들에 의해 만들어진 것이므로 $G_{i,j-1}$ 과 $G_{i,j}$ 사이

에는 소속 함수값을 가지지 않는 영역들이 존재할 수 있다. 그러나, 소속 함수가 정의되지 않는 영역들은 의미 있는 특정 공간의 크기를 제한하는 결과를 초래한다. 따라서, 추론 과정에서 이러한 영역들에 속하는 자료들에 대한 의미 있는 처리를 위하여 이러한 부분을 작은 소속 함수값을 가지도록 하는 간단한 보간 작업이 필요하다. 즉, 소속 함수값이 0인 부분들의 양쪽에 위치하는 소속 함수들($G_{i,j-1}$, $G_{i,j}$)의 시그모이드 함수 부분을 확장하여 이러한 영역을 포함하도록 한다. 왼쪽에 위치한 소속 함수 $G_{i,j-1}$ 의 시그모이드 함수 $S_{i,j-1}^R$ 와 오른쪽에 위치한 소속 함수 $G_{i,j}$ 의 시그모이드 함수 $S_{i,j}^L$ 의 길이의 비율을 고려하여 (8)과 같이 보간 작업을 수행한다. 그림 10의 (c)는 (b)의 각 소속 함수를 이와 같이 확장한 결과를 보여준다.

$$R_{i,j-1}^{\text{new}} = (C_{i,j} - C_{i,j-1}) \times \frac{R_{i,j-1}}{\text{MAX}} \quad (8-1)$$

$$L_{i,j}^{\text{new}} = (C_{i,j} - C_{i,j-1}) \times \frac{L_{i,j}}{\text{MAX}} \quad (8-2)$$

$$\text{MAX} = \max(R_{i,j-1}, L_{i,j})$$

일반적으로 각 특징값에 의하여 정의되는 퍼지 집합들 중에서 특징축의 가장 왼쪽과 오른쪽에 위치하는 퍼지 집합은 최소와 최대의 개념을 나타낸다. 따라서, 이러한 특성을 갖는 퍼지 집합에 대해서는 (9)와 같이 소속 함수의 M값을 조절하여 최소 및 최대의 개념을 나타낼 수 있도록 한다. 즉, 특징축의 가장 왼쪽에 있는 소속 함수 $G_{i,\text{first}}$ 의 인수 $M_{i,\text{first}}$ 의 값을 원점에서 $G_{i,\text{first}}$ 의 중심 $C_{i,\text{first}}$ 까지의 거리로 설정하고, 가장 오른쪽에 있는 소속 함수 $G_{i,\text{last}}$ 의 인수 $M_{i,\text{last}}$ 의 값을 $G_{i,\text{last}}$ 의 중심값 $C_{i,\text{last}}$ 에서 특징축의 최대값 1까지의 거리로 설정한다. 그림 10의 (d)는 이러한 과정을 잘 보여 주고 있다.

$$M_{i,\text{first}} = C_{i,\text{first}} \quad (9-1)$$

$$C_{i,\text{first}} = 0 \quad (9-2)$$

$$M_{i,\text{last}} = 1 - C_{i,\text{last}} \quad (9-3)$$

이처럼 소속 함수에 대한 적합과 조율이 완료되면 이들 각각에 대해 언어적 퍼지 변수가 할당되어 하나의 퍼지 집합을 구성하게 된다. 예를 들어 그림 10에서와 같이 특징 i에 대해 2개의 퍼지 소속 함수가 만들어 졌다면 이들 각각에 대해 “작다”, “크다”와 같은 언어적 변수를 할당하여 퍼지 집합 $F_{i,\text{작다}}$, $F_{i,\text{크다}}$ 를 이루

게 된다.

이와 같이 형성된 퍼지 집합들을 기반으로 하여 추론 시스템의 퍼지화 단계에 해당하는 각 노드들을 구성하고 퍼지 연상 기억장치의 조건부와 결론부의 노드들을 구성하여 시스템을 초기화한다. 3.2 절에서는 이렇게 초기화된 퍼지 연상 기억장치를 통해 퍼지 규칙을 가중치의 형태로 학습하는 방법에 대해 설명한다.

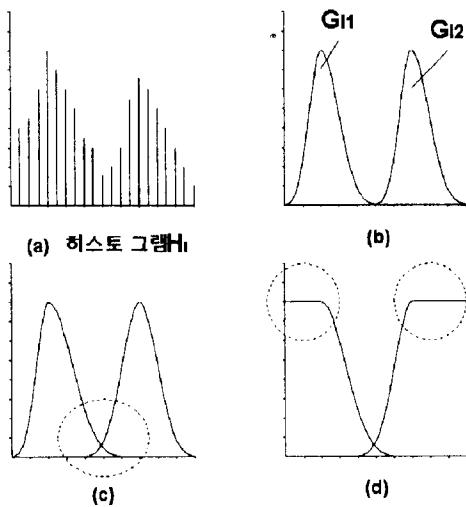


그림 10. 소속 함수의 결정

Fig. 10. Determination of membership function.

2. 학습을 통한 퍼지 규칙의 생성

히스토그램 분석을 통해 각 입력 특징들과 출력값에 대한 퍼지 소속 함수가 결정되면 이를 바탕으로 조건부와 결론부를 만들어 퍼지 연상 기억장치를 초기화한다. 이처럼 퍼지 연상 기억장치가 초기화되면 적절한 학습 방법을 이용하여 조건부와 결론부의 각 노드들을 연결하는 가중치 행렬 W 를 결정하게 된다. 일반적으로 퍼지 연상 기억장치의 가중치의 학습은 헤비안 학습에 기초한 학습 방법을 사용한다^[11].

헤비안 학습은 가장 오래되고 유명한 생물학적 신경망의 학습 방법 중의 하나로 정신 생리학자인 Hebb에 의해 1949년 소개되었다. 헤비안 학습은 “연결된 두 개의 뉴런들이 동시에 활성화된다면 이들의 연결 강도가 증가한다.”라고 하는 신경망의 생물학적 학습 방법을 설명하고 있다^[10]. 인공 신경망에서는 이러한 생물학적 신경망의 학습 규칙을 이용하여 많은 분야에 응용하고 있다. 즉, 학습 과정에서 연결된 두 노드들이 모두 큰 값으로 활성화된다면, 이들을 연결하는 가중치

w 는 그만큼 증가하고 이러한 현상이 반복적으로 발생하면 할수록 가중치 w 는 계속 증가한다. 이렇게 학습된 가중치들은 각 노드들 사이의 연결 강도를 결정하여 각 노드들이 나타내는 개념들 사이의 연결성을 표현한다. 헤비안 학습 방법을 수학적 형태로 표현하면 t 번째 학습 자료에 대해 $x_i(t)$ 와 $y_j(t)$ 로 표현되는 각 입출력 노드들의 연결성을 나타내는 가중치의 변화량 $\Delta w_{ij}(t)$ 는 (10)과 같이 표현된다.

$$\Delta w_{ij}(t) = \eta \cdot x_i(t) \cdot y_j(t) \quad (10)$$

여기에서 η 는 양의 상수로 학습률을 나타내는 것으로 학습의 진행 속도와 정밀도를 결정한다.

퍼지 연상 기억장치에서는 이러한 헤비안 학습 방법에 퍼지 집합 개념을 적용하여 퍼지 집합들 간의 연결성을 학습한다. 즉, 곱셈 연산 대신 퍼지 최소 연산을 사용하여 가중치를 학습하고, 가중치 변화를 누적시킬 때에도 덧셈 대신 퍼지 최대 연산을 사용한다. 입력층이 n 개의 퍼지 집합 A_1, A_2, \dots, A_n 으로 구성되고, 출력층이 m 개의 퍼지 집합 B_1, B_2, \dots, B_m 으로 구성되며 입력벡터와 출력벡터가 각각 (x_1, x_2, \dots, x_n) , (y_1, y_2, \dots, y_m) 으로 주어질 경우 입력층과 출력층을 연결하는 가중치 행렬 W 는 (11)과 같이 계산될 수 있다.

$$W(t+1) = W(t) \oplus \Delta W(t+1) \quad (11-1)$$

$$\Delta W = X^T \otimes Y \quad (11-2)$$

$$X = (\mu_{A1}(x_1), \mu_{A2}(x_2), \dots, \mu_{An}(x_n))$$

$$Y = (\mu_{B1}(y_1), \mu_{B2}(y_2), \dots, \mu_{Bm}(y_m))$$

$$\Delta w_{ij} = \min(\mu_{Ai}(x_i), \mu_{Bi}(y_j)) \quad (11-3)$$

μ_{Ai} : i번째 입력 퍼지 집합 A_i 의 소속 함수

μ_{Bi} : j번째 출력 퍼지 집합 B_j 의 소속 함수

여기서 연산자 \oplus 는 행렬의 각 대응되는 원소들에 대한 퍼지 최대 연산을, 연산자 \otimes 는 벡터의 각 대응되는 원소들에 대한 퍼지 최소 연산을 의미한다. 위의 식에서 각 입출력 노드들은 그에 해당하는 소속 함수값을 가지고 이를 최소 연산으로 결합하여 노드들 사이의 연결성을 결정한다. 그리고 이렇게 결정된 연결성은 최대 연산으로 다시 누적되어 최종적인 가중치 벡터를 얻게 된다. 이와 같이 산술 연산이나 행렬 연산 대신 퍼지 연산을 사용하여 학습을 수행함으로써 퍼지

집합의 특성을 최대한 활용할 수 있다.

본 논문에서는 이러한 퍼지 연상 기억장치의 학습 방법을 이용하여 조건부의 퍼지 집합들과 결론부의 퍼지 집합들 사이의 연결성을 학습한다. 즉, 입력 퍼지 집합으로 조건부를 구성하고 출력 퍼지 집합으로 결론부를 구성하여 각 퍼지 집합의 소속 함수값으로 (11)과 같이 가중치 벡터를 학습한다. 완전히 연결되어 있는 조건부와 결론부들의 집합에서 어떤 조건부 x_i 의 만족도가 클 때, 이와 연결된 어떤 결론부 y_j 의 만족도가 크게 나타난다면 조건부 x_i 와 결론부 y_j 로 이루어지는 퍼지 규칙이 성립될 가능성이 크다는 것을 의미하고, 이들을 연결하는 가중치 w_{ij} 에 큰 값이 할당되어 추론 시 전체적인 결론을 이끌어 내는데 그만큼 큰 영향을 미치게 된다. 만약, 조건부가 하나의 특징에 의해 구성되지 않고 여러 특징들에 의해 결정된다면 조건부는 각 특징에 해당하는 소속 함수들의 조합으로 구성되고 각 조건부를 구성하는 소속 함수값들의 최소값으로 조건부의 값이 결정된다.

이와 같이 퍼지 연상 기억장치의 학습을 통하여 가중치 행렬 W 가 완성되면 퍼지 연상 기억장치의 구성이 완료되어 그림 5와 같은 퍼지 연상 기억장치의 기반한 추론 시스템이 구성된다. 그림 5에서 보는 바와 같이 퍼지 연상 기억장치에 기반한 추론 시스템은 입력층, 퍼지화층, 조건부층, 결론부층, 역퍼지화층의 5개의 층으로 이루어진다. 퍼지 연상 기억장치는 조건부층과 결론부층으로 이루어져 시스템에서 가장 핵심적인 역할을 하고 있으며, 퍼지 연상 기억장치의 입력노드를 구성하는 각 조건부를 이끌어 내기 위해 입력 특징값들을 퍼지화하고 결합하는 전처리 과정을 거치게 된다. 퍼지화층에서는 각 입력 특징값들을 각 퍼지 집합의 소속 함수에 따라 퍼지화하며, 그 결과에 다시 퍼지 집합의 유용도를 곱하여 조건부층으로 넘겨준다. 조건부층에서는 조건부를 구성하는 퍼지 집합들로부터 입력 특징값들을 받아 논리곱 연산을 통하여 이들을 결합하고, 그 결과를 가중치 행렬과 논리곱 연산을 수행한 다음 결론부층으로 전달한다. 결론부층에서는 조건부층으로부터 입력되는 각 입력값들을 각 결론 퍼지 집합에 대해 논리곱을 수행하여 부분적인 결론을 얻고 이들을 논리합 연산을 통해 결합하여 전체적인 결론을 유도한다. 이처럼 추론된 결론은 퍼지 집합의 형태로 표현되므로 역퍼지화층을 거쳐 원하는 형태의 결론을 도출한다.

본 논문에서 제안하는 추론 시스템은 주어진 문제의 해를 구하는 추론 과정에 사용하거나 또는 그림 5와 같이 신뢰도를 포함하는 형태의 퍼지 규칙들을 추출하기 위하여 사용될 수 있다. 학습을 통해서 결정된 가중치 행렬 W 가 곧 각 퍼지 규칙의 신뢰도를 결정하고 있기 때문에 이들의 값을 분석하여 신뢰도가 특정한 임계값 θ 보다 큰 조건부와 결론부의 조합만을 퍼지 규칙으로 추출하여 계산 과정을 단순화할 수 있다. 즉, 임계값 θ 보다 작은 가중치를 갖는 연결을 제거하여 입출력층간의 연결 구조를 단순화할 수 있다. 이러한 임계값 θ 가 너무 큰 경우에는 작은 신뢰도를 갖는 퍼지 규칙들을 잊어버리기 때문에 정밀한 추론을 수행할 수 없게 되고, 임계값 θ 가 너무 작은 경우에는 퍼지 규칙의 수가 많아진다는 문제가 발생할 수 있어 적절한 임계값 θ 를 설정하는 것도 중요하다.

본 논문에서는 제안한 추론 시스템을 시험해 보기 위해 패턴 분류의 표준 평가 자료인 “아이리스 자료(iris data)”를 분류하는 문제에 적용해 보았으며, 그 결과를 4장에서 다루기로 한다.

IV. 실험 및 결론

본 장에서는 본 논문에서 제안하는 퍼지 연상 기억장치에 기반한 추론 시스템의 효율성을 검토하기 위해 패턴 분류의 표준 자료인 아이리스 자료에 대하여 실험한 결과를 보인다. 실험에 사용된 컴퓨터는 IBM-PC/486이며 사용된 언어는 Microsoft C 8.0이다. 아이리스 자료는 4개의 특징과 3개의 클래스로 이루어져 있으며, 각 클래스에 대해 50개씩의 특징 벡터를 가지고 있어, 총 150개의 특징 벡터로 이루어진다. 본 논문에서는 각 클래스에 대해 n 개의 아이리스 자료를 무작위로 추출하여 총 $N(3 \times n)$ 개의 아이리스 자료를 학습 자료로 사용한다. 그리고 나머지 150- N 개의 아이리스 자료를 시험 자료로 사용한다. 학습 자료의 갯수에 따른 성능을 평가하기 위해 여러 학습 자료의 갯수 $N(21, 30, 60, 90)$ 에 대해 실험을 수행하였다. 표 1은 실험에 사용된 아이리스 자료를 나타낸다. 본 논문에서 제안한 시스템의 성능을 비교하기 위해 [3]에서 비교되고 제안된 방법들을 중심으로 제안한 방법과 비교하였다.

학습 자료들은 4개의 특징값과 하나의 결론 클래스로 이루어지는 벡터(x_1, x_2, x_3, x_4, c) 형태로 입력된

다. 표 1은 75개일 때(75개의 학습 자료) 각 특징에 대해 히스토그램을 생성한 결과는 그림 11과 같고 학습 단계의 소속 함수 생성 단계를 거쳐 퍼지 소속 함수를 결정하면 그림 12와 같은 소속 함수를 얻을 수 있다. 표 4에서는 이와 같이 생성된 각 소속 함수들에 대한 유용도를 나타낸다.

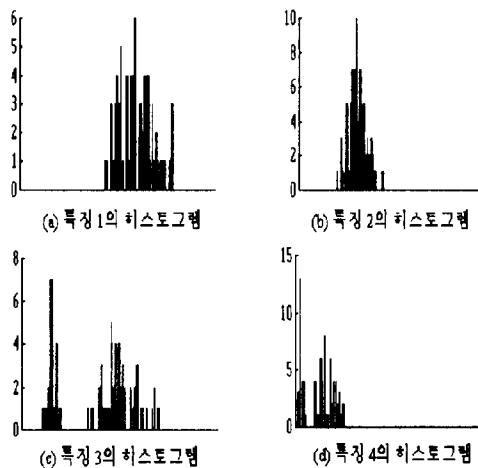


그림 11. 각 특징에 대한 소속 함수

Fig. 11. membership functions for each feature.

그림 12의 (b)와 같은 경우에는 첫번째 퍼지 집합과 두번째 퍼지 집합의 소속함수가 많이 중복되어 거의 구별할 수 없음을 알 수 있다. 이와 같은 경우 유용도가 매우 낮게 결정되어 표 4에서 특징 2의 소속함수 1과 소속함수 2와 같이 낮은 유용도가 계산된다. 그러나 (c)와 같이 각 퍼지 집합이 명확하게 구분되는 경우에는 표 4의 특징 3의 소속함수들과 같이 유용도가 높게 계산된다. 결론부의 퍼지 집합들은 각 입력 벡터의 클래스값들을 중심으로 각 특징에 대한 퍼지 집합을 구하는 방법과 동일한 방법으로 결정한다. 이를 바탕으로 가중치를 학습하고 시험 자료에 대해 추론을 수행하면 표 2, 표 3과 같은 결과를 얻을 수 있다. 표 2에서는 학습 자료의 갯수를 변화시키며 추론을 수행 했을 때의 분류율을 보여주고 있다. 표 3에서는 각 학습 자료의 갯수에 대해 생성된 규칙의 갯수를 나타낸다. 규칙의 갯수는 조건부의 퍼지 집합과 결론부를 조합하여 생성되는 가능한 모든 규칙들 중에서 임계값 0.0001을 적용하여 만들어지는 규칙의 수를 보여준다.

표 1. 실험에 사용된 아이리스 자료

Table 1. Iris data used for experiment.

F1	F2	F3	F4	클래스	F1	F2	F3	F4	클래스					
0.51	0.35	0.14	0.02	1	0.70	0.32	0.47	0.14	2	0.63	0.33	0.60	0.25	3
0.49	0.30	0.14	0.02	1	0.64	0.32	0.45	0.15	2	0.58	0.27	0.51	0.19	3
0.47	0.32	0.13	0.02	1	0.69	0.31	0.49	0.15	2	0.71	0.30	0.59	0.21	3
0.46	0.31	0.15	0.02	1	0.55	0.23	0.40	0.13	2	0.62	0.29	0.56	0.18	3
0.50	0.36	0.14	0.02	1	0.65	0.28	0.46	0.15	2	0.65	0.30	0.58	0.22	3
0.54	0.39	0.17	0.04	1	0.57	0.28	0.45	0.13	2	0.76	0.30	0.66	0.21	3
0.46	0.34	0.14	0.03	1	0.63	0.33	0.47	0.16	2	0.49	0.25	0.45	0.17	3
0.50	0.34	0.15	0.02	1	0.49	0.24	0.33	0.10	2	0.73	0.29	0.63	0.18	3
0.44	0.29	0.14	0.02	1	0.66	0.29	0.46	0.13	2	0.67	0.25	0.58	0.18	3
0.49	0.31	0.15	0.01	1	0.52	0.27	0.39	0.14	2	0.72	0.36	0.61	0.25	3
0.54	0.37	0.15	0.02	1	0.50	0.20	0.35	0.10	2	0.65	0.32	0.51	0.20	3
0.48	0.34	0.16	0.02	1	0.59	0.30	0.42	0.15	2	0.64	0.27	0.53	0.19	3
0.48	0.30	0.14	0.01	1	0.60	0.22	0.40	0.10	2	0.68	0.30	0.55	0.21	3
0.43	0.30	0.11	0.01	1	0.61	0.29	0.47	0.14	2	0.57	0.25	0.50	0.20	3
0.58	0.40	0.12	0.02	1	0.56	0.29	0.36	0.13	2	0.58	0.28	0.51	0.24	3
0.57	0.44	0.15	0.04	1	0.67	0.31	0.44	0.14	2	0.64	0.32	0.53	0.23	3
0.54	0.39	0.13	0.04	1	0.56	0.30	0.45	0.15	2	0.65	0.30	0.55	0.18	3
0.51	0.35	0.14	0.03	1	0.58	0.27	0.41	0.10	2	0.77	0.38	0.67	0.22	3
0.57	0.38	0.17	0.03	1	0.62	0.22	0.45	0.15	2	0.77	0.26	0.69	0.23	3
0.51	0.38	0.15	0.03	1	0.56	0.25	0.39	0.11	2	0.60	0.22	0.50	0.15	3
0.54	0.34	0.17	0.02	1	0.59	0.32	0.48	0.18	2	0.69	0.32	0.57	0.23	3
0.51	0.37	0.15	0.04	1	0.61	0.28	0.40	0.13	2	0.56	0.28	0.49	0.20	3
0.46	0.36	0.10	0.02	1	0.63	0.25	0.49	0.15	2	0.77	0.28	0.67	0.20	3
0.51	0.33	0.17	0.05	1	0.61	0.28	0.47	0.12	2	0.63	0.27	0.49	0.18	3
0.48	0.34	0.19	0.02	1	0.64	0.29	0.43	0.13	2	0.67	0.33	0.57	0.21	3
0.50	0.30	0.16	0.02	1	0.66	0.30	0.44	0.14	2	0.72	0.32	0.60	0.18	3
0.50	0.34	0.16	0.04	1	0.68	0.28	0.48	0.14	2	0.62	0.28	0.48	0.18	3
0.52	0.35	0.15	0.02	1	0.67	0.30	0.50	0.17	2	0.61	0.30	0.49	0.18	3
0.52	0.34	0.14	0.02	1	0.60	0.29	0.45	0.15	2	0.64	0.28	0.56	0.21	3
0.47	0.32	0.16	0.02	1	0.57	0.26	0.35	0.10	2	0.72	0.30	0.58	0.16	3
0.48	0.31	0.16	0.02	1	0.55	0.24	0.38	0.11	2	0.74	0.28	0.61	0.19	3
0.54	0.34	0.15	0.04	1	0.55	0.24	0.37	0.10	2	0.79	0.38	0.64	0.20	3
0.52	0.41	0.15	0.01	1	0.58	0.27	0.39	0.12	2	0.64	0.28	0.56	0.22	3
0.55	0.42	0.14	0.02	1	0.60	0.27	0.51	0.16	2	0.63	0.28	0.51	0.15	3
0.49	0.31	0.15	0.02	1	0.54	0.30	0.45	0.15	2	0.61	0.26	0.56	0.14	3
0.50	0.32	0.12	0.02	1	0.60	0.34	0.45	0.16	2	0.77	0.30	0.61	0.23	3
0.55	0.35	0.13	0.02	1	0.67	0.31	0.47	0.15	2	0.63	0.34	0.56	0.24	3
0.49	0.36	0.14	0.01	1	0.63	0.23	0.44	0.13	2	0.64	0.31	0.58	0.18	3
0.44	0.30	0.13	0.02	1	0.56	0.30	0.41	0.13	2	0.60	0.30	0.48	0.18	3
0.51	0.34	0.15	0.02	1	0.55	0.25	0.40	0.13	2	0.69	0.31	0.54	0.21	3
0.50	0.35	0.13	0.03	1	0.55	0.26	0.44	0.12	2	0.67	0.31	0.56	0.24	3
0.45	0.23	0.13	0.03	1	0.61	0.30	0.46	0.14	2	0.69	0.31	0.51	0.23	3
0.44	0.32	0.13	0.02	1	0.58	0.26	0.40	0.12	2	0.58	0.27	0.51	0.19	3
0.50	0.35	0.16	0.06	1	0.50	0.23	0.33	0.10	2	0.68	0.32	0.59	0.23	3
0.51	0.38	0.19	0.04	1	0.56	0.27	0.42	0.13	2	0.67	0.33	0.57	0.25	3
0.48	0.30	0.14	0.03	1	0.57	0.30	0.42	0.12	2	0.67	0.30	0.52	0.23	3
0.51	0.38	0.16	0.02	1	0.57	0.29	0.42	0.13	2	0.63	0.25	0.50	0.19	3
0.46	0.32	0.14	0.02	1	0.62	0.29	0.43	0.13	2	0.65	0.30	0.52	0.20	3
0.53	0.37	0.15	0.02	1	0.51	0.25	0.30	0.11	2	0.62	0.34	0.54	0.23	3
0.50	0.33	0.14	0.02	1	0.57	0.28	0.41	0.15	2	0.59	0.30	0.51	0.18	3

표 2에서 보는 바와 같이 본 논문에서 제안하는 방법은 기존의 방법들과 비교해서 학습자료의 갯수가 충분히 클 경우(60,90) 기존의 방법들과 비슷한 분류율을 나타내고 있으며, 생성되는 규칙의 갯수는 표 3에서 보는 바와 같이 기존의 방법들보다 훨씬 작게 생성됨을 알 수 있다. 그리고 기존의 방법들에서는 학습자료의 갯수가 증가함에 따라 생성되는 퍼지규칙의 갯수

도 크게 증가하는데 본 논문에서 제안하는 방법에서는 생성되는 규칙의 갯수가 학습자료의 갯수가 증가하더라도 크게 변화가 없음을 알 수 있다.

퍼지 연상 기억장치에 기반한 추론 시스템을 사용하여 아이리스 자료의 분류 문제에 적용한 결과 [3]에서 비교되고 제안된 방법들에 비해 비교적 정확히 그리고 빨리 학습을 수행하고 효율적으로 추론을 수행할 수 있음을 알 수 있다. 그리고 추출되는 규칙의 갯수도 상당히 줄일 수 있었다.

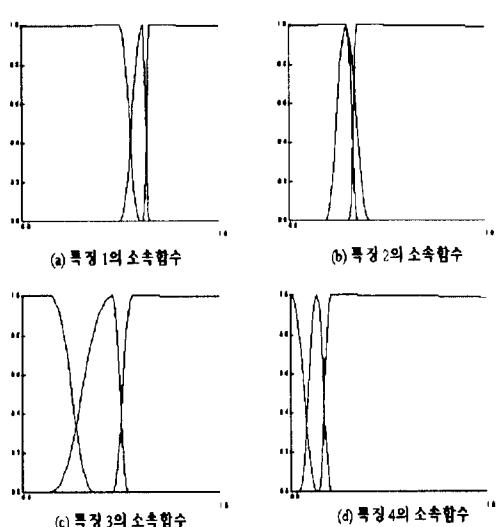


그림 12. 각 특징들에 대한 히스토그램

Fig. 12. Histograms for each feature.

표 2. 각 방법에 대한 평균 분류율

Table 2. Average classification rate for each method.

학습자료의 개수(N)	단순 퍼지 격자 (Simple fuzzy grid)	분산된 퍼지 규칙 (Distributed fuzzy if-then rules)	CF criterion	NM criterion	RM criterion	본 논문에서 제안하는 방법
21	91.3	92.4	91.1	89.8	89.6	88.3
30	92.7	93.8	91.8	93.0	93.3	91.6
60	93.5	95.4	93.8	93.9	94.1	93.3
90	94.5	95.8	95.1	94.8	94.6	95.0

본 논문에서는 일반적인 퍼지 추론이 가지고 있는 퍼지 규칙의 생성과 학습에 있어서의 문제점을 해결하기 위해 간단한 신경망 모델과 퍼지 집합을 결합시킨 퍼지 연상 기억장치를 이용하는 추론 시스템을 제안하였다. 퍼지 연상 기억장치에 기반한 추론 시스템은 소

속 함수를 결정하고 퍼지 규칙을 생성하는 학습 단계와 실제로 추론을 수행하는 추론 단계의 두 단계로 분리되어, 동적으로 변화하는 환경 하에서 쉽게 퍼지 규칙을 학습하고, 이를 통하여 추론을 수행할 수 있는 퍼지추론망을 제공한다.

표 3. 각 방법에 의해 생성되는 규칙의 평균
갯수

Table 3. Average number of rules generated by each method.

학습자료의 개수(N)	단순 퍼지 격자 (Simple fuzzy grid)	분산된 퍼지 규칙 (Distributed fuzzy if-then rules)	CF criterion	NM criterion	RM criterion	본 논문에서 제안하는 방법
21	455	8328	253	51	72	32
30	1727	20512	307	83	87	36
60	2452	63069	449	105	107	46
90	3440	140498	528	150	150	46

표 4. 각 퍼지 소속 함수들의 유용도

Table 4. Usefulness of each fuzzy membership function.

특징 1	소속함수 1	0.84	특징 2	소속함수 1	0.28
	소속함수 2	0.4		소속함수 2	0.24
	소속함수 3	0.44		소속함수 3	0.6
특징 3	소속함수 1	1.0	특징 4	소속함수 1	1.0
	소속함수 2	0.88		소속함수 2	0.92
	소속함수 3	0.88		소속함수 3	0.92

본 논문에서 제안한 추론 시스템은 아이리스 자료에 대한 실험에서 나타나듯이 패턴 분류 문제를 해결하는데 매우 효과적이며, 제어 등과 같은 응용 분야에서도 효율적으로 적용될 수 있으리라 기대된다.

참 고 문 헌

- [1] Hideyuki Takagi and Isao Hayashi, "NN-Driven Fuzzy Reasoning", *International Journal of Approximate Reasoning*, vol. 5, no. 3, pp 191-212, 1991.
- [2] H. J. Zimmermann, *Fuzzy Set Theory and Its Applications*, KALA, 1987.
- [3] Hisao Ishibuchi, Ken Nozaki and Hideo

- Tanaka, "Efficient fuzzy partition of pattern space for classification problems". *Fuzzy Sets and Systems*, vol. 59, pp 295-304, 1993.
- [4] Shoichi Araki, Hiroyoshi Nomura, Isao Hayashi and Noboru Wakami, "A self-generating method of fuzzy inference rules", *IFES'91*, pp 1047-1058, 1991.
- [5] Hiroyoshi Nomura, Isao Hayashi and Noboru Wakami, "A Learning Method of Fuzzy Inference Rules by Descent Method", *IEEE International Conference on Fuzzy Systems*, pp 203-210, 1992.
- [6] James M. Keller and Hossein Tahani, "Implementation of Conjunctive and Disjunctive Fuzzy Logic Rules With Neural Networks", *International Journal of Approximate Reasoning*, vol. 6, pp 221-240, 1991.
- [7] In Ho Hwang and Seongwon Cho, "Fuzzy Systems Based on Counterpropagation Neural Network Learning Algorithm". *Proceedings of KFMS Spring Conference*, pp 140-145, 1994.
- [8] Jong Sung Kim, Gyu Tae Park, Won Jang, Jeungnam Bien and Sung Kwon Kim, "A Recognition of Korean Finger Spell using Fuzzy Min-Max Neural-Network Classifier", *Proceedings of KFMS Spring Conference*, pp 134-139, 1994.
- [9] Richard P. Lippman, "An Introduction to Computing with Neural Nets", *IEEE ASSP Mag.*, pp 4-22, April 1987.
- [10] James A. Freeman and David M. Skapura, *Neural Networks : Algorithms, Applications and Programming Techniques*, Addison Wesley Publishing Company, 1991.
- [11] Bark Kosko, *Neural Networks and Fuzzy Systems*, Prentice-Hall International, 1992.

저자 소개



張大植(正會員)

1972년 2월 12일생. 1994년 2월 숭실대학교 전자계산학과 졸업(공학사). 1994년 2월 ~ 현재 숭실대학교 대학원 전자계산학과 석사과정 재학중. 주관심 분야는 컴퓨터비전, 동작이해, 영상처리, 퍼지 추론시스템 등임

崔灝一(正會員)

1956년 8월 16일생. 1979년 2월 연세대학교 전자공학과 졸업(공학사). 1982년 6월 미시간 대학교 전산공학과 졸업(공학석사). 1987년 6월 미시간 대학교 전산공학과 졸업(공학박사). 현재 숭실대학교 전자계산학과 부교수 재직중. 주관심분야는 컴퓨터비전, 퍼지 및 신경망이론, 패턴인식, 지식기반시스템 등임