

論文94-31B-5-18

## 지능적인 뉴로-퍼지 시스템의 설계 및 구현

## (The Design and Implementation of An Intelligent Neuro-Fuzzy System(INFS))

曹永任\*, 黃鍾善\*, 孫進坤\*\*

(Young Im Cho, Chong Sun Hwang and Jin Gon Shon )

## 要約

기존의 추론 방법인 Max-Min CRI 방법은 주관적인 멤버십 함수의 결정, 오류 발생 가중치 전략, 비합리적인 추론 규칙들의 조합이라는 세가지 문제점 때문에 원하는 추론 결과와 실제 추론 결과 사이에 상당한 오류 영역을 발생시킨다.

본 논문에서는 이를 해결하기 위해 퍼지 이론에 신경 회로망의 학습 기능과 자기 조절 기능이 융합되어 문제 영역에서 지능적으로 작동하는 뉴로-퍼지 시스템(INFS)을 제안한다. INFS에서는 Max-Min CRI 방법의 첫번째 문제를 해결하기 위해 신경 회로망(EBP 학습 알고리즘)을 이용하였고, 두번째 문제를 해결하기 위해 Max-Min CRI 방법에 유사도를 이용해 개선한 NCRI 방법을 이용하였으며, 세번째 문제를 해결하기 위해 규칙 선택 기준(RSL)에 따라 적당한 규칙들만을 조합하는 비퍼지화 전략을 이용하였다.

제안된 INFS를 직류 계열 모터에 적용한 결과 신경 회로망을 사용하지 않았을 때 보다 오류 영역을 상당히 줄여주었으며, NCRI 방법은 Max-Min CRI 방법 보다 훨씬 효율적이었다.

## Abstract

The Max-Min CRI method, a traditional inference method, has three problems: subjective formulation of membership functions, error-prone weighting strategy, and inefficient compositional rule of inference. Because of these problems, there is an insurmountable error region between desired output and inferred output.

To overcome these problems, we propose an Intelligent Neuro-Fuzzy System(INFS) based on fuzzy theory and self-organizing functions of neural networks. INFS makes use of neural networks(Error Back Propagation) to solve the first problem, and NCRI(New Max-Min CRI) method for the second. With a proposed similarity measure, NCRI method is an improved method compared to the traditional Max-Min CRI method. For the last problem, we propose a new defuzzification method which combines only the appropriate rules produced by the rule selection level.

Applying INFS to a D.C. series motor, we can conclude that the error region is reduced and NCRI method performs better than Max-Min CRI method.

\* 正會員, 高麗大學校 電算科學科  
(Dept. of Computer Science, Korea Univ.)

\* 正會員, 韓國放送通信大學校 電子計算學科

(Dept. of computer Science, Korea Air and  
Correspondence Univ.)

接受日字 : 1993年 6月 25日

I. 서론

퍼지 제어기(Fuzzy Logic Controller: FLC)는 퍼지 논리<sup>[1]</sup>를 이용한 제어기로, 기존의 모델 기반 제어 시스템이 다루기 어려웠던 수학적으로 정의하기 어려운 비선형, 동적 시스템 등에 적용되어 좋은 성능을 보여주었다. 즉, FLC는 기존의 미적분을 이용한 PID(Proportional Integral Derivative)제어기에 비해 몇가지 장점을 갖는다.<sup>[2]</sup> 즉, FLC 개발은 동일한 성능을 갖는 다른 모델 기반 제어기 개발 비용보다 훨씬 경제적이고, FLC는 PID보다 더 넓은 범위의 작동 조건을 만족하고 있기 때문에 훨씬 견고하며, FLC는 규칙들이 자연어로 되어 있기 때문에 이해하기 쉬울 뿐 아니라 변경이 용이하다는 것이다.

FLC에서는 시스템 출력을 결정짓는 추론 방법으로 Zadeh<sup>[1]</sup>가 제안한 Max-Min CRI(Compositional Rule of Inference)방법을 이용하고 있는데 이 방법에는 다음과 같은 몇가지 문제점이 존재한다. 첫째, 멤버십 함수가 매우 주관적으로 결정되며 퍼지 집합의 구조적 변경이 용이하지 못하다. 둘째, 결론 생성시 오류를 발생시키는 가중치 전략을 사용한다. 셋째, 규칙 베이스에서 규칙 조합시 모든 규칙들을 조합하는 비합리적인 조합 전략을 사용한다. 그러므로 "IF <조건부 명제> THEN <결론부 명제>" 형태의 규칙 베이스에서 임의의 한 규칙의 조건부와 동일한 입력 사실이 주어져도 그 규칙의 결론부와 동일한 결론을 생성해 내지 못하고 오류 영역을 발생시킨다.

그러므로 FLC를 변화하는 환경에 대응하기 위해 제안된 시스템이 Kang<sup>[2]</sup>과 Yen<sup>[3]</sup> 등에 의해 제안된 적응적 제어기 (Adaptive FLC: AFLC)이다. AFLC에서는 신경 회로망의 구조와 기능을 많이 따르고 있으면서도 신경 회로망과는 독립적인 학습 기법을 이용하고 있다. 그러나 AFLC가 보다 진정한 적응적 시스템이 이루어 지려면 자기 조절(Self-Organizing)기법들이 융합되어야 한다. 이것이 뉴로-퍼지 시스템이다. 그러나 이렇게 융합된 어느 뉴로-퍼지 시스템도 Max-Min CRI 방법의 세가지 문제점을 모두 해결해 주지 못하고 있다.

따라서 본 논문에서는 Max-Min CRI 방법의 문제점들을 모두 해결하고 오류 영역을 발생시키지 않기 위해 신경 회로망과 퍼지 이론의 장점만을 융합한 지능적인 뉴로-퍼지 시스템 모델(Intelligent Neuro-Fuzzy System: INFS)을 제안하고자 한다. 여기서 지능적이란 자기 조절 기법들이 융합된 진정한 의미에서의 적응적 시스템을 의미한다. INFS는 지식

획득 단계(Knowledge Acquisition Phase), 적응 조절 단계(Adaptation Phase), 추론 단계(Inference Phase)를 통해 지능적으로 작동되는 시스템이다. INFS의 성능 평가를 위해 간단한 FLC인 직류 계열 모터(Direct Current series motor)에 적용하여 그 실험 결과를 토의하고자 한다.

본 논문의 구성은 다음과 같다. II장에서는 기존 퍼지 추론 방법의 문제점을 분석하고 이를 해결하기 위한 뉴로-퍼지 시스템의 필요성과 융합 형태를 분류한다. III장에서는 지능적인 뉴로-퍼지 시스템 모델(INFS)을 설계하고 시스템의 기능을 설명한다. IV장에서는 직류 계열 모터에 적용하여 실험 결과 및 성능 평가를 하고, V장에서 결론을 맺고자 한다.

II. 이론적 배경

1. Max-Min CRI 방법의 문제점

Max-Min CRI 방법은 Mamdani가 제안한 최소 연산 법칙(mini-operation)<sup>[4]</sup>을 이용하는 추론 방법으로, 직접법 또는 Zadeh의 추론 방법이라고도 하며 기존에 많이 사용되어온 퍼지 추론 방법이다. Max-Min CRI 방법은 규칙 베이스에 규칙이 다음과 같은 형태로 있을 때, 임의의 입력 사실에 대해 적당한 결과를 산출하기 위한 퍼지 추론 방법이다.

$$\begin{aligned} &IF\ X\ is\ A_1\ THEN\ Y\ is\ B_1 \\ &ALSO\ IF\ X\ is\ A_2\ THEN\ Y\ is\ B_2 \\ &\quad \vdots \\ &ALSO\ IF\ X\ is\ A_n\ THEN\ Y\ is\ B_n \end{aligned} \tag{1}$$

식(1)에서 'X is A'는 규칙의 조건부 퍼지 명제를, 'Y is B'는 결론부 퍼지 명제를 의미한다.

Max-Min CRI 방법의 실제적 추론 방법은 다음과 같다. 규칙 베이스의 모든 규칙들은 다음과 같은  $I_{X_j}$ ,  $I_{Y_j}$  형태의 가능성 분포로 표현된다.

$$\begin{aligned} IF\ X\ is\ A\ THEN\ Y\ is\ B \Rightarrow IF\ \prod_x = \mu_A\ THEN\ \prod_y = \mu_B \tag{2} \\ B' = A' \circ (A \rightarrow B) \\ = A' \circ R \end{aligned} \tag{3}$$

식(1)의 규칙 베이스에서 입력 사실 A'에 대한 추론 결과 B'를 구하기 위해 식(2)를 CRI 방법에 따라 표현하면 식(3)과 같다. R은 퍼지 관계를 나타내며, 'o'는 A와 R을 합성하라는 합성 기호이다.

식(3)은 한 규칙에서 추론 결과 B'를 생성하라는 의미를 가진 표현이지만 동시에 퍼지 추론 방법의 전

체적 개요를 보여주는 식이기도 하다.  $R$ 은 Zadeh가 제안한 행렬 형태로 나타내기도 하는데 대부분 행렬 형태가 아닌 경우로서 다음의 과정에 의해 결정된다.

식(3)의 ' $A \rightarrow B$ '에서 ' $\rightarrow$ '는 퍼지 조건 연산자 (fuzzy implication operator)를 의미하는데 퍼지 조건 연산자를 정의하기 위한 과정은 다음 두 단계로 구성된다. 즉, 제 1단계에서 한 규칙에 대한  $R_i$ 를 구한 후, 제 2단계에서  $R$ 들을 조합해서 전체 퍼지 관계  $R$ 을 생성한다. 제 1단계를 위해 다음과 같이 Takefujii<sup>[5]</sup>가 정의한 일치도  $\alpha$ 를 이용한다.

$$\alpha = \max \min(\mu_{A'}(u), \mu_A(u)) \quad (4)$$

식(4)로부터 식(3)의 합성 순서를 결정하는데 이 과정은 다음과 같다. 이때  $\mu_{B'}(v)$ 가 생성됨으로써  $R_i$ 가 결정된다.

$$\forall v \in V, u \in U, \mu_{B'}(v) = \max \min(\mu_{A'}(u), \mu_R(u, v)) = \min(\alpha, \mu_B(v)) \quad (5)$$

제 2단계에서는 식(5)에서 생성된  $\mu_{B'}(v)$ 로부터 전체  $R$ 을 구하기 위해 'ALSO' 연산을 적용하여 조합한다. 조합된 규칙 베이스의 모든 규칙들로부터 새로운 결론부 함수를 생성한 후 비퍼지화 과정<sup>[4]</sup>에 의해 수치화된 비퍼지값을 산출한다.

Max-Min CRI 방법은 간단하고 구현하기 쉬우며 타당성에 관해서는 Lee<sup>[4]</sup>, Kiszka<sup>[6]</sup>, Kandel<sup>[7]</sup>, Mizumoto<sup>[8]</sup> 등에 의해 증명되었다. 그러나 Max-Min CRI 방법은 규칙 베이스의 임의의 한 규칙의 조건부 퍼지 명제와 입력 사실이 일치해도 그 규칙의 결론부에 해당되는 결론을 추론해 내지 못하고 추론 결과에 상당한 오류 영역(원하는 추론값 - 실제 추론값)을 발생시킨다.<sup>[9]</sup>

오류 영역이 발생될 수 밖에 없는 것은 다음 세가지 이유 때문이다. 첫째, 멤버십 함수가 주관적으로 결정된다. 둘째, 오류를 발생시키는 가중치 전략을 사용한다. 셋째, 추론 규칙들을 비합리적으로 조합한다는 점 때문이다. 이러한 문제점을 해결하기 위해 접근 시도된 개념이 퍼지 추론에 신경 회로망을 융합한 뉴로-퍼지 시스템이다.

본 논문은 2절에서 이러한 뉴로-퍼지 시스템의 필요성과, 3절에서 뉴로-퍼지 시스템의 융합 형태와 융합 측면을 살펴보고, 뉴로-퍼지 시스템이 Max-Min CRI 방법의 문제점을 어떻게 해결하고 있는지 알아보고자 한다.

## 2. 뉴로-퍼지 시스템의 필요성

뉴로-퍼지 시스템에 관한 연구의 대표적인 학자로는 Kosko와 Takagi를 들 수 있다. Kosko<sup>[10]</sup>는 지식의 형태를 구조적 지식과 비구조적 지식으로 나누고 지식 표현 형태도 심볼릭과 수치적으로 나누어 여러 시스템들의 지식 처리 형태를 분류하였다. 그러나 그는 인간의 지식 정보 처리 과정은 어느 시스템에도 국한된 것이 아니라 여러 지식 정보 처리의 통합체라고 볼 수 있기 때문에 신경 회로망과 퍼지 시스템의 융합의 중요성은 매우 크다고 하였다. Takagi<sup>[11]</sup>는 뉴로-퍼지 시스템은 신경 회로망과 퍼지 이론의 장점과 유사점들을 융합하려는 노력에서 부터 시작되었다고 하였다.

실제로 신경 회로망은 학습 기능이 있어서 기대 이상의 훌륭한 문제 해결책을 제시해 줄 수 있으나 학습 시간이 오래 걸린다는 단점을 갖고 있다. 반면 퍼지 이론은 신경 회로망이 갖지 못한 독특한 추론 기능이 있어서 절차적 추론이 가능하나 멤버십 함수가 주관적으로 결정된다는 단점을 갖고 있다. 따라서 서로의 장단점을 보완하면서 문제를 해결한다면 매우 강력한 도구가 될 수 있다.

## 3. 뉴로-퍼지 시스템의 형태 분류

본 논문에서는 뉴로-퍼지 시스템을 표 1과 같이 크게 두가지 형태로 분류하였다.

표 1. 뉴로-퍼지 시스템의 형태 분류  
Table 1. The Types of Neuro-Fuzzy Systems.

	융합 형태	융합 측면
제 1형태	신경 회로망 구조에 퍼지 이론을 도입한 형태	지식표현시 멤버십 함수 적용 신경 회로망의 출력결과를 퍼지 추론에 이용 신경 회로망의 일부 기능을 퍼지 추론 체계로 대체
제 2형태	퍼지 추론 구조에 회로망을 도입한 형태	멤버십함수 생성 및 적용적 조절 규칙획득, 규칙베이스 구성및조절 바람직한 입출력 벡터쌍을 찾음 퍼지 추론 구조를 신경 회로망으로 표현

표 1의 제 1형태는 신경 회로망 구조에 퍼지 이론을 도입한 시스템으로, 융합 측면에 따라 지식 표현시 연결 부분이나 가중치값에 멤버십 함수를 적용하는 연구<sup>[12]</sup>와 신경 회로망의 출력 결과를 퍼지 추론에 이용하는 연구<sup>[13]</sup>, 그리고 신경 회로망의 일부 기능을 퍼지 논리 체계로 대체하려는 연구<sup>[14]</sup>로 구분된다.

표 1의 제 2형태는 퍼지 추론 구조에 부분적으로 신경 회로망을 도입한 시스템으로, 융합 측면에 따라 멤버십 함수의 생성과 적응적 조절에 관한 연구<sup>[15]</sup>, 규칙 획득 및 규칙 베이스의 구성과 조절에 관한 연구<sup>[16]</sup>, 바람직한 입출력 벡터쌍을 찾아내는 연구<sup>[17]</sup>, 그리고 신경 회로망 구조로써 퍼지 추론 구조를 표현하는 연구<sup>[18]</sup> 등으로 구분된다.

그러나 이들 시스템 형태에 따른 융합 방식의 분류는 실제로 서로 독립된 것이 아니라 밀접하게 관련되어 있다. 최근에는 제 1.2형태의 융합 방식을 부분적으로 연구하는 것이 아니라 모두 통합된 구조로 융합하고 있는데, Lin<sup>[19]</sup> 과 Gupta<sup>[20]</sup> 의 연구가 대표적이다.

그러나 어느 뉴로-퍼지 시스템도 Max-Min CRI 방법의 세가지 문제점을 모두 해결해 주지는 못하고 있다. 본 논문에서는 Max-Min CRI 방법의 세가지 문제점을 모두 해결하기 위한 퍼지 추론 기반 지능적인 뉴로-퍼지 시스템 모델(Intelligent Neuro-Fuzzy System model: INFS)을 제안하고자 한다.

### III. 지능적인 뉴로-퍼지 시스템 모델(INFS)의 설계

#### 1. INFS의 개요

INFS는 전문가에 의해 주관적으로 정의된 멤버십 함수로부터 초기 규칙 베이스를 구성한 후 원하는 입출력 쌍을 가장 잘 표현하는 최적의 규칙 베이스를 신경 회로망을 이용해 재구성하는 지능적인 시스템 모델이다. INFS는 신경 회로망의 학습 기능과 퍼지 이론의 추론 기능의 장점만을 융합하여 특성을 살림으로써 두 분야의 단점을 보완해 주는 뉴로-퍼지 시스템이다.

INFS는 문제 영역에 대한 최종적 시스템 행동을 결정짓기 위해 지식 획득 단계(Knowledge Acquisition Phase), 적응 조절 단계(Adaptation Phase), 추론 단계(Inference Phase)의 세 단계의 수행 과정을 거친다. 다음 그림 1은 INFS의 전체 시스템 구조를 나타낸 그림이다.

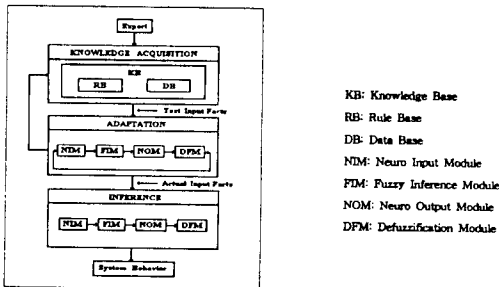


그림 1. INFS의 전체 구조

Fig. 1. The Total Structure of INFS.

지식 획득 단계는 전문가에 의해 주관적으로 정의된 멤버십 함수값을 데이터 베이스에 저장하고 이로부터 주어진 문제 영역에 대한 초기 지식 베이스를 구성하는 단계이다. 따라서 멤버십 함수의 조절로부터 데이터 베이스가 조절되고 이로부터 규칙 베이스가 조절되어 결국 지식 베이스가 조절될 수 있는 것이다. 그러므로 본 논문에서는 지식 베이스의 조절이란 용어와 규칙 베이스 및 멤버십 함수의 조절이란 용어는 같은 의미로 사용하겠다.

적응 조절 단계는 이러한 초기 규칙 베이스를 문제 영역에 적용된 최적의 규칙 베이스로 재구성하기 위한 단계이다. 이 단계에서는 규칙의 조건부 멤버십 함수와 일치하는 입력 사실에 대해 그 규칙의 결론부 멤버십 함수와 일치하는 출력 결과가 산출될 수 있도록 EBP 학습 알고리즘<sup>[21]</sup>을 이용해 반복적으로 적응 조절한다. 조절 방법은 규칙의 조건부 멤버십 함수를 나타내는 벡터 표현을 학습하여 적응하고 올바른 결과가 나올 수 있도록 조절하여 결국 최적의 규칙 베이스를 재구성하는 과정을 반복한다. 여기서 적응은 학습이 끝난 상태를 말하고 조절은 변경된 값을 재학습하여 문제 영역에 가장 적합한 가중치를 생성한 상태를 의미하는데, 실제로는 이 둘이 분리된 것이 아니라 동시에 이루어진다.

추론 단계에서는 지식 획득 단계와 적응 조절 단계를 거쳐서 문제 영역에 적용된 최적의 지식 베이스가 형성되었을 때 필요시 실제로 추론을 행하는 단계이다.

그러므로 문제 영역에 대한 임의의 입력 사실에 대해 가장 적합한 시스템 행동을 결정짓게 된다.

INFS의 적응 조절 단계에는 뉴로 입력 모듈(Neuro Input Module: NIM), 퍼지 추론 모듈(Fuzzy Inference Module: FIM), 뉴로 출력 모듈(Neuro Output Module: NOM), 그리고 비퍼지화 모듈(DeFuzzification Module: DFM)이 유기적으로 작동한다. NIM에서는 원하는 출력값을 가장 잘 산출할 수 있는 규칙의 조건부 멤버십 함수를 학습하여 적응한 후 나중에 DFM의 출력을 입력으로 하여 주관적 멤버십 함수가 객관적이 되도록 반복 조절한다. 이때 EBP 학습 알고리즘을 이용한다. 따라서 기존의 Max-Min CRI 방법의 첫번째 문제점인 주관적인 멤버십 함수 결정 문제를 해결할 수 있다. NIM의 출력값은 조절된 조건부 멤버십 함수이며 이로부터 조절된 규칙 베이스를 갖고 FIM을 시작한다. FIM에서는 두번째 문제점인 오류 발생 가중치 전략 문제를 해결하기 위해 두 퍼지 집합간의 유사도를 정의하고 이를 이용한 새로운 추론 방법인 NCRI

(New Max-Min CRI) 방법을 이용한다. 따라서 두 번째 문제가 해결된다. FIM의 출력값은 각 규칙마다 퍼지 추론한 결과인데 최종 시스템 행동 결정시 결론부 멤버십 함수의 반영 정도가 되는 값이다. 이 값은 NOM에 입력으로 사용된다. NOM에서는 원하는 출력값과 실제 출력값과의 차이를 최소화하기 위해 EBP 학습 알고리즘에 의해 규칙의 결론부 멤버십 함수의 반영 정도를 조절한다. DFM에서는 조절된 반영 정도로 부터 특징값(규칙 선택 기준) 이상인 규칙들만을 선택적으로 조합하는 비퍼지화 전략을 채택함으로써 세번째 문제점인 추론 규칙들의 비합리적인 조합 문제를 해결할 수 있다. 그러므로 INFS는 Max-Min CRI 방법의 세가지 문제점을 동적으로 모두 해결할 수 있는 시스템 모델이다.

2. 지식 획득 단계(Knowledge Acquisition Phase)

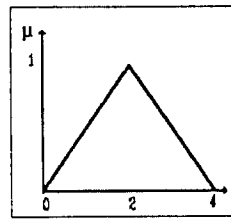
전문가로 부터 얻은 지식을 바탕으로 식(1)과 같은 형태의 n개의 규칙을 갖는 초기 규칙 베이스를 구성한다. 이때 전문가가 원하는 임출력 쌍에 대한 데이터도 함께 얻는다. 각 규칙은 적당한 여러 멤버십 함수를 갖는다. 멤버십 함수는 그림 2와 같은 삼각형 형태의 벡터로 표현하여 휴리스틱하게 주관적으로 결정된다. 그러나 이 벡터값은 적응 조절 단계에서 원하는 출력값을 산출할 수 있도록 반복적으로 적응 조절된다.

3. 적응 조절 단계(Adaptation Phase)

획득된 지식을 바탕으로 규칙 베이스와 멤버십 함수를 학습하여 적응하고 원하는 출력값을 산출할 수 있도록 조절하는 단계로, INFS에서 가장 중요한 핵심 단계이다. 이를 위해 규칙의 조건부를 테스트 입력 사실로 하여 적응 조절 과정을 반복한다.

1) NIM(Neuro Input Module)

NIM는 EBP 학습 알고리즘을 이용해 규칙의 조건부 멤버십 함수를 학습하고 조절하는 모듈이다. 이때 각 멤버십 함수를  $F$ 라 하면, 벡터값  $V_F = (v_{F1}, v_{F2}, v_{F3})$ 로 표현한다. 여기서  $v_{F1}$ 은 멤버십 함수  $F$ 의 멤버십 값이 0( $\mu=0$ )인 왼쪽 점을,  $v_{F2}$ 는 멤버십 값이 1( $\mu=1$ )인 중심 점을,  $v_{F3}$  멤버십 값이 0( $\mu=0$ )인 오른쪽 점을 각각 의미한다. 예를 들면, 언어적 변수 'Zero'를 나타내는 멤버십 함수는 그림 2(a)와 같이 표현하며 그림 2(b)에서 처럼 벡터로 표현한다.  $v_{F1}$ ,  $v_{F2}$ ,  $v_{F3}$ 값은 적응 조절 단계에서 원하는 출력값을 산출할 수 있도록 반복적으로 학습에 의해 적응되고 조절된다.



(a)

$$V_{ZERO} = (0, 2, 4)$$

(b)

그림 2. 'Zero'의 멤버십 함수와 벡터 표현  
Fig. 2. The Membership Function and Vector Representation of 'Zero'

NIM은 그림 3과 같이 세 층의 신경 회로망으로 구성된 학습 모듈(LEarning Module: LEM)과 두 층으로 된 조절 모듈(ADjust Module: ADM)로 구성되어 있다.

LEM은 EBP 학습 알고리즘을 이용해 전문가로 부터 얻은 원하는 출력값과 그 출력값의 산출 근거가 되는 규칙의 조건부 멤버십 함수와의 관계를 학습하여 적응한다. 학습시 해당되는 규칙의 조건부 멤버십 함수는 1의 값을, 아닌 경우는 0의 값을 부여한다. 예를 들어, 원하는 출력값이 1867이고 이 출력값의 산출 근거가 되어야 하는 규칙이 #1 규칙일 경우, LEM의 입력값은 1867이고 출력층의 원하는 출력 벡터를 '1 0 0 0 0'로 하여 학습한다.

LEM의 입력층의 입력 노드수는 원하는 출력값을 입력할 수 있는 만큼의 수(본 논문에서는 dummy 노드 포함 2개로 함. dummy 노드는 EBP에서 노드 오프셋을 결정하기 위함)이어야 하며, 출력층의 출력 노드수는 규칙 베이스의 조건부 퍼지 명제의 수만큼으로 한다(본 논문에서는 6개). 중간층의 노드수는 특별한 규칙이 없으나 출력층 노드수의 약 2배 정도가 적합하다(본 논문에서는 dummy 노드 포함 13개로 함)고 한다.<sup>[21]</sup>

멤버십 함수를 조절하기 위해 학습 후 DFM의 비퍼지화된 출력값을 NIM의 LEM에 적용시켜 출력층의 출력 벡터를 생성한 다음 ADM에서 조절된다. ADM의  $V_F$ 층은 LEM의 출력층이 의미하는 멤버십 함수를 벡터 형태로 유지한다.(그림 2(b) 참조)

따라서 ADM에서는 LEM의 출력 벡터 중 최대 벡터를 대응되는 멤버십 함수 벡터 각 원소에 곱함으로써 멤버십 함수를 조절한다. 또한 최대 벡터의 오른쪽과 왼쪽에 출력된 벡터값은 대응되는 멤버십 함수 벡터에 각각 1을 더한값과 빼값을 각 원소에 곱함으로써 멤버십 함수를 조절한다. 이렇게 하는 이유는

결론 생성시 관계없는 규칙들은 원하는 추론 결과로부터 점점 더 멀어지게 하기 위함이다.

NIM의 알고리즘은 다음과 같다.

LEM:

① LEM은 EBP 학습 알고리즘을 이용해 원하는 출력값과 규칙의 조건부 멤버십 함수와의 관계를 학습한다.

② EBP의 forward path:

입력층: 입력 벡터는 전문가로부터 얻은 원하는 출력값으로 한다. 패턴 p에 대한 각 입력 노드의 입력 벡터  $I_p$ 는 다음과 같다. 각 노드의 출력값을  $O_p^i$ 로 표시한다(I: input layer). 여기서 1은 노드 오프셋을 위한 dummy 노드이다. 이 노드의 출력값은 항상 1이다.

$$I_p = (i_p, 1), (i=\text{원하는 출력값}) \quad (6)$$

$$O_p^i = (O_{i1}, 1) \quad (7)$$

연결선 1: 연결선 1은 노드 i와 노드 j간의 연결 정도를 나타내는 선으로 가중치  $w_{ij}$ 로 표시한다. 즉, 입력층과 중간층을 연결하는 선을 의미한다.  $w_{ij}$ 는 학습에 의해 값이 수정된다.

중간층: 중간층의  $net_{pj}^h$ ,  $f_j^h$ ,  $O_{pj}^h$ 는 다음과 같다 (h: hidden layer). 여기서 노드 오프셋( $\theta$ )은 입력층에 항상 1 값을 갖는 dummy 노드를 뒀으므로 결정된다.

$$net_{pj}^h = \sum_{i=1}^n w_{ij} \times O_p^i, (i=1,2, j=1..m, j=\text{중간층 노드}) \quad (8)$$

$$f(\alpha) = \frac{1}{1 + \exp^{-(\alpha - \theta)}} \quad (9)$$

$$O_{pj}^h = f(net_{pj}^h) = \frac{1}{1 + \exp^{-(\sum w_{ij} \times O_p^i) + \theta}} \quad (10)$$

연결선 2: 연결선 2는 노드 j와 노드 k간의 연결 정도를 나타내는 선으로 가중치  $w_{jk}$ 로 표시한다. 즉, 중간층과 출력층을 연결하는 선을 의미한다.  $w_{jk}$  역시 학습에 의해 값이 수정된다.

출력층: 출력층의  $net_{pk}^o$ ,  $f_k^o$ ,  $O_{pk}^o$ 는 다음과 같다 (o: output layer).

$$net_{pk}^o = \sum_{j=1}^m w_{jk} \times O_{pj}^h, (j=1..m, k=1..l, k=\text{규칙의 조건부 멤버십 함수}) \quad (11)$$

$$f(\alpha) = \frac{1}{1 + \exp^{-(\alpha - \beta)}} \quad (12)$$

$$O_{pk}^o = f(net_{pk}^o) = \frac{1}{1 + \exp^{-(\sum w_{jk} \times O_{pj}^h) + \beta}} \quad (13)$$

③ 모든 패턴 P에 대해 다음의 E값이 시스템에서 정한 허용치내에 들어오면 backward path를 하지 않고 다음 패턴을 학습시키고, 그렇지 않으면 backward path를 한다. 식(14)에서  $D_{pk}$ 는 패턴 P의 k번째 출력 벡터값이고  $O_{pk}^o$ 는 실제의 출력값을 의미한다.

$$E = \frac{1}{2} \sum_p \sum_k (D_{pk} - O_{pk}^o)^2 \quad (14)$$

④ EBP의 backward path:

출력층: 원하는 출력 벡터를 준 후 실제 출력 벡터와의 차로부터 출력층의 오류값을 계산한다.

$$D_p = (D_{p1}, \dots, D_{pk}) \quad (15)$$

$$\begin{aligned} \delta_{pk} &= (D_{pk} - O_{pk}^o) f_k'(net_{pk}^o) \\ &= (D_{pk} - O_{pk}^o) O_{pk}^o (1 - O_{pk}^o) \end{aligned} \quad (16)$$

연결선 2: 다음 학습 규칙에 따라 연결 가중치를 수정한다.

$$\begin{aligned} w_{jk}(k+1) &= w_{jk}(t) + \eta (D_{pk} - O_{pk}^o) f_k'(net_{pk}^o) O_{pj}^h \\ &= w_{jk}(t) + \eta (D_{pk} - O_{pk}^o) O_{pk}^h (1 - O_{pk}^h) O_{pj}^h \\ &= w_{jk}(t) + \eta \delta_{pk} O_{pj}^h \end{aligned} \quad (17)$$

중간층: 중간층에 대한 오류값을 계산한다.

$$\delta_{pj}^h = O_{pj}^h (1 - O_{pj}^h) \sum_k \delta_{pk} W_{jk} \quad (18)$$

연결선 1: 다음 학습 규칙에 따라 연결 가중치를 수정한다.  $\beta$ 는 학습 속도와 관계된 모멘텀 상수 (momentum constant)로 임의의 실수값을 갖는다.

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \eta O_{pj}^h (1 - O_{pj}^h) \sum_k \delta_{pk} W_{jk} \\ &\quad \times O_p^i + \beta (w_{ij}(t) - w_{ij}(t-1)) \\ &= w_{ij}(t) + \eta \delta_{pj}^h O_p^i + \beta (w_{ij}(t) - w_{ij}(t-1)) \end{aligned} \quad (19)$$

⑤ 모든 패턴에 대해 몇번의 epoch를 통해 학습을 마친 후 테스트 입력 사실에 대해 DFM의 출력값을 LEM에 적용시켜서 출력층의 출력 벡터 O를 구한다.

$$O = (o_1, \dots, o_k, \dots, o_n), (n=\text{출력층의 출력 노드수}) \quad (20)$$

⑥ 출력 벡터 중  $o_k (1 \leq k \leq n)$ 를 최대 벡터라 하면  $o_k$ 에 대해 출력 벡터 O를 정규화 하여  $O'$ 를 구한다.

$$O = (o_1, \dots, o_k, \dots, o_n), (n=\text{출력층의 출력 노드수}) \quad (21)$$

⑦ 정규화된 벡터를 ADM에 입력값으로 한다.

ADM:

⑧ 입력층: LEM의 정규화된 출력 벡터  $O'$ 를 입력으로 한다.

$$O' = I = (i_1, i_2, \dots, 1, \dots, i), \quad (k = \text{규칙의 조건부 멤버십 함수}, n = \text{규칙의 수}) \quad (22)$$

⑨ 출력층: 출력층은 조절된 멤버십 함수 벡터  $V_{kf}'$ 을 생성하는 층이다. 따라서 출력 벡터 중 k번째 벡터가 최대라고 하면, k번째 규칙의 조건부 멤버십 함수의 벡터값  $V_{kf}'$ 은 다음과 같이 조절된다. 그러나 실제로 이 경우는 처음의 멤버십 함수와 같은 형태가 된다.

$$V_{kf}' = i_k V_{kf} = 1 V_{kf} = V_{kf} \quad (23)$$

⑩ 만약 멤버십 함수 벡터들이  $V_{kf}'$ 의 오른쪽에 있으면  $V_{kf}'$ 는 다음과 같이 조절된다.

$$V_{kf}' = (1 + i_k) V_{kf} \quad (24)$$

⑪ 만약 멤버십 함수 벡터들이  $V_{kf}'$ 의 왼쪽에 있으면  $V_{kf}'$ 는 다음과 같이 조절된다.

$$V_{kf}' = (1 - i_k) V_{kf} \quad (25)$$

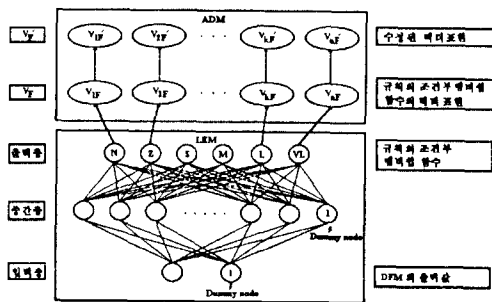


그림 3. NIM(Neuro Input Module)  
Fig. 3. Neuro Input Module.

이렇게 조절된 멤버십 함수를 FIM에 입력으로 하여 규칙 베이스를 재구성하고 유사도를 이용한 NCRI 방법을 적용한다.

2) FIM(Fuzzy Inference Module)

FIM은 NIM에서 조절된 멤버십 함수로부터 재구성된 규칙 베이스를 가지고 추론을 수행하는 모듈이

다. FIM에서는 기존의 Max-Min CRI 방법을 개선한 새로운 방법을 이용하여 추론하는데 이것을 NCRI(New Max-Min CRI)라고 명명한다. NCRI 방법은 퍼지 집합간의 유사성을 측정하는 유사도를 정의하여 결론 생성시 반영함인 Max-Min CRI 방법과의 차이점이다. 따라서 입력 사실과 규칙의 조건부 퍼지 명제간의 측정된 유사도 값에 따라 결론 생성시 그 규칙의 결론부 퍼지 명제의 반영 정도가 조절된다. 이는 Max-Min CRI 방법이 유사성을 고려하지 않고 무조건 같은 정도로 규칙의 결론부 퍼지 명제를 조합한 것에 비하면 매우 효율적이 된다.

본 논문에서 제안한 유사도는【정의 1】과 같다.

【정의 1】유사도(Similarity Measure)

퍼지 집합 A, A'의 유사도는 모든 u(u∈U)에 대해 다음과 같이 측정한다. 이때  $\tau$ 는 측정된 유사도 값이다. ( $\wedge$ : min,  $\vee$ : max)

$$SM(A, A') = \tau = \frac{\int (\mu_A(u) \wedge \mu_{A'}(u)) du}{\int (\mu_A(u) \vee \mu_{A'}(u)) du}$$

제안된 유사도는 측정하기 용이하며 다음과 같은 몇 가지 특징을 갖는다.

- $SM(A, A') = SM(A', A)$
- $SM(A, C) \leq SM(A, B) + SM(B, C)$
- $SM(A, A) = 1$
- $0 \leq SM(A, A') \leq 1$
- $SM(A, \neg A) = 0$ , ( $\neg$ : not)
- $\kappa SM(A, A') = SM(\kappa A, \kappa A')$ ,  $\kappa$ : 임의의 상수

유사도를 이용한 NCRI 방법에서의 추론 방법은 다음과 같다. 주어진 규칙 베이스가 있을 때,  $\tau$ 를 측정된 유사도 값이라 하면  $\mu_B'$ 는 추론된 결과값을 의미한다.

$$\forall v \in V, u \in U, \mu_B'(v) = \max \min(\mu_A(u), \mu_R(u, v)) = \min(\alpha \times \tau, \mu_B(v)) \quad (26)$$

FIM의 출력은 각 규칙의 결론부 멤버십 함수들의 반영 정도이며 이 값들은 NOM에 입력으로 이용된다.

3) NOM(Neuro Output Module)

NOM은 EBP 학습 알고리즘을 이용해 규칙의 조건부 멤버십 함수와 대응되는 결론부 멤버십 함수와의 관계를 학습하는 모듈이다. 이때 출력층의 출력값과 원하는 출력값과의 차가 최소가 될 때까지 반복적으로 학습한다.

NOM은 그림 4와 같이 다섯 단계의 과정으로 이루어져 있다. FIM의 출력값은 입력층, 중간층, 출력층의 세층으로 구성된 신경 회로망에 입력된다. 입력

층의 노드수는 규칙의 조건부 멤버십 함수를 입력할 수 있는 만큼의 수(본 논문에서는 dummy 노드 포함 7개로 함)이어야 하며, 출력층은 규칙의 결론부 멤버십 함수를 출력할 수 있는 만큼의 수(본 논문에서는 6개)이어야 한다. 중간층 역시 NIM에서와 같은 방법으로 노드수를 결정한다.

NOM 역시 NIM과 마찬가지로 식(14)의 값을 최소로 하려는데 목적이 있다. NOM의 알고리즘은 NIM과 같은 방법으로 진행하나 규칙의 조건부와 결론부 멤버십 함수와의 관계를 학습함이 차이점이다. 또한 EBP의 forward path에서 입력층의 입력값이 다르다. 즉, 입력 벡터는 입력 사실에 대해 퍼지 추론(FIM)을 통한  $\theta \times \tau$  값으로 한다.

NOM의 실제 출력값은 DFM의 입력으로 이용된다.

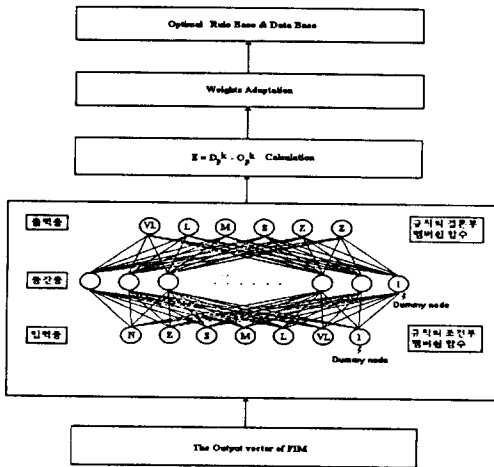


그림 4. NOM(Neuro Output Module)  
Fig. 4. Neuro Output Module.

4) DFM(Defuzzification Module)

DFM은 NOM에서의 출력값인 결론부 멤버십 함수들의 반영 정도를 입력으로 받아 최소 반영 정도 이상인 멤버십 함수들만을 조합하는 비퍼지화 과정을 수행하는 모듈이다. 이때 최소 반영 정도를 규칙 선택 기준(Rule Selection Level: RSL)이라 한다. 즉, RSL 이상인 출력 벡터 값만을 이용해 다음 식의 방법에 따라 추론 결과를 산출한다. RSL은 신경 회로망을 이용해 정의할 수 있으나 본 논문에서는 출력 벡터들의 평균값을 이용한다. 따라서 합리적으로 관련된 규칙들만을 선별하여 조합할 수 있으므로 규칙 조합 시간이 줄어들 뿐 아니라 Max-Min CRI 방법의 세번째 문제를 해결할 수 있다.

$$\text{출력값} = \sum COA_k \times \frac{O'_{pk}}{\sum O'_{pk}} \quad (27)$$

여기서  $\sum COA_k$ 는 출력층의 각 출력 노드의 해당되는 멤버십 함수의 무게 중심값이고,  $O'_{pk}$ 는 출력층 각 노드의 출력 벡터값이고,  $\sum O'_{pk}$ 는 RSL이상인 출력 벡터들의 합을 의미한다.

4. 추론 단계(Inference Phase)

3절까지의 적응 조절 단계를 거쳐 초기 규칙 베이스와 멤버십 함수로 부터 문제 영역에 적용된 최적의 규칙 베이스와 멤버십 함수를 구성했으면 이로부터 임의의 입력 사실에 대해서도 추론을 수행할 수 있다. 추론 단계는 적응 조절 단계에서 학습을 통해 문제 영역에 가장 적합한 규칙 베이스와 멤버십 함수가 재구성되었기 때문에 별도의 학습 과정 없이 NIM → FIM → NOM → DFM 순으로 차례대로 진행하면 되는 것이다. 추론 과정은 NIM으로 부터 NCRI 방법을 적용하는 FIM을 통해 출력값을 NOM에 입력하여 RSL을 정하고, RSL에 따라 규칙 베이스에서 적당한 규칙들만을 선별하여 DFM을 거쳐 문제 영역에 대한 시스템의 행동을 결정짓게 된다.

IV. 실험 및 성능 평가

본 논문에서는 제안된 INFS의 성능을 평가하고 설명하기 위해 간단한 퍼지 제어기인 직류 계열 모터(D.C.series motor)<sup>[6]</sup>를 이용하였다.

1. 직류 계열 모터

직류 계열 모터는 FLC의 성능 평가를 위한 매체(vehicle)로써 제공되는 간단한 퍼지 제어기로, 그림 5와 같은 구조를 갖는다. 이 모터의 일반적인 수행 범위는 다음과 같다.

- Power rating:  $P_N = 0.7 \text{ Kw}$
- Voltage rating:  $U_N = 110 \text{ V}$
- Rated current:  $I_N = 8.84 \text{ A}$
- Rated speed:  $n_N = 1500 \text{ r.p.m.}$

이 모터의 전자적 유입량은 변화하는 현재값  $i$ 에 비례하며  $i$ 와 속도  $n$ 과는 비선형적 관계를 갖는다. 따라서 직류 계열 모터는 현재값  $i$ 와 회전 속도값  $n$ 으로 부터 비선형식  $n = f(i)$ 에 의해 모터의 실제 상태를 측정한다.

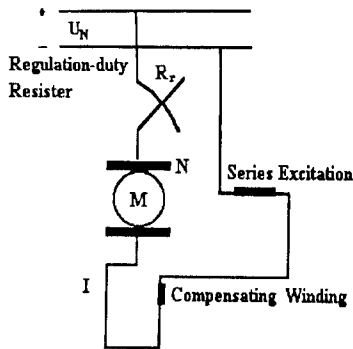
직류 계열 모터가 작동하는 규칙 베이스는 다음과 같으며 전문가로 부터 얻은 규칙으로 모터의 현재값  $I$ 와 시간당 회전 속도  $N$ 을 나타내는 퍼지 집합을 얻



어 멤버십 함수에 대한 데이터 베이스를 구성한다. 각 규칙을 그림으로 나타내면 그림 6과 같다.

```

IF I = null THEN N = very large
ALSO
IF I = zero THEN N = large
ALSO
IF I = small THEN N = medium
ALSO
IF I = medium THEN N = small
ALSO
IF I = large THEN N = zero
ALSO
IF I = very large THEN N = zero
    
```



(I:모터 현재값, N:분당 회전 속도,  $U_N$ :제공된 볼트, M:모터)

그림 5. 직류 계열 모터  
Fig. 5. D.C. Series Motor.

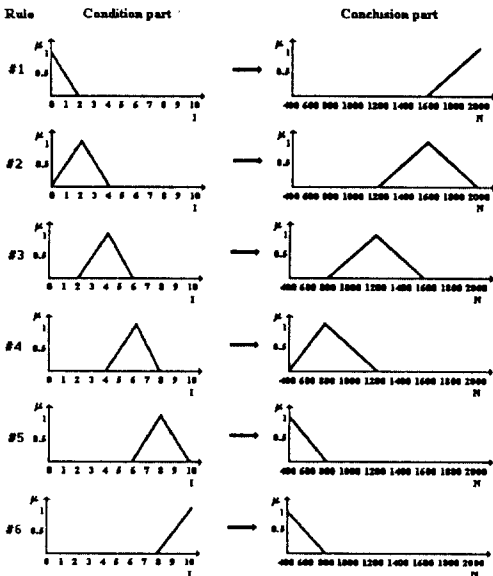


그림 6. 지식 베이스  
Fig. 6. Knowledge Base.

2. 실험 결과 및 성능 평가

본 절에서는 INFS가 Max-Min CRI 방법의 세가지 문제점을 어떻게 해결하였는지 해결 과정과 효과에 대해 실험 결과를 통해 성능 평가 하고자 한다.

첫째, 멤버십 함수 측면에서 볼 때, 신경 회로망을 사용하여 실제 곡선과 같은 곡선이 나오도록 학습을 충분히 하였기 때문에 멤버십 함수는 그림 7과 같이 조절된다. 따라서 초기에 주관적으로 정의된 멤버십 함수가 최적의 결과를 산출할 수 있도록 객관적으로 조절된 것이다.

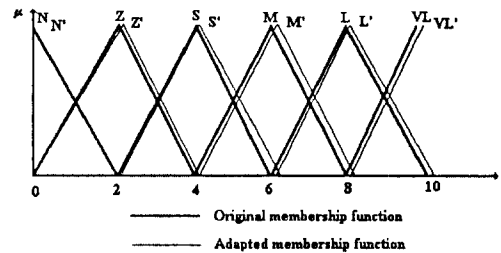


그림 7. 조절된 규칙의 조건부 멤버십 함수  
Fig. 7. The Adapted Membership Function of Condition Part in Rule Base.

둘째, 오류 비발생 가중치 전략 측면에서는 우선 INFS에서 이용하는 NCRI 방법의 성능을 평가하면 다음과 같다. 그림 8에서와 같이 NCRI 방법이 훨씬 오류 영역을 줄여 주고 있다.

NCRI 방법의 성능 평가를 위해 동일 문제 영역에서 동일 데이터를 이용해 Max-Min CRI 방법, Takefuji 방법<sup>[5]</sup>, Turksen 방법<sup>[22]</sup> 및 NCRI 방법을 각각 비교한다. 여기서 Takefuji 방법 및 Turksen 방법은 Takefuji와 Turksen이 각각 제안한 유사도를 식(26)의  $\gamma$  대신 적용한 퍼지 추론 방법을 의미한다.

실험 결과, NCRI 방법이 가장 우수했으며 다음이 Takefuji 방법이고 그 다음이 Turksen 방법이며 가장 성능이 떨어지는 방법은 유사도를 적용하지 않는 Max-Min CRI 방법으로 평가된다. 이 결과를 그림으로 나타내면 그림 8과 같다. 이 그림에서 실제 곡선과 각 그래프와의 차가 오류 영역을 나타내는 부분이다.

이 그림에서 NCRI 방법은 Max-Min CRI 방법에 비해 오류 영역을 최대 82.1%까지 줄여 주며, Turksen 방법에 비해서는 최대 74.6%까지, Takefuji 방법에 비해서는 최대 41.8%까지 줄여 준다.

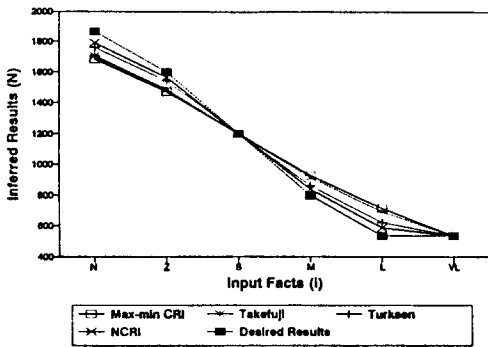


그림 8. 퍼지 추론 방법들의 추론 결과 비교  
 Fig. 8. The Comparison of Inferred Results of Fuzzy Inference Methods.

셋째, 규칙들의 합리적인 조합 측면에서는 INFS가 출력 벡터 중 RSL이상인 벡터만을 조합하는 비퍼지화 전략을 채택하고 있기 때문에 NCRI 방법에서 약간 발생했던 오류 영역(그림 8 참조)을 완벽하게 줄여 준다. 이에 대한 실험 결과는 다음과 같다. 다음 표 2는 입력 사실에 따라 INFS에서 선택한 규칙의 결론부 멤버쉽 함수를 나타낸 것이다.

표 2. 규칙들의 선택적 조합  
 Table 2. The Selective Combination of Rules.

결론부 함수 입력 사실	VL			L			M			S			Z		
	s1	s2	s3	s1	s2	s3	s1	s2	s3	s1	s2	s3	s1	s2	s3
N(Null)	o	o	o	o	x	x	o	x	x	o	x	x	o	x	x
Z(zero)	o	x	x	o	o	o	o	x	x	o	x	x	o	x	x
S(Small)	o	x	x	o	x	x	o	o	o	o	x	x	o	x	x
M(Medium)	o	x	x	o	x	x	o	x	x	o	o	o	o	x	x
L(Large)	o	x	x	o	x	x	o	x	x	o	x	x	o	o	o
VL(Very L)	o	x	x	o	x	x	o	x	x	o	x	x	o	o	o

(o: 선택된 규칙, x: 선택되지 않은 규칙, s:시스템)

표 2의 선택적 규칙들로 부터 조합하여 산출된 INFS의 추론 결과는 그림 9와 같다.

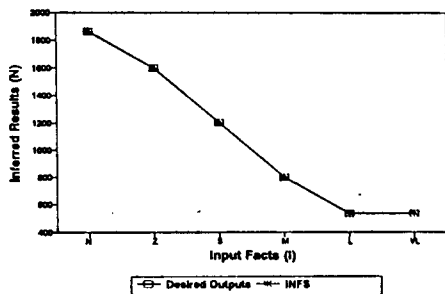


그림 9. INFS의 추론 결과  
 Fig. 9. The Inferred Results of INFS.

그림 9는 NCRI 방법에서와 마찬가지로 동일 문제 영역에서 동일 데이터를 이용한 실험 결과이다.

그림 8과 그림 9를 비교해 보면 INFS가 매우 정확한 추론 결과를 생성하는 효율적인 뉴로-퍼지 시스템이 됨을 알 수 있다. 만약 INFS가 NCRI 방법 외에 Takefujii, Turksen, Max-Min CRI 방법 등의 추론 방법을 이용하면, 어떤 추론 방법이라도 학습한 입력 사실에 대해서는 매우 정확한 값을 추론해 준다. 그러나 평균 학습 시간을 고려하였을 때, NCRI 방법을 이용한 INFS의 경우가 Takefujii, Turksen, Max-Min CRI 방법들을 이용한 INFS의 경우보다 평균 학습 시간이 각각 4.76%, 28.63%, 40.67% 정도 감소되는 결과를 보여 준다. 이것은 INFS가 NCRI 방법을 채택하는 경우가 가장 효율적임을 의미하며 동시에 INFS의 타당성을 증명하는 결과이기도 하다.

지금까지 실험 결과를 종합하면 다음과 같다. 신경 회로망의 융합 유무에 관계없이 NCRI 방법은 매우 효율적이며, 특히 NCRI 방법에 신경 회로망이 융합된 INFS 모델은 Max-Min CRI 방법의 세가지 문제점을 모두 해결해 줌으로써 오류 영역을 완벽하게 줄여줄 수 있는 문제 영역에서 매우 지능적으로 작동하는 시스템임을 알 수 있다.

V. 결론

기존의 퍼지 추론 방법인 Max-Min CRI 방법은 멤버쉽 함수가 주관적으로 결정되고 오류를 발생시키는 가중치 전략을 사용하며 비합리적으로 추론 규칙들을 조합하는 문제점 때문에 추론 결과에 상당한 오류 영역을 발생시킨다.

본 논문에서는 이 문제를 해결하기 위해 신경 회로망과 퍼지 이론의 장점만을 융합한 지능적인 뉴로-퍼지 시스템 모델(Intelligent Neuro-Fuzzy System: INFS)을 제안하였다. INFS는 지식 획득 단계, 적응 조절 단계, 그리고 추론 단계의 세단계로 구성되었고 적응 조절 및 추론 단계에는 NIM, FIM, NOM, DFM 등이 유기적으로 작동하는 시스템 모델이다.

INFS가 Max-Min CRI 방법의 세가지 문제점을 어떻게 해결하고 있는지 해결 과정과 효과에 대해 직류 계열 모터를 문제 영역으로 하여 실험을 통해 성능 평가 하였다.

첫째, NIM에서 원하는 출력값과 규칙의 조건부 멤버쉽 함수를 학습하여 멤버쉽 함수가 원하는 출력값을 생성할 수 있도록 가장 최적이면서도 객관적으

로 조절되었다.

둘째, 유사도를 이용한 NCRI 방법을 이용해 오류 영역을 상당히 줄여주었으나 NCRI 방법에서 발생하는 약간의 오류 영역은 신경 회로망을 이용해 완벽하게 해결하였다. 그러나 NCRI 방법은 Takefuji, Turksen, Max-Min CRI 방법 등의 다른 퍼지 추론 방법에 비해 오류 영역을 최대 82.1%까지 줄여줌으로써 상당히 우수한 성능을 나타내었다. 따라서 퍼지 추론만을 사용할 경우 NCRI 방법이 가장 효율적이다.

셋째, DFM에서 정의한 RSL에 따라 비퍼지화 과정을 수행함으로써 규칙들이 매우 합리적으로 조합되었다. 또한 NCRI 방법에서 발생했던 약간의 오류 영역도 완벽히 줄여 주었다. 만약 INFS가 NCRI 방법외에 Takefuji, Turksen, Max-Min CRI 방법 등의 퍼지 추론 방법을 이용한다 해도 NCRI 방법을 적용한 INFS 방법이 다른 추론 방법을 적용했을 때보다 평균 학습 시간이 각각 4.76%, 28.63%, 40.67% 정도 적게 걸리므로 훨씬 효율적이었다. 따라서 NCRI 방법을 신경 회로망에 융합시킨 INFS 모델은 Max-Min CRI 방법의 세가지 문제점을 모두 해결해 줄 뿐 아니라 문제 영역에서 매우 지능적으로 작동하는 시스템임을 알 수 있었다.

앞으로 INFS에 많은 데이터를 학습시켜 일반 영역에서도 성능을 향상시킬 수 있도록 하는 것과 보다 효율적인 뉴로-퍼지 시스템이 되도록 신경 회로망의 학습 알고리즘 개발에 관해 더 연구해야 할 것이다.

#### 参 考 文 献

- [1] L.A.Zadeh, "Outline of a new Approach to the analysis of complex Systems and Decision Process," *IEEE Transactions on SMC*, vol. SMC-3, no. 1, pp. 27-44, January, 1973.
- [2] H.Kang, G.Vachtsevanos, "Adaptive Fuzzy Logic Control," *Proceedings of the IEEE International Conference on Fuzzy Systems*, San Diego, California, pp.389-397, March, 1992.
- [3] W.C.Daugherty, B.Rathakrishnan, J. Yen, "Performance Evaluation of a Self-Tuning Fuzzy Controller," *Proceedings of the IEEE International Conference on Fuzzy Systems*, San Diego, California, pp.407-414, March, 1992.
- [4] C.C.Lee, "Fuzzy Logic in Control Systems: Fuzzy Logic Controller, Part I,II," *IEEE Transactions on SMC*, vol. SMC-20, no.2, pp. 404-435, March /April, 1990.
- [5] Y.Takefuji, Meng-hiot Lim, "Computation Scheme for the General Purpose VLSI Fuzzy Inference Engine as Expert System," *Butterworth & Co(publishers) Ltd.*, vol.2, no.2, pp.109-116, June, 1989.
- [6] J.B.Kiszka, M.E.Kochanska, D.S.Sliwinska, "The Influence of Some Implication Operators on the Accuracy of a Fuzzy Model - Part I,II," *Fuzzy Sets and Systems*, North-Holland, vol. 15, pp. 112-128, 223-240, 1985.
- [7] Z.Cao, A.Kandel, "Applicability of Some Fuzzy Implication Operators," *Fuzzy Sets and Systems*, North-Holland, vol.31, pp.151-186, 1989.
- [8] M.Mizumoto, H.J.Zimmermann, "Comparison of Fuzzy Reasoning Methods," *Fuzzy Sets and Systems*, North-Holland, vol.8, pp.253-283, 1982.
- [9] 조 영입, 황 종선, 임 해창, "퍼지 제어 시스템을 위한 개선된 Max-Min CRI 방법," 한국정보과학회 논문지, vol.20, no.9, September 1993.
- [10] B.Kosko, *Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence*, Prentice Hall, 1991.
- [11] H.Takagi, "Fusion Technology of Fuzzy Theory and Neural Networks -Survey and Future Directions-," *Proceedings of the International Conference on Fuzzy Logic & Neural Networks*, IIZUKA, Japan, pp.13-26, July 20-24, 1990.
- [12] R.Masuoka, N.Watanabe, A.Kawamura, "NeuroFuzzy System-Fuzzy Inference Using a Structured Neural Network," *Proceedings of the International Conference on Fuzzy Logic &*


- Neural Networks*. IIZUKA, Japan, pp. 174-177, July 20-24, 1990.
- [13] T.Fukami, M.Mizumoto, K.Tanaka, "Some Considerations on Fuzzy Conditional Inference," *Fuzzy Sets and Systems*, North-Holland, vol.4, pp. 243-273, 1980.
- [14] P.Thrift, "A Backpropagation Algorithm for Fuzzy Logic Mapping and Control," *North American Fuzzy Information Processing Society*, University of Missouri-Columbia, pp. 317-321, May 14-17, 1991.
- [15] T.Yamakawa, M.Furukawa, "A Design Algorithm of Membership Functions for Fuzzy Neuron Using Example-Based Learning," *IEEE International Conference on Fuzzy Systems*, San Diego, pp.75-82, March 8-12, 1992.
- [16] S.Nakanishi, T.Takagi, K.Uehara, Y.Gotoh, "Self-Organizing Fuzzy Controller by Neural Networks," *Proceedings of the International Conference on Fuzzy Logic & Neural Networks*, IIZUKA, Japan, pp.187-191, July 20-24, 1990.
- [17] M.E.Cohen, D.L.Hudson, "Approaches to the Handling of Fuzzy Input Data in Neural Networks," *IEEE International Conference on Fuzzy Systems*, San Diego, pp.93-100, March 8-12, 1992.
- [18] K.Uehara, M.Fujise, "Learning of Fuzzy-Inference Criteria with Artificial Neural Network," *Proceedings of the International Conference on Fuzzy Logic & Neural Networks*, IIZUKA, Japan, pp.193-198, July 20-24, 1990.
- [19] C.T.Lin, C.S.George Lee, "Neural-Network-Based Fuzzy Logic Control and Decision System," *IEEE Transaction on Computers*, vol.40, no.12, pp.1320-1336, December, 1991.
- [20] M.M.Gupta, M.B.Gorzalczany, "Fuzzy Neuro-Computational Technique and Its Application to Modeling and Control," *IEEE International Conference on Fuzzy Systems*, San Diego, pp.1271-1274, March 8-12, 1992.
- [21] R.P.Lippmann, "An Introduction to Computing with Neural Nets," *IEEE ASSP Magazine*, pp.4-20, April, 1987.
- [22] I.B.Turksen, Z.Zhong, "An Approximate Analogical Reasoning Schema based on Similarity Measures and Interval Valued Fuzzy Sets," *Fuzzy Sets and Systems*, North-Holland, vol. 34, pp.323-346, 1990.

## 著者紹介




曹永任(正會員)

1988年 8月 고려대학교 전산과학과(이학사). 1990年 8月 고려대학교 전산과학과(이학석사). 1994年 2月 고려대학교 전산과학과(이학박사). 1990年 ~ 현재 고려대학교 전산과학과 강사. 주관심 분야는 Artificial Intelligence, Fuzzy Control, Neural Networks, Pattern Recognition 등임.



黃鍾善(正會員)

1966年 2月 고려대학교 수학과 졸업(이학사). 1978年 Univ. of Georgia, Statistics & Computer Science 박사. 1978年 South Carolina Lander 주립대학 조교수. 1981年 한국 표준 연구소 전자 계산실 실장. 1982年 ~ 1990年 고려대학교 전자계산실 부소장. 1986年 ~ 1989年 한국 정보과학회 부회장. 1982年 ~ 현재 고려대학교 전산과학과 교수. 주관심 분야는 Artificial Intelligence, Pattern Recognition, Algorithm 등임.



孫進坤(正會員)

1984年 2月 고려대학교 수학과 졸업(이학사). 1988年 2月 고려대학교 대학원 전산학 전공(이학석사). 1991年 2月 고려대학교 대학원 전산학 전공(이학박사). 1991年 ~ 현재 한국 방송 통신대학교 전자계산학과 조교수. 주관심 분야는 Artificial Intelligence, Modeling and Simulation, Distributed Systems 등임.