

퍼지 균등화와 언어적 Hedge를 이용한 GA 기반 순차적 퍼지 모델링

GA based Sequential Fuzzy Modeling Using Fuzzy Equalization and Linguistic Hedge

김승석* · 객근창* · 유정웅* · 진명근*

Seung-Suk Kim, Keun-Chang Kwak, Jeong-Woong Ryu, and Myung-Geun Chun

*충북대학교 전기전자 및 컴퓨터공학부 컴퓨터 정보통신 연구소

요 약

본 논문은 수치적인 데이터를 이용하여 시스템을 구성하는 퍼지 모델링에서 각각의 장점들을 유지하면서 순차적으로 성능을 개선하는 방법을 제안한다. 기존의 다양한 퍼지 모델링의 최적화 방법들은 각각의 뛰어난 최적화 기법을 이용하면서도 순차적으로 퍼지 모델의 성능을 개선하려하는 시도는 많지 않았다. 이에 본 논문에서는 각 단계별로 최적의 성능을 구현하고 이를 다음 단계에서 초기로 이용함으로써 퍼지 모델의 성능이 순차적으로 개선되는 것을 제안하였다. 이는 각각의 최적화 기법들을 지속적으로 이용함으로써 원하는 모델의 성능을 개선하고자 하는 것이다. 제안된 방법의 유용성을 Rice taste 데이터 모델에 적용하여 제안된 방법이 이전의 연구보다 좋은 결과를 보임을 알았다.

Abstract

In this paper, we propose a sequentially optimization method for fuzzy inference system using fuzzy equalization and linguistic hedge. The fuzzy equalization does not require the usual learning step for generating fuzzy rules. However, it is too sensitive for the given input-output data set. So, we adopt a sequential scheme which sequentially optimizes the fuzzy inference system. Here, the parameters of fuzzy membership function obtained from the fuzzy equalization are optimized by the genetic algorithm, and then they are also modified to increase the performance index using the linguistic hedge. Finally, we applied it to rice taste data and got better results than previous ones.

Key Words : Sequential Optimization, Linguistic hedge, Fuzzy equalization, Genetic Algorithm(GA)

1. 서 론

초기의 퍼지 모델링은 경험적인 지식이나 전문가 시스템에 의하여 시스템을 구성하였다. 하지만 이러한 퍼지 모델은 시스템을 정확하게 표현하지 못하는 단점을 가지고 있었다. 이에 주어진 수치적인 입출력 데이터를 이용하여 퍼지 모델을 생성하는 다양한 방법들[1][2]이 연구되어 왔다. 신경회로망[3]의 학습기능과 퍼지 추론 시스템의 추론기능을 융합한 뉴로-퍼지 시스템[4] 등이 이용되어져 왔으며 수치적 데이터의 확률밀도를 이용하여 이를 근거로 하여 퍼지 모델을 생성하는 기법[5]등도 제안되었다. 또한 수학적 제약을 해결하면서 병렬적으로 최적화를 탐색할 수 있는 유전알고리즘[6] 등을 사용하여 퍼지 모델의 성능을 개선하고자 하였다.

소속함수의 파라미터 이외에 소속함수의 형태[7]를 변화시켜 주어진 수치적 데이터에 적합하려 하는 시도들도

계속되어져 왔다. 퍼지 모델의 성능을 개선하려는 이러한 시도들은 다양한 다른 방법들과의 접목을 통하여 기존의 논문에서 보여진 결과들 보다 좋은 성능들을 보여 왔다. 이러한 방법들은 각각의 특성들을 병렬적으로 접목하여 사용하거나 하나의 주된 알고리즘과 이를 부수적으로 융합하여 퍼지 모델의 성능을 개선하고자 하는 단순한 형태의 직렬적인 적용이었다.

따라서, 이러한 문제점을 해결하기 위하여 제안된 방법에서는 학습을 거치지 않고 단지 주어진 수치적 데이터의 확률밀도를 근거로 퍼지 모델을 생성하는 퍼지 균등화 방법[8]과 이를 초기치로 전제부 소속함수 파라미터 최적화를 탐색하고 다시 최적화된 소속함수 파라미터를 초기치로 하여 최적의 언어적 hedge를 탐색하는 방법을 제안하였다. 이는 각각 다른 특성과 탐색을 가지는 알고리즘을 직렬적으로 연결하여 각각의 알고리즘의 특성을 그대로 유지하면서도 초기치를 최적에 가까운 값으로 가질 수 있어 퍼지모델의 성능을 순차적으로 개선시킬 수 있다. 즉, 퍼지 균등화에서 검증데이터에 대한 적합 문제와 유전알고리즘에서 적절한 초기값 선정을 통한 최적치 탐색에 대한 고려를 순차적으로 적용하여 퍼지 모델의 성능을 개선하고자 한다.

시뮬레이션으로 Ishibuchi의 Rice taste[9][10] 데이터의

접수일자 : 2001년 12월 1일

완료일자 : 2001년 12월 24일

감사의 글 : 본 연구는 정보통신부 대학기초연구지원사업에 의해 일부 지원 받았습니다.

학습 데이터 및 검증 데이터의 오차 비교를 통하여 제안된 방법의 유용성을 설명한다.

2. 퍼지이론과 유전알고리즘

2.1. 퍼지 균등화

퍼지 균등화[5][8][11]는 임의의 전체공간 X 가 주어지고 이 공간상에서 취득된 수치데이터가 있을 경우, 이들로부터 확률분포 함수를 구한 후 전체공간 X 에서 이들을 적절히 표현 할 수 있는 소속함수들을 원하는 개수만큼 체계적으로 만들어 낼 수 있는 기법으로 Pedrycz에 의해 소개되었다.

이러한 퍼지 균등화 이론은 Zadeh교수에 의해 정의된 퍼지 사건[12]의 개념에 기인한다. 기존의 확률개념에서 사용되는 사건(crisp event)의 개념에서는 A 라는 사건과 이의 확률분포함수 $p(x)$ 가 주어졌을 경우 사건 A 의 확률은 다음과 같이 구해진다.

$$P(A) = \int_A p(x) dx \quad (1)$$

그러나, 만약 사건 A 에 대하여 확률분포함수 $p(x)$ 와 더불어 소속함수 $A(x)$ 값이 주어진 퍼지사건일 경우의 확률은 아래와 같이 주어진다.

$$P(A) = \int_X A(x)p(x) dx \quad (2)$$

위와 같은 개념에 기초하여 전체공간 X 에 대하여 확률밀도함수 $p(x)$ 가 주어져 있을 때, 이 공간을 퍼지 집합 $\{A_1, A_2, \dots, A_G\}$ 로 나누는 퍼지사건을 정의한다고 하자. 그러면, 이때, 가장 바람직한 분할 방법은 다음과 같이 각각의 퍼지사건의 확률이 같도록 아래와 같이 균등화하는 방법이다.

$$P(A_1) = P(A_2) = \dots = P(A_G) = \frac{1}{G} \quad (3)$$

위의 개념을 적용하면 그림 1과 같이, 데이터가 조밀한 부분과 그렇지 않은 부분에서의 소속함수의 파라미터가 밀도를 근거로 하여 생성되므로 소속함수의 분포가 데이터의 분포와 비슷하게 되는 것을 볼 수 있다.




그림 1. 퍼지 균등화의 개념
Fig. 1 Fuzzy Equalization

위의 개념을 역으로 이용하면, 원하는 소속함수의 개수 G 와 확률 밀도 함수 $p(x)$ 가 주어져 있을 경우 소속함수를 정할 수 있다. 본 논문에서는 삼각형 및 사다리꼴 퍼지 함수 모양을 사용하고, 좌우의 소속함수와 1/2씩 겹치도록 하였다. 삼각형 퍼지 함수의 경우, 증가 부분과

감소 부분으로 나뉘어 있는데 소속함수의 수에서 다시 1/2로 나누어져 $P(A) = \int A(x)p(x) dx = \frac{1}{2G}$ 가 된다. 또한 각각의 퍼지 함수에 대하여 A_i 의 감소 부분과 A_{i+1} 의 증가부분에 데이터 영역은 같으므로 A_i 의 중심 값에서 시작되어 A_{i+1} 의 중심값으로 가는 A_{i+1} 의 증가부분에 관련된 값을 σ 라 하고 이를 A_{i+1} 의 확률밀도에서 $\frac{1}{G} - \sigma$ 에 해당하는 값을 A_{i+1} 의 감소부분에 더하면 A_{i+1} 의 모든 파라미터를 구할 수 있다.

2.2. 유전알고리즘

유전알고리즘[6][13]이란 유전적 계승과 생존경쟁이라는 자연현상을 알고리즘 형태로 모델링한 확률적 탐색법을 말한다. 유전적 계승은 각 세대에 새로운 자손을 생산하는 유전적 과정을 모사한 것이고, 생존경쟁은 세대에서 세대로 집단을 만들어가는 다윈의 진화과정을 모사한 것이다. 각 세대에서 개체의 복제와 선택을 구현하기 위하여 해가 될 가능성이 있는 집단을 유지하고 이를 개량하기 위하여 재생산, 교배, 돌연변이와 같은 유전연산자를 사용한다. 유전연산자를 통해 개체를 선택하고 이들 간의 정보형성과 교환을 장려하여 집단을 개량함으로써 여러 방향으로의 탐색을 실행한다. 특히 선택시 개체들의 강점과 약점은 적합도를 통해 구별된다.

유전알고리즘의 기본 연산자로는 복제, 교배, 돌연변이 등 세 가지가 있다. 복제는 한 세대에서 다음 세대로 개체를 생성할 때 적합도에 근거하여 생존능력이 높은 개체를 선택하는 연산이며 교배는 선택된 두 개의 개체로부터 정해진 교배점을 기준으로 서로의 유전자를 교환하여 다음 세대에 좀더 좋은 적합도를 기대하는 연산이다. 알고리즘이 진행되는 동안 각각의 유전자가 복제와 교배를 통하여 서로 닮아가게 되는데 이러한 현상은 유전자의 다양성 결핍으로 국부적 최적해(local optimal)에 빠지는 요인이 된다. 돌연변이 연산자는 임의로 선택된 유전자의 정보를 바꾸어 유전자의 다양성을 유지하도록 한다. 이러한 연산을 통하여 세대에서 모든 개체의 특징 비트가 고정되는 것을 방지해주고 또한 탐색영역을 확대해주시기도 한다.

만약 유전알고리즘이 한 세대의 최적 개체를 다음 세대에도 생존하도록 보장해 주는 어떤 방법을 갖고 있지 않다면 그림 2와 같이 엘리티즘을 채용하는 것도 성능 개선의 한 방법이 된다. 이 방법은 이전 세대의 최적 개체를 저장하고 있다가 복제-교배-돌연 연산을 거쳐 현 세대의 집단이 완성되면 최적 개체의 생존 유무를 확인하게 되고 만일 최적 개체가 소멸되었으면 저장된 개체를 현 세대의 집단 안에서 적합도가 가장 낮은 개체와 교환해준다. 이 방법은 일반적으로 성능을 개선해주는 것으로 알려져 있지만 가끔 초기 세대에 강한 개체가 집단을 지배하는 원인을 제공하기도 한다. 유전알고리즘이 진행되는 동안 각 세대들의 최적치를 모두 기록하여야 하며 이를 알고리즘 종료 후 확인하여 각 세대별로 최적치를 찾아 가장 좋은 수치를 사용하여야 하는 문제를 가지고 있었다. 하지만 엘리티즘은 한 세대의 최적치를 다음 세대에 변형을 가하지 않고 그대로 가져감으로 마지막 세대의 값이 현재 수행된 알고리즘에서의 최적치라고 말할 수 있다.

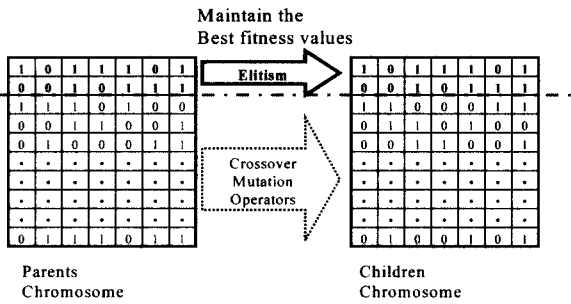


그림 2. 다음세대로 진행하는 과정
Fig. 2 The process for producing the next generation

3. 퍼지 균등화와 언어적 hedge를 이용한 GA 기반 순차적 퍼지 모델링

제안된 모델은 TSK(Takagi-Sugeno-Kang) 퍼지 모델로서 언어적 형태의 전제부와 1차 선형방정식을 가지는 결론부로 구성되어 있으며 제안된 방법에서는 그림 3과 같이 전제부 소속함수는 사다리꼴 소속함수와 삼각형 소속함수를 사용하였다. 입력이 두개인 TSK 형태의 퍼지 추론 시스템은 보통 다음과 같은 구조로 나누어지며 각각의 구성은 다음과 같다.




그림 3. TSK 퍼지 모델
Fig. 3 TSK fuzzy model

$$O_i^1 = \mu_{A_i}(x), \quad O_{i+2}^1 = \mu_{B_i}(y), \quad i = 1, 2$$

$$\mu_{A_i}(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases}$$

여기서, $\{a_i, b_i, c_i\}$ 는 전제부 파라미터이다.

$$O_i^2 = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2$$

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2$$

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad i = 1, 2$$

$$O_i^5 = y_i^* = \frac{\sum_{i=1}^2 \bar{w}_i f_i}{\sum_{i=1}^2 \bar{w}_i}$$

이상으로 얻어진 퍼지 모델의 출력 값과 원하는 출력 값 사이의 오차를 최소화하기 위해 전제부 파라미터가 정해지면 최소자승법[1]으로 결론부 파라미터를 추정한다.

제안된 방법에서는 3단계로 나누어 퍼지 모델 최적화를 실시한다. 먼저 퍼지 균등화에 의하여 전제부 소속함

수를 생성한다. 생성된 퍼지 모델은 학습데이터에 대하여 좋은 결과를 나타내는 반면 검증데이터에 대하여는 전혀 고려되지 않았다. 이에 유전알고리즘을 이용하여 학습데이터 및 검증데이터의 오차까지 함께 고려한 적합 함수를 사용하여 전제부 소속함수 파라미터 최적화를 실시한다. 초기 모든 개체는 퍼지 균등화에 의하여 생성된 파라미터를 초기값으로 가지고 있으면 세대 초기에는 유전알고리즘의 돌연변이 연산에 의하여 변화를 시작한다. 최적값을 유지하기 위한 방법으로 엘리티즘은 세대가 진화하는 동안 적합도가 높은 개체를 계속 보존함으로써 성능개선을 하면서도 반면에 성능이 나빠지는 것을 방지한다. 마지막으로 최적화된 전제부 소속함수 파라미터를 기반으로 하는 언어적 hedge를 탐색한다. 언어적 hedge는 각 소속함수로 표현하기 어려운 영역까지도 확장 또는 축소가 가능하다는 장점을 가지고 있다.

언어적 hedge[7]은 소속함수의 모양을 변형하여 사용하는 연산자이다. Zadeh에 따르면 언어적 영역 연산자는 집중(concentration), 팽창(dilation) 등의 크게 두 개로 나누어진다. 언어적 hedge는 다음과 같이 정의 된다.

$$A^a = \int_X [\mu_A(x)]^a / x \quad (4)$$

이를 다시 나누어 보면 a 가 1 보다 클 때 집중이라 하며 다음과 같이 정의된다.

$$\text{Absolutely} \quad x \doteq x^4 \quad (5)$$

$$\text{very} \quad x \doteq x^2 \quad (6)$$

$$\text{much more} \quad x \doteq x^{1.75} \quad (7)$$

$$\text{more} \quad x \doteq x^{1.5} \quad (8)$$

$$\text{plus} \quad x \doteq x^{1.25} \quad (9)$$

또 a 가 1 보다 작을 때 팽창이라 하며 다음과 같이 정의된다.

$$\text{minus} \quad x \doteq x^{0.75} \quad (10)$$

$$\text{more or less} \quad x \doteq x^{0.5} \quad (11)$$

$$\text{slightly} \quad x \doteq x^{0.25} \quad (12)$$

이들 언어적 영역은 ‘출다’, ‘덜다’ 등 다른 언어적 변수들과 조합되어 ‘매우 출다’, ‘매우 덜다’와 같이 만들어진다.




그림 4. 순차적 최적화
Fig. 4 Sequential optimization

제안된 방법은 그림 4와 같이 각각의 방법을 순차적으로 최적화하는 것으로서 단계 1에서 퍼지균등화 기법을 이용하여 전제부 소속함수를 생성하고 단계 2에서 유전알고리즘을 이용하여 소속함수 파라미터 최적화를 실

시한 후 단계 3에서 언어적 hedge 최적화를 수행한다. 각 단계에서의 결과를 다음 단계의 초기치로 사용하므로 다음 단계에서는 초기치 부터 좋은 결과를 가질 수 있으며 이를 엘리티즘을 이용하여 보존하므로 모든 단계가 마친 후 결과는 순차적으로 개선되어 간다.

4. 시뮬레이션 및 결과

본 논문은 Ishibuchi와 Nozaki가 사용한 Rice taste 데이터 모델링[9]에 적용하여 퍼지 추론 시스템을 구현하였다. 여기서는 제안된 방법이 학습데이터에 편중되지 않고 새로운 데이터에 대해서도 타당한 결과를 내는 모델인가를 평가하기 위해 데이터 집합을 학습데이터와 검증데이터로 나누었다. 입출력데이터의 집합은 이전의 논문과 비교하기 위해 0과 1사이에 정규화된 5개의 입력과 1개의 출력으로 구성하였으며 총 105개의 데이터 중 입력으로 75개는 학습데이터로 나머지 30개는 검증데이터로 사용하였다.




그림 5. 입력데이터 분포
Fig. 5 Input data distribution

이 예제에서 두개의 입력을 선택하기 위하여 기존 논문[4][14]와 같이 성능평가를 실시하여 훈련데이터의 오차와 검증데이터의 오차를 동시에 고려한 결과 flavor 데이터와 taste 데이터를 입력으로 선택하였고 출력은 overall evaluation을 이용하였다. 각각의 입력을 그림으로 표현하면 그림 5과 같이 전체 데이터 공간 내에 분포되어 있는 형태가 특정 영역에서는 높은 밀도로 분포되어 있으며 또 다른 영역에서는 거의 분포되어 있지 않거나 데이터가 존재하지 않는 공간이 존재하기도 한다.

단계 1: 퍼지 균등화를 이용한 퍼지 모델링

주어진 수치적 입출력 데이터에 대하여 퍼지 균등화를 실시한다. 퍼지 균등화에 의하여 생성된 전제부 소속함수는 그림 6에서의 데이터 밀도에 근거하여 그림 7과 같이 생성된다. 퍼지 균등화 기법의 단점으로는 훈련 데이터에 대하여 좋은 성능을 가지는 반면 검증 데이터에 대하여 전혀 고려되어 있지 않다. 따라서 검증 데이터에 대한 오차가 크다.

단계 2: GA를 기반으로 하는 FE 파라미터 동정


퍼지 균등화 기법에 의하여 생성된 전제부 소속함수 파라미터를 초기치로 하여 전제부 소속함수 최적화를 실

시한다. 유전알고리즘의 초기치는 모두 단계 1에서 생성된 파라미터를 가지므로 유전알고리즘 초기에는 돌연변이에 의하여 진행되며 알고리즘이 진행되면서 교배 등의 연산으로 최적화가 진행된다. 엘리티즘을 적용하여 각 세대에서 가장 좋은 성능을 가지는 유전자를 다음세대에 계속 생존하도록 하는 방법으로 각 세대에서 최적의 값을 계속 유지하도록 하였다. 유전알고리즘은 세대수 100, 개체수 50, 교배율 0.95, 돌연변이율 0.1로 정하고 평가함수로는 훈련데이터와 검증데이터를 동시에 고려하여 정하였다. 또한 적합함수로는 훈련 데이터의 오차와 검증 데이터의 오차를 동시고려하여 감소하는 방향으로 소속함수의 파라미터를 탐색하였다. 그림 8에서 유전알고리즘에 의하여 최적화된 전제부 소속함수를 나타내었다.


단계 3: 언어적 hedge를 이용한 퍼지 모델 최적화

단계 2에서 최적화된 전제부 소속함수의 파라미터를 기반으로 언어적 hedge 최적화를 탐색하였다. 유전알고리즘의 조건은 단계 2와 같고 파라미터는 고정하고 언어적 hedge에 대하여 최적화를 실시하였다. 그림 9에서와 같이 기존의 소속함수의 형태와 많은 차이가 있음을 알 수 있고 이를 데이터 분포와 비교하면 밀도가 높은 부분에서의 소속함수 형태와 그렇지 않은 부분에서의 형태가 데이터 분포에 근접하여 가는 것을 볼 수 있다.

그림 8과 그림 9의 전제부 소속함수 파라미터는 같으나 언어적 hedge에 의하여 소속함수의 형태가 변하며 그림 10에 제안된 모델에서의 출력 비교를 나타내었다. 또한 표 1에서 볼 수 있듯이 각 단계가 진행되어 감에 따라 제안된 퍼지 모델의 성능이 개선되는 것을 알 수 있다.




(a) flavor




(b) taste

그림 6. 입력에 대한 분포도
Fig. 6 Histogram of input




(a) flavor




(b) taste

그림 7. 퍼지균등화에 의한 소속함수
Fig. 7 Membership function using FE




(a) flavor




(b) taste

그림 8. 유전알고리즘을 이용한 전제부 소속함수
파라미터 탐색

Fig. 8 Membership function parameter search using GA



(a) flavor



(b) taste

그림 9. GA를 이용한 언어적 hedge 탐색
Fig. 9 Hedge of MF search using GA

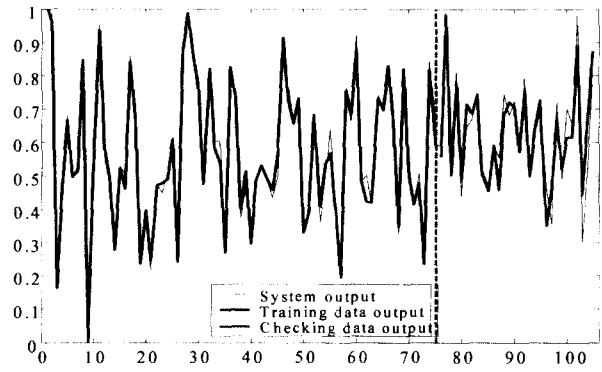


그림 10. 실제 출력과 제안된 모델의 출력

Fig. 10 Actual output and proposed model output

Table 1. Comparison with previous studies

| | 학습오차 | 검증오차 |
|--------------|--------|---------|
| Ishibuchi[9] | 0.006 | 0.142 |
| Herrera[15] | 0.0081 | 0.0192 |
| 제안된 방법 | 단계 1 | 0.00079 |
| | 단계 2 | 0.00075 |
| | 단계 3 | 0.00069 |

4. 결론

본 논문에서는 각각의 좋은 성능을 가지는 기법들을 순차적으로 연결하여 퍼지 모델의 성능개선을 시도하였다. 퍼지 균등화는 초기 학습을 거치지 않고 빠르게 전제부 소속함수를 생성하여 퍼지 모델을 생성할 수 있는 장점이 있으나 소속함수 생성에 있어 학습데이터를 기준으로 하여 검증 데이터에 대하여 타당성을 가지지 못했다. 이에 유전알고리즘을 이용하여 학습데이터와 검증데이터의 오차까지도 고려하여 소속함수를 탐색하여 좀더 성능을 개선하였고 다시 언어적 hedge를 탐색하여 퍼지 모델의 성능이 시스템에 더욱 근사하게 추종하도록 하였다. 언어적 hedge연산자는 수식으로 대응되는 파라미터의 추가로 소속함수의 형태에 영향을 주어 소속함수만으로 표현이 어려웠던 데이터의 형태나 공간상의 문제를 해결하려 시도한다.

제안된 방법에서는 각각의 최적화 기법을 각각의 특성들을 유지하면서 순차적으로 수행함으로써 퍼지 균등화에서 발생할 수 있는 검증 데이터에 대한 고려와 유전

알고리즘에서 발생하는 초기치 선정과 알고리즘의 진행에서 발생하는 여러 문제점들을 상호 보완하였고 보조적인 방법으로 엘리티즘을 이용하였다.

제안된 방법에서는 퍼지 모델의 성능 개선에 대하여만 고려하였다. 추후의 연구과제로는 퍼지 모델의 성능 개선 및 규칙수의 감소를 통하여 모델이 입력이 증가할 때 지수 함수적으로 규칙이 증가하는 문제점들을 해결하는 방법으로서 퍼지 균등화를 이용한 퍼지 클러스터링 등이 있다.

참 고 문 헌

- [1] J. S. R. Jang, C. T. Sun, E. Mizutani, "Neuro- Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence", Prentice Hall, 1997.
- [2] Lin-Xin Wang, Adaptive Fuzzy System and Control, Prentice Hall, 1994
- [3] Simon Haykin, Neural Network : A Comprehensive foundation, Macmillan, 1994
- [4] J. S. R. Jang, "ANFIS : Adaptive-Networks-based Fuzzy Inference System", *IEEE Trans. on System, Man, and Cybern.*, vol. 23, no. 3, pp. 665-685, 1993.
- [5] Witold Pedrycz, "Fuzzy equalization in the construction of fuzzy sets", *Fuzzy sets and system*, vol. 119, pp. 329-335, 1999.
- [6] Zbigniew Michalewicz, Genetic Algorithms+Data Structure = Evolution Programs, Springer, 1999.
- [7] Bin-Da Liu, Chuen-Yau Chen, Ju-Ying Tsao, "Design of Adaptive Fuzzy Logic Controller Based on Linguistic-Hedge Concepts and Genetic Algorithms", *IEEE Tr. On System, Man, And Cybernetics-Part B*, vol. 31, no. 1, 2001.
- [8] 광근창, 이대중, 유정웅, 전명근, "CFCM과 퍼지 균등화를 이용한 퍼지 규칙의 자동 생성", *한국 퍼지 및 지능시스템 학회 논문지*, vol. 10, no. 3, pp. 194-202, 2000.
- [9] Ken. Nozaki, Hisao Ishbuchi, Hideo Tanaka, "A simple but powerful heuristic method for generating fuzzy rules from numerical data", *Fuzzy sets and Systems*, vol. 86, pp. 251-270, 1997
- [10] Hisao Ishbuchi, Ken Nozaki, Hideo Tanaka, M. Matsuda, "Empirical Study on Learning in Fuzzy Systems", *IEEE International Conference on Fuzzy Systems*, pp. 606-611, 1993.
- [11] Hanqi Zhuang, Xiaomin Wo, "Membership Function Modification of Fuzzy Logic Controllers with Histogram Equalization", *IEEE Tr, System, Man, and Cybernetics-Part B*, vol. 31, no. 1, pp. 125-132, 2001.
- [12] Heriberto Roman-Flores, Laecio C Barros, Rodney C Bassanezi, "A note on Zadeh's extension", *Fuzzy Sets and Systems*, vol. 119, pp. 327-331, 2001.
- [13] 진강규, *유전알고리즘과 그 응용*, 교유사, 2000.
- [14] J-S R Jang, "Input Selection for ANFIS Learning", *Proceeding of the Fifth IEEE International Conference on Fuzzy Systems*, vol. 2, pp. 1493-1499, 1996.
- [15] J Casillas, O Cordon, J D Jesus, F Herrera, "Genetic tuning of fuzzy rule deep structures for linguistic

modeling", submitted to *IEEE Trans on Fuzzy Systems*, 2001

저 자 소개



김승석(Seoung-Suk Kim)

1998년 : 충주산업대학교 전기공학과(학사)
2000년~2002 : 충북대학교 전기공학과
(공학석사)

관심분야 : 퍼지 이론, 신경회로망, 유전 알고리즘

E-mail : powerkim@engine.chungbuk.ac.kr



곽근창(Keun-Chang Kwak)

1996년 : 충북대학교 전기공학과(학사).
1998년~현재 : 충북대학교 전기공학과
박사과정

관심분야 : 지능시스템, 패턴분류, 얼굴인식

E-mail : kckwak@engine.chungbuk.ac.kr



유정웅(Jeong-Woong Ryu)

1965년 : 한양대학교전기공학과(학사)
1987년 : 단국대학교 전기공학과(공학 박사)
1969년~1979년 : 대전개방대학 교수
1979년~현재 : 충북대학교 전기전자 및
컴퓨터공학부 컴퓨터정보
통신연구소 교수

관심분야 : 지능제어, 가변구조제어, QFT제어

E-mail : jwryu@engine.chungbuk.ac.kr



전명근(Myung-Geun Chun)

1987년 : 부산대학교 전자공학과(학사)
1989년 : 한국과학기술원 전기 및
전자공학과(공학석사)

1993년 : 한국과학기술원 전기 및
전자공학과(공학박사)

1993년~1996년 : 삼성전자 자동화연구소
선임연구원

2000년~2001년 : University of Alberta 방문교수
1996년~현재 : 충북대학교 전기전자 및 컴퓨터공학부
컴퓨터정보통신연구소 조교수

관심분야 : Biometrics, 감정인식, 음성신호처리, 얼굴인식

E-mail : mgchun@cbucc.chungbuk.ac.kr