

논문 2005-42CI-1-7

함수 근사화를 위한 강인한 TSK 퍼지 모델링

(Robust TSK-fuzzy modeling for function approximation)

김 경 중*, 김 은 태**, 박 민 용**

(Kyoungjung Kim, Euntai Kim, and Mignon Park)

요 약

본 논문에서는 새로운 강인한 TSK 퍼지 모델링 알고리즘을 제안한다. 데이터에 노이즈나 아웃라이어가 존재할 때 모델링하기 위한 다양한 강인한 접근법이 제안되었지만 주로 손실함수를 사용하여 아웃라이어나 노이즈의 효과를 감소시키는 접근방법들이 수행되었다. 제안된 알고리즘은 노이즈 클러스터링의 변형된 형태로, 손실함수를 사용하지 않고 노이즈를 하나의 클래스로 클러스터링하는 방법을 선택하였다. 노이즈 클러스터링은 포로토타입 기반의 클러스터링 알고리즘으로, 리그레션을 할 수 없기 때문에 먼저 데이터를 클러스터링한 후 다음으로 퍼지 리그레션을 수행한다. 전건부와 후건부의 매개변수를 동시에 얻기 위한 다른 방법들이 고안되었지만 그들 알고리즘들은 매개변수를 구한 후 좀더 정확한 함수의 근사화를 위해 매개변수에 대한 적응과정을 거친다. 본 논문에서는 노이즈 클러스터링 알고리즘을 변경하여 함수의 리그리션을 동시에 수행 할 수 있게 하였다. 제안된 알고리즘은 전건부와 후건부의 매개변수를 동시에 얻을 수 있으며, 매개변수를 구한 후 이에 대한 적응과정이 필요하지 않다. 제안된 알고리즘의 검증을 위하여 몇 가지 간단한 예제를 사용하여 실험하였으며, 기존에 연구된 다른 알고리즘과 비교, 분석하였다. 제안된 알고리즘은 노이즈나 아웃라이어에 대하여 강인한 성능을 보이며, 구현이 용이하다.

Abstract

This paper proposes a novel TSK fuzzy modeling algorithm. Various approaches to fuzzy modeling when noise or outliers exist in the data have been presented, but they are approaches to degrade effects of outliers or large noise by using loss function in the cost function mainly. The proposed algorithm is the modified version of noise clustering algorithm, and it adopts the method that does not use loss function, but method to cluster noise in a class. Noise clustering is a prototype-based clustering algorithm, and it has no capability to regress. It conducts clustering of data first, and then conducts fuzzy regression. There are many algorithms to obtain parameters of premise and consequent part simultaneously, but they need to adapt the parameters obtained for more accurate approximation. In this paper, fuzzy regression is conducted with clustering by modifying noise clustering algorithm. We propose the algorithm that parameters of the premise part and the consequent part are obtained simultaneously, and the parameters obtained are not needed to adapt. We verify the proposed algorithm through simple examples and evaluate the test results compared with existing algorithms. The proposed algorithm shows robust performance against noise and it is easy to implement.

Keywords : fuzzy modeling, noise, outliers, regression, noise clustering

I. 서 론

TSK 퍼지 모델이 제안된 이 후 TSK 퍼지 모델은 그의 비선형적 특성과 실제 시스템에 대한 적용에 있어서의 좋은 성능으로 인해 많은 연구가 수행되어져 왔다^[1,2,4]. 최근에는 데이터에 노이즈나 아웃라이어가 존재할

때 적용하기 위한 강인한 퍼지 모델링 기법에 관한 많은 연구들이 진행되어 왔다^[2,3,5,6,7,8,9,10,11]. 강인한 성능을 얻기 위해서 대부분의 연구에서 감소함수를 이용하였다^[2]. 하지만 감소함수를 이용할 경우에는 복잡하고 계산량이 많아진다. 또한 프로토 타입을 기본으로 하는 접근법들이 주를 이루는데 이의 대표적인 알고리즘으로 FCRM(Fuzzy c-regression model)^[4]이 있다. FCRM은 클러스터 구조의 리그레션 형태를 사용한 모델링 접근법으로 먼저 데이터들을 클러스터링하여 전건부의 퍼지 서브스페이스를 구한 후 후건부 매개변수를 구하여 매

* 정회원, ** 종신회원, 연세대학교 전기전자공학과
(Department of Electrical and Electronic Engineering, Yonsei University)
접수일자: 2004년7월6일, 수정완료일: 2005년1월5일

개변수에 대한 적응을 수행한다. 노이즈가 존재하지 않는 데이터의 경우에는 근사화 능력이 우수하지만 아웃라이어를 줄이는 능력이 결여되어 있다.

또한 FCRM은 퍼지 규칙의 수를 미리 정하여 주고 클러스터링을 수행하게 한다. 퍼지 규칙의 수를 초기에 정하지 않고 자동으로 퍼지 규칙의 수를 정하는 알고리즘에 대한 연구가 있었는데, 그 대표적인 경우가 SONFIN (Self-constructing Neural Fuzzy Inference Network)^[9]이다. SONFIN은 기본적으로 구조학습 능력을 가진 모델링 기법으로, 퍼지 부분공간이 데이터의 출력 부문에 의해 정의된다. FCRM의 결점을 극복하고 퍼지 구조를 자동으로 결정하게 하는 알고리즘에 대한 연구가 진행되어 RFRA(Robust Fuzzy Regression Algorithm)^[2]이 개발되었다. RFRA는 노이즈나 아웃라이어가 존재할 때 우수한 성능을 보이지만, 단점으로는 퍼지 규칙의 수를 사용자가 조정할 수가 없기 때문에 FCRM 등 사전 정보를 이용하여 퍼지 규칙의 수를 지정해주는 알고리즘에 비해서 퍼지 규칙의 수가 많아져 계산량이 많고 구현하기가 어려운 점이 있다. 본 논문에서는 노이즈 또는 아웃라이어에 대해 강인한 성능을 보이며 전건부와 후건부의 매개변수를 쉽게 구할 수 있는 새로운 TSK 퍼지 모델링 알고리즘이 제안된다. 제안된 알고리즘은 퍼지 리그레션과 노이즈 클러스터링 개념을 채택하였다^[3,5,6,7]. 또한 프로토타입에 바탕을 둔 알고리즘 대신에 퍼지 리그레션을 적용하여 클러스터링을 수행한 후 이를 바탕으로 한 함수 근사화를 수행하지 않고 동시에 수행하게 하였다. 제안된 알고리즘은 노이즈를 정상적인 데이터와 구분하여 클러스터링 함으로써 아웃라이어에 대해 강인한 성능을 보인다. 제안된 알고리즘에 대해 성능이 우수함을 보이기 위해 몇 가지 예제를 사용하여 모의실험 수행한다. 모의실험 결과는 제안된 알고리즘의 성능이 기존의 다른 접근방법들에 비해 우수함을 보여준다.

II. 본 론

1. TSK 퍼지 시스템

본 장에서는 TSK 퍼지 모델에 대해 간략히 기술한다. TSK 퍼지 모델은 정적 또는 동적인 비선형 시스템을 나타낼 수 있다. TSK 퍼지 모델은 선형 함수의 집합으로 구성된 후건부를 가지며 이는 부분 선형들의 확장으로 볼 수 있다. TSK 퍼지 모델은 다음과 같은 형태를 갖는다.

$$R^i : \text{If } x_1 \text{ is } A_1^i(\vec{\theta}_1^i) \text{ and } x_2 \text{ is } A_2^i(\vec{\theta}_2^i), \dots, x_n \text{ is } A_n^i(\vec{\theta}_n^i)$$

$$\text{then } y^i = f_i(x_1, x_2, \dots, x_n; \vec{a}^i)$$

$$= a_0^i + a_1^i x_1 + \dots + a_n^i x_n \quad (1)$$

$i = 1, 2, \dots, C$ 이고 이 때 C 는 룰의 수이고, $A_j^i(\vec{\theta}_j^i)$ 는 조정 가능한 매개변수 $\vec{\theta}_j^i$ 를 가진 x_j 에 대한 i 번째 룰의 퍼지 집합, $\vec{a}^i = (a_0^i, \dots, a_n^i)$ 는 후건부의 매개변수의 집합을 나타낸다.

퍼지 모델의 예상 출력은 다음과 같이 추론된다.

$$\hat{y} = \frac{\sum_{i=1}^C y^i w^i}{\sum_{i=1}^C w^i} \quad (2)$$

이 때 y^i 는 i 번째 룰의 출력을 나타내며, w^i 는 i 번째 규칙의 파이어링 세기를 나타낸다. 이는 모든 퍼지 변수의 퍼지 소속 정도의 최소로 얻어진다. 학습 데이터가 주어졌을 때 입출력 데이터로부터 퍼지 모델을 추정해야 한다. 시스템의 룰의 수가 정해져야하고 전건부와 후건부의 매개변수가 정해져야 한다. 노이즈나 아웃라이어가 존재할 때, 학습 데이터로부터 얻어진 모델은 부합되지 않는다. 본 논문에서는 아웃라이어에 대한 강인성 효과를 갖기 위해 노이즈 클러스터링 개념이 적용되며, 퍼지 서비스페이스와 후건부의 함수를 동시에 구하기 위해 리그레션이 적용된다. 자세한 알고리즘은 다음 절에서 소개한다.

2. 노이즈 클러스터링 개념을 사용한 퍼지 모델링

제안된 알고리즘은 노이즈 클러스터링을 개선한 것이다. 노이즈 클러스터링은 R. N. Dave에 의해 제안되었다. 노이즈 클러스터링 알고리즘은 입력 데이터와 클러스터의 프로토타입간의 거리의 함수를 가격 함수로 사용한다. 그러나 노이즈 클러스터링 알고리즘은 단지 클러스터링 알고리즘으로 후건부의 매개변수를 알 수 없으므로 퍼지 리그레션을 도입한다. 제안된 알고리즘의 가격함수는 원하는 출력과 룰에 의한 출력간의 오차와 거리로 이루어진 함수이다.

e_{ij} 를 모델링한 시스템의 j 번째의 원하는 출력과 j 번째 입력 데이터에 대한 i 번째 룰에 의한 출력 사이의 오차라 하면 다음과 같이 나타낼 수 있다.

$$e_{ij} = y_j - f_i(\vec{x}(j); \vec{a}^i)$$

$$i = 1, 2, \dots, C, j = 1, 2, \dots, N \quad (3)$$

이 때 y_j 는 j 번째 원하는 출력이고 C 는 퍼지 규칙의 개수, N 은 학습 데이터의 개수이다.

노이즈를 포함한 데이터를 다루기 위한 노이즈 클러스터링 개념이 제안된 알고리즘에 도입된다. 노이즈는 분리된 클래스로 구분되며 거리 δ 를 갖는다.

노이즈 클러스터내의 한 점 x_j 의 소속 합수 u_{*j} 는 다음과 같이 정의된다.

$$u_{*j} = 1 - \sum_{i=1}^C u_{ij} \quad (4)$$

좋은 클러스터를 위한 소속 상수는 다음과 같이 효과적으로 완화된다.

$$\sum_{i=1}^C u_{ij} < 1 \quad (5)$$

이 조건은 노이즈 점이 잘된 클러스터에서 임의의 작은 소속 합수 값을 갖게 한다.

다음으로 제안된 알고리즘의 가격함수를 다음과 같이 정의할 수 있다.

$$J = \sum_{i=1}^C \sum_{j=1}^N u_{ij}^2 e_{ij}^2 + \sum_{j=1}^N \delta^2 (1 - \sum_{i=1}^C u_{ij})^2 \quad (6)$$

이 때 u_{ij} 는 소속의 정도를 나타내며 δ 는 노이즈 거리를 나타낸다.

가격함수 J 를 최소화하기 위해 미분을 하면 다음의 소속 합수 갱신 방정식을 구할 수 있다.

$$\frac{\partial J}{\partial u_{ij}} = 2u_{ij}e_{ij}^2 - 2\delta^2(1 - \sum_{i=1}^C u_{ij}) = 0 \quad (7)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^C \frac{e_{ik}^2}{e_{kj}^2} + \frac{e_{ij}^2}{\delta^2}} \quad (8)$$

후전부의 매개변수 벡터는 다음과 같이 구해진다.

$$\frac{\partial J}{\partial \vec{a}^i} = \sum_{j=1}^N (u_{ij})^2 \frac{\partial e_{ij}^2}{\partial \vec{a}^i} = 0 \quad (9)$$

$$\sum_{j=1}^N (u_{ij})^2 [y_i - f_i(x_j; \vec{a}^i)] \frac{\partial e_{ij}}{\partial \vec{a}^i} = 0 \quad (10)$$

위 식에서 $\frac{\partial e_{ij}}{\partial \vec{a}^i}$ 는 식(3)으로부터 다음과 같음을 알 수 있다.

$$\frac{\partial e_{ij}}{\partial \vec{a}^i} = x_j \quad (11)$$

$$\sum_{j=1}^N (u_{ij})^2 y_i \frac{\partial e_{ij}}{\partial \vec{a}^i} - \sum_{j=1}^N (u_{ij})^2 f_i(x_j; \vec{a}^i) \frac{\partial e_{ij}}{\partial \vec{a}^i} = 0 \quad (12)$$

여기에서 $X \in R^{N \times (n+1)}$ 는 $(k+1)$ 번째 행으로 x_k 를 갖는 행렬로 X 의 첫 번째 항의 요소들은 모두 1이며, $Y \in R^N$ 는 k 번째 요소로 y_k 를 갖는 벡터이고 $D_i \in R^{N \times N}$ 는 k 번째 대각 요소로 u_{ik}^2 를 갖는 대각행렬로 정의한다.

위 식 (12) 로부터 i 번째 룰에 의한 후전부의 매개변수를 구할 수 있는데, 매개변수 벡터 \vec{a}^i 는 다음 식 (13)과 같이 얻어진다.

$$\vec{a}^i = [X^T D_i X]^{-1} X^T D_i Y, \quad i = 1, 2, \dots, C \quad (13)$$

제안된 알고리즘을 수행하는 절차는 다음과 같다.

1단계 : 클러스터 수 C 와 노이즈 거리 δ 를 정한다.

2단계 : 소속정도를 초기화 한다.

3단계 : 후전부 매개변수 집합 \vec{a}^i 를 계산한다.

4단계 : 오차 e_{ij} 를 계산한다.

5단계 : 소속정도 u_{ij} 를 갱신한다.

6단계 : 반복회수가 최고 반복회수를 초과하거나 알고리즘 종료 기준에 도달하면 학습을 중지한다. 그렇지 않으면 3단계를 반복한다.

위 절차로부터 소속정도 u_{ij} 와 후전부의 매개변수가 결정된다. 전전부에 i 번째 규칙의 j 번째 소속 합수의 두개의 매개변수를 가진 가우스 합수 형태의 소속 합수가 사용된다고 가정하면 두 매개변수는 u_{ij} 로부터 다음과 같이 쉽게 얻어질 수 있다.

$$\theta_{j1}^i = \frac{\sum_{k=1}^N (u_{ik})^2 x_j(k)}{\sum_{k=1}^N (u_{ik})^2} \quad (14)$$

$$\theta_{j2}^i = \sqrt{\frac{\sum_{k=1}^N (u_{ik})^2 (x_j(k) - \theta_{j1}^i)^2}{\sum_{k=1}^N (u_{ik})^2}} \quad (15)$$

이 때 θ_{j1}^i 와 θ_{j2}^i 는 각각 소속 함수의 평균과 표준 편차를 나타낸다.

III. 실험

본 장에서는, 제안된 알고리즘의 타당성을 검증하기 위해 두 개의 예제를 사용하여 모의실험을 수행 한다. 본 논문에서 사용한 예제는 다른 알고리즘들과의 비교를 위해 참고문헌^[2]에서 사용한 예제를 사용한다. 각 예제별로 201개의 학습데이터를 사용하며 다른 알고리즘과 비교를 위하여 RMSE를 사용한다. RMSE는 다음과 같이 정의된다.

$$RMSE = \sqrt{\frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{N}} \quad (16)$$

위 식에서 N 은 학습데이터의 개수이고, y_j 는 실제 출력이며 \hat{y}_j 는 j 번째 학습 패턴에 대한 TSK 퍼지 모델의 예측된 출력 값이다.

다른 알고리즘에 대한 비교를 위해 FCRM, RFRA와 SONFIN 등 세 개의 퍼지 모델 알고리즘을 이용한다.

알고리즘을 검증하기 위한 첫 번째 함수는 다음과 같이 정의된다.

$$y = \begin{cases} x, & 0 \leq x \leq 3 \\ 7.5 - 1.5x, & 3 < x < 5 \end{cases} \quad (17)$$

먼저 위 식으로부터 201개의 학습데이터를 발생시키고 [2]의 아웃라이어 모델링을 위해 총오차 모델을 사용하여 다음과 같이 정의한다.

$$F = (1 - \epsilon)G + \epsilon H \quad (18)$$

위 식에서 F 는 더해진 노이즈 분포를 나타내며 G 와 H 는 각각 확률 $1 - \epsilon$ 과 ϵ 를 갖는 확률분포이다. 이 예제에서는 총오차 모델을 구함에 있어 $\epsilon = 0.05$, $G \sim N(0, 0.05)$, $H \sim N(0, 0.5)$ 를 사용한다.

예제 1에 대해 제안된 알고리즘에서 사용하는 클러스터의 개수는 2로 정의한다.

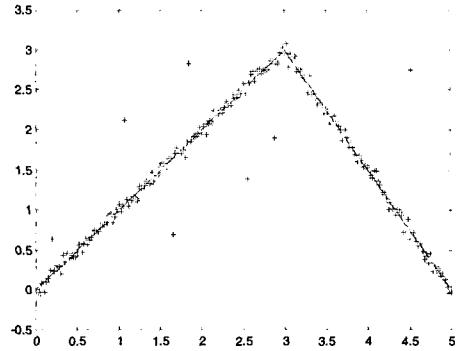


그림 1. (16)에 의해 발생된 학습데이터

Fig. 1. Training data generated by (16).

총 오차 모델("+"와 실제 함수("-")

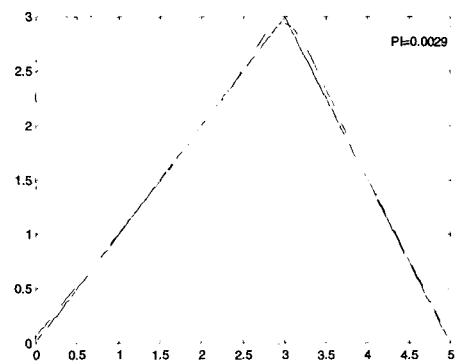


그림 2. 첫 번째 예제에 제안된 알고리즘을 사용한 모의실험 결과

Fig. 2. Simulation result using the proposed algorithm for example 1.

표 1. 첫 번째 예제에 대한 다른 알고리즘의 성능 비교

Table 1. Comparison of performance with other algorithms for example 1.

| Example 1 | |
|-------------------------------------|--------|
| Algorithm | RMSE |
| RFRA with robust learning algorithm | 0.0272 |
| SONFIN with BP algorithm | 0.0515 |
| FCRM with BP learning algorithm | 0.0607 |
| The proposed algorithm | 0.0029 |

그림 1은 식(17)을 이용한 모의시험에 사용된 학습데이터를 나타내며, 그림 2는 알고리즘을 수행한 후의 결과를 각각 나타낸다.

두 번째 검증에 사용할 함수는 식 (19)와 같이 정의된다.

$$y = x^{2/3}, \quad -2 \leq x \leq 2 \quad (19)$$

이 예제에서 또한 201 개의 입출력 데이터가 트레이

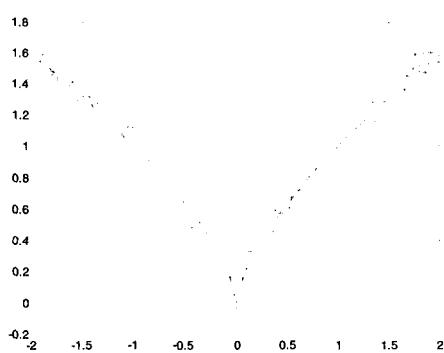


그림 3. (17)에 의해 발생된 학습데이터

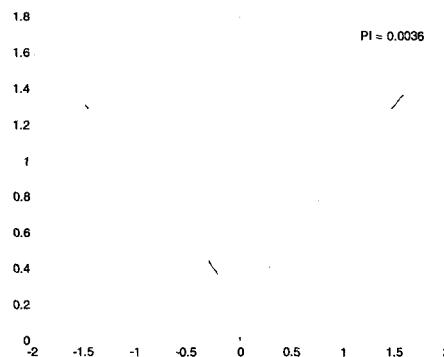
Fig. 3. Training data generated by (17).
총 오차 모델("+)과 실제 함수("-")

그림 4. 두 번째 예제에 제안된 알고리즘을 사용한 모의실험 결과

Fig. 4. Simulation result using the proposed algorithm for example 2.

표 2. 두 번째 예제에 대한 다른 알고리즘의 성능 비교

Table 2. Comparison of performance with other algorithms for example 2.

| Example 2 | |
|-------------------------------------|--------|
| Algorithm | RMSE |
| RFRA with robust learning algorithm | 0.0662 |
| SONFIN with BP algorithm | 0.0814 |
| FCRM with BP learning algorithm | 0.0844 |
| The proposed algorithm | 0.0036 |

는 데이터로 사용된다. 사용될 총오차모델은 식(18)과 같으며 $H \sim N(0, 0.1)$ 를 제외하고는 첫 번째 예제에서와 같은 값을 사용하여 구하며, 클러스터의 개수는 2로 선택한다.

그림 3과 그림 4는 식(19)를 이용한 모의실험에 사용된 데이터와 모의실험 결과를 각각 나타낸다.

제안된 알고리즘과 기존의 다른 알고리즘의 비교를 위한 RMSE가 예제 1에 대해서는 표1과 같이, 예제 2

에 대해서는 표 2와 같이 주어진다.

본 논문에서 사용된 FCRM, RFRA과 SONFIN 알고리즘에 대한 결과는 FCRM의 경우 클러스터 개수를 2로 정의하였으며, RFRA의 경우는 최대 클러스터의 개수를 40으로 설정하고, SONFIN의 경우는 퍼지 규칙의 개수를 첫 번째 예제의 경우에는 3, 두 번째 예제의 경우에는 5가 되었다. 그 밖에 유사기준, 출력기준 등의 다른 실험 환경 변수는 [2]에서와 같이 설정하였다. 제안된 알고리즘의 경우에는 노이즈 거리 δ 를 0.1로 정의하고, 종료 기준은 0.001로 정의하였다.

첫 번째 예제에서 사용한 데이터는 그림 1에서 보듯이 노이즈와 아웃라이어가 동시에 존재하고 두 번째 예제에서 사용한 데이터는 그림 3에서와 같이 노이즈가 심하고 비선형의 성격을 지닌 경우의 데이터이다. 그림 2와 4를 통해서 볼 때 제안된 알고리즘은 아웃라이어와 노이즈가 동시에 존재하는 데이터와 심한 노이즈가 존재하고 비선형성이 있는 데이터에 대해서도 실제 함수를 잘 근사화 하고 있음을 알 수 있다. 표 1과 표 2는 두 개의 예제를 통한 FCRM, RFRA, SONFIN 알고리즘과 새로운 모델링 알고리즘에 대한 모의 실험 결과를 보여준다. 표 1과 2를 통해 살펴보면 FCRM과 SONFIN은 아웃라이어가 존재할 때 만족할 만한 결과를 얻지 못함을 알 수 있다. RFRA 알고리즘은 아웃라이어가 존재할 때 만족할 만한 성능을 보이기는 하지만 본 논문에서 제안한 알고리즘에 비해 만족도가 큰 결과를 얻지 못하고 있다. 특히 두 번째 예제에서와 같이 데이터가 비선형성을 가지며 심한 노이즈를 포함할 경우에는 제안된 알고리즘이 노이즈의 효과를 크게 감소시키는 것을 알 수 있다. 이는 FCRM과 SONFIN은 노이즈나 아웃라이어 효과를 감소시킬 수 있는 능력을 보유하지 못하여 모델을 얻은 후 매개 변수에 대한 적응을 수행 하더라도 아웃라이어에 영향을 많이 받기 때문이고, RFRA의 경우는 아웃라이어에 대한 효과를 감소함수를 사용하여 감소시키지만 그 영향이 아직 남아 있기 때문이다. 제안된 알고리즘은 노이즈 또는 아웃라이어의 효과를 감소함수에 의해 감소시키는 대신에 아웃라이어를 따로 클러스터링함으로써 아웃라이어 또는 노이즈가 순수한 데이터에 영향을 줄 수 없게 하고 후건부의 매개변수를 얻기 위한 절차 수행 중 적응과정을 거치기 때문에 더 나은 성능을 보일 수 있다.

IV. 결 론

본 논문에서는 데이터에 노이즈나 아웃라이어가 존재할 때 노이즈 또는 아웃라이어의 영향을 감소시키면서 함수를 근사화할 수 있는 새로운 강인한 TSK 퍼지 모델링 알고리즘을 제안하였다. 새로운 강인한 퍼지 모델링 알고리즘은 퍼지 리그레션과 노이즈 클러스터링 개념을 바탕으로 새로운 가격함수를 정의하고 이를 기반으로 하여 전건부와 후건부의 매개변수를 구하는 알고리즘이다. 노이즈와 아웃라이어를 순수데이터와 따로 하나의 클래스로 클러스터링 함으로써 노이즈와 아웃라이어에 의한 영향을 줄이고, 알고리즘 수행을 위한 절차를 개선함으로써 전건부와 후건부의 매개변수를 동시에 얻을 수 있게 하였다.

기존 연구에서는 감소함수를 이용하여 노이즈나 아웃라이어의 영향을 줄이거나, 전건부를 먼저 구하고 후건부를 구한 후 다시 매개 변수를 적응시키는 방법을 사용하여 노이즈나 아웃라이어가 포함된 데이터에 대하여 모델링 하고자 시도 하였다. 후자의 경우에는 심한 노이즈나 아웃라이어에 대해 성능이 좋지 않았으며 전자의 경우는 노이즈나 아웃라이어에 대한 영향은 줄일 수 있었으나 여전히 영향을 받을 수밖에 없었고 이 역시 좋은 성능을 얻기 위해서는 얻어진 매개 변수에 대하여 적응을 시켜야만 했다. 제안된 알고리즘은 부수적으로 매개변수 획득 과정 중에 적응효과를 얻을 수 있어서 매개 변수 획득 후 별도의 적응 과정이 필요하지 않게 되었다.

본 연구에서는 강인한 TSK 퍼지 시스템을 모델링 하는 새로운 알고리즘을 제안하고, 여러 가지 다른 알고리즘과 비교함으로써 그 유용성을 기술하였다. 제안된 알고리즘은 구현하기 매우 용이하며 주어진 시스템을 기술하는 능력이 탁월하다. 하지만 시스템이 고차원이고 심한 비선형성을 가지고 있을 경우에는 다른 알고리즘의 경우와 같이 근사화 능력이 현저히 감소하거나 퍼지 규칙의 수가 급격히 증가하므로 이를 보완하기 위한 방법에 대한 연구가 필요하다. 추후 연구로는 퍼지 규칙의 수를 줄이면서 고차원의 비선형 시스템을 기술할 수 있게 하는 연구가 필요하다.

참 고 문 헌

- [1] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control," *IEEE Trans. Syst., Man, Cybern.*, vol. 15, pp. 116-132, 1985.
- [2] C. C. Chuang, S.-F. Su, and S.-S. Chen, "Robust TSK Fuzzy Modeling for Function Approximation With Outliers," *IEEE Trans. Fuzzy Systems*, vol. 9, no. 6, pp. 810-821, 2001.
- [3] R. N. Dave and R. Krishnapuram, "Robust Clustering Methods: A Unified View," *IEEE Trans. Fuzzy Systems*, vol. 5, no. 2, pp. 270-293, 1997.
- [4] Euntai Kim Minkee Park, Seunghwan Ji, Mignon Park, "A New Approach to Fuzzy Modeling," *IEEE Trans. Fuzzy Systems*, vol. 5, no. 3, pp. 328-337, 1997.
- [5] R. N. Dave and Sumit Sen, "Robust Fuzzy Clustering of Relational Data," *IEEE Trans. Fuzzy Systems*, vol. 10, no. 6, pp. 713-727, 2002.
- [6] R. N. Dave, "Characterization and detection of noise in clustering," *Pattern Recognition Lett.*, vol. 12, no. 11, pp. 657-664, 1991.
- [7] R.N. Dave, "Robust Fuzzy clustering algorithms," in 2nd IEEE int. conf. Fuzzy Syst., San Francisco, CA, Mar. 28-Apr.1, 1993, pp. 1281-1286.
- [8] H. Frigui and R. Krishnapuram, "A Robust Competitive Clustering Algorithm with Application in Computer Vision," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 21, no. 5, pp. 450-465, 1999.
- [9] C. F. Juang and C. T. Lin, "An on-line self-constructing neural fuzzy inference network and its applications," *IEEE Trans. Fuzzy Syst.*, vol. 6, pp. 12-32, 1998.
- [10] M. Figueiredo, R. Ballini, S. Soares, M. Andrade, F. Gomide, "Learning Algorithms for a Class of Neurofuzzy Network and Application," *IEEE Trans. Systems, Men and Cybernetics*, Part C, vol. 34, no. 3, pp. 293-301, 2004.
- [11] J. Gozalez, H. Rojas, J. Ortega, A. Prieto, "A new clustering technique for function approximation," *IEEE Trans. Neural Networks*, vol. 13, no. 1, pp. 132-142, 2002.

저 자 소 개



김 경 중(정회원)
1993년 공군사관학교 전산과학과
졸업(이학사)
1999년 연세대학교 전자공학과
석사과정 졸업(공학석사)
2002년 ~ 현재 연세대학교
전기전자공학과 박사과정

<주관심분야: Artificial intelligence, intelligent control, soft computing >

김 은 태(종신회원)
전자공학회논문지
제 41권 CI편 제 6호 참조

박 민 용(종신회원)
전자공학회논문지
제 41권 CI편 제 4호 참조

