

온라인 진화형 TSK 퍼지 식별

Online Evolving TSK fuzzy identification

김경중 · 박창우* · 김은태 · 박민용

Kyoungjung Kim, Chang-Woo Park*, Euntai Kim and Mignon Park

연세대학교 전기전자공학과

*전자부품연구원 정밀기기연구센터

요 약

본 논문에서는 TSK 퍼지 모델을 위한 온라인 식별 알고리즘을 제안한다. 제안된 알고리즘은 거리를 이용하여 TSK 퍼지 모델에 대한 전건부의 구조를 식별하고, 재귀적 최소자승법으로 후건부를 구성하는 부분 선형 함수들의 매개 변수를 구한다. 대부분의 다른 연구들에서는 전건부의 구조를 구하기 위해서 클러스터링을 수행할 때 입력 공간에서만 고려하였으나, 제안된 알고리즘에서는 입력 공간 및 출력 공간 모두에서 고려하여, 아웃라이어 효과를 효과적으로 배제할 수 있다. 기존의 대부분의 다른 알고리즘에서 샘플 데이터 자체를 클러스터의 중심으로 사용하여 잡음에 민감한 단점이 있었으나, 제안된 알고리즘에서는 데이터 자체를 클러스터의 중심으로 사용하지 않아 잡음에 대해 민감하지 않다. 제안된 알고리즘은 많은 데이터의 저장을 필요로 하지 않고, 한 번 통과함으로써 모델을 구할 수 있다.

Abstract

This paper presents online identification algorithm for TSK fuzzy model. The proposed algorithm identify structure of premise part by using distance, and obtain the parameters of the piecewise linear function consisting consequent part by using recursive least square. Only input space was considered in Most researches on structure identification, but input and output space is considered in the proposed algorithm. By doing so, outliers are excluded in clustering effectively. The existing other algorithm has disadvantage that it is sensitive to noise by using data itself as cluster centers. The proposed algorithm is non-sensitive to noise not by using data itself as cluster centers. Model can be obtained through one pass and it is not needed to memorize many data in the proposed algorithm.

Key Words : online, evolving, fuzzy identification, self-organizing

1. 서 론

TSK 퍼지 시스템은 다양한 응용분야에서 사용되어져 왔다. 최근에는 비선형 다이내믹 시스템에 대한 TSK 퍼지 모델을 기반으로 하는 시스템 식별에 관한 많은 연구들이 수행되고 있다. 시스템 식별은 대체로 두 개의 군으로 구분할 수 있다. 하나는 오프라인 식별 [12],[21], [22]이고 또 하나는 온라인 식별 [1-5],[7],[9-11],[13],[15], [20]로 나눌 수 있다. 오프라인 식별은 훈련 과정 수행 전에 모든 데이터가 사용가능하다는 것을 가정한다. 온라인 식별은 훈련 과정 시작 전에 데이터의 수집을 필요로 하지 않으며, 실시간으로 훈련과정을 수행할 수 있다. 온라인 식별은 모델의 구조를 식별하는 것과 매개변수를 식별하는 것으로 나눌 수 있다. 모델의 구조를 식별하기 위해 많은 연구들이 이루어져 왔지만 가장 많이 이용되고 있는 것이 클러스터링 방법이다. 클러스터링 방법에서 퍼지 규칙을 갱신하기 위한 방법으로 다양한 측정 방법이 이용되고 있다. 어떤 규칙의 중심으로부터의 거리, 새로운 데이터 샘플의 포텐셜, 또는 전 단계에서의 오차 등이 퍼

지 규칙을 갱신하는 메커니즘으로 사용된다. 퍼지 규칙을 갱신하기 위한 방법으로 오차를 사용하는 알고리즘에는 self-organizing fuzzy neural network (SOFNN) [1], self-constructing fuzzy neural network (SCFNN) [5], dynamic fuzzy neural network (D-FNN) [9],[10], general dynamic fuzzy neural network (GD-FNN) [8] 등이 있으며, 갱신을 위한 방법으로 거리를 사용하는 알고리즘에는 dynamic evolving neural-fuzzy inference system (DENFIS) [3], self-constructing neural fuzzy inference network (SONFIN) [4] 등이 있으며, 또한 포텐셜을 이용하는 알고리즘에는 evolving Takagi-Sugeno model (ETS) [2] 등이 있다. 그 밖의 방법으로는 두 소속 함수 벡터 간의 퍼지 차를 이용하는 evolving fuzzy neural networks (EFuNNs) [15],[20], kohonen's feature-maps를 이용하는 neural fuzzy control network (NFCN) [7], ART 개념을 이용하는 neuro-fuzzy ART-based structure and parameter learning TSK model (NeuroFAST) [11], 개선된 마운틴 클러스터링을 이용하는 generalized adaptive neuro-fuzzy inference systems (GANFIS) [13] 등이 있다. 또한 퍼리미터를 학습하기 위한 방법으로는 recursive least square (RLS) [2],[4],[9,10], weighted recursive least square (wRLS) [2] 등이 주로 쓰이며, 특이값분해(SVD) [6], δ 룰을

접수일자 : 2004년 1월 17일
완료일자 : 2005년 3월 14일

이용하는 방법 [11] 등도 사용되고 있다.

온라인 식별에서는 모델 구조의 구성이 매우 중요하다. 대부분의 연구가 모델의 구조를 구성하는 방법을 위주로 이루어지고 있으며, 퍼지 규칙의 수를 줄이고 실시간으로 모델을 생성할 수 있는 알고리즘을 개발하기 위해 클러스터링 방법을 채택하고 이에 따른 연구를 수행하고 있다. 따라서, 온라인 클러스터링이 온라인 식별의 주요 과정이라 볼 수 있다.

본 논문에서는 새로운 온라인 구조식별 알고리즘을 제안한다. 구조식별에서는 전건부의 퍼지 소속 함수를 구한다. 퍼지 소속 함수가 가우스 함수 형태를 갖는다고 가정하면, 이 가우스 함수의 중심점과 표준편차를 구조식별을 통해 구한다. 일반적으로, 클러스터링을 수행할 때 입력공간만을 고려한다. 하지만, 시스템의 출력 또한 시스템의 입력만큼 중요한 정보를 포함하고 있기 때문에, 본 논문에서는 입력 공간 및 출력 공간에 대해 동시에 고려하여, 아웃라이어에 강인한 성능을 보이도록 하였다. 또한 하나의 데이터를 중심점으로 지정할 경우에는 노이즈에 민감한 성능을 보이게 되는데, 이를 극복하기 위해 중심과 최대거리에 비례해 클러스터의 중심을 갱신한다.

후건부의 매개변수를 학습하기 위한 방법으로는 RLS[2],[4],[9],[10]를 사용하며, 이를 이용하여 재귀적으로 매개변수를 구한다. 이는 많은 양의 데이터를 저장하지 않고 실시간으로 매개변수를 구하기 위함이다.

2. TSK 퍼지모델 및 식별 알고리즘

TSK 퍼지 모델은 퍼지 전건부와 부분 선형 함수의 결합으로 이루어진 후건부로 이루어져 있으며, 다음과 같은 형태를 이룬다.

$$R^i: \text{If } x_1 \text{ is } A_1^i \text{ and } x_2 \text{ is } A_2^i, \dots, x_n \text{ is } A_n^i \\ \text{then } h^i = f_i(x_1, x_2, \dots, x_n; \vec{b}^i) = b_0^i + b_1^i x_1 + \dots + b_n^i x_n; \\ i = 1, 2, \dots, r \quad (1)$$

위 식에서 R^i 는 i 번째 퍼지 규칙을 나타내고, x_i 는 입력 변수, h^i 는 출력, r 는 퍼지 규칙의 수를 나타낸다.

퍼지 모델의 예상 출력은 다음과 같이 추론된다.

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

이 때 h^i 는 i 번째 규칙의 출력이고, w^i 는 i 번째 규칙의 가중치이며, 다음과 같은 퍼지 소속 함수의 최소 값으로 얻어진다.

$$A_j^i(C_{ij}, \sigma_{ij}) = \exp\left\{-\frac{(x_j - C_{ij})^2}{2\sigma_{ij}^2}\right\} \quad (3)$$

식별은 전건부의 구조식별과 후건부의 매개변수를 결정하는 두 가지로 나눌 수 있다. 구조식별은 식(1)에서 전건부 퍼지 함수의 개수 즉, r 의 값을 결정하고 퍼지 함수의 값을 결정한다. 퍼지 함수, A_j^i 가 가우스 함수의 형태를 가진다고 가정하면, 가우스 함수의 중심 값과 표준편차를 구한다. 여기에서는 중심점과 들어오는 데이터간의 거리를 이용하여 구조를 식별하고, RLS를 이용하여 매개변수를 구하는 방법을 제안한다.

2.1 클러스터링을 이용한 구조식별 알고리즘

구조식별은 입력 데이터 공간과 출력 데이터 공간을 클러스터링 하고, 그 중심점을 결정함으로써 이루어진다. 퍼지 소속 함수가 식(3)에서처럼 가우스 함수의 형태를 갖는다고 하면, 하나의 클러스터에 속하는 입력 값들과 클러스터 중심과의 거리를 이용하여 가우스 함수의 중심, C_{ij} 과 폭, σ_{ij} 을 결정한다.

들어오는 샘플데이터와 현존하는 클러스터간의 입력공간과 출력 공간에서의 거리를 구하면 다음과 같다.

$$d_{ij}^{\text{in}} = |x_i - C_{ij}^x|, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, m \quad (4)$$

$$d_{ij}^{\text{out}} = |y_i - C_{ij}^y|, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, m \quad (5)$$

이 때 x_i 는 입력데이터를, y_i 는 출력 데이터를 각각 나타내며, d_{ij}^{in} , d_{ij}^{out} 는 각각 j 번째 클러스터의 중심과 i 번째 데이터의 입력 공간과 출력 공간에서의 거리를 나타내고, n 은 데이터의 개수, m 은 클러스터의 개수를 각각 나타낸다. 또한 C_{ij}^x , C_{ij}^y 는 입력 공간과 출력 공간에서의 중심을 각각 나타낸다.

\bar{d}^{in} , \bar{d}^{out} 을 각각 입력 공간과 출력 공간에서의 미리 정해진 상한치라 하고, m 을 클러스터의 개수, $MAXD_j$ 를 j 번째 클러스터에서 이 클러스터에 속해있는 어떤 데이터 점과의 최대 거리라 한다. \bar{d}^{in} , \bar{d}^{out} 은 시스템의 입력과 출력에 관한 사전 지식을 이용하여 정한다.

제안된 구조식별 알고리즘을 기술하면 다음과 같다.

1) 새로운 클러스터를 발생시키고, 처음으로 들어오는 데이터의 위치를 클러스터 중심의 위치로 하고, 첫 번째 소속 함수의 폭을 작은 임의의 값으로 초기화 한다.

$$C_1 = [x_1, y_1], \quad \sigma_1 = \sigma_0$$

중심으로부터의 최장거리를 0으로 초기화 한다.

2) k 번째 데이터가 들어오면 들어오는 데이터와 현재 존재하는 모든 클러스터의 중심과의 거리를 입력 공간과 출력 공간에서 각각 구하고, 입력 공간에서의 최단거리를 찾는다.

3) 입력 공간에서의 최소거리가 정해진 상한치보다 크고 최소거리를 갖는 클러스터와 데이터 간의 출력 공간에서의 거리가 출력 공간에서의 상한치 보다 클 경우에는 들어오는 데이터를 아웃라이어로 간주하고, 현재의 클러스터의 중심 위치와 폭, 클러스터의 개수를 현재와 같이 유지한다. 입력 공간에서의 최소 거리가 입력 공간의 상한치보다 크고, 해당 클러스터와의 출력 공간에서의 거리가 출력 공간의 상한치 보다 작을 경우에는 클러스터의 개수를 증가 시키고, 새로운 클러스터를 생성한다. 입력 공간에서의 최소 거리가 상한치 보다 작고, 이에 따른 출력 공간에서의 거리가 상한치 보다 크면 이 때도 들어오는 데이터는 아웃라이어로 간주되고, 중심 위치, 폭, 클러스터의 개수 등이 그대로 유지된다. 최소 거리가 상한치보다 작고, 출력 공간에서 이에 따른 클러스터와 데이터 간의 거리가 상한치보다 작을 경우에는 데이터가 클러스터 j 에 속하는 것으로 간주되고, 클러스터의 중심과 폭을 갱신한다. 이 경우에는 클러스터의 개수는 그대로 유지한다.

$$\text{Case 1: } \min(d_{ij}^{\text{in}}) > \bar{d}^{\text{in}} \text{ and } d_{ij}^{\text{out}} > \bar{d}^{\text{out}}$$

$$C_j = C_i, \sigma_j = \sigma_i, m(t+1) = m(t) \quad (6)$$

Case 2: $\min(d_{ij}^{\text{in}}) > \bar{d}^{\text{in}}$ and $d_{ij}^{\text{out}} \leq \bar{d}^{\text{out}}$

$$C_j = x_k, \sigma_j = \sigma_0, m(t+1) = m(t) + 1 \quad (7)$$

Case 3: $\min(d_{ij}^{\text{in}}) \leq \bar{d}^{\text{in}}$ and $d_{ij}^{\text{out}} > \bar{d}^{\text{out}}$

$$C_j = C_i, \sigma_j = \sigma_i, m(t+1) = m(t)$$

Case 4: $\min(d_{ij}^{\text{in}}) \leq \bar{d}^{\text{in}}$ and $d_{ij}^{\text{out}} \leq \bar{d}^{\text{out}}$

$MAXD_i \geq d_{ij}^{\text{in}}$ 일 경우 다음 식에 의해 중심점의 위치와 폭을 갱신한다.

$$C_j(t+1) = C_j(t) + \alpha(MAXD_j - d_{ij}^{\text{in}}) \quad (8)$$

$$MAXD_i = d_{ij}^{\text{in}} \quad (9)$$

이 때 α 는 중심점을 갱신하기 위한 갱신 비율을 나타낸다.

$MAXD_i \geq d_{ij}^{\text{in}}$ 일 경우 중심 위치, 폭, 최대 거리를 현재대로 유지한다.

클러스터에 속하는 각 데이터와 클러스터 중심 간의 거리의 제곱 이용하여 함수의 폭을 결정한다.

$$S_j(t+1) = S_j(t) + d_{ij}^2 \quad (10)$$

$$\sigma_j^2 = \frac{S_j}{g_j}, \quad (11)$$

이 때 g_j 는 어떤 클러스터 j 에 속하는 데이터의 개수를 나타낸다.

2.2 후건부 매개변수 학습

본 논문에서는 후건부의 선형 함수의 매개변수를 추정하기 위해서 least-square estimator (LSE) 을 사용한다. 각각의 선형 함수는 다음과 같이 표현 할 수 있다.

$$y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_q x_q \quad (12)$$

학습을 위한 가격함수는 다음과 같이 정의된다.

$$J_G = \sum_{k=1}^N [y(k) - \hat{y}(k)]^2 \quad (13)$$

이 때 $y(k)$ 는 실제 시스템의 출력, $\hat{y}(k)$ 은 식별된 모델의 출력이며 N 은 식별에 사용할 데이터의 개수 이다.

가격함수를 행렬 형태로 다시 정렬 하면 다음과 같이 나타낼 수 있다.

$$J_G = (y - Xb)^T (y - Xb) \quad (14)$$

이 때 $b = [b_0 b_1 \dots b_q]^T$ 이고,

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1q} \\ 1 & x_{21} & x_{22} & \dots & x_{2q} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{p1} & x_{p2} & \dots & x_{pq} \end{pmatrix},$$

$$y = [y_1 y_2 \dots y_p]^T$$

식(14)의 가격함수로부터 다음과 같이 매개변수를 구하는 식을 유도할 수 있다.

$$b = (X^T X)^{-1} X^T y \quad (15)$$

위 식을 다시 정리하면 다음과 같이 나타낼 수 있다.

$$P = (X^T X)^{-1} \quad (16)$$

$$b = PX^T y \quad (17)$$

행렬 X 의 k 번째 행벡터를 $x_k = [1 x_{k1} x_{k2} \dots x_{kq}]$ 라 하고, y 의 k 번째 요소를 y_k 라 하면, b 는 다음과 같이 재귀적으로 계산될 수 있다 [2],[4],[9],[10].

$$b_{k+1} = b_k + P_{k+1} x_{k+1} (y_{k+1} - x_{k+1}^T b_k) \quad (18)$$

$$P_{k+1} = \frac{P_k - P_k x_{k+1} x_{k+1}^T P_k}{1 + x_{k+1}^T P_k x_{k+1}}, k = n, n+1, \dots, p-1 \quad (19)$$

P 와 b 의 초기치는 중심점과 이 중심점에 속하는 첫 번째 데이터에 대해 식 (16)과 (17)을 이용하여 구한다.

3. 온라인 학습 절차

제안된 알고리즘의 전체적인 온라인 학습 절차를 기술하면 다음과 같다.

1 단계) 입력 공간 및 출력 공간에서의 상한치 \bar{d}^{in} , \bar{d}^{out} , 중심의 갱신 비율 α 및 학습을 위한 가격함수의 기준을 설정한다.

2 단계) 첫 번째 데이터 샘플을 첫 번째 클러스터의 중심으로 하고, 폭 σ 은 임의의 작은 값으로 설정한다.

3 단계) k 번째 데이터가 들어왔을 때, 입력 공간에서의 기존의 클러스터와의 거리를 계산하고 가장 가까운 클러스터와의 거리가 상한치보다 크면 새로운 클러스터를 생성하고, 식 (6)과 같이 새로운 클러스터의 중심으로 한다.

4 단계) 입력 공간에서의 거리가 상한치보다 작을 경우 식 (8)-(11)을 이용하여 클러스터의 중심을 갱신하고 폭을 결정한다.

5 단계) 식 (18)과 식 (19)를 이용하여 재귀적인 방법으로 후건부의 매개변수를 구한다.

6 단계) 다음 샘플 데이터가 없으면 알고리즘의 수행을 멈춘다.

위와 같은 절차를 수행함으로써 온라인상에서 아웃라이어와 노이즈에 영향을 적게 받는 모델을 구할 수 있다. 또한 데이터를 저장하지 않고 모델의 구조를 구한 다음 중심과 폭의 매개변수를 다시 적용하는 과정이 없어 빠른 응답 성능을 보일 수 있다.

4. 모의실험

본 장에서는 제안된 알고리즘을 검증하기 위하여 [2],[3]에

서 사용한 퍼지 시스템 및 신경망 분야에서 표준 예제로 사용하는 Mackey Glass (MG) 데이터틀 이용하여 실험한다. 실험에서 사용할 시연속 데이터는 다음과 같은 MG 시간 지연 미분 방정식을 이용하여 생성된다.

$$\frac{dx(t)}{dt} = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (20)$$

본 실험에서는 $\tau=17$ 로 설정하고, $x(0)=1.2$, $x(t)=0$ for $t<0$ 으로 가정하였을 때 얻어진 데이터틀 사용하였다. $t=5001$ 에서 $t=5500$ 까지의 500개의 데이터 샘플을 사용하여 실험하였다.

MG 시연속 데이터틀 이용하여 실험을 함에 있어, 4개의 입력 변수 $[x(t), x(t-6), x(t-12), x(t-18)]$ 을 입력 벡터로 하고 $x(t+6)$ 을 출력 벡터로 갖는다.

본 실험에서는 6 시 간격에 위치한 4개의 점으로부터 $x(t+6)$ 를 추정한다.

알고리즘의 성능 평가를 위한 성능지표로는 RMSE(root mean square error)를 사용한다.

$$SE = \frac{\sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2}}{N} \quad (21)$$

여기에서 N 은 샘플 데이터의 개수이다.

실험에서 사용한 제안된 알고리즘의 클러스터 중심의 갱신 비율 α 은 0.5로 설정하였다.

그림 1은 위 식 (20)을 사용하여 얻은 순수한 데이터에 대해서 시험한 결과를 보여준다. 이 때 입력 공간에서의 상한치를 0.2, 출력 공간에서의 상한치를 0.8로 설정하였으며, 알고리즘의 실행을 통하여 퍼지 규칙의 수는 100개가 생성된다. 그림에서 실선은 실제 데이터의 분포를 나타내며, 점선은 제안된 알고리즘을 수행하여 예측한 결과 값을 나타낸다. 그림에서 보듯이 제안된 알고리즘에 의한 예측치가 실제 데이터 값을 잘 추종함을 알 수 있다.




그림 1. 제안된 알고리즘에 의한 식별 결과
Fig. 1 Identification result of the proposed algorithm
(실제값, · 추정 결과)

그림 1에서 적용한 데이터에 대하여 추출된 퍼지 규칙은 다음과 같이 나타난다.

if x_1 is about 0.658 and x_2 is about 0.883 and x_3 is 0.817 and x_4 is 0.743
then $y = 0.37x_1 + 0.05x_2 + 0.172x_3 + 0.13x_4 - 0.073$
...

표 1은 입력 공간에서의 상한치를 변경 하였을 때의 RMSE를 나타낸다. 출력 공간에서의 상한치는 같은 값으로 설정하였다.

표 1. 상한치 변경에 따른 식별 결과
Table 1. Identification result according to variation of upper bounds

상한치(입력공간)	퍼지규칙의 수	RMSE
0.2	100	0.0014
0.25	72	0.0025
0.3	50	0.0044
0.4	39	0.0061

표 1에서 알 수 있듯이 입력 공간에서의 상한치에 따라 퍼지 규칙의 수가 변화하며, RMSE 또한 퍼지 규칙의 수가 많아지면 감소하는 것을 알 수 있다. 퍼지 규칙의 수가 현저히 줄어도 제안된 알고리즘을 수행한 결과는 만족할 만하다고 볼 수 있다.

다음으로 데이터에 노이즈가 포함되었을 때도 제안된 알고리즘을 이용하여 함수 값을 잘 예측할 수 있는 지에 대한 실험을 수행 한다.

실험에 필요한 데이터를 얻기 위하여 식 (20)에 의해 얻어진 데이터에 다음과 같은 오차모델에 의해 얻어진 노이즈를 포함 시킨다.

$$F = (1-\epsilon)G + \epsilon H \quad (22)$$

위 식에서 F 는 더해진 노이즈 분포를 나타내며 G 와 H 는 각각 확률 $1-\epsilon$ 과 ϵ 를 갖는 확률분포이다. 총오차 모델을 구함에 있어 $\epsilon=0.05$ 를 사용하였다.

그림 2는 노이즈를 포함한 데이터와 실제 값을 보여준다. 이 때 $G \sim N(0, 0.05)$, $H \sim N(0, 0.5)$ 를 사용한다.




그림 2. 실제 값과 노이즈를 포함한 데이터
Fig. 2. Real values and data including noise
(- 실제 데이터, · 노이즈 데이터)

그림 3은 $G \sim N(0, 0.05)$, $H \sim N(0, 0.5)$ 일 때의 노이즈를 포함한 데이터에 대해 제안된 알고리즘을 사용하여 추정한 결과를 나타낸다. 실선 부분이 실제 함수를 나타내며, 점선 부분이 추정한 값을 나타낸다. 이 때의 RMSE는 0.0021 이다.




그림 3. 노이즈 포함된 데이터에 대한 제안된 알고리즘에 의한 추정 결과
 Fig. 3. Identification result of the proposed algorithm on data samples including noise
 (- 실제 데이터, · 추정 결과)

그림 4는 $G \sim N(0, 0.05)$, $H \sim N(0, 0.1)$ 일 때의 실제 데이터와 노이즈를 포함한 데이터를 보여준다.
 그림 4는 그림 3에 비해 노이즈가 심함을 알 수 있다.




그림 4. 심한 노이즈를 포함한 데이터와 실제 데이터
 Fig. 4. Real values and data sample including severe noise
 (- 실제 데이터, · 노이즈를 포함한 데이터)

그림 5는 그림 4의 데이터에 대해 제안된 알고리즘을 사용하여 추정한 결과를 나타낸다.
 다음으로는 다른 온라인 알고리즘이 본 논문에서 제안된 알고리즘을 비교한다. 표 2는 제안된 알고리즘과 다른 알고리즘과의 추정 결과에 대한 비교를 보여준다. 기존의 알고리즘들과의 비교를 위해 [2],[3],[15] 등에서 사용한 $t=5001$ 에서 $t=5500$ 까지의 500개의 데이터를 가지고 실험한 결과를 나타낸다. 표 2에서 사용한 성능 지수는 NDEI (Non-Dimensional Error Index)이다. NDEI는 RMSE를 데이터의 표준 편차로 나눈 값이다.
 표 2를 보면 제안된 알고리즘은 다른 알고리즘에 비해 퍼지 규칙의 수가 작으면서도 시연속 데이터에 대하여 우수한 결과를 보임을 알 수 있다.




그림 5. 노이즈가 심한 데이터에 대한 추정 결과
 Fig. 5. Identification result on data sample including severe noise
 (- 실제 데이터, · 추정 결과)

표 2. 제안된 알고리즘과 다른 알고리즘의 비교
 Table 2. Comparison of the proposed algorithm and other algorithms

Methods	Rules(nodes)	NDEI
DENFIS	58 rules	0.276
eTS model	113 rules	0.0954
EfuNN	1125 nodes	0.094
The proposed algorithm	50 rules	0.0176
The proposed algorithm	72 rules	0.01

이상의 실험에서 알 수 있듯이 제안된 알고리즘은 시연속 데이터에 대하여, 노이즈가 포함된 데이터에 대해서 적용하였을 경우에도 잘 추정하며, 다른 알고리즘에 비해 적은 규칙의 수를 가지고도 우수한 추정 성능을 보인다. 또한 퍼지 규칙의 수가 적음으로 인해 계산 량도 다른 알고리즘에 비해 적으므로 온라인 식별에 적절하다고 볼 수 있다.

5. 결 론

본 논문에서는 온라인상에서 TSK 퍼지 모델의 구조를 스스로 결정하는 알고리즘을 제안하였다. 제안된 알고리즘은 퍼지 규칙의 갱신을 위해 거리를 사용하였으며, 후건부의 매개 변수를 구하기 위해 재귀적 최소 자승법을 사용하였다. 제안된 알고리즘은 입력된 데이터 자체를 클러스터의 중심으로 사용하지 않고, 갱신하는 방법을 제안함으로써 노이즈에 강인한 특성을 지닌다. 또한 클러스터링을 수행함에 있어 입력 공간뿐 아니라 출력 공간도 고려하여 아웃라이어 추정 값에 포함되지 않게 하였다. 소속 함수의 폭을 구함에 있어서도 데이터와 클러스터 중심과의 거리의 제곱을 사용하여 재귀적 방법으로 구함으로써 소속 함수 간에 서로 겹치지 않게 하였다. 후건부의 매개변수는 RLS를 사용하여 재귀적으로 구하여 효과적으로 계산을 할 수 있다. 제안된 알고리즘은 아웃라이어와 노이즈에 강한 특성을 보이므로 노이즈가 포함된 시스템을 식별하는데 효과적인 방법이다. 차후 미지의 시스템에 적용하기 위하여 시스템에 관한 사전 정보를 필요로 하지 않는 방법에 관한 연구를 수행할 예정이며, 정확

모듈 조금 더 높이기 위한 방법을 연구 중이다.

참 고 문 헌

- [1] G. Leng, G. Prasad, T. M. McGinnity, "An on-line algorithm for creating self organizing fuzzy neural networks", *Neural Networks*, vol. 17, issue 10, pp. 1477-1493, December 2004.
- [2] P. P. Angelov, D. P. Filev, "An Approach to Online Identification of Takagi Sugeno Fuzzy Models", *IEEE Trans. System, Man, And Cybernetics part B*, vol. 34, no.1, pp. 484-498, February, 2004.
- [3] N. Kasabov, Q. Song, "DNFIS: Dynamic Evolving Neural Fuzzy Inference System and Its Application for Time Series Prediction", *IEEE Trans. Fuzzy Systems*, vol. 10, no. 2, pp. 144-154, April, 2004.
- [4] C. F. Juang, C.-T. Lin, "An On-line Self Constructing Neural Fuzzy Inference Network and Its Applications", *IEEE Trans. Fuzzy Systems*, vol. 6, no. 1, pp. 12-32, February, 1998.
- [5] F. J. Lin, C. H. Lin, P. H. Shen, "Self-Constructing Fuzzy Neural Network Speed Controller for Permanent-Magnet Synchronous Motor Drive", *IEEE Trans. Fuzzy Systems*, vol. 9, no. 5, pp. 751-759, October, 2001.
- [6] J. Yen, L. Wang, C. W. Gillespie, "Improving the Interpretability of TSK Fuzzy Models by Combining Global Learning and Local learning", *IEEE Trans. Fuzzy Systems*, vol. 6, no. 4, pp. 530-537, November, 1998.
- [7] C. T. Lin, "A neural fuzzy control system with structure and parameter learning", *Fuzzy Sets and Systems*, vol. 70, pp. 183-212, 1995.
- [8] S. Wu, M. J. Er, Y. Gao, "A Fast Approach for Automatic Generation of Fuzzy Rules by Generalized Dynamic Fuzzy Neural Networks", *IEEE Trans. Fuzzy Systems*, vol. 9, no. 4, pp. 578-594, August, 2001.
- [9] M. J. Er, S. Wu, "A fast learning algorithm for parsimonious fuzzy neural systems", *Fuzzy Sets and Systems*, vol. 126, pp. 337-351, 2002.
- [10] S. Wu, M. J. Er, "Dynamic Fuzzy Neural Networks A Novel Approach to Function Approximation" *IEEE Trans. Systems, Man, and Cybernetics Part B*, vol. 30, no. 2, pp. 358-364, April, 2000.
- [11] S. G. Tzafestas, K. C. Zikidis, "NeuroFAST: On line Neuro Fuzzy ART Based Structure and Parameter Learning TSK Model", *IEEE Trans. Systems, Man, and Cybernetics-Part B*, vol. 31, no. 5, pp. 797-802, October, 2001.
- [12] D. Kukulj, E. Levi, "Identification of Complex Systems Based on Neural and Takagi-Sugeno Fuzzy Model" *IEEE Trans. Systems, Man, and Cybernetics-PART B*, vol. 34, no. 1, pp. 272-282, February, 2004.
- [13] M. F. Azeem, M. Hanmandlu, N. Ahmad, "Structure Identification of Generalized Adaptive Neuro-Fuzzy Inference Systems", *IEEE Trans. Fuzzy Systems*, vol. 11, no. 5, pp. 666-681, October, 2003.
- [14] P. X. Liu, M. Q.-H. Meng, "Online Data-Driven Fuzzy Clustering With Applications to Real-Time Robotic Tracking", *IEEE Trans. Fuzzy Systems*, vol. 12, no. 4, pp. 516-523, August, 2004.
- [15] N. Kasabov, "Evolving Fuzzy Neural Networks for Supervised/Unsupervised Online Knowledge-Based Learning", *IEEE Trans. Systems, Man, and Cybernetics-PART B*, vol. 31, no. 6, pp.902-918, December, 2001.
- [16] P. P. Angelov, V. I. Hanby, R. A. Buswell, J. A. Wright, "Automatic generation of fuzzy rule-based models from data by genetic algorithms", in *Advances in Soft Computing*, R. John and R. Birkenhead, Eds. Heidelberg, Germany: Springer-Verlag, 2001, pp. 31-40.
- [17] P. P. Angelov, *Evolving Rule-Based Models: A Tool for Design of Flexible Adaptive Systems*. Heidelberg, Germany: Springer-Verlag, 2002.
- [18] T. Takagi, M. Sugeno, "Fuzzy identification of systems and its applications to modeling and control", *IEEE Trans. Systems, Man, and Cybernetics*, vol. 15, pp. 116-132, 1985.
- [19] L. X. Wang, *A Course in Fuzzy Systems and Control*, Prentice Hall, 1997.
- [20] N. Kasabov, "Evolving fuzzy neural networks - Algorithms, applications, and biological motivation," in *Methodologies for the Conception, Design, and Applications of Soft Computing*, T. Yamakawa and G. Matsumoto, Eds. Singapore: World Scientific, pp. 271-274, 1998.
- [21] K. Kim, Y.-K. Kim, E. Kim and M. Park, "A New Fuzzy Modeling Approach", *Proc. of FUZZ-IEEE 2004*, pp.773-776, July, 2004
- [22] E. Kim, M. Park, S. Ji, M. Park, "A new approach to fuzzy modeling," *IEEE Trans. Fuzzy Systems*, vol. 5, pp. 328-337, Aug. 1997.
- [23] K. Kim, K. M. Kyung, C.-W. Park, E. Kim, M. Park, "Robust TSK Fuzzy Modeling Approach Using Noise Clustering Concept for Function Approximation", *LNCS*, Vol. 3314, pp. 538-543, December, 2004.
- [24] R. Isermann, K.-H. Lachmann, D. Matko, *Adaptive Control Systems*, Prentice Hall, 1992.
- [25] L. Ljung, *System Identification: Theory for the user*, Prentice Hall, 1998.
- [26] G. C. Goodwin, K. S. Sin, *Adaptive Filtering Prediction and Control*, Prentice Hall, 1984.
- [27] S. Haykin, *Adaptive Filter Theory*, Prentice Hall, 1996.

[28] 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.

저 자 소 개



김경중(Kyoungjung Kim)

1993년 : 공군사관학교 전산학과 졸업.
1999년 : 연세대학교 전자공학과 석사 과정 졸업(공학석사)
2002년~현재 연세대학교 전기전자 공학과 박사과정

관심분야 : Artificial intelligence, intelligent control, soft computing, flight control

Phone : 02-2123-2868
Fax : 02-312-2333
E-mail : kjkim@yeics.yonsei.ac.kr



박창우(Chang-Woo Park)

1997년 : 고려대학교 전자공학과 졸업 (공학사).
1999년 : 연세대학교 전자공학과 석사 과정 졸업(공학석사)
2003년 : 연세대학교 전기전자공학과 박사과정 졸업(공학박사)

2003년~현재 전자부품연구원 정밀기기센터 선임연구원

관심분야 : Fuzzy control, robot vision, robotics

Phone : 032-621-2854
Fax : 032-621-2866
E-mail : drcwpark@keti.re.kr



김은태(Euntai Kim)

1992년 : 연세대학교 전자공학과 졸업 (공학사, 전체수석).
1994년 : 연세대학교 전자공학과 석사 과정 졸업(공학석사)
1999년 : 연세대학교 전자공학과 박사 과정 졸업(공학박사)
1999년3월~2002년 2월 국립한경대학교

제어계측공학과 조교수

2002년 3월~현재 연세대학교 전기전자공학부 조교수

2003년 University fo Alberta, visiting researcher

1998년~현재 IEEE TFS, IEEE SMC, IEEE CAS, FSS 등에서 심의위원 활동 중

관심분야 : Computational intelligence, 지능형 로봇
Phone : 02-2123-2863
Fax : 02-312-2333
E-mail : etkim@yonsei.ac.kr



박민용(Mignon Park)

1973년 : 연세대학교 전자공학과 졸업 (공학사).
1977년 : 연세대학교 전자공학과 석사과정 졸업(공학석사)
1982년 : 일본 동경대학 전자공학과 졸업(공학박사)

1982년~현재 연세 대학교 전기전자공학과 교수

관심분야 : 퍼지 이론, 지능제어, 의용공학

Phone : 02-2123-2868
Fax : 02-312-2333
E-mail : mignpark@yonsei.ac.kr