

클러스터 생성을 이용한 자기구성 퍼지 모델링

Self-Organizing Fuzzy Modeling Using Creation of Clusters

고택범

Taek-Beom Koh

경주대학교 컴퓨터전자공학부

요 약

본 논문에서는 상대적으로 큰 퍼지 엔트로피를 갖는 입력-출력 데이터 집단에 다중 회귀 분석을 적용하여 다차원 평면 클러스터를 생성하고, 이 클러스터를 새로운 퍼지 모델의 규칙으로 추가한 후 모델 파라미터의 개략 동조와 정밀 동조를 반복 수행하는 자기구성 퍼지 모델링을 제안한다. Weighted recursive least squared 알고리즘과 fuzzy C-regression model 클러스터링에 의해 퍼지 모델의 파라미터를 개략적으로 동조한 후 gradient descent 알고리즘에 의해 파라미터를 정밀 동조하면서 감수분열 유전 알고리즘을 이용하여 최적의 학습률을 탐색한다. 그리고, 자기구성 퍼지 모델링 기법을 이용하여 Box-Jenkins의 가스르 데이터, 비선형 다변수 정적 함수의 데이터, 하수처리 활성오니 공정과 Mackey-Glass 시계열 데이터의 모델링을 수행하고, 기존의 방법에 의한 모델링 결과와 비교하여 그 성능을 입증한다.

Abstract

This paper proposes a self-organizing fuzzy modeling which can create a new hyperplane-shaped cluster by applying multiple regression to input/output data with relatively large fuzzy entropy, add the new cluster to fuzzy rule base and adjust parameters of the fuzzy model in repetition. In the coarse tuning, weighted recursive least squared algorithm and fuzzy C-regression model clustering are used and in the fine tuning, gradient descent algorithm is used to adjust parameters of the fuzzy model precisely. And learning rates are optimized by utilizing meiosis-genetic algorithm. To check the effectiveness and feasibility of the suggested algorithm, four representative examples for system identification are examined and the performance of the identified fuzzy model is demonstrated in comparison with that of the conventional fuzzy models.

Key Words : 자기구성 퍼지 모델링, 클러스터 생성, 퍼지 엔트로피, 파라미터 동조, 감수분열 유전알고리즘

1. 서 론

시스템 모델링의 근본적인 목적은 물리적인 현상의 특징을 정확하게 표현할 수 있는 모델을 구축하는 것이다. 물리 화학의 기본 원리를 토대로 시스템을 선형 또는 비선형 미분 방정식으로 표현하는 수학적 모델은 모델링 하고자 하는 시스템이 복잡하고 비선형성이 강하거나 물리 화학적인 관계를 명확하게 파악하기 곤란한 경우 시스템의 입력-출력 변수 사이의 관계를 정확하게 기술하기 어렵다. 이러한 문제를 해결하기 위해 인간의 경험지식 또는 실제 시스템의 입력-출력 데이터를 토대로 모델을 구축하는 퍼지 모델, 신경회로망 모델에 관한 연구가 다양한 분야에 걸쳐 수행되어 왔다.

Takagi-Sugeno 퍼지 모델[1]은 주어진 시스템을 모델링 하는 능력이 우수하며, 신경회로망이나 퍼지-뉴럴 네트워크에 비해 정성적으로 이해하기 쉽고, 모델기반 제어에 적합한 장점을 갖고 있으나, 모델의 동조 알고리즘이 복잡하고 수행 시간이 많이 걸려 실제로 적용하는데는 어려움이 따른다. 이를 해결하기 위해 Kim[2]은 다차원 평면 클러스터를 이용하여 모델의 파라미터를 정밀하

게 동조하는 퍼지 모델링 기법을 제시하였다. 하지만, 모델링 오차가 증가되기 전까지 클러스터의 수를 단순하게 증가시키면서 모델의 파라미터 동조과정을 반복하기 때문에 클러스터의 단순 증가에 의해 모델링 오차가 줄어들기 어렵고, 파라미터의 정밀 동조 알고리즘에서 사용되는 학습률의 최적치를 구하여 모델의 성능을 개선할 필요가 있다.

본 논문에서는 Kim 모델의 파라미터 동조와 같이 fuzzy C-regression model(FCRM) 클러스터링[3]과 weighted recursive least squared(WRLS) 알고리즘[4]에 의해 퍼지 모델의 파라미터를 개략적으로 동조하고, gradient descent 알고리즘을 이용하여 파라미터를 정밀하게 동조한다. 동조 결과를 토대로 상대적으로 큰 퍼지 엔트로피의 입출력 데이터 집단에 다중 회귀분석을 적용하여 다차원 평면 클러스터를 구성하고 이를 퍼지 모델의 새로운 규칙으로 추가한 후 모델 파라미터의 동조를 수행하면서 감수분열 유전알고리즘(meiosis-genetic algorithm)[5]을 이용하여 최적의 학습률을 탐색하는 자기구성 퍼지 모델(SOFUM: self-organizing fuzzy model)을 제안한다. 그리고 Box-Jenkins의 가스르 데이터, 다변수 비선형 정적함수의 데이터, 하수처리 활성오니 공정과 Mackey-Glass 시계열 공정 데이터의 모델링에 자기구성 퍼지 모델을 적용한 결과와 기존의 방법에 의한 모델링 결과를 비교하여 그 성능을 입증한다.

접수일자: 2001년 10월 26일
완료일자: 2002년 5월 2일

2. 자기구성 퍼지 모델(SOFUM)

자기구성 퍼지 모델 SOFUM은 다음과 같이 크게 4 부분으로 구성된다.

- i) FCRM 클러스터링과 WRLS 알고리즘에 의한 모델 파라미터의 개략 동조
- ii) gradient descent 알고리즘에 의한 파라미터의 정밀 동조
- iii) 퍼지 엔트로피가 상대적으로 큰 입력력 데이터 집단에 다중 회귀 분석을 활용한 다차원 평면 클러스터의 생성과 새로운 퍼지 규칙의 추가
- iv) 감수분열 유전알고리즘에 의한 최적의 학습률 탐색

그림 1에 자기구성 퍼지 모델링의 전체 흐름도를 보인다.

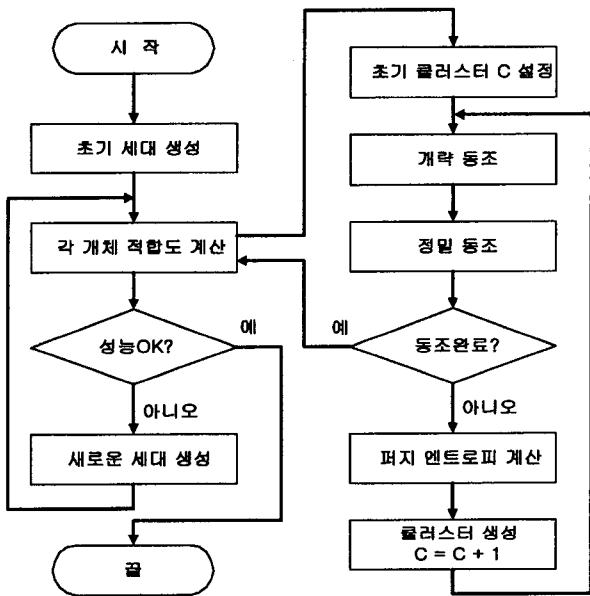


그림 1. 자기구성 퍼지 모델링의 흐름도
Fig. 1. Flow of SOFUM

2.1 모델 파라미터의 개략 동조

FCRM 클러스터링은 다차원 평면 클러스터에 적합하고, m 차원의 입력과 단일 출력의 경우 i 번째 클러스터는 다음과 같이 표현된다.

$$y^i = X^T P^i \quad (1)$$

여기서 $X = [1 \ x_1 \ \dots \ x_m]^T$, $P^i = [a_0^i \ a_1^i \ \dots \ a_m^i]$ 이다.

본 논문에서는 시스템 모델을 구축하기 위해 식(2)와 식(3)의 Takagi-Sugeno형 퍼지 모델을 이용한다.

$$R^i: \text{If } x_1 \text{ is } A_1^i(p_{11}^i, p_{12}^i) \text{ and } x_2 \text{ is } A_2^i(p_{21}^i, p_{22}^i) \text{ and } \dots \text{ and } x_m \text{ is } A_m^i(p_{m1}^i, p_{m2}^i), \text{ then } y^i = a_0^i + a_1^i x_1 + \dots + a_m^i x_m \quad (2)$$

$$y_m = \frac{\sum_{i=1}^c w^i y^i}{\sum_{i=1}^c w^i}, \quad w^i = \text{MIN}_{j=1}^m A_j^i(x_j) \quad (3)$$

여기서 $A_j^i = \exp \left\{ - \left(\frac{x_j - p_{j1}^i}{p_{j2}^i} \right)^2 \right\}$ 는 종형 소속함수이다.

다차원 평면 클러스터는 FCRM 클러스터링과 WRLS 알고리즘에 의해 다음 단계를 거쳐 반복 갱신된다.

1) FCRM 클러스터링

단계 1 : n 개의 표본 데이터 $(X_k, y_k), 1 \leq k \leq n$ 의 입력 공간에 C-means 알고리즘을 적용하여 초기 클러스터를 설정한다. 각 클러스터에 다중선형회귀 알고리즘을 적용하여 c 개의 다차원 평면 클러스터를 구한다.

$$y^1 = X^T P^1(1)$$

...

$$y^c = X^T P^c(1)$$

단계 2 : l 번째 반복시행에서 각각의 표본 데이터 $(X_k, y_k), 1 \leq k \leq n$ 를 각 클러스터 y^i 에 소속하는 정도 u_k^i 로 구성되는 $c \times n$ 행렬 $U(l)$ 을 다음과 같이 구한다.

$$I_k = \{i \mid 1 \leq i \leq c, d_k^i = \|y_k - X_k^T P^i(l)\| = 0\}$$

$$\bar{I}_k = \{1, 2, \dots, c\} - I_k$$

$$\text{If } I_k = \emptyset \Rightarrow u_k^i = \frac{1}{\sum_{j=1}^c \left(\frac{d_k^j}{d_k^i} \right)^{2/(m-1)}}$$

$$\text{If } I_k \neq \emptyset \Rightarrow u_k^i = 0 \ \forall i \in \bar{I}_k \text{ and } \sum_{i \in I_k} u_k^i = 1$$

단계 3 : 만일 $\|U(l) - U(l-1)\| \leq \epsilon$ 이면 종료, 아니면 단계 4를 수행.

단계 4 : WRLS 알고리즘에 의해 새로운 클러스터 $y^i = X^T P^i(l+1) (i=1, \dots, c)$ 를 구한다.

단계 5 : $l = l+1$, 단계 2를 수행.

2) WRLS 알고리즘

i 번째 다차원 평면 클러스터 $y^i = X^T P^i$ 는 식(4)~(6)의 순환 방정식에 의해 구해진다.

$$P_{k+1}^i = P_k^i + K_k [y_{k+1} - X_{k+1}^T P_k^i] \quad (4)$$

$$K_k = S_{k+1} X_{k+1} = \frac{S_k X_{k+1}}{\frac{1}{u_k^i} + X_{k+1}^T S_k X_{k+1}} \quad (5)$$

$$S_{k+1} = [1 - K_k X_{k+1}^T] S_k \quad (6)$$

$$S_0 = aI \ (a \text{는 } 100 \text{보다 큰 수, } I \text{는 단위행렬})$$

여기서 $k=1, \dots, n$ 이고, $i=1, \dots, c$ 이다.

전건부 파라미터는 소속도 행렬 $U(l)$ 을 이용하여 다음과 같이 구해진다.

$$A_j^i(p_{j1}^i, p_{j2}^i) = \exp \left\{ - \left(\frac{x_j - p_{j1}^i}{p_{j2}^i} \right)^2 \right\}$$

$$p_{j1}^i = \frac{\sum_{k=1}^n u_k^i x_{kj}}{\sum_{k=1}^n u_k^i}$$

$$\frac{p_{j2}^i}{\sqrt{2}} = \sqrt{\frac{\sum_{k=1}^n u_k^i (x_{kj} - p_{j1}^i)^2}{\sum_{k=1}^n u_k^i}}$$

여기서 p_{jk}^i 과 p_{jl}^i ($i=1, \dots, c$ 와 $j=1, \dots, m$)는 각각 i 번째 퍼지 규칙의 j 번째 소속함수의 평균과 표준편차를 나타낸다.

2.2 모델 파라미터의 정밀 동조

Gradient descent 알고리즘에 의해 다음과 같이 정밀하게 조정된다.

1) 전진부 파라미터의 정밀 동조

$$\Delta p_{jk}^i = \beta(y_d - y_m)(y^i - y_m) \frac{1}{\sum_{i=1}^c w^i} \frac{\partial w^i}{\partial p_{jk}^i} \quad (7)$$

여기서 β 는 전진부 파라미터의 학습률, y_d 는 목표 출력, y_m 은 퍼지 모델의 출력이다.

2) 후진부 파라미터의 정밀 동조

$$\Delta a_j^i = r(y_d - y_m) \frac{w^i x_j}{\sum_{i=1}^c w^i} \quad (8)$$

여기서 r 는 후진부 파라미터의 학습률이다.

2.3 클러스터의 생성

퍼지 집합을 정의역 $X = \{x_1, \dots, x_n\}$ 과 치역[0,1]의 대응이라고 하면, X 의 모든 퍼지 부분집합의 전체 집합은 다차원 입방체와 같고, 하나의 퍼지 집합은 이 다차원 입방체의 한 점과 같다[6]. 퍼지 집합의 애매 모호한 정도를 $X = \{x_1, \dots, x_m\}$ 에 대해 식(9)의 퍼지 엔트로피로 정의할 수 있다.

$$E(A) = \frac{a}{b} = \frac{l^2(A, A_{near})}{l^2(A, A_{far})} \quad (9)$$

여기서 $l^2(A, B) = \sqrt{\sum_{i=1}^m (m_A(x_i) - m_B(x_i))^2}$ 은 fuzzy Euclidean distance이며, $a = l^2(A, A_{near})$ 는 퍼지 집합 A 를 나타낸 점에서 가장 가까운 꼭지점까지의 거리, $b = l^2(A, A_{far})$ 는 퍼지 집합 A 를 나타낸 점에서 가장 먼 꼭지점까지의 거리이다.

퍼지 엔트로피가 상대적으로 큰 데이터 집합을 토대로 새로운 클러스터의 생성에 의해 퍼지 모델의 애매 모호한 정도가 적어지므로 모델링 오차가 줄어들 가능성이 크다.

본 논문에서는 각 표본 데이터 (X_k, y_k)의 퍼지 엔트로피를 구하는 대신에 소속도 행렬 U 를 참조하여 다음과 같이 애매 모호한 정도가 상대적으로 큰 데이터 집단을 구성하고, 이 데이터 집단에 다중 회귀분석을 적용하여 새로운 클러스터를 생성한다.

$$\begin{aligned} IF (MAX_{i=1}^c u_k^i - AVG_{i=1}^c u_k^i) < (\eta \times AVG_{i=1}^c u_k^i) \\ \text{and } (AVG_{i=1}^c u_k^i - MIN_{i=1}^c u_k^i) < (\eta \times AVG_{i=1}^c u_k^i) \\ \text{then } (X_k, y_k) \in Cluster_{new} \end{aligned}$$

여기서 η 는 새로운 클러스터의 퍼지 엔트로피 범위를 나타내는 상수이다.

2.4 최적의 학습률 탐색

퍼지 모델의 성능을 개선하기 위해 감수분열 유전 알고리즘을 이용하여 파라미터 학습률의 최적 값을 탐색한다. 감수분열 유전 알고리즘은 인간 내에 존재하는 감수분열(meiosis)을 적용하여 실수형 유전자로 구성된 개체를 생식체로 만들고, 세대가 진화함에 따라 생식체의 랜덤한 선택과 교배를 통해 진역탐색을 수행하면서 우수개체의 보존과 교배 및 변이를 통해 국부탐색을 수행한다. 감수분열 유전 알고리즘의 장점은 i) 실수형 유전자를 사용하여 분해능의 제약과 변환 오차가 없고, ii) 개체의 모든 유전자를 교배 기준선에 따라 분할하고 랜덤하게 변화시켜 개체를 생성함으로써 다양한 공간탐색이 가능하며, iii) 우수개체의 보존과 변이를 통해 부모세대의 우수 형질을 보존하면서 변이시켜 신속한 국부탐색을 동시에 가능하게 한다.

1) 생식체의 생성 유형

그림 2와 같이 생성 유형(XX, XY, MM)에 따라 개체를 가로열로 나누고 랜덤하게 변화시켜 생식체를 생성시키고 랜덤하게 선택하여 교배시킴으로써 다음 세대의 개체 집단을 생성한다.




그림 2. 감수분열 유전 알고리즘의 생식체 생성 유형 Fig. 2. Gamete types of meiosis-genetic algorithm

XX, XY 유형은 외형적으로 감수분열되는 비율에 따라 생성되는 생식체를 기준으로 구분되고, MM 유형의 감수분열은 염색체의 돌연변이를 모델로 한 것이다. 생식체간의 랜덤 선택에 의한 교배 결과 XY, MM 유형에 의해 경계값을 초과하는 개체가 생성될 수 있다. 본 논문에서는 개체의 각 염색체가 상한을 벗어나면 구간 내에 들어올 때까지 구간 값을 반복하여 빼고, 하한보다 작으면 구간 값을 더해 새로운 개체를 생성시킴으로써 모든 개체의 발생 확률이 균등하게 유지되도록 한다.

2) 감수분열 유전 알고리즘의 구성

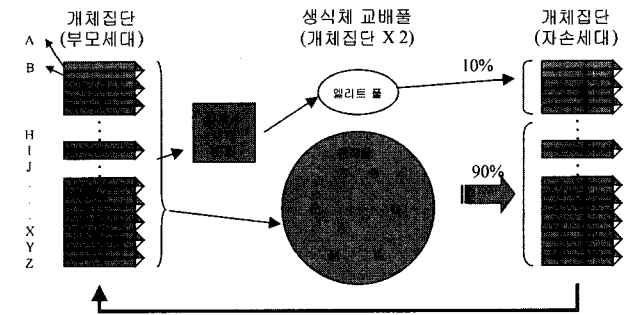


그림 3. 감수분열 유전 알고리즘의 구성 Fig. 3. Structure of meiosis-genetic algorithm

초기 개체 집단은 랜덤한 값으로 구성되며 각 개체에 대한 적합도를 평가하여 최우수 개체를 선정하고 자손세대의 엘리트 집단을 구성하는 종자로 사용하기 위해 최우수 개체 버퍼에 저장한다. 부모세대 내의 개체들은 XX 유형의 최우수개체 변형그룹과 XY, MM 유형의 감수분열을 적용할 개체그룹으로 나뉘어 생식체로 분리되고 교배 풀에 전달되며 랜덤하게 선택되어 자손세대를 구성한다.

생식체 교배 풀은 엘리트 풀과 동적 풀로 구성된다. 엘리트 풀에서는 최우수개체에 대해 XX 유형의 감수분열을 적용하여 생식체로 분리하고, 각 염색체를 랜덤하게 미세변화시켜 생성된 생식체들을 랜덤 교배를 통해 새로운 개체를 생성시켜 국부탐색을 수행하며, 자손세대 개체집단의 10%를 채우도록 한다. 동적 풀에서는 XX, XY, MM 유형으로 분리된 생식체들을 랜덤하게 교배시켜 전역탐색을 수행하며, 전역탐색이 국부탐색에 비해 더 큰 비중을 갖도록 자손세대 개체집단의 90%를 채운다.

3. 시뮬레이션 및 결과고찰

Box-Jenkins의 가스로 데이터, 다입력 단출력 비선형 정적함수의 데이터, 하수처리 활성오니공정의 입력-출력 데이터와 Mackey-Glass 시계열 데이터에 자기구성 퍼지 모델 SOFUM을 적용하여 모델링한 결과와 기존의 방법을 적용한 결과를 비교하여 그 유용성을 입증한다.

3.1 Box와 Jenkins의 가스로 데이터의 모델링

가스로 데이터는 9초 간격으로 샘플링된 296개의 입력-출력 시계열 데이터로 구성되어 있고, 입력 $u(k)$ 는 가스 로에 들어가는 가스 흐름률, 출력 $y(k)$ 는 출구의 CO_2 농도이다[7]. 모델의 종합적인 성능을 평가하기 위해 2가지 경우로 나누어 퍼지 모델을 구축하였다. 첫 번째 경우는 296개의 가스로 데이터를 학습하여 식(10)에 의해 모델의 학습성능지표 PI_e 를 구하였고, 두 번째 경우는 전체 가스로 데이터를 2개 부분으로 분할하여 148개의 전반부 데이터는 학습용으로, 148개의 후반부 데이터는 평가용으로 구분하고 식(10)에 의해 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다.

$$\text{성능지표 } PI = MSE = \frac{1}{n} \sum_{i=1}^n [y_d(i) - y_m(i)]^2 \quad (10)$$

여기서 $y_d(i)$ 는 공정출력, $y_m(i)$ 는 모델출력이다.

입력을 최대 입력치 2.84로 나누고 출력을 최대 출력치 60.5로 나누어 정규화된 변수 $\hat{u}(k)$, $\hat{u}(k-1)$, $\hat{u}(k-2)$, $\hat{y}(k-1)$, $\hat{y}(k-2)$, $\hat{y}(k-3)$ 을 퍼지 모델의 전건부 변수로 선정하였으며, 2개의 퍼지 규칙에서 시작하여 10개의 퍼지 규칙을 갖는 식(11)의 퍼지 모델을 구하였다.

$$\begin{aligned} R^i: & \text{ If } \hat{u}(k) \text{ is } A_1^i \text{ and } \hat{u}(k-1) \text{ is } A_2^i \\ & \text{ and } \hat{u}(k-2) \text{ is } A_3^i \text{ and } \hat{y}(k-1) \text{ is } A_4^i \\ & \text{ and } \hat{y}(k-2) \text{ is } A_5^i \text{ and } \hat{y}(k-3) \text{ is } A_6^i, \text{ then} \quad (11) \\ y^i(k) &= a_0^i + a_1^i \hat{u}(k) + d_2^i \hat{u}(k-1) + d_3^i \hat{u}(k-2) + \\ & + a_4^i \hat{y}(k-1) + d_5^i \hat{y}(k-2) + d_6^i \hat{y}(k-3) \end{aligned}$$

여기서 $A_j^i = \exp\left\{-\left(\frac{\hat{x}_j - p_{j1}^i}{p_{j2}^i}\right)^2\right\}$ 는 전건부 소속함수이고, $i=(1, \dots, c)$ 는 퍼지 규칙의 번호(또는 클러스터의 번호)이며, $j=(1, \dots, 6)$ 는 퍼지 변수의 번호이다.

표 1에 퍼지 모델의 성능지표 PI_e , PI_s , EPI_s 를, 표 2에 퍼지 규칙수의 변화에 대한 SOFUM의 모델성능지표 PI_e 를, 표 3에 SOFUM의 PI_s 와 EPI_s 를 나타낸다.

표 1. 가스로 데이터에 대한 퍼지모델의 성능
Table 1. Performance of fuzzy models over gas furnace data

| Model | 입력 | 규칙 | MSE | | |
|------------------------|----|----|--------|--------|--------|
| | | | PIe | PIs | EPIs |
| Sugeno and Yasukawa[8] | 3 | 6 | 0.190 | | |
| Sugeno and Tanaka[1] | 6 | 2 | 0.068 | | |
| Kim, et al.[2] | 6 | 2 | 0.055 | | |
| Kim, et al.[9] | 6 | 2 | | 0.034 | 0.244 |
| Lin and Cunningham[10] | 5 | 4 | | 0.071 | 0.261 |
| Oh's PNN[11] | 2 | - | | 0.018 | 0.262 |
| Park's FPN[12] | 6 | - | 0.0318 | 0.0101 | 0.1365 |
| Park's AFPNN[13] | 3 | - | | 0.0161 | 0.096 |
| SOFUM | 6 | 8 | 0.03 | 0.0168 | 0.1059 |

표 2. 가스로 전체 데이터에 대한 SOFUM의 학습오차
Table 2. Learning errors of SOFUM over the entire data of gas furnace

| 학습률 β | 학습률 ν | 입력 | 규칙 | PIe |
|-------------|-----------|----|----|--------|
| 0.0002 | 0.00015 | 6 | 2 | 0.0543 |
| | | | 3 | 0.0531 |
| | | | 4 | 0.0496 |
| | | | 5 | 0.0468 |
| | | | 6 | 0.0387 |
| | | | 7 | 0.0375 |
| | | | 8 | 0.0300 |

표 3. 가스로 데이터에 대한 SOFUM의 학습오차와 예측오차
Table 3. Learning and prediction errors of SOFUM over gas furnace data

| 학습률 β | 학습률 ν | 입력 | 규칙 | PIs | EPIs |
|-------------|-----------|----|----|--------|--------|
| 0.0063 | 0.0104 | 6 | 2 | 0.0158 | 0.1401 |
| | | | 3 | 0.0162 | 0.1394 |
| | | | 4 | 0.0156 | 0.1352 |
| | | | 5 | 0.0145 | 0.1450 |
| | | | 6 | 0.0143 | 0.1373 |
| | | | 7 | 0.0139 | 0.1413 |
| | | | 8 | 0.0168 | 0.1059 |
| | | | 9 | 0.0147 | 0.1332 |
| | | | 10 | 0.0147 | 0.1277 |

시뮬레이션 결과 자기구성 퍼지 모델 SOFUM이 기존의 모델보다 우수한 학습 성능과 예측 성능을 가지고 있으며, 대체로 클러스터의 수(퍼지 규칙의 수)가 증가함에 따라 모델링 오차가 축소됨을 알 수 있다.

3.2 비선형 정적함수 데이터의 모델링

2개의 입력과 1개의 출력을 갖는 식(12)의 비선형 정적함수[8]로부터 50개의 입력, 출력 데이터를 구하였다.

$$y = (1 + x_1^{-2} + x_2^{-1.5})^2, 1 \leq x_1, x_2 \leq 5 \quad (12)$$

입력 x_1, x_2 를 최대 입력치 4.99로 나누어 정규화된 변수 \hat{x}_1, \hat{x}_2 를 퍼지 모델의 전건부 변수로 선정하였고, 3~11개의 퍼지 규칙을 갖는 식(13)의 퍼지 모델을 구하였다.

$$R^i: \text{If } \hat{x}_1 \text{ is } A_1^i \text{ and } \hat{x}_2 \text{ is } A_2^i \text{ then } y^i = a_0^i + a_1^i \hat{x}_1 + a_2^i \hat{x}_2 \quad (13)$$

2개의 퍼지 모델을 구축하였으며, 첫 번째 경우는 50개의 전체 데이터를 학습하고 식(10)에 의해 학습성능지표 PI_e 를 구하였다. 두 번째 경우는 25개의 전반부 데이터는 학습용으로, 25개의 후반부 데이터는 평가용으로 구분하여 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다. 표 4에 비선형 함수에 대한 기존의 퍼지 모델과의 성능비교를, 표 5와 표 6에 각각 퍼지 규칙 수를 변화시키면서 전체 입력-출력 데이터를 학습한 SOFUM의 학습 성능과 전체 데이터를 학습용 및 평가용으로 분할하여 모델을 구축한 SOFUM의 학습 및 예측 성능을 나타낸다. 자기구성 퍼지 모델이 기존의 퍼지모델에 비해 월등한 학습 및 예측 성능을 보인다.

표 4. 비선형 함수에 대한 퍼지 모델의 성능
Table 4. Performance of fuzzy models over a nonlinear function

| Model | 입력 | 규칙 | MSE | | |
|----------------------------|----|----|---------|--------|-------|
| | | | PIe | PIs | EPIs |
| Sugeno and Yasukawa[8] | 2 | 6 | 0.079 | | |
| Gomez-Skarmeta, et al.[14] | 2 | 6 | 0.070 | | |
| Kim, et al.[2] | 2 | 3 | 0.019 | | |
| Kim, et al.[9] | 2 | 3 | 0.0089 | | |
| Oh, et al.[11] | 2 | - | 0.0041 | | |
| Kang, et al.[15] | 2 | 5 | | 0.017 | 0.128 |
| Park's AFPNN[13] | 2 | - | 0.0017 | | |
| SOFUM | 2 | 10 | 0.00037 | | |
| SOFUM | 2 | 11 | | 0.0023 | 0.016 |

표 5. 비선형 함수 전체 데이터에 대한 SOFUM의 학습오차

Table 5. Learning errors of SOFUM over the entire data of a nonlinear function

| 학습률 β | 학습률 ν | 입력 | 규칙 | PIe |
|-------------|-----------|----|----|---------|
| 0.000539 | 0.0138 | 2 | 3 | 0.058 |
| | | | 4 | 0.018 |
| | | | 5 | 0.0054 |
| | | | 6 | 0.0028 |
| | | | 7 | 0.0070 |
| | | | 8 | 0.0032 |
| | | | 9 | 0.0053 |
| | | | 10 | 0.00037 |
| | | | 11 | 0.0011 |

표 6. 비선형 함수에 대한 SOFUM의 학습오차와 예측오차
Table 6. Learning and prediction errors of SOFUM over a nonlinear function

| 학습률 β | 학습률 ν | 입력 | 규칙 | PIs | EPIs |
|-------------|-----------|----|----|--------|-------|
| 0.00778 | 0.0149 | 2 | 3 | 0.0061 | 0.067 |
| | | | 4 | 0.050 | 0.123 |
| | | | 5 | 0.043 | 0.135 |
| | | | 6 | 0.023 | 0.084 |
| | | | 7 | 0.045 | 0.134 |
| | | | 8 | 0.037 | 0.130 |
| | | | 9 | 0.024 | 0.083 |
| | | | 10 | 0.0077 | 0.093 |
| | | | 11 | 0.0023 | 0.016 |

3.3 하수처리 활성오니공정의 모델링

수도권의 한 하수처리장을 대상으로 활성오니공정의 수질 데이터를 추출하여 모델링 하였다. 입력 변수로는 혼합액 부유물(MLSS), 잉여오니 흐름률(WSR), 반응물 설정치(RRSP), 용존산소 설정치(DOSP)를, 출력 변수로는 유출수의 부유물(ESS) 농도를 선택한다. 52개의 전체 수질 데이터를 2개 부분으로 분할하여 26개의 전반부 데이터는 학습용으로, 26개의 후반부 데이터는 평가용으로 구분하고 식(10)에 의해 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다. 표 7에 자기구성 퍼지 모델과 기존의 퍼지 모델의 학습 및 예측성능지표를 비교한 결과를 나타내며, SOFUM이 기존의 퍼지 모델에 비해 전반적으로 우수한 학습 및 예측성능을 갖고 있다.

표 7. 기존 모델과의 동정오차 비교

Table 7. Comparison of identification errors with conventional fuzzy models

| Model | | MSE | |
|---------------------|--------------|--------|--------|
| | | PIs | EPIs |
| Oh and Pedrycz [16] | Simplified | 12.802 | 15.915 |
| | Linear | 6.396 | 54.233 |
| Oh's model[17] | FNN-(GA) | 10.163 | 14.698 |
| | FNN-(GA+HCM) | 9.920 | 10.129 |
| Oh's model[11] | PNN | 5.388 | 10.083 |
| Proposed model | SOFUM | 4.178 | 11.218 |

3.4 Mackey-Glass 시계열 데이터의 모델링

예측 알고리즘의 성능 평가를 위한 대표적인 예로 사용되는 Mackey-Glass 시계열[18]은 비선형 시스템으로부터 발생하는 카오스 신호의 일종이며 식(14)로 표현되는 비선형 동역학 방정식에 의해 생성된다.

$$x(t) = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (14)$$

본 연구에서는 식(14)의 수치적 해를 구하기 위해 4차 Runge-Kutta 방법을 적용하였고, time step은 0.1, 초기 조건 $x(0)$ 은 1.2, 시간지연상수 τ 는 17로 놓고 $x(t)$ 를 발생시켰다. 기존의 연구 결과들과 비교하기 위해 $x(t)$ 로부터 4입력 $x(t-18)$, $x(t-12)$, $x(t-6)$, $x(t)$ 와 단출력 $x(t+6)$ 형식의 입출력 데이터 쌍을 구하였다.

Mackey-Glass 시계열 데이터의 발생 초기에는 과도 영역이 존재하기 때문에 $t=118$ 에서 $t=1117$ 까지 1000개의 데이터를 추출하였다. 2개의 퍼지 모델을 구축하였으며, 첫 번째 경우는 $x(118)$ 에서 $x(1117)$ 까지 1000개의 전체 시계열 데이터를 학습하고 식(15)에 의해 학습성능지표 PI_e 를 구하였다. 두 번째 경우는 $x(118)$ 에서 $x(617)$ 까지 500개의 시계열 데이터를 모델의 학습에 사용하였고, 예측 성능을 평가하기 위해 $x(618)$ 에서 $x(1117)$ 까지 500개의 시계열 데이터를 모델의 예측치와 비교하여 식(15)에 의해 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다.

$$\text{성능지표 } PI = RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [y_d(i) - y_m(i)]^2} \quad (15)$$

표 8에 Mackey-Glass 시계열 데이터에 대한 기존의 퍼지 모델과의 오차 비교를 나타내며, 자기구성 퍼지 모델이 기존의 퍼지 모델에 비해 우수한 학습 및 예측 성능을 보인다. 표 9와 표 10에 각각 퍼지 규칙 수를 변화시키면서 전체 입력-출력 데이터를 학습한 SOFUM의 학습 성능과 전체 데이터를 학습용 및 평가용으로 분할하여 모델을 구축한 SOFUM의 학습 및 예측 성능을 나타낸다.

4. 결론 및 향후과제

본 논문에서는 퍼지 모델의 파라미터 동정 결과를 토대로 퍼지 엔트로피가 상대적으로 큰 데이터에 다중 회

표 8. Mackey-Glass 시계열에 대한 퍼지 모델의 성능

Table 8. Performance of fuzzy models over Mackey-Glass time series

| Model | MSE | | |
|----------|-------|-------|-------|
| | PIe | PIs | EPIs |
| Wang[19] | 0.044 | | |
| Wang[19] | 0.013 | | |
| Wang[19] | 0.010 | | |
| SOFUM | 0.010 | 0.010 | 0.010 |

표 9. Mackey-Glass 전체 시계열 데이터에 대한 SOFUM의 학습오차

Table 9. Learning errors of SOFUM over the entire data of Mackey-Glass time series

| 학습률 β | 학습률 ν | 입력 | 규칙 | PIe |
|-------------|-----------|----|----|--------|
| 0.0219 | 0.0375 | 4 | 2 | 0.0735 |
| | | | 3 | 0.0798 |
| | | | 4 | 0.0722 |
| | | | 5 | 0.0312 |
| | | | 6 | 0.0294 |
| | | | 7 | 0.0229 |
| | | | 8 | 0.0209 |
| | | | 9 | 0.0199 |
| | | | 10 | 0.0104 |

표 10. Mackey-Glass 시계열에 대한 SOFUM의 학습오차와 예측오차

Table 10. Learning and prediction errors of SOFUM over Mackey-Glass time series

| 학습률 β | 학습률 ν | 입력 | 규칙 | PIs | EPIs |
|-------------|-----------|----|----|--------|--------|
| 0.0402 | 0.0518 | 4 | 2 | 0.0755 | 0.0754 |
| | | | 3 | 0.0670 | 0.0663 |
| | | | 4 | 0.0328 | 0.0321 |
| | | | 5 | 0.0500 | 0.0494 |
| | | | 6 | 0.0306 | 0.0300 |
| | | | 7 | 0.0204 | 0.0197 |
| | | | 8 | 0.0310 | 0.0306 |
| | | | 9 | 0.0191 | 0.0185 |
| | | | 10 | 0.0103 | 0.0103 |

귀분석을 적용하여 새로운 다차원 평면 클러스터를 생성하고 모델 파라미터의 동정을 반복하면서 감수분열 유전 알고리즘을 이용하여 최적의 학습률을 탐색하는 자기구성 퍼지 모델 SOFUM을 제안하였다. 컴퓨터 시뮬레이션을 통해 Box와 Jenkins의 가스르, 비선형 다변수 정적함수, 하수처리 활성오니공정과 Mackey-Glass 시계열 데이터에 대한 모델링을 수행한 결과 자기구성 퍼지 모델이 기존의 퍼지 모델에 비해 우수한 학습성능 및 예측성능을 보였다. 추후 최적의 클러스터 탐색과 병렬 처리에

대한 연구가 필요하다고 하겠다.

참 고 문 헌

- [1] T. Takagi and M. Sugeno, "Fuzzy identification of systems and its application to modeling and control," *IEEE Trans. on Syst., Man & Cybern.*, vol.15, pp.116-132, 1985
- [2] E. Kim, M. Park, S. Ji and M. Park, "A new approach to fuzzy modeling," *IEEE Trans. Fuzzy Syst.*, vol.5, no.3, pp.328-337, 1997
- [3] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Functional Algorithm*. New York: Plenum, 1981
- [4] L. Ljung, *System Identification: Theory for the User*. Englewood Cliffs. NJ: Prentice-Hall, 1987
- [5] 고택범, 이덕규, "감수분열 유전알고리즘을 이용한 퍼지 모델의 자동 설계," 대한전기학회 학술회의 논문집, pp.2696-2698, 2000
- [6] B. Kosko, *Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence*. Englewood Cliffs. NJ: Prentice-Hall, 1992
- [7] G. E. P. Box and G. M. Jenkins, *Time Series Analysis, Forecasting and Control*. San Francisco, CA: Holden Day, 1970
- [8] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling," *IEEE Trans. on Fuzzy Systems*, vol.1, no.1, pp.7-31, Feb., 1993
- [9] E. Kim, H. Lee, M. Park, and M. Park, "A simple identified Sugeno-type fuzzy model via double clustering," *Information Sciences* 110, 25-39, 1998
- [10] Y. Lin and G. A. Cunningham III, "A new approach to fuzzy-neural modeling," *IEEE Trans. Fuzzy Sets Syst.*, vol. 45, pp.136-156, 1995.
- [11] S. K. Oh, D. W. Kim, B. J. Park and H. S. Hwang, "Advanced polynomial neural networks architecture with new adaptive nodes," *Trans. on Control, Automation and Systems Engineering*, vol.3, no.1, Mar., 2001
- [12] 박호성, 오성권, 윤양응, "퍼지 뉴럴 네트워크 구조로의 새로운 모델링 연구," 제어·자동화·시스템 공학 논문지, 제7권, 제8호, pp.664-674, 2001
- [13] 박병준, 오성권, 장성환, "퍼지뉴럴 네트워크와 자기구성 네트워크에 기초한 적응 퍼지 다항식 뉴럴네트워크 구조의 설계," 제어·자동화·시스템 공학 논문지, 제8권, 제2호, pp.126-135, 2002
- [14] A. F. Gomez-Skarmeta, M. Delgado, and M. A. Vila, "About the use of fuzzy clustering techniques for fuzzy model identification," *Fuzzy Sets and Systems*, vol. 106, 179-188, 1999
- [15] S. -J. Kang, C. -H. Woo, H. -S. Hwang and K. B. Woo, "Evolutionary design of fuzzy rule base for nonlinear system modeling and control," *IEEE Trans. Fuzzy Sets Syst.*, vol. 8, pp.37-45, 2000
- [16] S. K. Oh and W. Pedrycz, "Identification of fuzzy systems by means of an Auto-Tuning algorithm and its application to nonlinear systems", *Fuzzy Sets and Systems*, vol.115, no.2, pp.205-230, 2000
- [17] S. K. Oh and K. C. Yoon and H. K. Kim, "The design of optimal Fuzzy-Neural networks architecture by means of GA and an aggregate weighted performance index", *Journal of Control, Automation and Systems Engineering*, vol.6, no.3, Mar., 2000
- [18] M. C. Mackey and L. Glass, "Oscillation and chaos in physiological control systems," *Science*, 197 : 287-289, July, 1977
- [19] L. X. Wang and J. M. Mendel, "Generating fuzzy rules from numerical data, with application," *IEEE Trans. on Systems, Man, and Cybern.*, 22 no. 6, pp.1414-1427, 1992

저 자 소개



고택범(Taek-Beom Koh)

1981년 : 연세대학교 전기공학과 졸업
(공학사)

1983년 : 동 대학원 졸업(공학석사)

1983-1995년 : LG산전연구소 선임연구원

1996년 : 연세대학교 대학원 졸업
(공학박사)

1996-1998년 : 한국하니웰연구소 책임연구원

1999년-현재 : 경주대학교 컴퓨터전자공학부 조교수

관심분야 : 지능제어, 모델링, 이상검출, 자기진단

Phone : 054-770-5260

Fax : 054-748-2895

E-mail : tbkoh@kyongju.ac.kr