

클러스터 생성을 이용한 자기구성 퍼지 모델링

Self-Organizing Fuzzy Modeling using Creation of Clusters

고택범

경주대학교 컴퓨터전자공학부

Taek-Beom Koh

School of Computer and Electronic Engineering

Kyongju University

E-mail : tbkoh@kyongju.ac.kr

요약

본 논문에서는 상대적으로 큰 퍼지 엔트로피를 갖는 입력-출력 데이터 집단에 각종 회귀 분석을 적용하여 다차원 평면 클러스터를 생성하고, 이 클러스터를 새로운 퍼지 모델의 규칙으로 추가한 후 퍼지 모델 파라미터의 개략 동조와 정밀 동조를 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 탐색 한다. 그리고 자기 구성 퍼지 모델링 기법을 이용하여 Box-Jenkins의 가스로 데이터, 다변수 비선형 정적 함수의 데이터와 하수 처리 활성오니 공정의 모델링을 수행하고, 기존의 방법에 의한 모델링 결과와 비교하여 그 성능을 입증한다.

1. 서론

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 수학적인 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, 신경회로망이

나 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 정밀하게 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 Kim의 모델링과 같이 fuzzy C-regression model(FCRM) 클러스터링[3]과 weighted recursive least squared(WRLS) 알고리

증[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(MGA: Meiosis-Genetic Algorithm)[5]을 이용하여 최적의 학습률을 탐색하는 자기구성 퍼지 모델(SOFUM: Self-Organizing Fuzzy Model)을 제안한다. 그리고 Box-Jenkins의 가스로 데이터, 단변수 비선형 정적함수의 데이터와 하수 처리 활성 오니 공정의 모델링에 자기구성 퍼지 모델 SOFUM을 적용한 결과와 기존의 방법에 의한 모델링 결과를 비교하여 그 성능을 입증한다.

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 입출력 데이터 집단에 다중 회귀분석을 활용한 다차원 평면 클러스터의 생성과 새로운 퍼지 규칙의 추가
- iv) 감수분열 유전알고리즘에 의한 최적의 학습률 탐색

그림 1에 자기구성 퍼지 모델링의 전체 흐름도를 보인다.

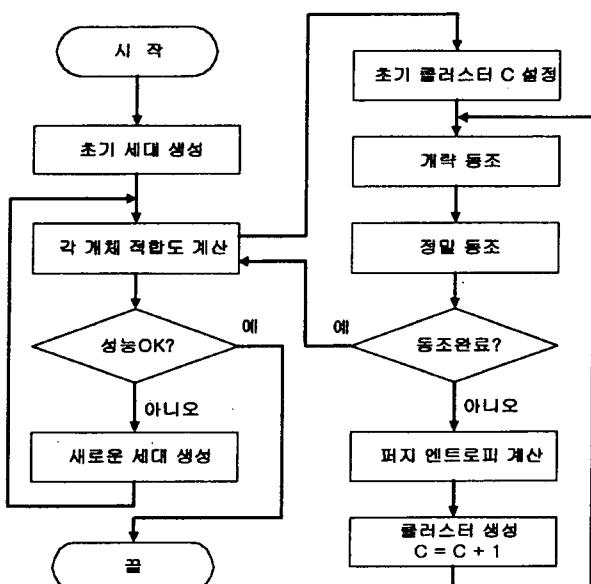


그림 1 자기구성 퍼지 모델링의 구성

2.1 모델 파라미터의 개략 동조

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

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

여기서 $\mathbf{X} = [1 \ x_1 \ \dots \ x_m]^T$, $\mathbf{P}^i = [a_0^i \ a_1^i \ \dots \ a_m^i]$ 이다. 시스템 모델을 구축하기 위해 (2)와 (3)의 Takagi-Sugeno형 퍼지 모델을 이용한다.

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

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

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 개선된다.

1) FCRM 클러스터링

단계 1: n 개의 표본 데이터 (\mathbf{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.

$$y^1 = \mathbf{X}^T \mathbf{P}^1(1)$$

...

$$y^c = \mathbf{X}^T \mathbf{P}^c(1)$$

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

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

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

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

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

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

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

단계 5: $i = i+1$, 단계 2를 수행

2) WRLS 알고리즘

i 번째 다차원 평면 클러스터 $y^i = \mathbf{X}^T \mathbf{P}^i$ 는

(4) ~ (6)의 순환 방정식에 의해 구해진다.

$$P_{k+1}^i = P_k^i + K_k [y_{k+1} - X_{k+1}^T P_k^i]$$

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

$$S_{k+1} = [I - K_k X_{k+1}^T] S_k$$

$$S_0 = \alpha I \quad (\alpha \text{는 } 100\text{보다 큰 수}, I \text{는 단위 행렬})$$

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

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

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

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

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

여기서 p_{j1}^i 과 p_{j2}^i ($i=1, \dots, c$ 와 $j=1, \dots, m$)는 각각 i 번째 퍼지 규칙의 j 번째 소속함수 평균과 표준편차를 나타낸다.

2.2 모델 파라미터의 정밀 동조

Gradient descent 알고리즘에 의해 다음과 같이 정밀하게 조정된다.

1) 전건부 파라미터의 정밀 동조

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

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

2) 후건부 파라미터의 정밀 동조

$$\Delta a_i = \gamma (y_d - y_m) \frac{w_i x_i}{\sum_{i=1}^c w_i} \quad (8)$$

여기서 γ 는 후건부 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 (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 퍼지

점까지의 거리, $b = l^2(A, A_{far})$ 는 퍼지 집합 A 를 나타낸 점에서 가장 먼 퍼지 점까지의 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 집합을 구성하고, 이 데이터 집단에 다중 회귀분석을 적용하여 새로운 클러스터를 생성한다.

$$IF (MAX_{i=1}^c u_k^i - AVG_{i=1}^c u_k^i) < (\eta \times AVG_{i=1}^c u_k^i)$$

$$\text{and } (AVG_{i=1}^c u_k^i - MIN_{i=1}^c u_k^i) < (\eta \times AVG_{i=1}^c u_k^i)$$

$$\text{then } (X_k, y_k) \in Cluster_{new}$$

여기서 η 는 새로운 클러스터의 퍼지 엔트로피 범위를 나타내는 상수이다.

2.4 최적의 학습률 탐색

퍼지 모델의 성능을 개선하기 위해 감수분열 유전 알고리즘을 이용하여 파라미터의 학습률의 최적 값을 탐색한다. 감수분열 유전알고리즘은 인간 내에 존재하는 감수분열(meiosis)을 적용하여 실수형 유전자로 구성된 개체를 생식체로 만들고, 세대가 진화함에 따라 생식체의 랜덤한 선택과 교배를 통해 전역탐색을 수행하면서 우수개체의 보전과 교배 및 변이를 통해 국부탐색을 수행한다. 감수분열 유전알고리즘의 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 우수형질을 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 개체집단을 생성한다.

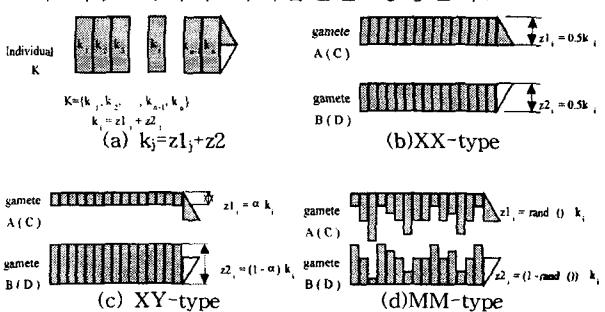


그림 2 생식체의 생성유형

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 유전알고리즘의 구성

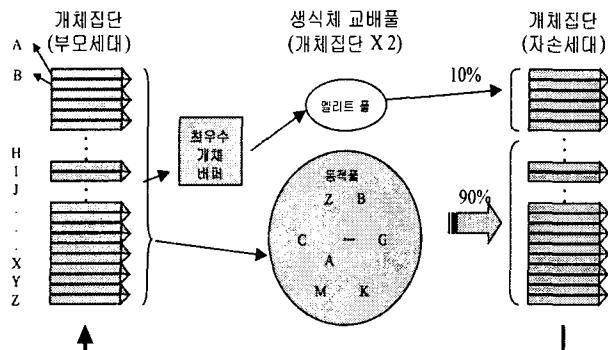


그림 3 감수분열 유전알고리즘의 구성

초기 개체 집단은 랜덤한 값으로 구성되며 각 개체에 대한 적합도를 평가하여 최우수 개체를 선정하고 자손세대의 엘리트 집단을 구성하는 종자로 최우수 개체 버페에 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 데이터와 하수처리 활성오니 공정의 입력-출력 데이터에 자기구성 퍼지 모델

SOFUM을 적용하여 모델링한 결과와 기존의 방법을 적용한 결과와 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 가스로에 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 (10)에 의해 모델의 학습성능지표 PI_e 를 구하였고, 두 번째 경우는 가스로 데이터를 2개 부분으로 분할하여 148개의 전반부 데이터는 학습용으로, 148개의 후반부 데이터는 평가용으로 구분하고 (10)에 의해 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다.

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

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

입력 $u(k)$, $u(k-1)$, $u(k-2)$ 를 최대 입력치 2.84로 나누고 출력 $y(k-1)$, $y(k-2)$, $y(k-3)$ 를 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 규칙(클러스터)에서 시작하여 10개의 퍼지 규칙을 갖는 (11)의 퍼지 모델을 구하였다.

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

$$y^i(k) = a_0^i + a_1^i \hat{u}(k) + d_2 \hat{u}(k-1) + d_3 \hat{u}(k-2) + \\ + a_4^i \hat{y}(k-1) + d_5 \hat{y}(k-2) + d_6 \hat{y}(k-3)$$

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, $j=1, \dots, 6$ 은 퍼지 변수의 번호이다.

표 1에 기존 퍼지 모델의 성능지표 PI_e , PI_s , EPI_s 를 나타낸다.

Model	입력	규칙	MSE		
			Ple	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 FPNN[12]	6	-	0.0318	0.0101	0.1365
Park's AFPNN[13]	3	-		0.0161	0.096

표 5 가스로 데이터에 대한 기존 모델의 성능

표 2에 SOFUM의 모델성능지표 PI_e 를, 표 3에 PI_s 와 EPI_s 를 보인다.

학습률 β	학습률 γ	입력	규칙	Ple
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 6 전체 데이터에 대한 SOFUM의 학습성능

학습률 β	학습률 γ	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

표 7 SOFUM의 학습성능 및 예측성능

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

3.2 비선형 정적함수 데이터의 모델링

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

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

입력 x_1, x_2 를 최대 입력치 4.99로 나누어 정규화된 변수 \hat{x}_1, \hat{x}_2 를 퍼지 모델의 전진부 변수로

선정하였고, 자기구성 퍼지 모델링을 적용하여 3~11개의 퍼지 규칙을 갖는 (13)의 퍼지 모델을 구하였다.

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

2가지 경우의 퍼지 모델을 구축하였으며, 첫 번째 경우는 50개의 전체 데이터를 학습하여 (10)에 의해 모델의 학습성능지표 PI_e 를 구하였다. 두 번째 경우는 전체 데이터 중에서 25개의 전반부 데이터는 학습용으로, 25개의 후반부 데이터는 학습된 모델의 타당성을 검증하기 위한 평가용으로 구분하여 (10)에 의해 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다.

표 5에 기존의 방법을 적용하여 구한 모델성능지표 PI_e, PI_s, EPI_s 를 보인다. 표 6과 표 7에 각각 전체 입력-출력 데이터를 학습한 SOFUM과 전체 데이터를 학습용 및 평가용으로 분할하여 모델을 구축한 SOFUM을 나타내며, 자기구성 퍼지 모델 SOFUM이 기존의 모델에 비해 월등한 학습 및 예측 성능을 보인다.

Model	입력	규칙	MSE		
			Ple	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		

표 8 비선형 함수에 대한 기존 모델의 성능

학습률 β	학습률 γ	입력	규칙	Ple									
				3	4	5	6	7	8	9	10	11	
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 9 전체 데이터에 대한 SOFUM의 성능

학습률 β	학습률 γ	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

표 10 SOFUM의 학습성능 및 예측성능

3.3 하수처리 활성오니공정의 모델링

수도권의 한 하수처리장을 대상으로 활성오니공정의 수질 데이터를 추출하여 모델링 하였다. 입력 변수로는 혼합액 부유물(MLSS), 잉여오니 흐름률(WSR), 반송률 설정치(RRSP), 용존산소 설정치(DOSP)를, 출력변수로는 유출수의 부유물(ESS) 농도를 선택한다. 52개의 전체 수질 데이터를 2개 부분으로 분할하여 26개의 전반부 데이터는 학습용으로, 26개의 후반부 데이터는 평가용으로 구분하고 (10)에 의해 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 구하였다. 표 7에 SOFUM과 기존의 퍼지 모델의 학습성능지표 PI_s 와 예측성능지표 EPI_s 를 비교한 결과를 보인다.

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]	PPN	5.388	10.083
Proposed model	SOFUM	4.178	11.218

표 11 SOFUM과 기존 모델과의 성능비교

표 7에 보인 바와 같이 활성오니공정의 모델링에서 SOFUM이 기존의 퍼지 모델에 비해 전반적으로 우수한 학습성능 및 예측성능을 갖고 있다.

4. 결론 및 향후과제

본 논문에서는 퍼지 모델의 파라미터 동정 결과를 토대로 퍼지 엔트로피가 상대적으로 큰 데이터에 다중 회귀분석을 적용하여 새로운 다차원 평면 클러스터를 생성하고 모델 파라미터의 동정을 반복하면서 감수분열 유전알고리즘을 이용하여 최적의 학습률을 탐색하는 자기구성 퍼지 모델 SOFUM을 제안하고, 컴퓨터 시뮬레이션을 통해 그 유용성을 입증하였다. Box와 Jenkins의 가스

로 데이터, 다입력 단출력 비선형 함수의 데이터와 하수처리 활성오니공정의 입력-출력 데이터에 대한 퍼지 모델링 결과에서 자기구성 퍼지 모델 SOFUM이 기존의 퍼지 모델에 비해 우수한 학습 및 예측 성능을 나타내었다.

추후 최적의 클러스터 탐색과 병렬 처리에 대한 연구가 필요하다고 하겠다.

6. 참고문헌

- [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, 윤양웅, "퍼지 뉴럴 네트워크 구조의 새로운 모델링 연구," 제어·자동화·시스템 공학 논문지, 제7권, 제8호, pp. 664-674, 2001.
- [13] 박병준, 오성권, 장성환, "퍼지뉴럴 네트워크와 자기구성 네트워크에 기초한 적응 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, March, 2000.