

## 퍼지 클러스터링 기반 퍼지뉴럴네트워크 설계 및 적용

박건준<sup>1</sup>, 이동윤<sup>2\*</sup>

<sup>1</sup>원광대학교 정보통신공학과, <sup>2</sup>중부대학교 전기전자공학과

# Design of Fuzzy Neural Networks Based on Fuzzy Clustering and Its Application

Keon-Jun Park<sup>1</sup> and Dong-Yoon Lee<sup>2\*</sup>

<sup>1</sup>Department of Information Communication Engineering, Wonkwang University

<sup>2</sup>Department of Electrical Electronic Engineering, Joongbu University

**요 약** 본 논문에서는 FCM 클러스터링 알고리즘을 기반으로 하는 퍼지뉴럴네트워크를 제안한다. 일반적으로, 퍼지 규칙을 생성할 때 차원이 증가하면 퍼지 규칙의 수가 기하급수적으로 증가하는 문제를 가지고 있다. 이를 해결하기 위해, 제안된 네트워크의 퍼지 규칙은 FCM 클러스터링 알고리즘을 이용하여 입력 공간을 분산 형태로 분할함으로써 생성한다. 퍼지 규칙의 전반부 파라미터는 FCM 클러스터링 알고리즘에 의한 소속행렬로 결정된다. 퍼지 규칙의 후반부는 다항식 함수의 형태로 표현되며, 퍼지뉴럴네트워크의 학습은 뉴런의 연결을 조절함으로써 실현되고, 오류 역전파 알고리즘에 의해 행해진다. 마지막으로, 제안된 네트워크는 비선형 공정으로의 적용을 통해 성능을 평가한다.

**Abstract** In this paper, we propose the fuzzy neural networks based on fuzzy c-means clustering algorithm. Typically, the generation of fuzzy rules have the problem that the number of fuzzy rules exponentially increases when the dimension increases. To solve this problem, the fuzzy rules of the proposed networks are generated by partitioning the input space in the scatter form using FCM clustering algorithm. The premise parameters of the fuzzy rules are determined by membership matrix by means of FCM clustering algorithm. The consequence part of the rules is expressed in the form of polynomial functions and the learning of fuzzy neural networks is realized by adjusting connections of the neurons, and it follows a back-propagation algorithm. The proposed networks are evaluated through the application to nonlinear process.

**Key Words** : Fuzzy Clustering Algorithm, Fuzzy Neural Networks (FNNs), Nonlinear Process, Rule Generation, Scatter Partition of Input Space

### 1. 서론

퍼지 집합 이론은 기존의 0이나 1중 하나의 값만을 선택해야 하는 이분법과는 달리 0과 1사이의 실수 값을 가질 수 있어 비선형 시스템에 내재되어 있는 불확실성을 효과적으로 나타내었으며, 이들 시스템의 정적 혹은 동적 특성을 언어 변수를 사용하여 묘사하였다. 이 언어적인 변수를 표현하는 입력변수, 즉 멤버십 함수는 주어진 데이터에 대하여 퍼지 집합으로 표현하여 소속정도를 나타

낸다. 퍼지 모델은 시스템을 이해하기 쉽도록 정성적인 표현이 용이하고 불확실한 정보를 가지고 있는 시스템에 강인성을 발휘할 수 있다. 그러나 학습기능을 가지고 있지 않고 있으며 퍼지규칙을 얻기 위해 전문가나 경험에 의존해야 하는 어려움이 있다. 반면에 신경회로망은 시스템의 입출력 관계를 학습을 통해 추출할 수 있으며 병렬 처리 기능을 가지고 있어 빠른 처리 능력을 가진다. 그러나 신경회로망은 주어진 시스템에 대해 정성적 표현이 어려워 시스템을 이해하기에는 어려움을 가진다. 이렇듯,

\*Corresponding Author : Dong-Yoon Lee (Joongbu University)

Tel: +82-41-750-6209 email: dylee@joongbu.ac.kr

Received October 11, 2012

Revised (1st November 26, 2012, 2nd December 31, 2012)

Accepted January 10, 2013

두 모델의 장점을 결합하고 단점을 해결하기 위해 퍼지 모델과 신경회로망의 유사성과 상호 보완관계를 이용하여 다양한 결합을 시도하고 있으며 이러한 구조가 퍼지 뉴럴네트워크이다[1-4].

퍼지뉴럴네트워크는 많은 연구자들에 의해 다양한 구조의 네트워크가 개발되고 있다[3, 4]. 하지만 매우 복잡한 구조를 가지고 있으며 컴퓨터 용량 및 계산시간 때문에 고계다변수 시스템의 적용에 문제점을 발생시킨다[3, 4]. 또한, 퍼지뉴럴네트워크는 퍼지 모델과 마찬가지로 퍼지 규칙으로 표현되며, 퍼지 규칙의 생성은 일반적으로 입력 공간의 분할 및 소속 함수에 의해 결정된다[3-6]. 이러한 방법은 고차원의 비선형 공정을 모델링하는 것은 규칙수의 한계를 갖고 있다[7]. 기존의 FCM 클러스터링 알고리즘은 파라미터를 추정하기 위해 사용되었거나[8], 학습을 사용하지 않았다[9]. 이렇듯, 일부 이러한 문제점을 극복하기 위하여 많은 노력이 시도되었으나 여전히 퍼지뉴럴네트워크의 구조 및 파라미터 동정을 위해서는 많은 연구가 필요하다.

본 논문에서는 FCM 클러스터링 알고리즘[10]에 의한 분산 형태의 입력 공간 분할에 의한 퍼지뉴럴네트워크를 제안한다. 퍼지 규칙은 FCM 클러스터링 알고리즘에 의해 입력 공간을 분산 형태로 분할하여 각각의 분할된 지역 공간이 하나의 규칙을 갖도록 형성한다. 후반부 동정에서 퍼지 추론 방법은 간략추론, 선형추론, 변형된 2차식 추론을 사용하며, 오류 역전파 알고리즘을 이용하여 연결가중치를 학습한다. 제안된 네트워크는 비선형 공정으로 적용 및 분석함으로써 평가한다.

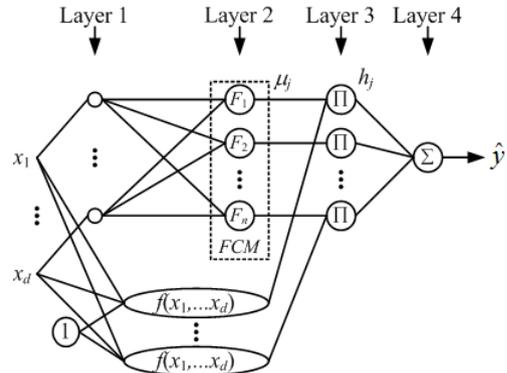
본 연구에서는 서론에 이어 제 2장에서는 퍼지뉴럴네트워크의 구조 및 학습방법에 대해 다루며, 제 3장에서는 제안된 네트워크를 비선형 공정으로 적용하여 특성을 분석하고, 제4 장에서는 결론을 맺는다.

## 2. FCM 기반 퍼지뉴럴네트워크

제안된 퍼지뉴럴네트워크는 FCM 클러스터링 알고리즘과 신경회로망의 두 구조가 유사성과 상호 보완적인 특성으로부터 결합이 시도되었다. 이 결합에 의한 퍼지뉴럴네트워크의 구조는 퍼지이론의 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 신경회로망의 학습능과의 상호간에 높은 융통성을 가지게 된다. 또한, FCM 클러스터링 알고리즘에 의한 퍼지뉴럴네트워크는 클러스터의 수와 소속 행렬에 의해 퍼지 규칙이 생성되며 퍼지 규칙의 수는 클러스터의 수가 된다. 이러한 퍼지 규칙의 생성은 고차원 시스템을 다루는데 매우 유용하다.

### 2.1 제안된 퍼지뉴럴네트워크의 구조

입력에 따른 퍼지 공간 분할은 FCM 클러스터링 알고리즘[10]에 의해 퍼지 규칙을 형성하며 후반부 구조는 간략 추론, 선형 추론, 변형된 2차식 추론에 의해 표현된다. 각 퍼지 규칙의 추론된 값은 연결가중치로 연결된 구조이다. Fig. 1은 제안된 FCM 클러스터 알고리즘 기반 퍼지뉴럴네트워크의 구조를 보여준다.



[Fig. 1] Structure of the proposed networks

Fig. 1에서 각 입력신호 \$x\_k(1 \le k \le d)\$는 FCM 클러스터링 알고리즘에 의해 적합도가 구해지고 적합도는 후반부 출력과 곱해진 다음, 대수적으로 합해짐으로써 최종 출력 \$\hat{y}\$를 생성한다. 퍼지 규칙은 퍼지뉴럴네트워크의 전체 구조가 퍼지 규칙을 형성하며, 그 규칙은 다음과 같이 표현된다.

$$R^j: \text{If } x_1 \text{ and } \dots \text{ and } x_d \text{ is } F_j \quad (1)$$

$$\text{Then } y_j = f_j(x_1, \dots, x_d)$$

간략추론(구조 1)

$$f_j = w_{j0} \quad (2)$$

선형추론(구조 2)

$$f_j = w_{j0} + \sum_{k=1}^d w_{jk} \cdot x_k \quad (3)$$

변형된 2차식추론(구조 3)

$$f_j = w_{j0} + \sum_{k=1}^d w_{jk} x_k + \sum_{k=1}^d \sum_{l=k+1}^d w_{jz} x_k x_l \quad (4)$$

여기서, \$R^j\$는 \$j\$번째 퍼지 규칙을 나타내며, \$F\_j\$는 FCM 클러스터링 알고리즘에 의한 \$j\$번째 규칙의 소속 정도로 표현된다. \$w\_{jk}\$는 후반부 계수이며, 연결가중치를 나타낸다. \$z\$는 입력 변수들의 조합의 수이다.

제안된 퍼지뉴럴네트워크의 구조에서 각 층의 연산 과

정은 다음과 같다.

[1층] 각 입력은 FCM 클러스터링 알고리즘을 위한 입력 신호를 전달한다.

[2층] FCM 클러스터링 알고리즘을 수행하여 소속 행렬을 구하고, 소속행렬로부터 전반부 적합도를 구한다.

[단계 1] 클러스터의 개수 ( $2 \leq c < n$ )를 결정하고, 소속행렬  $\mathbf{U}$ 를 초기화한다.

$$\sum_{i=1}^c u_{ip} = 1, \quad 1 \leq p \leq N \quad (5)$$

$$0 < \sum_{p=1}^N u_{ip} < N, \quad 1 \leq i \leq c \quad (6)$$

여기서,  $u_{ip}$  ( $i = 1, 2, \dots, c$ ;  $p = 1, 2, \dots, m$ )는 소속행렬의 파라미터이다.

[단계 2] 각각의 클러스터에 대한 중심벡터  $\mathbf{v}_i$ 를 구한다.

$$\mathbf{v}_i = \frac{\sum_{p=1}^N u_{ip}^{m_i} \mathbf{x}_p}{\sum_{p=1}^N u_{ip}^{m_i}} \quad (7)$$

여기서,  $m_i$ 는 퍼지화 계수이고 1.0보다 큰 값을 갖는다.

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬  $\mathbf{U}^{(r)}$ 을 생성한다.

$$u_{ip} = \frac{1}{\sum_{j=1}^c \left( \frac{\|\mathbf{x}_p - \mathbf{v}_i\|}{\|\mathbf{x}_p - \mathbf{v}_j\|} \right)^{\frac{2}{m_i - 1}}} \quad (8)$$

[단계 4] 만일 식 (9)를 만족한다면 종료하고, 그렇지 않으면  $r = r+1$ 로 놓고 [단계 2]로 간다.

$$Q = \sum_{i=1}^c \sum_{p=1}^N u_{ip}^{m_i} \|\mathbf{x}_p - \mathbf{v}_i\|^2 \quad (9)$$

[3층] 전반부 적합도와 후반부 출력과 곱해져 출력층의 입력이 된다.

$$h_j = \mu_j \cdot y_j \quad (10)$$

[4층] 들어오는 모든 입력 신호를 대수적으로 합해져 최종 출력을 구한다.

$$\hat{y} = \sum_{j=1}^n h_j \quad (11)$$

입력 공간을 분산 형태로 분할하는 방식은 FCM 클러스터링 알고리즘에 의해 수행된다. 이러한 분할 방식은 클러스터의 수만큼 입력 공간이 분할되고, 각 분할된 지역 공간은 규칙 수가 된다. 따라서 분산 형태의 입력 공간 분할 방식에서 퍼지 규칙의 수는 클러스터의 수가 된다.

## 2.2 퍼지뉴럴네트워크의 학습

제안된 퍼지뉴럴네트워크의 학습은 후반부 다항식 계수인 연결가중치를 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 오류역전파 알고리즘을 이용하며, 이는 원 출력과 모델 출력간의 차, 즉 오차를 바탕으로 이루어진다.

$$E_p = \frac{1}{2} (y_p - \hat{y}_p)^2 \quad (12)$$

간략 추론, 선형 추론 및 변형된 2차식 추론의 경우 연결가중치의 조절은 다음과 같이 기존의 값에 오차로부터 구해진 조절량 만큼의 변화를 더해 준다. 간략 추론의 경우 다음과 같다.

$$w_{j0}(p+1) = w_{j0}(p) + \Delta w_{j0} \quad (13)$$

$$\Delta w_{j0} = \eta \left( -\frac{\partial E_p}{\partial w_{j0}} \right) \quad (14)$$

따라서,

$$\Delta w_{j0} = \eta (y_p - \hat{y}_p) \hat{f}_j \quad (15)$$

또한, 모멘텀 계수를 포함하는 연결가중치 변화량은 다음과 같다.

$$\Delta w_{j0} = \eta (y_p - \hat{y}_p) \hat{f}_j + \alpha (w_{j0}(p) - w_{j0}(p-1)) \quad (16)$$

선형 추론인 경우와 변형된 2차식 추론인 경우에도 같은 방법으로 유도되며, 각각 다음과 같다.

$$\Delta w_{jk} = \eta (y_p - \hat{y}_p) \hat{f}_j x_k + \alpha (w_{jk}(p) - w_{jk}(p-1)) \quad (17)$$

$$\Delta w_{jz} = \eta (y_p - \hat{y}_p) \hat{f}_j x_k x_l + \alpha (w_{jz}(p) - w_{jz}(p-1)) \quad (18)$$

## 3. 비선형 공정으로의 적용

본 논문에서는 제안된 네트워크를 비선형 공정으로 적용하여 특성을 분석한다. 이를 위해, 비선형 공정에 대한 성능 평가의 척도로 사용되고 있는 가스로 공정[11]을 사

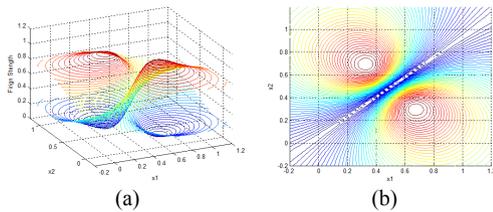
용한다. 모델의 평가 기준인 성능지수는 가스로 공정에 대해서 MSE (Mean Squared Error)를 이용한다.

$$PI = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (19)$$

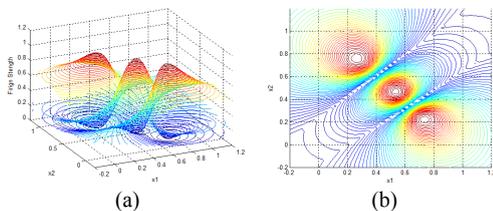
Box와 Jenkins가 사용한 가스로 시계열 데이터를 이용하여, 입출력 데이터인 가스 흐름률과 연소된 이산화탄소 농도의 가스로 공정을 모델링한다. 입력이 가스 흐름률이고 출력이 이산화탄소 농도인 1입력 1출력의 가스로 시계열 입출력 데이터 296쌍을 모의실험을 위해 입력으로  $[u(t-3), u(t-2), u(t-1), y(t-3), y(t-2), y(t-1)]$ 을, 출력으로  $y(t)$ 를 구성하여 사용한다. 또한 데이터 집합은 학습과 테스트 데이터로 나누어 추론에 의한 모델링을 수행한다.

먼저, 대표적으로 사용되는  $u(t-3)$ 과  $y(t-1)$ 을 입력으로 사용하여 2입력 1출력 시스템을 구성하여 2차원 시스템을 모델링한다. FCM 클러스터링 알고리즘에서 퍼지화 계수는 2.0을 사용하였으며, 학습률과 모멘텀 계수는 각각 0.1과 0.01로 설정하였다.

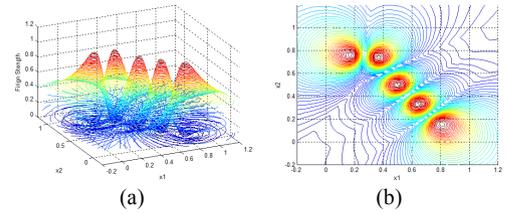
Fig. 2부터 Fig. 5까지는 2차원 입력 공간에서 FCM 클러스터링 알고리즘을 이용하여 클러스터의 수를 2개, 3개, 5개, 10개일 때 생성된 소속 행렬 및 분산 형태로 분할된 입력 공간을 보여준다. 소속 행렬은 클러스터의 수가 증가할수록 폭은 좁아지고 클러스터의 중심은 뾰족해지는 것을 볼 수 있다. 공간 분할은 각 클러스터의 중심을 기준으로 분산 형태로 분할되며, 클러스터의 수가 증가할수록 데이터가 밀집된 부분에서 세밀하게 공간이 분할되는 것을 알 수 있다.



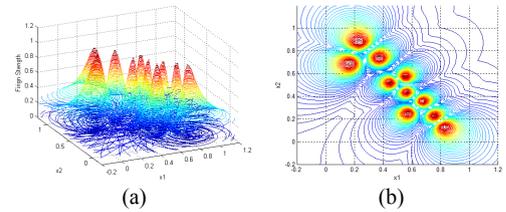
[Fig. 2] Input space (2 clusters)  
(a) Membership matrix (b) Scatter partition



[Fig. 3] Input space (3 clusters)  
(a) Membership matrix (b) Scatter partition



[Fig. 4] Input space (5 clusters)  
(a) Membership matrix (b) Scatter partition



[Fig. 5] Input space (10 clusters)  
(a) Membership matrix (b) Scatter partition

Table 1은 FCM 클러스터 알고리즘에 의한 클러스터의 수 및 후반부 구조에 의한 제한된 네트워크의 학습 데이터와 테스트 데이터에 대한 성능 지수를 보여준다. 여기서, PI는 학습 데이터에 대한 성능 지수를, E\_PI는 테스트 데이터에 대한 성능 지수를 보여준다.

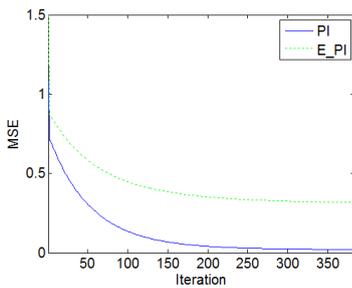
[Table 1] PI for 2 input system

클러스터 수	Type	PI	E_PI
2	구조 1	2.578	2.241
	구조 2	0.025	0.366
	구조 3	0.025	0.398
3	구조 1	1.126	1.434
	구조 2	0.024	0.360
	구조 3	0.024	0.371
5	구조 1	0.698	1.211
	구조 2	0.022	0.357
	구조 3	0.020	0.316
10	구조 1	0.502	0.991
	구조 2	0.034	0.413
	구조 3	0.023	0.343

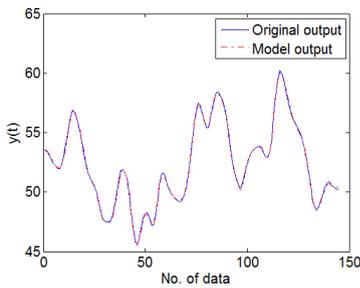
Table 1로부터 간략 추론 보다는 선형 추론, 변형된 2차식 추론이 더 좋은 성능을 보여준다. 또한, 클러스터의 수(규칙의 수)가 증가할수록 일반적으로 성능이 개선되는 것을 알 수 있다. 제한된 퍼지뉴럴네트워크의 경우 학습데이터에 의한 근사화 능력과 테스트 데이터에 의한

일반화 능력이 균형을 잘 잡는 것을 알 수 있다. FCM 클러스터링 알고리즘에 의한 퍼지뉴럴네트워크는 입력 공간을 분산 형태로 5개의 규칙을 가지고 변형된 2차식 추론을 이용한 경우가 가장 좋은 성능을 보여준다. 이때의 성능지수는 PI는 0.020이고 E\_PI는 0.316이다.

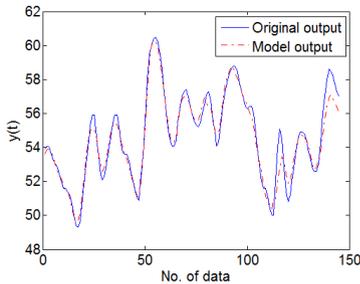
Fig. 6은 Table 1에서 선택된 모델인 5개의 규칙수를 가지고 후반부 구조가 변형된 2차식 추론인 퍼지뉴럴네트워크에 대하여 학습과정을 보여주며, 학습 데이터와 테스트 데이터에 대한 원 출력과 모델출력은 Fig. 7에서 보여준다. 그림에서 보는 바와 같이 원 출력과 유사한 출력을 갖는 것을 알 수 있다.



[Fig. 6] Learning process (2 inputs)



(a)



(b)

[Fig. 7] Model output (2 inputs)

(a) Training data (b) Testing data

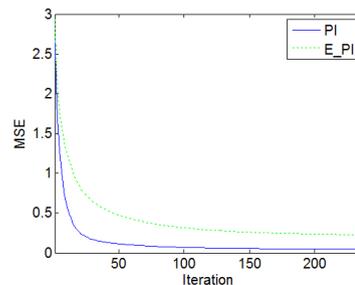
다음으로, 고차원의 비선형 시스템을 모델링하기 위하여 전체 입력을 사용하여 6입력 1출력 시스템을 구성하여 6입력 시스템을 모델링한다. 앞서와 같은 방법으로 FCM 클러스터링 알고리즘을 이용하여 입력 공간을 분산 형태로 분할하고 클러스터의 수와 추론 방법을 이용하였다. 학습 데이터와 테스트 데이터에 대한 성능 지수는 Table 2에서 보여준다.

[Table 2] PI for 6 input system

클러스터 수	Type	PI	E_PI
2	구조 1	2.776	2.991
	구조 2	0.040	0.228
	구조 3	0.047	0.227
3	구조 1	1.869	2.071
	구조 2	0.039	0.284
	구조 3	0.043	0.288
5	구조 1	1.199	2.046
	구조 2	0.035	0.243
	구조 3	0.037	0.260
10	구조 1	0.864	1.730
	구조 2	0.052	0.340
	구조 3	0.036	0.249

Table 2로부터 간략 추론인 경우 근사화 능력과 일반화 능력이 좋지 않은 결과를 가져왔다. 선형 추론과 변형된 2차식의 경우는 일반화 능력이 개선된 것을 알 수 있다. FCM 클러스터링 알고리즘에 의한 퍼지뉴럴네트워크는 입력 공간을 분산 형태로 2개의 규칙을 가지고 변형된 2차식 추론을 이용한 경우가 가장 좋은 성능을 보여준다. 이때의 성능지수는 PI는 0.047이고 E\_PI는 0.227이다.

Table 2에서 선택된 모델인 2개의 규칙 수를 가지고 후반부 구조가 변형된 2차식 추론인 네트워크에 대하여 학습과정을 Fig. 8에서 보여주며, 학습 데이터와 테스트 데이터에 대한 원 출력과 모델출력은 Fig. 9에서 보여준다.



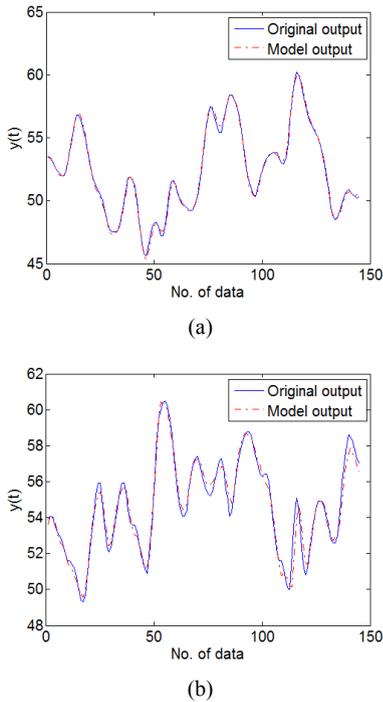
[Fig. 8] Learning process (6 inputs)

### 4. 결론

본 논문에서는 제안된 퍼지뉴럴네트워크는 FCM 클러스터 알고리즘을 이용하여 입력 공간을 분산 형태로 분할하고 분할된 지역 공간은 클러스터의 수만큼 퍼지 규칙을 형성하였다. 각각의 지역 공간은 간략 추론, 선형 추론 및 변형된 2차식 추론을 이용하여 표현하였으며, 오류 역전파 알고리즘을 이용하여 연결가중치를 학습하였다.

제안된 퍼지뉴럴네트워크는 비선형 공정에 적용함으로써 특성을 분석하였다. 저차원의 비선형 시스템의 동정은 일반적으로 근사화 능력과 일반화 능력이 대체로 균형을 잘 잡는 것을 알 수 있으며, 다소 근사화 능력에서 좋은 성능을 갖는 것을 알 수 있다. 고차원의 비선형 시스템을 동정하는 경우 매우 적은 수의 규칙을 사용하여 퍼지뉴럴네트워크를 설계할 수 있었으며, 후반부 구조가 변형된 2차식 추론인 경우가 좋은 결과를 얻을 수 있었다.

아울러, 제안된 네트워크는 신호처리, 패턴인식 및 얼굴인식 등 고차원의 데이터를 분석 및 적용하는 분야에서 매우 유용할 것으로 사료된다.



[Fig. 9] Model output (6 inputs)  
(a) Training data (b) Testing data

Table 3은 기존의 방법에서 소속 함수의 수에 대한 규칙의 수와 제안된 방법을 이용하여 실험을 통해 얻은 규칙의 수를 보여준다. 2차원의 경우 전체 규칙 수는 기존의 방법에 비해 절반 이하의 수를 이용하여 규칙을 생성할 수 있었으며, 6차원의 경우에는 차원과 무관한 2차원과 같은 수를 이용하여 규칙을 생성할 수 있었다.

[Table 3] Comparison of the number of rules  
(a) 2 inputs

기존		제안된 방법	
MFs 수	규칙 수	클러스터 수	규칙 수
2	4	2	2
3	9	3	3
4	16	5	5
5	25	10	10

(b) 6 inputs

기존		제안된 방법	
MFs 수	규칙 수	클러스터 수	규칙 수
2	64	2	2
3	729	3	3
4	4,096	5	5
5	15,625	10	10

### References

- [1] T. Yamakawa, "A Neo Fuzzy Neuron and Its Application to System Identification and Prediction of the System Behavior", *Proceeding of the 2nd International Conference on Fuzzy logic & Neural Networks*, pp. 447-483, 1992.
- [2] J. J. Buckley and Y. Hayashi, "Fuzzy neural networks: A survey", *Fuzzy Sets and Systems*, Vol. 66, pp. 1-13, 1994. DOI: [http://dx.doi.org/10.1016/0165-0114\(94\)90297-6](http://dx.doi.org/10.1016/0165-0114(94)90297-6)
- [3] J.-S. R. Jang, C. -T. Sun, E. Mizutani, *Neuro-Fuzzy And Soft Computing*, Prentice-Hall, 1997.
- [4] J. S. Roger Jang, "ANFIS : Adaptive-Network-based Fuzzy Inference Systems", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, No. 3, pp. 665-685, 1993. DOI: <http://dx.doi.org/10.1109/21.256541>
- [5] K. J. Park, D. Y. Lee, "Characteristics of Fuzzy Inference Systems by Means of Partition of Input Spaces in Nonlinear Process", *The Korea Contents Association*, Vol. 11, No. 3, pp. 48-55, 2011. DOI: <http://dx.doi.org/10.5392/JKCA.2011.11.3.048>
- [6] K. J. Park, D. Y. Lee, "Characteristics of Input-Output Spaces of Fuzzy Inference Systems by Means of Membership Functions and Performance Analyses", *The Korea Contents Association*, Vol. 11, No. 4, pp. 74-82,

2011.

- [7] K. J. Park, D. Y. Lee, "Nonlinear Characteristics of Fuzzy Inference Systems by Means of Individual Input Space", *The Korea Academia-Industrial Cooperation Society*, Vol. 12, No. 11, pp. 5164-5171, 2011.  
DOI: <http://dx.doi.org/10.5762/KAIS.2011.12.11.5164>
- [8] K. C. Yoon, B. G. Park, S. K. Oh, S. H. Lee, "The Design of Fuzz-Neural Networks Using FCM Algorithms", *The Proceeding of KIEE conference*, pp. 803-805, 2000.11
- [9] J. N. Choi, S. K. Oh, H. K. Kim, "Genetic Optimization of Fuzzy C-Means-Based Fuzzy Neural Networks", *KIEE*, Vol. 57, No. 3, pp. 466-472, 2008.3
- [10] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, PlenumPress, NewYork, 1981.
- [11] Box and Jenkins, *Time Series Analysis, Forecasting and Control*, Holden Day, SanFrancisco, CA.

---

**박 건 준**(Keon-Jun Park)

[정회원]



- 2005년 2월 : 원광대학교 제어계측공학과 (공학석사)
- 2010년 8월 : 수원대학교 전기공학과 (공학박사)
- 2010년 10월 ~ 2012년 8월 : 원광대학교 공과대학 2단계BK21 Post-Doc
- 2012년 9월 ~ 현재 : 원광대학교 공업기술개발연구소 리서치 펠로우연구교수

<관심분야>

컴퓨터 및 인공지능, 퍼지추론시스템, 신경망, 유전자 알고리즘 및 최적화이론, 지능시스템 및 제어

---

**이 동 윤**(Dong-Yoon Lee)

[정회원]



- 1990년 2월 : 연세대학교 전기공학과 (공학석사)
- 2001년 2월 : 연세대학교 전기전자공학과 (공학박사)
- 2002년 3월 ~ 현재 : 중부대학교 전기전자공학과 교수

<관심분야>

시큐리티시스템, 퍼지추론시스템, 인공지능