

데이터 정보를 이용한 퍼지 뉴럴 네트워크의 설계와 이의 최적화

Design of Fuzzy Neural Networks Using Data Information and Its Optimization

박건준, 오성권, 김현기

경기도 화성시 수원대학교 전기공학과
E-mail: ohsk@suwon.ackr

요 약

본 논문에서는 입출력 데이터의 특성을 이용하기 위하여 HCM 클러스터링에 의한 데이터 정보를 이용한 퍼지 뉴럴 네트워크의 설계를 제안하고 이를 최적화한다. 대상 시스템의 입출력 데이터를 취득하여 데이터들간의 거리를 중심으로 멤버십 함수를 정의하고 각 규칙에 속한 입출력 데이터를 추출하여 후반부 추론에 적용한다. 또한, 앞서 정의된 멤버십함수를 최적으로 동정하여 최적의 퍼지 뉴럴 네트워크를 설계한다. 제안된 퍼지 뉴럴 네트워크는 삼각형 멤버십 함수를 이용하며, 후반부 추론에는 간략, 선형, 변형된 2차식을 이용한다. 연결 가중치는 오류역전파 알고리즘을 이용하여 학습한다. 제안된 퍼지 뉴럴 네트워크는 표준 모델로서 널리 사용되는 수치적인 예를 통하여 평가한다.

Key Words : Fuzzy Neural Networks, Data Information, HCM Clustering, Optimization, Genetic Algorithms

1. 서 론

퍼지 이론과 신경망을 상호 융합한 지능형 모델, 즉 퍼지 뉴럴 네트워크는 비선형 공정에 대한 복잡성과 불확실성을 제어하기 위해 많은 연구가 이루어지고 있다. 퍼지이론은 1965년 Zadeh에 의해 창안된 퍼지 집합 이론을 이용하여 비선형적이고 복잡한 실 시스템의 특성을 해석하는데 적용함으로써 시스템의 성능 및 기능면에 있어서 기존의 수학적 모델보다 좋은 결과를 가져왔다. 인간의 두뇌가 이루고 있는 신경의 구조를 모방한 신경망은 학습을 통하여 모델이 지능적으로 행동할 수 있도록 하였고 계산처리에 있어서 병렬 분산 처리를 함으로써 계산처리 능력을 향상시키는 장점을 가졌다. 그러나 데이터 특성에 맞는 모델을 구축하는데 있어서는 전문가와 시행착오에 의존해야 하는 어려움이 있으며 동적으로 변화하는 환경에서 적응적으로 대처할 수 있는 모델을 구축하기가 힘들다. 이러한 문제를 해결하기 위한 방법으로 데이터 정보[1,2]에 대한 연구가 행해지고 있다.

본 논문에서는 이러한 퍼지 뉴럴 네트워크의 장점들을 이용하여 기존의 모델에 비해서 학습 속도가 빠르고, 수렴특성이 우수한 장점을 가

진 Yamakawa[3]에 의해 제안된 퍼지 뉴럴 네트워크를 변형한 관계 기반 퍼지 뉴럴 네트워크를 설계한다. 대상 시스템의 입출력 데이터의 정보를 이용하여 데이터 특성에 맞는 퍼지 뉴럴 네트워크를 설계한다. 이를 위해 HCM 클러스터링[4]에 의해 전반부 멤버십 함수를 정의하고 각 규칙에 속한 입출력 데이터를 추출하여 후반부 추론에 적용한다. 또한, 앞서 정의된 멤버십함수는 최적화 알고리즘인 유전자 알고리즘[5]을 이용하여 최적화한다. 제안된 퍼지 뉴럴 네트워크는 삼각형 멤버십 함수를 이용하며, 후반부 추론에는 간략, 선형, 변형된 2차식을 이용한다. 연결 가중치는 오류역전파 알고리즘을 이용하여 학습한다. 제안된 퍼지 뉴럴 네트워크는 표준 모델로서 널리 사용되는 수치적인 예를 통하여 평가한다.

2. 데이터 정보

대상 시스템의 입출력 데이터의 정보를 이용하여 데이터 특성에 맞는 모델을 구축하기 위해 클러스터링 알고리즘을 이용한다. 클러스터링 알고리즘이란 데이터의 분류를 위해서 사용

되는 것으로 데이터의 내부가 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하여 내부의 구조를 찾아내는 것이다. 본 논문에서는 클러스터링 알고리즘 중에서 데이터들 간의 거리를 기준으로 근접한 정도를 측정하고, 이를 바탕으로 데이터를 특성별로 분류하는 HCM 클러스터링 알고리즘[4]을 이용한다. HCM 클러스터링에 의한 데이터 분류는 다음과 같다.

[단계 1] 클러스터 개수 ($2 \leq c \leq n$)를 결정하고, 소속행렬 U 를 초기화한다.

[단계 2] 각각의 클러스터에 대한 중심벡터를 구한다.

[단계 3] 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬을 생성한다.

[단계 4] 종료 조건을 만족한다면 종료하고, 그렇지 않으면 [단계 2]로 간다.

본 논문에서는 HCM 클러스터링을 통해 입출력 데이터의 중심값을 이용하여 퍼지 뉴럴 네트워크의 전반부 멤버십 함수의 초기 정점을 동정하고, 후반부 입출력 데이터의 중심값을 적용한다.

3. 퍼지 뉴럴 네트워크 설계

본 논문에서 제안된 퍼지 뉴럴 네트워크 구조는 언어적 논리를 규칙의 형태로 표현할 수 있는 능력과 오류역전과 알고리즘을 사용한 학습가능 및 높은 융통성을 가진다. 제안된 구조는 전반부와 후반부로 나뉘어 설계된다.

3.1 전반부 동정

전반부 동정, 즉 구조 동정 및 파라미터 동정은 비선형 시스템을 표현하는데 있어서 매우 중요하다. 기존의 방법은 멤버십함수를 입력 변수의 최소값과 최대값 사이에서 임의의 개수로 등분하여 일률적으로 정의하였으나 이는 데이터들이 가지고 있는 특성을 제대로 반영하지 못하는 단점이 있다. 그래서 전반부 파라미터 동정을 위해 HCM 클러스터링에 의한 클러스터 중심을 이용하여 초기 멤버십함수의 정점을 동정한다. 그림 1은 Yamakawa가 제안한 모델을 변형하여 입력변수들의 상호관계를 고려한 전반부 퍼지공간을 보여준다.

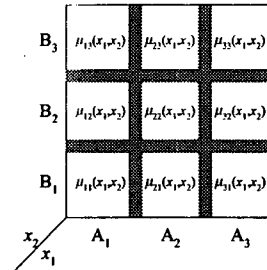


그림 1. 전반부 퍼지공간 분할

3.2 후반부 동정

제안된 구조의 후반부 구조는 퍼지추론의 세 가지 형태를 이용한다. 간략 퍼지추론의 형태는 식(1)과 같이 후반부가 상수항으로 이루어져 있으며, 선형 퍼지추론 구조는 식(2)와 같이 1차 선형식으로 구성되며, 변형된 2차식 퍼지추론 구조는 식(3)과 같이 구성된다.

$$R^i: \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots x_k \text{ is } A_{ik} \text{ then } y_i - m_i = w_0 \quad (1)$$

$$R^i: \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots x_k \text{ is } A_{ik} \text{ then } y_i - m_i = w_0 + w_{i1}(x_1 - v_{i1}) + \dots + w_{ik}(x_k - v_{ik}) \quad (2)$$

$$R^i: \text{If } x_1 \text{ is } A_{i1} \text{ and } \dots x_k \text{ is } A_{ik} \text{ then } y_i - m_i = w_0 + w_{i1}(x_1 - v_{i1}) + \dots + w_{ik}(x_k - v_{ik}) + w_{ik+1}(x_1 - v_{i1})(x_2 - v_{i2}) + \dots \quad (3)$$

입력 x_i 는 각 멤버십함수를 거쳐 적합도가 구해지고 그 적합도는 표준화된 후, 연결 가중치에 의한 네트워크와 곱해지며 이들이 대수적으로 합해져 i 번째 출력 $f_i(x_i)$ 를 생성한다. 간략 퍼지추론 형태를 가지는 식 (1)의 경우 R^i 는 j 번째 퍼지 규칙, A_{ij} 는 멤버십함수를, 후반부 w_{ij} 는 상수이며, 그림 2의 연결 가중치를 나타낸다. 식 (1)의 최종 추론결과는 다음과 같다.

$$\hat{y} = \sum_{i=1}^n f_i = \sum_{i=1}^n \bar{\mu}_i \cdot w_i = \sum_{i=1}^n \frac{\mu_i \cdot (w_0 - m_i)}{\sum_{i=1}^n \mu_i} \quad (4)$$

선형 퍼지추론의 형태를 가지는 퍼지 뉴럴 네트워크의 경우는 식 (5)와 같고, 변형된 2차식 퍼지추론의 경우도 같은 방법으로 추론된다.

$$\begin{aligned} \hat{y} &= \sum_{i=1}^n f_i = \sum_{i=1}^n \bar{\mu}_i \cdot C y_i \\ &= \sum_{i=1}^n \frac{\mu_i \cdot (w_0 + w_{i1}(x_1 - v_{i1}) + \dots + w_{ik}(x_k - v_{ik}) + m_i)}{\sum_{i=1}^n \mu_i} \end{aligned} \quad (5)$$

제안된 퍼지 뉴럴 네트워크의 학습은 연결 가중치 w_{ij} 를 모델에 가장 적절한 값으로 조정해 나가면서 이루어진다. 학습방법은 오류역전파 알고리즘을 사용하며, 오차를 바탕으로 이루어진다.

4. 최적화 알고리즘

유전자 알고리즘[5]은 자연 선택과 유전학에 기반으로 하는 확률적인 탐색방법으로써 탐색과 해의 가능영역들을 균형 있게 이용하기 위하여 생산, 교배, 돌연변이의 과정을 수행하는 일반성 있는 탐색법으로 비선형 최적화 이론에 탁월한 성능을 발휘하고 있다. 기존의 다른 탐색방법들과 달리 유전자 알고리즘은 해가 될 가능성이 있는 개체집단을 유지하면서 그들 모두가 동시에 최적값을 찾아나가기 때문에 지역 극소에 빠질 위험을 어느 정도 해결할 수 있다는 점과 더불어 모델의 성능지수가 최소가 되는 전역 극소 영역을 찾는 능력을 갖고 있으며, 또한 기존의 방법들과는 달리 선형, 연속, 미분가능 등의 제한이 없기 때문에 다양한 분야에 별다른 제한 없이 적용할 수 있다는 장점을 가진다는 것이 중요한 특징이다.

본 논문에서는 제안된 모델에 대한 멤버쉽함수의 정점을 최적으로 설정해 주기 위하여 유전자 알고리즘을 이용하여 모델의 최적화 과정을 수행하게 된다.

5. 실험 데이터를 통한 결과 고찰

제안된 퍼지 모델의 평가를 위해 다른 지능 모델에 널리 사용된 비선형 공정에 대한 성능 평가의 척도로 사용되고 있는 가스로 공정[5]을 사용한다. 모델의 평가 기준인 성능지수는 수치 데이터인 가스로 공정에 대해서 MSE(Mean Squared Error), 식 (6)을 이용한다.

$$PI = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

가스로 시계열 데이터는 입출력 데이터인 가스 흐름을 $u(t)$ 와 연소된 이산화탄소 농도 $y(t)$ 의 가스로 공정으로부터 추출된다. 시스템의 입력 변수는 $u(t-3)$, $y(t-1)$ 의 2입력을 적용한다. 출력은 $y(t)$ 이다. 또한 전체 시스템 입출력 데이터 쌍 296개 중 처음 148개의 데이터는 학습 데이터로 이용하고, 나머지 148개의 데이터는 테스트 데이터로 나누어 모델의 근사화와

일반화 능력을 평가한다.

본 모의실험을 위해 사용한 유전자 알고리즘의 초기 파라미터값을 표 1에 나타내었다.

표 1. 모델링을 위한 초기 파라미터들

Parameter	Value
Max. generation number	300
Population number	60
Crossover rate	0.6
Mutation rate	0.1

표 2에서는 멤버쉽 함수를 입력 변수의 최소값과 최대값 사이에서 임의의 개수(2개, 3개)로 등분하여 일률적으로 정의했을 때와 앞서 정의된 멤버쉽함수를 유전자 알고리즘을 통해 동조한 후 구추된 퍼지 뉴럴 네트워크의 성능지수를 보여준다. 표 3에서는 데이터 정보에 의한 멤버쉽 함수를 정의하고 각 규칙에 속한 데이터의 중심값을 후반부 다항식에 적용했을 때와 마찬가지로 멤버쉽함수를 유전자 알고리즘을 통해 동조한 후의 퍼지 뉴럴 네트워크의 성능을 보여준다.

표 2. 최소값과 최대값에 의한 성능지수

Method	MFs	Inference	PI	E PI
Max-Min	2x2	간략	0.023	0.342
		선형	0.025	0.349
		변형된 2차식	0.025	0.348
	3x3	간략	0.025	0.358
		선형	0.026	0.309
		변형된 2차식	0.025	0.317
GAs+ Max-Min	2x2	간략	0.025	0.327
		선형	0.030	0.278
		변형된 2차식	0.028	0.277
	3x3	간략	0.022	0.333
		선형	0.028	0.264
		변형된 2차식	0.024	0.270

표 3. 데이터 정보에 의한 성능 지수

Method	MFs	Inference	PI	E PI
HCM	2x2	간략	1.124	1.334
		선형	0.022	0.321
		변형된 2차식	0.022	0.326
	3x3	간략	0.263	0.904
		선형	0.022	0.381
		변형된 2차식	0.022	0.389
GAs+ HCM	2x2	간략	0.038	0.336
		선형	0.025	0.305
		변형된 2차식	0.024	0.304
	3x3	간략	0.062	0.368
		선형	0.022	0.284
		변형된 2차식	0.024	0.261

표 2와 표 3를 살펴보면 간략 퍼지추론의 형태인 경우 후반부가 상수항으로 이루어져 있어 데이터 정보의 효과를 볼 수 없지만 그 외의 퍼지추론의 형태인 경우는 일반적으로 성능이 향상된 것을 알 수 있다. 특히, 근사화 보다는 일반화 능력이 향상됨을 알 수 있다. 또한 유전자 알고리즘을 통한 멤버쉽함수의 정점을 동조한 후에도 성능이 향상됨을 알 수 있으며, 데이터 정보를 이용한 퍼지 뉴럴 네트워크의 경우 간략 퍼지추론의 형태는 성능이 두드러지게 향상된 것을 알 수 있다.

그림 5는 입력 변수가 $u(t-3)$, $y(t-1)$ 이고 각 멤버쉽함수의 수가 3개이며, 변형된 2차식 퍼지추론일 때의 데이터 정보를 이용한 퍼지 뉴럴 네트워크의 동조된 멤버쉽함수를 보여준다.

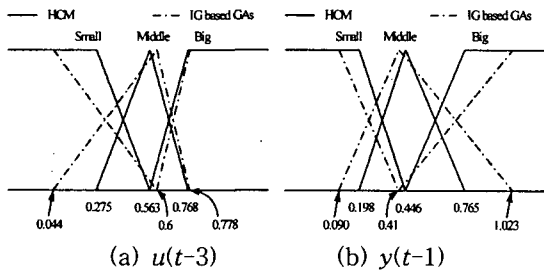


그림 5. 동조된 멤버쉽 파라미터

그림 6은 그림 5의 경우에 유전자 알고리즘에 의한 최적화 과정을 보여준다.

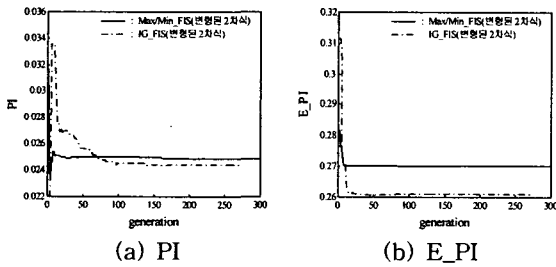


그림 6. 제안된 모델의 최적화 과정

6. 결론

비선형적이고 복잡한 시스템의 데이터 특성을 해석하고 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위하여 데이터 정보를 이용하여 퍼지 뉴럴 네트워크를 설계하였다. 즉, HCM 클러스터링 알고리즘을 이용하여 전반부 멤버쉽함수의 정의 및 다항식 함수의 초기값을 적용하여 데이터의 특성에 맞는 퍼지 뉴럴 네트워크를 구축하였다. 또한 앞서 정의된 멤버쉽함수의 정점을 유전자 알고리즘을 통해 동조함으로써 향상된 모델을 구축할 수 있었다.

실험 데이터를 통한 결과 고찰에서 볼 수 있듯이 본 논문에서 제안된 퍼지 뉴럴 네트워크는 간략 퍼지추론의 형태를 제외하고는 선형 퍼지추론과 변형된 2차식 퍼지추론의 형태에서 성능이 향상됨을 알 수 있었고, 특히 근사화 능력보단 일반화 능력이 향상됨을 알 수 있었다. 또한, 유전자 알고리즘을 이용한 멤버쉽함수의 최적화는 전반적인 성능 향상을 가져옴을 알 수 있었다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초 전력연구원(I-2004-0-074-0-00) 주관으로 수행된 과제임.

참고 문헌

- [1] L. A Zadeh , "Fuzzy logic = Computing with words," *IEEE Trans. Fuzzy Syst.*, Vol. 4, No. 2, pp. 103-111, 1996.
- [2] W. Pderycz and G. Vukovich, "Granular neural networks," *Neurocomputing*, Vol. 36, pp. 205-224, 2001.
- [3] Takeshi 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
- [4] P. R. Krishnaiah and L. N. Kanal, editors. *Classification, pattern recognition, and reduction of dimensionality*, volume 2 of Handbook of Statistics. North-Holland, Amsterdam, 1982.
- [5] D. E. Golderg, "Genetic Algorithm in search, Optimization & Machine Learning," Addison wesley, 1989.
- [6] G. E. P. Box and G. M. Jenkins, *Time Series Analysis, Forecasting, and Control*, 2nd edition Holden-Day, SanFransisco, 1976.