

FCM 기반 퍼지 뉴럴 네트워크의 진화론적 최적화

최 정내, 오 성권
수원대학교 전기공학과

Genetically Optimization of Fuzzy C-Means Clustering based Fuzzy Neural Networks

Jeoung-Nae Choi and Sung-Kwun Oh
The University of Suwon


Abstract - 본 논문에서는 FCM 기반 퍼지 뉴럴네트워크 구조를 제안하고 진화 알고리즘을 이용한 FCM 기반 퍼지 뉴럴네트워크의 구조와 파라미터의 최적화 방법을 제시한다.

클러스터링 알고리즘은 퍼지 뉴럴 네트워크에서 멤버십함수의 중심점과 반경 등을 결정하는 학습에 일반적으로 사용된다. 제안된 FCM 기반 뉴럴 네트워크에서 멤버십함수는 가우시안, 삼각형 타입 등의 정해진 형태를 사용하지 않고 데이터들 사이의 거리에 관계된 계산을 수행하는 FCM에 의해 결정된다. 후반부는 상수형, 선형, 2차식 등의 다양한 다항식 구조로 표현될 수 있으며 다항식의 계수는 LSE를 이용하여 결정한다.

FCM 기반 퍼지 뉴럴 네트워크는 퍼지규칙의 수, 입력변수의 선택, 후반부 다항식의 차수, FCM의 퍼지화 계수의 결정은 성능에 많은 차이가 있으며 이러한 구조와 파라미터의 최적화가 요구된다. 본 논문에서는 유전자 알고리즘을 이용하여 FCM 기반 퍼지뉴럴네트워크의 구조에 관련된 입력변수의 수, 퍼지규칙의 수 그리고 후반부 다항식의 차수와 파라미터에 관련된 퍼지화 계수를 최적화 한다. 제안된 방법은 비선형 시스템의 모델링에 적용하여 성능을 분석하였다.

알고리즘은 각각의 데이터와 각각의 클러스터 중심과의 거리에 대한 유사도 측정을 기반으로 목적함수를 최적화시키기 위한 알고리즘이다.

FCM-FNN은 다입력변수를 갖는 시스템에서 발생하는 다차원문제를 해결할 수 있고 빠른 학습을 수행할 수 있다는 장점이 있다.



〈그림 1〉 FCM 기반 퍼지 뉴럴 네트워크의 구조

FCM-FNN은 전반부와 후반부로 구성이 되어 있다. 전반부에서는 FCM에 기반하여 퍼지공간의 분할 및 각 퍼지공간에 대한 적합도가 계산되어지며 후반부는 각 퍼지공간에서의 로컬모델로써 다항식 구조를 갖는다. FCM-FNN은 다음처럼 표현되며 후반부 다항식은 4가지 형태를 고려한다.

$$R^i: \text{IF } x_1, \dots, x_n \text{ is } A_j \text{ THEN } y_j = f_j(x_1, \dots, x_n) \quad (1)$$

Type 1 : 간략식

$$f_j(x_1, x_2, \dots, x_n) = a_{j0} \quad (2)$$

Type 2 : 선형식

$$f_j(x_1, \dots, x_n) = a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n \quad (3)$$

Type 3 : 2차식

$$f_j(x_1, \dots, x_n) = a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n + a_{j(n+1)}x_1^2 + \dots + a_{j(2n)}x_n^2 + a_{j(2n+1)}x_1x_2 + \dots + a_{j(n+2)(n+1)/2}x_{n-1}x_n \quad (4)$$

Type 4 : 변형된 2차식

$$f_j(x_1, \dots, x_n) = a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n + a_{j(2n+1)}x_1x_2 + \dots + a_{j(n+2)(n+1)/2}x_{n-1}x_n \quad (5)$$

FCM-FNN의 학습은 크게 전반부 멤버십함수의 학습과 후반부 다항식의 학습부분으로 구성된다. 전반부 멤버십함수는 삼각형이나 가우시안 형태 등의 특정 형태를 사용하지 않고 거리에 기반을 둔 멤버십함수가 사용되며 FCM을 통하여 멤버십함수가 학습된다. i 번째 규칙(클러스터)에 대한 멤버십함수는 다음처럼 정의된다.

$$w_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_k - v_j\|}{\|x_k - v_i\|} \right)^{\frac{2}{p-1}}} \quad (6)$$

여기에서 $x_k = [x_{1k} \dots x_{nk}]$, v_i 는 i 번째 클러스터의 중심벡터, c 는 규칙수(클러스터 수), p 는 퍼지화 계수이며 멤버십함수의 값은 중심점과의 거리가 가까울수록 커진다. 모델 출력은 식(7)처럼 구해진다.

$$\hat{y}_k = \sum_{i=1}^m w_{ik} f_i(x_{1k}, \dots, x_{nk}) \quad (7)$$

여기에서 $k = 1, \dots, m$, m 은 데이터 수이며 후반부 다항식의 학습은 최소 자승법에 의하여 수행되며 식(8)처럼 구해진다.

$$\hat{a} = (X^T X)^{-1} X^T Y \quad (8)$$

후반부 다항식이 선형인 경우 각 변수는 다음처럼 정의된다.

$$\hat{a} = [a_{10} \dots a_{1n} \ a_{20} \dots a_{2n} \ \dots \ a_{m0} \dots a_{mn}]^T, \ X = [x_1 \ x_2 \ \dots \ x_m]^T$$

$$x_i^T = [w_{i1} \ \dots \ w_{in} \ x_{1i} w_{ni} \ \dots \ x_{ki} w_{ni} \ \dots \ x_{ki} w_{ni}], \ Y = [y_1 \ \dots \ y_m]^T$$

1. 서 론

최근에 강한 비선형 특성을 가진 복잡한 시스템의 모델링에 대한 많은 연구가 수행되고 있다. 비선형적이고 다변수인 시스템을 대상으로 한 퍼지 모델링 기법의 유용성은 이미 잘 알려져 있으며 이들은 퍼지추론에 기초하여 퍼지추론시스템, 퍼지뉴럴네트워크, RBF 뉴럴네트워크 그리고 퍼지 다항식 뉴럴 네트워크 등 다양한 구조로 연구되어 지고 있다.

퍼지모델의 성능은 퍼지규칙의 구성 방법에 의존하며 보다 좋은 성능을 위해서는 퍼지규칙의 동정이 필수적이다. 1980년대 초에 언어적 접근 방식과 퍼지 관계식에 기초한 접근 방식이 제안되었고 후반부에 선형식을 사용하는 Sugeno-Takagi 모델은 정교한 규칙 기반 모델의 초석이 되었으며, Complex 방법과 Least Square Method에 의해 동정하는 방법이 제안되었다. Pedrycz와 Oh는 로컬 모델이 다항식을 갖는 진보된 퍼지모델들을 제안하고, Simple Genetic Algorithms를 이용하여 Topology와 전반부 파라미터를 최적화 하는 방법을 제시하였다.

Clustering 알고리즘은 데이터를 분석하기 위해 사용되는 기법으로써 기계학습, 데이터마이닝, 패턴분류, 영상분석을 비롯한 많은 분야에서 사용되고 있다. HCM을 이용하여 정보입자를 추출하여 퍼지모델에 적용한 정보입자 기반 퍼지모델이 제시되었다. 특히 FCM 알고리즘은 각각의 데이터와 각각의 클러스터 중심과의 거리에 대한 유사도 측정을 기반으로 목적함수를 최적화시키기 위한 알고리즘으로써 많은 분야에서 적용되고 있다.

많은 연구에도 불구하고 퍼지이론 기반 모델의 다양한 구조와 동정에 관한 문제는 여전히 큰 관심 대상으로 남아있다.

본 논문에서는 FCM 기반 퍼지 뉴럴 네트워크 구조(FCM-FNN)를 제안한다. 이 구조는 RBF 뉴럴네트워크의 변형 및 확장된 구조로써 전반부에 FCM을 사용하고 후반부는 로컬모델로써 다양한 형태의 다항식으로 구성될 수 있다. 퍼지공간 분할과 멤버십함수는 FCM에 의해 결정된다. 특히 기존 퍼지모델과 달리 멤버십함수는 가우시안이나 삼각형 등의 특정 함수를 사용하지 않고 데이터들의 거리에 기반을 둔다. 각 퍼지공간에 대한 로컬모델로써 상수형, 선형 또는 2차식 등의 다항식을 사용할 수 있으며 다항식의 계수는 LSE를 사용하여 추정한다. FCM-FNN의 학습은 FCM과 LSE를 이용하여 학습하지만 모델 구축시 사용할 입력변수의 선택, 퍼지공간(퍼지 규칙)의 수, 후반부 다항식의 차수 및 퍼지화 계수 등을 최적화함으로써 성능을 극대화시킬 수 있다. 본 논문에서는 위와 같은 요소들을 계층적 경쟁 기반 병렬유전자 알고리즘(HFC-PGA)을 이용하여 최적화 한다.

가스로 공정에 제안된 FCM-FNN을 적용하여 성능을 비교 분석하였으며 제안된 방법의 타당성 및 우수성을 보였다.


2. FCM 기반 퍼지 뉴럴 네트워크

제안된 FCM 기반 퍼지 뉴럴 네트워크 (FCM-FNN)의 구조는 그림 1과 같다. 이 구조는 Radial Basis Function Neural Networks (RBFNN)의 변형된 구조로써 특정 RBF 커널을 사용하지 않고 FCM을 사용하여 퍼지공간 분할 및 멤버십함수를 수행하고 후반부는 다항식 형태로 확장되었다.

3. FCM 기반 퍼지 뉴럴 네트워크의 최적화

FCM-FNN은 FCM과 LSE에 의하여 학습되어 비교적 우수한 성능을 보이지만 퍼지규칙의 수, 적절한 입력변수의 선택, 후반부 다항식의 차수 그리고 퍼지화 계수의 설정에 따라 많은 성능차이를 보이며 최적화할 필요성이 있다. 본 논문에서는 FCM-FNN 모델의 구조에 관련된 입력변수 선택, 퍼지규칙 수 그리고 후반부 다항식의 차수와 파라미터에 관련하여 퍼지화 계수를 계층적 공정 경쟁 기반 병렬 유전자 알고리즘(HFC-PGA)을 사용하여 최적화 한다. HFC-PGA는 단순 유전자 알고리즘에서 발생하는 조기수렴문제를 해결하기 위하여 제시되었다. HFC-PGA는 개체들은 여러 개의 집단으로 분리되어 각각 다른 환경에서 일정세대 진화한 후 다른 집단으로 이주된다. 또한 적자생존 원리에 의하여 초기 생성된 열등한 개체가 바로 도태되는 것을 방지하여 일정세대 진화할 수 있도록 보호함으로써 공정한 경쟁이 이루어 질수 있도록 한다. 이 알고리즘은 개체들의 다양성을 유지하여 조기수렴문제를 해결하고 최적해 탐색능력을 극대화 시키며 다차원 문제에 있어서 우수한 성능을 보인다.

그림2에 FCM-FNN의 최적화를 위한 염색체의 구성을 보인다. 선택할 입력변수, 사용할 입력변수의 수, 퍼지규칙의 수, 후반부 다항식의 차수 그리고 퍼지화 계수에 대한 정보를 갖는 서브염색체로 구성이 되어있으며 염색체의 길이는 모델링 시에 주어진 전체 입력변수의 수+4이다. 여기에서 입력변수의 선택에 대한 부분은 정수로 표현되는 기호코딩방식을 사용한다. 나머지 네 개의 서브염색체는 실수로 표현되는 실수코딩 방식을 사용한다. 교배와 돌연변이 연산시 기호코딩에 관련된 염색체부분의 값들은 서로 중복이 되지 않도록 순화판매효용제(TSP)의 해결을 위해 제시된 부분사상교배(PMX)연산자와 상호돌연변이(RM)방법을 사용하였고, 실수코딩관련 염색체들은 산술교배(AX)와 균등돌연변이(UM)를 사용하였다.




기호코딩 기반 유전자 알고리즘 실수코딩 기반 유전자 알고리즘
〈그림 2〉 FCM-FNN의 최적화를 위한 HFC-PGA에서 염색체 구조

4. 실험 및 고찰

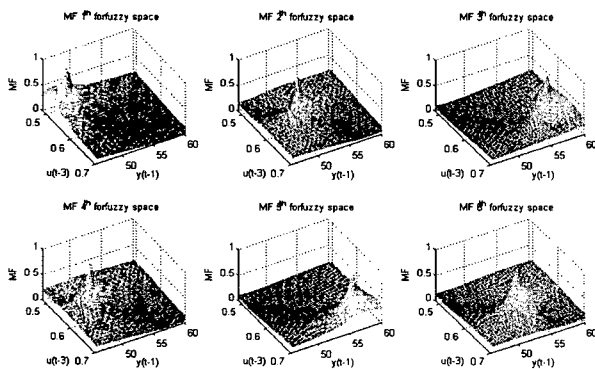
제안된 최적화 FCM-FNN 모델링방법을 Box와 Jenkins가 사용한 가스로 시계열 데이터를 이용하여, 입력력 데이터인 가스 흐름율과 연소된 이산화탄소 농도의 가스로 공정에 적용한다. $u(t)$ 와 $y(t)$ 의 296쌍의 입력력 데이터로부터 $u(t-3)$, $u(t-2)$, $u(t-1)$, $y(t-3)$, $y(t-2)$, $y(t-1)$ 의 6개의 입력변수와 한 개의 출력변수 $y(t)$ 를 설정하고 학습 데이터로 145개 테스트 데이터로 145개의 데이터 쌍을 사용한다. 성능지수로써 MSE를 사용하였다.

HFC-PGA에서 세대수는 300, 집단 수는 6, 각 집단에서 30개체, 교배율은 0.9, 돌연변이율은 0.1로 설정하였으며, 모델구축 시 사용할 최대 입력변수는 2개로 제한하고, 퍼지규칙수는 2~10, 후반부 다항식차수는 Type1~Type2, 퍼지화 계수는 1.0~15사이에서 탐색을 수행하였다.

시뮬레이션 결과 입력변수는 $u(t-3)$, $y(t-1)$ 가 선택되었으며, 퍼지규칙수는 6개, 후반부 다항식은 2차식(Quadratic) 그리고 퍼지화 계수(μ)는 2.97이 선택되었다. 이때 학습데이터에 대한 성능(PD)은 0.0146, 테스트 데이터에 대한 성능(EPI)은 0.3011이다. 그림 3에는 모델출력과 실제출력의 비교를 보이고 그림 4에는 각 퍼지공간에 대한 멤버십함수를 보인다. 표1에는 다른 모델과의 성능비교를 보인다.



〈그림 3〉 실제 출력과 모델출력 비교



〈그림 4〉 각 퍼지공간에 대한 멤버십함수

〈표 1〉 다른 모델과의 성능비교 (성능지수 : MSE)

모델	규칙수	PI	EPI
SVR(SVM)	X	0.023	1.028
Neural Networks	15 node	0.018	0.411
Fuzzy Inference System	6	0.020	0.264
George's Model[14]	7	0.022	0.266
Our Model	6	0.014	0.301

5. 결 론

본 논문에서는 FCM 기반 퍼지 뉴럴 네트워크 구조(FCM-FNN)를 제안한다. 이 구조는 RBF 뉴럴네트워크의 변형 및 확장된 구조로써 전반부에 FCM을 사용하고 후반부는 로컬모델로써 다양한 형태의 다항식으로 구성될 수 있다. FCM은 퍼지공간을 분할하며 멤버십함수를 결정하고 LSE를 사용하여 후반부 다항식의 계수를 추정한다. 또한 계층적 공정 경쟁기반 병렬 유전자 알고리즘을 사용하여 모델 구축에 사용할 의미 있는 최적의 입력변수를 선택하고, 퍼지공간의 수, 후반부 다항식차수 그리고 멤버십함수의 형태를 결정하는 퍼지화 계수를 최적화 한다.

제안된 FCM-FNN은 FCM을 사용하여 퍼지공간 분할과 멤버십함수를 결정한다. 그렇기 때문에 복잡한 다변수 시스템의 모델링에 적합하고 입력 데이터의 분포에 따라 멤버십함수가 변하기 때문에 데이터의 특성을 모델에 능동적으로 반영할 수 있어 우수한 특성을 보인다. 또한 모델 구축 시 사용할 입력변수의 선택, 퍼지공간(퍼지규칙)의 수, 후반부 다항식의 차수 및 퍼지화 계수 등을 계층적 공정경쟁 기반 병렬유전자 알고리즘을 사용하여 최적화함으로써 FCM-FNN의 근사화 능력 및 예측능력을 극대화 시킬 수 있다. 제안된 모델은 가스로 공정에 적용하여 분석을 수행하였으며 타당성 및 우수성을 입증하였다.

감사의 글

이 논문은 2007년도 정부(과학기술부)의 재원으로 한국과학재단의 지원을 받아 수행된 연구임(F01-2007-000-10058-0).

[참 고 문 헌]

- 1) T. Tagaki and M. sugeno, "Fuzzy identification of system and its applications to modeling and control", IEEE Trans. Syst. Cybern., Vol. SMC-15, No. 1, pp. 116-132, 1985
- 2) W. Pderycy and G. Vukovich, "Granular neural networks," Neurocomputing, Vol. 36, pp. 205-224, 2001.
- 3) P. R. Krishnaiah and L. N. Kanal, editors. Classification, pattern recognition, and reduction of dimensionality, Vol. 2 of Handbook of Statistics. North-Holland, Amsterdam, 1982.
- 4) 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 Syst., Vol. 115, No. 2, pp. 205-230, 2000.
- 5) Lin, S.C., Goodman, E., Punch, W.: Coarse-Grain Parallel Genetic Algorithms: Categorization and New Approach. IEEE Conf. on Parallel and Distrib. Processing. Nov. 1994
- 6) Hu, J.J., Goodman, E.: The Hierarchical Fair Competition (HFC) Model for Parallel Evolutionary Algorithms. Proceedings of the 2002 Congress on Evolutionary Computation: CEC2002. IEEE. Honolulu. Hawaii. (2002)
- 7) L. X. Wang, J. M. Mendel, "Generating fuzzy rules from numerical data with applications," IEEE Trans. Systems, Man, Cybern., Vol. 22, No. 6, pp. 1414-1427, 1992.
- 8) J. S. R. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System," IEEE Trans. System, Man, and Cybern., Vol. 23, No. 3, pp. 665-685, 1993.
- 9) L. P. Maguire, B. Roche, T. M. McGinnity, L. J. McDaid, "Predicting a chaotic time series using a fuzzy neural network," Information Sciences, Vol. 112, pp. 125-136, 1998.
- 10) C. James Li, T. -Y. Huang, "Automatic structure and parameter training methods for modeling of mechanical systems by recurrent neural networks," Applied Math. Modeling, Vol.23, pp. 933-944, 1999.
- 11) R. L. Cannon, J.V. Dave, J.C. Bezdek, "Efficient Implementation of Fuzzy C Means Clustering Algorithm," IEEE Trans. Pattern Anal. & Machine Int., Vol. PAMI-8, NO. 2, pp. 248-256, 1986.
- 12) A. Staiano, R. Tagliaferri, W. Pedrycz, "Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering," Neurocomputing, Vol. 69, pp. 1570-1581, 2006.
- 13) F. Ron, M. Pintore, A.Deman, J.R. Chretien, "Automatic initialization of RBF neural networks," Chemometrics and intelligent laboratory systems, Vol. 87, pp. 26-32, 2007.
- 14) George E. Tsekouras, "On the use of the weighted fuzzy c-means in fuzzy modeling," Advances in Engineering Software, Vol. 36, pp. 287300, 2005.