

FCM 기반 퍼지 뉴럴 네트워크의 진화론적 최적화

論文

57-3-21

Genetic Optimization of Fuzzy C-Means Clustering-Based Fuzzy Neural Networks

崔正乃* · 吳聖權† · 金賢起**

(Jeoung-Nae Choi · Sung-Kwun Oh · Hyun-Ki Kim)

Abstract - The paper concerns Fuzzy C-Means clustering based fuzzy neural networks (FCM-FNN) and the optimization of the network is carried out by means of hierachal fair competition-based parallel genetic algorithm (HFCPGA).

FCM-FNN is the extended architecture of Radial Basis Function Neural Network (RBFNN). FCM algorithm is used to determine centers and widths of RBFs. In the proposed network, the membership functions of the premise part of fuzzy rules do not assume any explicit functional forms such as Gaussian, ellipsoidal, triangular, etc., so its resulting fitness values directly rely on the computation of the relevant distance between data points by means of FCM. Also, as the consequent part of fuzzy rules extracted by the FCM-FNN model, the order of four types of polynomials can be considered such as constant, linear, quadratic and modified quadratic.

Since the performance of FCM-FNN is affected by some parameters of FCM-FNN such as a specific subset of input variables, fuzzification coefficient of FCM, the number of rules and the order of polynomials of consequent part of fuzzy rule, we need the structural as well as parametric optimization of the network. In this study, the HFCPGA which is a kind of multipopulation-based parallel genetic algorithms(PGA) is exploited to carry out the structural optimization of FCM-FNN. Moreover the HFCPGA is taken into consideration to avoid a premature convergence related to the optimization problems. The proposed model is demonstrated with the use of two representative numerical examples.

Key Words : Fuzzy Neural Networks, Fuzzy C-Means clustering, Hierachical Fair Competition based Parallel Genetic Algorithm, Least square estimator

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[1-4], 퍼지뉴럴네트워크[7-9], RBF 뉴럴네트워크[10-12] 그리고 퍼지 다항식 뉴럴 네트워크 [15]등 다양한 구조로 연구되어지고 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[1], Pedrycz와 Oh는 로컬 모델이 다항식을 갖는 진보된 퍼지모델들을 제안하고, Simple Genetic Algorithms(GA)를 이용하여 구조(Topology)와 전반부 파라미터를 최적화 하는 방법

을 제시하였다[4].

Clustering 알고리즘은 데이터를 분석하기 위해 사용되는 기법으로써 기계학습, 데이터마이닝, 패턴분류, 영상분석을 비롯한 많은 분야에서 사용되고 있다. C-Means clustering 알고리즘을 이용하여 정보입자를 추출하여 퍼지모델에 적용한 정보입자 기반 퍼지모델이 제시되었다. 특히 Fuzzy C-Means clustering 알고리즘 (FCM)은 각각의 데이터와 각각의 클러스터 중심과의 거리에 대한 유사도 측정을 기반으로 목적함수를 최적화시키기 위한 알고리즘으로써 많은 분야에서 적용되고 있다[10-13].

많은 연구에도 불구하고 퍼지이론 기반 모델의 다양한 구조와 동정(identification)에 관한 문제는 여전히 큰 관심 대상으로 남아있다.

본 논문에서는 FCM 기반 퍼지 뉴럴 네트워크 구조(FCM-FNN)를 제안한다. 이 구조는 Radial basis function neural network (RBFNN)의 변형 및 확장된 구조로써 전반부에 FCM을 사용하고 후반부는 로컬모델로써 다양한 형태의 다항식으로 구성될 수 있다. 퍼지공간 분할과 멤버쉽함수는 FCM에 의해 결정된다. 특히 기존 퍼지모델과 달리 멤버쉽함수는 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 Least square estimator(LSE)

* 正會員 : 水原大學 電氣工學科 工博

** 正會員 : 水原大學 電氣工學科 教授 · 工博

† 教授 저자, 正會員 : 水原大學 電氣工學科 教授 · 工博

E-mail : ohsk@suwon.ac.kr

接受日字 : 2007年 12月 10日

最終完了 : 2008年 1月 9日

를 사용하여 추정한다.

GA는 생태계의 진화 과정을 모방한 최적화 알고리즘으로써 전역해를 찾을 수 있어 많은 응용에 성공적으로 사용되고 있다. 그렇지만 세대가 진화함에 따라 개체들의 다양성의 결핍으로 인하여 더 우수한 해를 찾지 못하고 지역 해에 빠지는 조기수렴문제를 갖고 있다. 이런 조기수렴 문제는 개체들의 다양성을 유지시킴으로써 해결할 수 있다. 계층적 공정 경쟁 기반 병렬 유전자 알고리즘(Hierarchical Fair Competition based Parallel Genetic Algorithm ; HFCPGA)은 집단의 다중화 및 계층화를 통하여 개체들의 다양성을 유지함으로써 조기수렴 문제를 개선한다. HFCPGA는 기존의 GA보다 탐색능력이 우수하다[5-6].

FCM-FNN의 학습은 FCM과 LSE을 이용하여 학습하지만 모델 구축 시에 사용할 입력변수의 선택, 퍼지공간(또는 퍼지규칙, 클러스터)의 수, 후반부 다항식의 차수 및 퍼지화 계수 등을 최적화함으로써 성능을 극대화 시킬 수 있다. 본 논문에서는 위와 같은 요소들을 HFCPGA를 이용하여 최적화 한다.

2장에서는 FCM알고리즘과 FCM-FNN의 구조에 대하여 설명한다. 3장에서는 HFCPGA와 FCM-FNN의 최적화방법을 제시한다. 4장에서는 수학적 예제와 가스로 공정에 제안된 FCM-FNN을 적용하여 성능을 비교 분석결과를 보이고, 5장에서는 결론을 요약한다.

2. FCM 기반 퍼지 뉴럴 네트워크

이 장에서는 FCM 알고리즘과 FCM 기반 퍼지 뉴럴네트워크의 구조, 추론방법 및 학습방법에 대한 설명을 한다.

2.1 Fuzzy C-Means 클러스터링

Bezdek은 초기 C-Means 클러스터링을 개선하여 퍼지집합이론과 최소자승 에러 평가에 기반을 둔 FCM을 제시하였다[12-13]. FCM은 하나의 클러스터에 속해 있는 각각의 데이터 점을 소속 정도에 의해서 클러스터에 대한 데이터의 소속 정도를 열거한 데이터 분류 알고리즘이다.

FCM은 m 개의 벡터 $\mathbf{x}_i, i=1, \dots, m$ 의 집합을 c 개의 퍼지 그룹들로 분할하고, 비유사성 측정의 비용함수가 최소가 되는 것과 같은 각각의 그룹 안에서 클러스터의 중심을 찾는다.

FCM과 C-Means 클러스터링 알고리즘의 중요한 차이점은 C-Means 클러스터링 알고리즘에서 임의의 데이터는 소속정도는 0 또는 1값을 가지게 되며 단지 하나의 클러스터에 속하게 되지만 FCM 알고리즘에서 임의의 데이터는 0과 1 사이의 멤버쉽 값으로 특정 지어지는 소속정도를 가지고 여러 개의 클러스터에 속할 수 있다는 점이다. 그렇지만 FCM은 목적함수(비용함수)를 사용하며 데이터를 분할하는 동안에 비용함수가 최소가 되도록 분류한다.

소속 행렬 \mathbf{U} 는 0과 1사이의 값을 가질 수 있으며 주어진 데이터가 각 클러스터에 속하는 소속정도의 합은 식(1)처럼 1이 된다.

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n \quad (1)$$

여기서 c 는 클러스터의 수, n 은 데이터의 수이다.

FCM에서의 비용함수는 식(2)처럼 일반화 된다.

$$J(\mathbf{U}, \mathbf{v}_1, \dots, \mathbf{v}_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^p d_{ij}^2 \quad (2)$$

여기서 u_{ij} 는 0과 1사이의 값이며, \mathbf{v}_i 는 i 번째 클러스터의 중심값이다. $p \in [1, \infty]$ 은 퍼지화 계수이다.

d_{ij} 는 i 번째 클러스터의 중심과 j 번째 데이터 사이의 거리로써 식(3)처럼 정의되는 정규화된 유clidean 거리를 사용한다.

$$d_{ij} = \| \mathbf{v}_i - \mathbf{x}_j \| = \sqrt{\sum_{l=1}^r \frac{v_{il} - x_{il}}{\sigma_l^2}} \quad (3)$$

여기서 r 은 입력공간의 차원이며, σ_l^2 은 l 번째 변수의 분산이다.

정규화된 유clidean 거리를 사용함으로써 큰 값을 갖는 입력변수가 작은 크기를 갖는 입력변수보다 클러스터의 중심을 결정하는데 많은 영향을 미치는 것을 방지할 수 있다.

식(2)의 비용함수가 최소가 되기 위한 필요조건은 식(4),(5)와 같다

$$\mathbf{v}_i = \frac{\sum_{j=1}^n u_{ij}^p \mathbf{x}_j}{\sum_{j=1}^n u_{ij}^p} \quad (4)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ik}}{d_{kj}} \right)^{2/(p-1)}} \quad (5)$$

FCM은 식(4)과 식(5)을 더 이상 향상시키기 않을 때 까지 반복적으로 처리한다. FCM은 다음의 단계를 사용하여 소속행렬 \mathbf{U} 와 클러스터 중심 \mathbf{v}_i 를 결정한다. 식(5)는 거리에 기반하여 소속정도를 계산하며 소속정도의 합이 1이 되도록 정규화 한다. 여기서 퍼지화 계수는 정규화 정도를 결정하는 역할을 하며 $p=2$ 인 경우에 선형적으로 정규화가 된다. FCM은 다음 단계로 수행된다.

Step 1 : 식(1)을 만족하며 0과 1사이의 랜덤 값을 갖는 소속행렬 \mathbf{U} 를 초기화한다.

Step 2 : 식(4)를 이용하여 클러스터의 중심값, \mathbf{v}_i 를 계산한다.

Step 3 : 식(2)의 비용함수를 계산한다. 만약 허용오차보다 적거나 더 이상 개선되지 않으면 중단한다.

Step 4 : 식(5)를 이용하여 새로운 소속행렬 \mathbf{U} 를 구하고 Step 2를 수행한다.

2.2 FCM 기반 퍼지 뉴럴 네트워크의 구조 및 학습

Radial basis function neural networks(RBFNN)에서는 은닉층 활성함수로써 일반적으로 가우시안 함수를 사용한다. 이때 가우시안 함수의 중심점 및 폭의 결정은 매우 중요하며, 학습이나 클러스터링 알고리즘 등을 이용하여 결정할 수 있다. RBFNN의 출력은 활성함수의 값과 연결가중치의 선형결합으로써 표현될 수 있으며, 이때 연결가중치는 Gradient decent 방법이나 LSE등을 사용하여 학습시킨다[10].

제안된 FCM-FNN의 구조는 그림 1과 같다. 이 구조는 RBFNN의 변형 및 확장된 구조로써 가우시안이나 타원형

등의 특정 RBF 커널을 사용하지 않고 FCM을 사용하여 퍼지공간 분할 및 멤버쉽함수를 수행하고 후반부는 다항식 형태로 확장되었다.

FCM-FNN은 FCM을 이용하여 입력공간을 분할하기 때문에 격자분할(Grid partition)에 기반하는 퍼지모델에 발생하는 다차원문제를 해결하고 빠른 학습을 수행할수 있다. 또한 로컬모델로써 퍼지규칙의 후반부에 고차 다항식을 사용하여 적은 규칙을 가지고 정교한 모델을 구축할수 있기때문에 모델의 해석력(interpretability)을 향상시킬수 있다는 장점이 있다[16].

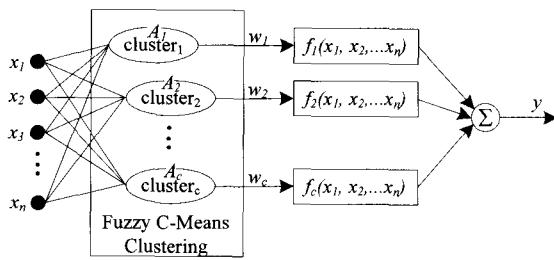


그림 1 FCM 기반 퍼지 뉴럴 네트워크의 구조

Fig. 1 Architecture of FCM based Fuzzy Neural Networks

FCM-FNN은 전반부와 후반부로 구성이 되어 있다. FCM은 전반부에 해당한다. 클러스터의 수는 퍼지규칙의 수가 되며 각 데이터의 소속정도는 각 규칙에 대한 적합도로써 사용된다. 다시 말하면 FCM 알고리즘에 의하여 입력공간의 분할 및 각 입력공간에서 멤버쉽값들이 결정된다. 후반부는 각 퍼지공간에서의 로컬모델을 의미하며 다항식 구조를 갖는다. FCM-FNN은 식(6)처럼 표현되며 후반부 다항식으로써 식(7)~(10)처럼 4가지 형태를 고려한다. RBFNN은 후반부가 식(7)처럼 상수값을 갖는 형태이다.

$$R^j: \text{IF } x_1, \dots, x_n \text{ is } A_j \text{ THEN } y_j = f_j(x_1, \dots, x_n) \quad (6)$$

Type 1 : 간략식(상수형)

$$f_j(x_1, x_2, \dots, x_n) = a_{j0} \quad (7)$$

Type 2 : 선형식

$$f_j(x_1, \dots, x_n) = a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n \quad (8)$$

Type 3 : 2차식

$$\begin{aligned} f_j(x_1, \dots, x_n) &= a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n \\ &+ a_{j(n+1)}x_1^2 + \dots + a_{j(2n)}x_n^2 \\ &+ a_{j(2n+1)}x_1x_2 + \dots + a_{j((n+2)(n+1)/2)x_{n-1}x_n} \end{aligned} \quad (9)$$

Type 4 : 변형된 2차식

$$\begin{aligned} f_j(x_1, \dots, x_n) &= a_{j0} + a_{j1}x_1 + \dots + a_{jn}x_n \\ &+ a_{j(2n+1)}x_1x_2 + \dots + a_{j((n+2)(n+1)/2)x_{n-1}x_n} \end{aligned} \quad (10)$$

FCM-FNN의 학습은 크게 전반부 멤버쉽함수의 학습과 후반부 다항식의 학습부분으로 구성된다. 전반부 멤버쉽 함수는 삼각형이나 가우시안 형태 등의 특정 형태를 사용하지 않고 FCM 알고리즘을 통하여 멤버쉽값이 결정된다.

식(6)에서 식 A_j 는 j 번째 클러스터(규칙)를 의미하며, 이 때 소속정도는 식(5)의 다른 표현인 식 (11)으로부터 구해진다.

$$\mu(A_j) = \omega_j = \frac{1}{\sum_{k=1}^c \left(\frac{\|\mathbf{x} - \mathbf{v}_j\|}{\|\mathbf{x} - \mathbf{v}_k\|} \right)^{\frac{2}{p-1}}} \quad (11)$$

여기에서 $j = 1, \dots, c$, c 는 규칙수이며, $\mathbf{x} = [x_1 \dots x_n]$, n 은 입력 변수의 수, \mathbf{v}_j 는 j 번째 클러스터의 중심벡터, p 는 퍼지화 계수이이다. 멤버쉽 값은 클러스터의 중심으로부터 거리가 가까울수록 커지며 다른 클러스터의 중심에 영향을 받는다.

FCM-FNN 모델은 출력은 식(12)처럼 구해진다.

$$\hat{y} = \sum_{j=1}^c w_j f_j(x_1, \dots, x_n) \quad (12)$$

후반부 다항식의 학습은 최소 자승법에 의하여 수행되며 식(13)처럼 구해진다.

$$\hat{\mathbf{a}} = (\Theta^T \Theta)^{-1} \Theta^T \mathbf{Y} \quad (13)$$

후반부 다항식이 선형인 경우 각 변수는 다음처럼 정의된다.

$$\hat{\mathbf{a}} = [a_{10} \dots a_{n0} \ a_{11} \dots a_{n1} \dots a_{1k} \dots a_{nk}]^T,$$

$$\Theta = [\Theta_1 \ \Theta_2 \ \dots \ \Theta_m]^T$$

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

$k = 1, \dots, n, m$ 은 데이터의 수이다.

3. FCM 기반 퍼지 뉴럴 네트워크의 최적화

3.1 계층적 공정 경쟁 기반 병렬 유전자 알고리즘

GA는 유전학과 자연환경에서 일어나는 진화원리와 적자생존의 법칙을 모방하여 만들어낸 최적화 알고리즘으로써 다차원의 해의 탐색 능력이 뛰어나며, 현재 많은 응용분야에 적용되고 있는 실정이다. 하지만, 단순 유전자 알고리즘은 염색체들의 다양성이 결여되어 모든 개체들이 최적의 해가 아닌 일정지역의 부분 최적해 안으로 수렴하게 되는 조기 수렴 문제를 내포한다. 이러한 현상은 높은 차수 문제(high-dimensionality problems)와 다봉성을 가진 문제(multi-modal problems)에 있어서 더욱 많이 발생한다[6].

이러한 조기 수렴을 억제하고 전역해를 찾기 위한 해결방안으로써 여러 개의 집단을 사용하여 집단 간의 개체가 이주하는 구조를 갖는 병렬유전자 알고리즘(Parallel genetic algorithm; PGA)[5,6]이 많이 연구되고 있다. PGA는 기존 GA의 단일 집단을 여러 개의 집단으로 나누어 격리시키고, 서로 격리된 각 집단이 독립적인 환경에서 진화해가면서 일정 세대 간격으로 개체들이 이주를 하는 알고리즘이다.

HFCPGA는 사회적 교육 시스템에서 동등 수준을 가진 그룹으로 나누어 학습에 대한 경쟁을 하며, 우수한 인재는 상위 그룹으로 진급하는 체계를 PGA에 적용한 것으로써, PGA의 수행과정에서 각 개체들을 적합도별로 나누어 경쟁을 시킴으로써 공정한 경쟁을 통해 처음 생성된 낮은 수준의 개체가 개선될 기회도 없이 탈락하는 경우를 방지한다. 낮은 수준의 개체도 다음 세대에서 높은 성능을 갖는 개체로 진화하면, 그 수준에 맞는 집단으로 바로 이동할 수 있다. 이와 같은 원리를 통해서 항상 아래 수준의 집단으로부

터 높은 수준의 개체가 올라올 수 있는 통로를 만들어 놓음으로써, 조기 수렴을 최대로 방지할 수 있다.

HFCPGA는 여러 개의 집단이 계층적으로 구성되어 교배율, 돌연변이율, 진화연산자 및 개체의 수 등을 다르게 설정함으로써 각 집단이 서로 다른 환경에서 독립적으로 진화한다. 각 집단은 특정 범위의 적합도를 갖는 개체들로 구성되어 있고, 하위 수준의 집단으로부터 개체의 진입을 위한 문턱적합도를 갖고 있다. 그리고 진화과정은 기존의 GA와 비슷하지만 이주과정이 있다는 것이 다른 점이다. 그림 2는 HFCPGA의 이주 구조를 보여주며 화살표는 개체들의 이동 가능한 방향을 의미한다. 개체들은 상위 집단으로만 이동할 수 있으며 하위 집단으로는 이동하지 않는다. HFCPGA에서 이주과정은 정해진 일정한 세대 간격마다 수행하게 된다. 이주과정의 단계는 다음과 같다.

[Step 1] 각각의 집단 개체들의 적합도를 정규화한다.

$$nf_{j,i} = f_{j,i}/f_{\max} \quad (14)$$

$f_{j,i}$ 는 j 번째 집단(deme)의 i 번째 개체 적합도, f_{\max} 는 전체 집단의 최대 적합도

[Step 2] 정규화된 적합도를 정해진 문턱적합도들과 비교하여 적합도 수준에 맞는 임시버퍼(Admission buffer)에 개체들을 저장한다.

[Step 3] 각각의 임시버퍼에 저장된 개체들과 해당하는 집단의 낮은 수준의 개체들을 바꾸어준다. 그리고 최하위 수준의 집단은 개체들의 다양성을 유지하기 위해 모든 개체들을 랜덤하게 다시 생성한다.

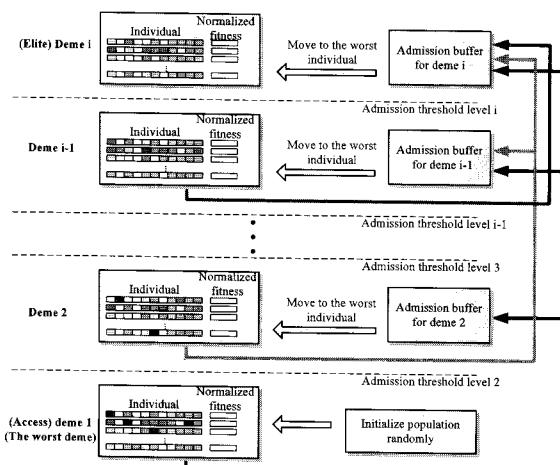


그림 2 HFCPGA의 이주구조

Fig. 2 The migration topology of HFCPGA

3.2 HFCPGA에서 염색체 구성 및 진화 연산자

FCM-FNN은 FCM과 LSE에 의하여 학습되어 비교적 우수한 성능을 보이지만 퍼지 규칙의 수(FCM에서 클러스터의 수), 적절한 입력변수의 선택, 후반부 다항식의 차수 그리고 퍼지화 계수의 설정에 따라 많은 성능차이를 보이며 최적화 할 필요성이 있다.

퍼지 규칙의 수는 전반부 입력공간의 분할 수와 관련되며, 퍼지화 계수는 분할된 공간들의 overlapping되는 영역을 조절하는 역할을 한다. 후반부 다항식의 형태는 각 분할된 영

역에서 로컬모델로써 어떤 함수를 사용할지에 관련되어 매우 중요한 요소들이다. 또한 적절한 입력변수를 선택함으로써 주어진 모든 입력변수를 사용하지 않고 시스템 모델링에 영향력 있는 변수만을 선정(or 악영향을 미치는 입력변수를 제거)함으로써 다변수 시스템에서 모델을 더욱 간단하게 하고 성능을 향상시킬 수 있다.

본 논문에서는 FCM-FNN 모델의 구조에 관련된 입력변수 선택, 퍼지 규칙 수 그리고 후반부 다항식의 차수와 파라미터에 관련하여 퍼지화 계수를 HFCPGA를 사용하여 최적화 한다.

입력변수	입력변수	...	입력변수	사용할 입력변수의 수	퍼지 규칙 수	후반부 다항식 차수	퍼지화 계수
부분사상교배 상호돌연변이						산술교배 균등 돌연변이	
예 1 1 6 2 5 3 4 1.92 4.65 2.12 2.97						선택된 입력변수 : 1, 6 번째 2개의 입력변수 퍼지 규칙 수 : 5 개 후반부 다항식 차수 : Type 2 (선형) 퍼지화 계수 : 2.97	
예 2 2 4 3 1 5 6 4.11 7.57 3.21 1.52						선택된 입력변수 : 2, 3, 3, 1 번째 4개의 입력변수 퍼지 규칙 수 : 8 개 후반부 다항식 차수 : Type 3 (2차식) 퍼지화 계수 : 1.52	

그림 3 HFC-PGA에서 염색체 구성 및 해석

Fig. 3 Chromosomal composition of HFCPGA and interpretation

그림 3에 FCM-FNN의 최적화를 위한 염색체의 구성 및 염색체의 해석 예를 보인다. 선택할 입력변수, 사용할 입력변수의 수, 퍼지 규칙의 수, 후반부 다항식의 차수 그리고 퍼지화 계수에 대한 정보를 갖는 서브염색체로 구성이 되어 있으며 염색체의 길이는 주어진 전체 입력변수의 수+4이다. 여기에서 입력변수의 선택에 대한 부분은 정수로 표현되는 기호코딩방식을 사용하고 나머지 네 개의 서브염색체는 실수로 표현되는 실수코딩 방식을 사용한다. 교배와 돌연변이 연산시 기호코딩에 관련된 염색체부분의 값들은 서로 중복이 되지 않도록 순회판매원문제(traveling salesman problem : TSP)의 적용을 위해 제시된 부분사상교배(partially mapped crossover : PMX)연산자와 상호돌연변이(Reciprocal mutation)방법을 사용하였고, 실수코딩관련 염색체들은 산술교배 (Arithmetical crossover: AX)와 균등 돌연변이(uniform mutation)를 사용하였다. 염색체의 해석 시에 선택할 염색체의 수, 퍼지 규칙수, 후반부 다항식 차수는 정수화 하여 사용하고, 입력변수는 선택할 입력변수의 수에 해당하는 만큼 앞에서부터 사용한다.

4. 실험 및 고찰

FCM-FNN 모델의 성능분석을 위하여 수학적 예제와 가스로 데이터에 적용하였다. 시뮬레이션은 Matlab을 사용하여 수행하였다. FCM-FNN 모델의 최적화에 사용된 HFCPGA에 관련한 파라미터는 표 1에 상세하게 설명하였다. 각 집단에서 서로 다른 환경을 조성하기 위해 교배율을 다르게 설정하였다. 맨 앞의 값은 최하위 집단의 값이며 맨 뒤의 값은 최상위 집단의 값을 의미한다.

성능지수로써 식(15)처럼 mean square error(MSE)를 사용하였다.

$$PI \text{ (or } MSE) = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (15)$$

표 1 HFCPGA에서 파라미터의 요약
Table 1 Summary of the parameters of HFCPGA

HFCPGA 파라미터	
세대 수	300
집단수	6
각 집단의 개체수	[30 30 30 30 30 30]
각 집단에서의 교배율	[0.9 0.85 0.75 0.65 0.65 0.65]
각 집단에서의 돌연변이율	[0.1 0.1 0.1 0.1 0.1 0.1]
이주 주기	20세대
탐색 범위	
선택할 입력변수 수	실험 4.1 경우 : 2 실험 4.2 경우 : 1 ~ 2
후반부 다항식 차수	1 ~ 4 (Type 1 ~ Type 4)
퍼지화 계수(p)	1.0 ~ 4.0

4.1 수학적 예제 1

식(16)처럼 2입력 변수를 갖는 수학적 함수에 대하여 적용하였다

$$y = 1.9 \left(1.35 e^{x_2} e^{-x_1} \sin(12(x_2 - 0.6)^2) \sin(7x_1) \right), \quad 0 \leq x_1, x_2 \leq 1 \quad (16)$$

식(16)의 함수로부터 100개의 데이터를 랜덤하게 발생시켜 학습 데이터로써 사용하였으며, 2차원에 대하여 0.02 간격의 교차점을 테스트 데이터로써 사용하였다. 표 1의 파라미터를 갖는 HFCPGA를 사용하여 최적화 하였다. 이 경우에는 입력 변수가 2개이기 때문에 입력변수는 2개 모두 사용하도록 설정하였다. HFCPGA 결과 퍼지 규칙 수는 9개, 후반부 다항식 차수는 식(9)와 같은 2차식, 퍼지화 계수(p)는 1.9076으로 최적화 되었다. 이때 학습 데이터에 대한 성능지수(PI)는 0.00199, 테스트 데이터에 대한 성능지수(EPI)는 0.07158이다. 그림 4에는 FCM을 통하여 분할된 영역과 각 영역에서 멤버쉽 값을 보인다.

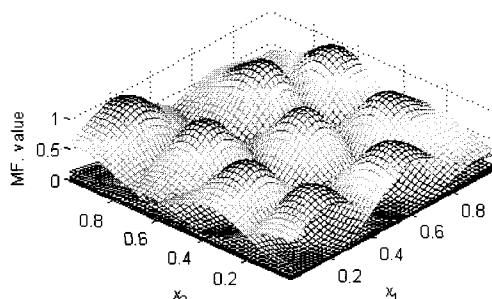


그림 4 FCM에 의한 공간 분할 및 멤버쉽 값
Fig. 4 Space division and membership value through FCM

그림 5(a)는 식(9)에 대한 함수의 출력과 100개의 학습 데이터이며, 그림 5(b)는 제안된 방법에 의하여 최적화된 FCM-FNN 모델의 출력이다. 그림 5를 통하여 제안된 방법은 복잡한 비선형 특성을 갖는 플랜트를 잘 묘사할 수 있음을 볼 수 있다.

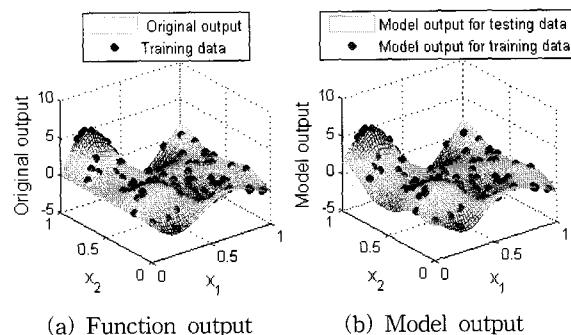


그림 5 실제 출력과 모델 출력
Fig. 5 Original output and model output

4.2 가스로 데이터에 대한 실험

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

시뮬레이션 결과 입력변수는 $u(t-3)$, $y(t-1)$ 가 선택되었으며, 퍼지규칙 수는 6개, 후반부 다항식은 2차식(Quadratic) 그리고 퍼지화 계수(p)는 1.098이 선택되었다. 이때 학습 데이터에 대한 성능(PI)은 0.0149, 테스터 데이터에 대한 성능(EPI)은 0.283이다. 그림 6은 FCM을 통하여 분할된 영역과 각 영역에서 멤버쉽 값을 보인다. 각 분할 영역사이에서 멤버쉽함수의 overlapping 영역이 그림4보다 적음을 볼 수 있으며, overlapping 영역은 퍼지화 계수를 통하여 조절된다.

그림 7에는 학습 데이터와 평가 데이터에 대하여 실제 출력과 모델 출력의 비교를 보인다. 학습 데이터에 대하여 출력은 거의 일치하지만 평가 데이터에 대하여 약간의 오차가 존재한다. 표 2에서는 다른 모델들과의 성능 비교표를 보인다.

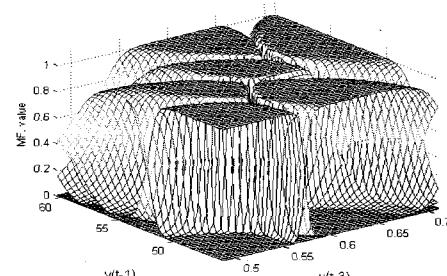


그림 6 FCM에 의한 공간 분할 및 멤버쉽 값
Fig. 6 Space division and membership value through FCM

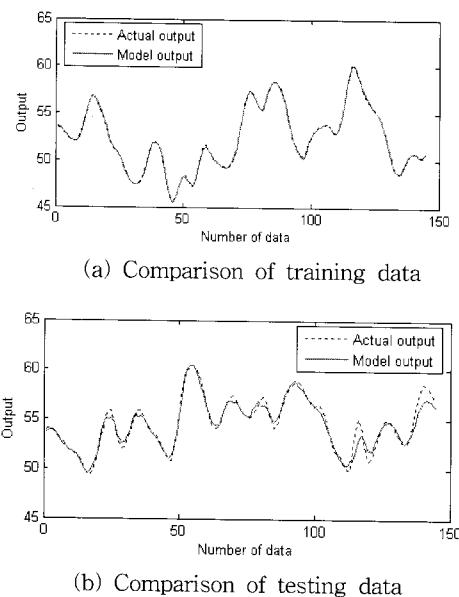


그림 7 실제 출력과 모델 출력의 비교

Fig. 7 Comparison of actual output and model output

표 2 다른 모델과의 성능비교 (성능지수 : MSE)

Table 2 Comparison of other model (Performance Index : MSE)

모델	규칙수	PI	EPI
SVR(SVM)	X	0.023	1.028
Neural Networks	15 (node)	0.018	0.411
Fuzzy model[4]	8	0.020	0.333
George's Model[14]	7	0.022	0.266
Our Model	6	0.015	0.283

5. 결 론

본 논문에서는 FCM-FNN를 제안한다. 이 구조는 RBFNN의 변형 및 확장된 구조로써 전반부에 FCM을 사용하고 후반부는 로컬모델로써 다양한 형태의 다항식으로 구성될 수 있다. FCM은 퍼지공간을 분할하여 멤버쉽함수를 결정하고 LSE를 사용하여 후반부 다항식의 계수를 추정한다. 또한 계층적 공정 경쟁기반 병렬 유전자 알고리즘을 사용하여 모델구축에 사용할 의미 있는 최적의 입력변수를 선택하고, 퍼지공간의 수, 후반부 다항식차수 그리고 멤버쉽함수의 형태를 결정하는 퍼지화 계수를 최적화 한다.

제안된 FCM-FNN은 FCM을 사용하여 입력 공간 분할과 멤버쉽함수를 결정한다. 그렇기 때문에 복잡한 다변수 시스템의 모델링에 적합하고 입력 데이터의 분포에 따라 멤버쉽함수가 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(교육인적자원부)의 재원으로 한국학술진흥재단의 지원을 받아 수행된 연구임 (KRF-2007-313-D00710).

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. Pedrycz 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] A. Staiano, J. Tagliaferri, W. Pedrycz, "Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering," Neurocomputing, Vol. 69, pp. 1570-1581, 2006
- [11] F. Behloul, R.P.F. Lelieveldt, A. Boudraa, J.H.C. Reiber, "Optimal design of radial basis function neural networks for fuzzy-rule extraction in high dimensional data", Pattern Recognition Vol. 35, pp. 659-675, 2002

- [12] J.C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms," Plenum, New York, 1981
- [13] J.C. Bezdek, J. Keller, R.Krisnapuram, N.R. Pal, "Fuzzy Models and Algorithms for Pattern Recognition and Image Processing," Kluwer Academic Publisher, Dordrecht, 1999
- [14] George E. Tsekouras, "On the use of the weighted fuzzy c-means in fuzzy modeling," Advances in Engineering Software, Vol. 36, pp. 287-300, 2005
- [15] S.K. Oh, W. Pedrycz, "A new approach to self-organizing multi-layer fuzzy polynomial neural networks based on genetic optimization," Advanced Engineering Informatics, Vol. 18, pp. 29-39, 2004
- [16] L.J. Herrera, H.Pomares, I.Rojas, "Tase, a Taylor series-based fuzzy system model that combines interpretability and accuracy," Fuzzy Set and systems. Vol. 153, pp. 403-427, 2005



김 현 기 (金 賢 起)

1985년 : 동 대학원 전기공학과 졸업(공학석사). 1991년 : 동 대학원 졸업(공학박사). 1997년~현재 : 경기지역 산학연 기술지원단 단장 1998년~현재 : 산업기술정책 연구소 심의위원. 2000년~현재 : 사단법인 산학연 협소사업 전국협의회 회장. 1989년~현재 : 수원대학교 전기전자정보통신공학부 교수. 관심분야 : 시스템자동화 및 감시제어, 지능형모델링 및 제어 등.
Tel : (031) 220-2300
E-mail : hkkim@suwon.ac.kr

저 자 소 개



최 정 내 (崔 正 乃)

1997년 : 원광대 제어계측과 졸업. 1999년 : 동 대학원 제어계측과 졸업(공학석사). 2004년 : 동 대학원 전기공학과 졸업(공학박사). 2006년~2007 : 수원대학교 전기공학과 Post-Doc. 관심분야 : PID제어, 지능 제어, 최적화 기법, 퍼지이론, 신경망 이론 등.

Tel : (031) 222-6544

E-mail : cjn9828@gmail.com



오 성 권 (吳 聖 權)

1983년 : 연세대학원 전기공학과 졸업(공학석사). 1983~1989년 : 금성산전연구소(선임연구원). 1993년 : 연세대 대학원 전기공학과 졸업(공학박사). 1996~1997년 : 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1993~2005년 : 원광대 전기전자 및 정보공학부 교수 2005년~현재 : 수원대 전기공학과 교수. 2002년~현재 : 대한전기학회, 퍼지및지능시스템학회 및 제어자동화시스템 공학회 편집위원. 관심분야 : 시스템 자동화, 퍼지이론, 신경회로망 응용 및 제어, 컴퓨터 지능 등.

Tel : (031) 229-8162

E-mail : ohsk@suwon.ac.kr