

공간탐색 진화알고리즘을 이용한 Interval Type-2 pRBF 뉴럴 네트워크의 구조적 해석

Architectural Analysis of Type-2 Interval pRBF Neural Networks Using Space Search Evolutionary Algorithm

오성권¹ · 김옥동 · 박호성 · 이영일

Sung-Kwun Oh, Wook-Dong Kim, Ho-Sung Park and Young-Il Lee

수원대학교 전기공학과

요 약

본 논문에서는 RBF 뉴럴 네트워크에서 은닉층 활성화함수에 Interval type-2 퍼지개념을 적용한 새로운 RBF 뉴럴 네트워크를 설계하였다. 퍼지 시스템 분야에서 불확실한 정보에 대한 Type-1 퍼지집합의 성능을 보완하고자 Type-2 퍼지집합이 제안되었으며, 멤버쉽함수 안에 다시 멤버쉽함수를 생성함으로써 불확실한 정보를 좀 더 효과적으로 다루고자 하였다. 따라서 본 논문에서는 RBF 뉴럴 네트워크의 은닉층 활성화함수에 type-2 퍼지집합의 개념을 적용하여 불확실한 정보에 대한 모델 성능을 개선하고자 하였다. 나아가 연결가중치를 상수항이 아닌 1차식으로 구성된 다항식을 사용하여 최종출력을 입력-출력의 관계식으로 표현하였다. 연결가중치는 기존의 경사하강법(Gradient Descent Method; GDM) 대신 conjugate gradient method(CGM)을 사용하여 파라미터를 동조하고, 은닉층의 활성화함수는 공간탐색 진화 알고리즘(Space Search Evolutionary Algorithm; SSEA)을 이용하여 가우시안 함수의 중심점 및 분포상수를 동조하여 모델의 성능을 개선시킨다. 제안된 모델의 성능을 평가하기 위해 가스로 시계열 데이터를 사용하였으며, 결과를 기존 모델과 비교하였다.

키워드 : Interval type-2 퍼지집합, 공간탐색 진화 알고리즘, RBF 뉴럴 네트워크, Conjugate Gradient Method

Abstract

In this paper, we proposed Interval Type-2 polynomial Radial Basis Function Neural Networks. In the receptive field of hidden layer, Interval Type-2 fuzzy set is used. The characteristic of Interval Type-2 fuzzy set has Footprint Of Uncertainty(FOU), which denotes a certain level of robustness in the presence of un-known information when compared with the type-1 fuzzy set. In order to improve the performance of proposed model, we used the linear polynomial function as connection weight of network. The parameters such as center values of receptive field, constant deviation, and connection weight between hidden layer and output layer are optimized by Conjugate Gradient Method(CGM) and Space Search Evolutionary Algorithm(SSEA). The proposed model is applied to gas furnace dataset and its result are compared with those reported in the previous studies.

Key Words : Interval Type-2 퍼지집합, 공간탐색 진화 알고리즘, RBF 신경회로망, Conjugate Gradient Method

1. 서 론

최근 시스템 모델링의 문제는 최적화 기술과 함께 다양한 분야에서 폭넓게 연구되어지고 있다[1-2]. 이러한 연구 중에서, 선형 또는 비선형 미분 방정식에 기반을 둔 정량적

인 수학적 모델과 인공지능의 영역에서 나타나는 정성적 특징을 가진 지능형 모델은 시스템 모델링을 위한 대표적인 기술이다. 시스템 모델링과 이를 위한 동정의 근본적인 목적은 물리적 현상의 특징을 적절하게 반영할 수 있는 모델을 개발하는 것이다. 기존 모델링의 대부분은 미분 또는 차분 방정식의 언어에서 표현되어진 선형 또는 비선형 함수의 형태로 수학적 모델을 이끌어 냈다. 그러나 정교한 수학적 모델이 거의 완벽하게 시스템을 표현할 수 있다하더라도 그것은 시스템 동작과 변수 사이의 종속관계에 대한 원하는 정보를 제공하지 못한다. 또한 모델링을 하고자 하는 시스템이 복잡하고, 대규모 구조인 경우는 함수식으로 모델의 표현이 한정되지 않기 때문에 적용하기가 어렵다. 이러한 문제와 어려움을 해결하기 위해 퍼지 모델[3], 신경회로망[4]과 같은 지능형 모델에 관한 연구가 진행되었으며, 최근에는 이러한 모델들의 최적화를 통해 모델이 가지고 있는 독특한 특성을 살리면서 지능 모델의 효율과 성능 향상을 최대한 이끌어 내는 연구가 활발히 진행되어지고 있다[5].

접수일자 : 2010년 10월 21일

완료일자 : 2010년 12월 22일

*본 논문은 본 학회 2010년도 추계학술대회에서 선정된 우수논문입니다

¹ 교신저자

*본 연구는 중소기업청에서 지원하는 2010년도 산학연 공동 기술개발사업(No. 00043125)의 연구수행으로 인한 결과물임을 밝힙니다 그리고 2010년도 정부(과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2010- D00065).

Zadeh의 퍼지 집합에 기초로 하여 Mendel에 의해 type-2 퍼지 집합이 제안되었으며[6], Type-2 퍼지 논리 시스템은 기존의 type-1 보다 불확실한 정보를 세분화 된 멤버쉽 함수로 표현함으로써 불확실성을 효과적으로 다룰 수 있다. Type-2 퍼지 논리 집합은 Mendel에 의해 General type 과 Interval type으로 세분화 되었다. 본 연구에서는 은닉층 활성화함수에 type-2 interval 멤버쉽 함수를 사용하여 은닉층을 구성한다. 또한 연결가중치 및 은닉층 활성화함수의 중심점과 분포상수를 Conjugate Gradient Method(CGM)을 적용하여 성능을 최적화한다.

은닉층의 활성화함수에 필요한 학습률과 FOU(Footprint Of Uncertain)같은 초기 파라미터를 찾기 위해 공간탐색 진화 알고리즘(Space Search Evolutionary Algorithm)을 이용한다.

2. Interval Type-2 pRBF 신경 회로망

2.1 Interval Type-2 pRBF 신경 회로망의 구조

Interval Type-2 pRBF 뉴럴 네트워크의 구조는 기존의 RBF 신경 회로망[7]과 동일하며, 차이점은 은닉층의 활성화 함수에 type-2 퍼지 집합을 적용하였으며, 은닉층과 출력층 사이에 Karnik and Mendel(KM) 알고리즘을 적용하여 type-2를 type-1으로 줄여주는 type reduction 역할을 수행한다. 제안된 모델의 구조는 그림1과 같다.

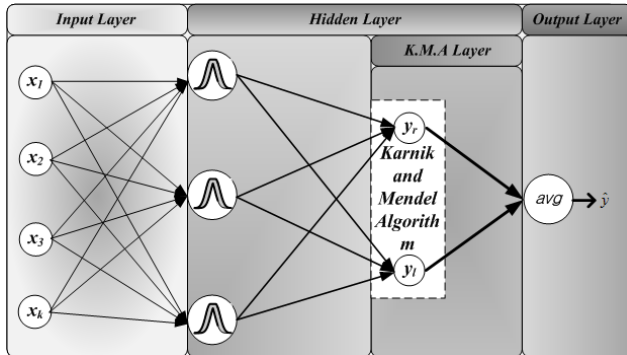


그림 1. Interval Type-2 pRBF 신경회로망 구조
Fig. 1. Architecture of Interval Type-2 pRBF NNs

활성함수는 가우시안 함수를 사용하였으며, 그림 2과 같이 나타낼 수 있다. $h_i (i=1, \dots, n)$ 는 은닉층 노드수를 나타내며, $x_j (j=1, \dots, k)$ 는 입력변수의 수를 나타내며, $m_{1j}, m_{2j}, \sigma_{1j}, \sigma_{2j}$ 은 각각 중심점과 분포상수를 나타낸다. 활성화 함수의 출력은 $upper[\bar{w}_i]$ 값과 $lower[w_i]$ 값으로 표현된다. 중심점 및 분포상수는 기존의 RBF 뉴럴 네트워크의 값을 가지고 $\pm FOU\%$ 를 연산하여 $m_{1j}, m_{2j}, \sigma_{1j}, \sigma_{2j}$ 파라미터의 초기값을 설정해준다.

활성함수의 출력을 구한 다음, Karnik and Mandel[1]이 제안한 KM 알고리즘과 퍼지추론 방법을 이용하여 최종출력을 구할 수 있다. 식(1)은 모델의 최종 출력식이며, y_r, y_l 의 평균값으로 구해진다.

$$\hat{y} = \frac{y_r + y_l}{2} \quad (1)$$

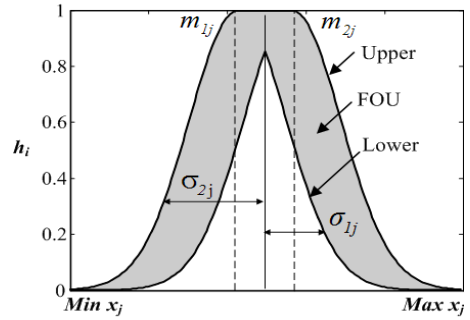


그림 2. 은닉층의 Interval-type2 활성화함수
Fig 2. Interval-type2 receptive field of hidden layer

$$y_r = \frac{\sum_{i=1}^R y_r^i w_i + \sum_{i=R+1}^n y_r^i \bar{w}_i}{\sum_{i=1}^R w_i + \sum_{i=R+1}^n \bar{w}_i} \quad (2)$$

$$y_l = \frac{\sum_{i=1}^L y_l^i \bar{w}_i + \sum_{i=L+1}^n y_l^i w_i}{\sum_{i=1}^L \bar{w}_i + \sum_{i=L+1}^n w_i} \quad (3)$$

여기서, L, R 은 KM 알고리즘으로 구한 upper와 lower 값의 스위치 포인트이다.

$$y_r^i = \sum_{j=1}^k c_j^i x_j + c_0^i + \sum_{j=1}^k |x_j| s_j^i + s_0^i \quad (4)$$

$$y_l^i = \sum_{j=1}^k c_j^i x_j + c_0^i - \sum_{j=1}^k |x_j| s_j^i - s_0^i \quad (5)$$

식(4-5)에서 c_j 는 연결가중치의 값이며, s_j 는 연결가중치의 간격을 나타내는 구간 계수가 된다. 연결가중치 계수는 랜덤하게 임의의 구간 안에서 생성하거나, 일반적인 RBF 신경회로망에서 가져오게 된다. 논문에서는 일반적인 RBF 신경회로망의 연결가중치 계수를 사용하였다.

그리고 $m_{1j}, m_{2j}, \sigma_{1j}, \sigma_{2j}, c_j, s_j$ 와 같은 파라미터를 경사 하강법과 유사한 Conjugate Gradient Method(CGM)을 사용하여 학습을 통해 모델의 성능을 개선시켰다.

2.2 Karnik and Mendel(KM) 알고리즘

활성함수의 출력(적합도)와 연결가중치를 가지고 식(1)의 최종 출력을 구하게 된다. 이때 type reduction이 요구되며, 논문에서는 Karnik and Mendel이 제안한 KM 알고리즘을 사용하여 모델의 최종 출력을 구한다. KM 알고리즘[6] 과정은 아래와 같다.

[step 1] 먼저 y_l^i 을 오름차순으로 $y_l^1 < y_l^2 < \dots < y_l^h$ 정렬한다. 정렬된 인덱스 번호를 기준으로 **Upper**와 **Lower** 적합도로 다시 정렬한다.

[step 2] 정렬된 **Upper**와 **Lower** 적합도의 평균을 이용하여 Type-1 형태의 적합도로 환산한다.

$$w^j = \frac{w_j + \bar{w}_j}{2} \quad (6)$$

그리고 나서 환산된 적합도 w^j 와 y_l^j 을 이용하여 출력 y_l' 을 계산한다.

$$y_l' = \frac{w^j \times y_l^j}{\sum_{j=1}^h w^j} \quad (7)$$

[step 3] 다음 식을 만족하는 스위칭 포인트 $p(1 \leq p < h-1)$ 를 찾는다.

$$y_l^p \leq y_l' \leq y_l^{p+1} \quad (8)$$

[step 4] 스위칭 포인트를 기준으로 *Upper*와 *Lower*의 적합도 위치를 서로 바꾼다.

$$w^j = \begin{cases} w_j, & j \leq p \\ w_j, & j > p \end{cases} \quad (9)$$

식(9)의 적합도를 가지고 한번 더 출력을 구하며 이 때의 출력은 y_l'' 으로 놓는다.

$$y_l'' = \frac{w^j \times y_l^j}{\sum_{j=1}^h w^j} \quad (10)$$

[step 5] 식(7)과 식(10)이 같으면, y_l'' 이 최종출력이 되고 알고리즘을 종료한다. 그렇지 않으면, step 6으로 이동한다.

[step 6] $y_l' = y_l''$ 을 놓고 step 3으로 이동하여 알고리즘을 반복 수행한다.

2.3 Interval Type-2 pRBF 신경 회로망 학습

파라미터를 학습시키기 위해서 실제출력과 모델출력사이의 오차를 이용한 Back-Propagation을 사용한다. 그리고 학습 가능한 파라미터에 대한 오차의 기울기를 계산하기 위해 경사하강법이 대표적으로 사용된다. 하지만 경사하강법은 수렴속도가 느리며, 지역해에 빠질 가능성이 높다. 경사하강법(Gradient Descent Method; CDM)의 문제점을 개선시키고자 공액경사법(Conjugate Gradient Method; CGM)[8]을 사용하여 파라미터를 학습시킨다. 경사하강법은 현재의 기울기(경사벡터)로 탐색방향을 결정하지만, 공액경사법은 과거의 탐색방향(방향벡터)과 현재의 기울기(경사벡터)를 동시에 고려하여 탐색방향(방향벡터)을 결정하게 된다. 식(6)은 실제출력과 모델출력사이의 오차를 구하는 식이며, 이를 미분하여 경사벡터 및 방향벡터를 결정함으로써 다음세대의 파라미터를 생성한다. 이 과정을 반복하여 오차가 최소가 되도록 학습한다.

$$Error(E) = \frac{1}{2}(y - \hat{y})^2 \quad (6)$$

여기서, y 는 실제출력이며, \hat{y} 는 모델출력이다.

오차를 미분한 각각의 파라미터의 경사벡터로 계산된 방향벡터는 식(7)과 같다.

$$D(t) = -G(t) + \beta(t)D(t-1) \quad (7)$$

여기서, $G(t)$ 는 현재세대의 경사벡터이며, $D(t)$ 는 현재세대의 방향벡터가 되고, $D(t-1)$ 는 이전세대의 방향벡터를 나타낸다. $\beta(t)D(t-1)$ 부분이 경사하강법과 공액경사법의 차이점이 되며, $\beta(t) = 0$ 이 되면 경사하강법의 방향벡

터가 된다.

$\beta(t)$ 는 3가지 공식을 사용하여 구할 수 있으며, 논문에서는 Fletcher-Reeves 공식을 사용하였다.

$$Fletcher-Reeves : \beta(t) = \frac{G(t)^T G(t)}{G^T(t-1) G(t-1)} \quad (8)$$

$$Polak-Ribiere : \beta(t) = \frac{G(t)^T (G(t) - G(t-1))}{G^T(t-1) G(t-1)} \quad (9)$$

$$Beale-Sorenson : \beta(t) = \frac{G(t)^T (G(t) - G(t-1))}{D^T(t-1) (G^T(t) - G(t-1))} \quad (10)$$

$\beta(t)$ 가 $\beta(t) > 1$ 면, 모델 성능이 불안정한 문제점이 발생하므로, 구간을 $[0, 1]$ 로 정해준다. 따라서 $\beta(t) > 1$ 면, 임의로 0으로 바꿔주어 경사하강법의 방향벡터만 사용하여 파라미터를 학습한다.

새로운 파라미터는 다음과 같다.

$$m(t+1) = m(t) + \Delta m(t) = m(t) + \eta_1 \cdot D_m(t) \quad (11)$$

$$\sigma(t+1) = \sigma(t) + \Delta \sigma(t) = \sigma(t) + \eta_2 \cdot D_\sigma(t) \quad (12)$$

$$a(t+1) = a(t) + \Delta a(t) = a(t) + \eta_2 \cdot D_a(t) \quad (13)$$

$$s(t+1) = s(t) + \Delta s(t) = s(t) + \eta_2 \cdot D_s(t) \quad (14)$$

t 는 학습 횟수를 나타낸다. 여기서 η_1 은 중심점(m) 및 분포상수(σ)의 학습률이 되며, η_2 는 연결가중치 계수(a) 및 구간 계수(s)의 학습률이 된다. 중심점 및 분포상수는 파라미터의 탐색 공간이 제한적이기 때문에 연결가중치 계수 및 구간계수의 학습률과 별도로 설정하였다. 학습률은 heuristic rules을 사용하여 학습 횟수마다 변화 시켰다. 따라서 성능지수가 5번 연속으로 감소하면, 학습률을 10%를 증가시키며, 성능지수가 증가하면 학습률을 10% 감소시키는 방법을 사용하여 학습률을 조절하였다.

3. 공간탐색 진화 알고리즘

3.1 공간탐색 진화 알고리즘의 구조

공간 탐색 진화알고리즘(Space Search Evolutionary Algorithm; SSEA)[9]는 최근 제안된 최적화 알고리즘이다. 유전자 알고리즘과 같이 교배연산과 돌연변이 연산으로 구성된 진화 알고리즘으로 교배연산은 유전자 알고리즘과는 다른 방법으로 염색체를 생성하며, 돌연변이 연산은 유전자 알고리즘과 동일하다. 공간탐색 진화 알고리즘의 단계별 과정은 다음과 같다.

[step 1] 염색체를 주어진 공간에서 랜덤하게 생성한다.

[step 2] 생성된 염색체를 가지고 목적함수의 적합도를 평가한다.

[step 3] 평가된 적합도 중에서 가장 좋은 best fitness와 가장 나쁜 worst fitness를 판별한다.

[step 4] 전체 인구수에서 랜덤하게 M=8개의 염색체를 선택한다.

[step 5] 선택된 염색체를 교배시켜 새로운 염색체 x^{new} 을 생성한다.

$$x_i^{new} = \sum_{k=1}^M \gamma_k x_i^k, [where \sum_{k=1}^M \gamma_k = 1 (-0.5 \leq \gamma_k \leq 1.5)] \quad (15)$$

여기서, γ 는 교배 가중치로써 교배연산을 통해 새로운 염색체가 생성되는 공간의 크기를 결정한다. 따라서 사용자에게 의해 범위를 변경할 수 있다.

[step 6] 새로 생성된 염색체 x^{new} 을 가지고 적합도를 평가한다.

[step 7] 새로운 염색체의 적합도 new fitness를 worst fitness와 best fitness를 비교한다.

$$If(worst_fit > fit_new) \quad (16)$$

$$pop(x^{worst_index}) = pop(x^{new})$$

$$If(best_fit > fit_new) \quad (17)$$

$$pop(x^{best_index}) = pop(x^{new})$$

[step 8] 염색체가 교체되었으면, 다시 적합도의 best fitness와 worst fitness를 판별한다.

[step 9] best fitness의 염색체를 선택하여 돌연변이 연산을 수행한다.

[step 10] 염색체 전체의 길이에서 랜덤하게 유전자 개체를 선택하여 돌연변이 연산을 통해 새로운 유전자 개체를 생성한다.

$$x_i^{new} = rand \times (space_i^{max} - space_i^{min}) + space_i^{min} \quad (18)$$

여기서, $space$ 는 최초 주어진 탐색 공간이 된다.

[step 12] 새로 생성된 염색체를 가지고 step6 ~ step 8을 수행한다.

[step 13] 종료조건을 만족하면 프로그램을 종료하며, 그렇지 않으면 [step 4] 이동하여 반복 수행한다.

알고리즘의 단계별 과정을 순서도로 나타내면 그림 3과 같다.

SSEA는 각 세대에서 하나의 염색체만을 생성하고 평가하기 때문에 기존의 진화 알고리즘 보다 빠른 연산속도를 갖는 장점이 있다. 논문에서 제안된 모델의 경우 모델 자체적으로 BP를 이용한 학습시간이 소요되기 때문에 SSEA를 사용함으로써 기존의 진화 알고리즘을 사용할 때보다 연산 시간의 이득을 얻을 수 있다.

3.2 제안된 모델의 염색체 구조

제안된 모델에서 FOU와 학습률의 초기 설정에 따라 모델의 학습속도 및 성능이 좌우된다. 따라서 논문에서는 이 초기 파라미터를 SSEA를 이용하여 최적화 시켰다. 그림 4는 제안된 모델의 염색체 구조를 나타낸다.

그림에서 보듯이 FOU와 중심점 및 분포상수의 학습률은 은닉층의 노드 수만큼 설정해 주었다. 이는 입력변수의 분포범위를 고려하여 입력변수의 범위에 맞게 학습률을 개별적으로 설정하였다. 목적함수로는 Means Square Error(MSE)를 사용하여 목적함수가 최소가 될 때의 파라미터를 모델에 적용하였으며, MSE는 식(19)과 같다.

$$MSE = \frac{1}{N} \sum_{z=1}^N (y_z - \hat{y}_z)^2 \quad (19)$$

여기서, y_z 는 실제 출력이며, \hat{y}_z 는 모델 출력이 된다. 그리고 N은 데이터의 수를 나타낸다.

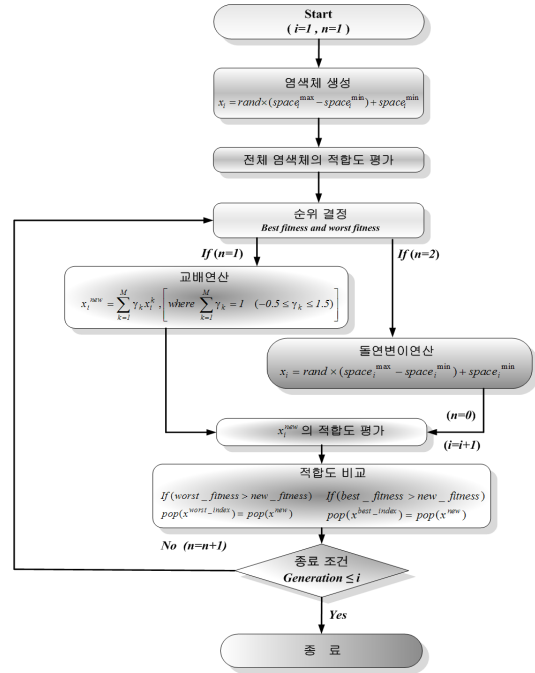


그림 3. 공간탐색 진화 알고리즘 순서도
Fig. 3. Overall flowchart of Sear Space Evolutionary Algorithm(SSEA)




그림 4. SSEA의 염색체
Fig. 4. Chromosome of SSEA

4. 실험결과 및 고찰

제안된 모델의 성능 평가를 위해서 가스로 시계열 데이터를 사용하였다. 1입력-1출력의 296개 데이터를 6입력으로 나누고 학습데이터 145개와 테스트 데이터 145개로 나누어 사용하였다. 표 1은 SSEA의 파라미터 설정 값을 나타낸다.

표 1. 파라미터 설정 값

Table 1. Parameter values

파라미터	설정값
세대 수	200
염색체 수	100
교배 연산 염색체 수(M)	8
교배 가중치 (γ)	[-0.5, 1.5]
돌연변이 개체 수	총 염색체 길이 / 2

그림 5는 SSEA의 목적함수 수렴과정을 나타낸다. 목적함수는 식(19)을 사용하여 최소값을 찾도록 최적화가 진행된다. 그림은 은닉층의 노드 수가 4개 일 때의 모델이며, 경사하강법과 공액경사법을 비교하여 나타내었다. 그림의 MSE 성능지수는 모델의 학습 횟수가 5번일 때의 값을 나

타낸다. 이는 2.3장에서 언급했듯이 모델의 학습률이 성능에 따라 변화하기 때문에 최적화 알고리즘으로는 마지막 학습 횟수에서 최적의 성능을 나타내는 파라미터를 찾아주게 된다. 그리고 선택된 파라미터 값을 가지고 모델에 다시 적용하여 학습 횟수를 500번 늘려 학습을 시킨다. SSEA로 최적화 시킬 때 모델의 학습 횟수를 500번 적용시켜도 문제는 없으나 탐색체가 최적의 파라미터가 아님을 알면서도 모델에서 500번을 학습하는 것은 불필요한 시간을 소요하게 된다. 따라서 이러한 시간문제를 개선하기 위해서 모델의 학습 횟수를 5번만 적용하게 되었다.

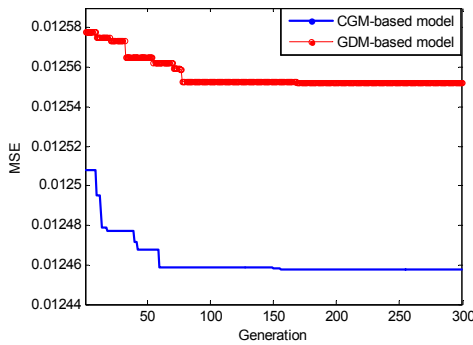


그림 5. SSEA의 세대별 MSE 수렴과정

Fig 5. Convergence process of MSE according to the increase of no. of generations in SSEA

그림에서 보듯이 공액경사법(CGM)을 적용한 모델의 성능이 더 우수함을 알 수 있다. 여기서 마지막 300세대에서의 탐색체에 저장된 파라미터를 가지고 모델에 적용하여 500번 학습을 수행하면 더욱 개선된 성능을 얻을 수 있다.

표 2는 은닉층의 노드 수를 2, 4, 6개로 설정하고 경사하강법(GDM)을 적용한 모델과 공액경사법(CGM)을 적용한 모델의 성능지수를 나타낸다. Case I는 최적화를 적용하지 않고 사용자가 임의의 파라미터를 설정한 모델이며, Case II는 SSEA로 최적화 시킨 파라미터를 적용한 모델이 된다.

표 2. 제안된 모델의 성능지수.


Table 2. Performance Index of proposed model.

No. of nodes	BP	Case	PI	EPI
2	CGM	Case I	0.0143	0.1945
		Case II	0.0142	0.1944
	GDM	Case II	0.1444	0.1980
4	CGM	Case I	0.0115	0.2194
		Case II	0.0113	0.2218
	GDM	Case II	0.0116	0.2199
6	CGM	Case I	0.0093	0.2500
		Case II	0.0092	0.2409
	GDM	Case II	0.0093	0.2407

Case I : Without optimization Case II : With optimization

표에서 보듯이 공액경사법(CGM)을 적용한 모델의 성능이 경사하강법(GDM)을 사용한 모델보다 우수함을 알 수 있다. 또한 SSEA로 초기 파라미터를 최적화 시킨 모델이

최적화를 적용하지 않은 모델 Case I보다 성능이 우수함을 확인할 수 있다. 그림 6은 공액경사법과 경사하강법의 학습 속도를 비교하여 나타낸 그림이다. 학습 횟수는 500번으로 설정하였으며, 은닉층의 노드 수가 4개와 6개일 때의 MSE 수렴곡선을 나타내었다. BP학습은 학습데이터(Training dataset)만 가지고 수행하였다. 노드 수가 4개일 때는 공액경사법의 학습속도 및 성능이 우수함을 알 수 있으며, 노드 수가 6개일 때는 성능은 비슷하지만 학습속도는 공액경사법이 빠름을 확인할 수 있다. 표 3은 기존모델의 성능지수를 정리한 표이다. 표에서 퍼지 추론 시스템(Fuzzy Inference System)보다 성능이 전체적으로 개선되었음을 알 수 있다. 퍼지 모델의 경우 입력변수를 2~3개를 사용하였다. 이는 규칙수가 입력변수에 비례하기 때문에 입력변수가 많아지면 규칙수(노드수)가 늘어나 PI의 성능을 더 개선시킬 수 있으나 모델의 구조는 복잡해지는 문제점이 있다. 하지만 제안된 모델의 경우 RBF 신경회로망을 기본 구조로 사용하여 입력변수와는 상관없이 노드수를 결정하기 때문에 동일한 구조에서 더 우수한 성능을 나타낼 수 있는 이점이 있다.



(a) Nodes 4 (b) Nodes 6

그림 6. 공액경사법과 경사하강법 비교

Fig. 6. Comparison between CGM-based model and GDM-based model

표 3. 기존모델과의 성능지수 비교.

Table 3. Comparison of performance with several models.

Models		No. of nodes	PI	EPI
<i>Oh et al.'s [10]</i>	Simplified	4	0.024	0.328
	Linear	4	0.022	0.326
		6	0.021	0.364
<i>HCM+GA FIS [11]</i>	Simplified	4	0.035	0.289
		6	0.022	0.333
	Linear	4	0.020	0.264
		6	0.022	0.236
<i>George's [12]</i>	-	7	0.022	0.236
<i>PGA FIS [13]</i>	Joint	5	0.016	0.266
	Successive	6	0.015	0.263
<i>Proposed model</i>	CGM with optimization	2	0.014	0.194
		4	0.011	0.222
		6	0.009	0.241

5. 결 론

본 논문에서는 RBF 신경회로망 은닉층 활성화함수에 type-2 퍼지 개념을 적용한 Interval Type-2 pRBF 신경회로망을 제안하였다. type-2 퍼지 개념을 적용하여 주어진 정보를 좀 더 효율적으로 처리하며, 중심점 및 분포상수와, 연결가중치 계수 및 구간 계수를 공액경사법(CGM)으로 학습시킴으로써 기존의 경사하강법보다 빠른 학습속도 및 성능을 개선시켰다. 또한 공간탐색 진화 알고리즘(SSEA)를 적용하여 모델에 필요한 초기 파라미터를 (불확실한 영역 (FOU), 활성화함수의 학습률(η_1), 연결가중치의 학습률(η_2)) 최적화시켜 최적의 성능을 갖도록 모델을 설계하였다.

참 고 문 헌

- [1] L. Zhao, Y. Yang, and Y. Zeng, "Eliciting Compact T-S Fuzzy Models Using Subtractive Clustering and Coevolutionary Particle Swarm Optimization," *Neurocomputing*, Vol. 72, No. 10-12, pp. 2569-2575, 2009.
- [2] B. Niu, Y. Zhu, X. He, and H. Shen, "A Multi-Swarm Optimizer Based Fuzzy Modeling Approach for Dynamic Systems Processing," *Neurocomputing*, Vol. 71, No. 7-9, pp. 1436-1448, 2008.
- [3] A. Kandal, L. Li, and Z. Cao, "Fuzzy Inference and Its Application to Control Systems," *Fuzzy Sets and Systems*, Vol. 48, No. 1, pp. 99-111, 1992.
- [4] Z-B. Xu, H. Q. J. Peng, and B. Zhang, "A Comparative Study of Two Modeling Approaches in Neural Network," *Neural Networks*, Vol. 17, No. 1, pp. 73-85, 2004.
- [5] L. Sanchez, I. Couso, and J. Casillas, "Genetic Learning of Fuzzy Rules Based on Low Quality Data," *Fuzzy Sets and Systems*, Vol. 160, No. 17, pp. 2524-2552, 2009.
- [6] N. N. Karnik and J. M. Mendel, "Centroid of a type-2 fuzzy set," *Information science*, Vol. 132, pp. 195-220, 2001.
- [7] Y. Y. Fu, C. J. Wu, J. T. Jeng, and C. N. Ko, "Identification of MIMO systems using radial basis function networks with hybrid learning algorithm," *Applied Mathematics and Computation*, Vol. 213, pp. 184-196, 2009.
- [8] A. Y. Al Bayati, N. A. Sulaiman, and G. W. Sadiq "A Modified Conjugate Gradient Formula for Back Propagation Neural Network Algorithm," *Journal of Computer Science*, Vol. 5, No. 11, pp. 849-856, 2009.
- [9] W. Huang, L. Ding, S. K. Oh, C. W. Jeong, and S. C. Joo, "Identification of Fuzzy Inference System Based on Information Granulation," *KSII Trans. on Internet and Information systems*, Vol. 4, No. 4, pp. 575-593, 2010.
- [10] S. K. Oh, and W. Pedrycz, "Identification of fuzzy

systems by means of an auto-tuning algorithm and its application to nonlinear systems," *Fuzzy Set and Systems*, Vol. 115, No. 2, pp. 205-230, 2000.

- [11] B. J. Park, W. Pedrycz and S. K. Oh, "Identification of fuzzy models with the aid of evolutionary data granulation," *In : IEE Proc. -Control Theory and Applications*, Vol. 148, No.5, pp. 406-418, 2001.
- [12] G. E. Tsekouras, "On the use of the weighted fuzzy C-Means in fuzzy modeling," *adv. Eng. software*, Vol. 36, 287-300, 2005.
- [13] J. N. Choi, S. K. Oh, and W. Pedrycz, "Identification of fuzzy models using a successive tuning method with a variant identification ratio," *Fuzzy Set and Systems*, Vol. 159, No. 21, pp. 2873-2889, 2008.

저 자 소 개



오성권(Oh Sung-Kwon)

1981년 : 연세대학교 전기공학과 졸업

1993년 : 동 대학원 박사

1983~1989년 : 금성산전연구소

(선임연구원)

1996~1997년 : 캐나다 Manitoba 대학 전기

및 컴퓨터공학과 Post-Doc.

1993~2004년 : 원광대학교 전기전자 및

정보공학부 교수

2005~현재 : 수원대학교 전기공학과 교수

2002~현재 : 대한전기학회, 제어로봇시스템학회, 퍼지및지

능시스템학회 편집위원.

관심분야 : 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 컴퓨터지능, 지능 제어등.

Phone : 031-229-8162

E-mail : ohsk@suwon.ac.kr



김옥동(Kim Wook-Dong)

2009년 : 수원대학교 전기공학과 졸업

2009~현재 : 동 대학원 석사과정

관심분야 : 퍼지추론 시스템, 뉴럴 네트워크, Granular Computing, 진화론적 최적화 알고리즘.

Phone : 031-222-6544

E-mail : wdkim@suwon.ac.kr



박호성(Park Ho-Sung)

1999년 : 원광대학교 제어계측공학과 졸업.
2005년 : 동 대학원 박사
2005~2006년 : 원광대학교 전기전자 및
정보공학부 전임강사
2006~2007년 : 캐나다 Alberta 대학 전기
및 컴퓨터공학과 Post-Doc.
2008~현재 : 수원대학교 산업기술연구소
학술연구교수

관심분야 : 퍼지추론시스템, 퍼지신경회로망, 진화론적 알고리즘등의 컴퓨터지능 등.

Phone : 031-222-6544

E-mail : parkhs@suwon.ac.kr



이영일(Young-II Lee)

1980년 : 연세대학교 전자공학과 졸업.
1996년 : 퍼듀 대학원 전기공학과 졸업
(공학박사).
1997년~현재 : 수원대학교 전기공학과
교수.

관심분야 : 전력시스템, 전자회로 및 퍼지시스템 등.

Phone : (031) 220-2584

E-mail : leeyi@suwon.ac.kr