

진화 컴퓨팅 기반 RBF 신경회로망의 설계

Design of Evolutionary Computing-based RBF Neural Networks

정병조, 노석범, 장성환, 오성권
원광대학교 전기전자 및 정보공학부

Byoung-Jo Jeong, Seok-Beom Roh, Sung-Whan Jang, Sung-Kwon Oh
Dept. of Electrical Electric and Information Engineering Wonkwang University
E-mail : ohsk@wonkwang.ac.kr

요 약

본 논문은 최적화 방법인 유전자 알고리즘을 이용하여 진화 컴퓨팅 기반 RBF 신경회로망을 이용한 새로운 비선형 시스템 설계 방법을 제안한다. 비선형 시스템 설계시 문제점으로는 복잡성과 불확실성을 들 수 있으며, 이러한 문제를 해결하기 위해서 지능형 모델을 사용하게 되었다. 본 논문에서는 일반적인 신경회로망보다 성능이 뛰어난 RBF 신경회로망을 사용하여 비선형 시스템을 모델링 한다. HCM 클러스터링을 이용하여 유사한 특성을 가진 비선형 데이터를 분류하여 입력으로 사용한다. 제안한 진화 컴퓨팅 기반 RBF 신경회로망을 이용한 모델의 적용 및 유용성을 비교 평가하기 위하여 비선형 학습 데이터와 테스트 데이터를 이용하여 그 우수성을 보인다.

1. 서론

컴퓨터의 급속한 성장에 따라 첨단 인공지능 기법을 통한 모델 개발의 이론적 발전과 실무적용에서 상당한 성과를 얻고 있다. 특히, 모델의 이론적 개발은 입출력 데이터쌍의 집합으로부터 미지의 함수를 평가하는 것으로 이는 다양한 과학과 공학분야에서 여전히 중요한 관심이 된다. 알려지지 않은 시스템의 입출력데이터만으로는 시스템의 동적 특성을 분석하기는 어려운 문제이다. 실제의 제어시스템은 비선형성, 파라미터의 변동, 모델링 오차 등의 복합적인 문제를 포함하고 있으며, 프로세스에 대한 충분한 지식과 정보의 결핍으로 일반적인 수학적 방법만으로는 시스템을 모델링하는데에는 상당한 어려움이 따른다. 따라서 비선형 제어시스템의 복잡성과 불확실성을 제어하기 위해 다양한 연구가 계속되고 있다. 지능형 모델방식은 수학적인 방법으로 해결하지 못했던 문제점들을 점진적으로 개선하는 추세이다. 사람의 자연적인 언어체계를 표현하는데 효과적인 퍼지 모델과 생물학적 신경계통을 공학에 응용한 신경회로망[1]을 이러한 지능모델의 대표적인 것으로 꼽을 수 있다.

본 논문에서는 RBF 신경회로망[2]의 연결가중치와 RBF 함수의 중심값을 계산하는 방법을 제시하고 제안한 유도식을 증명하였다. 지금까지의 연구에서는 멤버쉽 함수로 가우시안 함수 등을 사용하여 모델링 하였으나, 본 연구에서는 은닉층의 RBF 함수를 퍼지 멤버

쉽 함수로 변환하여 신경회로망을 구성하는 새로운 방식에 관하여 연구하였다. 또한 각각의 모델링에 대한 알고리즘을 개발하여 Sugeno[3],[4]가 제안하여 이용한 비선형 함수에 본 연구에서 제안한 방법을 적용하여 비교하였다. 비선형적이고 복잡한 실제의 제어시스템의 데이터 특성을 해석하고 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위하여 HCM 클러스터링 방법(hard C-mean clustering method)[5]을 이용하여 입출력 데이터를 서로 유사한 특성을 가진 그룹으로 분류하였다. 제안된 모델에서는 기존 모델들의 단점인 데이터의 특성을 고려하지 않고 모델을 구축하는 것에서 벗어나 HCM 클러스터링 알고리즘을 이용하여 데이터의 특성에 맞는 모델을 구축하였다.

2. RBF 신경회로망

일반적인 RBF 신경회로망은 그림 1과 같이 입력층과 은닉층 그리고 출력층으로 구성되어 있다. 입력층은 단순히 데이터의 입력을 받아들이는 노드이고, 은닉층에 활성화함수로서 RBF를 사용하게 된다. 출력층은 연결가중치(weight)와 RBF의 곱을 가산하는 가산기 역할을 한다.

x 는 i 번째 입력벡터를 나타내고, $R_i(X)$ 는 활성화함수로서 Gaussian 함수가 사용된다. 식 (1)은 이 활성화함수를 나타낸 것이다. w 는 은닉층과 출력층 사이의 연결

가중치를 나타내고, \hat{y}_p 는 출력을 나타낸 것이다. 식 (2)는 출력식을 나타낸 것이며, 본 논문에서는 학습을 개시시키기 위하여 식 (3)과 (4)를 사용하였다.

$$R_j(X) = \exp\left(-\frac{X-v_j^2}{2\sigma_j^2}\right), (j=1, 2, \dots, k), X=(x_1, x_2, \dots, x_n) \quad (1)$$

여기서, v_j 는 j 번째 RBF의 중심, σ_j 는 j 번째 RBF의 너비, \cdot 는 Euclidean 크기를 나타낸다.

$$\hat{y}_p = \sum_{j=1}^k w_j \cdot R_j(X) \quad (2)$$

$$E_p = (y_p - \hat{y}_p)^2 \quad (3)$$

$$E = \frac{1}{m} \sum_{p=1}^m E_p \quad (4)$$

여기서 y_p 는 원하는 출력값을 나타내고, m 은 데이터 수를 나타낸다.




그림 1 일반적인 RBF 신경회로망
Fig. 1 General RBF neural networks

지금까지의 연구에서는 멤버십 함수로 가우시안 함수 등을 사용하여 모델링 하였으나 본 연구에서는 RBF 함수를 퍼지 멤버십 함수(fuzzy membership function)로 이용하는 새로운 방식에 관하여 연구하였다. 식 (5)와 (6)은 모델의 출력을 나타낸다.

$$\hat{y}_k = \frac{\sum_{j=0}^c w^T \cdot R_k(X)}{\sum_{j=0}^c R_k(X)} = \frac{\sum_{j=0}^c w_j \cdot R_k(X)}{\sum_{j=0}^c R_k(X)} \quad (5)$$

$$\hat{y}_k = \frac{\sum_{j=0}^c \frac{w_j \cdot R_k(x_k - v_j^2)}{\sum_{j=0}^c R_k(x_k - v_j^2)}}{\sum_{j=0}^c R_k(x_k - v_j^2)} = \frac{\sum_{j=0}^c w_j \cdot R_k(x_k - v_j^2)}{\sum_{j=0}^c R_k(x_k - v_j^2)} \quad (6)$$

여기서 $R_k(X) = \Phi(x_k - v_j) = R_k(x_k - v_j^2)$ 는 멤버십 함수에 대한 소속정도를 나타낸다.

이러한 경우 퍼지 규칙(fuzzy rule)은 아래와 같다.

- IF x_k is RBF1 THEN $y = w_1$
- IF x_k is RBF2 THEN $y = w_2$
- ⋮
- IF x_k is RBFj THEN $y = w_j$

[연결가중치 학습 알고리즘]

연결가중치 학습은 식 (7)과 같이 기존의 값에 오차로부터 구해진 조절량 만큼의 변화를 더해지면 된다.

$$w_j(new) = w_j(old) + \Delta w_j \quad (7)$$

$$\Delta w_j = -\eta \cdot \frac{\partial E}{\partial w_j} \quad (8)$$

$$\frac{\partial E}{\partial w_j} = \frac{\partial E}{\partial \hat{y}_k} \frac{\partial \hat{y}_k}{\partial w_j} \quad (9)$$

$$\begin{aligned} \frac{\partial E}{\partial \hat{y}_k} &= \frac{1}{2} \frac{\partial}{\partial \hat{y}_k} \sum_{k=1}^i (y_k - \hat{y}_k)^2 \\ &= -\sum_{k=1}^i (y_k - \hat{y}_k) \end{aligned} \quad (10)$$

$$\frac{\partial \hat{y}_k}{\partial w_j} = \frac{\partial}{\partial w_j} \frac{\sum_{j=0}^c w_j \cdot R_k(X)}{\sum_{j=0}^c R_k(X)} = \frac{R_k(X)}{\sum_{j=0}^c R_k(X)} \quad (11)$$

$$\therefore \Delta w_j = \eta \cdot \sum_{k=1}^i (y_k - \hat{y}_k) \cdot \frac{R_k(X)}{\sum_{j=0}^c R_k(X)} \quad (12)$$

이렇게 해서 구해진 최종 연결가중치 학습식은 식 (13)과 같이 된다.

$$\begin{aligned} \therefore w_j(new) &= w_j(old) + \eta \cdot \sum_{k=1}^i (y_k - \hat{y}_k) \\ &\quad \cdot \frac{R_k(X)}{\sum_{j=0}^c R_k(X)} \end{aligned} \quad (13)$$

[중심값 학습 알고리즘]

중심값 학습은 식 (14)와 같이 기존의 값에 오차로부터 구해진 조절량 만큼의 변화를 더해지면 된다.

$$v_j(new) = v_j(old) + \Delta v_j \quad (14)$$

$$\Delta v_j = -\eta \cdot \frac{\partial E}{\partial v_j} \quad (15)$$

$$\frac{\partial E}{\partial v_j} = \frac{\partial E}{\partial \hat{y}_k} \frac{\partial \hat{y}_k}{\partial v_j} \quad (16)$$

$$\begin{aligned} \frac{\partial E}{\partial \hat{y}_k} &= \frac{1}{2} \frac{\partial}{\partial \hat{y}_k} \sum_{k=1}^i (y_k - \hat{y}_k)^2 \\ &= -\sum_{k=1}^i (y_k - \hat{y}_k) \end{aligned} \quad (17)$$

$$\begin{aligned} \frac{\partial \hat{y}_k}{\partial v_j} &= \frac{1}{\sum_{j=0}^c R_k(X)} \frac{2\beta}{m-1} R_k(\|x_k - v_j\|^2) \\ &\quad \cdot (x_k - v_j) \cdot (w_j - \hat{y}_k) \end{aligned} \quad (18)$$

$$\begin{aligned} \therefore \Delta v_j &= \eta \cdot \frac{2\beta}{m-1} \frac{1}{\sum_{j=0}^c R_k(X)} \sum_{k=1}^i (y_k - \hat{y}_k) \\ &\quad \cdot R_k(\|x_k - v_j\|^2)(x_k - v_j)(w_j - \hat{y}_k) \end{aligned} \quad (19)$$

이렇게 해서 구해진 최종 중심값 학습식은 식 (20)와 같이 된다.

$$\begin{aligned} \therefore v_j(new) &= v_j(old) + \eta \frac{2\beta}{m-1} \frac{1}{\sum_{j=0}^c R_k(X)} \\ &\quad \cdot \sum_{k=1}^i (y_k - \hat{y}_k) R_k(\|x_k - v_j\|^2)(x_k - v_j)(w_j - \hat{y}_k) \end{aligned} \quad (21)$$

3. 진화 알고리즘

본 논문에서는 유전자 알고리즘을 시뮬레이션하기 위해 설정된 각각의 개체에 존재하는 염색체의 수와 군집의 크기에 대한 파라미터의 정의로써, 한 개체에 여러 변수의 정보를 담는 직렬 방식을 사용한다. 재생산(Reproduction)연산으로 roulette-wheel 방식, 돌연변이연산은 선택된 비트를 반전시키는 invert 방식, 교차(crossover)연산은 one-crossover 방식을 사용하였다.

그림 2는 유전자 알고리즘의 전체적인 흐름도를 나타낸다.




그림 2 유전자 알고리즘의 흐름도
Fig. 2 Flowchart of genetic algorithms

본 논문에서는 주어진 학습데이터를 이용하여 RBF 신경회로망을 구축하고, 테스트 데이터를 사용하여 모델을 테스트하기 위하여 근사화 및 일반화의 상호 균형과 의존 능력을 가진 합성 목적 함수(성능지수)를 이용하여 상호 연계된 데이터의 성능 결과에 대한 하중계수를 가진 목적함수인 합성 성능지수로써 식 (22)와 같이 정의한다.

$$f(PI, EPI) = \theta \times PI + (1 - \theta) \times EPI \quad (22)$$

하중계수를 가진 목적함수인 식 (22)를 유전자 알고리즘과의 연계를 위해서 유전자 알고리즘의 적합도 함수로 다음과 같이 식 (23)을 사용한다.

$$F(\text{Fitness Function}) = \frac{1}{1 + f(PI, EPI)} \quad (23)$$

θ 는 PI 와 EPI 에 대한 하중계수를 나타내고, PI 는 학습데이터에 대한 성능지수, EPI 는 테스트 데이터에 대한 성능지수를 나타낸다[6].

4. 시뮬레이션 및 결과고찰

본 논문에서 제안한 진화 컴퓨팅 기반 RBF 신경회로망을 이용한 모델의 적용 및 유용성을 비교 평가하기 위하여 식 (24)로 표현되는 비선형 함수를 이용하였다.

$$y = (1.0 + x_1^{0.5} + x_2^{-1} + x_3^{1.5})^2 \quad (24)$$

이 함수는 Sugeno가 제안한 퍼지추론 및 파라미터 동정 기법에 적용된 함수로 Sugeno가 사용한 40개의

입출력 데이터를 본 연구에 적용함으로써 제안된 모델을 비교하여, 타당성 및 정확도를 검토하였다. 모델의 성능지수는 식 (25)를 이용하며, 40개의 데이터 중 20개는 학습용 데이터로, 나머지 20개는 평가용 데이터로 사용하였다.

$$PI = \frac{1}{m} \sum_{p=1}^m \frac{y_p - \hat{y}_p}{y_p} \times 100\% \quad (25)$$

여기서 m 은 데이터의 수를 나타낸다.

제안한 RBF 신경회로망의 전체적인 흐름도는 그림 3과 같다.

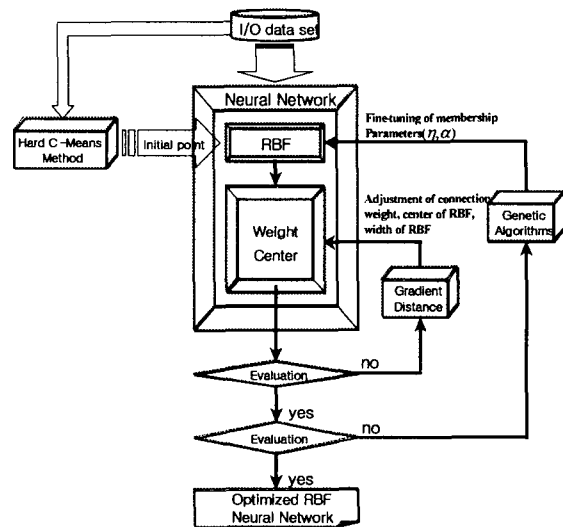


그림 3 진화 컴퓨팅 기반 RBF 신경회로망
Fig. 3 Evolutionary computing-based RBF neural network

표 1 비선형 함수에 대한 RBF 신경회로망의 성능지수
Table 1 Performance index of RBF neural network for the nonlinear function

	설정용[PI(%)]	평가용[EPI(%)]
선형모델	12.7	11.1
GMDH	4.7	5.7
퍼지모델 I	1.5	2.1
퍼지모델 II	1.1	3.6
제안한 모델	0.165	0.404

표 2 GAs와 RBF 신경회로망의 관련 정보
Table 2 Information related to GAs and RBF neural network

GAs	Maximum generation	300
	Population size	60
	Selection operator	roulette-wheel
	Crossover operator	one-point
	Mutation operator	0.8
	Mutation rate	0.08
RBF Neural Network	String length	10
	Iteration	1500
	Input layer	3
	Hidden layer	6
	Output layer	1

표 1은 식 (24)의 데이터를 가지고 주어진 RBF 신경 회로망 모델의 성능지수이다. Sugeno가 제안하였던 퍼지모델 I, II보다 본 논문에서 제안했던 RBF 신경회로망 모델이 더 우수함을 보여주고 있다. 표 2는 제안한 모델의 내부 정보를 나타낸다.

그림 4의 (a)는 RBF 신경회로망의 학습용 데이터의 모델 출력과 원 출력을 비교하여 나타낸 곡선이고, (b)는 모델 출력과 원 출력사이의 오차이다. 그림 5의 (a)는 RBF 신경회로망의 평가용 데이터의 모델 출력과 원 출력을 비교하여 나타낸 곡선이고, (b)는 모델 출력과 원 출력사이의 오차이다. 그림에서 보는 바와 같이 제안된 모델은 원하는 출력에 근사하게 접근되었다. 그림 6은 제안된 모델에 의한 최적화 과정을 나타내고 있다.

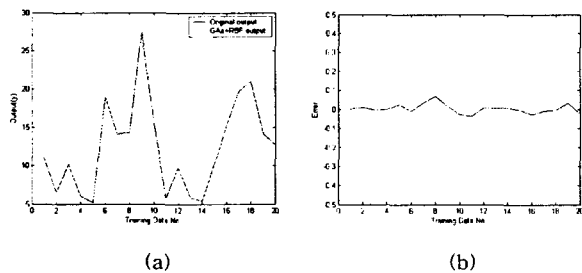


그림 4 (a) 학습용 데이터의 원 출력과 모델출력 (b) 오차
Fig. 4 (a) Original output and model output of training data (b) Error

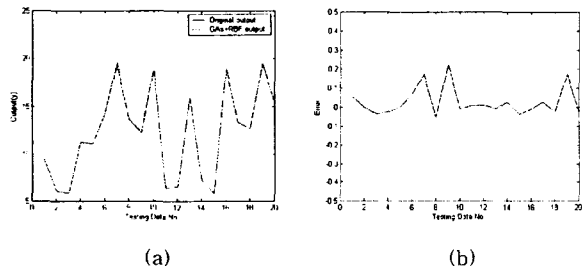


그림 5 (a) 평가용 데이터의 원 출력과 모델출력 (b) 오차
Fig. 5 (a) Original output and model output of testing data (b) Error




그림 6 GAs에 의한 최적화 과정
Fig. 6 Optimal procedure by GAs

5. 결론

본 연구는 은닉층의 RBF 함수를 퍼지 멤버쉽 함수로 변환하여 신경회로망을 구성하였다. 또한 각각의 모델에 대한 알고리즘을 개발하여 Sugeno가 제안하여 이용한 비선형 함수에 본 연구에서 제안한 방법을 적용하여 비교하였다. 비선형적이고 복잡한 실시간 제어 시스템의 데이터 특성을 해석하고 데이터의 특성에 따른 체계적이고 효율적인 모델을 구축하기 위하여 HCM 클러스터링, 진화 알고리즘과 RBF 신경회로망을 사용한 모델을 제안하였다.

본 논문에서는 학습 및 평가용 데이터의 성능을 조절하여 모델의 근사화와 일반화 사이에 적절한 방향을 제시하였으며, 진화론적으로 설계된 RBF 신경회로망 모델이 우수한 특성과 성능을 보임을 알 수 있었다. 이것은 복잡하고 비선형성이 강한 제어시스템에서 기존의 모델들 보다 성능이 향상됨을 알 수 있었다. 따라서 제안된 모델은 비선형 모델을 위한 다변수 입출력 지능형 모델구조를 설계하는데도 활용될 수 있을 것으로 기대된다.

감사의 글

본 연구는 산업자원부의 지원에 의하여 기초전력공학 공동연구소(R-2003-B-274) 주관으로 수행된 과제임.

6. 참고문헌

- [1] C.H.Chen, "Fuzzy Logic and Neural Network Handbook", IEEE Press.
- [2] Miyoung Shin and Amrit L. Goel, "Empirical Data Modeling in Software Engineering Using Radial Basis Functions", IEEE Trans. on Software Engineering, Vol. 26, No. 6, June 2000.
- [3] G.Kang and M.Sugeno, "Fuzzy Modeling", Transactions of the Society of Instrument and Control Engineers, Vol. 23, No. 6, pp. 106-108, 1987.
- [4] T.Tagagi and M.Sugeno, "Fuzzy Identification of Systems and Its Applications to Modeling and Control", IEEE Transactions on Systems, Man and Cybernetics, Vol. 15, No. 1, pp. 116-132, 1985.
- [5] 오성권, "프로그래밍에 의한 컴퓨터지능(퍼지, 신경 회로망 및 진화알고리즘을 중심으로)", 내하출판사, 2002.
- [6] 박호성, 박병준, 장성환, 오성권, "진화론적 최적 자기구성 다항식 뉴럴 네트워크", 전기학회논문지 53D권 1호, 2004, 1.