

PSO를 이용한 뉴로-퍼지 시스템의 파라미터 최적화

Optimization of the Parameter of Neuro-Fuzzy system using Particle Swarm Optimization

김승석¹, 김용태², 김주식³, 전병석¹

¹ 충북대학교 전기전자공학부
E-mail: powerkim@chungbuk.ac.kr
koamma88@chungbuk.ac.kr

² 한경대학교 정보제어공학과
E-mail: ytkim@hknu.ac.kr

³ 특허청
E-mail: kimjusik@kipo.go.kr

요 약

본 논문에서는 Particle Swarm Optimization 기법을 이용한 뉴로-퍼지 시스템의 파라미터 동정을 실시한다. PSO의 학습 및 군집 특성을 이용하여 시스템을 학습한다. 유전 알고리즘과 같은 무작위 탐색법을 이용하며 하나의 해 군집에 대해 다수 객체들이 탐색하는 기법을 통하여 최적해 부분의 탐색성능을 높여 전체 모델의 학습성능을 개선하고자 한다. 제안된 기법의 유용성을 시뮬레이션을 통하여 보이고자 한다.

Key Words : Particle Swarm Optimization, Neuro-Fuzzy Modeling, TSK Fuzzy Model

1. 서 론

인공지능 모델을 학습할 때, 수학적 배경을 기반으로 모델의 파라미터를 추정하는 기법은 모델의 학습과정을 체계적으로 설명하거나 분석할 수 있는 장점을 가진다[1][2]. 그러나 일반적인 모델은 대부분 선형시스템을 기반으로 하는 학습 기법을 이용하기 때문에 비선형 시스템으로 가정할 수 있는 지능모델에서는 학습이 어렵거나 불가능한 영역이 발생할 수 있다[2].

이러한 특성을 피하기 위해 유전알고리즘과 같은 무작위 탐색법이 도입되어 기존의 수학적 모델링에서 발생하는 문제점을 피하고자 하였다[3-5]. 자연의 진화형태 중 하나인 적자생존 법칙을 모사한 유전알고리즘의 경우, 학습영역에서 무작위로 탐색을 실시하여 미분을 기반으로 하는 기존의 학습기법에서 종종 발생하는 국부 해 수렴 문제를 해결할 수 있으나, 매 학습마다 같은 결과를 보장할 수 없으며 최종 학습된 해 역시, 최적해라 할 수 없는 단점을 가진다[3][4].

제안된 기법은 동물이나 벌레 등의 군집이 먹이를 찾아 다중 탐색을 실시하는 Particle

Swarm Optimization (PSO) 기법을 적용하여 지능모델의 학습을 실시하였다[6]. 군집이 해를 탐색하며 우수한 성능을 보이는 해 공간 부근을 군집이 같이 탐색을 실시한다. 무작위 탐색 기법이면서도 최적해로 수렴하는 과정은 기존의 미분기반 탐색기법과 유사하면서도 무작위 탐색기법의 특성을 가지고 있으므로 국부적 수렴 문제를 개선할 수 있는 장점을 가진다.

제안된 기법은 매 학습기회에서 취득된 우수한 해 공간을 중심으로 PSO의 각 객체들이 탐색을 실시하며 더 우수한 해 공간이 탐색되면 다시 그 공간을 중심으로 탐색을 지속하는 기법을 이용하였다. 초기 결정된 해 공간을 벗어나지 못해 유전알고리즘과 같은 전역적 탐색이 어려워지는 단점과 해 공간 주위를 각 객체들이 자세하게 탐색하여 우수한 해를 찾을 수 있도록 하는 장점을 가진다. 이러한 특성을 뉴로-퍼지 모델링에서 전체부 파라미터의 학습에 적용하여 최적화 과정을 수행한다.

제안된 기법의 유용성을 전형적인 벤치마크(benchmark) 예제인 Box-Jenkins 가스로 데이터에 적용하여 학습이 진행되는 동안 모델의 성능이 개선되는 특성을 보인다.

2. Particle Swarm Optimization

집단을 이루며 생활하는 새들의 지능은 매우 낮으나 서로 상호 협동에 의해 필요한 먹이를 취득한다. 군무를 이루며 하늘에서 먹이를 탐색할 때, 모든 객체는 먹이를 탐색하면서도 일정한 형태를 이룬다[5]. 이들 객체들은 같은 공간을 동시에 공유(충돌)하지 않으며 각자 먹이를 탐색하고 탐색된 먹이에 대해 서로 정보를 공유하여 다시 비행의 방향을 바꾼다. 각 객체가 동시에 같은 공간을 공유하지 않고 다른 공간을 공유함으로써 동일한 학습시간 안에서 더 많은 해를 탐색할 수 있는 장점을 가지고, 우수한 해 주변을 객체들이 탐색함으로써 좀더 최적화된 해를 탐색할 수 있는 특징을 가진다.

PSO의 기본 학습형태는 각 객체가 탐색한 공간에서의 성능을 평가한 뒤 우수한 성능을 보이는 공간 부근으로 다른 객체들을 이동시킨다. 이때 각 객체는 동시에 같은 공간을 차지하지 않으며 이러한 특성은 탐색 성능의 개선으로 이루어진다.

군집을 이루며 나는 새를 예를 들면, 각 객체는 자신이 이동하는 속도와 위치를 가진다. 이동하는 위치는 현 학습단계에서 최적해를 가지는 객체를 향하고 있으며 상호간의 충돌은 있지 않는다. 따라서 이를 수식으로 표현하면 다음과 같다.

$$v_{id} = v_{id} + c_1 \times rand(\cdot) \times (p_{id} - x_{id}) + c_2 \times rand(\cdot) \times (p_{gd} - x_{id}) \quad (1)$$

$$x_{id} = x_{id} + v_{id} \quad (2)$$

여기서 v_{id} 는 각 객체의 이동속도이고, c_1 과 c_2 는 학습에 필요한 파라미터이며, p_{id} 와 p_{gd} 는 국부적 최적해와 전역적 최적해이고, x_{id} 는 객체의 위치이다.

본 논문에서는 객체가 이동하며 해를 탐색할 때, 다음 학습에서 이전보다 우수한 해를 탐색하지 못하는 경우 학습이 진행되는 동안 최적화 결과가 오히려 나빠지는 문제점을 개선하기 위하여 유전알고리즘에서 이용하는 엘리티즘(Elitism)을 적용하여 학습이 진행되는 동안 탐색 성능이 떨어지는 것을 방지하였다[3-5]. 즉, 현재의 학습에서 하나의 객체는 이전 학습에서 가졌던 최우수 해를 보관하고 있어 현재의 학습 결과가 나쁠 경우 이전의 우수한 성능을 가지는 해를 다음 탐색 공간의 중심으로 계속 유지하도록 하였다.

3. PSO를 이용한 뉴로-퍼지 모델링

3.1 뉴로-퍼지 모델링

학습에 이용된 모델은 언어적인 입력부와 선형 방정식 형태의 출력부를 가진 Takagi - Sugeno - Kang 퍼지 모델을 이용하였다. 이 모델은 비선형 입력에 대해 선형 추론을 하는 것으로 고려할 수 있으며 식 (3)과 같다.

$$\text{Rule } i: \text{ If } x \text{ is } A_i \text{ and } y \text{ is } B_i \\ \text{Then } f_i = p_i x + q_i y + r_i \quad (3)$$

여기서 x 와 y 는 입력의 각 차원이며 A_i 와 B_i 는 i 번째 전제부 소속함수이고, p_i , q_i , r_i 는 i 번째 결론부 파라미터이다.

전제부 소속함수는 Gaussian 소속함수로서 데이터의 소속도를 소속함수의 중심과 이에 관련된 분산으로 표현하며 식 (4)와 같다.

$$\mu_i = \exp\left(-\frac{(x-c_i)^2}{2\sigma}\right) \quad (4)$$

기존의 퍼지 모델은 입출력 공간을 격자 분할하여 각 공간에 규칙을 부여하는 기법을 이용하여 모든 입출력 공간을 이용하였다. 이 경우, 퍼지 규칙의 수가 늘어나거나 입출력 차원이 증가하는 경우, 퍼지 규칙의 수가 지수함수적으로 증가하는 문제점을 가지고 있다. 따라서 제안된 방법에서는 클러스터링 기법을 이용하여 데이터 군집이 존재하는 공간만을 규칙으로 할당, 퍼지 규칙의 증가를 억제하여 전체 학습 모델의 크기를 줄였으며 학습속도 역시 개선하였다. 제안된 뉴로-퍼지 모델의 기본 구조는 그림 1과 같다[2][9].

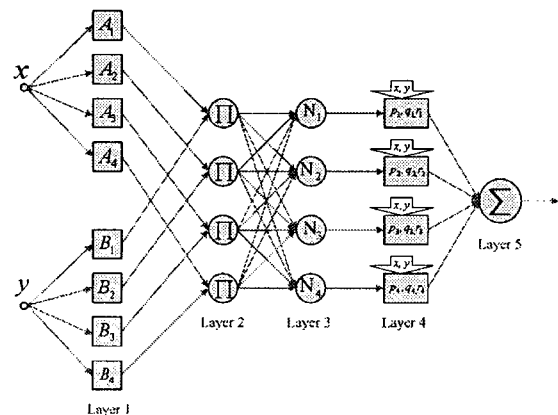


그림 1. TSK 형 뉴로-퍼지 시스템

3.1 제안된 뉴로-퍼지 모델링

제안된 기법은 전제부 소속함수 파라미터를 PSO 학습기법을 이용하여 추정하고 결론부 파라미터는 최소자승법을 이용하여 추정한다. 기본적인 학습과정은 다음과 같다. 각 학습에서 PSO에 의해 갱신된 전제부 파라미터를 이용하여 전제부를 구성하고 입출력 데이터와 전제부 소속함수를 이용하여 결론부 파라미터를 추정한다. 생성된 모델을 평가하여 가장 우수한 성능을 가지는 객체를 PSO 학습에서 이용하도록 한다. 전체 학습과정을 그림 2에 나타내었다.

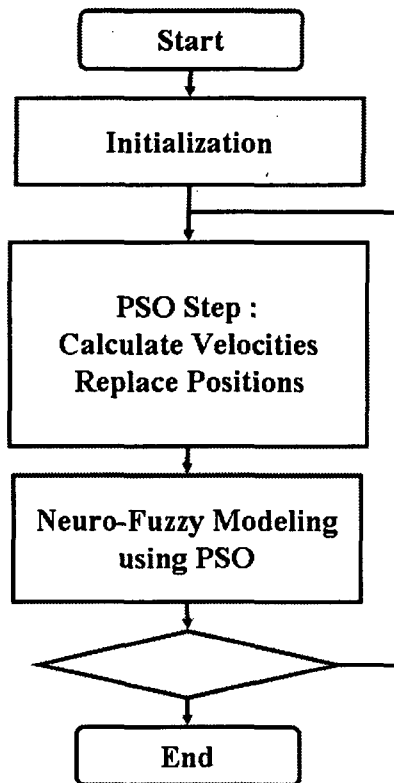


그림 2. 제안된 학습 알고리즘

비율 $u(k-3)$ 를 이용하였다. PSO의 학습이 진행되는 동안 전체 데이터의 학습오차(MSE) 변화를 그림 3에 나타내었다. 모델은 클러스터의 수를 4개로 하였으며, 생성된 뉴로-퍼지 규칙 역시 4개이다. PSO에서 각 학습에 적용된 객체의 수를 20개로 하여 100회 학습을 실시한 결과이며, 초기 탐색공간을 임의로 지정함으로 학습결과는 달라질 수 있다. 또한 학습과정 중에 가장 우수한 해를 찾은 객체의 변동을 그림 4에 나타내었다. 한 객체가 우수한 해를 찾았을 때 다음 학습에서 이를 기준으로 다시 해를 탐색하는데, 현재의 해보다 좋은 성능을 보이지 않는 경우 현재의 해가 다음 학습의 해로 바로 넘겨지는 엘리티즘을 이용하여 학습과정 중에 탐색성능이 떨어지는 것을 방지하였다.




그림 3. 학습과정 중 오차 변화

4. 시뮬레이션 및 결과

제안된 기법을 전형적인 비선형 시계열 benchmark 데이터인 Box-Jenkins 가스로 데이터에 적용하여 유용성을 보인다. Box - Jenkins 가스로 데이터는 단일 입출력으로써, 입력은 메탄 흐름률이며 출력은 이산화탄소 CO_2 의 비율이다. 총 296개의 입출력 데이터 쌍에서 유효한 290개를 실험에 이용하고 Jang의 입력선택 방법에 의해 다음과 같이 선택하였다.

$$y(k+1) = f(y(k), u(k-3)) \quad (5)$$

입력으로 메탄 흐름률과 이전의 이산화탄소

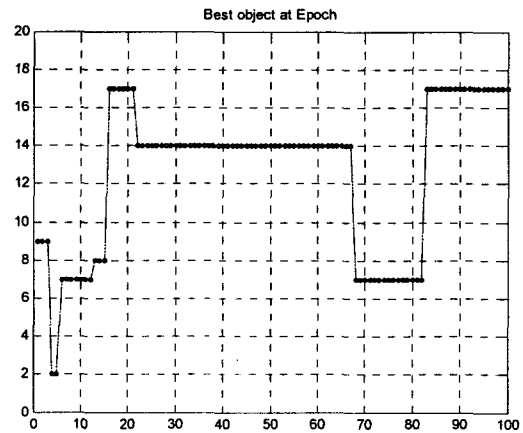


그림 4. 학습과정 중 최적객체 변화

PSO의 객체의 수 및 소속함수의 수를 변화시키며 실험을 100회 반복 학습하였을 때 학습된 모델의 최종 오차를 표 1에 나타내었다.

표 1. 모델링을 위한 초기 파라미터들.

No. of Object	No. of Membership	Error (MSE)
20	4	0.1210
	5	0.1214
	6	0.1178
30	4	0.1266
	5	0.1195
	6	0.1201
40	4	0.1222
	5	0.1199
	6	0.1207

5. 결론 및 향후 연구과제

본 논문에서는 PSO를 이용한 뉴로-퍼지 모델링을 실시하였다. PSO 군집의 우수한 공간 탐색 능력을 뉴로-퍼지 모델링의 학습에 적용하여 모델의 성능을 개선하였다. 무작위 탐색 기법의 장점인 공간 탐색 능력과 미분을 기반으로 하는 수학적 최적화 기법의 장점인 수렴 특성을 접목하여 모델의 파라미터를 학습하였다.

향후 연구과제로는 PSO의 탐색 및 최적화 기법을 모델의 파라미터 동정뿐만 아니라 구조 동정까지 적용하여 모델을 구성하는 방법과 클러스터링에서 동일차원에서의 파라미터 최적화 특성을 PSO의 객체에 정확하게 구현하여 동일 공간 내에서 상호 연관성을 가지는 클러스터링 학습을 시키는 것이다.

참 고 문 헌

[1] C. T. Lin, C. S. G. Lee, "Neural fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems", Prentice Hall, 1996.
 [2] J. S. R. Jang, C. T. Sun, E. Mizutani, "Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence", Prentice Hall, 1997.

[3] Zbigniew Michalewicz, Genetic Algorithms + Data Structure = Evolution Programs, Springer, 1999.
 [4] J. H. Holland, "Genetic Algorithms in Search, Optimization and Machine Learning," Addison- Wesley, Reading, MA, 1989.
 [5] Bin-Da Liu, Chuen-Yau Chen, Ju-Ying Tsao, "Design of Adaptive Fuzzy Logic Controller Based on Linguistic-Hedge Concepts and Genetic Algorithms", IEEE Tr. On System, Man, And Cybernetics-Part B, Vol. 31, No. 1, 2001.
 [6] Kennedy, J., Eberhart, R, "Particle swarm optimization", Neural Networks, 1995. Proceedings., IEEE International Conference on, Volume 4, pp. 1942 - 1948, 1995.
 [7] H. Takagi and M. Sugeno, "Fuzzy Identification of Systems and Its Application to Modeling and Control," IEEE Trans. on Sys. Man and Cybern., Vol. 15, pp. 116-132, 1985.
 [8] J. S. R. Jang, "ANFIS : Adaptive Network-based Fuzzy Inference System", IEEE Trans on System, Man, and Cybernetics, Vol.23, No. 3, pp. 665-685, 1993.
 [9] 김승석, 김성수, 유정웅, "새로운 클러스터링 알고리즘을 적용한 향상된 뉴로-퍼지 모델링", 대한전기학회 논문지, Vol. 53D, No. 7, pp. 536-543, 2004.
 [10] S. R. Jang, "Input Selection for ANFIS Learning", Proceeding of Fifth IEEE International Conference on Fuzzy Systems, Vol. 2, pp. 8-11, 1996.