

PSO를 이용한 뉴로-퍼지 시스템 최적화

김승석*, 전병석*, 송창규*, 김주식**, 김용태***
 *충북대학교, **특허청, ***한경대학교

Optimization of Neuro-Fuzzy System using Particle Swarm Optimization

Sung-Suk Kim, Byung-Suk Jeon, Chang-Kyu Song, Ju-Sik Kim, Yong-Tae Kim
 Chungbuk National University, KIPO, HanKyong National University

Abstract - 본 논문에서는 PSO를 이용한 뉴로-퍼지 모델의 구조 및 파라미터 동정을 실시한다. 진화연산 기법의 무작위 탐색 능력과 오차 미분기반 학습에서의 수렴 특성을 가진 PSO를 이용하여 학습이 진행되는 동안 모델의 구조 및 파라미터를 주어진 학습 데이터에 적합하도록 최적화 시킨다. 또한 모델의 크기를 결정하는 규칙의 수 결정을 클러스터링 기법을 이용하여 소속함수의 수가 증가하더라도 규칙이 지수함수적으로 증가하는 문제를 해결하였다. 제안된 기법의 유용성을 시뮬레이션을 통해 보이고자 한다.

의 진행속도를 계산하는 식(1)과 계산된 속도를 이용하여 다시 자신의 위치를 결정하는 식(2)가 있다.

$$v_i^{k+1} = w_i v_i^k + c_1 \text{rand} X(Pbest_i - s^k) + c_2 \text{rand} X(Gbest_i - s^k) \quad (1)$$

$$s_i^{k+1} = s_i^k + v_i^{k+1} \quad (2)$$

위의 두 식은 알고리즘이 진행되는 동안 자신의 이동속도와 변경된 위치를 다시 정하는 방식으로 종결조건을 만족할 때까지 반복수행 한다.

1. 서 론

뉴로-퍼지 시스템의 모델링은 모델의 구조를 결정하는 구조동정과 이들 파라미터를 최적화 하는 파라미터 동정으로 나눌 수 있다[2]. 주어진 입력력 데이터를 이용하여 모델링을 실시하는 경우, 먼저 모델의 구조에 해당하는 소속함수의 형태나 수 또는 규칙의 수 등을 결정하고 관련된 파라미터를 최적화한다. 모델의 구조에 따라 성능이 달라질 수 있으며 주어진 입력력 데이터의 형태에 따라 최적의 구조도 달라질 수 있다. 입력력 데이터에 기인하여 모델링을 실시하는 경우 각각의 구조에 따라 파라미터를 반복적으로 최적하여 그중 가장 좋은 성능을 가지는 구조와 파라미터를 선택하는 방법이 일반적이다.

진화연산 기법을 이용한 모델의 최적화는 선형 시스템을 기반으로 수학적 최적화 기법이 가지는 국부적 수렴 문제의 제약을 해결할 수 있으며 적자 생존 법칙 등을 이용하여 우수한 성능을 탐색하는 능력을 가진다. 하지만 대부분의 진화연산 기법은 최적해를 보장할 수 없으며 한 세대에서 다음 세대의 객체로 진화를 위해 많은 연산이 필요로 하다[3].

Particle Swarm Optimization (PSO)는 진화연산 기법 중 하나로 군집을 이루고 생활하고 있는 벌레나 새들과 같은 저지능 객체의 집단 생활을 모델링 한 것이다[1]. 각 객체는 낮은 지능을 가지도 단순한 역할을 수행하나 공동된 규칙이나 의사소통을 통하여 집단 전체의 성능은 우수하다. 또한 저지능을 모델링하는 경우 연산량이기존의 기법보다 크게 줄어드는 장점이 있다. 기존 진화연산 기법의 무작위 탐색 성능과 각 진화(시간)에서 최적해를 중심으로 해를 탐색 및 수렴해 가는 미분제약을 해소한 수학적 접근 방법의 장점을 동시에 가지고 있다.

본 논문에서는 진화연산 기법에서의 빠른 연산과 수렴특성을 가진 PSO를 이용하여 뉴로-퍼지 시스템을 모델링하였다. 제안된 PSO 기법은 소속함수의 소속도와 오차를 평가하여 자율적으로 규칙의 수를 결정하며 동시에 이들 파라미터를 최적화하였다. 제안된 기법의 유용성을 시뮬레이션을 통하여 보이고자 한다.

2. PSO를 이용한 뉴로-퍼지 모델링

2.1 Particle Swarm Optimization의 학습

PSO는 각 객체가 단순한 역할(연산)을 가지면서 상호 정보교환 및 협력을 통하여 원하는 목적을 이루는 벌레나 군집을 이루어 먹이를 탐색하는 새들 등을 모사한 기법이다[1]. 먹이를 탐색하며 비행하는 새들을 예를 들면 다음과 같다. 각각의 새는 자신의 진행방향에서 먹이를 탐색하며 이들 정보를 상호 공유한다. 공유된 정보 중 더 좋은 먹이 위치가 발견되면 군집은 진행방향은 새로운 먹이 위치로 변경되어진다. 각각의 객체가 먹이를 탐색하는 동안 새들은 동일 시간에 같은 위치나 공간을 동시에 점유하지 않는다. 다시 말하면 모든 새들 객체는 이전에 파악된 먹이위치로 진행하는 동안 다시 더 좋은 먹이 위치를 탐색하면서도 서로가 같은 공간을 탐색하지 않는다.

유전 알고리즘 등과 같은 형태의 진화연산 기법은 국부적 해를 얻어나거나 전역적 해를 탐색하기 위해 다양한 연산기법을 사용하고 있으며 이러한 특성으로 인해 최적화하는데 많은 연산과 시간이 소요된다[3]. 또한 알고리즘이 진행되는 동안 해의 수렴특성이 수학적 연산 및 최적화 기법에 비해 우수하다고 할 수 없다. 반면 PSO 기법은 진화연산 기법의 무작위 선택법을 이용하여 수학적 최적화 기법이 가지는 국부적 수렴특성을 해결하였으며, 간단한 연산량으로 기존의 진화연산 기법보다 빠른 학습 및 최적화 시간을 가진다. 더불어 군집이 해로 수렴하면서도 계속적으로 해를 탐색하는 수학적 최적화 기법의 특성을 모두 가지고 있다. 다시 말해서, 진화연산 기법에서 이용하는 수학적 최적화의 수렴기법을 가진 알고리즘으로 볼 수 있다.


PSO의 연산은 단지 두 가지로 표현할 수 있다. 먼저 현재 진행하는 객체

2.2 뉴로-퍼지 시스템

신경회로망의 학습기능과 퍼지 논리의 추론기능의 장점을 융합한 뉴로-퍼지 시스템은 서로의 장점을 결합하고 단점을 보완하고 있다. 일반적인 퍼지 규칙에 의한 모델의 경우 입력력 데이터 공간을 격자분할하여 각 공간에 규칙을 부여하는 방식을 이용하고 있다. 이 경우 입력의 차원이 증가하거나 소속함수의 수가 증가하는 경우, 규칙의 수가 지수함수적으로 증가하는 문제점을 가지고 있다. 본 논문에 적용된 뉴로-퍼지 시스템은 입력의 차원이나 소속함수의 수가 증가하더라도 규칙은 단지 소속함수의 수에 영향을 받는 클러스터링 기법을 적용하였다. 또한 언어적 입력을 가지는 전제부와 선형방정식 형태의 출력력을 가지는 Takagi-Sugeno-Kang (TSK) 퍼지 시스템을 모델링에 이용하였다. 이를 기반으로 하는 뉴로-퍼지 시스템에서 전체 규칙은 다음과 같이 표현할 수 있다[2].

RULE i : If x is A_i ; and y is B_i ;
 Then $f_i = p_i x + q_i y + r_i$ (3)

여기서 x, y 는 각 입력차원이며, A_i, B_i 는 입력차원에 대응하는 i 번째 소속함수이고, p_i, q_i, r_i 는 i 번째 규칙의 결론부 파라미터이다. 클러스터링 기반 뉴로-퍼지시스템을 그림 1에 나타내었다.



〈그림 1〉 클러스터링 기반 TSK 뉴로-퍼지 시스템

클러스터링 기반 모델링은 각 입력차원에서의 입력에 대해 하나의 소속함수만 대응되는 형태로 구성되어 있으므로, 입력 공간에서 의미를 가지지 않는 부분을 규칙에 포함하지 않아 입력차원이나 소속함수의 증가에 대해 지수함수적으로 규칙이 증가하지 않는 장점을 가지며 단지 소속함수의 수에 의해 규칙이 증가한다. 또한 TSK 모델의 장점은 비선형 형태의 전제부와 1차 선형방정식 형태의 결론부를 가지므로, 전제부 파라미터가 결정되면 결론부는 기존에 나와 있는 선형시스템 기반 파라미터 추정방법을 이용할 수 있다. 제안된 기법은 식(4)와 같이 전제부는 Gaussian 소속함수를 이용하였으며, 전제부 파라미터가 결정되었을 때, 결론부 파라미터는 최소자승법(Least Square Estimation)을 이용하였다[2].

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

여기서 c_i 는 i 번째 소속함수의 중심을, σ_i 는 분산을 의미한다.

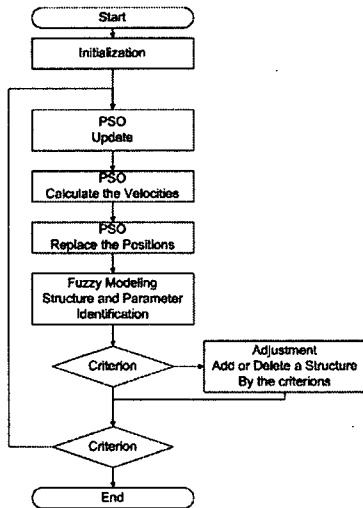
2.3 PSO를 이용한 뉴로-퍼지 시스템 모델링

뉴로-퍼지 모델링은 크게 구조 동정(Structure Identification)과 파라미터 동정(Parameter Identification)으로 나누어진다. 구조 동정은 입력력 데이터에 따른 소속함수의 수, 규칙의 결정 등이 있으며 파라미터 동정은 전체부 소속함수 등과 결론부 방정식 파라미터 등을 최적화하는 것이다. 모델링은 먼저 구조를 고정한 후 파라미터의 초기값을 다양한 학습방법에 의해 최적화시켜 결과를 얻는 것으로 모델의 구조와 초기값 결정에 의해 최종 모델의 성능이 영향을 받아 왔다. 우수한 성능을 얻기 위해 같은 구조에 다양한 초기값으로 실험을 반복해야 하며, 또한 구조를 변경하면서 위의 과정을 되풀이하는 번거로움이 있었다.

제안된 기법은 뉴로-퍼지 시스템 모델링을 PSO를 이용하여 자율적으로 구조 및 파라미터 동정을 실시하고자 하였다. 초기 주어진 PSO의 객체의 수를 이용하여 모델의 구조를 결정하고 임의의(random) 값으로 초기 파라미터를 지정한다. 이후 PSO의 학습이 진행되는 동안 자율적으로 규칙을 증가 또는 감소하면서 모델링을 실시한다. 모델의 규칙의 증감 규칙은 다음과 같다.

1) 규칙의 증가 : 하나의 클러스터에 제한치 이상의 소속도의 데이터가 포함된 경우

2) 규칙의 감소 : 하나의 클러스터에 제한치 이상의 오차가 포함된 경우 하나의 클러스터에 많은 관련 데이터가 포함된 경우 그 부분의 클러스터를 나누어 데이터 집합을 좀더 원활하게 표현하게 하였으며, 오차가 많은 클러스터의 경우 클러스터가 데이터 집합을 정확하게 표현하지 못한다고 가정하여 제거하였다. 위의 조건에 부합하지 않은 경우 PSO의 학습은 파라미터 동정만을 실시한다. 제안된 기법을 순서도로 표현하면 그림 2와 같다.



〈그림 2〉 제안된 모델링

진화연산 기법 중에서 간단한 연산량과 학습시간을 가지면서도 클러스터 수렴특성을 가지는 PSO를 뉴로-퍼지 시스템 모델링에 이용함으로써, 두 가지 기법이 가지는 장점을 모두 활용하였다. 또한 학습이 진행되는 동안 최적해를 유지하는 방법으로 엘리트즘(Elitizm) 기법을 추가하였다[3].

3. 시뮬레이션 및 결과

본 논문에서는 제안된 기법의 유용성을 보이기 위해서 전형적인 비선형 시계열 데이터인 Box-Jenkins 가스로 데이터 집합을 이용하였다. 이 데이터는 단일 입력력으로서 입력은 메탄 흐름률이며 출력은 이산화탄소의 비율이다. 총 296개의 입력력집합에서 유효한 290개를 실험에 이용하였고 Jang의 입력선택방법에 의해 다음과 같이 선택하여 시뮬레이션을 실시하였다[2].

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

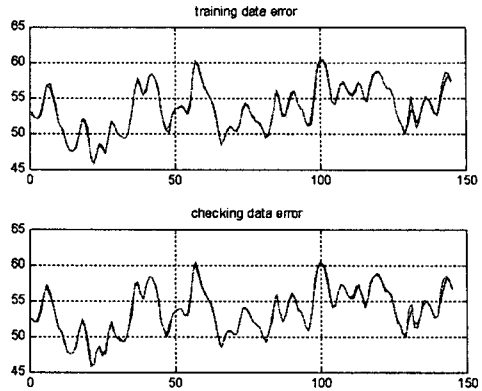
또한 이전 논문과의 비교를 위해 학습 데이터와 검증 데이터로 반반 나누어 모델의 학습에 이용하였다. 실험은 초기 PSO 객체의 수를 20개로 설정하고 각 학습에서 500회 학습을 실시하며, 초기 규칙을 수를 가변하며 모델의 성능을 추정하였다. 모델의 성능평가는 기존 논문의 평가방식인 Mean Square Estimation (MSE)를 이용하였다.

초기 클러스터의 수를 7개로 하여 자율적으로 학습을 진행하였을 때 학습 및 검증 데이터의 출력을 그림 3에 나타내었다.

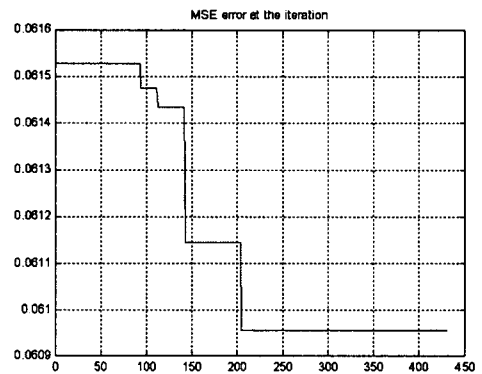
PSO의 초기 학습 파라미터는 임의로 설정되기 때문에 반복적으로 학습을 할 때마다 항상 같은 결과를 기대할 수 없다. 학습과정 중의 오차 감소를 그림 4에 나타내었다. 그림에서 볼 수 있듯이 Elitism 기법을 적용하여 학습이 진행되는 동안 오차가 커지는 문제점을 해결하였다. 학습 초기에 파라미터가 전혀 학습데이터를 추정하지 못하는 경우가 발생할 수 있지만 학습이 진행되는 동안 이러한 문제점들은 사라진다.

모델의 구조 역시 출력 오차를 기준으로 자율적으로 변동하면 변동된 구조를 다시 파라미터 동정에서 최적화 시키며 학습을 진행한다. 모델의 초기

구조를 가변하여 학습하였을 때, 최종 결정된 규칙의 크기와 오차를 표 1에 나타내었다. 임의로 결정되는 초기치에 의해 최종 수렴되는 규칙의 수는 달라 지는 경우도 발생한다.



〈그림 3〉 모델의 출력 및 오차



〈그림 4〉 학습과정 중의 오차감소

〈표 1〉 규칙 및 오차의 변화

초기구조 (규칙)	최종구조 (규칙)	학습오차	검증오차
8	3	0.062643	0.066152
7	3	0.062802	0.063704
6	3	0.062970	0.065584
5	4	0.060713	0.072425
4	3	0.063160	0.066077

4. 결 론

진화연산 기법을 이용하여 수학적 접근 방법의 문제점을 해결하면서도 빠른 학습이 가능하며, 수학적 접근 방법에서 이용하는 해의 수렴특성을 이용한 PSO를 이용하여 뉴로-퍼지 모델링을 실시하였다. 제안된 기법은 기존의 진화연산 기법과 비교하여 빠른 연산과 학습을 볼 수 있으며, 다른 기법에서 보이는 국부적 수렴 특성을 개선하여 우수한 모델링 성능을 볼 수 있다.

추후 연구과제로는 PSO의 초기값 결정을 통해 더욱 우수한 모델링 결과를 유도하는 것과 다른 지능 모델의 학습으로 확장하는 것이다. 또한 이를 실제 문제에 적용하여 성능을 확인하는 것 등이 있다.

〈참 고 문 헌〉

[1] [1] Kennedy, J, Eberhart, R, "Particle Swarm Optimization", IEEE Conference on Neural Networks 1995, Vol 4, pp. 1942-1948, 1995.
 [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] J. H. Holland, "Genetic Algorithms in Search. Optimization and Machine Learning", Addison-Wesley, 1989
 [4] 김승석, 김성수, 유정웅, "새로운 클러스터링 알고리즘을 적용한 향상된 뉴로-퍼지 모델링", 대한전기학회 논문지, Vol. 53D, No. 7, pp. 536-543, 2004.