

유전 알고리즘을 이용한 퍼지-신경망 제어기 설계

추연규 · 김현덕
진주산업대학교 전자공학과
ygchoo@cjcc.chinju.ac.kr

Design of Fuzzy-Neural Network controller using Genetic Algorithms

Yeon-Gyu Choo · Hyun-Duk Kim
Dept. of Electronic Engineering Chinju National Univ.
ygchoo@cjcc.chinju.ac.kr

요 약

본 논문에서는 정밀 제어와 온-라인 제어를 위하여 유전 알고리즘을 이용한 퍼지-신경망 제어기를 제안하였다. 제안된 제어기의 설계방법은 다음과 같은 3단계의 동조과정으로 구성한다.

- (1) 퍼지 제어기의 비퍼지화 연산을 신경망을 이용하여 함수근사화시킨 후, 퍼지-신경망 제어기를 구성한다.
- (2) 플랜트에 적합한 퍼지 소속함수의 형태를 얻기 위해 유전 알고리즘을 이용하여 근사화된 퍼지 소속함수를 찾는다.
- (3) 근사화된 초기 퍼지 소속함수를 퍼지-신경망 제어기에 의해 적용학습으로 최적의 퍼지 소속함수를 얻고, 또한 플랜트의 파라미터 변동이나 외부환경의 변화에 대해 적용할 수 있도록 최적의 퍼지 소속함수를 추정한다.

제안된 제어기의 성능을 평가하기 위하여 DC 서보모터의 속도제어에 적용하였다.

I. 서 론

최근에 정밀제어와 적용에 관한 연구가 여러 알고리즘들을 결합하는 형태로 발전해 가고 있다. 그중에서도 가장 많이 적용하고 있는 부분은 제어기법중 전문가의 지식을 기반으로 효율적인 제어가 가능한 퍼지 제어기를 주로 하고 신경망 또는 유전 알고리즘을 도입하는 구조로 퍼지 제

어기에서 가장 설계하기 힘든 지식기반을 바탕으로 한 소속함수 형태 또는 규칙을 신경망과 유전 알고리즘으로 설정하는 것이다.^{[1][2]} 그러나 각각의 결합된 제어구조에는 약간의 문제점도 가지고 있다. 먼저 신경망을 도입하는 제어구조에서는 학습시간이 길어지고 지역 최소치에 대한 문제점으로 최적화된 수렴치를 구하지 못하는 경우가 생긴다.^[1] 그리고 유전 알고리즘과 퍼지 제어기를 결합시킨 제어구조에서는 최적화된 소속함수 형

태를 구할 수는 있지만 적용을 위한 온-라인 제어 방식을 채택할 수는 없다.^[3] 따라서 본 논문에서는 최적화에 있어서는 유전 알고리즘을 사용하여 불확실한 플랜트에 대한 근사적 소속함수를 얻고, 근사적 소속함수를 초기로 하고 퍼지-신경망에 의한 적용 제어구조로 플랜트에 적용하는 소속함수를 얻고자 하는 것이다. 그리고 성능을 평가하기 위하여 DC 서보모터에 적용함으로써 정밀한 제어특성을 분석하고자 한다.

II. 퍼지-신경망 제어기

단순 퍼지 제어기에 신경망의 학습법을 이용하여 퍼지 제어기의 소속함수 형태를 조정하여 시스템에 적합한 제어신호를 얻도록 구성한다.^[3] 본 논문의 모델 구조는 그림 1과 같이 퍼지 추론방법에 의한 입력과 퍼지규칙의 조건부와의 소속정도를 계산하는 부분과 신경망에 의한 비퍼지화 연산 부분으로 나누어 진다.




그림 1. 퍼지-신경회로망의 구조.

1. 신경회로망에 의한 비퍼지화 연산부분

신경회로망의 함수근사화를 이용하여 비퍼지화 연산에 대한 부분을 MLP로 구성한다. 그리고 비퍼지화 부분의 학습을 위한 데이터는 결론부에 나타나는 언어항에 대한 기존의 추론방법으로 구한다. 신경망을 이용한 비퍼지화 부분은 다음과 같이 구성한다.

(i) 그림 1의 비퍼지화 연산부분과 같이 3층 이상의 MLP로 구성한다.

- (ii) 중간층과 출력층의 활성화(임계)함수는 모두 바이폴라 시그모이드 함수를 사용한다.
- (iii) 오차역전파 방법(델타규칙과 일반화된 델타규칙을 적용)에 의한 오차항을 계산한다.
- (iv) 성능평가 척도 $J = \frac{1}{2} \sum (\delta_i - o_i)^2$ 를 이용한다.

2. 입력과 퍼지규칙의 조건부와의 소속정도를 계산하는 부분

입력과 퍼지규칙의 조건부와의 소속정도를 계산하는 부분은 그림 1의 퍼지추론부와 같이 4개의 층으로 구성한다.

각층 유니트의 구조를 살펴보면 다음과 같다.

- (i) n층 : 각 유니트는 입력변수(e, ce)에 해당된다.
- (ii) m층 : 각 유니트는 언어항을 의미하며, 이 층에서는 입력에 대하여 해당 언어항의 소속정도를 계산한다.

삼각 퍼지숫자의 경우 각 유니트에 있어서 언어항의 수식적 표현은 다음과 같다.

$$U^m(x) = \begin{cases} 1 - \frac{x - c^m}{s_R^m} & x \in [c^m, c^m + s_R^m] \\ 1 + \frac{x - c^m}{s_L^m} & x \in [c^m - s_L^m, c^m] \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

- (iii) l층 : 각 유니트는 각각 퍼지규칙의 조건부에 해당되며, m층에서 계산된 소속정도를 최소값 연산을 통해 합성한다.

- (iv) k층 : 각 유니트는 결론부의 언어항에 대응한다. 대응하는 언어항을 결론부에 있는 퍼지규칙들의 소속정도를 최대값 연산을 통해 합성한다.

3. 퍼지 소속함수 수정을 위한 학습

학습방법으로 최대경사법(gradient descent

method)을 사용하고, 직접적인 방법으로 퍼지-신경망의 출력에 대한 성능평가를 할 수 없으므로 이미 신경망으로 학습된 비퍼지화 연산부분의 오차를 역전파 시켜서 입력과 각 규칙의 소속정도에 대한 오차값을 간접적으로 계산하는 방법을 사용한다. 따라서, 오차 역전파 알고리즘에 의한 비퍼지화 부분의 각 층에서 역전파되는 오차들은 다음과 같다.

출력층의 오차 :

$$\begin{aligned} \varepsilon_j &= -\frac{\partial E}{\partial net_j} = -\frac{\partial E}{\partial o_i} \frac{\partial o_i}{\partial net_j} \\ &= (\delta_i - o_i) f'(net_i) \end{aligned} \quad (2)$$

중간층의 오차 :

$$\begin{aligned} \varepsilon_j &= -\frac{\partial E}{\partial net_j} = -\frac{\partial E}{\partial o_i} \frac{\partial o_i}{\partial net_j} \\ &= \sum_k \varepsilon_k w_{jk} f'(net_j) \end{aligned} \quad (3)$$

입력층의 오차 :

$$\varepsilon_k = -\frac{\partial E}{\partial net_k} = \sum_j \varepsilon_j w_{kj} \quad (4)$$

퍼지 소속함수를 시스템에 맞도록 형태를 수정하기 위해 m층의 각 파라미터(c^m, s_L^m, s_R^m)를 연쇄법칙에 의해 수정한다. 각 파라미터의 증분형 계산은 다음과 같다.

$$\begin{aligned} \Delta c^m &= -\eta \frac{\partial E}{\partial c^m} = -\eta \sum_k \frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial c^m} \\ &= -\eta \sum_k \frac{\partial E}{\partial o_k} \sum_l \frac{\partial o_k}{\partial o_l} \frac{\partial o_l}{\partial o_m} \frac{\partial o_m}{\partial c^m} \\ &= \eta \sum_k \varepsilon_k \sum_l \frac{\partial o_k}{\partial o_l} \frac{\partial o_l}{\partial o_m} \frac{\partial o_m}{\partial c^m} \end{aligned} \quad (5)$$

$$\begin{aligned} \Delta s_L^m &= -\eta \frac{\partial E}{\partial s_L^m} \\ &= \eta \sum_k \varepsilon_k \sum_l \frac{\partial o_k}{\partial o_l} \frac{\partial o_l}{\partial o_m} \frac{\partial o_m}{\partial s_L^m} \end{aligned} \quad (6)$$

$$\begin{aligned} \Delta s_R^m &= -\eta \frac{\partial E}{\partial s_R^m} \\ &= \eta \sum_k \varepsilon_k \sum_l \frac{\partial o_k}{\partial o_l} \frac{\partial o_l}{\partial o_m} \frac{\partial o_m}{\partial s_R^m} \end{aligned} \quad (7)$$

$$\frac{\partial o_k}{\partial o_l} = \begin{cases} 1 & \text{if } o_k = o_l \text{ and } w_{lk} = 1 \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

$$\frac{\partial o_l}{\partial o_m} = \begin{cases} 1 & \text{if } o_l = o_m \text{ and } w_{ml} = 1 \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

III. 유전 알고리즘을 이용한 퍼지 소속함수의 최적화

1 유전 알고리즘

유전 알고리즘은 1970년대의 미국의 John Holland에 의해 정립된 이론으로 자연선택(Natural selection)의 원리와 자연계의 유전학(Natural Genetic)에 근거한 최적해 탐색방법이다.^[4] 일반적으로 유전 알고리즘은 전역적인 최적의 해를 발견할 높은 가능성과 목적함수에 대한 수학적 제약이 거의 없기 때문에 최적화 문제, 분류 시스템, 신경회로망의 학습문제, 퍼지 규칙 베이스의 자동생성 등 여러 응용분야에서 적용되고 있다.^[5] 유전 알고리즘의 진화과정은 생물학적 유전인자인 염색체에 해당하는 문자열(string)을 가지고 생물과 같은 재생산(reproduction), 교배(crossover), 돌연변이(mutation)를 거쳐 다음세대의 자손(offsprings)을 만들어 낸다.

유전 알고리즘의 성능은 실제 파라미터의 부호화 기법, 교배율 및 돌연변이율, 평가함수 설정 등에 크게 좌우된다.^{[5],[6]}

2. 유전 알고리즘과 퍼지 제어기의 결합

퍼지 제어기의 설계에 있어서 가장 중요하게 여겨지며 또한 어려운 점은 지식기반을 토대로 한 퍼지 소속함수의 형태 또는 퍼지규칙을 설계하는 작업이다. 본 논문에서는 지식기반의 토대를 유전 알고리즘을 이용하여 소속함수의 형태를




그림 2. 유전 알고리즘을 결합한 퍼지 제어기의 구성도

최적화 하려고 한다. 유전 알고리즘은 다양한 공간에서 최적의 해집합을 얻을 수 있다는 장점으로 시스템을 최적으로 제어할 수 있는 퍼지 소속함수의 형태를 찾고자 한다. 유전 알고리즘을 기존의 퍼지 제어기 제어구조에 부가적으로 연하여 최적의 퍼지 소속함수를 찾는 구조는 그림 3과 같다.

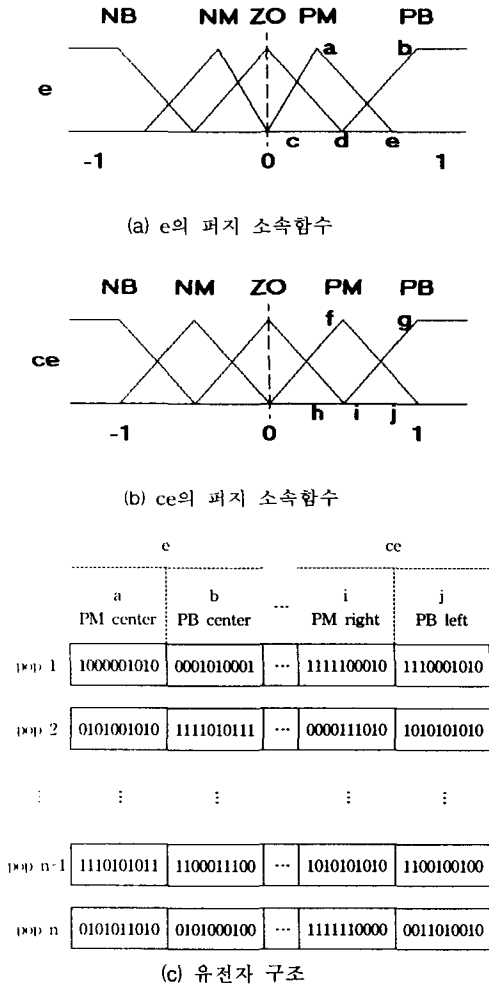


그림 3. 퍼지 소속함수와 유전자 구조

유전자 구조는 여러개의 염색체를 갖는 형태로 한세대에 n개의 유전자들로 그림 3과 같이 설정하였다. 오차(e)와 오차변화(ce)의 모든 퍼지소속 함수에 대한 중심과 폭을 해로 하여 염색체를 설정할 경우 정상상태의 해를 얻기 위해서는 많은 세대를 반복해야 하므로 본 논문에서는 10개의 염색체로 줄여서 그림 3과 같이 구성하므로 유사 해를 앞의 경우보다는 짧은 세대에서 얻을 수 있도록 한다.

10개의 염색체는 다음과 같이 설정한다. 그리고 각 염색체는 10비트 2진코드로 구성한다. 이렇게 얻어진 각 염색체 정보는 다음과 같은 시스템의 안정화를 위한 제약사항과 더불어 소속함수의 형태를 결정하였다. 먼저 ZO를 중심으로 좌측과 우측을 대칭으로 설정하였다. 즉 양의 부분만을 얻어서 음의 부분을 설정하였다. 예를 들어 NM의 중심은 PM의 중심값에 음의 부호를 붙여서 처리하고, NM의 좌폭값은 PM의 우폭값으로 처리하였다. 그리고 ZO의 중심은 고정시키고 ZO의 좌,우폭값은 PB의 중심에서 PB의 좌폭값을 뺀것으로 처리하였다. 시스템의 안정화를 위하여 PM의 좌폭은 PM의 중심값보다 크지않도록 하였다.

초기 세대 유전자는 무작위 설정보다는 안정화된 세대진화를 위하여 각 퍼지수에 적절한 영역을 설정하여 다음 세대를 생성하도록 하였다. 세대를 진화시키는 요소는 앞의 염색체 구조와 다음의 평가함수로 이루어진다. 이 평가함수는 시스템에 있어서 적합한 유전자인가를 평가할 수 있는 적합도 함수이다. 여기서 사용한 평가함수는 오차와 오차변화를 최소화 하는 것을 목적으로 한다. 따라서 다음과 같이 오차와 오차변화의 제곱 누적을 평가함수의 항으로 사용하였다.

$$F(pop_i) = \frac{K_1}{1 + \sum_k e_k^2} + \frac{K_2}{1 + \sum_k ce_k^2} \quad (10)$$

여기서, $K_1 + K_2 = 1$ 로 하여 K_1, K_2 를 적절하게 설정한다.

IV. 유전 알고리즘을 결합한 퍼지-신경망 제어기

유전 알고리즘을 결합한 퍼지-신경망 제어기의 구성도는 그림 4와 같다.




그림 4. 유전 알고리즘을 결합한 퍼지-신경망 제어기의 구성도 .

본 논문의 소속함수 최적화 방법과 온라인 제어 방식에 의한 소속함수 조정에 관한 알고리즘은 다음과 같다.

- 단계 1. 먼저 퍼지 제어기의 비퍼지화 부분을 신경망을 사용하여 함수근사화 시켜서 신경망의 가중치를 고정시킨다. 이것은 온라인에 의한 퍼지 소속함수의 파라미터 조정부분에서 사용하기 위함이다.
- 단계 2. ②를 on시키고 ①를 비퍼지화로 on시켜 단순 퍼지 제어기의 소속함수의 형태를 유전 알고리즘에 의한 유전자 생성으로서 최적화 값을 얻는다.
- 단계 3. 단계 2에서 얻어진 최적화된 퍼지 소속함수 형태를 신경망 퍼지 제어기의 소속함수로 고정시켜서 신경망의 역전파 알고리즘을 이용하여 온라인 방식에 의한 적응성을 갖도록 한다. 이 때에는 ②를 off시키고 ①를 신경망으로 근사화된 비퍼지화로 on시킨다.

V. 실험 및 결과

실험 장치의 구성도는 그림 5와 같다. 제어신호는 PC에서 프로그램된 제어기에서 출력되며

이 제어신호값은 12bit resolution을 갖는 D/A변환기에 의해 모터 구동회로로 인가된다. 이렇게 인가된 구동회로부에서는 PWM방식으로 DC 서보모터를 구동시킨다.






그림 5. 실험 장치 구성도

DC 서보모터의 실제 측정되는 레환치는 타코 제네레이터에 의해 검출되며 이 검출된 실제 출력값은 12bit A/D 변환기에 의해 제어기에 전달된다.



(a) e, ce의 퍼지 소속함수



(b) 출력

그림 6. 11세대 진화 후의 퍼지 소속함수와 출력




그림 7. 적응학습 후의 퍼지 소속함수와 출력

실험에서 퍼지 제어기의 비퍼지화 부분을 근사화시킬 때의 각 파라미터는 학습률 0.3, 모멘텀 계수 0.7로 그리고 학습수를 2000번 설정하였다. 그림 6은 11세대를 진화 시킨 후의 퍼지 소속함수와 출력을 나타낸다. 사용된 유전 알고리즘의 파라미터는 다음과 같다. 유전율 0.6, 돌연변이율 0.0035, 한 세대의 유전자수는 30개로 하였다. 근사화된 소속함수의 형태를 퍼지-신경망을 도입하여 적응학습시켜 보았다. 그 때의 퍼지 소속함수와 출력은 그림 7과 같았다

VI. 결 론

기존의 퍼지-신경망 제어기에 있어서 신경회로망에서 발생하는 지역최소치에 대한 문제점과 지역 최소치를 극복하기 위한 수단으로 학습율을 낮추어 줄 경우 많은 학습수를 필요로 하는 문제점이 나타났다. 그러므로 이러한 문제점을 해결

하기 위하여 유전 알고리즘을 이용할 경우 최적화된 퍼지 소속함수형태를 얻을 수는 있었다. 그러나 유전 알고리즘은 오프-라인에 의한 제어구조를 가지므로 적용성에 대한 문제점을 해결할 수 없었다.

본 논문에서는 최적화된 퍼지 소속함수를 초기로 하고 퍼지-신경회로망을 구성하여 온라인방식에 의한 제어구조를 제안하였다. 그리고 본 논문에서 제안한 유전 알고리즘의 염색체 구조는 가장 근접한 최적화 값을 얻을 수 있었다. 그러므로 근사화된 파라미터를 유전 알고리즘으로 먼저 찾고 퍼지-신경망을 사용하여 적응학습시켰다. 유전 알고리즘은 해집합 선택방법에 있어서 해집합이 클 경우 최적화 하는데 많은 시간이 소요되었다. 그러므로 더 효율적인 해집합 선택방법이 연구되어야 할 것이다.

참 고 문 헌

- [1] C. T. Lin, C. S. G. Lee, "Neural-Network based fuzzy logic control and decision making", IEEE Trans. on Computers, Vol. 40, No. 12, pp. 1320~1336, 1991.
- [2] J. Buckley, Y. Heyashi, "Fuzzy Genetic Algorithms for Optimization", Proc. of Int. Joint Conf. on Neural Networks, pp. 725~728, 1993.
- [3] K. Krishnakumar, David E. Goldberg, "Control System Optimization Using Genetic Algorithms", Journal of Guidance, Control, and Dynamics Vol. 15, NO. 3, 1992.
- [4] David E. Goldberg, "Genetic Algorithms in Search, Optimization, and Machine Learning", pp. 60~70, Addison-Wesley, 1989
- [5] 장병탁 "인공진화에 의한 학습 및 최적화", 제어·자동화·시스템 공학회지, Vol. 1, No. 3, 1995.
- [6] Vittorio Maniezzo, "Genetic Evolution of the Topology and Weight Distribution of Neural Networks", IEEE Transactions on Neural Networks, Vol.5, No.1, pp.39~53, January 1994.