

랜덤 신호 기반 학습의 유전 알고리즘을 이용한 퍼지 제어기의 설계

Design of a Fuzzy Controller Using Genetic Algorithms Employing Random Signal-Based Learning

한창우, 박정일
(Chang-Wook Han and Jung-Il Park)

Abstract : Traditional genetic algorithms, though robust, are generally not the most successful optimization algorithm on any particular domain. Hybridizing a genetic algorithm with other algorithms can produce better performance than both the genetic algorithm and the other algorithms. This paper describes the application of random signal-based learning to a genetic algorithm in order to get well tuned fuzzy rules. The key of this approach is to adjust both the width and the center of membership functions so that the tuned rule-based fuzzy controller can generate the desired performance. The effectiveness of the proposed algorithm is verified by computer simulation.

Keywords : genetic algorithms, random signal-based learning, fuzzy controller

I. 서론

시스템의 비선형성과 입·출력 관계에 대한 제한된 양의 데이터 등은 시스템을 분석하는데 있어서 많은 문제점이 되고 있다. 그래서 퍼지, 신경망 등과 같은 지식 기반 연산에 많은 관심이 집중되고 있으나, 이론적인 발전과 많은 실제적인 성공에도 불구하고 바람직한 결과를 얻기 위한 퍼지 제어 규칙의 최적화 과정은 언어 제어 규칙이 전문가의 지식에 기반되었다 하더라도 시간이 많이 걸리고 지루한 작업이다. 이러한 문제점을 극복하기 위해 자기 학습 퍼지 제어기가 Mamdani[1]에 의해 제안되었고 이것에 관한 많은 연구가 진행되고 있다. 예를 들면 simulated annealing을 이용하여 퍼지 제어기의 소속함수를 구하거나[2], 적용 퍼지 제어기(adaptive fuzzy controller)를 이용하여 퍼지 제어 규칙을 자동으로 생성하거나[3], Sugeno 형태의 퍼지 제어기의 결론부 파라메터들을 유전 알고리즘을 이용하여 구하기도 하였다[4].

유전 알고리즘(Simple Genetic Algorithm; SGA) 또는 진화 알고리즘(evolutionary algorithms)은 자연 세계의 진화 과정을 컴퓨터 상에서 시뮬레이션 함으로써 복잡한 실세계의 문제를 해결하고자 하는 계산 모델이다. 1970년대 초반 J. Holland에 의해 제시된 유전 알고리즘[5]은 자연계에 존재하는 적자생존의 원리를 이용하여 적합도가 큰 개체를 다음 세대에 복제함으로써 전역해(global minima)를 찾아가는 최적화 기법중의 하나이다. 기존의 최적화 이론들과 유전 알고리즘의 근본적인 차이점은 목적함수에 연속미분조건이 없으며 다수의 변수들을 하나의 문자열로 나타낸 집단을 사용함으로써 병렬연산 및 동시 최적화가 가능하다는 것이다. 또 확률적인 방법에 의해 전역탐색을 수행하므로 부분 극소점(local minima)에 빠질

가능성이 적다. 그래서 유전 알고리즘은 최근 주목받는 최적화 기법중의 하나가 되었으며 적용적 탐색과 학습 및 최적화를 통한 공학적인 문제의 해결에 많이 응용되고 있고 최근 들어 특히 신경망과 퍼지 로직과 결합한 적용사례들이 많이 발표되고 있다. [6]의 논문에서는 유전 알고리즘을 신경망의 연결 강도를 최적화 하는데 이용하였고, [7]의 논문에서는 유전 알고리즘을 이용하여 퍼지 제어기의 소속함수와 제어 규칙을 동시에 최적화하였다.

랜덤 신호 기반 학습(random signal-based learning)[8]은 본 논문의 저자들이 최초로 제안한 것으로 신경망(neural network)의 학습에 랜덤 신호를 적용한 것이다. 랜덤 신호를 발생하여 양극성 계단 함수(bipolar step function)인 활성 함수(activation function)를 통과시킨 값으로 퍼지 제어기의 규칙을 구성하는 소속함수(membership functions)의 중심값과 폭을 학습하고, 이전 단계와 서로 에너지를 비교하여 강화 신호(reinforcement signal)를 내보낸다.

본 논문에서는 유전 알고리즘의 유전 연산자(genetic operators)로 복제(reproduction), 교차(crossover), 돌연변이(mutation) 외에 추가로 랜덤 신호 기반 학습을 적용하는 방법을 제안하고자 한다. 기존의 유전 알고리즘을 이용한 퍼지 제어 규칙의 최적화와 본 논문에서 제안된 방법을 이용한 퍼지 제어 규칙의 최적화 결과를 비교하기 위해 대표적인 비선형 시스템인 도립진자(inverted pendulum)의 시뮬레이션을 수행하고, 이를 통하여 그 유용성을 확인하고자 한다.

II. 랜덤 신호 기반 학습

1. 학습 방법

신경망 학습은 시냅스 강도(synapse strength)가 어떠한 정보를 가지는 규정된 규칙에 의해서 바뀌는 과정이다. Hebb은 학습 규칙을 다음과 같이 나타내었다. 두 개의 뉴런(neuron) A, B가 서로 연결되어 있을 때 뉴런 A가 활성

화 되면 뉴런 B 또한 활성화 된다. 결과적으로 뉴런 A, B 사이의 시냅스 강도는 (1)과 같이 나타낸다. 여기서 m 은 시냅스 강도, η 는 학습 계수, y 는 시스템 출력이다.

$$m_{BA}^{new} = m_{BA}^{old} + \eta y_A y_B \quad (1)$$

시냅스 강도의 변화가 없는 정상 상태(steady state)에서는 (2)와 같이 시냅스 평형(synaptic equilibrium)이 이루어진다.

$$\dot{m} = 0 \quad (2)$$

인위적인 학습을 위하여 의도적으로 가우스 백색 잡음 프로세스(Gaussian white noise process) $\{n(t)\}$ 를 (2)에 추가한다. 그러면 $\dot{m}(t) = n(t)$ 즉, 랜덤 신호 벡터 n 이 시냅스 강도 m 을 변화시키게 되고 m 은 (3)과 같이 확률적인 평형(stochastic equilibrium)에 도달하게 된다.

$$E[\dot{m}(t)] = E[n(t)] = 0 \quad (3)$$

학습 방법은 (4)와 같다.

$$m(t+1) = m(t) + \eta r(t)f(n(t) - \theta) \quad (4)$$

여기서 η : 학습률

f : 활성 함수

n : 0에서 1사이의 이산 랜덤 값

θ : 바이어스($=0.5$)

$r(t)$: 강화 학습 신호

그리고 강화 학습 신호 $r(t)$ 는 다음과 같이 정의된다.

$$r(t) = u(J(t) - J(t-1)) \quad (5)$$

여기서 $u(x) = \begin{cases} 1, & \text{if } x \leq 0 \\ 0, & \text{otherwise} \end{cases}$

위의 학습 방법에서 시냅스는 학습 후에 평가 함수(performance index) (7)이 감소할 때만 학습된다. 즉, (4)의 $r(t)$ 가 1이 된다. 그 이외의 모든 경우는 학습이 이루어지지 않는다. 즉, (4)의 $r(t)$ 가 0이 된다.

양극성 계단 함수인 활성 함수 f 는 (6)과 같다.

$$f(x) = \begin{cases} +1 & \text{if } x > 0 \\ -1 & \text{if } x < 0 \end{cases} \quad (6)$$

2. 자기 학습 퍼지 제어기

학습 알고리즘은 평가 함수가 줄어들 경우에만 초기에 주어진 퍼지 제어 규칙들의 소속함수의 중심값과 폭을 계속 학습시키는 것이다. 이를 판단하기 위해서 (7)과 같은 평가 함수를 사용한다.

$$J = \sum_{j=0}^P [e_j^2 + e_j^2] \quad (7)$$

여기서 e 는 오차, \dot{e} 는 오차의 변화분, P 는 입·출력 쌍의 수이다. 퍼지 제어기에서 두 개의 입력 변수 x, y 와 하나의 출력 변수 z 를 가지는 i 번째 제어 규칙은 (8)과 같다.

R_i : If x is A_i and y is B_i

then z is C_i , $i=1,2,\dots,n$ (8)

본 논문에서는 간단히 하기 위해서 퍼지 제어 규칙의 결론부(consequents)만을 학습 대상으로 고려하였다 [3][4]. 즉, 결론부 소속함수의 중심값과 폭을 학습시켜서 평가 함수가 최소가 되도록 하는 것이다.

랜덤 신호 기반 자기 학습 퍼지 제어기의 구조를 그림 1에 나타내었다.

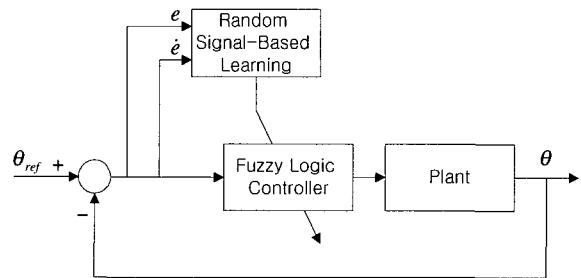


그림 1. 랜덤 신호 기반 자기 학습 퍼지 제어기의 구조.

Fig. 1. The structure of the random signal-based self-learning fuzzy controller.

그림 1은 초기에 주어진 퍼지 제어 규칙의 결론부 소속함수의 중심값과 폭을 학습시키는 부분을 제외하면 기존의 퍼지 제어기와 유사하다.

그림 2는 랜덤 신호 기반 자기 학습 퍼지 제어기의 전체적인 흐름도를 나타낸 것으로 간단히 설명하면 다음과 같다.

1) Start with initial fuzzy rule table : 결론부 소속함수의 중심값과 폭의 초기값이 주어진다.

2) System simulation : 일정한 초기 각도(0.3rad)로 주어진 시간 동안 제어 입력을 내보내어 평가 함수를 산출한다.

3) energy1=performance index : 산출된 평가 함수를 energy1에 넣는다.

4) Hibernate the rule table : 과정 2)의 중심값과 폭을 임의의 장소에 기억시켜 놓는다.

5) Searching new rule table with random signal-based learning scheme : 랜덤 신호 기반 학습을 이용하여 중심값과 폭을 학습시키고 이 값을 현재의 퍼지 제어 규칙으로 둔다.

6) System simulation : 학습된 중심값과 폭 즉, 학습된 퍼지 제어 규칙으로 과정 2)를 반복한다.

7) energy2=performance index : 과정 6)에서 산출된 평가 함수를 energy2에 넣는다.

8) energy2-energy1 : 만약 energy2-energy1의 결과가 0 보다 크거나 같으면 즉, 학습 후의 결과가 학습 전의 결과 보다 나쁘면, 과정 4)에서 기억시켜 놓은 중심값과 폭을 가져와 현재의 퍼지 제어 규칙으로 두고 energy1을 energy에 넣는다. 만약 0 보다 작으면 즉, 학습 후의 결과가 학습 전의 결과 보다 좋으면, 과정 5)의 값으로 현재의 퍼지 제어 규칙을 구성하고 energy2를 energy에 넣는다.

9) Judge the performance : 평가 함수가 허용치 이내에 들어오면 학습을 끝내고, 그렇지 않으면 과정 2)로 돌

아가 반복 수행한다.

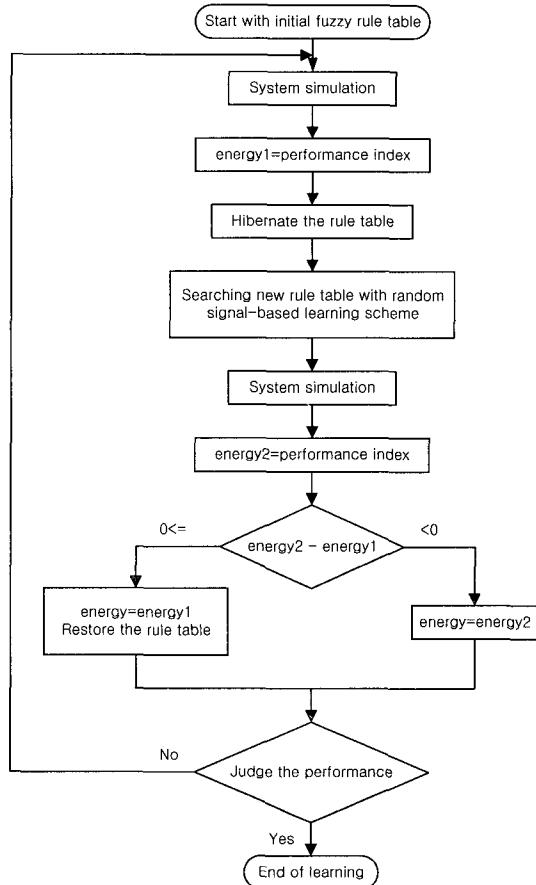


그림 2. 학습 흐름선도.

Fig. 2. Learning flow chart.

III. 랜덤 신호 학습 기반의 유전 알고리즘

유전 알고리즘은 풀고자 하는 문제에 대한 가능한 해들을 염색체(chromosome)로 표현한 다음 이들을 유전 연산자를 이용하여 점차적으로 변형함으로써 점점 더 좋은 해들을 생성한다. 유전 알고리즘이 기존의 탐색 방법과 구별되는 점 중의 하나는 점(point)에 의한 탐색이 아니라 군(population)에 의한 탐색이라는 것이다. 즉, 진화적 탐색에 있어서 임의의 값들로 초기화된 가능한 해의 집합(탐색군)으로 시작하여 세대 교체를 반복함으로써 점점 더 우수한 해의 집합을 생성하려 시도한다.

유전 알고리즘을 이용하여 어떤 문제의 해를 찾기 위해서는 먼저 두 가지의 준비 작업이 필요하다. 하나는 풀고자 하는 문제에 대한 가능한 해를 염색체의 형태로 표현(encoding)하는 것이다. 또 다른 하나는 각 염색체가 문제를 해결하는데 얼마나 좋은지를 측정하기 위한 적합도 함수(fitness function)를 결정하는 것이다.

1. 염색체 표현

문제에 대한 해를 염색체로 표현하는 방법은 문제마다 다르고 또한 적용하는 유전 알고리즘의 종류마다 다르다. 본 논문에서는 그림 3과 같이 폐지 제어 규칙 결론부의 중심값과 폭을 '0'과 '1'의 2진 문자열(string)로 나타내었다. 5개의 소속함수를 사용하므로 규칙의 수는 25개이다. 즉,

중심값과 폭의 개수는 각각 25개이다.

center(1)	center(2)	...	center(n)	width(1)	width(2)	...	width(n)
0100	0111	1110	0010	0101	1001

그림 3. 염색체의 구조($n=25$).

Fig. 3. The structure of the chromosome($n=25$).

중심값과 폭은 각각 4비트로 구성되므로 염색체의 길이는 200이다.

2. 적합도 함수

개체군 내의 각 개체(individual)에 대하여 유전 알고리즘을 적용하기 위해서는 그 개체가 풀고자 하는 문제에 어느 정도 적합도를 평가하는 적합도 함수를 사용해야 한다. 적합도 함수는 풀고자 하는 문제에 따라서 결정이 되며, 일반적으로 제어 분야에서는 오차, 제어시간 등을 이용하여 평가 함수를 산출하므로 평가 함수의 역수나 지수 함수를 사용하여 정의한다. 본 논문에서는 (7)의 평가 함수를 사용하고 적합도 함수는 (9)와 같이 정하였다.

$$F = 1/(1 + J) \quad (9)$$

여기서 적합도 함수 F 는 0~1사이의 값을 가진다.

3. 유전 연산자

유전 알고리즘은 복제, 교차, 돌연변이의 3개의 유전 연산자들을 사용하여 최적화를 행한다.

1) 복제 : 복제는 높은 적합도를 가지는 개체가 다음 세대에 더 많은 자손을 남기게 하는 과정이다. 본 논문에서는 복제를 위해 Roulette wheel selection을 사용한다. 적합도 F 를 갖는 개체는 적합도에 비례하여 (10)과 같이 더 높은 복제 확률 $P_{s,i}$ 를 가진다.

$$P_{s,i} = \frac{F_i}{\sum F_i} \quad (10)$$

2) 교차 : 복제된 개체들은 임의로 짹 지워져 교차 연산자에 의해 무작위로 선택된 교차 위치를 기준으로 두 개체 간의 유전자 값이 교환되어 새로운 두 개의 자식 개체가 생성된다. 교차는 확률 P_c 에 의해서 그 적용 빈도수가 제어된다.

3) 돌연변이 : 돌연변이 연산자는 이진 문자열을 염색체로 사용하는 유전 알고리즘의 경우, 각각의 비트에 대해 돌연변이 확률 P_m 에 따라 '0'은 '1'로 '1'은 '0'으로 변경하는 연산자이다. 문자열에 대한 돌연변이는 문자열에 있는 각각의 비트에 대한 돌연변이를 독립적으로 P_m 의 확률로 적용함으로써 수행된다.

4. 제안된 알고리즘

본 논문에서 제안된 랜덤 신호 학습 기반의 유전 알고리즘은 기존의 유전 알고리즘 연산자에 랜덤 신호 기반 학습을 추가로 넣으므로써 학습 속도, 수렴 시간 등에서 기존의 유전 알고리즘 또는 랜덤 신호 기반 학습만을 사용할 때 보다 우수함을 보이고자 한다.

그림 4는 제안된 알고리즘의 전체적인 흐름도를 나타내며 이것을 개략적으로 설명하면 다음과 같다.

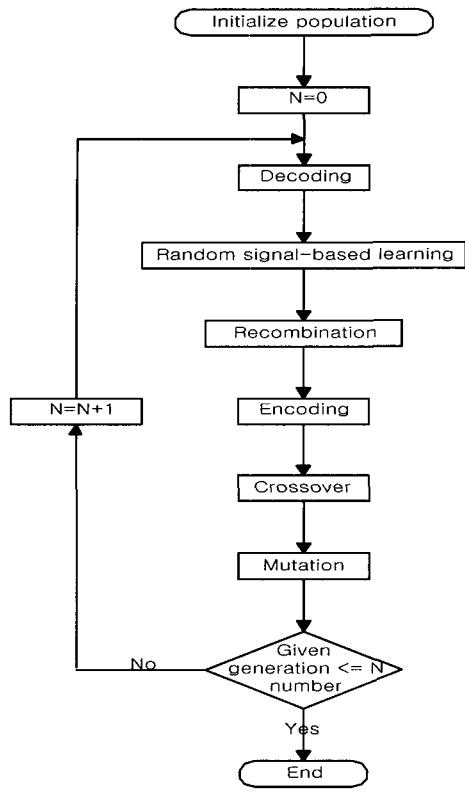


그림 4. 제안된 알고리즘의 전체 흐름도.

Fig. 4. Flow chart of the proposed algorithm.

- 1) Initialize population : 초기의 중심값과 폭을 무작위로 설정하여 2진 문자열로 나타낸다.
- 2) N=0 : 카운터 N을 0 으로 셋팅한다.
- 3) Decoding : 2진수 형태의 각 개체를 주어진 제약조건(constraint) 하에서 10진수로 나타낸다.
- 4) Random signal-based learning : 각각의 개체에 대해 랜덤 신호를 이용하여 중심값과 폭을 학습하고 그 결과 즉, 에너지를 학습 전과 비교하여 성능이 뛰어난 쪽의 중심값과 폭을 선택한다. 즉, 그림 2의 과정 2)에서 과정 8) 까지를 1회만 수행한다.
- 5) Recombination, Encoding, Crossover, Mutation : 유전 알고리즘의 유전 연산자이다. 여기서 Encoding은 과정 3)에서 Decoding 된 것을 다시 2진 문자열로 바꾸어 준다.
- 6) Given generation number<=N : 카운터 N이 주어진 세대(generation) 보다 작으면 카운터 N을 1 증가시켜 과정 3)으로 돌아가 반복 수행하고, 카운터 N이 주어진 세대와 같아지면 알고리즘을 종료한다.

IV. 모의 실험 및 결과

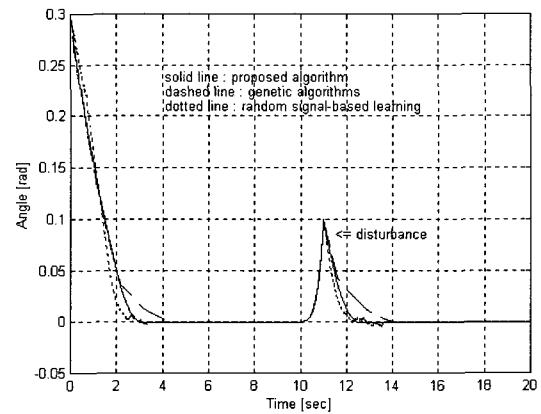
본 논문에서는 제안된 알고리즘의 우수성을 보이기 위하여 대표적인 비선형 시스템중의 하나인 도립 진자를 사용하여 모의 실험을 행하였다.

도립 진자의 수학적 모델링은 (11)과 같다.

$$(M+m)\ddot{x} - ml(\sin \theta)\dot{\theta}^2 + ml(\cos \theta)\dot{\theta} = u$$

$$m\ddot{x}\cos \theta + ml\ddot{\theta} = mg \sin \theta \quad (11)$$

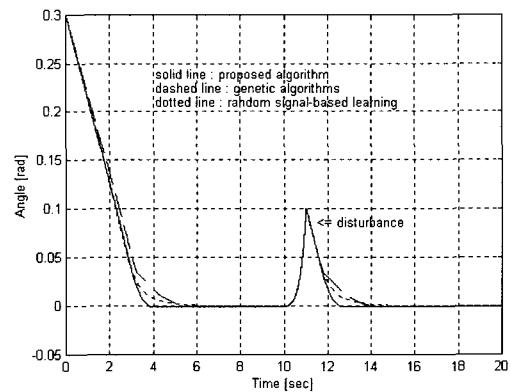
여기서 M 은 대차의 무게(3Kg), m 은 폴(pole)의 무게(0.1Kg), l 은 폴의 길이(0.6m), g 는 중력 가속도($9.8 m/s^2$)이다. 유전 알고리즘에서 세대의 크기 $G=100$, 개체군의 크기(population size)=10, 교차 확률 $P_c=0.6$, 돌연변이 확률 $P_m=0.013$ 이다. 또한 랜덤 신호 기반 학습에서 양극성 계단 함수인 활성 함수를 사용하였고 학습률은 0.026이며 사용된 폐지 멤버쉽 함수의 수는 5개이다. 모의 실험은 C 언어를 이용하여 팬티엄II 컴퓨터에서 실행하였다.



$$m=0.1Kg, l=0.6m$$

그림 5. 학습된 폐지 제어 규칙을 이용한 모의 실험 결과.

Fig. 5. Simulation results using the learned fuzzy rule table.



$$m=0.2Kg, l=1.2m$$

그림 6. 학습된 폐지 제어 규칙을 이용한 모의 실험 결과 (파라메터 변화).

Fig. 6. Simulation results using the learned fuzzy rule table (change parameters).

그림 5는 랜덤 신호 기반 학습, 유전 알고리즘, 제안된 알고리즘을 각각 이용하여 학습한 후 얻은 결과 즉, 최종 중심값과 폭(표 1, 표 2, 표 3)을 이용한 폐지 제어 규칙을 구성하여 폴(pole)의 무게 $m=0.1Kg$, 폴의 길이 $l=0.6m$ 즉, 학습시의 파

라메터 값과 동일하게 두고 초기 각도를 0.3rad 으로 도립 진자의 각도를 제어한 결과이다. 여기서 랜덤 신호 기반 학습은 평가 함수가 거의 변화가 없을 때까지 학습하였고 유전 알고리즘과 제안된 알고리즘은 100세대 동안 학습하였다. 그림 5에서 보는 바와 같이 본 논문에서 제안한 알고리즘에 의한 결과와 랜덤 신호 기반 학습에 의한 결과가 거의 비슷하나, 후자의 경우 0rad 에 수렴시 약간의 진동이 발생하고 유전 알고리즘의 경우는 수렴 속도가 상대적으로 느리다. 그리고 제어 시간이 약 10초 정도 되었을 때 인위적인 외란을 가하여 그 결과를 살펴 보면, 제안된 알고리즘에 의한 결과는 초기 수렴시와 같고 랜덤 신호 기반 학습의 경우는 수렴 후 약 2초간 진동이 발생하며 유전 알고리즘의 경우는 초기 수렴시와 같이 수렴 속도가 느린다.

그림 6은 랜덤 신호 기반 학습, 유전 알고리즘, 제안된 알고리즘을 각각 이용하여 학습한 후 얻은 최종 중심값과 폭(표 1, 표 2, 표 3)을 이용한 퍼지 제어 규칙을 구성하고, 폴(pole)의 무게 $m=0.2\text{Kg}$, 폴의 길이 $l=1.2\text{m}$ 로 변화시킨 다음 초기 각도를 0.3rad 으로 도립 진자의 각도를 제어한 결과이다.

그림 6에서 보는 바와 같이 도립 진자의 파라메터를 m 은 0.1Kg 에서 0.2Kg 으로 l 은 0.6m 에서 1.2m 로 변화하였을 때 본 논문에서 제안한 알고리즘에 의한 결과는 파라메터 변화에 의한 수렴 속도의 변화가 적으나 유전 알고리즘과 랜덤 신호 기반 학습만을 이용한 결과에서는 파라메터 변화에 의한 수렴 속도의 변화가 큰 것을 볼 수 있다. 그리고 그림 5에서와 같이 10초 정도 되었을 때 외란을 가하면, 그 결과가 모두 초기 수렴시와 유사한 것을 볼 수 있다.

그림 5와 그림 6의 결과에 의해서 본 논문에서 제안한 알고리즘이 수렴 속도, 파라메터 변화와 외란 인가에 대한 강인성 등의 면에서 랜덤 신호 기반 학습과 유전 알고리즘 보다 우수한 것을 알 수 있다.

표 1은 본 논문에서 제안한 알고리즘을 이용하여 학습한 중심값과 폭의 최종값이다. 표 2, 표 3은 유전 알고리즘과 랜덤 신호 기반 학습만을 각각 이용하여 학습한 중심값과 폭의 최종값이다. 표에서 괄호 밖의 숫자는 중심값이고, 괄호 안의 숫자는 폭이다.

표 1, 표 2, 표 3에서 e 가 ZE이고 \dot{e} 가 ZE인 룰과 이와 인접한 룰의 중심값과 폭을 각 표 끼리 비교해 보면 중심값의 크기는 큰 차이가 없으나 폭의 크기는 차이가 많이

표 1. 제안된 알고리즘으로 학습된 중심값과 폭.
Table 1. Centers and widths learned by the proposed algorithm.

$e \setminus \dot{e}$	NB	NM	ZE	PM	PB
NB	0.73(1.9)	0.65(0.4)	0.79(0.5)	0.41(0.4)	0.01(2.0)
NM	0.68(0.1)	0.89(0.2)	0.28(0.1)	-0.01(1.9)	-0.95(1.5)
ZE	0.79(1.4)	0.52(0.7)	-0.04(0.6)	-0.36(0.1)	-1.0(2.0)
PM	0.28(0.1)	0.07(0.5)	-0.55(0.4)	-0.73(1.1)	-0.76(2.0)
PB	0.2(1.2)	-0.49(0.1)	-0.87(1.5)	-0.68(0.9)	-0.87(1.0)

표 2. 유전 알고리즘 만으로 학습된 중심값과 폭.
Table 2. Centers and widths learned by genetic algorithms only.

$e \setminus \dot{e}$	NB	NM	ZE	PM	PB
NB	1.0(0.5)	0.89(0.3)	0.87(0.3)	0.44(1.6)	0.01(2.2)
NM	0.6(1.1)	0.71(0.9)	0.36(1.5)	0.01(3.0)	-0.92(0.68)
ZE	0.97(2.8)	0.33(2.4)	-0.01(1.5)	-0.41(0.5)	-0.65(1.1)
PM	0.31(1.6)	0.12(1.1)	-0.25(0.9)	-0.73(1.5)	-0.84(2.8)
PB	-0.12(2.8)	-0.23(0.1)	-0.97(3.0)	-0.76(0.3)	-0.76(0.9)

표 3. 랜덤 신호 기반 학습 만으로 학습된 중심값과 폭.
Table 3. Centers and widths learned by random signal-based learning only.

$e \setminus \dot{e}$	NB	NM	ZE	PM	PB
NB	0.96(1.2)	1.02(0.8)	0.32(1.0)	0.44(1.0)	0.32(1.2)
NM	0.98(1.1)	0.42(1.0)	0.54(1.0)	-0.06(1.1)	-0.42(1.1)
ZE	0.9(1.1)	0.34(1.1)	0.0(1.1)	-0.46(1.0)	-0.94(1.0)
PM	0.46(1.0)	0.08(1.0)	-0.38(1.0)	-0.46(0.9)	-0.92(1.0)
PB	-0.1(1.0)	-0.52(0.8)	-0.42(0.9)	-0.98(0.9)	-0.86(1.0)

나는 것을 볼 수 있다. 상대적으로 표 1의 폭의 크기가 작은 것을 볼 수 있는데 이로 인해 0rad 부근에서의 수렴 속도가 표 2 표 3을 이용한 결과 보다 빠른 것을 그림 5, 그림 6에서 알 수 있다.

그림 7은 본 논문에서 제안한 알고리즘을 이용하여 모의 실험하였을 때 각 세대별 적합도의 합이고, 그림 8은 유전 알고리즘만을 이용하여 모의 실험하였을 때 각 세대별 적합도의 합이다. 랜덤 신호 기반 학습의 경우 적합도의 형태로 나타낼 수 없기 때문에 본 논문에서는 생략하였다.

그림 7과 그림 8에서 보는 바와 같이 본 논문에서 제안한 알고리즘에 의한 적합도의 합이 유전 알고리즘만을 이용한 학습 보다 학습 속도와 적합도의 크기면에서 우수한 것을 볼 수 있다.

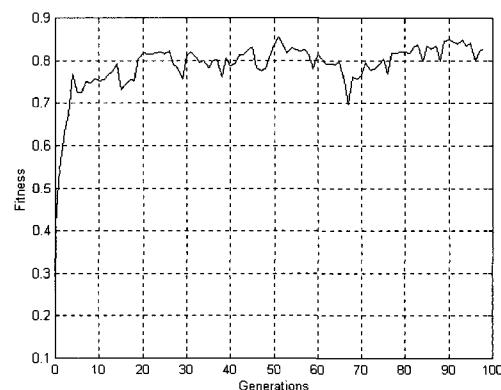


그림 7. 제안된 알고리즘에 의한 적합도의 합.
Fig. 7. Fitness for the proposed algorithm.

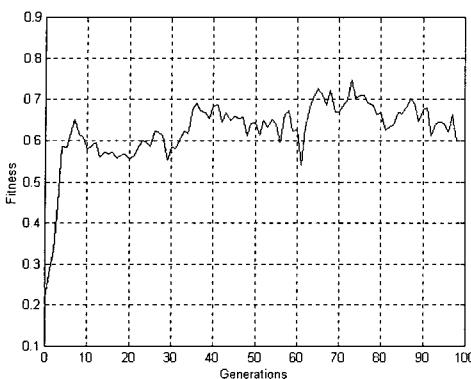


그림 8. 유전 알고리즘에 의한 적합도의 합.
Fig. 8. Fitness for the genetic algorithms.

그림 9, 그림 10, 그림 11은 본 논문에서 제안한 알고리즘과 유전 알고리즘 그리고 랜덤 신호 기반 학습 만을 각각 사용하여 구한 표 1, 표 2, 표 3의 결과를 이용하여 구한 오차와 오차 변화에 대한 제어 입력(force) 평면을 나타내고 있다. 그림 9에서 그림 10과 그림 11에 비해 상대적으로 제어 입력 평면의 경사가 심한 부분들이 있는데 이것은 수렴 속도를 향상시키는 역할을 하여 파라메터가 변하여도 수렴 속도가 빠른 것을 볼 수 있다. 그리고 오차와 오차의 변화가 0인 점 부근의 제어 입력 평면이 부드럽게 변화하고 있어서 진동 없이 수렴하는 결과가 나타난다.

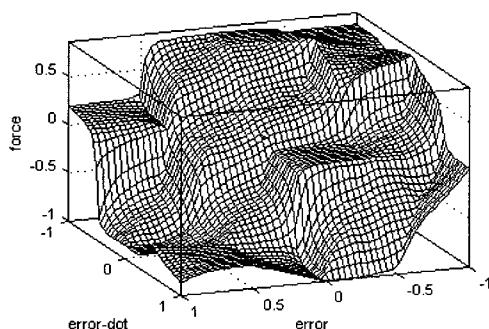


그림 9. 제안된 알고리즘에 의한 제어 입력 공간.
Fig. 9. Control input space of the proposed algorithm.

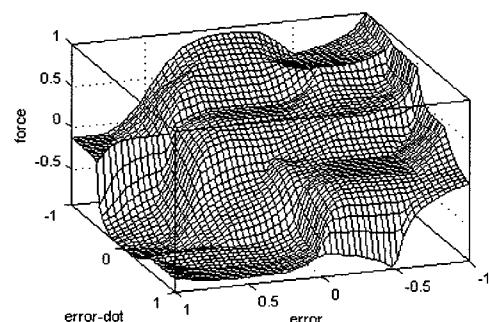


그림 10. 유전 알고리즘에 의한 제어 입력 공간.
Fig. 10. Control input space of the genetic algorithms

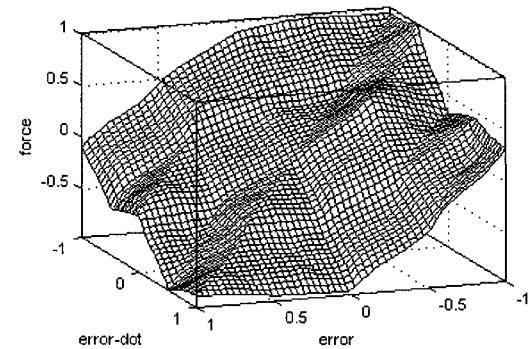


그림 11. 랜덤 신호 기반 학습에 의한 제어 입력 공간.
Fig. 11. Control input space of the random signal-based learning.

그림 10은 오차와 오차의 변화가 0인 점 부근에서 제어 입력 평면의 경사가 거의 없는 부분이 있어서 이 부근에서는 제어 입력의 변화가 없으므로 수렴 속도가 느린다. 즉, 학습된 결론부 소속함수의 모양이 표 2에서와 같이 0 부근에서 폭이 넓게 학습된 결과이다. 그리고 오차와 오차의 변화가 0인 점에서 제어 입력 평면이 부드럽게 변화하고 있으므로 진동 없이 수렴하는 결과가 나타난다. 그림 11은 오차와 오차의 변화가 0인 점을 대칭으로 제어 입력 평면이 날카롭게 올라온 부분이 있어서 부드러운 제어 입력 평면을 가지는 결과 보다 상대적으로 진동이 심하다. 그리고 그림 9는 그림 10과 그림 11이 복합된 형태이다. 즉, 0 부근은 그림 11과 비슷하나 뾰족한 부분이 없는 부드러운 평면이고, 그 외의 부분은 그림 10과 비슷하다. 이것은 본 논문에서 제안한 알고리즘이 유전 알고리즘과 랜덤 신호 기반 학습을 복합적으로 사용한 결과이다.

V. 결론

본 논문에서는 기존의 유전 알고리즘의 유전 연산자에 랜덤 신호 기반 학습을 추가하는 알고리즘을 제안하였다. 유전 연산자로 복제, 교차, 돌연변이만을 주로 사용하고 있는데 여기에 랜덤 신호 기반 학습을 추가함으로써 그 성능을 향상시키고자 하였다.

도입 진자의 모의 실험을 통하여 본 논문에서 제안한 알고리즘의 학습 결과와 유전 알고리즘, 랜덤 신호 기반 학습 만을 각각 이용한 학습 결과를 비교하여 본 논문에서 제안한 알고리즘이 학습 속도, 수렴 시간, 파라메터 변화와 외란에 대한 강인성 등에서 우수함을 입증할 수 있었으며, 다른 모든 최적화 문제에도 사용될 수 있을 것으로 사료된다.

향후 연구 과제로 최적해의 개체들을 초기에 몰아내어 유전적 다양성을 잃어버리는 문제와 초기에 조기 수렴이 되면 발생할지도 모르는 지역해로의 수렴 문제들을 해결하기 위하여 simulated annealing을 본 연구에 적용할 예정이다.

참고문헌

- [1] T. J. Procyk and E. H. Mamdani, "A linguistic

- self-organizing process controller," *Automatica*, vol. 15, no. 1, pp. 15-30, 1979.
- [2] K. Kavaklioglu and B. R. Upadhyaya, "Optimal fuzzy control design using simulated annealing and application to feedwater heater control," *Nuclear Technology*, vol. 125, no. 1, pp. 70-84, 1999.
- [3] Li-Xin Wang, "Automatic design of fuzzy controllers," *Proc. of the American Control Conference*, vol. 3, pp. 1853-1854, 1998.
- [4] M.-Y. Shieh, C.-W. Huang, and T.-H. S. Li, "A GA-based Sugeno-Type fuzzy logic controller for the Cart-Pole system," *Proc. of the 23rd International Conference on Industrial Electronics, Control, and Instrumentation*, vol. 3, pp. 1028-1033, 1997.
- [5] D. E. Goldberg, "Genetic algorithms in search, optimization and machine learning," Addison-Wesley, 1989.
- [6] Chin-Teng Lin, Chong-Ping Jou, and Cheng-Jiang Lin, "GA-based reinforcement learning for neural networks," *International Journal of System Science*, vol. 29, no. 3, pp. 233-247, 1998.
- [7] A. Homaifar and E. McCormick, "Simultaneous design of membership functions and ruleets for fuzzy controllers using genetic algorithms," *IEEE Trans. Fuzzy Syst.*, vol. 3, pp. 129-139, 1995.
- [8] S. H. Jeong, C. W. Han, J. I. Park, and S. H. Kwon, "A study on learning scheme of self-learning rule-based fuzzy controller using random variable sequence," *Proc. of the American Control Conference*, vol. 3, pp. 1862-1863, 1998.
- [9] J. Lei, G. He, and J. P. Jiang, "The state estimation of the CSTR system based on a recurrent neural network trained by HGAs," *Proc. of the International Conference on Neural Networks*, vol. 2, pp. 779-782, 1997.
- [10] 장병탁, "인공 진화에 의한 학습 및 최적화," 제어·자동화·시스템공학회지, 제1권, 제3호, pp. 52-61, 1995.



한 창 육

1971년 1월 25일생. 1994년 2월 영남대학교 전자공학과 졸업(공학사). 1996년 2월 영남대학교 대학원 전자공학과 졸업(공학석사). 1997년 9월 ~ 현재 영남대학교 대학원 전자공학과 박사수료. 1996년 2월 ~ 1997년 8월 현대중공업 전력제어설계부 근무. 관심분야는 지능제어, 유전 알고리즘, 퍼지시스템, 신경회로망.



박 정 일

1958년 4월 8일생. 1981년 2월 경북대학교 전자공학과 졸업(공학사). 1983년 2월 서울대학교 대학원 전자공학과 졸업(공학석사). 1989년 2월 서울대학교 대학원 전자공학과 졸업(공학박사). 1983년 4월 ~ 1985년 12월 삼성전자 종합연구소 연구원. 1989년 4월 ~ 1992년 2월 삼성종합기술원 전자기기 연구소 선임연구원. 1992년 3월 ~ 현재 영남대학교 전자정보공학부 부교수. 1998년 1월 ~ 1999년 1월 University of Illinois at Urbana-Champaign 방문교수. 관심분야는 지능제어, 리니어·서보모터 제어, 메카트로닉스, 적용학습 시스템.