

## 유전 알고리즘과 시뮬레이티드 어닐링이 적용된 적응 랜덤 신호 기반 학습에 관한 연구

### A Study on Adaptive Random Signal-Based Learning Employing Genetic Algorithms and Simulated Annealing

한창욱, 박정일

(Chang-Wook Han and Jung-Il Park)

**Abstract :** Genetic algorithms are becoming more popular because of their relative simplicity and robustness. Genetic algorithms are global search techniques for nonlinear optimization. However, traditional genetic algorithms, though robust, are generally not the most successful optimization algorithm on any particular domain because they are poor at hill-climbing, whereas simulated annealing has the ability of probabilistic hill-climbing. Therefore, hybridizing a genetic algorithm with other algorithms can produce better performance than using the genetic algorithm or other algorithms independently. In this paper, we propose an efficient hybrid optimization algorithm named the adaptive random signal-based learning. Random signal-based learning is similar to the reinforcement learning of neural networks. This paper describes the application of genetic algorithms and simulated annealing to a random signal-based learning in order to generate the parameters and reinforcement signal of the random signal-based learning, respectively. The validity of the proposed algorithm is confirmed by applying it to two different examples.

**Keywords :** random signal-based learning, genetic algorithms, simulated annealing, 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 기반 되었다 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], 적응 퍼지 제어기(adaptive fuzzy controller)를 이용하여 퍼지 제어 규칙을 자동으로 생성하거나[3], Sugeno 형태의 퍼지 제어기의 결론부 파라미터들을 유전 알고리즘을 이용하여 구하기도 하였다[4].

유전알고리즘(genetic algorithms:GAs)은 자연 세계의 진화 과정을 컴퓨터 상에서 시뮬레이션 함으로써 복잡한 실제 세계의 문제를 해결하고자 하는 도구이다. 1970년대 초반 J. Holland에 의해 제시된 유전 알고리즘[5]은 자연계에 존재하는 적자생존의 원리와 유전학에 기초하여 집단내 개체들을 모의진화시킴으로써 전역해(global minima)를 찾아가는 최적화 기법이다. 유전알고리즘이 기존의 최적화 이론들과 근본적으로 다른 점은 목적함수의 도함수를 사용하지 않

며 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. 이러한 장점 때문에 유전알고리즘은 최근 주목받는 최적화 기법중의 하나가 되었으며 최근 들어 특히 신경망과 퍼지 로직과 결합한 적용 사례들이 많이 발표되고 있다. Lin 등[6]은 논문에서는 유전 알고리즘을 신경망의 연결 강도를 최적화 하는데 이용하였고, Homairfar 등[7]은 유전알고리즘을 이용하여 퍼지 제어기의 소속함수와 제어 규칙을 동시에 최적화하였다. 유전알고리즘은 전역 탐색 기능은 뛰어나나 근사 전역해(approximate global solution)를 찾는다 단점이 있다.

Kirkpatrick[8]에 의해서 소개된 시뮬레이티드 어닐링(simulated annealing:SA)은 금속의 열처리 중의 하나인 금속 어닐링의 개념으로부터 유추되었으며, 에너지가 낮아지는 방향으로의 이동은 항상 허용되며, 에너지가 높아지는 방향으로의 이동은 온도의 함수인 확률에 따라 허용된다. 시뮬레이티드 어닐링은 고차의 문제를 해결하는 능력이 뛰어나지만 속도가 느리다.

랜덤 신호 기반 학습(random signal-based learning)[9]은 본 논문의 저자들이 최초로 제안한 것으로 신경망(neural networks)의 학습에 랜덤 신호를 적용한 것이다. 랜덤 신호를 발생하여 양극성 계단 함수(bipolar step function)인 활성화 함수(activation function)를 통과시킨 값으로 학습을 수행하고, 이전 단계와 서로 에너지를 비교하여 강화 신호(reinforcement signal)를 내보낸다.

본 논문에서는 유전알고리즘을 이용하여 랜덤 신호 기반 학습의 파라미터인 학습률과 이산 랜덤 값을 각각 생성하고

[10], 시뮬레이티드 어닐링을 이용하여 랜덤 신호 기반 학습의 강화 신호를 생성하는[11] 적응 랜덤 신호 기반 학습 알고리즘을 제안하고자 한다. 랜덤 신호 기반 학습에서 학습율이 고정되어 있는 경우 지역해로 수렴하거나 거친 학습(coarse learning)이 수행되지만 유전알고리즘을 이용하여 학습률을 적절히 변화시킴으로써 전역 탐색 및 미세한 탐색이 가능하며, 시뮬레이티드 어닐링을 이용하여 강화 신호를 생성함으로써 비록 적합도는 작지만 최적해의 유전자를 보유한 개체들을 초기에 몰아내어 유전적 다양성을 잃게 되는 문제와 초기 세대에 적합도가 큰 초우량 지역해의 출현으로 인한 조기수렴 문제를 해결할 수 있을 것이다. 즉, 유전알고리즘의 경우 문제가 복잡해질수록 개체군의 크기가 커져야 지역해로의 조기 수렴 문제를 해결할 수 있으나 확률적인 hill-climbing 기능을 가지고 있는 시뮬레이티드 어닐링을 적용함으로써 개체군의 크기를 증가시키지 않고 지역해로의 조기 수렴 문제를 해결할 수 있을 것이다. 제안된 알고리즘을 이용하여 비선형 함수의 최적화와 퍼지 제어를 이용한 도립진자의 모의실험을 수행하고, 이를 통하여 그 유용성을 확인하고자 한다.

**II. 랜덤 신호 기반 학습**

신경망 학습은 시냅스 강도(synapse strength)가 어떠한 정보를 가지는 규정된 규칙에 의해서 바뀌는 과정이다. Hebb[12]은 학습 규칙을 다음과 같이 나타내었다. 두 개의 뉴런 A, B가 서로 연결되어 있을 때 뉴런 A가 활성화 되면 뉴런 B 또한 활성화 된다. 결과적으로 뉴런 A, B 사이의 시냅스 강도는 (1)과 같이 나타낸다. 여기서  $m$ 은 시냅스 강도,  $\eta$ 는 학습 계수,  $y$ 는 시스템 출력이다.

$$m_{BA}^{new} = m_{BA}^{old} + \eta y_A y_B \tag{1}$$

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

$$\dot{m} = 0 \tag{2}$$

인위적인 학습을 위하여 의도적으로 정규 백색 잡음  $\{n(t)\}$ 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.

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

학습 방법은 (4)와 같다.

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

여기서  $\eta$ : 학습률  
 $f$ : 활성화 함수  
 $n$ : 0에서 1 사이의 이산 랜덤 값

$\theta$ : 바이어스(=0.5)

$r(t)$ : 강화 학습 신호

그리고 강화 학습 신호  $r(t)$ 는 다음과 같이 정의된다.

$$r(t) = u(J(t) - J(t-1)) \tag{5}$$

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

위의 학습 방법에서 시냅스는 학습 후에 평가함수가 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 활성화 함수  $f$ 는 (6)과 같다.

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

**III. 시뮬레이티드 어닐링**

시뮬레이티드 어닐링은 금속의 열처리 중의 하나인 금속 어닐링의 개념으로부터 유추되었다. 금속 어닐링에서는 금속을 녹는 점의 고온의 상태에서 서서히 온도를 낮추면 저온에서 저 에너지의 금속 격자가 형성된다.

이와 유사하게 시뮬레이티드 어닐링에서는 최적화하고자 하는 시스템에 초기에는 높은 온도를 부여하고 이 온도를 낮추어 나간다. 그러면 이 시스템은 볼츠만 확률 분포(Boltzmann distribution)에 따라 새로운 상태로 변하게 되는데, 최종적으로 더이상의 에너지 변화가 없을 때 최적 해를 구하게 된다. 에너지가 낮아지는 방향으로의 이동은 항상 허용되며, 에너지가 높아지는 방향으로의 이동은 온도의 함수인 선택 확률에 따라 허용된다. 선택 확률은 다음과 같이 볼츠만 확률 분포를 따른다.

$$p = \exp(-\Delta E/T) \tag{7}$$

여기서  $\Delta E$ 는 평가 함수의 변화이고,  $T$ 는 온도이다. 만약,  $\Delta E$ 가 음이면, 즉 에너지가 낮아지는 방향으로 이동하면 새로운 해는 항상 선택되고,  $\Delta E$ 가 양이면, 즉 에너지가 높아지는 방향으로 이동하면 새로운 해는 (7)의 확률이 랜덤하게 생성된 0에서 1 사이의 값 보다 클 때 선택이 된다. 이와 같이 에너지가 증가하는 방향으로의 이동을 허용함으로써 지역 극소점을 탈출할 수 있게 하는 것이다.

새로운 해의 수용 여부가 결정이 되면, 온도  $T$ 는 냉각 과정(cooling schedule)에 의해서 조정된다. 그리고 이러한 과정은 만족할만한 결과가 나올 때까지 반복된다. 본 논문에서는 학습 속도를 고려하여 지수함수의 냉각 과정을 사용한다[13]. 최적화 동안 각 단계에서의 온도는 다음과 같다.

$$T_k = \alpha^k T_0 \tag{8}$$

여기서  $T_0$ 는 초기 온도,  $\alpha$ 는 냉각률(cooling rate),  $k$ 는 반복 시간을 각각 나타낸다.

c_learn24	c_learn0	c_rand24	c_rand0	w_learn24	w_learn0	w_rand24	w_rand0
0100	0111	1110	0010	0101	1001	1101	1000

w\_rand0~w\_rand24:random numbers for the widths  
w\_learn0~w\_learn24:learning rates for the widths  
c\_rand0~c\_rand24:random numbers for the centers  
c\_learn0~c\_learn24:learning rates for the centers

그림 1. 염색체의 구조.

Fig. 1. The structure of the chromosome.

IV. 제안된 알고리즘

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

유전알고리즘을 이용하여 어떤 문제의 해를 찾기 위해서는 먼저 두 가지의 준비 작업이 필요하다. 하나는 풀고자 하는 문제에 대한 가능한 해를 염색체의 형태로 표현하는 것이고, 또 다른 하나는 각 염색체가 문제를 해결하는데 얼마나 좋은지를 측정하기 위한 적합도(fitness)를 결정하는 것이다.

1. 염색체 표현

문제에 대한 해를 염색체로 표현하는 방법은 문제마다 다르고 또한 적용하는 유전알고리즘에 따라 다르다. 본 논문에서는 (4)의 학습률  $\eta$ 와 이산 랜덤 값  $n$ 을 유전알고리즘을 이용하여 구하므로 이것을 염색체로 표현한다.

퍼지 제어기를 이용하여 독립진자를 제어하는 경우 그림 1과 같이  $\eta$ 와  $n$ 을 각각 4비트의 '0'과 '1'의 2진 문자열(string)로 나타내었다. 5개의 소속함수를 사용하므로 퍼지 제어 규칙의 수는 25개이다. 즉, 결론부 소속함수의 중심값과 폭의 개수는 각각 25개이다. 25개의 중심값과 25개의 폭이 4비트로 구성된  $\eta$ 와  $n$ 으로 각각 학습되므로 염색체의 길이는 400이다. 비선형 함수 최적화의 경우  $\eta$ 와  $n$ 을 각각 8비트의 '0'과 '1'의 2진 문자열로 나타내므로 염색체의 길이는 16이다.

2. 적합도 함수

개체군 내의 각 개체(individual)에 대하여 유전알고리즘을 적용하기 위해서는 그 개체가 풀고자 하는 문제에 어느 정도 적합한지를 평가하는 적합도 함수를 사용해야 한다. 적합도 함수는 풀고자 하는 문제에 따라서 결정이 되며, 일반적으로 제어 분야에서는 오차, 제어시간 등을 이용하여 평가함수를 산출하므로 평가함수의 역수나 지수 함수를 사용하여 정의한다. 본 논문에서는 (10)과 (12)의 평가함수를 사용하여 적합도 함수를 (9)와 같이 정의하였다.

$$F = 1/(1 + J) \tag{9}$$

여기서 적합도 함수  $F$ 는 0~1 사이의 값을 가진다.

3. 유전 연산자

유전알고리즘은 복제, 교차, 돌연변이 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 선택을 사용한다.

2) 교차 : 복제된 개체들은 임의로 짝 지어져 무작위로 선택된 교차 위치를 기준으로 유전자 값이 교환되어 새로운 두 자식 개체가 생성된다. 교차는 확률  $P_c$ 에 의해서 그 빈도수가 제어된다.

3) 돌연변이 : 돌연변이 연산자는 이진 염색체를 사용하는 유전알고리즘의 경우, 각각의 비트에 대해 돌연변이 확률  $P_m$ 에 따라 '0'은 '1'로 '1'은 '0'으로 변경한다.

4. 제안된 알고리즘

본 논문에서는 단순유전알고리즘(SGA)을 이용하여 랜덤 신호 기반 학습의 파라미터인 학습률과 이산 랜덤 값을 각각 생성하여 학습을 수행한 후 시뮬레이터 어닐링을 이용하여 (4)의 강화 신호  $r(t)$ 를 생성하여 SGA에 의해서 새롭게 생성된 개체들, 즉 학습률과 이산 랜덤 값의 수용 여부를 결정한다.

그림 2는 제안된 알고리즘의 전체적인 흐름도를 나타내며 이것을 개략적으로 설명하면 다음과 같다.




그림 2. 제안된 알고리즘의 흐름도.

Fig. 2. Flow chart of the proposed algorithm.

- 1) 초기 해와 개체들을 랜덤하게 설정한다.
- 2) 현재의 개체들을 임의의 장소에 기억시켜놓고 SGA를 수행한다.
- 3) SGA 수행전의 평가함수를 E1에 넣고 수행후의 평가함수를 E2에 넣는다.
- 4) E1, E2를 비교하여 E2가 작으면 SGA 수행후의 개체들을 받아들이고, 그렇지 않으면 SA를 이용하여 새로운 개체들을 받아들일 것인지, 아니면 수행전의 개체들을 받아들일 것인지 결정한다.
- 5) SGA 전후의 개체들을 이용하여 학습된 해 중에서 최적의 해를 현재의 해로 두고, 학습 종료 조건이 만족되면 알고리즘을 종료하고 그렇지 않으면 학습 종료 조건이 만족될 때까지 반복 수행한다.

**V. 모의 실험 및 결과**

본 논문에서는 제안된 알고리즘의 우수성을 보이기 위하여 두 가지 예를 적용하여 모의 실험을 수행하였다.

**1. 비선형 함수를 이용한 최적화**

첫 번째 예는 그림 3에 나타낸 (10)의 비선형 함수를 최소로 하는  $x$ 를 찾는 것이다[13].

$$F(x) = \frac{(x+0.9)(x+0.7)(x+0.2)}{(x-0.4)(x-0.7)(x-0.9)} + 0.04 \quad (10)$$

여기서  $-1 < x < 1$  이다.

그림에서 알 수 있듯이  $F(x)$ 는 두 개의 지역해와 한 개의 전역해 0.07715를 가지고 있다.

SGA에서 세대의 크기  $G=50$ , 개체군의 크기  $N=10$ , 교차 확률  $P_c=0.6$ , 돌연변이 확률  $P_m=0.013$ 이고, SA의 초기 온도  $T_0$ 는 20, 냉각률  $\alpha$ 는 0.98이다. 랜덤 신호 기반 학습에서 양극성 계단 함수인 활성 함수를 사용하였다.

그림 4는 제안된 알고리즘으로  $x$ 의 초기 값을 각각 다르게 설정하여 독립적으로 6번 실험하였을 때 각 세대별 최적의 적합도를 가지는  $x$ 를 나타내었다. 그림에서 보는 바와 같이 항상 전역해인 0.07715에 수렴하는 것을 볼 수 있다. 그림 5는 SGA 만을 이용하여 독립적으로 실험한 것으로서 근사 전역해에 수렴하는 것을 볼 수 있다. 그림 6은 랜덤 신호




그림 3. 비선형 함수  $F(x)$ .  
Fig. 3. A nonlinear function  $F(x)$ .




그림 4. 각 세대별 최적의  $x$ (제안된 알고리즘).  
Fig. 4. The best  $x$  in each generation(proposed algorithm).

기반 학습만을 이용하여 독립적으로 실험을 수행한 것으로서 지역해에 수렴하는 것을 볼 수 있다. 그리고 그림 7은 SA 만을 이용하여 독립적으로 2번 실험한 것으로서 각각 전역해에 수렴하고 있으나 SA의 단점인 학습 시간이 상대적으로 오래 걸린다. 수렴할 때까지의 평가함수 산출 회수를 비교해 보면 제안된 알고리즘은 약 340( $17 \times 20$ ), SGA은 약 290( $29 \times 10$ ) 그리고 SA은 약 750이다. 수렴시까지의 평가함수 산출 회수는 SGA이 제안된 알고리즘 보다 약 50회 적으




그림 5. 각 세대별 최적의  $x$ (SGA).  
Fig. 5. The best  $x$  in each generation(SGA).




그림 6. 각 단계별 산출된  $x$ (랜덤 신호 기반 학습).  
Fig. 6. The estimated  $x$  in each iteration(random signal-based learning).




그림 7. 각 단계별 산출된  $x$ (SA).  
Fig. 7. The estimated  $x$  in each iteration(SA).

나 근사 전역해로 수렴하고 있다. 그러나 제안된 알고리즘은 항상 전역해로 수렴하고 있다.

2. 자기 학습 퍼지 제어를 이용한 도립진자의 제어

또 다른 예는 대표적인 비선형 시스템 중의 하나인 도립진자를 사용하여 모의 실험을 수행하였다.

도립진자의 수학적 모델링은 (11)과 같다.

$$\begin{aligned} (M+m)\ddot{x} - ml(\sin\theta)\ddot{\theta} + ml(\cos\theta)\dot{\theta}^2 &= u \\ m\dot{x}\cos\theta + ml\dot{\theta} &= mg\sin\theta \end{aligned} \quad (11)$$

여기서  $M$ 은 대차의 무게(3Kg),  $m$ 은 폴(pole)의 무게(0.1 Kg),  $l$ 은 폴의 길이(0.6m),  $g$ 는 중력 가속도( $9.8 \text{ m/s}^2$ )이다. SGA에서 세대의 크기  $G=100$ ,  $N=10$ , 교차 확률  $P_c=0.6$ , 돌연변이 확률  $P_m=0.013$ 이고, SA의 초기 온도  $T_0$ 는 10, 냉각률  $\alpha$ 는 0.98이다. 랜덤 신호 기반 학습에서 양극성 계단 함수인 활성화 함수를 사용하였고 사용된 퍼지 소속함수의 수는 5개이다.

평가함수는 다음과 같다.

$$J = \sum_{i=0}^P [e_i^2 + \dot{e}_i^2] \quad (12)$$

여기서  $e$ 는 오차,  $\dot{e}$ 는 오차의 변화분 그리고  $P$ 는 입·출력 데이터의 수이다. 같은 초기 각도로 주어진 시간 동안 도립진자를 안정화하는 과정에 평가 함수를 산출한다.

본 논문에서는 문제를 간단히 하기 위해서 퍼지 제어 규칙의 조건부(antecedent part)는 고정시키고 결론부(consequent part)만을 학습 대상으로 고려하였다[3][4]. 즉, 결론부 소속함수의 중심값과 폭을 학습시켜서 평가 함수가 최소화 되도록 하는 것이다.

제안된 알고리즘을 이용한 자기 학습 퍼지 제어기의 구조를 그림 8에 나타내었다.

표 1은 본 논문에서 제안한 알고리즘을 이용하여 학습한 중심값과 폭의 최종값이다. 표 2, 표 3, 표 4는 SGA, 랜덤 신호 기반 학습 그리고 SA만을 각각 이용하여 학습한 중심값과 폭의 최종값이다. 표에서 괄호 밖의 숫자는 중심값이고,

괄호 안의 숫자는 폭이다.




그림 8. 제안된 알고리즘을 이용한 자기 학습 퍼지 제어기의 구조.

Fig. 8. The structure of the self-learning fuzzy controller using the proposed algorithm.

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	1.01(0.24)	0.89(0.10)	0.43(0.13)	-0.01(0.30)	-0.18(0.01)
NM	0.67(0.15)	0.31(0.11)	0.22(0.11)	-0.18(0.08)	-0.53(0.11)
ZE	0.65(0.14)	0.62(0.22)	0.003(0.07)	-0.60(0.24)	-0.63(0.15)
PM	0.55(0.14)	0.21(0.09)	-0.24(0.13)	-0.28(0.13)	-0.60(0.19)
PB	0.21(0.02)	0.05(0.25)	-0.49(0.09)	-0.90(0.07)	-1.03(0.23)

표 2. SGA에 의해 학습된 중심값과 폭.

Table 2. Centers and widths learned by the SGA.

$e \setminus \dot{e}$	NB	NM	ZE	PM	PB
NB	1.00(0.49)	0.89(0.29)	0.87(0.29)	0.44(1.65)	0.01(2.23)
NM	0.6(1.07)	0.71(0.87)	0.36(1.45)	0.01(3.00)	-0.92(0.68)
ZE	0.97(2.81)	0.33(2.42)	-0.01(1.45)	-0.41(0.49)	-0.65(1.07)
PM	0.31(1.65)	0.12(1.07)	-0.25(0.87)	-0.73(1.45)	-0.84(2.81)
PB	-0.12(2.81)	-0.23(0.10)	-0.97(3.00)	-0.76(0.29)	-0.76(0.87)

표 3. 랜덤 신호 기반 학습만으로 학습된 중심값과 폭.

Table 3. Centers and widths learned by random signal-based learning

$e \setminus \dot{e}$	NB	NM	ZE	PM	PB
NB	0.96(1.18)	1.02(0.76)	0.32(0.96)	0.44(1.02)	0.32(1.18)
NM	0.98(1.14)	0.42(0.96)	0.54(1.00)	-0.06(1.08)	-0.42(1.08)
ZE	0.9(1.08)	0.34(1.12)	0.00(1.06)	-0.46(1.00)	-0.94(0.96)
PM	0.46(1.02)	0.08(1.04)	-0.38(0.96)	-0.46(0.92)	-0.92(0.96)
PB	-0.1(1.02)	-0.52(0.84)	-0.42(0.86)	-0.98(0.88)	-0.86(1.02)

표 4. SA 만으로 학습된 중심값과 폭.

Table 4. Centers and widths learned by SA.

$e \setminus \dot{e}$	NB	NM	ZE	PM	PB
NB	0.72(0.78)	1.10(0.90)	0.22(1.18)	0.68(0.72)	0.22(0.26)
NM	1.10(0.54)	-0.08(1.36)	0.10(1.24)	0.14(1.02)	-0.14(1.14)
ZE	1.08(1.02)	0.82(1.04)	0.00(0.52)	-0.32(0.76)	-1.14(0.92)
PM	0.34(0.52)	0.38(1.10)	-0.14(0.74)	-0.96(1.28)	-0.76(1.10)
PB	-0.32(0.74)	-0.46(0.96)	-0.12(1.14)	-1.40(0.70)	-1.10(1.20)

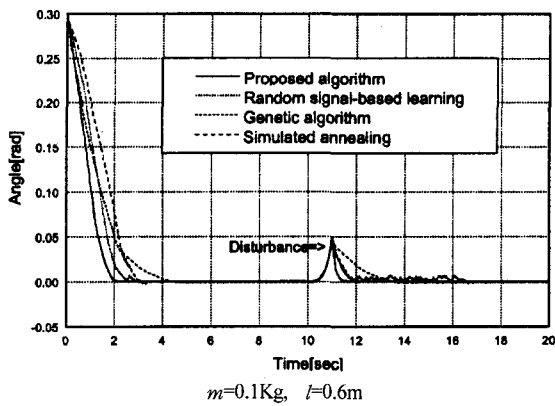


그림 9. 학습된 퍼지 제어 규칙을 이용한 모의 실험 결과.  
Fig. 9. Simulation results using the learned fuzzy rule table.

그림 9는 제안된 알고리즘, 랜덤 신호 기반 학습, SGA 그리고 SA를 각각 이용하여 학습한 후 얻은 결과, 즉 최종 중심값과 폭(표 1, 표 2, 표 3, 표 4)을 이용한 퍼지 제어 규칙을 구성하여 폴(pole)의 무게  $m=0.1\text{Kg}$ , 폴의 길이  $l=0.6\text{m}$ , 즉 학습시의 파라미터 값과 동일하게 두고 초기 각도를 0.3rad으로 도립 진자의 각도를 제어한 결과이다. 여기서 랜덤 신호 기반 학습과 SA는 평가함수가 거의 변화가 없을 때까지 학습하였고 SGA와 제안된 알고리즘은 100세대 동안 학습하였다. 그림 9에서 보는 바와 같이 본 논문에서 제안한 알고리즘에 의한 결과의 수렴 속도가 훨씬 빠른 것을 볼 수 있다. 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 진동이 발생하며 SGA의 경우는 초기 수렴시와 같이 수렴 속도가 느리다.

그림 10은 제안된 알고리즘, 랜덤 신호 기반 학습, SGA 그리고 SA를 각각 이용하여 학습한 후 얻은 최종 중심값과 폭(표 1, 표 2, 표 3, 표 4)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 0.3rad으로 도립 진자의 각도를 제어한 결과이다. 그림 10에서 보는 바와 같이 도립 진자의 파라메

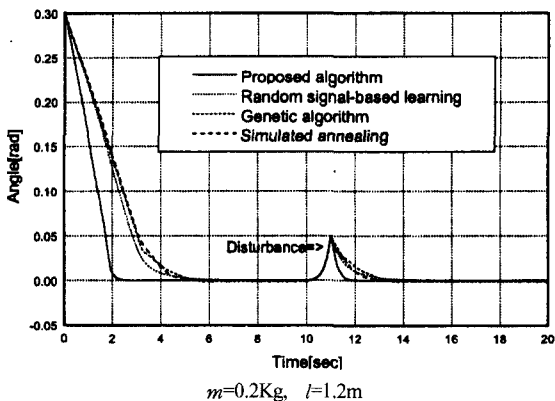


그림 10. 학습된 퍼지 제어 규칙을 이용한 모의 실험 결과 (파라미터 변화).  
Fig. 10. Simulation results using the learned fuzzy rule table (change parameters).

터를  $m$ 은 0.1Kg에서 0.2Kg으로  $l$ 은 0.6m에서 1.2m로 변화하였을 때 본 논문에서 제안한 알고리즘에 의한 결과는 파라미터 변화에 의한 수렴 속도의 변화가 거의 없으나 SGA, 랜덤 신호 기반 학습 그리고 SA만을 이용한 결과에서는 파라미터 변화에 의한 수렴 속도의 변화가 큰 것을 볼 수 있다. 그리고 그림 9에서와 같이 10초 정도 되었을 때 외란을 가하면, 그 결과가 모두 초기 수렴시와 유사한 것을 볼 수 있다.

그림 9와 그림 10의 결과에 의해서 본 논문에서 제안한 알고리즘이 수렴 속도, 파라미터 변화와 외란 인가에 대한 강인성 등의 면에서 랜덤 신호 기반 학습, SGA 그리고 SA보다 우수한 것을 알 수 있다.

그림 11은 본 논문에서 제안한 알고리즘을 이용하여 모의 실험하였을 때 최적성능이고, 그림 12는 SGA만을 이용하여 모의 실험하였을 때의 최적성능이다. 랜덤 신호 기반 학습과 SA의 경우 최적성능을 비교할 수 없기 때문에 생략하였다.

그림 11과 그림 12에서 보는 바와 같이 본 논문에서 제안한 알고리즘의 성능이 SGA를 이용한 것 보다 학습 속도와 성능면에서 우수한 것을 알 수 있다.

그림 13, 그림 14, 그림 15, 그림 16은 본 논문에서 제안한 알고리즘, SGA, 랜덤 신호 기반 학습 그리고 SA만을 각각 사용하여 구한 표 1, 표 2, 표 3, 표 4의 결과를 이용하여 구한 오차와 오차 변화에 대한 제어 입력 평면을 나타내고 있다. 그림 13을 보면 그림 14와 그림 15에 비해 상대적으로 제어

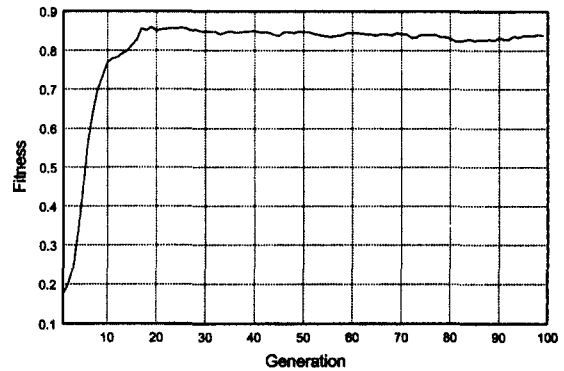


그림 11. 제안된 알고리즘의 최적성능.  
Fig. 11. Best performance of the proposed algorithm.




그림 12. SGA의 최적성능.  
Fig. 12. Best performance of the SGA.




그림 13. 제안된 알고리즘에 의한 제어 입력 평면.  
Fig. 13. Control input surface of the proposed algorithm.




그림 15. 랜덤 신호 기반 학습에 의한 제어 입력 평면.  
Fig. 15. Control input surface of the random signal-based learning.




그림 14. SGA에 의한 제어 입력 평면.  
Fig. 14. Control input surface of the SGA.




그림 16. SA에 의한 제어 입력 평면.  
Fig. 16. Control input surface of the SA.

입력 평면의 경사가 심한 부분들이 있는데 이것은 수렴 속도를 향상시키는 역할을 하여 파라미터가 변화해도 수렴 속도가 빠른 것을 볼 수 있다. 그리고  $e$ 와  $\dot{e}$ 가 0인 점 부근의 제어 입력 평면이 부드럽게 변화하고 있어서 진동 없이 부드럽게 수렴하는 결과가 나타난다.

그림 14는  $e$ 와  $\dot{e}$ 가 0인 점 부근에서 제어 입력 평면의 경사가 거의 없는 부분이 있어서 이 부근에서는 제어 입력의 변화가 없으므로 수렴 속도가 느리다. 즉, 학습된 결론부 소속함수의 모양이 표 2에서와 같이 0 부근에서 폭이 넓게 학습된 결과이다. 그리고  $e$ 와  $\dot{e}$ 가 0인 점에서 제어 입력 평면이 부드럽게 변화하고 있으므로 진동 없이 수렴하는 결과가 나타난다.

그림 15는  $e$ 와  $\dot{e}$ 가 0인 점을 대칭으로 제어 입력 평면이 날카롭게 올라오고 들어간(convex and concave) 부분이 있어서 앞의 경우 보다 상대적으로 진동이 심하다. 그리고 그림 13은 그림 14와 그림 15가 복합된 형태이다. 즉, 0 부근은 그림 15와 비슷하나 뾰족한 부분이 없고, 그 외의 부분은 그림 14와 비슷하다. 이것은 본 논문에서 제안한 알고리즘이 SGA과 랜덤 신호 기반 학습을 복합적으로 사용한 결과이다.

그리고 그림 16은  $e$ 와  $\dot{e}$ 가 0인 점 부근에서 제어 입력 평면의 경사가 완만한 부분이 있어서 이 부근에서는 제어 입력의 변화가 적으므로 수렴 속도가 느리다.

### VI. 결론

본 논문에서는 유전알고리즘을 이용하여 랜덤 신호 기반 학습의 파라미터인 학습률과 이산 랜덤 값을 각각 생성하고, 시뮬레이티드 어닐링을 이용하여 랜덤 신호 기반 학습의 강화 신호를 생성하는 적응 랜덤 신호 기반 학습 알고리즘을 제안하였다. 유전알고리즘을 이용함으로써 전역 탐색이 가능하였으며, 시뮬레이티드 어닐링을 이용하여 강화 신호를 생성함으로써, 즉 에너지가 증가하는 방향으로의 학습을 확률적으로 허용함으로써 최적해의 개체들을 초기에 몰아내어 유전적 다양성을 잃게 되는 문제와 개체군의 크기가 적어서 초기에 조기수렴이 되면 발생할지도 모르는 지역해로의 수렴 문제를 어느 정도 해결할 수 있었다.

비선형 함수의 최적화와 도립 진자의 모의 실험을 통하여 제안한 알고리즘의 학습 결과와 유전알고리즘, 랜덤 신호 기반 학습 그리고 시뮬레이티드 어닐링만을 각각 이용한 학습 결과를 비교하여 본 논문에서 제안한 알고리즘이 학습 속도, 수렴 시간, 파라미터 변화와 외란에 대한 강인성 등에서 우수함을 입증할 수 있었으며, 다른 모든 최적화 및 제어 문제에도 사용될 수 있을 것으로 사료된다.

향후 연구 과제로는 근사 전역해로의 수렴 문제를 해결하기 위해서 좀더 정밀한 학습 알고리즘을 유전알고리즘에 추가하여야 할 것이다.

## 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 rule sets for fuzzy controllers using genetic algorithms," *IEEE Trans. Fuzzy Syst.*, vol. 3, pp. 129-139, 1995.
- [8] S. Kirkpatrick, C. D. Gelatt Jr., and M. P. Vecchi, "Optimization by simulated annealing," *Science*, vol. 220, pp. 671-680, 1983.
- [9] Seung-hyun Jeong, Chang-wook Han, Jung-il Park, and Soon 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.
- [10] Chang-wook Han and Jung-il Park, "Design a fuzzy controller using reinforcement learning trained by genetic algorithms," *Proc. of the 3rd International Workshop on Advanced Mechatronics*, pp. 244-247, 1999.
- [11] Chang-wook Han and Jung-il Park, "Design of a fuzzy controller using random signal-based learning employing simulated annealing," *Proc. of the 39th IEEE Conference on Decision and Control*, pp. 396-397, 2000.
- [12] D. O. Hebb, "The organization of behavior," John Wiley, New York, NY, 1949.
- [13] Il-kwon Jeong and Ju-jang Lee, "Adaptive simulated annealing genetic algorithm for control applications," *International Journal of Systems Science*, vol. 27, no. 2, pp. 241-253, 1996.
- [14] 한창욱, 박정일, "랜덤 신호 기반 학습의 유전 알고리즘을 이용한 퍼지 제어기의 설계," *제어·자동화·시스템공학 논문지*, 제7권, 제2호, pp. 131-137, 2001.



## 한창욱

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 현대

중공업 전력제어설계부 근무. 관심분야는 지능제어, 유전 알고리즘, 퍼지시스템, 신경회로망.



## 박정일

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 삼

성전자 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, 적응학습 시스템.