

GA-Hard 문제를 풀기 위한 공진화 모델

Co-Evolutionary Model for Solving the GA-Hard Problems

이동욱 · 심귀보

Dong-Wook Lee and Kwee-Bo Sim

중앙대학교 전자전기공학부

요 약

일반적으로 유전자 알고리즘은 최적 시스템을 디자인하는데 주로 이용된다. 하지만 알고리즘의 성능은 적합도 함수나 시스템 환경에 의해 결정된다. 두 개의 개체군이 꾸준히 상호작용하고 공진화 하는 공진화 알고리즘은 이러한 문제를 극복할 수 있을 것으로 기대된다. 본 논문에서는 GA가 풀기 어려운 GA-hard problem을 풀기 위하여 저자가 제안한 3가지 공진화 모델을 설명한다. 첫 번째 모델은 찾고자하는 해와 환경을 각각 경쟁하는 개체군으로 구성해 진화하는 방법으로 사용자의 환경설정에 의해 지역적 해를 찾는 것을 방지하는 경쟁적 공진화 알고리즘이다. 두 번째 모델은 호스트 개체군과 기생(스키마) 개체군으로 구성된 스키마 공진화 알고리즘이다. 이 알고리즘에서 스키마 개체군은 호스트 개체군에 좋은 스키마를 공급한다. 세 번째 알고리즘은 두 개체군이 서로 게임을 통해 진화하도록 하는 게임이론에 기반한 공진화 알고리즘이다. 각 알고리즘은 비주얼 서보잉, 로봇 주행, 다목적 최적화 문제에 적용하여 그 유효성을 입증한다.

Abstract

Usually genetic algorithms are used to design optimal system. However the performance of the algorithm is determined by the fitness function and the system environment. It is expected that a co-evolutionary algorithm, two populations are constantly interact and co-evolve, is one of the solution to overcome these problems. In this paper we propose three types of co-evolutionary algorithm to solve GA-Hard problem. The first model is a competitive co-evolutionary algorithm that solution and environment are competitively co-evolve. This model can prevent the solution from falling in local optima because the environment are also evolve according to the evolution of the solution. The second algorithm is schema co-evolutionary algorithm that has host population and parasite (schema) population. Schema population supply good schema to host population in this algorithm. The third is game model-based co-evolutionary algorithm that two populations are co-evolve through game. Each algorithm is applied to visual servoing, robot navigation, and multi-objective optimization problem to verify the effectiveness of the proposed algorithms.

Key words : GA-hard problem, Competitive co-evolution, Schema co-evolution, Game model-based co-evolution

1. 서 론

유전자 알고리즘(GA)은 자연계의 진화과정을 컴퓨터상에서 시뮬레이션 함으로써 복잡한 실세계의 문제를 해결하고자 하는 계산모델이다[1][2]. GA는 구조가 간단하고 방법이 일반적이어서 응용범위가 매우 넓고, 특히 적응적 탐색과 학습 및 최적화를 통한 공학적인 문제의 해결에 많이 이용되고 있다. 그런데, GA가 모든 최적화 문제에 좋은 결과를 가져오는 것은 아니다. 예를 들면, 최적해를 포함하는 스키마의 적합도가, 경쟁하는, 최적해를 포함하지 않는 스키마의 적합도보다 낮아서 결국 최적해를 포함하지 않는 스키마 쪽으로 수렴하기 때문에 최적해를 찾지 못하고 국소해에 머무는 경우

가 발생한다. 이와 같은 경우의 문제를 GA-hard problem이라고 한다[2]. 다시말하면 GA는 코딩방법 및 적합도 설정에 의해 결정되는 적합도 지형(fitness landscape)에 의해 성능의 제약을 받는다. 따라서 적합도 지형이 GA가 문제를 풀기 어렵게 결정되면 GA는 국소해에 조기 수렴하거나 해를 찾는데 시간이 오래걸린다.

이와 같은 문제점을 해결하기 위하여 좀 더 자연계의 진화 현상과 가깝게 모델링 한 것이 공진화 알고리즘이다 [3]-[12]. 공진화란 두 개 이상의 개체군이 서로 영향을 주고 받으며 진화하는 것을 말한다. 여러 개체군간의 상호 작용은 동적인 적합도 환경을 제공하여 해가 조기 수렴하는 것을 막고 진화 속도를 향상 시킬 수 있다.

공진화 알고리즘은 개체군 간에 영향을 주고받는 방식에 따라 경쟁적 공진화 모델[3]-[6], 협조적 공진화 모델 [4][7][8], 기생 공진화 모델[9]-[12]로 나누어 볼 수 있다. Hillis[3]는 sorting network과 data의 경쟁적 공진화 모델을 제안하였고 이 모델을 기반으로한 신경망과 학습패턴의 경쟁적 공진화 모델도 개발되었다[4][5]. Sim의 게임이론에 기반한 공진화알고리즘[6]도 경쟁적 공진화 알고리즘의 하나이다. Paredis는 SYMBIOT[4]라는 협조하는 두 개체군의 공진화

접수일자 : 2005년 4월 1일

완료일자 : 2005년 5월 16일

감사의 글 : 본 연구는 산업자원부의 뇌신경정보학연구사업의 '뇌정보처리에 기반한 감각정보 융합 및 인간행위 모델 개발'의 연구비 지원으로 수행되었습니다. 연구비 지원에 감사드립니다.

모델을 제안하였고 Potter와 DeJong[7]은 n개의 협조적으로 영향을 주고받는 공진화 모델을 개발하였다. Pena-Reyes와 Sipper[8]는 Potter의 공진화 모델을 퍼지 모델링에 적용하였다. 기생 개체군으로 virus 개체군[9]과 schema 개체군[10]-[12]을 도입한 기생 공진화 모델도 개발되었다. 한편 생물학자 Valen은 진화적 혁신과 적응의 주요한 원동력으로서 공진화적 군비확장경쟁(arms race)에서 유도되는 “Red-Queen effect”를 제안하였다[13].

GA가 풀기 어려운 GA-hard problem을 풀기 위한 방법으로 본 저자는 경쟁적 공진화 모델, 스키마 공진화 모델 그리고 게임이론에 기반한 공진화 모델을 제안하였다. 경쟁적 공진화 모델은 해와 환경을 각각 개체군으로 구성하여 강건한 해를 찾기 위한 모델이고, 스키마 공진화 모델은 기생 개체군인 스키마 개체군을 이용하여 해 개체군의 진화적 탐색을 돕는 알고리즘이다. 게임이론에 기반한 공진화 모델은 해의 부분을 두 개의 개체군에 나누고 각 개체군이 게임을 통해 진화하는 알고리즘이다. 2, 3, 4장에서 각각 알고리즘에 대하여 자세히 설명한다.

2. 경쟁적 공진화 알고리즘

2.1. 경쟁적 공진화 알고리즘

본 알고리즘은 풀고자 하는 해와 환경을 함께 공진화 시켜 변화하는 환경에 대해서도 강건한 해를 찾기 위한 알고리즘이다. 주어진 문제를 본 알고리즘에 적용하기 위하여 목적하는 해를 주 개체군으로 구성하고 환경이나 외부요인을 부 개체군으로 구성한다. 그림 1은 신경망 제어기와를 주 개체군으로 학습패턴을 부 개체군으로 구성한 경쟁적 공진화를 나타낸 그림이다.

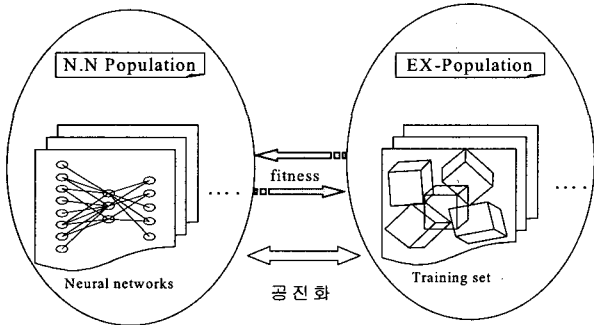


그림 1. 신경망과 학습패턴의 공진화
Fig. 1. Co-evolution of neural networks and learning examples

[경쟁적 공진화 알고리즘]

(1) 개체군 구성

주목적이 되는 대상을 주개체군(primary population)으로 구성하고 환경과 같은 외부 요인을 부개체군(secondary population)으로 구성한다.

(2) 적합도 평가

주 개체군의 개체와 부 개체군의 개체의 적합도는 다음의 식 (1)과 (2)에 의해 구한다.

$$f(P_i) = \frac{\sum_{j \in A} f(P_i, S_j)}{L} \quad (1)$$

$$f(S_j) = \frac{\sum_{i \in B} f(S_j, P_i)}{K_j} \quad (2)$$

이때, 사용되는 변수는 다음과 같다.

N : 주개체군의 개체수

P_i : 주개체군의 i 번째 개체(individual), 단, $i=0 \dots N$

M : 부개체군의 개체수

S_j : 부개체군의 j 번째 개체, 단, $j=0 \dots M$

$f(P_i)$: P_i 의 적합도

$f(S_j)$: S_j 의 적합도

$f(P_i, S_j)$: 주개체 i 와 부개체 j 의 상호관계에 의한 적합도 ($= 1 - f(S_j, P_i)$)

A : 주개체 i 가 선택한 부개체들의 인덱스 집합

L : 주개체의 평가회수

B : 부개체 j 를 선택한 주개체들의 인덱스 집합

K_j : 부개체 j 가 선택된 회수

즉, 주개체는 부개체에서 선택한 L 개의 개체에 대하여 상호 적합도를 구한 후 평균값을 취하여 자신의 적합도로 가지며 부개체도 선택되었던 K_j 번의 상호적합도를 평균하여 자신의 적합도로 갖는다.

(3) 유전 연산

각각의 개체군에 대하여 일반적인 진화 알고리즘과 같은 선택, 교차, 돌연변이의 과정을 거쳐 다음 세대의 개체군을 구성한다.

(4) 종료조건

지정된 최대 세대가 지나거나 만족한 결과가 나올 때까지 (2)와 (3)을 반복한다.

2.2. 공진화의 유효성 측정

경쟁적 공진화에서 진화적 적응과 개선이 일어나는 주요한 원인은 종간의 군비경쟁(arms race) 때문이다[12]. 즉 한 개체군은 다른 개체군의 적합도를 감소시키는 방향으로 진화를 하고 적합도의 영향을 받은 개체군은 떨어진 적합도를 유지하고자 진화를 하는 것이다. 이와 같이 적합도가 상대적으로 정의가 되어있기 때문에 공진화하는 개체의 동적인 적합도 지형(dynamic fitness landscape)을 갖는다. 따라서 적합도의 변화를 이용해 진화의 진행을 알아보기 힘들다. 따라서 공진화가 유효하게 진행되고 있는가를 알아보기 위하여 ‘상대 개체 조상들과의 경쟁’이라는 방법을 제안하였다[5].

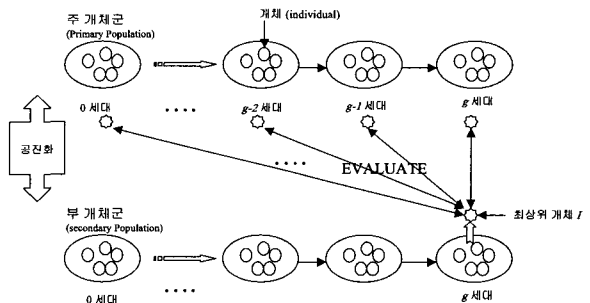


그림 2. 상대 개체 조상들과의 경쟁 개념
Fig. 2. Ancestral opponent contest method

현재 g 세대의 진화의 진행과정을 알아보기 위하여 부개체군의 g 세대 이전의 각 세대들의 최고 개체들과 주개체군의 g 세대 최고 개체와 순차적으로 경쟁을 시켜서 얻어진 적합도의 변화 모양을 살펴봄으로서 진화의 진행 과정을 알아볼 수 있다. 그림 2는 '상대 개체 조상들과의 경쟁'을 통한 공진화의 진행과정을 알아보는 방법을 나타낸 것이다.

2.3. 실험 결과

제안한 방법에 대하여 RV-M2 로봇 매니플레이터의 끝에 카메라를 장착하여 영상에 의하여 물체를 따라가는 비주얼 서보잉에 적용하여 그 유효성을 검토하였다.

비주얼 서보잉을 위한 대상 물체는 50×50×30mm의 직육면체로 하였고 카메라 화면상의 목표영상은 미리 알고 있으며, 시스템의 목적은 평면상에 주어진 물체를 화면상에서 목표영상과 일치하도록 로봇 매니플레이터를 움직이는 것이다. 대상물의 영상과 목표영상이 일치하면 그리퍼(gripper)를 통하여 물체를 잡을 수 있다.

그림 5는 카메라 화면의 목표영상과 실제영상을 나타낸다. 목표영상과 실제영상의 4개의 특징점 각각의 x, y 좌표편차를 신경망의 8개 입력으로 하였고 RV-M2의 5개 관절각의 변화량을 출력으로 하였다.




그림 3. 목표영상과 실제영상
Fig. 3. Ideal image and object image

(1) 신경망 구조의 진화

신경회로망은 입력노드 8개, 출력 노드 5개와 하나의 은닉층에 최소 1개, 최대 10개의 뉴런을 가질 수 있도록 하여 구조를 탐색하였다. 신경망의 구조로 구성되는 주개체군의 크기는 20으로 하였고, 주개체군의 적합도를 계산하기 위해서 부개체군의 학습패턴중 임의의 5개의 개체에 대하여 학습을 하였다. 교차 연산 확률은 0.8로 하였으며, 구조 진화 시 교차후 생긴 자손의 유전성을 보장하기 위하여 신경망의 은닉층 뉴런단위로 교차 연산을 수행하였다. 돌연변이 확률은 0.02로 설정하고 적합도 비례선택을 사용하였다.

(2) 학습패턴의 진화

학습패턴은 평면의 x(300mm), y(400mm)좌표 및 회전각도 (-45°~45°)로 표현하여 각각 5,5,6bit로 코드화 하였다. 이때 각각의 정밀도는 9.375mm, 12.5mm, 1.4°가 된다.

학습패턴을 진화하기 위한 부개체군의 크기는 20으로 하였고 적합도 비례선택을 수행하고 이때 돌연변이 확률은 0.02로 하였고 1점 교차를 수행하였다.

(3) 적합도 평가

주개체군 및 부개체군의 개체에 대한 적합도는 (1)식과

(2)식에 의하여 구했으며, 주개체는 부개체군의 5개의 학습패턴(L=5)에 대한 적합도의 평균값으로 하였다.

하나의 학습패턴에 대한 적합도는 (3)식과 같이 모든 학습패턴에 대하여 동일한 비교가 될 수 있도록 하였다.

$$f(P_i, S_j) = \begin{cases} 0 & \text{if } f(P_i, S_j) \leq 0 \\ N - \frac{e_{end}}{e_{init}} - \sum_{i=1}^{N-1} \frac{|L_i - L_i^*|}{L_i} & \text{otherwise} \end{cases} \quad (3)$$

단, $e_{init} = \sum_{i=0}^{N-1} d_i(0)$, $e_{end} = \sum_{i=0}^{N-1} d_i(T)$ 이고, $d_i(t)$ 는 그림 5에서 시간 t 에서의 목표영상과 실제영상의 i 번째 특징점 사이의 거리오차를 나타낸다. T 는 총 동작시간, L_i 는 목표영상에서 i 번째 특징변의 길이 L_i^* ; 는 시간 T 에서의 실제영상의 i 번째 특징변의 길이, N 은 특징점의 개수이다.

신경망의 구조와 학습패턴의 47세대에 걸친 공진화를 통하여 준최적화된 신경망 구조를 얻을 수 있었다. 신경망의 구조는 7개의 은닉층 뉴런과 46개의 연결강도로 구성되어 있었다. 그림 4는 최종 얻어진 구조에 대한 학습패턴의 오차곡선을 나타낸다.





그림 4. 학습패턴에 대한 오차곡선($\sum_{i=0}^3 d_i$)
Fig. 4. Error curve of a training pattern

공진화 방법에서는 적합도 변화가 동적으로 나타나기 때문에 공진화 진행과정을 알아보기 매우 힘들다. 그림 4은 공진화 진행과정을 알아보는 '상대 개체 조상들과의 경쟁' 방법을 표시하였다.



(a) 부개체 조상과의 경쟁 (b) 주개체 조상과의 경쟁
그림 5. 상대 개체 조상들과의 경쟁방법

Fig. 5. Ancestral opponent contest method

그림 5의 (a)를 보면 47세대 신경망 구조와 학습패턴의 조상들과의 적합도 관계를 보여주고 있다. 그래프가 대체적으로 감소하는 것은 학습패턴의 진화가 신경망이 점점 학습하기 어려운 즉 신경망 구조의 적합도를 감소시키는 방향으로 진행되고 있음을 보여주고 있다. 반면 그림 5의 (b)는 반대의 경우를 보여주는데 감소하는 정도가 명확히 나타나질 못하고

있다. 이는 신경망의 구조가 학습패턴에 비해서 느리게 진화가 되고 있음을 보여준다. 그 원인은 연결 가중치의 초기값에 따라서 적합도의 영향을 많이 받기 때문이다.

본 절에서는 자연계의 진화 모델을 좀더 가깝게 표현한 공진화 방법을 사용하여 최적의 신경망을 탐색하는 방법을 제안하였다. 주개체군은 신경망의 구조를 유전자 알고리즘의 염색체로 표현하여 경쟁적으로 진화하는 학습패턴에 대해서 전역적 탐색을 행하고, 부개체군은 신경망의 학습에 필요한 학습패턴으로 주개체군과 마찬가지로 교차와 돌연변이 연산자를 이용하여 우수한 개체를 탐색한다. 이때 신경망의 구조와 학습패턴사이의 경쟁적인 공진화 관계로 서로의 적합도에 영향을 주면서 진화한다. 주 개체군은 제한된 수의 부개체군의 학습패턴을 통해서 최적의 학습능력을 갖는 구조를 탐색한다. 또한 공진화의 동적인 적합도 변화를 알아보기 위해서 조상 개체들과의 적합도 비교해 보는 방법을 알아보았다. 제안된 방법을 로봇 매니플레이터의 비주얼 서보잉 문제에 적용하여 공진화를 통해서 최적의 신경망구조와 유효한 학습패턴의 선택을 동시에 얻을 수 있음을 확인했다.

3. 스키마 공진화 알고리즘

3.1. 스키마 공진화 알고리즘

다른 공진화 알고리즘과 같이 스키마 공진화 알고리즘(SCEA)은 두 개의 협조적으로 작용하는 개체군을 갖는다. 본 알고리즘은 기생 공진화 알고리즘의 일종으로서 해의 후보 개체군을 호스트 개체군(host population) 스키마로 구성된 개체군을 기생 개체군(parasite population)이라고 한다. 호스트 개체군은 일반적인 유전 알고리즘과 같은 방식으로 수행되고, 기생 개체군은 스키마타의 집합으로서, '빌딩 블록'이라 불리는 유용한 스키마를 찾는데 사용된다. 그림 6은 SCEA 프로세스를 나타낸다.

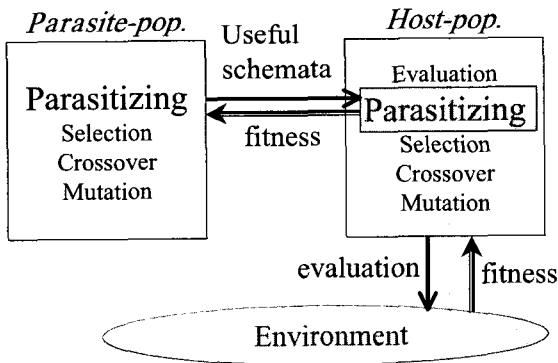


그림 6. SCEA 프로세스
Fig. 6. Process of the SCEA

GA는 한 세대동안 네 가지 중요한 단계를 갖는데, 그것은 적합도 평가, 선택, 교차, 돌연변이이다. 그러나 SCEA는 선택과정 전에 기생 프로세스를 추가로 포함한다. 호스트-개체군의 모든 개체들이 평가되어진 후에, 그 중의 몇 개가 기생-개체군의 스키마를 위해 임의로 선택된 다음, 기생 프로세스가 수행된다. 이것을 통해 새롭게 생성된 개체를 평가하고, 원래의 개체와 기생 프로세스에 의해 변한 개체 사이의 적합도 개선 정도를 측정한다. 가장 큰 개선 값을 갖는 기생 개체

를 각각의 스키마에 대응하는 개체와 대체한다. 개선된 양을 이용하여, 기생 개체군에서 각각의 스키마의 적합도를 부여할 수 있다. 그러므로 기생 개체군의 스키마의 적합도는 스키마의 유용성을 가리킨다. 적합도 평가 후의 기생 개체군에는 SGA와 동일한 과정을 적용한다. 기생-개체군의 개체의 적합도는 기생 프로세스에 의해 계산된다. 따라서 기생 개체군은 기생, 선택, 교차, 돌연변이의 네 단계를 거친다.

3.2. 기생 프로세스

기생 개체군은 유용한 스키마타를 탐색하고 기생 프로세스에 의해 유전 정보를 호스트 개체군으로 전달한다. 그림 7은 기생 프로세스를 보여준다.




그림 7. 기생 프로세스. N 은 호스트-개체군 크기, M 은 기생-개체군 크기, n 은 M 개의 sub-개체군 크기.
Fig. 7. Parasitizing process. N is the size of host-pop., M is the size of parasite-pop., n is the size of M sub-pop.

기생 개체군의 스키마의 적합도는 호스트 개체군에서 추출된 n 개의 스트링에 의해 결정된다. 기생 프로세스는 스트링의 유전자가 스키마의 특정한 유전자에 의해 대체되어지는 것을 의미한다. 스키마 y 의 p 번째 위치가 고정위치이면 그 값을, 그렇지 않고 * (don't care)이면 자신의 값을 갖는다(식(4)).

$$\hat{x}_{i^p} = \begin{cases} y^p, & \text{if } p \text{th character of } y \text{ is fixed} \\ x_{i^p}, & \text{otherwise} \end{cases} \quad (4)$$

여기에서 p 는 유전자좌($0 \leq p \leq l-1$), x_{i^p} 는 스트링 x_i 의 p 번째 자리 값, l 은 스트링의 비트 개수를 나타낸다. 그림 8은 parasitizing의 한 예를 보여준다.




그림 8. Parasitizing의 예: x_i 는 스키마 y 에 의해 \hat{x}_{i^y} 로 parasitizing 됨.

Fig. 8. Example of the parasitizing: x_i is parasitized to \hat{x}_{i^y} by the schema y .

SCEA의 주요 프로세스는 기생 개체군에서 찾은 유용한 스키마를 적합도에 따라 호스트 개체군에 전달하는 것이고, 기생 개체군의 진화 방향은 호스트-개체군에 의해 결정된다.

기생 개체군에서 스트링 y 의 적합도 F_y 는 다음 단계에 의해 결정된다. 다음은 스키마 공진화 알고리즘이다

[스키마 공진화 알고리즘]

- (1) 호스트 개체군에서 n 개의 스트링이 임의로 선택되어 복사된다.
- (2) 그림 5와 같이 parasitizing이 수행된다.
- (3) 기생-개체군에서 스트링 y 의 적합도를 결정하기 위해, 적합도 함수를 다음 식과 같이 적합도의 개선 값으로 설정한다.

$$\hat{f}_{iy} = f(\hat{x}_{iy}) - f(x_i), \quad (i=1, \Lambda, n) \quad (5)$$

이 식에서 x_i, Λ, x_n 는 추출된 스트링, $\hat{x}_{iy}, \Lambda, \hat{x}_{iy}$ 는 parasitizing된 스트링, $f(x_i)$ 는 스트링 x_i 의 적합도, $f(\hat{x}_{iy})$ 는 \hat{x}_{iy} 의 적합도를 나타낸다.

- (4) 각각 M 개의 스키마타에 대해, 가장 큰 개선 값을 갖는 최적 개체가 원래의 호스트-개체군의 대응되는 개체에 대체된다. 대체 결과, 호스트-개체군의 유용한 스키마타는 증가하고 유용하지 않은 스키마타는 감소한다. 이 때, 원래의 호스트-개체군에 존재하지 않는 새로운 스키마타가 추가될 수 있다.
- (5) 기생 개체군이 유용한 스키마타를 찾는 역할을 하기 때문에 스키마 y 의 적합도 F_y 는 (6)과 같이 적합도 개선 값의 합으로 정의된다.

$$F_y \equiv \sum_{i=1}^n \max[0, \hat{f}_{iy}] \quad (6)$$

식 (6)은 기생 개체군에서 스키마의 적합도가 호스트 개체군에서 대체된 스트링에 의존하고 있는 것을 의미한다. 본 알고리즘에서 기생 개체군은 호스트 개체군에 유용한 스키마를 전달하여 전역적 해의 수렴성을 보장하고 수렴속도를 개선한다.

3.3. 실험 결과

본 논문에서는 퍼지 제어기에서 그림 6과 같이 세 개의 멤버십 함수를 갖도록 설계한다. 또한 퍼지 추론 엔진에서는 TSK model의 simplified method를 사용한다. 이 방식의 장점은 후건부가 상수로 주어지며, 퍼지 디코더를 포함하고 있어서 전체 퍼지 제어기의 구조가 간단해진다는 것이다.




그림 9. 퍼지 제어기의 멤버십 함수

Fig. 9. Membership function in the fuzzy controller

그림 9에서와 같이, 세 개의 멤버십 함수는 8개의 파라미터가 필요하다 ($m1-m8$). 세 개의 입력에 대해 세 개의 멤버십 함수를 가지므로, 퍼지 제어기는 27개의 퍼지 룰을 가지며, 마찬가지로 27개의 후건부 상수가 필요하다 ($c1-c27$). 따라서 총 35개의 파라미터가 결정되어야 한다. 하나의 파라미터

를 6비트로 잡으면 거리는 64cm까지를 범위로 하고 로봇의 방향 회전 값은 $\pm 10^\circ$ 를 오차로 했을 경우에는 충분히 모든 방향에 대해 제어가 가능하다. 따라서 진화 연산을 적용하기 위해 필요한 비트 스트링은 210비트가 된다. 즉, 호스트 개체군에서는 모두 210비트 길이를 갖는 개체를 진화시킨다. 본 적용에서는 구현을 간단히 하기 위해, 후건부 상수 값을 로봇의 방향 회전 값으로 할당하였다. 즉 로봇은 일정한 속도로 움직이며, 방향 회전만으로 장애물을 회피하게 된다.

진화 연산에서 또 하나 중요한 것은 적합도 함수를 설정하는 것이고, 이것은 적용하는 문제에 따라 달라진다. 본 연구에서는 (7)와 같은 적합도 함수를 사용하였다.

$$f = \frac{pos}{11} \times \frac{1 - close}{50} \times \frac{15}{time} \quad (7)$$

로봇이 움직일 거리를 11 부분으로 나누고 시작점은 0점을 도착점은 11점을 주도록 하였다. 'pos'는 이러한 로봇의 움직인 거리를 나타낸다. 또한 로봇이 벽에 너무 가까이 다가가지 않도록 하기 위해 'close'항을 추가하였다. 즉 로봇이 장애물에 5cm 이내로 접근한 횟수를 측정하여 'close'로 값을 준다. 즉 장애물이 가까이 가지 않은 로봇은 'close'값이 0이 되어 높은 적합도를 갖게 된다. 또한 총 주행시간을 적합도 함수에 반영하여 로봇이 장애물에 가까이 가지 않고 도착점까지 갔더라도 더 빨리 주행한 로봇에게 높은 적합도를 부여한다. 물론 로봇이 끝까지 주행하지 않은 경우에는 'time'은 가장 큰 값(20)을 주어 도착점에 가지 않고 이미 주행이 끝난 로봇에 대해서는 낮은 적합도를 부여하도록 하였다. 여기서 값 15는 전체 적합도의 최대치를 1로 맞추기 위한 스케일링 값이다. 결과적으로, 장애물에 너무 가까이 가지 않으면서 빠른 시간에 도착점까지 충돌 없이 주행한 로봇이 최고의 적합도를 부여 받는다. 물론 장애물의 충돌이 있을 경우에는 로봇의 주행이 바로 정지되며, 적합도는 0을 받는다.

퍼지 규칙은 매우 불규칙적인 적합도 지형을 갖기 때문에, 다른 알고리즘은 최적해를 찾지 못하고 국소해에 자주 빠진다. 그러나 SCEA는 호스트-개체군의 적합도를 높이는 우수한 스키마를 결정적인 방식에 의해 공급하고 기생-개체군의 다양성을 보장하고 있기 때문에, 국소해를 탈출하기 쉽다. 따라서 시뮬레이션의 결과로부터 SCEA가 다른 알고리즘보다 더 최적해를 잘 찾는 것을 알 수 있다.

위의 SCEA 시뮬레이션에 의해 설계된 퍼지 제어기를 이동 로봇에 장착한 후에, 장애물 회피 실험을 수행하였다. 그림 10은 이러한 실험 모습을 보여준다. 이 그림에서 볼 수 있듯이, 로봇은 장애물을 피하면서 벽을 잘 따라가는 것을 볼 수 있다. 이것은 SCEA에서 벽을 따라 가는 것이 높은 적합도를 갖는 개체로 선택되었기 때문이다.




그림 10. SCEA에 의해 설계된 퍼지 제어기를 장착한 이동 로봇의 장애물 회피 실험

Fig. 10. Experiment on the avoidance of obstacles by a mobile robot with fuzzy controller that is designed by SCEA

4. 게임이론에 기반한 공진화 알고리즘

4.1. 게임이론에 기반한 공진화 알고리즘

진화적 게임의 형태를 가지는 공진화는 적정 세대가 지나면 안정된 균형 상태에 도달하고 이 상태는 '지배 특성(dominance property)' 관점에서 게임의 최적해에 해당하므로 수학적 관점에서 이러한 공진화는 게임 이론적인 특성과 다이나믹스를 가진다. 이러한 특성들로부터 공진화 알고리즘을 게임 행렬을 통하여 구성하고 진화적 게임의 형태를 가지는 문제들에 대한 해법으로 제시될 수 있음을 알 수 있다. 본 논문에서는 '다목적 함수 최적화 문제(Multi-objective Optimization Problems: MOPs)'의 풀이를 통한 알고리즘을 제안한다. 공학자들이 접하는 실세계 최적화 문제의 대부분은 서로 경합하는 두 개 이상의 목적함수를 동시에 최적화해야 하는 문제를 포함하게 되는데 하나의 목적함수를 가진 '단목적 함수 최적화 문제(Single-objective Optimization Problems: SOPs)'의 경우에는 명확한 최적해가 존재하지만 다목적 함수의 최적화 문제의 경우는 그렇지 않다. 일반적으로 MOPs의 경우에는 하나의 최적해가 존재하는 것이 아니라 '파레토 최적해 집합(Pareto optimal solution set)'이라고 알려진 해들의 집합이 존재하는데 이는 탐색 공간에서 모든 목적 함수를 고려할 때 이러한 해들의 집합보다 우위를 점하는 해가 존재하지 않는다는 점에서 최적해임을 의미한다.

4.2. MOPs를 풀기위한 GCEA의 설계

일반적인 '다목적 함수 최적화 문제(Multi-objective Optimization Problems: MOPs)'는 n 개의 '결정 변수(decision variable)', k 개의 '목적함수(objective function)' 그리고 m 개의 '제약조건(constraint)'을 포함한다. x, y 두 개의 결정 변수를 가지고 두 개의 목적 함수 $f_1(x, y), f_2(x, y)$ 를 최적화 하는 풀기위한 게임이론에 기반한 공진화 알고리즘(GCEA)은 다음과 같다.

[게임이론에 기반한 공진화 알고리즘]

- (1) 그림 11과 같이 유전적으로 독립된 두개의 개체군 Population 1과 Population 2를 생성한다.
- (2) 첫 번째 개체군에서 선택된 첫 번째 게임 참가자는 두 번째 개체군에서 선택되어진 두 번째 게임 참가자와 게임을 수행하고 (8)식으로부터 보상값을 지불 받는다.
- (3) 두 번째 개체군의 게임 참가자는 표 2와 (8)식으로부터 보상값을 지불 받는다.
- (4) 두 참가자의 적합도가 (9)식에 의해 결정된다.
- (5) 두 개체군의 모든 참가자에 대하여 (2)와 (3)의 과정을 수행한다.
- (6) 이렇게 평가된 적합도에 기반하여 각 개체군의 자손 세대가 유전자 알고리즘을 통하여 독립적으로 재생산된다.
- (7) 두 개체군의 진화가 static state에 도달할 때까지 (2)에서 (6)까지의 과정을 반복한다.

그림 6에서 적합도 F_n 은 게임 행렬(G)로부터 계산되어진 게임의 Pay-off, G_n 으로부터 결정되는데 (8)식과 같이 G_n 은 두개의 목적함수 값 이용해 계산한다.

$$G_1((x_n, y_n), (x'_n, y'_n)) = f_1(x_n, y_n) - f_2(x'_n, y'_n) \quad (8)$$

$$G_2((x_n, y_n), (x'_n, y'_n)) = f_2(x'_n, y'_n) - f_1(x_n, y_n)$$

식(8)으로부터 두 게임 참가자의 보상값이 결정되면 두 개체의 적합도는 (9)에 의해 계산된다.

$$F_n = 100 \times G_1((x_n, y_n), (x'_n, y'_n)) / \alpha$$

$$F'_n = 100 \times G_2((x_n, y_n), (x'_n, y'_n)) / \alpha \quad (9)$$

식(7)에서 α 는 적합도 F_n 과 F'_n 을 normalize하기위한 상수이므로 $\max |G_k((x_n, y_n), (x'_n, y'_n))|$ 이 되어야 한다. 이 식들을 이용하여 GCEA는 다음과 같이 구성된다.




그림 11. GCEA의 개체군들 구조도
Fig. 11. Structure of populations for GCEA

4.3. 실험 결과

위 알고리즘을 통하여 안정 상태에 도달한 후 얻어진 모든 개체들은 MOPs의 파레토 평면에 존재하는 해 집단이 된다. 그림 13은 아래의 T_1 함수에 대한 GCEA의 진화 결과 개체들이 파레토 평면에 분포함을 보여준다.

$$T_1 :$$

$$f_1(x_1) = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$$

$$g(x_2, \dots, x_n) = 1 + 9 \cdot \left(\frac{\sum_{i=2}^n x_i}{n-1} \right)^{0.25}$$

$$h(f_1, g) = 1 - \left(\frac{f_1}{g} \right)^2$$

단, $n=10$ and $x_i \in [0,1]$.




그림 12. GCEA에 의해 탐색된 T_1 의 진화안정상태(ESS)
Fig. 12. The ESS of T_1 searched by GCEA.

본 절에서는 게임이론과 진화이론의 두 가지 분야를 결합하여 문제해결의 새로운 해법으로써 진화적 게임 이론을 적용한 공진화 알고리즘인 GCEA를 제안하였다. 또한 이렇게 제안된 GCEA의 최적화 성능을 평가하기 위하여 다목적 함수 최적화 문제를 사용하였는데 실험 결과를 통하여 비록 ESS는 수학과 경제학 분야와 관련된 진화적 게임 문제들의 균형해로 간주되고 있으나 GCEA를 이용하여 다목적 함수 최적화 문제의 해를 탐색하는 방법으로도 이용 될 수 있음을 확인하였다.

5. 결 론

본 논문에서는 GA로 풀기 어려운 문제를 위한 공진화 알고리즘을 제안하였다. 공진화 알고리즘은 두 개 이상의 개체군이 상호 작용하여 진화함으로써 동적인 적합도 지형을 제공하고 이를 통해 지역적 최적해에 조기수렴하는 것을 막으며 수렴속도를 향상시킨다. 본 논문에서는 주 목적인 대상과 환경을 각각 개체군으로 구성하여 경쟁시키는 경쟁적 공진화 알고리즘과 스키마 개체들로 구성된 기생 개체군을 도입한 스키마 공진화 알고리즘 MOP문제를 위한 게임이론에 기반한 알고리즘을 제안하고 설명하였다. 경쟁적 공진화 알고리즘은 RVM2 로봇 매니플레이터의 제어기 신경망과 학습패턴을 찾기 위한 문제에 적용하였고 스키마 공진화 알고리즘은 적합도 지형이 매우 울퉁불퉁한 퍼지 제어기의 진화에 적용하였다. 마지막으로 게임이론에 기반한 공진화 알고리즘은 파레토 평면에 해를 갖는 MOP문제에 적용하여 그 유효성을 알아보았다.

참 고 문 헌

[1] J.H. Holland, *Adaptation in Natural and Artificial Systems*, Univ. of Michigan Press, 1975.
 [2] D.E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, 1989.
 [3] W.D. Hillis, "Co-evolving parasites improve simulated evolution as an optimization procedure," *Artificial Life II*, Addison-Wesley, pp. 313-324, 1991.
 [4] J. Paredis, "Coevolutionary Computation," *Artificial Life*, vol. 2, no. 4, pp. 355-375, 1995.
 [5] 정치선, 이동욱, 전효병, 심귀보, "경쟁적 공진화법에 의한 신경망의 구조와 학습패턴의 진화," *대한전자공학회 논문지*, 제36권 S편, 제1호, pp. 29-37, 1999. 1.
 [6] K.B. Sim, D.W. Lee, and J.Y. Kim, "Game theory based coevolutionary algorithm: A new computational coevolutionary approach," *Int. J. of Control, Automation, and Systems*, vol. 2, no. 4, pp. 463-474, 2004.
 [7] M.A. Poter and K.A. Dejong, "Cooperative coevolution: An architecture for evolving co-adapted subcomponents," *Evolutionary Computation*, vol. 8, no. 1, pp. 1-29, 2000.
 [8] C.A. Pena-Reyes and M. Sipper, "Fuzzy CoCo: a

cooperative-coevolutionary approach to fuzzy modeling," *IEEE Trans. on Fuzzy Systems*, vol. 9, no. 5, pp. 727-737, 2001.
 [9] T. Fukuda, N. Kubota, and K. Shimojima, "Virus-evolutionary genetic algorithm and its application to traveling salesman problem," *Evolutionary Computation: Theory and Applications*, World Scientific, ch. 7, pp.235-255, 2000.
 [10] H. Handa, T. Horiuchi, O. Katai, and M. Bada, "A novel hybrid framework of coevolutionary GA and machine learning," *Int. J. Computational Intelligence and Applications*, vol. 2, no. 1, pp. 33-52, 2002.
 [11] K.B. Sim and D.W. Lee, "Schema co-evolutionary algorithm (SCEA)," *IEICE Trans on Information and Systems*, vol. E87-D, no. 2, pp. 416-425, 2004.
 [12] K.B. Sim, K.S. Byun, and D.W. Lee, "Design of fuzzy controller using schema coevolutionary algorithm," *IEEE Trans. on Fuzzy Systems*, vol. 12, no. 4, 2004.
 [13] D. Cliff, G.F. Miller, "Tracking the red queen: Measurements of adaptive progress in co-evolution," *COGS Technical Report CSR/P 363*, Univ. of Sussex, 1995.

저 자 소개



이동욱(Dong-Wook Lee)

1996년 : 중앙대학교 제어계측학과 공학사

1998년 : 동 대학원 제어계측학과 공학석사

2000년 : 동 대학원 제어계측학과 공학박사

2002년~2004년: 중앙대학교 정보통신연구

원 연구전담교수

2004년 ~ 현재 : The Univ. of Tennessee, Dept. of Electrical and Computer Engineering, 박사후 연구원

관심분야 : 인공생명, 진화연산, 인공면역계, 인공두뇌 등

E-mail : dwlee@wm.cau.ac.kr



심귀보(Kwee-Bo Sim)

제15권 제2호(2005년 4월호) 참조