

다목적 함수 최적화를 위한 게임 모델에 기반한 공진화 알고리즘에서의 해집단의 다양성에 관한 연구

Study on Diversity of Population in Game model based Co-evolutionary Algorithm for Multiobjective optimization

이희재 · 심귀보*

Hea-Jae Lee · Kwee-Bo Sim*

중앙대학교 전자전기공학부

요 약

다목적 함수의 최적화 문제(Multiobjective optimization problems)의 경우에는 하나의 최적해가 존재하는 것이 아니라 '파레토 최적해 집합(Pareto optimal set)'이라고 알려진 해들의 집합이 존재한다. 이러한 이상적 파레토 최적해 집합과 가까운 최적해를 찾기 위한 다양한 해탐색 능력은 진화 알고리즘의 성능을 결정한다. 본 논문에서는 게임 모델에 기반한 공진화 알고리즘(GCEA: Game model based Co-Evolutionary Algorithm)에서 해집단의 다양성을 유지하여, 다양한 비지배적 파레토 대안해(non-dominated alternatives)들을 찾기 위한 방법을 제안한다.

Abstract

In searching for solutions to multiobjective optimization problem, we find that there is no single optimal solution but rather a set of solutions known as 'Pareto optimal set'. To find approximation of ideal pareto optimal set, search capability of diverse individuals at population space can determine the performance of evolutionary algorithms. This paper propose the method to maintain population diversity and to find non-dominated alternatives in Game model based Co-Evolutionary Aalgorithm.

Key Words : Co-evolutionary, Evolutionary Algorithm, Multiobjective optimization, Diversity

1. 서 론

진화 알고리즘(Evolutionary Algorithm)은 진화 과정 중에 가장 적응도가 높은 개체를 찾아내는 최적화 알고리즘이다. 그러나 진화 알고리즘에서 해집단의 다양성을 잃어 조기 수렴에 빠지는 일이 종종 발생한다. 이러한 조기 수렴은 전역 최적해(Global optimum) 대신에 지역 최적해(Local optimum)로의 수렴일 것이다. 다목적 함수의 최적화 문제(Multiobjective optimization problems : MOPs)에서 잘 만들어진 진화 알고리즘의 경우 다음의 세 가지 조건을 만족해야한다. 첫 번째로 해들은 가능한 이상적 파레토 프론트(Pareto front)에 가깝게 위치해야 한다. 두 번째, 가능한 많은 비지배적 대안해(non-dominated alternatives)들이 있어야 한다. 마지막으로 모든 비지배적 대안해들은 이상적 파레토 프론트에 고르게 분포해야 한다. 그러므로 다목적 함수의

최적화에서 해집단의 다양성을 조기에 잃어버리는 것은 가까운 이상적 파레토 프론트를 얻는 것과 비지배적 대안해들의 숫자와 고른 분포에 영향을 미치게 된다.

이러한 해집단의 다양성을 유지하며, 최적해를 찾기 위한 많은 연구가 있었다[1-8]. 공진화 알고리즘 역시 이런 유전적 다양성을 제공하며 다목적 함수를 최적화 하는 것을 목적으로 하고 있다. 하지만 공진화 알고리즘에서도 좋은 특성을 가지고 있는 개체들을 잃어버리는 현상은 여전히 남아있었다. 이러한 현상을 막기 위한 기억 메커니즘(memory mechanism)은 우리가 얻은 해들중에서 좋은 특성의 개체가 어떤 것인지 판단해야하는 문제를 가지고 있다[9].

본 논문에서는 해집단의 다양성을 유지하기 위하여, 비지배적 해들을 기억시키고 이 해들과의 유클리디안 거리(Euclidean distance)를 통해 다음 세대의 개체를 선택하는 방법을 제안하고, 이를 게임 모델에 기반한 공진화 알고리즘에 적용시켜 성능을 평가한다.

본 논문의 2장에서는 다목적 함수 최적화 문제의 정의에 대해 기술하고, 3장에서는 게임 모델에 기반한 공진화 알고리즘에 대해 기술한다. 그리고 4장에서는 비지배적인 해들과의 유클리디안 거리에 의한 선택방법에 대해 설명하고, 마지막으로 5장에서는 실험 및 그 결과에 대해 기술한다.

접수일자 : 2007년 10월 10일

완료일자 : 2007년 12월 1일

* 교신 저자

감사의 글 : 본 연구는 산업자원부의 [총괄과제 : 집단(群) 로봇 기술을 이용한 사회안전로봇 개발, 세부과제 : 로봇 통제 및 환경기술 개발] 연구비지원에 의해 수행되었습니다. 연구비지원에 감사드립니다.

2. 다목적 함수 최적화 문제의 정의

일반적인 다목적 함수의 최적화 문제는 m 개의 파라미터를 가지는 n 개의 함수로 구성된 벡터 함수 $F(x)$ 로 식 (1)과 같이 표현할 수 있다.

$$\begin{aligned} \min/\max y = F(x) &= (f_1(x), f_2(x), \dots, f_n(x)) \\ \text{subject to } x &= (x_1, x_2, \dots, x_m) \\ y &= (y_1, y_2, \dots, y_n) \end{aligned} \quad (1)$$

여기서 x 는 결정변수 벡터(decision vector)라 불리며, X 의 결정변수 공간(decision space)을 가지고 있고, y 는 목적함수 벡터(objective vector)이며 Y 의 목적함수 공간(objective space)을 가지고 있다.

다목적 함수의 최적화 문제에서 해들은 파레토 최적해 집합(Pareto optimal set)으로 정의된다. 이러한 파레토 최적해들은 서로 비지배적 관계에 있으며, 어떤 다른 해에 대해서도 지배받지 않는다. 최소화 문제의 경우 두 결정변수 벡터 $a, b(a, b \in X)$ 를 생각 할 때, a 가 b 를 지배한다는 것은 식 (2)와 같이 나타낼 수 있으며, a 가 b 를 지배한다는 기호는 $b < a$ 와 같이 쓰인다.

$$\begin{aligned} \forall i \in \{1, 2, \dots, n\} : f_i(a) &\leq f_i(b) \wedge \\ \exists j \in \{1, 2, \dots, n\} : f_j(a) &< f_j(b) \end{aligned} \quad (2)$$

역시 최소화 문제의 경우 파레토 최적해 집합 P 는 식 (3)과 같이 나타낼 수 있으며, 파레토 최적해 집합을 목적함수 공간으로 나타낸 파레토 프론트 집합 PF 의 정의는 식(4)와 같이 나타낼 수 있다.

$$P = \{x_p \in X \mid \neg \exists x_a \in X \ x_p \leq x_a\} \quad (3)$$

$$PF = \{y = F(x_p) \in Y \mid x_p \in P\} \quad (4)$$

3. 게임 모델에 기반한 공진화 알고리즘

진화적 안정 전략은 게임 이론에 기초를 두고 있으며, 진화적 게임에 있어서 개체군 내의 대부분이 이것을 채택하면, 다른 대체 전략에 의해서 변화시킬 수 없는 전략으로 정의된다. 이것은 어떠한 우수한 전략도 상대방으로부터 완전한 이익을 남길 수 없으며 열등한 전략들에 비하여 항상 우위를 점할 수 없음을 나타낸다. 게임 모델에 기반한 공진화 알고리즘(GCEA : Game model based co-evolutionary algorithm)은 게임을 통해서 이러한 진화적 안정 전략을 찾을 수 있다는 아이디어로부터 출발한 알고리즘이다[10]. GCEA의 구조는 다음과 같다.

- ① 만약 게임 참가자(Player)가 2명이라 가정하면, 그림 1과 같이 두 개의 해집단 Pop1과 Pop2를 생성한다.
- ② 그림 1과 같이 첫 번째 해집단의 첫 번째 개체와 나머지 해집단의 모든 개체들과 게임을 하여 보상(reward)을 받는다. 여기서 적합도는 한 개체가 나머지 해집단의 모든 개체들과의 게임을 통해 얻은 보상값을 모두 더한 것이며, 식 (5)와 같이 나타낼 수 있다.

$$Fitness(i) = \sum_{k=1}^j Reward(i, k) \quad (5)$$

Pop 1			Pop 2		
No.	Chromosome	Fitness	No.	Chromosome	Fitness
1.	1001101	87	1.	0110011	76
2.	0111011	58	2.	1001101	55
3.	1010100	79	3.	0100111	93
4.	1000100	82	4.	0011011	34
5.	0101011	27	5.	1101010	89
6.	1011101	79	6.	1010111	48
7.	0110010	53	7.	0110101	98
8.	1101001	21	8.	1101100	73
9.	0000100	94	9.	0011010	84
10.	0100011	27	10.	0100101	54
	.			.	
	.			.	
i.	0110100	69	j.	1011010	81

그림 1. 게임을 위한 공진화 알고리즘의 해집단

Fig 1. Population for GCEA

- ③ 모든 해집단의 모든 개체들에 대해 ②의 과정을 수행시킨다.
- ④ 이렇게 결정된 적합도를 통하여 각 해집단을 독립적으로 교차와 변이를 수행시켜 다음 해집단을 생성한다.
- ⑤ 종료조건이 만족할 때까지 ②~④과정을 반복한다.

4. 비지배적 해들과의 유클리디안 거리에 의한 선택 방법

지난 20년간 다목적 함수의 최적화 문제를 위해 진화알고리즘을 사용한 다양한 방법들이 제안되었다. 이 방법들은 크게 엘리트 전략과 비엘리트 전략으로 나눌 수 있다.

- elitist EAs : Rudolph's algorithm, distance based Pareto GA, strength Pareto EA, multi-objective messy GA, Pareto archived evolution strategy, etc.
- non-elitist EAs : vector-optimized evolution strategy, niched Pareto GA, random weighted GA, weight-based GA, non-dominated sorting GA, multiple objective GA, etc.

이러한 두 그룹의 차이는 다음 세대 개체의 선택시에 엘리트 개체들을 선택할 것인가에 대한 차이이다. 이러한 엘리트 전략과 비엘리트 전략의 연구는 해집단의 다양성에 대해 연구한 것이라 할 수 있으며, 이러한 다양한 연구가 있었지만 진화 알고리즘에서 해집단의 다양성을 유지시키며, 이상적인 파레토 최적해 집합을 얻는 문제를 완벽히 만족시키는 것은 쉽지 않았다. 본 논문에서 제안하는 GCEA에서의 다음 세대 개체의 선택 방법은 해집단의 다양성을 유지시키기 위한 비엘리트 전략으로 비지배적 해들을 기억시키고, 그 해들과의 유클리디안 거리(Euclidean distance)를 통해 선택하는 방법으로 다음과 같다.

해집단의 수는 2개(Pop1, Pop2)이며, 이전 세대의 해집합과 교차와 변이에 의해 새롭게 생성된 개체들의 집합을 PopAll, 비지배적인 해들의 집합을 PopND라 가정하자.

- ① PopAll에서 비지배적인 해들을 찾아 제거하고, PopND에 넣어준다.
- ② PopND에서 기준 개체(가장 적합도가 높은 개체)부터 일정한 거리(Sharing Parameter)내에 있는 비지배적인 해들을 제거하고, 다시 PopAll에 넣어준다. 제거한 해들을 제외한 비지배적 해집합의 모든 해들에 이 작업을 수행한다. 이 작업은 PopND의 개체 수가 전체 해집단

의 크기를 넘을 경우와 한 지점으로의 비지배적인 해들의 집중을 막아 해집단의 다양성을 보존하기 위한 방법이다.




그림 2. 비지배적 해들의 분배 방법 및 유클리디안 거리를 통한 선택 방법

Fig 2. the division method of non-dominated alternatives and the selection method by euclidean distance

- ③ 위의 과정에서 찾아낸 비지배적 해들을 Pop1과 Pop2에 그림 2와 같이 분배한다. 분배 방법은 비슷한 특성의 개체들로 묶어서 분배하는 것이며, 본 논문에서는 각 개체의 f_1 값을 기준으로 분배했다.
- ④ Pop1과 Pop2의 다른 개체는 그림 2와 같이 PopAll에서 Pop1과 Pop2의 비지배적 해들과의 유클리디안 거리가 가까운 개체를 번갈아가며 선택해 분배한다. 선택 시에는 해집단의 다양성을 좀 더 높이기 위해 그림 2와 같이 Pop1의 f_1 값이 가장 작은 개체와 Pop2의 f_1 값이 가장 큰 개체부터 선택권을 부여하였다.

위 방법을 통하여 진화 과정시 비지배적 파레토 해집합을 잃어버리지 않게 되며, 유클리디안 거리가 비슷한 집합으로 나뉘어 좀 더 빠른 수렴과 다양한 비지배적 파레토 개체들이 창발되는 것을 기대할 수 있다.

5. 실험 결과

5.1 성능 평가를 위한 MOPs

본 논문에서는 기존 GCEA와의 성능 평가를 위하여 Sefrioui, Schaffer, Zitzler의 논문에서 제시되어진 5개의 테스트용 다목적 함수 최적화문제를 이용하여 성능을 평가하였다[11-13]. 5개의 테스트용 MOPs는 다음과 같다.

- Sefrioui의 논문에서 사용된 MOP : t_1
 $f_1(x, y) = (x-1)^2 + (x-y)^2$
 $f_2(x, y) = (y-3)^2 + (x-y)^2, -5 \leq x, y \leq 5$ (6)
- Schaffer의 논문에서 사용된 MOP : t_2
 $f_1(x, y) = (x-1)^2 + (y-1)^2$

$$f_2(x, y) = (x-4)^2 + (y-4)^2, -5 \leq x, y \leq 5 \quad (7)$$

- Zitzler의 논문에서 사용된 MOP : t_3

$$f_1(x_1) = x_1$$

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

$$h(f_1, g) = 1 - \sqrt{f_1/g}, n = 30, x_i \in [0, 1] \quad (8)$$

- Zitzler의 논문에서 사용된 MOP : t_4

$$f_1(x_1) = x_1$$

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

$$h(f_1, g) = 1 - (f_1/g)^2, n = 30, x_i \in [0, 1] \quad (9)$$

- Zitzler의 논문에서 사용된 MOP : t_5

$$f_1(x_1) = x_1$$

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

$$h(f_1, g) = 1 - \sqrt{f_1/g} - (f_1/g) \sin(10\pi f_1) \quad (10)$$

$$n = 30, x_i \in [0, 1]$$

5.2 기존 GCEA와의 비교 실험 결과

다음 그림3~7은 GCEA에서 기존의 엘리트 선택 방법을 적용했을 때와 본 논문에서 제안하는 선택 방법을 적용했을 때를 비교한 그림이다. 실험에 적용된 기본 파라미터는 다음과 같다.

- Population size : 100
- # of Population / Generation : 2 / 100
- Sharing Parameter : 0.015
- Crossover(Prob.) : two point crossover(1.0)
- Mutation(Prob.) : Simple mutation(0.1)

그림 3~7은 실험을 통하여 기존 GCEA와 본 논문에서 제안한 비지배해들과의 유클리디안 거리에 의한 선택방법을 적용한 경우의 파레토 프론트를 위에서 언급한 5가지 테스트 함수로서 비교한 것이다. 그림 3~7의 왼쪽 그림은 기존 GCEA로 탐색된 $t_1 \sim t_5$ 의 Pareto front를, 오른쪽 그림은 비지배해들과의 유클리디안 거리에 의한 선택방법을 적용한 경우 $t_1 \sim t_5$ 의 Pareto front를 나타낸다.

실험 결과 기존 GCEA는 실험 때마다 비지배적 대안해들의 숫자가 상당히 불안정하였지만, 본 논문에서 제안한 선택방법을 적용했을 때에는 언제나 안정적으로 비지배적 파레토 대안해들이 고르게 분포되며 이상적인 파레토 프론트와 아주 가까운 해들을 얻을 수 있음을 알 수 있었다. 또한, 기존 GCEA의 엘리트 선택이 약 50~70세대가 지나야 이상적 파레토 최적해 집합에 가까운 해들을 찾는 반면, 본 논문에서 제안하는 방법을 적용한 경우에는 단 약 20세대 정도에 이상적 파레토 최적해 집합에 비슷하면서, 비지배적 대안해의 숫자도 증가하였음을 알 수 있었다. 또한 약 50~70세대가 지난 이후에 기존 GCEA는 급격한 수렴으로 인해 해의 다양성이 감소하는데 비해, 본 논문에서 제안한 방법을 적용한 경우에는 약 20세대가 지난 이후에도 이상적 파레토 프론트로 수렴하며, 비지배적 대안해들을 잃어버리지 않고, 새로운 비지배적 대안해들을 빠른 속도로 찾아냄을 알 수 있었다.




그림 3. Sefrioui's 테스트 함수 t_1 의 Pareto front
 Fig 3. The pareto front for Sefrioui's test function t_1




그림 4. Schaffer's 테스트 함수 t_2 의 Pareto front
 Fig 4. The pareto front for Schaffer's test function t_2




그림 5. Zitzler's 테스트 함수 t_3 의 Pareto front
 Fig 5. The pareto front for Zitzler's test function t_3




그림 6. Zitzler's 테스트 함수 t_4 의 Pareto front
 Fig 6. The pareto front for Zitzler's test function t_4




그림 7. Zitzler's 테스트 함수 t_5 의 Pareto front
 Fig 7. The pareto front for Zitzler's test function t_5

5.3 다른 EA들과의 비교 실험 결과

위의 실험을 통하여, 우리는 본 논문에서 제안한 선택 방법이 GCEA의 성능을 향상시켰음을 알 수 있었다. 하지만

아직 여러 다른 EA들과의 성능 비교 문제가 남아있다. 그래서 우리는 여러 다른 EA들과의 비교를 위하여 대표적인 8개의 진화 알고리즘들의 성능을 평가한 Zitzler의 논문[3]을 이용하였다. Zitzler의 논문에서 비교한 8개의 진화 알고리즘들은 다음과 같다.

- SPEA : The strength pareto evolutionary algorithm
- SOEA : A single-objective evolutionary algorithm
- NSGA : The nondominated sorting genetic algorithms
- VEGA : The vector evaluated genetic algorithm
- HLGA : Hajela and Lin's weighted-sum based approach
- NPGA : The niched pareto genetic algorithm
- FFGA : Fonseca and Fleming's multiobjective genetic algorithm
- RAND : A random search algorithm

성능 평가를 위한 테스트용 MOPs로는 위에서 언급한 MOP 중 Zitzler의 논문에서 제안된 3가지 t_3, t_4, t_5 를 사용하였으며, 역시 Zitzler의 논문에서 제안된 2가지의 MOP t_6, t_7 를 추가하였다. 이 테스트용 MOPs는 진화 알고리즘의 성능 평가를 위하여 현재까지도 널리 사용되어지고 있다. 추가된 t_6, t_7 은 다음과 같다.

▪ Zitzler의 논문에서 사용된 MOP : t_6

$$f_1(x_1) = x_1$$

$$g(x_2, \dots, x_n) = 1 + 10(n-1) + \sum_{i=2}^n (x_i^2 - 10\cos(4\pi x_i))$$

$$h(f_1, g) = 1 - \sqrt{f_1/g}$$

$$n = 30, x_i \in [0, 1]$$

(11)

▪ Zitzler의 논문에서 사용된 MOP : t_7

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

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

$$h(f_1, g) = 1 - (f_1/g)^2$$

$$n = 10, x_i \in [0, 1]$$

(12)

그림 8~12의 왼쪽 그림은 Zitzler의 논문에서 실험을 통하여 나타낸 그림으로, $t_3 \sim t_7$ 까지의 5가지 MOP에 진화 알고리즘들을 적용해 파레토 프론트를 나타낸 것이며, 오른쪽 그림은 각 MOP에 본 논문에서 제안한 선택방법을 적용한 GCEA의 파레토 프론트이다. Zitzler의 논문에서 실험시 적용한 각 파라미터들은 다음과 같다.

- Population size : 100
- # of Generation : 500
- Crossover(Prob.) : one point crossover(0.8)
- Mutation(Prob.) : Simple mutation(0.01)

본 논문에서의 실험 역시 위의 파라미터들과 동일하게 적용하였으며, Sharing Parameter는 0.015, 해집단의 수는 2개로 실험하였다. $t_3 \sim t_7$ 의 MOP를 사용한 실험 결과를 살펴보면, 본 논문에서 제안한 방법이 SPEA를 제외한 모든 알고리즘보다 이상적 파레토 최적해집합에 가까우면서도 많은 비지배적 대안해를 찾아내고 있음을 확인할 수 있다. 그리고 $t_6 \sim t_7$ 의 MOP를 사용한 실험에서는 SPEA보다도 더 많은 비지배적 대안해를 찾아내고 있음을 확인할 수 있다.

기존 GCEA에서는 이상적 파레토 프론트에 가까운 해를 찾지만 여러 대안해들을 찾지 못하는 문제를 가지고 있었지만, 본 논문에서 제안한 방법을 통해 이 문제를 상당히 개선시킬 수 있으며, 이러한 성능 향상을 통하여 실험에서 비교한 기존 EA들 보다도 좋은 성능을 가진 것을 실험 결과로부터 확인할 수 있었다.

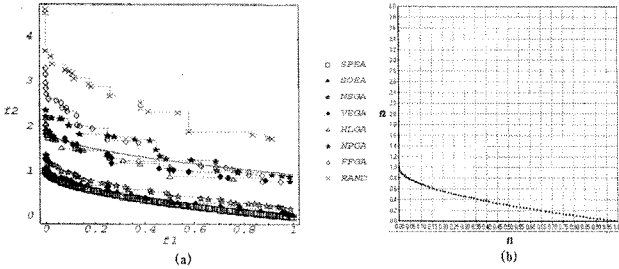


그림 8. Zitzler's 테스트 함수 t_3 의 Pareto front
Fig 8. The pareto front for Zitzler's test function t_3

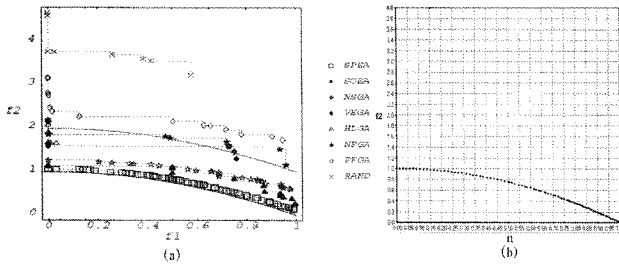


그림 9. Zitzler's 테스트 함수 t_4 의 Pareto front
Fig 9. The pareto front for Zitzler's test function t_4




그림 10. Zitzler's 테스트 함수 t_5 의 Pareto front
Fig 10. The pareto front for Zitzler's test function t_5

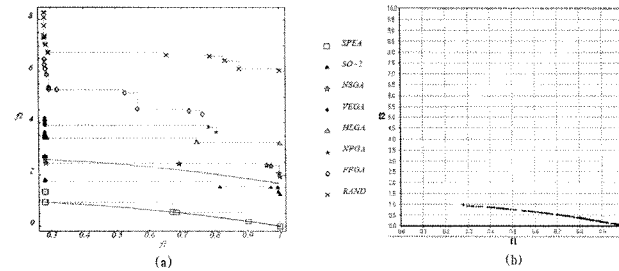


그림 11. Zitzler's 테스트 함수 t_6 의 Pareto front
Fig 11. The pareto front for Zitzler's test function t_6

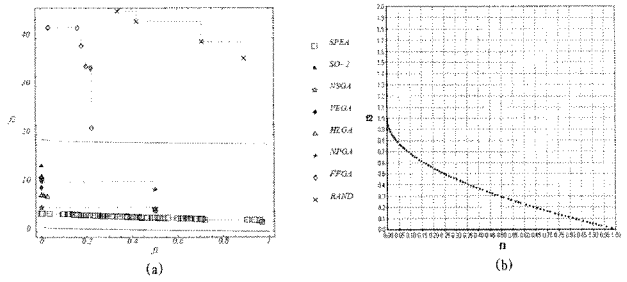


그림 12. Zitzler's 테스트 함수 t_7 의 Pareto front
Fig. 12. The pareto front for Zitzler's test function t_7

표 1은 본 논문에서 제안한 방법으로 위의 5가지 테스트 함수의 비지배적 해들 중에서 가장 적합도가 높은 개체를 찾은 것이다. 테스트는 5.3장에서의 실험 파라미터들을 사용하였으며, 100번의 실험을 통하여 그 평균값을 나타낸 것이다. 하지만 t_7 을 제외하고는 매번 모두 똑같은 개체가 선택되었다. 이는 본 논문에서 실험시 Visual C++을 이용하여 프로그래밍 하였는데, 이 프로그래밍시의 x_n 이 가지는 분해능 문제로 생각되어지며, 그 범위안에서 가장 좋은 개체를 항상 정확히 찾아내고 있다고 생각되어진다.

표 1. 5가지 테스트 함수의 최적해
Table 1. Optimal solutions of MOPs

No.	x_1	$x_2 \cdots x_n$	F_1	F_2
t_3	0.250007629627369	0	0.250007629627369	0.499992370430841
t_4	0	0	0	1
t_5	0.850556963	0	0.850556963	-0.772682607
t_6	0.250007629627369	0	0.250007629627369	0.499992370430841
t_7	0.093813898	0	0.999257065	0.001484767

6. 결론

본 논문에서는 공진화 알고리즘에서의 해의 다양성을 유지시키기 위하여 다음 세대 개체들의 선택시 비지배적 해들을 기억시키고, 이 비지배적인 해들과의 유클리디안 거리에 의해서 선택하는 방법에 대해서 제안하였고, 이를 GCEA에 적용시켜 성능을 평가하였다. 기존 GCEA는 이상적 파레토 해집합에 근사한 해들을 찾아내기는 하지만 많은 대안해들을 찾지는 못하였으나, 본 논문에서 제안하는 방법을 적용시킨 후에는 비지배적 대안해 증가에 대해서 만족할 만한 성능을 보였을 뿐만 아니라, 같은 특성을 가진 해집단으로 나누어 줌으로써 이상적 파레토 프론트에 기존 GCEA보다 빠르게 수렴하여, 계산량 또한 상당히 감소시켰다. 또한 여러 다른 EA들과의 성능 평가에서도 좋은 성능을 보이고 있음을 알 수 있었다. 향후 좀 더 복잡하고 다양한 MOP들로써 좋은 성능을 가지고 있는 진화 알고리즘들(예를 들어 많이 사용되어지는 NSGA-III[15], SPEA[3] 등)과 성능을 체계적으로 비교, 검증한 후 향후 에이전트 제어기 등 최적화 문제에 적용할 예정이다.

참 고 문 헌

[1] K. Deb and D. E. Goldberg, "An investigation of niche and species formation in genetic function optimization," *Proceedings of the Third International Conference on Genetic Algorithms*, J.D.Schaffer, Ed. San Mateo, CA:Morgan Kauffman, pp. 42-50, 1989.

[2] T .Blickle and L. Thiele, "A comparison of selection schemes used in evolutionary algorithms," *Evol. Comput*, vol. 4, no. 4, pp.361-394, 1996.

[3] E. Zitzler, "Multiobjective evolutionary algorithms : the strength pareto approach," *IEEE Trans. Evolutionary Computation*, vol. 3, no. 4, 1999.

[4] N. Srinivas and K. Deb, "Multiobjective optimization using nondominated sorting in genetic algorithm," *Evol. Comput*, vol. 2, no. 3, pp. 221-248, 1994.

[5] J. D. Knowles and D. W. Corne, "Approximating the nondominated front using the pareto archived evolution strategy," *Evol. Comput*, vol. 8, no. 2, pp. 149-172, 2000.

[6] M. Laumanns, L. Thiele, K. Deb, E. Zitzler, "Combining convergence and diversity in evolutionary multiobjective optimization," *Evol. Comput*, vol. 10, no. 3, pp. 263-282, 2002.

[7] P. Czyzak and A. Jaszkiwicz, "Pareto simulated annealing - A metaheuristic for multiobjective combinatorial optimization," *Multi-Criteria Decision Anal*, vol. 7, pp. 34-47, 1998.

[8] J. Horn and N. Nafpliotis and D. E. Goldberg, "A niched pareto genetic algorithm for multiobjective optimization," *Proceeding of the First IEEE Conference on Evolutionary Computation*, Picataway, NJ : IEEE Press, pp. 82-87, 1994.

[9] S. G. Ficici and J. B. Pollack, "A Game Theoretic Memory Mechanism for Coevolution," *GECCO 2003*, LNCS 2723, pp. 286-297, 2003.

[10] K. B. Sim and J. Y. Kim, "Game Theory Based Co-evolutionary Algorithm," *KFIS2004*, vol. 14, No. 3, pp 253-261, 2004.

[11] M. Sefrioui and J. Periaux, "Nash Genetic Algorithms : examples and applications," *Proc. of the 2000 Congress on Evolutionary Computation CEC00*, IEEE Press, pp. 509-516, 2000.

[12] J. D. Schaffer, "Multiple objective optimization with vector evaluated genetic algorithm," *Proceedings of an International Conference on Genetic Algorithms and their Applications*, pp. 93-100, 1985.

[13] E. Zitzler and L. Thiele, "Multiobjective evolutionary algorithms - a comparative case study," *Fifth International Conference on Parallel Problem Solving from Nature(PPSN-V)*, Springer, Berlin, Germany, pp. 292-301, 1998.

[14] E. Zitzler, K. Deb, and L. Thiele, "Comparison of multi-objective evolutionary algorithms : Empirical results," *Evol. Comput*, vol. 8, no. 2, pp. 173-195, 2000.

[15] K. Deb, S. Agrawal, A. Pratap, and T. Meyarivan, "A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization : NSGA-II," *Parallel Problem Solving from Nature(PPSN VI)*, M. Schoenauer et al., Eds. Berlin, Germany : Springer, pp. 849-858, 2002.

저 자 소 개



이희재 (Hee-Jae Lee)
 2003년 : 중앙대학교 전자전기공학부
 공학사
 2007년 ~ 현재 : 동대학원
 전자전기공학부 석사과정

관심분야 : 최적화문제, 진화연산, 소프트 컴퓨팅, 패턴 인식



심귀보 (Kwee-Bo Sim)
 1990년 : The University of Tokyo
 전자공학과 공학박사

[제17권 5호(2007년 10월호) 참조]

1991년 ~ 현재 : 중앙대학교 전자전기공학
 부 교수
 2006년 ~ 현재 : 한국퍼지 및 지능시스템학회 회장

E-mail : kbsim@cau.ac.kr
 Homepage URL : http://alife.cau.ac.kr