

게임 이론에 기반한 공진화 알고리즘

Game Theory Based Co-Evolutionary Algorithm (GCEA)

심귀보 · 김지윤 · 이동욱

Kwee-Bo Sim, Ji-Youn Kim, and Dong-Wook Lee

중앙대학교 전자전기공학부

요 약

게임 이론은 의사 결정 문제와 관련 된 연구와 함께 정립 된 수학적 분석법으로써 1928년 Von Neumann이 유한개의 순수 전략이 존재하는 2인 영합게임은 결정적(deterministic)이라는 것을 증명함으로써 수학적 기반을 정립하였고 50년대 초, Nash는 Von Neumann의 이론을 일반화하는 개념을 제안함으로써 현대적 게임이론의 장을 열었다. 이후 진화 생물학 연구 자들에 의해 고전적인 게임 이론의 가정에 해당하는 참가자들의 합리성(rationality) 대신 다윈 선택(Darwinian selection)에 의해 게임의 해를 탐색하는 것이 가능하다는 것이 밝혀지게 되었고 진화 생물학자 Maynard Smith에 의해 진화적 안정 전략(Evolutionary Stable Strategy: ESS)의 개념이 정립되면서 현대적 게임 이론으로써 진화적 게임 이론이 체계화 되었다. 한편 이와 같은 진화적 게임 이론에 관한 연구와 함께 생태계의 공진화를 이용한 컴퓨터 시뮬레이션이 1991년 Hillis에 의해 처음으로 시도되었으며 Kauffman은 다른 종들 간의 공진화적 동역학(dynamics)을 분석하기 위한 NK 모델을 제안하였다. Kauffman은 이 모델을 이용하여 공진화 현상이 어떻게 정적 상태(static state)에 이르며 이 상태들은 게임 이론에서 소개되어진 내쉬 균형이나 ESS에 해당한다는 것을 보여주었다. 이후, 몇몇 연구자들 게임 이론과 진화 알고리즘에 기반 한 연산 모델들을 제시해 왔으나 실용적인 문제의 적용에 대한 연구는 아직 미흡한 편이다. 이에 본 논문에서는 게임 이론에 기반 한 공진화 알고리즘을(Game theory based Co-Evolutionary Algorithm: GCEA) 제안하고 이 알고리즘을 이용하여 공진화적인 문제들을 효과적으로 해결할 수 있음을 확인하는 것을 목표로 한다.

Abstract

Game theory is mathematical analysis developed to study involved in making decisions. In 1928, Von Neumann proved that every two-person, zero-sum game with finitely many pure strategies for each player is deterministic. As well, in the early 50's, Nash presented another concept as the basis for a generalization of Von Neumann's theorem. Another central achievement of game theory is the introduction of evolutionary game theory, by which agents can play optimal strategies in the absence of rationality. Not the rationality but through the process of Darwinian selection, a population of agents can evolve to an Evolutionary Stable Strategy (ESS) introduced by Maynard Smith. Keeping pace with these game theoretical studies, the first computer simulation of co-evolution was tried out by Hillis in 1991. Moreover, Kauffman proposed NK model to analyze co-evolutionary dynamics between different species. He showed how co-evolutionary phenomenon reaches static states and that these states are Nash equilibrium or ESS introduced in game theory. Since the studies about co-evolutionary phenomenon were started, however many other researchers have developed co-evolutionary algorithms, in this paper we propose Game theory based Co-Evolutionary Algorithm (GCEA) and confirm that this algorithm can be a solution of evolutionary problems by searching the ESS. To evaluate newly designed GCEA approach, we solve several test Multi-objective Optimization Problems (MOPs). From the results of these evaluations, we confirm that evolutionary game can be embodied by co-evolutionary algorithm and analyze optimization performance of GCEA by comparing experimental results using GCEA with the results using other evolutionary optimization algorithms.

Key words : Game theory, evolutionary stable strategy, co-evolutionary algorithm, multi-objective optimization problem

1. 서 론

일반적으로 게임 이론은 협조적 게임이론과 비협조적 게임이론으로 나뉘어지는데 비협조적 게임이론은 협조적 게임이론과 달리 비협조적 게임의 문제들까지 다루기 위해 일반화된 이론이므로 본 논문에서는 비협조적 게임이론에 초점을 맞춘다. 비협조적 게임 이론의 수학적 토대는 1928년, Von Neumann에 의해 처음으로 정립되었으나 1944년 이러한 연구 결과를 책으로 출간하면서 여러 연구자들에 의해 본격적으로 연구되기 시작하였다[1]. 이후, Nash[2]는 2인 게임의 해를 위한 후보 전략의 최소 요구 조건으로써 각 게임 참가자들은 다른 참가자들에 대해 가장 좋은 대응 전략이 되어

접수일자 : 2004년 2월 10일

완료일자 : 2004년 5월 25일

본 연구는 과학기술부의 뇌신경정보학연구사업의 연구비 지원으로 수행되었습니다. 연구비 지원에 감사드립니다.

야 한다는 Von Neumann의 이론을 일반화하는 개념을 제안하였는데 ‘내쉬 균형(Nash equilibrium)’이라 불리는 이 개념은 현대적 게임 이론의 초석이 되었다. 비협조적 게임의 해로써 내쉬 균형이 제안된 후 게임의 균형해를 찾는 연구가 활발해졌는데 이 중 Lewontin[3]은 진화 생물학의 분석에 게임이론을 도입하여 게임의 균형해를 찾고자 하였으나 그의 접근법은 기존의 게임과는 달리 각 종들이 환경을 상대로 게임을 하여 게임의 참가자가 소멸될 확률을 최소화 하는 전략을 찾는 것이었다. 또, Hamilton은 Maynard Smith 와 Price[4]에 의해 소개되어진 ‘진화적 안정 전략(Evolutionary Stable Strategy)’과 유사한 개념의 ‘Unbeatable Strategy’를 제안하였다.

이런 연구들과 더불어 다른 종들 사이의 진화를 이용하여 소프트웨어 분야의 여러 가지 문제를 해결하고자 공진화 알고리즘이 연구되었는데 1991년 Hillis[5]는 컴퓨터 시뮬레이션을 통하여 공진화가 유전적 다양성을 제공함으로써 실제적인 최적화 문제에 어떻게 효율적으로 적용 될 수 있는지와 공진화하는 기생체(parasite)들이 어떻게 공진화 과정을 향상시킬 수 있는 지를 보여주었다. 또 몇몇 다른 공진화 알고리즘 연구자들은 공진화적 현상을 게임이론의 관점에서 연구하였는데 그 중 Kauffman은 통계학적 모델인 NK 클래스에 기반 한 공진화를 소개하였다. 이 연구를 통하여 그는 공진화하는 생태계가 어떻게 내쉬 균형이나 진화적 안정 전략과 같은 균형상태를 이루며 안정된 상태를 유지할 수 있는 지를 보여주었다[6].

이에 본 논문에서는 게임 이론과 공진화 알고리즘의 몇 가지 주요한 개념들을 간략하게 소개하고 앞서 소개된 관점에서 새로이 구성된 ‘게임 이론에 기반 한 공진화 알고리즘(Game Theory based Co-evolutionary Algorithm: GCEA)’을 제안하고 이를 여러 가지 실험적 문제들에 적용하여 다른 진화 알고리즘의 적용결과들과 비교함으로써 본 논문에서 제안된 GCEA의 성능을 평가한다.

2. 게임 이론

게임 이론은 게임이라고 불리는 상충적인 이득을 놓고 각 참가자들이 서로의 이득을 최대화하기 위하여 경쟁하는 상태 속에서 최적 전략 탐색과 같은 의사 결정 문제에 대한 수학적 해법을 제공한다. 이와 같은 상태를 포함하는 게임은 ‘게임 참가자(player)’, ‘전략(strategy)’, ‘행동(action)’ 그리고 ‘보상(pay-off)’과 같은 요소들로 구성되며 게임의 참가자는 특정한 전략을 선택하고 이에 해당하는 행동을 취함으로써 발생하는 게임의 결과로부터 보상을 받는다. 이러한 과정에서 게임 이론은 일반적으로 게임의 모든 참가자들이 합리적인 의사 결정을 한다는 것을 가정으로 하는데 이는 게임의 각 참가자가 게임 상황을 나타내는 게임 행렬이나 게임 트리로부터 결정되는 보상을 극대화하는 전략을 선택해야만 한다는 것을 의미한다. 이러한 가정 속에서 게임 이론과 관련된 몇 가지 개념들을 정리하면 다음과 같다.

2.1 최대 최소 조건과 게임의 안정점

게임의 각 참가자들의 보상의 총합이 항상 0이 되는 게임을 ‘영합게임(Zero-sum game)’이라고 하는데 A 와 B , 두 명의 참가자가 존재하는 2인 영합 게임의 경우, 참가자 A 가 선택할 수 있는 순수 전략들을 a_1, a_2, \dots, a_n , 참가자 B 가 선택

할 수 있는 순수 전략들을 b_1, b_2, \dots, b_m 이라고 두고 e_{ij} 를 A 가 전략 A_i 를 선택하고 B 가 전략 B_j 를 선택했을 때 A 가 게임으로부터 받는 기대 보상값이라고 하면 두 참가자 A 와 B 의 기대 보상값 $e_1(i, j)$ 과 $e_2(i, j)$ 는 각각 $e_1(i, j) = -e_2(i, j) = e_{ij}$ 가 된다. 이 때 A 가 게임에 이기면 B 는 패배하게 되고 자신의 보상을 증대시키기 위하여 더 우등한 새로운 전략을 선택하게 되는데 이는 또한 참가자 A 의 보상을 최소화 시키는 전략이 된다. 이것은 참가자 A 가 이처럼 참가자 B 에 의해 자신이 받게 될 최소 보상값들을 최대화 시키는 전략을 선택해야함을 의미하며 이러한 전략을 결정하는 기준을 최대 기준(maximin criterion)이라 한다. 이 조건을 사용하여 A 는 최소한 게임의 lower value인 $v_L = \max_i \min_j e_{ij}$ 을 게임의 보상으로 보장해주는 전략을 선택할 수 있으며 같은 방법으로 B 는 참가자 A 의 보상값이 게임의 upper value인 $v_u = \min_j \max_i e_{ij}$ 이상이 되지 않도록 보장하는 전략을 선택할 수 있다. 만약 이러한 게임에서 $v_L = v_u$ 가 되도록 보장하는 전략이 순수 존재한다면 이 전략쌍을 게임의 안정점이라고 한다.

2.2 최소 최대정리와 게임의 해

앞서 설명한 2인 영합게임에서 참가자 A 는 n 개의 전략들을, 참가자 B 는 m 개의 전략들을 가진다면 $v_L^M = v_u^M = v$ 가 되는 전략 p^* 와 q^* 에 대해 $e(p^*, q^*) = v_L^M = v_u^M = v$ 가 되는 v 를 게임의 값이라 하고 p^* 와 q^* 를 게임의 해라고 한다.

$$e(p, q^*) \leq e(p^*, q^*) \leq e(p^*, q) \quad (1)$$

이 때 어떤 전략 p 와 q 에 대해 전략쌍 p^* 와 q^* 가 (1)을 만족시킬 때 이 전략쌍을 게임의 ‘균형쌍(equilibrium pair)’이라고 한다.

2.3 내쉬 균형

1952년, Nash는 비협조적 게임의 해를 찾기 위해 유한한 수의 순수전략을 가진 모든 2인 영합 혹은 비영합 게임은 적어도 하나 이상의 내쉬 균형이라 불리는 균형쌍을 가진다는 게임 이론의 새로운 개념을 제안하였으며 이를 수학적으로 증명하였다. 또 그의 증명에 의하면 게임의 각 참가자들은 자신의 전략집합과 목적함수를 가지고 있으며 게임을 하는 동안 상대 참가자의 전략이 고정된 상태에서 자신의 보상값을 최적화하는 전략을 선택하는 방식으로 번갈아 게임을 수행할 경우 모든 참가자가 자신의 보상값을 더 이상 향상시킬 수 있는 전략을 찾지 못하는 상태에 이르게 되는데 이러한 상태를 내쉬 균형이라고 불리는 이러한 균형 상태를 비협조적 게임의 해로 제시하였다.

2.4 진화적 게임과 진화적 안정전략의 정의

고전적인 게임 이론과는 달리 진화적 게임 이론에서는 게임 참가자의 전략이 참가자의 합리적인 선택이 아니라 다윈 선택(Darwinian selection)에 의해 선택된다. 이러한 진화적 게임 이론의 중요한 업적 중 하나는 진화적 안정 전략이라는 개념의 도입으로 볼 수 있는데 세계적인 생물학자인 Maynard Smith는 그의 저서를 통하여 진화적 안정 전략은 개체군 내의 모든 구성원이 이 전략을 선택할 경우 자연 선

택에 의해 다른 어떤 전략도 개체군 내에 전파 될 수 없도록 하는 전략으로 진화적 안정 전략을 설명한다. 결국 진화적 안정 전략은 내쉬 균형의 정제된 개념으로써 게임 참가자의 합리적 선택이라는 전통적인 게임이론의 가정을 자연 선택으로 대체한다[7]. 이러한 개념 하에 진화적 안정 전략은 다음과 같이 수학적으로 정의 된다. X 를 게임 참가자가 선택할 수 있는 전략들의 집합이라고 가정할 때 $y \in X, y \neq x^*$ 를 만족하는 모든 전략 y 에 대해 $e(x^*, \bar{X}) > e(y, \bar{X})$ 인 $x^* \in X$ 는 진화적 안정 전략이다.

3. 게임 이론에 기반 한 공진화 알고리즘

컴퓨터 시뮬레이션에 의한 공진화 알고리즘의 연구는 Hillis에[5] 의해 제안되었는데 정렬 네트워크(sorting network) 문제를 이용하여 제안한 알고리즘의 성능을 평가하였으며 그가 제안한 숙주-기생체 공진화(host-parasite co-evolution)은 경쟁적 공진화(competitive co-evolution) 알고리즘들의 탄생에 영향을 미쳤다. 또 1994년에는 Paredis[8]가 공진화 GA(Co-evolutionary Genetic Algorithms: CGAs)을 제안 하였는데 이것은 전형적인 유전자 알고리즘의 all-at-once fitness evaluation과는 달리 부분적이면서도 연속적인 적합도 평가를 이용한다. 상호 작용하는 다수의 하위 개체군들은 섬 모델(island model)이라 불리는 공진화하는 niche들을 탐색할 수 있도록 설계하였으며 각 개체들은 하나의 하위 개체군으로부터 다른 하위 개체군으로 이주하는 것을 허용함으로써 유전적 장점의 혼합을 피하였다. 이러한 경쟁적 공진화와는 달리 한편으로 Potter, De Jong 그리고 Grefenstette와 같은 연구자들에 의해 협조적 공진화에 대한 연구도 진행되었는데 그들에 의해 제안된 협조적 공진화 알고리즘(Cooperative Co-evolutionary Algorithm)[9]은 유전적으로 독립된 각 개체군들을 대표하는 개체를 선택하고 이를 하나의 개체로 결합하여 상위 레벨의 일을 수행하기에 유리한 개체로써 평가 받을 수 있는 개체(agent)를 생성한다. 이처럼 생태계의 개체군 사이의 진화에 대한 연구로부터 시작된 공진화 알고리즘은 지금까지 학계에 많은 응용 알고리즘과 적용 사례들이 보고되어 왔으나 본 논문에서는 게임 이론과의 유사성에 착안하여 고안 한 ‘게임 이론에 기반 한 공진화 알고리즘(Game Theory based Co-evolutionary Algorithm: GCEA)’을 제안한다.

3.1 게임 이론에 기반 한 공진화 알고리즘

앞서 밝힌 바와 같이 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 다이내믹스를 가진다. 이러한 특성들로부터 공진화 알고리즘을 게임 행렬을 통하여 구성하고 진화적 게임의 형태를 가지는 문제들에 대한 해법으로 제시될 수 있음을 알 수 있는데 본 논문에서는 이러한 공진화 알고리즘의 개념에 진화적 게임 이론을 결합한 새로운 구조의 공진화 알고리즘인 ‘게임 이론에 기반 한 공진화 알고리즘(GCEA)’을 제안하고 여러 가지 난제를 포함한 최적화 문제에 적용하여 다른 진화 알고리즘의 최적화 결과와 성능을 비교 평가하는

것을 목표로 한다. 물론 제안된 알고리즘은 로봇의 제어기나 분산 로봇에서 환경의 변화에 따라 전략의 종류에 따른 로봇의 비율을 진화시킴으로써 전체 시스템의 효율을 높이는 데에도 적용 가능 할 것으로 생각되나 이는 차후 연구 주제로 남기고 본 논문에서는 ‘다목적 함수 최적화 문제(Multi-objective Optimization Problems: MOPs)’의 풀이를 통한 최적화 성능을 평가한다. 공학자들이 접하는 실세계 최적화 문제의 대부분은 서로 경합하는 두개 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.

3.2 다목적 함수 최적화 문제의 정의

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. 이 때 목적함수와 제약조건은 결정 변수의 함수가 되는데 만약 다목적 함수 최적화 문제의 목적이 함수 y 를 최대화 하는 것이라면 식(2)와 같이 나타낼 수 있다.

$$\begin{aligned} \text{maximize } y &= f(x) = (f_1(x), \dots, f_i(x), \dots, f_k(x)) \\ \text{subject to } e(x) &= (e_1(x), \dots, e_j(x), \dots, e_m(x)) \leq 0 \end{aligned} \quad (2)$$

단, $x = (x_1, x_2, \dots, x_n) \in X, y = (y_1, y_2, \dots, y_n) \in Y$
 식(2)에서 x 는 ‘결정변수 벡터(decision vector)’를, y 는 ‘목적함수 벡터(objective vector)’를 각각 나타내고 X 는 ‘결정변수 공간(decision space)’, Y 는 ‘목적함수 공간(objective space)’을 의미한다. 또 ‘제약함수(constraint function) $e(x) \leq 0$ ’는 ‘실행 가능 해집합(set of feasible solution)’을 결정하는데 실행 가능 해집합 X_f 는 제약 함수 $e(x) : X_f = \{x \in X | e(x) \leq 0\}$ 를 만족시키는 결정 변수 벡터 x 의 집합으로 정의 된다. 목적 함수 공간에 사상된 X_f 의 이미지를 ‘실행 가능 영역(feasible region)’이라고 하며 $Y_f = f(X_f) = \cup_{x \in X_f} \{f(x)\}$ 로 나타낸다.

3.2 다목적 함수 최적화 문제의 기존 해법

다목적 함수 최적화 문제의 해 집합인 파레토 최적 집합을 찾는 고전적인 방법으로는 다목적 함수의 목적 함수들을 파라미터화 된 하나의 목적함수로 대체하여 이 파라미터들을 변화시켜 해를 구하는 방법이 주를 이루는데 이러한 부류의 대표적인 방법으로는 weighting method[10] (Cohon, 1978), constraint method[10], goal programming[11], 그리고 min-max approach[12] 등이 있다. 이와는 달리 진화 알고리즘을 이용하여 목적 함수들을 독립적으로 다루는 방법이 Schaffer에 의해 제안되었는데[13], Schaffer는 MOP의 해 집합을 찾기 위한 진화 알고리즘인 Vector Evaluated Genetic Algorithm (VEGA)를 제안하였다. 이 외에도

Fourman[14], Kursawe[15], 그리고 Hajela와 Lin[16]등에 의해 진화 알고리즘을 이용하여 MOPs의 해 집합을 탐색하기 위한 연구들이 진행되었지만 이러한 연구들은 비 지배 개체들에게 다른 적합도 값을 할당하는 Pareto-optimality의 정의를 직접적으로 이용하지는 않았다. Goldberg[17]는 다목적 함수 최적화 문제의 표준적인 진화 알고리즘적 해법으로 인정받고 있는 Pareto Genetic Algorithm (Pareto GA)이라 불리는 파레토에 기반한 적합도 할당 기법을 제안하였는데 이 알고리즘의 기본 아이디어는 개체군 내의 비 지배적인 개체들에게 높은 선택확률을 할당하는 것으로서 비지배적인 해의 순서에 따라 파레토 랭킹이라고 불리는 랭킹을 할당하고 이를 적합도로 할당하는 방식을 이용한다. Pareto GA가 소개되어진 후 여러 연구자들에 의하여 최적화 성능을 더욱 향상시키는 기법들[18][19]이 소개되어져 왔으나 본 논문에서는 GCEA를 이용하여 다목적 함수 최적화 문제의 해를 탐색하는 기법을 제안하고자 한다.

3.3 MOPs를 풀기위한 GCEA의 설계

최근 몇 년 동안 Tic-Tac-Toe (TTT) 게임[20]이나 디지털 생태계의 적용[21]이나 경쟁적인 환경 속에서 인공적인 유기체의 구현[22]과 같은 문제를 풀기위하여 게임 이론에 기반한 공진화적인 해법에 관한 연구들이 수행되어 왔으나 본 논문에서는 MOPs를 풀기위한 GCEA의 제안과 성능 평가를 다룬다. 다목적 함수의 최소화 문제를 생각 할 경우, x, y 두 개의 결정 변수를 가지고 두 개의 목적 함수 $f_1(x, y), f_2(x, y)$ 를 최적화 하는 풀기위한 GCEA는 다음과 같이 설계된다.

표 1. GCEA의 첫 번째 개체군을 위한 게임 행렬
Table. 1 The game matrix for population 1 of GCEA

	(x_1, y_1)	(x_2, y_2)	(x_3, y_3)	...	(x_n, y_n)
(x_1, y_1)	$G_1((x_1, y_1), (x_1, y_1))$	$G_1((x_1, y_1), (x_2, y_2))$	$G_1((x_1, y_1), (x_3, y_3))$...	$G_1((x_1, y_1), (x_n, y_n))$
(x_2, y_2)	$G_1((x_2, y_2), (x_1, y_1))$	$G_1((x_2, y_2), (x_2, y_2))$	$G_1((x_2, y_2), (x_3, y_3))$...	$G_1((x_2, y_2), (x_n, y_n))$
(x_3, y_3)	$G_1((x_3, y_3), (x_1, y_1))$	$G_1((x_3, y_3), (x_2, y_2))$	$G_1((x_3, y_3), (x_3, y_3))$...	$G_1((x_3, y_3), (x_n, y_n))$
⋮	⋮	⋮	⋮	⋮	⋮
(x_n, y_n)	$G_1((x_n, y_n), (x_1, y_1))$	$G_1((x_n, y_n), (x_2, y_2))$	$G_1((x_n, y_n), (x_3, y_3))$...	$G_1((x_n, y_n), (x_n, y_n))$

표2. GCEA의 두 번째 개체군을 위한 게임 행렬
Table. 2 The game matrix for population 2 of GCEA

	(x_1, y_1)	(x_2, y_2)	(x_3, y_3)	...	(x_n, y_n)
(x_1, y_1)	$G_2((x_1, y_1), (x_1, y_1))$	$G_2((x_1, y_1), (x_2, y_2))$	$G_2((x_1, y_1), (x_3, y_3))$...	$G_2((x_1, y_1), (x_n, y_n))$
(x_2, y_2)	$G_2((x_2, y_2), (x_1, y_1))$	$G_2((x_2, y_2), (x_2, y_2))$	$G_2((x_2, y_2), (x_3, y_3))$...	$G_2((x_2, y_2), (x_n, y_n))$
(x_3, y_3)	$G_2((x_3, y_3), (x_1, y_1))$	$G_2((x_3, y_3), (x_2, y_2))$	$G_2((x_3, y_3), (x_3, y_3))$...	$G_2((x_3, y_3), (x_n, y_n))$
⋮	⋮	⋮	⋮	⋮	⋮
(x_n, y_n)	$G_2((x_n, y_n), (x_1, y_1))$	$G_2((x_n, y_n), (x_2, y_2))$	$G_2((x_n, y_n), (x_3, y_3))$...	$G_2((x_n, y_n), (x_n, y_n))$

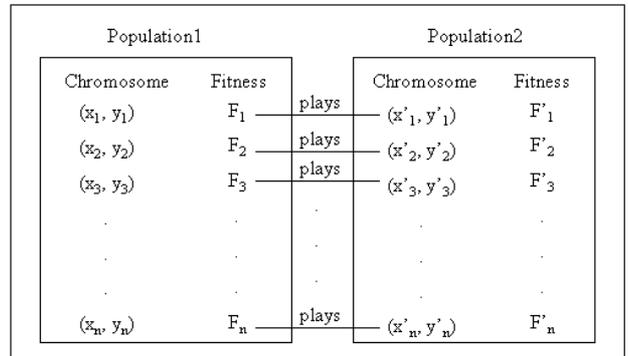


그림 1. GCEA의 개체군들 구조도
Fig. 1. Structure of populations for GCEA

그림 1에서 적합도 F_n 은 표 1, 2에 나타난 게임 행렬로부터 계산되어진 게임의 Pay-off, G_n 으로부터 결정되는데 식 (3)에 나타나 있듯이 G_n 은 두개의 목적함수 값에 의해 계산된다.

$$G_1((x_n, y_n), (x'_n, y'_n)) = f_1(x_n, y_n) - f_2(x'_n, y'_n) \quad (3)$$

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

식(3)으로부터 두 게임 참가자의 보상값이 결정되면 두 개체의 적합도는 (4)에 의해 계산되어진다.

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

$$F'_n = 100 \times G_2((x_n, y_n), (x'_n, y'_n)) / \alpha \quad (4)$$

식(4)에서 α 는 적합도 F_n 과 F'_n 을 normalize하기위한 상수이므로 $\max_k |G_k((x_n, y_n), (x'_n, y'_n))|$ 이 되어야 한다. 이 식들을 이용하여 GCEA는 다음과 같이 구성된다.

- ① 그림 1과 같이 유전적으로 독립된 두개의 개체군 Population 1과 Population 2를 생성한다.
- ② 첫 번째 개체군에서 선택되어진 첫 번째 게임 참가자는 두 번째 개체군에서 선택되어진 두 번째 게임 참가자와 게임을 수행하고 표 1과 (3)으로부터 보상값을 지불 받는다.
- ③ 두 번째 개체군의 게임 참가자는 표 2와 식(3)으로부터 보상값을 지불 받는다.

- ④ 두 참가자의 적합도가 식(4)에 의해 결정된다.
- ⑤ 두 개체군의 모든 참가자에 대하여 ②와 ③의 과정을 수행한다.
- ⑥ 이렇게 평가된 적합도에 기반하여 각 개체군의 자손 세대가 유전자 알고리즘을 통하여 독립적으로 재생산된다.
- ⑦ 두 개체군의 진화가 static state에 도달할 때까지 ②에서 ⑥까지의 과정을 반복한다.

4. 다목적 함수 최적화 문제를 이용한 GCEA의 성능 비교 및 평가

4.1 성능 평가를 위한 다목적 함수 최적화 문제들

앞서 소개한 바와 같이 기존의 다목적 함수 최적화 문제 풀이법들은 매우 다양하게 연구되어 왔고 실제적인 문제에도 성공적으로 적용되어왔음에도 불구하고 각 알고리즘의 성능이나 특징들을 구별지어주기에 적합한 평가 방법에 대한 연구는 부족한 실정이었으나 Deb[23]와 Zitzler[24]에 의해 진화 알고리즘에서 해결하기 어려운 문제에 대한 성능 평가를 위한 함수들이 제시되었다. 이에 본 논문에서도 Zitzler의 논문에서 제시되어진 6개의 테스트용 다목적함수 최적화 문제를 이용하여 성능을 평가하였다.

본 논문에서 적용된 다목적 함수 최적화 문제들은 다음과 같다.

- 평가 함수 t_1 convex Pareto optimal front를 가진다.

$$f_1(x_1) = x_1$$

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

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

여기서 $n = 30$, $x_i \in [0, 1]$ 이다.

- 평가 함수 t_2 는 non-convex Pareto optimal front를 가진다.

$$f_1(x_1) = x_1$$

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

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

여기서 $n = 30$, $x_i \in [0, 1]$ 이다.

- 평가 함수 t_3 는 non-contiguous convex part들로 구성된 Pareto optimal front를 가진다.

$$f_1(x_1) = x_1$$

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

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

여기서 $n = 30$, $x_i \in [0, 1]$ 이다.

- 평가 함수 t_4 는 21^9 개의 지역적 Pareto-optimal set을 가지는 문제로써 multimodality에 대한 최적화 성능을 평가하는 문제이다.

$$f_1(x_1) = x_1$$

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

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

여기서 $n = 30$, $x_1 \in [0, 1]$, $x_1, \dots, x_n \in [0, 1]$ 이다.

- 평가 함수 t_5 는 x_i 가 이진 스트링으로 구성된 deceptive problem을 나타낸다.

$$f_1(x_1) = 1 + u(x_1)$$

$$g(x_2, \dots, x_n) = \sum_{i=2}^n v(u(x_i))$$

$$h(f_1, g) = 1/f_1$$

여기서 $u(x_i)$ 는 bit vector x_i 내에 존재하는 1의 개수를 나타내며 다음 식으로 주어진다.

$$v(u(x_i)) = \begin{cases} 2 + u(x_i) & \text{if } u(x_i) < 5 \\ 1 & \text{if } u(x_i) = 5 \end{cases}$$

여기서 $n = 11$, $x_1 = \{0, 1\}^{30}$, $x_2, \dots, x_n \in \{0, 1\}^5$

- 평가 함수 t_6 는 objective space에서 non-uniformity 하게 분포된 Pareto optimal front를 가진다.

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

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

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

여기서 $n = 10$, $x_i \in [0, 1]$ 이다.

4.2 실험 결과와 성능 평가

다음의 그림들은 Zitzler의 논문에서 소개된 진화 알고리즘들과 GCEA를 이용하여 최적화 된 MOP들의 해를 나타내고 있다. GCEA를 이용하여 최적화 된 해를 Zitzler의 논문[24]에서 8개의 진화 알고리즘을 이용하여 최적화 된 실험 결과와 비교하여 GCEA의 성능을 평가하였는데 Zitzler가 실험한 8개의 진화 알고리즘은 다음과 같다.

- RAND: A RANDom search algorithm.
- FFGA: Fonseca and Fleming's multiobjective GA.
- NPGA: The Niched Pareto Genetic Algorithm.
- HPGA: Hajela and Lin's weighted-sum based approach.
- VEGA: The Vector Evaluated Genetic Algorithm.
- NSGA: The Nondominated Sorting Genetic Algorithm.
- SOEA: A single-objective Evolutionary Algorithm using weighted-sum aggregation.
- SPEA: The Strength Pareto Evolutionary Algorithm.

그림 2, 4, 6, 8, 10, 12는 각각 Zitzler의 논문에서 나타난 실험 결과를 인용한 것으로 위에 소개된 8개의 다른 진화 알고리즘을 이용하여 최적화된 해를 보여준다. 또 그림 3, 5, 7, 9, 11, 13은 본 논문에서 제안된 알고리즘인 GCEA를 이용하여 최적화 된 해들을 보여주는데 이 실험들에서 각각 사용된 GA 파라미터는 세대수 500, 개체군 크기는 100, 교차 확률 0.8 그리고 돌연변이 확률 0.01로써 Zitzler의 논문에서 쓰인 파라미터와 동일하게 실험하였다.

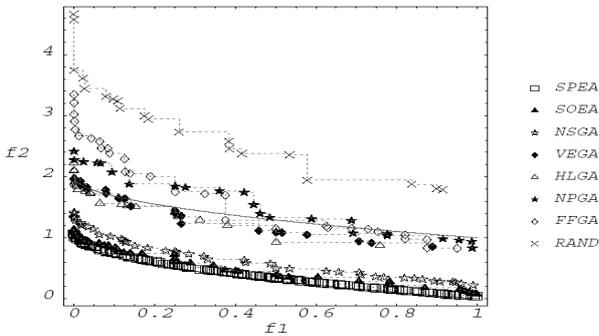


그림 2. 기존의 EA를 이용하여 탐색된 t_1 의 pareto front
Fig. 2. The pareto fronts of t_1 searched by conventional EAs

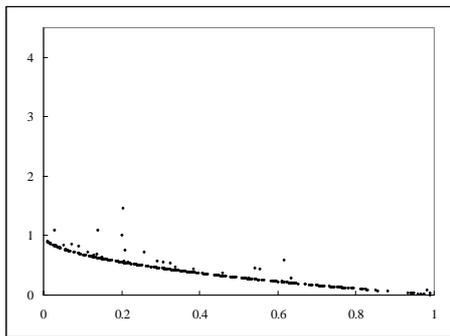


그림 3. GCEA를 이용하여 탐색된 t_1 의 pareto front
Fig. 3. The pareto front of t_1 searched by GCEA

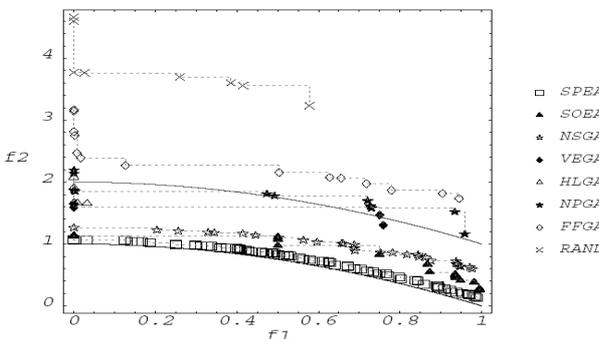


그림 4. 기존의 EA를 이용하여 탐색된 t_2 의 pareto front
Fig. 4. The pareto fronts of t_2 searched by conventional EAs

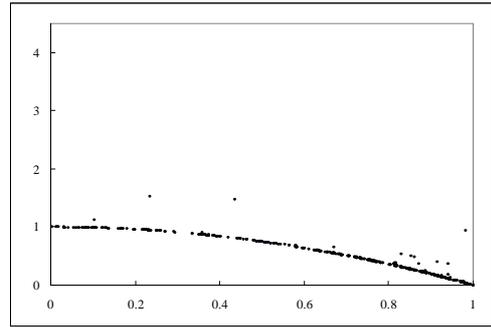


그림 5. GCEA를 이용하여 탐색되어진 t_2 의 pareto front
Fig. 5. The pareto front of t_2 searched by GCEA

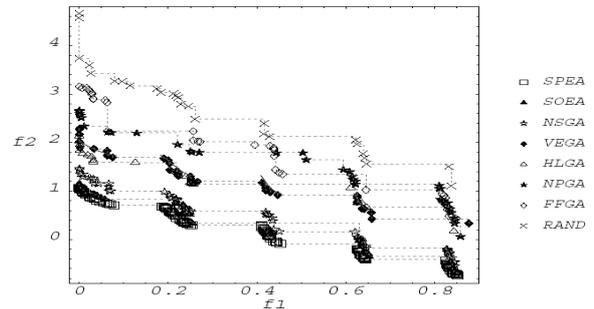


그림 6. 기존의 EA를 이용하여 탐색된 t_3 의 pareto front
Fig. 6. The pareto fronts of t_3 searched by conventional EAs

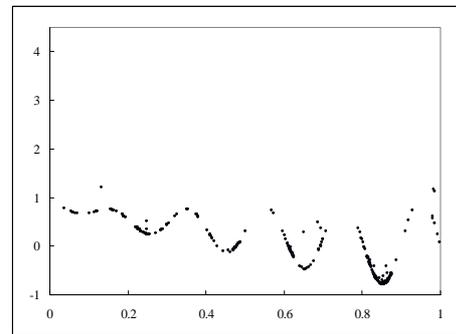


그림 7. GCEA를 이용하여 탐색된 t_3 의 pareto front
Fig. 7. The Pareto front of t_3 searched by GCEA

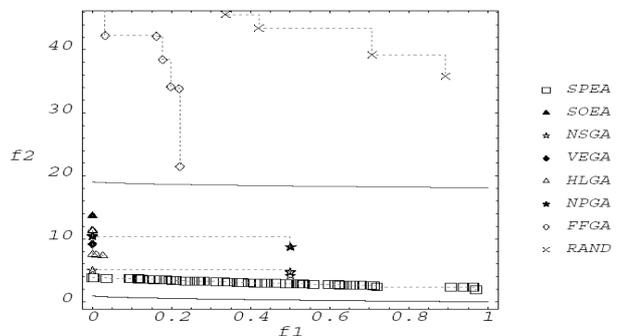


그림 8. 기존의 EA를 이용하여 탐색된 t_3 의 pareto front
Fig. 8. The pareto fronts of t_3 searched by conventional EAs

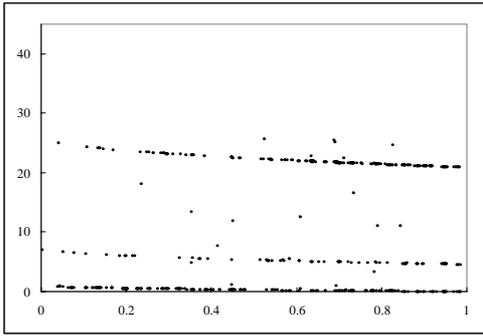


그림 9. GCEA를 이용하여 탐색된 t_4 의 pareto front
Fig. 9. The pareto front of t_4 searched by GCEA

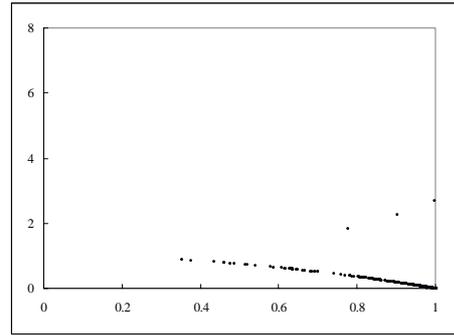


그림 13. GCEA를 이용하여 탐색된 t_6 의 pareto front
Fig. 13. The pareto front of t_6 searched by GCEA

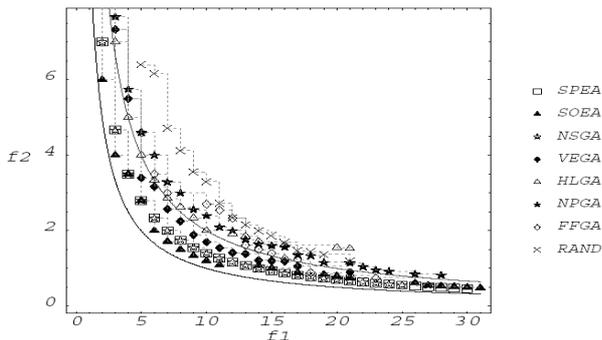


그림 10. 기존의 EA를 이용하여 탐색된 t_5 의 pareto front
Fig. 10. The pareto fronts of t_5 searched by conventional EAs

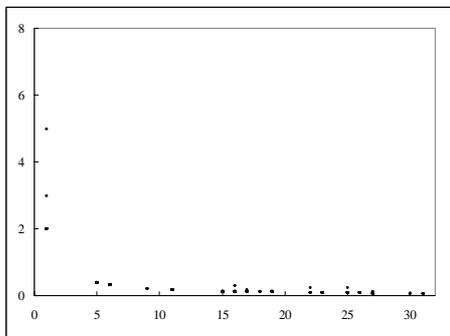


그림 11. GCEA를 이용하여 탐색된 t_5 의 pareto front
Fig. 11. The pareto front of t_5 searched by GCEA

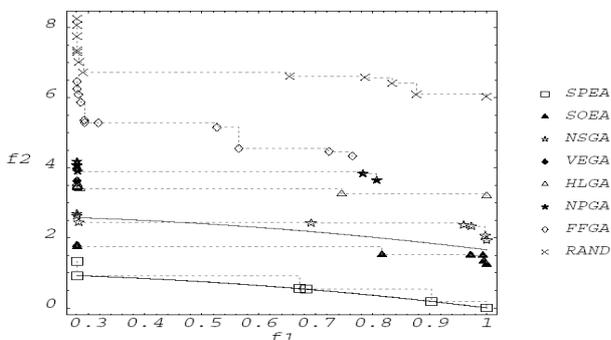


그림 12. 기존의 EA를 이용하여 탐색된 t_6 의 pareto front
Fig. 12. The pareto fronts of t_6 searched by conventional EAs

위의 실험 결과에서 대부분의 실험 결과들이 Zitzler의 실험 결과와 비교해 볼 때 비교적 우수한 최적화 성능을 나타내는 것을 볼 수 있으나 t_4 평가 함수의 경우 지역해를 완전히 구별 해내지 못하는 것을 볼 수 있는데 Zitzler는 그의 논문에서 이 함수의 해탐색에 있어서의 난점을 지적하면서 증가된 개체군 크기와 엘리티즘을 이용하여 이러한 문제를 해결하고자 하였다. 그러나 본 논문에서 제안하는 GCEA의 경우 이러한 부가적인 기법이 없이 단지 개체군 크기만 증가시키는 방법으로도 최적해 탐색 성능을 향상시킬 수 있다. 그림 14는 Zitzler의 논문에서 이처럼 개체수를 늘리고 엘리티즘을 적용해 가면서 NSGA를 이용하여 t_4 평가 함수의 최적해를 탐색한 결과를 인용한 것이고 그림 15는 단지 개체수만을 500으로 늘린 후 100세대 동안 본 논문에서 제안한 GCEA를 이용하여 같은 평가 함수의 최적해를 탐색한 결과를 나타낸 것이다. 그림 14에서 N은 개체수를 T는 세대수를 나타내는데 그림 15의 결과와 비교해 볼 때 t_4 평가 함수에 대해서도 GCEA를 이용하여 최적화 한 경우의 결과가 NSGA를 사용하여 개체수 500에 엘리티즘을 적용하여 1000세대 동안 최적화 한 결과보다는 못하지만 나머지 경우보다는 비교적 우수한 해를 찾는 것을 알 수 있는데 이는 적은 개체수와 짧은 세대수 동안 다른 유전적 기법을 필요로 하지 않고도 더 최적화 된 해를 찾아 낼 수 있다는 것을 의미한다.

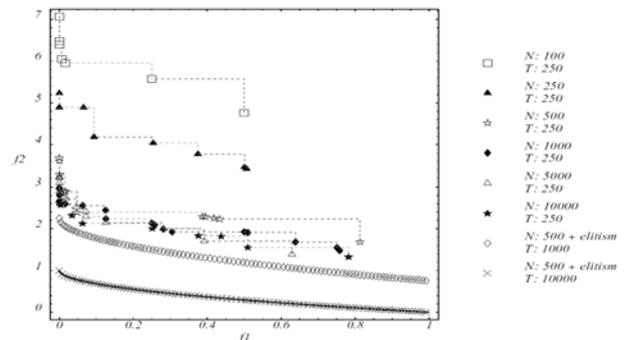


그림 14. 여러 조건에서 NSGA를 이용하여 탐색된 t_4 함수의 pareto front
Fig. 14. The pareto fronts of t_4 searched by NSGA under the several different conditions

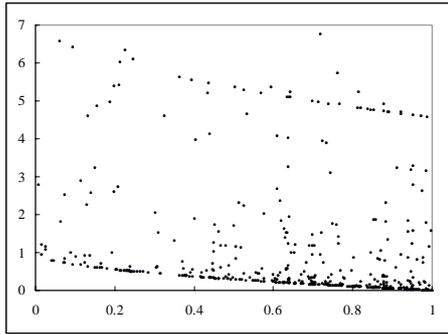


그림 15. GCEA를 이용하여 탐색된 t_4 의 pareto front
Fig. 15. The pareto front of t_4 searched by GCEA

5. 결 론

본 논문에서는 게임 이론의 간략한 몇 가지 개념의 간략한 소개와 더불어 생태계의 진화 메커니즘을 공학적으로 응용한 공진화 알고리즘에 대해 소개하고 이러한 두 연구 분야를 이어주는 차원에서 진행된 몇 가지 연구들을 소개하였다. 또 이러한 관점에서 이 두 가지 분야를 결합하여 진화적인 접근법으로 해결하는 문제들의 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 이용될 수 있음을 확인하였다. 따라서 본 논문에서 제안된 GCEA는 차후 상충하는 여러 개의 목적함수를 가진 환경에서 최적의 전략을 결정하는 에이전트들의 제어기 설계에도 적용이 가능할 것으로 보이며 향후 GCEA를 이용한 에이전트의 제어기 설계를 연구를 수행할 예정이다.

참 고 문 헌

[1] J. Von Neumann and O. Morgenstern, *The Theory of Games and Economic Behavior*, Princeton, Princeton University Press, 1944.
 [2] J.F. Nash, "Noncooperative games," *Annals of Mathematics*, vol. 54, pp. 289, 1951.
 [3] R.C. Lewontin, "Evolution and the theory of games," *J. theor. Biol.*, vol. 1, pp. 382-403, 1961.
 [4] S.J. Maynard and G.R. Price, "The logic of animal conflict," *Nature*, Lond. vol. 246, pp. 15-18, 1973.
 [5] W.D. Hillis, "Co-evolving parasites improve simulated evolution as an optimization procedure," *Artificial Life II*, Addison-Wesley, 1991.
 [6] S.A. Kauffman and S. Johnsen, "Co-evolution to the edge of chaos: Coupled fitness landscapes, poised states, and co-evolutionary avalanches," *Artificial Life II*, Addison-Wesley, 1991.
 [7] S.G. Ficici and J. B. Pollack, "Game theory and the simple coevolutionary algorithm: Some

preliminary results on fitness sharing," *GECCO 2001 Workshop on Coevolution*, 2001.
 [8] J. Paredis, "Coevolutionary constraint satisfaction," *Proc. PPSN-III, Lecture Notes in Computer Science*, vol. 866, Springer Verlag, 1994.
 [9] M.A. Potter, K.A. De Jong and J.J. Grefenstette, "A coevolutionary approach to learning sequential decision rules," *Proc. of the Sixth Int. Conf. on Genetic Algorithms*, San Francisco, Morgan Kaufmann, pp. 366-372, 1995.
 [10] J.L. Cohon, "Multiobjective programming and planning," New York, Academic Press, 1978.
 [11] R. E. Steuer, *Multiple Criteria Optimization: Theory, Computation, and Application*, New York, Wiley, 1986.
 [12] J. Koski, *New Directions in Optimum Structural Design*, Wiley, pp. 483-503, 1984.
 [13] J.D. Schaffer, "Multiple objective optimization with vector evaluated genetic algorithms," *Proc. of Int. Conf. Genetic Algorithms and their Applications*, pp. 93-100, 1985.
 [14] M.P. Fourman, "Compaction of symbolic layout using genetic algorithms," *Genetic Algorithms and Their Applications: Proc. 1st Int. Conf. Genetic Algorithms*, Princeton, Lawrence Erlbaum, pp. 141-153, 1985.
 [15] F. Kursawe, "A variant of evolution strategies for vector optimization," *Parallel Problem Solving from Nature, 1st Workshop Proc.*, vol. 496, pp. 193-197, 1991.
 [16] P. Hajela and C.-Y. Lin, "Genetic search strategies in multicriterion optimal design," *Struct. Optim.*, vol. 4, pp. 99-107, 1992.
 [17] D.E. Goldberg and J.J. Richardson, "Genetic algorithms with sharing for multi-modal function optimization," *Genetic Algorithms and Their Application: Proc. of the Second ICGA*, Lawrence Erlbaum Associates, Hillsdal, pp. 41-49, 1987.
 [18] C.M. Fonseca and P.J. Fleming, "Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization," *Proc. of the 5th Int. Conf. Genetic Algorithms*, San Mateo, CA., Morgan Kaufmann, pp. 416-423, 1993.
 [19] C. M. Fonseca and P. J. Fleming, "An overview of evolutionary algorithms in multiobjective optimization," *IEEE Trans. Evolutionary Computation*, vol. 3, no. 1, pp. 1-16, 1995.
 [20] N. Moeko, Y. Koji, E. Satoshi and M. Hayao, "Competitive co-evolution based game-strategy acquisition with the packaging," *Proc. Second Int. Conf. on Knowledge-Based Intelligent Electronic Systems*, pp. 21-23, 1998.
 [21] F. Azuaje, "Adaptation and reverse evolution in a digital ecosystem," *Proc. IEEE Int. Conf. on Systems, Man, and Cybernetics*, vol. 2, pp. 1064-1068, 2001.
 [22] F. Azuaje, "A computational evolutionary

approach to evolving game strategy and cooperation,” *IEEE Trans. System, Man, and Cybernetics*, Part B, vol. 33, no. 3, pp. 498-503, 2003.

- [23] K. Deb, “Multi-objective genetic algorithms: Problem difficulties and construction of test problems,” *IEEE Trans. Evolutionary Computation*, vol. 7, no. 3, pp. 205-230, 1999.
- [24] E. Zitzler, “Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach,” *IEEE Trans. Evolutionary Computation*, vol. 3, no. 4, 1999.



김지윤(Ji-Yoon Kim)

2002년 : 중앙대학교 전자전기공학부
공학사
2004년 : 동대학원 전자전기공학부
공학석사
2004년 ~ 현재 : 동대학원
전자전기공학부 박사과정

관심분야 : 게임이론, 최적화문제, 진화연산, 지능로봇, 인공지능 등
E-mail : jonathan@wm.cau.ac.kr

저 자 소 개



심귀보(Kwee-Bo Sim)

1984년 : 중앙대학교 전자공학과 공학사
1986년 : 동대학원 전자공학과 공학석사
1990년 : The University of Tokyo 전
자공학과 공학박사
1991년 ~ 현재 : 중앙대학교 전자전기공
학부 교수
2000년 ~ 현재 : 제어자동화시스템공학
회 이사 및 지능시스템연구회 회장

2002년 ~ 현재 : 중앙대학교 산학연컨소시엄센터 센터장
2003년 ~ 현재 : 일본계측자동제어학회(SICE) 이사
2003년 ~ 현재 : 한국퍼지 및 지능시스템학회 부회장

관심분야 : 인공지능, 지능로봇, 지능시스템, 인공두뇌, 다개체시스템, 자율분산로봇시스템, 기계학습 및 적응알고리즘, 소프트웨어(뉴로, 퍼지, 진화연산), 진화하드웨어, 인공면역시스템, 침입탐지 등

Phone : +82-2-820-5319
Fax : +82-2-817-0553
E-mail : kbsim@cau.ac.kr
Homepage URL : <http://alife.cau.ac.kr>



이동욱(Dong-Wook Lee)

1996년 : 중앙대학교 제어계측공학과
공학사
1998년 : 동 대학원 제어계측학과
공학석사
2000년 : 동 대학원 제어계측학과
공학박사

2002년 ~ 현재 : 중앙대학교 전자전기공학부 연구교수

관심분야 : 인공지능, 진화연산, 인공면역계, 인공두뇌 등
E-mail : dwlee@wm.cau.ac.kr