

실수최적화 진화 알고리즘을 위한 새로운 세대차 모델

New Generation Gap Models for Evolutionary Algorithm in Real Parameter Optimization

최준석 · 서기성*

Junseok Choi and Kisung Seo*

서경대학교 전자공학과

요 약

수정된 PCX(parent-centric recombination) 연산자와 결합한 두 가지 새로운 세대차 모델이 제안된다. 첫째, 자가적응 세대차 모델(SGG, self-adaptation generation gap)은 자손에 의한 부모의 대치 확률을 일정한 수준으로 유지하는 제어 방식이다. 둘째, 가상 클러스터 세대차(VCGG, virtual cluster generation gap)는 클러스터링을 통해 부모간의 거리를 조정해 주며, 이로 인해 개체들이 다양화 될 수 있다. 이 모델에서 부모간의 거리는 클러스터의 크기로 조절된다. 제안된 두 가지 접근법의 효용성을 입증하기 위해서 3 가지 표준적인 문제에 대한 실험이 수행되었다. 가장 최근의 경쟁력 있는 접근법인 CMA-ES 와 G3-PCX 와 비교한 결과, 제안된 두 기법 모두 기존의 접근법들 보다 우수함을 보여준다.

키워드 : 세대차 모델, 실수 파라미터 최적화, 진화 알고리즘, SGG, VCGG

Abstract

Two new generation gap models with modified parent-centric recombination(PCX) operator are proposed. First, the self-adaptation generation gap(SGG) model is a control method that keeps a replaced probability of parents by offspring to a certain level which obtains better performance. Second, virtual cluster generation gap(VCGG) is provided to extend distances among parents using clustering, which causes it to diversify individuals. In this model, distances among parents can be controlled by size of clusters.

To demonstrate the effectiveness of our two proposed approaches, experiments for three standard test problems are executed and compared to most competing current approaches, CMA-ES and Generalized Generation Gap(G3) with PCX. It is shown two proposed methods are superior to consistently other approaches in the study.

Key Words : Generation Gap Model, Real-parameter Optimization, Evolutionary Algorithm

1. 서 론

실수 최적화 문제 해결에 효과적인 ES(Evolution Strategy), DE(differential evolution) CMA-ES등의 EA(Evolutionary Algorithm) 중에서 특히, 실수 파라미터 GA(Genetic Algorithm)가 특히 관심을 끌고 있다[1,2]. 효과적인 실수 파라미터 GA 알고리즘 설계를 위하여 재조합 연산자 및 세대차 모델에 대한 연구가 중점적으로 진행되어 왔다.

실수 재조합 연산자인 UNDX(unimodal normal distribution crossover)[3], SPX(simplex crossover)[4] 그리고 SBX(simulated binary crossover)[5]에 대한 기존 연구 결과는 [2]에 잘 정리되어 있다. 이러한 실수 재조합 연산자들은 실수 염색체간의 벡터 성분을 이용하여 자손을 생성한다. 전형적인 GA(genetic algorithm)와 달리 3 개 이상의 부모를 연산하여 자손을 생성하는 방식이 우수한 성능을 보여 주고 있으며[4-6] 특히 다수의 부모를 사용하는 재조합 연산자 중 Deb[2]가 설계한 PCX(parent-centric recombination)

연산자는 기존의 다른 연산자보다 우수한 성능을 보여 주고 있다.

연산자와 함께 기존의 GA방식과는 다른 새로운 진화 모형에 대한 연구도 진행되었다. 최적화 문제에서 빠르게 진역최적화로 접근하기 위하여 군집의 다양성을 고려한 세대차의 개념이 연구되었다. Satoh[7]가 제안한 진화 모형은 점진적인 진화 방식의 MGG(minimum generation gap) 모델에 UNDX 연산자를 사용하였다. $\mu(=3)$ 개의 부모들의 연산을 통해 $\lambda(=200)$ 개의 자손을 생성하고, 그 중 2 개를 선택하여 다음 세대로 진화시키는 방식을 사용하였다. 하지만 Satoh의 방식은 너무 많은 연산량을 필요로 하기 때문에 특정한 연산자에서 최적화된 부모와 자손의 수를 실험하였다. 그 결과 MGG 모델에서 UNDX 연산자를 사용할 때 $\mu(=3)$ 의 부모를 이용하여 2 개의 자손을 생성하는 것이 가장 우수한 결과를 보였다[8].

MGG의 연산속도를 향상시키기 위하여 G3(generalized generation gap)모델이 Deb에 의하여 제안 되었으며 G3 모델에서 다양한 연산자를 사용하여 자손과 부모의 수에 따른 성능의 관계를 실험을 통하여 증명하였다. 그 결과 G3 모델은 PCX 연산자를 사용하였을 때 기존의 UNDX, SBX 그리고 SPX보다 우수한 성능을 보여 주었다[2].

그밖에 재조합 연산자의 부모(μ)와 자손(λ)의 변화에 따

접수일자 : 2008년 6월 13일

완료일자 : 2008년 8월 30일

* 교신저자

른 성능실험 등이 다양한 연산자를 사용하여 여러 진화 모형에서 진행되었다[2,8]. 하지만 다른 실수 파라미터에 대한 분석은 언급되지 않고 있다.

본 논문에서는 기존에 연구되어온 연산자 파라미터(μ, λ) 뿐만 아니라 세대차에 따른 성능분석과 PCX 연산자의 자손생성 범위 조절에 대한 확장된 연구를 수행하였다. 그리고 이러한 파라미터 분석 연구를 기반으로 진화과정에서 세대차와 자손의 생성범위를 자가적응적으로 조절하는 SGG(Self-adaptation Generation Gap) 와 가상 클러스터를 이용하여 부모간의 거리를 일정거리 이상 유지시키는 VCGG(Virtual Cluster Generation Gap) 기법을 설계하였다. 제안된 기법의 검증을 위하여 Rosenbrock, Schwefel 그리고 Ellipsoidal 함수에 대해서 CMA-ES[9]와 G3모형을 사용한 기존 기법과 비교 실험하였다.

2. 기존의 진화 알고리즘

2.1 PCX 연산자

PCX 연산자는 우수해를 중심으로 자손을 생성하는 연산자다. 자손의 생성범위는 군집의 수렴도가 높을수록 즉 재조합 연산자의 부모간의 거리가 작을수록 우수해 가까이 자손이 생성된다. 자손의 생성 수식은 식 (1)과 같이 표현된다.

$$\vec{y} = \vec{x}^{(p)} + \omega_c \vec{d}^{(p)} + \sum_{i=1, i \neq p}^n \omega_n D e^{(i)} \quad (1)$$

μ 개의 부모를 선택하여 부모의 벡터 성분을 이용하여 우수해 주변에 자손의 생성한다[2]. 각각의 부모간의 거리는 연산자의 탐색구간이며 탐색구간의 크기에 따라서 자손의 생성범위는 변화하게 된다. 그림 1과 같이 우수 염색체와 임의의 부모의 평균벡터거리(d^1, d^2)가 증가하면 탐색구간이 증가하며 우수한 염색체에서 넓은 범위의 자손을 생성하게 된다. 즉 PCX 연산자는 선택된 부모들의 거리, 우수해와 임의로 선택된 부모간의 벡터의 성분을 이용하여 일정한 구간에서 자손을 생성하기 때문에 지역탐색 기법이라 할 수 있다.

실험을 통하여 UNDX(Unimodal Normal Distribution Crossover) 연산자처럼 3개의 부모를 사용하는 2개 이하의 자손을 생성하는 것이 가장 우수한 성능을 보여주었다 [2].

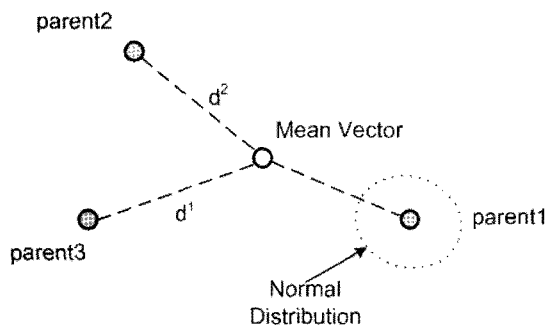


그림 1. 부모중심 재조합 교배(PCX).
Fig 1. Parent-centric recombination Crossover

2.2 기존의 세대차 모델

먼저 Satoh가 제안한 MGG(minimal generation gap model) 모델은 다음과 같다[7].

1. 전체 군집 P에서 μ 개의 임의의 부모를 선택한다.
2. μ 개의 부모를 재조합 연산자를 사용하여 λ 개의 자손을 생성한다.
3. 전체 군집 P에서 두 개의 부모를 임의로 선택 한다.
4. 두 개의 부모 중, 하나는 생성된 λ 개의 자손중 가장 우수한 것으로 대체되고, 또 다른 하나는 λ 개의 자손과 선택된 두 개의 부모 가운데 룰렛선택 과정으로부터 얻어진 해로 대체된다.

두 번째로 설명하는 세대차 모델은 MGG 모델의 진화 속도를 향상시키기 위하여 룰렛선택을 대체한 G3 모델이다. G3(generalized generation gap) 모델은 PCX연산자를 사용할 때 기존의 점진적인 진화 모델 중 가장 우수한 결과를 보이고 있다[2].

1. 전체 군집 P에서 최우수 개체와 $\mu-1$ 개의 임의의 부모를 선택한다.
2. μ 개의 부모를 재조합 연산자를 사용하여 λ 개의 자손을 생성한다.
3. 전체 군집 P에서 두 개의 부모를 임의로 선택 한다.
4. 두 개의 부모와 λ 개의 자손의 합으로부터 두 개의 우수해를 선택하고, 이를 단계 3에서 선택된 두 부모와 대체시킨다.

3. 세대차 모델의 설계

3.1 세대차의 분석과 새로운 세대차 조절방법

세대차는 일정한 세대에서 자손과 부모가 대체되는 양을 의미하며 세대차의 크기는 군집의 분포에 영향을 준다[10]. 따라서 자손의 대체 방식과 재조합 연산자간의 조합이 세대차에 미치는 영향을 분석하고 적합한 세대차를 설정하는 것이 중요하다.

세대차에 영향을 미칠 수 있는 요소로는 대체할 부모의 선택방법과 자손의 생성방법, 그리고 대체할 자손의 선택등을 들 수 있다. 본 연구에서는 대체할 부모의 선택방법과 자손의 생성방법에 관련된 두 가지 파라미터를 중심으로 고찰한다.

먼저 다음과 같은 대체방식을 적용한다.

1. 전체군집 P에서 임의의 부모 1 개를 선택한다.
2. 나머지 1 개의 부모를 전체군집에서 토너먼트 선택을 이용하여 선택한다.
3. 전체 군집 P에서 선택된 부모와 생성된 2 개의 자손과 비교하여 가장 우수한 2 개의 후보해를 다음세대로 진화시킨다.

G3 방식이 임의의 두 부모를 선택하여 자손과 대체한 것에 비해서, 본 연구에서는 한 부모는 임의로 선택하고, 다른 부모는 토너먼트 선택을 사용한다. 토너먼트의 크기를 조절

함으로써, 대치되는 한 부모의 적합도의 수준을 대략적으로 선택할 수 있어서, 대치되는 비율 즉 세대차의 조절이 가능하다.

두 번째 파라미터로서 자손의 생성범위에 영향을 미치는 ω_c 를 선택한다. 토너먼트 크기와 ω_c 를 조합하여 사전 실험을 수행하였고, 표 1과 같이 두 파라미터와 세대차와의 근사적인 상관관계를 얻을 수 있었다. 토너먼트 크기가 작을수록 세대차가 크며, ω_c 가 작을수록 세대차는 높게 나올 수 있다.

표 1. 세대차 조절을 위한 파라미터.

Table 1. Control of generation gap by related parameters.

ω_c	Tournament size in proposed replacement scheme	Generation gap
$\omega_c = 0.1$	2	≈90%
$\omega_c = 0.1$	4	≈80%
$\omega_c = 0.1$	12	≈70%
$\omega_c = 0.18$	12	≈65%
$\omega_c = 0.3$	12	≈60%

아래의 그림2는 Rosenbrock 함수에서(크기 N= 20), 표 1의 파라미터를 사용하여 각각의 대치확률에 따라 성능을 실험한 결과이다. $1e-20$ 이하의 전역 최소점을 찾을 때까지의 연산량을 표시하였다. 군집의 수(P)는 100으로 설정하였으며, PCX 연산자에 대한 가장 우수한 파라미터 조합인 $\mu = 3$ 과 $\lambda = 2$ 로 설정하였다. 각각의 세대차에 대하여 10 회의 실험을 반복하여 얻은 결과가 그림 2에 나타나 있다.

그림 2를 보면 65%의 대치확률을 가질 때 가장 우수한 결과가 나왔으며, 성능(연산량)에 약 10% 정도 영향을 준다는 것을 알 수 있다.




그림 2. Rosenbrock 함수에서 대치확률에 따른 성능분석.

Fig 2. Performances for different generation gap in Rosenbrock function.

성능이 우수하게 나온 60% ~ 70% 대치확률은 토너먼트 크기가 12 이고 자손의 생성범위(ω_c)가 0.1 ~ 0.3 일 때 얻어진다. 자손의 생성범위가 커지면 대치 확률이 낮아지고 자손의 생성범위가 크면 대치 확률이 높아짐을 실험을 통하여 확인 하였다. 하지만 지나친 자손의 생성범위의 증가는 알고리즘의 성능을 저하 시킨다.

본 연구에서는 자손과 부모가 대치되는 확률을 이용하여 최적화에 적합한 세대차를 도출하고자 한다.

3.2 SGG(Self-adaptation Generation Gap)

세대차의 사전 실험을 토대로 일정한 세대마다 PCX 연산자의 자손 생성범위(ω_c)를 자가 적응하는 SGG(Self-adaptation Generation Gap) 모델을 설계하였다.

그림 2에서 가장 우수하게 나온 65%의 세대차를 일정하게 유지하기 위하여 식 (2)와 식 (3)의 자가적응 수식을 실험에 의하여 구성하였다.

$$Dist(g) = \left(\sum_{j=1}^{\mu-1} \left(\sum_{i=1}^n |X_{Best_parent}(i) - X_{parent(j)}(i)| \right) \right) / (\mu - 1) \quad (2)$$

$$\omega_c = \left| \log(\lambda_{target} - \lambda_{replace_rate}(g)) \times 0.1 + 0.004 \right| \quad (3)$$

$$\lambda_{Target} = 0.7$$

식 (2)는 PCX 연산자에 사용된 3개의 부모의 거리를 구한 것이며 $Dist(g)$ 가 0.005 보다 클 경우 60 세대마다 한 번씩 식(3)을 이용하여 생성범위 ω_c 를 조절하여 자손의 발생 범위를 조절한다.

SGG 모델은 아래와 같이 수행된다.

1. 군집 P에서 $\mu-1$ 개의 임의의 부모와 하나의 우수한 부모를 선택한다.
2. μ 개의 선택된 부모에서 PCX 연산자를 이용하여 λ 개의 자손을 생성한다.
3. λ 개의 자손을 3.1 절의 대치방식을 사용하여 다음세대로 자손을 진화 시킨다.
4. 만일 수식 (2)에서 $Dist(g)$ 가 0.005 보다 크면 ω_c 를 식 (3)을 이용하여 조정한다. 그렇지 않으면 이전의 ω_c 를 유지한다.

3.3 VCGG(Virtual Cluster Generation Gap)

VCGG(Virtual Cluster Generation Gap) 모델은 가상의 클러스터를 사용하여 군집의 다양화와 자손의 생성범위를 조절하기 위해서 설계되었다. 이 방식은 SGG 처럼 자손의 생성범위(ω_c)를 직접적으로 조절하지 않고, 재조합 연산을 위한부모의 선택에 각각의 가상 클러스터를 사용한다. 이를 통해 자손의 발생 범위를 크게 함으로써, 군집의 다양성을 유지하게 하는 방법이다.

재조합 연산자에 사용되는 부모의 수만큼 가상의 클러스터를 만들고 각각의 군집의 크기를 설정한다. 각각의 부모 클러스터의 크기를 이용하여 다른 부모와 일정한 거리를 유지시켜 주기 때문에 군집이 수렴하여도 적절한 거리를 유지할 수 있다. 그림 3에서 알 수 있듯이 우수해 군집의 크기는 연산자에 사용되는 부모간의 거리를 증가시켜 넓은 구간의 자손을 발생시키는 역할을 한다.

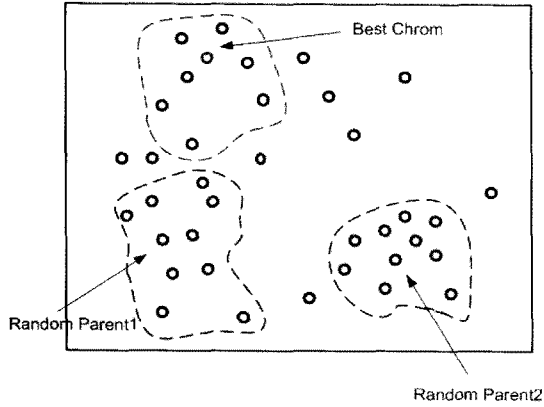


그림 3. 부모들의 가상 군집화.
Fig 3. Virtual clustering for parents.

VCGG 모델은 PCX 연산자의 탐색영역을 기준으로 우수해 군집의 크기를 조절 한다. PCX 연산자에 선택되는 부모간의 거리가 증가하면 연산자의 탐색영역이 증가하게 된다. 10 세대주기 마다 각 세대의 탐색영역을 이용하여 식 (4)와 식 (5)를 설계하였다. 탐색영역의 변화에 따라서 우수해 클러스터의 크기를 조절하며 임의의 부모의 클러스터의 크기는 25로 설정하였다.

$$Dist_{(g)} = Dist_{(g-s)} + \left(\sum_{j=1}^{\mu-1} \sum_{i=1}^n X_{Best_parent}(i) - X_{parent(j)}(i) \right) / (\mu-1) \quad (4)$$

$$Cluster_size = \left\lceil \ln \left(\frac{Dist(g) - Dist(g-S)^2}{Dist(g) - Dist(g-S)^2 + 1} \right) \right\rceil \quad (5)$$

$initsize=15, S=10$

VCGG 모델은 아래와 같이 수행된다.

1. 군집 P, $\mu-1$ 개의 임의의 부모와 하나의 우수한 부모를 선택한다.
2. μ 개의 선택된 부모를 PCX 연산자를 이용하여 λ 개의 자손을 생성한다.
3. λ 개의 자손을 3.1의 대체방식을 사용하여 다음세대로 자손을 진화 시킨다.
4. 만일 수식 (4)에서 $Dist(g)-Dist(g)$ 가 0.005 보다 크면 우수해의 클러스터의 크기를 식 (5)을 이용하여 제어한다. 그렇지 않으면 클러스터의 크기를 15로 고정한다.

4. 실험 결과

4.1 실험 파라미터 설정

본 논문에서 제안한 SGG(self-adaptation generation gap)와 VCGG(virtual cluster generation gap)모델을 3 개의 벤치마크 함수에 대하여 CMA_ES[9] 및 PCX 연산자를 사용한 G3모델과 비교 분석한다.

테스트 문제로는 ellipsoidal, Schwefel's 그리고 Rosenbrock's 함수를 사용한다. 각각의 함수에서 문제의 크기(n)는 20으로 설정하고 전역 최소값이 $1e-20$ 에 도달할 때까지의 연산량으로 성능을 평가한다. 실험을 위하여 CMA_ES는 2000년 Hansen[9]의 Matlab 코드를 사용하였으며 G3 알고리즘은 Deb의 C++ 코드를 사용하였다. G3

모델에서 부모와 자손 수는 $\mu=3, \lambda=1$ 로 설정하고, PCX 연산자의 확률변수 $\omega_\zeta, \omega_\eta$ 는 모두 0.1, 군집의 크기 P는 100으로 설정한다[4].

SGG와 VCGG 모델은 $\mu=3, \lambda=2$ 로 설정하고 군집의 크기 P는 100으로 설정한다. VCGG 모델은 ω_ζ 와 ω_η 는 모두 0.1로 고정 하지만 SGG 모델은 ω_η 만 0.1로 고정하고 ω_ζ 는 세대차변화에 의하여 조절이 가능하도록 설계하였다.

부가적으로 SGG 모델에서 초기의 자손의 생성범위(ω_ζ)는 0.1로 설정 하였고, VCGG 방식에서는 초기 우수해 클러스터의 크기를 15로 설정하였다. 모든 문제에 대한 실험은 30 회를 반복하였다.

4.2 Ellipsoidal Function

식 (6)는 Ellipsoidal 함수이며 모든 탐색체가 (0,...,0)일 경우 전역 최소값을 가지는 함수이다.

$$F_{elp}(x_1, \dots, x_n) = \sum_{i=1}^n ix_i^2 \quad (6)$$

$-5.12 \leq x_i \leq 5.12, n=20$

표 2. Ellipsoidal 함수에 대한 성능비교

Table 2. Performance comparison for F_{elp}

	F_{elp}
CMA - ES	8,472
G3	6,800
SGG	6,202
VCGG	6,011

30번의 반복 실험 결과가 표 2에 나와 있다. 제안된 SGG 방식과, VCGG 방식이 기존의 방법에 비해 우수함을 보인다. 특히 VCGG 방식이 가장 우수한 결과를 보이고 있으며 기존에 PCX 연산자를 사용한 G3보다 9%, CMA_ES보다 29% 정도의 개선된 결과가 나왔다.

군집의 다양성과 자손의 생성의 차이는 그림 4와 5를 통하여 확인할 수 있다. 그림 4는 PCX 연산자에 사용된 부모의 거리를 세대별로 누적시켜 표현한 그래프로서, 제안된 SGG 와 VCGG 알고리즘에서의 부모의 거리가 기존의 G3 알고리즘보다 크다는 것을 확인할 수 있다. 즉 군집이 다양화되어 우수해 에서 멀리 떨어진 개체들이 재조합 연산자에 선택되어 지는 것을 알 수 있다.

특히, 군집의 다양성 측면에서는 VCGG가 가장 다양한 분포를 보여 주고 있는데, 이것은 가상 클러스터를 이용하여 선택되는 부모의 분포를 분산시켜준 효과로 생각된다.

그러나, 자손의 생성범위는 그림 5를 통하여 SGG 모델이 가장 넓은 자손의 발생범위를 가지고 있음을 확인할 수 있다. 군집의 다양성보다 자손의 생성범위(ω_ζ)를 직접적으로 설정하는 방식이 자손의 생성범위를 증가시키는 효과적인 임을 알 수 있다.

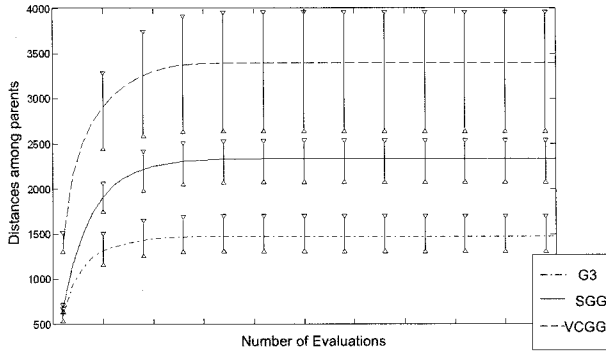


그림 4. F_{elp} 에서 재조합 연산자에 사용된 부모의 거리
Fig 4. Accumulated distances among parents for F_{elp}

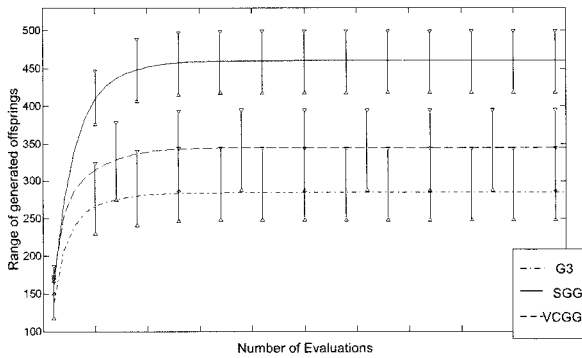


그림 5. F_{elp} 에서 자손의 생성범위
Fig 5. Accumulated range of created offspring for F_{elp}

4.3 Schwefel Function

Schwefel 함수는 모든 염색체가 (0,...,0)일 경우 전역 최소값을 가지는 함수이다.

$$F_{sch}(x_1, \dots, x_n) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2 \quad (7)$$

$-5.12 \leq x_i \leq 5.12, n = 20$

표 3. Schwefel 함수에서 성능비교

Table 3. Performance comparison for F_{sch}

	Fsch
CMA - ES	18,602
G3	15,600
SGG	14,700
VCGG	14,200

표 3에서 보듯이 역시 VCGG 방식이 가장 우수한 결과를 보이고 있으며 기존에 PCX 연산자를 사용한 G3보다 6%, CMA_ES보다는 23% 정도의 개선되었다. 그림 6 과 7 을 통해, F_{sch} 함수의 결과가 F_{elp} 와 유사하게 나옴을 알 수 있다.

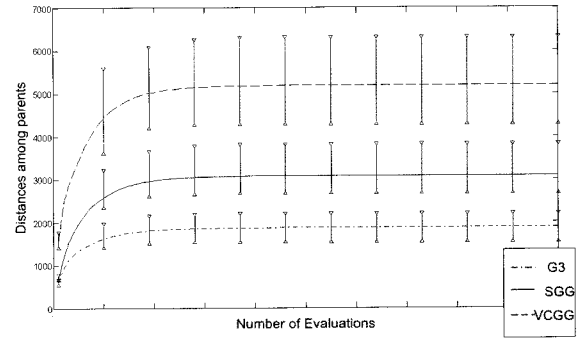


그림 6. F_{sch} 에서 재조합 연산자에 사용된 부모의 거리
Fig 6. Accumulated distances among parents for F_{sch}

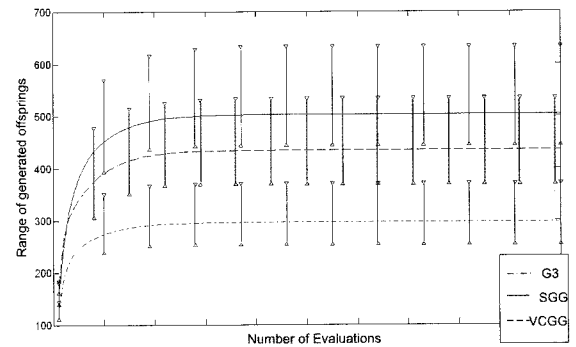


그림 7. F_{sch} 에서 자손의 생성범위
Fig 7. Accumulated range of created offspring for F_{sch}

4.4 Rosenbrock Function

Rosenbrock 함수는 모든 염색체가 (1,...,1)일 경우 전역 최소값을 가지는 함수이다.

$$F_{ros} = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i^2) + (1 - x_i)^2) \quad (8)$$

$-5.12 \leq x_i \leq 5.12, n = 12$

앞의 두 실험 결과와 마찬가지로, VCGG 방식이 가장 우수하며, 기존의 PCX 연산자를 사용한 G3보다 12%, CMA_ES보다는 23% 정도의 개선된 결과가 나왔다(표 4).

그림 8을 보면, F_{ros} 에서는 F_{elp} 나 F_{sch} 함수와 비슷한 형태를 가진다. 하지만 전역 극소점의 탐색까지의 부모거리의 변화는 다르게 나타났다. 즉, 초기세대부터 중기 세대까지 누적되는 부모의 거리가 완만하게 증가를 보이고 있다. 이것은 F_{ros} 함수가 완만한 기울기와 넓은 전역 극소구간을 가지고 있는 영향이라고 볼 수 있다.

그림 9의 자손의 생성범위 그래프를 보면 SGG 모델이 F_{elp} 와 F_{sch} 처럼 가장 넓은 자손의 생성범위 가지고 있음을 확인할 수 있다.

표 4. RosenbRock 함수에서 성능비교
Table 4. Performance comparison for F_{ros}

	Fros
CMA - ES	33,048
G3	21,452
SGG	18,962
VCGG	18,662

3가지 테스트 문제에 대한 실험결과, 제안된 SGG 방식과, VCGG 방식이 기존의 방법에 비해 모두 우수한 성능을 보였으며, 제안된 두 가지 방법 중에서는 VCGG 방식이 SGG 에 비해서 약간 더 우수한 결과를 나타내었다. 재조합 연산자에 사용된 부모간의 거리나 자손의 생성범위에 대한 결과 그래프에서 각각의 알고리즘들의 일관된 현상 및 영향을 확인할 수 있었다.




그림 8. F_{ros} 에서 재조합 연산자에 사용된 부모의 거리
Fig 8. Accumulated distances among parents for F_{ros}




그림 9. F_{ros} 에서 자손의 생성범위
Fig 9. Accumulated range of created offspring for F_{ros}

5. 결 론

실수 연산자의 설계뿐만 아니라 세대차의 설계가 진화연산 알고리즘의 성능향상에 매우 중요한 영향을 주며 이 두 가지 요소가 최적화되어 결합되면 성능향상에 도움을 준다.

본 논문에서 제안한 알고리즘들은 PCX 연산자를 사용하여 세대차에 따라서 군집의 다양성을 조절하고 자손의 생성범위를 조절하여 기존의 G3 모델보다 전역최적화로 다가가는 속도를 높였다.

SGG 알고리즘은 유전 연산자에 의하여 생성된 자손의 세대차에 따라서 자손의 생성범위를 자가 적응적으로 조절하여, 보다 적은 연산량으로 전역 최적화를 찾았다. 그리고 VCGG 알고리즘은 가상의 클러스터를 이용하여 재조합 연산자에 사용되는 부모를 선택할 때 일정한 거리를 유지하여 선택하여 자손의 발생범위를 조절 하였으며 군집을 다양화 하였다.

실험결과 기존의 G3 방식보다 군집의 다양성을 확인 하였으며 초기의 군집의 다양화는 후반세대의 전역최적화로 군집을 집중 시켜주는데 도움을 준다는 사실을 발견하였다. 그리고 각각의 군집의 탐색구간과 자손의 대처 확률을 바탕으로 자가적응 알고리즘을 사용하여 적은 연산량으로 성능을 향상시켰다.

제안된 방법을 3 가지 주요 벤치마크 테스트 문제에 적용하여 실험하였으며, 기존의 다른 알고리즘에 비해서 모두 향상된 성능을 나타내었다.

참 고 문 헌

- [1] H.-P. Schwefel, *Evolution and Optimum Seeking*, John Wiley & Sons, Inc, 1995.
- [2] K. Deb, A. Anand and D. Joshi, " A Computationally Efficient Evolutionary Algorithm Conference for Real-Parameter Optimization." *Evolutionary Computation*. pp. 10(4): 371-395, 2002.
- [3] I. Ono and S. Kobayashi, "A real-coded genetic algorithm for function optimization using unimodal normal distribution crossover." *In Proceedings of the Seventh International Conference on Genetic Algorithms(ICGA-7)*, pp. 246-253, 1997.
- [4] T. Higuchi, S. Tsutsui, and M. Yamamura, "Theoretical analysis of simplex crossover for real-coded genetic algorithms," *In Proceedings of Parallel Problem Solving from Nature (PPSN-VI)*, pp. 365-374, 2000.
- [5] K. Deb and R. B. Agrawal. "Simulated binary crossover for continuous search space," *Complex Systems*, 9(2) pp. 115 - 148, 1995.
- [6] H. Kita, I. Ono and S. Kobayashi, "Multi-parental Extension of the Unimodal Normal Distribution Crossover for Real-Code Genetic Algorithm," *In Proceedings of IEEE Conference on Evolutionary Computation, Vol. 2* pp. 1581-1587, 1999.
- [7] H. Satoh, M. Yamamura, and S. Kobayashi, "Minimal generation gap model for GAs considering both exploration and exploitation," *Methodologies for the Conception, Design, and Application of Intelligent Systems*, pp. 494 - 497, World Scientific, Singapore, 1996.

- [8] O. Takahashi, H. Kite, S. Kobayashi, "A Distance Dependent Alternation on Real-coded Genetic Algorithms," *In Proceedings of IEEE Conference on Evolutionary Computation*, pp. 619 - 624, Vol. 1, 1999.
 - [9] N. Hansen and A. Ostermeier, "Adapting arbitrary normal mutation distributions in evolution strategies," *In Proceedings of IEEE Conference on Evolutionary Computation*, pp. 312 - 317, 1996.
 - [10] Sarma. J and De Jong. K, *Generation gap methods. Hand book of Evolutionary Computation*, pages C2.7:1-C2.7:5, Oxford University Press, UK, 1997.
 - [11] M. M. Raghuvanshi and O. G. Kakde, "Distributed Quasi Steady-State Genetic Algorithm with Niches and Species," *International Journal of Computational Intelligence Research*, Vol. 3, No. 2, pp. 155-164, 2007
-

저 자 소 개



최준석(Junseok Choi)
2006년 : 서경대학교 전자공학과 공학사
2006~현재 : 서경대학교 전자공학과 석사과정



서기성(Kisung Seo)
1986년 : 연세대학교 전기공학과 공학사
1988년 : 연세대학교 전기공학과 공학석사
1993년 : 연세대학교 전기공학과 공학박사
1993~1998년 : 서경대학교 산업공학과 전임강사, 조교수

1999~2002년 : Michigan State University, GARAGe (Genetic Algorithms Research and Applications Group), Research Associate

2002년~2003년 : Michigan State University, Electrical & Computer Engineering, Visiting Assistant Professor

2003~2004년 : 서경대학교 전자공학과 조교수

2004~현재 : 서경대학교 전자공학과 부교수