

Multimodal 함수 최적화를 위한 Niching 유전 알고리즘에 대한 연구

이철균*, 조동혁**, 정현교**

*현대중공업 중앙연구소 전력전자 연구실, **서울대학교 전기공학부

A Study on Niching Genetic Algorithm for Multimodal Function Optimization

*Chul-Gyun Lee, **Dong Hyeok Cho, and **Hyun-Kyo Jung

*Hyundai Heavy Industry, Co.,LTD., **School of Electrical Eng. of Seoul Nat'l University

Abstract - Niching methods extend genetic algorithms to domains that require the location of multiple solutions. But, current niching methods have some of drawbacks in the ability of search and preservation of solutions. So, this paper presents a new technique, named as Restricted Competition Selection(RCS). Then, RCS method is compared with sharing and deterministic crowding by applying to some multimodal problems in order to verify that it has more favorable properties.

1. 서 론

전기기기의 최적화 문제는 동시에 만족되어야 할 서로 상충되는 설계 목적들이 많이 존재하는 다목적 최적화의 범주에 속하는 문제들이 대부분이라고 할 수 있다.

이와 같은 다목적 최적화 문제에 대한 기존의 접근방법은 가중치 법이나 제약조건법과 같이 주어진 문제를 단일목적 최적화 문제로 치환하여 얻어지는 하나의 목적 함수를 최적화하는 방법이다. 그러나, 가중치를 이용하여 목적함수들을 하나로 결합하는 가중치법은 몇 가지 문제점이 존재한다. 첫째로, 목적함수들을 결합하기 위한 가중치와 정규화 상수를 선정하기 힘들다. 둘째로, 설계자의 선호도, 제작의 용이함 등과 같이 수량화 하기 힘든 목적함수도 존재한다. 그러므로, 보통의 경우 설계 목적 중에서 하나를 목적 함수로 선정하고 나머지는 제약 조건으로 처리하여 해결한다[1]. 그러나, 이 경우에 전역 최적점(global optimal point) 외에 실용적으로 목적함수의 크기가 거의 같은 국소 최적점들(local optimal points)이 여러 개 존재하는 경우가 있다.

이러한 문제들을 해결하기 위해서 설계 대상물의 가장 중요한 특성 하나만을 목적함수로 선정 한 후에 생물학의 niche 개념을 도입한 최적화 루틴에서 설계자에게 여러 개의 최적해 후보들을 제시하고, 설계자는 그 후보들 중에서 설계 대상물의 기타 특성과 설계자의 직관 등을 사용하여 최적점을 선정하는 Niching 최적화 기법이 제안되고 있다[2].

본 논문에서는 전기기기 최적화 문제에 적용하기에 적합한 새로운 Niching 유전 알고리즘인 Restricted Competition Seltion(RCS) 방법을 제안한다. 제안한 방법의 타당성을 확인하기 위해 제안한 알고리즘을 대표적인 multi-modal 문제들에 적용하여 기존 방법들에 비해 탐색 성능 및 탐색된 해의 정확성에서 우수하다는 것을 보인다.

2. Niching 유전 알고리즘

유전 알고리즘은 자연계의 진화 현상을 모델링한 최적화 기법으로서 Holland에 의해 제안되고 Goldberg 등의 연구에 의해 발전되었다. 다른 최적화 기법이 탐색 과정에서 하나의 변수를 택하여 최적해를 찾아가는 방식

을 취하는 것과는 달리, 많은 변수들을 무작위로 선택하여 개체집단을 구성하고, 선택, 교배, 돌연변이 과정을 거쳐 개체집단을 진화 시킴으로써 최적해를 찾아가는 방식을 취하는 특징을 가지고 있으며[3], 전역 최적점을 구하는 최적화 방법 중에서 널리 쓰이고 있다.

그러나, multimodal한 최적화 문제의 경우에 일반적인 유전 알고리즘을 적용하는 경우 비록 많은 설계점을 개체집단으로 사용하더라도 탐색과정에서 하나의 전역 최적점에만 수렴하게 된다. 이는 유전알고리즘이 개체집단을 사용하지만 탐색공간 내에서 국소 최적점에 해당하는 스키마타(schemata) 사이의 경쟁을 제한할 수 없으므로 하나의 전역 최적점에만 수렴하게 된다. 이러한 현상을 genetic drift라 한다[4]. 이러한 현상을 해결하기 위해 도입된 Niching 기법은 생태계의 'niche' 개념을 도입하여 탐색공간에서 여러 해를 병렬적으로 찾을 수 있게 한다. 자연 생태계에서 비슷한 모습을 가진 개체들의 집합인 종(specie)들이 각각의 자기영역과 역할을 가지고 있는 데 이것을 niche라고 한다. 그리고, 각각의 niche에서의 생존 자원(resources)은 유한하고 그 niche 내의 개체들에게 분배된다. 그러므로, niche 내의 생존자원이 풍부한 경우 그 niche의 개체수는 증가하고 반대인 경우 감소한다. 이러한 생물학의 niche, 종, 생존 자원의 개념을 multimodal 최적화 문제를 해결하기 위한 유전 알고리즘에 도입하는데, niche는 탐색 공간 내에서의 각 피크점들의 위치, 각 niche의 생존 자원은 적합도, 종은 전체 개체집단(population)중에서 서로 어떤 거리 내에 있는 개체들에 해당된다. 그리고 이러한 niche들을 탐색하는 유전 알고리즘을 Niching유전 알고리즘이라 한다. 일반적으로 많이 사용되는 Niching 유전 알고리즘에는 Sharing[5]과 Crowding[6]이 있다.

2.1 Sharing

Sharing기법은 한 개체의 적합도를 전체 개체집단 내에서 비슷한 개체수에 관련된 양인 니체용량(Niche Count)으로 나누어 새로운 적합도 Shared Fitness로 정의한다. 각 개체의 니체용량은 그 개체와 전체 개체집단내의 개체들과의 Sharing 함수 값들의 합이다. 따라서 이 방법은 어느 정도 이상의 개체집단이 필요하다. Sharing 함수 값은 두 개체간의 거리 $d(i,j)$ 에 따라 결정되는 데, 만일 두 개체가 완전히 동일하면 1이고 거리가 Niche Radius인 σ_{share} 를 초과하면 0이다. 어떤 개체 i 의 Shared Fitness, $f'(i)$, 와 Sharing 함수, sh , 는 다음과 같이 정의되며 a 는 일반적으로 1과 2사이의 값을 사용한다.

$$f'(i) = \frac{f(i)}{\sum_{j=1}^n sh(d(i, j))}$$
$$sh(d) = \begin{cases} 1 - \left(\frac{d}{\sigma_{share}}\right)^a, & \text{if } d < \sigma_{share}; \\ 0, & \text{otherwise} \end{cases}$$

2.2 Crowding

Crowding 기법은 새로운 개체를 개체집단내의 기존 개체들 중에서 가장 비슷한 개체와 교체하는 것이다. Mahfoud는 동일 니체의 부모 세대와 자식 세대간의 경쟁을 도입함으로써, 기존의 Crowding 기법을 개선한 Deterministic Crowding(DC)을 제안했다. 부모 세대와 자식 세대간의 2가지 가능한 조합 중 더 유사한 부모자식끼리 경쟁하도록 하는 것이다. 그러나, DC는 탐색 과정 중에 찾았던 국소 최적점이 다른 최적점과의 경쟁에서 사라질 수가 있다. 그림 1은 DC 방법의 동작 원리를 보여주고 있다.

$d(p1,c1) + d(p2,c2) < d(p1,c2) + d(p2,c1)$ 이고 $p1, c2$ 의 적합도가 각각 $c1, p2$ 의 적합도보다 크므로 경쟁에서 $p1, c2$ 가 선택된다.




그림 1. DC 방법의 원리

2.3 Restricted Competition Selection

Sharing과 DC는 니체의 적합도(Fitness)에 비례하여 개체들을 유지한다. 그러나 유도전동기의 형상이나 구조 설계 최적화 문제의 경우 어떤 niche 내에서 가장 큰 적합도를 가지는 개체만이 필요하다. 그 이유는 같은 niche 내에 있는 개체들은 형상, 구조, 전동기 특성 등이 아주 비슷하기 때문이다. 그러므로 본 논문에서 니체 하나당 적합도가 최대인 하나의 개체만 유지하는 새로운 Niching 유전 알고리즘인 Restricted Competition Selection (RCS)을 제안한다. 보통의 유전 알고리즘은 자식 세대 개체집단을 구성할 때 Roulette Wheel Selection을 사용한다. 그러나, RCS 기법은 자식 세대 개체집단을 구성할 때 개체의 다양성을 유지하기 위해 같은 니체 개체간의 경쟁은 허용하지만 서로 다른 니체 개체들간의 경쟁을 제한한다. 즉, 탐색영역에서 서로간의 거리가 Niche Radius이내인 개체들의 적합도를 비교하여 승자의 적합도는 그대로 유지하고 패자의 적합도는 0으로 지정한다. 이렇게 함으로써 같은 니체내에서는 하나의 개체만이 자식 세대로 전달되고, 다른 니체의 개체는 비록 적합도가 작더라도 선택된다. 위 RCS 기법 외에 최적화 과정 중에 탐색된 국소 최적점을 유지하기 위해 엘리트 집합(Elite Set)을 도입한다. RCS 기법을 사용하는 Niching 유전 알고리즘의 흐름도는 그림 2와 같다.

3. 평가 함수 및 방법

3.1 평가 함수

본 논문에서 제안한 RCS 방법의 타당성을 검증하기 위하여 F1-F6의 6가지 multimodal 함수를 사용한다.

F1: 피크의 높이와 피크간의 간격이 동일한 5개의 피크를 가지는 1차원 sinc 함수

$$F1(x) = \sin^6(5\pi x)$$

F2: 피크간의 간격은 동일하나 피크의 높이가 서로 다른 sinc 함수

$$F2(x) = \sin^6(5\pi[x^{0.75} - 0.05])$$

F3: 피크의 높이는 동일하나 피크간의 간격이 서로 다른 sinc 함수

$$F3(x) = e^{-2(\ln 2x \frac{x-0.08}{0.854})^2} \sin^6(5\pi x)$$

F4: 피크간의 높이와 간격이 서로 다른 sinc 함수

$$F4(x) = e^{-2(\ln 2x \frac{x-0.08}{0.854})^2} \sin^6(5\pi[x^{0.75} - 0.05])$$

F1-F4에서 $0 \leq x, y \leq 1$ 이다.

F5: 25개의 피크를 가지는 2차원 Foxhole 함수

$$F5(x, y) = 500 - \frac{1}{0.002 + \sum_{i=0}^{24} \frac{1}{1 + (x - a(i))^6 + (y - b(i))^6}}$$

여기서, $a(i) = 16 \lfloor (i \bmod 5) \rfloor$,

$$b(i) = 16 \lfloor (i/5) - 2 \rfloor$$

$-65.536 \leq x, y \leq 65.536$ 이다.

F6: 18개의 높이가 같은 피크와 760개의 국소 최대점을 가지는 Shubert 함수

$$F6(x, y) = \left\{ \sum_{i=1}^5 i \cos[(i+1)x + i] \right\} \cdot \left\{ \sum_{j=1}^5 j \cos[(i+1)y + j] \right\}$$

여기서, $-10 \leq x, y \leq 10$ 이다.

step 0 : (초기화)

- * 랜덤(random)하게 초기개체집단(개체수 N) 구성

- * 적합도 순서로 M개를 선택, Elite set 구성

- * 세대수 g를 1로 지정

step 1 : (유전조작)

- * 개체집단에서 복원없이 2개의 부모세대개체 선택하여 교배와 변이의 유전작용 시행

- * N/2번 반복하여 새로운 개체집단 구성

step 2 : (Restricted Competition Selection)

step 2-1 : * 새 개체집단에 엘리트 집합을 합쳐 N+M의 개체수를 가진 경쟁 개체 집단을 구성.

step 2-2 :

dij(두 개체 xi 와 xj간의 거리) < share (niche radius) 일때 적합도 비교.

- * 패자의 새 적합도를 0으로 지정

step 2-3 : * 경쟁 개체집단에서 새 적합도 순서대로 N개 선택하여 새로운 부모 세대 개체 집단 구성.

- * 그 중에서 상위 M개로 엘리트 개체집단 구성.

step 4 : (종료)

- * 세대수 g >= Gn (미리 지정한 반복 세대수) 이면 종료 아니면, 세대수를 1증가시키고 step 1로 감.

그림2. RCS 방법의 흐름도




그림 3. 평가함수 F4의 그래프




그림 4. 평가함수 F5의 그래프




그림 5. 평가함수 F6의 그래프

표 1. 개체 집단의 크기가 피크수의 2배일 때 알고리즘의 성능 비교

	NMP		MPR	
	F1	F2	F3	F4
Sharing	2.46	0.4787	2.06	0.5423
DC	4.93	0.9831	4.88	0.9551
RCS	5.00	0.9924	5.00	0.9958
	F5		F6	
Sharing	2.95	0.5629	2.68	0.6523
DC	4.77	0.9533	3.93	0.9115
RCS	5.00	0.9945	5.00	0.9965
	F5		F6	
Sharing	22.95	0.8628	8.43	0.4314
DC	20.00	0.7588	8.46	0.4696
RCS	25.00	0.9989	18.00	0.9987

표 2. 개체 집단의 크기가 피크수의 4배일 때 알고리즘의 성능 비교

	NMP		MPR	
	F1	F2	F3	F4
Sharing	1.30	0.2507	1.29	0.2483
DC	4.36	0.8683	3.67	0.8234
RCS	5.00	0.9896	5.00	0.9913
	F5		F6	
Sharing	1.52	0.2507	1.50	0.3677
DC	4.25	0.8238	3.59	0.8123
RCS	5.00	0.9875	5.00	0.9920
	F5		F6	
Sharing	12.56	0.4761	2.72	0.1401
DC	14.73	0.5697	6.09	0.3378
RCS	25.00	0.9974	16.89	0.9356

3.2 평가 방법

Niching 유전 알고리즘의 경우 각 알고리즘의 우열을 판정하는 기준은 multi-modal 함수의 최적화 방법의 특성상 기존의 최적화 알고리즘에서 일반적으로 적용하는 최종 수렴값과 목적함수 계산 횟수만으로 하기 어렵다. 본 논문에서는 제안한 RCS 방법과 기존의 Sharing과 DC 방법을 평가 함수에 적용하여 비교하기 위하여 다음과 같은 평가 기준을 이용하였다.

첫째, 알고리즘의 종료시 탐색된 니체의 갯수 (number of maintained peaks, NMP)이다.

이 기준은 각각의 알고리즘이 전체 최적점뿐만이 아니고 국소 최적점에 대하여 얼마나 탐색을 잘하는가를 평가하는 기준이다. 알고리즘이 종료되었을 때 각 개체들 중 각 니체 내에서 실제 피크의 80% 이상 되는 점이 하나 이상 존재할 때 하나의 니체를 찾았다고 정의한다. 예를 들어, 평가함수 F1의 경우 NMP의 최대값은 5이며 목적함수가 0.8 이상의 값을 가져야 한다.

둘째, 알고리즘의 종료시 찾은 니체들에서의 최대값의 합을 실제 최대값들의 합으로 나눈 값(maximum peak ratio, MPR)이다. 이 MPR의 최대값은 1이며, 이때 모든 피크를 정확하게 찾았다고 할 수 있다.

4. 적용 결과

테스트 함수 F1-F6에 Sharing, Deterministic Crowding (DC), RCS 기법을 적용하였다. 이때, 교배 확률은 0.8, 변이확률은 0.1로 하였으며 반복 계산 횟수는 500으로 지정하였다.

확률적인 알고리즘의 특성상 각각 100회씩 적용하여 그 평균 결과를 표 1과 2에 보였다. 표 1은 개체 집단의 크기가 피크수의 2배일 때, 즉 F1-F4에서는 10, F5는 50, F6의 경우에는 36개 일 때의 결과이며 표 2는 개체 집단의 크기가 피크수의 4배일 때의 경우를 보여주고 있다.

표 1, 2에서 볼 수 있듯이 모든 평가 함수에 있어서 본 논문에서 제안한 RCS 기법이 NPM이나 MPR에서 우월함을 알 수 있다. RCS 기법은 표 2에서 개체 집단의 크기가 36인 F6 함수에서 18개인 피크 중에서 평균적으로 16.89개를 찾았을 뿐 나머지 경우에는 모든 피크를 찾았음을 볼 수 있다.

표 1에서 Sharing 기법은 평가함수 F1-F6에서 DC나 RCS 방법에 비해 상당히 성능이 떨어지는 것을 볼 수 있는데 이것은 알고리즘의 특성상 개체집단의 크기가 어느 정도 이상이 되어야 sharing 함수가 원하는 방향으로 작용할 수 있다는 것을 나타낸다. 이것은 표 2의 F5 평가함수의 적용 결과에서 개체집단의 크기가 100이 되었을 때 DC에 비해 우수한 성능을 보이는 것으로부터 알 수 있다.

5. 결론

본 논문에서는 Restricted Competition Selection (RCS)을 사용하는 새로운 Niching 유전 알고리즘을 제안하였으며, 제안한 RCS 방법의 타당성을 보이기 위하여 대표적인 multimodal 함수들의 최적점들을 찾는 문제에 적용하여 탐색된 피크수와 최대 피크비에 있어 기존의 Niching 알고리즘인 Sharing이나 Crowding 보다 우수하다는 것을 확인하였다.

본 논문에서 제안한 최적화 기법은 전기기기의 형상이나 치수의 최적화의 문제 등과 같은 목적함수의 값이 실질적으로 거의 같은 후보해들을 요구하는 문제에 적용될 수 있을 것이다.

(참고 문헌)

- [1] J. L. Cohon, Multiobjective Programming and Planning, Academic Press, 1978.
- [2] B. Sareni, L. Krahenbuhl and A. Nicolas, "Niching Genetic Algorithms for Optimization in Electromagnetics", The 11th COMPUMAG'97, 563-564, Rio de Janeiro, 1997.
- [3] D.E. Goldberg, Genetic Algorithms in Search, Optimization & Machine Learning, Addison-Wesley Publishing Co., 1989.
- [4] K. A. De Jong, An analysis of the behavior of a class of genetic adaptive systems, Doctoral dissertation, Univ. of Michigan, 1975.
- [5] D. E. Goldberg and J. Richardson, "Genetic Algorithms with Sharing for Multimodal Function Optimization", Proc. 2nd ICGA, 41-49, 1987.
- [6] S.W. Mahfoud, "Crowding and preselection revisited," In R. Manner & B. Manderick (Eds.), Parallel problem solving from nature, Vol.2, pp. 27-36, Elsevier, 1992.