

## 다목적함수 최적화를 위한 새로운 진화적 방법 연구

심 문 보<sup>\*</sup> · 서 명 원<sup>†</sup>

(2000년 12월 14일 접수, 2002년 4월 11일 심사완료)

### A Study of New Evolutionary Approach for Multiobjective Optimization

Mun-bo Shim and Myung-won Suh

**Key Words :** Multiobjective Optimization(다목적함수 최적화), Continuous Evolutionary Algorithms (C.E.A.), Pareto-optimal(Pareto 최적해), Niche formation(Niche 형성), Historical storage (H.S.)

#### Abstract

In an attempt to solve multiobjective optimization problems, many traditional methods scalarize the objective vector into a single objective. In those cases, the obtained solution is highly sensitive to the weight vector used in the scalarization process and demands the user to have knowledge about the underlying problem. Moreover, in solving multiobjective problems, designers may be interested in a set of Pareto-optimal points, instead of a single point. In this paper, Pareto-based Continuous Evolutionary Algorithms for Multiobjective Optimization problems having continuous search space are introduced. This algorithm is based on Continuous Evolutionary Algorithms to solve single objective optimization problems with a continuous function and continuous search space efficiently. For multiobjective optimization, a progressive reproduction operator and a niche-formation method for fitness sharing and a storing process for elitism are implemented in the algorithm. The operator and the niche formulation allow the solution set to be distributed widely over the Pareto-optimal tradeoff surface. Finally, the validity of this method has been demonstrated through a numerical example.

#### 1. 서 론

현재까지 공학적 최적화 분야에서 많은 연구가 이루어져 왔으나 그 연구들은 실제적 공학적 문제를 해결하는 연구였다기보다 거의 이상적이고 비현실적인 문제들을 해결하는데 머물러 있었다. 그 이유 중에 하나는 수년동안 단일 목적함수 최적화 문제를 해결하는데 초점을 두었기 때문이다. 그러나 실제 공학적 문제들은 몇몇 목적 함수들의 대립으로 이루어져 있다. 이러한 상황들은 설계자에게 잘 정의된 최적화 기준을 사용하여 해를 구하는 것을 막고 단지 그들의 경험을 바탕으로 한 제약 조건을 이용해 해를 구하려 하였다.

전형적인 다목적함수 최적화 문제에서 설계가 능영역의 설계점들 중 목적함수 공간의 모든 목적함수를 고려했을 때 적어도 하나의 목적함수는 다른 목적함수보다 작거나 같은 설계점이 존재할 때 그 설계점을 Pareto 최적해집합<sup>(1)</sup>이라 한다.

Pareto 최적해 집합들은 더 생각할 필요도 없이 다른 해들보다 좋은 해집합이기 때문에 다목적 최적화의 목적은 가능한 많고 넓게 분포되어 있는 Pareto 최적해 집합을 구하는 것이다. 그런 해집합들이 발견되면 일반적으로 그들 중 하나의 해를 선택하는 고차원적인 선택과정(decision-making)을 필요로 하게 된다. 본 연구에서는 Pareto 해집합을 효과적으로 찾는 것에만 국한하고자 한다.

다목적 최적화 문제를 다루는데 있어서 전통적인 최적화 방법 즉, weighted sum methods, goal programming,  $\varepsilon$ -constraint method, min-max method 등이 있으나 그리 효과적이라 할 수 없다. 왜냐하면 그들 대부분의 방법은 한번 적용하는 것으로부터 다수의 해를 구하는 것이 불가능하고 원하는

\* 회원, 성균관대학교 기계공학부

† 책임저자, 회원, 성균관대학교 기계공학부

E-mail : suhmw@yurim.skku.ac.kr  
TEL : (031)290-7447 FAX : (031)290-5276

Pareto 해집합의 수를 사전에 결정해서 그 수만큼 계산을 반복해야 한다. 또한 다수의 적용으로부터 얻은 해집합이 넓게 분포된 Pareto 해집합이 되는 것도 보장되어 있지 않다.

대조적으로 진화적 방법에 대한 연구<sup>(4,6,7)</sup>에서는 위에서 언급된 어려움들을 효과적으로 극복한 사례들을 보여줘 왔다. 이 방법들은 해의 탐색에 있어서 집단(population)을 사용하기 때문에 다수의 Pareto 해를 한번의 최적화 수행을 통해 얻을 수 있었다. 하지만 이러한 연구에서도 넓게 분포된 다수의 Pareto 해를 찾는 연구라기보다는 단지 다수의 Pareto 해를 찾는 연구였고 문제 적용에 있어서도 단순한 예가 대부분이었다.

본 연구에서 효과적으로 넓게 분포된 Pareto 해집합을 구하기 위해 적합도 계산 방법이 새롭게 적용된 다목적 함수 최적화 기법이 제시된다. 이 알고리듬은 연속 함수 및 연속 탐색 구간인 단일 최적화 문제를 해결하기 위해 개발된 Continuous Evolutionary Algorithms(CEAs)<sup>(3)</sup>에 기초를 두고 있으며 기존의 진화적 방법으로 다목적 함수 최적화를 했던 것보다 더 좋은 성능향상을 위해 연속 탐색 구간에서 효과적인 교배 연산(recombination)이 사용되고 Elitism 과 안정적인(robust) Pareto 해집합을 얻기 위해 외부저장 연산이 수행된다. 이와 같은 연산들이 결합된 새로운 다목적 함수 최적화 기법인 Pareto-based continuous evolutionary algorithms for multiobjective optimization(MOPCEAs)은 넓게 분포된 Pareto 해집합을 효과적으로 얻을 수 있게 한다.

## 2. Pareto-based Continuous Evolutionary Algorithms for Multiobjective Optimization (MOPCEAs)

### 2.1 알고리듬 구조

다목적 함수 최적화를 위한 새로운 진화적 방법인 Pareto-based continuous evolutionary algorithms for multiobjective optimization (MOPCEAs)은 다음과 같은 특징들이 있다.

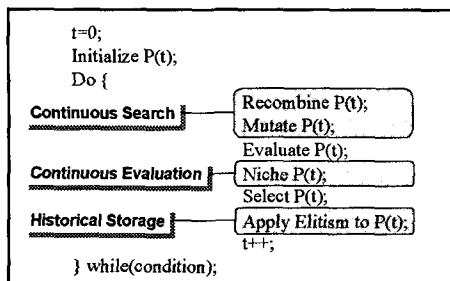


Fig. 1 Flowchart of MOPCEAs

1. Continuous Search: 연속 탐색 구간인 최적화 문제의 해를 찾기 위하여 실수로 구성된 객체(individual)를 사용해 효과적 탐색을 위한 교배 및 돌연변이 연산 수행
2. Continuous Evaluation: 넓게 분포된 Pareto 해집합을 얻기 위한 연속 탐색 구간을 갖는 Niche 형성
3. Historical Storage: 명확한 Pareto 해집합을 구하고 빠른 Pareto 해집합의 수렴을 위해 전 세대의 Pareto 해들을 저장

Fig. 1은 본 연구에서 제안된 MOPCEAs의 기본적인 구조를 나타낸다.

먼저 실수 개체로 표현된 집단이 무작위로 구성된다.(세대 t=0)

$$\mathbf{P}^t = \{\mathbf{x}_1^t, \dots, \mathbf{x}_{\lambda}^t\} \in (\mathbf{R}^n)^{\lambda} \quad (1)$$

여기서  $\mathbf{R}^n$ 은 개체의 차원을 나타내며  $\lambda$ 는 개체의 수를 나타낸다. 실수로 표현된 개체들은 일반적으로 표현형(phenotype)이라 한다.

### 2.2 Continuous Search

교배와 돌연변이(mutation) 연산은 실수 범위에서 확률적인 분포에 의해 수행된다. 교배의 경우 부모 세대들의 정보를 결합함으로써 자녀 세대를 구성하게 된다. 교배 연산은 다음과 같이 정의 된다.<sup>(3)</sup>

$$\begin{cases} \mathbf{x}_{\alpha}^{t+1} = (1 - \mu_{\alpha}') \mathbf{x}_{\alpha}^t + \mu_{\beta}' \mathbf{x}_{\beta}^t \\ \mathbf{x}_{\beta}^{t+1} = \mu_{\alpha}' \mathbf{x}_{\alpha}^t + (1 - \mu_{\beta}') \mathbf{x}_{\beta}^t \end{cases} \quad (2)$$

이를 비대칭 교배(asymmetry recombination)라 하며 여기서  $\mathbf{x}_{\alpha}^t$ 와  $\mathbf{x}_{\beta}^t$ 는 세대 t에서의 부모 세대이고  $\mu_i'$ 는 평균이 0이고 표준편차가  $\sigma$ 인 정규분포이다.

$$\mu_i' = N(\mathbf{0}, \sigma^2) \quad (3)$$

몇몇 연구에서<sup>(8,9)</sup>  $\mu$ 를 부모 세대와 관계없이 같은 값을 사용하였다. 이를 대칭 교배(symmetry recombination)라 한다. 대칭 교배의 경우 문제의 성질이 단봉(unimodal)이거나 간단한 문제의 경우 빠른 수렴성을 보이지만 다목적 함수 최적화의 문제에서는 비대칭 교배 연산이 안정적인 탐색을 하기 때문에 더 효과적이다.

Fig. 2는 교배 방법들의 차이를 나타내고 있다. ‘o’으로 표시된 부분이 부모 세대이고 이 부모 세대로부터 각각의 교배 방법에 의해 새롭게 만들어지는 자녀 세대들을 ‘\*’으로 표시하였다. 대칭 및 비대칭 교배의 경우 표준편차가 0.5인 정규분포를 사용하여 무작위로 자녀 세대를 생성하였다. 이진 교배의 경우 각 변수 당 문자길이를 7로 하고 단일 교배점을 사용하였으며 1비트부터 20비트까지

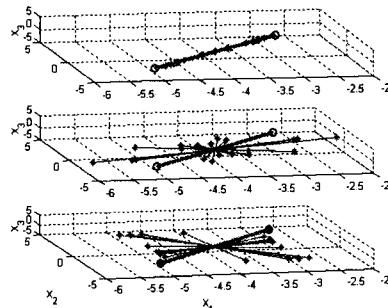


Fig. 2 Comparison of symmetric, asymmetric and genetic crossover

를 차례대로 교배점으로 사용하여 자녀 세대를 생성하였다. 대칭 교배의 경우 부모 세대의 내부 선상에서만 자녀 세대가 생성하므로 국부 탐색에는 효과적이나 안정성(robustness)이 결여된 탐색임을 알 수 있다. 상대적으로 비대칭 교배와 이진 교배의 경우 안정성을 갖는 탐색 방법임을 알 수 있으나 이진 교배의 경우 전역 탐색이 너무 강한 것을 볼 수 있다. 결과적으로 비대칭 교배가 전역 탐색 및 국부 탐색을 효과적으로 수행하는 것을 알 수 있다.

돌연변이 연산은 다음과 같이 단순한 형태로 수행된다.

$$\mathbf{x}^{t+1} = \text{rand}(\mathbf{x}_{\min}, \mathbf{x}_{\max}) \quad (4)$$

비대칭 교배가 전역 탐색에도 상당히 기여하므로  $\mu_t^i$  가 클 경우 자녀 세대가 크게 변화할 수 있기 때문에 돌연변이 연산이 필요 없을 경우도 있다.

### 2.3 Continuous Evaluation

넓게 분포된 집단을 유지하기 위한 MOPCEAs의 주된 방법들은 목적함수 공간에서 좋은 집단들을 결정짓는 순위선택(ranking selection) 방법과 변수 공간에서 분산된 집단을 유지하기 위한 분배(sharing) 방법이다. MOPCEAs는 효과적인 선택(selection) 방법을 강조하는 알고리듬이다. Fig. 3 은 MOPCEAs의 Niche 형성 과정을 보여주고 있다.

먼저 현재 세대에서 Pareto 최적 조건을 만족하는 객체를 찾는다. 그리고 이들을 순차적인 방법으로 순위(rank)를 매긴다.<sup>(5)</sup>

$$G(k) = \{\mathbf{x}_i \mid \text{rank}(\mathbf{x}_i) = k, \forall i \in \{1, \dots, n\}\} \quad (5)$$

여기서  $k$ 는 순위 번호이고  $G(k)$ 는  $k$  순위에 속하는 객체 집합이다. 또한 각 객체들의 임시 적합도(fitness)를 Fig. 4 와 같은 방법으로 구한다. 은 MOPCEAs의 Niche 형성 과정을 보여주고 있다.

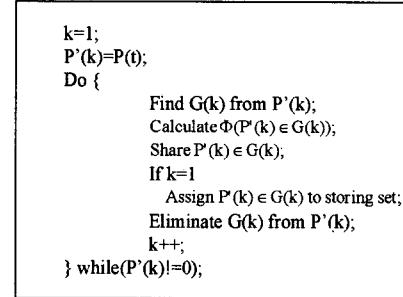


Fig. 3 The process of the niche formation

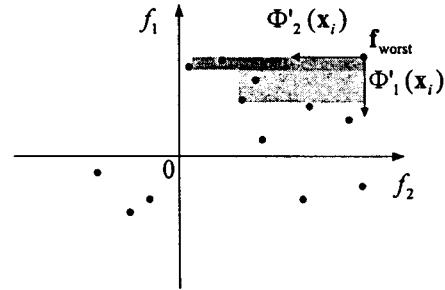


Fig. 4 Evaluation of individuals

먼저 현재 세대에서 Pareto 최적 조건을 만족하는 객체를 찾는다. 그리고 이들을 순차적인 방법으로 순위(rank)를 매긴다.<sup>(5)</sup>

$$G(k) = \{\mathbf{x}_i \mid \text{rank}(\mathbf{x}_i) = k, \forall i \in \{1, \dots, n\}\} \quad (5)$$

여기서  $k$ 는 순위 번호이고  $G(k)$ 는  $k$  순위에 속하는 객체 집합이다. 또한 각 객체들의 임시 적합도(fitness)를 Fig. 4 와 같은 방법으로 구한다.

Fig. 4 에서 보여지는 바와 같이 목적함수 값들을 각각 계산하여 각 목적함수에 대해 가장 큰 값을 갖는 목적함수 값을  $f_{\text{worst}}$  로 하고 가장 작은 값을 갖는 목적함수 값을  $f_{\text{best}}$  로 하여 임시 적합도를 구한다.

$$f_{\text{worst}} = \max\{f_j(\mathbf{x}_i) \mid \forall i \in \{1, \dots, n\}\}$$

$$f_{\text{best}} = \min\{f_j(\mathbf{x}_i) \mid \forall i \in \{1, \dots, n\}\} \quad (6)$$

$$\Phi'_j(\mathbf{x}_i) = \frac{f_{\text{worst}} - f_j(\mathbf{x}_i)}{f_{\text{worst}} - f_{\text{best}}}$$

이때 정규화된 임시 적합도를 구할 수 있다.

$$0 \leq \Phi'_j(\mathbf{x}_i) \leq 1 \quad (7)$$

이것은 같은 스케일로 각각의 목적함수를 취급할 수 있다는 것을 의미하며 또한 목적함수 공간의 상대적인 거리에 따른 비중을 나타낸다. 이와 같이 계산된 임시 적합도는 순위에 따른 가상 적

합도를 구하는데 사용된다.

$$\Phi_j(\mathbf{x}_i) \equiv \Phi_j^{G(k)}(\mathbf{x}_i) = \max\{\Phi'_j(\mathbf{x}_i) \mid \mathbf{x}_i \in G(k)\} \quad (8)$$

결과적으로 순위에 따른 각 객체의 가상 적합도는 다음과 같이 계산된다.

$$\Phi(\mathbf{x}_i) = \sum_{j=1}^m \Phi_j(\mathbf{x}_i) \quad (9)$$

여기서  $m$ 은 목적함수의 수를 나타내며 가상 적합도의 범위는 다음과 같다.

$$0 \leq \Phi(\mathbf{x}_i) \leq m \quad (10)$$

이와 같이 계산된 가상 적합도는 목적함수 공간을 고려한 적합도로서 유용하나 같은 순위의 객체들이 같은 적합도를 갖는다는 문제를 나타낸다. 이런 문제는 많은 연구자들에 의해 어려움을 느꼈던 해의 집중현상(general drift)을 초래하여 넓게 분포된 Pareto 해집합을 얻는데 장애가 된다. 그러므로 이를 해결하기 위해 본 연구에서는 분배방법을 도입하였고 이는 다음과 같이 적용된다.

먼저 앞에서 구한 순위  $k$  번째의  $G(k)$ 가  $n_k$  개 있다고 하면 분배방법은 우선 서로 다른 객체들 사이의 변수 공간에서의 정규화된 Euclidean 거리를 구한다.

$$d_{ij} = \sqrt{\sum_{p=1}^{\lambda} \left( \frac{\mathbf{x}_p^i - \mathbf{x}_p^j}{\mathbf{x}_p^u - \mathbf{x}_p^l} \right)^2} \quad (11)$$

여기서  $i = 1, 2, \dots, n_k$ 에 대해  $j$  번째 객체 값들이 계산 된다.  $\mathbf{x}_p^u$ 과  $\mathbf{x}_p^l$ 는 변수  $\mathbf{x}_p$ 의 상한값과 하한값을 의미한다. 이 거리는 미리 정의된  $\sigma_{share}$  값과 비교되고 분배함수 값이 계산된다.

$$Sh(d_{ij}) = \begin{cases} 1 - \left( \frac{d_{ij}}{\sigma_{share}} \right)^2 & \text{if } d_{ij} \leq \sigma_{share} \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

$\sigma_{share}$  값은 문제에 따라 변화될 수 있으며 정확하게 규정하기는 어려우나 대개 다음과 같은 식의 값을 사용해 왔다.<sup>(5)</sup>

$$\sigma_{share} \approx \frac{0.5}{\sqrt[3]{q}} \quad (13)$$

여기서  $q$ 는 구하고자 하는 Pareto 해집합의 수를 의미한다. 선행 연구자에 의해 제시된  $\sigma_{share}$ 는  $q$  값에 의존적일 뿐만 아니라 아진수를 사용하기 때문에 분해도(resolution)에 따라 영향을 받기 때문에 그리 효과적이지 못했다. 그러나 본 연구에서 개발된 MOPCEAs는 연속 탐색 구간을 사용하기 때문에 효과적으로 적용되었다. 분배함수

$Sh(d_{ij})$ 는  $j$ 가  $n_k$ 에 도달할 때까지 반복 계산을 수행하며  $i$  번째 해의 niche 수는 다음과 같이 계산된다.

$$m_i = \sum Sh(d_{ij}) \quad (14)$$

$k$  번째 Pareto 해집합에서  $i$  번째 해의 가상 적합도  $\Phi_k$ 는 niche 수에 의해 실제 적합도로 변환된다.

$$\Phi_i^* = \frac{\Phi_k}{m_i} \quad (15)$$

이와 같은 계산을 모든  $i = 1, 2, \dots, n_k$ 에 대해 수행하며 대응하는  $\Phi_i^*$ 을 얻는다. 또한 전체 집단이 몇몇의 순위로 분류될 때까지 위의 과정을 반복 수행한다. 위의 과정으로부터 얻어진 적합도는 목적함수 공간과 변수 공간의 정보를 함께 사용해서 얻어진 값으로 집단의 다양성을 유지하는데 매우 효과적이라 하겠다. Fig. 5는 분배과정 전후과정을 통해 얻어진 적합도의 변화를 나타낸다.

이 과정들에서 순위 1인 객체들은 Pareto 해집합을 구체적으로 형성하는 historical storage 과정에 사용되며 이런 추가적인 과정에 의해 더욱 효과적인 Pareto 해집합의 분산과 수렴속도의 향상이 이루어진다.

#### 2.4 Historical Storage

단일 목적함수 최적화 문제와 달리 다목적함수 최적화 문제는 셀 수 없는 해들이 존재한다. 이러한 해집합을 즉, Pareto 최적 공간을 찾기 위해 반드시 필요한 방법이 historical storage이다.

Fig. 6은 historical storage 과정을 보여준다. Niche 형성에서 얻어진 순위 1인 객체들을 현재 세대까지 얻어진 Pareto 해집합과 함께 고려하여 그들 중 Pareto 해집합을 찾는다. 이들을 진화과정 외부에 저장하여 엘리티즘(elitism) 과정에 적용한다. 이와 같은 외부 저장 Pareto 해집합은 수렴속도를 매우 향상시킬 뿐만 아니라 해들의 다양성을 보장해 준다. 외부 저장 시 유의해야 할 점은 Pareto

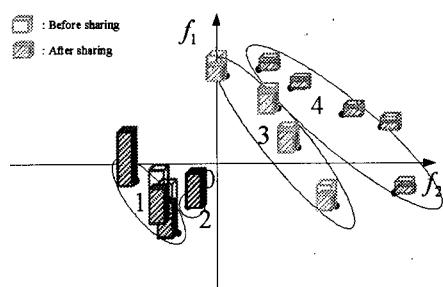


Fig. 5 Comparison of the fitness before and after the sharing process

해집합이 무한 원소를 가지고 있으므로 저장 해집합으로 선택할 때 서로가 충분히 다를 경우에만 저장을 하는 조건이 필요하다.

### 3. 수치해석 적용 및 결과

이 문제는 단일 목적함수 최적화 뿐만 아니라 다목적 함수 최적화에 사용되는 문제이다<sup>(2)</sup>. 이 문제에서는 하나의 보가 다른 보에 접합되어야 하며 일정 하중  $F$ 를 받는다.

Fig. 7 과 같은 길이가 14 인치의 용접된 보에 6000lb 의 하중이 작용되어 있다. 단일 목적함수 최적화 문제일 경우, 비용을 최소화하기 위한 4개의 설계변수(보의 두께  $b$ , 보의 폭  $t$ , 용접 길이  $L$ , 용접 두께  $H$ )를 찾기 원한다. 직관적으로 비용을 최소화하기 위해 모든 설계변수가 작은 값을 갖으면 좋을 것이다. 반대로 보의 강성(또는 처짐)을 크게 하려면 설계변수 중 몇몇은 큰 값을 가져야 한다. 이와 같이 최소 비용과 최대 강성의 설계 최적해는 서로 대립되고 이런 대립은 Pareto 해집합을 이룬다. 이런 다목적함수 최적화 문제를 정의하면 다음과 같이 표현되고 보다 자세한 내용은 참고 문헌들을 참고하기 바란다.

$$X = \{b, t, L, H\} \quad (16)$$

Minimize:

$$\begin{cases} f_1 = 1.10471H^2L + 0.04811tb(14.0 + L) \\ f_2 = \delta = \frac{2.1952}{t^3b} \end{cases} \quad (17)$$

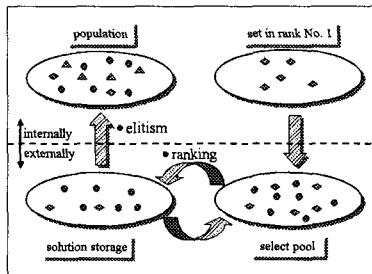


Fig. 6 The process of historical storage

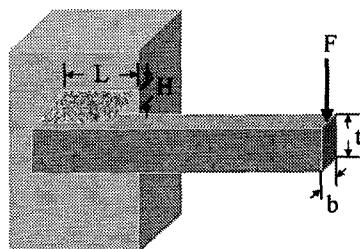


Fig. 7 The welded beam design problem. Minimizations of cost and end deflection are two objectives

Subject to:

$$\begin{cases} g_1 = 13,600 - \tau \geq 0 \\ g_2 = 30,000 - \sigma \geq 0 \\ g_3 = b - H \geq 0 \\ g_4 = P_c - 6,000 \geq 0 \end{cases} \quad (18)$$

$$0.125 \leq H, b \leq 5.0$$

$$0.1 \leq L, t \leq 10.0$$

여기서  $g_1$ 은 전단 응력,  $g_2$ 는 굽힘 응력,  $g_3$ 은 용접,  $g_4$ 는 좌굴에 대한 제한 조건이다. MOPCEAs 는 제한조건에 대한 충족성을 자체적으로 해결할 수 없기 때문에 제한 조건은 외부 벌점(exterior penalty) 함수 방법을 사용하여 적용하였다. 이때 제한조건에 부여되는 벌점 계수는 첫번째 목적함수와의 결합에 대해서 100, 두 번째 목적함수와의 결합에 대해서 0.1 을 사용하였다. MOPCEAs

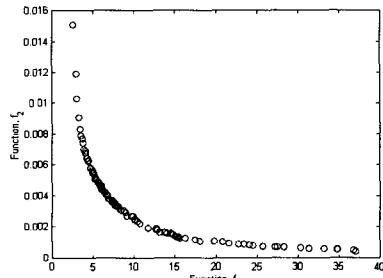


Fig. 8 Pareto-optimal solutions

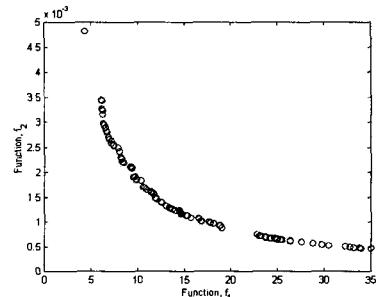


Fig. 9 Pareto-optimal solutions (binary strings of size 10)

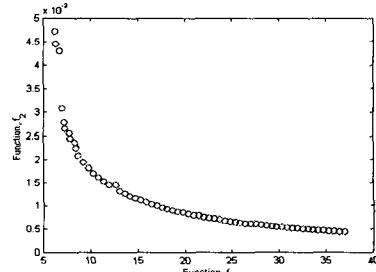


Fig. 10 Pareto-optimal solutions (binary strings of size 7)

의 계수들은 집단 100,  $\sigma_{share} = 0.281$ , 돌연변이율 0.001을 사용하였다.

Fig. 8은 62세대에서 모든 집단이 Pareto 해집합으로 된 것을 나타낸다. 그림에서 알 수 있듯이 MOPCEAs는 빠른 수렴속도와 넓게 분포된 Pareto 해집합을 얻을 수 있게 해 준다.

제안된 MOPCEAs 효용성을 보이기 위해 다른 방법을 비교해 보았다. 진화 이론 중 가장 널리 사용되고 있는 유전자 알고리듬(Genetic Algorithms)을 사용했으며, 기본적으로 MOPCEAs과 동일한 형태이지만 이진수를 사용하였고 이진교배와 이진 돌연변이 방법을 적용하였다. 이때 유전자 알고리듬의 계수는 MOPCEAs의 경우와 같으며 추가적을 교배율 0.8 이진수 길이를 각각의 변수에 대해 10비트와 7비트인 두 경우에 대해 적용해 보았다.

Fig. 9, 10에서 알 수 있듯이 모든 집단이 Pareto 해집합이 되지 못했으며 넓게 분포된 해집합을 얻을 수 없었다. 또한 변수의 분해능에 따라 해집합의 형태가 변하는 것을 알 수 있었으며 이는 다목적함수에서 넓게 분포된 해집합을 얻는데 중요한 역할을 하는 niche 형성은 실수를 이용한 연산이기 때문에 이진수 연산을 수행하는 유전자 알고리듬에는 한계가 있음을 나타낸다.

#### 4. 결 론

본 연구에서 효과적으로 넓게 분포된 Pareto 해집합을 구하기 위해 적합도 계산 방법이 새롭게 적용된 MOPCEAs이 제시되었다. 이 알고리듬은 연속 함수 및 연속 탐색 구간에서 새롭게 정의된 적합도 계산과 함께 효과적인 교배 연산(recombination) 및 엘리티즘과 외부저장 연산이 수행된다.

일반적 설계문제는 연속인 실수 범위에서 적용되고 다목적함수 최적화에서 주된 알고리듬이 실수 연산을 수행하므로 이진수를 사용하는 기존의 유전자 알고리듬에 비해 MOPCEAs는 매우 강력한 방법이라 할 수 있다. 또한, 이러한 다목적함수 최적화 방법의 개발은 이상적으로 이루어왔던 단일 목적함수 최적화 문제를 좀 더 현실적으로 해결할 수 있는 해법이라 할 수 있다.

#### 후 기

본 논문은 한국과학재단 산하 성균관대학교 산업설비 안전성평가 연구센터의 연구비 지원으로 이루어진 것으로서, 이에 관계자 여러분께 감사드립니다.

#### 참고문헌

- (1) Chankong, V. and Haimes, Y.Y., 1983, "Multiobjective Decision Making Theory and Methodology," New York:North-Holland.
- (2) Reklaitis, G.V., Ravindran, A. et al., 1983, Engineering Optimization, John Wiley & Sons.
- (3) Furukawa, T. and Yagawa, G., 1997, "Inelastic Constitutive Parameter Identification using an Evolutionary Algorithm with Constitutive Individuals," *Int. Journal for Numerical Methods in Engineering*, Vol. 40, pp. 1071~1090.
- (4) Srinivas, N. and Deb, K., 1994, "Multiobjective Optimization using Nondominated Sorting in Genetic Algorithms," *Evolutionary Computation*, 2(3), pp. 221~248.
- (5) Goldberg, D.E., 1989, Genetic Algorithms for Search, Optimization and Machine Learning, Addison-Wesley.
- (6) Fonseca, C.M. and Fleming, P.J., 1993, "Genetic Algorithms for Multiobjective Optimization: Formulation, Discussion, and Generalization," *Proceedings of the Fifth International Conference on Genetic Algorithms*, pp. 416~423.
- (7) Horn, J. and Nafpliotis, N. and Goldberg, D.E., 1994, "A niched Pareto Genetic Algorithm for Multiobjective Optimization," *Proceedings of the First IEEE Conference on Evolutionary Computation*, pp. 82~87.
- (8) Obayashi, S., 1998, "Multidisciplinary Design Optimization of Aircraft Wing Platform Based on Evolutionary Algorithms," *Proceedings of the IEEE International Conference on Systems*, La Jolla, California, IEEE.
- (9) Qing, A. and Lee, C.K. and Jen, L., 1999, "Microwave Imaging of Parallel Perfectly Conducting Cylinders using Real-Coded Genetic Algorithm," *Journal of Electromagnetic Waves and Application*, Vol. 13, pp. 1121~1143.
- (10) Shim, M.B., Furukawa, T., Suh, M.W. et al., 2000, "Efficient Multi-point Search Algorithms for Multiobjective Optimization Problem," *Proceedings of the Conference on Computational Engineering and Science*, Vol. 5, No.2, pp. 459~462.
- (11) Suh, M.W., Shim, M.B. and Kim, M.Y., 2000, "Crack Identification using Hybrid Neuro-Genetic Technique," *Journal of Sound and Vibration*, Vol. 238, No. 4, pp. 617~635.