

다목적 유전 알고리즘을 이용한 쌍대반응표면최적화

이동희[†] · 김보라 · 양진경 · 오선혜

한양대학교 산업융합학부

Dual Response Surface Optimization using Multiple Objective Genetic Algorithms

Dong-Hee Lee · Bo-Ra Kim · Jin-Kyung Yang · Seon-Hye Oh

Division of interdisciplinary industrial studies, Hanyang University

Dual response surface optimization (DRSO) attempts to optimize mean and variability of a process response variable using a response surface methodology. In general, mean and variability of the response variable are often in conflict. In such a case, the process engineer need to understand the tradeoffs between the mean and variability in order to obtain a satisfactory solution. Recently, a Posterior preference articulation approach to DRSO (P-DRSO) has been proposed. P-DRSO generates a number of non-dominated solutions and allows the process engineer to select the most preferred solution. By observing the non-dominated solutions, the DM can explore and better understand the trade-offs between the mean and variability. However, the non-dominated solutions generated by the existing P-DRSO is often incomprehensive and unevenly distributed which limits the practicability of the method. In this regard, we propose a modified P-DRSO using multiple objective genetic algorithms. The proposed method has an advantage in that it generates comprehensive and evenly distributed non-dominated solutions.

Keywords: Response Surface Methodology, Dual Response Surface Optimization, Multiple Objective Genetic Algorithm, Posterior Preference Articulation Approach

1. 서론

반응표면법은 공정최적화를 위한 품질공학 방법론으로 입력 변수와 반응변수와의 관계를 분석하여 최적 공정조건을 도출하는 것을 목표로 한다. 쌍대반응표면최적화는 반응표면법의 확장된 연구 분야로 반응변수의 평균뿐만 아니라 산포까지 고려하는 다구찌의 철학을 반응표면법을 통해 접근하는 연구분야이다(Yum *et al.*, 2013). 연구의 핵심은 반응변수의 평균과 산포를 각각 독립적인 반응표면함수로 모형화한 뒤, 두 반응표면함수(평균반응함수와 산포반응함수)를 동시에 최적화하는 것이다.

일반적인 반응표면법은 단일 반응변수의 최적화에 초점을

맞추고 있다. 반면 쌍대반응표면최적화는 두 개의 반응표면함수를 동시에 최적화해야 하기 때문에 필연적으로 두 반응표면함수에 대한 의사결정의 이슈가 수반된다. 즉, 두 반응표면함수의 상충관계에 대한 이해를 바탕으로 최적의 절충안을 도출하는 과정이 수반된다. 이는 두 가지의 목적함수를 동시에 최적화하는 문제에 해당하므로 쌍대반응표면최적화 연구는 다목적의사결정방법 연구와 밀접한 관련이 있다고 볼 수 있다. 다목적의사결정방법은 의사결정자의 선호도 정보 반영 시점에 따라 사전/대화식/사후 선호도정보반영법(Prior/Interactive/Posterior Preference Articulation Approach)으로 구분하고 있는데(Hwang *et al.*, 1979), 쌍대반응표면최적화 연구도 이러한 체계를 활용하여 분류할 수 있다(Lee *et al.*, 2013).

이 논문은 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2015R1C1A1A01051952).

[†] 연락저자 : 이동희 교수, 04763 서울특별시 성동구 왕십리로 222 한양대학교 산업융합학부, Tel : 02-2220-2363, Fax : 02-2220-2363,

E-mail : dh@hanyang.ac.kr

2016년 12월 8일 접수; 2017년 4월 3일 수정본 접수; 2017년 4월 4일 게재 확정.

사후선호도정보반영법은 우수한 대안해(candidate solution)를 생성한 다음 의사결정자에게 이를 제공한다. 그리고 의사결정자가 이 가운데 가장 만족스러운 해를 선택할 수 있도록 지원한다. 의사결정자는 생성된 해를 비교 평가하는 과정에서 두 반응표면함수간의 상충관계를 이해할 수 있다. 이러한 장점으로 인해 최근 들어 다수의 사후 선호도 정보 반영법 기반의 쌍대반응표면최적화 연구가 이루어졌다(Koksoy and Donanaskoy 2003; Lee *et al.*, 2010; Lee and Kim, 2013; Seo *et al.*, 2016; Park and Lee, 2016).

사후선호도정보반영법의 장점을 극대화하기 위해서는 대안해를 균일한 간격으로 포괄적으로 생성하여 의사결정자에게 제공해야 한다. 이를 통해 의사결정자는 두 반응표면함수간의 상충관계를 충실히 이해할 수 있고 최종 해선택의 폭을 넓힐 수 있다. 대안 해 생성을 위한 가장 대표적인 방법은 Haimes *et al.* (1971)이 제안한 ϵ -제약법(ϵ -constraint method)이다. ϵ -제약법은 대안해에 해당하는 비지배해(non-dominated solution)를 생성하기 위한 기법으로 쉽고 직관적인 방법이며 nonconvex 최적화 문제에서도 비지배해를 생성한다는 장점이 있다. 하지만 생성된 해의 간격이 균일하지 않고 비지배해를 생성할 때마다 최적화 문제를 풀어야 하기 때문에 다수의 비지배해를 생성하는데 있어 계산 부담(computational burden)이 큰 단점이 있다(Jeong and Lee, 2016).

이에 본 연구는 기존의 ϵ -제약법에 기반한 쌍대반응표면최적화의 단점을 극복하고자 다목적 유전 알고리즘(multi-objective genetic algorithms)에 기반한 쌍대반응표면최적화 방법을 제안한다. 즉, 제안된 방법은 사후선호도정보반영법이며 해 생성 기법으로 다목적 유전 알고리즘을 사용한다. 다목적 유전 알고리즘은 개념과 이론이 단순하고 해의 탐색 성능 우수하며, 모형의 적용 유연성이 높아 제약의 첨가와 목적함수의 변경이 용이하다는 장점이 있다. 특히, 기존 ϵ -제약법의 단점인 비지배해 간의 간격이 균일하지 않은 점을 극복할 수 있다.

논문은 다음과 같이 구성된다. 제 2장에서는 다목적 유전 알고리즘과 기존 사후선호도정보반영법에 기반한 쌍대반응표면최적화 연구를 고찰한다. 제 3장에서는 제안된 방법을 설명한다. 제 4장과 제 5장에서는 사례를 통해 제안된 방법의 작동 원리 및 장점을 설명하고 제 6장에서 이에 대한 토의를 한다. 마지막으로 제 7장에서 결론 및 추후 연구이슈를 제안한다.

2. 기존 연구 고찰

2.1 다목적 유전 알고리즘

다목적 유전 알고리즘은 다수의 목적을 가진 최적화 문제에서 생물의 진화 과정을 모방하여 비지배해를 탐색하는 기법이다. 일반적으로 다목적 최적화 문제에서는 다수의 목적 함수들이 서로 상충하는 관계에 있기 때문에 이를 고려하여 최적해를 도출하는 것이 중요하다. 다목적 유전 알고리즘을 통해 도출

된 비지배해를 비교평가함으로써 목적 함수 간의 상충관계를 이해할 수 있으며, 궁극적으로 최적해를 효과적으로 도출할 수 있다. 이러한 장점으로 인해 다목적 유전 알고리즘은 공학, 자연과학, 경영학, 사회과학 등의 다목적 최적화 문제를 다루는 기법으로 각광받고 있다(Kim, 2011).

유전 알고리즘의 가장 큰 목적은 우수한 해를 다양하게 찾는 것이다. 이는 파레토 최적 해집단(Pareto optimal solution set)으로의 수렴성과 해의 균일한 분포를 나타내는 다양성을 의미한다. 이 두 가지 목적을 달성함으로써 의사결정자의 선택의 폭을 넓힐 수 있다. 다목적 유전 알고리즘은 모집단(population)을 운용하여 적합도(fitness)를 평가하고 선택(selection), 교차(crossover), 돌연변이(mutation) 연산을 하며 세대를 반복하는데 이 반복 과정을 통해 수렴성과 다양성이 개선된다.

유전 알고리즘의 기본 아이디어는 <Figure 1>과 같다. 먼저 초기 모집단을 무작위로 생성한 뒤, 모집단 내 모든 해들에 대하여 적합도를 평가한다. 적합도는 유전 알고리즘의 목적인 수렴성과 다양성을 유지하기 위해 목적함수의 값, 해들 간의 거리 등의 요소들을 이용하여 부여한다. 사전에 정의한 종료 조건을 검토하여 종료 조건을 만족하지 않으면 선택, 교차, 돌연변이 연산을 하여 새로운 세대를 구성한다.

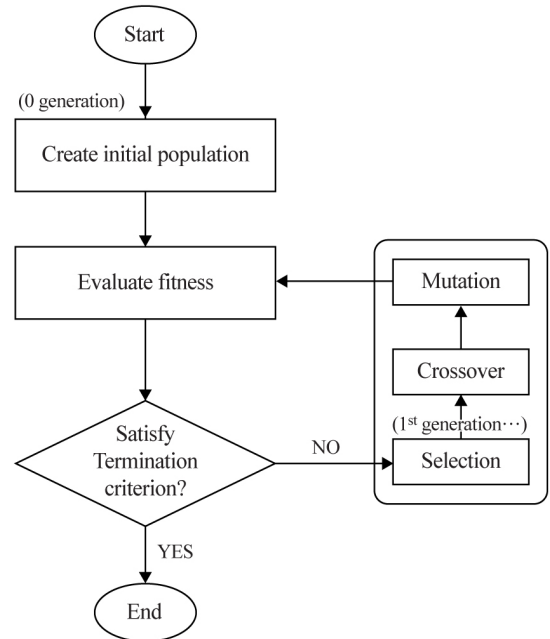


Figure 1. A Flowchart of the Working Principle of a Multiple Objective Genetic Algorithm

(1) Non-elitist 알고리즘

다목적 유전 알고리즘은 해당 세대에서 찾은 가장 우수한 해인 엘리트 해(elite solution)의 보존 여부에 따라 Non-elitist와 Elitist 유전 알고리즘으로 분류할 수 있다. Non-elitist 유전 알고리즘은 엘리트 해를 보존하지 않는 방식이다. 단일목적 유전 알고리즘에서 발전되어 단순한 형태의 진화전략만을 사용

한다. 알고리즘의 실행이 간단하고 비교적 복잡성이 낮은 장점이 있으나 우수한 해를 다음 세대로 보존하지 않기 때문에 수렴성과 다양성이 떨어진다는 단점이 있다(Deb, 2001). 대표적인 알고리즘은 아래와 같다.

1) Vector Evaluated Genetic Algorithm(VEGA)

VEGA는 Schaffer(1984)가 다목적 최적화 문제를 위해 처음 개발한 유전 알고리즘이다. 초기모집단을 목적함수의 개수만큼 하위모집단(subpopulations)으로 나눈다. 각 하위모집단에 하나의 목적함수를 할당해주고 이에 기반하여 적합도를 부과한다. 부여된 적합도를 기준으로 해 선택 및 유전 연산을 수행하여 종료 조건이 만족될 때까지 세대를 반복한다. VEGA는 실행 방법이 간단하기 때문에 비교적 계산 복잡도가 낮은 장점이 있다. 그러나 각 해들이 다른 목적함수들에 대해서는 평가되지 않기 때문에 다목적 유전 알고리즘의 맥락에서 중요한 다양성이 저해되는 단점이 있다(Deb, 2001).

2) Niche Genetic Algorithm(NPGA)

NPGA는 Horn *et al.*(1994)이 제시한 알고리즘으로 선택 과정에서 토너먼트 선택과 적소(niche) 개념을 사용하는 것이 가장 큰 특징이다. 초기 모집단에서 두 후보해와 비교해집합을 임의로 선택한다. 두 후보 해와 비교해집합을 토너먼트 방식으로 지배관계를 비교하여 다음 세대의 부모가 될 해를 결정하고 유전 연산을 통해 세대를 반복한다. 토너먼트 선택으로 우수한 후보해의 선정이 어려운 경우 적소 메커니즘을 이용한다. 적소 메커니즘은 두 후보해와 생성된 자손들 간의 거리 정보를 반영하여 밀집도가 낮은 해를 선택하는 방법이다. 따라서 NPGA는 좀 더 다양한 해를 찾을 수 있는 장점이 있으나 알고리즘 성능이 적소 파라미터 설정에 민감한 단점이 있다(Deb, 2001).

3) Non-dominated Sorting Genetic Algorithm(NSGA)

NSGA는 Srinivas and Deb(1994)이 제안한 방법으로 모집단 운용과 적합도 평가 방식에서 특징을 보인다. 초기 모집단에서 각 해들의 지배 관계에 따라 프런트(front)로 분류한다. 같은 프런트 내의 해들에는 동일한 임시적합도를 부여하고, 해들 간의 밀집도 정보를 반영해주는 뭉치기함수(sharing function)를 이용하여 각 해의 배분적합도(shared fitness)를 다시 부여해준다. 배분적합도를 기준으로 다음 세대의 부모를 선택하고 유전 연산을 수행한다. 종료 조건을 만족할 때까지 세대를 반복하여 우수한 해를 탐색한다. NSGA는 뭉치기함수를 이용하여 다양성을 보존할 수 있지만 밀집도를 계산하기 위한 적소 반경 파라미터 값 설정이 필요하다는 단점이 있다(Deb, 2001).

4) Predator-Prey Evolution Strategy(PPES)

PPES는 Laumanns *et al.*(1998)이 제안한 다목적 진화전략으

로 지금까지 나열된 방법들과 다른 새로운 형태의 알고리즘이다. 초기모집단의 해들을 정사각형 그리드에 임의로 배치한다. 포식자-먹이 모델을 적용하여 지배해(dominated solution)를 삭제하고 비지배해를 유전연산하여 새로운 해를 생성해 나간다. 종료 조건을 만족할 때까지 해당 과정을 반복하며 우수한 해를 탐색해 나간다. PPES는 모든 절차가 단순하고 복잡성이 낮다. 그러나 포식자가 랜덤하게 선택되는 특성으로 인해 최악의 해는 유지되면서 중간 해(intermediate solutions)만 제거될 가능성이 있어 다양성이 떨어진다는(Deb, 2001).

(2) Elitist 알고리즘

Elitist 유전 알고리즘은 엘리트 해를 보존하는 방식으로 보존 방식에 따라 다양한 알고리즘이 존재한다. 대표적인 알고리즘은 아래와 같다.

1) Elitist Non-Dominated Sorting Genetic Algorithm(NSGA-II)

NSGA의 높은 계산 복잡도, elitist 전략의 부재, 적소 파라미터 설정이 필요하다는 단점을 보완한 알고리즘으로 Deb (2000)이 제안하였다. NSGA-II는 초기 모집단인 부모 집단에 대한 적합도 평가 없이 유전 연산을 먼저 수행하여 자손 집단을 생성한다. 두 집단을 합하여 모든 해들에 대해 적합도를 평가한다. 적합도 값을 기준으로 모집단 크기만큼 해를 선택하여 다음 세대의 부모 집단을 구성한다. 종료 조건을 만족할 때까지 세대를 반복한다. 모집단의 해들을 지배 관계에 따라 프런트로 분류한 후 각 프런트 내의 해들에 동일한 적합도 값을 부과해준다. 모집단 크기 조정 시 같은 프런트 내의 해 중 일부를 선택해야 할 경우 밀집거리(crowding distance) 계산을 통해 다양성을 유지한다. 한 세대의 부모가 자손 생성과 다음 세대의 모집단 선택에 중복으로 참여하기 때문에 상대적으로 해공간(objective space) 탐색 능력이 떨어지지만 우수한 수렴성으로 인해 가장 널리 사용되고 있다(Kim, 2011).

2) Distance-Based Pareto Genetic Algorithm(DPGA)

Oszycza and Kundu(1995)에 의해서 제안된 알고리즘이며 초기 모집단의 첫 번째 해에 임시 적합도를 부과해주고 엘리트 집단에 포함시킨다. 이 후 모집단 내의 해들을 순서대로 비교하여 엘리트 집단과의 거리에 따라 적합도를 보정하고, 지배 관계에 따라 엘리트 집단에서 제거하거나 포함시킨다. 최종 엘리트 집단은 다음 세대로 선택되어 유지되며, 모집단에 유전연산을 수행하여 생성된 자손 집단을 결합하여 다음 세대의 부모 집단을 구성한다. 종료 조건이 만족될 때까지 해당 과정을 반복하여 최종 집단을 생성한다. DPGA는 유전 연산이 수행되는 부모 집단과 지금까지 찾은 모든 비지배해를 운용하는 특징을 갖는다. 적소 파라미터 사용 없이 다양성을 유지할 수 있으나 모집단 내의 해들 순서에 민감하다는 단점을 지닌다(Deb, 2001).

3) Strength Pareto Evolutionary Algorithm(SPEA)

Zitzler and Thiele(1998)에 의해 제안된 알고리즘이다. SPEA에서는 부모 집단의 모든 비지배해들을 외부 보관소(archive)에 복사한다. 외부 보관소의 크기가 모집단 크기를 초과하는 경우 클러스터링(clustering) 방식을 이용해 크기를 조정한다. 클러스터링 방식은 외부 보관소에 있는 모든 해들을 각각의 클러스터(cluster)로 만들고 클러스터 간의 거리 계산을 통해 클러스터의 개수를 모집단 크기만큼 줄여나간다. 하나 이상의 해를 포함한 클러스터에 대해서는 해들 간의 거리 계산을 통해 가장 중심에 있는 하나의 해만 남겨둔다. 모집단과 외부 보관소의 크기가 같아지면 모든 해들에 대한 지배해 수를 기준으로 적합도를 부여해준다. 적합도가 부여된 두 집단에 대하여 이진 토너먼트 방식으로 해들을 선택하고, 유전연산을 통해 다음 세대의 부모 집단을 구성한다. 종료 조건이 만족될 때까지 해당 과정을 반복한다. SPEA는 적합도 부여 절차와 클러스터링 파라미터 설정이 간단하다. 그러나 동일한 적합도를 가지는 해가 존재할 경우에는 우열을 가리기 어렵고 클러스터링 방법이 클러스터 중심에 있는 해를 선택하기 때문에 가장 멀리 위치한 극점해(extreme solution)를 제거하여 다양성을 떨어뜨릴 수 있다는 단점을 지닌다.

4) Strength Pareto Evolutionary Algorithm 2(SPEA2)

SPEA에서 해가 동일한 적합도를 갖는 단점을 개선하기 위해 Zitzler *et al.*(2001)가 제안하였다. SPEA2는 SPEA와 달리 보관소 크기를 일정하게 유지하며, 보관소에서 해 선택이 이루어진다. 또한 기존 적합도 부여 방식에 해들 간의 거리 정보를 추가로 반영하고, 절단(truncation) 방법을 이용하여 극점해들이 사라지지 않아 다양한 해 탐색을 가능하게 한다. 여러 연구에서 NSGA-II에 비해 해의 다양성 측면에서 약간 더 우수한 성능을 가졌다고 언급하고 있으며, 목적 수가 많은 문제에서 보다 좋은 성능을 보인 것으로 나타났다. 현재 NSGA-II와 함께 가장 널리 사용되고 있다(Kim, 2011).

2.2 쌍대반응표면최적화

본 절에서는 유전 알고리즘을 이용한 쌍대반응표면최적화 연구와 사후선호도정보반영법을 이용한 쌍대반응표면최적화 연구를 고찰한다. Arungradang and Kim(2013)은 인공신경망(artificial neural network)과 유전 알고리즘을 이용하여 공정의 평균과 산포를 동시에 최적화하는 방법을 제안하였다. 일반적인 쌍대반응표면최적화는 반응표면법에 기반하여 공정 평균과 산포를 독립적으로 모델링한다. 반면 Arungradang and Kim(2013) 인공신경망을 이용하여 공정변수와 공정평균 및 산포 간의 관계를 추정한다. 이후 유전 알고리즘을 이용하여 최적해를 도출한다. 이때 평균제곱오차(mean squared error; MSE)가 최소화되도록 최적해를 도출한다.

공정의 최적 조건을 도출하는 과정에서 유전 알고리즘을 적

용했다는 점에서 공통점을 지니지만 본 연구는 다수의 비지배해를 생성하고 의사결정자가 해를 선택하는 방식인 반면, Arungradang and Kim(2013) 평균제곱오차가 최소가 되는 단일 최적해를 도출하는 방식이다. 즉, 제안된 방법은 사후선호도정보반영법을 채택하고 있는 반면, Arungradang and Kim(2013)은 목적함수를 평균제곱오차로 사전에 정의하고 해를 도출한다는 점에서 사전선호도정보반영법을 채택하고 있다. 목적함수를 사전에 미리 정의할 수 있다면 Arungradang and Kim(2013)과 같은 방식이 효율적이다. 하지만 공정에 대한 사전지식이 없는 경우에는 목적함수를 정의하는 것이 어려운 일이다 (Lee *et al.*, 2010). 이때는 두 반응표면함수간의 상충관계를 파악하는 것이 중요하며 이 과정에서 사후선호도정보반영법을 활용하는 것이 효과적이다.

Lee *et al.*(2010)은 사후선호도정보반영법을 이용한 쌍대반응표면최적화를 제안하였다. ϵ -제약법을 활용하여 비지배해를 생성하고 이 가운데 의사결정자가 만족스러운 해를 선택하는 방식을 제안하였으며 사례 연구를 통해 의사결정자가 만족스러운 해를 찾을 수 있음을 보여주었다. Lee *et al.*(2010)의 연구를 기반으로 이후 다수의 쌍대반응표면최적화 사례 연구가 진행되었다. Lee and Kim(2013)은 반도체 메탈 배선 공정(metal process) 최적화 사례에서 Lee *et al.*(2010)의 방법을 도입하였다. Seo *et al.*(2016)과 Park and Lee(2016)는 반도체 평탄화 공정(Chemical and mechanical planarization process)에서 Lee *et al.*(2010)의 방법을 도입하였다.

위 방법들은 기본적으로 비지배해 생성을 위해 ϵ -제약법을 사용한다. Lee *et al.*(2010)의 방법은 충분히 많은 비지배해를 생성할 수 있을 때 장점을 가지는 방법이다. 하지만 ϵ -제약법을 활용하기 때문에 다수의 비지배해를 생성하는 과정에서 계산 부담(computational burden)이 클 수 있으며 생성된 비지배해 간의 간격이 균일하지 않을 수 있다(Jeong and Lee, 2016). 해를 균일하게 생성해야 의사결정자가 두 반응표면함수간의 상충관계를 충실히 이해하는데 도움이 되므로, 이를 만족시키는 것이 사후선호도반영법의 장점을 극대화하는데 중요하다.

한편, 쌍대반응표면최적화 문제에서 비지배해 생성을 위해 ϵ -제약법과 함께 가중합 방법(weighted sum method), 가중 메트릭 방법(weighted metric method), 목적 계획법(goal programming) 등이 활용 될 수 있다. 가중합 방법은 의사결정자가 설정한 가중치를 각 목적함수에 곱하고 이를 합하여 하나의 목적함수로 결합하여 최적화를 수행한다. 이와 유사한 방법으로 이상적인 해와 임의의 해에 대한 가중치 거리 값을 계산하여 목적함수 값을 최소화하는 가중 메트릭 방법(Miettinen, 1999)이 있다. 목표 계획법(Charnes *et al.*, 1955)은 각 목적 함수에 대해 목표값을 설정하고 목표값과의 차이가 최소화 되는 해를 찾는 것이다. 이러한 방법들은 가중치 벡터(weight vectors) 설정에 대한 어려움이나 nonconvex 문제에서 해를 생성하지 못하는 있는 단점 때문에 최근 선호되지 않는 접근법이다(Deb, 2011).

3. 제안된 방법

3.1 제안된 방법의 절차

제안된 방법은 크게 세 가지 단계로 구성된다. 단계 1에서는 실험 데이터를 수집하여 통계적 모델을 구축한다. 통계적 모델은 일반적으로 식 (1)과 같이 평균과 표준편차에 대해 2차 다항식으로 반응표면함수를 나타낸다. 식 (1)에서 x_1, \dots, x_k 는 k 개의 입력변수를, $\hat{\omega}_\mu(x)$ 와 $\hat{\omega}_\sigma(x)$ 는 평균과 표준편차의 반응표면함수 추정식을 의미한다.

$$\begin{aligned}\hat{\omega}_\mu(x) &= \hat{\beta}_0 + \sum_{i=1}^k \hat{\beta}_i x_i + \sum_{i=1}^k \hat{\beta}_{ii} x_i^2 + \sum_{i=1}^{k-1} \sum_{j>i} \hat{\beta}_{ij} x_i x_j, \\ \hat{\omega}_\sigma(x) &= \hat{\gamma}_0 + \sum_{i=1}^k \hat{\gamma}_i x_i + \sum_{i=1}^k \hat{\gamma}_{ii} x_i^2 + \sum_{i=1}^{k-1} \sum_{j>i} \hat{\gamma}_{ij} x_i x_j\end{aligned}\quad (1)$$

단계 2에서는 비지배해 생성을 위해 다목적 유전 알고리즘을 이용하여 <Figure 1>의 과정을 수행한다. 단계 3에서는 최종 모집단의 해들 중 의사결정자의 선호, 목적의 중요도, 비용 등을 고려하여 최적의 대안을 결정한다.

기존의 사후선호도정보반영법 연구에서는 단계 2의 비지배해 생성을 위해 ϵ -제약법을 사용했지만 본 연구에서는 다목적 유전 알고리즘을 사용한다. 다목적 유전 알고리즘은 모집단을 운용하기 때문에 다양한 비지배해를 효율적으로 생성할 수 있으며 생성된 해가 균일하게 분포한다는 장점이 있다.

3.2 다목적 유전 알고리즘을 이용한 비지배해 생성시 고려사항

다목적 유전 알고리즘을 이용하여 비지배해를 생성하는 과정에서는 다음과 같은 이슈가 존재한다. 우선 알고리즘 선택에 대한 이슈이다. 이를 위해 제 2장에서 살펴본 각 알고리즘들의 특성을 살펴보고 어떤 알고리즘이 쌍대반응표면최적화에 적절한지 아래와 같이 검토해보았다.

Non-elitist에서 VEGA는 단일 목적에 적합한 비지배해 분류를 수행하기 때문에 두 가지 목적을 지니는 쌍대반응표면최적화 문제에 적용 시 비효율적인 결과를 보일 수 있어 본 연구에서 제외했다. 다양성을 유지하는 연산자가 없는 PPES와 NSGA-II로 발전되어 그 성능이 떨어진다고 보고된 NSGA 또한 본 연구에서 제외했다(Kim, 2011). 따라서 Non-elitist에서는 두 개 이상의 목적 함수를 고려하며 적소 개념을 도입하는 NPGA를 본 연구에 적용했다

Elitist에서는 기존 연구들에서 다른 알고리즘에 비해 우수한 성능을 보인다고 보고되는 NSGA-II와 SPEA2를 본 연구에 적용했다(Kim, 2011; Deb, 2001). 두 알고리즘은 모든 목적 함수에 대응하는 적합도 부여 방식의 알고리즘이며, 수렴성과 다양성을 만족시키기 위해 해들 간의 거리 계산 또한 반영하는 방식의 알고리즘으로 본 연구의 취지인 비지배해의 균일성 개선에 부합한다.

두 번째는 유전 알고리즘 파라미터 설정에 대한 이슈이다. 유전 알고리즘은 모집단 크기, 세대 수, 교차율, 돌연변이율 등의 파라미터를 필요로 한다. 그러나 해결하고자 하는 문제에 적합한 파라미터를 결정하는 것은 쉽지 않다. 따라서 문제에 적합한 파라미터 조합을 찾기 위해 다양한 실험이 요구된다.

세 번째는 목적함수 설정에 대한 이슈이다. 다목적 유전 알고리즘에서 최적화 문제 중 최소화 문제에 대하여 더 좋은 성능을 보인다고 알려져 있다(Deb, 2001). 쌍대반응표면최적화에서 망소 특성을 가지는 $\hat{\omega}_\sigma$ 는 최소화되어야 하는 함수이나 $\hat{\omega}_\mu$ 는 망목(nominal the best) 혹은 망대(larger the better)특성인 경우가 존재한다. 따라서 본 연구에서는 이를 망소(smaller the better) 특성 함수로 변환하여 식 (2)와 같이 평균과 산포 모두 최소화시키는 최적화 문제로 풀이하였다. 이후 망소특성으로 변환된 두 함수를 각각 F_1 과 F_2 로 명명한다.

$$F_1 = \begin{cases} \hat{\omega}_\mu & \text{if } \hat{\omega}_\mu \text{ is smaller the better type} \\ |\hat{\omega}_\mu - T| & \text{if } \hat{\omega}_\mu \text{ is normal the best type} \\ -\hat{\omega}_\mu & \text{if } \hat{\omega}_\mu \text{ is larger the better type} \end{cases}\quad (2)$$

$$F_2 = \hat{\omega}_\sigma$$

3.3 평가 척도

이 절에서는 여러 다목적 유전 알고리즘 및 ϵ -제약법의 결과를 비교하기 위한 척도를 제시한다. 평가 척도는 도출된 비지배해에 대해 파레토 최적 집합으로의 수렴성과 다양성을 고려한다.

(1) 수렴성 척도

수렴성 척도는 Zitzler(1999)가 제시한 평가 척도인 $M1$ 을 이용하였다. $M1$ 은 파레토 최적 집합이 알려져 있는 경우 사용할 수 있으며, 이 값이 작을수록 생성된 비지배해들이 파레토 최적 집합으로 수렴함을 의미한다. 수식은 다음의 식 (3)과 같다. 여기서 u 는 구한 각 비지배해를 뜻한다. U 는 전체 비지배해 집합을 의미하고 $|U|$ 는 비지배해 집합의 원소 개수이다. y 는 각 파레토 최적해이고 Y_p 는 전체 파레토 최적 집합을 뜻한다.

$$M1 = \frac{1}{|U|} \sum_{u \in U} \min \{ \|u - y\| \mid y \in Y_p \}\quad (3)$$

$M1$ 은 각 비지배해에 대해 가장 가까운 파레토 최적해와의 유클리드 거리(Euclidean distance)를 평균 낸 것이다. 그러나 대부분의 쌍대반응표면최적화 문제에서는 파레토 최적 집합을 알지 못한다. 또한 유클리드 거리는 목적함수의 스케일(scale)이 다른 경우, 스케일이 큰 목적함수가 거리에 많은 영향을 미치게 된다. 이에 본 연구에서는 $M1$ 을 수정한 $M1'$ 을 식 (4)와 같이 제안하고, 이를 사례연구에 적용하였다. $M1'$ 은 각 세대에서 얻어진 비지배해 집합의 모든 원소 u 에 대해 이상점

(ideal point)까지의 정규화된 거리를 구한 뒤 이를 평균 낸다. 이상점은 F_1 과 F_2 를 축으로 구성된 이차원에서 하나의 점 (F_{1min}, F_{2min})으로 표현된다. 이상점과 정규화에 사용되는 $F_{1min}, F_{1max}, F_{2min}, F_{2max}$ 는 각각 두 함수 F_1 과 F_2 의 최소값과 최대값을 의미한다.

$$M\Delta' = \frac{1}{|U|} \sum_{u \in U} \left\{ \frac{F_1(u) - F_{1min}}{F_{1max} - F_{1min}} \right\} + \frac{1}{|U|} \sum_{u \in U} \left\{ \frac{F_2(u) - F_{2min}}{F_{2max} - F_{2min}} \right\} \quad (4)$$

(2) 다양성 척도

비지배해 집합의 다양성을 나타내는 평가 척도는 Deb(2001)이 제시한 식을 이용하였다. 본 연구에서 다양성은 생성된 비지배해 집합이 극점해(extreme solution)와 얼마나 가까운지를 의미하는 포괄성과 비지배해 간의 거리가 얼마나 균일한지를 의미하는 균일성으로 정의한다. Zitzler(1999)가 제시한 척도 중 다양성을 위한 평가 척도로 $M2, M3$ 가 있으나, 이는 사용자가 정의한 파라미터 값을 요구한다. 본 연구에서는 파라미터 설정 기준의 모호함을 최소화하고자 이를 사용하지 않는 Deb(2001)의 다양성 척도 Δ 를 이용하였다(Kim, 2011).

이를 평가하기 위한 척도로 식 (5)의 Δ 가 있다. m 은 목적함수의 개수를 의미하고 d_k^e 는 k 번째 목적함수에 대한 극점해와 가장 가까운 비지배해와의 유클리드 거리이다. 여기서 k 번째 목적함수에 대한 극점해는 k 번째 목적함수를 최소화 했을 때의 해이다. d_i 는 i 번째 비지배해와 이웃하는 ($i+1$)번째 비지배해 간의 유클리드 거리를 나타내고 \bar{d} 는 d_i 를 평균 낸 것이다.

$$\Delta = \frac{\sum_{k=1}^m d_k^e + \sum_{i=1}^{|U|-1} |d_i - \bar{d}|}{\sum_{k=1}^m d_k^e + (|U|-1)\bar{d}} \quad (5)$$

$$d_i = \|u_i - u_{i+1}\| \quad (6)$$

Δ 에서 목적함수간의 스케일 차이를 보정하기 위해 정규화된 거리를 활용하여 Δ 와 d_i 를 각각 식 (7)과 식 (8)의 Δ' 과 d_i' 로 수정하였다. 쌍대반응표면최적화 문제는 $m = 2$ 이며, 식 (7)과 식 (8)은 이를 반영하여 표현되었다. 식 (7)에서 d_μ^e 와 d_σ^e 는 각각 비지배해 집합에서 F_1, F_2 에 대한 극점해와 가장 가까운 비지배해와의 거리를 나타낸다. F_1^i 와 F_1^{i+1} 는 각각 F_1, F_2 의 i 번째 비지배해를 의미한다.

$$\Delta' = \frac{d_\mu^e + d_\sigma^e + \sum_{i=1}^{|U|-1} |d_i - \bar{d}|}{d_\mu^e + d_\sigma^e + (|u|-1)\bar{d}} \quad (7)$$

$$d_i' = \sqrt{\left(\frac{F_1^i - F_{1min}}{F_{1max} - F_{1min}} - \frac{F_1^{i+1} - F_{1min}}{F_{1max} - F_{1min}} \right)^2 + \left(\frac{F_2^i - F_{2min}}{F_{2max} - F_{2min}} - \frac{F_2^{i+1} - F_{2min}}{F_{2max} - F_{2min}} \right)^2} \quad (8)$$

비지배해 집합이 두 극점해를 포함하고(즉, $d_\mu^e = 0, d_\sigma^e = 0$ 이고), 비지배해 간의 간격이 균일하다면(즉, d_i 가 동일한 값을 가지면) $\Delta' = 0$ 으로 계산되어 포괄성과 균일성 측면에서 가장 이상적인 해가 된다.

4. 사례 1 : 프린팅 공정

프린팅 공정 사례는 Box and Draper(1987)가 제시한 문제로, 속도(x_1), 압력(x_2), 거리(x_3)의 입력변수를 최적화하여 인화 품질(y) 500의 달성과 산포 최소화를 목표로 하는 쌍대반응표면최적화 문제이다. 평균과 표준편차에 대한 반응 표면은 Vining and Myers(1990)가 모형화한 식 (9), 식 (10)을 사용하였다. $\hat{\omega}_\mu$ 는 망목 특성을 지니고 $\hat{\omega}_\sigma$ 는 망소 특성을 갖는다.

$$\hat{\omega}_\mu = 327.6 + 177.0x_1 + 109.4x_2 + 131.5x_3 + 32.0x_1^2 - 22.4x_2^2 - 29.1x_3^2 + 66.0x_1x_2 + 75.5x_1x_3 + 43.6x_2x_3, \quad (9)$$

$$\hat{\omega}_\sigma = 34.9 + 11.5x_1 + 15.3x_2 + 29.2x_3 + 4.2x_1^2 - 1.3x_2^2 + 16.8x_3^2 + 7.7x_1x_2 + 5.1x_1x_3 + 14.1x_2x_3 \quad (10)$$

4.1 비지배해 생성

유전 알고리즘을 이용한 비지배해 생성 시 목적함수를 망소 특성으로 변환하는 과정이 필요하다. $\hat{\omega}_\mu$ 는 망목 특성이므로 아래 식 (11)과 같이 망소 특성으로 변환하였다.

$$F_1 = |\hat{\omega}_\mu - 500| \quad (11)$$

$$F_2 = \hat{\omega}_\sigma$$

제 3.2절에서 언급한 바와 같이 Elitist에서는 NSGA-II, SPEA2와 Non-elitist에서는 NPGA를 선정하였다. 각 알고리즘은 <Table 1>과 같이 모집단 수와 교차율 간의 총 6가지 조합의 파라미터 설정을 적용하여 MATLAB 프로그램으로 연산을 수행하였다.

Table 1. Parameter Setting for the Gas

Case	Population	Crossover rate	Mutation rate
1	50	0	1
2	50	0.5	0.5
3	50	1	0
4	100	0	1
5	100	0.5	0.5
6	100	1	0

Arungpadang and Kim(2013)에서 100 이상의 모집단 수가 비지배해의 수렴성 및 다양성에 큰 영향을 미치지 않는다고 보고되었다. 이에 모집단 수를 50과 100으로 설정하였다. 유전 알

고리즘은 초기 모집단 생성, 유전 연산, 선택 등의 과정에서 난수(random number)를 발생시켜 진행하는 확률적인 알고리즘으로 실행마다 결과가 달라질 수 있다(Kim and Yum, 2010). 이를 고려하여 각 조합별로 10회 반복 실험하였다. 유전 연산에 따른 해의 변화를 살펴보고자 세대는 200으로 고정하고 교차율(crossover rate)과 돌연변이율(mutation rate)의 총 합이 1이 되도록 0, 0.5, 1로 설정하였다.


4.2 다목적 유전 알고리즘 비교평가

NPGA, NSGA-II, SPEA2를 통해서 생성한 비지배해들을 $M1'$ 과 Δ' 를 기준으로 비교하였다. <Table 2>에서 평균, 표준편차는 각 알고리즘을 200세대씩 10회 반복한 실험 결과로 얻은 $M1'$ 의 평균과 표준편차를 나타낸다. 표준편차가 작기 때문에 평균값을 기준으로 실험 결과를 비교하였으며, 그 결과 $M1'$ 은 SPEA2, NSGA-II, NPGA순으로 우수하게 나타났다. NPGA에서의 평균 $M1'$ 값이 가장 우수한 경우는 0.546으로 100모집단, 1.0교차율의 파라미터 값을 가진다. NSGA-II는 100모집단, 1.0교차율일 때 $M1'$ 의 평균이 0.479로 가장 우수하다. SPEA2는 $M1'$ 의 평균이 0.399로 50모집단, 1.0교차율 조합일 때 수렴성이 다른 알고리즘에 비해 가장 우수한 것으로 나타났다.


Table 2. Comparison of $M1'$ Value on Each Algorithm

Case		NPGA		NSGA-II		SPEA2	
		Mean	St.D	Mean	St.D	Mean	St.D
1	50-0	0.568	0.695	0.495	0.011	0.493	0.025
2	50-0.5	0.547	0.018	0.488	0.009	0.481	0.017
3	50-1	0.546	0.045	0.485	0.022	0.399	0.011
4	100-0	0.573	0.008	0.489	0.009	0.507	0.016
5	100-0.5	0.555	0.006	0.486	0.007	0.501	0.023
6	100-1	0.546	0.039	0.479	0.018	0.435	0.016


<Figure 2>는 각 알고리즘 별 가장 우수한 $M1'$ 값을 가지는 비지배해 집합을 $\hat{\omega}_\mu$ 과 $\hat{\omega}_\sigma$ 을 축으로 한 이차원 공간에 나타낸 것이다. 이상점은 F_1 과 F_2 의 최소값을 의미한다. F_1 의 최소값은 0이며, 이는 <Figure 2>에서의 가로축 $\hat{\omega}_\mu$ 에서 500에 해당한다. 세 알고리즘 모두 교차율이 1이고 돌연변이율이 0일 때 가장 좋은 성능을 보였으나, NPGA는 한 점으로 수렴하는 경향이 보였다. 또한 교차율이 1이 아닌 경우에도 NSGA-II, SPEA2에 비해 가장 좋지 않은 성능을 보였다. NSGA-II와 SPEA2의 경우 알고리즘 성능이 우수하기 때문에 돌연변이가 있는 경우 오히려 해의 수렴성을 떨어뜨리는 것으로 보여진다(Deb, 2001).




(a) 100 solutions from NPGA(Crossover rate is 1 and mutation rate is 0)



(b) 100 solutions from NSGA-II(Crossover rate is 1 and mutation rate is 0)



(c) 100 solutions from SPEA2(Crossover rate is 1 and mutation rate is 0)



(d) Comparing the solutions from GAs

Figure 2. Set of Non-Dominated Solutions with the Best $M1'$ Value on Each Algorithm

Table 3. Comparison of Δ' Value on Each Algorithm

Case		NPGA		NSGA-II		SPEA2	
		Mean	St.D	Mean	St.D	Mean	St.D
1	50-0	0.695	0.026	0.455	0.025	0.588	0.050
2	50-0.5	0.784	0.060	0.499	0.040	0.667	0.070
3	50-1	1.000	0.000	0.534	0.041	0.809	0.032
4	100-0	0.668	0.046	0.448	0.025	0.575	0.055
5	100-0.5	0.771	0.046	0.467	0.027	0.627	0.038
6	100-1	1.000	0.000	0.522	0.036	0.709	0.035

<Table 3>은 생성된 비지배해의 Δ' 값을 비교한다. 비지배해의 균일성과 포괄성을 나타내는 척도인 Δ' 는 NSGA-II, SPEA2, NPGA 순서로 좋은 결과를 보였다. 가장 우수한 NPGA의 평균 Δ' 값은 0.668로 100모집단, 0교차율에서 가장 우수했다. NSGA-II의 평균 Δ' 값은 0.448로 100모집단, 0교차율에서 가장 우수한 결과가 나왔다. SPEA2의 평균 Δ' 값은 0.575로 100모집단, 0교차율에서 가장 우수했다.

<Figure 3>은 각 알고리즘 별 가장 우수한 Δ' 값을 가지는 비지배해 집단을 그래프로 나타낸 결과이다. <Figure 3>에서 NPGA는 수렴성, 균일성 그리고 포괄성 측면에서 모두 다른 알고리즘들에 비해 좋지 않은 결과를 보인다. SPEA2와 NSGA-II


모두 교차율이 0이고 돌연변이율이 1인 경우 균일성과 포괄성이 가장 좋게 나타났는데, 이는 돌연변이가 탐사 능력을 강화하여 균일성과 포괄성이 우수한 결과가 나타난 것으로 보인다.

5. 사례 2 : 가스 메탈 아크 용접 공정


본 장에서는 Kim과 Rhee(2003)에서 소개한 non-convex 유형의 문제인 가스 메탈 아크 용접 공정 사례에 대해 제안된 방법을 통해 비지배해를 생성하였다. 문제의 목적은 공정의 투과길이 (penetration) (y)의 공정 평균 목표치인 3.7mm 달성과 산포를 최소화하기 위해 입력변수 와이어 이송 속도(x_1), 용접 속도(x_2)를 최적화하는 것이다. 투과길이의 평균과 표준 편차에 대한 반응 표면 실험은 5번 반복의 3^2 요인배치법을 수행하여 아래와 같이 모형화했다(Kim and Rhee, 2003). 예제 1과 같이 $\hat{\omega}_\mu$ 는 망목 특성을 지니고 $\hat{\omega}_\sigma$ 는 망소 특성을 갖는다.

$$\hat{\omega}_\mu = 3.0422 + 0.4967x_1 - 0.4367x_2 + 0.0567x_1^2 - 0.0033x_2^2, \quad (12)$$


$$\hat{\omega}_\sigma = 0.4813 + 0.1174x_1 + 0.0515x_2 - 0.1515x_1^2 + 0.0115x_2^2 + 0.0462x_1x_2 \quad (13)$$



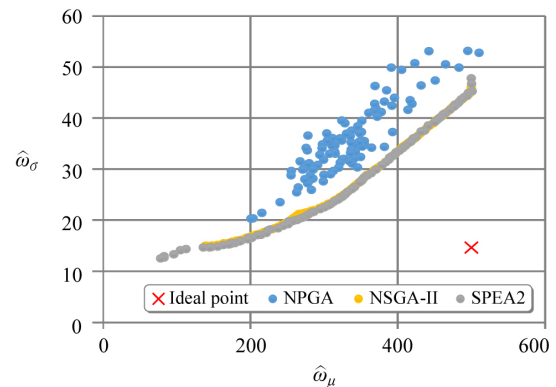
(a) 100 solutions from NPGA(Crossover rate is 0 and mutation rate is 1)



(b) 100 solutions from NSGA-II(Crossover rate is 0 and mutation rate is 1)



(c) 100 solutions from SPEA2(Crossover rate is 0 and mutation rate is 1)



(d) Comparing the solutions from GAs

Figure 3. Set of Non-Dominated Solutions with the Best Δ' Value on Each Algorithm

5.1 비지배해 생성

Printing process 예제와 마찬가지로 망목 특성의 목적함수를 망소 특성으로 변환하였다. NPGA, NSGA-II, SPEA2의 파라미터 설정은 <Table 1>을 적용하여 연산을 수행했다.

$$\begin{aligned} F_1 &= |\hat{\omega}_\mu - 3.7|, \\ F_2 &= \hat{\omega}_\sigma \end{aligned} \quad (14)$$

5.2 ϵ -제약법과 다목적 유전 알고리즘 비교평가

평가지표는 Printing process 예제에서 소개한 정규화된 $M1'$, Δ' 를 동일하게 사용하기로 한다. 제 4장의 예제 1에서 NPGA가 다른 두 알고리즘에 비해 수렴성, 균일성 그리고 포괄성 측면에서 모두 뒤떨어지는 성능을 보였기 때문에 본 예제에서는 제외하였다. 기존 비지배해 생성 방법인 ϵ -제약법은 non-convex에 적용이 가능하다고 보고된 바 있다(Lee et al., 2010). 따라서 본 장에서는 NSGA-II와 SPEA2, ϵ -제약법을 통해 생성된 비지배해들을 비교하였다.


<Table 4>에서 알고리즘 별 $M1'$ 은 SPEA2, NSGA-II, ϵ -제약법 순으로 우수하게 나타났다. ϵ -제약법의 경우 $M1'$ 이 0.600으

로 가장 좋은 결과를 보인 NSAG-II와 SPEA2에 비해 수렴성이 떨어지는 것으로 나타났다. $M1'$ 은 하나의 이상점과 생성된 비지배해집단과의 거리로 결정되기 때문에 이상점과 비교적 먼 비지배해들과의 거리로 인해 그 값이 커진 것으로 보인다. NSGA-II의 평균 $M1'$ 값은 0.596, SPEA2의 평균 $M1'$ 값은 0.571로 100모 집단에서 각 교차율이 0.5, 1일 때 가장 우수한 성능을 보였다.


<Figure 4>는 각 알고리즘 별 가장 우수한 $M1'$ 의 비지배해 집단을 그래프로 나타낸 결과이다. NSGA-II, SPEA2, ϵ -제약법의 경우 각각의 $M1'$ 이 0.596, 0.571, 0.600으로 값의 차이가 크지 않아 <Figure 4>에서의 비지배해 집단의 양상이 비슷한 것을 알 수 있다.

Table 4. Comparison of $M1'$ Value on Each Algorithm


Case	NSGA-II		SPEA2		ϵ -constraint	
	Mean	St.D	Mean	St.D		
1	50-0	0.633	0.033	0.579	0.010	0.600
2	50-0.5	0.619	0.020	0.574	0.007	
3	50-1	0.636	0.021	0.578	0.011	
4	100-0	0.612	0.020	0.578	0.005	0.600
5	100-0.5	0.596	0.010	0.574	0.005	
6	100-1	0.601	0.010	0.571	0.005	



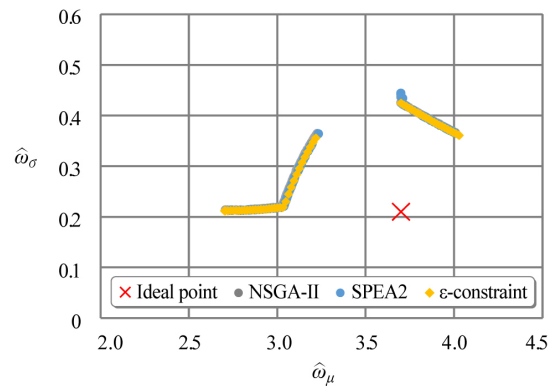
(a) 100 solutions from the ϵ -constraints method



(b) 100 solutions from NSGA-II(Crossover rate is 0.5 and mutation rate is 0.5)



(c) 50 solutions from SPEA2(Crossover rate is 1 and mutation rate is 0)



(d) Comparing the solutions from Gas and the ϵ -constraints method

Figure 4. Set of Non-Dominated Solutions with the Best $M1'$ Value on Each Algorithm

포괄성을 나타내는 척도인 Δ' 는 NSGA-II, SPEA2, ϵ -제약법 순서로 좋은 결과를 보였다. <Table 5>에 나타난 NSGA-II의 평균 Δ' 값은 0.474로 모집단이 100이고 교차율이 0.5일 때 가장 우수했다. SPEA2의 평균 Δ' 값은 0.644로 50모집단, 0교차율 조합에서 가장 우수했다. ϵ -제약법의 Δ' 는 0.890으로 다른 두 알고리즘보다 좋지 않은 결과가 나왔다. 균일성과 SPEA2는 제 4장의 예제 1과 마찬가지로 교차율이 0이고 돌연변이율이 1일 때 다양성이 가장 좋은 결과를 보였지만 NSGA-II의 경우 반대로 다양성이 가장 떨어지는 결과를 보였다.

ϵ -제약법의 경우 다른 유전 알고리즘들에 비해 Δ' 값이 확연히 좋지 않은 결과를 보였다. 이는 ϵ -제약법이 $\hat{\omega}_\mu$ 축을 기준으로 구간을 나누어 해를 생성하기 때문에 $\hat{\omega}_\sigma$ 축 기준의 해 간격을 고려하지 못하기 때문이다. <Figure 3>에서 $\hat{\omega}_\sigma$ 의 간격이 급격하게 커지는 현상이 x축의 3.0~3.5구간에서 나타나고 있음을 확인 할 수 있다. 이는 아래 ϵ -제약법의 원리를 살펴보면 알 수 있다.

Table 5. Comparison of Δ' Value on Each Algorithm

Case		NSGA-II		SPEA2		ϵ -constraint method	
		Mean	St.D	Mean	St.D	Mean	St.D
1	50-0	1.066	0.087	0.644	0.061	0.890	
2	50-0.5	0.489	0.051	0.670	0.049		
3	50-1	0.542	0.063	0.721	0.050		
4	100-0	1.138	0.086	0.654	0.045	0.890	
5	100-0.5	0.474	0.038	0.679	0.047		
6	100-1	0.529	0.049	0.711	0.036		

$$\begin{aligned} & \underset{x \in \Omega}{\text{Minimize}} && \hat{\omega}_\sigma(\mathbf{x}) \\ & \text{subject to} && |\hat{\omega}_\mu(\mathbf{x}) - 3.7| \leq \epsilon \end{aligned} \quad (15)$$

ϵ -제약법은 위 최적화 문제를 ϵ 값을 일정한 간격으로 증가시키면서 반복적으로 푼다. ϵ 값을 일정한 간격으로 증가시키기 때문에 $\hat{\omega}_\mu$ 축으로는 해간의 간격이 일정하다. 반면 $\hat{\omega}_\sigma$ 축으로는 해간의 간격이 일정하지 않다.

6. 토의

NPGA는 Non-Elitist 방식의 유전 알고리즘으로 좋은 해의 이용이 적어 다른 두 알고리즘에 비해 수렴성이 확연히 떨어진다. 부모 선택 시 이진 토너먼트 방식을 사용하여 중복 선택 가능성이 높아 수렴 속도 또한 느리다. 특히 유전 연산 중 해의 이용 정도를 강화하는 교차의 비율이 0이고 해의 탐사 정도를

강화하는 돌연변이의 비율이 1인 경우 해가 한점으로 수렴하는 경향을 보여 쌍대반응표면최적화 문제에 적용하기에 부적합한 것으로 보인다. 따라서 본 장에서는 유전 알고리즘의 목표인 수렴성과 다양성 측면에서 성능이 가장 우수하게 나타난 NSGA-II와 SPEA2에 대하여 분석하기로 한다.

수렴성 측면에서는 NSGA-II보다 SPEA2가 우수한 결과를 보였다. 이는 모집단의 프런트 간의 다양성(lateral diversity)과 프런트 내의 다양성(diversity along a front)이 모두 유지될 때 비로소 파레토 프런트로의 수렴성이 우수해질 수 있기 때문이다(Deb, 2001). 모집단 개수 조정 시 SPEA2는 전체 모집단 내에서의 거리를 기준으로 절단하는 방법을 사용하여 균일성과 포괄성을 유지한다. 반면 NSGA-II는 프런트를 기준으로 먼저 지배관계 분류 후 동일 프런트 내에서의 거리로 절단을 하기 때문에 첫 번째 프런트에 속한 해들이 살아남을 확률이 높아져 프런트 간의 다양성이 떨어진다. 또한 NSGA-II는 부모 선택 시 $(\mu + \lambda)$ -생존자 전략을 사용하는 등 SPEA2에 비해 더 강한 파레토 전략을 사용하여 오히려 프런트 간의 다양성이 떨어지는 결과를 보인다(Deb, 2001).

다양성 측면에서는 SPEA2보다 NSGA-II가 우수한 결과를 보였다. 이는 해들 간의 비지배 분류 방법의 차이에 따른 것으로 보인다. NSGA-II는 목적함수 기반의 적합도 할당을 통한 비지배 비교와 밀집거리 비교를 따로 수행하는 반면 SPEA2는 적합도 할당 시 비지배 강도 기반의 적합도에 밀집도를 더한 최종 적합도를 기준으로 밀집도의 영향력이 줄어들기 때문인 것으로 보인다.

파라미터 조합의 경우 두 알고리즘 모두 수렴성과 다양성에 대체로 비슷한 영향을 끼치는 것으로 보였다. 모집단 크기는 성능에 큰 영향을 주지 않는 것으로 보여진다. 하지만 두 알고리즘에서 공통적으로 교차율이 1이고 돌연변이율이 0인 경우 수렴성이 좋게 나타나고, 교차율이 0이고 돌연변이율이 1인 경우 다양성이 좋게 나타났다. 이는 교차가 해의 이용을 강화하고 돌연변이가 해의 탐사를 강화하는 특성이 그대로 나타난 결과이다(Kim, 2011). 따라서 의사결정자의 선호에 따라 다목적 유전 알고리즘의 두 목적적인 수렴성과 다양성 중 더 중요시 되는 요소를 고려하여 교차율과 돌연변이율을 설정을 해야 할 것으로 보인다.

7. 결론

본 논문에서는 쌍대반응표면최적화 문제에서 비지배해 생성 시 다목적 유전 알고리즘을 적용하여 유전 알고리즘 간의 비교와 기존 연구에서 사용된 ϵ -제약법과의 비교를 수행하였다. 예제 1의 $M1'$ 비교 결과는 SPEA2, NSGA-II, NPGA 순으로, Δ' 비교 결과는 NSGA-II, SPEA2, NPGA 순으로 좋게 나타났다. 예제 2의 $M1'$ 비교 결과는 SPEA2, NSGA-II, ϵ -제약법 순으로, Δ' 비교 결과는 NSGA-II, SPEA2, ϵ -제약법 순으로 좋게 나타났다. 두 예제 모두 수렴성 평가 척도인 $M1'$ 측면에서는

SPEA2가 가장 우수한 것으로 나타났고, 균일성과 포괄성 평가 척도인 Δ' 측면에서는 NSGA-II가 가장 우수한 것으로 나타났다.

후속 연구 과제로는 다중반응표면최적화(multi response surface optimization, MRSO) 문제로 확장하여 유전 알고리즘을 적용하는 것과 다목적 유전 알고리즘과 유사한 해 탐색 기법인 입자군집최적화(particle swarm optimization)를 이용하여 쌍대반응표면최적화 문제에 적용하여 그 결과를 본 논문과 비교해볼 수 있을 것으로 보여진다. 입자군집최적화는 새와 물고기들이 행하는 군집의 사회적 행동 양식을 바탕으로 해를 탐색한다. 이는 매우 간단한 개념으로 구성되어 있고 단순한 수학적 연산자들만을 필요로 하기 때문에 메모리 요구량이나 실행 속도 측면에서 효과적이다. 입자군집최적화는 유전 알고리즘과의 비교평가에서도 좋은 결과를 보여주었고, 특정 분야에서는 적용성이 훨씬 좋다고 알려져 있기 때문에(Park and Lee, 2011) 유전 알고리즘과 함께 MRSO 문제에 적용하는 연구가 진행될 수 있을 것이다.

본 연구에서는 공정 평균과 산포를 최소화하는 쌍대반응표면최적화에 다목적 유전 알고리즘을 적용하였다. 하지만 대부분의 현실 세계의 문제들은 다수의 목적을 지니고 있다. 따라서 추후 연구 과제에서는 본 연구에서 수행된 예제들을 다중반응표면최적화 문제로 확장하여 다목적 유전 알고리즘을 적용하고자 한다. 또한 본 연구에서 문제 특성에 따른 다목적 유전 알고리즘의 파라미터 설정 값을 정확하게 제시해줄 수 없다는 한계점이 존재한다. 이를 보완하기 위한 방법으로 유전 알고리즘과 유사한 해 탐색 기법인 다목적 입자 군집 최적화(multi objective particle swarm optimization)를 적용할 수 있을 것이다.

참고문헌

- Arungpadang, T. R. and Kim, Y. J. (2013), A Study on Dual Response Approach Combining Neural Network and Genetic Algorithm, *Journal of Korean Institute of Industrial Engineers*, **39**(5), 361-366.
- Byun, J. O. and Choi, Y. H. (2015), Stair Locomotion Method of Quadruped Robot Using Genetic Algorithm, *The Journal of The Korea Institute of Electronic Communication Sciences*, **10**(9), 1039-1047.
- Box, G. E. P. and Draper, N. R. (1987), *Empirical Model Building and Response Surfaces*, John Wiley & Sons, NY, United States.
- Charnes, A., Cooper, W., and Ferguson, R. (1955), Optimal estimation of executive compensation by linear programming, *Management Science*, **1**(2), 138-151.
- Deb, K., Agrawal, S., Pratap, A., and Meyarivan, T. (2000), A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization : NSGA-II, *Lecture Notes in Computer Science*, **1917**, 849-858.
- Deb, K. (2001), *Multi-objective optimization using evolutionary algorithms*, John Wiley & Sons, Chichester, England.
- Horn, J., Nafpliotis, N., and Goldberg, D. E. (1994), A niched Pareto genetic algorithm for multiobjective optimization, *IEEE*, **1**, 82-87.
- Jeong, J. H. and Ahn, C. W. (2016), An Automatic Rhythm and Melody Composition System Considering User Parameters and Chord Progression Based on a Genetic Algorithm, *Journal of KIISE*, **43**(2), 204-211.
- Jeong, I. and Lee, D. (2016), Generating Evenly Distributed Nondominated Solutions in Dual Response Surface Optimization, working paper.
- Kim, B. and Yum, B. (2010), Development of Virtual Metrology Models in Semiconductor Manufacturing Using Genetic Algorithm and Kernel Partial Least Squares Regression, *Journal of the Korean Institute of Industrial Engineers*, **23**(3), 229-238.
- Kim, D. and Rhee, S. (2003), Optimization of GMA welding process using the dual response approach, *International Journal of Production Research*, **41**(18), 4505-4516.
- Kim, Y. G. (2011), *Evolutionary algorithms*, Chonnam National University Press, Gwangju, Korea.
- Kim, W. W. (2012), A Multi-Objective Genetic Algorithm Using Sequential Surrogate Models, *Hanyang University Graduate School*.
- Laumanns, M., Rudolph, G., and Schwefel, H. P. (1998), A spatial predator-prey approach to multi-objective optimization : A preliminary study, *Lecture Notes in Computer Science*, **1498**, 241-249.
- Lee, D., Jeong, I., and Kim, K. (2010), A posterior preference articulation approach to dual response surface optimization, *IIE Transactions*, **42**(2), 161-171.
- Lee, D. and Kim, K. (2013), Determining the target value of ACICD to optimize the electrical characteristics of semiconductors using dual response surface optimization, *Applied Stochastic Models in Business and Industry*, **29**(4), 377-386.
- Lee, D., Kim, K., and Koksalan, M. A. (2011), posterior preference articulation approach to multiresponse surface optimization, *European Journal of Operational Research*, **210**(2), 301-309.
- Lee, D., Jeong, I., and Kim, K. (2013), Methods and Applications of Dual Response Surface Optimization : A Literature Review, *Journal of the Korean Institute of Industrial Engineers*, **39**(5), 342-350.
- Lee, S. M. (1972), *Goal Programming for Decision Analysis*, Auerbach Publishers, Philadelphia.
- Lee, S. Y. (2006), Multiobjective Optimization Using Simulated Annealing and Multiobjective Metrics, *Korea Advanced Institute of Science and Technology*.
- Lin, D. and Tu, W. (1995), Dual response surface optimization, *Journal of Quality Technology*, **27**(1) 34-39.
- Miettinen, K. (1999), *Nonlinear Multiobjective Optimization*, Kluwer, Boston.
- Oszycza, A. and Kundu, S. (1995), A new method to solve generalized multicriteria optimization problems using the simple genetic algorithm, *Structural optimization*, **10**(2), 94-99.
- Park, J. and Lee, D. (2016), Optimizing multiple response variables of chemical and mechanical planarization process for semiconductor fabrication using a clustering method, *International Journal of Industrial Engineering*, **23**(5), 283-293.
- Park, K. J. and Lee, C. S. (2011), Metric Information and Pareto Dominance Concept in Multi-Objective Particle Swarm Optimization Using a Supply Chain Model and a Known Function, *Journal of the Korean Society of Supply Chain Management*, **11**(2), 31-39.
- Schaffer, J. D. (1984), *Some Experiments in Machine Learning Using Vector Evaluated Genetic Algorithms*, Ph.D. Thesis, Vanderbilt University, TN, United States.
- Seo, J. H., Lee, D. H., Lee, K. C., Kim, K. J., and Kim, K. J. (2016), Optimizing a blend of a mixture slurry in chemical mechanical planarization for advanced semiconductor manufacturing using a posterior preference articulation approach to dual response surface

- optimization, *Applied Stochastic Models in Business and Industry*, **32**(5), 648-659.
- Srinivas, N. and Deb, K. (1994), Multi-objective function optimization using non-dominated sorting genetic algorithms, *Evolutionary Computation Journal*, **2**(3), 221-248.
- Veldhuizen, D. A. V. and Lamont, G. B. (2000), On measuring multi-objective evolutionary algorithm performance, *Evolutionary Computation*, **1**, 204-211.
- Vining, G. G. and Myers, R. H. (1990), Combining Taguchi and response surface philosophies : a dual response approach, *Journal of Quality Technology*, **22**(1), 38-45.
- Yum, B., Kim, S., Seo, S., Byun, J., and Lee, S. (2013), The Taguchi Robust Design Method : Current Status and Future Directions, *Journal of Korean Institute of Industrial Engineers*, **39**(5), 325-341.
- Zitzler, E. and Thiele, L. (1998), An evolutionary algorithm for multi-objective optimization : The strength Pareto approach, Technical Report 43, Zürich, Switzerland: Computer Engineering and Networks Laboratory(TIK), Swiss Federal Institute of Technology(ETH).
- Zitzler, E. (1999), Evolutionary Algorithms for Multiobjective Optimization : Methods and Applications, Ph. D. Thesis, Zürich, Switzerland. Swiss Federal Institute of Technology(ETH) (Dissertation ETH No. 13398).
- Zitzler, E. and Laumanns, M. (2001), SPEA2 : Improving the strength Pareto evolutionary algorithm. Eidgenössische Technische Hochschule Zurich(ETH), Institut für Technische Informatik und Kommunikationsnetze(TIK).