

## 다중반응표면 최적화에서 가중평균제곱오차 최소화법을 위한 선호도사후제시법

정인준\*

<sup>1</sup>대구대학교 경영학과

### A Posterior Preference Articulation Method to the Weighted Mean Squared Error Minimization Approach in Multi-Response Surface Optimization

In-Jun Jeong<sup>\*</sup>

<sup>1</sup>Department of Business Administration, Daegu University.

**요약** 다중반응표면 최적화는 다수의 반응변수(품질특성치)를 동시에 고려하여 최적의 입력변수 조건을 찾는 반응표면분석의 세부 분야이다. 가중평균제곱오차(Weighted Mean Squared Error, WMSE) 최소화법은 평균제곱오차의 두 구성 요소인 제곱편차와 분산에 가중치를 부여한 WMSE를 활용하는데, 반응변수별로 WMSE를 구하여 이들을 종합적으로 최소화한다. 지금까지 WMSE 최소화법과 관련하여 개발된 기법은 대부분 의사결정자의 선호도 정보를 문제풀이 이전에 결정할 것을 요구하는 선호도사전제시법에 해당된다. 그러나 현실적으로 의사결정자가 자신의 선호도 정보를 사전에 정확히 제공하는 것은 매우 어렵다. 본 논문에서는 이러한 한계점을 개선하기 위하여 WMSE 최소화를 위한 선호도사후제시법을 제안한다. 제안된 방법은 의사결정자의 선호도 정보 없이 다수의 비지배적해를 생성한 후, 의사결정자가 생성된 비지배해 중 최고선호해를 선택하는 단계로 진행된다. 제안된 방법은 의사결정자로 하여금 전체 해집합의 트레이드오프 관계를 보다 폭넓은 시각으로 이해한 후 선호도 정보를 제시할 수 있도록 함으로써, 의사결정자의 선호도에 부합하는 최고선호해를 효과적으로 도출할 수 있다.

**Abstract** Multi-Response Surface Optimization aims at finding the optimal setting of input variables considering multiple responses simultaneously. The Weighted Mean Squared Error (WMSE) minimization approach, which imposes a different weight on the two components of mean squared error, squared bias and variance, first obtains WMSE for each response and then minimizes all the WMSEs at once. Most of the methods proposed for the WMSE minimization approach to date are classified into the prior preference articulation approach, which requires that a decision maker (DM) provides his/her preference information a priori. However, it is quite difficult for the DM to provide such information in advance, because he/she cannot experience the relationships or conflicts among the responses. To overcome this limitation, this paper proposes a posterior preference articulation method to the WMSE minimization approach. The proposed method first generates all (or most) of the nondominated solutions without the DM's preference information. Then, the DM selects the best one from the set of nondominated solutions a posteriori. Its advantage is that it provides an opportunity for the DM to understand the tradeoffs in the entire set of nondominated solutions and effectively obtains the most preferred solution suitable for his/her preference structure.

**Keywords :** Multi-Response Surface Optimization, Weighted Mean Squared Error, Posterior Preference Articulation Approach

---

이 논문은 2013학년도 대구대학교 학술연구비 지원에 의한 논문임.

\*Corresponding Author : In-Jun Jeong (Daegu Univ.)

Tel: +82-53-850-6275 email: ijjeong@daegu.ac.kr

Received July 8, 2015

Revised August 10, 2015

Accepted October 8, 2015

Published October 31, 2015

## 1. 서론

반응표면분석(Response Surface Methodology)은 제품 · 공정설계 시 반응변수(품질특성치)와 이에 영향을 미치는 입력변수들 간의 관계를 모형화하고 최적화하는 품질공학의 대표적인 연구방법론이다[1]. 대부분의 반응표면분석 문제에서는 다수의 반응변수를 동시에 고려하여야 하는 경우가 흔히 존재하는데, 이와 같이 다수의 반응변수를 고려하는 반응표면분석 문제를 다중반응표면(Multi-Response Surface) 문제라고 부른다[2].

다중반응표면 문제는 크게 세 가지 단계를 거쳐 해법을 찾게 되는데, 데이터 수집(Data Collection), 모형화(Modeling), 그리고 최적화(Optimization)가 바로 그것이다. 본 논문은 여기서 최적화 단계에 초점을 맞추고 있다. 다중반응표면 최적화(Multi-Response Surface Optimization) 문제는 식 (1)과 같이 정의된다. 식 (1)에서  $\hat{y}_i(\mathbf{x})$ 는  $i$ 번째 반응함수의 추정식( $i=1, \dots, k$ ),  $\mathbf{x}$ 는 입력변수 벡터,  $\Omega$ 는 입력변수의 제약범위를 각각 나타낸다.

$$\begin{aligned} & \text{Optimize } [\hat{y}_1(\mathbf{x}), \hat{y}_2(\mathbf{x}), \dots, \hat{y}_k(\mathbf{x})] \\ & \text{s.t. } \mathbf{x} \in \Omega. \end{aligned} \quad (1)$$

다중반응표면 최적화 기법의 개발과 관련하여 지금까지 수많은 연구가 수행되었는데[3], 이 중 평균제곱오차(Mean Squared Error, MSE)를 최소화하는 연구가 최근 집중적으로 이루어지고 있다[4-7]. MSE 최소화 접근법은 각각의 반응변수별로 MSE를 구한 후, 이들을 다양한 기준으로 최소화한다. MSE는 제곱편차(Squared Bias)와 분산(Variance)으로 구성되는데, 최근에는 MSE의 두 요소에 가중치를 부여하는 가중평균제곱오차(Weighted MSE, WMSE) 최소화 접근법이 제안되었다[9, 10]. WMSE 최소화 접근법은 품질관리 목표나 스케일 보정 등을 위하여 제곱편차와 분산을 서로 다른 비중으로 고려할 수 있다는 장점이 있다.

WMSE 최소화 접근법의 구체적인 기법 개발에 관한 연구로는 가중합(Weighted Sum) 기반법[9]과 Tchebycheff Metric 기반법[10]이 있다. 가중합 기반법은 개별 반응변수에 대한 WMSE의 가중합을 최소화하는 것을 목표로 한다. Tchebycheff Metric 기반법은 개별 WMSE가 각각의 이상치로부터 떨어진 가중거리가

가장 큰 것을 최소화하는 것을 목표로 한다. 이 방법은 가중합 기반법의 한계점, 즉 WMSE들이 구성하는 목적함수 공간(Objective Space)에서 볼록하지 않은(Nonconvex) 구간을 탐색하지 못한다는 점을 보완한 방법이다.

이상의 WMSE 최소화 기법은 의사결정자의 선호도 정보(Preference Information)를 필요로 하는데, 가중합 기반법에서는 개별 WMSE에 대하여 부여되는 ‘가중치’, Tchebycheff Metric 기반법에서는 개별 WMSE가 각각의 이상치로부터 떨어진 거리에 대한 ‘가중치’가 바로 선호도 정보—정확히는, 선호도 정보가 전달되는 매개변수(Preference Parameter)—에 해당된다. 이들 기법은 의사결정자의 선호도 정보를 문제를 풀기 전에 사전에 주어져 있다는 것을 가정하고 있다. 즉, 다목적 최적화(Multi-Objective Optimization) 분야의 기법 분류에 따르면 선호도사전제시법(Prior Preference Articulation Approach)에 해당된다. 그러나 의사결정자가 최적화 과정 전에 WMSE 간의 상호관계를 이해하고, 이들 간의 트레이드오프에 대한 선호도 정보를 정확히 제시하는 것은 현실적으로 매우 어렵다. 이에 본 논문에서는 의사결정자의 선호도 정보를 정확히 반영하기 위하여 WMSE 최소화 접근법에 대한 선호도사후제시법(Posterior Preference Articulation Approach)을 제안하고자 한다.

본 논문은 다음과 같이 구성되어 있다. 2장에서는 WMSE 최소화 접근법 및 다목적 최적화 기법에 관한 기존 문헌을 고찰한다. 3장에서는 WMSE 최소화를 위한 선호도사후제시법을 제안한다. 4장에서는 제안된 방법을 활용하여 대표적인 다중반응표면 문제를 풀어보고, 기존 가중합 기반 WMSE 최소화법 및 Tchebycheff Metric 기반법과 비교한다. 마지막으로, 결론을 5장에서 제시한다.

## 2. 기존문헌 고찰

### 2.1 WMSE 최소화 접근법

WMSE 최소화 접근법은 우선 개별 반응변수에 대하여  $WMSE_i$ 를 구성하는 것으로 시작한다. 반응변수가 망목특성(Nominal-The-Best)을 띄는 경우,  $WMSE_i$ 는 식 (2)와 같이 정의된다.

$$WMSE_i = \lambda_i (\hat{\mu}_i(\mathbf{x}) - T_i)^2 + (1 - \lambda_i) (\hat{\sigma}_i(\mathbf{x}))^2. \quad (2)$$

식 (2)에서  $\hat{\mu}_i(\mathbf{x})$ 와  $\hat{\sigma}_i(\mathbf{x})$ 는 반응변수의 평균과 표준편차 모형의 추정식을,  $T_i$ 는 반응변수의 목표수준을 각각 나타낸다. 여기서  $(\hat{\mu}_i(\mathbf{x}) - T_i)^2$ 은 제곱편차,  $(\hat{\sigma}_i(\mathbf{x}))^2$ 은 분산을 각각 의미한다. 식 (2)에서  $\lambda_i$ 와  $(1 - \lambda_i)$ 는 제곱편차와 분산에 부여되는 가중치를 각각 나타낸다( $0 \leq \lambda_i \leq 1$ ). 참고로, 반응변수가 망소특성(Smaller-The-Better) 및 망대특성(Larger-The-Better)을 띄는 경우의  $WMSE_i$  정의는 [9]에 제시되어 있다.

개별  $WMSE_i$ 를 구성할 때 필요한 것 중 하나는  $\lambda_i$ 의 결정이다. 지금까지 제안된 가중치  $\lambda_i$  결정 기법으로, 데이터 기반법(Data-Driven Method), 선호도 기반법(Preference-Based Method), 대화식 결정법(Interactive Weighting Method) 등이 있다[11-14].

개별  $WMSE_i$ 가 정의되면,  $WMSE_i$ 들을 어느 기준, 즉 목적함수(Objective Function)에 따라 최소화한다(식 (3)).

$$\begin{aligned} & \text{Minimize } [WMSE_1, WMSE_2, \dots, WMSE_k] \\ & \text{s.t. } \mathbf{x} \in \Omega. \end{aligned} \quad (3)$$

식 (3)에서 어떠한 목적함수를 두느냐에 대하여 몇 가지 연구가 최근 수행되었다. [9]는 목적함수로  $WMSE_i$ 들의 가중합(Weighted Sum)을 제안하였다(식 (4)). 식 (4)에서  $w_i$ 는  $WMSE_i$ 에 대한 가중치를 나타낸다.

$$\begin{aligned} & \text{Minimize } \sum_{i=1}^k w_i WMSE_i \\ & \text{s.t. } \mathbf{x} \in \Omega. \end{aligned} \quad (4)$$

가중합 기반법은  $WMSE_i$ 들이 구성하는 목적함수 공간에서 블록하지 않은 구간을 탐색하지 못한다는 단점을 지니고 있다. [10]은 이러한 단점을 보완하기 위하여 목적함수로 Tchebycheff Metric을 사용할 것을 제안하였다(식 (5)).

$$\begin{aligned} & \text{Min } \alpha \\ & \text{s.t. } \alpha \geq w_i (WMSE_i - WMSE_i^0), \\ & \quad \quad \quad i = 1, \dots, k, \\ & \quad \quad \quad \sum_{i=1}^k w_i = 1, \\ & \quad \quad \quad \mathbf{x} \in \Omega. \end{aligned} \quad (5)$$

식 (5)에서  $WMSE_i^0$ 는  $WMSE_i$ 의 이상치를,  $w_i$ 는  $WMSE_i$ 와  $WMSE_i^0$  간의 거리에 대한 가중치를 의미하고,  $\alpha$ 는  $w_i(WMSE_i - WMSE_i^0)$ 들 중 최대치를 나타낸다. 식 (5)은 각각의  $WMSE_i$ 가 이상치인  $WMSE_i^0$ 로부터 떨어진 (가중)거리의 최대치를 최소화하는 것이 목적이다. 참고로, 식 (5)는 약한 비지배해(Weakly Nondominated Solution)를 도출할 수 있는데, 이러한 가능성을 없앤 방법으로 Augmented Tchebycheff Metric과 Lexicographic Tchebycheff Metric이 있다[15]. Tchebycheff Metric 기반법은 가중합 기반법과 달리 블록하지 않은 목적함수 공간을 놓치지 않고 해를 찾아낼 수 있다.

## 2.2 다목적 최적화 기법

다목적 최적화 분야 분야에서는 의사결정자의 선호도가 제시되는 시점에 따라 다목적 최적화 기법을 선호도 사전제시법, 선호도대화식제시법(Interactive Preference Articulation Approach), 선호도사후제시법으로 구분한다[15, 16]. 선호도사전제시법은 의사결정자의 선호도 정보를 최적화 과정 전에 모형에 반영하여 해를 구한다. 선호도대화식제시법은 의사결정자가 최적화 과정 동안 중간결과를 검토하여 선호도 정보를 단계적으로 제시하는 방식을 취하고 있다. 선호도사후제시법은 다수의 효율적 해집합(혹은 파레토 해집합)을 도출한 후, 이로부터 의사결정자가 가장 선호하는 해를 ‘선택’하는 과정으로 구성된다.

선호도사전제시법은 의사결정자가 개념적으로 이해하기 쉽고, 최적화 과정이 단 한번만 진행되므로 간단하다는 장점이 있다. 이 접근법은 의사결정자의 선호도 정보가 사전에 정확히 파악되어 있어야 올바르게 작동한다. 그러나 현실적으로 의사결정자의 선호도 정보를 사전에 정확하게 제공하는 것은 매우 어렵다. 왜냐하면 (상충되는) 목적식에 대하여 자신의 선호도 정보를 수리적인 형태로 정확하게 표현하는 것은 현실적으로 불가능하기 때문이다.

선호도대화식제시법은 선호도 정보를 정확히 반영할 수 있어 만족스러운 절충해를 도출하는데 효과적이거나, 의사결정자가 매 단계에서 하나의 해만을 접할 수 있기 때문에 전체 해집합(Efficient Frontier)에서 나타나는 트레이드오프 관계를 이해하지 못한 채 선호도 정보를 제시할 수밖에 없고, 정해진 반복단계 횟수 내에서 만족스러운 절충해의 도출을 보장을 할 수 없다는 단점이 있다.

반면, 선호도사후제시법은 의사결정자가 전체 해집합의 트레이드오프 관계를 보다 폭넓은 시각으로 이해하여 선호도 정보를 제시할 수 있고, ‘선택’이라는 의사결정 절차를 통하여 비교적 제한된 횟수 내에서 만족스러운 절충해를 도출할 수 있어 선호도대화식제시법의 단점을 해결할 수 있다. 참고로, 선호도사후제시법은 많은 해를 한 번에 도출해야 하기 때문에 계산시간이 오래 걸리는 등 계산상의 부담이 있지만, 최근 컴퓨팅 파워의 대폭적인 향상에 힘입어 이러한 문제점도 해결되어 가는 추세이다.

WMSE 최소화 접근법과 관련하여 지금까지 제안된 기법들, 즉 가중합 기반법, Tchebycheff 기반법은 다목적 최적화 기법 구분 관점에서는 선호도사전제시법에 해당된다. 이들 기법은 의사결정자의 선호도 정보를 문제풀이 이전에 결정할 것을 요구한다. 가중합 기반법과 Tchebycheff 기반법의 가중치, 즉 식 (4)-(5)의  $w_i$ 들이 의사결정자의 선호도 정보에 해당된다. 그러나 앞서 언급한 바와 같이 의사결정자의 선호도 정보를 문제풀이 이전에 정확히 제시하는 것은 현실적으로 매우 어렵다.

### 3. 제안된 방법: 가중평균제공오차 최소화를 위한 선호도사후제시법

#### 3.1 개요

본 논문에서는 WMSE 최소화 접근법에서 의사결정자의 선호도 정보를 효과적으로 반영하기 위해서 선호도사후제시법을 제안하고자 한다. 제안된 방법은 일반적인 선호도사후제시법의 절차를 따른다. 즉, 비지배적해의 생성(Generation of Nondominated Solutions) 단계와 생성된 비지배해 중 최고선호해의 선택(Selection of the Most Preferred Solution) 단계로 구성된다. 선택 단계는 문제에서 고려되는 반응변수의 개수, 즉  $k$ 의 값에 따라 다른 전략으로 진행된다. 즉,  $k=2$ 이면 ‘구간 선택 전략(Interval Selection Strategy)’으로,  $k \geq 3$ 이면 ‘셀 선택 전략(Cell Selection Strategy)’으로 진행된다. 3.3절에서  $k$ 의 개수에 따른 선택 전략을 자세히 설명한다.

#### 3.2 절차

제안된 방법은 앞서 언급한 바와 같이 비지배적해의 생성 단계(단계 1)와 최고선호해의 선택 단계(단계 2)로

구성된다. 각 단계에 대한 상세한 설명은 다음에 기술되어 있다.

#### 3.2.1 단계 1: 비지배적해의 생성

단계 1은 입력변수의 제약조건을 고려하여  $WMSE_i$  목적함수 공간에서 다수의 비지배적해를 생성한다.  $WMSE_i$ 들은 모두 작을수록 좋은 망소특성을 띄는 변수이다. 이에 따라  $WMSE_i$  목적함수 공간에서의 비지배적해는 다음과 같이 정의된다. 입력변수의 해  $x^*$ 에 대하여  $WMSE_i(x) \leq WMSE_i(x^*)$ 를 만족시키고( $i=1, \dots, k$ ) 이들  $k$ 개의 부등식 중 하나는 엄격한 부등관계(Strict Inequality)를 만족시킬 경우  $x^*$ 를 비지배적해라고 한다. 즉,  $WMSE_i$  목적함수 공간에서  $x^*$ 로부터 도출된  $WMSE_i(x^*)$ 들 보다 우수한 결과를 만들어내는 다른 해( $x$ )가 존재하지 않으면  $x^*$ 가 비지배적해가 됨을 의미한다. 여기서  $x^*$ 는 파레토 최적해(Pareto Optimal Solution)라고도 부른다.

단계 1은 단계 2에서의 최고선호해 선택을 위해 충분히 많은 수의 비지배적해를 생성하여야 한다. 이 때 특별히 고려해야 하는 사항으로 목적함수 공간에서 볼록하지 않은(Nonconvex) 구간에서도 비지배적해를 생성할 수 있어야 한다. 다목적 최적화 분야에서 비지배적해를 생성하는 방법으로 Weighting 방법,  $\epsilon$ -Constraint 방법, Achievement Scalarizing Function 방법 등이 제안되었는데[15-18], 본 논문에서는 간단하면서도 Nonconvex 구간에서 비지배적해를 생성할 수 있는  $\epsilon$ -Constraint 방법[19]을 채택한다.

$\epsilon$ -Constraint 방법은 여러  $WMSE_i$ 들 중 하나(가령,  $WMSE_j$ )를 목적식으로 두고, 나머지  $WMSE_i$ 들을 제약식에 두는 최적화 모형을 우선 수립한다(식 (6)).

$$\begin{aligned} \text{Min } & WMSE_j \\ \text{s.t. } & WMSE_i \leq \epsilon_i, i = 1, \dots, k (i \neq j), \\ & x \in \Omega. \end{aligned} \tag{6}$$

식 (6)에서  $\epsilon_i$ 는  $WMSE_i$ 의 상한값을 나타내는 파라미터이다.  $\epsilon$ -Constraint 방법은 식 (6)에서  $\epsilon_i$ 들의 값을 단계적으로 변화시키면서, 즉 최소값에서 최대값으로 증가시키면서 (또는 최대값에서 최소값으로 감소시키면서) 최적화 모형을 풀어 많은 수의 비지배적해를 생성한다. 파라미터  $\epsilon_i$ 의 최소값과 최대값은 입력변수의 제약범위

**Table 1.** Dependent and Independent Variables of the Illustrative Example

| Variable Type        | Code  | Descriptions                        | Improvement Direction | Target Value |
|----------------------|-------|-------------------------------------|-----------------------|--------------|
| Dependent Variable   | $y_1$ | Non-linearity                       | Nominal-The-Best      | 1            |
|                      | $y_2$ | Hysteresis                          | Smaller-The-Better    | -            |
| Independent Variable | $x_1$ | Lozenge angle                       | -                     | -            |
|                      | $x_2$ | Bore diameter                       | -                     | -            |
|                      | $x_3$ | Half-length of the vertical segment | -                     | -            |

내에서 개별  $WMSE_i$ 를 최소화 또는 최대화하여 구한다. 그리고  $\epsilon_i$ 들의 증분값 (또는 감분값)은 생성해야 할 비지배적해의 수와  $\epsilon_i$ 의 최소값 및 최대값을 고려하여 결정한다.

**3.2.2 단계 2: 최고선호해의 선택**

단계 2는 의사결정자가 단계 1에서 생성된 비지배적해 중 최고선호해를 선택하는 단계이다. 단계 1에서 생성되는 비지배적해는 적게는 수십 개에서 많게는 수천 개에 달한다. 많은 수의 비지배적해를 동시에 비교·평가하여 한 번에 최고선호해를 고르는 것은 매우 어렵다. 의사결정자의 선택 과정을 지원하는 효과적인 방법은 최고선호해가 포함되어 있을 영역을 단계적으로 줄여가는 것이다. 이와 관련한 구체적인 기법으로, 구간 선택 전략 [20]과 셀 선택 전략[21]이 최근에 제안되었다. 본 논문에서는 이 두 전략을 문제 상황에 맞게 수정·활용하고자 한다.

구간 선택 전략은  $k=2$ 일 때 적용할 수 있는 전략으로, 비지배적해를 일정한 길이의 대안구간(Alternative Interval)으로 나누고 이 중 최고선호해가 있을 구간을 고르는 과정을 반복하는 방식으로 진행된다. 이와 같은 반복 과정은 대안구간이 충분히 좁다고 판단될 때, 즉 대안구간 길이가 임계수준보다 작을 때 멈춘다. 여기서 대안구간의 개수와 대안구간 길이의 임계수준은 사전에 정해져야 한다. 반복 과정이 종료되면 마지막에 선택된 대안구간 내에서 최고선호해를 선택하게 된다. 참고로, 대안구간 및 최고선호해를 선택할 때에는 WMSE와 함께 제곱편차 및 분산, 더 나아가 평균 및 표준편차도 고려해야 한다.

셀 선택 전략은  $k \geq 3$ 일 때 적용하는 전략이다. 이 전략은 2차원 평면 상에서만 작동되는 구간 선택 전략을 3차원 공간 이상으로 확대한 것이다. 이를 위하여 구간 대신 공간의 개념을 도입한다. 이 전략은 구간 선택 전략의 진행 방식과 마찬가지로, 비지배적해를 일정한 크기의

대안공간 즉, 셀로 나누고, 이 중 최고선호해가 있을 셀을 고르는 과정을 반복한다. 셀을 선택하는 과정은 의사결정자의 선호도가 낮은 셀을 쌍대비교를 통해 제거해 나가는 방식으로 진행된다[22]. 최종적으로는 제거된 셀에 포함되지 않은 비지배적해를 쌍대비교하여 최고선호해를 도출한다. 구간 선택 전략과 마찬가지로, 선호도가 낮은 셀을 제거하거나 최고선호해를 선택할 때에는 WMSE, 제곱편차 및 분산, 평균 및 표준편차 등을 동시에 고려해야 한다.

**4. 하중변환기 탄성요소 설계 문제를 통한 예증**

본 장에서는 "하중변환기의 탄성요소 설계(Design of the Elastic Element of a Force Transducer)" 문제[23]를 통하여 제안된 선호도사후제시법을 예증하고, 기존에 제안된 WMSE 최소화 기법들, 즉 가중합 기법, Tchebycheff Metric 기법과 비교하고자 한다.

**4.1 문제 설명**

이 문제는 하중변환기의 정확성(반응변수)을 개선하기 위한 최적의 탄성요소(입력변수) 수준을 찾는 것이 목표이다. 이 문제는 반응변수는 2개, 입력변수는 3개로 구성되어 있다. 각각의 변수에 대한 설명은 Table 1과 같다. 이들 변수들을 가지고 중심복합설계의 실험계획이 수립되었고, 총 25회의 실험이 실시되었다. 반응변수  $y_1, y_2$ 의 평균, 표준편차 모형은 실험 데이터를 활용하여 식 (7)-(10)과 같이 도출되었다. 이들 평균, 표준편차 모형이 도출되는 과정은 [5, 23]에 자세히 제시되어 있다.

$$\hat{\mu}_1(\mathbf{x}) = 1.38 - 0.361x_1 - 0.155x_2 + 0.0771x_3 - 0.148x_1x_2 + 0.0218x_1x_3 + 0.0130x_2x_3 + 0.0481x_1^2, \tag{7}$$

**Table 2.** Results of the Proposed Method for the Illustrative Example

| Round 1                    | Round 2                    | $\mathbf{x}^* = (x_1^*, x_2^*, x_3^*)$ | $(\hat{\mu}_1, \hat{\sigma}_1)$ | $(\hat{\mu}_2, \hat{\sigma}_2)$ | $WMSE_1^*$    | $WMSE_2^*$    | $U^*$         |
|----------------------------|----------------------------|--|---------------------------------|---------------------------------|---------------|---------------|---------------|
| AI* 1                      | -                          | (0.8046, -0.1366, -1.6820)             | (1.7471, 0.0641)                | (2.4912, 0.1676)                | 0.0009        | 0.4605        | 0.0000        |
|                            |                            | ⋮                                      | ⋮                               | ⋮                               | ⋮             | ⋮             | ⋮             |
|                            |                            | (0.3637, -0.9252, -1.6820)             | (1.7471, 0.0641)                | (1.5748, 0.1576)                | 0.0742        | 0.1967        | 0.0002        |
| AI 2                       | -                          | (0.3668, -0.9649, -1.6820)             | (1.7471, 0.0641)                | (1.5528, 0.1576)                | 0.0780        | 0.1919        | 0.0002        |
|                            |                            | ⋮                                      | ⋮                               | ⋮                               | ⋮             | ⋮             | ⋮             |
|                            |                            | (0.4084, -1.5619, -1.6820)             | (1.7471, 0.0641)                | (1.2066, 0.1583)                | 0.1513        | 0.1252        | 0.0015        |
| AI 3                       | AI 3.1                     | (0.4099, -1.5878, -1.6820)             | (1.7471, 0.0641)                | (1.1911, 0.1583)                | 0.1552        | 0.1226        | 0.0017        |
|                            |                            | (0.4115, -1.6133, -1.6820)             | (1.7471, 0.0641)                | (1.1757, 0.1583)                | 0.1590        | 0.1201        | 0.0021        |
|                            |                            | (0.4129, -1.6384, -1.6820)             | (1.7471, 0.0641)                | (1.1605, 0.1584)                | 0.1629        | 0.1176        | 0.0027        |
|                            |                            | (0.4144, -1.6632, -1.6820)             | (1.7471, 0.0641)                | (1.1455, 0.1584)                | 0.1667        | 0.1152        | 0.0036        |
|                            | AI 3.2                     | (0.4035, -1.6820, -1.6820)             | (1.7471, 0.0641)                | (1.1311, 0.1582)                | 0.1706        | 0.1128        | 0.0053        |
|                            |                            | (0.3538, -1.6820, -1.6820)             | (1.7471, 0.0641)                | (1.1192, 0.1574)                | 0.1744        | 0.1107        | 0.0086        |
|                            |                            | (0.3066, -1.6820, -1.6820)             | (1.7471, 0.0641)                | (1.1088, 0.1568)                | 0.1783        | 0.1089        | 0.0190        |
|                            |                            | <b>(0.2616, -1.6820, -1.6820)</b>      | <b>(1.7471, 0.0641)</b>         | <b>(1.0997, 0.1563)</b>         | <b>0.1821</b> | <b>0.1074</b> | <b>0.5624</b> |
|                            | AI 3.3                     | (0.2333, -1.6820, -1.6510)             | (1.7471, 0.0641)                | (1.0915, 0.1560)                | 0.1860        | 0.1060        | 0.0200        |
|                            |                            | (0.2292, -1.6820, -1.5704)             | (1.7471, 0.0641)                | (1.0831, 0.1560)                | 0.1898        | 0.1047        | 0.0102        |
|                            |                            | (0.2252, -1.6820, -1.4903)             | (1.7471, 0.0641)                | (1.0747, 0.1559)                | 0.1937        | 0.1035        | 0.0069        |
|                            |                            | (0.2212, -1.6820, -1.4110)             | (1.7471, 0.0641)                | (1.0664, 0.1559)                | 0.1976        | 0.1022        | 0.0052        |
| (0.2172, -1.6820, -1.3322) |                            | (1.7471, 0.0641)                       | (1.0582, 0.1559)                | 0.2014                          | 0.1010        | 0.0042        |               |
| (0.2133, -1.6820, -1.2539) |                            | (1.7471, 0.0641)                       | (1.0501, 0.1558)                | 0.2053                          | 0.0998        | 0.0036        |               |
| (0.2094, -1.6820, -1.1763) |                            | (1.7471, 0.0641)                       | (1.0420, 0.1558)                | 0.2091                          | 0.0986        | 0.0031        |               |
| (0.2055, -1.6820, -1.0992) |                            | (1.7471, 0.0641)                       | (1.0340, 0.1558)                | 0.2130                          | 0.0974        | 0.0028        |               |
| AI 3.4                     | (0.2016, -1.6820, -1.0226) | (1.7471, 0.0641)                       | (1.0261, 0.1557)                | 0.2168                          | 0.0963        | 0.0025        |               |
|                            | (0.1978, -1.6820, -0.9465) | (1.7471, 0.0641)                       | (1.0182, 0.1557)                | 0.2207                          | 0.0951        | 0.0023        |               |
|                            | (0.1939, -1.6820, -0.8709) | (1.7471, 0.0641)                       | (1.0104, 0.1557)                | 0.2245                          | 0.0940        | 0.0021        |               |
|                            | (0.1901, -1.6820, -0.7958) | (1.7471, 0.0641)                       | (1.0026, 0.1557)                | 0.2284                          | 0.0929        | 0.0019        |               |
| AI 3.5                     | (0.1864, -1.6820, -0.7212) | (1.7471, 0.0641)                       | (0.9949, 0.1556)                | 0.2323                          | 0.0918        | 0.0018        |               |
|                            | ⋮                          | ⋮                                      | ⋮                               | ⋮                               | ⋮             | ⋮             |               |
|                            | (0.1179, -1.6820, 0.6219)  | (1.7471, 0.0641)                       | (0.8570, 0.1552)                | 0.3055                          | 0.0738        | 0.0009        |               |
| AI 4                       | -                          | (0.1146, -1.6820, 0.6895)              | (1.7471, 0.0641)                | (0.8502, 0.1552)                | 0.3094        | 0.0730        | 0.0009        |
|                            |                            | ⋮                                      | ⋮                               | ⋮                               | ⋮             | ⋮             | ⋮             |
| AI 5                       | -                          | (-0.1207, -1.6820, 1.6820)             | (1.7471, 0.0641)                | (0.7363, 0.1552)                | 0.3826        | 0.0604        | 0.0007        |
|                            |                            | ⋮                                      | ⋮                               | ⋮                               | ⋮             | ⋮             | ⋮             |

\* AI = Alternative Interval

$$\hat{\mu}_2(\mathbf{x}) = 1.64 + 0.592x_1 + 0.438x_2 - 0.095x_3 + 0.301x_1x_2 - 0.143x_1x_3 + 0.201x_1^2 - 0.0844x_1x_2x_3, \quad (8)$$

$$\hat{\sigma}_1^2(\mathbf{x}) = (-0.0588 + 0.01x_1)^2 + 0.00045986, \quad (9)$$

$$\hat{\sigma}_2^2(\mathbf{x}) = (0.0794x_1)^2 + 0.024. \quad (10)$$

### 4.2 제안된 방법을 활용한 문제 풀이

제안된 방법을 적용하기에 앞서 2개의 반응변수에 대하여  $WMSE_1$  과  $WMSE_2$  를 구성해야 한다. 이를 위하여  $\lambda_1, \lambda_2$  를 결정하여야 하는데, 2.1절에서 언급한 바와 같이 데이터 기반법, 선호도 기반법, 대화식 결정법 등이 활용될 수 있다. 본 문제는 기존의 가중합 기반 WMSE 최소화법, Tchebycheff Metric 기반 WMSE 최소화법으로도 풀이된 적이 있는데[9, 10], 4.3절에서 이들 풀이 결과와 동등하게 비교하기 위하여 본 논문에서도 [9]에

서 도출한  $\lambda_1 = 0.69, \lambda_2 = 0.07$  을 그대로 사용한다. 참고로 [9]는 데이터 기반법을 통해  $\lambda_1, \lambda_2$  값을 도출하였다. 이들을 활용하여  $WMSE_1$  과  $WMSE_2$  는 식 (11)-(12) 와 같이 구성된다.

$$WMSE_1 = \lambda_1(\hat{\mu}_1(\mathbf{x}) - T_1)^2 + (1 - \lambda_1)(\hat{\sigma}_1(\mathbf{x}))^2 = 0.69(\hat{\mu}_1(\mathbf{x}) - 1)^2 + 0.31(\hat{\sigma}_1(\mathbf{x}))^2. \quad (11)$$

$$WMSE_2 = \lambda_2(\hat{\mu}_2(\mathbf{x}))^2 + (1 - \lambda_2)(\hat{\sigma}_2(\mathbf{x}))^2 = 0.07(\hat{\mu}_2(\mathbf{x}))^2 + 0.93(\hat{\sigma}_2(\mathbf{x}))^2. \quad (12)$$

이제  $WMSE_1$  과  $WMSE_2$  가 구성되었기 때문에 제안된 방법을 적용할 수 있다. 제안된 방법의 세부 단계 적용 과정은 다음에 제시되어 있다.

#### 4.2.1 단계 1: 비지배적해의 생성

단계 1에서는 우선 식 (11)-(12)에 정의된  $WMSE_1$  과

$WMSE_2$ 를 이용하여 식 (6)과 같은 최적화 모형을 구성한다. 본 문제 풀이에서는 식 (13)과 같이  $WMSE_2$ 를 목적식으로 두고  $WMSE_1$ 을 제약식에 둔다.

$$\begin{aligned} \text{Min } & WMSE_2 \\ \text{s.t. } & WMSE_1 \leq \epsilon_1, \\ & \mathbf{x} \in \Omega. \end{aligned} \quad (13)$$

식 (13)에서  $\epsilon_1$ 의 최소값과 최대값은  $WMSE_1$ 를 최소화 및 최대화하여 각각 0.00094369과 0.38645로 구해졌다. 다음으로  $\epsilon_1$ 의 증분값은 0.0038551로 정하였다. 이 증분값은 100개의 비지배적해를 도출하도록 인위적으로 계산된 수치이다. 본 문제 풀이에서는  $\epsilon_1$ 을 0.00094369에서 0.38645까지 0.0038551만큼 증가시키면서 식 (13)을 반복적으로 풀었다. 비지배적해 도출 결과는 Fig. 1에 주어져 있으며, 이 중 일부는 Table 2에 구체적인 수치로 제시되어 있다.

#### 4.2.2 단계 2: 최고선호해의 선택

이 문제에서는 반응변수의 개수가 2개, 즉  $k=2$ 이므로 구간 선택 전략을 활용하여 단계 1에서 생성된 비지배적해로부터 최고선호해를 선택해 나간다. 앞서 언급한 바와 같이 구간 선택 전략을 적용하려면 대안구간의 개수와 대안구간 길이의 임계수준이 정해져야 한다. 본 예제 풀이에서는 대안구간의 개수는 5개로, 대안구간 길이의 임계수준은  $WMSE_1$  기준 0.0500,  $WMSE_2$  기준 0.0100로 정하였다. 즉, 대안구간 길이가 이 기준보다 작으면(둘 모두 충족), 더 이상 대안구간을 나누지 않는다. 대안구간 또는 최고선호해의 선택은 의사결정자의 주관적 판단에 따라 그때그때 이루어지나, 본 문제 풀이에서는 판단 기준을 객관화하기 위하여 식 (14)와 같은 효용함수(망대특성)를 가정하고, 효용함수 값에 따라 대안구간 또는 최고선호해를 선택한다.

$$U(\mathbf{x}) = \frac{1}{1000} \sqrt{\frac{WMSE_1(\mathbf{x})\hat{\sigma}_2(\mathbf{x})}{(\hat{\mu}_2(\mathbf{x}) - 1.1)^2}} \quad (14)$$




Fig. 1. Results of the Proposed Method for in the Illustrative Example

상기와 같이 정해진 기준과 효용함수를 가지고 첫 번째 라운드를 진행하였다. 우선 100개의 비지배적해를 동일한 개수(20개)를 가지는 5개의 대안구간으로 나누었다. 이들 대안구간은 Fig. 1과 Table 2에 AI 1~5로 표시되어 있다. 이들 5개의 대안구간 중 최고선호해가 있을 구간은 효용함수 값이 가장 큰 AI 3로 선택되었다. AI 3의 길이는  $WMSE_1$  기준 0.0732(= 0.2284 - 0.1552),  $WMSE_2$  기준 0.0297(= 0.1226 - 0.0929)로, 각각의 임계치인 0.0500, 0.0100보다 크기 때문에 다음 라운드를 진행하기로 하였다.

두 번째 라운드에서는 우선 첫 번째 라운드에서 선택된 AI 3를 다시 동일한 개수(4개)의 비지배적해를 가지는 5개 대안구간으로 나누었다. 이들 대안구간은 Fig. 1과 Table 2에 AI 3.1~3.5로 표시되어 있다. 이들 5개의 대안구간 중 최고선호해가 있을 구간은 효용함수 값이 가장 큰 AI 3.2로 선택되었다. AI 3.2의 길이는  $WMSE_1$  기준 0.0116(= 0.1821 - 0.1706),  $WMSE_2$  기준 0.0055(= 0.1128 - 0.1074)로, 각각의 임계치인 0.0500, 0.0100보다 모두 작기 때문에 더 이상 라운드를 진행하지 않기로 하였다.

최종적으로, AI 3.2에 포함된 4개 비지배적해 중 효용함수 값( $U^*=0.5624$ )이 가장 큰 네 번째 해를 최고선호해로 선택하였다. 즉, 최고선호해는  $\mathbf{x}^* = (0.2616, -1.6820, -1.6820)$ 로 도출되었고, 그에 따라  $(\hat{\mu}_1^*, \hat{\sigma}_1^*) = (1.7471, 0.0641)$ ,  $(\hat{\mu}_2^*, \hat{\sigma}_2^*) = (1.0997, 0.1563)$ ,  $WMSE_1^* = 0.1821$ ,  $WMSE_2^* = 0.1074$ 로 나타났다.

### 4.3 기존 방법과의 비교

본 절에서는 제안된 방법과 기존의 가중합 기반법 및 Tchebycheff Metric 기반법의 풀이 결과를 비교하고자 한다. 구체적으로, 제안된 방법과 유사한 결과를 얻기 위해

가중합 기반법과 Tchebycheff Metric 기반법의 가중치, 즉  $w_i$ 가 어느 수준으로 주어져야 하는지를 사후적으로 확인해 보고자 한다. 참고로, 가중합 기반법과 Tchebycheff Metric 기반법은 선호도사전제시법으로 분류되므로  $w_i$ 의 값은 사전에 정해져 있어야 문제를 풀 수 있다.

먼저 제안된 방법과 (효용함수 값 측면에서) 유사한 결과를 얻기 위한 가중합 기반법에서의  $w_i$  값을 찾아보려고 한다. 이를 위하여 식 (11)-(12)의  $WMSE_1$ 과  $WMSE_2$ 를 가지고 가중합 기반 최적화 모형을 식 (15)와 같이 구축하였다.

$$\begin{aligned} \text{Min } & w_1 WMSE_1 + w_2 WMSE_2 \\ \text{s.t. } & w_1 + w_2 = 1, \\ & \mathbf{x} \in \Omega. \end{aligned} \tag{15}$$

다양한  $w_i$  값에 대하여, 즉 0.01 단위로 변화시키면서 식 (15)를 풀어 보았다. 그 결과,  $(w_1, w_2) = (0.27, 0.73)$ 일 때 효용함수의 값이 0.2411로 제안된 방법의 결과에 가장 근접하게 나왔다. 이 때의 해는  $\mathbf{x}^* = (0.2594, -1.6820, -1.6820)$ 로 도출되었고, 그에 따라  $(\hat{\mu}_1^*, \hat{\sigma}_1^*) = (1.5125, 0.0602)$ ,  $(\hat{\mu}_2^*, \hat{\sigma}_2^*) = (1.0993, 0.1563)$ ,  $WMSE_1^* = 0.1823$ ,  $WMSE_2^* = 0.1073$ 로 나타났다.

다음으로 Tchebycheff Metric 기반법에 대해서도 식 (16)과 같이 최적화 모형을 구축하여 다양한  $w_i$  값을 가지고 풀어 보았다.

$$\begin{aligned} \text{Min } & \alpha \\ \text{s.t. } & \alpha \geq w_1 (WMSE_1 - 0), \\ & \alpha \geq w_2 (WMSE_2 - 0), \\ & w_1 + w_2 = 1, \\ & \mathbf{x} \in \Omega. \end{aligned} \tag{16}$$

그 결과,  $(w_1, w_2) = (0.37, 0.63)$ 일 때 효용함수의 값이 0.1407로 제안된 방법의 결과(0.5624)에 가장 근접하

**Table 3.** Comparisons of the Proposed Method with the Weighted Sum Method and the Tchebycheff Metric Method for the Illustrative Example

|                           | $(w_1, w_2)$ | $\mathbf{x}^* = (x_1^*, x_2^*, x_3^*)$ | $(\hat{\mu}_1^*, \hat{\sigma}_1^*)$ | $(\hat{\mu}_2^*, \hat{\sigma}_2^*)$ | $WMSE_1^*$ | $WMSE_2^*$ | $U^*$  |
|---------------------------|--------------|--|-------------------------------------|-------------------------------------|------------|------------|--------|
| Proposed Method           | -            | (0.2616, -1.6820, -1.6820)             | (1.7471, 0.0641)                    | (1.0997, 0.1563)                    | 0.1821     | 0.1074     | 0.5624 |
| Weighted Sum Method       | (0.27, 0.73) | (0.2594, -1.6820, -1.6820)             | (1.5125, 0.0602)                    | (1.0993, 0.1563)                    | 0.1823     | 0.1073     | 0.2411 |
| Tchebycheff Metric Method | (0.37, 0.63) | (0.2567, -1.6820, -1.6820)             | (1.5128, 0.0602)                    | (1.0988, 0.1563)                    | 0.1826     | 0.1072     | 0.1407 |



게 나왔다. 이 때의 해는  $\mathbf{x}^* = (0.2567, -1.6820, -1.6820)$ 로 도출되었고, 그에 따라  $(\hat{\mu}_1^*, \hat{\sigma}_1^*) = (1.5128, 0.0602)$ ,  $(\hat{\mu}_2^*, \hat{\sigma}_2^*) = (1.0988, 0.1563)$ ,  $WMSE_1^* = 0.1826$ ,  $WMSE_2^* = 0.1072$ 로 나타났다.

제안된 방법 및 가중합 기반법 및 Tchebycheff Metric 기반법의 풀이 결과는 Table 3에 정리되어 있다. 각각의 방법을 비교한 결과, 효용함수 값의 차이는 다소 있었으나  $\mathbf{x}^*$ ,  $(\hat{\mu}_1^*, \hat{\sigma}_1^*)$ ,  $(\hat{\mu}_2^*, \hat{\sigma}_2^*)$ ,  $WMSE_1^*$ ,  $WMSE_2^*$  값 측면에서는 사실상 동일한 결과를 도출하였다.

선호도사전제시법에 해당하는 가중합 기반법과 Tchebycheff Metric 기반법은 사전에  $(w_1, w_2)$ 가 결정되어 있어야 하는데, 그 값은 각각 (0.27, 0.73)과 (0.37, 0.63)이었다. 현실적으로 이들 가중치를 전체 해결합에서 나타나는 트레이드오프 관계를 파악하지 못한 상태에서 사전에 알아낸다는 것은 사실상 불가능하다. 제안된 방법은 이러한 가중치와 같은 의사결정자의 선호도 정보를 사전에 요구하지 않는다. 제안된 방법은 다수의 비지배적해를 생성한 후 의사결정자로 하여금 이들 간의 트레이드오프 관계를 이해시킨 후 해를 선택하도록 한다. 이를 통하여 의사결정자의 선호도에 부합하는 최고선호해를 효과적으로 도출할 수 있다.

## 5. 결론

본 논문에서는 다중반응표면 최적화에서 WMSE 최소화를 위한 선호도사후제시법을 제안하였다. WMSE 최소화와 관련된 기존의 기법, 즉 가중합 기반법과 Tchebycheff 기반법은 선호도사전제시법에 해당되는데, 이는 의사결정자의 선호도 정보(가중치)를 문제풀이 이전에 결정할 것을 요구한다. 그러나 현실적으로 의사결정자가 자신의 선호도 정보를 사전에 정확히 제공하는 것은 매우 어렵다. 제안된 방법은 의사결정자의 선호도 정보 없이 다수의 비지배적해를 생성한 후, 의사결정자가 생성된 비지배해 중 최고선호해를 선택하는 단계로 진행된다. 제안된 방법은 의사결정자가 전체 해결합의 트레이드오프 관계를 보다 폭넓은 시각으로 이해한 후 선호도 정보를 제시할 수 있도록 함으로써, 의사결정자의 선호도에 부합하는 최고선호해를 효과적으로 도출할 수 있다.

본 논문의 토의사항으로, 제안된 방법의 효율성을 개선한 기법을 사용하는 것을 들 수 있다. 제안된 방법은 다수의 비지배적해를 생성한 다음에, 의사결정자가 구간(셀) 선택 전략에 따라 최고선호해를 선택하게 된다. 그러나 구간(셀) 선택 전략에서 대안구간을 생성할 때 매우 많은 수의 비지배적해들은 활용되지 않는 비효율성을 지니고 있다. 이러한 비효율성은 대안구간을 생성하는데 필요한 최소한의 비지배적해를 반복적으로 생성하는 방식으로 해결할 수 있다[24].

제안된 방법의 한계점으로는 비지배적해의 생성을 위해 채택한  $\epsilon$ -Constraint 방법의 단점을 들 수 있다. 식 (6)에서 설명한 바와 같이,  $\epsilon$ -Constraint 방법은  $\epsilon_i$ 들의 값을 일정하게 증가(또는 감소)시키며  $WMSE_i$  목적함수 공간에서 비지배적해를 생성한다. 이 때  $WMSE_i$  목적함수 공간이 어떻게 형성되어 있느냐에 따라 생성된 비지배적해의 분포 간격이 일정하지 않을 수 있다. 만약 비지배적해의 분포 간격이 균일하지 못한 상태에서 의사결정자가 원하는 최고선호해가 간격이 넓은 구간에서 존재하면 이를 찾지 못하게 된다. 다시 말하면, 생성된 비지배적해의 간격이 일정하지 못할 경우, 의사결정자가 원하는 정밀한 수준의 최고선호해를 선택하지 못할 수 있다. 따라서 모든 구간에서 보다 일정하게 분포된 비지배적해를 생성하기 위한 방법론 개선이 필요하다.

## References

- [1] Myers, R. H. and Montgomery, D. C., Response Surface Methodology (2<sup>nd</sup> ed.), John Wiley & Sons, New York, NY, 2002.
- [2] Khuri, A. I., "Multiresponse Surface Methodology", In Handbook of Statistics: Design and Analysis of Experiment (Vol. 13) (eds. A. Ghosh and C. R. Rao), pp. 377-406, 1996.  
DOI: [http://dx.doi.org/10.1016/s0169-7161\(96\)13014-5](http://dx.doi.org/10.1016/s0169-7161(96)13014-5)
- [3] Jeong, I. "Multiresponse Optimization: A Literature Review and Research Opportunities", Journal of the Korean Society for Quality Management, Vol. 39, No. 3, pp. 377-390, 2011.
- [4] Köksoy, O., "Multiresponse Robust Design: Mean Square Error (MSE) Criterion", Applied Mathematics and Computation, Vol. 175, No. 2, pp. 1716-1729, 2006.  
DOI: <http://dx.doi.org/10.1016/j.amc.2005.09.016>
- [5] Köksoy, O. and Yalcinoz, T., "Mean Square Error Criteria to Multiresponse Process Optimization by a New Genetic Algorithm", Applied Mathematics and Computation, Vol. 175, No. 2, pp. 1657-1674, 2006.  
DOI: <http://dx.doi.org/10.1016/j.amc.2005.09.011>

- [6] Rheem, S. and Lee, W. "Multiresponse Optimization in Response Surface Analysis: A Method by Minimization of Weighted Sum of Estimates of Expected Squared Relative Errors", Journal of the Korean Society for Quality Management, Vol. 33, No. 1, pp. 73-82, 2004.
- [7] Köksoy, O., "A Nonlinear Programming Solution to Robust Multi-Response Quality Problem", Applied Mathematics and Computation, Vol. 196, No. 2, pp. 603-612, 2008.  
DOI: <http://dx.doi.org/10.1023/A:1008314306344>  
DOI: <http://dx.doi.org/10.1016/j.amc.2007.06.023>
- [8] Shin, S., Samanlıoglu, F., Cho, B. B., and Wiecek, M. M., "Computing Trade-Offs in Robust Design: Perspectives of the Mean Squared Error", Computers and Industrial Engineering, Vol. 60, No. 2, pp. 248-255, 2011.  
DOI: <http://dx.doi.org/10.1016/j.cie.2010.11.006>
- [9] Jeong, I. and Cho, H., "A Weighted Mean Squared Error Approach to Multiple Response Surface Optimization", Journal of The Korea Academia-Industrial Cooperation Society, Vol. 14, No. 2, pp. 625-633, 2013.  
DOI: <http://dx.doi.org/10.5762/KAIS.2013.14.2.625>
- [10] Jeong, I., "A Weighted Mean Squared Error Approach Based on the Tchebycheff Metric in Multiresponse Optimization", Journal of The Korea Academia-Industrial Cooperation Society, Vol. 16, No. 1, pp. 97-105, 2015.  
DOI: <http://dx.doi.org/10.5762/KAIS.2015.16.1.97>
- [11] Ding, R., Lin, D. K. J., and Wei, D., "Dual Response Surface Optimization: A Weighted MSE Approach", Quality Engineering, Vol. 16, No. 3, pp. 377-385, 2004.  
DOI: <http://dx.doi.org/10.1081/QEN-120027940>
- [12] Jeong, I., Kim, K., and Chang, S. Y., "Optimal Weighting of Bias and Variance in Dual Response Surface Optimization", Journal of Quality Technology, Vol. 37, No. 3, pp. 236-247, 2005.
- [13] Jeong, I., Kim, K., and Lin, D., "Bayesian Analysis for Weighted Mean Squared Error in Dual Response Surface Optimization," Quality and Reliability Engineering International, Vol. 26, No. 5, pp. 417-430, 2010.  
DOI: <http://dx.doi.org/10.1002/qre.1058>
- [14] Lee, D. and Kim, K., "Interactive Weighting of Bias and Variance in Dual Response Surface Optimization", Expert Systems with Applications, Vol. 39, No. 5, pp. 5900-5906, 2012.  
DOI: <http://dx.doi.org/10.1016/j.eswa.2011.11.114>
- [15] Steuer, R. E., Multiple Criteria Optimization: Theory, Computation, and Application, John Wiley & Sons, New York, NY, 1986.
- [16] Hwang, C., Masud, A. S. M., Paidy., S. R., and Yoon, K., Multiple Objective Decision Making. Methods and Applications (Lecture Notes in Economics and Mathematical Systems), Springer-Verlag, Berlin, 1979.  
DOI: <http://dx.doi.org/10.1007/978-3-642-45511-7>
- [17] Tind, J. and Wiecek, M. M., "Augmented Lagrangian and Tchebycheff Approaches in Multiple Objective Programming", Journal of Global Optimization, Vol. 14, pp. 251-266, 1999.
- [18] Miettinen, K., "Some Methods for Nonlinear Multi-Objective Optimization." Lecture Notes in Computer Science, Vol. 1993, pp. 1-20, 2001.  
DOI: [http://dx.doi.org/10.1007/3-540-44719-9\\_1](http://dx.doi.org/10.1007/3-540-44719-9_1)
- [19] Haimes, Y. Y., Lasdon, L. S., and Wismer, D. A., "On a Bicriterion Formulation of the Problems of Integrated System Identification and System Optimization", IEEE Transactions on Systems, Man, and Cybernetics, Vol. 1, No. 3, pp. 296-297, 1971.  
DOI: <http://dx.doi.org/10.1109/TSMC.1971.4308298>
- [20] Lee, D., Jeong, I., and Kim, K. "A Posterior Preference Articulation Approach to Dual-Response-Surface Optimization", IIE Transactions, Vol. 42, No. 2, pp. 161-171, 2010.  
DOI: <http://dx.doi.org/10.1080/07408170903228959>
- [21] Lee, D., Kim, K., and Kosalan, M., "A Posterior Preference Articulation Approach to Multiresponse Surface Optimization", European Journal of Operational Research, Vol. 210, No. pp. 301-309, 2011.
- [22] Kösalan, M. and Sagala, P. N. S., "Interactive Approaches for Discrete Alternative Multiple Criteria Decision Making with Monotone Utility Functions", Management Science, Vol. 41, No. 7, pp. 1158-1171, 1995.  
DOI: <http://dx.doi.org/10.1287/mnsc.41.7.1158>
- [23] Romano, D., Varetto, M., and Vicario, G., "Multiresponse Robust Design: A General Framework Based on Combined Array", Journal of Quality Technology, Vol. 36, No. 1, pp. 27-37, 2004.
- [24] Jeong, I. "An Iterative Posterior Preference Articulation Approach to Dual Response Surface Optimization", Journal of the Korean Society for Quality Management, Vol. 40, No. 4, pp. 481-496, 2012.  
DOI: <http://dx.doi.org/10.7469/JKSQM.2012.40.4.481>

정인준(In-Jun Jeong)

[정회원]



- 2006년 2월 : 포항공과대학교 산업 경영공학과 (공학박사)
- 2006년 2월 ~ 2010년 4월 : 한국 전자통신연구원 선임연구원
- 2010년 5월 ~ 2012년 2월 : 정보통신정책연구원 부연구위원
- 2012년 3월 ~ 현재 : 대구대학교 경영학과 조교수

<관심분야>

품질경영/공학, 생산운영관리, 통신전과정책