

# 품질 기능 전개를 통한 대용 특성값의 결정 방법

변은신\* · 엄봉진\*\*

Determination of Engineering Characteristic Values  
by Quality Function Deployment

Eun-Shin Byun\* · Bong-Jin Yum\*\*

## ABSTRACT

The basic idea of Quality Function Deployment(QFD) is to deploy the voice of customers into the final product through product planning, part planning, process planning, and manufacturing. In the product planning stage, which is the first stage of product development, customer attributes(CAs) are translated into engineering characteristics(ECs). Then, based on the relationships between CAs and ECs, the target values of ECs are determined. In the previous research, the process of analyzing these relationships is mostly subjective in nature. In this article, we formulate the process of determining the target values of ECs as an optimization model. That is, we first determine the relationships between CAs and ECs as cumulative logit models and construct constraints into which the company strategy as well as the needs of customers can be incorporated. Next, cost functions of ECs are developed, which are summed into an objective function. An algorithm to solve the formulated optimization problem is developed and illustrated with an example.

## 1. 서 론

품질보증 활동은 검사 위주에서 공정 관리 중심으로 바뀌어 왔으며 현재는 제품 개발 단계에 중점을 두는 추세로 변화하고 있다. 제품 개발에

중점을 두는 품질보증에서는 품질 문제를 제품 및 공정의 설계 단계에서 해결하게 되므로, 제품의 결함을 수정하기에 용이하고 설계의 최적화를 도모할 수 있다. 특히 기술혁신과 소비자 요구의 다양화로 인해 기업이 처하고 있는 환경이 급속

\* LG-EDS 품질경영팀

\*\* 한국과학기술원 산업공학과

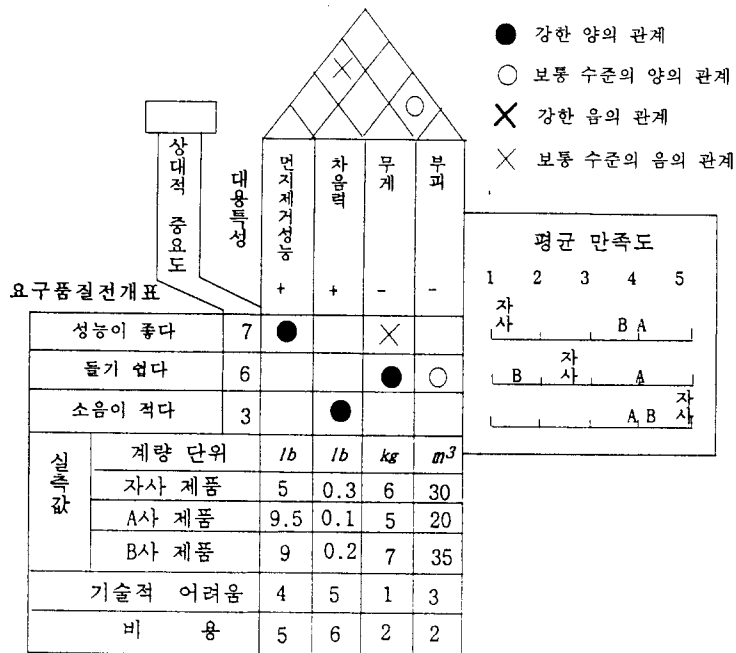
하게 변화하는 상황에서 소비자의 요구를 적극적으로 반영한 제품 또는 서비스를 빠른 시간 내에 개발하는 것은 무엇보다도 중요하다. 품질 기능 전개(Quality Function Deployment, QFD)는 이를 효과적으로 달성하기 위해 제품 개발 단계에서 활용할 수 있는 기법으로서 최근 많은 관심의 대상이 되고 있다. 일본의 대표적 품질 잡지인 '표준화와 품질관리', '품질관리', '품질'에 게재된 QFD 관련 문헌의 추이를 보면 1981년 이후 그 수가 급격히 증가하고 있으며, 특히 신제품 개발 및 설계에 관련된 활용 내용이 두드러지게 많아지고 있다 [3]. 이는 품질 문제를 보다 이른 단계에서부터 확보하려는 경향을 대변하는 것이라 볼 수 있다.

한편, QFD는 역사가 짧고, 실천과 경험으로부터 얻은 노하우를 행렬 형태로 정리하는데 역점을 두어 왔기 때문에 아직 의사결정 과정이 주관적이고 체계화도 미흡한 실정이다. 최근에 이러한 한계점을 극복하기 위해 분석 과정을 객관화하려

는 시도가 이루어지고 있으나, 보다 합리적인 의사결정을 내릴 수 있도록 하는 체계적인 지원이 필요하다. 본 논문에서는 제품 기획 단계의 HOQ (House Of Quality)를 분석하는 보다 객관적이고 체계적인 방법론을 제시하고자 한다.

## 2. QFD의 개념

QFD는 소비자의 요구를 제품의 특성으로 전환하여 완성품의 설계품질을 결정한 다음, 이를 다시 부품 특성, 공정 특성, 그리고 결국 생산을 위한 구체적 사양에 이르기까지 이들 간의 관계를 계통적으로 전개하는 체계적인 제품 개발 방법이다[3]. 이러한 과정은 HOQ라 불리는 일련의 도표에 의해 이루어진다. 이 HOQ를 이용하여 각 단계의 요구사항(What)과 이를 실천할 수 있는 방법(How)을 관련시켜 가면서 소비자의 요구사항을 구체적으로 전개하게 된다[8][14]. <그림 1>



<그림 1> 진공청소기에 대한 제품 기획 단계의 HOQ

은 진공청소기에 대해 가상적으로 전개한 제품 기획 단계의 HOQ이다. 이 단계의 HOQ는 사용자가 원하는 진정한 품질을 체계화하고 제품 특성과의 관련을 파악하여, 사용자의 요구를 대응 특성(Engineering Characteristic, EC)으로 전환하기 위한 도표이다. 앞으로 이 예를 중심으로 HOQ를 구성하는 각 항목에 대해 설명하고자 한다.

### 2.1 제품 기획 단계의 HOQ

HOQ의 각 요소는 다음과 같다.

- 소비자 요구품질(Customer Attribute, CA): QFD는 소비자의 요구사항을 파악하는 일로부터 시작된다. 예를 들어, 진공청소기에 대해 소비자는 ‘성능이 좋다’, ‘들기 쉽다’ 등을 요구할 수 있고, 이들이 각각 하나의 CA를 구성하게 된다. CA는 설문 조사, 개별 면접, 초점 그룹(focus group)과의 면담, 전시회 참가 등의 방법을 통해 얻을 수 있으며, <그림 1>에서 보듯이 HOQ의 왼편에 놓여진다.

- CA의 상대적 중요도: CA의 중요도는 CA와 마찬가지로 설문 조사, 개별 면접, 초점 그룹과의 면담 등을 통해 얻을 수 있으며, 주로 순서 범주형 자료(ordinal categorical data)의 형태로 얻어진다. 이 때 각 범주에 적당한 점수를 부여한 후 소비자들의 평가 점수를 평균한 값을 상대적 중요도라 하며, 요구품질 전개표의 오른편에 기록한다.

- 시장 평가 자료: 시장 평가 자료는 각 CA에 대해 자사의 제품과 경쟁 관계에 있는 타사 제품의 만족도를 비교, 평가한 벤치마킹 데이터를 의미한다. 이 자료는 CA의 상대적 중요도 자료를 얻는 방법과 유사하게 얻어지며, 시장 내에서의 위치를 결정하거나 전략을 세우는 데 중요한 자료로 이용될 수 있다. 자사 제품이란 기존의 제품

이거나 시제품을 의미한다. 본 논문에서 제안하는 방법에서는 자사 제품에 대한 시장 평가자료는 없어도 무방하다.

- 대응 특성(Engineering Characteristic, EC): CA는 소비자의 언어로 표현되기 때문에 모호한 경우가 많아서 제품 설계에 직접 이용하기 어렵다. 따라서 설계자에 의해 결정될 수 있는 제품 특성으로의 전환이 필요하며 이를 대응 특성이라 한다. EC는 CA와 달리 제품이 완성된 후 계량적으로 측정될 수 있고, 그 제품에 대한 소비자의 인식에 직접적으로 영향을 미칠 수 있는 특성이어야 한다. <그림 1>의 상단부에 열거된 각 EC 아래에는 +와 -기호가 있는데, 이 기호는 CA를 만족시키기 위해 각 EC가 개선되어야 할 방향을 의미한다. 예를 들어 ‘먼지제거성능’이라는 항목 아래의 + 기호는 먼지제거성능이 클수록 바람직함을 나타낸다.

- CA와 EC간의 관계표(relationship matrix): 각 EC가 CA에 ‘얼마나’, ‘어떻게’ 영향을 미치는가를 나타낸 표로 HOQ의 몸체에 해당된다. 관련이 있다고 여겨지는 셀에 수치나 특정 기호를 이용하여 관계의 성질과 관련 강도를 기록한다. 예를 들어, <그림 1>의 ‘무게’라는 EC는 그 값이 작을 수록 ‘성능이 좋다’라는 CA에는 바람직하지 않은 영향을 미치나, ‘들기 쉽다’라는 CA에는 매우 긍정적인 영향을 미치고 있다.

- EC간의 상호 연관표(correlation matrix): HOQ의 지붕에 해당하는 부분으로 CA와 EC간의 관계표와 마찬가지로 수치나 기호를 이용하여 관련의 성질과 강도를 표시한다.

- 현재의 EC 수준 비교: HOQ 몸체 행렬의 바로 아래에는 자사 제품 및 경쟁사 제품의 EC 실측값이 기록된다. 앞에서와 마찬가지로 자사 제품이란 기존의 제품 또는 시제품을 의미한다. 본 연구에서 제안하는 방법에서는 자사 제품에 대한

EC 실측값은 없어도 무방하다.

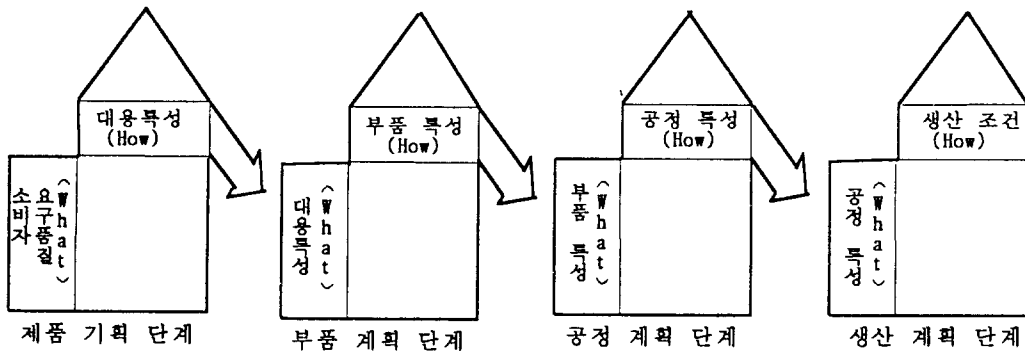
• 그 밖의 선택적 항목: 대상이 되는 제품이 무엇인가에 따라 위의 항목 이외에 기술적 난이도, 비용 등 여러 선택적 항목을 추가할 수 있다.

위에서 열거한 모든 항목으로 부터의 정보를 바탕으로 자사 제품의 목표 EC 수준을 결정한다.

### 2.2 소비자 요구의 전개

제품 기획 단계의 HOQ를 통해 결정된 EC는 다음 단계의 HOQ에서는 요구사항이 된다. 즉 전 단계의 'How'는 다음 단계의 'What'으로 연결되는 것이다. 전개의 단계는 제품에 따라 달라질 수

있으나, 일반적으로 <그림 2>와 같이 4단계로 구분할 수 있다[8]. 그림에서 보듯이 제품 기획 단계에서 결정된 EC는 부품 계획 단계의 HOQ를 거쳐 부품 특성으로 전개된다. 이 때 목표 EC값을 충족시키기 위한 부품 특성값이 결정된다. 다음 단계인 공정 계획 단계에서는 이 부품을 생산하게 될 관련 공정과의 연결이 이루어진다. 마지막으로 생산 계획 단계에서 세부적인 공정 조건 및 생산을 위한 구체적인 사양을 결정하게 된다. 이와 같은 일련의 과정을 통하여 소비자의 요구가 각 단계에서 구체적인 목표로 변환되어, 결과적으로 소비자가 원하는 수준의 품질과 기능이 최종 제품에 적극적으로 구현되어질 수 있다.



<그림 2> 소비자의 요구가 전개되는 QFD 프로세스[8]

### 3. 관련 연구

QFD에 대한 연구는 크게 QFD의 개념 및 활용방안에 대한 연구[3][4][8][14], QFD를 응용한 사례[4][12], 그리고 정량적인 분석을 시도한 연구[3][10][13][16]로 나누어 볼 수 있다. 이 중 최근 시도되고 있는 QFD를 정량화하고 체계적으로 분석하기 위한 방법들은 주로 QFD의 첫 단계인 제품 기획 단계에 중점을 두고 있다. 가장 간단하면서 대표적인 방법은 CA와 EC와의 연관

정도를 수량화해서 적당한 점수를 배정한 후 CA의 상대적 중요도를 곱하여 각 EC별로 가중합을 산출하고 이를 EC의 중요도로 삼는 것이다[3]. 이렇게 해서 구해진 중요도를 기준으로 각 EC의 목표값을 주관적으로 결정한다. Lyman[10]과 Wasserman[16]은 이 방법을 확장하여 어떤 CA<sub>i</sub>와 EC<sub>j</sub>의 연관 정도를 CA<sub>i</sub>에 미치는 모든 EC들의 총 영향의 정도로 표준화하는 방법을 제시하였다. 그리고 EC<sub>j</sub>의 중요도는 표준화된 연관정도를 이용해서 위의 대표적인 방법과 마찬가지로

계산하고, 이 중요도의 비율로 노력을 배분하여 각 EC를 개선한다면, 각 CA의 만족도를 향상시키기 위한 노력은 각 CA에 대해 소비자가 판단하는 중요도의 비율로 배분되게 된다[1]. 그러나 이 두 방법은 CA와 EC의 연관 정도에 따라 할당하는 점수가 인위적이며, 할당하는 값에 따라 EC의 중요도가 달라질 수 있다는 문제점을 안고 있다. 이러한 문제점을 해결하고자 Moskowitz와 Kim[13]은 CA 각각에 대한 시장 평가 자료와 제품의 EC값으로 부터 CA와 EC간의 관계를 통계적으로 분석하고, 이를 바탕으로 EC의 목표값을 결정하는 방법을 제시하였다. 이 방법은 순서형 범주로 측정되는 CA의 만족도에 적당한 점수를 부여하여 이를 종속변수로 하고 각 CA에 영향을 미치는 EC를 독립변수로 하여 회귀 분석을 수행한 것이다. 그러나 이 방법 역시 각 범주에 부여하는 점수의 할당이 주관적이기 때문에 EC의 목표값을 보다 합리적으로 결정할 수 있는 방법이 필요하다.

## 4. 새로운 분석방법

### 4.1 소비자 요구품질과 대응 특성의 관계 분석

각 단계의 HOQ를 분석할 때 각 'What' 항목이 종속변수가 되고, 'How' 항목은 독립변수가 된다. 제품 기획 단계에서는 종속변수인 CA의 만족도가 <표 1>에서 보는 것처럼 주로 순서 범주형 데이터로 얻어진다. 표에서  $n^i_k$ 는  $i$ 번째 소비자 요구품질인  $CA_i$ 의 만족도 조사 결과,  $k$ 번째 제품에 대해  $r$ 번째 범주에 응답한 소비자의 수를 의미한다. 종속변수가 순서 범주형 자료로 얻어질 때 이를 분석하는 가장 일반적인 방법은 점수법(scoring method)이다. 이 방법은 각 순서형 범주에 적당한 점수를 부여하여 마치 연속변수인 것처럼 분석하는 것으로 Moskowitz와 Kim[13]의 분석 방법이 이에 해당한다. 그러나 이 방법은 앞서 언급한 바와 같이 점수의 할당이 주관적이다.

<표 1>  $CA_i$ 의 만족도에 대한 데이터

	만 족 도				합
	1,	2,	...	, C	
제품1	$n^i_{11}$ ,	$n^i_{12}$ ,	...	, $n^i_{1C}$	$n^i_{1+}$
제품2	$n^i_{21}$ ,	$n^i_{22}$ ,	...	, $n^i_{2C}$	$n^i_{2+}$
⋮	⋮	⋮	⋮	⋮	⋮
제품S	$n^i_{S1}$ ,	$n^i_{S2}$ ,	...	, $n^i_{SC}$	$n^i_{S+}$

Cumulative logit model은 순서 범주형 데이터를 다루는 또 다른 모형이다[2][6]. 이 모델을 이용하면 주관성을 배제할 수 있을 뿐 아니라, 각 CA와 EC의 관계를 효과적으로 밝혀낼 수 있다. 모수의 추정을 위해서는 가중최소자승법(Weighted Least Squares Method, WLS)과 최우추정법(Maximum Likelihood Estimation, MLE)이

이용될 수 있다. 그리고, 소비자는 각 CA에 대한 만족도 판단시 각 제품에 대해 독립적으로 판단한다고 가정한다.

본 질에서 사용되는 기호는 다음과 같다.

#### 기호

$CA_i$ :  $i$ 번째 소비자 요구품질( $i=1, \dots, I$ )

- $EC_j$   $j$ 번째 대응 특성( $j=1, \dots, J$ )
- $F_{kr}^i$   $CA_i$ 의 만족도 조사 결과,  $k$ 번째 제품에 대해  $r$ 번째 범주에 응답한 소비자의 비율( $=n_{kr}^i/n_{k+}$ )
- $F_{kr}^j$   $CA_i$ 의 만족도 조사 결과,  $k$ 번째 제품에 대해  $r$ 번째 범주 이하로 응답한 소비자의 비율 [ $=\sum_{i=1}^r n_{ki}^j/n_{k+}^j$ ]
- $\pi_{kr}^i$   $F_{kr}^i$ 의 참값

4.1.1 WLS에 의한 분석

Grizzle 등[6]은 종속변수가 순서 범주형 변수 일 때 WLS를 이용하여 독립변수와의 관계를 분석하는 일반적인 모델을 제시하였다. Cumulative logit model은 그 중 한 모델로서 아래 식과 같이 쓸 수 있다.

$$\begin{aligned}
 g_1(\mathbf{P}_k) &\equiv \ln \left[ \frac{P_{k2} + \dots + P_{kC}}{P_{k1}} \right] = \ln \left[ \frac{1 - F_{k1}}{F_{k1}} \right] \\
 &= \beta_{01} + \beta_{11}x_{k1} + \dots + \beta_{q-1,1}x_{k,q-1} + \varepsilon_{k1} \\
 g_2(\mathbf{P}_k) &\equiv \ln \left[ \frac{P_{k3} + \dots + P_{kC}}{P_{k1} + P_{k2}} \right] = \ln \left[ \frac{1 - F_{k2}}{F_{k2}} \right] \\
 &= \beta_{02} + \beta_{12}x_{k1} + \dots + \beta_{q-1,2}x_{k,q-1} + \varepsilon_{k2} \\
 &\vdots
 \end{aligned}
 \tag{1}$$

$$H(\pi_k) = \begin{bmatrix} \frac{\partial g_1(\mathbf{P}_k)}{\partial P_{k1}} & \frac{\partial g_1(\mathbf{P}_k)}{\partial P_{k2}} & \dots & \frac{\partial g_1(\mathbf{P}_k)}{\partial P_{kC}} \\ \frac{\partial g_2(\mathbf{P}_k)}{\partial P_{k1}} & \frac{\partial g_2(\mathbf{P}_k)}{\partial P_{k2}} & \dots & \frac{\partial g_2(\mathbf{P}_k)}{\partial P_{kC}} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial g_{C-1}(\mathbf{P}_k)}{\partial P_{k1}} & \frac{\partial g_{C-1}(\mathbf{P}_k)}{\partial P_{k2}} & \dots & \frac{\partial g_{C-1}(\mathbf{P}_k)}{\partial P_{kC}} \end{bmatrix} \mathbf{P}_k = \pi_k$$

이다. 따라서,  $g(\mathbf{P}_k)$ 의 공분산행렬은 근사적으로 다음 식과 같다.

$$\Sigma_k = H(\pi_k)V(\pi_k)H(\pi_k)'$$

단,  $V(\pi_k)$ 는  $\mathbf{P}_k$ 의 공분산행렬로서 다음과 같이

$$\begin{aligned}
 g_{C-1}(\mathbf{P}_k) &\equiv \ln \left[ \frac{P_{kC}}{P_{k1} + \dots + P_{k,C-1}} \right] = \ln \left[ \frac{1 - F_{k,C-1}}{F_{k,C-1}} \right] \\
 &= \beta_{0,C-1} + \beta_{1,C-1}x_{k1} + \dots + \beta_{q-1,C-1}x_{k,q-1} + \varepsilon_{k,C-1}
 \end{aligned}$$

각  $CA$ 에 대한 분석은 동일하므로 위 식에서  $i$ 번째 요구품질을 나타내는 위첨자  $i$ 는 생략하였으며,  $\mathbf{P}_k = (P_{k1}, P_{k2}, \dots, P_{kC})'$ 이다.  $x_{kj}$ 는 제품  $k$ 에서  $EC_j$ 의 실측값이며,  $CA_i$ 에 영향을 미친다고 판단되는  $EC$ 의 총 갯수인  $q-1$ 은  $CA_i$ 에 따라 달라질 수 있다. 만일  $x_{kj}$ 가 이산형 변수이면 가변수(dummy variable)를 도입하도록 한다(5절의 예제 참조). 위 모델을 앞으로 CLM1이라 부르기로 하자.

임의의 제품  $k$ 에 대해

$$\begin{aligned}
 \pi_k &= (\pi_{k1}, \pi_{k2}, \dots, \pi_{kC})' \\
 g(\mathbf{P}_k) &= (g_1(\mathbf{P}_k), g_2(\mathbf{P}_k), \dots, g_{C-1}(\mathbf{P}_k))'
 \end{aligned}$$

라 할 때, Talyor Series를 1차까지 전개하면  $g(\mathbf{P}_k)$ 는 근사적으로

$$g(\mathbf{P}_k) \approx g(\pi_k) + H(\pi_k)(\mathbf{P}_k - \pi_k)$$

로 표현할 수 있다. 단,

주어진다.

$$V(\pi_k) = (Diag(\pi_k) - \pi_k \pi_k') / n_{k+}$$

이 때  $\pi_k$ 를 모르므로  $\pi_k$ 에  $\mathbf{P}_k$ 를 대입함으로써 다음과 같이  $\Sigma_k$ 의 표본추정치를 얻을 수 있다.

$$\hat{\Sigma}_k = H(\mathbf{P}_k)V(\mathbf{P}_k)H(\mathbf{P}_k)'$$

제품의 총수를 S라 하고 모든 제품에 대해 독립적으로 자료가 얻어진다고 가정하면,

$$\mathbf{P} = (\mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_S)'$$

$$G(\mathbf{P}) = (g'(\mathbf{P}_1), g'(\mathbf{P}_2), \dots, g'(\mathbf{P}_S))'$$

라 할 때,  $G(\mathbf{P})$ 의 공분산행렬  $\Sigma$ 의 추정치  $\hat{\Sigma}$ 은 다음과 같다.

$$\hat{\Sigma} = \text{Diag}(\hat{\Sigma}_1, \hat{\Sigma}_2, \dots, \hat{\Sigma}_S).$$

식 (1)을 모든 제품에 대해 행렬 형태로 다시 쓰면

$$\begin{bmatrix} g_1(\mathbf{P}_1) \\ \vdots \\ g_{C-1}(\mathbf{P}_1) \\ \hline \vdots \\ \hline g_1(\mathbf{P}_S) \\ \vdots \\ g_{C-1}(\mathbf{P}_S) \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1,q-1} & & \\ & & & & \ddots & \\ & & & & & 1 & x_{11} & \dots & x_{1,q-1} \\ \hline & & & & & & & & \\ & & & & & & & & \\ \hline & & & & & & & & \\ & & & & & & & & \\ \hline 1 & x_{S1} & \dots & x_{S,q-1} & & \\ & & & & \ddots & \\ & & & & & 1 & x_{S1} & \dots & x_{S,q-1} \end{bmatrix} \begin{bmatrix} \beta_{01} \\ \vdots \\ \beta_{q-1,1} \\ \hline \vdots \\ \hline \beta_{0,C-1} \\ \vdots \\ \beta_{q-1,C-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{1,C-1} \\ \hline \vdots \\ \hline \varepsilon_{S1} \\ \vdots \\ \varepsilon_{S,C-1} \end{bmatrix}$$

이 되고, 식 (2)와 같이 간단하게 표현할 수 있다.

$$G(\mathbf{P}) = \mathbf{X}\beta + \varepsilon \tag{2}$$

한 제품 내에서 오차항의 분산은 일정하지 않고 서로 독립이 아니므로 모수( $\beta$ )를 추정하기 위해서는  $G(\mathbf{P})$ 의 공분산 행렬인  $\Sigma$ 를 이용한 WLS 방법을 사용하는 것이 바람직하다. 그러나,  $\Sigma$ 를 모르므로 이를 대신하여  $\Sigma$ 의 추정치인  $\hat{\Sigma}$ 을 이용한다.  $\beta$ 의 WLS 추정치는 식 (3)과 같다[6].

$$\mathbf{b} = (\mathbf{X}\hat{\Sigma}^{-1}\mathbf{X})^{-1}\mathbf{X}\hat{\Sigma}^{-1}G(\mathbf{P}). \tag{3}$$

이 때 제품의 수 S가 (1)의 각 식의 모델 파라미터의 수 q보다 커야  $\mathbf{b}$ 의 추정이 가능하다.

샘플수가 충분히 큰 경우에 다음 식 (4)에 주어진 잔차제곱합(Error Sum of Squares, SSE)은 점근적으로 자유도  $(S-q)(C-1)$ 인 chi-square 분포를 따른다[6]. 이 사실을 이용하여 모형의 적합도에 대한 검정을 수행할 수 있다[6].

$$SSE = [G(\mathbf{P}) - \mathbf{X}\mathbf{b}]' \hat{\Sigma}^{-1} [G(\mathbf{P}) - \mathbf{X}\mathbf{b}] \sim \chi^2_{(S-q)(C-1)}. \tag{4}$$

한편, 모델에 포함된 각 변수의 유의성을 검정하기 위한 절차는 다음과 같다. 모델에  $x_0, x_1, \dots, x_j$ 가 포함되었을 때의 SSE를  $SSE(t, 1, \dots, j)$ 라 하고  $x_i$ 를 제외했을 때의 SSE를  $SSE(1, \dots, j)$ 라 할 때

$$SSE(1, \dots, j) - SSE(t, 1, \dots, j) \quad (5)$$

를 검정 통계량으로 사용할 수 있으며, 이는 점근적으로 자유도  $C-1$ 인 chi-square 분포를 따른다[6].

CLM1의 분석을 위해서는 SAS 패키지의 CATMOD procedure를 이용할 수 있다[15]. CATMOD procedure는 모수의 추정 및 모델에 포함된 독립변수의 유의성 검정을 지원한다. 그러나 변수 선택 알고리즘을 지원하지는 않는다. 따라서 각 CA에 대해 유의한 EC를 선택하기 위해서는 CA에 영향을 미친다고 여겨지는 EC를 대상으로 식 (5)의 검정 통계량을 이용하여 일반 회귀분석에서 사용하는 여러 변수 선택 절차(예를 들어, forward selection, backward elimination, stepwise regression 등)와 유사한 절차를 따로 봐야 한다.

#### 4.1.2 MLE에 의한 분석

McCullagh[12]는 다음 모델을 제안하였다.

$$\begin{aligned} \ln\left[\frac{P_{k1}}{P_{k2} + \dots + P_{kc}}\right] &= \ln\left[\frac{F_{k1}}{1 - F_{k1}}\right] \\ &= \theta_1 + \beta_1 x_{k1} + \dots + \beta_{q-1} x_{k,q-1} + \varepsilon_{k1} \\ \ln\left[\frac{P_{k1} + P_{k2}}{P_{k3} + \dots + P_{kc}}\right] &= \ln\left[\frac{F_{k2}}{1 - F_{k2}}\right] \\ &= \theta_2 + \beta_1 x_{k1} + \dots + \beta_{q-1} x_{k,q-1} + \varepsilon_{k2} \\ &\vdots \\ \ln\left[\frac{P_{k1} + \dots + P_{k,C-1}}{P_{kc}}\right] &= \ln\left[\frac{F_{k,C-1}}{1 - F_{k,C-1}}\right] \\ &= \theta_{C-1} + \beta_1 x_{k1} + \dots + \beta_{q-1} x_{k,q-1} + \varepsilon_{k,C-1} \end{aligned} \quad (6)$$

이 모델은 식 (1)의 CLM1에서  $\beta_w = -\theta_r$  ( $r=1, \dots, C-1$ ),  $\beta_j = \dots = \beta_{r,C-1} = -\beta_j$  ( $j=1, \dots, q-1$ )로써 얻어질 수 있는 특수한 경우이다. 이와 같이 '동일한 독립변수 앞의 계수는  $(C-1)$ 개의 식에서 모두 같다'는 가정을 '평행선(parallel line)가정'이라 한다. 앞으로 이 모델을 CLM2라 부르기로 하자.

McCullagh는 'Fisher scoring' 방법을 사용하여 모수의 최우추정값을 얻는 과정을 보였다. 구해진 모수의 최우추정값을 식 (6)에 대입하면  $P_{kr}$ 의 참값인  $\pi_{kr}$ 의 최우추정값( $\hat{\pi}_{kr}$ )을 얻을 수 있다.

SAS의 LOGISTIC procedure는 CLM2의 분석을 지원하며, 모델에 포함된 독립변수 전체의 유의성 검정, 독립변수 각각의 유의성 검정, 평행선 가정의 검정 등을 위한 검정 통계량을 제공한다[15]. 한편 LOGISTIC procedure가 지원하는 여러 변수 선택 알고리즘을 이용하면 각 CA에 영향을 미치는 유의한 EC로 구성된 모델을 쉽게 얻을 수 있다.

그러나 LOGISTIC procedure의 단점은 모델 자체의 유의성을 검정하지는 않는다는 것이다. 모델의 유의성은 아무 제약이 없는 상황에서 최대우도량( $L_1$ )과 식 (6)의 모델하에서 최대우도량( $L_0$ )의 비를 이용한 우도비 검정을 통하여 수행할 수 있다[1]. 이 때 검정통계량은 다음과 같으며 점근적으로 자유도  $f = S(C-1) - (C-1+q-1)$ 인 chi-square 분포를 따른다[1][2].

$$-2\ln\Lambda = -2(\ln L_0 - \ln L_1) = 2 \sum_{k=1}^S \sum_{r=1}^C n_{kr} \ln \left[ \frac{n_{kr}}{\hat{m}_{kr}} \right] \quad (7)$$

식 (7)에서  $\hat{m}_{kr}$ 은  $n_{k+} \cdot \hat{\pi}_{kr}$ 으로서 주어지며 제안된 모델에서  $k$ 번째 제품에 대해 만족도를 조사했을 때  $r$ 번째 범주에 응답할 소비자 수의 추정값이다.  $-2\ln\Lambda$ 가  $\chi_{f,\alpha}^2$  보다 작으면  $100\alpha\%$  유의수준으로 모델이 적합하다는 가설을 기각하지 않는다.

이상에서 WLS와 MLE에 의한 두 모델의 모수 추정 및 다양한 검정통계량에 대해 살펴 보았다. CLM2는 평행선 가정을 채택하고 있으므로 CLM1보다 다양한 상황을 묘사하지 못하나, CLM2의 모수를 MLE에 의해 추정하는 것이 CLM1의 모수를 WLS로 추정하는 것보다 더 정



확하다고 알려져 있다[2]. 따라서 각 CA와 EC간의 관계를 분석할 때, 먼저 CLM2를 이용하여 분석하고 만일 이 모델이 기각되거나 평행선 가정이 받아들여지지 않는 경우에 다시 CLM1으로 분석하는 것이 바람직하다.

#### 4.2 제약식의 구성

CLM1 또는 CLM2의 분석을 통하여 CA<sub>i</sub>각에 대해 다음의 최종 모델을 얻었다고 하자.

$$\begin{aligned} \ln\left[\frac{1-\hat{F}_1^i}{\hat{F}_1^i}\right] &= h_1^i(\mathbf{x}_i) \\ &\vdots \\ \ln\left[\frac{1-\hat{F}_{C-1}^i}{\hat{F}_{C-1}^i}\right] &= h_{C-1}^i(\mathbf{x}_i) \end{aligned} \quad (8)$$

단,  $i=1, \dots, I$ 이다. 식 (8)에서

$\mathbf{x}_i$  : 분석 결과, CA<sub>i</sub>에 영향을 미치는 것으로 판단된 EC의 벡터,

$h_r^i(\mathbf{x}_i)$  : CLM2 또는 CLM1의 분석을 거쳐 얻어진 선형 모형,

$\hat{F}_r^i$  : CA<sub>i</sub>의 만족도에 대해  $r$ 번째 범주 이하로 응답할 비율의 추정값

이다.

식 (8)에서  $1-\hat{F}_r^i$ 는 CA<sub>i</sub>에 대해 소비자가  $r$ 번째 범주보다 큰 만족도를 보일 확률의 추정치이다. 이를 이용하면 각 CA<sub>i</sub>에 대해 ‘몇 %의 소비자를 어느 정도 이상 만족시키겠다’는 전략이 반영된 식을 구성할 수 있다. 즉, 특정 CA<sub>i</sub>에 대해  $100\tau\%$  이상의 소비자들을 범주  $r$ 을 넘도록 만족시키고자 한다면,

$$1-\hat{F}_r^i \geq \tau \quad (9)$$

와 같은 식을 구성할 수 있다. 식 (9)는 다음과 같이 쓸 수 있다.

$$(10) \quad \ln\left[\frac{1-\hat{F}_r^i}{\hat{F}_r^i}\right] = h_r^i(\mathbf{x}_i) \geq \ln\left[\frac{\tau}{1-\tau}\right]$$

즉, 식 (10)을 만족하도록  $\mathbf{x}_i$ 를 결정해야 한다.

각 CA<sub>i</sub>에 대해  $r$ 과  $\tau$ 의 결정은 회사의 전략에 따라 달라질 수 있지만, 공통된 것은 중요한 CA일수록 많은 소비자를 높은 수준으로 만족시켜야 한다는 것이다. 이 때 CA의 중요도는 소비자가 중요하다고 판단하는 정도와 경쟁 제품의 만족도 평가 정도의 두 가지 관점으로 판단할 수 있다. 즉, 각 CA<sub>i</sub>에 대한 중요도 조사로부터 많은 소비자가 중요하다고 판단하는 CA<sub>i</sub>에 대해서는 보다 많은 사람을 만족시켜야 하므로  $\tau$ 를 높게 선정하고, 만족도 조사에서 경쟁사 제품이 높은 수준의 범주에 높은 응답률을 보인다면  $r$  역시 높은 수준의 범주로 선택해야 한다. 구체적인  $r$ 과  $\tau$ 의 결정은 5절의 예제를 참고하기 바란다.

이렇게 해서 구성된 식 (10)을 최적화 모형의 제약식으로 채택함으로써 소비자의 요구와 회사의 전략이 동시에 반영된 대응 특성값을 결정할 수 있다. 대응 특성값을 결정할 때는 주어진 요구 조건을 만족하면서 가장 적은 비용을 필요로 하는 값을 선택하는 것이 바람직하다. 이를 위해서는 각 EC값에 따른 비용 함수를 파악할 필요가 있다.

#### 4.3 대응 특성의 비용 함수

##### 4.3.1 대응 특성이 연속형 변수인 경우

EC<sub>j</sub>가 취하는 값을  $x_j$ 라고 할 때 Derringer[5]가 제시한 호감도 함수(desirability function)를 이용하면  $x_j$ 에 따른 다양한 형태의 비용 함수를 표현할 수 있다. 단, Derringer는 0에서 1 사이의 값을 취하는 함수를 제시하였으므로 이를 최소

비용에서 최대 비용 사이의 값을 취하도록 스케일을 조정한다.  $x_j$ 의 비용 함수는


$$L_j : x_j \text{의 하한값} \quad U_j : x_j \text{의 상한값}$$

$$LC_j : \text{최소 비용} \quad UC_j : \text{최대 비용}$$

이라 할 때 다음과 같이 표현될 수 있다.

•  $x_j$ 가 클수록 비용이 증가하는 경우

$$Cost_j = (UC_j - LC_j) \left[ \frac{x_j - L_j}{U_j - L_j} \right]^\delta + LC_j \quad (11)$$



〈그림 3〉  $x_j$ 가 클수록 비용이 증가하는 경우

만일  $x_j$ 가 특정값  $t_j$ 에서 비용이 최대가 된다면  $x_j \leq t_j$ 일 때와  $x_j \geq t_j$ 인 두 경우로 나누어 각각 식 (11), (12)와 같은 비용 함수를 구성할 수 있다.


4.3.2 대응 특성이 이산형 변수인 경우

Cumulative logit model 상정시  $EC_j$ 가 이산형 변수인 경우에 가변수를 도입할 수 있다.  $EC_j$ 의 비용 함수 역시 이 가변수를 이용하여 구성할 수 있다. 예를 들어,  $EC_j$ 가 A, B, C의 3 수준을 취하는 이산형 변수라면 〈표 2〉와 같은 2개의 가변수  $z_1, z_2$ 를 생각할 수 있다.

•  $x_j$ 가 작을수록 비용이 증가하는 경우

$$Cost_j = (UC_j - LC_j) \left[ \frac{U_j - x_j}{U_j - L_j} \right]^\delta + LC_j \quad (12)$$

식 (11), (12)에서  $\delta$  값을 달리함으로써 다양한 형태의 함수를 표현할 수 있다. 예를 들어,  $1 \leq x_j \leq 10$ 이고 최소 비용이 10, 최대 비용이 100일 때, 〈그림 3〉, 〈그림 4〉에서 보는 것처럼  $\delta$  값에 따라 여러 형태의 비용 함수를 표현할 수 있다.



〈그림 4〉  $x_j$ 가 작을수록 비용이 증가하는 경우

〈표 2〉 가변수

	$z_1$	$z_2$
A	1	0
B	0	1
C	0	0

A, B, C의 각 수준에서  $a, b, c$ 의 비용이 든다고 하자. 비용 함수를  $Cost_j = l \cdot z_1 + m \cdot z_2 + n$ 이라 하면 A에서의 비용이  $l+n=a$ , B에서의 비용이  $m+n=b$ , C에서의 비용이  $n=c$ 이므로,  $l=a-c, m=b-c, n=c$ 가 된다. 따라서 비용 함수는 다음과 같이 표현된다.

$$Cost_i = (a-c)z_1 + (b-c)z_2 + c$$

$EC_i$ 가 2 또는 4개 이상의 수준을 취하는 이산형 변수인 경우에도 유사한 방법으로 비용 함수를 구성할 수 있다.

#### 4.4 최적 대응 특성값의 결정

각 CA와 EC간의 관계로 부터 구한 (10)의 제약식과 대응 특성의 비용 함수를 바탕으로 다음과 같은 최적화 모형을 구성한다.

$$\text{minimize } \sum_{j=1}^J Cost_j$$

s.t.

$$h_r^i(x_i) \geq \ln \left[ \frac{\tau_i}{1-\tau_i} \right], \quad i=1, \dots, I$$

$$L_j \leq x_j \leq U_j, \quad j=1, \dots, J$$

물리적인 법칙이나 기술적인 지식으로부터 EC사이의 관계식을 알고 있으면 이를 제약식에 추가하도록 한다.

위의 모형에서 목적식인 비용 함수는 종종 비선형 함수로 표현되며, cumulative logit model로부터 구한 제약식도 비선형식일 수 있다. 이 경우 위의 모형은 비선형 계획 문제가 된다. 특정  $EC_i$ 가 이산형 변수일 때는 가변수를 도입하게 되므로 비선형 혼합 정수 계획(nonlinear mixed in-

teger programming) 문제가 된다. 이 경우, 예를 들어 Gupta와 Ravindran[7]이 제시한 Branch and Bound 알고리즘을 이용하면 효율적으로 문제를 풀 수 있다. Branch and Bound 알고리즘 적용시 각 부분문제가 nonconvex 프로그래밍 문제가 되는 경우에는 각 부분문제의 국부 최적해가 전체 최적해를 보장하지 못하므로, nonconvex 프로그래밍 문제에서 사용하는 여러 방법, 예를 들어 서로 다른 초기해로 부터 국부 최적해를 구해 가장 좋은 것을 취하는 방법 등을 이용할 필요가 있다.

## 5. 예 제

본 절에서는 예제를 통하여 대응 특성의 최적 목표값을 결정하는 과정을 보이고자 한다. 예제의 자료는 가상적으로 만들어진 것이다. 4개의 소비자 요구품질( $CA_1 \sim CA_4$ )과 이에 영향을 미치는 7개의 제품 설계 변수( $EC_1 \sim EC_7$ )가 선정되었다고 하자. <표 3>은 7개 제품에 대한 각 EC의 실측값이다. 먼저 <표 3>의 자료를 바탕으로 각 CA와 EC간의 관계를 알아 보자. 단, CLM2를 이용하여 분석한 후, 모델이 유의하지 않거나 평행선 가정이 받아들여지지 않는 경우에 CLM1으로 분석하기로 한다.

<표 3> EC의 실측값

제품	$EC_1$	$EC_2$	$EC_3$	$EC_4$	$EC_5$	$EC_6$	$EC_7$
1	9.2	2.1	3.5	5.0	9.3	P	S
2	10.0	3.3	2.2	3.5	8.5	P	S
3	11.1	4.5	1.2	1.0	4.3	P	T
4	8.2	2.6	3.4	6.5	2.1	R	T
5	10.5	3.7	2.4	1.9	6.7	Q	S
6	9.5	4.8	1.8	4.7	3.9	Q	S
7	10.5	5.5	0.7	2.1	3.2	P	S

<표4>  $CA_1$ 의 만족도

제품	만족도					합
	1	2	3	4	5	
1	36	25	21	11	7	100
2	35	19	25	13	8	100
3	49	24	21	3	3	100
4	26	30	18	16	10	100
5	16	24	20	23	17	100
6	39	29	24	6	2	100
7	30	30	18	15	7	100

[단계1] 각 CA와 EC간의 관계 분석 및 제약식 구성

먼저 CA<sub>1</sub>의 만족도를 조사하여 <표 4>의 결과를 얻었다고 하자. CA<sub>1</sub>에 영향을 미친다고 생각되는 EC는 EC<sub>1</sub>, EC<sub>4</sub>, EC<sub>5</sub>이다. 이 중에 EC<sub>1</sub>은 기존의 경험에 비추어 볼 때 값이 증가하면 만족도의 증가율이 급격히 커지며, EC<sub>4</sub>와 음의 상관관계가 있을 지도 모른다는 의견이 있었으므로, x<sub>1</sub><sup>2</sup>, x<sub>1</sub>, x<sub>4</sub>, x<sub>5</sub>, x<sub>1</sub>x<sub>4</sub>를 모델에 포함하기로 하였다. 이 모델을 CLM2로 분석하기 위해 LOGISTIC procedure의 변수 선택 알고리즘을 이용하여 분석한 결과, 이 중 x<sub>5</sub>와 x<sub>1</sub>x<sub>4</sub>는 유의하지 않은 것으로 판명되었다. 선택된 최종 모델은 다음과 같다.

$$\ln\left[\frac{\hat{F}_1^1}{1-\hat{F}_1^1}\right] = -0.6879 + 0.5416x_1^2 - 6.1428x_1 + 2.1063x_4,$$

$$\ln\left[\frac{\hat{F}_2^1}{1-\hat{F}_2^1}\right] = 0.4200 + 0.5416x_1^2 - 6.1428x_1 + 2.1063x_4,$$

$$\ln\left[\frac{\hat{F}_3^1}{1-\hat{F}_3^1}\right] = 1.4847 + 0.5416x_1^2 - 6.1428x_1 + 2.1063x_4,$$

$$\ln\left[\frac{\hat{F}_4^1}{1-\hat{F}_4^1}\right] = 2.6172 + 0.5416x_1^2 - 6.1428x_1 + 2.1063x_4.$$

식 (7)의 검정통계량에 의한 모델 유의성 검정의 p-value는 약 0.15이었으며 평행선 검정에 대한 p-value도 0.1073이었으므로 위 모델을 기각하지 않는다.

한편, CA<sub>1</sub>의 중요도 조사 결과가 <표 5>와 같이 얻어졌다고 하자.

<표 5> CA<sub>1</sub>의 중요도

중요도					
1	2	3	4	5	
7	10	22	38	23	100

<표 5>로부터 61%의 소비자가 CA<sub>1</sub>을 중요한 요구품질로 평가함을 알 수 있다. 그런데 가장 높은 만족 수준을 보이는 제품 5가 이미 3이상의 범주에 60%의 소비자를 만족시키고 있으므로(표 4 참조), CA<sub>1</sub>을 중요하다고 판단하는 61%의 소비자를 최소한 제품 5만큼, 혹은 그보다 더 만족시키려면 범주는 3이상이 되어 한다. 즉 다음과 같은 제약식을 꾸밀 수 있다.

$$1 - F_2^1 \geq 0.61.$$

최종 제약식은 다음과 같다.

$$\begin{aligned} \ln\left[\frac{1-\hat{F}_2^1}{\hat{F}_2^1}\right] &= -\ln\left[\frac{\hat{F}_2^1}{1-\hat{F}_2^1}\right] \\ &= -0.4200 - 0.5416x_1^2 + 6.1428x_1 \\ &\quad - 2.1063x_4 \geq \ln\left[\frac{0.61}{1-0.61}\right] \end{aligned} \tag{13}$$

CA<sub>2</sub>~CA<sub>4</sub>에 대해서도 유사하게 분석하여 다음의 세 식을 얻었다고 하자.

$$\begin{aligned} -11.5751 + 1.3336x_2 + 1.2104x_3 + 0.2652x_2x_3 \\ \geq \ln\left[\frac{0.39}{1-0.39}\right], \end{aligned} \tag{14}$$

$$\begin{aligned} 1.94 + 0.85x_4^2 - 6.15x_4 + 3.45z_1 + 2.66z_2 + 2.70z_3 \\ \geq \ln\left[\frac{0.82}{1-0.82}\right], \end{aligned} \tag{15}$$

$$\begin{aligned} -4.4260 + 0.5877x_2 + 0.8237\sqrt{x_5} + 1.8442z_3 \\ \geq \ln\left[\frac{0.75}{1-0.75}\right]. \end{aligned} \tag{16}$$

[단계 2] 각 EC의 비용 함수

EC<sub>1</sub>은 값이 감소할수록 비용이 증가한다고 가정하고 식 (12)에서 제시된 비용 함수를, EC<sub>2</sub>~EC<sub>5</sub>는 값이 증가할수록 비용이 증가한다고 가정하고 식 (11)의 비용 함수를 이용하기로 한다. 기존의 경험으로부터 비용 함수의 형태를 추정하여 적절한 δ 값을 결정한 결과 다음의 비용 함수를 구성했다고 하자.

$$\begin{aligned}
 Cost_1 &= (55-25) \left[ \frac{12-x_1}{12-8} \right]^2 + 25, & 8 \leq x_1 \leq 12 \\
 Cost_2 &= (95-55) \left[ \frac{x_2-2}{7-2} \right]^3 + 55, & 2 \leq x_2 \leq 7 \\
 Cost_3 &= (27-12) \left[ \frac{x_3-0}{5-0} \right] + 12, & 0 \leq x_3 \leq 5 \\
 Cost_4 &= (48-23) \left[ \frac{x_4-1}{7-1} \right]^2 + 23, & 1 \leq x_4 \leq 7 \\
 Cost_5 &= (26-14) \left[ \frac{x_5-2}{10-2} \right] + 14, & 2 \leq x_5 \leq 10
 \end{aligned}$$

$EC_6$ 과  $EC_7$ 은 이산형 변수이므로 각각 <표 6>과 <표 7>의 가변수를 도입하기로 한다. 이 때  $EC_6$ 과  $EC_7$ 의 비용함수는 다음과 같이 표현할 수 있다.

$$\begin{aligned}
 Cost_6 &= (46-12)z_1 + (23-12)z_2 + 12 = 34z_1 + 11z_2 + 12, \\
 Cost_7 &= (74-32)z_3 + 32 = 42z_3 + 32.
 \end{aligned}$$

<표 6>  $EC_6$ 의 가변수      <표 7>  $EC_7$ 의 가변수

$EC_6$	$z_1$	$z_2$	비용
P	1	0	46
Q	0	1	23
R	0	0	12

$EC_7$	$z_3$	비용
S	1	74
T	0	32

[단계3] 최적 대용 특성값 결정

식 (13)~(16)을 제약식으로,  $Cost_1 \sim Cost_7$ 의 합을 목적식으로 하여 최적화 모형을 세울 수 있다. 이 때 모형은 비선형 혼합 정수 프로그래밍 모형이므로 Branch and Bound 알고리즘을 이용하여 최적해를 찾을 수 있다. 각 부분 문제는 nonconvex 프로그래밍 문제로서, 각 부분 문제의 국부 최적해를 찾기 위해 Generalized Reduced Gradient 방법을 적용하는 GINO 패키지를 이용하였다[9]. 대용 특성의 최적해는  $x_1^*=10.8$ ,  $x_2^*=4.8$ ,  $x_3^*=1.9$ ,  $x_4^*=1.0$ ,  $x_5^*=6.5$ ,  $z_1^*=0$ ,  $z_2^*=1$ (즉,  $x_6='Q'$ ),  $z_3^*=1$ (즉,  $x_7='S'$ )이다. 구해진 대용 특성의 최적해는 다음 단계인 부품 기획 단계의 'What' 항목의 목표값이 된다.

## 6. 결 론

지금까지 제품 기획 단계의 HOQ를 중심으로 QFD의 분석 방안에 대하여 살펴보았다. 제품 기획 단계에서 적절한 대용 특성값을 결정하는 것은 매우 중요하다. 부적절한 값이 대용 특성의 목표값으로 결정되는 경우 이를 달성하기 위한 이후 단계에서의 노력이 무의미해지기 때문이다. 그리고 더욱 중요한 것은 대용 특성이 소비자의 인식과 직접 연결된다는 사실이다. 지금까지 제시된 방법은 분석 과정이 주관적이고 정성적인 판단에 의존하는 부분이 많았기 때문에 잘못된 의사결정을 내리거나 QFD의 활용이 유명무실해질 가능성이 높았다. 본 연구에서 제시된 방법은 이러한 주관성을 가능한 한 배제하고 보다 체계적으로 대용 특성값을 결정할 수 있는 접근 방법이라 할 수 있다.

소비자의 요구가 최종 제품으로 정확하게 구현되기 위해서는 제품 기획 단계에서 결정된 사항이 부품 기획, 공정 기획 및 생산 기획 단계로 정확하게 전개되어야 한다. 이러한 단계에서 실험계획법이나 여러 통계적 품질관리 기법이 사용될 수 있으며 앞으로 폭 넓은 연구가 요구되는 부분이다. 한편 최근에 품질의 전개와 아울러 비용 전개, 신뢰성 전개, 기술 전개 등이 제시되고 있는데 앞으로 이들을 결합할 수 있는 이론적 체계화 과정과 구체적 운용 방안이 강구되어야 할 것이다.

## 참 고 문 헌

[1] 변 은신, "품질 기능 전개를 통한 대용 특성의 결정 방법에 관한 연구", 「한국과학기술원」, 석사논문, 1996.  
 [2] Agresti, A. *Categorical Data Analysis*, Wiley, New York, 1990.

- [3] Akao, Y. *Quality Function Deployment: Integrating Customer Requirements into Product Design*, Productivity press, Portland, Oregon, 1990.
- [4] Day, R.G. *Quality Function Deployment: Linking a Company with Its Customers*, ASQC Quality Progress, Milwaukee, Wisconsin, 1993.
- [5] Derringer, G., "Simultaneous optimization of several response variables," *Journal of Quality Technology*, Vol. 12, No. 4 (1980), pp. 214-219.
- [6] Grizzle, J. E., Starmer, C. F. and Koch, G.G., "Analysis of categorical data analysis," *Biometrics*, Vol. 25, No. 3(1969), pp. 489-504.
- [7] Gupta, O. K. and Ravindran A., Branch and bound experiments in convex non-linear programming, *Management Science*, Vol. 31, No. 12(1985), pp. 1533-1546.
- [8] Hauser, J.R. and Clausing, D., "The house of quality", *Harvard Business Review*, Vol. 66, No. 3(1988), pp. 63-73.
- [9] Liebman, J., Lasdon, L., Schrage, L. and Waren, A., *A Modeling and Optimization with GINO*, Scientific Press, Palo Alto, California, 1985.
- [10] Lyman, Dilworth. Deployment Normalization, *Transactions from A Second Symposium on Quality Function Deployment*, (1990), pp. 307-315.
- [11] Maduri, O., "Design Planning of an off-highway dump truck: a QFD approach", *Quality Through Engineering Design*, (1993), pp. 97-104.
- [12] McCullagh, P., Regression models for ordinal data(with discussion), *Journal of Royal Statistical Society(series B)*, Vol. 42, No. 2(1980), pp. 109-142.
- [13] Moskowitz, H. and Kim, K.W., "QFD Optimizer: a novice friendly quality function deployment decision support system for optimizing product design", *Working Paper*, 1995.
- [14] Sullivan, L.P., "Quality function deployment", *Quality Progress*, Vol. 19, No. 6 (1986), pp. 39-50.
- [15] *SAS/STAT User's Guide*, Version 6, Fourth edition, Volume 2, SAS institute, Cary, North Calolina.
- [16] Wasserman, G.S., On how to prioritize design requirements during the QFD process, *IIE Transactions*, Vol. 25, No. 3 (1993), pp. 59-65.