▩ 연구논문

몬테칼로 씨뮬레이션을 통한 SN비의 효율성비교[+]

임용빈
이화여자대학교 통계학과
이영조
서울대학교 계산통계학과

Efficiency Comparison of Signal-to-Noise Ratios through Monte Carlo Simulations

Yong Bin Lim
Dept. of Statistics, Ewha Womans University
Youngjo Lee
Dept. of Computer Sciences and Statistics, Seoul National University

Abstract

For quality improvement, Taguchi emphasizes the reduction of variation of the quality characteristic. Taguchi has used the signal-to-noise ratios for achieving minimum dispersion of the quality characteristic with its location adjusted to some desired target value τ. Lim(1994) proposes a reasonable *SN* ratio based on a linking relationship of the variance and mean through simple data analysis technique. In this paper we investigate the efficiency of those two *SN* ratios and variance stablizing transformations through Monte Carlo Simulations.

+ 이 논문은 1994년도 문교부 기초과학연구비 지원(과제번호 BSRI-94-1415)에 의한 연구결과임.

1. 서론

제품의 품질특성치가 망목특성인 경우에 품질공학에서의 가장 중요한 목표는 품질특성치의 산포를 작게하면서, 평균을 목표치에 근접시키는 것이다. 품질특성치에 영향을 주는 요인들은 실험자가 그 값들을 제어할 수 있는 설계인자(design factors; x)와 제품의 사용환경조건, 제조 또는 공정 주위 환경조건 등과 같이 실험자가 제어할 수 없는 인자인 잡음인자(noise factors; z)로 분류된다. 설계인자 중에서 제어에 비용이 많이 들어서 제어를 하지 않으면 잡음인자로 분류한다. 실제 공정에서는 잡음인자들을 제어하지 않지만, 다구찌(Taguchi)는 제어인자의 실험조건들이 잡음인자들에 미치는 영향을 평가하기 위해서 제어인자들의 각각의 실험조건에서 잡음인자의 배치를 인위적으로 실험계획에 포함시켜서, 실험실에서 실험을 할 때에 제어인자는 물론 잡음인자들도 제어시킨 점이 품질공학을 위한 실험계획법분야에서의 다구찌의 가장 큰 업적의 하나이다. 다구찌는 직교배열표를 이용하여 선택된 각각의 설계인자들의 실험조건에서 모든 잡음인자의 배치에 대한 실험을 실시하는, 설계인자의 배치와 잡음인자의 배치의 교적실험(product array)을 제안하였다. 제조공정과정에서의 잡음인자(z)의 변화가 품질특성치의 변동을 초래한다. 평균을 목표치에 근접시키는 여러개의 설계인자들의 실험조건들이 존재하면, 그 중에서 잡음인자의 변화에 영향을 가장 적게 받는, 즉 품질특성치의 산포를 가장 작게 하는 설계인자들의 조건을 찾는 것이 다구찌 방법의 기본 개념이다.

산포를 제어하는 인자를 찾기 위해서 다구찌(1987)는

$$SN = 10 \log \frac{\mu^2}{\sigma_y^2} \tag{1.1}$$

을 정의하고, 각각의 설계인자들의 실험조건에서의 SN비를

$$(SN)_i = 10 \log \frac{\bar{y}_i^2}{s_i^2} \tag{1.2}$$

으로 추정하였다. 여기서 μ와 σ_y^2은 각각의 설계인자들의 실험조건에서의 특성치의 평균과 분산이고, $\bar{y}_i$와 s_i^2은 설계인자들의 i번째 실험조건에서 실시된 n개의 잡음인자의 배치에서 얻어진 특성치 $y_{i1}, \cdots, y_{in}$의 자료평균과 자료분산이다. $(SN)_i$를 최대로 하는 실험조건이 산포를 가장 작게 하는 조건이고, 나머지 설계인자들 중에서 평균에 영향을 주는 인자들를 찾아내어 평균치를 목표치에 근접시키는 이단계 최적조건을 찾는 방법을 제시하였다.

Leon, Shoemaker & Kacker(1987)와 Box(1988)는 일반적으로 특성치의 분산 σ_y^2이 평균 μ에 함수적으로 종속되어서 분산과 평균의 관계가 $\sigma_y^2 \propto [f(\mu)]^2$로 주어지는 경우에

$$P(d) = \frac{\sigma_y^2(x)}{[f(\mu(x))]^2} \tag{1.3}$$

의 최소화와 평균을 목표치에 근접시키는 이단계 최적조건의 발견이 품질특성치 y의 목표치 τ에 관한 평균제곱오차(MSE) 인 $M=E(y-\tau)^2$을 최소로 한다는 사실을 보여 주었다. 여기서 $x=(d, a)$로 d는 설계인자들 중의 일부이고, 나머지 설계인자들에 해당되는 a로 평균의 조정이 가능하다고 가정한다. $P(d)$는 산포특성치(a measure of dispersion)로 평균에 독립인 산포를 나타내는 특성치가 되어서 PerMIA(Performance Measure Independent of Adjustment) 라고 불리운다. 승법모형

$$y(d, a) = \mu(d, a)\varepsilon(z, d) \tag{1.4}$$

이 실제모형인 경우, 즉 평균과 분산의 관계가 $\sigma_y^2(d, a) \propto \mu^2(d, a)$인 경우에 $P(d)=\sigma_y^2(d, a)/\mu^2(d, a)$가 되어서 식 (1.1)에서 정의된 다구찌의 SN과 비교할 때에

$$SN = -10 \log P(d) \tag{1.5}$$

가 성립한다. 따라서 $P(d)$의 최소화는 SN의 최대화와 동치이고, 승법모형의 경우에 다구찌의 이단계 최적화 방법이 평균제곱오차를 최소화하여 이차손실함수를 가정한 경우의 기대손실을 최소화한다는 다구찌 방법에 대한 이론적 근거를 최초로 제시하였다.

실제문제에서 분산과 평균의 종속관계인 $\sigma_y^2/[f(\mu)]^2$는 일반적으로 알려져 있지 않다. Box(1988)는 $Y=h(y)$가 분산안정변환(variance stabilizing transformation)일 경우에 $P(d)$의 최소화는 $\sigma_Y^2(d)$의 최소화와 동치가 되어서 산포에 영향을 주는 산포제어인자는 $\sigma_Y^2(d)$에 영향을 주는 인자라는 사실을 보여 주었다. 또한 실험자료에 근거하여 분산안정변환을 선택하기위해서 각각의 멱변환(power transformation)

$$Y = \begin{cases} y^{\lambda} & \text{if} \quad \lambda \neq 0 \\ \log y & \text{if} \quad \lambda = 0 \end{cases}$$

에 대해서, 각각의 설계인자의 실험조건에서의 변환된 자료의 평균을 새로운 특성치로 하여서 각각의 평균효과들에 대한 t-값을 계산하고, 변환된 자료의 표본분산에 로그를 취한 값을 특성치로 해서 각각의 산포효과들에 대한 t-값을 계산하여서 평균효과와 산포효과에 대한 lambda plots 을 각각 그린 후에, 모형의 간단성(parsimony)과 분산과 평균의 분리성(separation)의 원칙에 근거하여 분산안정변환에 해당되는 λ^*를 선택하는 것을 제안하였다.

임용빈(1994)은 분산안정변환에 대응되는 λ^*를 선택하기 위해서 간단한 자료분석적 기법인 변환된 자료의 평균과 표준편차의 산점도를 이용하였다. 5개의 멱변환(power transformation) $Y=y^{\lambda}$, $\lambda=1, .5, 0, -.5, -1$에 의해 변환된 자료들을 가지고, 각각의 설계인자들의 실험조건에서 계산된 자료평균과 자료표준편차의 산점도를 검토하여, 변환된 자료의 평균과 표준편차의 표본상관계수의 크기를 참조하여서, 변환된 자료평균과 자료표준편차가 함수적으로 독립인 관계처럼 보이는 멱변환을 선택하여, 그에 대응되는 $(SN)_i = 10 \log \bar{y}_i^{2(1-\lambda^*)}/s_i^2$을 합리적 SN비의 추정치로 사용할 것을 제안하였다.

이 논문의 목적은 몬테칼로 씨뮬레이션을 이용하여 산포제어인자를 분류하는 방법들의 효율성을 비교하는 것이다. 2절에서는 4개의 산포제어인자를 분류하는 방법이 소개되고, 3절에서는 Box(1988)에서와 같은 방법으로 자료를 생성하는 과정을 소개한다. 9개의 각각의 분산안정변환에 대해서 1000개의 자료들을 생성하여 각각의 분류방법에 대해서 유의수준 0.05에서 고려한 산포제어인자만을 올바르게 찾아낸 횟수를 누적하여 효율성을 계산한다. 4절에서는 몬테칼로 씨뮬레이션의 결과를 간략하게 요약하였다.

2. 산포제어인자를 분류하는 방법

분산안정변환이 알려졌을 경우에 변환된 자료의 분산의 최소화와 합리적 *SN*비의 최대화는 동치이지만, 실험자료에 근거한 효율적인 추정방법은 합리적 *SN*비의 추정치인 $(SN)_i = 10 \log \bar{y}_i^{2(1-\lambda^*)} / s_i^2$ 보다도 변환된 자료의 표본분산이 더 효율적이라는 사실이 통계적으로 잘 알려져 있다. 기술자들이 다구찌의 *SN*비에 익숙한 점을 고려하여 산포제어인자를 분류하는 4가지 방법의 효율성을 비교하고자 한다. 각 방법의 각각의 내측배열의 실험조건에서의 산포제어인자를 분류하기 위한 산포특성치는 다음과 같다.

방법 1. 임용빈(1994)에 의해서 제시된 합리적 *SN*비의 추정치인

$$(SN)_i = 10 \log \frac{\bar{y}_i^{2(1-\lambda^*)}}{s_i^2} \tag{2.1}$$

이다. λ^*의 선택 방법을 계량화하기 위해서 λ를 -1.4에서 1.4까지 0.02 간격으로 취해서, 그 중에서 변환된 자료의 평균과 표준편차의 표본상관계수의 크기가 가장 작은 λ값을 λ^*로 선택한다.

방법 2. 방법 1에서 결정된 분산안정변환으로 기대되는 $Y = y^{\lambda^*}$로 모든 자료를 변환한 후에, 각각의 설계인자의 실험조건에서 변환된 자료의 표본분산을 로그로 취한 값인 $\log s_{Y_i}^2$을 특성치로 한다.

방법 3. 다구찌의 $(SN)_i$인

$$(SN)_i = 10 \log \frac{\bar{y}_i^2}{s_i^2} \tag{2.2}$$

이다.

방법 4. 모든 자료를 다구찌의 *SN*비에 대응되는 변환인 $Y = \log y$로 변환한 후에, 각각의 설계인자의 실험조건에서 변환된 자료의 표본분산을 로그로 취한 값을 특성치로 한다.

3. 몬테칼로 씨뮬레이션

Box(1988)에서와 같은 방법으로 자료를 생성한다. 8개의 제어인자 A, B, C, D, E, F, G, H에 대한 실험계획인 내측배열은 $L_{16}(2^{15})$ 직교배열표이고, 각각의 인자를 8, 4, 2, 1, 14, 13, 11, 7열에 배치하여 내측배열이 주효과와 2인자 교호작용효과가 서로 교락되지 않는 2^{8-4}_{IV} 부분실시법이 되게 한다. 잡음인자들의 배치에 해당되는 외측배열은 단순한 반복으로 반복의 크기는 4로 하여 16개의 각각의 내측배열의 실험조건에서 각각 4회씩 반복하는 실험을 계획한다. 변환 $Y=y^{\lambda^0}$, $\lambda^0=-1, -.75, -.5, -.25, 0, .25, .5, .75, 1$에서 모형이 간단하게 표현되는 것(additive model)을 가정한다. 평균에 영향을 미치는 3 개의 주효과와 산포에 영향을 주는 인자가 1 개인 경우와 2개인 경우를 고려한다.

(1) 산포에 영향을 주는 인자가 1개인 경우

변환 $Y=y^{\lambda^0}$에서 전체 모평균 $\mu=5$, 평균에 영향을 미치는 3개의 주효과(location main effects) $B=-3$, $D=2$, $G=-2$와 1개의 산포에 영향을 주는 효과(dispersion main effects)인 D의 1수준에서의 표준편차를 .75, 0수준에서의 표준편차를 .25로 가정하여 두 수준에서의 분산비를 3^2으로 한다. 따라서 $Y=y^{\lambda^0}$ 자료가 생성되는 모형은

$$y_{ijkl}^{\lambda^0} = \mu + b_i + d_j + g_k + \varepsilon_{ijkl} \tag{3.1}$$

이다. 여기서 $\varepsilon_{i1kl} \sim N(0, .75^2)$ 이고 $\varepsilon_{i0kl} \sim N(0, .25^2)$이다. 예를 들어서 내측배열의 1번 실험조건의 모집단은 유의한 인자들만의 수준결합이 $B_0D_0G_0$ 이기에 평균이 $E(y_{000l}^{\lambda^0})$ $=5+1.5+(-1)+1.5=7$ 이고, 분산이 0.25^2인 정규분포가 되어서 $N(7, .25^2)$로부터 난수를 4개 생성하여 4개의 관측치가 결정된다. 마찬가지 방법으로 내측배열의 나머지 15개 실험조건에서 관측치를 각각 4개씩 얻는다. 원래 단위의 자료인 y를 얻기 위해서 역변환을 취한다. 예를 들어서 $\lambda^0=-1$ 경우에 16×4 각각의 관측치에 역수를 취해줌으로 원래 단위로 표시된 자료를 얻는다. 2절에서 설명한 4가지 방법에 의해서 얻어진 내측배열의 16개 실험조건에서의 산포특성치를 계산하여 분산분석을 한 후에 유의수준 0.05에서 인자 D만을 유일한 인자로 분류하는 경우에는 그 방법이 산포제어인자를 올바로 분류하였다고 한다. SAS의 PROC IML을 이용하여 동일한 씨뮬레이션을 1000회 반복하여 각 방법이 올바르게 산포제어인자로 인자 D만을 분류한 비율을 계산한 결과가 〈표 3.2〉에 주어진다. 참고로 인자 D를 산포제어인자로 분류하는 경우(인자 D 이외의 다른 인자를 산포제어인자로 포함할 수도 있음)의 비율을 가로안의 숫자로 나열한다.

씨뮬레이션에서 가정된 모형 (3.1)의 내측배열에서의 실험조건에서의 분산은 분산에 로그를 취한 값에 대해서 additive model 인

$$\log Var(y_{ijkl}^{\lambda^0}) = \log \sigma^2 + d_j^* \tag{3.2}$$

에 의해서 결정된다고 생각할 수 있다. 여기서 일원배치법에서와 같이 $d_0^*+d_1^*=0$를 가

정한다. D_1에서의 분산 $.75^2$과 D_0에서의 분산 $.25^2$을 식 (3.2)에 대입하면

$$\log .25^2 = \log \sigma^2 + d_0^*$$
$$\log .75^2 = \log \sigma^2 + d_1^*$$

을 얻는다. 위 식을 풀면, $d_1^* = \log 3$, $d_0^* = -\log 3$이 되어서 이 경우에 산포효과인 D^*는 $2 \log 3$이 되고, 총분산 σ^2은 D_1에서의 분산과 D_0에서의 분산의 기하평균인 3/16 이 된다. 따라서 모형 (3.1)에서 총평균 $\mu = 5$인 경우에 변동계수는 $CV = 8.66\%$ 이다. 변동계수가 작아짐에 따라서 4가지 방법의 효율성을 비교하기 위해서 $\mu = 7$, 10, 50 ($CV = 6.19$, 4.33, 0.87%)인 경우에 대해서 $\mu = 5$인 경우와 마찬가지로 동일한 씨뮬레이션을 1000회 반복하여 효율성을 비교한 결과가 〈표 3.2〉, 〈표 3.3〉, 〈표 3.4〉, 〈표 3.5〉 에 정리되어 있다.

〈표 3.3〉, 〈표 3.4〉, 〈표 3.5〉 에 주어진 산포제어인자 D만을 올바르게 산포제어인자로 분류하는 각 방법의 효율을 비교하여 보자. 먼저 $\lambda^0 = 0$에 해당되는 로그변환을 제외하고 비교하자. 변환된 변수의 $CV = 8.66\%$ 에 해당되는 $\mu = 5$인 경우에, 분산안정변환을 추정하여 결정된 방법1과 방법2의 효율성이 48% 근처이지만, 다구찌의 SN비와 관련된 방법3과 방법4의 효율성은 9% 내외로 방법1과 방법2가 훨씬 더 효율적임을 알 수 있다. $CV = 6.19\%$ 에 해당되는 $\mu = 7$인 경우와 $CV = 4.33\%$ 에 해당되는 $\mu = 10$인 경우에, 방법1, 2의 효율은 $\mu = 5$인 경우와 별로 차이가 없지만, 방법3, 4의 효율은 32%, 53% 근처로 효율이 상당히 향상되어서 $CV = 4.33\%$ 에 해당되는 $\mu = 10$인 경우에는 방법3, 4의 효율이 방법1, 2의 효율보다 모든 변환에 대해서 우수하다. $CV = 0.87\%$ 에 해당되는 $\mu = 50$인 경우에 방법1, 2의 효율은 65% 근처이고, 방법3, 4의 효율은 72% 근처로 $\mu = 10$인 경우와 마찬가지로 방법3, 4의 효율이 방법1, 2의 효율보다 모든 변환에 대해서 우수하다. 4가지 각각의 경우에 방법1과 방법2, 방법3과 방법4의 일율적인 비교는 효율의 측면에서는 서로 대등해 보인다. λ^0일 경우에는 다구찌의 SN비에 해당되는 방법3의 효율이 대략 72% 근처로 기대했던대로 로그변환된 자료의 표본분산에 로그를 취하는 방법인 방법4보다 효율이 약간 떨어지지만, 합리적 SN비의 추정에 근거한 방법인 방법1의 효율인 약 44% 보다 우수하다.

인자 D를 산포제어인자로 분류하는 경우(인자 D 이외의 다른 인자를 산포제어인자로 포함할 수도 있음)의 효율은 방법1, 2가 85% 근처이고 방법3, 4가 $CV = 8.66\%$ 에 해당되는 $\mu = 5$인 경우의 53% 정도에서 $CV = 4.33\%$ 에 해당되는 $\mu = 10$인 경우에는 88% 근처로 향상되고, $CV = 0.87\%$ 에 해당되는 $\mu = 50$인 경우에는 약 95%로 인자 D만을 올바르게 분류하는 효율보다 훨씬 큰 값을 갖는다.

(2) 산포에 영향을 주는 인자가 2개인 경우

변환 $Y = y^{\lambda^0}$에서 전체 모평균 $\mu = 7$, 평균에 영향을 미치는 3개의 주효과(location main effects) $B = -3$, $D = 2$, $G = -2$와 2개의 산포에 영향을 주는 효과(dispersion main effects)인 D와 H의 각 수준에서의 분산비를 각각 3^2과 2^2으로 한다. 분산에 대한 모형은

$$\log Var(y_{ijklm}^{\lambda 0}) = \log \sigma^2 + d_j^* + h_l^* \qquad (3.3)$$

이다. 여기서 총분산 σ^2은 산포제어인자가 1개인 경우의 모형 (3.2)에서와 같이 $\sigma^2 = 3/16$이고, $d_0^* = -\log 3$, $d_1^* = \log 3$, $h_0^* = -\log 2$, $h_1^* = \log 2$ 이다. D와 H의 실험조건에서의 분산을 구하면, 〈표 3.1〉과 같다. 따라서 내측배열의 16개 실험조건에서의 특성치의 평균은 모형 (3.1)에서와 같이 인자 B, D, G의 수준값에 따라서 결정되고, 분산은 각 조건에서의 인자 D와 H의 수준값에 따라서 〈표 3.1〉에 주어진 값으로 결정되어 각 내측배열에서의 4개의 관측치의 값이 얻어진다. 예를 들어서 내측배열의 1번 실험조건의 모집단을 결정하는 유의한 인자들의 수준결합은 $B_0 D_0 G_0 H_0$ 이어서 모집단의 평균이 $7+1.5-1+1.5=9$이고, 표준편차가 $1/\sqrt{32}$ 이다. 전체모평균이 5인 경우에는 $B_1 D_1 G_1 H_1$ 에서 특성치의 분포가 평균이 3, 표준편차가 $3/\sqrt{8}$ 인 정규분포를 따르게 되어서 특성치가 음수가 나올 수도 있기에 전체모평균을 $\mu=7$으로 한다.

〈 표 3.1 〉 D와 H의 실험조건에서의 분산

	D_0	D_1
H_0	1/32	9/32
H_1	1/8	9/8

산포에 영향을 주는 인자가 1개인 경우와 마찬가지로 역변환을 취하여 원래단위인 y로 표시된 자료를 얻고, 각각의 산포제어인자 분류방법의 효율성을 1000회의 씨뮬레이션에 근거하여 계산한다. 변동계수가 작아짐에 따라서 4가지 방법의 효율성을 비교하기 위해서 $\mu=10$, 50인 경우에 대해서 $\mu=7$인 경우와 마찬가지로 동일한 씨뮬레이션을 1000회 반복하여 효율성을 비교한 결과가 〈표 3.6〉, 〈표 3.7〉, 〈표 3.8〉에 정리되어 있다.

〈표 3.6〉, 〈표 3.7〉, 〈표 3.8〉에 주어진 산포제어인자 D와 H만을 올바르게 산포제어인자로 분류하는 각 방법의 효율을 비교하여 보자. 먼저 $\lambda^0=0$에 해당되는 로그변환을 제외하고 비교하자. 변환된 변수의 $CV=6.19\%$에 해당되는 $\mu=7$인 경우에, 분산안정변환을 추정하여 결정된 방법1과 방법2의 효율성이 32% 근처이지만, 다구찌의 SN비와 관련된 방법3과 방법4의 효율성은 22% 내외로 방법1, 2가 더 효율적임을 알 수 있다. $CV=4.33\%$에 해당되는 $\mu=10$인 경우에, 방법1, 2의 효율은 $\mu=7$인 경우와 별로 차이가 없지만, 방법3, 4의 효율은 34% 근처로 효율이 상당히 향상되어서 방법3, 4의 효율이 방법1, 2의 효율보다 대부분의 변환에 대해서 약간 우월하다. $CV=0.87\%$에 해당되는 $\mu=50$인 경우에 방법1, 2의 효율은 46% 근처이고, 방법3, 4의 효율은 51% 근처로 산포제어인자가 1개인 경우와 마찬가지로 방법3, 4의 효율이 방법1, 2의 효율보다 모든 변환에 대해서 우수하다. 물론 $\lambda^0=0$일 경우에는 다구찌의 SN비에 해당되는 방법3의 효율이 대략 48% 근처로 기대했던대로 로그변환된 자료의 표본분산에 로그를 취하는 방법인 방법4 보다 효율이 약간 떨어지지만, 합리적 SN비의 추정에 근거한 방법인 방법1의 효율 약 32% 보다는 우수하다.

4. 결론

임용빈(1994)에 의해서 제시된 합리적 SN비의 추정에 의한 산포제어인자 분류방법과 다구찌의 SN비에 의한 방법의 효율성을 몬테칼로 씨뮬레이션에 의해서 비교한 결과, 분산안정변환으로 변환된 변수의 변동계수가 5% 보다 큰 $CV=8.66\%$, 6.19% 경우에는 합리적 SN비에 의한 방법이 훨씬 효율적이지만, 변동계수가 5% 보다 작은 $CV=4.33\%$, 0.87% 경우에는 오히려 다구찌의 SN비에 의한 방법이 더 효율적이라는 결과를 얻었다. 이 결과는 공업실험에서 망목특성의 경우에 다구찌의 SN비의 적용을 통해서 품질향상을 이룬 많은 성공사례들을 부분적으로 설명할 수 있는 근거를 제공한다.

〈 표 3.2 〉 $\mu=5$ ($CV=8.66\%$) 경우에 산포인자 D 만을 올바르게 분류하는 백분율

λ^0	방법 1	방법 2	방법 3	방법 4
−1	47.5 (81.3)	47.1 (81.8)	10.1 (52.5)	9.3 (52.6)
−.75	51.9 (86.0)	52.0 (86.8)	9.2 (52.1)	9.1 (52.4)
−.5	45.2 (83.8)	46.3 (85.0)	7.9 (52.9)	7.1 (53.1)
−.25	48.7 (82.4)	45.7 (83.9)	9.0 (51.3)	9.5 (53.4)
0	39.0 (80.9)	44.5 (85.0)	72.3 (94.8)	72.3 (95.4)
.25	53.4 (85.3)	51.1 (85.5)	10.5 (51.5)	9.7 (52.8)
.5	49.1 (85.8)	49.3 (85.8)	8.6 (54.5)	9.3 (54.1)
.75	47.2 (84.6)	47.1 (84.8)	8.3 (54.3)	8.4 (54.9)
1	46.9 (85.7)	46.5 (85.2)	9.9 (55.3)	9.5 (54.4)

〈 표 3.3 〉 μ=7 (CV=6.19%) 경우에 산포인자 D만을 올바르게 분류하는 백분율

λ^{0}	방법 1	방법 2	방법 3	방법 4
−1	43.9 (85.4)	44.3 (85.4)	29.8 (77.6)	29.6 (77.7)
−.75	50.9 (87.4)	50.3 (87.4)	35.8 (79.9)	36.5 (79.8)
−.5	48.8 (87.8)	51.0 (87.4)	35.5 (82.0)	35.4 (82.0)
−.25	47.3 (84.0)	46.5 (85.4)	33.3 (76.6)	32.8 (77.4)
0	39.8 (82.7)	44.4 (85.5)	71.6 (95.7)	73.1 (96.3)
.25	46.0 (85.5)	47.3 (85.5)	33.4 (78.8)	33.2 (79.7)
.5	46.9 (83.9)	47.8 (84.3)	30.7 (75.9)	31.1 (76.3)
.75	47.3 (86.7)	47.2 (86.5)	31.5 (79.6)	31.1 (79.7)
1	47.5 (85.9)	47.8 (85.9)	31.7 (79.7)	32.3 (79.6)

〈 표 3.4 〉 μ=10(CV=4.33%) 경우에 산포인자 *D*만을 올바르게 분류하는 백분율

λ^0	방법 1	방법 2	방법 3	방법 4
−1	49.3 (87.5)	49.5 (87.5)	53.4 (87.7)	53.3 (88.1)
−.75	44.0 (86.5)	44.0 (86.5)	53.8 (89.3)	53.7 (89.3)
−.5	47.5 (85.3)	47.1 (85.2)	55.6 (88.1)	55.3 (88.4)
−.25	46.7 (85.2)	45.0 (85.0)	52.7 (86.7)	51.9 (87.2)
0	40.3 (82.1)	46.3 (85.8)	74.9 (96.0)	75.6 (96.9)
.25	47.1 (86.4)	47.3 (86.2)	53.3 (88.0)	54.5 (88.2)
.5	46.5 (86.6)	46.7 (86.7)	52.3 (87.4)	52.0 (87.8)
.75	50.4 (88.0)	59.9 (88.0)	54.7 (88.0)	54.4 (88.0)
1	44.6 (84.7)	44.7 (84.9)	50.9 (86.4)	51.2 (86.6)

〈 표 3.5 〉 μ=50 (CV=0.87%) 경우에 산포인자 D만을 올바르게 분류하는 백분율

λ^0	방법 1	방법 2	방법 3	방법 4
−1	70.6 (94.4)	70.6 (94.4)	73.4 (95.9)	73.5 (95.9)
−.75	67.8 (91.9)	67.6 (91.8)	70.8 (93.7)	70.9 (93.6)
−.5	62.0 (92.7)	62.0 (92.7)	71.2 (95.2)	71.5 (95.4)
−.25	52.8 (88.3)	52.6 (88.2)	72.9 (96.0)	72.9 (95.8)
0	41.6 (80.9)	47.5 (85.0)	72.3 (94.5)	73.0 (95.1)
.25	52.7 (88.8)	53.0 (88.8)	71.7 (95.6)	71.5 (95.7)
.5	64.3 (91.9)	64.3 (92.2)	72.8 (95.6)	73.2 (95.6)
.75	65.0 (92.9)	64.4 (92.9)	69.7 (94.5)	69.7 (94.4)
1	68.4 (93.4)	68.4 (93.5)	71.7 (94.5)	71.4 (94.5)

〈 표 3.6 〉 μ=7 (CV=6.19%) 경우에 산포인자 D, H만을 올바르게 분류하는 백분율

λ^0	방법 1	방법 2	방법 3	방법 4
−1	31.8 (61.3)	31.8 (61.5)	21.9 (57.1)	22.1 (57.3)
−.75	32.0 (61.2)	31.4 (61.5)	20.7 (57.2)	20.7 (57.4)
−.5	31.2 (64.0)	31.5 (64.0)	22.6 (59.8)	22.8 (60.5)
−.25	28.9 (59.4)	30.6 (63.3)	20.7 (55.2)	21.5 (58.8)
0	24.9 (55.5)	31.1 (62.7)	46.0 (62.7)	48.6 (67.0)
.25	31.6 (62.3)	32.6 (63.5)	23.5 (58.0)	23.5 (60.2)
.5	34.3 (63.4)	34.4 (63.9)	24.9 (60.0)	24.7 (59.7)
.75	32.0 (63.1)	47.2 (86.5)	21.8 (59.0)	21.5 (58.7)
1	31.1 (62.0)	31.7 (61.8)	23.0 (59.0)	23.0 (59.2)

〈 표 3.7 〉 μ=10(CV=4.33%) 경우에 산포인자 D, H만을 올바르게 분류하는 백분율

λ^0	방법 1	방법 2	방법 3	방법 4
-1	30.4 (62.7)	30.7 (63.1)	33.0 (64.2)	33.2 (64.5)
-.75	30.5 (59.4)	30.7 (59.8)	33.5 (61.4)	33.7 (61.8)
-.5	31.3 (62.4)	31.4 (63.1)	34.4 (62.8)	34.2 (63.2)
-.25	30.9 (62.0)	30.2 (63.3)	35.6 (64.2)	34.8 (64.5)
0	28.2 (59.3)	32.4 (67.0)	49.2 (65.7)	51.8 (70.7)
.25	33.1 (63.9)	34.1 (65.0)	33.4 (63.0)	34.9 (64.8)
.5	30.6 (61.7)	30.1 (61.7)	33.9 (62.1)	33.2 (62.0)
.75	31.2 (61.8)	31.5 (61.4)	36.0 (62.4)	35.6 (62.0)
1	34.0 (65.4)	33.8 (65.4)	36.7 (65.2)	37.2 (65.6)

〈 표 3.8 〉 $\mu=50$ ($CV=0.87\%$) 경우에 산포인자 D, H만을 올바르게 분류하는 백분율

λ^0	방법 1	방법 2	방법 3	방법 4
−1	49.6 (68.3)	49.5 (68.2)	51.7 (68.9)	51.8 (68.9)
−.75	46.7 (68.5)	46.9 (68.5)	51.0 (69.8)	51.1 (69.8)
−.5	46.3 (68.7)	46.2 (68.6)	51.4 (69.9)	51.6 (70.0)
−.25	36.5 (63.1)	36.6 (63.2)	47.8 (65.4)	48.1 (65.7)
0	25.3 (54.7)	31.8 (63.2)	47.7 (63.2)	53.6 (70.2)
.25	37.2 (65.2)	37.8 (65.0)	50.1 (69.6)	50.1 (69.4)
.5	46.5 (67.7)	46.3 (68.0)	51.2 (68.6)	51.4 (68.7)
.75	49.1 (68.6)	48.9 (68.6)	50.6 (69.8)	51.0 (69.9)
1	49.3 (69.0)	49.3 (69.0)	51.2 (70.2)	51.3 (70.2)

참고문헌

[1] 박성현 (1993), 「품질공학」, 민영사.

[2] 임용빈 (1994), "망목특성에서의 자료분석을 통한 *SN*비의 선택," 「대한품질경영학회지」, 22권, 4호, pp. 1-12.

[3] Box, G. E. P (1988), "Signal-to-Noise Ratios, Performance Criteria and Transformations," *Technometrics*, Vol. 30, pp. 1-40.

[4] Leon, R. V., Shoemaker, A. C., and Kacker, R. N. (1987), "Performance Measure Independent of Adjustment: An Explaration and Extension of Taguchi's Signal to Noise Ratio," *Technometrics*, Vol. 29, pp. 253-285.

[5] Nair, V. N. (1992), "Taguchi's Parameter Design: A Panel Discussion," *Technometrics*, Vol. 34, pp. 127-161.

[6] Nair, V. N., and Pregibon, D. (1986), "A Data Analysis strategy for Quality Engineering Experiments," *AT&T Technical Journal*, pp. 73-84.

[7] Taguchi, G. (1987), *System of Experimental Design: Engineering Methods to Optimize Quality and Minimize Cost, White Plains*, NY: UNIPUB/Krau International.