

파라미터 설계에서 신호대 잡음비 사용 없이 신경망을 이용한 최적화 대체방안[†]

나명환¹ · 권용만²

¹전남대학교 통계학과 · ²조선대학교 컴퓨터통계학과

접수 2010년 1월 6일, 수정 2010년 2월 17일, 게재확정 2010년 3월 12일

요약

다구찌는 파라미터 설계에서 설계인자의 최적조건을 구하는데 필요한 수행측도로서 신호대 잡음비를 이용하여 자료 분석을 하였다. 다구찌 품질공학은 품질을 개선하는데 있어서 큰 기여를 하였으나 자료 분석하는데 있어서 망목특성에서의 신호대 잡음비의 사용은 많은 문제점이 지적되었고 여러 학자들에 의하여 대체방안 연구되었다. 제품의 설계단계에서 품질특성과 여러 개의 설계인자와의 관계는 복잡한 비선형 형태를 가지는 경우가 대부분이다. 신경망은 유연한 모형 선택과 학습능력은 알 수 없는 복잡한 비선형 형태를 파악하는데 아주 유용한 도구이다. 본 논문은 파라미터 설계에서 설계인자의 최적조건을 찾는 데 있어서 문제가 되는 신호대 잡음비를 사용하지 않고 신경망을 이용한 최적화 방안을 제안하고자 한다. 아울러 예제를 들어 기존의 다구찌 방법과 새로이 제안한 대체방안을 비교하고자 한다.

주요어: 설계 (제어)인자, 신경망, 신호 대 잡음비, 최적조건, 최적화 방안, 파라미터 설계.

1. 서론

품질을 획기적으로 향상시키기 위해서는 설계 단계에서의 품질관리 활동이 절대적으로 필요하다. 다구찌 품질공학은 통계학 분야가 제품 설계 단계에서 품질관리의 전 분야에 걸쳐서 품질을 개선하는데 있어서 광범위하게 활용되는데 큰 기여를 하였다 (Taguchi, 1987). 다구찌 품질공학에서는 품질특성의 편 (bias)뿐만 아니라 변동 (분산 혹은 표준편차)을 가능한 줄이는 것을 목적으로 한다. 다구찌 파라미터 (parameter) 설계에서 직교배열표 (orthogonal array)를 이용한 교차배열 (product array)은 제어인자 (control factor)와 잡음인자 (noise factor)의 모든 교호작용을 고려한 실험배치를 하여 신호대 잡음비 (signal-to-noise ratio; SN)를 이용한 자료분석을 하였다. 교차배열에서 잡음인자는 품질특성치의 품질변동을 유발시키는 역할을 함으로써 변동에 둔감하면서 동시에 품질특성치의 평균을 목표치에 접근하는 제어인자의 최적조건을 찾을 수 있는 파라미터 설계를 가능하게 한다 (Kwon, 2001).

다구찌 품질공학은 품질을 개선하는데 있어서 큰 기여를 하였으나 자료 분석하는데 있어서 망목특성에서의 SN의 사용은 많은 문제점이 지적되었고 여러 학자들에 의하여 대체방안 연구되었다. 이와 관련하여 Box (1988) 등의 학자들은 자료변환을 통한 분석방법을 제안하였고 Vining과 Myers (1990)은 SN을 사용하는 대신에 반복 측정된 자료로부터 회귀분석을 통하여 적합한 평균모형과 표준편차모형

[†] 이 논문은 2008년도 조선대학교 학술연구비의 지원을 받아 연구되었음.

¹ (500-757) 광주광역시 북구 용봉동, 전남대학교 통계학과, 부교수.

² 교신저자: (501-759) 광주광역시 동구 서석동 375, 조선대학교 컴퓨터통계학과, 부교수.

E-mail: ymkwon@chosun.ac.kr

을 분리해서 품질특성의 최적조건을 구하는 대체방안 처음으로 시도하였다. 그들은 Myers와 Carter (1973)의 이중반응 (dual response) 함수에 대한 최적화기법을 사용하여 실험자료를 분석하였다. 그 이후로 Copeland와 Nelson (1996) 등의 학자들은 망목특성, 망대특성, 망소특성 별로 각기 다른 최적화 방안을 제시하였다.

신경망 (neural network)은 복잡하게 연결된 뉴런 (neuron)의 망으로 구성된 생체 학습 시스템을 수학적 모델을 빌려 만들어진 정보처리 시스템이다. 설계 단계에서 제품의 품질특성치와 제어인자의 관계는 복잡한 비선형 형태를 가지는 경우가 대부분이며 생산현장에서는 잡음인자가 품질특성치에 영향을 미쳐 품질변동을 유발시킴으로써 제어인자의 최적조건을 찾는 데 어려움이 따른다. 신경망은 복잡한 구조를 가진 자료에서의 예측문제를 해결하기 위해서 사용되는 유연한 비선형모형의 하나로 분류된다.

본 논문의 목적은 파라미터 설계에서 자료 분석 하는데 문제가 되는 SN을 사용하지 않고 신경망 방법을 이용하여 추정 (혹은 학습)된 평균과 분산을 분리해서 품질특성의 최적조건을 구하는 대체방안을 이용하기로 한다. 아울러 예제를 들어 기존의 다구찌 방법과 새로이 제안한 대체방안을 비교하고자 한다.

2. 신경망에 의한 파라미터 설계 최적화 방안

파라미터 설계는 기대손실을 줄이기 위한 실험배치 및 분석방안이다. 제품이나 공정설계에서 기대손실을 줄이기 위해서는 품질특성치의 평균을 목표치에 근접하게 하는 동시에 품질변동을 줄이도록 해야 한다. 다구찌 품질공학에서 자료 분석하는데 있어서 망목특성에서의 SN의 사용은 많은 문제점이 지적되었고 여러 학자들에 의하여 대체방안 연구되었다. 파라미터 설계에서 자료를 분석하는데 있어서 평균과 변동 (혹은 분산)을 하나로 묶은 수행측도 (performance measure)인 SN을 사용함에 따라 문제가 발생하였다. 파라미터 설계에서 실험배치 방법인 교차배열에서는 제어인자는 내측배열 (inner array)에 변동을 유발시키는 잡음인자는 외측배열 (outer array)에 배치하는 교차실험을 함으로써 각기 서로 다른 제어인자의 실험조건에서 잡음인자에 의한 반복된 자료를 얻을 수 있으며 이러한 자료로부터 표본평균과 표본분산 (혹은 표본표준편차)을 구할 수 있다. 따라서 SN을 사용하는 대신 반복 측정된 자료로부터 추정된 평균과 분산을 분리해서 품질특성의 최적조건을 구하는 대체방안을 생각해 볼 수 있을 것이다.

파라미터 설계에서 잡음에 강건 (robust)한 제어인자의 최적조건을 구하는데 있어서 다구찌 방법은 아주 유용한 방법이다. 그러나 많은 제어인자와 잡음인자의 영향까지 고려한 파라미터 설계에서는 제어인자들간의 관계가 비선형인 경우가 대부분이기 때문에 다구찌 방법에서 수준 평균법과 분산분석에 의한 제어인자의 최적조건을 구하는 것은 한계가 있다. 신경망은 유연한 모형 선택과 학습능력은 알 수 없는 복잡한 비선형 형태를 파악하는데 아주 유용한 도구이다. 신경망에는 여러 가지 모형이 있으나 가장 널리 사용되는 모형은 다층 퍼셉트론 (MLP, multilayer perceptron) 모형이다. MLP 모형은 입력층 (input layer), 은닉층 (hidden layer) 그리고 출력층 (output layer)으로 구성된 전방향 (feed-forward) 신경망이다. 가장 유명한 신경망 알고리즘은 역전파 (back-propagation) 알고리즘이다. 역전파 신경망은 입력층, 은닉층, 출력층으로 구성되며 학습 방식은 학습입력 패턴을 먼저 신경망에 입력하여 출력을 구한 뒤 출력값과 목표값과의 차이 즉, 오차를 구하고 그 오차값을 역방향으로 전파시키면서 출력층과 은닉층의 연결 가중치를 변경하면서 허용오차에 수렴하면 학습을 중단하는 방식이다 (박우창 등, 2000).

Copeland 와 Nelson (1996)은 반복된 자료로부터 회귀분석에 의한 추정된 평균 모형 $\widehat{M}(x)$ 와 표준편차 모형을 이용하여 망목특성, 망대특성, 망소특성 별로 각기 다른 최적화 방안을 제시하였다. 그들이 제시한 망대특성과 망소특성에서의 최적화 공식은 표준편차모형에 제한조건을 주면서 동시에 평균모형을 최대화 혹은 최소화시키는 방안이라면 망목특성에서의 최적화 공식은 평균모형에 제한조건을 주면서 동시에 표준편차모형을 최소화시키는 방안을 사용하여 품질특성에 따라 제한조건이 달라지는 문제점을

가지고 있다. 이러한 질차상 문제는 파라미터 설계에서 품질평균 보다 품질변동을 줄이는 것이 우선이라는 측면에서 잘못된 방안이라 할 수 있겠다. 또한 그들은 망대특성과 망소특성인 경우에서 표준편차 모형에 제한조건으로 특정한 상수로 하거나 상한을 둔다고 하였는데 구체적으로 어떻게 설정한다는 것인지 방법이 기술되어 있지 않다.

본 연구에서는 반복 측정된 자료로부터 표본평균과 표본분산을 구하고 이를 입력 자료로 사용하여 신경망 방법에 의하여 추정된 (또는 학습된) 평균 $\widehat{M}(x)$ 과 분산 $\widehat{V}(x)$ 을 이용한 새로운 방안을 다음과 같이 제안하고자 한다. 모든 품질특성들은 어떤 특정한 목표치 (Target value; T)를 갖는다. 따라서 우리는 추정된 평균에서 세 가지 품질특성에 대한 목표치를 다음과 같이 설정하고자 한다.

$$(1) \text{망목특성: } T_\mu = \text{특정한 상수}$$

$$(2) \text{망대특성: } T_\mu = \max_{x \in R_x} \widehat{M}(x)$$

$$(3) \text{망소특성: } T_\mu = \min_{x \in R_x} \widehat{M}(x)$$

여기서 x 는 제어인자의 실험조건, R_x 는 제어인자의 흥미영역이다. 식 (2.1)로부터 모든 품질특성들은 제어인자들의 흥미영역에서 어떤 특정한 목표치 T_μ 를 갖는다는 점에서 망목특성이라고 보아도 아무런 문제가 없다. 따라서 자료분석에 의한 최적공정을 찾는 방법은 모든 품질특성에 대하여 망목특성처럼 동일하게 적용할 수 있다. 아울러 분산모형에서 모든 품질특성에 대한 목표치는 작을수록 좋기 때문에 다음과 같이 설정하고자 한다.

$$\text{모든 특성: } T_\sigma = \min_{x \in R_x} \widehat{V}(x) \quad (2.1)$$

따라서, 파라미터 설계에서는 품질평균 보다 품질변동을 줄이는 것이 우선이라는 측면에서 모든 품질특성에 대한 최적화 방안을 다음과 같이 제안하고자 한다.

$$\min_{x \in R_x} |\widehat{M}(x) - T_\mu| \quad \text{such that} \quad |\widehat{V}(x) - T_\sigma| \leq \Delta \quad (2.2)$$

여기서 허용범위 Δ 은 임의의 상수이다. Δ 를 정하는 방법은 신뢰구간을 이용하거나 여러 가지 방안이 있을 수 있으나 근본취지는 우선적으로 품질변동을 목표치에서 가능한 범위 내에 두는데 있으므로 여러 가지 범위에서 제어인자들의 거동을 살펴보는 것이 제어인자들의 최적조건들을 구하는 방법이 될 것이다.

3. 예제

자동차 접합 케이블의 코어 인장력을 규격 (40 ± 15 파운드)에 맞도록 제품을 개발하기 위한 실험이다. 품질특성치 코어 인장력은 망목특성이고 목표치는 40이다. 제어인자 8개 중에서 A인자는 2수준, 나머지 B, C, D, F, G, H, I 인자 모두 3수준으로 $L_{18}(2^1 \times 3^7)$ 형 직교배열표에 실험 배치하고 각각 2개의 2수준인 잡음인자의 4가지 실험 조건에서 반복 실험하여 표 3.1과 같이 총 $18 \times 4 = 72$ 번의 실험데이터를 얻었다. 표 3.1에서 각 실험조건에서 대한 평균 M , 분산 V 그리고 SN은 $10 \log[(M)^2/V]$ 을 이용하여 구하였다 (박성현, 1990; Na와 Kwon, 2009).

3.1. 다구찌 방법

다구찌 방법에서는 SPSS를 사용하여 분석하였다. 다구찌 방법에서 수준 평균법 (level average method)에 의한 최적 조건 선정은 각 인자 수준별로 SN의 평균값을 구하여 인자별 최대의 SN을 가지

표 3.1 실험과 데이터

실험수	A	B	C	D	F	G	H	I	y_{n_1}	y_{n_2}	y_{n_3}	y_{n_4}	M	V	SN비
1	1	1	1	1	1	1	1	1	30	40	38	49	39.25	60.92	14.0
2	1	1	2	2	2	2	2	2	10	15	25	25	18.75	56.25	7.8
3	1	1	3	3	3	3	3	3	49	53	53	55	52.50	6.33	26.4
4	1	2	1	1	2	2	3	3	62	58	52	68	60.00	45.33	19.0
5	1	2	2	2	3	3	1	1	30	50	49	62	47.75	174.92	11.0
6	1	2	3	3	1	1	2	2	10	25	29	36	25.00	120.67	6.9
7	1	3	1	2	1	3	2	3	58	42	41	50	47.75	62.92	15.6
8	1	3	2	3	2	1	3	1	28	29	32	31	30.00	3.33	24.3
9	1	3	3	1	3	2	1	2	110	74	94	115	98.25	341.58	14.5
10	2	1	1	3	3	2	2	1	76	88	66	103	83.25	254.25	14.3
11	2	1	2	1	1	3	3	2	52	37	54	59	50.50	89.67	14.5
12	2	1	3	2	2	1	1	3	55	79	62	98	73.50	368.33	11.6
13	2	2	1	2	3	1	3	2	5	35	16	42	24.50	289.67	2.6
14	2	2	2	3	1	2	1	3	52	96	79	91	79.50	387.00	12.1
15	2	2	3	1	2	3	2	1	50	70	56	65	60.25	80.25	16.5
16	2	3	1	3	2	3	1	2	15	20	18	21	18.50	7.00	16.9
17	2	3	2	1	3	1	2	3	51	62	59	70	60.50	61.67	17.7
18	2	3	3	2	1	2	3	1	77	83	66	74	75.00	50.00	20.5

는 수준을 최적 조건으로 선정한다. 표 3.2에서 인자 A는 1수준 나머지 인자 B, C, D, F, G, H, I 는 모두 3수준 즉, $A_1B_3C_3D_3F_2G_3H_3I_3$ 이 최적 조건이 된다.

표 3.2에서 SN에 대한 분산분석 결과 B, D, G, H, I는 대체로 유의하다고 본다면 산포제어인자 (dispersion control factor)로 볼 수 있고 인자 수준별 평균에 의하여 최적 조건은 $B_3D_3G_3H_3I_3$ 가 된다. 평균 M에 관한 분산분석 결과 크게 유의한 인자가 없으나 산포제어인자를 제외한 나머지 인자는 평균조정 인자로 보아서 인자 수준별 평균값이 목표치 40에 가까운 수준을 택한다면 $A_1C_1F_2$ 이 최적조건이 된다. 따라서 최종적인 제어인자의 최적조건은 $A_1B_3C_1D_3F_2G_3H_3I_3$ 가 된다. 표 3.2와 표 3.3에서 분산분석 결과 유의하지 않는 인자 즉 산포제어인자나 평균조정인자에도 포함되지 않는 인자는 기술적, 경제적 특성을 고려하여 임의로 수준을 택할 수도 있다 (박성현, 1990; Na와 Kwon, 2009).

표 3.2 SN비의 분산분석표 및 인자수준별 평균

요인	제공합	자유도	제공평균	F	유의확률	인자수준별 평균		
						1	2	3
모형	578.04	15	38.54	11.80	0.081			
A	9.10	1	9.10	2.79	0.237	15.50	14.08	
B	142.83	2	71.42	21.86	0.044	14.77	11.35	18.25
C	16.78	2	8.39	2.57	0.280	13.73	14.57	16.07
D	98.21	2	49.10	15.03	0.062	16.03	11.52	16.82
F	14.27	2	7.13	2.18	0.314	13.93	16.02	14.42
G	47.27	2	23.64	7.23	0.121	12.85	14.70	16.82
H	86.32	2	43.16	13.21	0.070	13.35	13.13	17.88
I	163.26	2	81.63	24.98	0.038	16.77	10.53	17.07
오차	6.53	2	3.27					
합계	584.58	17						

3.2. 신경망 방법

신경망 방법에서 망목특성인 경우에 제어인자의 최적조건을 찾기 위하여 표 3.1에서 구한 18개의 평

표 3.3 평균값의 분산분석표 및 인자수준별 평균

요인	제공합	자유도	평균제공	F	유의확률	인자수준별 평균		
						1	2	3
모형	8282.47	15	552.17	0.94	0.631			
A	627.17	1	627.17	1.06	0.411	46.58	58.38	
B	92.76	2	46.38	0.08	0.927	52.96	49.50	55.50
C	1226.22	2	613.11	1.04	0.490	45.54	47.83	64.08
D	724.69	2	362.35	0.61	0.619	61.46	47.88	48.13
F	933.01	2	466.50	0.79	0.558	52.83	43.50	61.13
G	2541.69	2	1270.85	2.16	0.317	42.13	69.13	46.21
H	438.26	2	219.13	0.37	0.729	59.46	49.25	48.75
I	1698.67	2	849.34	1.44	0.410	55.92	39.25	62.29
오차	1178.97	2	589.48					
합계	9461.43	17						

균 M과 분산 V를 각각 활용 가능한 데이터로 쓰기로 한다. 신경망 방법에서 자료분석은 SAS Enterprise Miner를 사용하였다 (최종후 등, 2001). 자료가 많지 않아 과적합 (overfitting)을 방지하기 위하여 훈련 (training)에 자료의 70% 평가 (validation)에 30%를 사용하였다. 입력층의 노드 (node)가 제어 인자의 수와 같은 8개, 1개의 은닉층 그리고 출력층으로 이루어진 MLP 모형을 사용한다. 은닉층의 수와 은닉층내 노드의 수에 따라서 신경망의 구조가 달라지고 결과도 달라질 수 있다 (허명희 등, 2003). 신경망 모형을 18개의 분산 V와 평균값 M을 각각 사용하여 은닉층이 1개 일 때 은닉 노드의 수를 2, 3, 4로 해본 결과 RMSE (root mean square error) 크기에 큰 차이가 없어 간단한 모형인 1개의 은닉층에 2개의 노드를 가진 8-2-1 역전파 신경망의 구조를 사용하여 신경망 모형을 적합하고 예측한다. RMSE는 예측의 정확성을 측정하는 척도 (measure)이다. RMSE는 다음과 같이 계산된다.

$$RMSE = \sqrt{\sum_{i=1}^n (Y_i - P_i)^2 / n}$$

여기서 Y_i 는 i 번째 실험조건에서의 분석하고자 하는 통계량 값이고 P_i 는 i 번째 실험조건에서의 예측 값이다. 표 3.4는 통계량인 V와 M인 경우 신경망 적합 구조에 따른 RMSE 값이다. 표 3.5는 표 2.1의 제어인자를 입력층 데이터, V를 출력층 데이터로 사용하여 MLP 모형에 의해 추정된 분산은 $\widehat{V}(x)$ 이고 이에 따라 예측된 V의 값은 P_V이다. 같은 방법으로 신경망에 의해 추정된 평균은 $\widehat{M}(x)$ 이고 예측된 평균값은 P_M이다.

표 3.4 신경망 적합 구조

구조	V에 대한 RMSE		M에 대한 RMSE	
	훈련(training)	평가(validation)	훈련(training)	평가(validation)
8-2-1	107.1439	98.1508	15.0143	15.2411
8-3-1	109.3818	98.1805	14.9878	15.6214
8-4-1	119.7195	105.4273	14.5332	16.4412

신경망 방법에서 훈련과 평가에 의해 추정된 분산 $\widehat{V}(x)$ 와 평균 $\widehat{M}(x)$ 를 이용하여 제어인자의 모든 실험조건 $2 \times 3^7 = 4374$ 에서 분산 V와 평균값 M을 예측하면 각각 P_V와 P_M이 된다. 이들을 사용하여 2장에서 제안한 최적화 방안을 이용하여 파라미터 설계에서 제어인자의 최적조건을 구하여 보자. 최적화 방안에서 식 (2.3)은 품질특성의 분산 (혹은 변동)을 먼저 제한하면서 평균을 목표치에 가져가는 제어인자의 최적조건을 찾는 것이다. 최적화 방안을 적용하기 위하여 첫째, 품질특성의 분산을 제한하

기 위하여 제어인자의 모든 실험 조건에서 신경망 모형에 의해 예측된 P.V값을 순위별로 나타내고 그 중에서 상위 100가지로 선택적으로 제한하고 둘째, 선택된 제어인자의 100가지 실험조건에서 평균을 목표치인 40에 가까운 제어인자의 최적조건을 찾기 위하여 신경망 모형 이용하여 예측된 평균값 중에서 40 ± 10 범위에서 상위 10개를 최적조건으로 나타낸 것이다 (표 3.6).

표 3.5 실험실제 조건에서 신경망 방법에 의해 예측된 평균과 분산

	A	B	C	D	F	G	H	I	M	P_M	V	P.V
1	1	1	1	1	1	1	1	1	39.25	34.47	60.92	179.20
2	1	1	2	2	2	2	2	2	18.75	32.39	56.25	56.23
3	1	1	3	3	3	3	3	3	52.50	66.16	6.33	6.20
4	1	2	1	1	2	2	3	3	60.00	66.16	45.33	2.82
5	1	2	2	2	3	3	1	1	47.75	32.89	174.90	190.20
6	1	2	3	3	1	1	2	2	25.00	34.33	120.70	120.75
7	1	3	1	2	1	3	2	3	47.75	40.74	62.92	47.65
8	1	3	2	3	2	1	3	1	30.00	34.28	3.33	4.02
9	1	3	3	1	3	2	1	2	98.25	62.07	341.60	259.45
10	2	1	1	3	3	2	2	1	83.25	68.25	254.30	259.38
11	2	1	2	1	1	3	3	2	50.50	43.53	89.67	77.82
12	2	1	3	2	2	1	1	3	73.50	68.15	368.30	360.98
13	2	2	1	2	3	1	3	2	24.50	34.31	289.70	126.90
14	2	2	2	3	1	2	1	3	79.50	68.25	387.00	360.98
15	2	2	3	1	2	3	2	1	60.25	66.16	80.25	80.23
16	2	3	1	3	2	3	1	2	18.50	32.53	7.00	15.42
17	2	3	2	1	3	1	2	3	60.50	68.14	61.67	106.91
18	2	3	3	2	1	2	3	1	75.00	57.98	50.00	47.65

표 3.6 신경망 방법에 의해 예측된 최적조건

No.	A	B	C	D	F	G	H	I	P.V	P_M
1	1	3	1	3	1	3	3	1	2.88	31.78
2	1	3	1	3	2	3	3	1	2.88	32.39
3	1	3	2	3	1	3	3	1	3.47	33.18
4	1	3	2	3	2	3	3	1	3.47	36.79
5	1	3	1	3	3	3	3	1	3.48	35.86
6	1	3	1	2	2	3	3	1	3.58	37.17
7	1	3	3	3	2	3	3	1	3.58	40.17
8	1	3	2	2	2	3	3	1	3.68	39.18
9	1	3	2	3	3	3	3	1	3.68	39.26
10	1	3	3	3	1	3	3	1	3.78	40.29

제어인자의 최적조건에서 신경망 방법이 다구찌 방법과 크게 다른 점은 최적조건에서 제어인자 I의 수준이 다구찌 방법이 3수준이라면 신경망 방법은 1수준이라는 것이 다른 점이라고 할 수 있다. 신경망 방법과 다구찌 방법간에 제어인자의 최적조건에서 다소 차이가 있는 것은 최적조건을 선택하는 방법에 있어서 다음과 같은 차이가 있기 때문이다. 첫째로 최적조건을 선택하는데 있어서 다구찌 방법은 SN을 사용하였고 신경망 방법은 평균과 분산을 분리하여 사용하였다. 자료를 분석하는데 있어서 평균과 분산을 하나로 묶은 수행측도인 SN의 사용에 따른 문제점은 이미 여러 학자들에 의해서 지적되었다. 둘째로 다구찌 방법에서 산포제어인자와 평균조정인자를 분리하여 단계별로 최적조건을 찾는 것도 문제가 될 수 있다. 왜냐하면 두 가지 조건이 서로 독립적이지 않기 때문이다. 셋째로 제어인자나 품질특성치간에 알 수 없는 복잡한 비선형 형태를 가지거나 제어인자들 간에 교호작용이 존재하는 경우에 다구찌 방법으로 최적수준을 찾는 것은 한계가 있기 때문이다. 표 3.2과 표 3.3에서 SN비와 평균값의 분산분석

결과 모형의 유의확률이 0.081과 0.631로 나타났다. 이는 주효과 (main effect) 분석만으로 제어인자와 SN 그리고 제어인자와 평균의 관계를 설명하는데 문제가 있을 수 있음을 알 수 있다.

4. 결론

다구찌 파라미터 설계에서 자료분석에 사용되는 망목특성의 수행측도인 SN은 여러 학자로부터 문제점이 지적되었다. 따라서 본 논문에서는 신경망 방법을 이용하여 실험자료로부터 평균과 분산을 분리 추정하여 파라미터 설계를 하기 위한 최적화 방안을 제시하였다. 이전까지는 파라미터 설계에서 수행측도를 세 가지 품질특성별로 달리 적용하였으나 새로이 제안한 최적화 방안에서는 모든 품질특성들은 망목특성이라 하였으며 자료분석을 하기 위한 최적화 공식을 모든 품질특성에 동일하게 적용하였다. 파라미터 설계에서 제품의 품질특성과 제어인자와의 관계를 규명하는 것은 굉장히 어려울 것이다. 이들의 관계가 단순한 수학적 모형으로 설명할 수 없을 만큼 복잡할 뿐만 아니라 외부적인 환경요인 즉, 잡음 인자의 영향도 무시할 수 없기 때문이다. 제어인자들의 수가 많고 제어인자들 간의 상호 작용이 품질특성에 큰 영향을 미치는 경우에는 기존의 다구찌 방법을 적용하는 것이 적절하지 않을 수도 있을 것이다. 본 연구에서 나타난 결과를 비교해 보면 기존의 다구찌 방법에 의한 최적 조건과 같은 실험을 통해 얻어진 데이터를 신경망 방법을 이용하여 예측한 최적 조건과는 일부 인자에서 차이가 나타나고 있음을 앞서 3장을 통해 비교해 보았다.

본 연구는 신경망 방법을 이용하여 SN을 사용하지 않고 파라미터 설계에 대한 새로운 최적화 방안을 제시하고 적용하는 방법을 찾는 것이다. 다구찌 방법의 단점을 역전과 신경망의 추론 기능을 이용하여 별도의 통계학적인 계산 절차 없이 최적조건을 찾아내는 방법을 제안하였다. 신경망 모형의 학습을 위한 적절한 데이터를 얻기 위하여 다구찌 방법의 실험계획 방법을 똑같이 적용하였다. 따라서 데이터의 크기가 충분히 크지 않아서 신경망 방법을 설계하는데 제약이 따르기는 하였으나 신경망의 방법을 적용하여 좋은 결과를 얻을 수 있었다. 신경망에 대한 장단점은 이미 잘 알려져 있다. 어떠한 최적화 방안이 제일 좋다는 것은 없다. 단점을 보완하면서 장점을 잘 활용하여야 할 것이다. 실제 문제에 직면했을 때는 사용의 편리성과 여러 가지 최적화 방안을 동시에 고려하여야 할 것이다.

참고문헌

- 박성현 (1990). <응용실험계획법>, 영지문화사, 서울.
- 박우창, 송현우, 용환승, 최기현 (2000). <데이터 마이닝 개념 및 기법>, 자유아카데미, 서울.
- 최종후, 한상태, 강현철, 김은석, 김미경 (2001). <데이터마이닝>, 자유아카데미, 서울.
- 허명희, 이용구 (2003). <데이터마이닝 모델링과 사례>, SPSS 아카데미, 서울.
- Box, G. E. P. (1988). Signal-to-noise ratios, performance criteria and transformations. *Technometrics*, **30**, 1-17.
- Copeland, K. A. F. and Nelson P. R. (1996). Dual response optimization via direct function minimization. *Journal of Quality Technology*, **28**, 331-336.
- Kwon, Y. M. (2001). Simultaneous optimization of multiple responses to the combined array. *Journal of the Korean Data & Information Science Society*, **12**, 57-64.
- Myers, R. H. and Cater, W. H. Jr. (1973). Dual response surface techniques for dual response systems. *Technometrics*, **15**, 301-317.
- Na, M. H. and Kwon, Y. M. (2009). Optimization procedure for parameter design using neural network. *Journal of the Korean Data & Information Science Society*, **20**, 829-835.
- Taguchi, G. (1987). *System of experimental design: Engineering methods to optimize quality and minimize cost*, White Plains, NY: UNIPUB / Kraus International.
- Vining, G. G. and Myers, R. H. (1990). Combining Taguchi and response surface philosophies: A dual response approach. *Journal of Quality Technology*, **22**, 38-45.

Alternative optimization procedure for parameter design using neural network without SN[†]

Myung Whan Na¹ · Yong Man Kwon²

¹Department of Statistics, Chonnam University

²Department of Computer and Statistics, Chosun University

Received 6 January 2010, revised 17 February 2010, accepted 12 March 2010

Abstract

Taguchi has used the signal-to-noise ratio (SN) to achieve the appropriate set of operating conditions where variability around target is low in the Taguchi parameter design. Many Statisticians criticize the Taguchi techniques of analysis, particularly those based on the SN. Moreover, there are difficulties in practical application, such as complexity and nonlinear relationships among quality characteristics and design (control) factors, and interactions occurred among control factors. Neural networks have a learning capability and model free characteristics. These characteristics support neural networks as a competitive tool in processing multivariable input-output implementation. In this paper we propose a substantially simpler optimization procedure for parameter design using neural network without resorting to SN. An example is illustrated to compare the difference between the Taguchi method and neural network method.

Keywords: Design (control) factors, neural networks, optimization procedure parameter design.

[†] This research was supported by Chosun University Research funds, 2008.

¹ Associate professor, Department of Statistics, Chonnam University, Gwangju 500-757, Korea.

² Corresponding author: Associate professor, Department of Computer and Statistics, Chosun University, Gwangju 501-759, Korea. E-mail: ymkwon@chosun.ac.kr