

파라미터 설계에서 신경망을 이용한 최적화 방안[†]

나명환¹ · 권용만²

¹전남대학교 통계학과 · ²조선대학교 컴퓨터통계학과

접수 2009년 7월 10일, 수정 2009년 9월 1일, 게재확정 2009년 9월 21일

요약

다구찌 파라미터 설계는 품질특성의 변동을 최대한 줄이면서 동시에 품질특성의 평균을 목표치 가까이 가져가기 위한 설계인자의 최적조건을 찾는 방법이다. 제품의 설계단계에서 품질특성과 여러 개의 설계인자와의 관계는 복잡한 비선형 형태를 가지는 경우가 대부분이다. 신경망에서 유연한 모형 선택과 학습능력은 알 수 없는 복잡한 비선형 형태를 파악하는데 아주 유용한 도구이다. 본 연구는 파라미터 설계에서 설계인자의 최적조건을 찾기 위하여 신경망을 이용한 최적화 방안을 제안하였다.

주요용어: 다구찌 방법, 설계인자, 신경망, 최적조건, 최적화 방안, 파라미터 설계.

1. 서론

다구찌 품질공학은 통계학 분야가 제품 설계 단계에서 품질관리의 전 분야에 걸쳐서 품질을 개선하는데 있어서 광범위하게 활용되는데 큰 기여를 하였다 (Taguchi, 1987). 품질을 획기적으로 향상시키기 위해서는 설계 단계에서의 품질관리 활동이 절대적으로 필요하다. 그 중에서도 파라미터 설계가 가장 중요하다고 할 수 있다. 다구찌 품질공학에서는 품질특성의 평균뿐만 아니라 변동 (분산 혹은 표준편차)을 가능한 줄이는 것을 목적으로 한다. 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. 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; SN비)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 (권용만, 2001; 권용만 등, 2003).

신경망 (neural network)은 복잡하게 연결된 뉴런 (neuron)의 망으로 구성된 생체 학습 시스템을 수학적 모델을 빌려 만들어진 정보처리 시스템이다. 신경망은 복잡한 구조를 가진 자료에서의 예측문제를 해결하기 위해서 사용되는 유연한 비선형모형의 하나로 분류된다.

본 논문의 목적은 파라미터 설계에서 신경망이론을 이용한 최적화 방법을 제안하고자 한다. 다구찌 방법에서는 SPSS를 사용하고 신경망 방법에서는 SAS Enterprise Miner를 사용하여 분석하였다 (최종후 등, 2001).

[†] 본 연구는 2007년도 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

2. 다구찌 방법에 의한 파라미터 설계 최적화 방안

2.1. 실험계획

자동차 점화 케이블의 코어 인장력을 규격 (40 ± 15 파운드)에 맞도록 제품을 개발하기 위한 실험이다 (박성현, 1990, p. 214). 품질특성치 코어 인장력은 망목특성 (nominal-is-best characteristics)이고 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 2.1과 같이 $18 \times 4 = 72$ 번의 실험데이터를 얻었다. 표 2.1에서 M은 각 실험에 대한 평균, V는 분산 그리고 SN비는 $10 \log[(M)^2/V]$ 을 이용하여 구하였다.

표 2.1 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

2.2. 다구찌 방법

다구찌 방법에서 수준 평균법 (level average method)에 의한 최적 조건 선정은 각 인자 수준별로 SN비의 평균값을 구하여 인자별 최대의 SN비를 가지는 수준을 최적 조건으로 선정한다. 표 2.2에서 인자 A는 1수준 나머지 인자 B, C, D, F, G, H, I는 모두 3수준 즉, $A_1B_3C_3D_3F_2G_3H_3I_3$ 이 최적 조건이 된다.

표 2.2에서 SN비에 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. 표 2.3에서 평균 M에 관한 분산분석 결과 크게 유의한 인자가 없으나 산포제어인자를 제외한 나머지 인자는 평균조정인자 (mean adjustment factor)로 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 2.2과 표 2.3에서 분산분석 결과 유의하지 않는 인자 즉 산포제어인자나 평균조정인자에도 포함되지 않는 인자는 기술적, 경제적 특성을 고려하여 임의로 수준을 택할 수도 있다.

표 2.2 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						

표 2.3 평균값의 분산분석표 및 인자수준별 평균

요인	제공합	자유도	제공평균	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						

3. 신경망에 의한 파라미터 설계 최적화 방안

파라미터 설계에서 잡음에 강건 (robust)한 제어인자의 최적조건을 구하는데 있어서 다구찌 방법은 아주 유용한 방법이다. 그러나 많은 제어인자와 잡음의 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. MLP 모형을 적합시키는 알고리즘 중에서 역전파 (back-propagation) 알고리즘이 가장 유명하다. 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 (Werbos, 1994; 박우창 등, 2000).

신경망 방법에서 망목특성인 경우에 제어인자의 최적조건을 찾기 위하여 표 2.1에서 구한 18개의 SN비와 평균 M을 각각 활용 가능한 데이터로 쓰기로 한다. 과적합을 방지하기 위하여 훈련 (training)에 자료의 70%, 평가 (validation)에 30%을 사용한다. 입력층의 노드 (node)가 제어인자의 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). 그러나 신경망 모형을 18개의 SN비와 평균값 데이터를 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 품질특성치이고 P_i 는 i 번째 실험조건에서의 예측값이다. 표 3.1은 신경망 적합 구조에 따른 SN비와 M에 대한 RMSE 값이다. 표 3.2는 제어인자를 입력층 데이터, SN비를 출력층 데이터로 사용하여 역전파 신경망에 의해 예측된 SN비의 값이다. SN비와 같은 방법으로 신경망에 의해 예측된 평균값 P_M이다.

표 3.1 신경망 적합 구조

구조	SN비에 대한 RMSE		M에 대한 RMSE	
	훈련(training)	평가(validation)	훈련(training)	평가(validation)
8-2-1	4.5319	5.8351	15.0143	15.2411
8-3-1	3.8537	5.0638	14.9878	15.6214
8-4-1	2.7195	5.4273	14.5332	16.4412

표 3.2 신경망 방법에 의해 예측된 최적조건

	A	B	C	D	F	G	H	I	M	P_M	SN비	P-SN
1	1	1	1	1	1	1	1	1	39.25	34.47	14.0	14.0
2	1	1	2	2	2	2	2	2	18.75	32.39	7.8	7.3
3	1	1	3	3	3	3	3	3	52.50	66.16	26.4	23.9
4	1	2	1	1	2	2	2	3	60.00	66.16	19.0	19.0
5	1	2	2	2	3	3	1	1	47.75	32.89	11.0	11.0
6	1	2	3	3	1	1	2	2	25.00	34.33	6.9	7.3
7	1	3	1	2	1	3	2	3	47.75	40.74	15.6	15.6
8	1	3	2	3	2	1	3	1	30.00	34.28	24.3	24.3
9	1	3	3	1	3	2	1	2	98.25	62.07	14.5	14.5
10	2	1	1	3	3	2	2	1	83.25	68.25	14.3	22.2
11	2	1	2	1	1	3	3	2	50.50	43.53	14.5	7.4
12	2	1	3	2	2	1	1	3	73.50	68.15	11.6	11.6
13	2	2	1	2	3	1	3	2	24.50	34.31	2.6	2.6
14	2	2	2	3	1	2	1	3	79.50	68.25	12.1	12.6
15	2	2	3	1	2	3	2	1	60.25	66.16	16.5	16.5
16	2	3	1	3	2	3	1	2	18.50	32.53	16.9	16.9
17	2	3	2	1	3	1	2	3	60.50	68.14	17.7	17.7
18	2	3	3	2	1	2	3	1	75.00	57.98	20.5	17.7

훈련과 평가에 의해 추정된 (또는 학습된) 신경망 모형을 이용하여 제어인자의 모든 실험조건 $2 \times 3^7 = 4374$ 가지에서 SN비와 평균값을 예측할 수 있다. 신경망 모형에 의해 예측된 SN비인 P-SN과 평균 P-M을 이용하여 파라미터 설계에서 제어인자의 최적조건을 구하는 방법을 품질특성에 따라 다음과 같이 제안하고자 한다.

1. 망목특성: 제어인자의 모든 실험조건에서 신경망 모형에 의해 예측된 SN비 값을 순위별로 나타내고 그 중에서 만족스러운 상위 일부분을 선택하고 선택된 제어인자의 실험조건에서 예측된 평균값을 구한 다음 그 중에서 SN비와 평균값을 동시에 만족하는 제어인자의 조건을 선택하여 제어인자의 최적조건으로 한다.
2. 망대특성 (large-is-better characteristics)과 망소 (smaller-is-better)특성: 예측된 SN비 값을 순위별로 나타내고 그 중에서 상위 일부분을 선택하고 그 중에서 제어인자의 최적조건으로 선택한다.

망목특성인 경우 신경망을 적용하는데 있어 망소특성과 망대특성에 비해 복잡하고 어려움이 있고 앞서 다구찌 방법과 비교하기 위하여 표 2.1에 있는 망목특성인 경우를 예로 들어 설명하기로 한다. 표 3.3은 제어인자의 모든 실험 조건 $2 \times 3^7=4374$ 가지 경우에, 신경망 모형에 의해 예측된 SN비 값을 순위별로 나타내고 그 중에서 상위 200가지를 선택하고 선택된 제어인자의 200가지 실험조건에서 최적화된 평균에 대한 신경망 모형 이용하여 예측된 평균값 중에서 40 ± 15 범위에서 상위 10개를 나타낸 것이다.

표 3.3 신경망 방법에 의해 예측된 최적조건

No.	A	B	C	D	F	G	H	I	P_SN	P_M
1	1	3	2	3	2	3	3	1	22.63	36.79
2	1	3	2	3	2	3	2	1	22.60	36.79
3	1	3	3	3	2	1	3	1	22.59	34.28
4	1	3	2	3	2	3	1	1	22.59	36.79
5	1	3	2	3	2	2	3	1	22.57	36.86
6	1	3	1	3	3	3	3	1	22.55	35.86
7	1	3	1	3	2	3	3	1	22.55	32.39
8	1	3	3	3	2	1	2	1	22.54	34.47
9	1	3	3	3	2	1	1	1	22.53	34.47
10	2	3	1	3	2	3	3	1	22.51	46.46

표 3.4는 앞서 다구찌 방법에서 제어인자의 최적조건을 신경망 방법을 적용하여 예측한 것이다. 첫 번째는 수준평균법에 의한 제어인자의 최적조건이고 두 번째는 산포제어인자와 평균조정인자를 동시에 고려한 최적수준이다. 제어인자의 최적조건에서 다구찌 방법이 신경망 방법과 크게 다른 점은 평균 예측값 (P_M)이 목표치 40에서 크게 벗어나 있다는 것이다. 특히 최적조건에서 제어인자 I의 수준이 다구찌 방법이 3수준이라면 신경망 방법은 1수준이라는 것이 다른 점이라고 할 수 있다.

표 3.4 다구찌 방법에서 최적조건에 따른 신경망 방법에서의 예측값

No.	A	B	C	D	F	G	H	I	P_SN	P_M
1	1	3	3	3	2	3	3	3	22.41	66.16
1	1	3	1	3	2	3	3	3	22.36	66.19

신경망 방법과 다구찌 방법은 제어인자의 최적조건에서 다소 차이가 있는 것은 최적조건을 선택하는 방법에 있어서 차이가 있기 때문이다. 특히 제어인자나 품질특성치 간에 알 수 없는 복잡한 비선형 형태를 가지거나 제어인자들 간에 교호작용이 존재하는 경우에 다구찌 방법으로 최적수준을 찾는 것은 한계가 있기 때문이다. 표 2.2과 표 2.3에서 SN비와 평균값의 분산분석 결과 모형의 유의확률이 0.081과 0.631로 나타났다. 이는 주효과 (main effect) 분석만으로 제어인자와 SN비, 제어인자와 평균의 관계를 설명하는데 문제가 있음을 알 수 있다. 또한 다구찌 방법에서 산포제어인자와 평균조정인자를 분리하여

단계별로 최적조건을 찾는 것도 문제가 될 수 있다. 왜냐하면 두 가지 조건이 서로 독립적이지 않기 때문이다.

4. 결론

파라미터 설계 즉, 설계 단계에서 제품의 품질특성과 설계인자 (제어인자)와의 관계를 규명하는 것은 굉장히 어려운 것이다. 이들의 관계가 단순한 수학적 모형으로 설명할 수 없을 만큼 복잡할 뿐만 아니라 외부적인 환경요인 즉, 잡음인자의 영향도 무시할 수 없기 때문이다. 실험에 의한 최적조건을 구하는 여러 방법들이 연구되어 왔고 실제로 성공적으로 적용되고 있다. 특히 다구찌 방법은 생산현장에서 아주 경제적이고 빠르게 최적 조건을 선정하는 방법의 하나로 많이 활용되고 있다. 그러나 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 보면 기존의 다구찌 방법에 의한 최적 조건과 같은 실험을 통해 얻어진 데이터를 신경망 이론을 이용하여 예측한 최적 조건과는 일부 인자에서 차이가 나타나고 있음을 앞서 3장을 통해 비교해 보았다.

본 연구는 신경망 방법을 이용하여 파라미터 설계에 대한 새로운 최적화 방안을 제안하고 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 있습니다. 어떠한 최적화 방안이 제일 좋다는 것은 없습니다. 단점을 보완하면서 장점을 잘 활용하여야 할 것입니다. 실제 문제에 직면했을 때는 사용의 편리성과 여러 가지 최적화 방안을 동시에 고려하여야 할 것입니다. 통계학 분야에서 제시된 많은 방법들이 이론을 위한 이론에 그치는 경우가 많고 응용 분야에서는 실제로 사장되거나 무분별하게 이용되는 것을 안타깝게 생각하면서 실제로 연구된 논문이 활용되기를 바라면서 신경망과 통계패키지의 활용 측면에서 대체 방안을 연구한 논문입니다.

참고문헌

- 박우창, 승현우, 용환승, 최기현 (2000). <데이터 마이닝 개념 및 기법>, 자유아카데미, 서울.
 박성현 (1990). <응용실험계획법>, 영지문화사, 서울.
 최종후, 한상태, 강현철, 김은석, 김미경 (2001). <데이터마이닝>, 자유아카데미, 서울.
 허명희, 이용구 (2003). <데이터마이닝 모델링과 사례>, SPSS 아카데미, 서울.
 Kwon, Y. M. (2001). Simultaneous optimization of multiple responses to the combined array. *Journal of the Korean Data & Information Science Society*, **12**, 57-64.
 Kwon, Y. M., Hong, Y. W. and Chang, D. J. (2003). Multiple response optimization for robust design using desirability function. *Journal of the Korean Data & Information Science Society*, **14**, 325-335.
 Werbos, P. J. (1994). *The roots of backpropagation*, Wiley, New York.
 Taguchi, G. (1987). *System of experimental design: Engineering methods to optimize quality and minimize cost*, White Plains, NY: UNIPUB / Kraus International.

Optimization procedure for parameter design using neural network[†]

Myung Whan Na¹ · Yong Man Kwon²

¹Department of Statistics, Chonnam University

²Department of Computer and Statistics, Chosun University

Received 10 July 2009, revised 1 September 2009, accepted 21 September 2009

Abstract

Parameter design is an approach to reducing performance variation of quality characteristic value in products and processes. Taguchi has used the signal-to-noise ratio to achieve the appropriate set of operating conditions where variability around target is low in the Taguchi parameter design. However, there are difficulties in practical application, such as complexity and nonlinear relationships among quality characteristics and control factors (design 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. An example is illustrated to compare the difference between the Taguchi method and neural network method.

Keywords: Control factors, neural networks, optimization procedure, parameter design.

[†] This research was supported by the Chosun University Research funds in 2007.

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