

# 신경망이론을 이용한 어인자의 수준사이를 고려한 최적조건 선정에 관한 연구

홍정의<sup>1)</sup>

충주대학교 산업공학과

## Selecting the Optimum Process Condition Between the Factor Level Using Neural Network

Hong, Jungeui

Department of Industrial Engineering Chung-Ju National University

Keywords : Experimental Design, Taguchi Method, Neural Network

### Abstract

Defining the relationship between the quality of injection molded parts and the process condition is very complicate because of lots of factor are involved and each factor has a non-linearity. With the development of CAE(Computer Aided Engineering) technology, the estimation of volumetric shrinkage of injection mold parts is possible by computer simulation even though restricted application. In this research, Neural Network applied for finding optimal processing condition. The percent of volumetric shrinkage compared on each case and show neural network can be successfully applied selecting optimum condition not only within factor level but also between factor level.

### 1. 서론

사출성형의 원리는 플라스틱 성형재료를 사출성형기의 히터를 통해 일정한 온도L:로 가열하여 유동성을 갖게 한 후 스크루를 이용 금형 안으로 고압으로 사출하고 냉각에

따른 성형 품의 체적 수축을 보상하기 위하여 일정시간 압력을 유지시키는 보압 과정과 일정시간의 보압 과정이 지난 후 냉각시키는 일련의 과정을 통해 완성품을 얻을 수 있다. 사출성형은 이러한 복잡한 공정에도 불구하고 다양한 형상의 제품을 비교적 높은 정밀도를 얻을 수 있고 재현성이 좋기 때문에 대량 생산 방법으로 널리 활용되고 있다. 이러

1) 충주대학교 산업공학과 교수

한 장점에도 불구하고 사출 성형 품의 품질은 플라스틱 수지의 재료 특성, 사출성형 조건, 성형 품의 형상 등에 따라 성형공정에서 일어나는 복잡한 유동적, 열 적 현상들의 변화에 민감한 것으로 알려져 있다[1][2]. 따라서 성형공정에서 제품의 불량률 최소화하기 위해서는 수지, 금형, 그리고 성형조건에 대한 최적설계가 이루어 져야 한다. 그러나 제품의 품질과 설계변수와의 관계는 비선형 다차원(Non-linear Multi-Variable)의 관계가 있을 뿐만 아니라 생산현장에서 발생하는 잡음(Noise)의 역할도 무시할 수 없는 변수이기 때문에 최적의 가공조건을 선정하는 것은 매우 어려운 것이 현실이다.

컴퓨터 기술의 발전에 따라 사출성형 해석용 소프트웨어의 개발이 잇따르고 있고 이러한 CAE(Computer Aided Engineering) 기술을 이용하여 제한된 범위에서의 예측을 가능하게 하고 있다. 하지만 완전한 Simulation 효과를 얻기 위해서는 아직도 해결해야 할 문제가 많이 남아 있다. 즉 지금 까지 개발된 대부분의 해석용 소프트웨어는 완전한 3차원적 해석보다는 2차원적인 해석에 가깝기 때문에 그 적용대상 이 평면 또는 두께가 얇은 제품으로 극히 제한적 일 수밖에 없다는 것이다.

본 연구의 목적은 사출성형 과정에서 최적의 성형조건을 찾아내기 위해 그 동안 많은 연구가 이루어져 왔던 다구찌 방법과 이 과정에서 얻은 데이터를 이용하여 인공지능의 한 기법인 신경망 이론 (Neural Network)을 적용하여 제어인자 간의 최적 조건을 찾아내고 뿐만 아니라 신경망의 예측 기능을 이용하여 제어 인자의 수준사이의 최적 조건을 찾아내고자 한다. [3][4][5].

다구찌 방법은 많은 제어 인자를 가지는

실험에서 아주 적은 수의 실험횟수만을 가지고도 비교적 최적에 근사한 가공조건을 찾아 내는데는 성공적인 방법으로 평가되고 있다. 따라서 다구찌의 방법과 절차에 따른 실험을 수행하고 이를 통하여 얻은 실험 데이터를 신경망 이론에 적용하여 그 결과를 비교하였다. 사출 성형시 캐비티에서 발생하는 체적 수축률 차이는 성형 품의 휨과 변형에 가장 큰 영향을 미친다. 따라서 본 연구에서는 체적 수축률(volumetric shrinkage) 차이를 최소화시키기 위한 성형조건을 도출하는데 목적을 두었다. 적용 제품으로는 컬러 휴대폰용 2 인치 도광판을 대상으로 하였으며, 사출성형 해석 프로그램인 C-MOLD를 사용하였다.

## 2. 실 험

다구찌 방법은 우선 제어 가능한 인자들을 설정하고 제어가 불가능하거나 제어하기에 비용(Cost)이 많이 드는 인자들을 잡음(Noise) 라고 정의하고 제어인자들의 수준(Level) 값을 실험을 통하여 수정함으로써 최적의 생산 조건을 찾는 방법이 그 주요 내용이라 할 수 있다[5]. 따라서 환경적인 변화 즉 실험실 환경이 아닌 실제 생산환경에 변화에 강건(Robust)한 설계를 위한 적합한 방법이라 할 수 있다. 또한 바이어스 되지 않은 직교 좌표표(Orthogonal Array)에 의한 최소의 실험으로 손쉽게 최적에 근사한 가공 조건을 찾을 수 있는 방법이기도 하다. 다구찌 방법을 수행하기 위한 절차는 먼저 제어 가능한 가공인자를 설정하고, 직교 좌표표에 의한 실험을 실시하고, 품질 특성에 의한 신호 대 잡음비(S/N Ratio)를 계산하여 최대의

S/N 비를 나타내는 성형조건을 찾아내고 이를 확인실험을 통해 기존의 조건과 비교하여 향상된 최적조건을 선정 할 수 있다.

## 2.1 제어인자와 그 수준

사출성형은 온도, 압력, 시간, 속도 등의 모든 물리량들이 적절히 조정되어야만 최고 품질의 제품을 얻을 수 있다. 특히 사출시간, 보압시간, 가열실린더의 온도, 금형의 온도, 스크루의 속도, 사출압력 등은 사출기의 특성상 손쉽게 제어 가능한 인자 들이므로 제어인자로 설정했다.

<표 1> 제어인자와 그 수준

Control factor	Unit	Level		
		1	2	3
A. Filling time	sec	0.5	1	1.5
B. Timer for hold pressure	sec	3	4.5	6
C. Inlet melt temp	℃	280	295	310
D. Mold temp	℃	80	100	120
E. Ram speed profile	Step	1 단	3 단	5 단
F. Hold pressure	MPa	80	100	120

No

각각의 제어인자는 제작자의 가이드북 또는 경험치 에 의하여 선정된 값에서 일정한 양을 가감하여 3단계의 수준을 정의 할 수 있다. <표1>은 각각의 제어 인자와 인자의 수준을 나타내고 있다. 따라서 수학적인 모델은 6개의 제어 인자를 가지고 있고 각각의 인자는 3단계의 수준을 가지고 있다.

<표 2>  $L_{18}$  직교 배열표

Ex	실험행렬조건								
	p	e	e	A	B	C	D	E	F
1	1	1	1	1	1	1	1	1	1
2	1	1	2	2	2	2	2	2	2
3	1	1	3	3	3	3	3	3	3
4	1	2	1	1	2	2	3	3	3
5	1	2	2	2	3	3	1	1	1
6	1	2	3	3	1	1	2	2	2
7	1	3	1	2	1	3	2	3	3
8	1	3	2	3	2	1	3	1	1
9	1	3	3	1	3	2	1	2	2
10	2	1	1	3	3	2	2	1	1
11	2	1	2	1	1	3	3	2	2
12	2	1	3	2	2	1	1	3	3
13	2	2	1	2	3	1	3	2	2
14	2	2	2	3	1	2	1	3	3
15	2	2	3	1	2	3	2	1	1
16	2	3	1	3	2	3	1	2	2
17	2	3	2	1	3	1	2	3	3
18	2	3	3	2	1	2	3	1	1


이러한 모델에서는 Full Factorial Design 을 위해서는  $3^6=729$ 개의 조합이 필요하며 따라서 최적조건 선정을 위해서는 많은 경비와 시간이 필요하다. 제어인자의 Level 1 과 Level 3은 Level 2에서 일정한 값을 가감하여 설정했다.

## 2.2 ANOVA 분석

<표4>는 ANOVA 분석에 의한 각각의 제어 인자들이 체적 수축율에 영향을 미치는 정도를 분석한 자료이다. 모델의 분산 분석의 가설 검정에서 기각치는 모델의 자유도가 12이고 분모 자유도가 5이므로  $F_{12,5,0.05}= 4.68$

<표 3>  $L_{18}$  직교배열표에 따른 체적수축율 차이 및 SN 비.

No Exp	실험행렬조건								결과			
	e	e	A	B	C	D	E	F	최대값(%)	최소값(%)	차이(%)	SN 비(dB)
1	1	1	1	1	1	1	1	1	3.701	1.345	2.356	-7.443
2	1	1	2	2	2	2	2	2	2.793	0.747	2.046	-6.220
3	1	1	3	3	3	3	3	3	2.229	0.578	1.651	-4.353
4	1	2	1	1	2	2	3	3	1.898	0.196	1.702	-4.619
5	1	2	2	2	3	3	1	1	3.556	1.343	2.213	-6.898
6	1	2	3	3	1	1	2	2	2.657	0.571	2.086	-6.387
7	1	3	1	2	1	3	2	3	2.026	0.392	1.634	-4.267
8	1	3	2	3	2	1	3	1	3.811	1.152	2.659	-8.494
9	1	3	3	1	3	2	1	2	2.554	0.650	1.904	-5.594
10	2	1	1	3	3	2	2	1	3.676	1.190	2.487	-7.912
11	2	1	2	1	1	3	3	2	3.393	1.271	2.122	-6.533
12	2	1	3	2	2	1	1	3	1.966	-0.013	1.978	-5.927
13	2	2	1	2	3	1	3	2	3.160	0.777	2.382	-7.540
14	2	2	2	3	1	2	1	3	2.101	0.252	1.850	-5.343
15	2	2	3	1	2	3	2	1	3.613	1.483	2.129	-6.565
16	2	3	1	3	2	3	1	2	2.734	0.870	1.864	-5.408
17	2	3	2	1	3	1	2	3	1.790	0.003	1.787	-5.042
18	2	3	3	2	1	2	3	1	3.906	1.700	2.206	-6.871



<그림 1> 수축율 측정위치

임을 알 수 있다. 즉 검정 통계량 의 값 (4.592)이 기각치(4.68)를 초과하지 못하므로  $H_0$ 를 기각 할 수 없다. 따라서 주 효과 분석 만으로는 제어인자와 체적 수축율의 관계를 설명하는데 문제가 있다. 따라서 체적 수축율은 제어 인자사이의 교호작용(Interaction)이 영향을 미치고 있음을 알 수 있다.

<표 4> 주효과 ANOVA 분석

제어인자	제공합	자유도	평균제공	F	유의확률
모형	23.416	12	1.951	4.592	0.052
Fill time	0.669	2	0.335	0.788	0.504
Hold Time	0.453	2	0.227	0.533	0.617
Inlet Temp	0.023	2	0.011	0.27	0.974
M o l d Temp	3.948	2	1.974	4.644	0.072
Ram Speed	0.408	2	0.204	0.480	0.645
H o l d Pressure	17.915	2	8.958	21.017	0.004
오 차	2.215	5	0.425		
R 제공	0.917				

<표 5> 교호작용을 고려한 ANOVA 분석

제어인자	제공합	자유도	평균제공	F	유의확률
모형	25.28	14	1.806	21.106	0.014
Fill time	0.435	2	0.218	2.544	0.225
Hold Time	0.453	2	0.227	2.648	0.217
Mold Temp	3.947	2	1.974	23.067	0.015
Ram Speed	0.176	2	0.088	1.030	0.456
Hold Pressure	9.560	2	4.780	55.86	0.004
HoldTime* Mold Temp	1.891	4	0.473	5.524	0.096
오 차	0.257	3	0.085		
R 제공	0.990				

<표5>는 주효과와 교호작용(Hold time \* Mold Temp)를 고려한 ANOVA 분석의 결


과이다. 상관계수  $R^2$ 의 값을 비교해 보면 주 효과 만을 고려한 경우 0.917에서 교호작용을 고려한 경우 0.990으로 큰 차이가 있음을 알 수 있다.

### 2.3 최적조건 선정


또한 분산 분석의 가설 검정에서 기각치는 모델의 자유도가 14이고 분모 자유도가 3이므로  $F_{14,3,0.05} = 8.70$ 임을 알 수 있다. 즉 검정 통계량 의 값(21.106)이 기각치(8.70)를 초과하므로  $H_0$ 를 기각 할 수 있다. 즉 교호작용을 포함한 모델은 95%의 유의 수준에서 S/N 비와의 관계를 나타낼 수 있다. 다구찌 방법에서 사용하는 수준 평균법 (Level Average Method)에 의한 최적 조건 선정은 각 인자별로 같은 수준에 있는 조건의 S/N 비의 평균값을 구하는 방법으로 인자별 최대의 S/N 비를 가지는 수준을 최적 조건으로 선정한다. 즉 <표4>에서와 같이 인자 A의 최적 조건은 3수준이 된다. 이러한 방법으로 각각의 제어 인자의 수준별 최적 조건을 구할 수 있다. 제어인자별 최적 조건은 <표4>에 나타내었다.

<표6> 체적수축율 차이에 대한 인자효과

인자	수준별 평균		
	1	2	3
A. Filling time	-6.198	-6.422	<b>-5.949</b>
B.Timer Hold pressure	<b>-5.966</b>	-6.287	-6.316
C. Inlet melt temp.	<b>-6.141</b>	-6.205	-6.223
D. Mold temp.	-6.806	-6.093	<b>-5.671</b>
E. Ram speed	-6.102	<b>-6.066</b>	-6.402
F. Hold pressure	-7.364	-6.280	<b>-4.925</b>



<그림 2> 다구찌 방법에 의한 체적 수축률



<그림 3> 기존의 조건에 의한 체적 수축률

&lt;표 7&gt; 최적조건 확인 실험

Exp. No	수준조합						확인해석			
	A	B	C	D	E	F	최대값(%)	최소값(%)	차이	SN 비
Opt.1	3	1	1	3	2	3	2.72842	0.97912	1.7493	-4.8572

## 2.4 확인실험 결과

수준 평균법에 의하여 각각의 제어 인자의 최대 S/N비를 나타내는 수준을 최적조건으로 선정하면 다구찌 방법이 의한 최적 설계가 완료된다. 이 조건을 가지고 확인실험을 통하여 기존의 가공조건에서의 품질과 최적 설계후의 품질의 변화를 측정할 수 있다. <표5>와 <그림3>는 최적 조건 확인 실험의 결과를 나타내고 있다. 실험의 결과는 기존의 성형조건에서의 S/N비가 -6.220 dB에서 -4.857 dB로 상당히 향상된 것을 알 수 있다.

## 3. Neural Network을 이용한 최적 조건의 예측

다구찌 방법은 아주 경제적으로 새로운 최적조건을 찾아내는 유용한 방법으로 많은 적용과정을 통해 입증되어 왔다. 하지만 수준 평균법(Level Average Method)에 의한 해석은 때로는 그 해석이 모호할 때가 많다. 이를 보완하기 위한 일반적인 방법으로 회귀분석에 의한 제어인자와 측정치간의 관계를 이용 최적값을 찾는 방법이 많이 사용되어지고 있다. 하지만 실험에 의해 얻을 수 있는 데이터의 양이 실험비용이나 시간적인 측면에서 제한적일 수밖에 없고 인자들간의 관계가 Multi-variable Nonlinear인 경우가 대부분이기 때문에 해석이 어려울 수밖에 없다.

본 연구는 신경망 이론이 가지는 추론기능을 이용하여 실험에 의해 얻은 최소한의 데이터를 수없이 많은 계산 과정을 거치는 신경망의 학습기능을 이용하여 접근 하고자 한다. 먼저 신경망 이론의 적용을 위해 활용 가능한 실험 데이터에 대한 고려가 필요하다. 본 실험에서 적용한 L<sub>18</sub> 직교좌교표에 따라 활용 가능한 데이터 Set은 18경우가 된다. 일반적으로 신경망 설계시 전체의 Weight Matrix수는 데이터의 Set보다 적어야 한다. 즉 입력층의 Node가 제어인자의 수와 같은 6개이고 두개의 Hidden Layer에 2개의 node를 사용하고 출력층의 Node가 한 개인 경우 전체의 Weight Matrix수는 18개가 된다. 따라서 <그림3>과 같은 이중 Hidden Layer의 역전파 신경망(back-propagation Neural Network)을 이용한다.

또한 시그모이드(Sigmoid) 함수를 사용하는 신경망에 적용하기 위한 데이터는 <식2>을 이용해 0.2와 0.8 사이의 값으로 변환시키는 Generalization과정이 필요하다.

$$Tar = Tar_{min} + \frac{value - value_{min}}{value_{max} - value_{min}} \times (Tar_{max} - Tar_{min}) \quad <식2>$$

<표8>은 신경망 학습을 위한 일반화된 Input 및 Output 데이터 그리고 Sum of Square Error 0.0002 일 때 학습된 신경망에 의해 예측된 S/N 비의 값을 나타낸다. 표에

나타난 것과 같이 설계된 신경망은 제어인자와 S/N비와의 관계를 아주 근사한 범위내에서 예측 가능함을 보여주고 있다.

다음은 학습된 신경망을 이용하여 Full Factorial 실험 조건에서의 S/N 비를 예측하여 최대의 값을 가지는 조건을 선정 할 수 있다.


<표 8> 신경망 학습 데이터

A	B	C	D	E	F	Output data	학습후 예측값
0.2	0.2	0.2	0.2	0.2	0.2	0.349	0.3490
0.5	0.5	0.5	0.5	0.5	0.5	0.523	0.5230
0.8	0.8	0.8	0.8	0.8	0.8	0.788	0.7880
0.2	0.2	0.5	0.5	0.8	0.8	0.750	0.7501
0.5	0.5	0.8	0.8	0.2	0.2	0.427	0.4270
0.8	0.8	0.2	0.2	0.5	0.5	0.499	0.4990
0.2	0.5	0.2	0.8	0.5	0.8	0.800	0.7999
0.5	0.8	0.5	0.2	0.8	0.2	0.200	0.2000
0.8	0.2	0.8	0.5	0.2	0.5	0.612	0.6120
0.2	0.8	0.8	0.5	0.5	0.2	0.283	0.2830
0.5	0.2	0.2	0.8	0.8	0.5	0.478	0.4780
0.8	0.5	0.5	0.2	0.2	0.8	0.564	0.5639
0.2	0.5	0.8	0.2	0.8	0.5	0.335	0.3350
0.5	0.8	0.2	0.5	0.2	0.8	0.647	0.6471
0.8	0.2	0.5	0.8	0.5	0.2	0.474	0.4740
0.2	0.8	0.5	0.8	0.2	0.5	0.638	0.6380
0.5	0.2	0.8	0.2	0.5	0.8	0.690	0.6899
0.8	0.5	0.2	0.5	0.8	0.2	0.430	0.4301

본 연구에서의 Full Factorial 실험 조건은  $3^6=729$  가지의 경우를 설정 할 수 있다. 신경망 이론을 적용하여 도출한 최적조건과 그에 따른 예측 값을 순위별로 나타낸 것은 <표9>과 같다. 또한 <표9>와 동일한 조건에 대하여 C-Mold해석을 수행하여 얻은 체적 수축율 차이 및 SN비는 <표10>과 같다.

<표 9> Neural Network방법에 의해 예측된 최적조건.


Predicted Optimal Condition No.	실험행렬조건						NN Output
	A	B	C	D	E	F	
Opt. 1	1	1	3	3	1	3	0.895
Opt. 2	1	2	3	3	1	3	0.894
Opt. 3	1	1	3	3	2	3	0.892
Opt. 4	1	3	3	3	1	3	0.890
Opt. 5	2	3	3	3	1	3	0.890




<그림 4> 역전파 신경망 설계

<표9>에서와 같이 인자 C, D 그리고 F는 제3수준으로 변화가 없음을 보여주고 있다. 하지만 인자 A, B, 그리고 E는 수준이 경우에 따라 변하고 있다. 또한 ANOVA 분석에 의한 교호작용의 효과를 보면 B\*D (Hold Time\*Mold Temp)의 효과가 크게 나타나고 있음을 알 수 있다. 따라서 신경망이론을 이용한 학습 후 전체 인자를 기준의 세 단계 수준이 아닌 16단계 수준으로 나누어 최대의 S/N 비를 나타내는 조건을 예측 해 볼 수 있을 것이다.





<그림5> 신경망이론에 의한 체적 수축률



[그림 6] 인자 A와 B의 효과

<표 10> Neural Network방법에 의한 최적 조건의 확인실험

Exp. No	확인해석			
	최대값(%)	최소값(%)	차이	SN 비
Opt.1	1.719	0.327	1.392	-2.876
Opt.2	1.712	0.273	1.439	-3.160
Opt.3	1.729	0.283	1.445	-3.199
Opt.4	1.742	0.274	1.468	-3.335
Opt.5	1.675	0.254	1.420	-3.048

### 4. 수준사이의 최적 조건 예측


제한된 수의 실험데이터를 이용해서 제어 인자와 체적 수축률과의 관계를 정의하기 위해 여러 가지의 연구가 이루어져 왔다. 특히 본 연구에서는 제어인자의 수가 많고 제어 인자 사이의 상관관계가 복잡할 경우 일반적인 접근방법으로는 많은 문제점을 가지고 있음을 알 수 있었다. 특히 본 연구와 같이 인자간의 교호작용(Interaction)이 작용하는 경우 다구찌 방법에 의한 최적 조건은 많은 오

류를 포함하고 있을 수 있다.


앞에서 언급한 바와 같이 각각의 제어 인자를 16단계 수준으로 나누어 최고의 S/N 비를 나타내는 신경망에 의하여 예측된 값을 <표11> 에 나타내었다.

<그림5>는 학습된 신경망 이론을 통해 예측한 A(Filling Time) 와 B(Time for HoldPressure) 가 S/N비에 미치는 영향을 나타내고 있다 이때 나머지 인자는 최적 조건의 수준으로 고정하였다. 그림에서와 같이 Filling time은 실험에서 제1수준과 2수준 사이에 최적조건이 있음을 알 수 있다. <그림 6>은 인자 B(Time for hold Pressure)와 D(Mold Temp)와의 관계를 보여주고 있다. 그림에서와 같이 두 인자 사이의 관계는 서로 대각선으로 나타나므로 두 인자 사이에는 교호작용이 있음을 알 수 있다. 그리고 인자의 수준별 효과는 linear하다고 판단 할 수 있다.


<그림7>은 A(Filling time) 과 D (Mold



[그림 7]인자 B와 D의 효과



<그림 8> 인자 A와 D의 효과



<그림 9> 수준사이의 값을 고려한 최적수축률

Temp)와의 관계를 나타낸다. 이 두 제어인자의 관계는 <그림6>에 나타난 제어 인자들의 관계와 비슷하지만 교호작용의 크기나 S/N비에 미치는 영향이 작음을 알 수 있다.

다음은 그림6, 7, 8의 해석 결과를 가지고 인자 수준 사이의 체적 값을 찾기 위하여 이미 학습된 신경망을 이용하여 수준사이의 값을 세분하여 그 결과를 예측하여 보았다. 즉

<표 11> 인자의 수준사이의 값을 고려한 최적 조건

A	B	C	D	E	F	NN Out값
0.3	0.2	0.8	0.8	0.2	0.8	0.901
0.3	0.25	0.8	0.8	0.2	0.8	0.900
0.35	0.2	0.8	0.8	0.2	0.8	0.900
0.35	0.25	0.8	0.8	0.2	0.8	0.900
0.35	0.3	0.8	0.8	0.2	0.8	0.900
0.25	0.2	0.8	0.8	0.2	0.8	0.899

<표 12> 예측방법에 대한 확인실험결과 비교

예측방법	실험행렬조건						확인해석			
	A	B	C	D	E	F	최대값(%)	최소값(%)	차이	SN 비
일반가공조건	1	4.5	295	100	3단	100	2.793	0.747	2.046	-6.220
다구찌 방법	1.5	3	280	120	2단	120	2.728	0.979	1.749	-4.875
인공지능(수준간)	0.5	3	310	120	1단	120	1.719	0.326	1.392	-2.876
인공지능(수준사이)	0.67	3	310	120	1단	120	1.713	0.408	1.305	-2.318

Generalization된 인자의 수준 사이가 0.2, 0.5, 그리고 0.8의 세 단계를 0.05씩 증가시켜 13단계로 나누어 출력되는 결과중 최대의 Output 값을 나타내는 조건을 <표11>에 나타내었다. 표에서와 같이 인자 C, D, E, 그리고 F의 값은 동일한 수준에 고정되어 있고 인자 A와 B의 값만 미세하게 변하는 것을 알 수 있다. 따라서 본 연구의 최적 가공 조건은 제어인자 A 즉 Filling time의 값 0.3을 실제 값으로 변환하면 약 0.667초가 됨을 알 수 있다. 그림9는 인자의 수준사이의 값을 고려한 체적 조건에 의한 체적 수축률을 나타내고 있다.

### 5. 결론

생산 현장에서 제품의 품질과 가공조건의

관계를 규명하는 것은 굉장히 어려운 일 중의 하나일 것이다. 이는 이들이 수학적인 모델링으로 설명 할 수 없는 복잡할 뿐만 아니라 외부적인 환경요인의 역할도 무시할 수 없기 때문이다. 따라서 생산 현장에서 이러한 고려 가능한 모든 요소들을 고려하여 실험을 통하여 이들의 관계를 규명하고자 하는 노력이 계속되고 있다.

실험에 의한 최적 조건의 선정과정에서 그 시간적, 경제적인 한계를 극복하기 위한 여러 방법들이 연구되어 왔고 또 실제적으로 성공적을 적용되고 있다. 특히 다구찌 방법은 일반 생산현장에서 아주 경제적이고 빠르게 최적 조건을 선정하는 방법의 하나로 많이 활용되고 있다 하지만 제어인자의 수가 많고 인자들간의 상호 작용이 품질에 큰 영향을 미치는 경우에는 Level Average 방법의 적용이 적절하지 않을 수밖에 없다. 본

연구에서 나타난 결과를 보면 기존의 가공조건에 의한 체적 수축률의 최대값과 최소값의 차이는 2.046%이고 다구찌 방법에 의한 최적 조건의 체적 수축률 차이는 1.749%로 많이 향상된 것을 알 수 있다. 하지만 같은 실험을 통해 얻어진 데이터를 신경망 이론을 이용하여 예측한 최적 조건의 체적 수축률 차이는 1.392%로 다구찌 방법에 의한 것보다 월등히 향상된 것을 알 수 있었다. Neural Network 방법에 의해 도출한 최적조건의 경우가 다구찌 방법에 의하여 도출한 최적조건에 비하여 25.62%정도 체적수축율을 줄일 수 있음을 알 수 있다. 뿐만 아니라 전체적인 체적 수축률의 값도 다구찌 방법에 의한 값보다 상당히 줄어들었음을 알 수 있었다. 이는 앞에서 언급한 바와 같이 제어인자간의 교호작용이 존재하는 경우 다구찌 방법에 의한 체적조건선정에 한계가 있음을 보여주고 있다.

본 연구는 다구찌 방법의 단점을 인공지능의 추론 기능을 이용하여 별도의 통계학적인 계산 절차 없이 최적조건을 찾아내는 방법을 제시하였다. 신경망이론의 학습을 위한 적절한 데이터를 얻기 위하여 다구찌 방법의 실험계획방법이 적용되었다. 따라서 상당히 제한된 데이터의 양이 신경망 설계에 제한을 주기는 하였으나 그 결과는 상당히 주목할 만 하였다.

또한 신경망이론은 지금까지의 실험계획법상의 수준간의 최적 조건을 찾는 방법에서 벗어나 수준내의 최적조건을 선정 할 수 있음을 보여주고 있다.

## 참고문헌

- [1] 조용식, 사출성형 금형설계기술, 기전연구사, 1997.
- [2] 홍명웅, 사출성형, 법경 출판사, 1988.
- [3] 민병현, "신경회로망을 이용한 사출 성형품의 체적 수축률에 관한 연구", 한국정밀 공학회지 제 16권, 11호, pp.224-233.
- [4] 최기홍 외4인 "다구찌 방법을 이용한 사출 성형공정의 신경회로망 모델링에 관한 연구", 대한기계학회논문집, 126-A, pp.765-774.
- [5] Kacker, Paugh N., "Off-line quality control parameter design", Journal of quality technology, Vol.17, No.4, 1985, pp.176-188.
- [6] Glen Stuart Peace, "Taguchi Methods", Addison Wesley, 1993.
- [7] 박성현, 현대 실험계획법, 영지문화사, 1990.
- [9] 김우철, 외 7인, 현대 통계학, 영지문화사, 1988.
- [10] Kohonen, T., Foundations of Neural networks, Addison-Wesley, 1984.
- [11] Lippman, Richard P., "An introduction to computing with neural nets", IEEE ASSP Magazine, 1987, pp.4-22.
- [12] D. C. Montgomery, Design and Analysis of Experiments. 2nd Ed. Wiley, New York, 1984.
- [13] J. A. Freeman, D. M. Skapura, Neural Networks, Addison Wesley, 1991.