

# 신경회로망을 이용한 사출성형품의 체적수축률에 관한 연구

민병현\*

## A Study on Volumetric Shrinkage of Injection Molded Part by Neural Network

Byeong-Hyeon Min\*

### ABSTRACT

The quality of injection molded parts is affected by the variables such as materials, design variables of part and mold, molding machine, and processing conditions. It is difficult to consider all the variables at the same time to predict the quality. In this paper neural network was applied to analyze the relationship between processing conditions and volumetric shrinkage of part. Engineering plastic gear was used for the study, and the learning data was extracted by the simulation software like Moldflow. Results of neural network was good agreement with simulation results. Nonlinear regression model was formulated using the test data of 3,125 obtained from neural network. Optimal processing conditions were calculated to minimize the volumetric shrinkage of molded part by the application of RQP(Recursive Quadratic Programming) algorithm.

**Key Words :** Injection molding process(사출성형공정), Neural network(신경회로망), Volumetric shrinkage(체적수축률), Quality prediction(품질예측), Simulation(모의실험), Optimization(최적화)

### 1. 서론

사출성형공정은 일반적으로 150 - 300°C로 용융된 플라스틱 수지를 고압으로 사출금형 내로 충전시켜 냉각에 따른 수지의 체적수축을 보상하기 위해 일정시간 압력을 유지한 후 냉각과정을 거쳐 사출성형품을 얻는 제조공정으로 내부에 금속 삽입물을 포함한 조립부품의 대량생산에 특히 효율적이다.<sup>1)</sup> 이러한 장점에도 불구하고 최종 사출성형품의

품질은 플라스틱 수지 재료의 특성 변동, 사출성형품의 형상이나 치수 등의 설계변수, 금형의 구조특성, 사출성형기의 성능 및 성형공정 동안 일어나는 복잡한 유동적, 열적, 물리적 현상들의 변화에 아주 민감한 것으로 보고되고 있다.<sup>2)</sup> 품질에 영향을 주는 인자(입력인자)들과 품질 변수간의 정확한 관계식의 도출은 입력인자의 구성이 위에서 언급한 바와 같이 특성이 뚜렷한 5개 그룹으로 나누어져 있고 이들이 복합적으로 품질 변수에 영향을 끼치

\* 동의대학교 기계산업시스템공학부

므로 현실적으로 모든 입력인자의 영향을 고려하는 것은 불가능하다. 이러한 연유로 한 개의 입력인자 그룹의 품질변수에 대한 영향을 먼저 분석하고 그 결과에 따라 분석된 입력인자 그룹의 최종조건을 고정한 후 다음 입력인자 그룹으로 옮겨 품질변수에 대한 영향을 분석하는 것이 효율적이라 사료되어 본 연구에서는 플라스틱 수지의 재료, 성형품과 금형의 설계변수 및 사출성형기의 성능 등을 최적으로 조정되었다는 가정 하에서 사출성형 공정조건이 품질 변수에 끼칠 수 있는 영향에 대하여 분석하고자 한다.

성형품의 품질 예측과 성형공정의 최적화와 관련된 지금까지의 연구로 우선 실험계획법이 많이 사용되었는데 이는 공정 창(Processing Windows)에서 얻을 수 있는 각 입력인자들의 범위를 최소 값부터 최대 값까지 연속적으로 변화시키면서 모의실험이나 실제 실험 데이터를 확보해야하는 시행착오법에 비하여 모든 인자의 영향을 포함하면서 하나의 인자효과를 볼 때 다른 인자의 영향에 치우침이 없이 분산분석표의 작성이 용이한 장점들을 지닌 직교배열표를 사용함으로써 시간 소요나 비용 측면에서 효율적인 연구방법이다.<sup>3)</sup> 물론 실험계획법에 의한 연구는 효율적인 데이터 확보뿐만 아니라 일반적인 성형공정과 관련된 인자의 중요성을 분석하는 내용으로 연결되거나<sup>4,6)</sup> 공정과 관련된 인자들을 2개씩 가능한 조합으로 분류하여 각 조합들에 대한 2개의 변수 및 6개항으로 구성된 비선형 2차 회귀식을 사용하여 다단계 회귀분석을 행하여 가장 연관성이 높은 인자들로만 구성된 회귀모델식을 유도하는 GMDH (Group Method of Data Handling) 기법으로 연결되기도 하였다.<sup>7,10)</sup> 또한 경험적으로 얻어지는 사출공정의 특성을 지식베이스 전문가시스템 등과 접목하여 실제 공정 상에서 발생하는 경험적 결과를 바탕으로 공정 분석 및 공정 최적화를 위한 연구가 진행되고 있기도 하며<sup>11-13)</sup> 최근에는 신경회로망 및 유전자 알고리듬 등을 이용한 연구도 사출성형공정에 활발히 적용되고 있다.<sup>14-18)</sup>

본 연구에서는 Fig. 1에 설명된 바와 같이 유용한 공정조건을 입력인자로 선별한 후, 5 인자 3 수준의 실험계획법을 적용하여 얻은 입력과 출력간의 사실적인 기본관계로부터 학습기능을 통하여 다양한 입력조건의 변화에 물리적 의미가 높은 출력을 예측할 수 있는 신경회로망을 입력 층 노드가 5개, 중간층 노드가 3개 및 출력 층 노드가 2개인 5-3-2

층 신경회로망을 구축하다. 하지만 학습데이터를 이용하여 노출된 신경회로망은 다양한 입력인자의 변화에 따른 품질 변수의 변화를 예측 가능하게 하지만 죄적 조건을 노출하는데는 모든 탐색영역을 검색한 후에 결과를 알 수 있으므로 불편한 점이 있다. 따라서 다음 과정에서는 구축된 신경회로망에 입력인자의 최소 및 최대 값의 범위 구간을 5단계로 적용한  $5^5 = 3,125$  개 모의실험조건을 적용시켜 입력 및 출력간의 데이터를 얻은 후 통계 소프트웨어(SAS<sup>®</sup>)를 이용하여 2차 비선형 회귀모델식을 두 개의 출력 변수에 대하여 구성한다. 이는 회귀모델식의 도출에 필요한 충분한 데이터를 많은 시간과 비용을 들이지 않고서도 실제 사출성형에서 얻는 결과와 가까운 데이터를 신경회로망으로 얻을 수 있는 장점을 이용한 것이다.

한편, 성형품의 품질 변수로는 치수, 외관, 기계적 강도 등 여러 가지가 있을 수 있으나 시뮬레이션 소프트웨어를 통하여 품질 특성치의 도출이 용이한 성형품의 체적수축률을 품질 변수로 간단하게 정의하였는데, 성형품의 체적수축은 용융수지의 냉각에 의한 체적 감소, 상 변화에 따른 체적 감소 및 취출 후 체적 증가의 상대적인 양에 의해 결정되며, 성형조건, 재료 특성, 성형품의 형상 등의 설계 구속 조건에 따른 금형의 구속 조건 등에 따라 발생되므로 발생 원인이 광범위하고 이는 성형품 치수의 정밀도에 영향을 끼치기 때문에 중요한 품질 변수로 정의할 수 있다. 본 연구에서 사용한 CAE S/W에서 도출되는 체적수축률은 정상상태에서 얻어진 P-v-T 데이터에 의존한 것이고 결정구조상 내용을 잘 고려하지 못하는 단점이 있다. 케이스류 성형품의 경우는 부위별 수축률 편차에 따른 변형이나 뒤틀림이 성형품의 품질에 나쁜 영향을 줄 수 있고, 치수정밀도와 관련하여 일반 기어나 커넥팅 브리지 정밀도인 4/100mm로부터 컴팩트 또는 광자기 디스크의 정밀도인 1/1000mm 등 다양한 치수정밀도를 반복시키기 위해서는 주어진 조건하에서 성형품의 체적수축률을 먼저 고려함이 필요하다. 사출성형공정의 특성 상 부위별로 체적수축률 값이 다르므로 평균값 및 최대 값과 최소 값의 차이인 편차 값 2개를 성형품의 품질 변수로 규정하였다. 앞서 선정된 두 개의 출력 변수에 대하여 구성된 비선형 2차 회귀식에 최적화 과정을 적용하여 출력을 최적화 할 수 있는 공정조건을 구한다. 최적화는 상용 프로그램(IDESIGN<sup>®</sup>)<sup>19)</sup>에 인터페이스 프로그

램을 작성하여 수행되었으며, 반복이차계획법(Recursive Quadratic Programming)<sup>20)</sup> 알고리듬을 적용하여 엔지니어링 플라스틱 기어 성형품의 체적수축률의 평균 값 및 부위별 편차를 최소화하는 성형조건을 구하였다. 본 연구에서 필요한 데이터는 사출성형해석용 상용 소프트웨어(Moldflow<sup>®</sup>)를 사용한 모의실험을 통하여 구하여졌다.

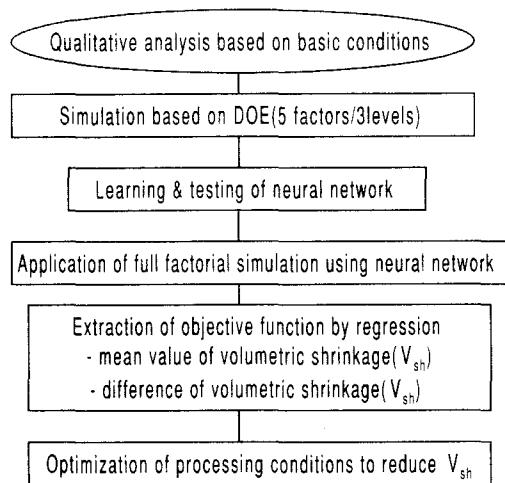


Fig. 1 Block diagram of the application of neural network

## 2. 실험계획법에 의한 신경회로망 구성

### 2.1 적용모델

본 연구에서 적용될 사출성형품은 Fig. 2와 같은 형태의 자동차 부품이나 다른 기계요소 부품으로 사용될 수 있는 엔지니어링 플라스틱 기어로 PA66 (Polyamid 66) 엔지니어링 플라스틱을 재료로 사용하고 내부에 치형 구조를 갖추고 있는 인터널 엔지니어링 플라스틱 기어이다. 자동차의 부품으로 사용될 플라스틱 기어 성형품의 품질을 정의할 수 있는 인자로는 치수정밀도, 각종 강도, 내마모성, 내구성, 급가감속 특성, 토크부하 등 여러 가지가 있으나<sup>21)</sup> 시뮬레이션 소프트웨어에 의한 모의실험을 통하여 추정이 가능한 인자인 체적수축률 값을 성형품의 품질 변수로 정의하여 이를 예측할 수 있는 신경회로망을 구성하고자 한다.

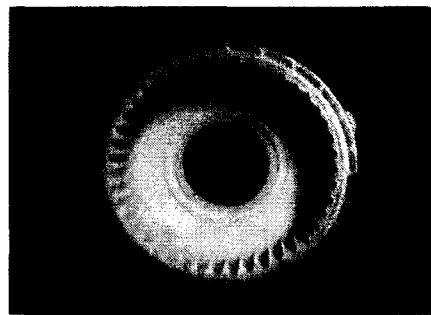


Fig. 2 Plastic gear molded by PA66

### 2.2 신경회로망 구성

사용될 신경회로망은 입력 층, 은닉 층 및 출력층의 다층 퍼셉트론(Multilayer Perceptron)으로 구성되며 Rumelhart McClelland<sup>22)</sup>에 의해 제안된 역전파(Backpropagation) 학습 알고리즘을 이용하여 목표 출력 값과 신경회로망에 의한 출력 값의 차이를 최소화하도록 각 층간의 연결강도와 임계값을 조정하여 원하는 신경회로망을 구성한다. 우선 각 노드에서의 입력은 전 층 노드 출력의 하중 합(Weighted Sum)에 임계 값(Threshold Value)을 더한 값으로 아래 식과 같이 나타난다.

$$\text{net}_k = \sum_j w_{kj} O_j + \theta_k \quad (1)$$

여기서,

$n_{etk}$  : k 번째 노드로의 입력

$O_j$  : 전 층 j 번째 노드의 출력

$w_{kj}$  : 전 층 j 번째 노드와 현재 층 k 번째 노드 사이의 하중계수

$\theta_k$  : k 번째 노드에서의 임계 값

한편, 각 노드의 출력은 입력의 시그모이드(Sigmoid) 함수형태로 다음과 같이 나타난다.

$$O_k = f(\text{net}_k) = \frac{1}{1 + \exp(-\text{net}_k)} \quad (2)$$

목표 출력 값과 신경회로망에 의한 출력 값의 차이를 나타내는 오차 함수 E는 다음과 같이 나타나는데  $T_k$  와  $O_k$  는 출력 노드 k에서 각각 학습 샘플의 출력과 신경회로망의 출력이다.

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (3)$$

오차 값을 최소화하는데는 최속강하법(Steepest

Descent Method)에 의한 순차적인 방법(Iterative Method)을 사용하여 하중계수 및 임계값은 다음식들에 의해 순차적으로 계산된다.

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj} \quad (4)$$

$$\theta_{kj}(n+1) = \theta_{kj}(n) + \Delta \theta_{kj} \quad (5)$$

먼저 출력 층에 대한 하중계수의 증분량을 계산하면

$$\Delta w_{kj} = -\eta_w \frac{\partial E}{\partial w_{kj}} \quad (6)$$

$$= -\eta_w \frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial w_{kj}} \quad (7)$$

$$= \eta_w \delta_k O_j \quad (8)$$

와 같이 주어지며  $\eta_w$ 는 수렴속도를 높이는 상수이다. 여기서,

$$\delta_k = -\frac{\partial E}{\partial \text{net}_k} \quad (9)$$

$$= -\frac{\partial E}{\partial O_k} \frac{\partial O_k}{\partial \text{net}_k} \quad (10)$$

$$= (T_k - O_k) O_k (1 - O_k) \quad (11)$$

한편, 임계값도 위와 동일한 과정에 의해

$$\Delta \theta_{kj} = -\eta_t \frac{\partial E}{\partial \theta_{kj}} \quad (12)$$

$$= -\eta_t \frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial \theta_{kj}} \quad (13)$$

$$= \eta_t \delta_k \quad (14)$$

와 같이 주어지며  $\eta_t$ 는 수렴속도를 결정하는 상

수이고,  $\delta_k$ 는 위의 식 (11)을 따른다.

다음으로 은닉 층에 대한 하중계수의 증분량을 계산하기 위해 위와 같은 방법을 적용하면

$$\Delta w_{ji} = -\eta_w \frac{\partial E}{\partial w_{ji}} \quad (15)$$

$$= \eta_w \delta_j O_i \quad (16)$$

이고,  $\delta_j$ 의 값은

$$\delta_j = O_j (1 - O_j) \sum_i w_{ji} \delta_i \quad (17)$$

가 된다. 한편, 임계값도 위와 동일한 과정에 의해

$$\Delta t_{ji} = \eta_t \delta_j \quad (18)$$

한 가지 주어진  $\delta_j$ 는 위의 식 (17)을 따른다. 이를 계산을 시작할 때 위의 하중계수와 임계값을 사용하면 이들은 반복과정이 진행됨에 따라 안정화되게 된다. 즉, 학습동안 학습 샘플의 입력이 입력층에 주어지고 네트워크의 중간층을 통하여 전파되어 출력 층의 출력으로 나타나게 된다. 이 출력을 근거로  $\delta$  값들이 식 (11)과 (17)에서 출력 층과 중간 층에 대하여 각각 계산되고, 최종적으로 식 (4)와 (5)에 의하여 하중계수와 임계값의 조정이 이루어진다.

입력 인자로는 성형품의 체적수축률에 영향을 줄 수 있는 요인들 중에 성형재료, 성형품의 설계인자, 금형의 설계인자 및 제작 등과 관련한 요인들은 최적조건이 사용된 것으로 가정하고 사출 성형조건과 관련된 용융 수지온도( $x_1$ ), 보압( $x_2$ ), 금형온도( $x_3$ ), 보압시간( $x_4$ ) 및 사출속도( $x_5$ ) 5개만 고려한다. 은닉 층은 3개의 노드로 구성된 1개 층으로 구성하며 출력 층은 성형품의 체적수축률의 평균값과 최대 및 최소 값의 차이인 편차 값 2개로 정의한다. 은닉 층의 수나 노드 수를 변경하면서 그 효과를 분석하는 것도 중요하나 본 연구에서는 Fig. 3에 보여주는 바와 같이 5-3-2의 신경회로망을 우선적으로 고려하고 향후 은닉 층의 수나 노드 수를 변경하면서 그 효과를 분석할 예정이다.

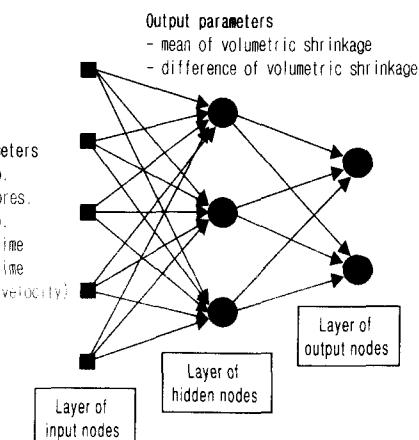


Fig. 3 Backpropagation neural network with 5-3-2 network structure

### 2.3 실험계획법에 의한 모의실험

일반적으로 성형품의 품질에 영향을 주는 인자들의 영향을 정확히 고려하려면 각 인자들의 공정 범위를 최소 값부터 최대 값까지 연속적으로 변화 시키면서 모의실험이나 실제 실험 데이터를 확보해야 하나 시간소요나 비용측면에서 비효율적이다. 한편 입력인자를 몇 개의 수준을 정의하여 실험을 수행한다해도 (수준수)<sup>(인자수)</sup> 만큼, 즉 본 연구에서는 입력인자 5개에 3수준이면  $3^5 = 243$ 개의 실험이 수행되어야 하므로 시간이나 실험비용 등이 문제가 되고 또한 인자들간의 교호작용이 있는 경우에는 이에 대한 고려가 불가하므로 이러한 단점을 보완하기 위해 나구찌의 실험계획법에 의한 직교배열표를 이용함이 유리하다.

이러한 직교배열표는 일부실시법(Partial Factorial Experiments)을 수행하여 실험횟수를 줄이면서도 모든 인자의 영향을 포함하고, 하나의 인자 효과를 볼 때 다른 인자의 영향에 치우침이 없고 또한 분산분석표의 작성이 쉽다는 장점들을 지니고 있다. 따라서 신경회로망의 학습을 준비하기 위한 모의실험 조건은 5인자 3수준의 실험조건을 포함할 수 있는 직교배열표를 이용하며 채택된 실험계획법은 교호작용이 없는 13개 인자에 대해 3 수준 까지 실험이 가능한 L27(313) 직교배열표이다. 본 연구에서 고려하는 독립인자는 용융 수자온도(x1), 보압(x2), 금형온도(x3), 보압시간(x4) 및 사출속도(x5) 5개이므로 L27(313) 직교배열표는 본 연구의 목적에 충분히 부합한다. 공정조건인 각 입력인자의 수준은 Table 1에서 보여주는 실제 입력인자의 최소 값, 중간 값 및 최대 값을 변환하여 0, 0.5 및 1의 3 수준으로 하였다. 품질 변수인 성형품의 체적수축률은 Fig. 4에서 보여주는 바와 같이 동일한 실험조건 하에서도 게이트 부근에서 최소 값, 게이트로부터 멀리 떨어진 곳에서 최대 값을 가지는데 본 연구에서는 최소, 최대 값의 산술평균 값과 그 편차를 성형품의 품질을 판정할 수 있는 인자로 고려하였다. 신경회로망의 학습을 위한 상세한 실험 조건 및 그에 따른 체적수축률의 평균 값(y1) 및 편차 값(y2)의 최소 값부터 최대 값까지를 0에서 1까지 정규화 한 값이 Table 2에 보여진다. 체적수축률의 평균값은 최소 7.36%에서 최대 8.41%까지의 분포를 보여주고, 편차 값은 최소 5.34%에서 최대 6.85%까지의 분포를 보여주었다. 시뮬레이션 소프트웨어(Moldflow(r))에 의한 모의실험은 같은 실험

조건에서는 동일한 결과를 보여주므로 각 조건에서 한번만 수행되었으며 실험순서는 무작위로 수행되었다.

Table 1 Range of processing values for the simulation

Input Variables	Processing value		
	Minimum	Medium	Maximum
Melt temp.(°C)	270	280	290
Packing pressure(MPa)	25	35	45
Mold temp.(°C)	50	60	70
Packing time(sec.)	14	18	22
Injection time(sec.)	3.0	2.5	2.0

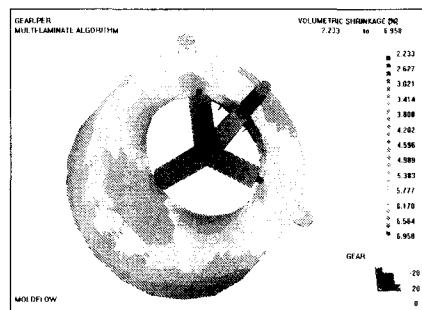


Fig. 4 Volumetric shrinkage of injection molded part

### 3. 결과 및 고찰

#### 3.1 신경회로망 성능

27개의 모의실험 조건인 학습데이터를 이용하여 시뮬레이션에 의한 체적수축률 목표치와 신경회로망에 의한 체적수축률 출력치 간의 오차를 최소화하도록 각 층간의 강도계수가 결정되었으므로 이러한 오차항의 분포가 얻어진 신경회로망의 성능을 대변하며 그 결과가 Fig. 5에 보여진다. 본 연구에서 채택한 오차 항은 RMS(Root Mean Squared) 오차로 삭(19)로 표현된다. RMS 값은 초기에 0.4371에서 0.0385로 연속적으로 줄어들지만 반복 횟수에 비해 줄어드는 정도가 적어 30,000회 반복 후 프로

그램을 범주도록 하였다. 따라서 본 과정에서 구축된 신경회로망은 0.0385의 RMS 오차를 포함하고 있다.

Table 2 Test data for the learning of neural network based on design of experiments

#	X <sub>1</sub>	X <sub>2</sub>	X <sub>3</sub>	X <sub>4</sub>	X <sub>5</sub>	y <sub>1</sub>	y <sub>2</sub>
1	0	0	0	0	0	0.8095	0.8543
2	0	0	0	0.5	0.5	0.7905	0.8278
3	0	0	0	1	1	0.7524	0.8609
4	0	0.5	0.5	0	0	0.5905	0.3046
5	0	0.5	0.5	0.5	0.5	0.5619	0.3311
6	0	0.5	0.5	1	1	0.5714	0.3179
7	0	1	1	0	0	0.4857	0.0728
8	0	1	1	0.5	0.5	0.3810	0.0000
9	0	1	1	1	1	0.4476	0.0728
10	0.5	0	1	0.5	1	1.0000	0.6291
11	0.5	0	1	1	0	0.9905	0.6556
12	0.5	0	1	0	0.5	1.0000	0.6159
13	0.5	0.5	0	0.5	1	0.4095	0.6556
14	0.5	0.5	0	1	0	0.4381	0.6887
15	0.5	0.5	0	0	0.5	0.4190	0.6887
16	0.5	1	0.5	0.5	1	0.2381	0.3642
17	0.5	1	0.5	1	0	0.2952	0.3841
18	0.5	1	0.5	0	0.5	0.2381	0.3974
19	1	0	0.5	1	0.5	0.7810	0.9007
20	1	0	0.5	0	1	0.8857	0.9338
21	1	0	0.5	0.5	0	0.8667	1.0000
22	1	0.5	1	1	0.5	0.7238	0.5629
23	1	0.5	1	0	1	0.7238	0.5298
24	1	0.5	1	0.5	0	0.7333	0.5563
25	1	1	0	1	0.5	0.0095	0.5430
26	1	1	0	0	1	0.0000	0.5629
27	1	1	0	0.5	0	0.0476	0.5629

$$\text{RMS} = \sqrt{\frac{1}{n} \sum_{i=0}^n (O_i - T_i)^2} \quad (19)$$

O<sub>i</sub>: 신경회로망에 의한 체적수축률

T<sub>i</sub>: 시뮬레이션에 의한 체적수축률

n: 신경회로망 학습을 위한 데이터 수

Fig. 6a에 시뮬레이션에 의한 체적수축률의 평균 값과 신경회로망에 의한 체적수축률의 평균 값

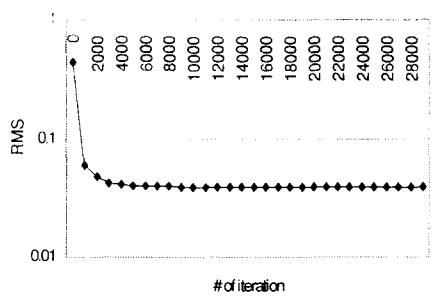


Fig. 5 RMS error according to the iteration of neural network

의 정규화된 값의 결과 비교가, Fig. 6b에 시뮬레이션에 의한 체적수축률의 평균 값과 신경회로망에 의한 체적수축률의 평균 값의 정규화된 값의 결과 비교를 27개 학습조건에 대하여 보여주는데 위의 오차항의 분포에서 확인된 바와 같이 허용된 오차 범위 내에서는 잘 일치함을 알 수 있다.

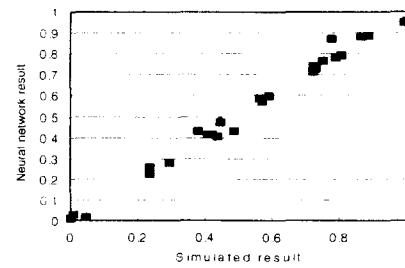


Fig. 6 (a) Mean value

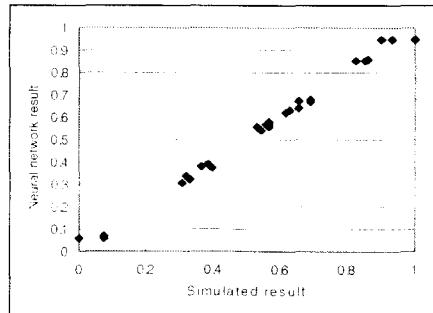


Fig. 6 (b) Difference between gate and far away from gate

Fig. 6 Comparison of normalized volumetric shrinkage between simulation and neural network

### 3.2 회귀모델식 도출

한편 5개 입력인자를 5수준으로 확대한 신제설 시법(Full Factorial Experiments)에 의한 실험조건을 구해진 신경회로망에 적용하여 입력인자의 변화에 따른 체적수축률의 변화를 보고자 한다. 이를 위한 종 실험조건은  $S^5=3.125$ 개로 보의실험이나 실제 실험을 통하여 데이터를 얻기는 현실적으로 불가능하나, 학습이 잘 된 신경회로망을 통해서는 노드간의 연결강도가 결정될 때 내포된 허용오차 범위 내에서는 3,125개의 데이터도 간단히 얻을 수 있다. 하지만 신경회로망에 의한 출력 데이터도 재한된 입력조건에서만 가능하므로 본 연구에서는 신경회로망을 통하여 구해진 데이터를 2차 다항 회귀모델에 적용함으로써 입력인자의 연속적인 변화에 따른 출력치의 변화를 주정하고, 출력치인 사출성형품의 체적수축률의 평균 값과 편차 값을 최소화하는 최적 사출성형조건을 회귀모델식으로부터 구해보고자 한다. 적용된 회귀모델식은 아래의 식(20)과 같다.

$$y = f(x_1, x_2, x_3, x_4, x_5) \\ = a_0 + \sum_{i=1}^5 a_i x_i + \sum_{i,j} a_{ij} x_i x_j \quad (20)$$

회귀모델식의 계수는 통계프로그램인 SAS<sup>®</sup> 소프트웨어를 이용하여 구하였으며 체적수축률의 평균 값 및 편차 값에 대한 회귀모델식의 계수 값에 대한 통계분석 결과가 Table 3 및 4에 보여진다.

오차분석 결과 체적수축률의 평균 및 편차 값에 대한 회귀모델식의 결정계수( $r^2$ )는 각각 0.9909 ( $=1198.23/1108.32$ ) 및 0.9970 ( $=1130.43/1133.79$ )으로 일반적으로 결정계수 값이 0.81 이상이면 물리적으로 의미를 갖는다는 관점에서 볼 때 매우 좋은 결과임을 알 수 있다. 한편, 체적수축률의 평균 값 및 편차 값에 대한 회귀모델식의 상수항, 1차 항 및 2차 항의 계수 값을 아래에 보여준다.

Table 3 Non-linear least squares summary statistics of mean value of volumetric shrinkage( $y_1$ )

Source	DOF	Sum of Squares
Regression	21	1098.23
Residual	3104	10.09
Total	3125	1108.32

Table 4 Non-linear least squares summary statistics of the difference of volumetric shrinkage( $y_2$ )

Source	DOF	Sum of Squares
Regression	20	1130.43
Residual	3105	3.36
Total	3125	1133.79

체적수축률의 평균 값에 대한 회귀모델식 계수는 아래와 같다.

$$\begin{array}{lll} a_0 = 0.7655 & a_1 = -0.0485 & a_2 = -0.7308 \\ a_3 = 0.2811 & a_4 = -0.0121 & a_5 = 0.0404 \\ a_{11} = -0.1088 & a_{22} = 0.0436 & a_{33} = 0.0332 \\ a_{44} = -0.0089 & a_{55} = -0.0414 & a_{12} = -0.2926 \\ a_{13} = 0.0130 & a_{14} = -0.0707 & a_{15} = 0.1490 \\ a_{23} = 0.0183 & a_{24} = 0.0661 & a_{25} = 0.1344 \\ a_{34} = -0.0206 & a_{35} = -0.0337 & a_{45} = -0.0390 \end{array}$$

체적수축률의 편차 값에 대한 회귀모델식 계수는 아래와 같다.

$$\begin{array}{lll} a_0 = 0.8272 & a_1 = 0.2743 & a_2 = -0.6464 \\ a_3 = -0.2553 & a_4 = 0.0024 & a_5 = 0.0038 \\ a_{11} = -0.0398 & a_{22} = 0.2360 & a_{33} = -0.2182 \\ a_{44} = 0.0001 & a_{55} = 0.0045 & a_{12} = -0.0432 \\ a_{13} = 0.2626 & a_{14} = -0.0211 & a_{15} = -0.0177 \\ a_{23} = -0.0176 & a_{24} = -0.0030 & a_{25} = -0.0267 \\ a_{34} = 0.0300 & a_{35} = 0.0068 & a_{45} = 0.0036 \end{array}$$

### 3.3 회귀모델식의 최적화 및 최적성형조건 비교

한편 체적수축률의 평균 값 및 편차 값은 목적 함수로 두고 이를 최소화하는 사출성형조건은 최적화 상용 소프트웨어인 IDESIGN<sup>®</sup>을 이용하여 구하였다. 먼저 정규화 된 체적수축률의 평균 값에 대한 회귀모델식의 반복횟수에 따른 수렴매개변수 값의 분포가 Fig. 7에 목적함수 값의 분포가 Fig. 8에 그리고 공정변수의 변화가 Fig. 9에 보여진다. 수렴매개변수 값은 7회 반복 이후 허용 수렴매개변수 범위를 만족하여 프로그램이 멈추었으며,  $x_1=1.0$ ,  $x_2=1.0$ ,  $x_3=0.0$ ,  $x_4=0.0$ ,  $x_5=0.0$ 의 조건에서 정규화 된 체적수축률의 평균 값 0.0639가 얻어졌다. 이를 신경회로

방법 시뮬레이션 결과와 비교하기 위한 데이터가 Table 5에 주어졌다.

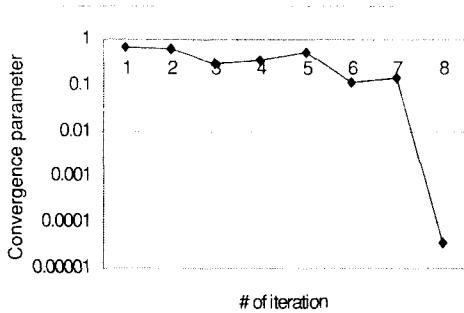


Fig. 7 Convergence parameter according to the iteration( $y_1$ )

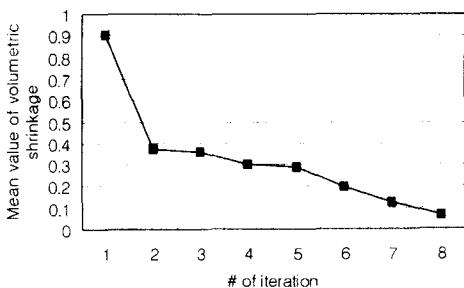


Fig. 8 Normalized mean value of volumetric shrinkage according to the iteration( $y_1$ )

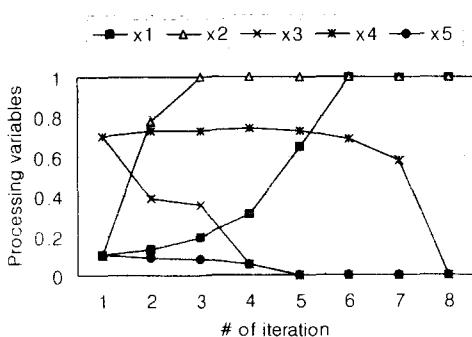


Fig. 9 History of processing variables( $y_1$ )

Table 5의 결과를 보면 체적수축률의 평균 값이

최소가 되는 조건이 사출속도( $x_5$ )를 제외하고는 3 가지 방법의 경우에 대하여 동일한 결과를 준다. 즉 용융 수지온도와 보압이 크고 금형온도와 보압 시간이 작을수록 정규화 된 체적수축률의 평균 값은 최소가 되며, 최소 값 자체는 시뮬레이션 결과가 0.0, 신경회로망 결과가 0.0065 및 회귀모델식의 결과가 0.0639로 0.65%에서 6.39% 정도 차이가 있음을 볼 수 있다.

Table 5 Comparison of results of mean value of volumetric shrinkage( $y_1$ )

Item	Simulation	NN	Reg.
$x_1$	1.0	1.0	1.0
$x_2$	1.0	1.0	1.0
$x_3$	0.0	0.0	0.0
$x_4$	0.0	0.0	0.0
$x_5$	1.0	1.0	0.0
$y_1$	0.0	0.0065	0.0639

다음으로 정규화 된 체적수축률의 편차 값에 대한 회귀모델식의 반복횟수에 따른 수렴매개변수 값의 분포가 Fig. 10에 보여지고, 목적함수 값의 분포가 Fig. 11에 보여지고 그리고 공정변수의 변화가 Fig. 12에 보여진다. 수렴매개변수 값은 9회 반복 이후 혼용 수렴매개변수 범위를 만족하여 프로그램이 멈추었으며, 각 공정조건이  $x_1=0.0$ ,  $x_2=1.0$ ,  $x_3=1.0$ ,  $x_4=0.0$ ,  $x_5=1.0$ 의 값에서 정규화 된 체적수축률의 평균 값 0.0092가 얻어졌다. 이를 신경회로망 및 시뮬레이션 결과와 비교하기 위한 데이터가 Table 6에 보여준다.

Table 6의 결과를 보면 체적수축률의 편차 값이 최소가 되는 조건도 체적수축률의 평균값에 대한 결과와 유사하게 사출속도( $x_5$ )를 제외하고는 3 가지 방법의 경우에 대하여 동일한 결과를 준다. 즉 보압과 금형온도가 크고 용융 수지온도 및 보압시간이 작을수록 정규화된 체적수축률의 편차 값은 최소화하였으며 최소 값 자체는 시뮬레이션 결과가 0.0, 신경회로망 결과가 0.037 및 회귀모델식의 결과가 0.0092로 0.92%에서 3.7% 정도의 차이가 있음을 볼 수 있다.

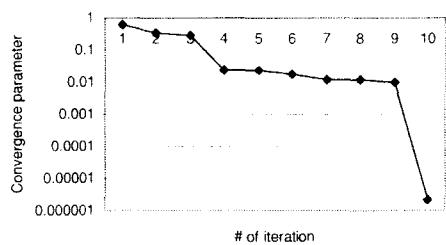


Fig. 10 Convergence parameter according to the iteration( $y_2$ )

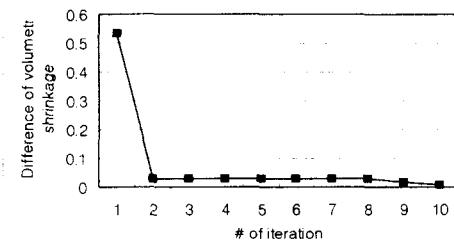


Fig. 11 Normalized mean value of volumetric shrinkage according to the iteration( $y_2$ )

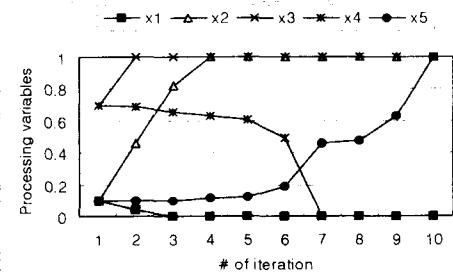


Fig. 12 History of processing variables( $y_2$ )

Table 6 Comparison of results of difference of volumetric shrinkage( $y_2$ )

Item	Simulation	NN	Reg.
x1	0.0	0.0	0.0
x2	1.0	1.0	1.0
x3	1.0	1.0	1.0
x4	0.0	0.0	0.0
x5	0.5	0.5	1.0
y2	0.0	0.037	0.0092

#### 4. 결론

용융 수지온도, 보압, 금형온도, 보압시간 및 사출속도 등의 공정조건이 엔지니어링 플라스틱 기어의 체적수축률에 끼치는 영향을 분석하기 위해 Moldflow<sup>(r)</sup> 소프트웨어를 이용한 모의실험으로부터 얻은 27개 학습데이터에 역전파 학습 알고리즘을 적용하여 5-3-2 신경회로망을 구성하였는데 모의실험 결과와 비교하여 좋은 일치를 보여주었다. 또한 공정조건과 품질인자로 정의된 체적수축률의 평균 값 및 편차 값과의 관계식을 유도하기 위해 학습된 신경회로망을 5개 인자를 5수준으로 확장한 3,125 개 조건에 적용시켜 그로부터 2차 다항 비선형 회귀모델식을 구하였다. 체적수축률의 평균 값 및 편차 값을 최소화하는 회귀모델의 최적화를 반복이차 계획법알고리즘을 적용하여 도출하였으며 이를 결과를 모의실험 및 신경회로망에 의한 결과와 비교하였는데 사출속도를 제외한 용융 수지온도, 보압, 금형온도, 보압시간 등의 공정조건에서 3 가지 경우에 대하여 일치된 결과를 보여주었다. 특히 체적수축률의 평균 값은 용융 수지온도 및 보압이 크고 (1.0) 금형온도 및 보압시간이 작을수록(0.0), 체적수축률의 편차 값은 보압 및 금형온도가 크고(1.0) 용융 수지온도 및 보압시간이 작을수록(0.0) 최소값을 보여주었다. 한편 사출속도 값은 모의실험과 신경회로망의 결과는 서로 일치하나 회귀모델식의 결과와는 차이가 나타났다. 최적조건에서 정규화된 체적수축률의 평균 값 및 편차 값의 최소값은 3가지 경우 사이에 0.65%에서 6.39% 정도의 오차를 보였다. 본 연구에서는 성형조건에 따른 체적수축률의 평균 및 편차 값을 품질 변수로 정하였으나, 향후 성형재료 및 금형과 관련한 설계변수도 포함하고 품질 변수의 수도 늘려 본 연구에서 적용된 최적화 과정을 이용하면 다양한 설계 및 성형조건 하에서도 성형품의 품질 예측이 가능하리라 사료된다.

#### 참고문현

- Tadmor Z. and Gogos C. G., "Principles of Polymer Processing," John Wiley & Sons, pp.584-610, 1979.
- Rheinfeld, D., "Influencing Molding Quality During Injection Molding," VDI-Verlag,

- pp.297-298. 1981.
3. Taguchi, G. "Introduction to Quality Engineering: Designing Quality into Products and Processes." Asian Productivity Organization, pp.101-102, 1986.
  4. Blyskal, P. J.. "Applying DOE Analysis Techniques to the Injection Molding Process," ANTEC '94, pp.729-803. 1994.
  5. Viana, J. C., Kearney , P., and Cunha, A. M., "Improving Impact Strength of Injection Molded Plates through Molding Conditions Optimization: A Design of Experiments Approach," ANTEC '98, pp.646-650, 1998.
  6. Meheran, P. J. and Blyskal, P. J., "Design of Experiments for the Injection Molding Process." ANTEC '95, pp.506-509. 1995.
  7. Chao, P. Y., Ferreira, P. M., and Liu, C. R., "Applications of GMDH-type Modeling in Manufacturing," J. of Manufacturing Systems, Vol. 7, No. 3, pp.241-252. 1988.
  8. Sarychev, A. P., "Averaged Regularity Criterion for the Group Method of Data Handling in the Problem of Searching for the Best Regression," Soviet J. of Automation and Information Sciences. Vol. 23, No. 5, pp.24-29, 1990.
  9. Ravidra, H. V. and Krishnamurthy, R.. "Tool Wear Estimation by Group Method of Data Handling in Turning," International J. of Production Research, Vol. 32, No. 6, pp.1295-1312, 1994.
  10. Min, B. H., "An Analysis of Shrinkage of Injection Molded Parts based on the GMDH Algorithm," J. of Injection Molding Technology, Vol. 1, No. 4, pp. 204-211. 1997.
  11. Kameoka, S. and Sakai, T., "Development of an Expert System for Injection Molding," Advances in Polymer Technology. Vol. 12, No. 4, pp.403-407, 1993.
  12. Chin, K. S. and Wong, I. N., "Knowledge-based Evaluation for the Conceptual Design Development of Injection Molding Parts," Engineering Applications of Artificial Intelligence, Vol. 9, No. 4, pp.359-376, 1996.
  13. Sheleshnezhad, K. and Siories, E. "Intelligent System for Plastic Injection Molding Process Design," Journal of Materials Processing Technology, Vol. 63, pp. 458-462. 1997.
  14. Demirci, H. H., Coulter J. P., and Guerri, S. I., "A Numerical and Experimental Investigation of Neural Network-Based Intelligent Control of Molding Processes," Journal of Manufacturing Science and Engineering, Vol. 119, No. 1, pp.88-94, 1997.
  15. Ivester, R. and Danai, K. "Automatic Tuning and Regulation of Injection Molding by the Virtual Search Method," Journal of Manufacturing Science and Engineering, Vol. 120, No. 1, pp.323-329, 1998.
  16. Moller, J. C. and Rowe, J. J., "Prediction of Injection Molded Part Quality by Neural Networks," ANTEC '98, pp.651-654, 1998.
  17. Petrova, T. and Kazamer, D., "Development of a Hybrid Neural Network for Quality Control of Injection Molding," ANTEC '98, pp.655-659, 1998.
  18. Kim, S. J., Lee, K., and Kim, Y. I., "Optimization of Injection-modeling Conditions using Genetic Algorithm," Proceedings of SPIE-International Society for Optical Engineering, pp.173-180, 1996.
  19. Arora, J. S. and Tseng, C. H., "IDESIGN User's Manual," The University of Iowa, pp.24-28, 1986.
  20. Arora, J. S., "Introduction to Optimum Design," McGraw-Hill, pp.404-407, 1989.
  21. Haupt, U., "Production of Gear Wheel Sets for Seat Adjustment Gears of Cars by using Metal Injection Molding Technology," Advances in Powder Metallurgy and Particulate Materials, Vol. 2, No. 6, pp.287-294, 1995.
  22. Fausett, L., "Fundamentals of Neural Networks," Prentice Hall, pp.289-304. 1994.