

플라스틱 광학렌즈 사출성형에 있어서 수축 변형량 예측을 위한 사출성형 조건 탐색에 관한 연구

곽태수*, 오오모리히토시*, 배원병#

A study on searching method of molding condition to control the thickness reduction of optical lens in plastic injection molding process

Tae Soo Kwak*, Hitoshi Ohmori*, Won Byong Bae#

ABSTRACT

In the injection molding of plastic optical lenses, the molding conditions have critical effects on the quality of the molded lenses. Since there are many molding parameters involved in injection molding process, determination of the molding conditions for lens molding is very important in order to precisely control the surface contours of an optical lens. Therefore this paper presents the application of neural network in suggesting the optimized molding conditions for improving the quality of molded parts based on data of FE Analysis carried out through CAE software, Timon-3D. Suggested model in this paper, which serves to learn from the data of FE Analysis and induce the values for optimized molding conditions, has been implemented for searching the molding conditions without void and with minimized thickness shrinkage at lens center of injection molding optical lens. As the result of this study, we have confirmed that void creation at the inside of lens is primarily determined by mold temperature and thickness shrinkage at center of lens is primarily determined by the parameters such as holding pressure and mold temperature.

Key Words : Optical lens(광학렌즈), Plastic injection molding(플라스틱 사출성형), Molding conditions(사출조건), Neural network(신경회로망)

1. 서론

정밀 사출성형 기술은 낮은 제조 비용과 대량 생산의 장점이 있으므로 플라스틱 광학 렌즈와 같은 고부가가치 부품을 제조하는데 있어서 주목받고 있다. 반면에 사출성형에 의한 플라스틱 렌즈는 유리 등의 재질에 비해 가공 중 열변형이 심하

므로 높은 치수정밀도를 내기 어려울 뿐 아니라 공정 변수가 많아 사출 조건을 제어하는데 많은 어려움이 있다. 특히 광학 렌즈는 성능과 직결되는 표면 형상의 정밀한 제어가 요구되므로 사출 조건 결정에 상당한 시간과 경험이 요구된다. 따라서 최근에는 플라스틱 광학렌즈의 개발과 더불어 초 정밀 사출성형 부품의 품질을 정밀하게 제

접수일: 2003년 07월 14일; 게재승인일: 2003년 11월 14일

* 이화학연구소(RIKEN), Japan

교신저자: 부산대학교 기계공학부

E-mail wbbae@pusan.ac.kr Tel. (051) 510-2313

어할 수 있는 사출성형 조건의 탐색 방법에 대한 연구가 이루어 지고 있다.

사출성형 조건의 탐색과 관련된 최근의 연구 동향을 살펴보면 사출성형 조건을 결정하기 위해 사출성형 해석 프로그램 또는 실험에 의한 지식 데이터 베이스를 기초로 통계적 기법,¹ 신경회로망 기법,^{2,6} 유전자 알고리즘 기법³ 등을 적용하는 연구가 활발히 이루어 지고 있다.

최적화와 관련된 초기의 연구는 주로 실험결과를 이용한 통계적인 방법에 의존하였다.⁴ 즉, 실험 결과로부터 입력변수에 따른 출력변수의 상관관계를 통계적으로 분석하고 사출성형 조건을 예측하는 방식이다. 이러한 방법은 통계처리 데이터를 얻기 위해 일정한 실험이 수행되어야 하고 새로운 사출조건이 설정된 후에도 최적의 조건이 결정될 때까지 실험을 반복 수행하는 방법으로서 시간적, 공간적 제약이 뒤따랐다. 이후 사출성형 해석 프로그램이 개발되면서 실험에 의존하지 않고 근사적인 수지의 유동 특성 및 결합 등의 예측이 가능하게 되었다.

이러한 시뮬레이션 기술의 발전과 함께 G.H.Choi⁵ 등은 CAE 해석 결과를 이용하여 사출성형 조건의 최적화를 시도한 바 있으며, B.H.Min⁶은 실험계획법의 직교배열표에 의한 CAE 해석 횟수를 결정하고 신경회로망과 2 차 다항 회귀 모델식으로 체적 수축률의 최적화를 시도하였다. 또한 B.H.M. Sadeghi⁷는 공학용 전자계산기 커비에 대하여 G.H.Choi⁵와 유사한 방법을 적용하였으나 약 2000 여 회의 과도한 CAE 해석 수행이 필요하여 시간적 제약이 예상되었다. 이 외에도 H.C.W. Lau² 등은 샘플제품의 주요 치수를 입력변수로 하고 성형공정 변수를 출력변수로서 예측하는 역 추적 신경회로망 모델을 제안하기도 하였다. 현재까지 이러한 최적화 연구에서는 사출성형 조건의 예측 가능성을 확인하는 수준이므로 이론적인 계산에 의해 그 결과를 평가하였다.

본 연구에서는 신경회로망 예측 시스템을 제안하고 플라스틱 초 정밀 광학렌즈의 사출성형 조건 탐색에 적용하여 사출성형 해석 및 실험을 통해 예측기의 성능을 확인하였다. 학습 데이터는 CAE 해석 결과를 사용하였으며 해석의 횟수를 줄이기 위하여 실험계획법의 직교배열표를 사용하였다.

2. 방법론

본 연구에서 제안하고 있는 방법은 Fig. 1 과 같다. 대상 제품 선정 후 CAD 모델링과 동시에 최적화 목표값, 즉 입출력 변수를 선정하고 직교배열표를 작성하여 사출성형 해석 조건과 횟수를 결정한다. 해석 결과 데이터는 신경회로망 학습 과정을 거쳐 뉴우런의 가중치(weight value)를 계산하는데 사용된다. 가중치 계산이 성공적으로 완료되면 신경회로망 프로그램은 임의 조건에 대한 목적값(출력변수)의 계산이 가능하다. 본 연구에서는 다원배치표를 작성하여 사출조건 조합에 대해 목적값을 계산하였으며, 예측 값의 검정을 위해서 사출성형 해석 및 실험을 수행하였다. 신경회로망은 입력층과 은닉층, 출력층으로 구성되어 있으며, 입력 변수는 작업성이 편리하며 품질에 영향이 큰 사출성형 조건을 우선적으로 선정하였다.

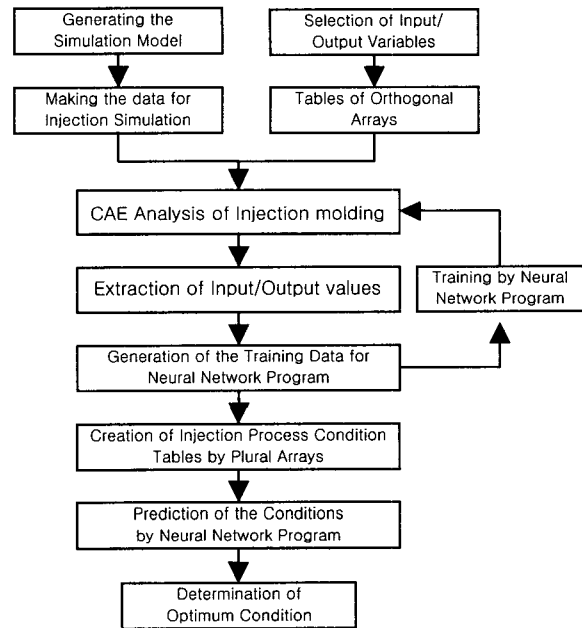


Fig. 1 Flow chart for optimization of molding parameters in the plastic injection molding process

근사의 목적값을 예측하기 위한 학습데이터는 신경회로망 예측기의 성능을 결정하는 중요한 데이터이다. 고정도의 학습데이터를 얻기 위해서는 각 요인과 수준을 정의하여 다원배치표에 따라 실험을 수행한 후 그 결과를 이용하는 것이 이상적

이나 요인의 수가 늘어나면 실험의 횟수가 기하급수적으로 증가하므로 시간과 공간, 비용 측면에서 매우 비효율적이다. 다행히 신경회로망의 학습 데이터는 입력변수 즉, 사출조건에 따라 정성적으로 일정한 경향을 가진 데이터에 의해 가중치의 계산이 가능하므로 사출성형 해석 결과는 학습데이터로 사용할 수 있다. 학습 데이터의 신뢰성을 높이고 해석 시간을 단축하기 위해 Taguchi⁸가 제안한 실험계획법의 직교배열표를 이용하였다. 실험계획법은 직교배열표를 이용하여 특성 값에 대한 요인의 영향도를 효율적으로 해석하는 방법으로서 품질관리를 중심으로 폭 넓게 이용되고 있는 방법이다.

2.1 사출성형 해석

대상으로 선정된 모델은 8 mm 비디오 카메라용 플라스틱 비구면 광학 렌즈이다. 외곽 직경이 16.6 mm, 렌즈의 유효 직경은 12.48 mm 이며 렌즈 중심부 두께는 2.6 mm, 구면 반경(R) 16.16 mm, 비구면 반경(R) 72.547 mm 이다. 플라스틱 재료는 투명성이 우수한 PMMA(Poly Methylmethacrylate) 수지를 사용하였다.




Fig. 2 Aspherical lens and mesh modeling

Fig. 2 는 비구면 렌즈의 사진과 요소분할 모델을 보여주고 있다. 사출성형 해석을 위한 프로그램은 3D Timon v.6.11(Toray co., Japan)을 사용하였으며, 렌즈의 표면 형상을 최대한 표현하고 계산시간을 단축하기 위하여 렌즈 코어는 사면체 요소를, 그리고 게이트와 런너, 스프류는 쉘(shell)과 빔(beam) 요소를 사용하였다.

위 프로그램은 충전 해석시 일반적인 유체역학의 기초식인 연속식, 운동방정식, 에너지 방정식으로 구성된 지배방정식을 사용하며 압축항, 관성항, 중력항은 무시하고 정상상태로 가정하고 있다.⁹

사출성형 해석 프로그램은 모델링 요소의 형상에 따라 다른 결과를 보여주며, 중력계산, 전단발

열, 금형을 통한 열전달 등을 무시하여 정식화 하고 있으므로 정밀 부품에 있어서 정량적인 값을 정확히 예측하는 것은 어렵다.

Table 1 Input condition of 4 factors and 3 levels

Factors	Levels	Z ₀	Z ₁	Z ₂
T _{melt} (°C)		280	300	320
T _{mold} (°C)		100	120	140
t _{filling} (sec)		0.5	0.7	1.0
t _{holding} (sec)		1.0	1.5	2.0

Table 2 Orthogonal Arrays of 4 factors and 3 levels

Data Number	Factors			
	T _{melt} (°C)	T _{mold} (°C)	t _{filling} (sec)	t _{holding} (sec)
1	280	100	0.5	1
2	280	100	1	1.5
3	280	100	1.5	2
4	280	120	0.5	1
5	280	120	1	1.5
6	280	120	1.5	2
7	280	140	0.5	1
8	280	140	1	1.5
9	280	140	1.5	2
10	300	100	0.5	1.5
11	300	100	1	2
12	300	100	1.5	1
13	300	120	0.5	1.5
14	300	120	1	2
15	300	120	1.5	1
16	300	140	0.5	1.5
17	300	140	1	2
18	300	140	1.5	1
19	320	100	0.5	2
20	320	100	1	1
21	320	100	1.5	1.5
22	320	120	0.5	2
23	320	120	1	1
24	320	120	1.5	1.5
25	320	140	0.5	2
26	320	140	1	1
27	320	140	1.5	1.5

그러나 동일한 요소 모델을 이용하는 경우에 사출성형 해석 프로그램은 사출 조건별 비교, 금형 형상별 비교, 수지의 종류에 따른 비교 등의 경향성 예측이 가능하므로 신경회로망의 학습데이터를 얻을 수 있다.

본 논문에서 사출성형 해석은 신경회로망 학습 데이터를 얻기 위한 것이므로 앞서 제안한 직교배열표에 따라 해석 함으로서 입력변수의 동등한 영향도를 가진 데이터를 얻을 수 있다. 학습데이터를 얻기 위하여 직교배열표에서 사용된 입력변수의 수준과 요인은 Table 1 과 같다. 입력변수는 3 수준 4 요인으로 설정하였으며 Table 2 와 같이 $L_{27}(3^4)$ 의 직교배열표를 작성하였다.

2.2 신경회로망 모델

신경회로망은 분류 및 연상 기억, 함수 근사 등에 사용될 수 있으며, 비선형 문제를 다루는데 있어서 통계학적 접근 데이터의 해석과 관련이 있는 반면 신경회로망은 예측 값을 포함한 계산 가능한 모든 함수를 계산할 수 있다.¹⁰ 즉, 입력 및 결과 값을 포함하는 학습데이터에 의해 성공적인 학습 후에는 입력 데이터만을 제시하여 기대되는 근사의 출력 값을 계산할 수 있다.

사출성형 해석에서 사용된 사출성형 조건을 입력변수로, 각 사출조건에 따른 해석 결과값을 출력변수로 추출하였다. 입력 변수는 사출온도(T_{melt}), 금형온도(T_{mold}), 사출시간($t_{filling}$), 보압시간($t_{holding}$)의 4 요인으로 하였고, 렌즈 중심부에 있어서 두께 수축 변형률(S)와 렌즈 내부와 표면간의 체적 수축 변형율 비(D)를 출력변수로 각각 선정하였다.




Fig. 3 Structure of neural network for prediction model

Fig. 3 은 4 개의 입력층과 2 개의 출력층 그리고 5 개의 은닉층(Hidden Layer)으로 구성된 신경회로망이다. 학습률(learning rate)과 문턱값(threshold)은 각각 0.9 와 0.003 으로 하였으며, 계산된 가중치(weight value)에 의해 입력 변수에 대한 출력변수를 예측하였다. 이때, 입력변수에 따른 출력변수를 예측하기 위해 사출온도, 금형온도, 충전시간, 보압시간에 대하여 각각 9, 9, 6, 5 수준으로 설정하고 다원배치표를 작성하여 2,430 개의 사출조건 조합을 얻었다.

3. 실험

3.1 실험장치

사출 성형 실험에서 사용된 사출 성형기와 금형은 Fig. 4,5 와 같다. 사출 성형기는 최대 사출압력 2,610 kgf/cm², 사출률 114 cm³/s, 형체력 50 ton 인 Tuparl TR50S2(Sodick Plastech.co.Ltd, Japan)이며, 실험에 사용된 렌즈 금형의 개취수는 2 개이다. Fig. 5 는 금형의 코아부 사진이다. 플라스틱 수지의 흡습량이 렌즈의 품질에 영향을 미치지 않도록 전기식 오븐 내에서 80℃, 6 시간 건조 시킨 후 실험하였다.





Fig. 4 Plastic injection molding machine



(a) Lower side (b) Upper side

Fig. 5 Cavity of mold for plastic optical lens

3.2 사출조건 선정

본 실험을 위한 사출성형 조건은 Table 3 과 4 에 나타내었다. Table 3 은 렌즈 내부의 기공 예측 실험을 위해 사용되었으며 실험 후에는 각 조건에 따라 발생된 기공의 비율을 백분율로 환산하였다. 렌즈 중심부에서 기공 발생의 원인은 충전이 완료된 후 냉각과정에서 급형과 접촉하고 있는 렌즈의 표면과 렌즈 내부의 고화속도 차이로 인해 발생하는 것으로 예상된다. 체적 수축 변형율 비(D)는 냉각 시 렌즈 표면과 내부의 온도차에 의한 고화속도 차이를 나타내는 지표가 되며 다음과 같다.

$$D = D_i - D_s$$

여기서, D_i 와 D_s 는 각각

$$D_i = \left[\frac{V_s - V_{atm}}{V_s} \right]_{inside}, \quad D_s = \left[\frac{V_s - V_{atm}}{V_s} \right]_{surface}$$

로 표시되며 렌즈 내부와 표면에서의 기준 절점에 대한 체적 수축 변형율 비이다. 또한, V_s 는 수축개시 시의 비체적이며 V_{atm} 은 대기압 하에서의 비체적이다. Table 3 은 신경회로망으로 예측된 결과에 따라 선정된 대표 조건으로 기공발생 예측에 사용되었으며 해석 결과와의 비교를 위해 사출 성형 해석을 수행하였다. Table 3 이외의 사출 조건 즉, 사출압력, 보압력, 보압 후 냉각시간은 각각 130 Mpa, 70 Mpa, 40 sec 로 동일 조건으로 하였다. 사출 조건 별로 7 회씩 실험하여 샘플은 모두 84 개를 얻을 수 있었다.

Table 3 Injection molding conditions

Inj. Conditions	1	2	3	4	5	6
T _{melt} (°C)	295	315	300	295	280	315
T _{mold} (°C)	140	140	135	130	120	120
t _{filling} (sec)	0.7	0.6	0.8	0.5	0.9	0.7
t _{holding} (sec)	2.0	1.0	1.0	1.0	2.0	1.3

Table 4 은 신경회로망 프로그램에서 예측된 렌즈의 두께 값에 따라 선정된 조건이다. 본 조건에 따라 실험하고 두께를 측정하였으며 그 결과는 신경회로망 예측 값과 비교하였다. 신경회로망 프로그램은 유한요소 모델링 및 계산 오차와 신경회로망의 RMS 오차 등을 포함하고 있다. 따라서 오차에 의한 영향을 줄이기 위해 실험조건을 일정한

그룹으로 묶고 측정값을 그룹별로 평균 하였다. 앞서 수행한 렌즈내부의 기공발생 실험 결과에 따라 기공이 발생하지 않는 사출조건 범위 내에서 렌즈중심부의 수축 변형량을 오름차순으로 배열하고 사출조건을 7 그룹으로 나누어 실험을 수행한 후 측정하였다. 렌즈내부의 기공발생 실험에서와 마찬가지로 입력변수 외의 사출 조건은 동일조건으로 하였다. 각 그룹별로 60 개의 샘플을 취하여 총 420 개의 샘플을 얻었다. 렌즈중심부의 두께는 마이크로 미터로 측정하였으며 측정기의 오차는 ±1 마이크로 미터였다.

Table 4 Injection molding conditions

Group	Injection Conditions	T _{melt} (°C)	T _{mold} (°C)	t _{filling} (sec)	t _{holding} (sec)
1	A	280	140	0.6	2.0
	B	280	140	1.0	1.5
	C	285	140	1.0	1.0
	D	310	140	0.8	2.0
	E	310	140	1.0	1.7
2	A	285	140	0.6	1.7
	B	285	140	0.7	1.5
	C	285	140	0.8	1.3
	D	285	140	0.9	1.0
	E	290	140	0.8	1.5
3	A	285	140	0.7	1.3
	B	290	140	0.6	1.7
	C	295	140	0.8	1.5
	D	295	140	1.0	1.3
	E	315	140	0.9	1.7
4	A	295	140	0.6	1.7
	B	300	140	0.5	2.0
	C	310	140	0.6	2.0
	D	315	140	1.0	1.5
	E	320	140	0.9	1.7
5	A	280	140	0.9	1.3
	B	305	140	0.6	1.7
	C	305	140	0.9	1.3
	D	310	140	0.8	1.5
	E	320	140	0.8	1.7
6	A	280	140	0.7	1.3
	B	305	140	0.9	1.0
	C	305	140	0.7	1.3
	D	310	140	1.0	1.0
	E	320	140	0.9	1.3
7	A	280	140	0.5	1.0
	B	280	140	0.6	1.0
	C	280	140	0.7	1.0
	D	280	140	0.8	1.0
	E	295	140	0.6	1.0

4. 결과 및 고찰

신경회로망 학습데이터를 얻기 위해 Table 2 의 사출조건에 대해 27 회의 사출성형 해석을 수행하여 신경회로망 학습에 필요한 데이터를 Fig. 6 및 Fig. 7 와 같이 얻을 수 있었다.




Fig. 6 Volumetric distortion rate(D) from simulation results




Fig. 7 Shrinkage(S) at lens center from simulation results

Fig. 6 은 사출성형 해석을 통해 얻어진 체적 수축 변형율 비(D)의 예측을 위한 학습데이터를 보여주고 있다. 체적 수축 변형율 비(D)는 금형의 온도와 반비례하였고, 충전 온도와 비례함을 알 수 있다. 그러나 학습데이터에서 충전 시간과 보압 시간에 의한 영향은 확인하기 어려웠다. Fig. 7 는 렌즈 중심부 두께에서의 수축 변형량(S) 예측을 위한 학습데이터를 보여주고 있다. 충전 온도와 금형 온도는 증가할수록 렌즈 중심부에 있어서 수축 변형량(S)이 커지는 경향을 볼 수 있으며, 충전 시간과 보압 시간에 의한 영향은 뚜렷한 경향성을 확인하기는 어려웠다. Fig. 6 과 Fig. 7 에서 체적수축 변형율에 대한 금형온도의 영향은 가장 뚜렷하였다. 그러나 다변수에 대한 사출조건에 대한 신경회로망 프로그램은 이러한 학습데이터로서 학습과

정을 수행하고 각 뉴우런의 가중값이 계산되었으며 다원배치표에 의한 사출 조건의 조합에 대해 다변수 출력값을 구할 수 있었다.

4.1 기공 결함 예측

신경회로망 예측기를 통해 체적 수축 변형율 비(D)를 예측하고 Table 3 에서 선정된 6 가지의 사출성형 조건에 대해 유한요소 해석을 재수행하여 Fig. 8 과 같은 결과를 얻었다. Fig. 8 에서 보는바와 같이 두 그래프는 0.8% ~ 15% 내에서 일치하였다. 뿐만 아니라 사출조건에 따라 정성적으로 증가하는 경향은 잘 일치하였다.

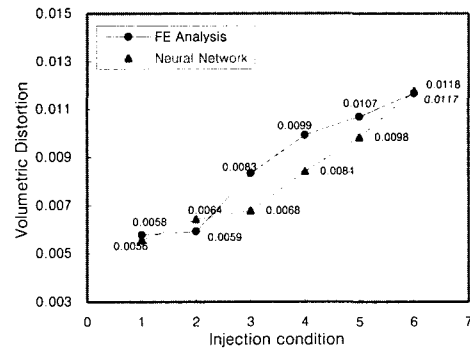


Fig. 8 Volumetric distortion rate(D) predicted by FE analysis and neural network program




Fig. 9 Percentage of void creation inner lens

3.2 절에서 설명한 바와 같이 체적 수축 변형율 비가 커질수록 렌즈 내부에서 기포생성의 가능성이 높아진다. 본 연구에서는 위의 6 가지 사출조건에 따라 실험한 후 렌즈 내부에 기공이 발생한 비율을 백분율로 표시하여 Fig. 9 의 그래프를 얻은

수 있었다. Fig. 9 의 실험 결과는 체적 수축 변형을 비가 작은 1, 2, 3 번 조건에서는 기공이 발생하지 않고 체적 수축 변형을 비가 커질수록 기공 발생률이 현저함을 보여주고 있다. 따라서 볼록렌즈의 사출성형에 있어서 체적 수축 변형을 비를 예측하고 대표조건에 대한 간단한 실험에 의해 렌즈 내부의 기공 결함 예측이 가능하였다.

4.2 수축 변형량(S) 예측

4.1 절에서 금형의 온도는 체적수축 변형율의 값을 결정하며 체적수축 변형율은 기공발생과의 연관성이 확인되었다. 따라서 금형의 온도를 최고 온도인 140℃로 일정하게 유지하여 수축 변형량 S에 의한 렌즈의 두께 변화를 확인하기 위한 조건을 Table 4 와 같이 선정하였다. 수축 변형량 예측 실험은 Table 4 의 조건에 따라 수행되었으며 실험 후 렌즈 중심부를 측정하여 Fig. 10 의 그래프를 얻을 수 있었다.

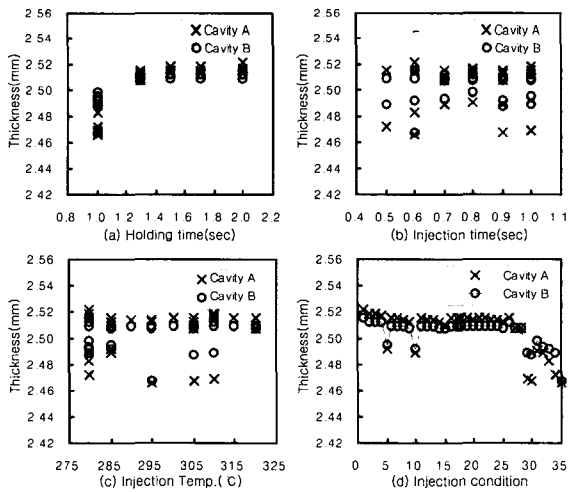


Fig. 10 Experimental results for thickness shrinkage(S)

금형의 온도가 일정한 경우에 Fig. 10 (a)와 같이 보압 시간이 증가할수록 렌즈의 두께는 증가하였다. 이것은 보압 시간이 길어질수록 두께 수축 변형량은 줄어든다는 것을 의미한다. 또한 보압 시간 1.3 초 이상에서 두께 수축량의 변화는 적었다. Table 4 의 조건에서의 실험결과에 의하면 Fig. 10 (b), (c)와 같이 수축 변형량은 사출시간과 사출 온도와의 관련성을 확인하기는 어려웠다. Fig. 10 의 (d)는 사출 조건에 따른 두께 측정 결과 그래프이

다. Fig. 11 은 신경회로망에 의한 렌즈의 두께를 예측한 결과와 사출성형 해석 값을 비교한 그래프이다. 두 그래프의 경향성은 잘 일치함을 알 수 있다. Fig. 12 는 캐비티 별로 두께를 측정하고 평균한 실험 결과이다. 실험에서 동일한 사출조건에서도 캐비티 간의 오차가 있었으며 이것은 금형의 치수공차와 캐비티 간의 비대칭성, 금형온도의 차이, 중력방향과 중력의 반대 방향으로의 용융수지의 흐름 등의 원인에 의한 오차로 생각된다. 캐비티 간에는 최소 5.0 마이크론에서 최대 7.6 마이크론의 두께 차이가 있었다.

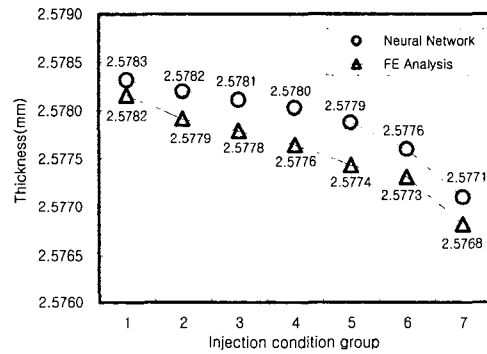


Fig. 11 Thickness shrinkage vs injection condition at lens center predicted from neural network program

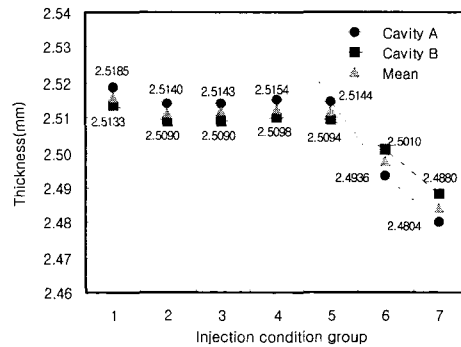


Fig. 12 Thickness shrinkage vs injection condition at lens center measured from experimental results

Fig. 11 과 Fig. 12 의 그래프를 비교해 보면 경향은 잘 일치하고 있으나, 예측값과 실험 결과값의 절대치는 다소 차이를 보여주었다. 이것은 2.1 절에서 설명한 바와 같이 유한요소분할 모델의 치수와 금형의 실제 치수의 오차와 계산오차 등을 포

함하고 있으므로 정량적인 값의 예측은 일정 범위 내에서 가능하였다. 본 논문에서 사출성형 해석 및 신경회로망 프로그램은 사출 조건에 따른 출력 값의 경향 예측을 목적으로 하고 있다. Fig. 11 과 Fig. 12 의 결과는 본 연구에서 제안한 신경회로망 프로그램의 예측값과 성형해석 결과 그리고 실험 결과값이 정성적으로 매우 잘 일치함을 보여준다. 따라서 Table 4 의 사출성형 조건 가운데 첫번째 그룹의 사출 조건에 따라 사출 성형을 하는 경우 렌즈 두께의 수축 변형량을 최소화 할 수 있음을 확인하였다.

5. 결론

사출성형 해석 결과와 신경회로망 프로그램을 응용하여 정밀 사출성형 조건의 결정 방법을 제안 하고 표면 형상의 정밀한 제어가 요구되는 플라스틱 비구면 광학 렌즈에 적용하여 다음과 같은 결론을 얻었다.

1. 렌즈 내부와 렌즈 표면간의 체적 수축 변형율 비(D)는 렌즈 내부의 기공발생 비율과 비례하였으며, 금형의 온도가 높아질수록 체적 수축 변형율 비는 작아졌다.
2. 보압 시간이 길수록 렌즈 중심부의 두께 수축 변형량(S)이 감소하였으며 보압 시간 1.3 초 이상에서 두께 수축 변형량의 변화는 적었다.
3. 사출성형 해석 결과를 학습데이터로 이용하고 신경회로망 프로그램으로 체적 수축 변형율 비(D)를 예측하여 사출성형 해석과 비교한 결과 두 값은 0.8% ~ 15%내에서 일치하였으며 정성적인 경향도 잘 일치하였다.
4. 사출성형 해석 결과를 학습 데이터로 이용하고 신경회로망 프로그램으로 두께의 수축 변형량(S)을 예측하여 사출성형 해석 및 실험과 비교하였으며 두 그래프는 정성적으로 잘 일치하였다.

정밀 사출성형 기술은 사출성형 조건의 결정에 있어서 지식 데이터 베이스를 활용한 최적화 방법이 요구되고 있다. 제품의 특성에 맞는 최적화 변수를 선정하여 본 연구에서 적용된 방법을 이용하면 플라스틱 광학 렌즈와 같은 정밀 사출성형품의 다양한 사출성형 조건의 탐색이 가능할 것이다.

참고문헌

1. Lu, Xuehong, Khim, Lau Soo, "A statistical experimental study of the injection molding of optical lenses," J. of material processing technology vol.113, pp.189 - 195, 2001.
2. Lau, H.C.W., Ning, A., Pun, K.F., Chin, K.S., "Neural networks for the dimensional control of molded parts based on a reverse process model," J. of material processing technology, vol.117, pp.89 - 96, 2001.
3. Kim, S.J., Lee,K., Kim, Y.I., "Optimization of injection-molding conditions using genetic algorithm," Proceedings of SPIE-International Society for optical Engineering, pp.173 - 180, 1996.
4. Wu, J.L., Chen, S.J., "Pattern analysis of injection molding process: statistical correlation study," SPE ANTEC, Vol. 48, pp. 233 - 237, 1990.
5. Choi, G.H., Lee, K.D., Chang, N., Kim, S.G., "Optimization of Process Parameters of Injection Molding with Neural Network Application in a Process Simulation Environment," Annals of the CIRP, vol. 43, pp. 449 - 452, 1994.
6. Min, B.H., "A study on volumetric shrinkage of injection molded part by neural network," Journal of the Korean Society of Precision Engineering, vol.16, no.11, pp. 224 - 233, 1999.
7. Sadeghi, B.H.M., "A BP-neural network predictor model for plastic injection molding process," J. of material processing technology, vol.103, pp. 411 - 416, 2000.
8. Taguchi, G., "Introduction to quality engineering: designing quality into products and processes," Asian productivity organization, pp. 101 - 102, 1986.
9. Toray CAE software division, "3D TIMON reference manual version 7.0," Toray Industries Inc., pp.2, 2002.
10. Valiant, L.G., "Functionality in Neural Nets," Proc AAI, Saint Paul, Minnesota, pp. 629 - 634, 1988.