

신경회로망을 이용한 정밀 사출금형의 제작에 관한 연구

이상찬[#]

A Study on Manufacturing of Precision Injection Mold Using Neural Network

Sang Chan Lee[#]

ABSTRACT

To predict the shrinkage of molded parts using numerical simulations, the mathematical model should be simplified to overcome the difficulties of formulation due to non-linearity of problems. So it is hard to predict the shrinkage exactly because of the simplification. In the present work, the neural network is used to predict the shrinkage which can implement nonlinear models very well. Comparison between the results of neural network and that of the commercial analysis software, ABAQUS, shows that the result of the neural network is in better agreement with that of the experiments.

Key Words : Precision injection mold (정밀 사출금형), Neural network (신경회로망), Shrinkage (수축)

기호설명

L = latent heat

δ = half thickness of liquid phase

$\delta\varepsilon_{ij}$ = virtual strain

ε_{kl}^* = strain predicted by the neural network

ε_{kl} = strain to be evaluated

1. 서론

최근 기계와 전자산업 등의 발달로 사출성형품의 용도는 다양해지고 정밀도가 매우 중요하게 되었다. 성형품의 정밀도를 향상시키기 위해서는 성형품의 변형과 수축을 정확하게 예측할 수 있어야

한다. 성형공정에 대한 많은 연구결과로 수치해석프로그램이 개발되어 성형조건과 금형의 형상 등을 임의로 바꿔가면서 수치모사를 할 수 있게 되었다¹⁻⁷. 그러나 유한요소해석으로 수축을 예측하기 위해서는 재료거동을 실제와 동일하게 묘사하기 위한 수학적 모델의 비선형성으로 인해 야기되는 수식화의 어려움 때문에 단순화하여 해석을 하여야 한다. 이러한 수학적 모델의 단순화로 인하여 정확한 수축을 예측하는데 어려움이 있기 때문에 정밀사출금형을 제작하는데 어려움이 있다.

오랫동안 실용화되지 못하던 신경회로망은 단순하고 명료한 학습방법이 개발되어 근래에 공학적, 산업적으로 많이 사용되고 있다. 다른 인공지능

접수일: 2004년 06월 10일; 개재승인일: 2005년 02월 18일

교신저자: 목포대학교 기계시스템전공

E-mail sclee@mokpo.ac.kr Tel. (061) 450-2417

의 기법과 비교할 때, 신경회로망은 복잡한 추론 법칙과 많은 데이터가 없어도 단순한 학습법에 의해 경험을 축적할 수 있고, 다양한 정보를 병렬, 분산형으로 처리하여 입력에 의해 생긴 잡음과 파손 등에 강한 장점을 갖는다. 신경회로망은 의료진단이나 항공기와 선박의 항로 계획, 음성인식 등 일반적인 응용 외에, 신호처리나 영상인식을 이용한 제조라인에서의 부품인식, PCB(Printed Circuit Board)나 기계제품의 조립성 검사, 로봇의 제어나 AGV(Automated Guided Vehicle)의 위치 추정 및 경로 계획, 그리고 자동화 설비의 적응제어등 진단 및 제어분야에서 이용이 급증하고 있다. 재료가공 분야에서도 공작기계에서의 최적 공구경로 결정, 최적 절삭조건 설정 등의 적용 예도 있다. 한편, 소성가공에서는 Osakada⁸ 등이 신경회로망의 형상분류 능력을 이용하여 여러 가지 공정조건에 대한 제품결함 및 금형의 파손여부를 예측하였다.

본 연구에서는 복잡한 잔류응력과 재료의 거동을 수식화하여 사출성형품의 수축을 예측하지 않고, 신경회로망을 이용한 학습과정을 통하여 수축을 예측할 수 있는 방법을 개발하였다. 먼저, 사출성형공정 해석 프로그램을 개발하여 여러 공정조건에 대한 충전과 충전후과정이 끝나는 순간에서 압력, 온도와 밀도 분포를 구하였다. 그리고 동일한 공정조건에서 성형하고 성형품의 변위를 실험적으로 측정하였다. 해석을 통하여 얻은 압력, 온도와 밀도 등을 신경회로망의 입력으로 하고, 측정한 변위로 부터 얻어진 변형율(strain)을 출력으로 하여 학습시킨 후 원하는 공정조건에서의 수축을 예측하였다.

2. 본론

2.1 사출성형 공정의 모델링

본 연구에서 제시한 신경회로망을 이용하여 사출성형품의 수축을 예측하기 위해서는 신경회로망의 입력자료를 구하기 위하여 사출성형공정에 대한 수치해석을 다음과 같이 하였다.

사출성형공정은 고분자수지가 금형의 캐비티에 충전되는 충전과정과 압축을 받는 충전 후 과정이 있다. 본 연구에서는 이 과정들을 해석할 수 있도록 수치해석 프로그램을 개발하였다.

운동방정식

$$\begin{aligned}\frac{\partial}{\partial z} \left(\eta \frac{\partial u}{\partial z} \right) &= \frac{\partial P}{\partial x} \\ \frac{\partial}{\partial z} \left(\eta \frac{\partial v}{\partial z} \right) &= \frac{\partial P}{\partial y}\end{aligned}\quad (1)$$

해석영역을 고상과 액상의 2상으로 모델링하여 상변화를 고려하면, 에너지방정식은 액상과 고상에 따라 각각 다음과 같이 나타낼 수 있다.

$$\rho C_{pl} \left(\frac{\partial T}{\partial t} + u \frac{\partial T}{\partial x} + v \frac{\partial T}{\partial y} \right) = k_l \frac{\partial^2 T}{\partial z^2} + \eta \gamma^2 \quad (2)$$

$$\rho C_{ps} \frac{\partial T}{\partial t} = k_s \frac{\partial^2 T}{\partial z^2} \quad (3)$$

이와 함께 고상-액상의 경계에서는 다음의 경계에너지 보존방정식 (interfacial energy balance equation)i] 적용된다.

$$k_s \frac{\partial T_s}{\partial z} - k_l \frac{\partial T_l}{\partial z} = \rho_s L \frac{\partial \delta}{\partial t} \quad \text{at } z = \delta \quad (4)$$

위 식에서 L은 상변화시 발생하는 잠열(latent heat)을 나타낸다.

그리고 수정된 Cross 점성모델⁹과 액상과 고상에서 고분자 재료의 압축성을 고려할 수 있는 Tait 상태방정식(Tait state equation)을 압축성 모델로 사용하였다.

위의 지배방정식을 이용하여 다음과 같이 압축성을 고려한 압력 장에 대하여 유한요소법을 이용하여 수식화 하였다.

$$\sum_i \left(\sum_m \left(M_{im}^{(l)} \frac{\partial P_m^{(l)}}{\partial t} \right) - f_i^{(l)} + \sum_m K_{im}^{(l)} P_m^{(l)} \right) - \dot{m}_N^{ext} = 0 \quad (5)$$

두께방향의 온도분포는 고상과 액상부분을 각각 일정한 개수의 유한격자로 나누어 유한차분법을 사용하여 수식화 하였다. 식 (2)의 에너지방정식에서 대류 (convection)항과 점성열(viscous heating)항은 전 스텝의 온도를 사용하여 구하였고, 시간과 전도(conduction)항에는 후방차분방법을 사용하였다. 요소 i의 i번째 충에서 시간 j 일 때의 유한차분 근사식은 다음과 같다.

$$\begin{aligned}\beta T_{l,i-1,j+1} - (1+2\beta) T_{l,i,j+1} + \beta T_{l,i+1,j+1} = \\ - T_{l,i,j} + \Delta t_j (\text{CONVEC}_{l,i,j}) - \alpha (\text{VISCOSUS}_{l,i,j})\end{aligned}\quad (6)$$

위 식에서

$$\alpha = \frac{\Delta t_i}{\rho C_p}, \quad \beta = k \frac{\Delta t_i}{\rho C_p \Delta z^2} \quad (7)$$

식(6)에서 CONVEC는 대류항을, VISCOUS는 점성열항을 나타낸다. 이 값들은 액상에서만 존재하며 고상에서는 존재하지 않는다.

액상의 두께의 반인 δ 는 경계 에너지 균형방정식 (4)를 사용하여 변화시킨다. 이 때 식 (4)의 유한차분식은 다음과 같다.

$$k_s \frac{T_{l,nl+1,j+1} - T_m}{\Delta z_s} - k_l \frac{T_m - T_{l,nl-1,j+1}}{\Delta z_l} = \rho_s L \frac{\delta_{l,j+1} - \delta_{l,j}}{\Delta t_j} \quad (8)$$

위 식에서 nl 은 상경계면의 위치를 나타내고 Δz_s 와 Δz_l 은 각각 고상과 액상의 유한차분 격자의 크기를 나타낸다.

개발한 프로그램을 이용한 해석결과와 실험결과는 잘 일치하였다¹⁰.

2.2 신경회로망을 이용한 수축 예측 방법

사출성형공정의 수치해석과 신경회로망을 이용하여 성형품의 수축을 예측하는 알고리즘이 Fig. 1에 나타나 있다.

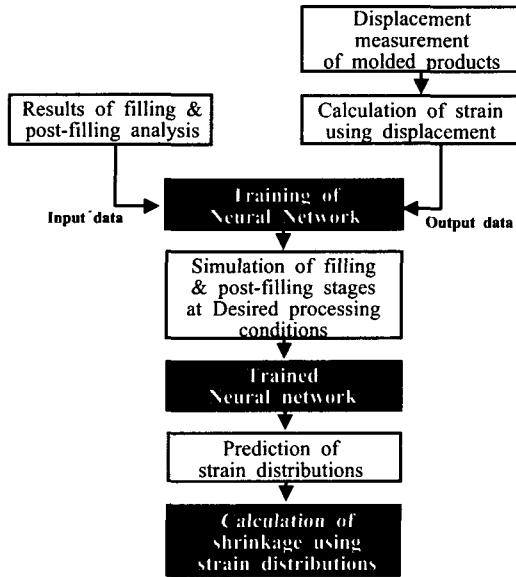


Fig. 1 Algorithm of shrinkage prediction using numerical simulation and neural network

먼저, 사출성형의 충전과정과 충전후과정을 수치해석하여 얻은 요소 중심에서의 온도와 압력을 이용하여 성형품의 수축에 영향을 미치는 신경회로망의 입력값들을 구한다.

Fig. 2는 본 연구에서 사용한 다층 퍼셉트론 신경회로망의 입력값과 출력값을 나타낸 것이다.

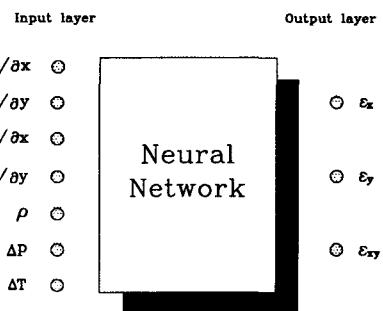


Fig. 2 Input and output data for the neural network

본 연구에서는 다음과 같은 7개의 입력값들을 실험계획법(Design of experiments))을 이용하여 사출성형품의 수축과 변형에 영향을 가장 많이 미치는 공정변수를 선정하였다. 먼저, 각 요소와 주위의 온도차를 입력값으로 사용하였는데, 이것은 주위의 온도가 수축에 영향을 주는 효과를 고려하기 위한 것이다. 성형품의 수축에 많은 영향을 주는 잔류응력은 성형품내의 압력분포가 불균일 하기 때문에 발생하므로 주입구에서의 압력과 각 요소 중심에서의 압력과의 차를 구하여 신경회로망의 입력값으로 하였고, 요소의 불균일한 수축을 고려하기 위하여 요소 내에서 각 방향으로의 온도구배와 압력구배를 구하여 입력값으로 이용하였다. 또한, 각기 다른 고분자재료의 압축성을 반영하기 위하여 밀도를 구한 후 입력값으로 사용하였다.

신경회로망의 출력값은 수치해석에 이용한 유한요소와 같은 크기인 3mm 간격의 눈금을 캐비티에 새긴 후 사출성형한 성형품의 눈금의 변위를 측정하고 다음과 같이 변형율을 구하여 사용하였다.

$$\begin{aligned} \epsilon_x &= \frac{\partial N_i}{\partial x} u_i \\ \epsilon_y &= \frac{\partial N_i}{\partial y} v_i \\ \epsilon_{xy} &= \frac{1}{2} \left(\frac{\partial N_i}{\partial x} v_i + \frac{\partial N_i}{\partial y} u_i \right) \quad \text{where, } i=1, 2, 3 \end{aligned} \quad (9)$$

이때, 절점(node)의 변위를 직접 신경회로망의 출력값으로 사용하지 않은 것은 그 절점의 변위량은 주위의 요소들의 변위량이 중첩되어 나타나므로 요소의 위치에 따라 다른 결과를 얻기 때문이다. 또한, 입력값들이 압력구배와 온도구배와 같이 요소의 중심에서 정의되므로 출력값도 요소의 중심에서 정의되는 변형율을 사용하였다.

이 신경회로망을 이용하여 여러 성형조건에 대해서 학습을 한 후 원하는 성형조건에 대해서 학습된 신경회로망을 이용하여 각 요소에서의 변형율을 구한다.

신경회로망의 학습에 의해 변형율이 전 캐비티 영역에서 계산되면, 성형품의 수축률은 아래와 같은 가상일의 원리(principle of virtual work)에 의하여 구한다.

$$\int_{\Omega} \delta \varepsilon_{ij} C_{ijkl} (\varepsilon_{kl} - \varepsilon_{kl}^*) d\Omega = 0 \quad (10)$$

여기서, $\delta \varepsilon_{ij}$ 는 가상 변형율 증분이고, ε_{kl}^* 는 신경회로망에 의하여 학습된 변형율이며, ε_{kl} 는 구하고자 하는 변위의 변형율이다. 식 (10)은 다음의 식과 같이 정리할 수 있다.

$$\int_{\Omega} \delta \varepsilon_{ij} C_{ijkl} \varepsilon_{kl} d\Omega = \int_{\Omega} \delta \varepsilon_{ij} C_{ijkl} \varepsilon_{kl}^* d\Omega \quad (11)$$

식 (11)를 이산화 시키면 아래와 같다.

$$K \underline{u} = F \quad (12)$$

여기서,

$$K = \int_{\Omega} B^T C B d\Omega$$

$$F = \int_{\Omega} B^T C \varepsilon^* d\Omega \quad (13)$$

식 (12)를 계산할 때 적절한 경계조건을 주어 병진과 회전운동의 영향을 제거한다. 즉, 원점은 완전고정조건 그리고 한 점은 한 방향 구속조건을 가한다.

본 논문에서 사용한 역전파 알고리즘을 이용한 신경회로망의 은닉층의 구조를 결정하기 위하여 Table 1과 같은 다양한 네트워크의 구조에서 학습을 수행하였다. 신경회로망의 정확도는 학습을 위한 공정조건에서의 출력값인 변형율의 측정값과 추

정값 사이의 평균제곱근(RMS)오차로 평가하였다.

Table 1 The results of various configurations with the error back-propagation algorithm

Unit of hidden layer	RMS error
6	2.776e-2
8	2.424e-2
10	2.075e-2
12	2.859e-2
14	3.072e-2

본 논문에서 은닉층은 RMS오차가 가장 작은 10개의 유니트로 구성되어 있다. 또한, 모멘텀 계수는 0.3으로 하였다.

3. 결과 및 고찰

사출성형해석과 신경회로망을 이용하여 성형품의 수축을 예측하기 위해 수축이 상대적으로 많이 일어나는 반결정(semi-crystalline) 재료인 폴리프로필렌(BJ500)을 사용하였다. 사출성형해석과 신경회로망의 출력값을 측정하기 위해 Fig. 3과 같은 4개의 캐비티를 갖고 간격이 3mm인 메쉬(mesh)가 그어져 있는 금형을 사용하였다.

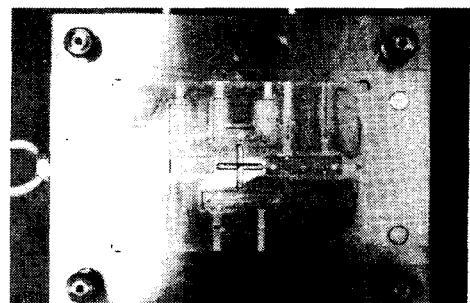


Fig. 3 Photograph of the 4-cavities of mold

실험과 사출성형해석은 Table 2에 나타낸 것처럼 성형조건은 배럴온도 220°C, 금형온도 40°C, 충전시간은 1초이고, 보압 유지시간(duration time)은 9초로 일정하게 하고 보압(holding pressure)을 각기 34.45MPa, 48.23MPa 과 68.90MPa로 달리한 3가지

조건에 대하여 수행하였다.

Table 2 Molding conditions for numerical simulation and experiment

	Cond1	Cond2	Cond3
barrel temp (°C)	220	220	220
mold temp (°C)	40	40	40
filling time (sec)	1	1	1
duration time (sec)	9	9	9
holding pressure (MPa)	34.45	48.23	68.90

보압이 34.45MPa (Cond1)과 68.90MPa (Cond3)인 조건에서의 사출성형 해석결과를 입력값으로 사용하고, 실험을 통해 얻어진 성형품에 새겨진 메쉬 절점의 좌표를 광학투사기(optical projector)로 측정하여 각 절점의 변위를 구한 후, 식 (9)에 의하여 각 요소(element)에서 계산된 변형율을 출력값으로 사용하여 신경회로망을 학습시켰다. 좀더 정확한 학습데이터를 얻기 위하여 측정이 어려운 각 캐비티들의 외곽 요소들은 학습범위에서 제외하였다.

Fig. 4는 보압이 48.23MPa (Cond2)인 성형조건에서의 사출성형해석 결과들을 보여주며, 학습된 신경회로망을 이용하여 성형품의 수축을 예측하기 위하여 이 결과값들을 사용하였다.

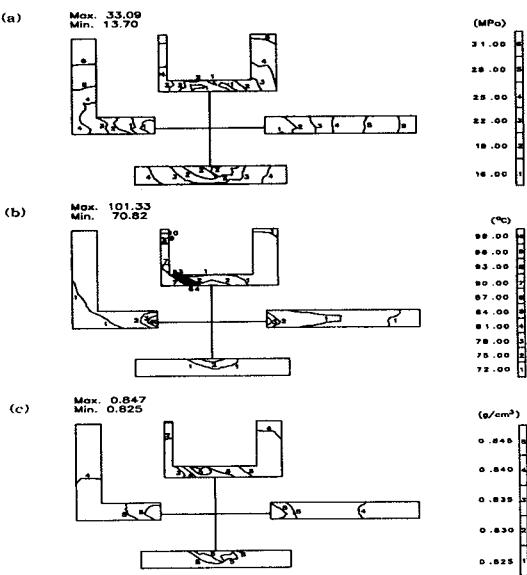


Fig. 4 Results of numerical simulation at Cond2
($P_{holding}=48.23\text{MPa}$)

- (a) Contour of pressure difference ($P_{inlet}-P_{element}$)
- (b) Contour of temperature difference ($T_{element}-T_{room}$)
- (c) Contour of density.

Fig. 4(a)는 주입구(inlet)의 압력과 각 요소의 압력들과의 차를 나타낸 것인데, L 형상의 캐비티 끝 부분에서 최대값이 33.09MPa이고 각 캐비티들의 게이트 부근에서 최소값이 13.70MPa임을 보여준다.

Fig. 4(b)는 각 요소의 온도와 상온(20°C)과의 차를 나타낸 것인데, 상대적으로 단면적이 작아 빠른 충전속도로 인한 전단응력의 영향으로 U 형상의 왼쪽 끝에서 최대 101.33°C가 되고 충전이 가장 늦게 되는 L 형상의 캐비티에서 최소값 70.82°C임을 볼 수 있다. Fig. 4(c)는 밀도 분포인데, 온도가 최대인 U 형상의 왼쪽 끝에서 최소값이 0.825g/cm³이고 게이트 부분에서 최대값 0.847g/cm³임을 나타낸다.

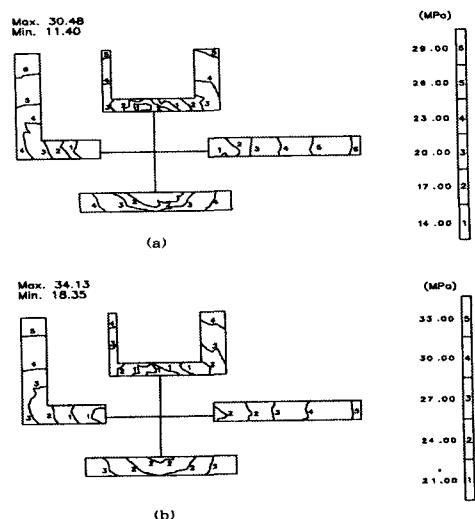


Fig. 5 Contour of pressure difference at
(a) Cond1 ($P_{holding}=34.45\text{MPa}$)
(b) Cond3 ($P_{holding}=68.90\text{MPa}$)

성형조건이 Cond2 일 때의 성형품의 수축을 예측하기 위한 신경회로망을 학습시키기 위해서는 학습데이터들의 범위가 Cond2의 최소값들과 최대값들을 포함하여야 한다. Fig. 5(a)는 성형조건이

Cond1 일 때의 압력차인де, 각 캐비티들의 게이트 부분에서의 최소값이 11.40MPa로 Cond2 보다 작음을 알 수 있다. Fig. 5(b)는 성형조건이 Cond3 일 때의 압력차를 나타낸 것인데, L 형상의 캐비티 끝부분에서 최대값이 34.13MPa로 Cond2 보다 크다.

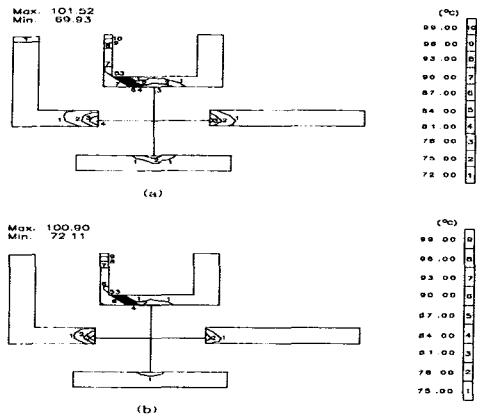


Fig. 6 Contour of temperature difference at
(a) Cond1 ($P_{holding}=34.45\text{ MPa}$)
(b) Cond3 ($P_{holding}=68.90\text{ MPa}$)

온도차는 Fig. 6(a)에서 보듯이 성형조건이 Cond1 일 때, U 형상의 왼쪽 끝부분에서 최대값이 101.52°C이고 최소값도 69.93°C로 Cond2 일 때의 값들을 포함한다. Fig. 6(b)는 성형조건이 Cond3 일 때의 온도차를 보여준다.

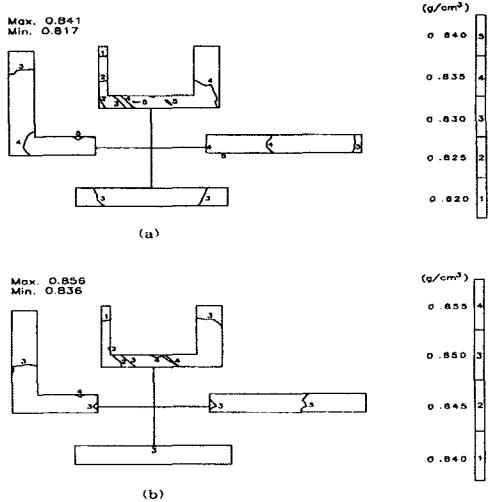


Fig. 7 Contour of density difference at

- (a) Cond1 ($P_{holding}=34.45\text{ MPa}$)
- (b) Cond3 ($P_{holding}=68.90\text{ MPa}$)

Fig. 7은 밀도분포를 나타낸 것이다. Fig. 7(a)에서 보듯이 U 형상의 왼쪽 끝부분에서 성형조건이 Cond1 일 때 최소값이 0.817 g/cm^3 이고, Cond3 일 때는 Fig. 7(b)에서 알 수 있듯이 게이트 부근에서 최대값이 0.856 g/cm^3 이 되어 Cond2의 밀도분포의 최대값과 최소값을 포함한다.

신경회로망을 이용한 수축해석 결과와 비교하기 위하여 상용 프로그램인 ABAQUS를 사용하여 수축해석을 수행하였다. 성형품의 재료는 탄성체로 가정하였고 열변형과 밀도의 불균일한 분포로 인한 수축만 고려하였다. 해석에 사용된 고분자재료인 폴리프로필렌의 탄성계수(elastic modulus)는 1200 MPa^o이고 포아송비(poison's ratio)는 0.43이며, 열팽창계수(thermal expansion coefficient)는 $9.0 \times 10^{-5}\text{ }^{\circ}\text{C}^{-1}$ 이다.

Fig. 8과 Fig. 9는 성형조건이 Cond2 일 때, 실험결과와 신경회로망과 ABAQUS의 해석결과를 비교한 것이다. Fig. 8은 성형품을 측정하여 구한 체적수축율(volume shrinkage ratio)과 신경회로망과 ABAQUS를 사용하여 예측한 체적수축율을 비교한 것이다.

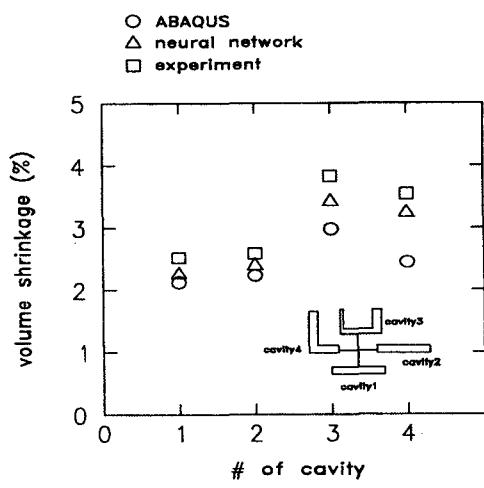


Fig. 8 Comparison of volume shrinkage at Cond2($P_{holding}=48.23\text{ MPa}$)

측정의 결과와 마찬가지로 신경회로망과 ABAQUS로 예측한 체적수축율은 모두 U 형상(cavity3)이 가장 크고 하측의 I 형상(cavity1)의 캐비티가 가장 작게 예측되었다. 신경회로망과 ABAQUS의 결과를 정량적으로 비교하면, 체적수축이 가장 많이 발생하는 U 형상에서 측정되어진 체적수축율은 3.834%, 신경회로망의 결과는 3.420%이고 ABAQUS는 2.977%를 예측하였다. ABAQUS의 결과가 오차가 많은 이유는 고분자재료를 탄성체로 가정하여 해석하였기 때문이라 사료된다.

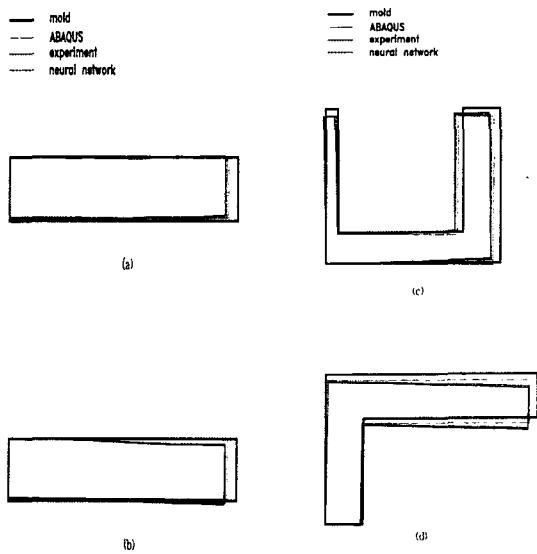


Fig. 9 Comparison of linear shrinkage (displacement: 3X) at Cond2 ($P_{holding}=48.23\text{ MPa}$)

Fig. 9는 변위를 3배 확대해 각 캐비티들이 선형 수축(linear shrinkage)된 형상들을 보인 것이다. ABAQUS의 결과는 온도변화와 불균일한 밀도분포로 인한 수축만 해석이 되기 때문에 거의 균일하게 수축된 형상으로 예측되어 U 형상과 L형상은 측정 결과와 잘 맞지 않음을 볼 수 있다.

이에 반하여 신경회로망을 이용한 해석결과는 측정값과 잘 일치하는데, 이것은 성형조건이 Cond1과 Cond3에서의 실제로 수축된 형상의 변형율로 학습을 하여 성형품의 수축에 영향을 미치는 실제적인 인자들의 비선형적인 관계가 고려되었기 때문이다.

본 연구의 결과로 고분자재료의 비선형적인 냉

각과정을 수치해석이 아니라 신경회로망을 이용하여 더 정확하게 예측할 수 있다. 이와같은 정확한 수축량의 예측으로 인하여 정밀 사출금형을 설계할 수 있다.

4. 결론

본 연구의 결과는 다음과 같다.

1. 신경회로망을 이용하여 여러형상을 가지는 성형물의 사출성형공정에서 수축에 의한 변형을 예측할 수 있는 시스템을 구축하였다.
2. 체적수축율은 신경회로망과 상용 프로그램인 ABAQUS의 해석결과가 측정한 결과와 잘 일치하였다.
3. 선형 수축되어 변형된 최종의 형상은 ABAQUS의 결과가 실제 변형된 형상과 잘 맞지 않는 반면, 수축에 관련된 변수들의 비선형성을 고려한 신경회로망의 결과는 잘 일치하였다.
4. 두께방향으로 거의 변형이 발생하지 않고, 평면 방향에서의 수축이 발생하는 경우에는 신경회로망을 이용한 수축해석이 정확하고 효과적임을 알 수 있었다.

후기

본 연구는 한국과학재단 지역대학우수과학자 지원연구사업(R05-2002-000-00769-0)으로 수행되었음.

참고문헌

1. Kamal, M. and Kenig, S., "The Injection Molding of Thermoplastics Part I: Theoretical Model," *Polym. Eng. and Sci.*, Vol. 12, pp. 294, 1972.
2. Richardson, S., "Hele Shaw Flow with a Free Boundary produced by the Injection of Fluid into a Narrow Channel," *J. of Fluid Mech.*, Vol. 56, pp. 609, 1972.
3. White, J., "Fluid Mechanical Analysis of Injection Mold Filling," *Polym. Eng. and Sci.*, Vol. 15, pp. 44, 1975.
4. Ryan, M. and Chung, T., "Conformal Mapping Analysis of Injection Molding Filling," *Polym.*

- Eng. and Sci., Vol. 20, pp. 642, 1980.
5. Stevenson, J., "A Experimental study and Simulation of Disk Filling by Injection Molding," SPE Technical Papers, Vol. 22, pp. 282, 1976.
 6. White, J. and Dietz, W., "Some Relationships Between Injection Molding Conditions and the Characteristics of Vitrified Molded Parts," Polym. Eng. and Sci., Vol. 19, No. 15, pp. 1081, 1979.
 7. Krueger, W. and Tadmor, Z., "Injection Molding into a Rectangular Cavity with inserts," Polym. Eng. and Sci., Vol. 20, pp. 426, 1980.
 8. Osakada, K. and Yang, G., "Application of Neural Networks to an Expert System for Cold Forging," Int. J. Mach. Tool Manu., Vol. 41, pp. 577, 1991.
 9. Spencer, R. and Gilmore, G., "Equation of State for High polymers", J. Appl. Phys., Vol. 21, pp. 523, 1950.
 10. Lee, S. C., Park, C. E. and Yang, D. Y., "Analysis for Filling Stage of Injection Molding Considering Compressibility and Phase Change," J. of KSPE, Vol. 18, No. 12, pp. 60, 2001.