

<연구논문>

인공신경망을 이용한 폴리스타이렌 사출성형품의 기계적 물성 예측

김정곤 · 박헌진* · 이재욱
서강대학교 공과대학 화학공학과
*SK 케미칼 중앙연구소
(1998년 4월 15일 접수)

Prediction of Mechanical Properties in Injection Molded Polystyrene Parts using Artificial Neural Network

Jung Gon Kim, Hern-Jin Park* and Jae Wook Lee

Department of Chemical Engineering, Sogang University, Seoul 121-742, Korea
*SK Chemicals, R & D Center, Suwon 440-745, Korea
(Received April 15, 1998)

요 약

사출성형품의 설계는 그 내부의 기계적 물성 변화보다는 전통적으로 용도에 부합하는 형상을 위주로 하여 이루어져 왔기 때문에 설계 조건의 개선을 통하여 성능이 우수한 제품을 얻기까지는 많은 시행착오가 요구되고 있다. 그런데 사출성형 실험이나 물성 평가 시험을 하기 전에 성형품의 부위별 기계적 물성을 알 수 있다면 제품의 설계나 금형 설계에 많은 도움이 될 수 있으므로, 최근에 물성 예측을 위한 방법론들의 개발이 다양하게 시도되고 있다. 따라서 본 연구에서는 학습시스템, 사출성형 수치모사와 기계적 물성과의 상관관계를 밝히는 방법을 만들어, 사출물이 제작되기 전에 그들의 기계적 물성을 사출성형 수치모사에서 얻어진 열적·기계적 이력으로부터 예측하고자 하였다. 이 때 성형품의 기계적 물성과 열적·기계적 이력 사이에는 매우 복잡하고 비선형적인 상관관계를 보이기 때문에 이들 사이를 비매개변수적으로 연관짓기 위하여 역전파 인공신경망 알고리즘을 사용하였으며, 열적·기계적 이력은 사출성형용 수치모사 소프트웨어를 이용하여 구하였다. 학습과정에서 전역최소값에 도달하지 못하는 인공신경망의 문제점을 해결하기 위하여 모멘텀변수와 잡음지수를 포함하는 일련의 항을 첨가하여 연결가중치를 보정하였다. 그 결과 어떤 초기값에 의하여 학습이 되더라도 전역최소값에 도달하는 것을 확인하였으며, 이를 이용하여 다른 사출조건에서 사출물의 기계적 물성을 잘 예측할 수 있었다.

Abstract—The traditional method of design for injection molded parts does not account for the variation of mechanical properties within a part. Knowledge of part properties before actual molding and testing will be of immense help to part and mold designers in modification of design. Thus many methodologies to predict mechanical properties in injection molded parts have been developed. In this paper, the methodology involved the application of connection learning system, injection molding computer simulation, and experimental evaluation of mechanical properties, to relate the thermomechanical history to the resulting part properties so that they can be predicted before parts are molded. The mechanical properties of injection molded parts depend upon their thermomechanical history which in turn is greatly influenced by the processing condition and part geometry. As the relationship between mechanical properties and thermomechanical history is complex and highly non-linear, the developed methodology was based on a backpropagation neural network that provided the means for a non-parametric mapping between them. When thermomechanical history can be obtained from injection molding simulation, this methodology provides designers with the ability to predict mechanical properties in injection molded parts of another processing condition. The main weakness of backpropagation is that it cannot escape the local minimum. This paper applied the momentum parameter and noise factor, and thus although the some initial value was given in backpropagation, the predicted result was in good agreement with the mechanical properties.

Keywords: Injection molded parts, Prediction of mechanical properties, Thermomechanical history, Artificial neural network, Backpropagation

1. 서 론

사출성형공정은 고분자수지를 용융시킨 다음 가압하여 금형 내로 주입하고 냉각시킴으로써 원하는 형상의 성형품을 얻는

비등온 공정으로써, 복잡한 구조를 갖는 제품을 값싸고 빠르게 제작할 수 있기 때문에 가장 관심을 받고 있는 고분자 가공공정 중의 하나이다. 그러나 사출성형품은 성형가공 중에 금형의 형상과 위치에 따라 다양한 형태의 열이력과 변형이력을 겪게

되고, 그 결과 성형품 내부의 구조적인 양상이 현저히 달라지게 된다. 이러한 구조적 변화는 사출성형품의 기계적 물성을 위치에 따라 부분적으로 불균일하게 만들 뿐만 아니라, warpage나 수축현상 등으로 인한 치수안정성 문제를 야기하게 된다. 따라서 제품 및 금형의 최적 설계와 아울러 사출성형조건의 최적화를 통하여 열이력과 변형이력을 적절히 제어함으로써 기계적 물성을 극대화시키는 노력이 요구되고 있다.

지금까지 사출성형품을 제작하는 방법은 성형품 내의 기계적 물성의 차이가 있음에도 불구하고 수지 공급자가 제공하는 기계적 물성을 그대로 이용하여, 그 물성에 일정량의 안전변수 (safe factor)를 곱함으로써 성형품을 설계하였다. 예로써 ABS 수지의 충격강도는 공급자가 제공하는 값은 320 J/m 정도이지만 사출성형 후 성형품 내에서의 충격강도를 위치별로 측정하면, 사출조건과 위치에 따라서 1/6-2/3 정도의 강도를 갖는 것으로 알려져 있다[1]. 이와 같이 성형의 조건과 사출품 내의 위치에 따라 기계적 물성이 달라지게 되므로, 사용자는 일반적으로 2-3배 정도의 안전변수를 곱하여 설계한다. 다시 말하면 일단 경험에 의해 설계 및 사출을 함으로써 사출품을 얻은 다음, 사출품의 강도를 측정하고 원하는 강도에 도달하지 못하면 더 큰 안전변수를 곱하거나 금형 또는 수지를 교체하는 방법을 사용하였다. 그러나 이러한 방법으로 사출성형품을 제작하면 여러차례의 금형 수조과 수지의 낭비로 제작비용이 많이 소요되고 개발기간이 길어지게 된다. 따라서 효과적인 성형품을 설계 및 제작하기 위하여 사출성형품의 기계적 물성과 사출조건 간의 관계를 규명하기 위한 많은 연구가 진행되어 왔다[2-7].

그러나 이러한 최종물성을 예측하기 위한 방법은 다른 성형 조건이나 측정하지 않은 다른 위치에서의 기계적 성질의 예측에는 제한을 가질 수 밖에 없으므로, 모든 위치에서의 열적·기계적 이력을 컴퓨터 모사 프로그램을 이용하여 구한 다음 기계적 물성과 연관시킨다면 사출을 하지 않고도, 다른 사출조

건에 대한 모든 부분 사출성형품의 기계적 물성을 예측할 수 있을 것이다. 그러나 사출성형공정은 변수가 많고 이들이 복합적으로 영향을 미치기 때문에 사출성형품의 열적·기계적 이력과 기계적 성질의 상관관계는 매우 비선형적이어서 여타의 다른 모사로는 관계의 규명이 쉽지 않아 비선형 시스템을 관계 짓는 방법으로 최근 인공신경망이 이용되고 있다.

본 연구에서는 열적·기계적 이력과 기계적 물성의 상관관계를 밝히는 방법으로 인공신경망이론과 수치모사 프로그램을 이용하여, 부분적인 기계적 물성의 예측은 물론 다른 사출조건에서의 기계적 물성을 예측하고자 하였으며, 나아가 다른 형상의 사출물의 기계적 물성을 예측하는 방법을 개발하고자 하였다. 먼저 Fig. 1에서 보인 바와 같이, 전통적인 방법의 문제점인 실험에 의한 수지와 시간의 낭비를 제거하고 실험을 하지 않은 사출물의 기계적 물성의 예측을 위하여 사출모사 프로그램인 MOLDFLOW[®]를 이용하여 임의의 사출조건에서의 모든 부분의 열적·기계적 이력을 계산한 후, 이를 측정된 기계적 물성과 인공신경망으로 학습을 시킨 다음, 다시 다른 사출조건의 사출물의 열적·기계적 이력을 MOLDFLOW[®]에 의하여 계산하고, 이를 이미 학습되어진 신경망에 적용시켜 기계적 물성을 예측하였다. 그러나 일반적인 인공신경망의 경우는 학습과정에서 지역최소값에 도달하여도 학습을 중지하는 문제점을 가지고 있으므로 모멘텀변수와 잠음지수라는 일련의 항을 첨가하였으며, 그 결과 어떤 초기값에 의하여 학습이 되더라도 전역최소값에 도달하도록 하였다. 이런 방법을 사용하게 되면 같은 수지에 대해서는 항상 같은 신경망을 반복적으로 사용할 수 있고, 서로 다른 사출조건에 대해서도 MOLDFLOW[®]의 열적·기계적 이력을 이용함으로써 대상 사출물의 기계적 물성을 예측할 수 있으므로 사출성형을 하지 않고도 기계적 물성을 예측할 수 있음은 물론 몇 군데에서 측정된 기계적 물성을 가지고도 성형품 전체 모든 부분의 기계적 물성을 예측할 수가 있다.

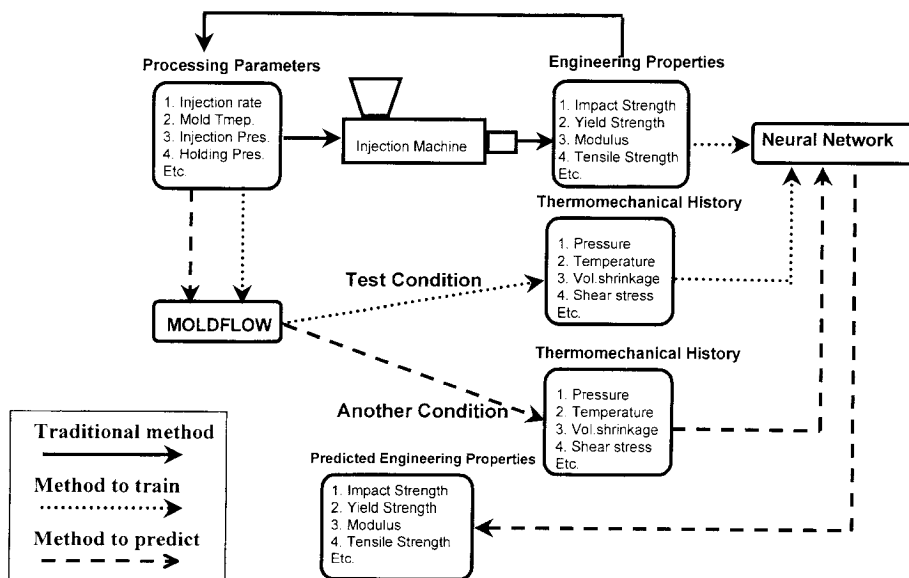


Fig. 1. The schematic methodology for this study and the traditional method.

2. 이 론

여러분은 군중 속에서 어떻게 한 얼굴을 인식하고, 어떻게 경제학자가 이자율의 방향을 예측한다고 생각하는가? 이러한 문제에 부딪혔을 때, 인간의 뇌는 정보를 처리하기 위하여 상호 연결된 처리요소인 신경세포(neuron)의 거미줄을 사용하며 [8], 각 신경세포는 자치적이고 독립적이며, 비동기적으로 움직이게 된다. 다시 말해서 다른 사건에 구애받지 않고 발생하는 것으로써, 이때 제기되는 두 가지 문제 중, 첫째는 문제 자체가 매우 복잡하다는 것으로 답을 얻기 위하여 스텝 바이 스텝(step by step) 알고리즘이나 정확한 공식을 만들 수 없다는 것을 의미하고, 두 번째는 문제를 풀기 위한 데이터가 역시 복잡하고 비선형성이 매우 크거나 입력과 출력의 데이터가 어떤 공식을 가진다고 확인할 수 없는 경우, 생물학적인 신경 처리의 연구에서 시작된 인공신경망의 이용이 필요하게 된다. 이런 신경망에는 fussy logic[9], back propagation[10], ART[11], genetic algorithm[12] 등의 다양한 종류가 알려져 있는데, 본 연구에서는 피드포워드 역전파 네트워크(Feedforward Backpropagation Network, BPN)을 이용하고자 한다. BPN은 신경망에서 가장 인기있는 모델로써, 이것은 피드백 연결을 갖지는 않지만 오차들을 학습기간동안에 역전파 시키고, 이 오차를 감소시키기 위하여 최소 자승 오차 평균이 사용되며, 대부분의 경우 다층 신경망(multilayer neural network)에 의하여 모델화 된다[13].

2.1. 역전파 네트워크

BPN 학습 알고리즘의 기본적인 구조는 Fig. 2와 같이 1개의 입력층과 다수개의 은닉층, 1개의 출력층으로 구성되어 있으며, 이들 각 층에는 입력과 출력에 대응하는 수만큼의 신경세포를 가지고 있다. 또 각 처리요소층은 수신한 데이터에 대해 신경세포별 특성에 따라 독립적인 계산을 수행하여 그 결과를 신경망을 통하여 다음 층의 신경세포로 전송한다. 이와 같은 과정을 각 층별로 되풀이하여 진행하여, 출력층에 도달하면 출력값과 목표값을 비교하고 그 차의 제곱의 합을 최소화시키는 방향으로 역전파시켜 연결가중치를 다시 조절하는 학습과정을 반복 수행하게 된다.

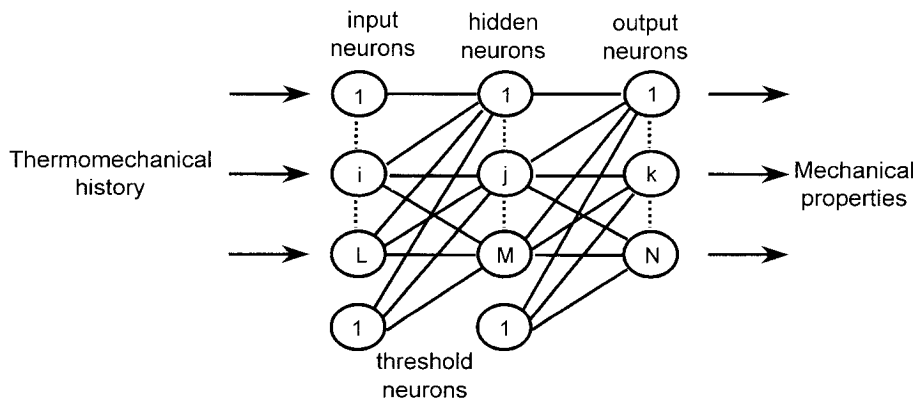


Fig. 2. Structure of backpropagation network.




Fig. 3. Plot of sigmoid function.

각 처리요소층의 신경세포의 특성을 결정짓는 활성화함수로 는 ramp 함수, step 함수 등이 존재하지만, 본 연구에서는 가장 많이 사용되는 sigmoid 함수

$$f = \frac{1}{1 + \exp(-x)} \tag{1}$$

를 사용하였으며, Fig. 3에서 보는 바와 같이 활성화함수는 임의의 입력값에 대해 출력이 0에서 1까지의 범위를 갖도록 하므로 표준화의 의미를 지니고 있다.

은닉층과 출력층의 신경세포와 이들을 연결하는 신경망을 무작위 함수(random function)를 사용하여 초기화함으로써 신경망의 연결가중치와 각 층의 신경세포에 대한 offset값을 얻은 다음, 여기에 학습 set를 입력층 신경세포에 제시하고 초기화되어진 입력을 이용하여 다음층의 입력을 구한다.

$$net_j = \sum W_{ji} o_i + \theta_j \tag{2}$$

$$o_j = f_j(net_j) \tag{3}$$

여기서 o_k 는 입력층에 의하여 출력된 값, W_{jk} 는 입력층과 다음층의 연결하는 신경망의 연결가중치, θ_j 는 신경세포의 offset값을 나타내며, f 는 식(1)에 나타낸 활성화함수를 의미한다. 또한 아래첨자 i 는 입력층, j 는 은닉층, k 는 출력층을 의미한다.

이후 출력층에 의하여 구해진 값과 목표값과의 오차로부터 출력층에 연결된 연결가중치와 출력층의 offset을 오차가 감소하는 방향으로 조절하여야 한다. 여기서 한 학습 set에 대한 출력값과 목표값의 오차 자승 평균값은 먼저 목표출력과 실제출력의 오차를 제공하고, 이를 목표값의 제공으로 나눈 다음 모두 합한값으로 구하였다.

$$E = \sum \frac{(o_k - t_k)^2}{t_k^2} \quad (4)$$

$$E_s = \sum E \quad (5)$$

여기서 o_k 는 출력값, t_k 는 목표값을 나타내고, E_s 는 학습 set의 오차합을 의미한다. 구해진 학습 set의 오차의 합이 최소가 되도록 연결가중치를 조절하기 위한 오차 감소 방법으로 델타 규칙(δ -rule)을 사용하였고, 이는 최소 자승 오차 평균(least mean squared error)로 알려져 있다.

$$\delta_j = o_j - t_j \quad (6)$$

$$-\frac{\partial E}{\partial W_{ji}} = -\frac{\partial E}{\partial o_j} \cdot \frac{\partial o_j}{\partial W_{ji}} = \delta_j \cdot x_j \quad (7)$$

델타규칙에는 사슬 규칙(chain rule)을 이용하였으며, x_j 는 j 번째 성분의 입력값을 나타낸다.

오차 자승 평균을 감소시키는 연결가중치의 값들의 집합은 신경망의 다음 학습에 필요한 것으로, 가감승제만 사용하여 계산함으로써 연결가중치들을 조절하면 실제 사용되는 연결가중치를 구할 수 있다. 이는 일정한 범위 내에 오차가 있거나 학습회수가 끝날 때까지 계속되고, 매번 연결가중치는 갱신된다. 이 때 하나의 층에 있는 i 번째 신경세포와 다음층의 j 번째 신경세포 사이의 연결에 대한 연결가중치만 본다면, 학습회수(iteration number) n 일 때의 연결가중치는 $W_{ji}(n)$ 이고, 한 사이클 후에 이 연결가중치는 $W_{ji}(n+1)$ 이 된다. 두 연결가중치의 차는 다음과 같이 묘사된다.

$$\Delta W_{ji}(n+1) = W_{ji}(n+1) - W_{ji}(n) = \beta x_i (o_j - t_j) \quad (8)$$

여기서 β 는 학습변수(learning parameter)로 1보다 훨씬 작은 양의 값을 항상 가져야 한다.

2.2. 역전파 네트워크 알고리즘의 개선

Fig. 4는 지역 최소값(local minimum)과 전역 최소값(global minimum)을 나타내며, 그림에서 보듯이 점 A와 B는 모두 극소값으로서, 일반적인 오차 감소 방법에 의해서는 구별을 해내지 못하므로 이 두 값 모두 최소 에너지 점이라고 말할 수 있다. 그러나 A의 위치에 오차값이 존재한다면, 아무런 문제가 없지만 B의 위치에 머물거나 심지어 극대값인 C에 도달하였




Fig. 4. Plot of local minimum and global minimum values.

다면, 어떤 방법을 동원하더라도 B가 아닌 A의 위치로 이동시켜야 한다. 이런 문제점을 극복하기 위하여 본 연구에서는 식(8)에 몇 가지 항을 첨가 하였다. 먼저 학습 법칙에 약간의 변화를 주어서 때로는 학습을 훨씬 빠르게 하는 방법으로 모멘텀 항(momentum parameter)을 부가하였다. 식(8)에 나타낸 역전파의 학습 법칙에 모멘텀 항을 부가하여 연결가중치를

$$\Delta W_{ji}(n+1) = \beta x_i (o_j - t_j) + \alpha \Delta W_{ji}(n) \quad (9)$$

로 변화시켰다. 우변 두 번째 항이 모멘텀 항이며 α 는 모멘텀 변수이다. 연결가중치의 변화는 지역 최소값에 빠져서 오차가 없을 때, 학습을 멈추는 것이 아니라 이전의 연결가중치에 상수를 곱한 것이 되므로 그것이 향하고 있는 방향으로 계속 진행되는 것을 의미하게 된다. 따라서 모멘텀변수는 연결가중치의 변화 과정이 멈추지 않고 계속되도록 하여 지역 최소값에 빠지는 것을 방지하도록 하는 역할을 하고 있다.

또한 지역 최소값을 쉽게 벗어나도록 하고 일반화 능력을 향상시키기 위한 또 다른 접근 방법으로 학습시키는 동안 어떤 잡음을 도입하였다. 역전파 네트워크에 인가된 입력 벡터의 각 입력 성분에 임의의 수를 더하는 잡음지수(noise factor, NF)에 의해 입력 벡터는 스케일링되며, 이때 잡음지수는 0과 1사이의 값을 가진다. 학습할 때에 원하는 만큼의 잡음을 부가할 수 있으며, 전역 최소값에 도달하면 그 최소값에 수렴하기 위하여 더 이상 잡음지수가 가해지지 않아야 하므로 오차값이 감소하면 잡음지수 또한 감소해야 하므로 잡음지수를 0으로 하여 잡음을 부가하지 않을 수도 있어야 한다.

$$o_j^{new} = o_j^{old} \cdot (1 + NF) \quad (10)$$

이며, 잡음지수를 도입하는 또 다른 이유는 네트워크에 의해 기억되는 것을 막기 위한 것으로, 각 사이클에 다른 유사한 입력 set이 인가될 때 학습 중인 네트워크가 그 전의 set을 기억하기 어렵게 하여 정확도를 증가시키도록 한 것이다.

3. 실험

3.1. 대상수지 및 사출성형실험

본 연구에서 사용된 수지는 비결정성 수지로서 상용 시판되고 있는 폴리스타이렌(PS, GPPS-25sp, LG Chem.)을 선정하여 사출실험을 수행하였다. 실험 전에 수지를 80°C에서 24시간동안 건조시킨 다음 실험에 사용하였으며, 수지의 유리전이온도는 97.11°C, MI는 3.3 g/10 min, 밀도는 1.05 g/cm³이다.

사출성형실험에는 L/D가 20이고 지름이 25 mm인 스크류가 부착된 25 ton, 2.08 ounce의 사출기(ABURG, Model 220M 250-75)를 사용하여 사출압, 사출온도 및 유속 등의 성형조건을 다양하게 변화시키면서 시편을 제작하였다. 금형온도 조절기(Regloplas 150K)를 사용하여 가열한 오일을 금형 내로 순환 시킴으로써 금형의 온도를 조절하였다. 각 성형조건에서 정상 상태에 도달하였음을 확인한 다음 기계적 물성 측정을 위한 10개 이상의 시편을 제작하였으며, 사출성형조건 범위는 MOLDFLOW[®]를 이용하여 수치모사를 수행한 결과 short shot 등의 성형이 불가능한 조건을 배제하고 결정하였다. 본 연구에서 사용한 사출실험 조건을 Table 1에 수록하였는데, 4가지의 사출온도, 3가지의 사출압과 3가지의 사출시간을 변수로 설정하고 이를 조합하여 36가지의 사출시편을 제작하였으며, 이때 보압, 보압시간, 냉각온도 등은 일정값으로 고정하였다.

사출성형에 사용된 금형의 모양은 Fig. 5와 같으며, 치수는 100 mm × 50 mm × 3 mm로써 좌·우가 동일한 금형이지만 냉각오일의 흐름 방향을 조절하여 서로 다른 이력을 가지도록

Table 1. Injection molding conditions

Condition	Value
Injection Temperature(°C)	220, 240, 260, 280
Injection Pressure(MPa)	90, 95, 100
Mold Temperature(°C)	60
Packing Pressure(MPa)	80
Packing Time(sec)	10
Cooling Time(sec)	30
Filling Time(sec)	0.8, 1.0, 1.4
Clamp Opening Time(sec)	2




Fig. 5. Mold geometry and sample test locations; (a) impact strength, (b) shear modulus

하였다. 그림에 표기된 각각의 점들은 기계적 물성을 측정하고 MOLDFLOW[®]에 의한 수치모사를 한 지점을 나타낸다.

3.2. 기계적 물성 측정

사출 평판을 절삭기에 부착하고, 1.588 cm의 크기를 갖는 end mill cutter를 사용하여 절삭함으로써 Fig. 5에 묘사된 위치에서 물성 측정용 시편을 제작하였다. 절삭 조건은 1.9 cm/min의 이동속도를 갖도록 하고 cutter의 회전수를 1000 rpm으로 하였으며, 절삭과정 중에 생성되는 열에 의한 변형을 막기 위하여 압축공기를 이용하여 냉각시켰다. Notch를 주지 않은 Charpy형의 시편을 사용하여 충격강도시험기(CEAST Impact tester)로 충격물성을 측정하였는데, 동일한 조건에서 사출된 5개이상의 시편에 대한 평균값으로 구하였다. 또 DMA 983을 사용하여 2°C/min의 승온속도로 10°C에서 70°C까지 승온시키며 1 Hz의 주파수로 동적 기계적특성을 측정하고 shear modulus는 30°C에서의 값으로 정하였다.

3.3. 열적 · 기계적 이력의 수치모사

본 연구에서는 사출성형공정의 수치모사를 위하여 상용화 개발되어 있는 MOLDFLOW[®]를 이용하였다. MOLDFLOW[®]는 충전, 냉각과 보압과정을 모사하기 위한 모듈을 가지고 있으며, 또한 사출물의 warpage와 응력을 예측하기 위한 모듈로 구성되어 있다. 본 연구에서는 MOLDFLOW[®]를 이용하여 열적 · 기계적 이력을 계산하기 위하여, MF/VIEW, MF/FLOW 와 MF/COOL을 이용하였으며, 각각의 element와 node에서의 온도, 압력, 전단 응력, 전단 속도, 금형 온도, shrinkage, flow orientation 등을 구하여, 열적 · 기계적 이력으로 표현하였다. 이와 같이 MOLDFLOW[®]를 이용하면 서로 다른 위치의 열적 · 기계적 이력을 반복적으로 구해낼 수 있고, 이를 실험을 통해서 기계적 물성을 측정할 어떤 일정한 지점과도 일치시킬 수 있다.

Table 2에는 MOLDFLOW[®]에 의해 계산된 값 중에서 기계적 물성에 중요한 영향을 준다고 알려진 9가지의 열적 · 기계적 이력을 수록하였다. 여기서 node에 주어진 값은 압력, 온도, 순간온도이며, element값은 부피수축, 최대전단응력, 밀도, 금형 상하의 온도와 그 차를 선택하였다. 이 중에서 압력, 온도,

Table 2. Thermomechanical history calculated from injection molding simulation

Node value	Element value
Pressure(MPa)	
Temperature(°C)	
Instant Temperature(°C)	Vol. Shrinkage(%)
	Max. Shear stress(MPa)
	Apparent Density(kg/m ³)
	Top Temperature(°C)
	Bottom Temperature(°C)
	Different Temperature(°C)

순간온도와 최대전단응력은 충전단계의 값이고, 나머지는 보압과정이 끝난 이후의 값으로, 압력은 완전히 충전 되었을 때의 압력분포를 의미하고, 온도(temperature)는 흐름이 측정하고자 하는 node에 도달한 순간의 온도를, 순간온도(instant temperature)는 용융수지가 완전히 충전된 순간의 node의 온도를 나타낸다. 또한 부피수축(volume shrinkage)은 일정한 element 내의 수지의 원래 부피에 대한 percent를 의미하고, 최대응력(Max. stress)은 용융수지가 충전될때 생기는 최대의 전단응력을 나타낸다. 또한 different temperature는 금형의 상단온도와 하단온도의 차를 나타낸다.

3.4. 역전파 네트워크의 학습

BPN을 학습시키기 위하여 먼저 36가지의 사출실험 데이터 set 중에서 18개의 set를 전체 실험범위를 포괄할 수 있도록 선택하였다. 그리고 나머지 18개의 set는 훈련된 신경망을 검증하기 위한 test set으로 사용하였으며, 각 set내에는 충격강도를 6개의 위치에서 측정하고 각 위치당 9개의 열적·기계적 이력을 MOLDFLOW[®]에서 얻었으므로 입력층의 신경세포의 개수는 54개가 된다. 또한 8개의 위치에서 shear modulus를 측정하고 9개의 열적·기계적 이력이 얻어지므로 72개의 입력층 신경세포를 가진다. 각 경우의 학습 set 개수가 18개이므로 실제 학습에 참여하는 입력값은 충격강도의 경우는 972개, shear modulus는 1296개가 된다. 이를 각 위치에서의 기계적 물성과 연결시켜서 학습 횟수를 1000번으로 정하고 허용오차로 식 (4)의 E값이 1%가 될 때까지 학습을 수행하였으며, 각 경우에 대해서 학습변수, 모멘텀변수, 잠음지수를 변화시키면서 학습시켰다. 학습과정 중 오차의 감소 경향을 주시하면서 학습 횟수가 증가하여도 오차가 더 이상 감소하지 않는 경우도 학습 횟수를 1000번까지 수행하였다.

4. 결과 및 토론

Fig. 6은 BPN을 사용하여 충격강도를 학습시키는 과정에서 나타나는 오차를 도시한 것으로, 오차는 식 (4)와 (5)에 나타낸 바와 같이 각 학습 set당 목표값과 실제 출력값의 차를 합한 값으로 표현하였다. 즉 충격강도의 경우 18개의 학습 set가 존재

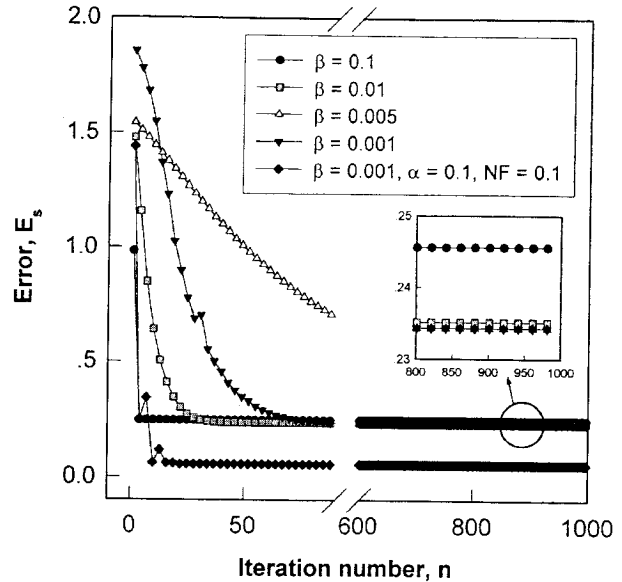


Fig. 6. Plot of pattern error of impact strength.

하므로 18개의 오차를 합한 것을 의미한다. 학습변수만을 사용하는 역전파 경우 학습 회수가 늘어남에 따라 오차의 값이 감소하여 일정한 값에 수렴하는 것을 볼 수 있지만, 최종적으로 수렴한 오차가 허용오차보다 상당히 크고 더 이상 감소하지 않음을 볼 수 있다. 모멘텀변수와 잠음지수를 고려한 경우 수렴 속도가 빨라지고 최종 수렴오차도 허용오차범위 내로 들어올 수 있는 바, 학습변수만으로 학습시킬 경우 지역최소값에 빠져서 전역 최소값을 찾지 못하고 있음을 알 수 있다. 이는 초기에 무작위함수에 의한 잘못된 연결가중치가 선택되면 기계적 물성 예측을 정확하게 할 수 없음을 의미하고 있다. 그러나 학습변수만 사용한 경우 학습변수값이 0.001일 때 최소의 오차값을 가지므로 모멘텀변수와 잠음지수를 첨가하는 향후의 계산에는 학습변수를 0.001로 고정하였다. 또한 shear modulus의 학습의 경우도 거의 같은 결과를 보여 주었다.

또 최적의 학습효과를 거두기 위한 변수들의 효과를 알아보기 위하여, 학습변수를 0.001로 고정하고 모멘텀변수와 잠음지수를 변화시키면서 오차값을 구한 결과, Fig. 7에서 보는 바와 같이 각 변수가 0.1인 경우 최소 오차값을 가지는 것을 확인할 수 있었다. 또 모든 경우 지역최소값을 벗어나기 위해서는 초기 반복 범위에서 오차가 약간 증가하다가 감소하는 경향을 보이고 있는데 이는 지역최소값을 벗어나 다시 오차가 증가하기 때문에 나타나는 현상으로 지역최소값을 벗어나고 있음을 확인시켜 주고 있다.

이렇게 오차의 변화를 측정하여 구한 최적의 연결가중치를 가진 BPN을 사용하여, 은닉층의 수를 증가시키면서 실험에 의해서 구해진 충격강도와 BPN에 의하여 예측된 값을 Fig. 8에 비교하였다. 여기서 은닉층의 수가 증가하더라도 예측의 정확성이 증가되어지지 않는 것을 볼 수 있는데, 이는 Cybenko[10]와 Hornik[11]에 의하여 밝혀진 것과 같이 은닉층이 증가하면 오히려 비선형성이 증가하여 더 많은 지역최소값을 가지게 되므로 이를 벗어나기 어렵게 됨에 기인하는 결과로

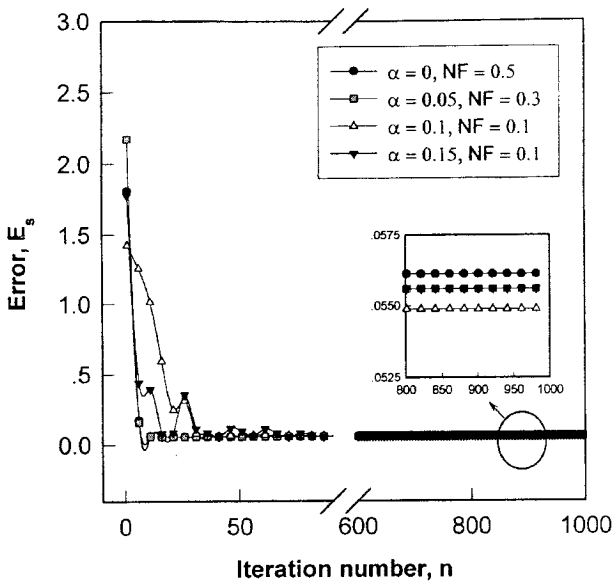


Fig. 7. Plot of pattern error of shear modulus on the fixed value of learning parameter ($\beta=0.001$) for different momentum parameters and noise factors.

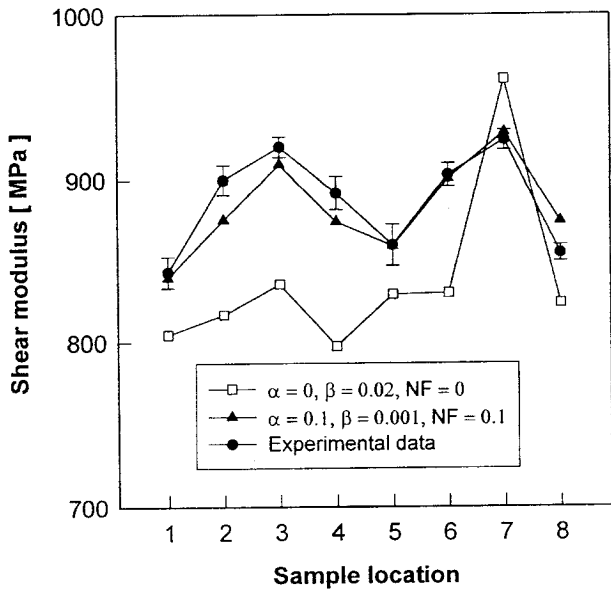


Fig. 9. Plot of comparison of shear modulus between experimental and predicted value.

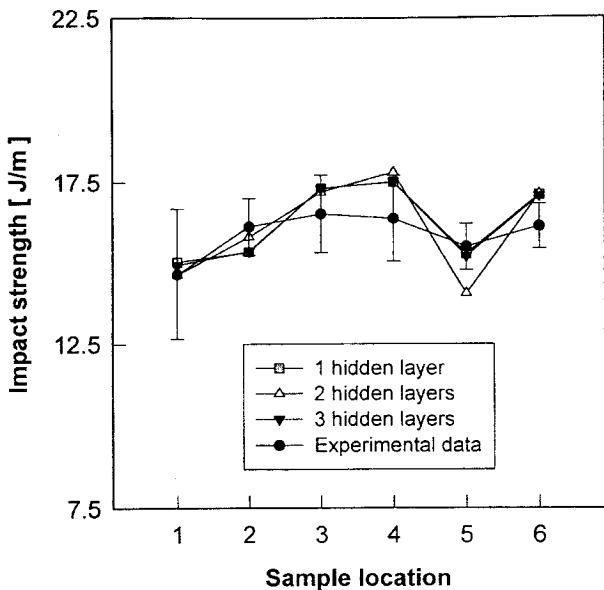


Fig. 8. Plot of comparison of impact strength for different number of hidden layers.

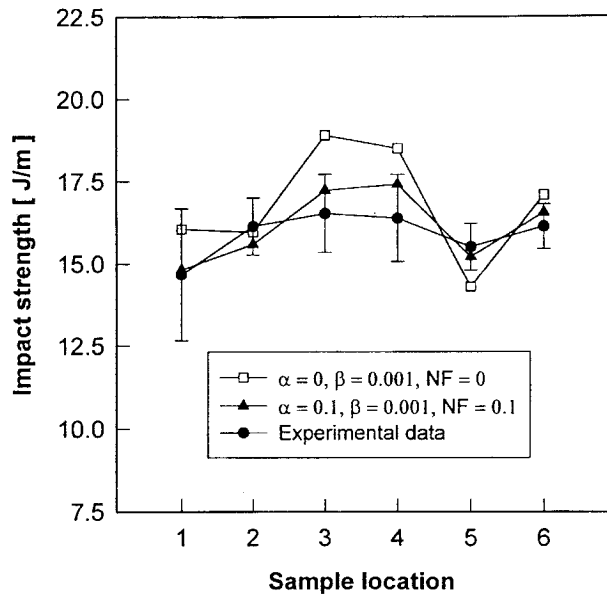


Fig. 10. Plot of comparison of impact strength between experimental and predicted value.

사료된다. 따라서 본 연구에서 수행한 모든 학습은 은닉층의 개수를 1개로 하고, 학습변수를 0.001로, 모멘텀변수와 잡음지수는 0.1로 고정하여 학습을 수행하였다.

이상에서 얻어진 최적의 학습조건을 적용하여 학습에 참여하지 않은 test set의 shear modulus를 예측한 결과와 단지 학습변수만 가지고 예측한 결과를 비교하면 Fig. 9와 같이 학습변수만으로 예측한 결과는 전역 최소값을 갖지 못하고 지역최소값에 머물러 모멘텀변수와 잡음지수를 모두 적용한 결과에 비하여 그 정확성이 떨어지는 것을 확인할 수 있었다. Fig. 10은

충격강도를 예측한 결과를 보인 바, shear modulus를 예측한 Fig. 9의 결과와 마찬가지로 충격강도에 있어서도 학습변수만을 적용한 결과보다 모멘텀변수와 잡음지수를 모두 적용한 결과가 더욱 정확한 결과 예측을 하는 것을 확인할 수 있었다.

5. 결 론

본 연구에서는 사출성형가공을 통하여 얻어진 사출품의 기계적 물성을 사출 전에 미리 예측하는 알고리즘을 개발하기 위하

여 상용화된 사출성형 수치모사 소프트웨어와 인공신경망을 이용하여 여러 사출조건에서 사출된 시편의 충격강도와 shear modulus를 조사하였다. 일정한 형상의 시편을 사용하여 사출성형 수치모사 소프트웨어에서 얻어진 열적·기계적 이력을 기초로 역전파 알고리즘을 기계적 물성과 학습시킨 결과, 실제 시편을 제작하거나 기계적 물성의 측정 전에 사출 시편의 기계적 물성을 비교적 정확하게 예측할 수 있는 것으로 보아 기계적 물성이 열적·기계적 이력에 의존함을 확인할 수 있었다. 또한 역전파 알고리즘을 단지 학습변수만을 적용하면 지역 최소값에 빠지는 문제를 해결하기가 불가능하기 때문에 이 문제점을 극복하기 위하여 본 연구에서는 몇 가지 항을 첨가하였다. 모멘텀 항을 부가하여 역전파의 학습의 연결가중치를 변화시켜 연결가중치의 변화 과정이 멈추지 않고 계속되도록 함으로써 지역 최소값에 빠지는 것을 방지하였고, 역전파 네트워크에 인가된 입력 벡터의 각 입력 성분에 잡음지수를 더해서 더욱 빠르고 정확한 예측을 가능하도록 하였다. 그러나 선택한 9개의 열적·기계적 이력만 가지고는 정확한 예측을 하기가 불가능한 것으로 사료되며, 더 정확한 예측을 위해서는 사출성형 수치모사 소프트웨어에서 제공되는 모든 열적·기계적 이력을 대입한 후, 기계적 물성에 영향을 적게 주는 열적·기계적 이력을 순서대로 제거해 나가는 방법의 알고리즘이 필요하다고 하겠다.

감 사

본 연구는 한국과학재단 특정기초 연구비(과제번호:94-

0502-04-01-3)의 지원으로 이루어졌으며, 국내 유변학 분야의 선구자적 역할을 하신 은사 이기준 교수(서울대학교)의 화갑 기념 특집호에 실리게 된 것을 기쁘게 생각합니다.

참고문헌

1. B. H. Kim, T. W. Hwang and H. J. Park, *J. Polym. Eng. Sci.*, **35**, 1252 (1995).
2. M. Guo and J. Bowman, *J. Appl. Polym. Sci.*, **28**, 2341 (1983).
3. F. La Mantia, *Material Chem. Phys.*, **16**, 115 (1987).
4. R. M. Criens, M. Haendler, and H. G. Mosle, *German Plastic*, **75**, 24 (1985).
5. D. E. Lopez, R. K. Bayer, H. G. Zachman, C. F. J. Balta, and W. Meins, *Polym. Eng. Sci.*, **29**, 193 (1989).
6. R. J. Crawford and K. McGonagle, *Plast. Rubber Process*, **5**, 51 (1985).
7. S. C. Malguarnera and A. Manisali, *Polym. Eng. Sci.*, **21**, 586 (1981).
8. J. J. Hopfield and D. W. Tank, *Science*, **233**, 625 (1986).
9. S. E. Fahlman and C. Lebiere, "The Cascade-Correlation Learning Architecture", in *Advances in Neural Information Processing Systems*, Morgan Kaufmann, San Mateo, Calif (1990).
10. G. Cybenko, *Math. Control Signal Systems*, **2**, 303 (1989).
11. K. Hornik, M. Stinchcombe, and H. White, *Neural Networks*, **2**, 359 (1989).
12. A. V. Ooyen and B. Nienhuis, *Neural Networks*, **5**, 456 (1992).
13. R. A. Jacobs, *Neural Networks*, **1**, 295 (1988).