

〈논 문〉

다구찌방법을 이용한 사출성형공정의 신경회로망 모델링에 관한 연구

최기흥* · 유병길* · 홍태민* · 이경돈* · 장낙영*

(1994년 9월 6일 접수)

A Study on Neural Network Modeling of Injection Molding Process Using Taguchi Method

G. H. Choi, B. G. You, T. M. Hong, K. D. Lee and N. Chang

Key Words : Injection Molding (사출성형), CAE (전산수치해석), Neural Network (신경회로망), Regression Model (회귀모델), Taguchi Method (다구찌방법), Factorial Design(요인배치법)

Abstract

Computer Integrated Manufacturing(CIM) requires models of manufacturing processes to be implemented on the computer. These models are typically used for determining optimal process control parameters or designing adaptive control systems. In spite of the progress made in the mechanistic modeling, however, empirical models derived from experimental data play a major role in manufacturing process modeling. This paper describes the development of a neural network model for injection molding process. The model uses the CAE analysis data based on Taguchi method. The developed model is, then, compared with the traditional polynomial regression model to assess the applicability in practice

기 호 설 명			
$A_j, j=1, N_o$: CAE(컴퓨터를 이용한 해석) 출력	df	: 자유도
$P_j, j=1, N_o$: 신경회로망 모델 또는 회귀모델의 출력	σ	: 분산값
$Z_j, i=1, N_i$: 신경회로망 모델 또는 회귀모델의 입력	F_o	: 분산비
N_o	: 신경회로망의 출력 노드수	t_f	: 충전시간
N_i	: 신경회로망의 입력 노드수	t_h	: 보압시간
N_e	: 유한요소해석시 요소의 수	T_c	: 냉각수 온도
N_n	: 유한요소해석시 노드의 수	T_m	: 수지온도
N	: 학습샘플의 수	P_p	: 보압
SS	: 제곱의 합	LS	: 수축률
		WP	: 변형률
		SI	: 싱크인덱스
		VLS	: 수축률의 분산
		DWP	: 변형률과 수축률의 차이
		DSI	: 싱크인덱스의 RMS 변화값

*회원, 고등기술연구원 생산기술연구원

1. 서 론

최근 눈부신 디지털 컴퓨터 이용 기술은 전통적인 생산공정의 자동화를 유발시켰으며, 데이터 레벨(CAD, CAM)에서 단위 설비 레벨(NC, CNC)에 이르기까지 자동화의 결과로 많은 생산성의 향상을 가져왔다. 따라서, 자동화 본래의 목적이 어느 정도 달성된 것도 사실이며, 향후 이러한 생산성의 향상은 지식 레벨에서의 의사결정 자동화 여부에 따라 크게 좌우될 것이다.⁽¹⁾ 의사결정의 자동화는 필연적으로 생산과 관련된 공정의 모델링 작업을 수반하게 된다. 즉, 현 단계에서 공정의 자동화에 수반되는 첫째 조건은 공정의 정확한 이해이다. 일반적으로 공정의 모델링은 입력 제어인자(input control parameters)와 출력 성능인자(output performance parameters) 간의 모사관계(mapping relationship)를 설정하는 과정이다. 이러한 공정모델은 공정에 수반되는 물리적 현상에 근거한 기계적 모델(mechanistic model), 실험 데이터에 근거한 실험적 모델(empirical model), 그리고 시행착오에 근거한 경험적 모델(heuristic model) 등으로 나뉘어 진다. 그러나, 실제 공정을 정확히 설명하는 물리적인 모델을 개발하는 것은 대단히 어렵고 상당한 계산량을 필요로 하며 경험적 모델도 적용범위에 한계가 있기 때문에 실험적 모델이 아직도 중요한 역할을 담당하고 있다. 실험적인 모델링의 기법으로 가장 많이 사용되는 것은 회귀모델링기법(regression modeling)이다. 회귀모델을 설정하기 위하여는 우선 모델의 구조(각항의 차수 등)와 이에 따른 모델링에 필요한 데이터가 미리 결정되어야 한다. 또한, 새로운 데이터가 얻어질 때마다 모델을 새로 설정해야 하는 불편이 있고, 많은 계산시간을 필요로 하게 된다. 이러한 회귀모델링 기법에 비하여 신경회로망에 의한 모델링은 다음과 같은 장점을 지니고 있다. 우선, 다수의 입력/출력(multi-input/multi-output) 관계의 모사가 용이하며 새로운 실험데이터가 얻어짐에 따라 이들만을 사용한 기존 모델의 수정(adaptation)이 가능하다. 이는 특히 데이터베이스의 효율적인 관리를 위하여도 필요하다. 둘째로는, 비교적 복잡한 형태의 함수도 간단한 구조로 모델링할 수 있는 장점이 있다. 이외에도 외란에 조금 영향받으며

(robustness) 사용하기 간편하고(compactness) 공정의 입출력관계를 일반화할 수 있는(generalization capability) 등의 장점도 있다.

공정과 연관된 문제점, 응용범위, 그리고 앞으로의 성장 가능성 등을 고려해 볼 때 자동화가 필요한 대표적인 생산공정중의 하나가 사출성형공정이다.⁽²⁾ 즉, 사출성형공정에서도 위에서 언급한 바와 같이 공정의 자동화 또는 최적화의 필요성이 오래전부터 제기된 바 있다. 이를 위하여는 공정의 모델링과 이를 통한 사출조건과 제품의 특징간에 정확한 관계 설정이 필수이다. 그러나, 아직도 사출성형공정의 완벽한 이해는 불가능하며 이외에도 제품과 금형의 형상디자인, 적절한 수지재료와 사출조건 선택 등 복잡한 과정을 거쳐야 한다. 통상, 사출성형품의 기본형상(primary geometry)은 제품설계 단계에서 제품의 기능과 외관에 관한 요구를 반영하여 디자인된다. 그런 다음, 리브(Rib)나 보스(Boss)와 같은 부가적인 형상(supplementary feature)이 제품의 기능이나 강도등을 고려하여 금형 설계자에 의해 금형제작 과정에서 부가되어진다.⁽³⁾ 이 때, 전체적인 사출성형공정의 특성도 변하게 되며 기본형상에 근거한 최적의 사출조건도 실제의 최적조건과는 차이가 나게 된다. 이는, 금형의 설계과정에서 부가형상의 변화가 발생할 때마다 공정모델의 변경이 필요함을 의미한다.

본 연구의 목적은 신경회로망의 학습능을 활용하여 사출성형공정에서 공정의 모델링에 관한 방법을 제안함에 있다. 특히, 사출성형공정후 제품에 나타나는 대표적인 특징의 하나인 치수변형과 각종 사출 입력변수들간의 관계를 설정하고 이들 치수변형을 사전에 예측할 수 있는 방법을 제시하고자 한다. Fig. 1은 본 연구에 적용되는 공정모델링 과정을 나타내고 있다. 사출공정의 모델링은 디자인 변수가 많거나 학습데이터의 취득에 많은 시간이 필요한 경우가 보통이다. 본 논문에서는 다구찌방법




Fig. 1 A framework of injection molding process modeling

에 의한 직교배열(orthogonal array)⁽⁴⁾을 사용하여 최소한의 실험단으로도 일관성있는 학습데이터를 취득할 수 있음을 보이려 한다. 또한, 사출성형공정에의 응용시 신경회로망 모델을 기존의 회귀모델과 비교하여 평가하려고 한다. 이를 위하여, 사출성형 해석용 소프트웨어인 C-MOLD 가 충전, 냉각, 변형 등의 공정 해석용으로 사용되었다. 해석 결과로부터 각종 출력변수들을 계산하기 위한 사용자 인터페이스(user interface) 프로그램도 작성되

$$DSI = \sqrt{\frac{\sum_i v_i (SI_i - SI_{ave})^2}{\sum_i v_i}}, \quad i=1, N_n \quad (2)$$

와 같이 정의되며⁽⁴⁾ SI_i 와 v_i 는 i 번째 노드에서의 싱크인덱스 값과 체적이며, N_n 은 유한요소(finite element)에 의한 총 노드의 수이다. 싱크인덱스는 국부적인 수축을 나타내 주는 척도로 특히 리브나 보스 주변에서 최소화될 필요가 있다. 그러나, 일반적으로 편평한 면에서의 높은 싱크인덱스 값은 사용되었다.

2. 신경회로망에 의한 공정모델링

신경회로망은 상호 연결된 뉴런(Neuron 또는 노드)에 의해 임의의 입력을 출력으로 모사해 주는 수학적 모델이다. 신경회로망은 기본적으로 인간 뇌신경 조직의 정보처리 기능을 모방하고 있기 때문에 사출성형공정에서의 신경회로망에 의한 공정 모델링은 현장 작업자가 흔히 수행하는 중요한 기능을 모사할 수 있다는 점에서 정당화 될 수 있다. 즉, 여러가지 다양한 형태의 정보를 활용되, 이들을 종합하여 취합할 수 있으며, 적응하는 능력을 가졌다는 점이다. 그러나 실제 응용을 위해서는 다음의 두 단계 과정을 거쳐야 한다. 우선, 회로망의 적절한 구조가 선택되어야 한다. 본 연구에 적용된

신경회로망은 Fig. 2에서와 같이 입력층, 중간층(은닉층), 그리고 출력층의 3층으로 이루어진 다층 퍼셉트론(5-4-3 또는 5-4-1)이다. 그림에서 입력층 및 출력층의 각 노드는 각각의 입력 및 출력변수에 대응한다. 위의 신경회로망 모델에서는 주어진 입력조건에 대하여 사출품의 품질을 나타내는 출력을 예측하는 것이 모델링의 주 목적이다. 따라서, 사출품의 품질을 결정하는 많은 인자중에서 기하학적 인 요인만을 본고에서는 고려한다. 즉, 컴퓨터를 이용한(CAE) 해석으로부터 얻어지는 수축률의 분산(variance of linear shrinkage, VLS), 변형률과 수축률의 차이(difference of warpage, DWP) 그리고 싱크인덱스의 변화값(RMS Deviation of Sink Index, DSI) 등을 출력변수로 설정하였다. DWP는

$$DWP = WP_{ave} - LS_{ave} \quad (1)$$

와 같이 정의되며 WP_{ave} 는 변형률의 평균값, LS_{ave} 는 수축률의 평균값이다. DSI 는 체적을 무게 함수(weighting factor)로 하여 큰 의미가 없다. 입력변수로는 충전시간(t_f), 수지 온도(T_m), 보압시간(t_h), 냉각수온도(T_c), 그리고 보압(P_p) 등이 사용되었다. 다음 단계에서는 학습을 통하여 현장 작업자의 문제 해결능력을 전수받게 된다. 본 연구에서는 역전파(back propagation) 알고리즘이 사용되었다.

3. 회귀모델

회귀모델은 다항식의 형태(polynomial regression)로 총 3개의 출력변수에 해당되는 수축률, 변형률, 그리고 싱크인덱스 모델이 고려되었다. 즉, 일반적으로 쓰이는 수학적 모델은 $A_i, j=1, N_o$ 를 CAE 해석의 출력이라 할 때, A_j 를 각 입력의 함수로 나타내면,

$$A_j = \phi_j(t_f, T_m, t_h, T_c, P_p), \quad i=1, N_o \quad (3)$$

와 같은 형태를 갖는다. 이 때, A_1, A_2, A_3 는 각각 VLS, DWP, DSI이며 각 모델에 쓰이는 계수는 일반적인 통계적 회귀분석기법에 의하여 설정될 수 있다.

4. 모의실험




Fig. 2 Structure of a 5-4-3 neural network model for modeling of injection molding process

Fig. 3에 나타난 바와 같이 Box 형태의 기본 형




Fig. 3 Geometries considered in this study. Ribs and bosses are added in case (b) and (c), respectively

상 A는 $200 \times 200 \times 60$ mm의 치수와 3 mm의 두께를 가지며 아랫부분은 빈 공간이고, 윗부분은 120×120 m의 정방형 공간을 갖는다. 형상 B는 기본 형상 A에 15×60 mm의 치수를 갖는 4개의 리브를 추가한 형태이며 형상 C는 형상 B에 다시 4개의 보스를 추가한 형상이다. 각 보스의 내경과 외경은 각각 10 mm와 20 mm이며 높이는 20 mm이다. 수축률은 형상 A와 C의 경우 CAE 해석 결과를 토대로 각 모서리를 포함한 총 20개의 위치

에서 측정되었으며 형상 B에 대하여는 27개 데이터가 측정되었다. 그런 다음, 이 데이터에서 평균값 LS_{ave} 와 분산값(VLS)이 계산되었다. 변형률(warpage)도 유사한 방법으로 형상의 윗면과 아랫면의 모서리의 중심점을 기준으로 형상 A, B, C에 대하여 각각 4개씩 측정된 다음 이들의 평균값 WP_{ave} 와 DWP 가 계산되었다. 각 입력변수는 Table 1에 나타난 최대값과 최소값을 근거로 (0, 1) 사이의 값으로 정규화(normalization)하여 사용하였으며 각 샘플로부터 취해진 출력데이터를 근거로 출력의 예상 최대값과 최소값을 정한 다음 이들 값을 사용하여 모든 출력값을 (0, 1) 사이의 값으로 정규화하여 사용하였다.

신경회로망의 학습샘플은 가능한 한 넓은 범위의 실험조건하에서 수집된 것이어야만 학습된 신경회로망의 적용범위가 넓어진다. 앞서서도 언급된 바와 같이 주어진 수지와 사출기하에서도 성형공정은 많은 인자에 의해 영향을 받는다. 따라서, 학습의 효율성을 유지하고 공정모델의 효용성을 보장하기 위해서 실험계획법에 근거한 학습샘플의 취득이 필요하게 된다. 이 때 모사실험의 수 또는 학습샘플의 수는 입력레벨의 수, 입력변수의 수 및 이들의 조합에 의해 결정된다. 그러나, 입력변수가 5개일 경우 2레벨의 요인배치법(factorial design)은 총 $2^5=32$ 개의 학습샘플(또는, 32 simulation runs)을 필요로 하고, 특히 주어진 입력범위내에서 출력변수의 선형성(linearity)을 보장할 수 없는 경우 3레벨 요인배치법은 $3^5=243$ 개의 샘플을 필요로 한다. 본 연구에서 고려되고 있는 형상과 같이 유한 요소의 수와 노드의 수가 각각 $N_e=800-1000$, $N_n=400-500$ 인 경우 CAE 해석에 소요되는 시간은 SUN SPARC 10 기종의 경우 약 20~30분 정도이

Table 1 Ranges of input conditions. Melt temperature and holding time were kept constant for conditions (2)

	(1)		(2)	
	Z_{min}	Z_{max}	Z_{min}	Z_{max}
Filling time, sec	1	3	0.5	1.5
Melt temperature, C	190	210	210	
Holding time, sec	5	10	2.5	
Coolant temperature, C	20	40	20	40
Packing pressure, MPa	60	80	60	80

므로 학습샘플을 생성하는 데만도 엄청난 시간을 적으로 분석해 볼 필요가 있다. 필요로하게 된다. 따라서, 실험계획에 수반되는 비용을 통상, 공정조건 설계시 강건설계⁽⁵⁾는 S/N비를 고려하여 각 입력변수의 중요도를 미리 통계 최대화 하는 제어인자의 조건, 즉 잡음의 영향하에

Table 2 8 input conditions based on 2-level orthogonal array. Levels 1 and 2 represent the normalized input 0 and 1, respectively

No.	Filling time	Melt temperature	Holding time	Coolant temperature	Packing pressure
1	1	1	1	1	1
2	1	1	2	2	2
3	1	2	1	1	2
4	1	2	2	2	1
5	2	1	1	2	1
6	2	1	2	1	2
7	2	2	1	2	2
8	2	2	2	1	1

Table 3 16 input conditions based on 2-level orthogonal array. Levels 1 and 2 represent the normalized inputs 0 and 1, respectively

No.	Filling time	Melt temperature	Holding time	Coolant temperature	Packing pressure
1	1	1	1	1	1
2	1	1	2	2	2
3	1	2	1	1	2
4	1	2	2	2	1
5	2	1	1	2	1
6	2	1	2	1	2
7	2	2	1	2	2
8	2	2	2	1	1
9	2	1	1	1	2
10	2	1	1	2	1
11	2	1	2	2	1
12	2	1	2	2	1
13	2	2	1	1	2
14	2	2	1	2	1
15	2	2	2	1	2
16	2	2	2	2	1

서도 성능특성치의 분산이 작고 평균이 목표치에 근접하는 제어인자의 조건을 찾아내는 것을 의미한다. 본 논문에서는 이와 유사한 개념하에서 수축률과 변형률의 S/N비를 분석하여 재현성이 높은 요인효과를 검토하기 위하여 분산분석(analysis of variance)을 시행하였다. 이 때의 샘플들은 Table 2 또는 Table 3과 같이 다구찌가 제안한 직교배열에 의해 선정되었으며, 이 때의 S/N비는 $A_{j,ave}$, $j=1, N_o$ 와 σ_j^2 , $j=1, N_o$ 를 각각 CAE 해석 결과의 평균값과 분산이라고 할 때

$$S/N Ratio_j = 10 \log_{10} \frac{A_{j,ave}^2}{\sigma_j^2}, j=1, N_o \quad (4)$$

와 같이 정의된다. S/N비를 정의할 때 방목특성(nominal-the best)을 고려하는 이유는 관측치가

유한한 목표치(예를 들면, A_j)가 최적이며 어느 쪽으로 산포되어도 바람직하지 않은 특성을 말한다. 사출제품의 경우, 각 부위에서 측정된 수축률(LP)이나 변형률(WP)이 산포됨이 없이 균등한 값을 가질 때 최적이 된다. 즉, 평균 수축률과 변형률을 각 부위에 공히 적용할 수 있을 때가 최적이다. 다구찌방법에 의한 실험계획시에는 일반적인 요인배치법과는 달리 직교배열의 사용으로 최소한의 실험에 의한 일관성있는 실험결과를 얻을 수 있다. 이 점은 디자인 변수가 많거나 본 논문의 예와 같이 학습샘플의 취득에 많은 시간이 필요한 경우 특히 유효하다. 예를 들면, Data Series 1은 형상 A에 대하여 Table 1(1)과 같이 5 입력변수에 대하여 2레벨 일부실시법(fractional factorial design)

Table 4 Results of analysis of variance for LS, (a) and WP, (b) after pooling, Simulation experiments were designed with conditions of Table 2

	df	(a)			(b)			F(0.05)	F(0.01)
		SS	V	F	SS	V	F		
Fill. time	1	33.82	33.82	15.69	182.2	182.2	4.11	7.71	21.2
Hold. time	1	4.62	4.62	4.62					
Cool. temp.	1				333.0	333.0	7.52	7.71	21.2
Packing press.	1	18.02	18.02	8.35	422.5	422.5	9.54	7.71	21.2
Error	4	8.62		2.16	117.2	44.3			
Total	7	65.09	1114.9						

Table 5 9 input conditions based on 3-level orthogonal array. Levels 1, 2 and 3 represent the normalized inputs 0, 0.5 and 1, respectively

No.	Filling time	Coolant temperature	Packing pressure
1	1	1	1
2	1	2	2
3	1	3	3
4	2	1	2
5	2	2	3
6	2	3	1
7	3	1	3
8	3	2	1
9	3	3	2

에 의한 8번의 모사실험 통하여 얻어진 것이다. Table 4는 수축률과 변형률의 S/N비 분석의 결과를 나타내고 있다. Table 4의 결과에 따르면 수축률의 분산을 예측하는 데는 수지온도, 냉각수온도 등은 별로 중요하지 않으며 변형률의 경우에는 보압시간, 수지온도 등이 중요하지 않다고 판단되어진다. 따라서, 충전시간, 보압, 그리고 냉각수온도 등을 3 유효인자(dominant factor)로 선택하여 3 레벨 일부실시법에 의해 총 9개의 학습샘플이 Table 1(2)와 Table 5의 공정조건 하에서 취해졌다(Data Series 2). 이 때, 수지온도와 보압시간은 각각 210도와 2.5초로 고정되었다. 그 외에도, Data Series 1에 대하여 Table 1(1)의 공정조건 범위내에서 임의의 입력조건 조합에 의한 6개의 평가샘플(Data Series E1)을 별도로 취하여 성능 평가에 사용하였다. 마찬가지로 Data Series 2에 대하여도 7개의 평가샘플(Data Series E2)을 취하였

다. 또한, 형상 B, C에 대하여도 Table 1(2) 공정 조건하에서 각각 9개의 학습샘플(Data Series 3, 4)을 취하여 모델링에 사용하였다.

5. 결과 및 토의

공정모델의 성능을 평가하기 위해서는 적절한 평




Fig. 4 Average output error convergence for 5-4-3 and 5-4-1 network

Table 6 Coefficients for regression models of VLS, DWP and DSI calculated from Data Series 1

Model	Variable	Coefficient	Standard error	t for H ₀	Prob.> t
VLS	Constant	-0.3708	0.5396	-0.69	0.563
	t _r	0.3784	0.1591	2.38	0.140
	T _m	-0.1871	0.1591	-1.18	0.361
	t _h	0.2118	0.1591	1.33	0.315
	T _c	-0.1155	0.1591	-0.73	0.543
	P _p	0.1681	0.1591	1.06	0.402
DWP	Constant	0.8535	0.1576	5.41	0.032
	t _r	-0.0300	0.0465	-0.65	0.585
	T _m	-0.0465	0.0465	-1.00	0.423
	t _h	0.0555	0.0465	1.19	0.355
	T _c	-0.3490	0.0465	-7.51	0.017
	P _p	0.0085	0.0465	0.18	0.872
DSI	Constant	-0.0493	0.0753	-0.65	0.58
	t _r	0.2995	0.0222	13.48	0.005
	T _m	0.0366	0.0222	1.65	0.241
	t _h	0.0147	0.0222	0.66	0.576
	T _c	-0.0390	0.0222	-1.76	0.221
	P _p	-0.0535	0.0222	-2.41	0.138

가척도가 정의되어야 한다. 통상, 모델의 성능은 RMS 에러로 다음과 같이 나타낼 수 있다 :

$$RMS\ Error = \sqrt{\frac{1}{N} \sum_{i=1}^N (A_i - P_i)^2}, \quad j=1, N_o \quad (5)$$

식 (5)에서 N은 총 학습샘플의 수이다. 우선, Data Series 1에 대한 5-4-3 회로망과 5-4-1 회로망에 의한 모델링의 경우 RMS 에러는 대략 2만 회의 Iteration 후에 포화되는 경향이 Fig. 4에 나타나 있다. 5-4-3 모델에서의 출력은 VLS, DWP, DSI를 모두 포함하며 5-4-1 모델은 이들중 하나만을 출력으로 사용한다. 정상상태에서의 에러는 곧 학습샘플에 의한 모델링 에러로 볼 수 있다. 이때, 식 (5)에서 사용된 변수들은 그림에 도시된 바와 같다. Table 6에서는 Data Series 1에 의한 수축률, 변형률, 싱크인덱스 모델에 대하여 회귀모델링 결과를 보여주고 있다. 수축률 모델의 경우 R-square 값은 0.839로 이는 주어진 입력조건 범위의 범위안에서 VLS 변화의 약 83.9%가 회귀모델에 의해 설명될 수 있음을 나타낸다. 변형률 모델과 싱크인덱스 모델에 대하여도 같은 방법으로 모델의 타당성을 검증할 수 있다. 이 두 경우에도 R-square 값은 0.9 이상에서 회귀모델에 의한 모델링이 적절함을 나타내고 있다. 그러나, 가설검증 (hypothesis testing)에 의한 t값은 각 요인별 중요도를 설명하지 못하고 있다.

일단 모델링이 끝나면 다른 샘플 (예를 들면, 평가샘플)에 대해서도 일반화할 수 있는가 검토할 필요가 있다. 이는 평가샘플의 입력조건에 대한 네트워크의 출력을 해당 CAE 출력과 비교함으로써 시행할 수 있다. Fig. 5에는 신경회로망 모델과 회귀모델의 두 경우에 대하여 학습샘플과 평가 샘플에 의한 출력을 실제의 CAE 출력과 비교, 도시하고 있다. 그림에서는 세 가지의 출력변수에 대하여 두

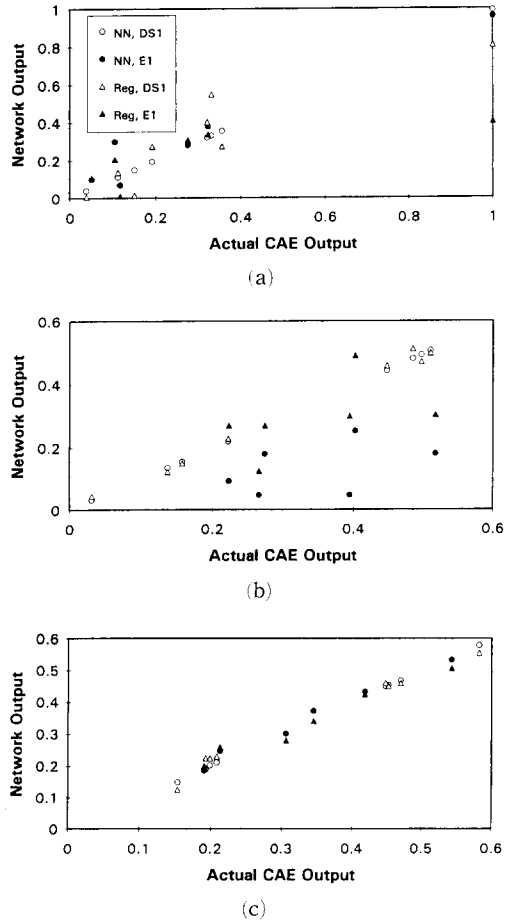


Fig. 5 Comparison of modeling performances of 5-4-1 neural networks and regression models for Vls, (a) DWP, (b) and DSI, (c) Both Data Series 1 and E1 were used for modeling and evaluation, respectively

가지의 모델링기법이 엇비슷한 성능을 보여주고 있다. 그러나, 평가샘플에 의한 모델링에러는 허용범위를 크게 벗어남을 나타내고 있다. 모델링 에러를

Table 7 Average RMS error calculated from 8, 16, 32, training samples in Data Series 1 for 5-4-1 VLS, DWP and DSI models. Data Series E1 was used for evaluation purpose

	8 Samples		16 Samples		32 Samples	
	DS 1	E 1	DS 1	E 1	DS 1	E 1
VLS	0.00315	0.09209	0.00548	0.19463	0.01547	0.09885
VWP	0.00381	0.23461	0.00393	0.11848	0.02653	0.14190
DSI	0.00307	0.02007	0.00265	0.02231	0.00873	0.03472

줄이기 위해서는 회귀 모델에서는 다항식의 차수를 증가시킬 수 있다. 그러나, 이들의 형태를 결정해야 하는 문제가 있고 특히 다구찌방법에 의한 실험 계획시 학습샘플의 수가 제한되어 있기 때문에 추가되는 항의 수도 제한을 받게 된다. 또 하나의 방법은 학습샘플의 수를 늘리는 것이다. Table 7은 학습에 사용된 샘플데이터의 수와 모델링 에러간의 관계를 Data Series 1에 대하여 나타내고 있다. Table 7에 따르면, VLS, DWP, DSI 모든 모델에 대하여 학습샘플의 수가 증가하여도 모델링 성능의 현저한 증가는 보이지 않는다. 특히, 32 학습샘플에 의한 2레벨 요인배치법의 경우에도 평가샘플에 의한 모델링 에러는 허용범위를 크게 벗어남을 보여주고 있다. 이는 바꾸어 말하면 직교배열에 의한 일부 실시법에 의해 효과적으로 각 인자의 영향을 모델링할 수 있음을 의미하기도 한다. 그러나, Data Series1은 2레벨 디자인에 의하여 얻어졌으므로 학습샘플과 평가샘플에 의한 모델링 성능의 현격한 차이는 사출공정의 비선형성(non-linearity)을 의미한다고도 할 수 있다. 예를 들면, Fig. 6에 나타난 바와 같이 3레벨 디자인에 근거한 Data Series 3에 의한 공정 모델의 경우 평가샘플에 의한 모델링 에러가 현저히 감소되는 것으로 알 수 있다. 이 때, 회귀모델의 경우 3가지 모델에 대하여 R-square 값은 모두 0.95 이상으로 회귀모델링의 적절함을 나타내고 있다.

신경회로망 모델에서는 다수의 입력/출력(multi-input/Multi-output) 관계의 설정이 용이하기 때문에 다수의 출력을 동시에 고려하는 경우 특히 유효하다. Fig. 7은 5-4-3 네트워크와 5-4-1 네트워크에 의한 모델링 에러를 나타내고 있다. 그림에서 출력노드의 수가 증가하여도 모델링 에러의 변화가 뚜렷하지 않음을 알 수 있다. 따라서, 주어진

입력변수에 대하여 간단히 출력노드의 수를 바꿈으로서 출력변수의 수를 조절할 수 있다.

마지막으로, Table 1(2) 공정조건하에서 형상 A, B, C에 대하여 시행된 CAE 해석으로 부터 얻어진 VLS와 DWP의 값들이 Fig. 8에 나타나 있다. 그림에서 형상 A와 B의 경우 VLS의 값들은 넓은 영역에 걸쳐 분포하되 리브가 부가됨에 따라 그 영역이 낮은 쪽으로 옮겨가는 경향을 보여준다. 그러나, DWP값의 변화는 거의 보이지 않는다. 형상 C의 경우에는 일관된 경향이 없이 넓게 산포되어 있음을 알 수 있다. 이는 부가형상이 더해짐에 따라 변화된 사출공정의 특성이 수축률에도 그대로 반영되어 나타나는 것을 보여준다. 실제 금형의 설계시 회귀모델에 의한 공정모델링은 리브와




Fig. 6 Comparison of modeling performances of 5-4-1 neural networks and regression models for Data Series 2. Data Series E2 was used for evaluation

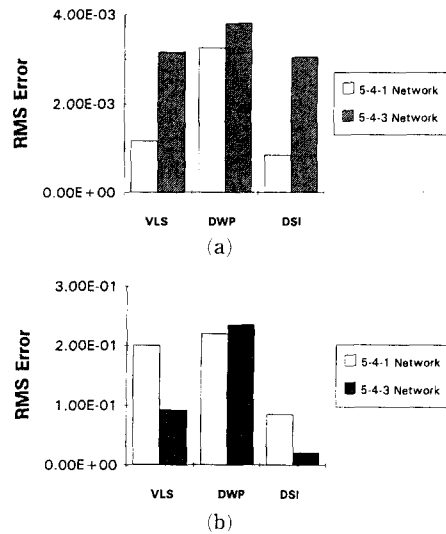


Fig. 7 Modeling performances of the neural network for different numbers of output nodes. Data Series 1 and 2 were used for (a) and (b) respectively




Fig. 8 Variation of VLS and DWP calculated from Data Series 2, 3 and 4 for Geometry A, B, and C

보스의 빈번한 수정이 이루어질 때마다 새로운 모델 설정을 위한 CAE 해석데이터를 필요로 하기 때문에 엄청난 비용을 초래하게 된다. 그러나, 신경회로망 모델의 경우 자기학습 기능에 근거한 적응최적화(adaptive optimization) 기법⁽⁶⁾에 의하여 최소한의 CAE 해석만으로도 부가형상의 변화에 대응할 수 있다. 따라서, 최소한의 CAE 해석만으로도 적절한 성능의 공정 모델링이 가능하게 된다.

6. 결 론

본 연구에서는 CAE 해석시 사출공정조건의 입력과 제품의 수축률, 변형률, 싱크인덱스 등 출력간의 관계에 대하여 신경회로망을 사용하여 실험적 모델을 설정하였고 이의 성능을 기존의 회귀분석 모델과 비교, 평가하였다. 특히, 모델링에 사용되는 실험데이터는 다구찌방법에 근거하여 재현성이 높고 외부 잡음인자에 강하면서 최소의 CAE 해석만으로도 얻을 수 있도록 하였다. 본 연구에서 얻어진 결과를 토대로 다음과 같은 결론을 내릴 수 있다.

(1) 사출공정의 해석을 위한 신경회로망 모델이 실험계획에 근거한 학습샘플로부터 성공적으로 설정되었다.

(2) 2 레벨 실험계획에 의한 모델링시 사출공정의 비선형성은 학습의 효율성을 떨어뜨린다. 이는 학습샘플의 증가에도 불구하고 모델링 에러가 감소하지 않으며, 경우에 따라서는 증가할 수도 있음으로 알 수 있다. 따라서, 공정의 비선형성을 고려한 3 레벨 실험계획으로 모델링 에러를 현저하게 줄일 수 있다.

(3) 신경회로망 모델에서는 다수의 입력/출력(multi-input/multi-output) 관계의 설정이 용이하기 때문에 다수의 출력을 고려하는 경우 특히 유효하다.

(4) 사출성형공정의 신경회로망 모델은 기존의 회귀모델과 유사한 성능을 나타낸다. 그러나, 신경회로망 모델은 구조의 변경이 용이하고 자기학습 기능을 통한 적응성과 일반화 특성을 지녔으므로 사출공정과 같이 형상의 빈번한 수정에 기인한 공정의 변화가 심한 경우 특히 민감하게 대응할 수

있을 것으로 사료된다. 따라서, 적극적인 현장 적용이 기대된다.

참고문헌

- (1) Yerramreddy, S. Lu S. C-Y. and Arnold, K. F., 1993, "Developing Empirical Models from Observational Data Using Artificial Neural Networks," *J. of Intelligent Manufacturing*, Vol. 4, pp. 33~41
- (2) Actis Dato, M. Di Dio, L. and Godlo, C., 1988, "A CIM Concept for Injection Molding," *Kunststoffe German Plastics*, Vol. 78, No. 3, pp. 9~11
- (3) Huh, Y. and Kim, S. G., 1991, "A Knowledge-based CAD System for Concurrent Product Design in Injection Moulding," *Int. J. CIM*, Vol. 4, No. 4, pp. 209~218
- (4) *C-MOLD User's Manual*, 1993, AC Technology, Inc.
- (5) 이종원, 김추호, 1994, "다구찌방법을 이용한 컴퓨터원용 강건설계기법의 개발," 대한기계학회논문집, 제18권, 제 2호, pp. 278~291
- (6) Choi, G. H., Lee, K. D., Chang, N. and Kim, S. G., 1994, "Optimization of Process Parameters of Injection Molding with Neural Network Application in a Process Simulation Environment," *Annals of the CIRP*, Vol. 43, No. 1, pp. 449~452
- (7) Tseng, A. A., Arinze, B. and Kaplan, J. D., 1992, "A Knowledge-Based Design Approach for Injection Molding of Plastic Balls," *Advances in Polymer Technology*, Vol. 11, No. 2, pp. 109~120
- (8) Hunkar D. B. and Mastine, H. R., 1991, "Neural Network Based Programs: A Possible Solution to Training Problems," *Proceedings of ANTEC*, pp. 1436~1441
- (9) Hebert, L. P., Laplume, F. and Salloum, G., 1992, "A Knowledge Based Advisor for Preventing Errors during Product and Mold Design and for Solving Injection Molding Problems," *Proceedings of ANTEC*, pp. 54~56
- (10) Phadke, M. S. 1989, *Quality Engineering Using Robust Design*, Prentice Hall