

사출성형 문제해결을 위한 퍼지 신경망 적용에 관한 연구

강성남*, 허용정**, 조현찬***

A Study on the Application of Fuzzy Neural Network for Troubleshooting of Injection Molding Problems

Sung Nam Kang*, Yong Jeong Huh**, Hyun Chan Cho***

ABSTRACT

In order to predict the moldability of a injection molded part, a simulation of filling is needed. Short shot is one of the most frequent troubles encountered during injection molding process. The adjustment of process conditions is the most economic way to troubleshoot the problematic short shot in cost and time since the mold doesn't need to be modified at all. But it is difficult to adjust the process conditions appropriately in no times since it requires an empirical knowledge of injection molding.

In this paper, the intelligent CAE system synergistically combines fuzzy-neural network (FNN) for heuristic knowledge with CAE programs for analytical knowledge. To evaluate the intelligent algorithms, a cellular phone flip has been chosen as a finite element model and filling analyses have been performed with a commercial CAE software. As the results, the intelligent CAE system drastically reduces the troubleshooting time of short shot in comparison with the experts' conventional methodology which is similar to the golden section search algorithm.

Key Words : Fuzzy Neural Network (퍼지 신경망), BP algorithm (BP 알고리즘), Injection Molding (사출성형), CAE (Computer Aided Engineering), Process Condition (공정 조건)

1. 서론

최근 눈부신 디지털 컴퓨터 이용 기술은 전통적인 생산공정의 자동화를 유발시켰으며, 데이터 레벨(CAD, CAM)에서 단위설비 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 필연적

으로 생산과 관련된 공정의 모델링 작업을 수반하게 된다. 즉, 공정의 정확한 이해를 바탕으로 입출력 변수 사이의 관계를 모델링 해야 한다. 이와 같은 의사결정의 자동화가 필요한 대표적인 공정중의 하나가 사출성형공정이다⁽²⁾.

그러나 사출성형 공정의 완벽한 이해는 아직도 불가능하며 공정조건과 제품 품질과의 정확한 관계를 확립하기가 어렵다. 이와 같은 이유로 아직까지 사출성형제품의 설계 및 제조는 전문가의 축적된 경험에 많이 의존하고 있다. Jan과 O'Brien 등은 사

*# 2002년 1월 21일 접수

* 한국기술교육대 대학원 기계공학과

** 한국기술교육대 메카트로닉스공학부

*** 한국기술교육대 정보기술공학부

출성형의 구성요소를 플라스틱 수지, 사출금형, 사출 성형기, 공정조건의 네 가지로 분류하였고⁽³⁾, 이 네 가지 요소가 복합적으로 결부되어 여러 가지 성형 불량을 유발한다고 하였다. 사출성형시 주로 발생하는 성형불량의 종류는 약 20여가지 정도이며 그중 가장 빈번하게 발생하는 불량 중 하나가 미성형이다⁽⁴⁾.

이러한 성형성을 예측하기 위하여 C-Mold⁽⁵⁾ 등의 사출성형해석용 CAE 상용 소프트웨어들이 많이 사용되고 있다. 미성형 해결방안으로 공정조건을 조절하는 방법은 금형의 수정을 피할 수 있기 때문에 경제적이고 효과적이다. 그러나 사출전문가의 오랜 기간 축적된 경험적 지식이 의존하기 때문에 시행착오를 겪어야 한다. 경험에 의한 해는 특정한 경우에 대해 미성형 해결을 했다고 할지라도 새로운 제품이나 작업환경에서는 다시 그 조건에 적합한 공정조건을 찾아야 하는 문제점을 갖는다⁽⁶⁾. 최근에 전문가의 애매한 경험적 지식을 표현할 수 있는 퍼지(fuzzy) 이론이 많은 분야에서 적용되고 있다. 그러나 퍼지논리 알고리즘은 소속함수와 규칙베이스가 매우 주관적으로 결정되기 때문에 전문가의 도움이 전적으로 필요하거나 실제로 구성하기 어려운 경우가 많다. 또한 규칙 베이스의 구성은 많은 시간 소모와 제어규칙의 최적화 문제가 제시된다⁽⁷⁾.

본 논문에서는 사출성형에서 발생하는 미성형 문제 해결에 중점을 두어 퍼지논리에 신경망기법을 융합한 퍼지 신경망(Fuzzy Neural Network)기법과 사출성형 해석 CAE 프로그램을 연계하여 미성형 방지를 위한 최적 공정조건을 최소의 반복회수로 구하는 지능형 CAE시스템을 구축하려는 것이다.

최근 플라스틱 제품의 추세는 경량화와 박막화이다. 박막형의 경우 면적에 비해 체적이 작고 따라서 플라스틱 자체의 열용량이 적어지게 되므로 미성형 방지에 있어서 가장 중요한 공정조건은 금형온도가 된다. 이러한 이유로 적합한 성형조건 윈도우내에서 충전시간과 용융수지 온도가 결정되면 최적 금형온도를 최소의 시간내에 지능형 알고리즘에 의해 구할 수 있도록 하였다. 또한 실제 현장에서 미성형이 발생한 박막형 제품의 사례연구를 통하여 실제 적용 가능성을 검토하였다.

2. 퍼지 신경망(FNN)의 구조

2.1 퍼지 이론과 신경회로망의 융합

퍼지논리는 언어적 제어의 특징과 논리성의 이점을 갖는 반면에 신경망은 학습능력과 오차 보간능력의 장점을 갖고 있다. 이런 장점들은 서로 상호 보완적이며 이들의 융합(fusion)은 좀 더 인간의 사고 능력에 가까운 알고리즘의 구현을 가능하게 한다⁽⁸⁾.

퍼지 논리와 신경망의 융합은 두 이론의 유사한 특성들을 이용해 새로운 퍼지 신경망 모델을 구성하는 방식이라고 할 수 있다. 일반적으로 두 이론은 다음의 유사한 특성을 갖는다.

첫째로, Fig. 1(a), (b)에서 보는 바와 같이 신경망의 활성화 함수의 출력 특성과 퍼지 이론의 소속함수의 특성이 유사하여 두 이론을 융합하는 기초가 된다. 신경회로망의 출력함수를 퍼지이론의 소속함수로 생각할 수 있다.

둘째로, Fig. 2(a), (b)에서 보는 바와 같이 신경망을 구성하는 뉴런의 곱 및 덧셈 연산과 퍼지 추론에서의 max-min 연산 기능이 유사하다.

위와 같은 두 이론의 유사성을 이용하여 퍼지 논리에 신경회로망의 학습 능력을 부여하게 되는 것이다.




Fig. 1(a) Sigmoid function of neural network




Fig. 1(b) Membership function of fuzzy logic




Fig. 2(a) Product · Sum operation of neuron




Fig. 2(b) Max-min operation of fuzzy inference

2.2 전체 시스템의 구성

본문에서 퍼지 신경망을 적용한 전체 시스템의 구성이 Fig. 3에 나타나 있다. Fig. 3에서 e , \dot{e} 및 ΔT_m 의 의미는 다음과 같다.

- e : $\Delta\%$ Volume (미성형 체적 %)
- \dot{e} : $\Delta\%$ Volume / Fill Time
- \ddot{e} : $\dot{e}(i-1) - \dot{e}(i)$
- ΔT_m : Δ Mold Temperature

충전시간(fill time), 용융수지 온도 및 금형 온도를 C-Mold에 입력하여 성형해석을 수행하면 미성형이 발생했을 경우 전체 체적에 대한 미성형 체적 e 와 \dot{e} 값을 얻게 된다. 충전시간이 도입된 이유는 충전시간이 미성형에 영향을 미치기 때문이다. 이 두 값이 Estimator에 입력되어 여기서 출력되는 금형 온도 ΔT_m 으로 퍼지 신경망의 학습을 하게 된다. 여기서 Estimator는 입력 e 와 \dot{e} 에 대해 미성형을 보상해 줄 수 있는 ΔT_m 값을 찾을 수 있도록 경험적인 직선의 방정식 삽입되어 있다. 실제로 사출성형 공정은 매우 복잡하고 비선형적이어서 이 직선의 방정식 자체가 오차를 가지고 있다. 그러나 이 오차는 신경망의 학습에 의해 그 오차를 감소시키는 방향으로 연결 강도(synapse weight)

를 조정해 주어 원하는 출력을 얻을 수 있다.




Fig. 3 Schematic diagram of fuzzy neural network application. e : $\Delta\%$ Volume (미성형 체적 %), \dot{e} : $\Delta\%$ Volume / Fill Time, \ddot{e} : $\dot{e}(i-1) - \dot{e}(i)$, ΔT_m : Δ Mold Temperature




Fig. 4(a) Membership functions of e




Fig. 4(b) Membership functions of \dot{e}

Fig. 4(a), (b)는 e 와 \dot{e} 의 소속함수를 각각 나타내고 있으며 Table 1의 언어 변수들의 수치 값의 구체적 범위를 보여주고 있다.

Fig. 5에서는 Table 1의 퍼지 규칙 베이스와 Max-Min 추론 방법을 신경망으로 표현한 퍼지 신경망의 구조를 보여주고 있다. Table 1에서 ZO,

PS, NS는 각각 영(zero), 양의 작은 값(positive small), 음의 작은 값(negative small)을 의미한다.

Table 1 Fuzzy rule base

ΔT_m		\ddot{e}					
		NB	NS	ZO	PS	PM	PB
e	VS	ZO	ZO	ZO	NS	NM	NB
	S	PS	PS	PS	PS	PS	PM
	M	PM	PM	PS	PS	PM	PM
	B	PB	PM	PM	PM	PM	PB
	VB	PB	PB	PM	PB	PB	PB

학습방법으로는 오차 역전파(Error back-propagation) 방법을 사용하고 있다. 효율적인 학습을 위해 본 연구에서는 2단계로 학습을 수행하였다. 첫 번째 단계에서는 사출시간, 금형온도, 용융수지온도와 같은 공정조건들이 서로 커풀되어 제품의 품질에 영향을 미치는 점을 고려하여 사출시간과 용융수지온도가 결정되면 이에 상응하는 적절한 금형온도를 찾을 수 있도록 학습을 한다. 두 번째 단계에서는 실제로 사출성형 해석을 통해 알 수 있는 미성형 체적의 비율을 에러로 하여 이를 영으로 만드는 방향으로 학습을 하게 된다.




Fig. 5 Structure of Fuzzy neural network

Fig. 5에서 보듯이 e와 \ddot{e} 값이 FNN에 입력되면 각각의 퍼지 집합에 가중치를 가지고 두 번째 뉴런 층으로 입력되는데, 이 값이 퍼지의 소속 값을 나타내게 된다. 세 번째 뉴런 층에서는 입력된 소속 값을 Min 연산하게 되고 이 값을 출력 값으로 해서 네 번째 뉴런 층으로 보내게 된다. 이를 같은 제어 동작(control action)을 갖는 뉴런을 묶어서 5 번째 뉴런 층으로 보내고 5 번째 뉴런 층에서는 입력 값들을 Max 연산하여 출력하게 된다. 5 번째 층에서 출력된 값들을 모두 합산하고 이를 비퍼지화 시켜서 출력 값 y, 즉 ΔT_m 을 얻게 된다.

3. 사례연구

3.1 해석모델

본 연구에서는 CAE 프로그램인 C-Mold를 이용하여 사출성형 해석을 수행하였다. 해석 모델은 실제현장에서 미성형이 발생한 Fig. 6에 도시되어 있는 핸드폰 플립 커버이다. 3차원 형상 모델링을 위해서는 기하학적 모델러가 필요한데 사출성형제품은 제품의 크기에 비하여 두께가 대단히 얇기 때문에 서피스 모델러(surface modeler)를 사용한다.




Fig. 6(a) Surface model of the mobile phone flip cover

Fig. 6(a)는 Pro/E를 이용한 서피스 모델이고, Fig 6(b)는 C-Mold를 이용해서 메쉬(mesh)를 생성한 FEM 모델이다. 부품 치수는 가로 30mm, 세로 40mm이고 두께는 1mm이다. 고분자 재료는 GE Plastics사의 ABS MAGNUM 3404를 선정하였다.




Fig. 6(b) FEM model of the mobile phone flip cover

3.2 공정조건

시뮬레이션상의 고분자 재료 및 공정조건은 Table 2에 주어져 있다. 점도모델은 C-Mold에서 채택한 일반화된 Cross/Carreau 모델이 이용되었다.

Table 3과 같이 10개의 공정조건에 대해 본 연구에서 제안한 퍼지 신경망을 이용해 시뮬레이션을 하고 같은 조건에 대해 황금분할탐색방법을 이용해 제안된 퍼지 신경망을 평가하였다. 퍼지 신경망을 황금분할탐색법과 비교한 이유는 황금분할탐색방법이 사출성형해석 숙련자가 최적의 공정조건을 찾아가는 방법과 유사하기 때문이다.

Table 3의 조건들의 경우 처음에 Table 3의 각각의 경우의 조건들과 금형온도의 초기 온도를 상온(25℃)으로 하여 시뮬레이션하면 처음에 전체 체적의 2~5 퍼센트에 해당하는 미성형이 발생한다⁽⁹⁾. 이를 방지하기 위해서는 최적의 금형온도를 구해내야 한다. 물성 등 보다 구체적인 데이터와 해석을 위한 자세한 내용은 참고문헌 9를 참조하면 된다.

Table 2 Process conditions

Resin name	ABS MAGNUM 3404
Injection pressure	120 MPa
Packing pressure	100 MPa
Gate type / number	Side gate / 2
Melt temperature	Variable (200~280℃)
Fill time	Variable (0.16~0.28sec)
Mold temperature	Output variable

Table 3 Simulation cases

No.	Fill time (sec)	Melt temperature (℃)
01	0.16	220
02	0.17	260
03	0.18	230
04	0.19	280
05	0.20	240
06	0.21	220
07	0.22	280
08	0.23	230
09	0.24	260
10	0.25	270

3.3 시뮬레이션 결과

Table 3의 각각의 경우에 대해서 미성형의 발생을 방지할 수 있는 최적의 금형온도가 존재한다. 미성형 해결을 위한 최적의 금형온도를 지능형 알고리즘에 의해 최소의 반복횟수로 찾아낸 결과를 Table 4에 도시하였다.

해석결과 황금분할 탐색법을 이용한 평균 시뮬레이션 반복횟수는 각 경우에 있어서 5에서 7사이로 평균 5.9회이고 퍼지 신경망의 경우는 Table 4의 결과와 같이 평균 1.8회로 상당히 반복횟수가 줄어들음을 알 수 있다. 반복횟수나 계산시간은 줄어든 반면 계산결과 값은 거의 유사한 것으로 나타났다. 10가지의 각각 경우에 대하여 Table 3과 Table 4의 공정조건이 미성형을 방지하기 위한 최적 공정조건이다. Fig. 7은 황금분할 탐색방법과 퍼지 신경망을 이용할 경우 각각의 경우에 있어서 반복횟수를 비교한 결과를 보여준다.

Table 4 The simulation results (By using FNN)

No.	Iteration number	Mold temperature (℃)
01	2	53
02	1	28
03	2	57
04	1	28
05	2	59
06	2	76
07	1	45
08	3	77
09	2	64
10	2	62

유동해석 시뮬레이션을 1회 수행하는 시간이 약 30~40 분이므로 퍼지 신경망을 이용하여 약 150분 정도 성형해석 시간을 단축할 수 있다고 볼 수 있다.




Fig. 7 Iteration number of the simulations

4. 결론

본 연구에서는 기존의 사출 전문가의 경험적 지식을 규칙 베이스화하여 퍼지로 구성하고 신경망을 적용하여 학습을 통해 미성형을 쉽게 해결할 수 있는 공정조건을 찾는 퍼지 신경망 알고리즘을 제안하였다. 퍼지 신경망 기법은 퍼지의 규칙을 시그모이드 학습을 통해 향상시킴으로써 해를 찾는 효과가 향상될 수 있다. 미성형이 발생한 핸드폰 플립의 사출성형 사례연구를 통해 본 논문에서 제안된 퍼지 신경망을 평가하였으며 이 때 같은 공정조건하에서 전문가의 문제해결 방법과 유사한 황금분할탐색방법으로 사출성형해석을 다시 수행하여 두 결과를 비교 분석하였다. 사출성형해석 결과 퍼지 신경망은 황금분할탐색법에 비해 약 69% 정도 미성형 해결시간을 단축했다. 이로써 비선형, 비뉴턴 유체유동을 포함하는 사출성형 문제해결에 퍼지 신경망이 효과적으로 적용될 수 있음을 보였다.

참고문헌

1. Yerramreddy, S., Lu, S. C. Y. and Arnold, K. F., "Developing Empirical Models from Observational Data Using Artificial Neural Networks," J. of Intelligent Manufacturing, Vol. 4, pp. 33-41, 1993.
2. Dato, A., DiDio, L. and Godlo, C., "A CIM

- Concept for Injection Molding," Kunst-stoffe German Plastics, Vol. 78, No. 3, pp. 9-11, 1988.
3. Jan, T. C., O' Brien, K. T., "Architecture of an Expert System for Injection Molding Problems," Annual Technical Conference in Society of Plastic Engineers '91, pp. 431-443, 1991.
4. Nguyen, L. T., Danker, A., Santhiran, N. and Shervin, C. R., "Flow Modeling of Wire Sweep during Molding of Integrated Circuits," ASME Winter Annual Meeting, pp. 8-13, 1992.
5. C-Mold User's Manual, AC Technology, 1989.
6. Kim, Sang-Gook, Suh, Nam P., "Knowledge-Based Synthesis for Injection Molding," Robotics & Computer Integrated Manufacturing, Vol. 3, No. 2, pp. 181-186, 1987.
7. Guez, A., Eilbert, J. L. and Kam, M., "Neural Network Architecture for Control," IEEE Control System Magazine, pp. 22-25, 1988.
8. Lin, C. T., Lee, C. S. George, "Neural-Network Based Fuzzy Logic Control and Decision System," IEEE Transaction on Computers, Vol 40, No. 12, pp. 1320-1336, December 1991.
9. Kang, Sung-Nam, "A Multi-Level Intelligent CAE System for the Moldability of Injection Molding," M.S. Thesis, Korea University of Technology and Education, 2002.