한국금형공학회지, 제13권 제3호, 2019
J. Korea Society of Die & Mold Engineering, Vol.13 No.3, 2019 ISSN 2092-9692

Artificial Neural Network를 이용한 사출압력과 사출성형품의 무게 예측에 대한 연구

양동철[1] · 김종선[†]
한국생산기술연구원 금형기술그룹[1,†]

A study on the prediction of injection pressure and weight of injection-molded product using Artificial Neural Network

Dong-Cheol Yang[1] · Jong-Sun Kim[†]
Molds & Dies R&D Group, Korea Institute of Industrial Technology[1,†]
(Received September 18, 2019 / Revised September 26, 2019 / Accepted September 30, 2019)

Abstract: This paper presents Artificial Neural Network(ANN) method to predict maximum injection pressure of injection molding machine and weights of injection molding products. 5 hidden layers with 10 neurons is used in the ANN. The ANN was conducted with 5 Input parameters and 2 response data. The input parameters, i.e., melt temperature, mold temperature, fill time, packing pressure, and packing time were selected. The combination of the orthogonal array L27 data set and 23 randomly generated data set were applied in order to train and test for ANN. According to the experimental result, error of the ANN for weights was $0.49 \pm 0.23\%$. In case of maximum injection pressure, error of the ANN was $1.40 \pm 1.19\%$. This value showed that ANN can be successfully predict the injection pressure and the weights of injection molding products.

Key Words: Artificial neural network, Injection molding, Machine learning, Weight

1. 서 론

플라스틱 사출성형은 복잡한 형상과 크기가 큰 제품을 짧은 시간에 저렴한 비용으로 생산해내는 제조기술이다[1]. 사출공정에서 용융된 수지는 차가운 금형 안으로 들어가 높은 보압 하에서 굳어진다[2]. 이러한 복잡한 공정과정을 거쳐 생산되는 사출성형품들의 품질을 정밀하게 관리하는 것은 매우 어려운 일이다. 사출성형품의 품질기준평가에서 무게는 하나의 중요한 평가요소이다. 제품 무게는 제품의 표면품질, 기계적 성질 등과 밀접한 관계가 있다[1]. 사출성형품의 무게를 예측할 때, 이전에는 사출성형기술자의 경험적인 지식에 의존하는 trial-and-error 방식이 사용되어 왔다. 하지만 이러한 방식은 비효율적이고 많은 시간이 소요된다. 따라서 최근 연구에서는 사출성형품의 무게를 예측할 때, 기계학습(machine learning)과 딥 러닝(deep-leaning)을 적용한 Artificial Neural Network(ANN) 방식이 사용되기도 한다[3]. ANN이 사출성형품의 무게예측에 많이 사용되는 이유는 기존의 최적화 기법들, 예를 들어 다구찌 방법 등 보다 결과들 도출하는 속도가 빠르고 정확하며 사출성형변수들 사이의 비선형적 관계까지 예측해 낼 수 있기 때문이다[4].

본 연구에서는 4개의 캐비티로 구성된 컵 금형을 사용하여 L27 직교배열을 이용한 5인자 3수준의 성형조건과 경계조건 내에서 무작위로 선택된 23개의 성형조건에 대해 사출성형을 진행하고 최대 사출압력과 무게를 측정한다. 그리고 50개의 조건 데이터 중 45개의 데이터를 ANN에 학습 데이터(training

1. 한국생산기술연구원 금형기술그룹
† 교신저자: 한국생산기술연구원 금형기술그룹
E-mail: libra74@kitech.re.kr

data)로 적용하고 나머지 무작위 조건 데이터 중 5개의 데이터를 실험 데이터(test data)로 사용하여 해당 조건에서의 무게와 최대 사출압력을 예측하여 비교하고 평가하였다.

2. 실험

2.1. 재료

실험에서 사용된 재료는 Polypropylene(PP)이며 그레이드(grade)는 J-150(Lotte chemical)이다. J-150은 일반 사출성형에 사용되는 범용 수지이며 Table 1에 권장 성형 조건과 용융 지수를 나타내었다.

Table 1 Properties of J-150 for injection molding

Properties	Value	Unit	Note
Melt flow index	10	g/min	Test temperature : 230℃ Test load : 2.16 kg
Melt temperature	210 ~ 240	℃	Recommended
Mold temperature	40 ~ 60	℃	Recommended

2.2. 사출성형

본 실험에서는 Fig. 1의 220톤 사출성형기(WIZ-220, LSMtron)를 사용하여 사출성형을 진행하였다. 금형은 Fig. 2의 4개의 캐비티로 이루어진 컵 금형을 사용하였다. 성형조건은 L27 직교배열법을 이용하여 Table 2의 5인자 3수준의 27개 조건을 적용하였으며 이외에도 각 인자의 경계조건 내에서 완전요인실험(full factorial design)이 아닌 임의로 23개의 성형조건을 추가로 생성하여 총 50개 성형조건에 대해 사출성형을 진행하였다. Fig. 3에는 성형된 제품을 나타내었다.

Fig. 1 Injection molding machine(WIZ-220, LSMtron)

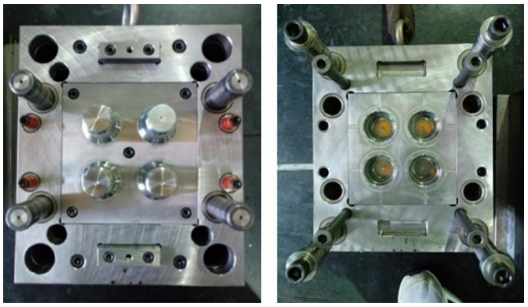

Fig. 2 Cup mold used in this study(4 cavity)

Table 2 5 factors and 3 levels for L27

Factor	Level			Unit
	1	2	3	
Fill time	0.5	1.0	1.5	sec
Melt temperature	210	225	240	℃
Mold temperature	30	45	60	℃
Packing prssure	30	50	70	MPa
Packing time	1	2	3	sec

Fig. 3 Cup mold used in this study(4 cavity)

2.3. Artificial Neural Network(ANN)

ANN은 자연에서의 생물학적 신경망 시스템을 모방해서 간단한 구조의 뉴런들이 모여 네트워크 신경망 시스템을 이룬다. ANN은 기계학습과 딥러닝 과정을 통해 뉴런들 사이의 weight 값을 변화시킨다. 즉, 훈련을 거듭하면서 입력데이터와 출력데이터 사이의 복잡한 함수 관계를 점진적으로 형성

한다. 본 연구에서는 Fig. 4와 같이 입력 데이터 5개, 5층 신경망, 신경망 당 뉴런 10개, 출력데이터 2개 구조를 사용하여 ANN을 구현하고 데이터를 학습하였다.

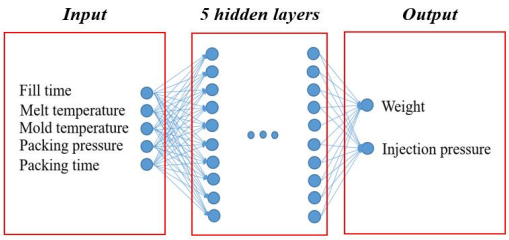

Fig. 4 Structure of ANN used this study

활성화 함수는 ReLU, 최적화에는 Adam optimizer를 사용하였다. ReLU(rectified linear unit)은 기계학습에서 많이 사용되는 활성화 함수 중 하나이다. 기존에 대표적인 활성화 함수로 Sigmoid function을 사용하였으나 기울기 손실(gradient vanishing) 문제로 인해 ReLU 함수를 적용하기 시작하였다. Sigmoid function은 0에서 1 사이의 값을 가지며 경사 하강법(gradient descent)으로 역전파(backpropagation) 수행 시, 레이어(layer)를 지나며 경사 값을 계속 곱하므로 0으로 수렴하고 레이어 수가 많아지면 에러가 발생한다. 반면, ReLU의 수식은 식(1)과 같이 입력값이 0보다 작으면 0을 출력하고 0보다 크면 입력값을 그대로 출력하며 부분적인 활성화(sparse activation), 기울기 손실 문제의 해결 등의 이점을 가진다.

$$f = \begin{cases} (x < 0) & f(x) = 0 \\ (x \geq 0 & f(x) = x \end{cases} \tag{1}$$

Table 3 Results of DOE (L27)

No.	Input index					Output index	
	Fill time [level]	Melt temperature [level]	Mold temperature [level]	Packing pressure [level]	Packing time [level]	Weight [g]	Max. Injection pressure [MPa]
1	1	1	1	1	1	14.552	679
2	1	1	1	1	2	14.879	675
3	1	1	1	1	3	15.054	679
4	2	1	2	3	1	14.210	552
5	2	1	2	3	2	14.114	551
6	2	1	2	3	3	13.939	566
7	3	1	3	2	1	14.212	526
8	3	1	3	2	2	14.201	519
9	3	1	3	2	3	14.245	511
10	1	2	2	2	1	14.207	470
11	1	2	2	2	2	14.249	482
12	1	2	2	2	3	14.225	480
13	2	2	3	1	1	14.449	511
14	2	2	3	1	2	14.711	506
15	2	2	3	1	3	14.825	381
16	3	2	1	3	1	14.231	489
17	3	2	1	3	2	14.135	493
18	3	2	1	3	3	13.905	505
19	1	3	3	3	1	14.209	404
20	1	3	3	3	2	14.264	409
21	1	3	3	3	3	14.313	404
22	2	3	1	2	1	14.252	423
23	2	3	1	2	2	14.300	416
24	2	3	1	2	3	14.254	425
25	3	3	2	1	1	14.279	421
26	3	3	2	1	2	14.299	412
27	3	3	2	1	3	14.268	407

Table 4 Results of random conditions

No.	Input index					Output index	
	Fill time [sec]	Melt temperature [℃]	Mold temperature [℃]	Packing pressure [MPa]	Packing time [sec]	Weight [g]	Max. Injection pressure [MPa]
28	1.2	210	52	37	1.8	14.690	436
29	1.1	211	32	32	2.1	14.911	529
30	0.8	211	52	56	2.4	14.147	542
31	0.9	213	60	49	1.5	14.222	514
32	0.6	214	47	40	1.7	14.441	421
33	0.9	217	44	51	1.7	14.203	510
34	1.1	217	52	46	1.6	14.297	481
35	0.7	218	55	43	1.7	14.304	452
36	0.6	219	46	62	2.8	14.115	503
37	1.4	221	30	44	3.0	14.237	449
38	0.9	222	40	67	3.0	14.109	502
39	1.1	223	52	62	1.5	14.260	487
40	0.6	225	58	62	1.0	14.197	466
41	1.3	225	48	60	1.8	14.232	479
42	1.1	227	39	40	2.8	14.443	410
43	1.4	228	41	59	2.9	14.032	486
44	0.5	232	30	42	2.6	14.310	436
45	1.4	233	42	36	2.0	14.431	371
46	0.8	234	38	59	2.6	14.241	449
47	0.8	236	34	65	1.6	14.222	447
48	0.5	237	58	30	2.4	14.624	355
49	0.9	238	42	36	2.5	14.358	374
50	0.9	238	30	63	2.0	14.315	425

Adam optimizer는 모멘텀(momentum) 최적화와 RMSprop 최적화를 합친 경사 하강법으로, RMSprop와 같이 식(1)처럼 학습 속도(running rate)의 크기를 조정하기 위해 경사의 제곱 값을 사용하며 식(2)와 같이 경사의 이동평균을 사용하여 모멘텀의 이점을 활용한다. Adam은 적응 학습 속도 방법(adaptive learning rate method)으로 매개 변수에 대한 개별 학습 속도를 계산하며 식(2)~(4)에 묘사되어 있다. v_t는 RMSprop 항에 대한 표현이며 m_t는 모멘텀 항에 대한 표현이고 θ는 네트워크들의 변수(parameter)를 의미한다. η, β_1, β_2, ϵ는 Adam optimizer를 나타내는 변수들로 일반적으로 각각 0.001, 0.9, 0.999, 10^{-8}을 최적의 기본 값으로 사용한다.

$$v_t = \beta_2 v_{t-1} + (1-\beta_2)(\nabla_\theta J(\theta))^2 \quad (2)$$

$$m_t = \beta_1 m_{t-1} + (1-\beta_1)\nabla_\theta J(\theta) \quad (3)$$

$$\theta = \theta - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}}\hat{m}_t,\ \hat{m}_t = \frac{m_t}{1-\beta_1^t},\ \hat{v}_t = \frac{v_t}{1-\beta_2^t} \quad (4)$$

Table 3에는 L27의 실험계획 조건에 대한 결과를 나타내었으며 Table 4에는 요인의 경계 수준 내에서 임의로 생성한 조건에 대한 사출성형 결과를 나타내었다. 결과에서 총 50개의 데이터 중에 L27 데이터를 포함한 42개를 학습 데이터로 사용하였으며 나머지 임의의 데이터 중 4개는 검증 데이터, 4개는 실험 데이터로 ANN 모델 검증에 사용하였다.

Table 4의 데이터에서 검증 데이터는 No. 35, 41, 48, 50, 실험 데이터는 No. 33, 38, 43, 47을 사용하였다. 데이터들은 정규화(normalized)를 진행하여 입력 데이터의 종류에 상관없이 0에서 1 사이의 값을 학습하도록 하여 정확한 예측 데이터를 얻을 수 있도록 하였고 검증 데이터의 정확도가 97% 이상일 때까지 학습을 진행하도록 설정하였다.

3. 결과

Figure 5는 ANN 모델에 대한 손실함수(cost function) 그래프이다. 손실함수의 경우, 학습 횟수가 20회 이상부터는 $1.95\times10^{-4}\pm7.89\times10^{-5}$으로 거

의 변동 없이 적절한 수렴성을 보이는 것을 확인할 수 있다.

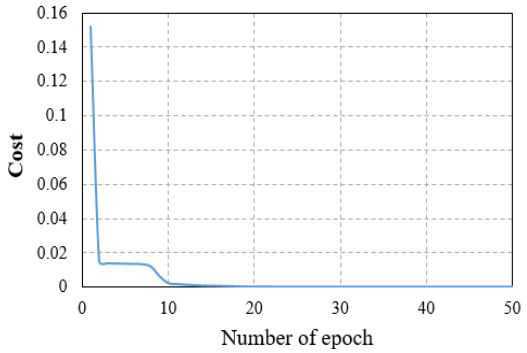

Fig. 5 Cost function graph for ANN

검증 데이터에 대해 ANN 모델에서 예측한 데이터와 실제 데이터 사이의 정확도 결과를 보면, 학습 반복 기준인 97%의 정확도에 도달하기까지 총 1,259회의 학습 횟수가 소요되었으며 최종적으로는 97.13%의 정확도를 나타내었다.

이와 같은 결과를 바탕으로, 본 연구에서 학습한 ANN 모델이 적절한 수렴성을 보이며 97% 이상의 기준 이상의 정확성을 보이는 것을 확인하였다. 따라서, 본 ANN 예측 모델을 이용하여 실험 데이터에 대한 무게와 최대 사출압력을 예측하여 실제 데이터와의 비교를 Table 5에 나타내었다.

Table 5 Comparison predictive data with experiment data for experiment data set No. 33, 38, 43, 47

No.	Weight [g]			Max. Injection pressure [MPa]		
	ANN	Exp.	%Error	ANN	Exp.	%Error
33	14.151	14.203	0.37	511	510	0.20
38	14.007	14.109	0.72	504	502	0.40
43	14.130	14.032	0.70	477	486	1.85
47	14.198	14.222	0.17	461	447	3.13

무게의 경우, ANN 모델로 예측한 무게가 실제 사출성형으로 생산한 제품의 무게와 일치하지는 않았으나 $0.49 \pm 0.23\%$의 오차를 가지며 실제 무게와 거의 유사하게 예측한 것을 확인하였다. 마찬가지로 최대 사출압력의 경우도 ANN 모델로 예측한 데이터가 실제 사출성형 시의 최대 사출압력과 비교하였을 때, 무게 예측의 오차보다는 크지만 전체적인 오차는 $1.40 \pm 1.19\%$로 매우 작은 값을 나타내었다.

4. 결론

본 연구에서는 4개의 캐비티로 구성된 컵 금형을 이용하여 27개의 5인자 3수준의 실험계획법 데이터와 인자의 경계 수준 내에서 임의로 생선한 23개의 성형 조건 데이터를 바탕으로 사출성형을 진행하고 제품의 무게를 측정하였다. 50개의 데이터 중 실험계획법의 27개 데이터를 포함한 42개의 데이터는 ANN의 학습 데이터로 사용하여 예측 모델을 학습하였으며 나머지 4개 데이터는 예측 모델에 대한 검증 데이터, 나머지 4개의 데이터는 실험 데이터로 사용하여 ANN 예측 모델을 구축하고 평가하여 실제 실험 데이터와 비교하고 다음과 같은 결론을 얻었다.

1) 사출시간, 용융온도, 금형온도, 보압, 보압시간을 입력 데이터로 하고 5개의 신경망과 신경망 당 10개의 뉴런, 그리고 무게와 최대 사출압력을 출력 데이터로 하고 활성화 함수를 ReLU, 최적화 도구를 Adam Optimizer, Learning rate를 0.007로 설정하였을 때 Cost function은 학습 횟수가 20회일 때부터 $1.95 \times 10^{-4} \pm 7.89 \times 10^{-5}$의 매우 작은 값에서 수렴하였으며, 본 연구의 ANN 예측 모델이 적절한 수렴성을 가지는 것을 확인하였다.

2) 반복 학습의 기준을 검증 데이터의 예측 값과 실험 값 사이의 차이에 대한 정확성으로 정하였으며 97% 이상으로 설정하고 ANN을 학습시킨 결과, 학습 횟수가 1259회일 때 기준 정확성인 97%를 넘어서 97.13%의 정확성을 나타내는 것을 확인하였다.

3) 학습한 ANN 예측 모델을 사용하여 실험 데이터에 대한 무게를 예측한 결과, 실험 값과 $0.49 \pm 0.23\%$의 오차를 가지며 매우 정확하게 예측하는 것을 확인하였다. 마찬가지로 최대 사출압력에 대한 예측 결과도 무게 예측 결과보다 오차가 큰 값을 나타내었지만, $1.40 \pm 1.19\%$의 오차를 나타내며 실제 값을 정확하게 예측한 것을 확인하였다.

따라서 본 연구결과를 활용하여 사출성형공정에 기계학습과 딥 러닝을 적용한 ANN 기법을 도입하면 무게나 사출압력과 같이 제품의 품질과 관련된 데이터를 보다 효율적으로 예측할 수 있으며, 더 나아가 최적의 품질을 가지는 성형조건을 예측하는 경우에도 효과적인 역할을 할 것으로 판단된다.

후기

본 연구는 산업통산자원부의 기계산업핵심기술개발사업(Project No. KM190170, 10067766)의 지원으로 진행되었습니다.

참고문헌

1) Meiabadi, M. S., Vafaeesefat, A., and Sharifi, F., “Optimization of Plastic Injection Molding Process by Combination of Artificial Neural Network and Genetic Algorithm”, J. Optim. Ind. Eng., Vol. 13, pp. 49-54, 2013.
2) Changuy, S., Lixia, W., and Qian, L., “Optimization of injection molding process parameters using combination of artificial neural network and genetic algorithm method”, J. Mater. Process. Technol., Vol. 183, pp. 412-418, 2007.
3) Chen, W. C., and Kurniawan, D., “Process Parameters Optimization for Multiple Quality Characteristics in Plastic Injection Molding using Taguchi Method”, BPNN, GA, and Hybrid PSO-GA”, nt. J. Precis. Eng. Manuf., Vol. 15, pp. 1583-1593, 2014.
4) Li, K., Yan, S., Zhong, Y., Pan, W., and Zhao, G., “Multi-Objective Optimization of the Fiber-reinforced Composite Injection Molding Process using Taguchi method”, RSM, and NSGA-II”, Simul. Modell. Pract. Theory, Vol. 91, pp. 69-82, 2019.