

인공신경망을 활용한 최적 사출성형조건 예측에 관한 연구

양동철^{1,2} · 이준한^{1,2} · 윤경환³ · 김종선^{4,#}

A Study on the Prediction of Optimized Injection Molding Condition using Artificial Neural Network (ANN)

D. C. Yang, J. H. Lee, K. H. Yoon, J. S. Kim

(Received June 17, 2020 / Revised July 21, 2020 / Accepted July 22, 2020)

Abstract

The prediction of final mass and optimized process conditions of injection molded products using Artificial Neural Network (ANN) were demonstrated. The ANN was modeled with 10 input parameters and one output parameter (mass). The input parameters, i.e.; melt temperature, mold temperature, injection speed, packing pressure, packing time, cooling time, back pressure, plastification speed, V/P switchover, and suck back were selected. To generate training data for the ANN model, 77 experiments based on the combination of orthogonal sampling and random sampling were performed. The collected training data were normalized to eliminate scale differences between factors to improve the prediction performance of the ANN model. Grid search and random search method were used to find the optimized hyper-parameter of the ANN model. After the training of ANN model, optimized process conditions that satisfied the target mass of 41.14 g were predicted. The predicted process conditions were verified through actual injection molding experiments. Through the verification, it was found that the average deviation in the optimized conditions was 0.15 ± 0.07 g. This value confirms that our proposed procedure can successfully predict the optimized process conditions for the target mass of injection molded products.

Key Words: Injection Molding, Artificial Neural Network, Optimization, Process Condition, Mass

1. 서론

플라스틱은 우수한 생산성, 경량성, 단열성 등의 다양한 장점이 있어 수십 년간 다양한 분야에서 사용되고 있으며 최근에는 자동차 산업이나 전자 산업 등에서 금속을 대체하기 위한 재료로 평가되고 있다. 플라스틱은 일반적으로 높은 온도로 가열하여 용융 상태로 변환하는 과정을 거친 다음 원하는 형상으로 가공되며, 성형 제품의 형태나 플라스틱의

종류에 따라 압출 공정, 사출공정 등의 가공방법을 적용한다. 플라스틱을 가공하는 다양한 방법 중에서 사출성형공정은 플라스틱을 용융점 이상의 온도로 가열하여 흐름성이 높은 상태로 변환하고, 제품 형상이 가공된 금형 내에 높은 압력으로 주입하는 공정으로, 타 공정과 비교하여 성형 가능한 제품 형상에 제약이 적고 높은 생산속도를 구현할 수 있다. 또한 사출성형은 공정 내에서 제품의 형상을 대부분 구현할 수 있으므로 성형 후에 추가적인 가공이 적은 편이다. 이러한 장점들로 인해 생활용품부터 가전제품이나 자동차 부품에 이르기까지 다양한 산업과 제품군에서 사출성형공정을 사용하여 제품들을 생산하고 있다[1]. 제조 분야에서 성형하는 제품

1. 한국생산기술연구원 형상제조연구부, 학연협동과정

2. 단국대학교 기계공학과, 대학원생

3. 단국대학교 기계공학과, 교수

4. 한국생산기술연구원 형상제조연구부, 수석연구원

Corresponding Author : Principal researcher, Korea Institute of Industrial Technology, E-mail : libra74@kitech.re.kr

ORCID:https://orcid.org/0000-0003-3445-8717

의 형태와 크기, 기능들이 다양하고 사용하는 수지의 종류도 가지각색이기 때문에 원하는 품질의 제품을 성형하기 위해서는 적절한 성형조건을 탐색하여 적용해야 한다[2]. 사출성형공정에서 제품의 품질과 관련된 대표적인 성형조건으로는 용융 수지의 온도, 금형 온도, 사출속도, 보압 등이 있으며 이외에도 계량조건, 가소화 조건 등 제품 성형을 위해 다양한 조건들을 결정해야 한다[3]. 실제 산업 현장에서 이러한 성형조건들은 가이드북이나 경험에 의한 시행착오(trial-and-error) 방식으로 결정된다[4]. 그러나 시행 착오 방법은 최적의 성형조건을 찾을 때까지 시간과 비용이 많이 소요되며 작업자의 숙련도와 경험에 따라 성형조건과 제품 품질의 편차가 발생한다.

CAE(computer aided engineering)의 발전과 함께 사출성형공정에 대한 유동해석, 열해석 등의 시뮬레이션 기술이 도입되었고, 이를 기반으로 한 공정설계는 성형품의 품질 개선과 생산 비용의 감소 효과를 가져왔다. 그러나 시뮬레이션 결과의 분석과 해석은 여전히 작업자의 경험이 중요한 요소로 작용하며 원하는 결과 도출에 상당한 계산 시간이 요구된다[5]. 그리고 CAE를 통한 공정 설계는 시행 착오 방식보다는 정확한 예측과 분석이 가능하지만, 사출성형 인자들이 비선형적인 관계들로 연결되어 있으므로 실제 생산 결과와 비교하여 정확한 성형공정과 최종 질량이나 힘 등 품질과의 관계를 예측하기에는 무리가 있다[6]. 따라서 이러한 문제점들을 해결하기 위해 사출성형공정을 모델링하고 최적화하는 새로운 방법에 관한 연구가 필요하다.

본 논문에서는 ANN(artificial neural network)를 적용하여 최적의 사출성형공정을 도출하였다. 최근에, ANN 기술은 매우 복잡한 형태의 비선형 시스템을 해석하고 분석하는 분야에 있어 매우 유용하고 효과적인 방법으로 평가받고 있다. 따라서 ANN 기술은 비선형적 관계들로 구성된 사출성형공정 모델에 적합한 최적화 기술로 고려되고 있으며, ANN 기술을 사출성형공정에 적용하는 연구들이 많이 진행되고 있다. 2004년 Liao 등[7]은 휴대전화 외장재의 수축률과 힘을 개선시키기 위해 인공신경망을 접목해, 4개의 성형조건을 최적화시키는 연구를 수행하였다. 2007년 Shen 등[8]은 냉장고의 외장재 제품의 수축률을 개선하기 위해 5개의 사출성형인자를 최적화

시키는 연구를 진행하였다. 그 외에도, 2011년 Yin 등[9]에 의해 자동차 내장재 제품의 굽힘을 개선하기 위해 5개의 성형조건을 최적화시키는 연구가 진행되었고, 2015년 Zhao 등[10]이 모니터 외장재 제품의 굽힘, 수축률 그리고 싱크마크(sink mark)를 개선하기 위해 6개의 성형조건을, 2019년 Beningh 등[11]이 렌즈 제품의 광학 물성을 개선하기 위해 7개의 성형조건을 최적화시키는 연구가 진행되었다.

기존의 연구들에서는 제한된 개수의 성형 인자만을 고려하여 최적 성형조건을 도출하였다. 따라서 본 연구에서는 사출성형품의 품질에 영향을 끼치는 정도가 낮은 성형 인자일지라도 추가하였을 시, 인공신경망 모델의 예측정확도와 신뢰성을 평가하였다. 기존 연구들에서 공통적으로 고려되었던 성형조건들 이외에 추가적으로 공정에 영향을 주는 조건을 포함하여 총 10개의 성형조건을 선정하고 조건에 따른 성형품의 질량을 ANN 모델로 학습하였다. 학습 이후 원하는 제품 질량에 대한 성형조건을 도출하고 실험을 통해 사출성형공정에 대한 ANN 예측 모델의 적합성을 평가하였다.

2. 실험

본 연구에서는 사출성형공정에서 성형품의 품질에 영향을 미치는 성형 인자들과 성형된 제품의 질량 사이의 관계를 학습하기 위해 Fig. 1의 4-캐비티를 가지는 3단 금형을 사용하였으며, 최종 성형 제품은 Fig. 2에 제시된 컵(cup) 형상으로 컵의 상하부 지름은 각각 54.2 mm와 34.6 mm이며 높이는 63.0mm이다.




Fig. 1 4-cavity-mold for injection-molded cup

제품 성형을 위해서 250톤 사출성형기 Roboshot-

α 250iA(FAUNAC, Japan)을 사용하였으며 폴리프로필렌(Polypropylene) 계열의 수지인 HOPELEN J-150(Lotte chemical, Korea)을 적용하였다. Table 1과 Table 2에는 각각 사출성형기의 사양과 사용 수지의 물성을 나타내었다.

3. 학습방법

사출성형공정에서 성형조건과 사출성형품의 품질 사이 관계는 복잡한 비선형적 양상을 나타내며, 일반적인 수치해석이나 다구찌 방법과 같은 최적화 기법으로는 정확한 관계 도출이 어렵다. 따라서 사출성형조건과 성형품 질량 사이의 비선형적인 관계를 학습하기 위해 ANN 기법을 사용하였다.



Fig. 2 Injection-molded cup product

Table 1 Specification of injection molding machine

Properties	Value	Unit
Screw diameter	32	mm
Max. injection acceleration	5.02	G
Max. injection speed	1,200	mm/s
Max. injection pressure	3,800	kgf/cm ²
Max. clamping force	250	ton

Table 2 Properties of resin (HOPELEN J-150) measured by VM-Tech, Korea

Properties	Value	Unit
Melt Flow Index	10	g/10min
Density	0.89	g/cm ³
Transition temperature	121	°C
Processing temperature	210~240	°C
Mold mold temperature	40~60	°C

3.1 인공신경망(Artificial Neural Network)

ANN 기술은 복잡하고 비선형적인 관계에서 발생하는 문제들을 정의하고 해결하려는 방법으로 널리 사용되고 있다. ANN 기술은 제어공학, 로봇공학, 패턴 인지 및 예측, 생산, 최적화 등 다양한 산업 분야에서 원인과 결과에 대한 관계를 분석하기 위해 사용되고 있다. ANN은 사람의 뇌가 문제를 해결하는 방식을 모방한 시스템으로, 뉴런(neuron)이라는 처리 유닛들이 레이어에 배치되어 상호 간에 고도로 연결된 계산 구조로 Fig. 3에 나타내었다.

뉴런에서는 연결된 입력값에 가중치와 편향(bias)을 적용하여 합산하고 선형, 혹은 비선형의 활성화 함수를 통해 결과에 반영하는 과정을 수행한다. 식 (1)에는 하나의 뉴런이 전 레이어의 입력값(x_i)을 받아 가중치와 편향이 더해져 다음 레이어의 출력값(net_j)을 계산하는 과정을 나타내었다.

$$net_j = \sum_{i=1}^n (x_i w_{ij} + b) \quad (1)$$

x_i 는 전 레이어의 i 번째 뉴런의 출력값으로써 j 번째 뉴런에서의 입력값이고, b 는 편향, w_{ij} 는 i 번째 뉴런과 j 번째 뉴런 사이의 가중치, n 의 경우는 뉴런이 첫 번째 은닉층 레이어에 있을 때는 입력인자의 개수, 그 외의 경우에는 이전 레이어의 뉴런의 개수이고, 마지막으로 net_j 는 j 번째 뉴런의 출력값이다. 식(1)에서 합산된 결과 net_j 는 활성화 함수를 통하여 다음 레이어의 뉴런에 입력값으로 적용되고, ANN 시스템은 해당 과정을 반복하여 초기 입력 파라미터에 대한 최종 출력 결과를 산출한다.




Fig. 3 Structure of ANN

3.2 오차역전파법 (Back Propagation)

역전과 알고리즘 학습은 인공지능과 관련된 많은 연구분야에서 사용되는 대표적인 ANN 학습 방법이다. 역전과 알고리즘은 피드 포워드(feed forward) 네트워크 구조를 가지며 각각의 레이어의 출력이 다음 레이어의 각 뉴런으로 직접 전달되는 방식으로 최종적으로 얻은 출력 값은 신경망에 입력한 값에 대한 실제 값과 비교하여 편차를 구한다. 해당 편차를 오류로 규정하고 출력 뉴런의 변화를 계산하여 역으로 전파하고 이전 뉴런들의 변화를 계산한다. 역전과 알고리즘은 이와 같은 과정을 차례로 반복하고 신경망의 가중치를 조정하여 데이터들 사이의 관계를 점진적으로 학습한다[12].

역전과 알고리즘에서 입력 데이터의 실제 결과 값과 ANN을 통한 예측 결과 값을 비교하기 위해 학습 데이터 그룹과 별도로 검증 데이터 그룹을 구분하여 적용한다. 검증 데이터 그룹은 ANN의 성능을 모니터링 하는데 사용되며 일반적으로 실제 값과 예측값의 평균 제곱근 오차(root mean square error, RMSE)가 최소값에 도달하는지를 평가한다.

4. 데이터 생성

본 논문에서는 사출성형품의 품질에 영향을 미치는 대표적인 성형조건인 용융 수지의 온도, 금형 온도, 사출속도, 보압 크기, 보압 시간 이외에 5가지 성형조건을 추가하여 ANN의 입력 파라미터로 사용하였다. 사출성형공정을 사출 단계, 보압 단계, 냉각 단계, 계량 단계로 구분하고 각 단계에서 중요한 공정 조건들을 선별하여 Table 3과 같이 총 10개의 중요 인자를 결정하였다. 그리고 선정된 10개의 사출성형 인자에 대해 수지의 물성과 권장 성형조건, 금형과 제품의 형태, 그리고 사출성형기의 사양 등을 고려하여 허용 가능한 최소 값과 최대값을 결정하였다. 그리고 Table 4와 같이 최소 최대값을 기준으로 10인자 3수준으로 사출성형 인자들을 구분하고 직교배열법을 사용하여 27개의 성형조건을 생성하였다.

추가적으로, 직교배열법을 사용한 실험계획의 격자점 이외의 데이터도 학습하기 위해 성형 인자의 경계값 내에서 임의로 선택된 50개의 성형조건을 추가하였다. 최종적으로 77개의 조건 데이터를 생성하였으며 해당 데이터들을 Table 5에 나타내었다.

Table 5의 1번부터 67번까지의 데이터는 학습 데이터로 사용하였으며 68번부터 72번까지는 검증 데이터, 73번부터 77번까지는 시험 데이터로 사용하였다. 그리고 실험 간에 편차를 고려하여 조건당 4개의 컵의 질량을 5번 측정하고, 평균값을 구하여 정리하였다.

Table 3 Input parameter for ANN model

Stage	Value	Unit
Injection	Melt temperature	°C
	Mold temperature	°C
	Injection speed	mm/s
	V/P switchover (pressure control)	bar
Packing	Packing pressure	bar
	Packing time	sec
Cooling	Cooling temperature	°C
Plasticification	Back pressure	bar
	Plasticification speed	rpm
	Suck back	mm

Table 4 Factors and levels for L27 orthogonal array

Value	Level			Unit
	1	2	3	
Melt temperature	200	220	240	°C
Mold temperature	40	50	60	°C
Injection speed	30	75	120	mm/s
V/P switchover (pressure control)	900	1000	1,100	bar
Packing pressure	700	900	1,100	bar
Packing time	1	3	5	sec
Cooling time	20	30	40	sec
Back pressure	40	60	80	bar
Plasticification speed	80	115	150	rpm
Suck back	2	3	4	mm

Table 5 Experiment result for data collecting(continued)

Data No.	Melt temperature (°C)	Mold temperature (°C)	Injection speed (mm/s)	V/P switchover (bar)	Packing pressure (bar)	Packing time (sec)	Cooling time (sec)	Back pressure (bar)	Plastification speed (rpm)	Suck back (mm)	Mass (g)
1	200	40	30	900	700	1	20	40	80	2	39.98
2	200	40	30	1000	700	3	30	60	115	3	41.47
3	200	40	30	1100	700	5	40	80	150	4	41.66
4	220	60	30	1000	900	1	20	40	115	3	40.56
5	220	60	30	1100	900	3	30	60	150	4	41.78
6	220	60	30	900	900	5	40	80	80	2	42.12
7	240	80	30	1100	1100	1	20	40	150	4	40.25
8	240	80	30	900	1100	3	30	60	80	2	41.66
9	240	80	30	1000	1100	5	40	80	115	3	42.33
10	200	60	75	1000	1100	1	30	80	80	4	40.31
11	200	60	75	1100	1100	3	40	40	115	2	41.86
12	200	60	75	900	1100	5	20	60	150	3	42.18
13	220	80	75	1100	700	1	30	80	115	2	39.28
14	220	80	75	900	700	3	40	40	150	3	40.44
15	220	80	75	1000	700	5	20	60	80	4	40.98
16	240	40	75	900	900	1	30	80	150	3	40.02
17	240	40	75	1000	900	3	40	40	80	4	41.53
18	240	40	75	1100	900	5	20	60	115	2	41.94
19	200	80	120	1100	900	1	40	60	80	3	39.25
20	200	80	120	900	900	3	20	80	115	4	40.7
21	200	80	120	1000	900	5	30	40	150	2	41.4
22	220	40	120	900	1100	1	40	60	115	4	40.24
23	220	40	120	1000	1100	3	20	80	150	2	41.83
24	220	40	120	1100	1100	5	30	40	80	3	42.3
25	240	60	120	1000	700	1	40	60	150	2	38.95
26	240	60	120	1100	700	3	20	80	80	3	40.48
27	240	60	120	900	700	5	30	40	115	4	41.19
28	212	74	66	1001	1008	3.9	23	75	98	2	41.65
29	217	44	32	950	758	2.5	37	52	105	3	41.57
30	229	57	109	1046	881	3.8	30	77	127	3	41.57
31	225	59	53	911	746	1.9	25	51	100	2	40.56
32	218	54	71	1091	1027	3	30	50	86	3	41.89
33	223	44	120	1053	951	3.8	25	73	145	4	41.96
34	213	72	52	1038	948	2.8	32	69	146	2	41.37
35	218	80	95	903	849	1.8	31	66	104	2	40.11
36	201	78	58	988	756	4	36	49	112	3	41.15
37	203	44	84	1033	939	4.6	35	77	148	3	41.93
38	211	59	116	978	1050	2.4	39	75	148	3	41.20
39	234	68	55	1038	1097	2.4	34	61	129	3	41.46
40	234	46	91	948	717	2.1	27	78	121	4	40.49
41	225	57	94	1078	892	1.5	22	72	139	3	40.43
42	201	43	40	928	922	3.2	38	73	103	4	41.81
43	218	60	80	1093	1000	1.1	25	45	147	4	40.32
44	203	52	85	1084	806	4.9	23	79	97	3	41.52
45	204	63	53	1033	804	1.5	30	75	120	3	40.25
46	209	73	75	916	834	3.5	36	70	141	3	41.05
47	228	55	103	942	915	4.9	30	69	105	3	41.97
48	234	59	115	1077	815	3.3	20	77	128	3	41.1
49	210	63	109	962	852	3.3	28	44	85	2	41.00
50	224	58	102	1011	946	3.9	28	61	119	3	41.79
51	206	65	51	1031	948	2.4	30	51	104	3	41.22
52	218	73	97	982	755	4.9	25	73	117	4	41.36
53	202	64	92	1084	804	4.3	23	71	90	3	41.23
54	205	76	52	905	862	4.1	39	75	84	3	41.53
55	208	57	87	1006	768	5	39	72	112	4	41.40
56	213	62	97	914	945	4	40	60	143	4	41.71
57	225	71	91	1083	1035	2.3	21	48	145	3	41.05
58	224	58	112	977	838	4.6	35	61	97	4	41.76

Table 5 Experiment result for data collecting(continued)

Data No.	Melt temperature (°C)	Mold temperature (°C)	Injection speed (mm/s)	V/P switchover (bar)	Packing pressure (bar)	Packing time (sec)	Cooling time (sec)	Back pressure (bar)	Plastification speed (rpm)	Suck back (mm)	Mass (g)
59	213	47	53	1077	902	1.5	31	41	117	2	40.81
60	216	48	102	901	1015	3.8	35	69	110	4	42.05
61	237	60	30	997	1072	1.3	29	64	132	3	41.04
62	239	43	114	1088	905	1.6	24	50	131	3	40.57
63	209	78	82	962	875	4.3	21	68	100	3	41.25
64	213	71	39	908	854	1.4	29	51	132	4	40.52
65	215	48	116	971	850	1.1	25	49	86	3	39.73
66	212	71	113	1056	982	4.8	27	78	123	2	41.80
67	233	55	63	1083	704	3.5	34	63	131	3	41.26
68	219	70	100	1026	716	1.3	39	78	88	2	39.58
69	223	63	111	1090	947	1.8	31	67	105	3	40.61
70	240	73	49	960	986	2.1	27	56	139	4	40.98
71	236	78	42	1067	807	4.7	33	50	128	3	41.58
72	227	73	116	924	1048	2.5	22	48	146	4	41.10
73	237	45	79	1059	1085	4.2	27	79	127	2	42.47
74	238	49	92	927	920	3.8	25	74	96	4	41.92
75	202	57	67	1002	847	4.6	29	45	134	2	41.59
76	216	78	47	994	941	1.3	24	72	114	4	40.31
77	235	40	32	1017	947	3.1	25	55	138	3	42.16

5. 인공신경망 학습

5.1 데이터 정규화

용융 수지의 온도, 금형 온도, 사출속도 등 ANN 모델의 기계학습에 적용하기 위한 입력 데이터와 결과 데이터는 각각의 값의 크기와 변화의 정도가 다르므로 식(2)를 적용하여 모두 동일한 크기와 범위의 수준을 가지도록 정규화를 진행하였다.

$$M = \frac{C - (C_{min} - w_n \times D)}{\{(C_{max} + w_n \times D) - (C_{min} - w_n \times D)\}} \quad (2)$$

M은 정규화된 데이터, C는 원래의 데이터, C_{min} 과 C_{max} 는 각각 데이터 경계 내에서 가장 작은 값과 높은 값, D는 C_{min} 과 C_{max} 의 차이 값 그리고 w_n 은 정규화 범위를 제한하기 위한 인자이다.

ANN 기술에서 데이터 그룹의 각 파라미터가 가지는 값의 크기와 변화의 폭이 서로 다를 경우, 오차가 최소로 수렴하는 속도가 느려지고 구축된 모델의 예측 성능이 저하된다[13]. 따라서 동일한 수준의 크기와 범위로 정규화하는 과정이 필요하다. 일반적으로 0 부터 1 사이의 범위로 정규화하지만, 인공신경망 관련 연구들에서 0.1 부터 0.9, 혹은 0.2 부터 0.8 사이의 값으로 정규화할 경우보다 높은 예측성과 신뢰성을 나타내는 결과를 보였다[14]. 본 연구에서는, 정규화 범위를 0.2 부터 0.8 사이의 값

으로 맞추도록 w_n 값을 탐색하였으며, 최종적으로 0.35로 선정하고 입력데이터와 출력데이터를 0.206 부터 0.794 사이의 값으로 정규화하였다.

5.2 하이퍼 파라미터 최적화

하이퍼 파라미터(hyper-parameter)란, ANN 모델을 구성하는 데 있어서 사용자가 직접 설정해주어야 하는 값들을 말한다. 대표적인 하이퍼 파라미터에는 기본적으로 연산 처리를 위한 뉴런의 수, 각 뉴런이 배치될 은닉층의 수가 있으며, 이외에도 입력값을 출력값으로 변환하는 활성화 함수(activation function), 인공신경망 학습을 효율적으로 진행시키는 최적화 도구(optimizer), 가중치의 초기값을 설정해주는 초기화 도구(initializer), 인공신경망 학습 시, 가중치 변화의 정도를 뜻하는 학습 속도(learning rate), 인공신경망의 과학습을 억제하기 위한 드롭아웃(dropout) 등이 있다[15]. 하이퍼 파라미터 설정값에 따라 ANN의 구조가 달라지며 결과적으로 예측 모델의 성능에 큰 영향을 주기 때문에 데이터 셋에 대한 ANN의 하이퍼 파라미터를 최적화하는 과정이 필요하다[16].

본 연구에서는 활성화 함수, 최적화 도구, 초기화 도구의 최적화에는 격자 탐색(grid search)을 적용하였다. 격자 탐색법은 해당 인자에 해당하는 도구들의 후보를 설정하고 가능한 모든 조합을 평가하는 방법으로 Table 6에 해당 변수들을 최적화하기 위한 도구들의 후보군을 나열하였다.

후보군 간의 평가에는 레이어 수 1개, 뉴런 수 30개, 학습 속도 0.01, 반복 횟수 500회로 설정하고 드롭아웃이 없이 고정된 모델을 사용하였다. Table 6의 격자 탐색법을 적용한 고정 모델에 대해 각각 67개의 학습 데이터 그룹을 학습하고 5개의 검증 데이터 그룹을 이용하여 최적화 여부를 검증하였다. 검증 데이터 그룹을 사용한 ANN 모델의 예측값과 실제 값 사이의 평균 제곱근 오차(root mean square error, RMSE)를 식 (3)과 같이 구하고 최소 오차가 발생하는 경우를 분석하였다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2} \quad (3)$$

여기서, N은 전체 샘플의 개수 그리고 y_i 와 t_i 는 각각 예측값과 실제값이다. 격자 탐색법을 이용한 총 48개의 후보군 조합 중 RSME가 최소인 5개의 모델을 Table 7에 나타내었다.

최적화 결과, 활성화 함수는 ELU, 최적화 도구는 Adams, 초기화 도구는 He normal의 구조를 가진 ANN 모델이 0.03707의 가장 작은 RMSE 결과를

Table 6 Tools of grid search method

Level	Activation function	Optimizer	Initializer
1	ReLU	Adams	Random normal
2	Sigmoid	Rmsprop	He normal
3	Tanh	SGD	Glorot normal
4	ELU	Adagrad	-

Table 7 RMSE results of grid search method

Model No.	Activation function	Optimizer	Initializer	RMSE
1	ELU	Adams	He normal	0.0307
2	ELU	Adams	Glorot normal	0.0353
3	ELU	Adagrad	He normal	0.0367
4	Sigmoid	Adams	Random normal	0.0392
5	Tanh	Adams	Random normal	0.0393

나타내었으며 이를 최적화된 하이퍼 파라미터로 선정하였다. 격자 탐색법을 이용하여 최적화한 파라미터들을 고정 도구로 설정하고 나머지 파라미터인 레이어 수, 뉴런 수, 학습 속도, 드롭아웃에 대한 최적화를 진행하였다. 해당 파라미터들은 수치적으로 구간을 나눌 수 있으므로 임의 탐색(random search) 방법을 적용하여 Table 8과 같이 각 인자의 최소, 최대 값을 지정하고 일정한 간격으로 수준을 구분하였다. 그리고 임의로 각 수준의 값들을 선택하여 총 5,000 개의 후보 조합을 추출하고 67개의 학습 데이터 그룹으로 학습을 진행하였다.

격자 탐색법과 마찬가지로 5개의 검증 데이터 그룹을 이용하여 학습된 후보군의 예측값과 실제 값 사이의 RSME 값을 구하고 최소 오차가 발생하는 경우를 분석하였다. 최적화 결과를 살펴보면, Table 9와 같이 학습 속도 0.002, 레이어 수 2개, 뉴런의 수는 1번 레이어가 43개, 2번 레이어가 40개, 드롭아웃은 0.3일 경우에 RSME 값이 최소가 되었으며 최종적으로 최적화된 파라미터 결과를 Table 10에 나타내었다.

Table 8 Levels of random search method

Parameter	Value		
	Minimum	Maximum	Step size
Learning rate	0.001	0.100	0.001
Number of layers	1	5	1
Number of neurons	5	50	1
Dropout	0.0	0.5	0.1

Table 9 Result of random search method

Parameter	Value
Learning rate	0.002
Number of layers	2
Number of neurons	Layer 1 : 43 Layer 2 : 40
Drop out	0.3

Table 10 Optimized hyper-parameters for ANN model

Parameter	Optimized value
Activation function	ELU
Optimizer	Adams
Initializer	He normal
Learning rate	0.002
Number of layers	2
Number of neurons	Layer 1 : 43 Layer 2 : 40
Drop out	0.3

5.3 학습결과

최적화된 ANN 구조를 사용하여 67개의 사출성형 학습 데이터 그룹에 대한 학습을 진행하였다. 학습 횟수(epoch)는 5,000으로 설정하였으며 학습 모델의 정확도는 손실함수 값(Loss)으로 평가하였다. 손실함수는 식 (4)와 같이 정의하여 해당 학습 횟수에서 모델의 예측값과 실제 값 사이의 차이를 평가한다. Fig. 4와 Fig. 5에 학습 횟수에 따른 학습 데이터 그룹과 시험 데이터 그룹의 손실함수 값을 나타내었다.

$$Loss = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (4)$$

여기서, N은 전체 샘플의 개수 그리고 y_i 와 t_i 는 각각 예측값과 실제값이다.

5,000번의 반복 학습 동안, 6번의 학습횟수 만에 시험 데이터 그룹에 대한 손실함수는 0.645로 수렴하였으며, 최종적으로는 손실함수는 0.001로 수렴되었다. 구축된 ANN 모델을 이용하여 시험 데이터 그룹의 질량을 예측한 결과, Table 11과 같이 최대 편차가 0.23 ± 0.02 g 수준의 정확도를 나타내는 것을 확인하였다.

6. 성형조건 예측

본 연구에서는 원하는 질량의 제품을 생산하기 위한 사출성형조건을 예측하기 위해 다수의 성형조건에 대한 질량을 예측하고 목표 질량과 비교하였다. 사출성형 인자들의 경계조건 내에서 조합이

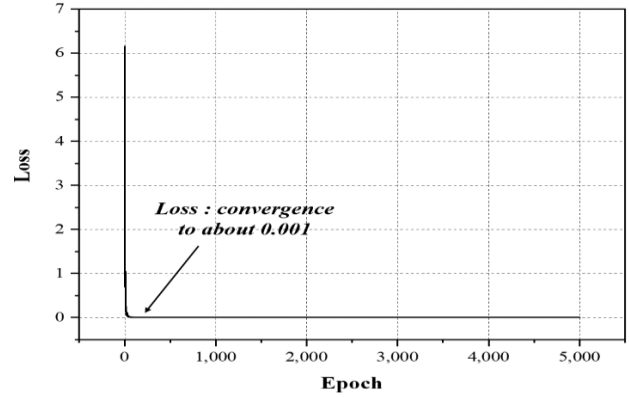


Fig. 4 Loss vs epoch graph(training data group)

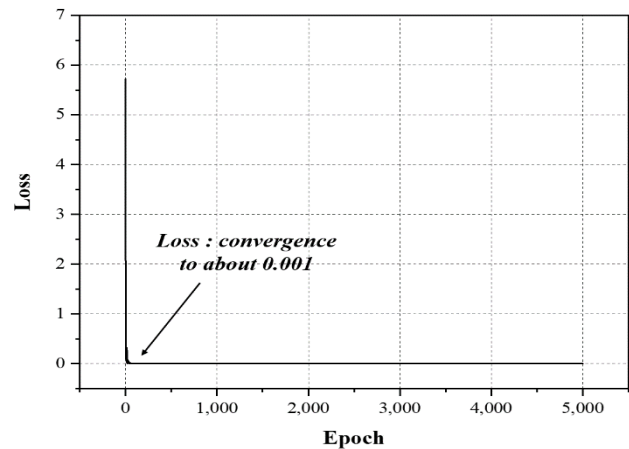


Fig. 5 Loss vs epoch graph(test data group)

Table 11 Validation for optimized ANN structure

Data No.	Experiment mass (g)	Predicted mass by ANN (g)	Deviation (g)
73	42.47 ± 0.02	42.24	0.23 ± 0.02
74	41.92 ± 0.02	41.87	0.05 ± 0.02
75	41.59 ± 0.02	41.67	0.08 ± 0.02
76	40.31 ± 0.01	40.35	0.04 ± 0.01
77	42.16 ± 0.02	42.02	0.14 ± 0.02

가능한 10 만개의 조건 데이터 그룹을 임의로 생성하고 각 조건에 대한 성형품의 질량을 구축된 ANN 모델을 이용하여 예측하였다. 10만 개의 사출성형조건을 선정할 시, 실제 사출성형기에서 제어 가능한 수준을 고려하여 Table 12의 수준으로 각 성형조건 인자들을 구분하여 선택하였다.

학습된 ANN 모델을 이용한 질량 예측의 경우, 10만개의 질량 결과를 도출하는데 총 0.89초가 소요되었으며 이는 ANN 기술의 장점 중 하나인 빠른 연산 처리 속도를 이용한 결과이다. 학습된 ANN 모델을 이용한 성형조건 예측의 정확성을 평가하기 위해 학습 데이터 그룹의 평균 질량인 41.14g을 목표로 설정하였으며 10만 개의 데이터 그룹 중 목표 질량에 근접한 성형조건들을 도출하였다. 도출된 목표 질량에 대한 성형조건들을 적용하여 사출성형을 진행하고 각각 5개 성형품의 질량을 측정하여 Table

13에 나타내었다. ANN 모델이 목표 질량인 41.14g에 근접한 질량으로 예측한 사출성형조건 그룹은 총 10개이며, 도출 조건을 이용한 사출성형품의 질량과 목표 질량 사이의 편차는 평균 $0.15 \pm 0.02g$ 으로 나타났다. 하지만 5번 조건과 같이, 목표 질량과의 편차가 $0.33 \pm 0.01g$ 으로 높은 편차 값이 나타났다. 이에 대한 원인은 학습 데이터 조건과 예측 조건을 실험했을 때 기온과 습도와 같은 환경변수의 차이에 의해 수지물성 및 공정 상태가 일정 부분 영향을 받았기 때문으로 판단된다[17].

Table 12 Step size for random injection molding conditions

Conditions	Step size	Unit
Melt temperature	1	℃
Mold temperature	1	℃
Injection speed	0.1	mm/s
V/P switchover (pressure control)	1	bar
Packing pressure	1	bar
Packing time	0.1	sec
Cooling temperature	1	℃
Back pressure	1	bar
Plasticification speed	1	rpm
Suck back	1	mm

7. 결론

본 연구에서는 4개의 캐비티로 구성된 컵 금형을 이용하여 27개의 10인자 3수준의 27개 실험계획법 데이터와 인자의 경계 수준 내에서 임의로 생성한 50 개의 성형 조건 데이터를 바탕으로 사출성형을 진행하고 제품의 질량을 측정하였다. 77개의 데이터 중 실험계획법의 27개 데이터를 포함한 67개의 데이터는 학습 데이터 그룹으로 사용하여 ANN 모델을 학습하였으며 나머지 5개 데이터는 ANN 구조의 하이퍼 파라미터를 최적화하기 위한 검증 데이터 그룹, 나머지 5개의 데이터는 ANN 모델의 신뢰성 평가를 위한 시험 데이터 그룹으로 사용하였다.

학습이 완료된 ANN 모델에 임의로 생성한 10만

Table 13 Predicted injection molding conditions for the target of 41.14 g

No.	Melt temperature (℃)	Mold temperature (℃)	Injection speed (mm/s)	V/P switchover (bar)	Packing pressure (bar)	Packing time (sec)	Cooling time (sec)	Back pressure (bar)	Plasticification speed (rpm)	Suck back (mm)	Mass (g)	Deviation (g)
1	210	57	66	1080	725	3	33	45	106	3	41.19 ± 0.02	0.05 ± 0.02
2	225	41	33.8	994	1030	1	21	62	139	4	41.15 ± 0.01	0.01 ± 0.01
3	217	66	88.3	901	813	3.2	38	69	130	4	41.24 ± 0.02	0.10 ± 0.02
4	237	59	75.7	1005	831	2.9	22	51	111	4	41.18 ± 0.01	0.04 ± 0.01
5	240	48	77.4	1005	780	3.4	34	65	146	2	41.47 ± 0.01	0.33 ± 0.01
6	203	79	44.1	903	962	2.4	22	49	133	2	41.32 ± 0.03	0.18 ± 0.03
7	203	65	38.6	1071	806	2.4	29	61	143	4	41.31 ± 0.02	0.17 ± 0.02
8	216	58	103.4	1041	737	3.8	23	51	134	2	41.28 ± 0.01	0.14 ± 0.01
9	210	71	57.7	979	738	3.7	20	46	146	3	41.33 ± 0.01	0.19 ± 0.01
10	215	55	93.4	956	741	3.3	39	49	83	3	41.25 ± 0.01	0.11 ± 0.01

개의 성형조건 적용하여 성형품의 질량을 예측하고 목표 질량과 근접한 결과를 나타내는 성형조건을 도출하였다. 도출된 성형조건에 대해 사출성형실험을 진행하고 목표 질량과 비교하여 ANN 모델의 정확성과 신뢰성을 평가하고 다음의 결론을 얻었다.

(1) 사출성형조건 중 10개를 선정하여 ANN 모델 구축을 위한 77개의 데이터 그룹을 생성하였다. 해당 데이터 그룹에 대한 최적의 ANN 구조를 결정하기 위해 활성화 함수 등의 하이퍼 파라미터를 최적화하였다.

(2) 최적화된 ANN 구조를 사용하여 67개의 학습 데이터를 학습한 이후, ANN 모델 구축에 사용하지 않은 5개의 시험 데이터 그룹을 이용하여 ANN의 정확도를 평가한 결과, 최대 편차가 0.23 ± 0.02 g 수준의 정확도를 나타내는 것을 확인하였다.

(3) 사출성형조건들의 경계 값 내에서 임의로 조합한 10만 개의 조건 데이터 그룹을 생성하였다. 해당 성형조건들을 학습이 완료된 ANN 모델에 입력하여 질량을 예측하고, 목표 질량인 41.14 g에 근접하게 예측한 성형조건을 도출하였다. 도출된 성형조건에 대해 성형품의 질량을 측정하고 목표 질량과 비교한 결과, 목표 질량과의 편차는 평균 0.15 ± 0.07 g

으로 높은 수준의 정확도와 신뢰성을 가지는 것을 확인하였다.

따라서 사출성형공정에서 다변수 입력에 대해 ANN 기술이 높은 수준의 정확도로 실제 성형품의 질량을 예측하는 것을 확인하였으며, 이를 이용하여 목표 질량에 대한 최적 조건을 도출하는 방법과 시스템에 대해 현장 평가를 진행하여 정확성과 신뢰성을 확인하였다. 향후 ANN 기술을 통해 도출된 목표 질량에 근접한 결과의 성형조건 중에서도 각각의 중요도를 반영하여 제조사의 권장 수치에 가까운 조건을 도출하는 시스템에 관한 연구가 필요하다. 그리고 이러한 연구 결과를 바탕으로 사출성형 전문가가 아닌 일반사용자도 원하는 성형품의 질량을 쉽게 구현할 수 있는 조건을 설정할 수 있으며 사출 성형 공장의 스마트 팩토리화가 가능할 것으로 예상된다.

후 기

본 연구는 기획재정부의 중소·중견기업중견기업 생산기술실용화 및 기술지원사업(Project No. JF200027)

과 산업통상자원부의 기계산업핵심기술개발사업(Project No. KM190170, 10067766)의 지원으로 진행되었습니다.

REFERENCES

- [1] H. Shi, Y. Gao, X. Wang, 2010, Optimization of Injection Molding Process Parameters Using Integrated Artificial Neural Network Model and Expected Improvement Function Method, *Int. J. Adv. Manuf. Technol.*, Vol. 48, No. 9-12, pp. 955-962. <https://doi.org/10.1007/s00170-009-2346-7>.
- [2] P. Zhao, H. Zhou, Y. He, K. Cai, 2014, A Nondestructive Online Method for Monitoring the Injection Molding Process by Collecting and Analyzing Machine Running Data, *Int. J. Adv. Manuf. Technol.*, Vol. 72, No. 08, pp. 765-777. <https://doi.org/10.1007/s00170-014-5711-0>.
- [3] D. Joseph B, 1987, *Injection Molds and Molding: A Practical Manual*, Springer Science & Business Media, Germany, pp. 1-5.
- [4] L. Xuehong, L. S. Khim, 2001, A Statistical Experimental Study of the Injection Molding of Optical Lenses, *J. Mater. Process. Technol.*, Vol. 113, No. 1-3, pp. 189-195. [https://doi.org/10.1016/S0924-0136\(01\)00606-9](https://doi.org/10.1016/S0924-0136(01)00606-9).
- [5] C. E. Castro, M. C. Rios, J. M. Castro, B. Lilly, 2007, Multiple Criteria Optimization with Variability Considerations in Injection Molding, *Polym. Eng. Sci.*, Vol. 47, No. 04, pp. 400-409. <https://doi.org/10.1002/pen.20639>.
- [6] S. Kashyap, D. Datta, 2015, Process Parameter Optimization of Plastic Injection Molding: a Review, *Int. J. Plast. Technol.*, Vol. 19, No. 1, pp. 1-18. <https://doi.org/10.1007/s12588-015-9115-2>.
- [7] S. J. Liao, W. H. Hsieh, J. T. Wang, Y. C. Su, 2004, Shrinkage and Warpage Prediction of Injection Molded Thinwall Parts Using Artificial Neural Networks, *Polym. Eng. Sci.*, Vol. 44, No. 11, pp. 2029-2040. <https://doi.org/10.1002/pen.20206>.
- [8] C. Shen, L. Wang, Q. Li, 2007, Optimization of Injection Molding Process Parameters Using Combination of Artificial Neural Network and Genetic Algorithm Method, *J. Mater. Process. Technol.*, Vol. 183, No. 2, pp. 412-418.

- <https://doi.org/10.1016/j.jmatprotec.2006.10.036>.
- [9] F. Yin, H. Mao, L. Hua, W. Guo, M. Shu, Back Propagation Neural Network Modeling for Warpage Prediction and Optimization of Plastic Products During Injection Molding, *Mater. Des.*, Vol. 39, No. 4, pp. 1844-1850. <https://doi.org/10.1016/j.matdes.2010.12.022>.
- [10] J. Zhao, G. Cheng, S. Ruan, Z. Li, 2015, Multi-objective Optimization Design of Injection Molding Process Parameters Based on the Improved Efficient Global Optimization Algorithm and Non-dominated Sorting-based Genetic Algorithm, *Int. J. Adv. Manuf. Technol.*, Vol. 78, No. 9-12, pp. 1813-1826. <https://doi.org/10.1007/s00170-014-6770-y>.
- [11] R. J. Bensigh, R. Machavaram, S. R. Boopathy, C. Jebaraj, 2019, Injection Molding Process Optimization of a Bi-aspheric Lens Using Hybrid Artificial Neural Networks (ANNs) and Particle Swarm Optimization (PSO), *Meas.*, Vol. 134, pp. 359-374. <https://doi.org/10.1016/measurement.2018.10.066>.
- [12] D. Svozil, V. Kvasnieka, J. Pospichal, 1997, Introduction to Multi-layer Feedforward Neural Networks, *Chemom. Intell. Lab. Syst.*, Vol. 39, No. 1, pp. 43-62. [https://doi.org/10.1016/S01697439\(97\)00061-0](https://doi.org/10.1016/S01697439(97)00061-0).
- [13] R. Leaman, R. I. Doğan, Z. Lu, 2013, Disease Name Normalization with Pairwise Learning to Rank, *Bioinf.*, Vol. 29, No. 22, pp. 2909-2917. <https://doi.org/10.1093/bioinformatics/btt474>.
- [14] R. Adnan, F. A. Ruslan, A. M. Samad, Z. M. Zain, 2013, New Artificial Neural Network and Extended Kalman Filter Hybrid Model of Flood Prediction System, 2013 IEEE 9th Int. Colloq. Signal Process. Appl., pp. 252~257. <https://doi.org/10.1109/CSPA.2013.6530051>.
- [15] P. Balaprakash, M. Salim, T. D. Uram, 2018, Deep Hyper: Asynchronous Hyperparameter Search for Deep Neural Networks, 2018 IEEE 25th Int. Conf. High Perform. Comput., pp. 42-51. <https://doi.org/10.1109/HiPC.2018.00014>.
- [16] C. Thornton, F. Hutter, H. H. Hoos, K. L. Brown, 2013, Auto-WEKA: Combined selection and Hyperparameter Optimization of Classification Algorithms, *Proc. Int. Conf. Knowl. Discovery Data Min.*, pp. 847~855. <https://doi.org/10.1145/2487575.2487629>.
- [17] J. H. Lee, J. J. Kang, K. H. Yoon, J. S. Kim, 2018, A Study on the Change of Optical and Mechanical Properties by Reprocessing for High Melt-Indexed Polycarbonate Used in Injection Molded Optical Parts, *Trans. Mater. Process.*, Vol. 27, No.4, pp. 211-221. <https://doi.org/10.5228/KSTP.2018.27.4.211>.