

다중 작업 학습 구조 기반 공정단계별 공정조건 및 성형품의 품질 특성을 반영한 사출성형품 품질 예측 신경망의 성능 개선에 대한 연구

이효은^{1,2} · 이준한¹ · 김종선^{1,†} · 조구영^{2,†}

한국생산기술연구원 금형성형연구부^{1,†}

단국대학교 기계공학과^{2,†}

A study on the performance improvement of the quality prediction neural network of injection molded products reflecting the process conditions and quality characteristics of molded products by process step based on multi-tasking learning structure

Hyo-Eun Lee^{1,2} · Jun-Han Lee¹ · Jong-Sun Kim^{1,†} · Gu-Young Cho^{2,†}

Department of Molding & Metal Forming R&D, Korea Institute of Industrial Technology^{1,†}

Department of Mechanical Engineering, Dankook University^{2,†}

(Received December 14, 2023 / Revised December 20, 2023 / Accepted December 31, 2023)

Abstract: Injection molding is a process widely used in various industries because of its high production speed and ease of mass production during the plastic manufacturing process, and the product is molded by injecting molten plastic into the mold at high speed and pressure. Since process conditions such as resin and mold temperature mutually affect the process and the quality of the molded product, it is difficult to accurately predict quality through mathematical or statistical methods. Recently, studies to predict the quality of injection molded products by applying artificial neural networks, which are known to be very useful for analyzing nonlinear types of problems, are actively underway. In this study, structural optimization of neural networks was conducted by applying multi-task learning techniques according to the characteristics of the input and output parameters of the artificial neural network. A structure reflecting the characteristics of each process step was applied to the input parameters, and a structure reflecting the quality characteristics of the injection molded part was applied to the output parameters using multi-tasking learning. Building an artificial neural network to predict the three qualities (mass, diameter, height) of injection-molded product under six process conditions (melt temperature, mold temperature, injection speed, packing pressure, pacing time, cooling time) and comparing its performance with the existing neural network, we observed enhancements in prediction accuracy for mass, diameter, and height by approximately 69.38%, 24.87%, and 39.87%, respectively.

Key Words: Artificial neural network, Injection molding, process step, Quality prediction, Multi-task learning

1. 서론

사출성형은 고온에서 용융된 수지를 금형 내에 주입하는 공정이다. 최종 생성물을 형성하기 위해 용융된 수지를 고속과 압력으로 금형 내의 캐비티로

주입한다. 이 과정은 공정의 각 단계에서 유변학, 전산 유체 역학 그리고 열전달 같은 다양한 물리현상의 복잡한 상호 작용을 포함한다. 따라서, 사출성형 공정에서의 공정조건 등과 같이 제품의 품질에 영향을 주는 인자들과 공정 사이의 관계를 구축하고 최적화하는 연구가 활발하게 진행되어 왔다⁴⁾. 최근 몇 년간 4차 산업혁명의 도래로 인공지능(AI) 기술은 데이터 마이닝, 이미지 프로세싱, 엔지니어링 시스템 모델링, 기술 제어 등 다양한 분야에서 적용되

† 교신저자: libra74@kitech.re.kr, guyoungcho@dankook.ac.kr

* 본 논문에 대한 저작권은 저자들에게 있으며 CC BY-NC-SA를 만족하는 조건으로 이용할 수 있습니다.

고 있다. 그 중에서도 인자 간의 복잡한 비선형 관계를 구축하는 데 강력한 성능을 나타내는 인공신경망 (artificial neural network가, ANN)에 대한 산업적 수요가 증가하고 있으며 인공지능 분야에서 가장 유망한 기술 중 하나로 인식되고 있다.

이러한 패러다임의 변화에 따라 사출 성형 산업에서도 공정 조건과 제품 품질 간의 관계를 예측하는 기존 기술의 한계를 극복하기 위해 인공 지능 기술을 적용하고 있다^{5,7)}. 인공신경망을 이용하여 성형품의 품질을 예측하는 모델은 두 가지 유형으로 분류할 수 있다. 하나는 다중 입력 조건에 대하여 단일 출력 파라미터를 예측하는 MISO (Multi Input, Single Output) 구조이다. 다른 하나는 다중의 입력 값과 다중의 출력 파라미터를 예측하는 MIMO (Multi Input, Multi Output) 구조이다. 이때, MIMO 모델을 구축하는 방법은 크게 단일작업 학습 (single-task learning) 과 다중작업 학습 (multi-task learning)으로 구분된다. 단일작업 학습의 경우 입력층과 출력층 내에 모든 입력 파라미터와 출력 파라미터가 위치하여 하나의 작업 구조를 통해 다수의 입력과 다수의 출력이 연결되는 형태이다. 단일작업 학습의 형태는 Fig.1에 나타내었다.




Fig. 1 Schematic of structure for artificial neural network (single-task learning)

초기에는 대부분 이러한 단일작업 학습 형태의 인공신경망을 이용하여 MIMO 모델을 구축하였다. 그러나 단일작업 학습은 서로 다른 특성을 가진 각각의 변수들을 하나의 층에 통합하여 학습을 시키기 때문에 각 파라미터들의 특징을 정확하게 반영하기 어렵다는 한계를 가지고 있다.

이러한 한계를 극복하기 위해 본 연구에서는 입력 파라미터와 출력 파라미터들을 각각 별도의 층들로 구분하고 배치하여 하나의 인공신경망 모델 내에서 파라미터 별로 별도의 학습이 가능한 다중작업 학습을 적용하였다. 다중작업 학습은 각각의 파라미터들을 특징별로 구분하여 별도의 학습이 가능하므로 파라미터들의 특징을 인공신경망에 반영할 수 있다

는 장점이 있다.

본 연구에서는 입력 파라미터와 출력 파라미터의 각 특성에 맞게 다중작업 학습 기법을 적용하여 하나의 MIMO 모델 내에 Fig.2와 같이 인공신경망을 구축하였다. 입력 파라미터들을 사출성형의 각 단계별 공정에 기반하여 적용하였으며 공유 층 (Shared layer)와 특성 층(Specific-task layer)를 구분하여 사출성형품의 품질 특성에 따른 학습 구조도 고려하여 구조적 최적화를 진행하였다. 또한, 본 연구는 기존의 인공신경망 구조를 적용한 품질 예측 모델과의 성능을 비교하기 위해 공유 층의 수는 고정하고 하이퍼 파라미터(hyper parameter)를 탐색하여 인공신경망 구조를 도출하였으며, 입력 파라미터와 출력 파라미터에 다중 학습 구조를 적용한 인공신경망에 대한 성능을 평가하였다.

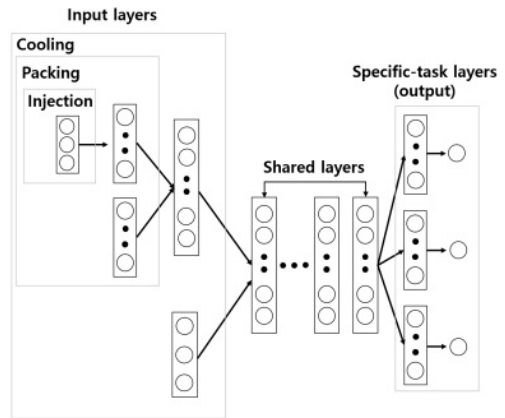


Fig. 2 Schematic of structure for artificial neural network (multi-task learning)

2. 실험

2.1. 재료 및 사출성형 장비

본 연구에서는 인공신경망 개발을 위한 데이터 수집을 위해 사출성형 실험을 진행하였다. Fig. 3과 같은 단일 캐비티 금형을 사용하여 직경 99.90mm, 높이 50.80mm 등 특정 치수의 그릇 형태(Fig.4)의 제품을 성형하고 데이터를 수집하였다. 핫 러너 시스템을 금형에 적용하였으며 노즐이 제품의 중심에 접촉되도록 하는 다이렉트(direct) 시스템을 적용하였다.



Fig. 3 The mold used in this study



Fig. 4 The children's tableware product (rice bowl)

2.2. 실험조건

수지 및 금형 온도에 대한 권장 성형 범위는 수지 제조업체의 권장 사항과 Moldflow Insight 2023내의 LUPOL GP1007의 특성 데이터베이스를 고려하여 정의하였다. 이러한 온도 범위는 Table.1 과 같이 세 가지 수준으로 분류되었다.

제품에 적합한 공정 범위를 설정하기 위해 예비 실험을 바탕으로 보압 크기와 시간을 결정하였으며, Table 1과 같이 3 수준으로 구분하여 실제 성형 실험에 적용하였다. Table 1의 공정 조건 수준을 기준으로 L27 직교배열 설계를 이용하여 27개의 공정 조건을 생성하였다. 추가적으로 Table 1의 공정 조

건 중 최소 및 최대 범위 내의 값을 무작위로 선택하여 23개의 공정 조건을 생성하였다. Table 2와 같이 총 50세트의 공정 조건에 대해 사출 성형 실험을 실시하였으며, ANN 학습에 사용되는 데이터 세트를 구성하기 위해 사출 성형된 제품의 질량, 직경 및 높이에 대한 데이터를 수집하였다.

Table 1 Process conditions and levels for the experiment

Conditions	Level1	Level2	Level3
Melt temperature	200	220	240
Mold temperature	40	50	60
Injection speed	40	70	100
Packing pressure	150	200	250
Packing time	6.0	12.0	18.0
Cooling time	38	48	58

2.3. 인공신경망 학습 방법

50개의 다양한 공정 조건을 포함하는 데이터 셋 중 38개의 데이터 셋을 학습 데이터(training data)로 지정하고, 6개의 데이터 셋을 검증 데이터(validation data)로 지정하였다. 그리고 나머지 6개 데이터 셋은 테스트 데이터 셋(test data set)으로 지정하여 모델의 성능 평가를 위해 사용하였다. 매개변수 척도의 영향이 일관되도록 설정 하고 매개변수 값 간의 크기와 차이를 표준화하기 위해 모든 데이터 셋은 식(1)을 사용하여 최소-최대 정규화 과정을 적용하였다.

$$x'_i = (0.9 - 0.1) \times \frac{(x_i - Min.X)}{(Max.X - Min.X)} + 0.1, \quad x_i \in X \quad (1)^7$$

Table 2 Injection molding conditions: orthogonal array of L27 and random array⁷⁾

Exp. No.	Melt temperature (°C)	Mold temperature (°C)	Injection speed (mm/s)	Packing pressure (bar)	Packing time (s)	Cooling time (s)	Note
1	200	40	40	150	6	38	L27
2	200	40	40	150	12	48	L27
3	200	40	40	150	18	58	L27
4	200	50	70	200	6	38	L27
5	200	50	70	200	12	48	L27
6	200	50	70	200	18	58	L27
7	200	60	100	250	6	38	L27
9	200	60	100	250	18	58	L27
10	220	40	70	250	6	48	L27
11	220	40	70	250	12	58	L27
12	220	40	70	250	18	38	L27
13	220	50	100	150	6	48	L27
14	220	50	100	150	12	58	L27
15	220	50	100	150	18	38	L27
16	220	60	40	200	6	48	L27
17	220	60	40	200	12	58	L27
18	220	60	40	200	18	38	L27
19	240	40	100	200	6	58	L27
20	240	40	100	200	12	38	L27
21	240	40	100	200	18	48	L27

22	240	40	40	250	6	58	L27
23	240	50	40	250	12	38	L27
24	240	50	40	250	18	48	L27
25	240	60	70	150	6	58	L27
26	240	60	70	150	12	38	L27
27	240	60	70	150	18	48	L27
28	214	55	82.7	204	16.3	52	Random
29	204	44	43.4	202	13.9	41	Random
30	203	46	93.6	205	13.7	45	Random
31	202	54	83.4	213	6.6	48	Random
32	206	43	61.6	221	6.9	39	Random

Table 2 Injection molding conditions: orthogonal array of L27 and random array (continued)⁷⁾

Exp. No.	Melt temperature (°C)	Mold temperature (°C)	Injection speed (mm/s)	Packing pressure (bar)	Packing time (s)	Cooling time (s)	Note
33	212	44	53.3	240	17	52	Random
34	212	51	90.8	224	6.1	48	Random
35	200	52	50	215	17.6	39	Random
36	229	51	46.2	153	11.7	45	Random
37	228	49	53.2	217	12.3	58	Random
38	222	51	63.7	167	8.7	51	Random
39	219	50	41.4	156	16.3	52	Random
40	228	46	96.5	154	16.7	57	Random
41	228	46	62.5	191	10.9	46	Random
42	219	42	98.4	237	17.9	41	Random
43	220	43	55.8	241	14.8	44	Random
44	233	42	50.8	198	13.5	55	Random
45	238	53	41.6	221	17.2	40	Random
46	234	48	68.2	222	8.8	41	Random
47	233	44	84.9	171	6.7	55	Random
48	234	43	56.9	176	11.1	48	Random
49	239	49	41.2	234	8.6	52	Random
50	240	49	76.1	241	6.4	51	Random

2.4. 인공신경망 아키텍처 및 구현

본 연구에서는 용융온도, 금형온도, 사출속도, 보압키, 보압시간, 냉각시간의 총 6가지 공정변수를 입력변수로 설정하고, 성형품의 질량, 직경, 높이를 출력변수로 설정하여 2가지 MIMO 모델을 구축하였다. 하나는 Fig.5와 같은 기존의 인공신경망인 단일 작업 층에서 세 가지의 출력 파라미터를 모두 결합한 형태이다. 이때, Hidden layer의 수는 1개부터 6개까지 진행하였다.

다른 한 개의 모델은 기존의 MIMO 모델에 입력 파라미터와 출력 파라미터의 각 특성에 맞게 다중작업 학습 기법을 적용하여 하나의 MIMO 모델 내에 Fig.6과 같이 사출성형의 각 단계별 구조를 반영한 입력 층, 공유 층, 성형품의 품질 특성을 고려한 특성 층을 구분하여 신경망이 구조적 최적화를 진행하였으며 기존 인공신경망의 예측 성능과 비교하여 평가하였다.




Fig. 5 Network with the output parameters of mass, diameter, and height being connected to the single-task layer

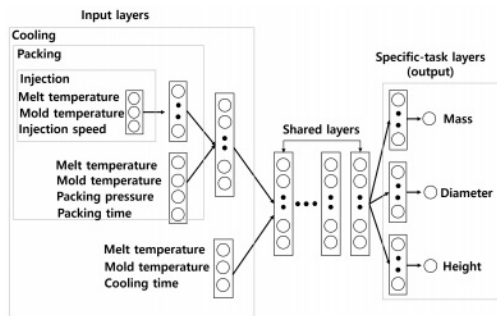


Fig. 6 MIMO structure using multi-task learning technique

Table 3은 두 가지 인공신경망 모델의 구조를 최적화하기 위한 하이퍼파라미터(hyper parameter)들의 범위를 나타내었다. Table 3의 하이퍼파라미터 범위에서 하이퍼밴드(hyper-band) 기법⁸⁾을 적용하여 해당 인공신경망의 구조와 데이터에 적합한 값들을 도출하여 인공신경망의 성능을 평가하였다. 은닉 층과 공유층 등의 층 개수는 두 가지 모델의 성능 비교를 위해 고정된 상태에서 다른 하이퍼파라미터들을 탐색하였다.

Table 3 Search range of hyper parameters

Factor	Structure of ANN	
	Single-task learning	Multi-task learning
Optimizer	Adams ⁹⁾	
Learning rate	0.0001~0.01 [step size 0.001]	
Number of hidden layers	4	3 (shared layer) 1 (specific-task layer)
Number of neurons	3 ~ 18 (from the number of output parameters to twice the sum of the number of output parameters and the number of input parameters.)	
Activation	Elu (hidden layers) Linear (output layer)	

Table 3 Search range of hyper parameters (continued)

Factor	Structure of ANN	
	Single-task learning	Multi-task learning
Weight initializer	He normal (hidden layers) Glorot normal (output layer)	
Drop number per hidden layer	0.0~0.4 [step size 0.1]	
etc.	L2 normalization (0.1, 0.01, 0.001) Batch normalization	

3. 실험결과 및 분석

Table 4에는 하이퍼밴드를 통한 2가지 인공신경망 모델의 하이퍼파라미터 최적화 결과를 나타내었다. 해당 결과를 기반으로 6개의 공정변수를 입력 파라미터로 하여 사출성형품의 3가지 품질을 예측하는 인공신경망을 구축하고 테스트 데이터를 적용하여 예측 성능을 평가하였다. Table. 4는 테스트 데이터 셋에 대한 기존의 인공신경망과 다중작업 학습이 적용된 인공신경망의 예측 성능을 나타내고 있다. 인공신경망의 예측 성능은 식(2)의 RMSE(root mean square error)로 평가하였다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y - \hat{y})^2}{n}} \quad (2)^7$$

Table 4 Search results of hyper parameters

Factor	Structure of ANN	
	Single-task learning	Multi-task learning
Optimizer	Adams ⁹⁾	
Learning rate	0.0001~0.01 [step size 0.001]	
Number of hidden layers	4	3 (shared layer) 1 (specific-task layer)
Number of neurons	17-13-8-7	7 (injection layer) 6 (packing layer) 3 (cooling layer) 18-7-7 (shared layer) [3, 5, 6] (mass, diameter, height layer)
Activation	Elu (hidden layers) Linear (output layer)	
Weight initializer	He normal (hidden layers) Glorot normal (output layer)	
Drop number per hidden layer	0.0-0.3-0.1-0.1	0.0 (injection layer) 0.2 (packing layer) 0.1 (cooling layer) 0.1-0.3-0.0 (shared layer) [0.1, 0.0, 0.3] (mass, diameter, height layer)
etc.	L2 normalization (0.01) Batch normalization	L2 normalization (0.01, 0.001, 0.1) Batch normalization

Table 5 Root mean square errors (RMSEs) of each normalized property data for Networks

Structure	Mass	Diameter	Height
Single-task learning structure (traditional)	6.280×10^{-2}	7.122×10^{-2}	4.876×10^{-2}
Multi-task learning structure	1.923×10^{-2}	5.351×10^{-2}	2.932×10^{-2}

Table 5에서 질량에 대한 다중작업 학습의 RMSE 값은 1.923×10^{-2} 로 기존 인공신경망의 결과와 비교하여 69.38% 정확도가 개선된 것을 알 수 있다. 마찬가지로 직경의 경우, 다중작업 학습 구조에서 RMSE가 5.351×10^{-2} 로 24.87%, 높이의 경우는 다

중작업 학습 구조에서 RMSE가 2.932×10^{-2} 로 39.87% 정도 정확도가 개선된 것을 확인하였다. 이러한 경로는 Fig. 7의 그래프에서도 확인할 수 있다. 따라서, 기존의 인공신경망 구조를 사용하여 사출성형공정의 공정조건과 성형품 품질 사이의 상관관계를 구축하는 것보다 다중작업 학습 구조를 활용하여 각 공정단계별 구조와 성형품 품질의 특성을 모두 반영하는 것이 더 적합한 것을 확인하였다.




Fig. 7 RMSE rate of change between conventional and multi-task learning

4. 결론

본 연구에서는 사출성형공정의 공정변수와 성형품 품질 사이의 관계를 구축하기 위해 단일작업 학습 구조가 적용된 기존의 인공신경망과 다중학습 구조가 적용되어 공정단계별 특성과 성형품 품질 특성을 반영한 인공신경망의 성능에 대해서 평가하였다. 그릇 형태의 제품을 사용하여 사출성형을 진행하고 총 50개의 데이터 셋을 구축하였다. 입력 파라미터로는 6개의 공정변수를 사용하였으며 다중학습 구조의 경우, 사출 단계, 보압 단계, 냉각 단계로 각 공정변수들을 구분하여 적용하였다. 성형품의 품질은 질량, 직경, 높이를 사용하였으며 다중학습 구조를 적용한 인공신경망에서는 각각의 품질을 별도의 층에 배치하여 상관관계를 구축하였다.

기존의 인공신경망과 입력 파라미터와 출력 파라미터에 다중작업 학습 구조를 적용한 신경망의 예측 성능을 비교한 결과, 질량, 직경, 높이 모두 다중작업 학습 구조를 적용한 인공신경망에서 우수한 RMSE 값을 보였으며 기존의 인공신경망의 성능과

비교하여 질량, 직경, 높이에 대한 예측 성능이 각각 69.8%, 24.87%, 39.87% 수준으로 개선된 것을 확인하였다. 이러한 결과를 바탕으로 본 연구에서 사용한 데이터에 대해서 기존의 인공신경망 구조를 적용하는 것보다 입력 파라미터와 출력 파라미터에 특성에 맞는 다중작업 학습 구조를 적용하는 것이 더 나은 선택임을 확인하였다. 또한 본 연구의 결과와 같이 공정단계별 특성과 성형품의 품질 특성을 별도의 작업으로 고려하는 적용 방법은 사출성형공정에서 공정조건과 성형품 품질 사이 상관관계의 정확성과 생산성을 향상시키는 동시에 품질 개선 등을 위한 조건 변경에 소요되는 시간을 단축할 수 있다. 따라서, 본 연구 결과는 향후 예측적 공정 제어, 최적 조건 도출, 또는 이를 기반으로 한 디지털 트윈 사출 성형 플랫폼 구축 등 사출 성형 산업에 ANN을 적용하기 위한 연구에 근거와 가이드로써 사용될 수 있다.

후기

본 연구는 중소기업벤처부의 스마트제조혁신기술개발사업 (Project No.00140364, SE230069)이 지원한 것이다.

참고문헌

- 1) Sung, S. M., Jun, J. S. A study on the motorcycle lear cowl injection molding by CAE analysis, Design & Manufacturing, Vol. 13:4 34-39. 2019.
- 2) Yoo, M. J., Kim, K. A., Han, S. R., Optimization of feed system of base mold for washing machine using CAE, Design & Manufacturing, Vol. 15:1, 1-7, 2021.
- 3) Hong, S. K., Implementation of an simulation-based digital twin for the plastic blow molding process, Design & Manufacturing, Vol. 17:3 1-7. 2023.
- 4) Lee, D. W., Kim, J. S., Lee, H. H., Lee, S. H., A study on CAE and injection molding of automotive thick-walled light guide with micro-optical patterns Design & Manufacturing, Vol. 17:3, 8-14. 2023.
- 5) Koh, B. W., Kim, J. S., Choi, H. G., Estimation of Process Parameters Using QFD and Neural Networks in Injection Molding, Ind. Eng. Interfaces, Vol. 21:2, 221-228, 2008.
- 6) Rhee, B. O., Tae, J. S., Choi, J. H., Injection Mold

Cooling Circuit Optimization by Back-Propagation Algorithm, J. Korean Soc. Manuf. Technol. Eng., Vol. 18:4, 430-435, 2009.

7) Lee, J. H., Yang, D. C., Yoon, K. H., Kim, J. S., Effects of Input Parameter Range on the Accuracy of Artificial Neural Network Prediction for the Injection Molding Process. Polym., Vol 14, 1724, 2022.

8) Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., Talwalkar, A., Hyperband: A novel bandit-based approach to hyper-parameter optimization. J. Mach. Learn. Res. Vol. 18, 6765 - 6816. 2017.

9) Kingma, D. P., Ba, J., Adam: A method for stochastic optimization., arXiv, 2014.

저자 소개

이 효 은 (Hyo-Eun LEE)



- 2023년 9월~현재: 단국대학교 기계공학과 (석사과정)
- 2023년 9월~현재: 한국생산기술연구원 학생연구원

< 관심분야 >
사출성형, 인공지능

이 준 한 (Jun-Han Lee)



- 2017년 3월~2022년 8월: 단국대학교 기계공학과 (공학박사)
- 2015년 3월~2022년 8월: 한국생산기술연구원 금형성형연구부, 학연협동과정생
- 2022년 9월~2023년 8월: ㈜이몰디노 솔루션 팀, Domain expert
- 2023년 9월~현재: 한국생산기술연구원 금형성형연구부, 포스트닥터

< 관심분야 >
사출성형 및 금형, 유동해석

김 종 선 (Jong-Sun Kim)



- 2005년 8월: 단국대학교 기계공학과 (공학박사)
- 2006년 3월~현재: 한국생산기술연구원 금형성형연구부, 수석연구원

< 관심분야 >
사출성형 및 금형, 유동해석

조 구 영 (Gu-Young Cho)



- 20016년 : 서울대학교 기계공학과 (공학박사)
- 2019년 3월~현재: 단국대학교 기계공학과 조교수

< 관심분야 >
연료전지, ALD, 인공지능