

설명가능 인공지능(XAI) 기반 사출금형 내 성형조건(IMC)의 품질 영향도 분석 방법론

김진수^{a,*}, 린청윈^{b,c}, 텅리셴^{b,c}

Analysis Methodology for Effect of In-Mold Condition (IMC) on Quality based on Explainable Artificial Intelligence (XAI) in Injection Molding

Jinsu Gim^{a,*}, Chung-Yin Lin^{b,c}, Lih-Sheng Turng^{b,c}^a Dongnam Technology Application Division, Korea Institute of Industrial Technology (KITECH)^b Department of Mechanical Engineering, University of Wisconsin-Madison^c Wisconsin Institute for Discovery, University of Wisconsin-Madison

ARTICLE INFO

Article history:

Received 29 August 2024
Revised 20 September 2024
Accepted 23 September 2024

Keywords:

Autonomous manufacturing
Explainable artificial intelligence (XAI)
Injection molding
In-mold condition
Process analysis

ABSTRACT

This paper proposes a methodology to analyze the effect of in-mold conditions (IMCs) on part quality for autonomous manufacturing in injection molding. The IMC is the most important information affecting part quality in injection molding because it presents detailed molding conditions in the cavity. To utilize IMCs for monitoring, optimization, and control, the relationship between IMC and quality should be analyzed. The main goal of the proposed method is to use explainable artificial intelligence (XAI) to automate analysis tasks and yield more objective and quantitative results than conventional knowledge-driven methods based on previous knowledge and understanding. The contributions of IMC features to the quality of a specific part quality and the overall effect of IMC features on molding processes are analyzed by applying XAI to IMC-Quality AI models. The analysis results can be further utilized for specific quality-targeted monitoring and intelligent process optimization based on IMCs.

1. 서론

사출성형 공정에서 금형의 캐비티 내 성형조건(형내 조건, in-mold condition, IMC)은 제품 품질에 가장 관련성이 높은 정보이다. 이는 IMC가 사출성형기, 금형 온도 조절기 등의 장비에 설정하는 공정 변수와 제품 품질 간의 연관관계를 나타내며^[1], 금형 내 캐비티에서 용융 고분자가 최종 제품 형상으로 성형되므로 IMC가 공정 변수의 성형공정에 대한 영향뿐만 아니라 외란의 영

향까지 포함하는 제품 성형에 대한 최종 정보이며^[2], 감쇄가 큰 용융 고분자의 특성에 의하여 캐비티에서 공정 상 거리가 먼 공정 변수가 직접적으로 금형 내 조건을 나타내지 못하기 때문이다^[3].

IMC의 중요성으로 인해 이를 측정하기 위하여 다양한 금형 내 센서(in-mold sensors)가 사용되고 있으며, 이러한 형내 센서의 활용은 데이터 기반 제조공정 지능화의 방안으로 제시되고 있다. 예를 들어 캐비티 내압^[4,5], 금형 표면 온도^[6], 캐비티 공기 온도^[7], 금형 변형률 센서^[8] 등의 다양한 금형 내 센서(in-mold sensors)가

* Corresponding author. Tel.: +82-55-924-0134

E-mail address: jgim@kitech.re.kr (Jinsu Gim).

사용되고 있다. 측정된 IMC는 단순히 금형 내 용융 고분자에 가해지는 물리적인 성형 조건 자체를 분석하고 이해할 뿐만 아니라, 궁극적으로는 제품 품질과 공정을 최적화하는데 활용된다.

IMC를 사출성형 공정 분석과 최적화에 활용하기 위해서는 제품 품질에 대한 연관관계 또는 영향도를 분석할 필요가 있으나, 기존에 시도되어 왔던 방법론은 한계점이 명확하다. IMC는 쿠션량, 최대 사출압력 등 각 성형 사이클을 대표하는 값이 아니라, 시간에 따른 온도 및 압력의 변화를 나타내는 시계열 데이터이다. 따라서 최대/최소/평균 등의 단편적인 값보다 구체적인 정보를 내포하고 있다. 이는 필연적으로 IMC를 분석하는데 사전지식과 이해가 필요하다라는 것을 의미한다.

기존의 시도되어 왔던 IMC를 활용한 사출성형 및 품질 영향도 분석 방법론은 대략적으로 다음의 순서를 따라왔다. 먼저, 사출성형 공정과 용융 고분자의 유변학적 특성 등에 대한 이해를 기반으로 IMC 프로파일에서 품질에 높은 연관성을 가질 것이라고 판단되는 특성을 추출하고, 추출된 각 특성과 제품 품질간의 연관관계를 분석하기 위하여 선형상관계수(Pearson correlation coefficient, R)를 도출한뒤, 높은 선형상관계수를 보이는 특성이 가장 높은 영향도를 보이는 것으로 판단함으로써, 해당 특성을 제품 품질을 예측하거나 공정을 최적화하는데 활용해왔다.

그러나, 이러한 접근방법은 IMC를 활용하여 사출성형 공정을 분석하고 최적화하는데 크게 세가지의 한계점을 가진다. 첫 번째는 사전지식과 이해가 부족한 경우 IMC 프로파일에서 특성을 추출하기 어려우며, 두 번째는 높은 선형상관계수는 연관관계의 선형성만을 나타낼 뿐 각 특성의 제품 품질에 대한 민감도를 나타내지는 않기에 비선형성이 높더라도 영향도가 높은(품질에 민감한 영향을 주는) 특성을 분석해 내는데 한계가 있으며, 세 번째는 제품 품질을 최적화하기 위한 구체적인 IMC 프로파일 형태를 제시하지 못한다는 한계가 있다.

최근 급속도로 발전해온 인공지능(artificial intelligence, AI) 기술은 단순한 예측 및 판단의 활용 목적을 넘어, 복잡한 물리적 현상에 대한 이해를 높이는 데까지 활용되고 있다. 특히 설명가능 인공지능(explainable artificial intelligence, XAI)은 예측 결과에 대한 입력 특징(input features)의 기여도 또는 민감도를 정량화함으로써, 수많은 가중치로 인해 수학적으로 설명이 어려운 “Black box” 특성을 보이는 AI 모델의 예측 결과를 사람이 이해할 수 있도록 한다. 이 때문에 XAI는 AI 모델의 신뢰성(trustworthiness)을 높이고, 모델을 개선(improvement)하며, AI 모델이 학습한 지식과 패턴을 찾는 데(knowledge discovery) 도움을 주고 있다.

XAI의 장점을 활용하여 사출성형 공정을 분석하기 위한 시도가 최근 이루어져 왔다. Román은 사출품의 표면 불량에 대한 소재 특성의 영향도 분석 결과를 기반으로 표면 불량 예측 모델의 예측

성능을 개선하였다^[9]. Lockner는 AI 모델의 타 소재 및 사출성형 기로의 전이학습을 수행하기 앞서 사출성형 시뮬레이션에 사용된 220개의 소재 물성 특성 중에서 유효한 특성을 XAI를 활용하여 선정하였다^[10]. Jeon은 사출성형기 배럴에서 토출되는 용융 고분자의 온도 프로파일에 대한 영향인자를 XAI를 활용하여 분석하였다^[11]. Lin은 시뮬레이션 데이터를 활용하여 사전학습된 AI 모델을 실제 공정에 적용하기 위한 전이학습을 수행하는데, 주된 영향을 미치는 입력 특성을 찾아내기 위하여 XAI를 활용하였다^[12].

또한 시계열 데이터인 IMC 프로파일을 이용한 AI 모델을 활용하여 성형공정을 분석하는 시도가 이루어지고 있다. Farahani는 제품 품질 예측에 대한 캐비티 압력과 금형 온도 프로파일의 각 구간에 대응되는 가중치를 분석함으로써, IMC 프로파일에서 주요한 구간을 추출하였다^[13]. Wang은 IMC 프로파일 특성으로 적분 및 최대값을 추출하여 제품 품질에 대한 영향도를 분석하였다^[14]. 그러나, 기존에 시도되어 왔던 방법론의 경우 최대/최소/평균/적분/표준편차 등의 단편적인 표준 특성(standard feature)^[15]을 활용하거나, 사전에 특성을 선정하는 선행 과정을 거친다. 전자의 경우 표준 특성으로 나타나지 않는 IMC 프로파일의 정보가 분석에서 누락될 가능성이 있으며, 후자의 경우 사전지식과 이해에 의존적이라는 한계를 가진다.

본 연구에서는 이러한 한계를 극복하고자, IMC 프로파일의 형상 정보에 기반한 IMC 특성을 자동적으로 추출하고, 이를 품질 예측의 입력 특성으로 하는 AI 모델을 구축하여 XAI로 분석함으로써, 특정 사출성형품의 품질 및 공정 전반에 걸친 품질에 대한 IMC 프로파일의 영향도를 분석하는 방법론을 제시하고자 한다. 본 논문의 결과는 IMC 기반의 지능형 사출성형 모니터링 기술과 IMC 중심의 사출성형 공정 최적화에 응용될 수 있다.

2. 방법론

제안하는 방법론은 AI가 학습한 IMC 프로파일의 각 구간과 품질 사이의 연관관계를 XAI를 기반으로 해석함으로써, IMC의 제품에 대한 영향도를 분석한다. AI 모델을 활용하기 때문에, 제안하는 방법론은 형내 센서를 이용한 IMC 측정, 품질 측정, 시계열 데이터 분할을 통한 입력 특성 추출을 포함하는 사전 작업과, 그 이후 AI 모델 학습과 XAI의 적용 및 이에 기반한 사출성형 공정 분석으로 각 단계가 구성된다. Fig. 1(a)는 제안 방법론의 전반적인 순서도를 나타낸다.

2.1 형내 공정조건 (IMC) 측정

본 방법론을 적용하기 위하여 스프루 게이트를 가지는 박스 형태의 제품과 금형을 선정하였다. Fig. 1(b)는 제품 형상과 캐비티

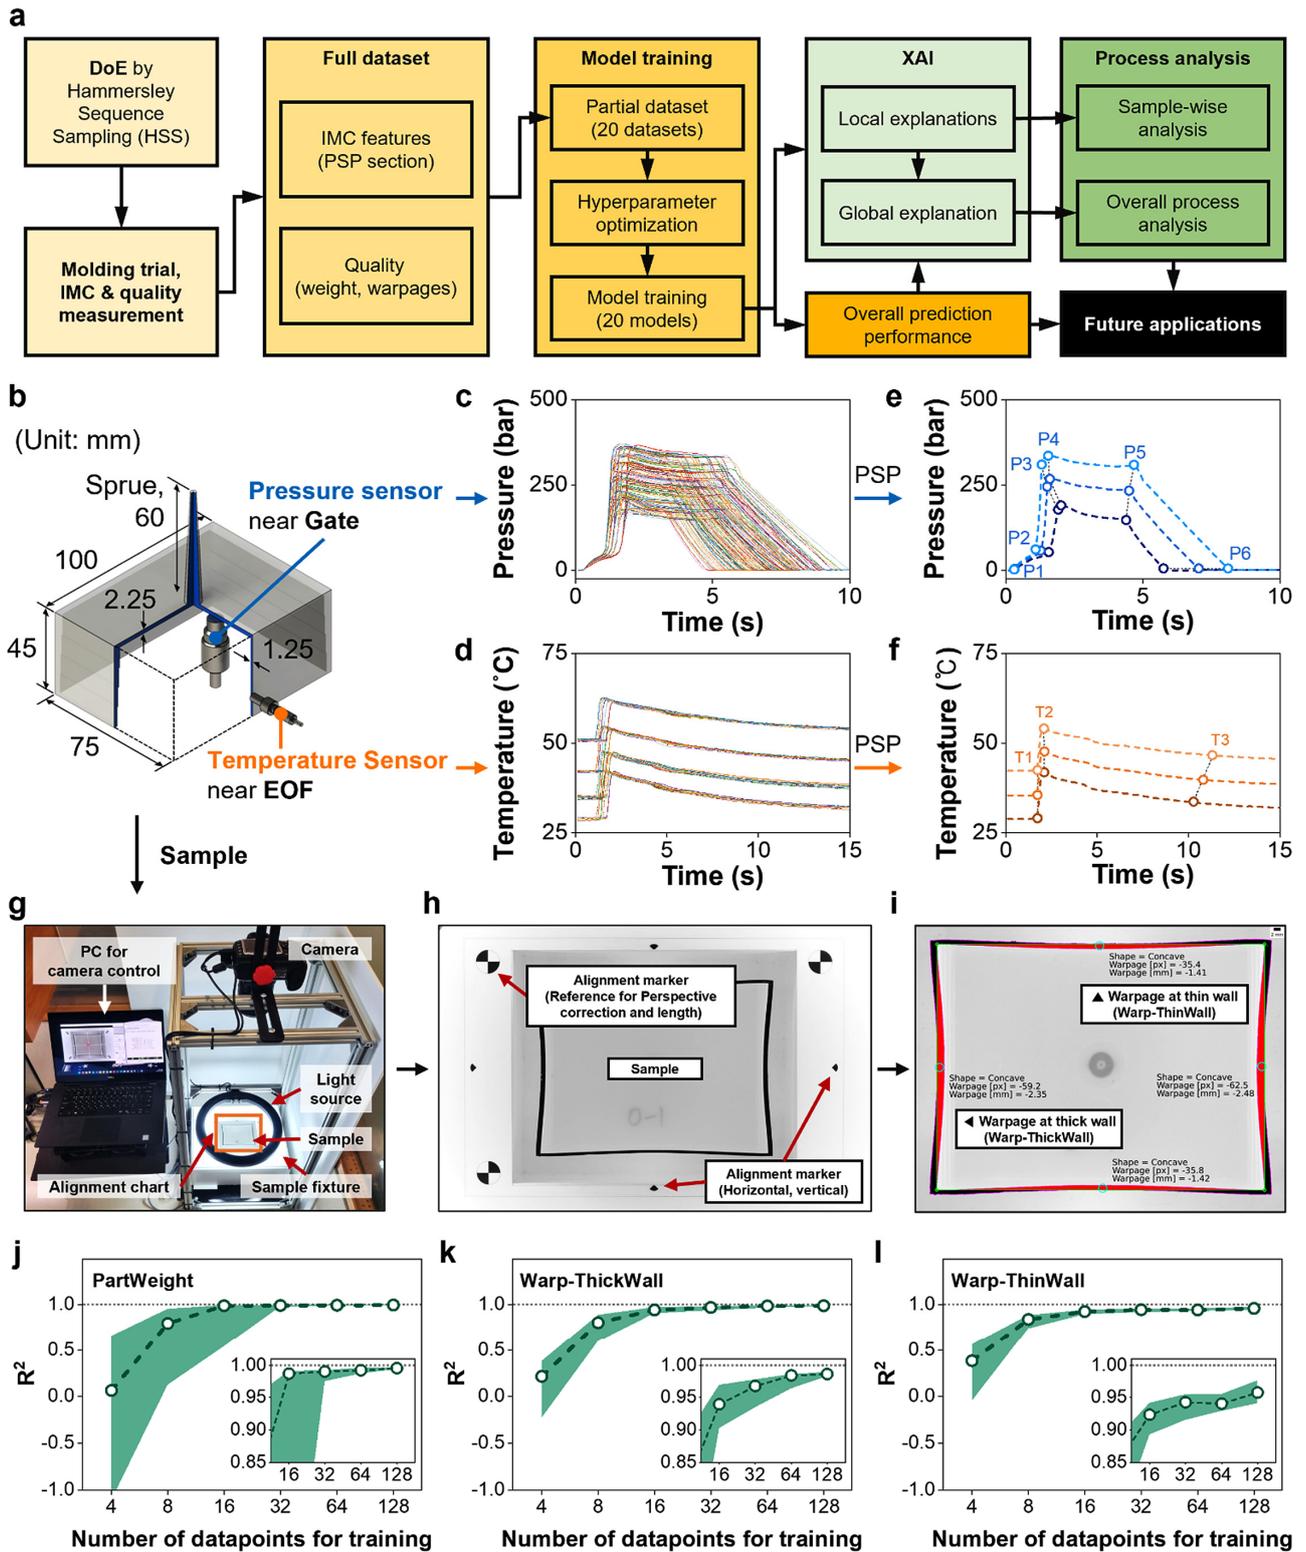


Fig. 1 XAI based analysis of the effect of in-mold condition (IMC) profile on injection-molded part quality. (a) Overall flow chart of the proposed method. (b) Sample and cavity dimension with in-mold sensor locations. (c) and (d) Cavity pressure and mold surface temperature profiles, respectively. (e) and (f) Extracted process state points (PSPs) and similarity of IMC profiles represented by PSPs. (g), (h) and (i) Imaging studio, alignment chart on sample fixture, and warpage measurement result by image processing, respectively. (j), (k) and (l) Prediction performance of IMC-quality models for part weight, warpage at thick wall, and thin wall, respectively. Note: EOF = End of filling.

압력 및 금형 표면 온도 센서 위치를 나타낸다. 해당 제품의 경우 직각 두 측면의 두께가 상이하며 내부 코어의 냉각이 충분하지 않다. 따라서 두 측면 모두에서 변형량을 억제하기 대단히 힘든 특성을 가지며, 완벽하게 변형을 억제하기 위해서는 초미세발포 등의 특수 공정이 적용되어야 한다¹⁶⁾.

IMC를 측정하기 위하여 캐비티 압력 센서와 금형 표면 온도 센서가 각각 게이트 부근과 충전 말단부에 설치되었다. 충전 초기부터 보압 및 냉각에 이르는 최대한 긴 압력 프로파일을 측정할 수 있도록, 캐비티 압력센서는 게이트 위치에 설치되었다. 단순 금형 표면 온도 정보뿐만 아니라 캐비티 충전 완료 시기를 확인하기 위하여 금형 표면 온도센서를 충전 말단부에 설치되었다.

시간 도메인에서의 고해상도의 시계열 데이터를 얻기 위하여 IMC는 100 Hz의 샘플링 속도로 측정되었으며, 프로파일의 시간 정보를 추후 입력 특성으로 활용하기 위하여 측정은 사출성형기의 스크루 전진 신호와 동기화되어 시작되었다. Table 1은 연구에 사용된 사출성형기, 고분자 소재의 정보이다. Fig. 1(c), (d)는 측정된 캐비티 내압 및 금형 표면 온도 프로파일이다.

2.2 실험계획

IMC 프로파일과 제품 품질 사이의 연관관계를 학습시키기 위한 양질의 공정 데이터를 얻기 위해서는, 제한된 시험 조건(시간, 비용, 인력 등)내에서 최대한 다양한 IMC 프로파일을 구현하고 이에 대응되는 제품 품질을 측정해야 한다. 이를 위해, 기본적인 사출성형 공정조건 4가지(사출속도, 보압크기, 보압시간, 냉각수 온도)를 공정 파라미터로 선정하였다. 각 공정 파라미터의 최대-최소 범위

Table 1 Experiment equipment and material

Equipment	Name
Molding machine	Arburg Allrounder 320S 500-150, Arburg GmbH+Co KG
Polymer material	Homo-PP, Pro-fax PD702, LyondellBasell Industries Holdings B.V., Netherlands
Cavity pressure sensor	PT465XL-7.5M, Dynisco LLC, USA
Mold surface temperature sensor	Type 6192B, Kistler Holdings AG, Switzerland
Data acquisition system	SC-2346 and PCI-6024E with SCC-SG24 (for pressure), SCC-TC02 (for temperature), and SCC-DI01 (for time reference), National Instruments Corp., USA
Weight measurement	PBW-3200, Intelligent Weighing Technology Inc., USA
Imaging device	D90, Nikon Corp., Japan with SP 60 mm, Tamron Co., Ltd., Japan

Table 2 Range of tested process parameters

Process parameter	Range
Coolant temperature	30~60 °C
Injection speed (cavity)	30~50 cm ³ /s
Packing pressure	300~500 bar
Packing time	2.0~4.0 s

(Table 2 참조) 내에서 각각의 사출조건이 서로 중복되지 않고, 상호 연관성이 없도록 Hammersley Sequence Sampling (HSS)를 활용하여 170종의 공정 파라미터 조합을 생성하였다.

2.3 IMC 프로파일 특성 추출

IMC 프로파일의 형상은 사출공정 조건에 대한 많은 정보를 내포하고 있기 때문에, AI 모델 학습을 위한 입력 특성을 추출하는데 프로파일 형상에 기반한 시계열 데이터 분할 알고리즘을 활용하였다. 예를 들어 캐비티 충전 속도와 관련된 정보를 나타내는 캐비티 압력 프로파일에서의 충전구간의 상승 기울기는, 단순한 평균과 표준편차 등의 표준 특성으로 추출되기 어려우나, 충전구간 시점과 종점의 시각과 압력 정보로 추출될 수 있다. 제품 품질에 대해 캐비티 충전 속도의 영향이 큰 경우, 이에 대응되는 구간의 시간과 압력의 영향도가 높을 것이라 예상할 수 있다. 시계열 분할 알고리즘으로 Perceptually important point (PIP)¹⁷⁾를 압력과 온도 프로파일 분할에 사용하였고, 추출된 프로파일 분할점을 공정 상태점(process state point, PSP)¹⁸⁾이라 명명하였다.

추출된 PSP는 다양한 IMC 프로파일의 유사성을 반영하여, 다른 IMC 프로파일이라도 동일한 의미의 프로파일 특성을 추출하고 분석을 가능하게 한다¹⁹⁾. PSP는 동적 시간 워핑 (dynamic time warping)의 warping path와 유사한 역할을 한다. 따라서 IMC 프로파일의 변화는 특정 시간에서의 압력/온도 값의 변화(y축 이동)가 아니라, 다른 프로파일의 대응되는 위치로 PSP의 이동으로 표현된다. 따라서, PSP를 이용한 IMC 프로파일의 특성 추출과 분석은 사출성형 공정에 타당한 접근이다. Fig. 1(e), (f)는 PSP의 예시와 상이한 IMC 프로파일의 PSP를 이용한 대응 관계를 나타낸다.

PSP의 시간과 압력 및 온도는 이전 PSP의 값에 의존적인 특성을 가지므로, PSP로 구분되는 각 구간(PSP section)의 시간/압력/온도의 변화량을 입력 특성으로 추출하였다. 예를 들어 캐비티 완충 시간이 대단히 짧은 경우, 충전 시작 시점과 보압 시작 시점은 매우 유사한 값을 보인다. 이러한 경우 두 시각의 영향도를 구분하기 매우 어렵게 된다. 따라서 각 PSP의 상호 연관성을 배제하기 위해서는, 구간별 변화량을 입력 특성으로 선정하였다.

2.4 품질 측정

제한 방법론을 적용하기 위하여 제품 중량, 두꺼운(짧은) 측면

및 얇은(긴) 측면에서의 변형. 총 세 가지의 제품 특성이 품질 요소로써 선정하였다. 측면의 변형을 정밀하게 측정하기 위하여 OpenCV와 scikit-image를 활용한 이미지 프로세싱을 활용하였다. 제품 내 측면의 코너와 모서리 인식을 토대로 변형을 측정하였으며, 외측으로 볼록한 경우 양수, 오목한 경우 음수의 변형값을 정의하였다. 사용된 품질 측정 장비는 Table 1에 구체적으로 제시되었다. Fig. 1(g)-(i)는 측면 변형량 측정을 위한 촬영 셋업, 이미지 프로세싱을 위한 차트, 그리고 각 측면의 변형량 측정 결과의 예시이다.

2.5 AI 모델 구축

IMC 프로파일과 품질 사이의 연관관계를 나타내는 AI 모델로 인공신경망(artificial neural networks, ANN)을 활용하였다. Decision tree와 같은 단순 모델과 비교하여 ANN은 설명성(explainability)이 부족하다. 그러나, 모델의 복잡성으로 인하여 예측 성능이 높기 때문에 사출성형 공정을 모델링하는데 유리하다. 또한 전이학습(transfer learning)을 통하여 금형 이관, 사출기 변경, 소재 변경 등에 대응할 수 있다.

사용된 ANN 모델은, 학습 데이터셋을 활용한 하이퍼파라미터 최적화(hyperparameter optimization, HPO)를 수행하여 최적 구조를 선정한 뒤에 학습되었다. 전체 데이터셋에서 무작위로 분할된 20종의 부분 데이터셋(훈련 2ⁿ, 검증 20, 시험 20)을 모델 학습에 활용하였다. 훈련 데이터의 경우 크기를 4에서 128까지 변경하였다. 훈련 데이터의 비용이 높은 제조업의 특성 상 대량의 데이터셋을 구축하기 어렵다. 따라서 제조 AI 모델은 언제나 부족한 데이터를 활용하여 구축되며, 동일 제조 공정이라 하더라도 사용된 데이터셋에 따라 최적 하이퍼파라미터는 상이할 수 있다. 이를 반영하기 위하여 각 학습 데이터셋에 대하여 HPO를 수행하고, 뒤이은 학습을 동일 학습 데이터에 대하여 수행하였다. HPO에 이은 본 학습은 별도의 수작업을 개입하지 않고 자동으로 수행되도록 하였다. 100 epoch 훈련 후의 R²를 HPO의 목적함수 선정하였다. HPO는 Tree-structured Parzen Estimator (TPE)를 활용한 베이지안 최적화 기법을 사용하였으며, 최적화 속도 향상을 위해 Successive Halving 및 Hyperband algorithm을 이용한 가지치기(pruning)를 통해 유망하지 않은 시도는 조기 종료되었다.

AI의 확률론적 특성(stochastic nature)을 고려하기 위하여^[20], 모델의 예측 성능은 총 20개의 모델에 대한 평균과 표준편차로 정량화 하였다. 사용된 개발 환경, AI 및 HPO 프레임워크는 Python 3.7, TensorFlow 2.9.2, Optuna 3.0.2이다. Table 3은 HPO의 수행 범위이다.

2.6 XAI 기반 IMC의 품질 영향도 해석

XAI를 이용한 AI 모델의 해석을 통하여 IMC 프로파일과 품질

Table 3 Search range of hyperparameter optimization

Hyperparameter	Range
Number of hidden layers	1, 2, 3
Number of neurons for each hidden layer	8, 16, 32
Weight initializer	Glorot normal, Glorot uniform, He normal, He uniform, LeCun normal, LeCun uniform
Activation function	ReLU, GELU, ELU, SELU, softplus, swish
Optimizer	Adadelta, Adam, Adamax
Learning rate	0.001, 0.01, 0.1

간의 연관관계를 분석하였다. AI 모델의 예측 성능이 충분히 높다면, 모델이 실제 제조공정을 잘 대변한다고 할 수 있다. 따라서 AI 모델의 분석 결과는 실제 제조공정에서의 연관관계를 나타낸다. 그러나, AI 모델을 구성하는 수많은 가중치에 의하여 모델의 예측 결과를 수학적으로 직접 해석하는 것은 매우 어렵다. 그러나 XAI는 모델의 예측에 대한 타당한 설명을 제공하므로, 이를 이용하면 실제 제조공정을 AI 모델을 토대로 분석할 수 있다.

구축된 AI 모델을 분석하기 위하여, 협동 게임이론의 Shapley 값에 기반한 Shapley Additive explanation (SHAP)^[21]을 활용하였다. SHAP은 간단히 말해서 기저(base) 결과인 전역 예측 평균과 특정 예측 결과의 차이를 각 입력 특성의 기여도의 합(Σ contribution)으로 표현한다. 입력 특성의 기여도는 양 또는 음의 값을 나타낼 수 있다. 이러한 국부 설명(local explanation) 결과들을 종합해보았을 때, 입력 특성의 기여도의 분포가 넓다면 전역적으로 해당 입력 특성의 중요도가 높음을 의미한다. 따라서, XAI에 활용된 데이터셋(또는 국부 데이터셋)에 대한 예측 결과 분석을 종합하여 각 입력 특성의 중요도(feature importance)를 도출하고 이러한 전역 설명(global explanation)을 제조 공정에 대한 전반적인 해석으로 이해할 수 있다.

XAI 기반 영향도 해석 결과는 총 20개 모델에 대한 SHAP 결과를 종합하여 도출하였다. 단편적인 SHAP 활용은 단일 모델에 대한 분석만을 제공하므로, 해당 모델이 우연히 특정 입력 특성의 영향도를 높게 반영하는 등의 AI의 확률론적 특성을 고려할 수 없다. 따라서, 각 모델의 해석 결과를 모두 종합하여 IMC 프로파일의 영향도를 분석하였다.

3. 결 과

3.1 IMC-품질 AI 모델

학습 데이터셋 크기가 증가할수록 AI 모델의 예측 성능이 향상

되는 일반적인 경향이 각 품질 예측 모델에 대해서 나타났다. Fig. 1(j)~(l)는 학습 데이터셋 크기에 따른 각 품질 예측 모델의 예측 성능을 나타낸다. 중량 예측 모델의 경우 학습 데이터셋이 16 포인트 미만 이더라도 $R^2 > 0.95$ 의 높은 예측 성능을 보였다. 측면 변형을 예측 모델의 경우 두 측면 모두 학습 데이터셋이 32 포인트 이상이 되어야 $R^2 \sim 0.95$ 를 만족하였다. 일반적으로 중량의 경우 캐비티 내압의 적분과 높은 상관관계를 보인다고 알려져 있는 만큼, 해당 결과를 통하여 IMC 프로파일 중에서 특히 압력 프로파일과의 중량 사이의 연관관계가 단순 및 직접적인 것이라는 것을 유추할 수 있다. 또한 중량과 비교하여 측면 변형은 예측하기가 까다로우며, IMC 프로파일과 측면 변형 사이의 연관관계에 비선형성이 많을 것이라고 유추할 수 있다. 이후 $R^2 \sim 0.95$ 를 공통적으로 만족하는 32 포인트의 학습 데이터셋으로 학습된 각 품질 예측 모델에 대하여 XAI 기반 IMC 프로파일의 제품 품질에 대한 영향 분석을 수행하였다.

3.2 특정 성형품 품질에 대한 IMC 영향 분석

AI 모델의 특정 예측 결과를 XAI를 활용하여 분석함으로써, 특정 제품 품질의 발생 원인을 IMC 프로파일 특성 각각의 기여도로 나누어 확인할 수 있다. Fig. 2는 특정 성형 공정에 대한 각각의

IMC 프로파일 특성의 영향도, 그리고 각 공정에서의 IMC 프로파일을 나타낸다. 각 IMC 프로파일 특성의 영향도는 SHAP의 국부 설명 결과에 해당하며, 20개 모델에 대한 설명 결과를 종합한 결과이다.

시험 조건 중에서 제품 중량이 최소가 되는 성형 공정, Fig. 2(a)은, P4-P5 구간의 시간차(Δt_{P4-P5}), P5-P6 구간의 시간차(Δt_{P5-P6}), 그리고 초기 온도(T_{T1})의 크게 3가지 IMC 프로파일 특성의 음의 기여도의 합으로 설명된다. 이는 해당 제품의 중량이 전반적인 평균(base value, 37.27 g)보다 작은 이유가, 보압부터의 압력 유지 시간(Δt_{P4-P5} 및 Δt_{P5-P6})과 초기 금형 온도(T_{T1}) 때문이라는 것을 의미한다.

사출성형 공정에 대한 기반 지식(domain knowledge)을 토대로 IMC 프로파일을 분석함으로써 해당 결과가 타당함을 확인할 수 있다. 일반적으로 캐비티 압력 프로파일의 면적(시간-압력 적분)은 제품 중량에 직접적인 연관성을 가진다고 알려져 있다^[22-25]. 또한 고분자 소재의 pvT 특성에 따라 밀도는 온도에 대하여 반비례의 연관성이 있다. 이러한 지식을 기반으로 캐비티 압력 프로파일, Fig. 2(b)를 확인해보면, 중량이 최소가 되는 이유가 해당 공정의 보압부터의 압력 유지 시간과 보압 크기가 상대적으로 부족하기 때문인 것으로 이해할 수 있다. 또한 금형 표면 온도 프로파일,

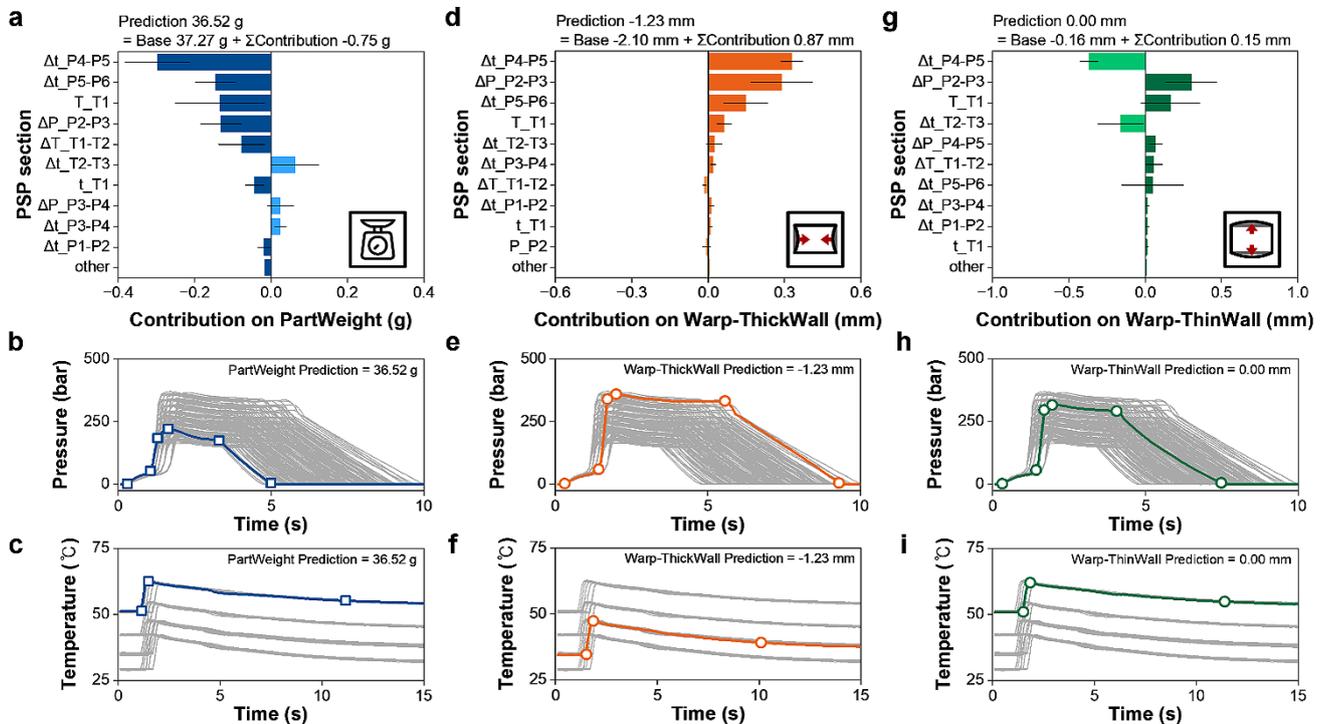


Fig. 2 Effect of IMC features on each quality of specific specimen. (a), (b), and (c) Effect of IMC features on the lowest part weight (PartWeight), and correlating cavity pressure, and mold surface temperature profile, respectively. (d), (e), and (f) Effect of IMC features on the smallest warpage at thick wall (Warp-ThickWall), and correlating cavity pressure, and mold surface temperature profile, respectively. (g), (h), and (i) Effect of IMC features on the smallest warpage at thin wall (Warp-ThinWall), and correlating cavity pressure, and mold surface temperature profile, respectively.

Fig. 2(c)에서의 초기 온도가 타 공정보다 높기 때문에 제품 중량이 작게 성형되었다고 이해할 수 있다. 따라서 XAI를 활용한 중량에 대한 IMC 프로파일의 영향도 분석 결과는, 기존의 사출성형 공정에 대한 지식에 기반한 분석 결과에 부합한다. 또한 Fig. 2(a)의 분석 결과는 단순히 충전과정에서 취출까지의 전체 시간 범위에서 캐비티 압력 프로파일의 면적보다도, 보압부터의 시간 구간에서의 적분 결과가 중량에 더욱 연관성이 높을 것임을 시사한다. 두꺼운 측면에서의 변형(Warp-ThickWall)이 최소가 되는 조건에서 IMC 프로파일에 대한 분석은 Fig. 2(d)이다. 해당 분석 결과

는 P4-P5 및 P5-P6 구간에서의 시간차이와, P2-P3의 압력차이가 모두 양의 기여를 했다고 설명한다. 이는 전반적인 평균(base value, -2.10 mm)과 비교하여 변형이 억제되는 이유가 주로 보압부터의 압력 유지시간과 보압 크기에 있다는 것을 의미한다. 흥미로운 점은 앞서 중량 분석 결과와는 다르게 두 성형품의 측면 변형에는 초기 급형 온도의 영향이 미미하게 분석되었다. Fig. 2(e)와 Fig. 2(f)는 해당 조건에서의 캐비티 압력과 온도 프로파일을 나타낸다. 구체적인 캐비티 압력 프로파일인 Fig. 2(e)에서 분석 결과에 대한 타당성을 역시 확인할 수 있다. 중량과 유사하게, 완충 이

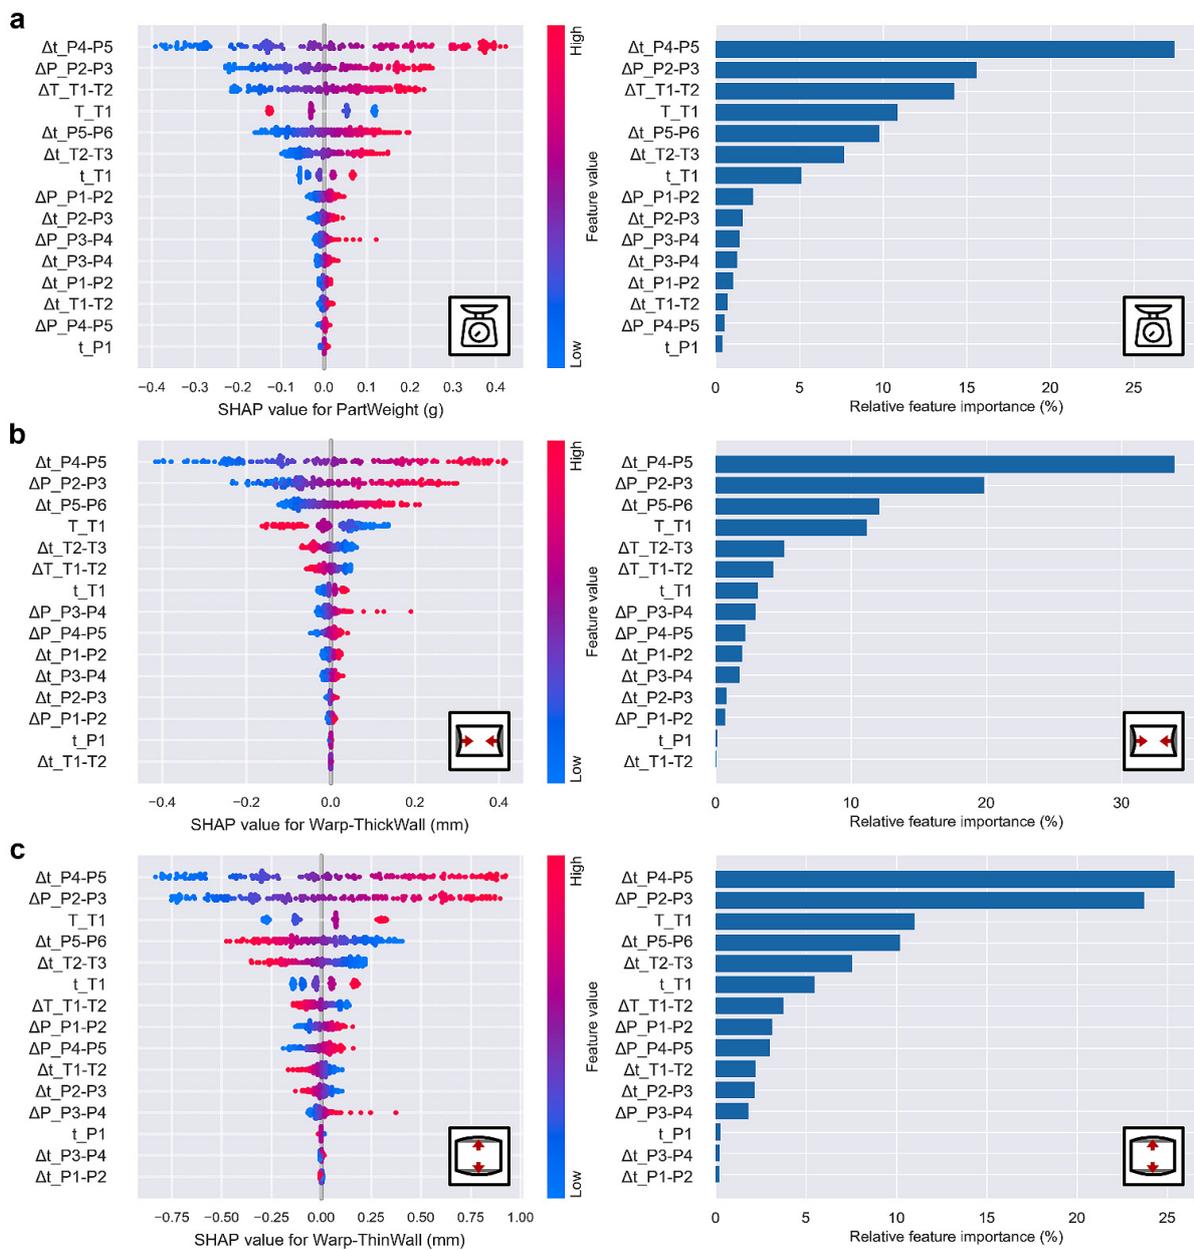


Fig. 3 Effect if IMC features on each quality of overall process. (a) Part weight, (b) warpage at thick wall, and (c) warpage at thin wall.

후 캐비티 압력 크기와 유지시간이 타 공정 조건보다 충분히 작용함으로써 제품에서 발생하는 수축량이 전반적으로 보상되었고, 결과적으로 측면 변형이 많이 억제되었다고 이해할 수 있다.

얇은 측면에서의 변형(Warp-ThinWall)이 최소가 된 공정에 대한 분석결과인 Fig. 2(g)에서, P2-P3 구간의 압력 차이와 초기 온도가 양의 기여도를 보임으로써, 전반적인 평균(base value, -0.16 mm)와 음의 기여도를 보였던 P4-P5구간의 시간 차이의 영향을 상쇄한 것으로 나타났다. 두 성형 조건의 특징은 Fig. 2(h), (i)의 캐비티 압력 프로파일과 금형 표면 온도 프로파일에서 확인 가능하다. 흥미로운 점은, 유사한 품질인 두꺼운 측면에서의 변형과 얇은 측면에서의 변형이 각각 최소가 되는데 주로 기여하는 IMC 프로파일 특성과 그 기여도가 상이하다는 것이다. 당연하게도, 다른 품질 요소에 대하여 IMC 프로파일 특성은 각각 다른 영향을 줄 것이며, 제안하는 방법론은 이러한 영향의 차이를 구체적으로 확인할 수 있도록 한다.

3.3 공정 전반에 걸친 품질에 대한 IMC 영향 분석

AI 모델의 다양한 예측 결과에 대해 XAI 분석 결과를 종합하여, 공정 전반에 걸친 품질에 대한 IMC 영향을 분석할 수 있다. Fig. 3은 각 품질에 대하여 공정 전반에 걸친 IMC 프로파일 특성의 영향도를 나타낸다. Fig. 3(a)~(c)의 왼쪽 그래프의 SHAP 값 1개의 점은 앞서 확인한 특정 제품 및 품질에 대한 각 IMC 프로파일 특성의 제품 품질에 대한 영향도를 나타낸다. 시험한 공정 전반에 걸쳐서 IMC 프로파일 특성의 분포는 색상으로 표현되어 있으며, 특성의 분포에 따른 품질에 대한 영향도는 SHAP 값의 분포로 나타난다. 따라서 SHAP 값의 분포가 큰 IMC 프로파일 특성일수록 공정 전반에 걸쳐 해당 품질에 대한 영향도가 높음을 의미한다. Fig. 3(a)~(c)의 오른쪽 그래프는 이를 간단하게 나타낸 결과이며, 도시된 값은 각 IMC 프로파일 특성의 기여도의 절대값 평균의 상대적인 차이를 의미한다. 즉, 표현된 값이 클수록 해당 특성이 다른 특성보다 품질에 영향도가 높음을 의미한다. Fig. 3의 결과는 각 품질별로 AI 모델 1개씩의 설명 결과이다. AI 및 ML의 확률론적 특성을 고려하기 위하여 각 품질별로 20개 AI 모델의 분석 결

과를 종합하고, 주된 영향을 미치는 IMC 프로파일 특성 5개의 상대적 영향도를 나타내면 Fig. 4와 같다.

다양한 공정 조건에서의 제품 중량에 전반적으로 영향을 미치는 IMC 프로파일 특성, Fig. 4(a)는 P4-P5, P5-P6 구간의 시간차, 초기 온도 (T_T1), P2-P3 구간의 압력차, 그리고 T1-T2 구간의 온도차이다. 이는 제품 중량을 제어함에 있어서 보압구간부터의 압력 유지시간과 보압크기, 그리고 초기 금형 온도와 용융수지 유입에 의한 금형 온도 상승량이 중요하다는 것을 뜻한다. 따라서 해당 제품의 사출성형 공정을 설정하고 품질을 관리하기 위해서는 보압과정, 냉각수 온도가 중요하며, 금형 온도 상승에 영향을 주는 용융수지의 온도 또한 중요하다고 판단할 수 있다.

측면에서의 변형에 전반적으로 영향을 미치는 주요 IMC 프로파일 특성은 Fig. 4(b), (c)에 나타난대로 유사하였다. P4-P5, P5-P6 구간의 시간차, P2-P3 구간의 압력차, 초기 온도(T_T1), 그리고 T2-T3 구간의 시간차이가 주된 영향을 보였다. 이는 대상 제품의 측면 변형량을 제어함에 있어서 보압구간부터의 압력유지시간, 보압크기, 초기 금형 온도, 그리고 냉각 속도가 중요하다는 것을 뜻한다. 그러나 두 측면에서의 각 IMC 프로파일 특성의 영향도는 상이한 특성을 나타내었다.

4. 고찰

제안한 방법론은 IMC 프로파일의 제품 품질에 대한 영향도를 분석하는데 유용하다. 공정 조건을 수정해가면서 변화하는 IMC 프로파일과 제품 품질의 연관관계를 수동적으로 찾지 않더라도, IMC 프로파일이 제품 품질에 대한 영향을 객관적으로 분석할 수 있다. 이 과정에서, IMC 프로파일 특성은 시계열 데이터 프로파일의 형상에 기반한 분할 알고리즘을 통해 기계적으로 추출하고, 해당 특성과 제품 품질간의 연관관계는 AI 모델이 찾아내며, 결과적으로 AI 모델이 찾아낸 연관관계를 분석한다. 따라서, 분석 과정에서 개인의 사전 지식, 이해의 차이와 주관이 개입할 여지가 적다는 이점이 있다.

공정 조건이 제품 품질에 미치는 영향을 분석하는데 IMC 프로

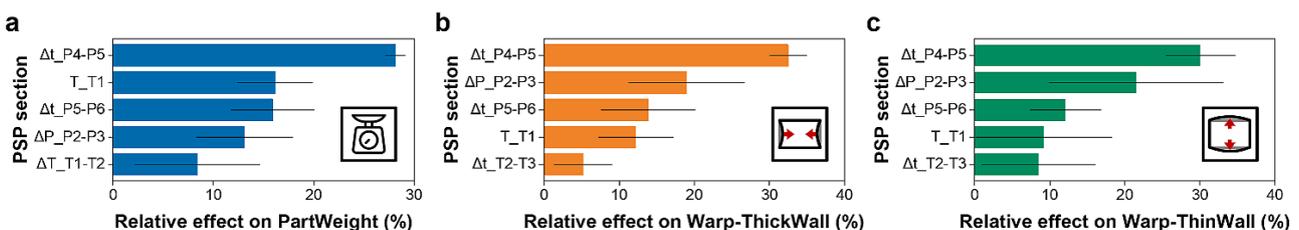


Fig. 4 Man influential IMC features on each quality of overall process. (a) Part weight, (b) warpage at thick wall, and (c) warpage at thin wall.

파일의 형상에 기반한 특성을 활용하기 때문에, 캐비티 내에서 시간에 따른 조건의 품질에 대한 영향을 구체적으로 분석할 수 있다. 따라서, 사출성형 공정의 충전-보압-냉각-취출 과정에서 제품 특성에 주된 영향을 미치는 공정 단계를 판단할 수 있다. 또한, IMC 프로파일 특성을 정의하는 PSP는 상이한 IMC 프로파일들의 유사성을 반영하고 있기 때문에, 특정 공정 조건의 특정 시점에 대한 영향도만을 분석하는 것이 아니라, 다양한 공정 조건의 IMC 프로파일을 종합적으로 분석할 수 있다.

IMC 프로파일의 품질에 대한 영향도 분석은 특정 제품/품질에 대한 분석과 공정 전반에 걸친 분석으로 나눌 수 있다. 특정 제품/품질에 대한 분석 결과는 해당 품질의 생성 원인을 구체적으로 제시한다. 또한 해당 분석 결과는 사출성형 공정에 대한 통상적인 지식에 부합하였다. 따라서 공정에 대한 지식과 경험이 부족한 경우, 분석 결과를 통하여 현재 사출성형 공정을 이해하는데 도움을 얻을 수 있을 것으로 판단된다.

보다 구체적인 분석을 위해서는 공정 전반에 대한 분석결과(Fig. 3 및 Fig. 4)와 함께 특정 제품/품질에 대한 분석결과(Fig. 2)를 같이 고려해야 한다. 예를 들어, 공정 전반에 대한 분석결과에서 두꺼운 측면과 얇은 측면에서의 변형에 주된 영향을 미치는 IMC 프로파일 특징이 유사하였다. 그러나, 두 측면에서의 변형이 최소인 제품과 공정을 분석한 결과, Fig. 3(d), (g)에서는 각 특징의 기여도가 상이하였다. 두꺼운 측면의 경우 전반적으로 변형이 -2.10 mm (base value)가 발생하는데, 해당 조건에서 대부분의 특성이 양의 기여를 함으로써 변형이 최소가 되었다. 이와 대조적으로, 얇은 측면의 경우에는 각 특성의 기여도가 서로 상쇄되는 방향으로 작용하여 변형이 최소가 되었다. 따라서, 구체적인 품질에 대한 IMC 프로파일의 영향도를 분석하는데에는 특정 제품/품질에 대한 분석 결과를 활용해야 하며, 변동하는 상황 등을 모니터링 하는 등의 목적에는 공정 전반에 대한 분석 결과를 활용해야 한다.

공정 전반에 대한 IMC 프로파일 특성의 영향도 분석 결과는, 제품 품질에 대한 영향도에 입각한 공정 모니터링 전략을 확립하는데 활용할 수 있다^[26]. 예를 들어 제품 중량의 일관성을 높이기 위한 모니터링 전략을 세우는 경우, P4-P5 구간의 시간차이를 타 PSP로 정의되는 구간의 시간차이보다 엄격히 관리해야 한다. 왜냐하면 해당 구간의 시간차이가 IMC 프로파일에서 타 구간의 시간 또는 압력/온도 차이보다 큰 영향도를 나타내기 때문이다.

또한 상이한 제품 품질을 동시에 관리하기 위한 다목적 모니터링 전략을 확립하는데도, 공정 전반에 대한 IMC 프로파일 특성의 영향도 분석 결과를 활용할 수 있다. 예를 들어 제품 중량의 경우, 두 측면에서의 변형량보다 초기 금형 온도의 영향을 많이 받는 것으로 분석되었다. 이는, 제품 중량을 관리하는 목적에 있어서 초기

금형 온도를 더 면밀히 모니터링해야 함을 의미한다. 반대로 측면 변형을 관리하는 목적에서는 P2-P3 구간의 압력차이를 면밀히 모니터링해야 한다.

공정 및 품질 최적화의 효율성을 높이기 위한 방안으로, 영향도가 높은 IMC 프로파일을 중점적으로 제어하기 위한 공정 변수를 선정하는 전략을 구상할 수 있을 것으로 판단된다. 사출성형 공정에 대한 이해가 깊은 엔지니어 또는 연구자의 경우에는 각 공정 변수에 의한 IMC 프로파일의 변화에 대한 연관관계를 이해하고 있으므로, 분석 결과를 토대로 직관적으로 공정을 수정할 수 있을 것이라 생각된다. 그렇지 않은 경우, 공정 변수와 IMC 프로파일 사이의 연관관계를 학습한 AI 모델을 함께 구축하여 공정 최적화에 활용할 수 있을 것으로 기대한다.

5. 결 론

사출성형 공정에서 캐비티 내 성형조건(in-mold condition, IMC)은 제품 품질에 관련성이 매우 높은 정보이며, 그 중요성으로 인하여 공정을 분석하고 최적화하는데 IMC가 활용되고 있다. IMC를 공정 모니터링, 최적화 및 제어에 활용하기 위해서는 IMC와 제품 품질 사이의 연관관계와 영향도를 분석할 필요가 있다. 그러나, 기존에 제시되어온 분석 방법은 공정에 대한 사전 지식과 이해에 대한 의존성이 높으며, 이와 개인의 주관통하여 IMC 프로파일의 특징(feature)을 선정하고, 단편적인 선형 관계만을 활용한다는 한계가 있어왔다. 이러한 한계를 극복하고자 본 연구에서는 설명가능 인공지능(explainable artificial intelligence, XAI)를 활용하여 IMC의 제품 품질에 대한 영향도를 분석하는 방법을 제안하였다.

제안한 분석 방법은 시계열 데이터 프로파일의 형상에 기반한 분할 알고리즘을 활용함으로써 기계적으로 IMC 프로파일에서 특징을 추출한다. 추출된 IMC 프로파일 특징과 사출성형 제품 품질의 연관관계를 AI 모델로 학습시킨다. 학습된 AI 모델의 예측을 XAI를 활용하여 분석하여 IMC 프로파일 특징의 품질에 대한 기여도를 정량적으로 분석한다. 각 예측의 분석 결과를 종합함으로써, 공정 전반에 걸쳐 IMC 프로파일의 특징의 영향도를 분석한다. AI 모델의 예측 결과에 대한 분석은 특정 제품/품질에 대한 이유를 제시하며, 이를 종합한 결과는 다양한 공정 조건을 포괄하는 설명을 제공한다.

제안한 방법론의 적용 결과는, 제품 품질에 주된 영향을 미치는 IMC 프로파일 특징을 그 영향도에 따라서 엄격히 관리함으로써, 제품 품질을 관리하기 위한 구체적인 공정 모니터링 전략을 세우는데 활용될 수 있다. 또한, 다양한 제품 품질을 동시에 관리하기 위하여 각 품질별로 상이한 모니터링 전략을 확립하는데 응용될

수 있다. IMC 프로파일 특징의 각 영향도에 따라서 공정 최적화 전략을 가중하여 적용함으로써, 보다 효율적으로 품질을 최적화하는 방법 또한 고안될 수 있을 것이다.

보다 넓은 측면에서, 본 연구에서 제안하는 방법론은 데이터와 AI에 기반한 공정 분석, 최적화 및 제어에 기여하며, 결과적으로 자율제조 기술 개발에 활용될 수 있을 것이라 기대한다.

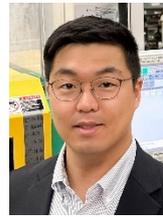
후 기

본 연구는 한국생산기술연구원 기본사업 “웹토초 레이저를 활용한 20 um 급 위치 제어 기반 고정밀 렌즈 사출성형 기술 개발 (KITECH UR240031)”의 지원으로 수행한 연구입니다.

References

- [1] Collins, C., 1999, Monitoring Cavity Pressure Perfects Injection Molding, *Assem. Autom.*, 19:3 197-202, <https://doi.org/10.1108/01445159910280056>.
- [2] Menges, G., Michaeli, W., Mohren, P., 2001, *How to Make Injection Molds*(3rd edition), Carl Hanser Verlag, USA.
- [3] Kazmer, D. O., 1995, *Dynamic Feed Control: A New Method for Injection Molding of High Quality Plastic Parts*, Doctorate Thesis, Stanford University, USA.
- [4] Huang, M.-S., Ke, K.-C., Liu, C.-Y., 2021, Cavity Pressure Based Holding Pressure Adjustment for Enhancing the Consistency of Injection Molding Quality, *J. Appl. Polym. Sci.*, 138:18 50357, <https://doi.org/10.1002/app.50357>.
- [5] Hassan, H., 2013, An Experimental Work on the Effect of Injection Molding Parameters on the Cavity Pressure and Product Weight, *Int. J. Adv. Manuf. Technol.*, 67 675-686, <https://doi.org/10.1007/s00170-012-4514-4>.
- [6] Gim, J.-S., Tae, J.-S., Jeon, J.-H., Choi, J.-H., Rhee, B.-O., 2015, Detection Method of Filling Imbalance in a Multi-cavity Mold for Small Lens, *Int. J. Precis. Eng. Manuf.*, 16:3 531-535, <https://doi.org/10.1007/s12541-015-0072-7>.
- [7] Kim, B., Gim, J., Han, E., Rhee, B., 2021, Development of the Vent Clogging Monitoring Methods for Injection Molding, *CIRP J. Manuf. Sci. Technol.*, 32 277-286, <https://doi.org/10.1016/j.cirpj.2021.01.009>.
- [8] Guan, W.-S., Huang, H.-X., 2013, A Proposed Technique to Acquire Cavity Pressure Using a Surface Strain Sensor During Injection-Compression Molding, *J. Manuf. Sci. Eng.*, 135:2 021003, <https://doi.org/10.1115/1.4023376>.
- [9] Román, A. J., Qin, S., Zavala, V. M., Osswald, T. A., 2021, Neural Network Feature and Architecture Optimization for Injection Molding Surface Defect Prediction of Model Polypropylene, *Polym. Eng. Sci.*, 61:9 2376-2387, <https://doi.org/10.1002/pen.25765>.
- [10] Lockner, Y., Hopmann, C., Zhao, W., 2022, Transfer Learning with Artificial Neural Networks Between Injection Molding Processes and Different Polymer Materials, *J. Manuf. Process.*, 73 395-408, <https://doi.org/10.1016/j.jmapro.2021.11.014>.
- [11] Jeon, J., Rhee, B., Gim, J., 2022, Melt Temperature Estimation by Machine Learning Model Based on Energy Flow in Injection Molding, *Polymers*, 14:24 5548, <https://doi.org/10.3390/polym14245548>.
- [12] Lin, C. Y., Gim, J., Shotwell, D., Lin, M.-T., Liu, J.-H., Turng, L.-S., 2024, Explainable artificial intelligence and multi-stage transfer learning for injection molding quality prediction, *J. Intell. Manuf.*, 1-20, <https://doi.org/10.1007/s10845-024-02436-w>.
- [13] Farahani, S., Xu, B., Filipi, Z., Pilla, S., 2021, A Machine Learning Approach to Quality Monitoring of Injection Molding Process using Regression Models, *Int. J. Comput. Integr. Manuf.*, 34:11 1223-1236, <https://doi.org/10.1080/0951192X.2021.1963485>.
- [14] Wang, Z. H., Wen, F. C., Li, Y. T., Tsou, H. H., 2023, A Novel Sensing Feature Extraction Based on Mold Temperature and Melt Pressure for Plastic Injection Molding Quality Assessment, *IEEE Sensors Journal*, 23:7 7451-7459, <https://doi.org/10.1109/JSEN.2023.3247597>.
- [15] Rønsch, G. Ø., Kulahci, M., Dybdahl, M., 2021, An Investigation of the Utilisation of Different data Sources in Manufacturing with Application in Injection Moulding, *Int. J. Prod. Res.*, 59:16 4851-4868, <https://doi.org/10.1080/00207543.2021.1893853>.
- [16] Kramschuster, A., Cavitt, R., Ermer, D., Chen, Z., Turng, L.-S., 2005, Quantitative Study of Shrinkage and Warpage Behavior for Microcellular and Conventional Injection Molding, *Polym. Eng. Sci.*, 45:10 1408-1418, <https://doi.org/10.1002/pen.20410>.
- [17] Fu, T.-C., Hung, Y.-K., Chung, F.-I., 2017, Improvement Algorithms of Perceptually Important Point Identification for Time Series Data Mining, *IEEE 4th International Conference on Soft Computing & Machine Intelligence (ISCMI)*, 11-15, <https://doi.org/10.1109/ISCMI.2017.8279589>.

- [18] Gim, J, Rhee, B., 2021, Novel Analysis Methodology of Cavity Pressure Profiles in Injection-molding Processes using Interpretation of Machine Learning Model, *Polymers*, 13:19 3297, <https://doi.org/10.3390/polym13193297>.
- [19] Gim, J., Turng, L.-S., 2023, Interpretation of the Effect of Transient Process Data on Part Quality of Injection Molding based on Explainable Artificial Intelligence, *Int. J. Prod. Res.*, 61:23 8192-8212, <https://doi.org/10.1080/00207543.2023.2216310>.
- [20] Colas, C., Sigaud, O., Oudeyer, P.-Y., 2018, How Many Random Seeds? Statistical Power Analysis in Deep Reinforcement Learning Experiments, *arXiv preprint arXiv:1806.08295*, <https://doi.org/10.48550/arXiv.1806.08295>.
- [21] Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., Lee, S.-I., 2020, From Local Explanations to Global Understanding with Explainable AI for Trees, *Nat. Mach. Intell.*, 2 56-67, <https://doi.org/10.1038/s42256-019-0138-9>.
- [22] Chang, H., Su, Z., Lu, S., Zhang, G., 2022, Application of Deep Learning Network in Bumper Warpage Quality Improvement Processes, 10:5 1006, <https://doi.org/10.3390/pr10051006>.
- [23] Chen, J.-Y., Tseng, C.-C., Huang, M.-S., 2019, Quality Indexes Design for Online Monitoring Polymer Injection Molding, *Adv. Polym. Technol.*, 2019:1 3720127, <https://doi.org/10.1155/2019/3720127>.
- [24] Ke, K.-C., Huang, M.-S., 2020, Quality Prediction for Injection Molding by Using a Multilayer Perceptron Neural Network, *Polymers*, 12:8 1812, <https://doi.org/10.3390/polym12081812>.
- [25] Párizs, R. D., Török, D., Ageyeva, T., Kovács, J. G., 2022, Machine Learning in Injection Molding: An Industry 4.0 Method of Quality Prediction, *Sensors*, 22:7 2704, <https://doi.org/10.3390/s22072704>.
- [26] Rhee, B., Gim, J, 2023, Monitoring Apparatus using Sensor Signal in Injection Mold and Method Thereof, KR Patent: 10-2500376.



Jinsu Gim

Senior Researcher, Korea Institute of Industrial Technology (KITECH). His research interests are Autonomous Manufacturing for Polymer/Plastic Industry, Rheology, and Mold Technology. E-mail: jgim@kitech.re.kr



Chung-Yin Lin

Research Assistant (Ph.D. Candidate), Department of Mechanical Engineering, University of Wisconsin-Madison. His research interests are Artificial Intelligence for Polymer Processing, Polymer Composites, and CAE. E-mail: clin349@wisc.edu



Lih-Sheng (Tom) Turng

Professor, Department of Mechanical Engineering, University of Wisconsin-Madison. His research interests are Injection Molding, Microcellular Injection Molding, Nanocomposites, Multi-functional Materials, Bio-based Polymers, Tissue Engineering, and Bio-manufacturing. E-mail: turng@engr.wisc.edu