

박사학위논문

CAE 및 머신러닝 기법을 활용한 사출
성형 최적화에 관한 연구

2021년

한 성 대 학 교 대 학 원

스마트융합건설팅학과

스마트융합제품전공

황 순 환

박 사 학 위 논 문
지도교수 이후진

CAE 및 머신러닝 기법을 활용한 사출 성형 최적화에 관한 연구

A Study on the Optimization of Injection Molding
Using CAE and Machine Learning Technique

2021년 6월 일

한 성 대 학 교 대 학 원

스마트융합컨설팅학과

스마트융합제품전공

황 순 환

박 사 학 위 논 문
지도교수 이후진

CAE 및 머신러닝 기법을 활용한 사출 성형 최적화에 관한 연구

A Study on the Optimization of Injection Molding
Using CAE and Machine Learning Technique

위 논문을 공학 박사학위논문으로 제출함

2021년 6월 일

한 성 대 학 교 대 학 원

스마트융합컨설팅학과

스마트융합제품 전공

황 순 환

황순환의 공학 박사학위논문을 인준함

2021년 6월 일

심 사 위 원 _____(인)

심 사 위 원 _____(인)

심 사 위 원 _____(인)

심 사 위 원 _____(인)

심 사 위 원 _____(인)

국 문 초 록

CAE 및 머신러닝 기법을 활용한 사출 성형 최적화에 관한 연구

한 성 대 학 교 대 학 원
스 마 트 융 합 컨 설 팅 학 과
제 품 전 공
황 순 환

일반적인 제조 프로세스는 아이디어-컨셉-설계-제조-판매로 이어진다. 이 프로세스를 더 빠르게 완료하고, 품질을 높일수록 더 많은 이익을 얻을 수 있다. 따라서 각 단계의 납기와 품질을 높이기 위한 혁신적인 프로세스 개발을 위해 시간과 자금을 투자하는 것으로 기업은 경쟁력을 강화하고 있다. 그러나 오늘날 빅데이터, 데이터 사이언스, 클라우드 컴퓨팅, 모바일 및 소셜 네트워크, 협업 경쟁력과 같은 기술 트렌드는 더 나은 의사결정 시스템과 최적화된 프로세스를 요구하고 있다. 컨셉은 개인의 취향에 맞추어야 더 많은 프리미엄을 받고, 설계는 협업을 통해 빠르고 정밀하며 혁신적인 제품을 만들어야 하며, 제조는 3D 프린터와 같이 유연한 생산 형태로 점차 변화하고 있고, 판매 후 모바일과 웹을 통해 사용자의 경험이 실시간으로 소통되면서 이후 판매에 직접적인 영향력으로 작용하고 있다. 그래서 품질 문제가 발생하면 기업은 제품 리콜로 인한 시간과 비용과 같은 단기적인 영향뿐 아니라 브랜드, 시장 점유율, 주가와 같은 장기적인 영

향을 미친다. 이러한 품질 문제를 해소하기 위해 제조 전 설계를 검증하기 위한 방법론 즉, 설계와 제조를 융합하는 기술이 CAE(Computer Aided Engineering: 컴퓨터 응용 공학)이다. 제조를 고려한 설계는 제조 현장에서 발생하는 시행착오를 미리 시뮬레이션에서 검증하여 개선할 수 있어 높은 품질을 짧은 납기로 제조할 수 있다.

사출 성형 공정은 복잡한 구조 형상과 여러 기능을 구현할 수 있으며, 아름다운 외관 처리 및 대량생산까지 가능하기 때문에, 다양한 분야에서 활용되고 있다. 그러나 혁신적인 제품을 구현하기 위한 프로세스는 복잡하고 정밀성을 요구하고 있어 성형가능구간이 좁고, 변수가 많아 성형하기가 까다롭다. 또한 강도를 높이기 위해 플라스틱 소재에 탄소 섬유나 유리 섬유를 첨가제로 사용하면서 뒤틀림과 같은 휨 변형으로 인한 치수 불량에 발생된다. 이러한 불량의 원인을 제조 전에 예측하고 개선하는 것이 CAE의 목표이다.

과거의 CAE는 제조 환경을 모사하는 소프트웨어의 많은 가정으로 인한 한계, 물성 측정 기술의 부족, 낮은 컴퓨터 성능으로 인한 메시(Mesh) 숫자와 실험 회수 부족으로 제한된 환경으로 정성적인 예측 즉, 경향성을 파악하는 수준에 머물러 왔다. 여기서 목표는 최소한의 실험으로 최대의 효과를 얻는 것이며, 정밀성에 필요한 정량적인 예측의 신뢰성에 문제가 제기되어 왔다. 그러나 2021년을 기준으로 사출 성형 CAE는 40년 넘게 제조 환경을 모사할 수 있는 소프트웨어가 업그레이드되고 있으며, 다양한 상황을 고려한 플라스틱 유변 물성 측정 기술을 확보하였고, 매년 수많은 물성이 측정되고 있다. 급격히 성장한 컴퓨터 성능으로 인하여 메시 제한 수준이 확장되고 많은 실험을 통한 통계적 접근이 가능하여, CAE 적확성을 확보할 수 있는 기반 기술이 발전되었다.

본 연구는 실제 사출 성형 공정과 CAE 예측의 편차가 발생하는 원인을 제시하고, CAE 적확성을 향상하기 위한 방법론과 실제 적용 사례를 나타내었다. 또한, 산업 현장과 학계에서 널리 사용하는 사출 유동 거리 검증을 위한 스파이럴(Spiral: 모기향 모양의 나선형) 금형의 형상 특성이 유동 거동에 미치는 영향을 조사하여 유동 거리 대표성에 문제가 없는지 확인하고자 하였다. 이를 위해 스파이럴의 폭 변화 및 막대(Bar) 형상과 판(Plate) 형상의 유동

거리를 비교하였다. 그리고 수지의 유변 물성을 평가하고 개선하는 방법을 제시하였다. 이러한 방법론을 활용하여 실제 사출 제품을 실험한 결과와 CAE 예측 결과를 비교하였으며 정확성 개선 방법을 도출하였다. 복합재료 사출 최적화 검토를 위해 유리 섬유가 30% 포함된 나일론수지(PA66+GF30%)를 활용한 라디에이터 탱크 제품의 사출 성형 조건 변화에 따른 사출압력, 형체력, 변형결과를 CAE로 데이터를 취출하여 ANN(Artificial Neural Networks: 인공신경망)으로 알려진 MLP(Multi-layer Perceptron: 다층퍼셉트론)를 적용하여 예측 모델링을 만들었으며, HMA(Hybrid Metaheuristic Algorithm: 하이브리드 메타휴리스틱 알고리즘)를 활용하여 구속조건을 만족하는 최적의 사출 성형 조건을 도출하였다. MLP는 예측 성능은 우수하지만 결정 과정에 대한 설명이 부족하기 때문에 Decision-tree(의사결정나무)를 이용하여 최적의 사출 조건을 위한 분류 기준과 복잡성의 변화에 따른 예측 성능을 평가하였다.

본 연구의 성과로 사출 성형 CAE 정확성 검증 방법은 해석 결과에 따른 검증, 해석 절차에 따른 검증, 해석 단계에 따른 검증 방법이 있음을 제시하였으며, 유동 거리 검증 모델로 사용되고 있는 스파이럴 형상의 특수성으로 인하여 막대 형상보다 28% 잘 흐르고, 판 형상보다 82% 잘 흐름을 확인하였다. CAE를 위한 수지 물성 측정 신뢰성이 낮은 물성을 편집하고 공정 조건 입력 개선으로 사출 압력 예측 오차율을 5% 이내로 개선이 가능함을 확인하였다. 라디에이터 탱크 제품의 Flash(플래시) 불량이 발생하지 않는 구속조건을 만족하면서 휨 변형 최소화를 위한 사출 공정 조건 최적화를 시도하였다. 결과적으로 108회 CAE를 진행하여 최적화된 휨 결과는 4.25mm, MLP와 HMA를 추가로 적용 시 3.68mm로 CAE만 적용한 결과 대비 0.57mm가 줄어들어 약 13.4% 개선되었다. 이를 다시 CAE에 적용하여 신뢰도를 평가한 결과 사출압력은 99.7%, 형체력은 99.78%, 휨 변형은 94.72%의 예측 성능을 보였다.

【주제어】 Computer Aided Engineering(컴퓨터 응용 공학), Injection Molding(사출 성형), Flow Analysis(유동 해석), Verification(검증), Artificial Neural Networks(인공신경망), Decision-tree(의사결정나무)

목 차

제 1 장 서 론	1
제 1 절 연구 배경	1
제 2 절 연구의 필요성	4
제 3 절 연구의 범위와 목적	9
제 2 장 이론적 배경 및 선행 연구	11
제 1 절 사출 성형 CAE의 선행연구	11
1) 사출 성형 CAE 초기 연구(1970~1980년대)	11
2) 사출 성형 CAE 중기 연구(1990~2000년대)	14
3) 사출 성형 CAE 최근 요구사항	15
제 2 절 사출 성형 CAE를 위한 수지 물성 측정 연구	18
1) CAE를 위한 수지 물성 품질	18
2) CAE를 위한 수지 측정 범위	18
3) 수지측정 방법 및 설명	19
제 3 절 사출 성형 CAE 메커니즘 이해	25
1) 유동 및 변형 CAE 메커니즘	25
2) 배향 편차(Differential Orientation)	27
3) 수축 편차(Differential Shrinkage)	30
4) 금형 온도 편차(Differential Cooling)	31
5) 결정화 편차(Differential Crystallization)	32
6) 코너효과(Corner Effect)	33
7) 변형을 줄이기 위한 방법	33
제 3 장 사출 성형 CAE 정확성 개선 연구	35
제 1 절 사출 성형 CAE 정확성 연구	35
1) 정확성 정의	35
2) 사출 성형 CAE 작업 순서 및 주요 인자	35

3) 제품 형상 복제	38
4) 사출 속도 복제	39
5) 보압 복제	43
6) 종횡비에 따른 해석 속도 및 유동 해석 결과 비교	47
7) 메시 타입에 따른 CAE 결과 비교	50
8) 금형 형상 복제	52
9) 코어 쉬프트에 따른 충전 결과 비교	57
10) 미성형 예측을 위한 메시 크기 결정	60
제 2 절 스파이럴 금형의 형상 검증 및 CAE 적확성 개선 연구	64
1) 스파이럴 금형을 활용한 유동 거리 예측 선행연구 검토	64
2) 유동성 비교 모델	65
3) 플라스틱 수지 그레이드와 성형 조건	68
4) 스파이럴 금형의 사출 유량에 따른 중량 비교	68
5) 막대 및 판상 형상 금형의 사출 유량 별 중량 비교	72
6) 압력의존성계수 D3를 활용한 유동 거리 개선	77
7) 영점 점도 수정 계수 D1을 활용한 유동 거리 개선	82
8) 영점 점도 측정 후 결과 비교	84
제 3 절 에어백 커버 제품 사출 압력 예측 개선에 관한 연구	92
1) 사출 압력 예측 검증 개요	92
2) 성형구간 해석(Molding Window)	97
3) 유동 해석 파라메트릭 연구	99
4) 유동 해석 DOE	101
5) 냉각 해석	105
6) 시험 사출 후 초기 CAE 결과와 사출 압력 비교	107
7) CAE 적확성 개선을 위한 수지 물성 및 사출 조건 검토	115
8) 개선된 CAE 사출 압력 결과	118
제 4 장 CAE 데이터 기반 머신러닝 모델 생성 및 최적화 연구	121
제 1 절 CAE 및 MLP를 이용한 힘 예측 및 공정 최적화 연구	121
1) CAE를 통한 데이터 축적과 MLP를 이용한 예측 모델 생성	121
2) 연구 방법	122

3) 역설계 공학	123
4) 라디에이터 탱크 제품 연구	124
5) 라디에이터 탱크 플라스틱 물성	127
6) 라디에이터 탱크 데이터 생성 및 분석	128
7) MLP(Multi-layer Perceptron) 알고리즘 이해	139
8) 머신러닝 학습모델 생성 및 비교	140
9) HMA(Hybrid Metaheuristic Algorithm)를 이용한 최적화	148
10) 실험결과 및 고찰	151
제 2 절 CAE 및 Decision-tree를 이용한 설명 가능한 사출 공정 최적화 연구	152
1) Decision-tree 기법의 필요성	152
2) 연구 방법	153
3) Decision-tree 모델 생성	154
4) 머신러닝 학습모델 생성 및 비교	155
5) Decision-tree 모델을 이용한 최적 사출 조건	157
6) 실험결과 및 고찰	163
제 5 장 결 론	165
참 고 문 헌	168
ABSTRACT	175

표 목 차

[표 1-1] 사출 성형 CAE 변수	6
[표 3-1] 메시 개수와 종횡비에 따른 해석 시간 비교	49
[표 3-2] 폭 15mm 스파이럴 모델 메시의 개수	66
[표 3-3] 사출 성형 CAE를 위한 공정조건	68
[표 3-4] 메시 타입에 따른 폭 15mm 스파이럴 중량 비교	71
[표 3-5] 메시 타입에 따른 폭 23mm 스파이럴 중량 비교	72
[표 3-6] 메시 타입에 따른 막대와 판 형상 중량 비교	73
[표 3-7] 형상 변화에 따른 유동길이 비교	75
[표 3-8] 에어백 커버 제품 메시 및 모델링 정보	93
[표 3-9] ASA LI912 사출 시간 변화에 따른 유동 해석 결과 비교	100
[표 3-10] ASA LI941 사출 시간 변화에 따른 유동 해석 결과 비교	100
[표 4-1] 사출 성형 공정 변수	129
[표 4-2] 직교 배열(Orthogonal Array) L108 Case 실험	129
[표 4-3] 직교 배열에 따른 L108 Case 실험 결과	130
[표 4-4] CAE 결과 비교	136
[표 4-5] HMA 최적화 결과 요약	148
[표 4-6] 기존 CAE 결과와 HMA 최적화 비교	149
[표 4-7] Decision-tree를 이용한 최적의 사출 조건 비교	163

그 립 목 차

[그림 1-1] 세계 재료 별 소비량	1
[그림 1-2] 해석 결과/절차/단계에 따른 다양한 검증 방법	7
[그림 2-1] Hele-Shaw(헬레-쇼) 모델이 설명하는 유동 개략도	12
[그림 2-2] 유동 및 변형 해석을 위한 복잡한 프로세스	25
[그림 2-3] 평판의 섬유 배향	28
[그림 2-4] 중심 게이트 형상의 섬유 배향	28
[그림 2-5] 평판의 섬유 배향(좌), 중심 게이트 섬유 배향(우) 사례	29
[그림 2-6] 두께 편차 및 게이트 위치에 따른 체적 수축 및 휨 결과	31
[그림 2-7] 상·하측 금형 온도 편차에 의한 휨 메커니즘	32
[그림 2-8] 변형을 줄이기 위한 방법	34
[그림 3-1] 사출 성형 CAE 해석 순서	36
[그림 3-2] 사출 성형 CAE 정확성 주요 인자	37
[그림 3-3] 메시 타입 설명	39
[그림 3-4] 두께 - 속도 - 압력 유동비 반응 표면 결과	40
[그림 3-5] 초기 유동 해석 결과	41
[그림 3-6] 정확성 개선한 유사한 해석 결과	41
[그림 3-7] 사출기 공정 설정 및 출력 그래프 결과 비교	42
[그림 3-8] 카드 시편 휨 측정 결과	44
[그림 3-9] 사출 성형 CAE 좌굴 모드 형상 결과	44
[그림 3-10] 초기 사출 성형 CAE 결과와 실제 휨 방향 비교	45
[그림 3-11] 공정 조건1(미성형), 2(저보압), 3(적정보압), 4(과보압)	45
[그림 3-12] 보압 변화에 따른 평균 체적 수축 결과 비교	46
[그림 3-13] 보압 변화에 따른 휨 변형 결과 비교	46
[그림 3-14] 개선된 사출 성형 CAE 결과와 실제 휨 방향 비교	47
[그림 3-15] 메시 타입에 따른 종횡비	48
[그림 3-16] 메시 조밀도에 따른 종횡비 비교 Case1(좌), Case2(우)	49
[그림 3-17] 종횡비에 따른 결과 비교, Case1(좌), Case2(우)	50
[그림 3-18] 바닥에 짧은 리브가 다수 설치된 제품	51

[그림 3-19] 듀얼 도메인 메시 적용 시 두께 인식 결과	51
[그림 3-20] 메시 타입에 따른 변형 결과 비교, Dual(좌), 3D(우)	52
[그림 3-21] 2단 금형의 구조	53
[그림 3-22] 3단 금형의 구조	53
[그림 3-23] 2단 금형의 사이드 게이트 구조	54
[그림 3-24] 3단 금형의 핀 포인트 게이트 구조	54
[그림 3-25] 핫러너 구조	55
[그림 3-26] 핫러너 매니폴드 및 형상적응형 냉각 메시 구현 사례	56
[그림 3-27] 핫러너 매니폴드 및 형상적응형 냉각 해석 결과	56
[그림 3-28] 중심 부분의 두께가 얇고 코어가 깊은 제품	57
[그림 3-29] 중심 부분의 두께가 얇고 코어가 깊은 제품	58
[그림 3-30] 코어 쉬프트를 고려하지 않은 유동 해석 결과	58
[그림 3-31] 코어 쉬프트를 고려한 유동 해석 결과	59
[그림 3-32] 코어 쉬프트에 의한 코어 힘 결과	60
[그림 3-33] 33,727개 메시(좌), 158,700개 메시(우)	61
[그림 3-34] 메시 변화에 따른 충전 결과 비교(4.4초일 때)	62
[그림 3-35] 메시 변화에 따른 충전 결과 비교(5.6초일 때)	62
[그림 3-36] 메시 변화에 따른 평균온도 결과 비교(약 6초일 때)	63
[그림 3-37] 메시 변화에 따른 평균온도 결과 비교(약 7.9초일 때)	63
[그림 3-38] 2mm 두께 스파이럴, 폭 15mm(좌), 폭 23mm(우)	65
[그림 3-39] 메시 타입 비교 : (a) 듀얼 도메인 (b) 3D 메시 6 레이어 (b) 3D 메시 10 레이어 (b) 3D 메시 20 레이어	66
[그림 3-40] 스파이럴과 비교 디자인 : 막대(a), 판(b)	67
[그림 3-41] 충전 해석 결과 : (a) 3D, (b) 듀얼 도메인	69
[그림 3-42] 폭 15mm 스파이럴 유동 거리 예측 결과(듀얼 도메인)	70
[그림 3-43] 폭 23mm 스파이럴 유동 거리 예측 결과(듀얼 도메인)	71
[그림 3-44] 막대 형상 유동 거리 예측 결과	73
[그림 3-45] 판 형상의 충전 해석 결과	74
[그림 3-46] 형상 변화에 따른 유동 거리 비교	76

[그림 3-47] 스파이럴 형상 폭 변화에 따른 Bulk temperature 비교	76
[그림 3-48] 사출실험과 CAE 중량 비교(18가지 사출 조건 변경)	78
[그림 3-49] 압력의존성계수 추가로 CAE 적확성 개선	78
[그림 3-50] 특정 조건에서는 실험과 CAE 차이 발생	79
[그림 3-51] 압력의존성계수 D3를 적용한 수지의 160MPa일 때 점도	79
[그림 3-52] 압력의존성계수 D3를 적용한 수지의 0MPa일 때 점도	80
[그림 3-53] LUPOY EU5000W의 160MPa일 때 점도	81
[그림 3-54] LUPOY EU5000W의 0MPa일 때 점도	81
[그림 3-55] LUPOY EU5000W 물성을 이용한 CAE 추가 비교 결과	82
[그림 3-56] 기존 물성에 D3를 수정한 Cross-WLF 점도 모델 계수	83
[그림 3-57] D3, D1을 수정한 Cross-WLF 점도 모델 계수	83
[그림 3-58] 수정된 D1,D3 물성을 이용한 CAE 추가 비교 결과	84
[그림 3-59] 회전 레오미터와 모세관 레오미터를 이용한 점도 측정	85
[그림 3-60] 측정한 데이터를 기반으로 데이터 피팅한 점도 그래프	85
[그림 3-61] 기존 점도 그래프와 새로운 점도 그래프 비교	86
[그림 3-62] 데이터 피팅 1(230/250/270℃ 기반)	87
[그림 3-63] 데이터 피팅 1 점도 데이터(230/250/270℃ 기반)	87
[그림 3-64] 데이터 피팅 2(230/270/330℃ 기반)	88
[그림 3-65] 데이터 피팅 2 점도 데이터(230/270/330℃ 기반)	88
[그림 3-66] 데이터 피팅 3(270/300/330℃ 기반)	89
[그림 3-67] 데이터 피팅 3 점도 데이터(270/300/330℃ 기반)	89
[그림 3-68] 데이터 피팅에 따른 유동 거리 비교 결과	90
[그림 3-69] 데이터 피팅에 따른 사출 중량 비교 결과	90
[그림 3-70] 영점 점도를 고려한 측정을 통한 유동 거리 개선 결과	91
[그림 3-71] 에어백 커버 제품 메시 및 금형 메시	92
[그림 3-72] 저점도 ASA LI912와 고점도 ASA LI941 기본 물성	93
[그림 3-73] ASA LI912(T_1)와 ASA LI941(T_2) 점도 물성 비교	93
[그림 3-74] ASA LI912(P_1)와 ASA LI941(P_2) pvT 물성 비교	94
[그림 3-75] 에어백 커버 제품 메시 평면도	94

[그림 3-76] 에어백 커버 제품 메시 측면도	95
[그림 3-77] 에어백 커버 제품 메시 정면도	95
[그림 3-78] 에어백 커버 제품 메시 단면도	96
[그림 3-79] 에어백 커버 제품 금형 메시 및 냉각 구조	96
[그림 3-80] Pressure drop, maximum 결과	97
[그림 3-81] Temperature at flow front, minimum 결과	98
[그림 3-82] 초기 해석 조건	98
[그림 3-83] Fill time 결과	99
[그림 3-84] Pressure at V/P switchover 결과	99
[그림 3-85] 사출 시간 변화에 따른 사출 압력 CAE 예측 결과	101
[그림 3-86] DOE Builder의 실험 선택	101
[그림 3-87] DOE Builder의 변수 선택	102
[그림 3-88] ASA LI912 사출 최대압력(MPa)	103
[그림 3-89] ASA LI912 필요 형체력(ton)	103
[그림 3-90] ASA LI941 사출 최대압력(MPa)	104
[그림 3-91] ASA LI941 필요 형체력(ton)	104
[그림 3-92] 상측 Temperature, mold(average) 결과	105
[그림 3-93] 하측 Temperature, mold(average) 결과	105
[그림 3-94] Temperature, mold(transient) 결과	106
[그림 3-95] Temperature, mold(transient from start-up) 결과	106
[그림 3-96] Engel社의 e-victory 사출 성형기	107
[그림 3-97] Engel社의 e-victory 사출장치 사양	107
[그림 3-98] 시험 사출 성형기 보압조건(좌), 사출 조건(우)	108
[그림 3-99] 핫러너 설정온도 230℃, 냉각수 설정 온도 60℃	108
[그림 3-100] 용융 수지 온도측정	108
[그림 3-101] 사출 성형기에서 사출 후 에어백 커버 금형 열림	109
[그림 3-102] 보압 절환시 제품 중량(좌), 보압적용 후 제품중량(우)	109
[그림 3-103] 시험 사출 후 취출된 제품의 상측 온도측정 결과	110
[그림 3-104] 시험 사출 후 취출된 제품의 하측 온도측정 결과	110

[그림 3-105] LI921 1단 속도제어 사출기 출력 속도 및 압력	111
[그림 3-106] LI921 다단 속도제어 사출기 출력 속도 및 압력	111
[그림 3-107] LI941 1단 속도제어 사출기 출력 속도 및 압력	112
[그림 3-108] LI941 다단 속도제어 사출기 출력 속도 및 압력	112
[그림 3-109] LI921 1단 속도제어 1st CAE 결과	113
[그림 3-110] LI921 다단 속도제어 1st CAE 결과	114
[그림 3-111] LI941 1단 속도제어 1st CAE 결과	114
[그림 3-112] LI941 다단 속도제어 1st CAE 결과	115
[그림 3-113] Moldflow 데이터베이스 중 ASA 물성 검색 결과	115
[그림 3-114] Moldflow 데이터베이스 중 점도 물성 비교	116
[그림 3-115] 1단 속도제어 2nd CAE 입력결과	117
[그림 3-116] 다단 속도제어 2nd CAE 입력결과	117
[그림 3-117] 보압제어 2nd CAE 입력결과	118
[그림 3-118] LI921 1단 속도제어 2nd CAE 결과	118
[그림 3-119] LI921 다단 속도제어 2nd CAE 결과	119
[그림 3-120] LI941 1단 속도제어 2nd CAE 결과	119
[그림 3-121] LI941 다단 속도제어 2nd CAE 결과	120
[그림 3-122] 1st CAE와 2nd CAE의 오차율 비교 결과	120
[그림 4-1] 철 라디에이터 탱크(좌), 플라스틱 재료 변경 모델(우)	125
[그림 4-2] 사출기 고정된 라디에이터 탱크 사출 금형 고정 측	125
[그림 4-3] 사출기에 고정된 라디에이터 탱크 사출 금형 가동 측	126
[그림 4-4] 라디에이터 탱크 제품의 휨 CAE 예측 결과	126
[그림 4-5] 점도 그래프 Technyl One J60 X1 V30 Grey 7035	127
[그림 4-6] 온도 및 압력에 따른 비체적 pvT 물성	128
[그림 4-7] 라디에이터 탱크 제품 메시의 ISO View	128
[그림 4-8] Q-Q, 박스 및 바이올린 플롯 분석 결과	132
[그림 4-9] 입력(Input) 조건 108 Case에 대한 CAE 결과(Output)	133
[그림 4-10] X 방향의 휨(Sum_X)의 상관분석 결과	133
[그림 4-11] 형체력(CF)의 상관분석 결과	134


[그림 4-12] 보압 절환 시 사출 압력(VP)의 상관분석 결과	134
[그림 4-13] X 방향 휨(Sum_X)의 상관분석 결과	135
[그림 4-14] Case44의 CAE 결과(초기 값)	137
[그림 4-15] Case33의 CAE 결과	137
[그림 4-16] Case24의 CAE 결과	138
[그림 4-17] X 방향의 변형 3D 반응 표면 결과	139
[그림 4-18] 1 은닉층, 8 뉴런을 적용한 MLP	142
[그림 4-19] 5 은닉층, 3 ~ 13 뉴런을 적용한 MLP	142
[그림 4-20] 은닉층에 따른 MLP 모델 결정계수 비교	143
[그림 4-21] 은닉층에 따른 MLP 모델 RSMD 비교(Training)	143
[그림 4-22] 은닉층에 따른 MLP 모델 RSMD 비교(Test)	144
[그림 4-23] PR(FQ), EDT 모델의 결정계수 비교	145
[그림 4-24] PR(FQ), EDT 모델의 RSMD 비교(Training)	145
[그림 4-25] PR(FQ), EDT 모델의 RSMD 비교(Test)	146
[그림 4-26] RBF(Int), RBF(Reg) 모델의 결정계수 비교	146
[그림 4-27] RBF(Int), RBF(Reg) 모델의 RSMD 비교(Training)	147
[그림 4-28] RBF(Int), RBF(Reg) 모델의 RSMD 비교(Test)	147
[그림 4-29] HMA 최적화 결과	149
[그림 4-30] MLP와 HMA를 이용한 사출 성형 CAE 최적화 결과	150
[그림 4-31] Decision-tree의 프로세스	155
[그림 4-32] Sum X에 대한 예측 성능 알고리즘 비교	155
[그림 4-33] 사출 압력에 대한 머신러닝 알고리즘 비교	156
[그림 4-34] 형체력에 대한 머신러닝 알고리즘 비교	156
[그림 4-35] Sum X 변형의 Decision-tree(Maximal Depth 3)	157
[그림 4-36] Sum X 변형의 Decision-tree(Maximal Depth 4)	158
[그림 4-37] 형체력의 Decision-tree(Maximal Depth 3)	158
[그림 4-38] 형체력의 Decision-tree(Maximal Depth 4)	159
[그림 4-39] 형체력의 수정된 Decision-tree(Maximal Depth 3)	160
[그림 4-40] 형체력의 수정된 Decision-tree(Maximal Depth 4)	160

[그림 4-41] 휨 변형의 수정된 Decision-tree(Maximal Depth 3)	161
[그림 4-42] 휨 변형의 수정된 Decision-tree(Maximal Depth 4)	161
[그림 4-43] 사출 압력의 수정된 Decision-tree(Maximal Depth 3)	162
[그림 4-44] 사출 압력의 수정된 Decision-tree(Maximal Depth 4)	162

제 1 장 서 론

제 1 절 연구 배경

최근 모든 자동차 회사들이 연비 향상을 위한 대책으로 경량화를 위해 노력하고 있다. 플라스틱은 기존의 철강 재료에 비해 가볍고, 생산성이 우수할 뿐만 아니라 첨가제의 종류, 형태 및 함유량에 따라 플라스틱 부품의 강성을 조절할 수 있어, 이미 수많은 자동차 부품들이 철강 재료에서 플라스틱 재료로 변경되었다. [그림 1-1]은 1930년대부터 2000년까지 세계의 재료별 소비량을 중량을 기준으로 나타내고 있다. 철강 재료는 1930년대부터 지금까지 매우 많은 양을 소비하고 있지만, 최근 들어 플라스틱 재료가 사실상 철강 재료의 사용량을 앞질렀다(Rosato, D. V., et al., 2012).



[그림 1-1] 세계 재료 별 소비량(Rosato, D. V., et al., 2012).

사출 성형 공정은 복잡한 형상과 정밀한 부품을 대량 생산할 수 있는 장점으로 산업 분야에서 일상생활 제품까지 광범위하게 적용되고 있다. 최근에는 효율을 극대화하기 위해 여러 부품을 조립하여 하나의 제품을 만들던 공정을 한 번의 사출로 만드는 고기능 사출 성형품 제작을 하고 있다. 예를 들면 인서트 사출, 2중 또는 3중 사출, 복합재료를 이용한 고강도 제품 사출(이규세, 2015), 미세다공 사출(김주권, 2019), 가스 사출(강세호, 2017), 스택 사출(신장순 외, 2006), 다색 다층 사출 등이 있다. 이렇듯 많은 기능을 갖춘 성형품을 단기간에 정확하고 정밀한 제조를 하기 위해 실무에 적용할 과학적인 기술이 필요하다(신장순 외, 2008).

사출 성형 제품의 품질은 금형, 수지, 성형조건, 환경에 의해 영향을 받는다. 이러한 다양하고 복잡한 변수의 조합이 양품 범위를 벗어나면 불량 발생한다. 일반적으로 불량을 해결할 방법은 각 분야 및 사람마다 다르며, 각자의 과거 경험 즉, 노하우에 의존하는 경우가 많다. 문제 해결과 관련된 많은 변수 중 가장 효과적인 변수를 찾아 최적의 조건으로 변경하는 것은 누구나 원하는 바이지만 쉬운 일이 아니다. 모든 제품과 수지 물성, 금형을 경험할 수 없으며, 이미 경험한 제품이라도 다양하고 복잡한 상호 작용의 관계를 사람이 이해하는 것은 불가능하기 때문이다. 사출 불량 문제를 해결하기 위한 범용적인 방법은 이미 널리 알려졌지만, 하나의 문제를 해결하기 위해 공정 조건이나 제품 설계를 변경할 경우 다른 문제가 발생하기도 한다. 그 예는 아래와 같다.

- ❖ 싱크마크¹⁾를 개선하기 위해 보압 조건을 높이면 그 문제는 개선이 되지만, 변형 문제나 치수 문제가 발생할 수 있다.
- ❖ 리브의 두께를 기본 살 두께의 50 ~ 75%로 설계하면 싱크마크는 개선되지만, 리브와 기본 살 두께의 편차로 인해 휨이 발생한다.
- ❖ 미성형²⁾이 발생하여 수지의 용융 온도를 높이면 점도가 낮아져 성형은 될 수 있지만, 온도가 상승하면서 발생하는 가스로 인한 외관 불량

1) 싱크마크(Sink mark): 플라스틱 성형품의 표면이 오목하게 들어가는 현상

2) 미성형(Short shot): 용융상태의 수지가 금형을 채우지 못하고 고화되어 발생하는 불량

이나 열화에 의한 탄화 현상이 발생할 수 있다.

이러한 불량을 개선하기 위해 제품 디자인 및 금형 구조를 변경하여 해결할 수도 있고, 사출 조건을 변경하여 개선할 수 있다. 제품 개발 초기 단계에서 변수 수정이 쉽게 가능한 제품 디자인에서 CAE³⁾를 활용하여 성형성 검증 및 불량 요인을 미리 제거하기 위해 다양한 설계 옵션을 평가해야 한다(Kennedy, P., et al., 2013).

그러나 CAE 결과를 얼마나 신뢰할 수 있을까? 그 대답은 때에 따라 다르다. 핵심 정보와 데이터를 확보하고 분석할 수 있는 경험을 가진 엔지니어가 있는가에 따라 결과물의 신뢰 수준은 달라질 수밖에 없다.

- ❖ CAE를 위한 검증된 재료 물성은 확보했는가?
- ❖ 우리가 적용하려는 공정이 CAE 가정에 어긋나거나 벗어나지는 않는가?
- ❖ CAE와 실제 결과에 대한 비교 경험을 통해 상관관계를 파악하였는가?
- ❖ CAE 범위와 불량 요인에 따른 주요한 변수를 이해하고 있는가?
- ❖ 초기 제품 디자인에서 변경된 최종 수정 모델링을 확보하고 있는가?
- ❖ 금형을 고려한 파팅라인 및 빼기 구매 모델링을 확보하고 있는가?
- ❖ 사출 성형기의 성능 및 사출 환경과 조건을 이해하고 있는가?
- ❖ 실물에 대해 정확한 측정 결과를 확보했는가?
- ❖ CAE 절차는 결과 분석 전에 검증되었는가?
- ❖ CAE 결과는 적절한 가시성 및 속성으로 표현되었는가?
- ❖ CAE는 선행 연구 단계, 양산 단계, 문제 해결을 위한 단계에 따라 다르게 접근하여 검증하고 있는가?

그러나 위의 정보가 모두 확보되면 실제와 CAE를 그대로 일치할 수 있을까에 대한 대답을 쉽게 할 수 없다. 그래서 관련 업계 종사자들은 실제 사출 성형 공정과 CAE 편차를 최소화하기 위한 검증 방법론과 CAE 정확성 개선 사례에 대한 관심이 뜨겁다.

3) CAE(Computer Aided Engineering): 컴퓨터 응용 공학

제 2 절 연구의 필요성

짧은 납기에 높은 품질의 제품을 생산하기 위해 기업들은 시간과 자금을 투자하고 있으며 더 나은 의사결정 시스템과 최적화된 프로세스를 위해 제조 전 설계를 검증하는 시스템 즉, 설계와 제조를 융합하는 CAE 기술이 주목받고 있다. 국내 CAE의 초기 연구들은 단순 제품에 대하여 CAE로 사출 성형 공정을 구현하는 데 집중 되었다. 4각 캐비티를 충전단계를 예측하는 현상을 수치 모사 기법으로 해석하였다. 유체의 점탄성 거동을 예측하기 위해 저밀도 폴리에틸렌을 선정하여 시간 변화에 따른 충전 현상을 모사하였다(이기준 외, 1989). 인장 시편 형상의 사출 성형 과정에서 금형 온도, 수지 온도, 보압 시간의 변화에 따른 선형수축률과 중량의 변화를 연구하였으며 CAE의 결과보다 실험값이 0.6% 크게 나타났다. 특히 수축은 30일까지 진행되어 정밀성형에서는 경시 변화가 중요한 인자임을 확인하였다(유중학, 1995).

최근 연구들은 특정 제품이나 공정에 대하여 CAE를 통해 예측하거나 최적화 방법론을 개발하였다. 최적화 연구 사례로는 자동차 내외장 제품인 범퍼와 대시보드 모델의 강건 설계를 위해 품질변동의 원인이 되는 잡음 인자에 둔감한 설계 조건을 찾는데 CAE를 이용하여 다수 품질 특성 중 설계자의 의도를 고려한 선호함수를 유도하고 직교 배열에 기초한 설계공간축소법을 대화 식으로 개발하였고(김광호, 2009), 박육 제품을 성형하기 위해 금형의 급속가열 장치를 개발 및 두께 0.5 ~ 1mm 시편에 대한 사출 성형 CAE를 통해 금형의 온도분포를 예측하여 캐비티 벽면의 유동 거동에 따른 Air-trap 불량을 관찰하였다(김옥래, 2010). 제품 표면의 미세 패턴에 대한 성형성 및 이형성을 수치 해석적 접근하였는데, 미세 패턴을 제외한 형상은 Shell 메시를 적용하여 Global 해석을 진행하여 해석 시간을 단축하였으며, 미세 패턴은 Global 해석 결과를 기반으로 경계 조건 및 초기조건으로 사용하는 Local 해석을 진행하였다(박시환, 2011). 또한 API를 활용하여 목적함수를 제품표면의 온도에 대한 평균편차로 설

정하고, 두께가 균일한 경우 플라스틱 제품의 방출 열량을 일정한 크기로 구분하여 형상적응형 냉각회로에 대한 자동최적설계 방법을 개발하였으며(최재혁, 2015), 사출 성형 CAE를 활용하여 가스사출제품의 내벽품질에 영향 도를 파악하기 위해 일반 사출과 비교하였다. 유동 과정에서 발생한 유동 선단의 온도 변화에 대한 기준과 사출 압력의 기준을 선정하여 예측하였다(강세호, 2017). 자동차 헤드램프 베젤 제품의 CAE 힘 예측 정확성을 개선하기 위해 수지 물성의 정확성이 CAE 개선에 가장 민감도가 높았으며, 기계적 물성 중 CTE가 중요한 인자임을 확인하였고 사출기 노즐의 압력 강하, 냉각 시뮬레이션 순서로 민감도가 높음을 확인하였다(황순환, 2017). 그리고 응답속도 분석을 위해 스파이럴 성형품을 사출 후 충전 길이 변화를 CAE를 통해 분석하여 충전에 미치는 영향을 확인하였다(홍청민, 2020). 위의 연구들은 CAE가 현실과 일치한다는 가정이 필요하다. 그러나 2019년 6월 27일에 개최된 한국금형비전포럼 컨퍼런스에서 국내 최고의 전자 회사 두 곳의 사장님과 부사장님의 발표에서 CAE는 제조 Process로 표준화되었지만 CAE 해석 정확도가 불일치하며, 이론과 실제의 결과 Data의 정확도 향상이 목표라고 강연 중 설명하였다.


최근 사출 성형공정을 컴퓨터로 시뮬레이션하고 최적화하는 방법론이 업계의 표준으로 만들어지고 있다. 사출성형분야의 CAT⁴⁾ 방법론으로 CAE를 활용한 수치 해석이 주를 이루고 있는데 [표 1-1]은 사출 성형 CAE의 다양한 변수들을 연꽃 기법으로 나타냈다. 이 변수들은 모두 사출 성형의 변수이자 CAE 정확성과 연관되어 있다. 사출 성형 CAE는 다양한 물성 정보와 사출기, 공정변수, 그리고 형상 정보를 유한요소로 나누어 가정 기반의 지배방정식을 이용하여 계산한다. 이러한 조건이 하나라도 맞지 않는다면 CAE 결과를 보장할 수 없다. 플라스틱 물성 정보는 Autodesk Moldflow에 약 10,000개 이상 저장되어 있지만(Autodesk Moldflow Help, 2021), 측정 품질은 물성마다 다른 수준을 이루고 있다.

4) CAT(Computer Aided Testing): 컴퓨터 응용 실험

[표 1-1] 사출 성형 CAE 변수

Modification of part shape for mold	Gate Type Positioning Number of Gate	Eject System	Quality Indicator	Viscosity Property	pVT Property	Design change	Structural Integrity	Thickness Size Tolerance
Machining Error	Mold Design	Cold or Hot runner system	Thermal property	Resin Property	Mechanical Property	Insert Ribs & Boss Fasteners Snap-fit	Part Design	Creep Stress Strength fatigue
Vent system	Cooling Channel	Series Parallel Circuit	Transition Temperature	Ejection Temperature	Filled or unfilled	Resin Property	Quality and Cost	Cycle time
Mid plane Dual domain 3D mesh	Number of Meshes & Laminiae Across thickness	Mold-melt Heat Transfer Coefficient	Mold Design	Resin Property	Part Design	Performance	Maximum Injection Speed	Maximum Injection Pressure
Isolate cause of warpage Consider Corner Effect	CAE Parameter	Inertia gravity wall slip Intermediate	CAE Parameter	Injection Molding CAE Accuracy	Injection Machine	Maximum Clamp Force	Injection Machine	Response Time
Convergence	Fiber Analysis Option	Venting Coreshift Analysis	Data Manage-ment	Process Setting	Environ-ment	Screw(Ram) Diameter	Intensification Ratio	Screw(Ram) Diameter
Data Collection	Design Standard	CAE Standard	Filling control	V/P Switch over	Packing Time	Ambient Temperature	Coolant pump performance	Part management after ejection
Data Science	Data Manage-ment	Optimization Technology	Cooling time	Process Setting	Packing Pressure	Feed system cutting	Environ-ment	Temperature controller system
Automated data collection using API	Machine Learning	Problem Solving Methodology	Starting Ram Position	Melt Temperature	Mold Temperature	Measurement	Aging effect	Eject System (Automated robot)

사출 성형 CAE 결과를 검증하는 방법은 실제 사출과 CAE 결과를 직접 비교하는 것이 일반적이다. 그러나 복잡한 상관관계를 갖는 검증이 필요할 때, 검증 방법을 [그림 1-2]와 같이 세부적으로 나눌 필요가 있다. CAE 결과를 직접적으로 비교하는 검증은 충전 패턴이나 정체 현상, 웰드라인 위치, 사출 압력, 압력이력, 싱크마크, 변형 및 수축을 비교할 수 있다. 그러나 실험 결과와 같이 CAE 결과를 개선하고 싶다면, CAE 절차에 따른 검증을 진행해야 한다.



[그림 1-2] 해석 결과/절차/단계에 따른 다양한 검증 방법

절차에 따른 검증은 CAE 작업이 올바른 방법으로 적용되었는가를 검증하는 프로세스로 아래와 같은 항목을 검증해야 한다.

- ❖ 모델링은 최종 모델링이 적용되었는가?
- ❖ 금형을 고려한 모델링인가?
- ❖ 메시의 경우 형상을 대표할 수 있는 개수를 갖추었는가?
- ❖ 종횡비는 적절한가?
- ❖ 메시 진단 후 문제는 없는가?
- ❖ 듀얼 도메인 메시의 경우 두께 인식은 적절하게 되었는가?
- ❖ 3D 메시의 경우 레이어는 적절한가?
- ❖ 플라스틱 수지의 물성은 어느 범위로 측정되었는가?
- ❖ 대포깁 범위는 어떠한가?
- ❖ 휨 예측 시 기계적 물성은 측정되었는가?

해석 범위와 목표는 해석 단계에 따라 다르다. 선행 연구 단계의 경우 아직 정확한 금형 설계 정보를 확보하지 않은 상태로 정확한 예측보다 초기 결정 단계에서 주요한 의사결정을 내릴 수 있는 내용에 초점이 맞춰져 있어야 한다. 그러나 양산단계나 문제해결에서는 정량적인 예측 및 문제 해결을 할 수 있는 방법론을 확보해야 한다. 결과적으로 일정한 품질의 CAE 결과를 확

보하기 어렵기 때문에 이전 프로젝트의 경험을 통계적인 분석으로 기대하는 결과 도출이 필요하다.

머신러닝⁵⁾이란 AI⁶⁾의 한 분야로 사람이 학습하는 것처럼 컴퓨터가 데이터를 통해 학습함으로써 기대하는 지식을 추출하는 것이다. 머신러닝은 1950년대 시작되었지만 최근 현저한 발전을 이루게 한 기술이 바로 딥러닝이다. 딥러닝 기술은 다층 구조의 인공 신경망 즉 은닉층과 은닉층에 존재하는 뉴런을 통하여 입력변수 및 출력변수의 관계를 파악한다. 입력된 데이터를 신경망을 통하여 예측된 값의 편차를 최소화하도록 각 레이어의 뉴런에 연결된 가중치와 편향을 반복적으로 훈련함으로써 우수한 신경망 모형을 완성한다. 이러한 모형은 과거의 사출 성형 CAE에서 시뮬레이션 시간의 한계 때문에 고려할 수 없었던 많은 양의 변수를 처리하여 최적의 결과를 얻는 데 도움을 줄 수 있다. 특히 역설계와 같은 정량적인 해석을 진행하기 위해서는 보다 신중한 프로세스를 적용해야 한다. 과거에는 정량적 힘 예측임에도 사출 공정 조건은 사출 작업자에 의해 결정되었고, CAE 사출 조건 결과는 무시했다. 그러나 CAE 결과 신뢰성을 높이기 위해서는 공정 조건의 불확실성이 얼마나 CAE 결과에 영향력이 있는지 파악해야 한다. 또한 사출 성형 CAE를 1회 진행하는데 작게는 1시간에서 많게는 수일이 소요된다. 다양한 변수를 고려하기 위해 매번 새로운 프로젝트마다 수많은 해석 Case를 진행할 수는 없기 때문에 사전에 유사 제품에 대하여 머신러닝을 진행하고 최적화 기법을 활용하여 최적의 성형 조건 확보하는 것이 필요하다.

5) 머신러닝(Machine Learning): 기계학습

6) AI(Artificial Intelligence): 인공지능

제 3 절 연구의 범위와 목적

본 연구의 첫 번째 목적은 사출 성형 CAE 예측 정확성 향상으로 정교한 데이터를 확보하는 방법과 사례를 만드는 것이고, 두 번째 목적은 CAE 데이터 기반 머신러닝을 통한 데이터 분석 및 예측 모델링을 구축하여, 사출 성형 최적화 프로세스를 구현하고자 한다.

CAE는 제조 전 다양한 변수를 시뮬레이션으로 검증하고 최적의 값을 찾을 수 있어 사출 성형 제조 프로세스로 표준화 되었다. 그러나 정확도 불일치로 인하여 중요한 의사결정에서 신뢰를 얻지 못하고 있다. CAE 개발사는 쉽고 자동화된 소프트웨어 개발로 사용자의 진입 장벽 낮아졌지만, 오히려 제조 방법과 CAE 원리를 이해하지 못한 상태에서 연구가 확대되어 CAE 정확성에 대한 적신호가 켜진 상태다. 과거의 CAE는 제조 환경에 대한 현상을 모사하는 소프트웨어의 제한된 한계, 여러 상황과 환경의 변화에 따른 물성을 평가하고 측정하는 기술의 부족, 컴퓨터 성능의 제한으로 인해 메시 숫자와 연구의 경우의 수를 충분히 적용할 수 없어 CAE 정확성에 대한 기대가 크지 않았다. 즉 최소한의 실험으로 최대의 효과를 얻기 위한 연구 및 예측에 집중되었다. 그러나 최근에는 현실의 제조 환경을 보다 폭넓게 모사할 수 있는 소프트웨어의 업그레이드와 다양한 상황을 고려한 물성 측정 기술, 급격히 성장한 컴퓨터 성능으로 인한 메시 증가와 많은 Case 연구로 정확성을 확보할 수 있는 기반 기술이 발전되었다. 그리고 인공지능(Artificial Intelligence)의 한 축인 머신러닝 기술이 발전하여 예측 성능이 높고, 결과에 대한 설명이 가능해짐에 따라 CAE와 머신러닝을 융합하여 사용할 경우 상용 소프트웨어에서 전용 예측 모델을 생성할 수 있어 보다 빠르고 정확한 예측이 가능하다. 이러한 전용 예측 모델을 기반으로 전역 최적화 모델을 적용할 경우 사출 성형 공정 최적화 프로세스가 구현될 것으로 사료된다.

본 논문의 2장은 사출 성형 CAE의 이론적 배경이 되는 선행 연구를 조사하여 정확성 저하의 원인이 되는 수치 물성 측정 방법 및 CAE 메커

니즘을 설명하였다. 3장은 CAE 적확성의 주요 인자를 설명하고, 적확성 향상을 위한 변수를 제시하였다. 그리고 CAE 적확성을 향상하기 위한 방법으로 CAE에 적용하는 플라스틱 재료의 유변 물성을 평가하고 복제하기 위한 편집 방법, 제품 형상 및 금형 모델링을 현실에 맞게 복제할 방법, 실제 사출 성형 공정 조건을 그대로 복제하는 방법, 사출기의 입력 조건이 아닌 출력 조건과 성능을 복제하는 방법에 대하여 설명하였다. 사출 유동 해석을 검증하기 위해 사용되고 있는 스파이럴 금형의 형상 특성이 유동 거리를 대표할 수 있는가를 평가하기 위해, 스파이럴 형상의 폭의 변화와 막대 형상, 판 형상의 유동 거리를 비교하여 유동 해석에 미치는 영향을 확인하였다. 또한 PC+ABS 수지의 유변 물성 중 영점 점도와 압력의존성 계수를 수정하여 유동 거리 예측 개선 방법을 제시하였다. 이러한 방법론을 활용하여 에어백 커버 제품을 실제 사출한 결과와 CAE 예측 결과를 비교하였으며 적확성 개선을 위해 어떠한 변수를 수정해야 하는지 사례를 제시하였다. 4장에서는 복합재료의 사출 성형 공정조건 변화에 따른 사출 압력, 형체력, 힘 결과에 대하여 사출 성형 CAE 소프트웨어 Autodesk社의 Moldflow Insight로 데이터를 확보하였다. 그리고 사출 성형 조건 최적화를 위해 PIDOTECH社의 PIA^{no}를 이용하여 ANN⁷⁾으로 알려진 MLP⁸⁾로 예측 모델링을 만들었으며(황순환 외, 2018), HMA⁹⁾를 활용하여 MLP 기반 구속조건을 만족하는 최적의 사출 성형 조건을 도출하는 전 과정을 설명하였다. 그리고 설명 가능한 머신러닝 기법인 Decision-tree¹⁰⁾ 모델을 RapidMiner社의 RapidMiner Studio를 활용하여 생성하였으며, 입력 변수인 사출 성형 조건과 목표함수인 힘 변형량과 구속조건인 형체력, 사출압력과의 관계를 분석하였다.

본 연구를 통해 CAE 적확성 향상을 위한 방법론과 머신러닝을 이용하여 CAE 작업자가 접근하기 힘들었던 사출 성형 조건 최적화 프로세스를 제안하였다.

7) ANN(Artificial Neural Networks): 인공신경망

8) MLP(Multi-layer Perceptron): 다층퍼셉트론

9) HMA(Hybrid Metaheuristic Algorithm): 하이브리드 메타휴리스틱 알고리즘

10) Decision-tree: 의사결정나무


제 2 장 이론적 배경 및 선행 연구

제 1 절 사출 성형 CAE의 선행연구

1) 사출 성형 CAE 초기 연구(1970~1980년대)

사출 성형 CAE에 대한 초기 작업은 수지의 평균 속도를 계산하여 용융 수지의 최대 유동 길이를 구하는 방식으로 시도되었다. 이 결과 주어진 길이 채우는 시간을 추론할 수 있었다. 1970년대 수학자들은 Hele-Shaw(헬레-쇼)¹¹⁾ 흐름에 관심을 가졌다(Richardson, S., 1972). 플라스틱 제품은 대부분 얇은 두께에 넓은 평판 구조로 되어 있다. 이러한 형상을 시뮬레이션 하는데 가장 널리 사용되는 모델이기 때문이다. 대부분의 플라스틱 제품은 두께 방향보다 평면 방향이 훨씬 크다. 또한 긴 분자 사슬 구조는 높은 점도를 유발하므로 관성력이 점성 전단 응력보다 훨씬 작다. 따라서 얇은 캐비티의 충전 흐름은 그 모델에 근접 할 수 있다. [그림 2-1]은 Hele-Shaw(헬레-쇼) 모델이 설명하는 일반적인 흐름을 나타낸다. 게이트에서 용융 수지가 흘러 두께 h , 폭 W , 유동길이 L 일 때 가정은 유동길이와 폭에 비해 두께는 매우 작다는 것이다. 식 (1)은 질량 보존 방정식을 나타내고 있다. 질량 보존 법칙은 닫힌계의 질량은 상태 변화에도 질량이 유지된다. 즉 유체의 경우 유로를 흐르는 유량은 언제나 일정하다는 가정이고 고체의 경우 분리되거나 이탈되지 않는 것이다. $\bar{u}$ 는 x 방향의 속도 성분 z (두께) 방향으로 평균값, $\bar{v}$ 는 Y 방향의 속도 성분 z (두께) 방향으로 평균값, b 는 x 와 y 함수의 절반 간격을 나타내고 있다.

11) Henry Selby Hele-Shaw(헬레-쇼)의 이름을 따서 명명 됨.



[그림 2-1] Hele-Shaw(헬레-쇼) 모델이 설명하는 유동 개략도
(Rosato, D. V., et al., 2012)

$$\frac{\partial}{\partial x}(b\bar{u}) + \frac{\partial}{\partial y}(b\bar{v}) = 0 \quad (1)$$

$$0 = \frac{\partial}{\partial z} \left(\eta \frac{\partial u}{\partial z} \right) - \frac{\partial p}{\partial x} \quad (2)$$

$$0 = \frac{\partial}{\partial z} \left(\eta \frac{\partial v}{\partial z} \right) - \frac{\partial p}{\partial y} \quad (3)$$

식 (2),(3)은 운동량 보존 방정식으로 힘을 받아 흐르는 현상을 계산한다. η 는 점도, p 는 x 와 y 에 작용하는 압력이다.

$$\frac{\partial}{\partial x} \left(S \frac{\partial p}{\partial x} \right) + \frac{\partial}{\partial y} \left(S \frac{\partial p}{\partial y} \right) = 0 \quad (4)$$

식 (4)와 같이 Hele-Shaw(헬레-쇼) 흐름의 지배 방정식은 질량 보존 방정식과 운동량 보존 방정식을 연립하여 나타낼 수 있다. S 는 유동성으로 S 가 클수록 유동이 원활히 이루어짐을 뜻한다. 요약하면, Hele-Shaw(헬레-쇼)는 2차원 유동 방정식이며, 두께 방향으로 대칭 하

여 계산하며 아래와 같은 가정을 이루고 있다.

- ❖ 용융 수지의 유동 흐름은 비압축성 유체의 확장된 층류로 간주 된다. 두께 방향의 속도는 무시할 수 있으며, 압력은 일정하게 유지된다.
- ❖ 높은 점도 때문에 점성 전단 응력보다 훨씬 작은 관성력은 무시할 수 있다.
- ❖ 두께 방향의 대류 열전달은 무시한다.
- ❖ 용융 수지의 흐름 방향에서 열전도는 무시할 수 있다.
- ❖ 유동 흐름 선단에서의 교차 흐름, 즉 분수 효과는 고려하지 않는다.
- ❖ 시뮬레이션에 대한 간격의 영향은 무시한다.

이후 연구에서 충전, 보압 및 냉각 단계를 고려했다(Kamal, M. R., et al., 1972). 그들은 압력과 온도 장을 풀기 위해 유한차분법을 사용했다. 1974년 CIMP¹²⁾가 형성되면서 사출 성형의 과학적 원리에 초점이 맞춰 연구가 개발되었다. 최초의 사출 성형 CAE 상용 소프트웨어는 Moldflow로 Austin이 호주에 설립하여 초기 사출 성형 CAE에 큰 영향을 주었다. 1986년에는 점탄성 재료 모델을 사용하여 충전 및 냉각 단계를 포함하는 사출 성형 CAE를 발표했다(Lafleur, P. G., et al., 1986). 비압축성 재료라는 가정과 제품의 미드플레인에 대한 대칭 유동장 및 Hele-Shaw(헬레-쇼) 근사법을 채택하였다. 이때에는 압력이 2D이고 속도 및 온도 장은 3D이기 때문에 이 방법을 2.5D 해석이라고 불렀다. 2.5D 방법의 코드는 각각 빔과 삼각형 요소를 사용하여 러너 시스템과 가변 두께 캐비티를 분석할 수 있게 되었다(Hieber, C. A., et al., 1980). 점도는 온도, 전단 속도 및 압력 의존성으로 모델링 되었다.

12) CIMP(Cornell Injection Molding Program): Cornell 대학의 사출 성형 프로그램

2) 사출 성형 CAE 중기 연구(1990~2000년대)

1990년에 Windows 운영 체제가 도입되어 사용자 인터페이스 및 그래픽 성능이 향상되었다. 금형의 상·하측 온도 차이로 인한 휨을 고려할 수 있었으며(Santhanam, N., et al., 1990), 비결정성 수지에 대한 점탄성 모델을 사용하여 잔류 응력의 발생을 시뮬레이션으로 적용했다(Douven, L., 1991). 또한 이 시기에 충전 분석을 위한 3D 메시를 활용한 개발이 착수되어 첫 번째 유형으로 IMI 코드가 처음 설명되었다. 압력 및 온도에 대한 유한 요소를 금형 요소에 이산화하고 각 노드에서 압력 및 세 가지 속도 구성 요소에 대한 Navier Stokes(나비에스토크스) 방정식을 사용했다(Hétu, J. F., et al., 1994). 질량 보존 방정식의 경우 식 (5),(6)과 같이 표현할 수 있다. Hele-Shaw(헬레-쇼) 방정식과 차이는 시간에 대한 밀도의 변화 항과 두께 방향의 속도 성분이 추가되었다.

$$\frac{\partial \rho}{\partial t} + \frac{\partial(\rho u)}{\partial x} + \frac{\partial(\rho v)}{\partial y} + \frac{\partial(\rho w)}{\partial y} = 0 \quad (5)$$

$$\frac{\partial \rho}{\partial t} + \nabla \cdot (\rho \bar{u}) = 0 \quad (6)$$

식 (7)은 점성 유체에 대한 일반적인 운동방정식이다. 2차원 유동 방정식과는 다르게, 운동량 보존 방정식에 가속도 항(∇)과 중력 항(g)이 추가되었고 방향 성분을 사용하여 x, y, z 즉 3D에 대한 수직 응력 P , 전단 응력 τ 를 고려하는 항을 사용한다.

$$\rho \frac{DV}{Dt} = -\nabla P + \nabla \cdot \tau + \rho g \quad (7)$$

식 (8)은 열의 이동을 지배하는 에너지 보존방정식으로 대류에 의한 열과 전도에 의한 열이 계산된다. 유체의 점성 유동으로 발생하는 전단 발

열을 계산하기 위해 점도 η 와 전달율의 제곱 $\dot{\gamma}^2$ 으로 계산한다. 요약하면, Navier Stokes(나비에스토크스) 유동 방정식은 3차원 유동 방정식이며, 관성 및 중력 등을 고려하여 계산하게 된다.

$$\rho c_p \left(\frac{\partial T}{\partial t} + \bar{u} \cdot \nabla T \right) = k \nabla^2 T + \eta \dot{\gamma}^2 \quad (8)$$

Moldflow社は 1995년에 자동 미드플레인 생성기를 출시했다. 지오메트리 표현이 STL(Stereolithography) 형식으로 입력되고, 지정된 두께를 가진 메시로 변환되는 시스템을 개발했다(Kennedy, P., et al., 1997). 1997년에는 충전 해석을 위해 듀얼 도메인 유한요소 기술을 도입했다. 3D 충전 분석은 1998년에 시장에 소개되었고(Rajupalem, V., et al., 1997), 1999년에 보압 기능이 추가되었다. 계산된 섬유 배향 분포로부터 기계적 특성 계산을 포함하는 3D 변형 분석을 도입했다(Fan, Z., Costa, et al., 2004). 금형 조립에 대한 산업 트렌드에 따라 3D 및 듀얼 도메인 분석 제품은 오버 몰딩 및 인서트 분석으로 확장하여 압력 방정식에 항을 추가하여 압력 계산에 대한 금형 탄성의 영향을 고려했다. 수축 및 휨 예측에 중요한 요소인 보압 중 압력 감쇠에 대한 금형 탄성의 효과를 보여 주었다(Leo, V., et al., 1996). 금형 변형을 포함한 추가 연구는 금형의 구조와 탄성 특성 특히 코어 이동으로 인한 금형 변형을 포함하도록 확장하였다(Delaunay, D., et al., 2000). 이러한 분석에는 유동 해석과 구조해석의 결합이 필요하였다(Bakharev, A., et al., 2004). 이 기술을 사용하면 성형 사이클 동안 금형의 잔류 응력을 확인을 통해 금형 수명을 평가하기 위한 금형 피로 예측을 할 수 있게 되었다.

3) 사출 성형 CAE 최근 요구사항

1978년 Moldflow 소프트웨어를 개발한 Colin Austin은 컴퓨터를 구입하기 위해 집 저당을 잡았다고 하는데, 그 컴퓨터의 메모리는 64KB이며,

그중 32KB가 BASIC이 차지했다고 한다(Moldmakingtechnology, 2021). 22년이 지난 2000년은 Windows NT(32bit)에 2 CPU, 256Mb RAM 정도를 사용했으며, 다시 21년이 지난 현재 2021년은 Windows 10(64bit), 196Gb RAM로 계산력이 놀라울 정도로 발전했다. 이로 인하여 기대되는 기술 경향은 중앙에 데이터가 모이고 데이터 공유, 재사용이 늘어나고 있다. 또한 어디서나 액세스가 가능하며, 정형, 비정형과 같은 새로운 종류의 데이터들이 늘어나고 있다. CAE는 API¹³⁾를 통해 자동화로 반복되는 업무에서 해방되어가고 있으며, 작업 순서는 간소화되고 있다. 그러나 아직도 CAE 엔지니어는 매일 아래와 같은 질문에 직면한다.

- ❖ 짧은 시간에 프로젝트를 혁신할 수 있을까?
- ❖ CAE 정확성을 향상할 수 없을까?
- ❖ 더 적은 재설계로 부품 품질을 개선할 수는 없을까?
- ❖ 프로세스 개선으로 제조를 간소화할 수 있을까?

위와 같은 요구사항을 달성하기 위해 CAE 정확성 인자에 대하여 파악하고, 정확성 높은 해석과 낮은 해석을 분류하고, 표준화 작업을 해야 한다. 표준화가 완료되면 해석 자동화를 통한 효율 극대화가 가능하다. 자동화는 메시, 피드 시스템, 공정조건 입력 등 전 범위에 자동화가 가능하다. 과거에는 유사한 작업을 반복적으로 실시하며 작업 중 오류가 발생하거나, 숙련도에 따라 작업 시간이 달라짐과 작업자마다 설정이 달라서 결과물 편차가 발생하는 문제가 있었다. 그러나 API를 통해 반복 작업을 자동화로 개발하면, 작업 중 오류를 방지할 수 있고, 작업 시간을 단축시키고, 설정 표준화로 작업자간 편차를 줄어둘게 할 수 있다. 결과 분석 및 보고서 자동화가 가능하며, 데이터베이스 구축은 CAE 결과를 자동으로 엑셀이나 CSV 파일 형식으로 저장하는 것이다. 일반적으로 CAE 결과를 검토할 때 보고서를 열어서 검토하거나, CAE의 연구 결과를 열어서 확인한다. 이러한 데이터를 통계적 분석이나 경향을 파악하기 위해서 엑셀과 같은

13) Application Programming Interface: 응용 프로그램 인터페이스, 자동화 함수의 집합체

스프레드시트 소프트웨어에 직접 입력하여 저장하는 과정에서 오류 발생 및 시간이 오래 걸리고, 표준화가 되지 못하였다. 그러나 API 개발을 통해 CAE 완료 후 엑셀로 자동 저장하여 표준화가 가능하며, 데이터베이스가 자동으로 저장된 이후 지속적으로 통계적 분석을 통해 예측 분석 및 의사 결정 엔지니어링 기술에 대한 역량을 강화할 수 있다. 즉, 데이터가 확보되면, 데이터 사이언스를 통한 예측 모델 생성 및 최적화를 통한 문제 해결 방법 구축이 가능하다.

제 2 절 사출 성형 CAE를 위한 수지 물성 측정 연구

1) CAE를 위한 수지 물성 품질

적확성이 확보된 CAE 예측은 플라스틱 성형품의 품질 향상 및 납기를 단축할 수 있는 전초기지를 마련한 셈이다. CAE 적확도를 높이기 위해 정교한 플라스틱 유변 물성 측정은 필수적인 요소이다. 즉 CAE에서 물성을 그대로 구현할 수 있도록 실제 수지의 점도나 열적 특성 등을 측정하여 시뮬레이션에 복제해야 한다. 수지 물성 측정은 플라스틱 재료에 특화된 방법과 실험실 장비를 이용하여 맞춤형 유변 물성 측정과 데이터 피팅이 필요하다. 그러나 측정 방법과 기기가 달라질 경우 CAE 결과 또한 흔들릴 수밖에 없다. 그래서 MPL¹⁴⁾에서는 지속적으로 수직 측정 기술을 위해 표준화가 되어 있으며, 수지 물성의 품질을 평가하여 품질이 높은 순으로 금, 은, 동으로 나누었다. 신뢰성 있는 결과를 얻기 위해서 실제 사용하고 있는 수지의 물성을 정확하게 측정하여 시뮬레이션에 적용해야 한다.

2) CAE를 위한 수지 측정 범위

수지 측정 범위는 아래와 같다. 측정 범위에 따라 해석 범위가 달라지는데 측정 범위를 충전 예측까지만 적용한다면 이후 보압과 변형과 관련된 물성은 일반화된 값이 적용되기 때문에 적확성이 낮아질 수밖에 없다.

- ❖ 충전 예측을 위한 측정: MPL-110
- ❖ 충전 및 보압 예측을 위한 측정: MPL-125
- ❖ 충전, 보압, CRIMS 제외 변형 예측을 위한 측정: MPL-130
- ❖ 충전, 보압, CRIMS를 통한 수축 보정 예측을 위한 측정: MPL-135
- ❖ 충전, 보압, CRIMS 및 변형 예측을 위한 측정 : MPL-150

14) MPL(Moldflow Plastic Lab): Autodesk Moldflow 수지 측정 연구소

추가로 특정 조건에서 신뢰성 향상을 위해 아래와 같은 옵션을 선택할 수 있다.

- ❖ 점도의 압력 의존성 예측을 위한 측정(Pressure Dependent Viscosity by Injection Molding Rheometer)
- ❖ 고 전단 점도 예측을 위한 측정(High Shear Viscosity by Injection Molding Rheometer)

3) 수지측정 방법 및 설명

가) 전단 점도(Shear Viscosity)

전단 점도(Shear Viscosity)는 전단 변형에 의한 유동 재료의 저항을 측정하는 것이다. 전단 속도, 온도 및 압력의 함수로 흐르는 샘플 수지의 전단 속도 (Shear Rate) 당 전단 응력(Shear Stress)을 측정한다. 점도 테스트는 표준 ASTM¹⁵⁾ D5422-09와 같이 모세관 레오미터(Capillary Rheometer)에 의한 열가소성 재료를 측정하며, ASTM D3835-08과 같이 모세관 레오미터를 사용하여 고분자 재료의 특성을 측정한다. 또한 ISO-11443(2005) 규격으로 모세관 레오미터와 슬릿다이 레오미터(Slit-die Rheometer)를 사용하여 플라스틱의 유동성을 측정한다. IMR¹⁶⁾은 사출 성형기에서 전단 점도가 측정된다. 플라스틱 수지는 사출 장치의 배럴에 직접 부착된 모세관 또는 슬릿다이를 통해 가소화된 수지가 압출된다. 각 사출 속도에 대해 금형의 용융 온도 및 압력 강하는 길이에 걸쳐 기록된다. 이는 다양한 사출 유속 및 용융 온도에서 반복된다. 결과적으로 Cross-WLF(Autodesk Moldflow Help Cross-WLF viscosity mode, 2021) 점도 모델은 수치, 유한 차분 체계를 사용하여 유변학적 물성 데이터에 적합하다. 측정된 온도 및 유속 값은 유동 시뮬레이션에서 금형 형상을 통해 사출 압력을 예측하는 데 사용된다. 점도 모델은 측정된 압력과 시뮬레이션 된 압력 간의 차이를 최소화하도록 조정된다. Moldflow는 수정된 형태의 Cross-WLF 모델을 사용하여 모든 전단 속도,

15) American Society for Testing Materials: 미국 재료 시험 협회

16) Injection Molding Rheometer: 사출 성형 점도 측정기

온도 및 압력에서 점도를 특성화한다. 식 (9)는 $T_g^{-17} \sim T_g + 100$ 일 때 Cross-WLF 점도 모델이며 식 (10)은 영점 전단 점도(Newtonian 영역에서의 점도)를 나타내고 있다. 식 (11)은 전단 박하가 생길 때 발생하는 온도이며, 식 (12)는 온도 상수이다(Autodesk Materials Lab, 2019).

$$\eta = \frac{\eta_0}{1 + \left(\frac{\eta_0 \dot{\gamma}}{\tau^*} \right)^{1-n}} \quad (9)$$

$$\eta_0 = D_1 \exp \left[- \frac{A_1 (T - T^*)}{\widetilde{A}_2 + (T - T^*)} \right] \quad (10)$$

$$T^* = D_2 + D_3 P \quad (11)$$

$$\widetilde{A}_2 = A_2 + D_3 P \quad (12)$$

- ❖ η_0 : 영점전단점도(Newtonian 영역에서의 점도)
- ❖ T^* : 전단 박하가 생길 때 발생하는 온도($T^* = D_2 + D_3 P$: D3값이 고려 됨)
- ❖ D_1 : 영점전단점도 보정계수
- ❖ D_2 : 일반적으로 유리전이온도(대략 $D_3 = 0$)
- ❖ D_3 : 선형적인 압력의존계수(K/Pa)
- ❖ A_1 : 17.44(유리전이온도 $T_g = T^*$ 일 때)
- ❖ A_2 : 51.6(K)(유리전이온도 $T_g = T^*$ 일 때)

나) pvT(Pressure-Volume-Temperature)

pvT는 재료의 특정 부피 즉 비체적(Specific Volume)을 압력과 온도의 함수로서 측정하는 것이다. 측정 방법으로 고압 간접 팽창 계(High Pressure indirect Dilatometry)를 사용한다. 테스트 전에, 표본의 밀도는 추가 측정을 위한 기준점(Reference Point)으로 사용하기 위해 실온(Room Temperature)에서 결정된다. 그런 다음 압력-체적-온도 측정은 제한 유체(수은)에 샘플을

17) T_g (Transition Temperatures): 유리전이온도

포함하는 Gnomix社의 pvT 장치를 사용하여 수행된다. 벨로우즈(Bellows)의 압력은 0 ~ 200MPa 범위에서 변화하며 제한 유체에 의해 샘플로 전달된다. 벨로우즈의 변위는 샘플의 부피 변화를 결정하는 데 사용된다. pvT 관계는 식 (13)과 같이 이중 도메인 테이트 방정식을 사용하여 모델링 된다.

$$v(T,p) = v_0(T) \left(1 - C \cdot \ln \left(1 + \frac{p}{B(T)} \right) \right) + v_1(T,P) \quad (13)$$

$v(T, p)$ 는 온도 T 및 압력 p 에서의 비체적, $v_0(T)$ 는 제로 게이지 압력에서의 비체적이며, C 는 0.0894(보편 상수), $B(T)$ 는 압력 감도를 나타낸다. 수지의 열역학적 특성은 고체 상태로 전환될 때 변하기 때문에 pvT 관계를 모델링하려면 두 개의 온도 영역이 필요하다. 제로 게이지 압력에서의 체적 천이온도는 b_5 로 표시되고 압력에 따른 천이의 선형 증가는 b_6 로 표시된다. 등압선 곡선을 천이온도로 외삽하여 얻은 비체적은 b_1 로 표시된다. 이 값은 유리 천이를 교차할 때 이중 도메인에 대해 동일하다. 그러나 재료가 반 결정성 재료인 경우 결정화로 인한 천이는 $b_{1m}(b_5$ 및 제로 압력에서의 용융 비체적)이 b_{1s} 보다 큰 비체적의 급격한 변화를 동반한다. 특정 부피의 온도 의존성은 b_2 에 의해 결정되는 반면, b_3 및 b_4 는 고체 및 용융 상태에서 $B(T)$ 를 특성화한다. b_4 가 양수일 때 온도가 증가함에 따라 비체적이 압력에 더 민감해진다. 상수 b_7 , b_8 및 b_9 는 고체 상태에서 $v_1(T, p)$ 을 특성화한다. pvT 테스트 결과는 고체 및 용융 상태의 밀도 값을 설정한다. $b_5 + b_6p$ 보다 온도가 낮을 때, 고체 상태로 식 (14),(15),(16)과 같이 계산되며, $b_5 + b_6p$ 보다 온도가 같거나 높을 때, 용융상태로 식 (17),(18),(19)로 계산된다.

$$v_0(T) = b_{1s} + b_{2s}(T - b_5) \quad (14)$$

$$B(T) = b_{3s} \exp[-b_{4s}(T - b_5)] \quad (15)$$

$$v_1(T,p) = b_7 \exp[b_8(T - b_5) - b_9p] \quad (16)$$

$$v_0(T) = b_{1m} + b_{2m}(T - b_5) \quad (17)$$

$$B(T) = b_{3m} \exp[-b_{4m}(T - b_5)] \quad (18)$$

$$v_1(T, p) = 0 \quad (19)$$

다) 천이온도(Transition Temperature)와 취출온도(Ejection Temperature)

천이온도는 수지가 용융 상태에서 고체 상태로 전환되는 온도로 미성형을 예측할 때 사용된다. 유동 선단의 온도가 천이온도 이하일 때 미성형이 발생한다고 예측할 수 있다. 취출온도는 사출 품이 금형에서 제거될 수 있을 만큼 충분히 냉각된 온도로 사이클 타임을 예측할 때 사용된다. 천이온도와 취출온도 측정 방법은 ASTM D3418-12e1와 같이 시차 주사 열량 측정법 즉 DSC(Differential Scanning Calorimetry)에 의한 고분자 융합 및 결정화의 천이온도 및 엔탈피에 대한 표준이 적용된다. ASTM D3418에 명시된 바와 같이 천이 및 취출온도는 결정성 재료의 경우 외삽된 고체화 시작 및 끝에서, 비결정성 재료의 경우 유리전이 영역의 중간 점 및 끝에서 각각 결정된다. 결과적으로 천이온도와 취출온도는 단일 포인트 값이다.

라) 비열(Specific Heat)

비열은 열에너지의 변화에 따라 재료가 온도를 얼마나 변화시키는지 측정한다. 즉 재료의 단위 질량을 1도(°C) 높이는데 필요한 열량이다. 비열은 ASTM E1269-11과 같이 시차 주사 열량계를 이용하여 비열 용량이 결정된다. ASTM D3418-12e1은 시차 주사 열량 측정법에 의한 고분자 융합 및 결정화의 T_g 및 엔탈피에 대한 표준 테스트 방법이다. TA社의 DSC는 비열 측정을 수행하는 데 사용된다. 이 방법은 빈 팬과 비교하여 열 흐름의 차이를 통해 샘플의 비열을 결정한다. TA社의 기술을 사용하여 각 센서 간의 불균형을 특성화하여 더 평평하고 더 낮은 변동 기준선을 결정한다. 비열 측정(위에 표시된 회로도)을 수행하기 위해 질량 샘플 m 을 팬 중 하나에 넣고 다른 팬은 비워 둔다. 센서 불균형으로 C_p (비열)은 기준선과 시료의 온도를 ΔT 로 변경하는데 필요한 시료 간의 열 흐름 차이 식 (20)과 같이 ΔQ 에서 계산된다.

$$C_P = \frac{\Delta Q}{m \Delta T} \quad (20)$$

비열은 20 °C / min의 냉각 속도로 최대 가공 온도에서 50°C 이하까지 측정된다.

마) 열전도율(Thermal Conductivity)

열전도율은 전도에 의해 열을 전달하는 재료의 물성을 측정한다. 즉 단위 길이 및 온도 당 전도에 의한 열전달 속도이다. ISO 22007-2와 같이 플라스틱-열전도율 및 열 확산율에 의해 결정된다. 과도 평면 열원 TPS¹⁸⁾ 방법은 Hot Disk TPS 2500 S 시스템을 사용하는 TPS 방법으로 측정된다. 여기서 TPS 센서는 사출 성형 플라크에서 절단된 테스트 재료의 두 디스크 사이에 배치된다. 샘플과 센서 스택은 액체 상태든 고체 상태든 재료 샘플과의 접촉을 보장하기 위해 스프링 장착 셀에 넣어진다. 이 셀을 오븐에 넣어 필요한 온도 범위에서 측정을 수행한다. 재료의 열전도도를 결정하기 위해 TPS 센서는 지정된 열 펄스를 적용하고 지정된 기간 온도 응답을 모니터링 하는 역할을 한다. 센서 인터페이스 및 셀 경계의 영향을 수정한 후 샘플 표면 온도 상승 (ΔT_s)을 결정할 수 있으며 무 차원 시간 매개 변수(D)에 대해 플롯할 때 직선을 따라야 한다. 선의 기울기는 식 (21)과 같이 벌크 열전도율 측정과 관련이 있다.

$$\Delta T_s(\tau) = P_0(\pi^{3/2}rk)^{-1}D(\tau) \quad (21)$$

여기서 P_0 는 열 펄스 전력 출력, r 은 TPS 센서의 반경, k 는 재료 열전도도, τ 는 TPS 센서의 상수를 곱한 시간 제곱근과 관련이 있다.

바) 수축(Shrinkage)

18) TPS(Transient Plane Source): 천이 평면 소스

수축 측정은 플라스틱 부품과 금형의 치수 차이를 나타낸다. 부품 수축에 대한 성형 조건의 영향을 정량화하기 위해 일련의 측정이 수행된다. 수축 측정을 위해 사출 성형기에서 수축 플라크(Shrinkage Plaques)를 성형한다. 테스트 금형의 고정 측에는 미세한 격자 패턴이 새겨져 있어 부품의 선형 치수를 정확하게 결정할 수 있다. 테스트 플라크 사출은 다양한 성형 조건(용융 온도, 금형 온도, 유속, 보압 시간, 냉각 시간, 보압력 및 부품 두께)에서 생산한다. 성형 후 샘플은 통제된 환경에서 명목상 일주일 동안 어닐링 한다. 선형 좌표 광학 측정 장치(Linear Coordinate Optical Measuring Device)는 각 조건 세트에서 성형된 사출 부품의 정확한 치수를 결정하는 데 사용된다. 측정된 각 성형 조건에서 유동 시뮬레이션이 수행되며 이러한 결과는 부품의 수축을 예측하는 데 사용된다. 수축 모델의 계수를 결정하기 위해 측정되고 예측된 수축의 회귀 분석이 수행된다. 수축 측정이 된 경우 CRIMS 모델(Corrected Residual In-Mold Stress Model)이나 잔류 변형 모델(Residual Strain Model)로 적용할 수 있다.


사) 금형 검증(Mold Validation)

금형 검증은 실험으로 측정된 캐비티 압력과 측정한 재료 데이터를 사용하여 시뮬레이션한 예측 결과를 비교한다. 서로 다른 두께의 플라크를 사출 성형기에서 성형한다. 성형은 일반적으로 권장 용융 온도 및 금형 온도와 다양한 유속에서 수행한다. 유동 시뮬레이션은 측정된 유동, 열 및 pVT 데이터를 사용하여 각 성형 조건에서 수행한 뒤 예측된 캐비티 압력과 실험한 결과를 비교한다.

제 3 절 사출 성형 CAE 메커니즘의 이해

1) 유동 및 변형 CAE 메커니즘

사출 성형 CAE의 정확성 개선이 어려운 이유는 다양한 상관관계로 얽혀 있기 때문이다. 특히 치수 문제의 대다수는 힘 변형으로 발생하는데 힘 예측은 유동 예측의 결과물이기 때문에 유동 해석의 결과가 일치해야 정확성 있는 힘 결과를 도출할 수 있다.



[그림 2-2] 유동 및 변형 해석을 위한 프로세스(황순환, 2017)

[그림 2-2]는 유동 및 변형 해석 프로세스를 설명하고 있다. 유체 역학을 기반으로 사출 압력과 유량이 계산되고, 첨가제가 함유된 플라스틱 수지의 경우 첨가제 함량과 중형비 등의 정보를 기반으로 배향 정보 (Fiber Orientation)가 계산된다. 또한 열전달 계산을 통해 금형과 플라스

틱 수지의 온도 및 고화 층을 계산하여 열역학 계산을 거쳐 미세 역학(Micromechanics)으로 전달된다. 첨가제가 함유되지 않은 수지는 미세 역학 계산은 하지 않는다. 수지의 흐름에 저항하는 점도 모델은 기본적으로 Cross-WLF를 사용하지만, 필요에 따라 Second Order¹⁹⁾, Matrix Mode²⁰⁾을 사용한다. 배향 정보 계산은 옵션에 따라 달라질 수 있다. 3D 메시 타입의 초기 배향 계산은 MRD(Moldflow Rotaional Diffusion model)이지만, 긴 섬유(Long Fiber)의 경우 ARD-RSC 모델을 선택해야 하며, 배향의 영향도를 조절하는 C_i 값을 변경하여 상관 분석이 필요할 수 있다. 온도와 압력에 따른 체적 수축 정보가 계산되면 수축모델(Shrinkage Model)로 전달된다. 미세 역학(Micromechanics)은 배향 정보를 기반으로 각 위치에 따른 열팽창계수가 업데이트되어 수축모델(Shrinkage Model)로 전달된다. 배향 정보를 기반으로 각 위치에 따른 탄성계수(Elastic Modulus, Young's Modulus)가 초기 스트레스(Initial Stresses) 계산으로 전달된다. 열팽창계수 및 탄성계수는 데이터베이스에 있는 물성을 사용하며 온도와 압력에 따른 체적 수축 정보와 미세 역학(Micromechanics)에서 계산된 CTE²¹⁾를 기반으로 선형 수축이 계산되어 초기 스트레스로 변위 값이 전달된다. 미드플레인과 듀얼 도메인 메시 타입의 수축모델(Shrinkage Model)은 CRIMS(Corrected Residual In Mold Stress) 물성이 측정된 경우, 실험을 기반으로 수축 모델이 보정되어 보다 정확성 있는 수축 계산이 가능하다. 미세 역학(Micromechanics)에서 계산된 탄성계수와 수축모델에서 계산된 변위를 기반으로 초기 스트레스를 계산하여 구조 해석(FEA Structural Analysis)으로 전달된다. 초기 스트레스 값과 무한강체 운동을 피하기 위한 경계조건이 자동으로 반영된 구조해석 계산이 완료되면 변형 해석(Warpage) 결과를 확인할 수 있다. 변형 결과에서 변형의 원인을 파악할 수 있으며 총 4가지의 원인 즉 배향 편차, 수축 편차,

19) Second Order: CAE에서 사용하는 점도 모델 중 하나로, 2차 방정식의 근의 공식으로 점도의 온도 및 전단율 종속성을 계산함.

20) Matrix Model: CAE에서 사용하는 점도 모델 중 하나로, 특정 온도, 전단율 및 압력에서 제공되는 측정 데이터로부터 점도를 결정하는 데 사용됨.

21) CTE(Coefficient of Thermal Expansion): 열팽창계수

냉각 편차, 코너 효과에 의한 응력 발생으로 휨이 발생하는 것을 CAE에서 확인할 수 있다.


2) 배향 편차(Differential Orientation : 유동 흐름 방향의 변화가 원인)

제품의 두께 방향으로 온도를 살펴보면 금형과 닿고 있는 부분이 차갑고, 중심 부분이 뜨겁다. 충전 과정에서 플라스틱 수지의 분자, 결정, 첨가제가 두께 방향으로 결이 달라질 수 있는 이유가 바로 여기에 있다. 이 결을 배향이라고 한다. 배향의 편차가 발생할 경우 휨의 원인이 되는 잔류응력이 발생한다. 두께가 다르거나 흐르는 방향이 복잡하면 유동에 의한 잔류응력이 발생한다. [그림 2-3]과 같이 직사각형 제품에서 게이트가 중심에 있는 경우 방사 형태로 충전되다가 유동 선단의 수지가 가까운 벽에 부딪치고 흐름 방향이 바뀌면, 표면층은 초기 방사 형태로 배향되고, 방향이 바뀐 시점의 두께 층은 다른 방향으로 배향되면서 두께 방향으로 다른 배향이 이루어진다. 이때 한 제품에 압축력과 인장력의 균형이 깨진다면 휨으로 이어지는 것이다. 같은 제품이라도 한쪽 끝 게이트를 위치할 경우 흐르는 방향이 일정하여 두께 방향으로 일정한 결을 유지하게 되고 잔류응력은 발생하지 않고, 휨도 발생하지 않는다. 금형 온도가 위치에 따라 다를 경우에도 배향이 달라지고 내부 응력이 발생한다.


[그림 2-3]는 평판 제품에서 전단 층(셀)과 코어 층이 다른 배향 결과를 나타내고 있다. 전단 층은 유동 방향으로 정렬되며, 코어 층은 임의 또는 교차 유동된다. [그림 2-4]과 같이 유동 패턴이 방사형일 경우 평면 내 유동 선단면적이 넓어지므로 플라크 형태와 같이 판 거동보다 디스크 형태의 유동은 코어가 두껍고 교차 유동 방향으로 정렬된다. 섬유 배향 예측은 유체역학 항과 상호작용 항으로 구성된다. 고분자 입자의 유동에 의한 유체역학 영향은 Jeffery 방정식으로 설명된다. 상호작용 항은 Folgar와 Tucker가 제안하여 섬유끼리 기계적인 상호작용으로 모델링하도록 통합되었다. RSC²²⁾모델은 환산 변형 클로저 모델로 Folgar와 Tucker가 제

22) RSC(Reduced Strain Closure): 섬유 배향 해석을 수행할 때 섬유 배향을 계산하기 위한 옵션으로 확산 항이 스칼라 계수 k만큼 줄어들고, 클로저 항으로 대체하는 이론.

안한 모델에서 배향 텐서의 과대평가를 개선하기 위해 개발되었다.²³⁾





[그림 2-3] 평판의 섬유 배향(Autodesk Moldflow Insight Advanced Cool and Warp, 2016)



[그림 2-4] 중심 게이트 형상의 섬유 배향(Autodesk Moldflow Insight Advanced Cool and Warp, 2016)

23) Delphi Technologies社의 RSC 모델은 미국 특허를 보유하고 있으며 Autodesk社는 이 모델 사용에 대한 독점 라이선스를 보유하고 있음.



[그림 2-5] 평판의 섬유 배향(상), 중심 게이트 섬유 배향(하) 사례

배향 텐서의 고윳값 성장률을 스칼라 계수 단위로 축소하고, 벡터 회전을 고정으로 유지한다. ARD²⁴⁾ 모델은 이방성 회전 확산 모델로 긴 섬유


(Long fiber) 복합재료의 배향을 예측하기 위해 개발되었다. 일반적으로 1mm 이상의 섬유를 긴 섬유로 간주한다. Folgar와 Tucker 및 RSC 모델에서 사용되는 등방성 확산으로는 긴 섬유의 상호작용을 예측할 수 없어, Phelps와 Tucker가 ARD 모델을 개발하였다. MRD(Moldflow Rotational Diffusion)모델은 Folgar와 Tucker가 배향 방정식을 기반으로 상호작용계수 두께 모멘트(D_z)와 상호작용계수(C_i)를 자동으로 계산하거나 임의의 값을 지정할 수 있다(Autodesk Moldflow Help Theoretical basis for fiber orientation prediction, 2021).

3) 수축 편차(Differential Shrinkage: 플라스틱 수지의 온도와 압력의 이력에 따른 수축 편차)

플라스틱 수지는 용융되면 팽창하고 굳으면 다시 수축한다. 이때 압력을 받으면서 고체화가 되면 수축이 덜 발생하고, 압력을 받지 못한 상태에서 고체화가 되면 많이 수축한다. 초기에 용융된 수지가 금형으로 주입될 때 고체화 영역과 용융 영역으로 나뉜다. 내부 중심부의 수축에 의한 인장력과 고화 층의 압축력에 의해 균형을 이루면 내부 응력 즉 잔류응력은 발생하지 않는다. 그러나 제품의 위치별 압력과 온도의 변화가 발생할 때, 이 균형은 깨지고 잔류 응력 및 휨이 발생한다. 고화에 따른 제품의 두께 방향으로 체적 수축과 온도와 압력의 변화가 휨을 유발한다. 표면층에서 고화되기 시작하고, 안쪽 층으로 점차 이동하는 과정에서 고화되는 온도에 도달하는 시점과 압력의 이력이 달라질 때 비체적에 변화를 나타낸다. 비체적의 변화는 p/vT 물성을 활용하여 예측한다. 정리하면 수축 편차의 원인은 아래와 같다.

- ❖ 게이트 근처와 게이트와 멀리 있는 곳의 수축 편차
- ❖ 두께가 두꺼운 곳과 얇은 곳의 수축 편차
- ❖ 금형의 온도가 뜨거운 곳과 차가운 곳의 수축 편차

24) ARD(Anisotropic Rotary Diffusion): 이방성 회전 확산 모델은 Phelps 및 Tucker가 개발하여 모든 단위 벡터 배향에 따라 추적된 단위 구의 면에 정의되어 긴 섬유일 때 최적화 됨.




[그림 2-6] 두께 및 게이트의 체적 수축 및 휨 결과(황순환 외, 2018)

[그림 2-6]은 두께의 변화에 따른 체적 수축 편차 및 휨에 대하여 설명하고 있다. 제품 두께 편차가 있으면 두께가 두꺼운 영역은 게이트 고화 이후 압력을 받지 못하고 고화가 되어 높은 수축이 발생한다. 얇은 영역은 높은 압력을 받으면서 고화되어 낮은 수축이 발생한다. 한 제품에서 낮은 수축과 높은 수축이 동시에 발생할 때 힘의 균형이 깨지면서 응력 및 휨이 발생한다.

금형의 온도가 위치에 따라 다를 경우, 제품의 온도와 압력의 이력이 위치에 따라 달라지고 힘의 균형이 깨지면서 휨을 일으키는 응력이 발생한다. [그림 2-7]와 같이 상·하측의 온도 편차도 휨의 원인이 될 수 있지만, 앞서 언급한 바와 같이 같은 상측, 또는 같은 하측의 위치에 따른 온도 편차도 수축 편차의 원인이 되기 때문에 금형의 온도 관리에 주의해야 한다.

4) 금형 온도 편차(Differential Cooling: 금형의 상·하측 온도 편차에 의한 수축 편차)

상·하측 금형 표면의 온도 편차에 의한 불 균일 수축은 휨을 일으키는 응력을 발생시킨다. 금형 표면과 용융 수지가 닿아, 고체화될 때 금형의 온도 편차는 두께 방향으로 고화되는 속도 편차를 일으키고, 압력의 이력도 달라지므로 휨이 발생하는 원인이 된다. 금형 온도 조절을 위해 냉각수나 히터를 설계할 때 제품 표면과 일정한 간격으로 유지하는 것이 원칙이다. 하지만 제품 형상의 복잡성이나 언더컷과 같은 구조 때문에 이론적인 설계 원칙을 유지하는 것이 불가능한 경우가 많다. [그림 2-7]와 같이 상·하측의 금형에 온도 편차가 발생하면 제품의 두께 방향으로 비대칭적인 인장·압축패턴을 유발해 휨 변형의 원인이 되는 모멘트가 발생한다. 결과적으로 균일하지 않은 두께를 가지거나 박스 형상의 코너 쪽의 코어 형상과 같이 냉각이 안 되는 부분을 가진 제품은 잔류 응력 및 휨이 발생한다.



[그림 2-7] 상·하측 금형 온도 편차에 의한 휨(황순환 외, 2018)

5) 결정화 편차(Differential Crystallization: 결정성 수지의 결정화 속도에 따른 수축 편차)

플라스틱 분자는 긴 원자 체인으로 구성된다. 분자 체인은 결정 구조를 규칙적으로 만드는 결정구조나 비결정 구조 또는 반 결정 구조를 만드는 형태의 조합이 된다. 결정화 편차는 수축 편차를 유발하여 사출 성형품의 휨에 영향을 준다. 결정구조는 용융 수지의 냉각 속도에 의존적이다. 용융 수지가 빠른 속도로 고화되면 결정화에 영향을 줄 수 있는 시간이 짧아지므로 수축이 덜 된다. 그러나 금형의 온도가 높을 경우 냉각 속도가 느려

지고 이때 결정화에 영향을 줄 수 있는 시간이 길어지므로 결정 함량이 많아져 더 잘 수축하게 된다. 냉각 속도에 영향을 줄 수 있는 요소는 금형의 온도에 영향을 줄 수 있는 냉각 구조와 냉각수 온도가 있다. 또한 사출 성형 제품의 두께가 두꺼운 경우 냉각 속도는 느려지므로 결정 함량이 많아지고 체적 수축이 높아진다. 그리고 두께가 매우 얇을 때 pvT 데이터에서 예측한 결과보다 결정 함량이 낮아지므로 체적 수축은 낮아진다.


6) 코너 효과(Corner Effect)

코너 형상이 있는 사출 성형품은 변형에 취약하다. 코너 효과에 의한 변형의 주요 원인은 열 축적과 수축 효과이다(Ammar, A., et al., 2001). 성형품의 코너 영역에서 열이 빠져나갈 수 있는 능력이 부족하여 열 집중에 발생하고 상대측과의 온도 편차에 의한 응력이 발생한다. 이는 냉각 해석을 통해 고려되며 냉각 효과에서 설명할 수 있다. 또한 금형 구속조건으로 인하여 두께 방향의 수축은 억제되지 않지만, 코너 영역은 금형 구속조건으로 억제되어 추가 변형이 발생한다. 이러한 현상을 고려하려면 듀얼도메인 메시나 미드플레인 메시일 경우 코너 효과 옵션으로 고려할 수 있다. 코너 효과는 평면 방향과 두께 방향의 수축 차이 및 금형 구속조건과 관련이 있다. 체적 수축을 줄이면 두께 방향의 수축을 줄여 코너 효과에 의한 변형을 줄일 수 있다.

7) 변형을 줄이기 위한 방법

변형을 줄이는 방법은 변형의 원인을 확인하는 것에서 시작된다. 앞서 설명한 힘을 일으키는 4가지의 원인 중 주된 원인이 무엇인지 확인하고, 원인에 맞게 해결 방법을 적용하여 변형을 줄일 수 있다. [그림 2-8]은 변형을 줄이기 위한 방법을 설명하고 있다. 변형 감소를 위해 변형의 원인이 냉각 편차(DC)로 인한 변형이라면 상·하측의 온도 편차를 줄일 수 있도록 냉각관을 추가하거나 열 전도성이 높은 금형 재료를 적용, 또는 냉

각수 온도를 변경하여 냉각 최적화로 변형을 줄일 수 있다. 변형의 원인이 수축 편차(DS)라면 수축의 변화를 줄이기 위해 두께 변화를 최소화하여 충전 최적화를 적용하고, 다단 보압을 적용하여 보압 조건 최적화를 적용한다. 또한 금형 온도 변화를 최소화하여 냉각 최적화를 통하여 체적 수축 편차에 의한 힘을 줄일 수 있다. 변형의 원인이 배향 편차(OE)라면 이방성 재료거나 결정성 수지일 가능성이 높다. 이 경우 게이트 위치 변경을 통하여 배향 변화를 적용하거나 성형 조건 변경을 통한 충전 최적화를 실현한다. 또한 금형 온도 편차를 줄여 냉각 최적화가 되면 변형을 줄일 수 있다. 코너 효과(CE)는 보압 증가와 같은 보압 최적화로 체적 수축을 감소하여 변형을 줄일 수 있다.



[그림 2-8] 변형을 줄이기 위한 방법(Autodesk Moldflow Insight Advanced Cool and Warp, 2016)

제 3 장 사출 성형 CAE 적확성 개선 연구

제 1 절 스파이럴 금형의 형상 검증에 관한 연구


1) 적확성 정의

CAE 결과를 평가할 때 정확성, 신뢰성, 적확성 등 다양한 용어를 혼용해서 사용하고 있다. 적확성의 적(的)은 목표, 과녁을 의미하며 조금도 틀리거나 어긋남 없이 정확하고 확실하다는 뜻으로 CAE 결과를 평가할 때 적합한 용어이다. 정확성의 정(正)은 바르고 확실한 성질을 뜻하고 있어 ‘정확한 방법으로 CAE를 운영한다.’고 사용하기에 적합하다. 신뢰성은 굳게 믿고 의지할 수 있는 성질을 뜻하기 때문에 ‘CAE 적확성을 향상하여 신뢰성을 높이자.’라고 사용하기에 적합하다. 대부분의 CAE 엔지니어들은 CAE 적확성 확보를 위한 방법론 즉, 벤치마킹²⁵⁾에 대한 많은 고민을 하고 있다. 벤치마킹은 예측된 결과와 실제 결과를 비교하여, 품질 변수를 평가하는 것이다. 결과적으로 나중에 의사 결정을 할 때 실제와 해석이 달라서 발생할 수 있는 위험을 방지하고, 소프트웨어를 사용할 수 있는 자신감과 경험을 얻을 수 있다. Moldflow社의 설립자인 Colin Austin은 1970년대 후반 일본 도쿄에서 도시바를 위해 최초로 문서화된 CAE 벤치마킹을 수행했다(Moldmakingtechnology, 2021)고 한다. 벤치마킹을 성공적으로 수행하기 위해서 주요한 변수를 정의하고 고려해야 한다. 즉, 생산 중인 성형품의 사출 현상을 그대로 복제할 수 있는지를 확인하는 것이다. 이것이 가능하다면 CAE 상태에서 변경 사항이 생산 부품에 적용될 경우에도 동일하게 복제될 것이라는 확신을 가질 수 있다.

2) 사출 성형 CAE 작업 순서 및 주요 인자

25) 벤치마킹(Benchmarking): 예측된 결과와 실제 결과를 비교 후, 품질 변수를 평가하는 것.


사출 성형 CAE를 시작할 때 기본 절차는 [그림 3-1]과 같다. CAE 목표는 기존 부품인지 새로운 부품인지에 따라 달라진다. 기존 부품이 아니면 성형 가능성을 예측하고 개선하는 것이다. 또한, 충전 최적화, 러너 균형을 위한 치수 결정, 냉각 최적화, 성형 조건 최적화를 통해 제품 변형을 예측하고 공차 범위를 벗어났을 때 변형의 원인을 파악하고 변형 감소를 위한 대책을 마련하는 것이다. 그러나 기존 부품의 경우 이미 결과물이 있어서 CAE 목표는 기존 결과물의 현상을 복제하는 것이다. 문제 현상을 구현하기 위해 진행하는 프로세스는 정확한 CAD 모델을 가져와서 적절한 메시를 준비하고 실제 공정을 구현해야 한다.



[그림 3-1] 사출 성형 CAE 해석 순서(Autodesk Moldflow Insight Advanced Cool and Warp, 2016)

사출 성형 필수 요소는 사출기, 사출 공정조건, 금형, 플라스틱 수지이며 옵션으로 주변 장치인 온도 조절 장치(냉각기, 가열기, 온조기, 냉각수 펌프), 핫러너 컨트롤러, 취출 장치 등이 있다. CAE는 실제 사출 성형 공

정의 필수장치 및 주변 장치에 대한 정보를 정확히 반영해야 한다. 그러나 CAE 실무를 할 때 아직 모든 조건이 결정되지 않은 상태이거나 정보를 확보하지 못한 상태에서 선행 연구 단계로 진행할 때가 많아서 어려움이 발생한다. 이때 주요 인자를 파악하고 과거의 경험을 토대로 적절한 값을 선정해야 할 때도 있다. 주요 인자 및 변수값이 CAE에 어느 정도 영향력이 있는지를 파악하고 있다면 아직 결정되지 않은 변수를 조정하여 최적의 제품개발을 이뤄낼 수 있다.



[그림 3-2] 사출 성형 CAE 정확성 주요 인자

CAE의 주요 인자는 사출 성형의 필수 요소 조건과 CAE 변수 조건이 있다. 먼저 사출 성형의 필수 조건인 사출기 성능(최대사출 압력, 최대형체력, 최대유량, 증압비 등), 사출 공정조건(사출 속도, 보압력 및 보압 시간, 수지 온도 및 금형 온도 등), 금형 정보(피드 시스템, 냉각 시스템, 금형 재질 등), 플라스틱 수지 물성 정보(수지 사용 조건, 점도 특성, 열적 특성, 수축 특성(pvT), 기계적 특성)가 있다. CAE 변수 조건은 실제 형상 모델을 해석이 가능한 상태로 변경하는 메시 타입 선정 및 조밀도 결정, 솔버 옵션이 있으며, 이를 전체적으로 관장하는 해석자의 경험이나 준비





된 데이터가 있다. 사출 성형 CAE의 주요한 목표는 아래와 같다.

- ❖ 주어진 제품, 성형 조건, 수지 물성으로 성형 가능성 유무
- ❖ 성형품의 품질 필요조건(평탄도, 성형압력, 전단응력, 온도분포)에 적합한 수지 결정
- ❖ 최적의 사출 성형 조건(사출 속도, 보압 크기와 시간, 금형 온도, 수지 온도, 최대 사출 압력, 필요 형체력, 냉각수 온도) 결정
- ❖ 성형품의 품질 필요조건을 만족하는 금형의 게이트 개수 및 위치 최적화
- ❖ 웰드라인 위치 파악 및 원하는 위치로 변경하기 위한 제품 두께 최적화 또는 게이트 위치 변경 결정
- ❖ 에어트랩 발생 여부 확인
- ❖ 형상 변경, 두께 변경에 따른 품질 변화
- ❖ 균형 충전을 위한 러너 크기 결정
- ❖ 리브의 성형성 검토 및 리브 두께 변화에 따른 변형 가능성 검토
- ❖ 금형의 온도 균일화를 위한 냉각라인 최적화
- ❖ 스크랩 최소화를 위한 러너, 스프루 치수 결정
- ❖ 외관 표면 불량(싱크마크, 플로우마크, 실버스트리크, 전사불량 등) 예측 및 개선
- ❖ 사출 후 변형 예측 및 개선

3) 제품 형상 복제

CAE를 위한 제품 형상 복제는 CAE 정확성 확보를 위한 필수 요소이다. 형상이 잘못된 경우 CAE는 본질적으로 다른 제품을 분석하는 것이다. 형상 복제 품질은 CAE를 진행한 모델링 형상과 실제 금형에 적용된 형상이 얼마나 유사한지를 나타낸다. CAE는 형상을 메시로 정의하기 때문에 형상의 과도한 단순화 과정에서 잘못된 두께 인식이나 형상 오류, 금형 설계과정에서 파팅 라인을 결정하고 빼기 구배를 적용할 경우 두께 변경이 발생할 때 이러한 사항을 반영시키지 못할 때 형상 복제 품질은 낮아진다.

그래서 적확성 확보를 위해 메시 작업 후 각 영역의 형상 두께와 총 체적이 올바른지 확인해야 한다. [그림 3-3]은 CAE 상용 소프트웨어 Autodesk Moldflow Insight에서 사용 가능한 메시 타입을 설명하고 있다. 메시 타입에 따라 가정이 다르기 때문에 CAE 결과는 달라진다. 미드플레인 메시로 적용할 경우 두께는 사용자가 직접 정의하기 때문에 정확하게 입력해야 한다. 그러나 듀얼 도메인 메시의 경우 자동으로 두께가 입력되어 두께 진단을 실행하여 확인한다. 3D 메시는 두께 방향으로 메시가 있어 두께를 잘못 인식하는 경우는 없으나 두께 방향으로 레이어를 어떻게 결정하는가에 따라 적확성은 달라진다. 형상 복제 품질을 높이기 위해서는 적절한 메시 타입, 조밀도, 종횡비를 결정해야 한다.


Midplane	Fusion Dual Domain™	Tetrahedral 3D Volume
		
		
Triangle 	Triangle 	Tetrahedral 

[그림 3-3] 메시 타입 설명(황순환 외, 2018)

4) 사출 속도 복제

유동길이(L: Flow Length)와 두께(t: Wall Thickness)의 비를 유동비


(L/t)라고 하는데, 사출 현장이나 금형 설계자들은 성형성을 쉽게 예측하기 위해 유동비를 이용한다. 과거에는 엔지니어가 유동비 표를 가지고 있다면 절대적으로 신뢰하기도 했다. 그러나 유동비는 일정하지 않으며 사출 속도에 따라 유동비는 달라진다. 일반적인 유동비(L/t) 표에는 사출 성형 공정의 충전 과정에 중요한 요소인 사출 속도가 빠져 있으며, 사출 속도 복제는 사출 성형 CAE에서 유동 거동 예측의 핵심 요소이다.



[그림 3-4] 두께 - 속도 - 압력 유동비 반응 표면 결과(Beaumont Advanced Processing, 2021)


[그림 3-4]는 버몬트테크놀로지에서 속도 인자를 고려한 유동비 특허 Thermo-flo™ 결과이다. 사출 속도에 따라 유동 거리가 비선형적으로 변화되고 있는 것을 확인할 수 있다. 즉 유동 해석 정확성을 확보하기 위해서는 사출 성형공정에서 실제 사용하고 있는 사출 속도를 입력해야 한다.

충전 시간
= 2.314[s]



[그림 3-5] 초기 유동 해석 결과


충전 시간
= 9.045[s]



[그림 3-6] 적확성 개선한 유사한 해석 결과

[그림 3-5]와 [그림 3-6]은 두께가 2.5mm인 판 제품에 사출 게이트가 중심에 있을 때의 유동 해석 결과를 나타내고 있다. 같은 형상에 같은 수치를 사용했지만, 유동 해석 결과가 매우 상이한 것을 확인할 수 있다. 사출 제품을 3sec에 충전할 때에는 웰드라인이 형성되지 않고, 12sec에

충전할 때에는 웰드라인이 중심에 발생한다. 실제 사출 현장에서 [그림 3-7]의 왼쪽 그림과 같이 금형의 상·하측을 열고 사출할 때 설정 속도(검은색)를 따라 실제 속도(보라색)가 유지되며, 설정 압력(파란색)보다 실제 압력(하늘색)은 낮게 나타나고 있는 것을 확인할 수 있다. [그림 3-7] 오른쪽 그림과 같이 금형을 닫고 사출을 진행하면 설정 제한 압력에 실제 압력이 도달하고, 실제 속도는 설정 속도 보다 낮게 되는 것을 확인할 수 있다.



[그림 3-7] 사출기 공정 설정 및 출력 그래프 결과 비교
금형을 열고 사출할 때(좌), 금형 닫고 사출할 때(우)

충전 과정은 플랜지(또는 램이나 스크류)를 유 압력 또는 전동력을 이용하여 주사기의 피스톤과 같이 전진하며 플라스틱 수지를 금형에 주입한다. 이 주입 속도를 사출 속도라고 한다. 최적의 사출 속도는 유동 선단의 온도가 변함없이 일정하게 충전하는 것이다. 유동 선단의 속도를 일정하게 유지하기 위해서는 속도 제어해야 한다. [그림 3-7]의 오른쪽 그림과 같이 사출 성형 압력이 부족한 경우 속도는 떨어지고, 제어되지 않은 속도는 미성형이나 정체 현상으로 이어져 불량 요인이 된다. 유동 거리 예측은 주어진 성형 조건(수지 온도, 금형 온도, 사출 속도)과 수지 정보(점

도, 비열, 열전도도, p_vT) 그리고 형상 정보(유동길이, 두께)를 유동 지배 방정식(Flow Governing Equations)을 통해 계산한다. 정리하면 유동 거리는 유동하는데 저항하는 압력 즉, 압력강하와 유리전이온도 T_g 와 깊은 상관관계가 있다. 제품을 사출하는데 필요한 압력이 사출기 최대 허용 압력보다 부족하여 정체 현상이 심하게 발생하거나, 유동 선단의 온도가 천이온도에 도달하면 미성형이 발생한다. 먼저 저항하는 압력은 충전에 필요한 피드 시스템²⁶⁾과 캐비티 형상 그리고 제품 두께의 함수이다.

유동길이는 형상 정보와 수지 물성(점도, 비열, 열전도도 등) 그리고 사출 속도가 중요한 인자이다. 사출 속도는 점도에 영향을 주고, 체적유량과 사출 압력에도 상관관계가 있다. 또한 두께 방향과 위치 지역별로 속도뿐 아니라 온도와 점도가 다양한 값을 가지기 때문에 CAE 없이 예측하는 것은 불가능에 가까운 일이다.


5) 보압 복제

보압은 용융상태의 수지가 고화되는 과정에서 발생하는 수축을 보상하기 위해 일정한 압력으로 유지하는 공정이다. 이러한 보압은 형체력과 휨변형에 중요한 인자이다. [그림 3-8]은 카드 시편이 사출 과정에서 힘이 발생하여 측정한 사진이다. 약 10mm의 들림 현상이 발생하였다. 카드 시편은 구조적 안정성이 약해 쉽게 좌굴이 발생할 수 있다. CAE로 좌굴 옵션을 적용하여 변형을 예측하면 [그림 3-9]와 같이 유사한 휨을 예측한 것처럼 보인다.

26) 피드 시스템(Feed system): 사출기 노즐에서 제품까지 용융 수지가 흐르는 통로로 스프루, 러너, 게이트를 의미함




[그림 3-8] 카드 시편 휨 측정 결과




[그림 3-9] 사출 성형 CAE 좌굴 모드 형상 결과

그러나 자세히 보면 CAE 예측 결과는 실제 변형과 방향이 반대로 예측된 것을 확인할 수 있다. 실험 결과는 오른쪽이 상측 방향으로 들렸지만, CAE 결과는 왼쪽이 들렸다.




[그림 3-10] 초기 사출 성형 CAE 결과와 실제 힘 방향 비교

이러한 현상이 발생하는 원인을 파악하기 위해 [그림 3-11]과 같이 미성형부터 과보압까지 변경하면서 사출을 진행하였다. 공정 조건에 따라 변형 패턴이 달라지는 것을 확인할 수 있다. 조건1·2와 같이 미성형이나 충전 초기에는 왼쪽 들림이 발생하고, 적정 보압이 적용될 때 변형량이 가장 낮으며(조건3), 과보압이 적용되면 반대 방향으로 힘이 발생했다(조건4).




[그림 3-11] 공정 조건1(미성형), 2(저보압), 3(적정보압), 4(과보압)

이 현상을 CAE에서 복제하기 위해 Case1과 같이 매우 낮은 보압을 적용하였고, Case2는 적정 보압, Case3은 과보압을 적용하였다. 보압 조건에 따라 [그림 3-12]와 같이 평균 체적 수축의 차이가 발생하는 것을 확인할 수 있다. Case1은 게이트 근처에서 6.09%, 유동 말단부위에서 11.65%, Case2는 게이트 근처와 유동 말단에서 약 7.04%, Case3은 게이트 근처에서 4.16%, 유동 말단부위에서 6.06%가 나타났다.




[그림 3-12] 보압 변화에 따른 평균 체적 수축 결과 비교

[그림 3-13]과 같이 보압 변화에 따른 휨 변형이 달라지는 것을 확인할 수 있다.



[그림 3-13] 보압 변화에 따른 휨 변형 결과 비교


[그림 3-14]와 같이 최종적으로 휨 방향 및 크기를 예측할 수 있게 되었다.



[그림 3-14] 개선된 사출 성형 CAE 결과와 실제 힘 방향 비교

6) 종횡비에 따른 해석 속도 및 유동 해석 결과 비교

종횡비는 메시의 너비와 높이의 비인데, CAE 해석 정확성 및 속도에도 영향을 미친다. 메시 타입에 따라 종횡비 계산은 다르며, [그림 3-15]는 메시 타입 별 종횡비를 나타내고 있다. 빔 메시의 종횡비는 L (길이)와 D (직경)의 비(L/D)로 정의된다. 빔 메시는 주로 스프루, 러너, 게이트, 카트리지 히터, 냉각 채널, 버블러, 펌프 등에 사용하며 때에 따라 제품 형상으로도 사용된다. 종횡비 기준은 2.5~3을 권장하며 최대 5 이하로 적용한다. 권장기준을 벗어날 경우 경고 메시지를 로그에서 확인할 수 있으며, 온도 및 시간 계산 문제가 발생할 수 있다. 삼각형 메시의 종횡비는 W (가장 긴 모서리)와 H (W 의 수직 높이)의 비(W/H)로 정의된다.





[그림 3-15] 메시 타입에 따른 종횡비

삼각형 메시는 미드플레인 및 듀얼 도메인 메시 타입에서 사용되며 주로 제품, 게이트, 금형, 인서트에서 사용된다. 종횡비 기준은 Moldflow Insight 2016버전 이하는 최대 권장 종횡비는 6 이하를 권장했으나 Moldflow Insight 2017버전부터 20 이하로 변경되었다. 평균 권장 종횡비는 3 이하, 3D 메시 변환 전 최대 종횡비는 30~50 이하로 적용하는 것을 권장한다. 종횡비 기준은 해석 종류에 따라 민감성이 다른데 유동 해석은 비교적 둔감하여 높은 종횡비로도 해석은 진행되지만, 냉각 해석과 변형 해석은 민감하여 해석 실행 자체가 되지 않은 경우도 발생할 수 있다. 사면체 메시의 종횡비는 W(가장 긴 모서리)와 H(W의 수직 높이)의 1.5의 제곱근으로 계산($W/(H \cdot \sqrt{1.5})$)된다. 사면체 메시는 3D 메시 타입으로 제품 및 게이트, 러너 형상 등 다양하게 사용된다. 최대 권장 종횡비 기준은 100 이하이며 평균 종횡비는 10 이하 이다. 전역 메시 사이즈는 제품 두께의 2배미만을 추천하며, 해석을 실행하기 위해 종횡비 기준을 꼭 만족해야 하는 것은 아니지만 기준을 초과할 경우 정확성 저하 및 해석을 진행하는 데 걸리는 시간이 기하급수적으로 증가한다. 삼각형 메시와 마찬가지로 종횡비 기준은 유동 해석에서 둔감하여 종횡비가 높아도 해석이 실행되는데 문제가 없는 경우가 많지만, 냉각 해석이나 변형 해석의 경우 해석 자체가 되지 않을 수 있다. [그림 3-16]은 메시 조밀도에 따른 종횡비를 비교한 결과이다.

Aspect ratio:		
Maximum	Average	Minimum
639.31	143.84	1.33

Aspect ratio:		
Maximum	Average	Minimum
84.78	10.48	1.07



[그림 3-16] 메시 조밀도에 따른 종횡비 비교 Case1(좌), Case2(우)


일반적으로 메시의 숫자가 많을수록 해석 시간이 오래 걸린다고 알려져 있다. 그러나 종횡비에 따라 결과는 다르게 나타난다. 본 해석은 3D 메시를 이용하였고, 메시 개수는 Case1은 144,829, Case2는 149,737로 Case2가 약간 많다. 그러나 [표 3-1]과 같이 종횡비가 낮은 Case2는 메시 개수가 많지만 13분, Case1은 77분의 해석 시간이 소요되었다.

[표 3-1] 메시 개수와 종횡비에 따른 해석 시간 비교

구분	변수		해석 시간(min)			
	메시 개수	종횡비	충전	충전+보압	변형	합계
Case1	144,829	639.31	53	59	18	77
Case2	149,737	84.78	6	10	3	13

종횡비는 해석 시간 뿐 아니라 CAE 적확성에도 영향을 미친다. [그림 3-17]과 같이 Case1은 화살표에 표시된 것처럼 상·하측의 유동 결과가 균형을 이루지 못하는 것을 확인할 수 있다. 그러나 Case는 균형을 이루


는 것을 확인할 수 있다.




[그림 3-17] 종횡비에 따른 충전해석 결과 비교, Case1(좌), Case2(우)

7) 메시 타입에 따른 CAE 결과 비교


메시 타입의 가정에 따라 CAE 결과는 달라진다. 예를 들면 듀얼 도메인 메시는 모서리(Edge)로 인식한 메시에 대하여 인접한 요소 두께의 75%로 인식한다고 가정하고 있다. [그림 3-18]과 같이 바닥에 짧은 리브가 다수 설치된 제품의 경우 듀얼 도메인 메시로 적용했을 때 실제 리브의 두께보다 얇게 인식하여 변형 시뮬레이션 결과가 과장되게 결과를 도출할 수 있다. [그림 3-19]는 듀얼 도메인 메시 타입에서 두께 인식 결과를 나타내고 있다. [그림 3-20]과 같이 듀얼 도메인 메시로 적용할 때 변형 예측 결과는 82.53mm이며 3D 메시로 적용할 경우 13.66mm로 예측되었다. 실제 결과는 3D 메시의 결과가 더 유사했다.



[그림 3-18] 바닥에 짧은 리브가 다수 설치된 제품




[그림 3-19] 듀얼 도메인 메시 적용 시 두께 인식 결과




[그림 3-20] 메시 타입에 따른 변형 결과 비교, Dual(좌), 3D(우)

8) 금형 형상 복제


사출 금형은 2단 금형과 3단 금형과 같은 콜드러너와 스크랩이 없는 핫러너로 분류할 수 있으며, 슬라이드 코어 금형, 나사 금형, 스택 금형과 같은 특수 금형으로도 분류할 수 있다. 2단 금형은 금형 분할 면으로 스프루 및 러너가 제품과 함께 취출되며, 3단 금형은 러너 스트리퍼 플레이트에서 취출되는 것이 다르다. [그림 3-21]은 2단 금형의 대표적인 피드 시스템 구조인 사이드 게이트이며, [그림 3-22]는 3단 금형의 대표적인 구조인 핀 포인트 게이트 구조이다.




[그림 3-21] 2단 금형의 구조(민현규, 2003)



[그림 3-22] 3단 금형의 구조(민현규, 2003)




[그림 3-23] 2단 금형의 사이드 게이트 구조




[그림 3-24] 3단 금형의 핀 포인트 게이트 구조

[그림 3-25]는 핫러너 구조이다. 그림의 노란 영역은 용융 수지가 흐르는 길로 용융 상태를 유지할 수 있는 히터가 설치되어 스크랩이 발생하지 않는다.




[그림 3-25] 핫러너 구조

적확성 있는 CAE 결과를 얻기 위해서는 금형의 모든 구조를 정확히 복제해야 한다. [그림 3-26]은 냉각 채널 메시를 3D로 적용하는 형상적응형 냉각 기능을 이용한 사례이다. 빔 메시로는 구현할 수 없는 넓은 판 냉각 구조를 정확히 표현하기 위해서는 이러한 기능을 이용해야 한다. 또한 핫러너 구조를 단순히 빔 메시로 적용하지 않고 핫러너 매니폴드를 메시로 적용할 경우 히터에 의한 금형 열전달을 보다 정확하게 계산할 수 있다. [그림 3-27]은 핫러너 매니폴드와 금형이 만나는 위치의 열전달 결과를 나타내고 있다.




[그림 3-26] 핫러너 매니폴드 및 형상적응형 냉각 메시 구현 사례



[그림 3-27] 핫러너 매니폴드 및 형상적응형 냉각 해석 결과

9) 코어 쉬프트에 따른 충전 결과 비교


금형이나 인서트가 사출 압력에 의해 처짐이 발생할 때도 제품 형상 두께가 달라질 수 있다. 이럴 경우 코어 쉬프트 해석을 이용하여 금형이나 인서트의 처짐을 예측하고, 제품 두께의 변화를 고려해야 한다(이종원 외, 2015). 그러나 그렇게 가정하지 않았을 때 CAE 정확성은 낮아지게 된다. [그림 3-28]은 중심 부분의 두께가 얇고 코어가 깊은 제품이다. [그림 3-29]와 같이 사출 성형품의 두께는 2mm에서 1mm로 변화되고 있다. 사출 압력에 의해 코어에 힘이 발생한다면 1mm 구간의 두께가 얇아질 수 있다.




[그림 3-28] 중심 부분의 두께가 얇고 코어가 깊은 제품

[그림 3-30], [그림 3-31]과 같이 코어 쉬프트 고려 여부에 따라 충전 패턴이 다른 것을 확인할 수 있다. 코어 쉬프트를 고려하지 않은 [그림

3-30]의 결과는 정체 현상이 발생하지 않고 잘 충전되지만 [그림 3-31]과 같이 코어 쉬프트를 고려하면 사출 압력에 의해 깊은 코어가 옆으로 넘어가 사출 성형품의 두께를 얇게 만들고 극심한 정체현상이 발생한다.




[그림 3-29] 중심 부분의 두께가 얇고 코어가 깊은 제품




[그림 3-30] 코어 쉬프트를 고려하지 않은 유동 해석 결과

[그림 3-32]와 같이 사출 압력에 의해 코어가 휘는 것을 관측할 수 있다. 이러한 현상이 실제 사출 현장에서도 발생하였다. 이렇게 코어의 휨이 발생하면 취출 과정에서 코어에 응력이 작용하여 몇 회 사출하지 못하고 코어가 부러진다. 이러한 문제를 초기 제품 개발 단계에서 예측하였다면, 두께 변경이나 형상 변경을 통해 금형 제작 전 또는 양산 전에 문제를 해결할 수 있다.



[그림 3-31] 코어 쉬프트를 고려한 유동 해석 결과




[그림 3-32] 코어 쉬프트에 의한 코어 힘 결과

10) 미성형 예측을 위한 메시 크기 결정

미성형 상황을 재현하기 위해서 주의해야 할 부분은 바로 비선형성을 예측하기 위한 CAE 프로세스이다. 미성형 예측을 위한 프로세스는 일반 유동 해석과 차별적인 프로세스를 진행해야 한다. 일반 유동 해석은 성형 성 검토나 사출기 선정의 경우 선행 검토에 대한 안전율을 고려하기 때문이고, Case Study 목적으로 진행하는 해석은 Case 중 비교하여 우월한 Case를 선정하기 때문에 1:1 매칭을 할 필요가 없다. 그러나 미성형 예측은 1:1 매칭을 해야 하므로 CAE와 실제 실험한 결과가 일치하지 않으면, 틀린 답이 된다. 유동 해석과 관련된 변수 중 표준화 요소로 메시 / 수치 물성 / 공정조건 / 금형구조 / 성형기 / 솔버 파라메타 중 중요한 변수를 잘못 설정하면, 미성형 결과는 실험 결과와 일치하지 않을 수 있다. 미성형 예측을 위해 메시는 더욱 조밀해야 한다. 미성형 과정에서 유동 선단의 온도는 급격하게 변하는데, 메시 조밀도에 따라 결과는 극명하게 달라진

다.

일반적으로 사용하는 수지 온도보다 낮게 설정했을 때 사출 성형 압력 결과를 실험과 비교할 때, 게이트의 메시를 3등분하면 표준화된 일반 사출 유동 해석 프로세스에는 잘 적용했다고 판단할 수 있지만, 수지의 온도가 낮고 저속으로 사출하는 경우 점도가 매우 급격하게 높아지면서, 미성형을 예측하기 위해 10개 이상 메시를 적용해야 유사하게 압력을 예측할 수 있다. 또한 Juncture loss²⁷⁾와 D3²⁸⁾ 물성까지 적용해야 실험값과 시뮬레이션 값이 일치하는 경우도 존재한다. [그림 3-33]과 같이 왼쪽은 매우 거친 메시(33,727개), 오른쪽은 매우 조밀한 메시(158,700개) 이다.




[그림 3-33] 33,727개 메시(좌), 158,700개 메시(우)


[그림 3-34]의 충전 결과를 보면 비교적 유사한 패턴을 보인다. 성형 가능 영역에서는 결과의 차이가 크게 존재하지 않는다. 약간 왼쪽 유동 패턴이 일그러지는 것을 확인할 수 있다. 그러나 [그림 3-35]와 같이 미성형이 일어나기 시작하는 지점에서는 거친 메시는 심하게 일그러진 유동 패턴을 확인할 수 있다. 그러나 조밀한 메시는 원형을 유지하는 것을 확인할 수 있다.

27) Juncture loss(정체로스계수): 용융 수지가 피드 시스템의 급격히 좁아지는 구간을 통과할 때 추가적인 압력 손실을 고려하는 계수.

28) D3(압력의존성계수): 식(10) Cross-WLF 의 압력에 따른 점도 변화를 고려하는 계수.




[그림 3-34] 메시 변화에 따른 충전 결과 비교(4.4초일 때)




[그림 3-35] 메시 변화에 따른 충전 결과 비교(5.6초일 때)

두께 방향으로 평균 온도를 나타내는 Bulk temperature(벌크 온도) 결과에서 거친 메시의 경우 중심 부분에 6각형의 패턴이 나타나는 것을 확인할 수 있다. 그러나 조밀한 메시의 경우 원에 가까운 것을 확인할 수 있다.



[그림 3-36] 메시 변화에 따른 평균온도 결과 비교(약 6초일 때)



[그림 3-37] 메시 변화에 따른 평균온도 결과 비교(약 7.9초일 때)

시간을 더 진행해보면, [그림 3-36], [그림 3-37]과 같이 일부는 천이온도 이하로 떨어지면서 유동은 멈추고, 일부는 흐를 수 있는 공간이 좁아지면서 높은 압력(사출기 최대 압력)을 받으면서 열리고 추가 유동이 발생하는 것을 확인할 수 있다. 같은 사출 속도라도 유동 선단 면적이 달라지면, 제품을 충전하는 속도가 달라지고, 열전달, 전단 발열 효과가 달리 계산되어 성형성은 달라진다. 유동비는 사출 속도와 형상에 따른 유동 선단 면적을 고려하지 않는 것이기에 성형성을 대표할 수 없다.

제 2 절 스파이럴 금형의 형상 검증 및 CAE 적확성 개선 연구

1) 스파이럴 금형을 활용한 유동 거리 예측 선행연구 검토

사출 성형 CAE의 유동 거리 예측 연구에서 인공지능망(ANN)을 이용하여 유동 거리 예측을 위해 머신러닝 모델을 이용하여 통계적 유의성을 확보하여 효과적으로 예측 및 검증한 사례를 스파이럴 금형을 이용하였다(Sandu, I. L., et al., 2020). 성형 불량 중 미성형을 개선하기 위한 변수를 얻기 위해 스파이럴 형상을 이용한 검증을 실시하였다(Liparoti, S., et al., 2020). 플라스틱 재료에 따른 유동 거리가 다르기 때문에 정확하게 예측하려면 플라스틱 물성을 확보하는 것이 중요하다고 하였다(Salimi, A., et al., 2013). 스파이럴 테스트를 활용하여 고화 층의 발달과 단면 감소에 대한 관계를 연구하였다(Martinez, A., et al., 2011). 스파이럴 형상을 활용하여 플라스틱 재료 물성에 대한 특성화 분석 및 사출 성형 CAE 시스템에 적용하여 적확성에 대한 연구를 진행하였다(Clavería, I., et al., 2005).

이러한 유동 해석 검증에 관한 연구의 대부분은 특별한 사출 조건에서의 유동 변화에 관심이 집중되어 연구를 진행하였다. 본 연구에서는 유동성을 평가할 때 자주 사용하는 유동비를 검증하고, 스파이럴 형상 검증을 위해 동일한 두께지만 사출품의 형상을 변경할 때 유동성을 연구하였다. 유동성 결과의 비교는 CAE 상용 소프트웨어 중 가장 많이 사용하고 있는 Autodesk Moldflow Insight를 이용하였고, 연구에 사용된 사출 성형품은 앞에서 언급된 유동성 연구에 많이 사용되고 있는 스파이럴 형상과 비교 형상으로 막대 형상 및 판 형상을 사용하였다. 본 연구에서 사출 성형품 형상의 변경이 유동 거리와의 상관관계를 파악하고 향후 실험과 CAE를 비교하는 수단으로 적합한 방법을 제안하고자 하였다(황순환 외 2021).

2) 유동성 비교 모델

본 연구는 스파이럴 디자인의 성형품과 막대 형상 막대 및 넓은 평판 디자인 판의 성형품에 대하여 사출 속도를 변화시켰을 경우 유동 거리의 변화를 사출 성형 CAE를 통하여 비교하였다. 유동 거리 비교는 사출 성형 CAE 완료 후의 성형품의 중량 비교 방법을 활용하였다. 즉, 사출 중량이 높을수록 유동 거리가 긴 것을 의미한다.




[그림 3-38] 2mm 두께 스파이럴 디자인, 폭 15mm(좌), 폭 23mm(우)

[그림 3-38]은 스파이럴 디자인 모델에서 CAE를 위한 메시를 나타내었다. 모델의 sprue 디자인은 직경이 3.5~8mm, 길이 83mm이다. 제품의 두께 2mm, 총 길이 1,350mm로서 왼쪽 형상은 폭이 15mm, 오른쪽은 폭이 23mm로 다르다. CAE를 위해 사용된 메시는 듀얼 도메인과 3D 메시를 사용하였다. 3D 메시의 경우 두께를 각각 6개, 10개, 20개의 레이어로 적용하여 메시 증가에 따른 유동 거리 변화 결과에 영향을 미치는 비율도 분석하였다. [표 3-2]는 모델의 메시 타입과 메시 개수를 나타내었다. [그림 3-39]는 듀얼 도메인 메시와 3D 메시의 레이어에 따른 단면의 메시 상태를 설명하고 있다(황순환 외 2021).

[표 3-2] 폭 15mm 스파이럴 모델 메시의 개수(황순환 외, 2021)

Modeling	Width 15mm
Dual-domain	52,897
6 Layers	251,995
10 Layers	426,577
20 Layers	958,390




[그림 3-39] 메시 타입 비교 : (a) 듀얼 도메인 (b) 3D 메시 6 레이어
(b) 3D 메시 10 레이어 (b) 3D 메시 20 레이어

[그림 3-40]은 두께 2mm, 폭 15mm의 막대 형상과 판 형상으로 스파이럴 디자인과 유동 길이를 비교하기 위한 모델로 선정하였다.



(a)



(b)

[그림 3-40] 스파이럴 디자인과 비교 디자인 : (a) 막대, (b) 판

사출 성형 CAE에서 사용한 수지의 유동은 비뉴턴(non-Newtonian), 비등온(non-Isothermal), 압축(Compressible) 거동이며, 지배방정식은 질량 보존, 운동량 보존 및 에너지 보존 방정식을 기본으로 사용하고 있다 (김경아 외, 2020).

3) 플라스틱 수지 그레이드와 성형 조건

CAE에 적용된 수지는 PC/ABS로 그레이드는 EU5000W, 제조사는 LG 화학이다. 사출 성형 CAE를 위한 성형 공정 조건은 [표 3-3]과 같다. 사출 성형 조건 중에서 변수는 사출 유량으로 10cc/sec에서 100cc/sec까지 10 단계로 파라메트릭 연구 기법을 적용하였다.

[표 3-3] 사출 성형 CAE를 위한 공정조건


Process conditions	Unit	Value
Injection pressure	MPa	160
Mold temperature	°C	60
Velocity/pressure switch-over	sec	10
Melt temperature	°C	255
Recommend mold temperature	°C	50 ~ 70
Ejection temperature	°C	99

4) 스파이럴 금형의 사출 유량에 따른 중량 비교

[그림 3-41]은 폭 15mm인 스파이럴 디자인 제품의 사출 유량 10cc/sec을 적용한 충전 시간 결과이다. 3D 메시, 10 레이어 결과와 듀얼 도메인 메시 결과를 비교할 때, 유동길이가 비슷한 것을 알 수 있다.



(a)




(b)

[그림 3-41] 충전해석 결과 : (a) 3D, (b)듀얼 도메인

유동 거리 비교를 위해 [표 3-4]에 나타난 것처럼 폭이 15mm인 스파이럴 디자인 금형에서 Case1은 3D 메시 / 6 레이어, Case2는 3D 메시 / 10 레이어, Case3은 3D 메시 / 20 레이어, Case4는 듀얼 도메인 메시를 적용했다. 분석 결과 사출 유량이 클수록 중량이 커짐을 의미한다.

즉 사출 속도가 빠를수록 유동 거리는 증가하였다. 대부분은 사출 유량이 같을 때 3D 메시 레이어 수가 증가할수록 중량이 증가하였다. 이 현상이 발생한 원인은 사출 성형 CAE의 원활한 해석 진행을 위한 가정과 생략에서 발생하는 미세한 차이가 메시 개수의 증가로 누적되어 예측한 결과라 사료된다.




[그림 3-42] 폭 15mm 스파이럴 유동 거리 예측 결과(듀얼 도메인)

메시 증가는 정밀한 CAE 결과를 얻을 수 있지만, CAE 시간이 오래 걸려 메시 사이즈 및 레이어 선정은 중요하다. 3D 메시 중 6 레이어와 20 레이어의 최대 차이는 사출 유량이 30cc/sec로, 약 1.1g 중량이 증가하였고, 10 레이어와 20 레이어의 최대 차이는 사출 유량 30cc/sec로, 약 0.45g 중량이 증가하였다. 20 레이어가 가장 정확하다는 가정 하에 95% 이상의 정확성을 위해서는 10 레이어를 적용해야 한다.

Case4와 Case2의 중량 비교 결과 최대 차는 2.7g(14.9%), 최소 차는 0.3g(0.5%)로 약 9.25%의 중량 차가 발생했다. 이러한 결과는 메시 타입에 의한 유동 예측 모델의 차이로 듀얼 도메인 메시는 Hele-shaw(헬레-쇼) 모델이 적용되고 3D 메시는 Navier-Stokes(나비에스토크스) 모델이 적용된다(Zhou, H., 2013).

[표 3-4] 메시 타입에 따른 폭 15mm 스파이럴 중량 비교(단위:g)

	Flow rate (cc/sec)	Case 1 (6 Layer)	Case 2 (10 Layer)	Case 3 (20 Layer)	Case 4 (Dual Domain)
1	10	15.11	15.98	15.73	16.07
2	20	17.21	17.81	18.16	18.59
3	30	18.06	18.71	19.16	20.32
4	40	18.62	19.22	19.49	21.49
5	50	19.22	19.53	19.85	22.22
6	60	19.69	19.98	20.23	22.95
7	70	20.18	20.28	20.50	22.22
8	80	20.49	20.56	20.77	22.5
9	90	20.78	20.80	20.97	22.79
10	100	20.97	20.98	21.06	23.06



[그림 3-43] 폭 23mm 스파이럴 유동 거리 예측 결과(듀얼 도메인)


[표 3-5] 메시 타입에 따른 폭 23mm 스파이럴 중량 비교(단위:g)

	Flow rate (cc/sec)	Case 5 (Dual Domain)	Case 6 (10 Layer)	Compare (%)
1	10	22.56	22.05	2.30
2	20	26.3	24.52	6.80
3	30	28.84	25.56	11.40
4	40	30.5	26.16	14.20
5	50	31.68	26.66	15.80
6	60	31.18	27.22	12.70
7	70	31.73	27.75	12.50
8	80	32.33	28.07	13.20
9	90	32.91	28.36	13.80
10	100	33.45	28.65	14.30

[표 3-5]는 두께 2mm, 폭 23mm인 스파이럴 디자인의 사출 유량 별, 메시 타입 별 중량에 대한 사출 성형 CAE 결과를 나타내었다. Case5는 듀얼 도메인 메시, Case6은 3D 메시의 10 레이어로 적용했다. 최대 중량 차는 사출 유량이 50cc/sec(15.8%)일 때이며, 폭이 15mm 스파이럴 디자인 CAE 결과와 동일하게 듀얼 도메인 메시의 중량이 높게 예측되었다.

5) 막대 및 판 형상 금형의 사출 유량에 따른 중량 비교

[그림 3-44]는 사출 유량이 10cc/sec를 적용했을 때 막대 형상의 충전 해석 결과이다. [그림 3-45]는 사출 유량 10cc/sec와 20cc/sec일 때 판의 충전 결과이다. 모두 듀얼 도메인 메시 타입으로 적용했으며 [표 3-6]과 같이 CAE로 예측된 중량 결과를 비교하였다(황순환 외 2021).




[그림 3-44] 막대 형상 유동 거리 예측 결과

[표 3-6] 메시 타입에 따른 막대와 판 형상 중량 비교(단위:g)

	Flow rate (cc/sec)	Case 7 (Bar)	Case 8 (Plate)
1	10	17.56	43.28
2	20	23.62	159.39
3	30	26.96	264.94
4	40	28.81	366.62
5	50	30.03	465.07
6	60	31.21	563.93
7	70	32.2	660.63
8	80	33.04	739.1
9	90	33.62	755.36
10	100	34.17	749.96

판의 경우 10cc/sec에서 20cc/sec로 변화되면서 중량이 급격히 증가하는 것을 알 수 있다. 원인으로 [그림 3-45]의 10cc/sec 유동 결과는 원형이지만, 유량이 20cc/sec로 변경되면, 수지의 유동 선단의 일부 영역은 굳고, 일부 영역은 더 흘러 '3'자 형태 또는 갈매기 형태의 유동이 나타나면서 중량이 급증하였다. 판은 유동 과정에서 유동 선단이 넓어지기 때문에 동일한 속도로 충전하게 되면 유동 정체 현상으로 일부는 고체화가 되고, 고체화 면적으로 인해 유동 선단의 면적이 좁아지면 다시 일부는 유동되기 때문에 중량으로 유동 거리를 예측할 수 없음을 확인하였다. 판의 유동 거리는 중량이 아닌 유동 선단이 멈추는 처음 위치라고 기준을 변경하여 유동 거리를 다시 확인하였다.




[그림 3-45] 판 형상의 충전 해석 결과

[표 3-7] 형상 변화에 따른 유동길이 비교(단위:mm)


	Flow rate (cc/sec)	SP_15	SP_23	Bar_15	Plate
1	10	380	430	275	70
2	20	460	500	375	125
3	30	530	560	425	175
4	40	550	600	450	180
5	50	570	630	475	190
6	60	580	620	490	205
7	70	575	630	500	210
8	80	580	640	515	215
9	90	585	650	525	220
10	100	590	660	530	225

[표 3-7]은 SP_15(폭 15mm, 스파이럴 디자인), SP_23(폭 23mm, 스파이럴 디자인), Bar_15(폭 15mm, 막대 디자인), Plate(판 디자인)의 CAE 상으로 예측된 유동 거리이다. 위 표의 결과를 [그림 3-46]과 같이 그래프로 나타냈다. 결과적으로 스파이럴 폭의 영향 도를 분석한 결과 15mm는 23mm보다 30~70mm(13%) 더 적게 흘렀다. 스파이럴 디자인은 막대 디자인보다 유동 거리가 60~105mm(28%) 더 흘렀다. 판은 스파이럴 폭 15mm에 비해 유동 거리가 310 ~ 380mm(82%) 더 적게 흘렀다. [그림 3-47]은 충전 후 4.1 sec 시점에서 폭 변경에 따른 수지 온도 변화를 비교하고 있다. 두 디자인 모두 스파이럴의 안쪽과 바깥쪽의 온도에 대한 편차가 발생하였다. 편차는 저항이 낮은 안쪽으로 용융 수지가 빠르게 흘러 발열이 발생하는데 폭이 좁은 디자인은 4.1sec 시점에서 내부의 용융 온도는 약 250℃이며, 폭이 넓은 디자인의 경우는 4.1 sec 시점에서 온도는 270℃로 약 20℃가 높았다. 폭이 넓은 스파이럴 디자인은 용융 수지의 유로가 넓어 그만큼 많은 열량을 품게 되어 금형 열 손실의 영향을 적게 받은 것으로 사료된다. 막대 형상은 스파이럴 디자인과 같이

안쪽과 바깥쪽의 온도 편차가 없어 유동 거리는 짧게 되었다. 막대와 스파이럴 디자인의 중량 비교 결과 막대가 무거웠다. 스파이럴 디자인은 나선형으로 중량 대비 거리의 비(거리/중량)가 더 높았다. 판의 유동 거리가 가장 짧게 된 이유는 유동 선단이 급격하게 넓어지면서 유동 선단의 속도 저하가 발생하여 고화가 촉진되었기 때문이다(황순환 외 2021).



[그림 3-46] 형상 변화에 따른 유동 거리 비교




[그림 3-47] 스파이럴 형상 폭 변화에 따른 Bulk temperature 비교


본 연구를 통해 두께가 같아도 사출 속도 및 형상, 유동 선단 변화율에 따라 유동 길이가 달라지는 것을 확인하였다. 스파이럴 폭의 변화는 유동 거리에 13% 영향 도를 나타냈으며, 스파이럴 디자인과 막대 형상은 28%의 차이, 판와 스파이럴 디자인의 유동 거리 차이는 82% 차이를 확인하였다. 결과적으로 스파이럴 형상은 막대 디자인과 판 디자인을 대표할 수 없음을 확인했다. 즉, 사출 실험과 CAE를 비교할 때에는 현업에서 사용하는 형상에 가까운 대표성 있는 디자인으로 실험을 진행하여 더욱 높은 적확성 있는 결과를 도출할 수 있다.

6) 압력의존성계수 D3를 활용한 유동 거리 개선


유동 거리 예측 신뢰성을 위해 무엇보다 “신뢰성 있는 수지 물성” 확보하는 것이 중요하다. 정확한 플라스틱 물성 측정은 시뮬레이션 예측 적확도를 향상한다. 그러나 언제나 신뢰성 있는 수지 물성을 확보할 수는 없다. 필요에 따라 플라스틱 유변 물성을 편집해서 실제와 가까운 결과를 얻을 수 있다. 유동 거리를 실제와 CAE 간의 차이를 빠르고 쉽게 맞춰갈 수 있다고 알려진 방법은 D3(압력의존성계수)를 수정하는 것이다. [그림 3-48]의 X축은 수지 온도, 금형 온도, 사출 속도 공정 조건을 변경한 18가지 조건이며, Y축은 중량이다. 실제 실험한 결과와 CAE 결과가 차이를 나타내는 것을 확인하였다. [그림 3-49]는 압력의존성계수 D3를 수정 입력하여 추가 해석을 진행한 결과 실험과 유동 거리를 유사하게 맞출 수 있었다. 이 방법은 제한된 조건으로 해석 적확성을 개선할 수 있다. D3를 추가하여 유동 거리(중량) 편차를 줄일 수 있지만, [그림 3-50]과 같이 특정 조건(9,10,11 공정 조건)에서는 패턴이 분명 다르다. D3는 전체적으로 압력을 높이거나 낮출 수 있는 형태로 변화되지만, 패턴을 변화시킬 수 없다.



[그림 3-48] 사출실험과 CAE 중량 비교(18가지 사출 조건 변경)




[그림 3-49] 압력의존성계수 추가로 CAE 정확성 개선




[그림 3-50] 특정 조건에서는 실험과 CAE 차이 발생

D3를 적용하게 되면 플라스틱 수지의 점도가 압력의 조건에 따라 달라진다. [그림 3-51]은 D3를 적용한 수지의 160MPa일 때 점도이다.




[그림 3-51] 압력의존성계수 D3를 적용한 수지의 160MPa일 때 점도




[그림 3-52] 압력의존성계수 D3를 적용한 수지의 0MPa일 때 점도

[그림 3-52]는 D3를 적용한 수지의 0MPa일 때의 점도 그래프이다. 수지의 온도가 280°C, 전단율이 1이라면 압력이 0MPa일 때 점도는 약 100Pa·s에 가깝지만, 160MPa일 때의 점도는 5000Pa·s 이상으로 약 50배 이상 점도가 높아진다. 스파이럴 실험의 초기 값은 최대 압력 160MPa을 제한 압력으로 적용하고 사출 속도를 변경하며 유동 거리를 측정하는데, 모든 조건에서 미성형이 발생할 정도로 유동 길이를 길게 모델링하였다. 이에 따라 모든 조건에서 최대 제한 압력으로 성형압력이 적용되고 유동 선단의 온도가 천이온도 이하로 떨어지면서 미성형이 발생한다. 이러한 조건에서 유동 거리 예측은 최대 제한압력일 때의 점도가 중요하기 때문에 D3를 활용하는 것은 실용적이고 유용하다. 그러나 유사한 수지 물성 중 처음부터 D3를 측정한 그레이드와 어떤 차이가 있는지를 비교해 보았다. 소재는 LUPOY EU5000W로 PC+ABS이다. [그림 3-53]과 같이 LUPOY EU5000W의 160MPa일 때 점도와 [그림 3-54]와 같이 LUPOY EU5000W의 0MPa일 때 점도를 나타냈다. 160MPa일 점도는 유사하지만, 0MPa일 때의 점도는 약 8배 점도가 높았다. [그림 3-55]와 같이 LUPOY EU5000W 물성을 활용한 CAE 결과가 실험과 유사한 패턴

이 나타나는 것을 확인할 수 있다.



[그림 3-53] LUPOY EU5000W의 160MPa일 때 점도



[그림 3-54] LUPOY EU5000W의 0MPa일 때 점도



[그림 3-55] LUPOY EU5000W 물성을 이용한 CAE 추가 비교 결과

7) 영점 점도 수정 계수 D1을 활용한 유동 거리 개선

영점 점도를 수정하는 D1과 D3를 함께 수정할 경우 실험과 CAE의 패턴이 개선될 가능성을 확인하였다. 기존 수지 물성에서 Cross-WLF 점도 모델 계수에 D3를 수정한 모델은 [그림 3-56]과 같다. 추가로 0MPa일 때 점도와 160MPa일 때의 점도를 LUPOY EU5000W와 유사하게 D1과 D3를 함께 수정한 Cross-WLF 점도 모델 계수는 [그림 3-57]과 같다.

Cross WLF Viscosity Model Coefficients

Cross-WLF viscosity model

n	0.4847	
Tau*	108908	Pa
D1	1.70832e+07	Pa-s
D2	417.15	K
D3	2.5e-07	K/Pa
A1	16.481	
A2~	51.6	K

Plot Viscosity

View test information...

확인 도움말

[그림 3-56] 기존 물성에 D3를 수정한 Cross-WLF 점도 모델 계수

Cross WLF Viscosity Model Coefficients

Cross-WLF viscosity model


n	0.4847	(0:1)
Tau*	108908	Pa (0:1e+09)
D1	1.70832e+08	Pa-s (0:)
D2	417.15	K (0:1000)
D3	1.776e-08	K/Pa (0:1e-05)
A1	16.481	(0:40000)
A2~	51.6	K (0:20000)

Plot Viscosity

Edit test information...

확인 취소 도움말


[그림 3-57] 기존 물성에 D3, D1을 수정한 Cross-WLF 점도 모델 계수




[그림 3-58] 수정된 D1,D3 물성을 이용한 CAE 추가 비교 결과

8) 영점 점도 측정 후 결과 비교


전단율(Shear rate) 영역별로 회전 레오미터와 모세관 레오미터로 점도를 측정하여 유사 수준의 점도를 확인하고자 실험을 진행하였다. 사용 장비는 회전 레오미터(0.1 ~ 100 1/s)와 모세관 레오미터(100 이상 1/s)로 측정 온도는 230, 250, 270, 300, 300°C로 진행하였다. [그림 3-59]는 회전 레오미터와 모세관 레오미터를 이용하여 점도를 측정한 결과이다. 모세관 레오미터의 기기 특성 상 100 이하의 전단율을 측정하기 어렵지만, 회전 레오미터를 이용할 경우 전단율이 0에 가까운 값을 측정할 수 있다. [그림 3-60]은 두 개의 측정기에서 측정한 점도를 만족하는 점도 그래프이다. [그림 3-61]은 기존의 점도 그래프(파란색)와 두 개의 측정기를 이용한 점도 그래프(빨간색)를 비교하였다. 기존 UDB(User Data Base)에 사용된 Data가 실질적인 유변 특성을 반영하지 못하고 있어 사출 성형 CAE 적용 시 정확성의 문제가 발생한 것으로 사료된다.



[그림 3-59] 회전 레오미터와 모세관 레오미터를 이용한 점도 측정



[그림 3-60] 측정된 데이터를 기반으로 데이터 피팅한 점도 그래프




[그림 3-61] 기존 점도 그래프와 새로운 점도 그래프 비교

다양한 온도 조합으로 데이터 피팅 시 점도 결과가 상이하며, 이에 따라 영점 전단 점도는 최대 2배 이상 다른 것으로 확인하였다. 같은 측정 결과라도 데이터 피팅 시 온도 조합을 어떻게 입력하는가에 따라 점도가 달랐다. [그림 3-62]는 230, 250, 270°C로 데이터 피팅을 하였으며 점도 그래프는 [그림 3-63]과 같다. [그림 3-64]는 230, 270, 330°C로 데이터 피팅을 하였으며 점도 그래프는 [그림 3-65]와 같다. [그림 3-66]은 270, 300, 330°C로 데이터 피팅을 하였으며 점도 그래프는 [그림 3-67]과 같다. 온도별로 비교할 때, 모두 선형적이지만 기울기가 상이하며 이에 따라 영점전단점도도 차이가 발생하였다.

Cross-WLF 점도 모델

n	0.4534	
Tau*	0.456458	Pa
D1	1.28269e+15	Pa-s
D2	417.15	K
D3	2.5e-07	K/Pa
A1	21.493	
A2~	51.6	K

[그림 3-62] 데이터 피팅 1(230/250/270°C 기반)




[그림 3-63] 데이터 피팅 1 점도 데이터(230/250/270°C 기반)

Cross-WLF 점도 모델

n	0.3898	(0:1]
Tau*	2.05752	Pa (0:1e+09)
D1	4.0541e+15	Pa-s (0:)
D2	417.15	K (0:1000)
D3	2.5e-07	K/Pa [0:1e-05]
A1	21.182	(0:40000)
A2~	51.6	K (0:20000)

[그림 3-64] 데이터 피팅 2(230/270/330°C 기반)




[그림 3-65] 데이터 피팅 2 점도 데이터(230/270/330°C 기반)

Cross-WLF 점도 모델


n	0.2591	(0:1]
Tau*	50.4129	Pa (0:1e+09)
D1	1.82833e+17	Pa-s (0:)
D2	417.15	K (0:1000)
D3	2.5e-07	K/Pa (0:1e-05)
A1	24.749	(0:40000)
A2~	51.6	K (0:20000)

점도 플롯


[그림 3-66] 데이터 피팅 3(270/300/330°C 기반)



[그림 3-67] 데이터 피팅 3 점도 데이터(270/300/330°C 기반)




[그림 3-68] 데이터 피팅에 따른 유동 거리 비교 결과,
230/250/270℃(좌), 230/270/330℃(중심), 270/300/330℃(우)



[그림 3-69] 데이터 피팅에 따른 사출 중량 비교 결과,
230/250/270℃(좌), 230/270/330℃(중심), 270/300/330℃(우)

[그림 3-68]은 데이터 피팅 변화에 따라 다른 점도 모델로 CAE를 진행하여 유동거리를 예측한 결과이다. 데이터 피팅의 설정 온도 저하에 따라 유동 거리가 짧아지는 것을 확인할 수 있다. [그림 3-69]은 사출 중량을 비교한 결과이다. 유동 거리가 짧아짐에 따라 중량이 감소하는 것을 확인할 수 있다. 결과적으로 실제 사출에서 적용하는 수지 온도 구간인 230/250/270℃ 기반으로 적용할 때 실제 실험한 결과와 유사한 결과가 도출되었다(황순환 외 2021).




[그림 3-70] 영점 점도를 고려한 측정 및 데이터 피팅을 통한 유동 거리 개선 결과

정리하면, 유동 거리 예측 정확성을 위해 MPL(Moldflow Plastic Lab)과 같은 정밀한 측정 기관에서 수지를 측정하는 것이 좋지만, 시간과 비용의 제한이 있을 때 수지 물성을 개선할 수 있는 방법으로 압력의존성계수(D3)는 전체 유동 거리를 맞추는데 도움이 되었다. 그러나 금형의 온도가 달라지는 시점에서 유동 거리 패턴이 달라지는 문제가 발생하였다. 이러한 문제의 원인을 확인하고자 MPL에서 측정한 수지와 임의로 압력의존성계수(D3)를 수정한 데이터를 비교한 결과 160MPa일 때에는 유사한 점도가 나타났지만 0MPa일 때 점도가 8배의 차이가 발생한 것을 확인하였다. 이 때 영점전단점도(D1)와 압력의존성계수(D3)를 동시에 수정하면 0MPa일 때와 160MPa일 때의 점도가 유사해지며 금형의 온도가 달라지는 지점에서 유동 거리 정확성이 개선되는 것을 확인하였다. 영점전단점도를 정밀하게 측정하기 위해 회전 레오미터와 모세관 레오미터를 이용한 결과 전단율이 낮았을 때 점도의 편차가 발생하는 것을 확인하였다. 18가지 사출 공정조건으로 CAE를 진행하여 중량을 예측하였으며, 실제 실험과 비교한 결과는 [그림 3-70]과 같다. 실제 실험한 결과와 영점전단점도를 고려한 점도 측정 결과가 유사한 것을 확인할 수 있다.

제 3 절 에어백 커버 제품 사출 압력 예측 개선에 관한 연구

1) 사출 압력 예측 검증 개요

사출 압력 예측은 제품 디자인 및 두께 결정, 소재 결정, 금형 설계 결정, 사출 조건 최적화 등 광범위하게 요구되는 품질 요소이다. CAE를 통한 압력 예측은 기본적으로 도출되는 결과지만, 실제 사출 결과와 비교해 보면 상이하게 예측될 때가 많다. 본 연구에서는 초기 해석 결과와 실제 압력을 비교하고 차이가 나는 원인을 파악 및 개선하는 연구를 하고자 한다. 또한 압력 비교 시 사출 전 과정에서 압력의 변화를 관측하고 패턴을 개선하였다.



[그림 3-71] 에어백 커버 제품 메시 및 금형 메시

[그림 3-71]은 에어백 커버 제품 메시 및 금형 메시지를 나타내고 있으며, [표 3-8]은 메시 및 모델링 정보를 나타내고 있다.

[표 3-8] 에어백 커버 제품 메시 및 모델링 정보

Index	Mesh & Modeling Information
Mesh Type	DD / 3D
Part Volume	120.9289 / 120.929cm ³
Number of Elements	88,200 / 1,380,750
Number of Nodes	44,181 / 252,496
Total Project Area	237.3628 / 237.3621cm ²

에어백 커버 제품 사출에 적용한 플라스틱 물성은 [그림 3-72]와 같이 저점도 수지로 ASA LI912와 고점도 수지 ASA LI941을 적용하였다.


□ ASA (ASA LI912)

- Specific Heat : 1888 J/kg-C(245°C)
- Melt Density : 0.9415 g/cm³
- Solid Density : 1.0729 g/cm³
- Thermal Conductivity : 0.14 W/m-C(245 °C)
- Transition Temp. : 93 °C
- Ejection Temp. : 86 °C
- Melt Temperature : 210 ~ 250 °C
- Mold temperature : 40 ~ 80 °C
- Filler : UnFilled


□ ASA (ASA LI941)

- Specific Heat : 2342.9 J/kg-C(245°C)
- Melt Density : 0.96479 g/cm³
- Solid Density : 1.0728 g/cm³
- Thermal Conductivity : 0.184 W/m-C(249 °C)
- Transition Temp. : 99 °C
- Ejection Temp. : 92 °C
- Melt Temperature : 210 ~ 250 °C
- Mold temperature : 60 ~ 80 °C
- Filler : UnFilled

[그림 3-72] 저점도 ASA LI912와 고점도 ASA LI941 기본 물성




[그림 3-73] ASA LI912(T_1)와 ASA LI941(T_2) 점도 물성 비교




[그림 3-74] ASA LI912(P_1)와 ASA LI941(P_2) pvT 물성 비교

[그림 3-73]은 ASA LI912와 ASA LI941의 점도 물성을 비교하였다. 전체적으로 ASA LI941 수지의 점도가 높았다. [그림 3-74]는 ASA LI912와 ASA LI941의 pvT 물성을 비교하였다. 압력이 0MPa일 때에는 ASA LI912 수지의 수축이 크지만, 100MPa일 때에는 수축 차이가 줄어들어 두 수지 모두 유사한 것을 확인할 수 있다.




[그림 3-75] 에어백 커버 제품 메시 평면도


[그림 3-75]는 제품 메시의 평면도를 나타내고 있으며, 확인한 결과 두께는 2.5mm로 균일하였다. 그러나 [그림 3-76]과 같이 측면도에서 확인한 결과 하측부 조립 구간의 두께가 2.271 ~ 1.515mm 가변되는 것을 확인할 수 있다. 또한 [그림 3-77]과 같이 정면도에서는 하측 조립부와 연결된 부분에서 두께가 약 11.66mm까지 증가하는 것을 확인할 수 있다.



[그림 3-76] 에어백 커버 제품 메시 측면도




[그림 3-77] 에어백 커버 제품 메시 정면도



[그림 3-78] 에어백 커버 제품 메시 단면도


[그림 3-78]과 같이 에어백 커버 제품 메시 단면도를 확인한 결과 상세도 “B”에서와 같이 두께가 12.6mm까지 증가하는 것을 확인하였다. [그림 3-79]는 에어백 커버 제품의 금형 메시 및 냉각 구조를 나타내고 있다. 하측 코어 외곽에는 냉각라인이 설계되어 있지만 중심 부분의 입자 코어에는 냉각라인 설계가 되어 있지 않아 열 집중이 발생할 것으로 예측된다.



[그림 3-79] 에어백 커버 제품 금형 메시 및 냉각 구조


2) 성형구간 해석(Molding Window)

성형구간해석은 해석 전 적절한 공정설정의 시작 범위를 빠른 시간에 검토할 수 있다. 유동 해석 전 수지 온도, 금형 온도, 사출 속도(사출 시간)를 신속하게 검토할 수 있다. 사출 속도는 성형 가능 구간이 넓도록 결정해야 한다. 성형 최적 조건은 재료 물성, 제품 형상, 게이트 위치, 최대 사출 압력을 기반으로 사출 압력, 유동 선단 온도, 전단응력, 전단율, 미성형 여부에 따라 사출 속도와 금형 온도, 수지 온도를 추천한다.



[그림 3-80] Pressure drop, maximum 결과

[그림 3-80]은 금형 온도 62.22℃, 수지 온도가 233.2℃일 때 사출 시간 변화에 따른 압력강하 결과를 나타내고 있다. 사출 시간은 1.3초 미만일 때 기울기가 가파르다. [그림 3-81]은 용융 수지가 231.1℃일 때 사출 시간 변화에 따른 유동 선단 온도를 나타내고 있다. 유동 선단 온도는 용융 수지 온도를 그대로 유지할 때 외관 불량을 최소화할 수 있으며, 최대 10℃ 이하로 떨어지는 것을 추천한다. 추천하는 사출 시간은 1.3~2.3sec 이다.



[그림 3-81] Temperature at flow front, minimum 결과


Process Settings Wizard - Fill+Pack Settings - Page 1 of 2

[그림 3-82] 초기 해석 조건


[그림 3-82]와 같이 속도 제어를 자동으로 적용할 경우 Molding Window(성형 구간)의 추천 값이 적용된다. 보압 절환 위치(V/P Switch Over)와 보압 제어(Pack/Holding Control)를 자동으로 적용한 후 초기 CAE를 진행하였다.

3) 유동 해석 파라메트릭 연구

[그림 3-83]는 충전 시간 변화에 따라 충전 영역을 나타내고 있다. 충전이 시작하고 2.34sec가 지난 시점에서 미성형 없이 충전이 완료되었다. [그림 3-84]는 보압 절환 시점의 압력으로 약 36.32MPa로 예측되었다.



[그림 3-83] Fill time 결과



[그림 3-84] Pressure at V/P switchover 결과

[표 3-9], [표 3-10]과 같이 저점도(LI912)와 고점도(LI941) 수지의 사출 시간의 변화에 따라 사출 압력 및 형체력 등 유동 해석 결과의 변화를 확인하기 위해 파라메트릭 연구를 진행하였다.


[표 3-9] ASA LI912 사출 시간 변화에 따른 유동 해석 결과 비교

	Injection time (sec)	Bulk temperature (°C)	Clamp force (ton)	V/P Pressure (MPa)	Shear Stress (MPa)	Flow front Temperature (°C)	Ejection Temperature (°C)
1	1	231.69	37.46	43.97	0.495	230.73	57.8
2	1.22	230.44	37.64	43.06	0.474	230.75	57.79
3	1.44	229.17	37.89	42.4	0.458	230.7	57.78
4	1.67	227.86	38.22	41.92	0.444	230.66	57.51
5	1.89	226.53	38.61	41.57	0.433	230.67	57.5
6	2.11	225.16	38.97	41.31	0.423	230.67	57.49
7	2.33	223.78	39.38	41.12	0.415	230.66	57.48
8	2.56	222.37	39.74	40.99	0.408	230.64	57.47
9	2.78	220.95	40.04	40.88	0.402	230.62	57.46
10	3	219.53	40.45	40.85	0.397	230.6	57.44

[표 3-10] ASA LI941 사출 시간 변화에 따른 유동 해석 결과 비교

	Injection time (sec)	Bulk temperature (°C)	Clamp force (ton)	V/P Pressure (MPa)	Shear Stress (MPa)	Flow front Temperature (°C)	Ejection Temperature (°C)
1	1	232.45	58.81	88.25	0.943	230.13	58.78
2	1.22	231.56	59.41	86.24	0.906	230.42	58.77
3	1.44	230.56	60.01	84.68	0.876	230.45	58.5
4	1.67	229.49	60.75	83.51	0.854	230.47	58.49
5	1.89	228.38	61.56	82.63	0.835	230.47	58.48
6	2.11	227.2	62.24	81.91	0.819	230.54	58.21
7	2.33	225.96	63.11	81.38	0.806	230.61	58.2
8	2.56	224.69	64.22	80.99	0.796	230.63	58.19
9	2.78	223.41	65.18	80.64	0.787	230.66	58.18
10	3	222.1	66.04	80.35	0.778	230.67	58.16

사출 시간 변화에 따른 사출 압력 결과를 [그림 3-85]와 같이 그래프로 적용한 결과 충전 시간이 2sec 일 때 ASA LI912는 약 41.5MPa, ASA LI941은 약 82.2MPa로 예측되었다.



[그림 3-85] 사출 시간 변화에 따른 사출 압력 CAE 예측 결과


4) 유동 해석 DOE

DOE Builder를 활용하여 변수 영향 분석 후 반응표면 모델을 활용하여 사출 압력, 형체력, 취출온도에 도달하는 시간을 분석하였다. 실험 영역은 [그림 3-86]과 같이 Variable Influences then Responses를 선택하였다.




[그림 3-86] DOE Builder의 실험 선택

변수 영향에서 변수 응답의 천이는 3개의 변수로 선정했다. [그림 3-87]과 같이 변수는 금형 온도, 수지의 용융 온도, 사출 유량 및 체적 총 4가지를 선택하였고, 최솟값과 최댓값은 수지 제조사에서 권장하는 온도 및 유동 선단의 면적을 고려한 추천 사출 유량 및 체적을 이용하였다.




[그림 3-87] DOE Builder의 변수 선택


ASA LI912, ASA LI941 수지의 DOE 결과는 [그림 3-88] ~ [그림 3-91]과 같이 반응표면 모델로 변수(X, Y)에 따른 최대 사출 압력 (MPa), 형체력(ton)을 나타낼 수 있다. 총 4개의 변수 중 영향력이 큰 수지의 온도 변화와 금형 온도 변화를 선정하였다. ASA LI912 수지는 사출 속도 변화에 따라 최대 사출 압력은 29.7 ~ 43.0MPa, ASA LI941수지는 59 ~ 93MPa로 예측되었다. 형체력은 ASA LI912 수지의 경우 90ton ~ 97ton, ASA LI941 수지는 115ton ~ 127ton으로 예측되었다.




[그림 3-88] ASA LI912 수지의 변수(X, Y)에 따른 최대 사출 압력,
X : 수지 온도(°C), Y : 금형 온도(°C), Z : 사출 최대압력(MPa)



[그림 3-89] ASA LI912 수지의 변수(X, Y)에 따른 필요 형체력,
X : 수지 온도(°C), Y : 금형 온도(°C), Z : 필요 형체력(ton)




[그림 3-90] ASA LI941 수지의 변수(X, Y)에 따른 최대 사출 압력,
X : 수지 온도(°C), Y : 금형 온도(°C), Z : 사출 최대압력(MPa)




[그림 3-91] ASA LI941 수지의 변수(X, Y)에 따른 필요 형체력,
X : 수지 온도(°C), Y : 금형 온도(°C), Z : 필요 형체력(ton)

5) 냉각 해석

[그림 3-92], [그림 3-93]은 상·하측 금형의 온도를 예측하였다. 상측은 80.2 ~ 102.7℃, 하측은 80.46 ~ 123.8℃로 예측되었다. 상측보다 하측의 온도가 약 21.1도 높았다.




[그림 3-92] 상측 Temperature, mold(average) 결과




[그림 3-93] 하측 Temperature, mold(average) 결과

[그림 3-94]와 같이 금형의 단면을 확인한 결과 하측 입자 코어에 냉각 채널이 없어 열 집중이 발생하여 입자 코어에 열 집중이 발생하였다. [그림 3-95]는 생산 초기부터 약 50 사이클 후에 온도가 정상 상태로 유지되어 초기 시험 사출 온도와 양산 사출 온도는 약 60도 이상 차이가 발생할 것을 확인하였다.




[그림 3-94] Temperature, mold(transient) 결과



[그림 3-95] Temperature, mold(transient from start-up) 결과

6) 시험 사출 후 초기 CAE 결과와 사출 압력 비교


시험 사출 성형기는 Engel社의 e-victory 120(기종 이름, 형체력 120ton, 스크류 직경 40mm) 기종 사용, 용융 수지의 설정 온도는 230℃, 프로브 타입 온도계로 측정한 결과 226.5℃로 측정되었다.




[그림 3-96] Engel社의 e-victory 120 사출 성형기

Plasticizing 1:		
Screw diameter	mm	40
Screw diameter	mm	35 40 45
Screw stroke	mm	175
Maximum injection capacity	cm ³	220
Screw speed	min ⁻¹	420
Screw torque	Nm	605
Recovery rate (3-zone screw) ^{1,2,3}	g/s	33,3
Recovery rate (barrier screw) ^{3,4}	g/s	40,2
Injection 1:		
Version:		Standard, Standard-Cl
Injection rate	cm ³ /s	224,40
Injection pressure (regenerative)	bar	2000,0
Nozzle 1:		
Nozzle stroke	mm	290
Nozzle contact pressure	kN	41,0
Material cylinder 1:		
L/D ratio		20,0
Heating zones incl. nozzle 1)		4
Heating wattage 1)	kW _{el}	9,4

[그림 3-97] Engel社의 e-victory 120 사출장치 사양




[그림 3-98] 시험 사출 성형기 보압조건(좌), 사출 조건(우)




[그림 3-99] 핫리너 설정온도 230℃, 냉각수 설정 온도 60℃


사출 성형기에서 사출 후 에어백 커버 금형을 열고 취출 전 이미지를 [그림 3-101]과 같이 촬영하였고, 보압 전환 시 제품 중량과 보압 적용 후 제품 중량을 [그림 3-102]와 같이 촬영하였다.



[그림 3-100] 용융 수지 온도측정




[그림 3-101] 사출 성형기에서 사출 후 에어백 커버 금형 열림




[그림 3-102] 보압 절환 시 제품 중량(좌), 보압적용 후 제품중량(우)

[그림 3-103]은 ASA LI912-V 수지로 에어백 커버 사출 후 열화상 카메라(FLIR E6xt)를 이용한 온도측정 결과이다. 두께가 두꺼운 부위 및 러너부위는 약 130.7°C 까지 높아져 있었고, 하측 리브와 연결된 부분이 빨간 띠를 이루며 뜨거운 것을 확인할 수 있다. [그림 3-104]는 시험 사출 후 취출된 제품의 하측 온도측정 결과이다. 제품두께가 가장 두꺼운 부위의 온도가 약 157°C 로 측정되었다. 상측보다 하측의 제품 온도가 약

26.3℃ 높은 것을 확인하였다.




[그림 3-103] 시험 사출 후 취출된 제품의 상측 온도측정 결과




[그림 3-104] 시험 사출 후 취출된 제품의 하측 온도측정 결과


[그림 3-105]는 LI921 1단 속도제어 시 사출기에서 출력된 사출 속도(파란색) 및 사출 압력(녹색) 그래프로 보압 절환 사출 압력은 85MPa 이었다. [그림 3-106]은 다단 속도제어 시 사출기에서 출력된 보압 절환 사출 압력은 80MPa 이었다. [그림 3-107]은 LI941 1단 속도제어 시 사출기에서 출력된 보압 절환 사출 압력은 103MPa 이었다. [그림 3-108]은 다단 속도제어 시 사출기에서 출력된 보압 절환 사출 압력은 99MPa 이었다.




[그림 3-105] LI921 1단 속도제어 사출기 출력 속도 및 압력



[그림 3-106] LI921 다단 속도제어 사출기 출력 속도 및 압력




[그림 3-107] LI941 1단 속도제어 사출기 출력 속도 및 압력




[그림 3-108] LI941 다단 속도제어 사출기 출력 속도 및 압력


CAE에서 초기 예측한 보압 절환 사출 압력은 [그림 3-109] ~ [그림 3-112] 같이 LI921 수지에 1단 속도제어일 때 36MPa, 다단 속도제어일 때 31MPa로 예측되었다. 이는 실제 사출 실험 결과 대비 38.8 ~ 42.4% 수준으로 오차율은 57.6 ~ 61.3% 수준이다. LI941 수지에 1단 속도제어일 때 74.2MPa, 다단 속도제어일 때 64.27MPa로 예측되었다. 이는 실제 사출 실험 결과 대비 64.9 ~ 72.0% 수준으로 오차율은 28.0 ~ 35.1% 수준이다. 실제 사출은 보압 절환 사출 압력보다 보압 압력이 모두 낮았지만, CAE 결과는 LI921일 때 보압 절환 사출 압력보다 보압 압력이 모두 높았다. 실제와 매우 다른 패턴이 발생하였다. 이러한 현상을 극복하기 위해 수지의 점도, 사출 조건 등 정확성 개선 인자를 파악해보고자 한다.




[그림 3-109] LI921 1단 속도제어 1st CAE 결과



[그림 3-110] LI921 다단 속도제어 1st CAE 결과



[그림 3-111] LI941 1단 속도제어 1st CAE 결과



[그림 3-112] LI941 다단 속도제어 1st CAE 결과


7) CAE 정확성 개선을 위한 수지 물성 및 사출 조건 검토

같은 제조사에서 ASA 수지 물성을 측정한 Autodesk Moldflow 데이터베이스에서 확인한 결과 [그림 3-113]과 같이 총 6가지이다.

	1	2	3	4	5	6
Manufacturer	LG Chemical	LG Chemical	LG Chemical	LG Chemical	LG Chemical	LG Chemical
Trade Name	LI918	LI929	LI935	LI940	LI941	LI912
Family/Abbreviation	ASA	ASA	ASA	ASA	ASA	ASA
Fibers / Fillers	Unfilled	Unfilled	Unfilled	Unfilled	Unfilled	Unfilled
Autodesk Moldflow Material ID	24513	24529	24530	24531	30369	52784
Autodesk Moldflow Grade Code	MAT6222	MAT6638	MAT6639	MAT6640	SN5778	LK801
Rheology	Injection Molding Rheology	Injection Molding Rheology	Injection Molding Rheology	Injection Molding Rheology	Injection Molding Rheology	Injection Molding Rheology
Date	14-AUG-17	15-NOV-18	15-NOV-18	26-NOV-18	08-MAR-10	29-JUN-01
Source	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs
Default Model	Cross/AVLF	Cross/AVLF	Cross/AVLF	Cross/AVLF	Cross/AVLF	Cross/AVLF
Thermal Conductivity	Line Source	Transient Plane Source	Transient Plane Source	Transient Plane Source	Line Source	TC200
Date	14-AUG-17	15-NOV-18	19-NOV-18	26-NOV-18	19-FEB-10	01-OCT-98
Source	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Moldflow Plastics Labs	Moldflow
Specific Heat	DSC cooling	DSC cooling	DSC cooling	DSC cooling	DSC cooling	DSC cooling
Date	14-AUG-17	15-NOV-18	15-NOV-18	22-NOV-18	08-MAR-10	01-OCT-98
Source	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Other	Moldflow
pVT	Indirect Dilatometry	Indirect Dilatometry	Indirect Dilatometry	Indirect Dilatometry	Indirect Dilatometry	Indirect Dilatometry
Date	22-AUG-17	21-NOV-18	22-NOV-18	27-NOV-18	19-FEB-10	01-OCT-98
Source	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Moldflow Plastics Labs	Moldflow
Shrinkage	CRIMS	CRIMS	CRIMS	CRIMS	CRIMS	CRIMS
Date	12-AUG-20	12-AUG-20	12-AUG-20	12-AUG-20	12-AUG-20	12-AUG-20
Source	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Autodesk Moldflow Plastics Labs	Moldflow Plastics Labs	Moldflow
Resin identification code	7	7	7	7	7	7
Energy usage indicator	5	3	4	5	5	4
Fill Quality Indicator	Gold	Gold	Gold	Gold	Gold	Bronze
Pack Quality Indicator	Gold	Gold	Gold	Gold	Gold	Bronze
Warp Quality Indicator	Gold	Gold	Gold	Gold	Gold	Bronze

[그림 3-113] Autodesk Moldflow 데이터베이스 중 ASA 물성 검색 결과


본 실험에서 초기 해석에서 사용한 수지는 [그림 3-114]의 5번, 6번 수지로 빨간 화살표와 같이 수지를 측정할 시점은 오차율이 높았던 LI912 소재의 경우, 1998년 10월로 현시점과 비교하면 약 23년이 지났으며, LI941 소재의 경우 측정할 시점은 2010년 2월로 약 11년이 되었다. [그림 3-113]의 맨 아래 화살표와 같이 Moldflow社의 수지 물성 평가도 LI912는 모든 영역에서 가장 낮은 단계였고, LI941의 경우 최고 등급이다. 사출 압력은 온도, 전단율, 압력에 의해 영향을 받는데, 물성 검토 결과 0MPa일 때 점도와 50MPa일 때의 점도의 차이가 없었다. [그림 3-114]와 같이 본 실험에 사용한 물성인 5번(LI941), 6번(LI921) 수지에서 왼쪽 점도 그래프(압력이 0MPa일 때)와 오른쪽 점도 그래프(압력이 50MPa일 때)에 선을 이어서 비교한 결과 변화가 없었다. Cross-WLF 모델상 압력의존성계수인 D3 값이 0으로 작성되었다. 그래서 기존 스파이럴 테스트와 같이 D3값을 임의로 작성하는 것보다, 같은 제조사에서 측정한 물성 중 0MPa 일 때 점도는 유사하지만 D3가 측정된 물성을 대체 그래이드로 선정 후 물성을 편집하여 해석을 수행하였다.




[그림 3-114] Autodesk Moldflow 데이터베이스 중 점도 물성 비교

또한 CAE에 사출 조건 입력 시 사출기의 출력 성능을 고려하기 위해


플랜지(스크류 또는 램)의 실제 이동 속도를 반영하였다. 설정 속도를 맞추기 위해 실제 이동 속도는 일정 시간이 지연된다. 또한 설정 압력을 맞추기 위해 실제 압력은 지연된다. 이러한 지연을 CAE에 고려하기 위해 사출 속도 제어를 1단 제어일 때 [그림 3-115] 적용하였으며, 다단계 제어일 때 [그림 3-116]과 같이 적용하였다. 또한 보압 조건은 [그림 3-117]과 같이 적용하였다.



[그림 3-115] 1단 속도제어 2nd CAE 입력결과




[그림 3-116] 다단 속도제어 2nd CAE 입력결과




[그림 3-117] 보압제어 2nd CAE 입력결과

8) 개선된 CAE 사출 압력 결과


수지 물성 변경과 사출 속도 및 보압 조건을 개선하여 CAE를 진행한 결과 [그림 3-118] ~ [그림 3-121]로 개선되었다.




[그림 3-118] LI921 1단 속도제어 2nd CAE 결과



[그림 3-119] LI921 다단 속도제어 2nd CAE 결과



[그림 3-120] LI941 1단 속도제어 2nd CAE 결과



[그림 3-121] LI941 다단 속도제어 2nd CAE 결과

[그림 3-122]와 같이 초기 CAE(1st)와 개선된 CAE(2nd)의 오차율 비교 결과, LI912 소재의 경우 사출 속도 변화에 따라 오차율이 57.6 ~ 61.3% 이었으나, 개선된 CAE(2nd CAE)는 5% 이내로 감소하였다. 또한 LI941 소재의 경우 사출 속도 변화에 따라 오차율이 28.0 ~ 35.1%였으나, 개선된 CAE(2nd CAE)는 2.2% 이내로 감소하였다.

	Resin	Ram speed	CAE	Trial	Ratio
1st CAE	912	Single	36	85	57.6%
	912	Multi	31	80	61.3%
	941	Single	74.2	103	28.0%
	941	Multi	64.27	99	35.1%
2nd CAE	928M	Single	86	85	-1.2%
	928M	Multi	84	80	-5.0%
	940M	Single	100.7	103	2.2%
	940M	Multi	99.55	99	-0.6%

[그림 3-122] 1st CAE와 2nd CAE의 오차율 비교 결과

제 4 장 CAE 데이터 기반 머신러닝 모델 생성 및 최적화 연구

제 1 절 CAE 및 MLP를 이용한 힘 예측 및 공정 최적화 연구

1) CAE를 통한 데이터 축적과 MLP를 이용한 예측 모델 생성

자동차 연비 향상을 위해 철로 된 소재를 플라스틱 소재로 변경함에 따라 유리 섬유나 탄소 섬유와 같은 첨가제를 적용한 고강도 플라스틱 복합재료의 사용량이 늘고 있다. 이 소재를 사용하면 사출 제조 공정에서 발생한 첨가제의 배향 방향과 강도에 따라 추가적인 힘 문제가 발생할 수 있다.

일반적으로 사출 성형 조건은 사출 작업자가 결정한다. 그 이유는 사출 현장에서 발생하는 여러 가지 상황을 제어 하면서 최적의 조건을 결정해야 하기 때문이다. 또한 사출 성형 공정 조건을 CAE 엔지니어가 정밀하게 출력하고 있지 못한 이유도 있다. 사출 성형기의 성능, 스크류 크기와 같은 상세 스펙이 정해지지 않은 상태에서 CAE를 적용하는 선행 연구가 많기 때문에 정량적 결과를 도출하기 어려운 경우도 있다. 그러나 CAE의 정확성에서 사출 성형 공정 조건 중요하기 때문에 공정 변수의 불확실성이 힘 변형에 얼마나 영향력이 있는지 파악해야 한다. 그리고 힘을 줄이기 위한 최적의 사출 성형 공정 설정을 찾아도 보압 크기에 따라 제품 전체 길이가 달라지기 때문에 적용을 못 하는 경우가 발생하여, 금형 설계 전에 힘을 줄이기 위한 금형 수축률 파악이 필요하다(황순환 외 2021).

본 연구에서는 Autodesk Moldflow Insight를 활용하여 유리 섬유 강화 플라스틱으로 적용된 라디에이터 탱크 제품의 사출 공정 변수에 따른 힘 변형 예측 Data를 생성하였다. 이를 통해 공정 조건 변경에 따른 힘 양이

얼마나 달라지는 것을 확인하였다. 그리고 힘 양을 줄이는 금형 수축률을 CAE를 통해 확인하였다. 그리고 인공 신경망 기법 중 딥러닝으로 불리는 MLP 기술에 대하여 지도학습을 통한 예측 모델을 생성하였다. 그리고 대표적인 회기 모델로 RSM(Response Surface Model)로도 불리는 PR(Polynomial Regression) 모델, EDT(Ensemble of Decision-tree) 모델, RBF(Radial Basis Function) 모델과 비교하여 최적의 근사 모델을 선정하였다.

2) 연구 방법

최근 배향에 의한 휨 변형 개선을 위해 역설계를 적용하는 기법이 사출 금형 업계에서 주목받고 있다. 사출 금형의 역설계는 휨 변형이 발생하는 방향을 기준으로 반대로 금형을 제작하여 사출 후 휨이 발생할 때 기존 형상으로 돌아오게 하는 기법이다. 이러한 역설계를 위한 사출성형 CAE의 활용은 금형 설계 최적화, 제품 설계 최적화, 수지 선정 최적화에 집중되었다. 그리고 사출 성형 공정 조건은 사출 작업자가 결정하는 방식을 사용하였다. 그러나 정확성 있는 CAE를 위해서는 사출 성형 조건의 변화가 휨 변형에 미치는 영향의 조사가 필요하다. 또한 CAE 결과를 머신러닝 모델로 학습하여 불량 발생하지 않는 구속조건 예측 모델과 변형 예측 모델을 만들어 최적의 조건을 찾는 프로세스가 필요하다.

본 연구에서는 사출 성형 CAE 상용소프트웨어 Autodesk Moldflow Insight를 활용하여 PA66 수지에 유리 섬유가 약 30% 함유된 유리 섬유 강화 플라스틱으로 사출 성형된 라디에이터 탱크에 대하여 사출 성형 공정 조건이 휨 예측에 미치는 영향을 조사하였다. 데이터 생성 방법은 직교 배열을 이용하여 5가지 공정 변수에 따른 휨 예측 Data를 총 108 Case를 진행하였다. 이를 통해 공정 조건 변경에 따른 휨 양의 변화를 분석하였다. 그리고 휨 양의 변화에 따른 금형 수축률을 검토하여 금형 제작 전 설계에 적용할 수 있는 프로세스를 검토하였다. 또한 인공 신경망 기법 중 딥러닝으로 알려진 MLP(Multi-layer Perceptron) 기술에 대하여 상용소

프트웨어 PIAAnO를 이용하여 지도학습을 통한 회귀 근사모델을 생성하였다. MLP 근사모델을 이용할 경우 실제 모델 해석 결과와 어떤 차이를 보이는지 검토하였으며, 힘 양을 최소화 할 수 있는 최적화를 진행하였다.


3) 역설계 공학

힘 변형 문제를 개선하기 위해 제품의 디자인 및 두께 변화, 사출 성형 공정조건 변경, 플라스틱 수지 변경 등 여러 가지 방법이 있지만, 이미 모든 사항이 고정되어 변경될 수 없을 때, 최후의 방법으로 역설계 기법을 사용한다. 역설계 기법이 마지막으로 사용되는 이유는 힘을 개선하는 과정에서 시행착오가 필요하고, 이때 금형 수정 비용이 발생하기 때문이다. 역설계는 이미 만들어진 제품을 역으로 추적하여 처음의 설계를 변경하여 기대하는 품질을 얻어 내는 일로, 핵심 기술은 이미 만들어진 제품을 정밀 측정하여 데이터를 수집하고, 가공하여 모델을 재구성하는 일이다 (Changming, Z., 2010). 그러나 CAE 기술을 적용하면 이미 만들어진 제품이 아닌, 제품을 만들기 전에 제품 모델링에 대한 불량 요인을 시뮬레이션으로 예측하여 설계에 반영할 수 있다. 일반적인 금형 설계는 제품 설계 모델링에 금형 수축률을 적용하고 피드 시스템 및 취출 시스템, 냉각 시스템과 같은 금형 구조를 설계한다. 역설계를 고려한 금형 설계는 위 순서에 사출 공정 중 발생할 힘을 예측하여 힘이 일어날 방향의 반대 방향으로 추가 설계를 적용하여 금형에 반영해야 한다. 역설계 기법의 핵심 사항은 크게 두 가지로 나눌 수 있는데, 첫째로 얼마나 힘이 발생할지를 예측하는 것이고, 둘째로 힘 방향의 반대 방향으로 모델링하는 것이다. 두 가지 핵심 사항을 상용 사출 성형 해석 소프트웨어에서 제공하고 있지만, 많은 CAE 해석자들이 활용을 주저하고 있다. 기존의 사출 성형해석이 정성적인 결과를 예측하는 데 주로 사용되었지만 역설계를 위한 CAE는 정량적인 해석을 진행해야 하므로 위험 부담이 크다. 또한 고려해야 할 사항이 기존 해석보다 많고 복잡하다. 금형의 복잡한 구조 때문에 힘 예측이 잘못 될 경우 관련 부품을 재가공해야 하기 때문이다. 그래서 역설계를 위한 정


량적 힘 예측은 보다 정밀한 분석에 의한 설계결정이 필요하다.

4) 라디에이터 탱크 제품 연구


라디에이터는 자동차 엔진과 같은 내연 기관의 냉각에 주로 사용되는 열 교환기이다. 내연 기관은 냉각수를 엔진 블록 주위로 순환시킴으로써 냉각되며, 엔진 블록에 의해 가열 된 냉각수는 라디에이터를 통해 냉각된다. 자동차 경량화 및 생산성 향상을 이유로 인해 [그림 4-1]과 같이 Steel 재료에서 Plastic 재료로 변경되었다. 라디에이터 탱크는 엔진 블록의 외부로 순환하여 냉각하는 라디에이터 제품 외곽에 연결된 부품으로 자동차 경량화 및 생산성 향상을 위해 고성능 플라스틱 재료와 사출 공정을 적용한다. 플라스틱 재료의 그레이드는 Technyl One J60 X1 V30 Grey 7035인 PA66에 첨가제로 유리 섬유가 30% 함유된 수지 재료를 사용한다. [그림 4-2], [그림 4-3]은 실제 라디에이터 탱크 금형의 상·하측 금형 구조이다. [그림 4-4]는 라디에이터 탱크의 사출 성형 생산 중에 발생하는 힘을 예측한 결과이다. 게이트가 중심에 있어 용융 수지가 제품에 사출될 때 방사 형태로 충전되면서 유동 선단이 가장 가까운 벽면을 부딪치고 방향이 바뀌며 유리 섬유의 배향이 달라지면서 배향이 강한 부분은 수축이 낮게 만들고, 배향이 약한 부분은 수축이 높게 만들어, 수축 편차로 힘을 발생시킨다. 캐비티의 개수는 2개이며, 1개의 캐비티 당 3개의 슬라이드 코어가 설치되어 있어 총 6개의 슬라이드 코어가 설치되었다. 피드 시스템은 핀 포인트 게이트 구조이며, 여러 개의 입자 코어로 분리되어 있다. 금형 복잡성으로 인하여 힘 예측이 잘못될 경우 역설계의 변경사항이 발생하고, 제품 설계 변경 및 금형 구조 변경이 필수적이다. 금형의 형상 변경은 관련 부품이 함께 변경되어야 하므로 높은 수정 비용이 발생한다. 일반적으로 라디에이터 탱크 제품은 [그림 4-4]와 같이 “A” 부분이 안쪽으로 수축하는 힘이 가장 크게 발생하며(X component), 평탄도(Z component)가 공차 범위에서 벗어날 경우 불량률의 요인이 된다(황순환 외 2021).




[그림 4-1] 첼로 된 라디에이터 탱크(좌), 플라스틱 재료 변경 모델(우)



[그림 4-2] 사출기에 고정된 라디에이터 탱크 사출 금형 고정 측 이미지




[그림 4-3] 사출기에 고정된 라디에이터 탱크 사출 금형 가동 측 이미지




[그림 4-4] 라디에이터 탱크 제품의 힘 CAE 예측 결과

5) 라디에이터 탱크 플라스틱 물성

[그림 4-5]는 수지의 점도를 측정하여 데이터 피팅을 통해 전단율과 온도의 변화에 따른 점도의 변화를 나타내는 유변학적 물성을 표현한 것이다. 라디에이터 탱크를 위한 플라스틱 재료는 내열성 및 기계적 강도 유지를 위해 Solvay Engineering Plastics社의 그레이드는 “Technyl One”으로 “J60 X1 V30 Grey 7035”이다. PA66에 첨가제로 유리 섬유가 30% 첨가된 수지를 선정하였다. 또한 [그림 4-6]과 같이 압력과 온도의 변화에 따른 비체적의 변화를 측정하여 수축 특성을 나타낼 수 있다. CAE는 아래의 물성을 토대로 유동 특성 및 수축 특성을 예측한다.




[그림 4-5] 점도 그래프



[그림 4-6] 온도 및 압력에 따른 비체적 pvT 물질

6) 라디에이터 탱크 데이터 생성 및 초기 분석

CAE를 수행하기 위해 Autodesk Moldflow Insight를 이용하여 [그림 4-7]과 같이 3D 메시로 10개 레이어로 적용하여 1,187,104개를 생성하였다. 또한 제품의 중심에 사출 점을 설계하였다.



[그림 4-7] 라디에이터 탱크 제품 메시의 ISO View

[표 4-1]과 같이 사출 현장에서 사용하는 공정 조건 변수(Process Setting Variables)를 기준으로 3 수준의 변수를 선정하였다. 목적함수(Objective Function)는 X 요소의 변형량 최소화이며, 가용할 수 있는 사출기 스펙 중 형체력을 270ton 이하로 제한하였으며, 심각한 외관 불량 발생하지 않도록 플래시가 발생하지 않는 사출 압력 80MPa 이하로 구속 조건(Process Setting Constraints)을 선정하였다(황순환 외 2021).

[표 4-1] 사출 성형 공정 변수

Process setting variables	Level		
IT: Injection time(s)	1	2	3
PP: Packing pressure(MPa)	20	50	80
PT: Packing time(s)	5	10	15
MeT: Melt temperature(deg)	270	290	310
MoT: Mold temperature(deg)	60	80	100

위 변수에 대하여 모든 해석을 수행할 경우 3^5 으로 계산하면 총 243 Case를 진행해야 한다. 그러나 직교 배열(Orthogonal Array)에 따르면 108회 실험으로(L108) [표 4-2]와 같이 생성하였다(황순환 외 2021).

[표 4-2]직교 배열(Orthogonal Array) L108 Case 실험

Classification	Input / Output	Detail	Data
Input (Variable)	IT	Injection time (sec)	1,2,3
	PP	Packing pressure (Mpa)	20,50,80
	PT	Packing time (sec)	5,10,15
	MeT	Melt temperature (deg)	270,290,310
	MoT	Mold temperature (deg)	60,80,100
Output (CAE or Machine learning Result)	FT	Fill time	Results Using Prediction Models
	VP	Pressure at V/P switch	
	CF	Clamp Force	
	We	Weight	
	Sum_X	Deflection, all effect : X Component	
	Sum_Y	Deflection, all effect : Y Component	
	Sum_Z	Deflection, all effect : Z Component	

이번 연구에서는 학습데이터와 테스트 데이터를 80:20 비율로 학습 세트와 평가 세트로 배분하였다(Google developers, 2021). 3D 메시로 10 개 레이어로 작성하여 총 1,187,104개를 사용하였다. 또한 제품의 중심에 사출 주입 점을 설정하였다. 미성형이 발생하지 않는 조건을 위하여 사출 시간은 1초에서 3초를 선정하였으며, 보압 시간과 크기는 제품 외곽 사이즈가 가능한 범위로 결정하였다. 또한 수지의 온도와 금형 온도는 수지 회사에서 추천하는 범위를 사용하였다. 요구 사항을 충족시키기 위해 설계 문제를 수학 문제로 공식화하였다(사택문, 2017). 식 (1)과 같이 설계 변수는 5개로 사출 시간(x_1), 보압 크기(x_2), 보압 시간(x_3), 수지 용융 온도(x_4), 금형 표면 온도(x_5) 이다. 본 실험의 목표는 식 (2)와 같이 힘 최소화이며 위치는 Fig. 1에서 같이 빨간색과 파란색으로 표현된 힘 결과이다. 구속 조건으로는 식 (3),(4)와 같이 형체력은 270ton 이하, 최대 사출 압력은 80MPa 이하이다.

$$Find: x_n \quad n=1, 2, 3, 4, 5 \quad (22)$$

$$To \ minimize: Max_deflection \quad (23)$$

$$Subject \ to: Clamp_force \leq 270 \quad (24)$$

$$Max_pressure \leq 80 \quad (25)$$


[표 4-3] 직교 배열에 따른 L108 Case 실험 결과

IT	PP	PT	MeI	MoI	FT	VP	CF	We	DeX	De-X	SumX	DeY	De-Y	SumY	De_Z	De_-Z	SumZ
1	20	10	270	60	1.092	107.4	131.4	473.1	2.363	2.616	4.979	1.862	2.202	4.064	1.122	1.001	2.123
1	20	10	270	100	1.097	100.4	129.7	471.5	2.319	2.555	4.874	1.814	2.197	4.011	1.107	0.9852	2.0922
1	20	10	290	60	1.074	84.06	98.15	474.8	2.333	2.587	4.92	1.84	2.176	4.016	1.093	1.009	2.102
1	20	10	290	80	1.071	81.33	96.5	474.1	2.33	2.547	4.877	1.887	2.198	4.085	1.093	0.9986	2.0916
1	20	10	310	80	1.057	63.68	73.57	475.4	2.338	2.541	4.879	1.838	2.212	4.05	1.088	1	2.088
1	20	10	310	100	1.066	61.82	71.05	474.3	2.33	2.521	4.851	1.854	2.228	4.082	1.086	0.9915	2.0775
1	20	15	270	80	1.1	103.3	127.1	472.1	2.332	2.583	4.915	1.837	2.213	4.05	1.111	0.9989	2.1099
1	20	15	270	100	1.097	100.4	129.7	471.5	2.319	2.555	4.874	1.814	2.197	4.011	1.107	0.9852	2.0922
1	20	15	290	60	1.074	84.06	98.15	474.8	2.333	2.587	4.92	1.84	2.176	4.016	1.092	1.009	2.101
1	20	15	290	100	1.068	78.98	95.48	473.3	2.341	2.551	4.892	1.835	2.189	4.024	1.089	0.9906	2.0796
1	20	15	310	60	1.069	65.48	74.93	476.2	2.353	2.538	4.891	1.846	2.254	4.1	1.089	0.9995	2.0885
1	20	15	310	80	1.057	63.68	73.57	475.3	2.338	2.541	4.879	1.838	2.211	4.049	1.087	1	2.087
1	50	5	270	60	1.066	107.4	165.1	478.4	2.119	2.363	4.482	1.658	1.994	3.652	0.9862	0.8861	1.8723
1	50	5	270	80	1.062	103.3	169.3	477.9	2.069	2.306	4.375	1.624	1.991	3.615	0.9788	0.8735	1.8523
1	50	5	290	80	1.046	81.33	178.6	478.2	2.099	2.219	4.318	1.686	1.973	3.659	0.9511	0.8996	1.8507
1	50	5	290	100	1.044	78.98	180.6	476.7	2.121	2.243	4.364	1.64	1.933	3.573	0.933	0.9258	1.8588
1	50	5	310	60	1.042	65.48	182	478.4	2.142	2.234	4.376	1.657	1.995	3.652	0.9245	0.9381	1.8626
1	50	5	310	100	1.037	61.82	184.6	474.4	2.271	2.433	4.704	1.713	2.024	3.737	0.9998	1.015	2.0148
1	50	10	270	60	1.066	107.4	165.1	478.5	2.117	2.367	4.484	1.656	1.99	3.646	0.9779	0.8861	1.864
1	50	10	270	100	1.065	100.4	173.4	477.3	2.047	2.282	4.329	1.607	1.959	3.566	0.9564	0.8509	1.8073
1	50	10	290	60	1.051	84.06	176	479.8	2.065	2.3	4.365	1.62	1.944	3.564	0.9439	0.8839	1.8278
1	50	10	290	80	1.046	81.33	178.6	479.1	2.049	2.245	4.294	1.657	1.952	3.609	0.943	0.8721	1.8151

1	50	10	310	80	1.038	63.68	183.3	480	2.054	2.231	4.285	1.603	1.95	3.553	0.9259	0.8762	1.8021
1	50	10	310	100	1.037	61.82	184.6	479.1	2.045	2.208	4.253	1.612	1.961	3.573	0.9254	0.8762	1.8016
1	80	5	270	80	1.046	103.3	290.1	482.4	1.803	1.989	3.792	1.399	1.741	3.14	0.8469	0.7577	1.6046
1	80	5	270	100	1.045	100.4	293.7	481.6	1.795	1.915	3.71	1.371	1.723	3.094	0.8426	0.7434	1.586
1	80	5	290	60	1.04	84.06	295.3	483.4	1.849	1.956	3.805	1.424	1.722	3.146	0.8317	0.7907	1.6224
1	80	5	290	100	1.04	78.98	298.7	480.5	1.954	2.01	3.964	1.452	1.712	3.164	0.8474	0.8541	1.7015
1	80	5	310	60	1.04	65.48	299.9	482.1	1.971	2.006	3.977	1.473	1.748	3.221	0.8131	0.8795	1.6926
1	80	5	310	80	1.038	63.68	301.1	480.1	2.049	2.199	4.248	1.52	1.783	3.303	0.8764	0.9423	1.8187
1	80	15	270	60	1.049	107.4	286.8	483	1.844	2.072	3.916	1.424	1.736	3.16	0.8323	0.7735	1.6058
1	80	15	270	80	1.046	103.3	290.1	482.5	1.775	2.018	3.793	1.384	1.721	3.105	0.8164	0.7558	1.5722
1	80	15	290	80	1.038	81.33	297.4	483.3	1.754	1.932	3.686	1.413	1.686	3.099	0.7924	0.7427	1.5351
1	80	15	290	100	1.04	78.98	298.7	482.5	1.755	1.935	3.69	1.359	1.667	3.026	0.7975	0.7351	1.5326
1	80	15	310	60	1.04	65.48	299.9	485	1.765	1.925	3.69	1.371	1.725	3.096	0.7951	0.7377	1.5328
1	80	15	310	100	1.036	61.82	302	483.1	1.773	1.916	3.689	1.363	1.685	3.048	0.8011	0.7486	1.5497
2	20	5	270	60	2.155	97.18	119.2	472.8	2.423	2.759	5.182	1.878	2.234	4.112	1.228	1.026	2.254
2	20	5	270	80	2.157	91.14	111.1	472.5	2.414	2.734	5.148	1.882	2.235	4.117	1.195	1.044	2.239
2	20	5	290	80	2.149	66.19	77.29	473.7	2.43	2.698	5.128	1.873	2.234	4.107	1.167	1.052	2.219
2	20	5	290	100	2.155	62.37	74.3	472.8	2.383	2.592	4.975	1.888	2.216	4.104	1.141	1.03	2.171
2	20	5	310	60	2.132	51.12	63.93	475	2.425	2.598	5.023	1.907	2.286	4.193	1.139	1.06	2.199
2	20	5	310	100	2.12	45.71	67.25	471.4	2.377	2.535	4.912	1.873	2.201	4.074	1.114	1.053	2.167
2	20	10	270	80	2.157	91.14	111.1	472.5	2.414	2.735	5.149	1.881	2.235	4.116	1.194	1.044	2.238
2	20	10	270	100	2.168	85.78	104.1	472.1	2.457	2.75	5.207	1.865	2.211	4.076	1.183	1.035	2.218
2	20	10	290	60	2.154	70.41	83.23	474.5	2.421	2.716	5.137	1.89	2.244	4.134	1.161	1.042	2.203
2	20	10	290	100	2.155	62.37	74.3	473.2	2.378	2.618	4.996	1.876	2.202	4.078	1.115	1.024	2.139
2	20	10	310	60	2.132	51.12	63.93	475.9	2.409	2.624	5.033	1.887	2.27	4.157	1.106	1.046	2.199
2	20	10	310	80	2.127	48.54	65.45	475.2	2.388	2.597	4.985	1.929	2.229	4.158	1.096	1.035	2.131
2	50	5	270	80	2.12	91.14	168.8	477.9	2.169	2.458	4.627	1.711	2.067	3.778	1.068	0.9175	1.9855
2	50	5	270	100	2.106	85.78	172.4	477.3	2.203	2.469	4.672	1.684	2.028	3.712	1.061	0.9161	1.9771
2	50	5	290	60	2.098	70.41	175.9	479.4	2.184	2.429	4.613	1.721	2.062	3.783	1.036	0.938	1.974
2	50	5	290	100	2.086	62.37	181.1	477.5	2.176	2.326	4.502	1.69	1.994	3.684	0.9829	0.9563	1.9392
2	50	5	310	60	2.085	51.12	182.4	479.4	2.204	2.349	4.553	1.806	2.064	3.87	0.9857	0.9794	1.9651
2	50	5	310	80	2.08	48.54	183.9	477.7	2.207	2.34	4.547	1.751	1.986	3.737	0.945	1.007	1.952
2	50	15	270	60	2.122	97.18	162.8	478.3	2.191	2.506	4.697	1.7	2.068	3.768	1.085	0.9161	2.0011
2	50	15	270	100	2.106	85.78	172.4	477.4	2.2	2.479	4.679	1.679	2.021	3.7	1.047	0.9147	1.9617
2	50	15	290	60	2.098	70.41	175.9	479.5	2.171	2.446	4.617	1.708	2.049	3.757	1.014	0.9311	1.9451
2	50	15	290	80	2.089	66.19	178.9	478.9	2.181	2.449	4.63	1.66	2.018	3.678	1.003	0.9371	1.9401
2	50	15	310	80	2.08	48.54	183.9	480	2.128	2.322	4.45	1.708	1.989	3.697	0.9463	0.9328	1.8791
2	50	15	310	100	2.078	45.71	185.2	479	2.091	2.26	4.351	1.635	1.971	3.606	0.941	0.9055	1.8465
2	80	10	270	60	2.103	97.18	286.4	482.9	1.94	2.225	4.165	1.499	1.873	3.372	0.9603	0.7982	1.7585
2	80	10	270	80	2.094	91.14	290.2	482.4	1.917	2.173	4.09	1.519	1.843	3.362	0.9336	0.8041	1.7377
2	80	10	290	80	2.08	66.19	297.8	483.2	1.93	2.178	4.108	1.442	1.782	3.224	0.8786	0.8286	1.7072
2	80	10	290	100	2.074	62.37	299.4	482.5	1.877	2.083	3.96	1.436	1.734	3.17	0.8462	0.8205	1.6667
2	80	10	310	60	2.081	51.12	300.2	484.8	1.892	2.107	3.999	1.444	1.795	3.239	0.8445	0.8357	1.6802
2	80	10	310	100	2.071	45.71	302.4	483.2	1.816	1.993	3.809	1.398	1.709	3.107	0.8214	0.7868	1.6082
2	80	15	270	60	2.103	97.18	286.4	482.9	1.94	2.225	4.165	1.499	1.873	3.372	0.9603	0.7982	1.7585
2	80	15	270	100	2.086	85.78	293.3	481.8	1.945	2.193	4.138	1.473	1.793	3.266	0.9171	0.8039	1.721
2	80	15	290	60	2.089	70.41	295.8	483.9	1.918	2.171	4.089	1.501	1.817	3.318	0.8825	0.8235	1.706
2	80	15	290	80	2.08	66.19	297.8	483.2	1.931	2.178	4.109	1.442	1.782	3.224	0.8781	0.8288	1.7069
2	80	15	310	80	2.075	48.54	301.4	484	1.868	2.061	3.929	1.473	1.736	3.209	0.8202	0.8194	1.6396
2	80	15	310	100	2.071	45.71	302.4	483.2	1.817	1.993	3.81	1.398	1.708	3.106	0.8214	0.7874	1.6088
3	20	5	270	60	3.276	102.6	130	473.2	2.385	2.711	5.096	1.908	2.147	4.055	1.253	0.9793	2.2323
3	20	5	270	100	3.208	83.51	105.7	472.3	2.392	2.689	5.081	1.885	2.179	4.064	1.226	0.9985	2.2245
3	20	5	290	60	3.223	67.82	82.62	474.3	2.419	2.715	5.134	1.915	2.215	4.13	1.218	1.024	2.242
3	20	5	290	80	3.211	61.79	74.72	473.7	2.413	2.68	5.093	1.882	2.25	4.132	1.21	1.03	2.24
3	20	5	310	80	3.182	42.97	65.48	474.1	2.442	2.644	5.086	1.927	2.258	4.185	1.173	1.062	2.235
3	20	5	310	100	3.169	39.6	67.34	472.3	2.406	2.618	5.024	1.91	2.234	4.144	1.145	1.063	2.208
3	20	15	270	60	3.276	102.6	130	473.2	2.385	2.712	5.097	1.908	2.147	4.055	1.253	0.9794	2.2324
3	20	15	270	80	3.227	92.96	117.8	472.6	2.398	2.721	5.119	1.899	2.165	4.064	1.229	0.9897	2.2187
3	20	15	290	80	3.211	61.79	74.72	473.9	2.411	2.687	5.098	1.88	2.245	4.125	1.196	1.028	2.224
3	20	15	290	100	3.211	56.58	68.1	473.2	2.393	2.69	5.083	1.865	2.221	4.086	1.158	1.038	2.196
3	20	15	310	60	3.198	46.62	63.06	475.8	2.426	2.699	5.125	1.899	2.269	4.168	1.178	1.04	2.218
3	20	15	310	100	3.169	39.6	67.34	474.2	2.386	2.622	5.008	1.898	2.234	4.132	1.113	1.034	2.147
3	50	10	270	60	3.219	102.6	155.6	478.4	2.193	2.5	4.693	1.761	2.013	3.774	1.133	0.8956	2.0286
3	50	10	270	80	3.192	92.96	165.1	478	2.187	2.491	4.678	1.735	2.012	3.747	1.114	0.8934	2.0074
3	50	10	290	80	3.147	61.79	177.8	478.8	2.18	2.427	4.607	1.694	2.067	3.761	1.061	0.9113	1.9723
3	50	10	290	100	3.131	56.58	181	478.2	2.138	2.406	4.544	1.683	2.025	3.708	1.02	0.9221	1.9421
3	50	10	310	60	3.146	46.62	182.4	480.5	2.185	2.423	4.608	1.723	2.072	3.795	1.035	0.9247	1.9597
3	50	10	310	100	3.119	39.6	185.4	478.9	2.134	2.356	4.49	1.687	2.008	3.695	0.9757	0.9314	1.9071
3	50	15	270	80	3.304	93.44	164.5	478	2.183	2.479	4.662	1.737	2.007	3.744	1.119	0.8841	2.0031
3	50	15	270	100	3.174	83.51	171.4	477.5	2.163	2.447	4.61	1.706	2.013	3.719	1.096	0.8914	1.9874
3	50	15	290	60	3.166	67.82	173.9	479.5	2.19	2.474	4.664	1.745	2.049	3.794	1.081	0.9188	1.9998
3	50	15	290	100	3.236	56.25	180.9	478.2	2.13	2.414	4.544	1.702	2.015	3.717	1.018	0.919	1.937
3	50	15	310	60	3.146	46.62	182.4	480.5	2.185								

3	80	5	270	60	3.184	102.6	281.1	482.8	1.965	2.26	4.225	1.575	1.837	3.412	1.022	0.8086	1.8306
3	80	5	270	100	3.143	83.51	292.6	481.8	1.922	2.181	4.103	1.502	1.84	3.342	1.008	0.7913	1.7993
3	80	5	290	60	3.149	67.82	293.9	483.6	1.968	2.203	4.171	1.578	1.875	3.453	1.002	0.825	1.827
3	80	5	290	80	3.134	61.79	297.4	482.9	1.963	2.12	4.083	1.531	1.894	3.425	0.9915	0.8132	1.8047
3	80	5	310	80	3.123	42.97	301.3	482.3	1.994	2.165	4.159	1.568	1.818	3.386	0.9099	0.9421	1.852
3	80	5	310	100	3.111	39.69	302.7	480.4	2.117	2.274	4.391	1.572	1.798	3.37	0.9008	1.001	1.9018
3	80	10	270	80	3.163	92.96	287.7	482.4	1.939	2.259	4.198	1.538	1.83	3.368	0.996	0.8131	1.8091
3	80	10	270	100	3.143	83.51	292.6	481.8	1.914	2.193	4.107	1.496	1.829	3.325	0.9864	0.7884	1.7748
3	80	10	290	60	3.149	67.82	293.9	483.7	1.947	2.229	4.176	1.562	1.854	3.416	0.9634	0.825	1.7884
3	80	10	290	100	3.12	56.58	298.9	482.4	1.891	2.129	4.02	1.486	1.805	3.291	0.9056	0.803	1.7086
3	80	10	310	60	3.135	46.62	299.9	484.6	1.94	2.155	4.095	1.528	1.858	3.386	0.9187	0.8124	1.7311
3	80	10	310	80	3.123	42.97	301.3	483.9	1.924	2.113	4.037	1.503	1.802	3.305	0.8914	0.8237	1.7151

CAE 결과를 탐색하기 위해 R을 이용하여 Q-Q와 박스 및 바이올린 플롯 결과를 이용하여 충전 결과(Fill Time), 보압 절환 압력(V/P Pressure), 형체력(Clamp Force), 제품 중량(Weight), X, Y, Z 방향의 변형(Sum_X, Sum_Y, Sum_Z) 분포를 분석하였다. 분포가 선형성을 나타내고 있어 정규 분포에 따르는 것을 알 수 있다.




[그림 4-8] Q-Q, 박스 및 바이올린 플롯 분석 결과

입력(Input) 조건 108 Case에 대한 CAE 결과(Output)를 [그림 4-9]와 같이 확인할 수 있다. 보압 전환 시 사출 압력(VP)은 최대 107MPa, 형체력은 303ton으로 구속 조건 범위를 넘어선 결과가 도출되었으며, 목표치인 주요 부위 휨 결과(Sum_X)는 최소 3.69mm에서 최대 5.21mm로 1.52mm의 차이가 발생하였다. 사출 작업자들은 뜨거운 상태에서 금형에서 취출된 제품을 확인할 수 있다. 이러한 사출 성형품은 상온까지 떨어지면서 휨이 진행되기 때문에 사출 작업자가 휨을 측정하면서 좋은 휨 양을 선택하기는 힘들다.

Descriptives	In put					Out put						
	IT	PP	PT	MeT	MoT	FT	VP	CF	We	Sum_X	Sum_Y	Sum_Z
N	108	108	108	108	108	108	108	108	108	108	108	108
Missing	0	0	0	0	0	0	0	0	0	0	0	0
Mean	2.00	50.0	10.0	290	80.0	2.11	72.6	188	478	4.51	3.68	1.93
Median	2.00	50.0	10.0	290	80.0	2.10	67.8	179	478	4.55	3.71	1.94
Minimum	1	20	5	270	60	1.04	39.6	63.1	471	3.69	3.03	1.53
Maximum	3	80	15	310	100	3.30	107	303	485	5.21	4.19	2.25

[그림 4-9]입력(Input) 조건 108 Case에 대한 CAE 결과(Output)



[그림 4-10] X 방향의 휨(Sum_X)의 상관분석 결과


[그림 4-10]과 같이 X 방향의 휨(Sum_X)의 상관분석 결과, 보압 크기인 PP(Packing Pressure)가 가장 컸다. [그림 4-11]은 구속조건인 형체력(CF)의 상관분석 결과, 보압 크기인 PP(Packing Pressure)가 가장 컸다. [그림 4-12]과 같이 보압 절환 시 압력(VP)의 상관분석 결과, 수지의 온도인 MeT(Melt Temperature)가 가장 컸다.



[그림 4-11] 형체력(CF)의 상관분석 결과



[그림 4-12] 보압 절환 시 사출 압력(VP)의 상관분석 결과




[그림 4-13] X 방향 힘(Sum_X)의 상관분석 결과

[그림 4-10]의 X 방향 힘(Sum_X) 주요 상관분석을 통한 변수의 수준 값 평가를 통해 X 방향의 힘 양을 줄이기 위해 가장 큰 영향력인 보압은 높이고, 두 번째 영향력인 사출 시간은 줄이는 것이다. 힘 양(Sum_X)과 상관관계 중 영향력 지수가 가장 높은 변수 보압 크기에 대하여 [그림 4-13]와 같이 상관 분석 결과 보압이 커지면 X 방향의 변형량이 적어지는 반비례 관계를 확인하였다. 변형량의 크기는 5.21mm에서 3.69mm로 공정 조건의 변화에 따라 약 41%의 힘 양이 달라지는 것을 확인하였다. 또한 조건의 변화에 따라 제품의 중량이 변화하는데 중량과 힘 또한 반비례 관계인 것을 확인하였다. 그리고 X 방향의 힘이 커질수록 Y 방향의 수축 및 Z 방향의 뒤틀림이 커짐을 확인하였다. 즉 보압을 높이면 힘은 줄지만 수축이 줄어 치수 문제가 발생할 수 있음을 확인하였다. [표 4-4]는 CAE 결과 중 초깃값과 변형 최댓값, 최소값을 비교하였다. 결과적으로 성형 조건 변화에 따라 변형량은 최대 1.52mm의 차이가 발생하는 것을 확인할 수 있다. 수축률도 조건에 따라 최대 2/1000가 달라지는 것을 확인하였다(황순환 외 2021).


[표 4-4] CAE 결과 비교

	Case study	Case 44	Case 33	Case 24
Variable	Injection_time	2	1	1
	Packing_pressure	20	80	50
	Packing_time	10	15	10
	Melt_temp.	270	290	310
	Mold_temp.	100	80	100
CAE Result	Fill_time	2.168	1.038	1.037
	Pressure at VP switchover	85.78	81.33	61.82
	Clamp force	104.1	297.4	184.6
	Weight	472.1	483.3	479.1
	Sum_X	5.207	3.686	4.253
	Sum_Y	4.076	3.099	3.573
	Sum_Z	2.218	1.5351	1.8016
Mold Shrink Analysis	Before	466.88	466.88	466.88
	After	462.80	463.78	463.31
	Shrink rate	1.0088	1.0067	1.0077

초기 공정 조건인 Case44는 [그림 4-14]과 같이 사출 시간 2sec, 보압 20MPa, 보압 시간 10sec 수지 온도 270℃, 금형 온도 100℃의 결과이다. 이때 해석 결과는 충전 시간 2.168sec, 최대 압력은 85.78MPa, 형체력은 104ton으로 예측되었으며, X 방향의 휨은 편측 5.207mm이다. Y 방향의 수축 양은 4.076mm이다. 금형 치수는 466.88mm에서 사출품 수축 후 치수는 Y 방향의 수축을 뺀 값으로 462.8mm로서 수축률은 8.8/1000이다. Z 방향의 뒤틀림 양은 2.218mm이다. Case33은 변형량이 가장 작은 Case로써 공정 조건은 사출 시간 1sec, 보압 80MPa, 보압 시간 15sec 수지 온도 290℃, 금형 온도 80℃이다. CAE 해석 결과는 [그림 4-15]와 같이 충전 시간 1.04sec, 최대 압력은 81.33MPa 으로 구속 조건에서 벗어나며, 형체력은 297ton으로 구속 조건에서 벗어나는 것을 예측하였다. X 방향의 휨은 3.69mm이다. 초기 조건에 비해 약 1.52mm 작게 휘는 것을 확인하였다. Y 방향의 수축은 3.01mm로서 초기 조건보다 0.98mm 작게 수축하였다. 수축률은 6.7/1000로서 초기 조건보다 2.1/1000 낮다. Z 방향의 뒤틀림은 1.54 mm이다(황순환 외 2021).




[그림 4-14] Case44의 CAE 결과(초기 값)




[그림 4-15] Case33의 CAE 결과(구속조건 벗어나는 최적값)

Case24는 구속 조건을 만족하면서 변형량이 가장 작은 Case로써 공정 조건은 사출 시간 1sec, 보압 50MPa, 보압 시간 10sec 수지 온도 310℃, 금형 온도 100℃이다. CAE 해석 결과는 충전 시간 1.037sec, 최대 압력은 61.82MPa, 형체력은 184.6ton을 예측하였다. X 방향의 휨 양은 4.253mm, Y 방향의 수축 양은 3.573mm, Z 방향의 휨 양은 1.802mm이다.



[그림 4-16] Case24의 CAE 결과(구속조건 만족하는 CAE 최적값)

휨에 영향력이 큰 보압크기와 사출 조건을 3D 반응 표면으로 검토한 결과는 [그림 4-17]과 같다. 보압 크기의 변화와 휨의 관계는 비교적 선형적이며, 사출 시간의 변화와 휨의 관계는 2초에서 3초로 변화할 때 보다 2초에서 1초로 변화할 때 더 급격한 변화가 이루어지는 것을 통해 비선형적인 것을 확인하였다(황순환 외 2021).



[그림 4-17] X 방향의 변형 3D 반응 표면 결과

7) MLP(Multi-layer Perceptron) 알고리즘 이해

머신러닝은 사람이 학습하는 것처럼 컴퓨터가 데이터를 통해 학습함으로써 기대하는 지식을 얻는 것이다. 딥러닝 기술은 인공 신경망 즉, 은닉층과 은닉층에 존재하는 뉴런을 통하여 입력변수 및 출력변수의 복잡한 관계를 멀티 레이어 구조로 파악하는 기법이다. 입력 값과 출력 값에 대하여 학습하여 신경망으로 예측된 값의 편차를 최소화하도록 각 레이어의 뉴런에 연결된 가중치와 편향 반복적으로 훈련함으로써 우수한 신경망 모형을 완성하도록 한다. MLP는 훈련을 위해 역전파²⁹⁾ 알고리즘을 사용한다. 역전파 알고리즘은 학습 데이터 중 입·출력에 대하여 “입력”을 신경망에 입력해 출력 값을 얻는다. 이 출력 값과 해당 입력의 출력 값과 비교해 오류를 구하고, 출력 노드들의 편차를 계산하여 출력 노드의 편차를 역

29) 역전파(Backpropagation): 출력 값과 비교해 오류를 구하고, 출력 노드들의 편차를 계산하여 출력 노드의 편차를 역전파해 바로 앞 은닉 노드들의 편차를 계산하는 알고리즘.

전파해 바로 앞 은닉 노드들의 편차를 계산한다. 이러한 입력층 바로 앞 은닉층까지 반복하고 신경망의 가중치를 학습 규칙으로 변경하여 개선한다.

8) 머신러닝 학습모델 생성 및 비교

본 연구에서는 은닉층(Hidden layers) 변화에 따라 MLP 모델을 비교하고, 최적의 MLP 모델을 검증하기 위해 3개의 다른 머신러닝 모델을 비교하고자 하였다. 먼저 EDT³⁰⁾은 입력된 데이터로 여러 개의 예측 모델을 만들어 예측 모델을 결합한 뒤 최종 예측 모델을 만드는 기법으로 많은 데이터가 존재하는 경우 입력변수와 출력변수의 비선형적 관계를 효율적으로 분석하는 기법이다. 두 번째로 PR³¹⁾은 RSM³²⁾으로도 널리 불리며 다항식(Polynomial)으로 구성되어 직관적이며 손쉽게 활용할 수 있다. 비선형성이 강한 해석 모델을 근사화하는 데에는 적합하지 않다. 마지막으로 RBF³³⁾은 대표적인 보간(Interpolation) 모델로 비선형성을 비교적 잘 표현하며 사용자 지정 변숫값을 어떻게 설정하는가에 따라 모델의 형상 및 예측 성능이 달라진다.

108개의 Case를 토대로 머신러닝을 진행하였으며, 학습 결과를 평가하기 위해 15개의 Case를 추가로 진행하여 테스트 모델로 사용하였다. 본 논문에서는 근사모델을 평가할 때 사용하는 도구로 결정계수(R-squared)와 평균 제곱근 오차 RMSE³⁴⁾를 사용하였다. 결정계수는 회귀모형의 설명력을 표현한 것이다. 결정계수는 SST³⁵⁾과 SSR³⁶⁾이 얼마나 비슷한지, SST과 SSE³⁷⁾가 얼마나 다른지에 따라 결정계수 값이 높아지며 모델이

30) EDT(Ensemble of Decision-trees): 의사결정나무의 앙상블

31) PR(Polynomial Regression): 다항회기

32) RSM(Response Surface Model): 반응표면모델

33) RBF(Radial Basis Function): 방사형구조 기능

34) RMSE(Root Mean Square Error): 평균 제곱근 오차

35) SST(Sum of Square Total): SSE+SSR

36) SSR(Sum of Square Residual): 잔차의 제곱의 합

예측한 값과 실제 환경 값의 차이를 다루는 값이다. 결정계수 식 (26)을 계산하는데 필요한 식 (27),(28),(29)의 y 는 관측값, $\hat{y}$ 는 예측값, $\bar{y}$ 는 평균 값이다. 식 (30)의 θ 는 근사 모델의 예측값이고 $\hat{\theta}$ 는 RSMD 방정식의 실제 값이다. PIAAnO는 근사 모델을 구성하고 평가하는 데 사용되었다.

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (26)$$

$$SST = \sum_{i=1}^n (y_i - \hat{y}_i + \hat{y}_i - \bar{y})^2 \quad (27)$$


$$SSE = \sum (y_i - \hat{y}_i)^2 \quad (28)$$

$$SSR = \sum (\hat{y}_i - \bar{y})^2 \quad (29)$$


$$RMSE(\hat{\theta}) = \sqrt{MSE(\hat{\theta})} = \sqrt{E\{(\hat{\theta} - \theta)^2\}} \quad (30)$$

본 연구에서는 [그림 4-18]과 같이 초깃값으로 은닉층 1개와 [그림 4-19]와 같이 최적화된 값으로 5개를 비교하였다. 5개의 은닉층 및 여러 개의 뉴런은 자동으로 손실함수 값이 작게 되도록 매개변수를 반복적으로 수정하여 선정하는 옵션을 활용했다. 머신러닝을 통해 얻은 MLP 모델의 은닉층에 따른 결정계수를 계산한 결과이다. 결정계수는 1에 가까울수록, RMSD는 0에 가까울수록 근사화가 잘 되었다고 판단할 수 있다. 결정계수 비교 결과 [그림 4-20]과 같이 충전 시간(Fill Time), 보압 절환 시 압력(V/P), 형체력(Clamp Force) 결과는 큰 차이가 없었지만, 중량(Weight) 및 변형(Sum X) 예측에서 1 은닉층의 성능이 떨어짐을 확인할 수 있다. 또한 RSMD의 경우 [그림 4-21], [그림 4-22]와 같이 보압 절환 시 압력, 형체력, 중량 값이 높게 나타나 은닉층이 낮을 때 예측 성능이 떨어짐을 확인할 수 있다(황순환 외 2021).


37) SSE(Sum of Square Error): 회귀식 추정치의 편차제곱의 합




[그림 4-18] 1 은닉층(Hidden layers), 8 뉴런을 적용한 MLP 모델 구조




[그림 4-19] 5 은닉층(Hidden layers), 3 ~ 13 뉴런을 MLP 모델 구조



[그림 4-20] 은닉층(Hidden layers)에 따른 MLP 모델 결정계수 비교




[그림 4-21] 은닉층(Hidden layers)에 따른 MLP 모델 RSM D
비교(Training)




[그림 4-22] 은닉층(Hidden layers)에 따른 MLP 모델 RSMD 비교(Test)

[그림 4-23] ~ [그림 4-25]는 PR 모델과 EDT 모델에 대해 얻은 결정계수 및 RSMD에 대한 결과를 나타낸다. MLP의 은닉층이 부족한 경우와 같이 형체력과 사출압의 RSMD 값이 높았다. [그림 4-26] ~ [그림 4-28]은 회귀 RBF(reg)와 보간 RBF(Int)의 결정계수 및 RSMD에 대한 결과를 나타낸다. 형체력과 무게에서 RSMD 값이 높았다.


종합적인 평가에서 라디에이터 탱크 제품의 사출 성형 CAE 예측 모델 비교 결과 최적화된 MLP 모델은 다른 머신러닝 모델보다 우수한 예측 성능을 보였다. 본 모델을 이용하여 최적화 알고리즘을 이용하여 구속조건을 만족하는 최적의 사출 성형 조건을 탐색하고자 한다.




[그림 4-23] PR(FQ), EDT 모델의 결정계수 비교




[그림 4-24] PR(FQ), EDT 모델의 RSMD 비교(Training)




[그림 4-25] PR(FQ), EDT 모델의 RSMD 비교(Test)



[그림 4-26] RBF(Int), RBF(Reg) 모델의 결정계수 비교



[그림 4-27] RBF(Int), RBF(Reg) 모델의 RSMD 비교(Training)




[그림 4-28] RBF(Int), RBF(Reg) 모델의 RSMD 비교(Test)

9) HMA(Hybrid Metaheuristic Algorithm)를 이용한 최적화

HMA는 서로 다른 두 개의 메타휴리스틱 알고리즘을 Bi-population Concept(이중 인구 개념)를 이용하여 결합하는 것이며, 여기서 사용된 두 개의 메타휴리스틱 알고리즘들은 Differential Evolution(미분 진화)과 Cuckoo Search(빠꾸기 검색)이다. HMA가 시작되면 초기 개체를 SOBOLE(소볼) 순서로 생성하고 적합도를 평가하며, 적합도가 상대적으로 우수한 상위 개체들과 나머지 하위 개체들로 분리하고, 상위 개체군은 Differential Evolution(미분 진화)로 자손을 생성하고 하위 개체군은 Cuckoo Search(빠꾸기 검색)로 자손 개체들을 생성한다. 그리고 새로 생성된 각각의 개체군들을 하나의 개체군으로 통합하고 각 개체의 적합도를 평가한다(Zachariadis, E. E., 2009). [표 4-5]는 HMA 최적화를 적용한 결과 요약으로 MLP를 통해 얻은 예측 모델을 사용하였으며 총 8350 Case로 전역 최적화하는데 1분 8초가 소요되었다. [그림 4-28]은 8350 Case에 대한 결과이다(황순환 외 2021).

[표 4-5] HMA 최적화 결과 요약

General description	
Task name	ac_DO
Starting time	20:43:53
Finishing time	20:45:02
Elapsed time	0:0:1:8
Completions status	Success
Console logs	logs.txt
Problem description	
Task	Design optimization
Method	HMA
Number of design variables	5
Number of objectives	1
Number of constraints	2
Number of iterations	39
Number of function calls	8,350




[그림 4-29] HMA 최적화 결과

[표 4-6] 기존 CAE 결과와 HMA 최적화 비교

Classification	Case study	Case 44	Case 33	Case 24	HMA
Variable	Injection_time	2	1	1	1.022
	Packing_pressure	20	80	50	72.48
	Packing_time	10	15	10	10.63
	Melt_temp.	270	290	310	310
	Mold_temp.	100	80	100	60
CAE	Fill_time	2.168	1.038	1.037	1.036
	Pressure at VP	85.78	81.33	61.82	65.37
	Clamp force	104.1	297.4	184.6	270
	Weight	472.1	483.3	479.1	484.2
	Sum_X	5.207	3.686	4.253	3.68
	Sum_Y	4.076	3.099	3.573	3.19
	Sum_Z	2.218	1.5351	1.8016	1.61
Mold	Before	466.88	466.88	466.88	466.88
	After	462.8	463.78	463.31	463.69
	Shrink rate	1.0088	1.0067	1.0077	1.0069

[표 4-6]와 같이 가장 X 방향의 힘이 작은 Case33은 구속 조건을 만족할 수 없었기 때문에 Case24가 구속 조건을 만족하는 가장 힘이 작은 결과는 약 4.25mm이었다. 그러나 HMA를 이용한 최적화를 통해 구속 조건을 만족하면서 힘이 가장 작은 Case를 [그림 4-30]과 같이 힘 양은 MLP 근사모델 결과는 3.68mm로 약 0.57mm 감소하였다. 최종 결과를 다시 실제 시뮬레이션에 적용하여 검토한 결과 성형 압력 예측은 0.17MPa 차이로 99.70% 유사했으며, 형체력은 0.6ton 차이로 99.78% 유사했고, X 방향의 힘은 0.18mm의 차이로 94.72% 유사했다(황순환 외 2021).



[그림 4-30] MLP와 HMA를 이용한 사출 성형 CAE 최적화 결과

10) 실험결과 및 고찰

본 연구에서는 역설계를 고려한 금형 설계를 위해 자동차 부품 중 라디에이터 탱크 제품에 대하여 사출 성형 CAE 및 머신러닝을 진행하였으며 다음과 같은 결론을 얻을 수 있었다.

- ❖ 사출 성형 CAE를 통한 힘 예측은 공정 설정에 따라 약 41% 인 1.52mm가 달라졌다. 힘 결과는 제품이 금형에서 취출되고 상온까지 떨어지면서 진행되기 때문에 사출 작업자가 바로 확인할 수 없다. 즉, 사출 조건 결정 시 CAE 분석을 통한 충분한 사전 검토를 진행해야 함을 확인하였다.
- ❖ 머신러닝을 통해 라디에이터 탱크를 위한 예측 모델을 생성하였으며, 얻어진 예측 모델에 대하여 결정계수(R-squared)와 평균 제곱근 오차(Root Mean Square Error: RMSE)를 통해 EDT, PR, RBF와 같은 근사 모델과 비교한 결과 MLP를 통한 머신러닝이 라디에이터 탱크 제품의 전반적인 공정 예측 및 힘을 예측하는데 효과적인 것을 확인하였다.
- ❖ 구속 조건인 형체력 270ton 이하, 사출 압력 80MPa 이하를 달성하면서, 힘 변형이 가장 낮은 Case는 X 방향의 힘이 약 4.25mm 발생하였으며 이때 이 공정을 통해 발생한 사출 물의 수축률은 Y 방향으로 7.7/1000 이다.
- ❖ HMA를 이용한 최적화를 MLP를 통해 얻은 예측 모델을 사용하였으며 총 8350 Case로 최적화하는데 1분 8초가 소요되었고 최적 결과는 3.68mm로 약 0.57mm 감소하였다.
- ❖ HMA를 통해 최적화된 결과를 실제 시뮬레이션에 적용하여 비교한 결과 사출 압력 예측은 0.17MPa 차이로 99.70% 유사했으며, 형체력은 0.6ton 차이로 99.78% 유사했고, X 방향의 힘은 0.175mm의 차이로 94.72% 유사했다.

제 2 절 CAE 및 Decision-tree 기법을 이용한 설명 가능한 사출 공정 최적화 연구

1) Decision-tree 기법의 필요성

머신러닝 기법을 활용한 사출 공정 변화에 따른 힘 변형 결과 데이터를 비교하기 위해, CAE 데이터를 생성하여 MLP 예측모델을 만들었고, HMA 기반 최적화 공정 결과를 얻은 결과(Hwang, S., et al., 2019) MLP 모델의 예측 성능은 우수했지만 블랙박스과 같이 변수의 결정 과정에 대한 설명이 부족했다. 즉 생성된 결과의 예측에 대하여, 이러한 결과가 좋은지를 설명하는 것, 즉 변수의 영향력과 우선순위를 분석할 수 있는 구조를 갖지 못해, 신뢰성 문제를 검증할 때 내부 결정 과정을 이용자에게 이해시키기 어렵다.

최근 사출 성형 제조 공정에서 복잡한 불량률의 요인에 대하여 머신러닝 기법으로 학습하여 잘못된 조건과 관련된 패턴에 관한 연구가 이루어지고 있다(Kozjek, D., et al., 2019). 사출 성형 공정을 통해 얻은 제품은 완제품이기 때문에 고품질이어야 하며, 수지의 온도나 성형 압력에 따라 품질이 달라진다(Ke, K. C., et al., 2020). 데이터에 기반을 둔 품질 관리 기술은 스마트팩토리 구현을 위해 적극적으로 개발하고 있으며, 제조 공정의 품질 예측 분석으로 제조 환경에 긍정적인 영향을 주고 있다. 사출 공정 조건의 변화에 따른 양품과 불량품으로 분류하는 방법에 관한 연구 중 Decision-tree는 설명 가능한 머신러닝 기법으로 널리 사용되고 있다(Kim, A., et al., 2018). 사출 성형 불량률은 복잡한 상관관계로 인해 최종 제품 품질에 영향을 미치는 변수를 의사 결정 나무와 인공 신경망(ANN), 딥러닝(MLP) 기법으로 학습하고 품질을 비교한 연구도 진행되었다(Ogorodnyk, O., et al., 2018). 위의 연구는 현장의 데이터를 기반을 두고 있어 데이터를 확보하기 위한 센서구입과 실험 금형과 같은 장비의 제작비용과 시간이 발생하며 데이터 분석을 위한 코딩 및 통계 전문 인력이

필요하다. 본 연구는 CAE 기반 데이터 확보 및 인공지능 플랫폼 소프트웨어를 활용한 분석으로 저비용, 쉽고, 빠른 CAT 방법론을 제시하고자 한다. 자동차 라디에이터 탱크 제품의 사출 공정 변화에 대하여 머신러닝 기법의 하나인 Decision-tree를 활용하여 형체력과 사출 압력과 같은 구속 조건을 만족하는 힙 개선 공정을 제안하면서 설명 가능한 예측 모델을 작성하고자 한다.

2) 연구 방법

일반적인 박스 형태의 제품에서 게이트가 제품의 중심에 위치하면, 용융 수지가 제품에 사출될 때 방사 형태로 충전되다가 가장 가까운 벽면에 부딪치면서 유동 방향이 바뀌어 유리 섬유의 배향이 달라지면서 배향이 강한 부분은 수축이 낮아지고, 배향이 약한 부분은 수축이 높아지면서 수축 편차로 휨이 발생한다. 정해진 작업 시간에 모든 영역의 사출 조건을 검토하는 것은 불가능하기 때문에 직교 배열(Orthogonal Array)에 따른 L108의 실험 점을 생성하여 학습하였고, 테스트를 위해 L18에서 L108과 겹치는 3점을 제외하고 15회 실험을 선정하여 테스트하였다. 이번 연구에서는 학습데이터와 테스트데이터를 80:20 비율로 학습 세트와 평가 세트로 배분하였다(Google developers, 2021). 수치해석은 Autodesk사의 Moldflow Insight를 이용하였으며, 3D 메시로 10개 레이어로 작성하여 총 1,187,104개를 사용하였다. 또한 제품의 중심에 사출 주입 점을 설정하였다. 미성형이 발생하지 않는 조건을 위하여 사출 시간은 1초에서 3초를 선정하였으며, 보압 시간과 크기는 제품 외곽 사이즈가 가능한 범위로 결정하였다. 또한 수지의 온도와 금형 온도는 수지 회사에서 추천하는 범위를 사용하였다.

근사모델을 평가하는 도구로 기존 연구와 동일한 방법인 RMSE(Root Mean Square Error)를 사용하였다(Google developers, 2021). 식 (31)과 같이 θ 값은 시뮬레이션에서 얻은 값이며, θ' 는 근사모델의 예측값이다. 예를 들어 시뮬레이션 상으로 예측한 힙 양은 4mm인데, 근사 모델인


Decision-tree에서 예측한 값이 3.9mm라면 RMSE는 0.1mm이다. 시뮬레이션 값과 근사모델의 차이를 양수로 만들어 수치화한 것이다. 즉 0에 가까울수록 신뢰성이 높은 모델이다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\Theta_i' - \Theta_i)^2} \quad (31)$$

3) Decision-tree 모델 생성

머신러닝 모델을 직접 코딩하지 않고 상용 소프트웨어 RapidMiner社의 RapidMiner Studio 제품을 활용하였다. [그림 4-31]은 RapidMiner에서 Decision-tree의 모델을 생성하고 평가하기 위한 프로세스를 구성하는 방법을 나타내고 있다. “Read CSV(CSV 읽기)”는 Autodesk Moldflow Insight를 이용하여 확보한 CAE 결과를 CSV 파일 형식으로 입력한다. “Set Role(역할 설정)”은 힘 예측 결과인 Sum X를 학습용 목표로 지정한다. 그리고 “Split Data(데이터 분할)”를 통해 학습용 데이터를 80%로 선정하고 테스트용 데이터를 20%로 나누었다. Decision-tree 분류를 위해 노드는 목פות값의 예측에 대한 의사 결정을 하기 위한 모음이다. 나무의 크기를 결정하는 변수로 “Maximal Depth³⁸⁾”를 이용하여 기대하는 의사결정 나무를 생성하고자 한다. 분리할 속성 선택 기준으로 최소 제곱을 지정하여 RMSE를 최소화하는 노드로 분할 학습한다. “Apply Mode(모델 적용)”은 Decision-tree를 적용하여 학습 모델로 나눈 Data의 테스트 데이터를 통하여 평가한다. “mod(모드)”포트는 Decision-tree 모델과 연결, “unl”는 “Split Data(데이터 분할)”에서 테스트로 분리한 데이터로 연결하였다. 그리고 “Performance(성능)”를 통해 통계 성능 평가를 진행하였다.


38)Maximal Depth(최대 깊이): RapidMiner Studio 의 Decision-tree 모델의 나무 크기를 결정하는 변수로 값의 변화에 따라 예측 성능 및 설명력이 달라짐.




[그림 4-31] Decision-tree의 프로세스

4) 머신러닝 학습모델 생성 및 비교

Decision-tree 기법 평가를 위해 [그림 4-32]와 같이 힘 예측 성능에 대하여 다양한 머신러닝 기법과 비교 하였다. 평가에 대한 방법은 식 (5)와 같이 RMSE를 계산하였다. Decision-tree의 RSME 값은 0.094mm로 예측값이 평균 대비 2.09%의 변동성으로 0.1mm 이내의 양호한 예측 성능을 나타내고 있다.




[그림 4-32] 힘 변형에 대한 예측 성능 알고리즘 비교



[그림 4-33] V/P 사출 압력에 대한 머신러닝 알고리즘 비교

사출 성형 압력에 대한 예측 성능의 평가 결과 Decision-tree 모델이 가장 예측 성능이 좋았다. RMSE 값은 1.24MPa로 V/P 사출 압력의 평균이 67.8MPa일 때 예측값은 평균보다 1.83%의 변동성이 나타나 양호한 예측 성능을 나타내고 있다.



[그림 4-34] 필요 형체력에 대한 머신러닝 알고리즘 비교


요구되는 형체력 예측 결과 Decision-tree 모델이 가장 예측 성능이 좋았다. 전체적으로 모델에 따른 예측 성능 편차가 발생하는 것을 확인하였다. Decision-tree 모델의 RMSE값은 3.26ton으로 필요 형체력의 평균

이 179ton일 때 예측값은 평균 대비 1.82%의 변동성으로 양호한 신뢰 수준을 나타냈다.

결과적으로 Decision-tree 모델의 예측 성능은 힘 변형, V/P 성형 압력, 필요 형체력 예측에서 다른 머신러닝 기법보다 우수한 예측 성능을 갖추고 있었다.


5) Decision-tree 모델을 이용한 최적 사출 조건

Decision-tree는 [그림 4-35] ~ [그림 4-36]과 같이 나무의 크기를 결정하는 Maximal Depth 값에 따라 예측 성능 및 설명력이 변화한다. [그림 4-35]와 같이 Maximal Depth를 3으로 설정한 Case는 힘 최소화 조건으로 보압 크기 PP(Packing Pressure)를 65MPa 초과로 설정하고, 사출 시간 IT(Injection Time)을 1.5sec 이하로 설정해야 했다.




[그림 4-35] Sum X 변형의 Decision-tree(Maximal Depth 3)

그러나 [그림 4-36]과 같이 Maximal Depth를 4로 변경할 경우 힘 최소화 조건은 PP를 65MPa 초과, IT을 1.5sec 이하 조건은 이전과 같지만 보압 시간 PT(Packing Time)를 7.5sec 이상으로 설정할 때 변형량을 더 줄일 수 있음을 확인하였다. Maximal Depth 증가가 분류에 대한 기준을 높일 수 있지만 복잡성도 증가하였다.




[그림 4-36] Sum X의 Decision-tree(Maximal Depth 4)

[그림 4-37], [그림 4-38]과 같이 필요한 형체력의 Decision-tree 결과에서 65MPa 초과 시 구속 조건 값 270ton을 넘어선다. 힘 최소화 조건과 구속조건인 필요 형체력 조건이 상충하여, Maximal Depth를 추가로 변경해 보았지만 개선되지 않았다.




[그림 4-37] 형체력의 Decision-tree(Maximal Depth 3)




[그림 4-38] 형체력의 Decision-tree(Maximal Depth 4)

목적함수와 구속조건의 상충한 문제가 추가 데이터를 학습시켰을 때 해결되는지를 확인하기 위해 추가 시뮬레이션을 진행하여 학습 데이터에 추가하였다. 이전의 보압 크기는 20, 50, 80MPa을 진행하였으나 상충 영역 60, 70MPa 조건을 추가로 CAE를 통해 실험을 진행하였고, 수지의 온도는 기존의 270, 290, 310℃에서 추가로 300, 290℃로 추가하였다. 또한 금형의 온도는 80℃로 한정, 보압 시간은 이전의 5, 10, 15sec에서 12.5, 7.5sec를 추가 적용하였다. [그림 4-39]와 같이 Maximal Depth를 3으로 적용했을 때 보압 조건을 75MPa 초과 시 구속조건에서 벗어나 75MPa 이하로 적용해야 함을 확인하였다. [그림 4-40]과 같이 Maximal Depth를 4로 적용하면 형체력을 65MPa 초과, 75MPa 이하로 적용해야 구속 조건 범위에 들어올 수 있었다.


추가 CAE 실험을 통해 얻은 힘 최소화 예측 분석 결과 [그림 4-41]과 같이 Maximal Depth 3일 때, 기존의 65MPa 기준에서 75MPa로 이동하였고 Maximal Depth 4를 적용할 경우 [그림 4-42]와 같이 PP 75MPa 초과, IT 1.5sec 이하, MeT 300℃ 이하일 때 힘 변형 결과가 최소화되었다.




[그림 4-39] 형체력의 수정된 Decision-tree(Maximal Depth 3)



[그림 4-40] 형체력의 수정된 Decision-tree(Maximal Depth 4)




[그림 4-41] 휨 변형의 수정된 Decision-tree(Maximal Depth 3)




[그림 4-42] 휨 변형의 수정된 Decision-tree(Maximal Depth 4)

구속 조건 V/P 사출 압력은 80MPa 이하가 적용되기 위해서 [그림 4-43]와 같이 Maximal Depth 3일 경우 용융 수지 온도 MeT가 280℃ 초과일 때로 예측되었으며 [그림 4-44]와 같이 Maximal Depth 4일 경우에도 MeT가 280℃ 초과로 예측되었다. Decision-tree 기반 구속조건을 만족하는 휨 변형을 최소화할 위해 추천 범위인 PP 72.5MPa, IT 1.25sec, MeT 290℃를 적용하여 CAE를 진행하였다.



[그림 4-43] 사출 압력의 수정된 Decision-tree(Maximal Depth 3)



[그림 4-44] 사출 압력의 수정된 Decision-tree(Maximal Depth 4)

[표 4-6]과 같이 CAE를 단독적으로 진행했을 때 CAE 결과 중 가장 큰 휨 변형으로 예측된 Case는 44번으로 5.207mm, 최소 휨 변형 예측 결과는 33번으로 3.686mm지만 구속조건에서 벗어났다. 이후 구속 조건을 만족하면서 최소의 휨 변형 Case는 24번으로 4.253mm이다. Decision-tree 기법을 적용한 공정조건 최적화로 CAE를 진행한 결과, 구속 조건을 만족하면서 휨 변형량이 3.924mm로 예측되어 Case 24 대비 7.7%가 개선되었다.

[표 4-7] Decision-tree를 이용한 최적의 사출 조건 비교

	Case study	CAE of Case 44	CAE of Case 33	CAE of Case 24	CAE of DT
Variable	IT(sec)	2	1	1	1.25
	PP(MPa)	20	80	50	72.5
	PT(sec)	10	15	10	8.75
	MeT(°C)	270	290	310	290
	MoT(°C)	100	80	100	80
Result	FT(sec)	2.168	1.038	1.037	1.296
	V/P(MPa)	85.78	81.33	61.82	75.36
	CF(ton)	104.1	297.4	184.6	267
	SumX(mm)	5.207	3.686	4.253	3.924

6) 실험결과 및 고찰

본 연구에서는 지속 가능한 사출 성형 제조 산업을 위해 CAE와 머신러닝을 이용하는 방법론을 제시하였다. CAE를 이용한 수치 해석 기법으로 실험 데이터를 생성하고, 머신러닝을 활용하여 학습 모델을 생성하고 예측 모델별로 평균 제공근 오차를 비교하여, 설명 가능한 머신러닝으로 알려진 Decision-tree를 활용하여 힙 변형의 최소화를 위한 사출 성형 공정조건을 예측하였으며 아래의 결론을 얻었다.

- ❖ Decision-tree는 RMSE 값이 힙 변형, 성형 압력, 형체력에 대하여 모두 97.5%의 예측 성능을 나타냈으며, 다른 머신러닝의 기법에 비해 양호한 성능을 갖추었다.
- ❖ Decision-tree 크기를 결정하는 Maximal Depth의 변화에 따라 예측 성능 및 설명력의 변화를 확인한 결과 Maximal Depth 증가는 분류 기준을 높일 수 있지만 그에 따른 복잡성도 함께 증가시켰다.
- ❖ 힙 변형 최소화를 위해 보압 크기는 65MPa 이상을 추천하지만, 그때 구속조건인 형체력이 270ton을 넘어 힙 변형 최소화 조건과 구속조건

이 상충하였으며, Maximal Depth를 변경해도 결과의 변화는 없었다.

- ❖ 상충한 문제가 추가 실험 점을 적용했을 때 해결되는지를 평가하기 위해 추가 CAE를 진행한 결과 상충 지점의 위치는 달라졌지만, 상충하는 상황은 그대로 유지되었다.
- ❖ Decision-tree 기반 구속조건을 만족하는 휨 변형을 최소화할 위해 추천 범위인 PP 72.5MPa, IT 1.25sec, MeT 290℃를 적용하여 CAE를 진행한 결과 기존 CAE 최솟값 대비 7.7%의 개선 효과가 있었다.

제 5 장 결 론

빅데이터, 데이터 사이언스, 클라우드 컴퓨팅, 모바일 및 소셜 네트워크, 협업 경쟁력과 같은 기술 트렌드는 더 나은 의사결정 시스템과 최적화된 프로세스를 가능하도록 돕는다. 사출 성형 분야도 시행착오를 최소화하고 혁신적인 제품 개발을 위해 설계와 제조를 융합하는 기술로 CAE는 제조 프로세스에 깊이 안착하였다. CAE는 제조 환경을 가상현실로 설계, 가공, 제작하여 검증할 수 있어 제조 프로세스를 가속할 수 있고 품질을 향상할 수 있다. 이러한 CAE 역할을 수행하기 위해서 필요한 기술은 CAE 예측의 정확성과 머신러닝을 활용한 최적화이다. 본 연구는 실제 사출 성형 공정과 CAE 예측의 편차가 발생하는 원인과 CAE 정확성 향상을 위한 방법에 대하여 연구하였으며, MLP와 Decision-tree를 활용한 사출 공정 최적화 연구를 진행했으며, 아래와 같은 성과를 얻어냈다.

- ❖ 유동 해석을 검증하는 방법론으로 사용되고 있는 스파이럴 금형의 형상 특성으로 인하여 유동 거동에 특수한 상황이 발생하여 스파이럴 폭의 변화는 유동 거리에 13% 영향 도를 나타냈으며, 스파이럴 디자인과 막대 형상은 28%의 차이, 판 디자인과 스파이럴 디자인의 유동 거리 차이는 82% 차이를 확인하였다. 결과적으로 유동 거리 예측에서, 스파이럴 형상은 막대 디자인과 판 디자인을 대표할 수 없음을 확인했다. CAE를 위한 수치 물성 품질이 낮은 경우 유변 물성 중 영점 점도와 압력 의존성계수의 편집은 유동 거리 예측 정확성을 개선할 수 있었다.
- ❖ 플라스틱 재료의 유변 물성 복제, 제품 형상 및 금형 모델링 복제, 사출 성형 조건 복제, 사출기 성능 복제 방법을 제시하였고 에어백 커버 제품을 실제 사출한 결과와 CAE의 사출 압력 예측 결과를 비교하였으며 기존의 오차율이 28.0 ~ 61.3%에서 5% 이내로 개선이 가능함을 확인

하였다.

- ❖ 라디에이터 탱크 제품의 폭넓은 사출 성형 조건을 반영한 최적화를 위해 CAE로부터 데이터를 추출하였고, MLP를 이용하여 예측 모델링을 만들었으며, HMA를 활용하여 MLP를 통해 얻은 예측 모델로 총 8350 Case로 최적화하는데 1분 8초가 소요되었다. 결과적으로 108회 CAE를 진행하여 최적화된 힘 결과는 4.25mm이었으나 MLP와 HMA를 추가로 적용했을 때 3.68mm로 예측되어 CAE만 적용한 결과 대비 0.57mm가 줄어들어 약 13.4% 개선되었다. HMA를 통해 최적화된 결과를 실제 시뮬레이션에 적용하여 비교한 결과 사출 압력 예측은 0.17MPa 차이로 99.70% 유사했으며, 형체력은 0.6ton 차이로 99.78% 유사했고, X 방향의 힘은 0.175mm의 차이로 94.72% 유사했다.
- ❖ MLP는 예측 성능은 우수하지만 결정 과정 설명이 부족하므로 Decision-tree를 이용하여 분류 기준과 복잡성을 비교하였다. Decision-tree는 힘 변형, 성형 압력, 형체력에 대하여 모두 97.5%의 예측 성능을 나타냈으며, 다른 머신러닝의 기법에 비해 양호한 성능을 갖추었다. Decision-tree 기반 구속조건을 만족하는 힘 변형을 최소화를 위해 추천 범위인 PP 72.5MPa, IT 1.25sec, MeT 290°C를 적용하여 CAE를 진행한 결과 기존 CAE 최솟값 대비 7.7%의 개선 효과가 있었다.

본 연구의 성과로 CAE를 사용하는 연구자들에게 소프트웨어의 가정 및 계산 방식의 변천사를 이해하고, CAE를 위한 플라스틱의 유변 물성 측정 범위에 따른 CAE 결과의 신뢰수준 및 구체적인 측정 방법에 대하여 접근할 수 있는 기회가 마련되었다. 또한 사출 성형 CAE의 유동 및 변형 예측 메커니즘은 유체역학, 열전달, 열역학과 미세 역학에 기반을 두며, 변형의 원인으로 냉각 편차, 수축 편차, 배향 편차, 코너 효과임을 알 수 있었다. 사출 성형 CAE 정확성 개선을 위한 주요 인자로, 제품 형상을 복제하기 위한 방법, 사출 속도와 보압과 같은 공정 조건의 복제, 메시 타입 및 조밀도와 종횡비, 금형 형상 복제, 코어 쉬프트를 통해 금형의 힘까지 고려해야

했다. 유동 거리 검증을 위해 사용되는 스파이럴 금형 연구를 통해 스파이럴 폭에 따라 유동 거리가 달라질 뿐만 아니라, 막대 형상과 판 형상 대비 스파이럴 금형은 더 많은 유동 거리가 예측되기 때문에 대표성이 없음을 확인하였다. 결과적으로 유동 거리 검증을 위해서 대표성 있는 형상으로 실험 금형을 제작하는 것을 추천하고 싶다. 그리고 압력의존성계수와 영점 점도를 수정하여 유동 거리 및 사출 압력 CAE 적확성을 개선할 수 있음을 확인하였다. 복합재료의 휨 예측에서 간과하고 있는 사출 공정 조건 설정 검증을 위해, 조건에 따라 휨 변형량의 변화를 조사한 결과 최소 휨 대비 최대 휨이 약 41%가 달라짐을 확인하였다. 이 결과를 통해 사출 성형 조건 최적화의 중요성을 확인하였고, 사출 성형 조건을 결정할 때에도 CAE를 활용해서 사전 검토가 필요함을 확인했다. CAT를 할 때 CAE를 단독적으로 적용하면, CAE 시간이 오래 걸리는 문제를 갖고 있는데 머신러닝은 이러한 문제를 보완할 수 있는 기술이다. MLP와 HMA는 CAE에서 실험하지 못한 영역 중 최적의 결과를 도출하였으며, Decision-tree를 통해 구속 조건과 목적함수의 관계를 이해하고 설명하는 것이 가능했다. CAE를 통한 데이터 확보를 위해 적확성을 개선하고, 머신러닝을 통한 모델 생성 그리고 활용은 상용 소프트웨어로 전용 예측모델을 만들어, 최적화의 장벽인 제한된 시간 뛰어넘을 수 있었다. 이를 통해 경제적 측면에서 품질 향상, 납기 단축, 원가 절감이 가능하며 신속한 의사 결정과 품질 불량으로 인한 위험이 감소되고 기업의 경쟁력이 강화될 수 있을 것으로 사료된다.

CAE를 사용하지 않는 연구자는 본 연구를 통해 플라스틱 유동 및 휨 거동의 특징을 확인할 수 있다. 즉, 사출 성형 조건의 변화에 따른 사출 압력과 휨의 변화 사례를 확인할 수 있다. 또한 머신러닝 사례는 CAE 데이터가 아닌 실험 데이터로도 최적화가 가능하기 때문에 사출 현장의 사출 성형 조건 최적화 방법으로 적용할 수 있다. 향후 다양한 수지와 형상의 CAE 적확성 향상 및 머신러닝을 활용한 예측 모델을 확장한다면 사출 성형 최적화의 완성도가 더욱 높아질 것으로 기대된다.

참 고 문 헌

1. 국내문헌

- 강세호. (2017). *박판형 가스사출제품의 성형정밀도 향상을 위한 연구* (박사학위). 인천대학교 대학원, 인천.
- 김광호. (2009). *플라스틱 사출 성형을 위한 강건설계법의 개발과 적용* (박사학위). 금오공과대학교 대학원, 구미.
- 김경아, & 한성렬. (2020). 수치해석을 이용한 플라스틱 폴리 성형품의 최적 성형에 관한 연구. *한국금형공학회. Vol. 14*(1), 30-35.
- 김옥래. (2010). *박육 성형제품 금형의 사출성능평가에 관한 연구* (박사학위). 인천대학교 대학원, 인천.
- 김주권. (2019). *정형 에어컨 부품의 초미세발포 사출성형 특성 규명* (박사학위). 부경대학교 대학원, 부산.
- 민현규. (2003). *사출 금형*. 한국산업인력공단
- 박시환. (2011). *Study of filling and demolding process in the injection molding through numerical simulation and experimental approaches* (박사학위). 서울대학교 대학원, 서울.
- 사택문, 박창현, 황순환, & 최동훈. (2017). 휨 변형량과 질량 최소화를 위한 평판 사출품의 격자 단위별 두께 최적설계. *대한기계학회 춘추학술대회*, 1844-1847.
- 신장순, 황순환, 김유진, 정귀재, 허영무, & 윤길상. (2006). 기능성 용기 2-level 스택 금형 개발. *한국정밀공학회 학술발표대회 논문집*, 575-576.
- 신장순, 김유진, 정귀재, 황순환, 허영무, 윤길상, 정우철, & 서태일. (2008). 수치해석을 이용한 플라스틱 폴리 성형품의 최적 성형에 관한 연구. *한국금형공학회. Vol. 2*(3), 28-31.

- 유중학, & 김희송. (1995). 폴리프로필렌의 사출성형조건이 성형품의 선형수축률과 중량에 미치는 영향 (The Effects of Injection Molding Conditions of Polypropylene on the Linear Shrinkage and Weight of Molded Parts). *대한기계학회 논문집*, 19(2), 322-329.
- 이규세. (2015). *형동시 압출-사출 성형 기술 (In-Line Compounding)을 이용한 장섬유강화 플라스틱(LFT)의 성형성 및 물성 향상에 관한 연구* (박사학위). 울산대학교 대학원, 울산.
- 이종원, 황순환, 박승화, & 이성희. (2015). 등각냉각채널금형의 코어변형에 대한 연구. *한국생산제조학회 학술발표대회 논문집*, 339-339.
- 이기준, 정광식, & 서문호. (1989). 사출성형 고분자물질의 공동충전현상에 관한 유변학적 해석. *HWAHAK KONGHAK*, 27(4), 579-587.
- 최재혁. (2015). *형상적응형 금형냉각회로 자동최적설계 방법 연구* (박사학위). 아주대학교 대학원, 수원.
- 홍청민. (2020). *사출 제품 품질향상을 위한 사출기와 성형조건에 관한 연구* (박사학위). 한국기술교육대학교 일반대학원, 천안.
- 황순환. (2017). *플라스틱 자동차 부품의 사출 공정 중 발생한 휨 예측과 개선에 관한 연구* (석사학위). 공주대학교, 천안.
- 황순환, 박창현, & 김종선. (2018). 사출 성형 시뮬레이션 실험계획을 이용한 Machine Learning 사례에 관한 연구. *한국생산제조학회 학술발표대회 논문집*, 69-69.
- 황순환, 박승화, 황수진, & 이재훈. (2018). *플라스틱 사출 성형 엔지니어를 위한 Moldflow Basic Course*. 청담북스.
- 황순환, 이후진, & 한성열. (2021). 사출 성형 CAE를 이용한 Spiral 금형의 형상 검증에 관한 연구. *한국기계기술학회. Vol. 23*(2), 204-210.
- 황순환, 한성열, & 이후진. (2021). CAE와 Decision-tree를 이용한 사출 성형 공정개선에 관한 연구. *한국산학기술학회. Vol. 22*(4), 580-586.

2. 국외문헌

- Ammar, A., Leo, V., & Regnier, G. (2001). Corner deformation induced by shrinkage anisotropy of injected thermoplastics: Experimental study and numerical approach. *PPS-17, Montréal*.
- Autodesk® Moldflow Insight Advanced Cool and Warp. (2016).
- Autodesk® Materials Lab. (2019). Material Testing Overview Thermoplastics.
- Bakharev, A., Fan, Z., Han, S., Costa, F., Jin, X., & Kennedy, P. (2004). Prediction of Core Shift effects using mold filling simulation. In *ANTEC-Conference Proceedings*-. (Vol. 1, pp. 621-625).
- Changming, Z. (2010). Research on injection mold design based on reverse engineering. In *2010 2nd International Conference on Computer Engineering and Technology* (Vol. 6, pp. V663-665). IEEE.
- Clavería, I., Javierre, C., & Ponz, L. (2005). Method for generation of rheological model to characterize non-conventional injection molding by means of spiral mold. *Journal of Materials Processing Technology*, 162, 477-483.
- Delaunay, D., Le Bot, P., Fulchiron, R., Luye, J. F., & Regnier, G. (2000). Nature of contact between polymer and mold in injection molding. Part II: Influence of mold deflection on pressure history and shrinkage. *Polymer Engineering & Science*, 40(7), 1692-1700.
- Douven, L. (1991). *Towards the computation of properties of injection*

- moulded products* (Doctoral dissertation, PhD thesis, Eindhoven University of Technology, Eindhoven).
- Fan, Z., Costa, F., Zheng, R., Lin, B., XiaoShi, J., & Kennedy, P. (2004). Three-dimensional warpage simulation for injection molding. In *ANTEC-Conference Proceedings*. (Vol. 1, pp. 491-495).
- Hétu, J. F., Lauzé, Y., & García-Rejón, A. (1994). *Three-dimensional finite element simulation of mold filling processes*. NRCC, Industrial Materials Institute.
- Hieber, C. A., & Shen, S. F. (1980). A finite-element/finite-difference simulation of the injection-molding filling process. *Journal of Non-Newtonian Fluid Mechanics*, 7(1), 1-32.
- Hwang, S., & Kim, J. (2019). Injection mold design of reverse engineering using injection molding analysis and machine learning. *Journal of Mechanical Science and Technology*, 33(8), 3803-3812.
- Kamal, M. R., & Kenig, S. (1972). The injection molding of thermoplastics part II: experimental test of the model. *Polymer Engineering & Science*, 12(4), 302-308.
- Ke, K. C., & Huang, M. S. (2020). Quality Prediction for Injection Molding by Using a MultiLayer Perceptron Neural Network. *Polymers*, 12(8), 1812.
- Kim, A., Oh, K., Jung, J. Y., & Kim, B. (2018). Imbalanced classification of manufacturing quality conditions using cost-sensitive Decision-tree ensembles. *International Journal of Computer Integrated Manufacturing*, 31(8), 701-717.
- Kennedy, P., & Yu, H. (1997). Plastic CAE analysis of solid geometry. In *Technical Papers Of The Annual Technical*

- Conference–Society Of Plastics Engineers Incorporated* (Vol. 1, pp. 666–669). Society Of Plastics Engineers INC.
- Kennedy, P., & Zheng, R. (2013). *Flow analysis of injection molds*. Carl Hanser Verlag GmbH Co KG.
- Kozjek, D., Kralj, D., Butala, P., & Lavrač, N. (2019). Data mining for fault diagnostics: A Case for plastic injection molding. *Procedia CIRP*, 81, 809–814.
- Lafleur, P. G., & Kamal, M. (1986). A structure-oriented computer simulation of the injection molding of viscoelastic crystalline polymers part I: Model with fountain flow, packing, solidification. *Polymer Engineering & Science*, 26(1), 92–102.
- Leo, V., & Cuvelliez, C. H. (1996). The effect of the packing parameters, gate geometry, and mold elasticity on the final dimensions of a molded part. *Polymer Engineering & Science*, 36(15), 1961–1971.
- Liparoti, S., Speranza, V., De Meo, A., De Santis, F., & Pantani, R. (2020). Prediction of the maximum flow length of a thin injection molded part. *Journal of Polymer Engineering*, 1(ahead-of-print).
- Martinez, A., Castany, J., & Mercado, D. (2011). Characterization of viscous response of a polymer during fabric IMD injection process by means a spiral mold. *Measurement*, 44(10), 1806–1818.
- Ogorodnyk, O., Lyngstad, O. V., Larsen, M., Wang, K., & Martinsen, K. (2018). Application of machine learning methods for prediction of parts quality in thermoplastics injection molding. In *International workshop of advanced manufacturing and automation* (pp. 237–244). Springer, Singapore.
- Rajupalem, V., Talwar, K., & Friedl, C. (1997). Three-dimensional

- simulation of the injection molding process. In *Technical Papers Of The Annual Technical Conference–Society Of Plastics Engineers Incorporated* (Vol. 1, pp. 670–673). Society Of Plastics Engineers INC.
- Richardson, S. (1972). Hele Shaw flows with a free boundary produced by the injection of fluid into a narrow channel. *Journal of Fluid Mechanics*, 56(4), 609–618.
- Rosato, D. V., & Rosato, M. G. (2012). *Injection molding handbook*. Springer Science & Business Media.
- Salimi, A., Subaşı, M., Buldu, L., & Karataş, Ç. (2013). Prediction of flow length in injection molding for engineering plastics by fuzzy logic under different processing conditions. *Iranian Polymer Journal*, 22(1), 33–41.
- Sandu, I. L., Susac, F., Stan, F., & Fetecau, C. (2020). Prediction of Polymer Flow Length by Coupling Finite Element Simulation with Artificial Neural Network. *Materiale Plastice*, 57(3), 202–223.
- Santhanam, N., & Wang, K. K. (1990). A theoretical and experimental investigation of warpage in injection molding. *ANTEC 90. Plastics in the Environment: Yesterday, Today & Tomorrow*, 270–273.
- Shoemaker, J. (2006). Moldflow design guide. *Carl Hanser, Munich*.
- Zachariadis, E. E., Tarantilis, C. D., & Kiranoudis, C. T. (2009). A hybrid metaheuristic algorithm for the vehicle routing problem with simultaneous delivery and pick-up service. *Expert Systems with applications*, 36(2), 1070–1081.
- Zhou, H. (2013). Computer modeling for injection molding. *Part II: Simulation, Mathematical Models for the Filling and Packing Simulation*, 49–254.

Autodesk Moldflow Help about material databases [Website]. (2021, June 1). Retrieved from <https://knowledge.autodesk.com/support/moldflow-insight/learn-explore/caas/CloudHelp/cloudhelp/2019/ENU/MoldflowInsight-Materials/files/GUID-9C852155-1ECC-4A68-A45D-F3FC5E79E057-htm.html>

Autodesk Moldflow Help Cross-WLF viscosity mode [Website]. (2021, June 1). Retrieved from <https://knowledge.autodesk.com/support/moldflow-insight/learn-explore/caas/CloudHelp/cloudhelp/2017/ENU/MoldflowInsight/files/GUID-7BC3A8F0-8B41-4FCB-BDF1-F1159E4DD175-htm.html>

Autodesk Moldflow Help Theoretical basis for fiber orientation prediction [Website]. (2021, June 1). Retrieved from <https://help.autodesk.com/view/MFIA/2019/ENU/?guid=GUID-50FF496F-0E3E-43CE-B30B-4B12CC24F7DE>

Beaumont Advanced Processing What is Therma-flo?™ [Website]. (2021, June 1). Retrieved from <https://www.bapmolding.com/therma-flo/>

Google developers Training and Test Sets: Splitting Data [Website]. (2021, June 1). Retrieved from <https://developers.google.com/machine-learning/crash-course/training-and-test-sets/splitting-data>

Moldmakingtechnology Ever Wonder How Injection Molding Simulation Began [Website]. (2021, June 1). Retrieved from <https://www.moldmakingtechnology.com/articles/ever-wonder-how-injection-molding-simulation-began>

ABSTRACT

A Study on the Optimization of Injection Molding Using CAE and Machine Learning Technique

Hwang, Soon-Hwan

Major in Smart Convergence Product

Dept. of Smart Convergence

Consulting

The Graduate School

Hansung University

A typical manufacturing process is idea – concept – design – manufacture – sell. Companies can complete the process faster, and the higher the quality, the more profits can be made. Therefore, companies are investing time and money to develop processes to improve delivery and quality. Today, technology trends such as big data, data science, cloud computing, mobile technology, social networks, and collaboration competitiveness are demanding better decision-making systems and optimized processes. The concept should be considered for personal taste. Design must work together to create fast, precise and innovative products. Manufacturing should consider both flexible production and mass production, such as 3D printers. As for sales, the influence of social networks is acting as an important variable. When a company's product

has a catastrophic quality problem, it is subject to short-term effects such as the time and cost of product recall. There are also long-term effects such as a decline in brand value, a decrease in market share, and a decline in stock prices. Computer Aided Engineering (CAE) is used as a method to solve the quality problem. It is a technology that combines design and manufacturing as a method to verify design before manufacturing. Design considering manufacturing can prevent trial and error occurring in the manufacturing site. So, the manufacturing verified in the simulation can be manufactured with high quality and short delivery time.

The injection molding process is used in a variety of fields because it can implement complex structural shapes and various functions, and can handle beautiful appearances and even mass-produce at the same time. The process of implementing innovative products is complex and requires precision. In addition, when carbon fiber or glass fiber is used as an additive material to the plastic material to increase strength, dimensional defects occur due to bending deformation such as warping. At this time, it is very difficult to mold because the section available for injection molding is narrow and there are many variables. CAE's goal is to predict and improve the cause of these defects before manufacturing.

In the past, CAE had limitations due to the Solver's assumptions that simulated the manufacturing environment. In addition, physical property data and measurement technology were lacking. The low computing power had to set the mesh number and case of the simulation to be low. As a result, it has been focused on predicting trends in a limited environment. At this time, the goal of CAE was to obtain maximum effect with minimal experimentation. As of 2021, the solver has been upgraded for over 40 years. And it has secured

plastic rheological property measurement technology considering various situations. Every year, many companies measure rheological properties. The rapidly growing computing power has enabled a large number of meshes, and statistical access through many case studies has become possible. In other words, the underlying technology that can secure accuracy has been developed.

This study suggests the cause of the difference between CAE and actual injection molding results. It describes how to apply to simulation as a method to improve CAE accuracy. In addition, the effect of the shape characteristics of the spiral mold on the flow behavior was investigated. The change in the width of the spiral and the flow distance of the bar shape and plate shape were compared. In addition, a method for evaluating and improving the rheological properties of the resin was suggested. A method of improving CAE prediction accuracy using these methods was described. Data was extracted to CAE to optimize injection molding conditions for Radiator Tank products using composite materials (PA66+GF30%). And predictive modeling was made using Multi-layer Perceptron (MLP) known as ANN (Artificial Neural Networks). In addition, using HMA (Hybrid Metaheuristic Algorithm), the optimal injection molding conditions were derived to minimize warpage that satisfies MLP-based injection pressure and clamping force constraints. MLP has excellent predictive performance, but lacks explanation of the decision process. So, the decision-tree was used to evaluate the classification criteria for the optimal injection condition and the predictive performance according to the change in complexity.

As a result of this study, it was suggested that injection molding CAE accuracy verification methods include verification according to the analysis result, verification according to the analysis procedure,

and verification methods according to the analysis stage. As a result of examining the specificity of the spiral shape used as the injection molding flow distance verification model, it was confirmed that the spiral flows 28% better than the bar and 82% better than the plate. It was confirmed that the injection pressure prediction error rate could be improved to within 5% by editing the resin properties for CAE and improving the input of process conditions. We tried to optimize the injection process conditions to minimize bending deformation while satisfying the constraints (injection pressure, clamping force) that do not cause flash failure of the Radiator Tank product. As a result, the optimal warpage result by performing CAE 108 times was 4.25mm, but when additional MLP and HMA were applied, it decreased to 3.68mm. Compared to the result of applying only CAE, it was reduced by 0.57mm, improving by about 13.4%. As a result of evaluating reliability by applying this to CAE again, injection pressure was similar in 99.7%, clamping force was 99.78%, and bending deformation was 94.72%.

【Key word】 Computer Aided Engineering, Injection Molding, Flow Analysis, Verification, Artificial Neural Networks, Decision-tree