

스칼라 기반 인공신경망 대리모델과 유전알고리즘을 이용한 Hat 단면 성형의 변형 예측 및 금형 최적화

Prediction of Deformed Shape and Die Optimization for Hat-section Forming Using a Scalar-based ANN Surrogate and Genetic Algorithm

노현도¹, 문승현¹, 배유빈¹, 정완진¹, 이창환^{1, #}Hyun-Do Noh¹, Seung-Hyeon Mun¹, Yubynn Bae¹, Wan-Jin Chung¹, and Chang Whan Lee^{1, #}¹ 서울과학기술대학교 기계시스템디자인공학과 (Department of Mechanical Design and Manufacturing Engineering, Seoul National University of Science and Technology)# Corresponding Author / E-mail: cwlee@seoultech.ac.kr, TEL: +82-2-970-6371

ORCID: 0000-0002-7848-280X

KEYWORDS: Hat-profile (Hat 형상), Optimization (최적화), Artificial neural network (인공신경망), Genetic algorithm (유전알고리즘), MLP (다층 퍼셉트론), Springback (스프링백)

The formation of a hat-profile is significantly influenced by springback and the final cross-sectional geometry, both of which are sensitive to die profile design. This study introduces a scalar-based artificial neural network (ANN) surrogate model combined with genetic-algorithm (GA) optimization to enhance die and process design efficiency. An automated ABAQUS finite-element workflow was established to generate 900 design cases. For each case, seven scalar geometric and angle responses characterizing the post-forming cross section were extracted and used to train a multilayer perceptron. This network maps four die design variables to the final geometry. The surrogate model demonstrated high predictive accuracy, with geometric and angular errors remaining small and coefficients of determination (R^2) nearing 1.0. This enabled quick evaluation of new designs without the need for additional finite-element analyses. By integrating the ANN surrogate within a GA, optimal die geometries were identified that reduce springback while meeting target dimensions, showcasing the proposed framework as an effective AI-driven design tool for sheet-metal forming.

Manuscript received: January 5, 2026 / Revised: January 31, 2026 / Accepted: February 3, 2026

1. 서론

Hat 형상은 자동차 차체 보강재, 충돌 에너지 흡수 부품 등에 널리 사용되는 대표적인 구조 형상으로 경량화와 충돌 안전성을 동시에 확보하기 위해 매우 중요하게 다루어진다[1]. 이러한 Hat 형상 부품의 성형 공정에서는 국부 변형, 주름, 균열과 같은 성형 결함을 억제하는 동시에 성형 후 발생하는 스프링백을 최소화하여 목표 형상에 가깝게 복원되도록 설계하는 것이 핵심 이슈이다. Hat 단면의 플랜지 폭, 웹 높이, 곡률 반경과 같은 단면 형상 인자와 공정 조건은 최종 성형성 및 스프링백 거동에 직접적인 영향을 미치므로 이를 정량적으로 예측하고 최적화하는 기술이 필수적이다[2].

기존 Hat 형상 성형 공정의 유한요소해석 기반 설계는 비선형적 특성으로 인한 과도한 해석 시간과 비용 문제로 인해 설계 공간의 충분한 탐색과 효율적인 최적 설계 수행에 어려움이 존재한다. 특히 복잡한 변수 조합을 최적화하기에는 계산적 부하가 매우 크기 때문에, 이를 대체할 인공지능(AI) 기반 대리 모델(Surrogate Model) 연구가 성형 공정 분야에서 주목받고 있다.

Jung et al. [3]은 관통자 형상을 설계 변수로 설정하고 유한요소해석으로 생성한 관통 깊이 데이터를 이용해 인공신경망(Artificial Neural Network, ANN)을 학습한 뒤 이를 유전알고리즘(Genetic Algorithm, GA)의 적합도 함수로 사용하여 최적 관통자 형상을 도출하였다. Trzepieciński and Lemu [4]는 V-다이 에어벤딩 공정에서 DC04 강판의 스프링백 계수를 예측하기

위해 인장시험으로 얻은 재료 물성치를 입력으로 V-다이 에어 벤딩 실험에서 측정한 스프링백 계수를 출력으로 하는 다층 퍼셉트론 기반 인공 신경망을 구축하고 유전알고리즘을 이용해 스프링백 예측 정확도를 향상시켰다.

본 연구에서는 Hat 형상 단면의 성형 거동을 대상으로 상용 유한요소 해석 프로그램(ABAQUS)을 사용하여 성형 해석의 전 과정을 자동화하고 이를 바탕으로 스칼라 기반 성형 해석 대리 모델을 구축하였다. 파이썬 스크립트를 이용하여 사용자가 설정한 Hat 단면 설계 변수 범위 내에서 900개 조합의 금형 형상을 샘플링하고 각 조합에 대한 공정 좌표표를 자동 생성하여 FEM 해석을 수행하였다. 900개의 다이 형상 스칼라 데이터와 성형 해석 후 소재의 변형 형상 스칼라 데이터를 CSV 형태로 변환하여 출력 데이터셋을 구성함으로써 Hat 형상 성형 공정에 특화된 스칼라 기반 학습 데이터를 확보하였다. 구축된 데이터셋을 이용하여 다층 퍼셉트론(Multi-layer Perceptron, MLP) 기반 스칼라 대리 모델을 학습함으로써 Hat 형상 설계 변수에 따른 성형 후 소재의 변형 형상을 예측할 수 있는 모델을 구축하며 유전알고리즘을 이용하여 기존의 유한요소해석을 대체할 수 있는 Hat 형상 성형 공정의 설계 및 최적화를 수행할 수 있음을 보이고자 한다.

2. Hat 형상 성형 공정 및 해석 모델

2.1 형상 특징

본 연구의 대상 부품은 Fig. 1(a)와 같은 Hat 형상 단면을 갖는 제품으로, 자동차 차체 보강 및 충돌 에너지 흡수 등의 기계 부품으로 사용된다. 제한된 두께에서 목표 강성을 확보해야 하는 요구가 커지면서 Hat 단면 형상 설계의 중요성도 증가하고 있다.

성형 시 소성변형은 주로 코너부와 굽힘 라인에 집중되며 국부 변형이 큰 구간의 파단/균열 위험을 데이터 기반으로 예측하려는 연구가 보고되었으며[5], 이 영역의 변형 정도가 최종 형상 정밀도와 스프링백에 큰 영향을 미친다. 또한 코너부의 과도한 국부 변형은 두께 감소와 균열을 유발할 수 있고 이를 기계학습으로 예측/평가하는 연구가 보고되었다[6]. 플랜지·웹 부의 변형은 스프링백을 증가시켜 설계 형상과의 오차를 키운다. 따라서 Hat 형상 성형 공정 설계에서는 목표 단면 형상뿐 아니라 변형 집중 구간을 제어해 스프링백과 성형 결함을 함께 억제하는 것이 중요하다.

Hat 형상은 Fig. 1(b)에 제시된 설계 파라미터를 통해 정의하였다. 제품의 높이(H)는 Hat 형상의 최 하단부와 최 상단부의 높이 차로 정의하였다. 상부 웹의 길이(L_1)와 플랜지 길이(L_2)는 단면의 유효 폭과 굽힘 강성을 결정하는 인자로 사용하였다. 두 코너부의 곡률반경 R_1 과 R_2 는 성형 시 국부 변형 집중과 두께 감소에 직접적인 영향을 주는 형상 변수이다. 성형 후 플랜지 부에서 발생하는 스프링백은 플랜지의 실제 기울기와 기준




Fig. 1 Target geometry : (a) Picture of the hat-shaped product (b) springback occurrence after the forming process




Fig. 2 (a) Finite element model of the hat-forming process and (b) Effective plastic strain distribution after forming

수평선 사이의 각도(θ_{spb})로 정의하여 성형 품질 평가 지표로 사용하였다.

또한 Fig. 1의 실제 형상, 해석 결과, 파라미터 정의를 기준으로 목표 Hat 형상과 스프링백 거동을 규정하고, 이후 유한요소 모델링과 스칼라 기반 대리 모델 구축, 설계 변수 샘플링 및 공정 최적화 전 과정에서 공통 기준으로 활용하였다.

2.2 유한 요소 해석 모델링

Hat 형상의 성형 및 스프링백 해석은 유한요소해석 프로그램인 ABAQUS/Standard v6.14-5를 사용하였다. 해석 모델 및 해석 결과는 Fig. 2와 같다. 앞에서 정의한 단면 형상은 길이 방향으로 일정하며 중량을 기준으로 좌우 대칭 구조를 이루므로 전체 공정은 폭 방향과 길이 방향에 대해 대칭성을 가진다. 따라서 본 연구에서는 전체 모델의 1/4만을 해석 모델로 구성하였다. 또한 본 연구에서는 모델을 단순화하기 위해 z-방향으로도 대칭 조건을 사용하였다. 따라서 재료는 z-방향으로는 변형 편차를 보이지 않는다. 다이와 펀치는 Hat 단면 형상을 갖는 Analytic Rigid로 모델링 하였으며 다이 고정하였다. 펀치와 다이 사이의 간격이 재료 두께가 될 때까지 펀치가 이동하여, 재료를 성형하도록




Fig. 3 Stress-strain relationship of Al5052

해석을 진행하였다. 마찰계수는 0.1로 설정하여 모사하였다. 성형 단계가 종료된 이후에는 접촉 및 하중을 제거하여 스프링백 해석을 진행하였다

판재는 가로, 세로 각각 50 mm, 두께 1 mm의 판재를 4절점 셀 요소(S4R)로 모델링하였다. 해석에 사용한 소재는 Al5052 두께 1 mm 소재이며, 해당 소재의 응력-변형률 관계는 Fig. 3(b)와 같다. Al5052는 이방성 재료이지만, 본 연구에서는 대칭 조건을 사용하여 해석하였기 때문에, 등방성 재료로 가정하였다. 탄성 계수는 $E = 72 \text{ GPa}$, 초기 항복응력은 $\sigma_y = 172 \text{ MPa}$ 이며, 응력-변형률 관계는 $\sigma = 325.87(\epsilon_p + 0.0033)^{0.118}$ 로 표현된다. 이와 같은 해석 조건 하에서 각 설계 변수 조합에 대해 Hat 형상 성형 및 스프링백 해석을 수행하였으며 해석 결과를 바탕으로 데이터 생성 및 스칼라 기반 대리 모델의 학습 데이터로 활용하였다.

3. 인공 신경망 구성

3.1 데이터 생성 및 모델 구조

본 연구에서 사용한 학습 데이터 생성 및 인공 신경망 구조는 Fig. 4의 플로우차트를 기반으로 수행되었으며 인공신경망 기반 기계학습 모델을 이용하여 Hat 형상 성형 공정의 거동을 스칼라 형상 파라미터 관점에서 예측하였다. 기존 공정 설계에서는 설계변수 조합이 변경될 때마다 전체 유한요소해석을 수행하고 해석 결과로부터 곡률 반경, 단면 각도, 높이 등 해석 결과를 후처리로 계산해야 하므로 계산 비용과 시간이 많이 소요된다는 한계가 있다. 이에 유한요소해석 결과를 학습한 인공신경망을 대리 모델로 활용하여, 동일한 설계 공간에 대해 주요 형상 응답을 신속하게 예측할 수 있도록 하였다[7]. 입력 신호가 여러 개의 은닉층을 거치며 비선형 변환을 수행하고 최종적으로 성형 결과에 해당하는 출력 신호를 생성하는 구조를 가진다. 각 은닉층의 노드는 앞-뒤 층의 노드와 가중치로 연결되어 있으며 학습 과정에서 이 가중치가 반복적으로 갱신되면서 공정 조건과 형상 응답 사이의 복잡한 비선형 관계를 근사하게 된다[8].

스칼라 기반 데이터 셋은 자동화된 ABAQUS 해석으로부터




Fig. 4 Flow chart of the proposed prediction model

각 설계 조건에 대한 Hat 형상의 대표 형상 변수와 성형 결과 데이터를 추출하여 구축하였다. 입력 벡터 x 는 금형 및 단면 형상을 나타내는 설계 변수 $[L_1, L_2, H, \theta_{spb}]$ 로 정의하였으며 여기서 L_1 는 상부 웹 길이, L_2 는 플랜지 길이, θ_{spb} 는 스프링백 각도 H 는 단면 높이를 의미한다. 출력 벡터 y 는 성형 후 형상을 요약하는 스칼라 응답 $[L_1, L_2, \theta, \theta_{spb}, R_1, R_2, H]$ 로 구성하였다. θ 는 Hat 형상 빗면부 각도, R_1, R_2 는 코너부 곡률 반경, H 는 성형 후 단면 높이로 정의되고 입력과 출력 관계를 통해 전체 형상 파라미터 간의 상관 관계를 신경망이 함께 학습하도록 하였다.

Fig. 2에서와 같이 제품의 형상은 3차원 형상이며, 해석은 3차원 해석으로 진행하였으나, 폭 방향(z-dir.)에 대해 대칭 조건을 사용하여, 해석의 결과는 2D 평면 변형을 조건과 동일하다. 본 연구에서는 폭 방향에 대한 변형 특성은 고려하지 않았으며, 해석 결과 중심부의 단면 형상(x-y Plane)에서의 형상으로 학습을 진행하였고, 인공신경망을 구성, 최적화를 진행하였다.

각 설계 케이스에 대해 유한요소해석이 완료되면 절점 좌표와 변위장으로부터 후처리 스크립트를 이용해 위에서 정의한 스칼라 응답을 계산하고 이를 하나의 샘플(x, y)로 저장하였다. 본 연구에서는 총 900개의 해석 케이스를 구성하였으며 전체 데이터에 대해 변수별 평균과 표준편차를 이용한 Z-score 정규화를 수행하였다. 분산이 0인 경우에는 표준편차를 1로 치환하여 수치적 불안정성을 방지하였으며 정규화된 샘플은 무작위로 섞은 후 학습(Train) 70%, 검증(Validation) 15%, 시험(Test) 15% 비율로 분할하였다. 스칼라 기반 대리 모델의 인공신경망




Fig. 5 Artificial neural network model for this model

구조는 Fig. 5와 같이 완전 연결형 다층 퍼셉트론으로 구성된다.

입력층은 네 개의 노드로 구성되어 설계 변수 $[L_1, L_2, H, \theta_{spb}]$ 를 받아들이며 출력층은 일곱 개의 노드로 구성되어 성형 후 형상 응답 $[L_1, L_2, \theta, \theta_{spb}, R_1, R_2, H]$ 를 동시에 예측한다. 은닉층은 각각 128, 128, 64개의 노드를 갖는 세 개의 완전 연결층으로 구성하였고 첫 번째 및 두 번째 은닉층에는 쌍곡 탄젠트 활성화함수(Tansig)를 적용하여 비선형성을 부여하였으며 마지막 층에는 선형 활성화함수(Purelin)를 사용하여 연속값 회귀 문제에 적합하도록 하였다. 학습 알고리즘으로는 Scaled Conjugate Gradient (SCG) 방법을 사용하였고 손실함수는 예측값과 정답값 사이의 평균 절대 오차(Mean Absolute Error, MAE)를 최소화하도록 설정하였다. 네트워크 내부의 기본 전처리 함수는 사용하지 않고 앞서 기술한 Z-score 정규화만 적용함으로써 입력·출력 스케일러를 명시적으로 관리하였다. 학습은 최대 5,000 epoch를 상한으로 수행하였으며 학습이 완료된 후에는 각 출력 변수에 대한 MAE와 RMSE를 산정하였다. 추가로 학습, 검증, 시험 데이터셋 각각에 대해 결정계수 R^2 를 계산하고 예측값과 참값을 좌표축에 도시한 파티티 플롯을 작성하여 네트워크가 곡률 반경, 단면 각도, 높이 등 주요 형상 파라미터를 얼마나 정확하게 재현하는지 시각적으로 검증하였다.

3.2 자동화 프로세스

Hat 형상 단면에 대한 설계 변수 조합이 900개에 달하기 때문에 개별 모델을 수작업으로 구성하는 것은 사실상 불가능하다. 설계변수마다 금형 형상 생성, 요소구성, 경계조건 및 하중 정의, 해석 수행, 결과 파일관리까지 동일한 절차를 반복해야 하므로 수동 작업으로는 시간과 인적 비용이 과도하게 요구될 뿐 아니라 일관성 유지와 오류 관리에도 한계가 있다.

본 연구에서는 이러한 문제를 해결하기 위해 데이터 생성 및 유한요소해석의 전 과정을 파이썬 스크립트를 사용하여 자동화하였다. Fig. 6은 Hat 형상 단면을 정의하는 특징점과 설계 변수 X_2, X_3, Y_3, Y_4 의 의미를 나타낸 것이고 Table 1은 이들 설계 변수의




Fig. 6 Characteristic points for the die geometry

Table 1 Parameters for X_2, X_3, Y_3 and Y_4

Variables	Minimum [mm]
X_2	12, 14, 16, 20, 22
X_3	25, 27, 29, 31, 33
Y_3	-10, -12, -14, -16, -18, -20
Y_4	$Y_3 + \text{offset}$ (offset: 6, 3, 1, -1, -3, -6)

범위를 정리한 것이다. 본 연구에서 대리 모델 학습을 위해 생성된 900개의 설계 케이스는 금형 형상을 결정하는 핵심 변수인 X_2 (5 수준), X_3 (5 수준), Y_3 (6 수준), Y_4 (6 수준)에 대해 전 요인 설계(Full Factorial Design) 방식을 적용하여 생성되었다. 각 설계 변수의 범위와 수준은 Table 1과 같이 설정되었으며, 총 900 ($5 \times 5 \times 5 \times 6$)가지의 해석 모델을 구축하였다. 이와 같은 전요인 설계 방식은 설계 공간의 균일한 탐색이 가능하며, 변수 간 상호작용을 인공지능망이 학습하기에 충분한 상관관계 데이터를 생성할 수 있다. 또한 형상 변수는 다이에 대해서만 진행하였다. 펀치 형상의 경우, 다이 형상으로부터 재료 두께만큼 오프셋 한 형상으로 정의하여 해석 모델을 구성하였다.

먼저 사용자가 설정한 설계 변수 범위(Table 1)를 바탕으로 설계 공간 내 900개 조합을 생성하였다. 유한요소해석은 Abaqus/Standard 2017를 활용하여 Intel Core i7-12700K CPU와 32GB RAM 환경에서 수행되었으며, 각 해석은 평균 670초 소요되었다. 각 조합에 대해 파이썬 스크립트가 ABAQUS/CAE API를 호출하여 900개의 해석 모델에 대해 각각 Hat 단면 금형 형상을 구성하고 1/4 모델의 메싱, 재료 물성, 접촉 조건, 경계 조건 및 하중을 정의한 뒤 입력파일을 생성한다. 이후 동일 스

Table 2 Parameters of the die geometry

Model	L_1	L_2	θ	θ_{spb}	R_1	R_2	H
1	12	25	37.5	13.5	5	6	10
303	14	19	39.5	3	5	6	14
600	20	23	66.4	14.6	5	6	22
900	22	17	61.2	19.4	5	6	26




Fig. 7 Examples of the die geometry

크립트가 순차적으로 각 입력 파일에 대해 ABAQUS 해석을 수행하고 계산이 완료되면 결과 파일을 저장한다. 이때 금형 설계를 위해 사용된 다이와 펀치의 단면 x, y 좌표를 계산하여 CSV 형식의 파일로 저장하였다.

Table 2는 900개 모델 중 예제로 선정한 4개 케이스에 대한 다이의 형상 조건이며, Fig. 7은 해당 조건에서의 다이 형상을 나타낸 그림이다. 이러한 2D Geometry 플롯은 자동 생성된 좌표가 설계 의도에 부합하는지, 금형 간 간극과 형상 변화가 물리적으로 타당한지를 빠르게 검증할 수 있으며 설계 변수를 입력 데이터로 활용하였다.

후처리 단계에서는 별도의 파이썬 스크립트를 통해 각 odb 파일을 열어 성형 후 소재의 최종 형상 좌표(Deformed Coordinates)를 단면 기준선 상의 절점에 대해 추출한다. 이렇게 얻은 (x, y) 좌표는 Fig. 8과 같이 세 개의 직선 구간과 두 개의 원호 필렛으로 이루어진 파라메트릭 곡선으로 근사된다. 구체적으로는 단면을 x 방향으로 여러 구간으로 나눈 뒤 좌·우 플랜지 구간과 중앙 빗면 구간에 대해 1차 최소자승법으로 직선을 피팅하고 인접 직선의 교점 부근에 반지름 R_1, R_2 를 갖는 원호를 삽입하여 line-arc-line-arc-line 형태의 곡선을 구성한다. 필렛 반




Fig. 8 Extraction of the geometric variables from the simulation results

경 R_1, R_2 는 유한요소해석으로 얻어진 단면 프로파일과 파라메트릭 곡선 사이의 거리 제곱합이 최소가 되도록 최적화하여 결정하며 결정된 곡선으로부터 플랜지 길이 L_1, L_2 빗면부 각도 θ , 스프링백 각도 θ_{spb} 코너부 곡률 반경 R_1, R_2 , 단면 높이 H 를 계산한다. Fig. 8은 이러한 피팅 절차를 거쳐 정의되는 각 형상 파라미터의 위치와 의미를 개략적으로 보여준다.

계산된 스칼라 값은 설계 변수와 함께 입력·출력 항목으로 구분하여 CSV 형식으로 저장되며 최종적으로 900개 설계조건에 대해 한 행이 하나의 샘플을 구성하는 스칼라 데이터 베이스가 구축된다. 이렇게 생성된 CSV 파일은 MATLAB 학습 코드에서 직접 불러와 정규화, 데이터셋 분할 및 인공신경망 학습에 사용된다. 본 연구의 데이터 전처리 및 인공신경망 학습은 Intel Core i7-12700K CPU와 32GB RAM 환경에서 MATLAB 2024를 사용하여 수행되었다. 이와 같은 자동화 파이프라인을 통해 사용자는 수백 개의 스칼라 데이터 샘플을 반복적인 수작업 없이 일괄적으로 생성할 수 있으며 동일한 프레임워크를 다른 재료 계열이나 성형 공정에 대해서도 용이하게 확장할 수 있다.

3.3 인공신경망 구성 결과


스칼라 기반 대리 모델의 성능을 평가하기 위해 구축한 900개 해석 케이스에 대해 인공신경망 학습을 수행하였다. 입력 벡터는 설계 변수 $[L_1, L_2, H, \theta_{spb}]$, 출력 벡터는 $[L_1, L_2, \theta, \theta_{spb}, R_1, R_2, H]$ 로 구성되어있으며 무작위로 데이터 분할을 시행한 후 학습이 진행되었다. 학습이 완료된 후 시험(Test) 데이터셋에 평가한 결과는 Fig. 9와 Table 3에 정리하였다.

Table 3에 나타난 것처럼 정규화된 출력공간에서 길이와 높이 성분의 MAE와 RMSE는 약 0.03–0.10, 각도 성분은 약 0.02–0.05 수준에 머무르며 곡률 반경 성분은 상대적으로 큰 약 0.28–0.34 범위를 보인다. 특히 단면 높이 H 와 스프링백 각도 θ_{spb} 의 오차가 가장 작게 나타나 스프링백 보정이나 목표 높이 설정과 같이 공정 설계에서 민감한 응답에 대해서도 충분한 신뢰도를 보이는 것을 확인하였다.

Fig. 9는 시험 데이터 셋에 대해 예측 값과 정답 값을 좌표평면에 도시한 R^2 Parity Plot이다. $L_1, L_2, \theta, \theta_{spb}$ 에서는 각 플롯의 결정계수 R^2 이 0.98이상으로 나타나 길이와 각도 응답에 대해 실제와 가까운 예측 성능을 보인다. 곡률 반경 R_1, R_2 에 대한 플롯에서는 기준선을 따라 산포가 존재하지만 전반적인 추세는

Table 3 Performance evaluation of the scalar surrogate model

Variables	MAE	RMSE
L_1	0.0820	0.1266
L_2	0.0938	0.1374
θ	0.0412	0.0536
θ_{spb}	0.0253	0.0325
R_1	0.2800	0.4640
R_2	0.3370	0.6395
H	0.0360	0.0469

Fig. 9 R^2 Parity Plots of Scalar ANN Model: (a) L_1 , (b) L_2 , (c) θ , (d) θ_{spb} , (e) R_1 , (f) R_2 , and (g) H

정답과 일치하며 단면 높이 H의 경우 점들이 기준선 위에 거의 겹쳐져 분포하며 매우 우수한 일치를 확인할 수 있다. 이러한 수치 지표와 파티티 플롯을 종합하면 제한한 스칼라 기반 대리 모델이 Hat 형상 단면의 주요 형상 파라미터를 높은 정확도로 재현하고 있으며 실제 설계 단계에서 유한요소해석을 부분적으로 대체할 수 있는 예측 성능을 갖추었음을 확인할 수 있다.

4. 금형 설계를 위한 유전 알고리즘

4.1 목적 형상을 위한 금형 설계 방안

본 연구의 스칼라 기반 대리 모델은 주어진 설계 변수 x 에 대해 성형 후 단면 형상 파라미터 y 를 신속하게 예측할 수 있으므로 이를 이용하여 최적화 설계 문제를 정식화 하였다. 여기서 설계변수 x 는 금형 단면 형상을 정의하는 $[L_1, L_2, H, \theta_{spb}]^T$ 로 구성되며 출력 벡터 y 는 $[L_1, L_2, \theta, \theta_{spb}, R_1, R_2, H]^T$ 로 정의된다. 사용하는 목표로 하는 성형 결과를 지정하고 대리 모델 $\hat{y}(x)$ 가 이 목표 벡터에 최대한 근접하도록 하는 설계 변수 x 를 탐색한다.

출력 각 성분의 단위와 스케일이 서로 다르기 때문에 본 연구에서는 학습 단계에서 사용한 평균 μ_Y 와 표준편차 σ_Y 를 이용하여 모든 출력 변수를 Z-score 형태로 무차원화 하였다. 식(1)과 같이 정의하고 정규화된 출력공간에서 목표 값과의 가중 유클리드 거리를 목적 함수로 채택하였다. 목적 함수 $J(x)$ 는 식(2)와 같이 정의되며 각 출력 성분의 중요도를 나타내는 가중치이다. 본 연구에서는 길이 L_1, L_2 에 대해서는 상대적으로 완화된 제약을 두고 코너 곡률 R_1, R_2 와 각도 θ, θ_{spb} , 높이 H에 더 큰 가중치를 부여함으로써 목표 단면 형상과의 곡률, 각도 일치치를 우선적으로 달성하도록 설계하였다. 이와 같은 정규화 및 가중치 설정을 통해 서로 다른 단위와 크기를 갖는 출력 변수들이 하나의 스칼라 목적 함수 안에서 균형 있게 반영되도록 하였다.

$$z(x) = \frac{\hat{y}(x) - \mu_Y}{\sigma_Y}, z_{target} = \frac{y_{target} - \mu_Y}{\sigma_Y} \quad (1)$$

$$J(x) = \sqrt{\sum_{i=1}^7 w_i (z_i(x) - z_{target,i})^2} \quad (2)$$

최적 설계 탐색은 전역 최적화 기법인 유전 알고리즘(GA)을 사용하여 수행하였다[9]. GA는 대리 모델을 통해 평가되는 목적 함수 $J(x)$ 만을 사용하므로 고차원 비선형 설계 공간에서도 유한요소해석을 직접 반복 수행하지 않고 효율적으로 탐색할 수 있다는 장점이 있다[10]. 또한 GA 특성상 여러 개의 우수한 후보 해가 동시에 유지되기 때문에 동일한 목표 성형 결과를 만족하는 복수의 대안 설계를 비교, 선택할 수 있다는 점에서도 적합하다.

실제 구현에서는 대리 모델을 호출하는 목적 함수 $J(x)$ 를 GA의 적합도 함수로 정의하여 전역 탐색을 수행하였다. 이후 도출된 후보 해들을 초기값으로 구속 조건 최적화 알고리즘을 적용하여 목적 함수를 미세 조정함으로써, 전역 탐색의 강건성과 국소 탐색의 수렴성을 동시에 확보하였다.

설계의 다양성을 확보하기 위해 단일 최적 해 대신 상위 5개의 설계를 최종 후보로 선정하였다. 이를 위해 모든 후보 해를 목적 함수 값 순으로 정렬한 뒤, 설계 변수 및 응답 공간에서의 거리를 기준으로 유사한 해를 제거하여 형상이 뚜렷하게 구분되는 설계안을 도출하였으며, 이에 대한 인공 신경망 예측 결과를 비교 분석하였다.

4.2 유전알고리즘 구성

정의한 목적 함수 $J(x)$ 를 최소화하기 위해 본 연구에서는 MATLAB Global Optimization Toolbox에서 제공하는 GA를 사용하였다. 설계 변수의 범위는 금형 설계에서 허용 가능한 영역으로 설정하였으며, GA는 연속 설계 공간에서 후보 해 집단을 생성한 뒤 대리 모델이 예측한 형상 응답을 이용해 $J(x)$ 를 평가하여 목표 형상에 가장 근접한 설계를 탐색한다.

탐색 다양성과 수렴 성능을 고려하여 개체 수는 세대당 100개, 최대 세대 수는 100세대로 설정하였다. 선택은 확률적 균등 선택을 사용하였고, 교차율(Crossover Factor)은 0.75로 설정하였다. 또한 모든 개체가 설계 변수의 상·하한 및 제약조건을 만족하도록 제약 처리 함수를 적용하였으며, 우수해 보존을 위해 엘리트 개체는 전체의 약 8%로 지정하였다.

전역 탐색 이후에는 GA 결과를 초기값으로 국부 최적화를 수행하도록 구성하였다. 초기 집단 의존성을 줄이기 위해 동일 설정으로 GA를 5회 반복 실행하였고, 각 실행에서 얻은 상위 후보를 수집한 뒤 중복 해를 제거하고 설계공간/응답공간 거리 기준을 함께 적용하여 서로 유사한 해를 배제하였다. 이를 통해서 다른 설계 전략을 대표하는 5개의 최종 설계안을 선정하였다.

선정된 설계안에 대해서는 대리 모델로 전 응답을 재예측하여 설계 변수-예측 응답-목표 응답을 CSV로 저장하였으며, 해당 파일은 금형 좌표 계산 및 ABAQUS 입력 파일 생성 과정과 직접 연계되도록 구성하였다.

4.3 금형 설계 결과

유전 알고리즘 기반 설계 탐색은 학습된 스칼라 대리 모델을 이용하여 수행되었으며 목표 응답은 최종 제품 형상의 플랜지 부분 각도(θ_{spb})가 0이 되도록 하였으며[11], 전체 목표 형상은 $[L_1, L_2, \theta, \theta_{spb}, R_1, R_2, H] = [18 \text{ mm}, 14 \text{ mm}, 40^\circ, 0^\circ, 5.5 \text{ mm}, 6 \text{ mm}, 10 \text{ mm}]$ 로 설정하였다.

Fig. 10은 유전 알고리즘을 5회 독립실행한 경우의 목적함수 수렴 이력을 나타낸다. 각 실행에서 초기 세대에서 3~4 수준이던 목적함수 값은 세대가 진행됨에 따라 신속히 감소하여 0.3 부근으로 수렴하였다. 5회의 실행 모두 유사한 수렴 패턴을 보였는데, 이는 대리 모델 기반의 목적함수 평가가 초기 집단에 의존하지 않고 일관되게 우수한 설계를 도출함을 의미한다.

최종적으로는 각 실행에서 얻어진 해들 가운데 목적 함수 값이 우수하면서도 서로 충분히 떨어져 있는 설계들을 선별하여 상위 5개의 후보를 결정하였다. 이들 5개 설계에 대해서는 GA 결과로부터 생성된 형상 파일을 자동화 프로세스에 입력하여 ABAQUS 성형 해석을 다시 수행하고 해석 결과로부터 출력 변수를 계산하였다.

Table 4는 이렇게 얻은 실제 FEA 결과와 동일한 주요 설계변수에 대해 대리 모델이 예측한 최적화 결과(Optimize)를 나란히 비교한 것이다. 표에서 볼 수 있듯이 플랜지 길이 L_1 , L_2 곡률 반경 R_1 , R_2 단면 높이 H 에 대해 FEA와 대리 예측값의 차이는




Fig. 10 Optimization results

Table 4 Comparison between FEA and Optimized result (Optimize/FEA, excluding θ)

	L_1	L_2	θ_{spb}	R_1	R_2	H
1	20.27/19.88	14.26/14.00	0.7/1.14	5.81/5.71	5.68/5.62	10.19/10.09
2	20.12/19.86	14.38/14.00	0.75/1.06	5.81/6.09	5.68/5.86	10.20/10.16
3	20.47/19.90	14.17/14.00	0.66/1.16	5.79/5.54	5.65/5.40	10.20/10.10
4	20.27/19.88	14.26/14.00	0.7/1.14	5.81/5.71	5.68/5.62	10.19/10.09
5	20.27/19.88	14.26/14.00	0.7/1.14	5.81/5.71	5.68/5.62	10.20/10.09




Fig. 11 Result of the optimization; (a) Optimized die profile, (b) Forming result of the optimized die, and (c) Deformed cross-section of optimized product

대부분 낮게 발생하는 것을 확인하였다.

특히 스프링백(θ_{spb})은 모든 후보에서 목표 값인 0° 에 매우 근접한 약 0.7° 수준으로 나타나 본 모델이 목표 형상을 안정적으로 구현함을 확인하였다. 다만 학습된 대리 모델의 R^2 및 MAE 수준을 고려하면 θ_{spb} 가 0° 에 더 근접할 것으로 기대할 수 있으나, Table 4에서 θ_{spb} 가 약 0.7° 수준으로 잔류하는 것은 본 최적화가 θ_{spb} 단일 목표가 아니라 다수 응답을 동시에 타겟에 맞추도록 가중 z-정규화 응답 공간에서 타겟과의 거리를 최소화하는 목적함수를 사용했기 때문이다. 즉, GA는 θ_{spb} 만을 0° 로 만드는 해를 찾기보다 다른 형상 응답들과의 일치도를 고려하여 종합적으로 가장 타겟에 가까운 설계를 선택하며 소폭의 잔류 오차가 발생할 수 있다.

Fig. 11에는 ANN-GA 최적화를 통해 얻어진 대표 설계인




Fig. 12 (a) Drawing of the optimized die geometry, (b) Photograph of the fabricated die of the fabricated die

Rank 1 케이스를 예시로 제시하였다. Fig. 11(a)는 Rank 1 설계에서 GA가 찾은 최적 다이 단면 형상, Fig. 11(b)는 해당 공정에 대한 성형 해석 결과, Fig. 11(c)는 스프링백 이후의 소재 단면 형상을 나타낸다. Rank 1 설계의 경우 GA가 찾은 입력 금형 설계 변수는 $L_1 = 18.93$ mm, $L_2 = 14.26$ mm, $H = 10.19$ mm, $\theta_{spb} = 1.69^\circ$ 로 나타났으며 해당 최적화 입력 변수를 바탕으로 FEA 해석 결과를 확인하였을 때 소재의 성형 후 형상은 $L_1 = 19.88$ mm, $L_2 = 14.00$ mm, $H = 10.09$ mm, $R_1 = 5.71$ mm $R_2 = 5.62$ mm, $\theta_{spb} = 1.14^\circ$ 이다. 이는 목표 값 [L_1 , L_2 , θ_{spb} , R_1 , R_2 , H] = [18 mm, 14 mm, 0° , 5.5 mm, 6 mm, 10 mm] 과 비교할 때 실제 FEA 검증 결과에서도 Rank 1 설계는 θ_{spb} 가 약 1° 내외로 유지되면서 L_1 , L_2 , R_1 , R_2 , H , θ_{spb} 역시 목표값 주변에서 균형 있게 분포하여 스프링백 제어와 단면 형상 유지 사이의 합리적인 절충안을 제공하는 것으로 나타났다.

Fig. 12는 Rank 1 설계에 대해 제작된 실험용 금형과 성형 실험 세팅을 나타낸다. Fig. 12(a)는 GA가 찾은 최적 다이 단면 형상을 기반으로 작성된 금형 도면이며, Fig. 12(b)는 해당 도면을 바탕으로 제작된 상·하부 금형을 프레스 장비에 장착한 모습을 보여준다. Rank 1 설계에서 얻어진 최적 설계변수 [$L_1 = 18.93$ mm, $L_2 = 14.26$ mm, $H = 10.19$ mm, $\theta_{spb} = 1.69^\circ$]를 그대로 적용하여 FEA와 동일한 조건으로 성형 실험을 수행하고 스프링백 후 소재 단면 형상을 측정하였다.

Fig. 13은 Rank 1 설계 금형으로 성형한 시편의 스프링백 후 단면 형상과 플랜지 각도 측정 결과를 나타낸다. Table 5는 해석 결과(FE Results)와 실험 결과(Experimental Results)를 비교한 표이다. 여기서 오차(Error)는 해석 결과와 실험 결과의 차이이다. 형상 측정 결과, FEA에서 예측된 단면 형상과 비교했을 때 플랜지 길이와 높이 그리고 곡률 반경이 전반적으로 잘 일치함을 확인할 수 있다. 또한 스프링백 각도(θ_{spb})는 목표 값에 근접하며, 해석과의 차이는 0.64° 임을 확인하였다. 이와 같은 비교를 통해 스칼라 기반 최적화 모델은 실제 성형 실험에서도 해석 결과와 매우 유사한 스프링백 특성과 단면 형상을 재현함을 확인할 수 있다.

이와 같이 스칼라 기반 대리 모델과 유전 알고리즘을 결합한 최적화 절차는 적은 계산 비용으로 타깃 형상에 근접한 후보 설계를 도출하고 자동화된 FEA 재해석을 통해 그 결과를 검증함으로써 Hat 형상 성형 공정의 금형 설계에 실질적으로 활용할




Fig. 13 Experimental cross-section of the formed hat-profile specimen with measured springback angle

Table 5 Quantitative comparison of Target, FE results, and Experimental results

Variable	Target	FE results	Experimental results	Error
L_1 [mm]	20.27	19.88	18.55	1.33
L_2 [mm]	14.26	14	13.56	0.44
H [mm]	10.19	10.09	9.6	0.49
θ [$^\circ$]	0.7	1.14	0.5	0.64
R_1 [mm]	5.81	5.71	6.15	-0.44
R_2 [mm]	5.68	5.62	5.68	-0.06

수 있음을 보여준다.

또한 본 연구의 형상 데이터는 2D 프로파일을 기반으로 하나, 전체 해석은 향후 연구의 확장성을 고려하여 3차원으로 수행하였다. 평면 변형률(Plane Strain) 조건을 통해 2차원 해석이 가능한 구조임에도 3차원 모델링을 채택한 이유는, 본 연구에서 구축한 자동화 해석 프레임워크를 3D 형상 전반으로 확대하기 위함이다. 현재 저자들은 이러한 3차원 해석 결과를 바탕으로 수치 데이터를 넘어 성형 이미지 자체를 학습하는 이미지 기반 3차원 해석 연구를 후속 과제로 수행하고 있으며, 이를 통해 AI 기반 성형 설계 기술의 고도화를 추진하고 있다.

5. 결론

본 연구에서는 Hat 형상 단면 보강재의 성형 및 스프링백 거동을 대상으로 ABAQUS와 파이썬 스크립트를 이용한 유한요소해석 자동화 파이프라인과 스칼라 기반 인공신경망 대리 모델 그리고 유전 알고리즘을 결합한 설계 프레임워크를 제안하였다. 900개 설계조합에 대해 금형 형상 생성부터 해석·후처리까지를 자동화하였고 단면 프로파일을 직선·원호 조합으로 근사하여 스칼라 데이터베이스를 구축하였다. 이를 이용해 학습한 MLP 모델은 시험 데이터셋 기준 길이·높이 성분에서의 MAE가 약 0.03–0.10, 각도 성분의 MAE가 약 0.02–0.05 수준에 머무르며 특히 길이·각도·높이 성분에서 0.98 내외의 R^2 를 보여 Hat 형상 단면의 주요 형상 파라미터를 높은 정확도로 예측할 수 있음을 확인하였다. 또한 학습된 대리 모델을 목적함수로 하는 유전 알고리즘을 적용하여 스프링백 각도 0° 를 목표로 하는 금형

설계 최적화를 수행하였다. GA와 국부 최적화를 통해 얻어진 상위 5개 설계에 대해 다시 자동화된 FEA를 수행한 결과 플랜지 길이·곡률 반경·단면 높이 등에서 대리 예측과 유사한 오차 수준을 보였으며 실제 스프링백 각도 역시 0°부근의 작은 잔류 각도로 수렴하였다. 제안된 인공 신경망 기반 대리 모델은 이러한 절차 전반에서 반복적인 해석 횟수를 크게 줄여 고비용 실험 및 시뮬레이션 의존도를 효과적으로 낮추며 본 연구의 자동화 프로세스 및 최적화 통합 방식은 Hat 형상뿐 아니라 다양한 판재 성형 공정으로 확장되어 AI 기반 최적 설계 플랫폼으로 활용될 수 있을 것으로 기대된다.

ACKNOWLEDGEMENT

본 연구는 서울과학기술대학교 교내연구비의 지원으로 수행되었습니다.

REFERENCES

- Chen, G., Chen, C., (2019), Theoretical analysis on bending collapse of reinforced thin-walled hat-shaped section beams, *International Journal of Automotive Technology*, 20(3), 559-568.
- Liew, K., Tan, H., Ray, T., Tan, M., (2004), Optimal process design of sheet metal forming for minimum springback via an integrated neural network evolutionary algorithm, *Structural and Multidisciplinary Optimization*, 26(3), 284-294.
- Jung, K. S., Cho, S. M., Yu, J. H., Yoo, Y. H., Kim, J. B., Chung, W. J., Lee, C. W., (2020), Optimization design of penetrator geometry using artificial neural network and genetic algorithm, *Journal of the Korean Society for Precision Engineering*, 37(6), 429-436.
- Trzepieciński, T., Lemu, H. G., (2020), Improving prediction of springback in sheet metal forming using multilayer perceptron-based genetic algorithm, *Materials*, 13(14), 3129.
- Marques, A. E., Dib, M. A., Khalfallah, A., Soares, M. S., Oliveira, M. C., Fernandes, J. V., Ribeiro, B. M., Prates, P. A., (2022), Machine learning for predicting fracture strain in sheet metal forming, *Metals*, 12(11), 1799.
- Contente, J., Prates, P., (2025), Predicting edge cracking in sheet metal forming: Evaluating machine learning models and data transformations, *The International Journal of Advanced Manufacturing Technology*, 138(7), 3089-3107.
- Sevšek, L., Pepelnjak, T., (2024), Optimisation of flexible forming processes using multilayer perceptron artificial neural networks and genetic algorithms: A generalised approach for advanced high-strength steels, *Materials*, 17(22), 5459.
- Goodfellow, I., Bengio, Y., Courville, A., Bengio, Y., (2016), *Deep learning*, MIT Press.
- Holland, J. H., (1975), *Adaptation in Natural and artificial systems*, University of Michigan Press.
- Goldberg, D. E., (1989), *Genetic algorithms in search, optimization, and machine learning*, Addison-Wesley.
- Lawanwong, K., Hamasaki, H., Hino, R., Yoshida, F., (2020), Double-action bending for eliminating springback in hat-shaped bending of advanced high-strength steel sheet, *The International Journal of Advanced Manufacturing Technology*, 106(5), 1855-1867.



Hyun-Do Noh

Undergraduate Student in the Department of Mechanical Information Engineering in Seoul National University of Science and Technology. His research interests include sheet metal forming, AI based forming process.

E-mail: nhd000909@gmail.com



Seung-Hyeon Mun

Undergraduate Student in the Department of Mechanical Information Engineering in Seoul National University of Science and Technology. His research interests include sheet metal forming, AI based forming process.

E-mail: munsh0417@naver.com



Yubynn Bae

Undergraduate Student in the Department of Mechanical Information Engineering in Seoul National University of Science and Technology. Her research interests include sheet metal forming, AI based forming process.

E-mail: yubynn008@naver.com



Wan-Jin Chung

Professor in the Department of Mechanical System and Design Engineering, Seoul National University of Science and Technology. His research interests include simulation(FEM) and sheet metal forming.

E-mail: wjchung@seoultech.ac.kr



Chang Whan Lee

Associate professor in the Department of Mechanical System and Design Engineering, Seoul National University of Science and Technology. His research interests include simulation and development of the metal forming process and lightweight materials.

E-mail: cwlee@seoultech.ac.kr