

판재 성형 공정의 윤활조건별 에너지 응답 예측을 위한 소규모 데이터 기반 대리모델 연구

장성수*¹, 유동휘*², 권재영*³, 이원희*⁴

Energy Response Prediction for Sheet Metal Forming Processes under Different Lubrication Conditions using Small-Data Surrogate Models

Seongsu Jhang*¹, Donghwi Yoo*², Jaeyoung Kwon*³, and Wonhee Lee*⁴

이 연구는 2025년도 산업통상자원부 및 한국산업기술기획평가원(KEIT) 연구비 지원에 의한 연구임(RS-2025-25447560, 가전 제조 산업의 판금 공정에서 AI 기반 밸류체인 협업 기술개발)

요약

판재 성형 공정은 자동차·가전 산업에서 널리 활용되지만, 재료의 비선형 소성 거동과 접촉·마찰, 공정 조건의 복합적 상호작용으로 인해 공정 설계 및 최적화가 어렵다. 전통적으로 유한요소해석(FEA)은 성형 공정의 거동 예측에 활용되어 왔으나, 설계변수 탐색이나 반복 최적화 과정에서는 높은 계산 비용이 한계로 지적된다. 이에 본 연구는 유한요소해석 결과로부터 에너지 응답을 예측하는 대리모델을 개발하고, 소규모 데이터 조건에서 다양한 회귀 알고리즘의 성능과 비교·분석하였다. 본 연구에서는 금속 판재의 소재 물성 정보와 윤활 조건(마찰계수)에 따른 시뮬레이션 종료 시점 및 최대값 기반의 에너지 지표를 기반으로 성형성을 예측할 수 있는 대리모델 선정을 위한 알고리즘별 성능을 비교하였다. 그 결과를 통해 윤활 조건과 에너지 응답을 연계한 최적 윤활 조건 도출 연구에 신규 소재 적용, 데이터 생성 및 학습에서의 활용 가능성을 제시한다.

Abstract

Sheet metal forming is widely used in automotive and home appliance industries, but its process design and optimization remain challenging due to nonlinear material behavior and complex frictional interactions. Finite element Analysis (FEA) has been extensively employed to predict forming responses; however, its high computational cost limits efficient parameter exploration. In this study, surrogate models are developed to predict energy-based responses of sheet metal forming processes using a small-scale FEA database. Material properties and lubrication conditions are used as input features, while energy-related indicators extracted from simulation results are adopted as outputs. Several regression algorithms, including linear models, tree-based ensembles, and Multilayer Perceptrons (MLP), are evaluated and compared.

Keywords

finite element analysis, sheet metal forming, surrogate model, energy based formability indicators, lubrication condition

* 한국전자기술연구원(*⁴ 교신저자)

- ORCID¹: <https://orcid.org/0000-0002-9725-7990>

- ORCID²: <https://orcid.org/0000-0003-0244-6914>

- ORCID³: <https://orcid.org/0009-0007-5628-2878>

- ORCID⁴: <https://orcid.org/0009-0006-9762-8583>

• Received: Feb. 02, 2026, Revised: Feb. 13, 2026, Accepted: Feb. 16, 2026

• Corresponding Author: Wonhee Lee

Dept. of Autonomous Manufacturing Research Center, KETI

Tel.: +82-31-759-8126, Email: zsed50@keti.re.kr

1. 서 론

판금 성형(Sheet metal forming) 공정은 자동차 차체 부품, 가전제품 외장 패널 등 다양한 산업 분야에서 널리 활용되는 핵심 공정이다. 최근에는 경량화, 고강도 소재 적용, 형상 복잡도 증가에 대한 요구가 확대되면서, 판금 성형 공정의 정밀한 설계와 품질 예측의 중요성이 더욱 강조되고 있다. 그러나 판금 성형 공정은 재료의 비선형 소성 거동, 공정 중 발생하는 복잡한 접촉 및 마찰 현상, 그리고 공정 변수 간의 강한 상호작용으로 인해 성형 거동을 정확히 예측하는 데 많은 어려움이 따른다[1][2]. 특히 윤활 조건과 재료 물성의 변화는 성형 하중, 변형 분포, 에너지 소산 및 파단 발생에 직접적인 영향을 미치며, 이는 공정 설계 단계에서의 불확실성을 증가시키는 주요 요인으로 작용한다 [3]-[7]. 이러한 복잡성을 극복하기 위해 유한요소해석(FEA, Finite Element Analysis)은 판금 성형 공정의 변형 거동, 응력·변형률 분포, 에너지 응답 등을 예측하는 대표적인 수치해석 도구로 널리 활용되어왔다 [3][8]-[10]. FEA는 실제 공정을 정밀하게 모사할 수 있다는 장점이 있으나, 다양한 재료 물성 및 마찰·윤활 조건을 고려한 반복 해석에는 막대한 계산 시간과 컴퓨팅 자원이 요구된다. 이로 인해 공정 변수의 광범위한 탐색이나 최적화 문제에 FEA를 직접 적용하는 데에는 현실적인 제약이 존재한다.

전술한 한계를 보완하기 위한 접근법으로, 최근에는 시뮬레이션 데이터를 기반으로 한 대리모델(Surrogate model) 또는 데이터 기반 예측 기법이 활발히 연구되고 있다. 대리모델은 제한된 수의 고비용 FEA 결과를 학습하여 입력 변수와 출력 응답 간의 관계를 근사함으로써, 추가적인 시뮬레이션 수행 없이도 빠르고 효율적인 예측을 가능하게 한다 [11]-[13]. 최근에는 대규모 데이터 확보가 어려운 제조 및 성형 공정 환경을 대상으로, 제한된 데이터 기반의 대리모델링 연구가 활발히 진행되고 있다 [13]-[16]. 이러한 연구들은 데이터 수의 제약하에서 모델 구조 단순화, 물리적 지표 활용, 또는 규제 기반 학습 전략을 통해 예측 안정성을 확보하고자 한다. 본 연구 역시 이러한 연구 흐름에 기반하여, 소규모 데이터 환경에서 에너지 기반 물리 지표를 예

측 대상으로 설정함으로써 공정 특성을 반영한 대리모델링 접근을 시도하였다는 점에서 기존 연구와 차별성을 가진다. 대다수 선행연구에서는[17]-[22] 네킹 발생 시점의 국부적인 응력 또는 변형률 조건을 기준으로 성형 한계를 정의하고, 이를 통해 실제 파단 시점을 간접적으로 추정하였다. 이러한 연구들은 판재의 파단이 단일 시점의 상태 변수에 의해 결정되기보다는, 변형 과정 전반에 걸친 변형 이력과 손상 누적 결과에 의해 네킹이 발생함을 공통적으로 보고하고 있다. 이는 곧 성형 공정에서의 파단 현상이 국부 상태보다는 누적된 변형 에너지 또는 소성 일(Work)과 밀접하게 연관되어 있음을 의미하며, 에너지 기반 파단 지표를 활용한 파단 가능성 예측의 타당성을 시사한다. 따라서 본 연구에서는 기존의 변형률 또는 응력 기반 성형한계 접근을 보완하기 위해, 공정 전반에 걸쳐 누적되는 에너지 지표를 기반으로 파단 가능성을 평가하고, 이를 대리모델을 통해 효율적으로 예측·분석하고자 한다.

II. 유한요소해석(FEA)

본 연구에서는 판재 성형 공정에서 발생하는 변형 거동과 에너지 누적 특성을 정량적으로 분석하고, 이를 기반으로 파단 가능성 예측을 위한 학습 데이터를 확보하기 위해 상용 소프트웨어인 LS-DYNA를 활용한 유한요소해석을 수행하였다.

유한요소해석은 실제 성형 시험에서 관찰되는 변형 메커니즘을 합리적으로 재현할 수 있으며, 실험적으로 계측이 어려운 국부 응력, 변형률 및 에너지 관련 물리량을 정밀하게 획득할 수 있다는 장점을 가진다. 유한요소해석에서의 반구형 펀치를 이용한 Dome forming 시험은 Erichsen 및 Nakazima 시험과 같이 판재 성형성을 평가하기 위한 대표적인 표준 방법으로 널리 활용되어 왔다. 이 시험 방법은 반구형 펀치에 의해 단축 인장부터 이축 인장에 이르는 다양한 변형 경로와 재료 유동이 동시에 발생하므로, 경로의존도가 높은 공정에서 주로 활용하는 데이터인 인장시험에 비하여 성형 과정에서의 변형 이력 누적과 국부 네킹 및 파단 거동을 효과적으로 관찰할 수 있다. 또한 시험 형상과 경계 조건이 비교적 단순하고 명확하여, 유한요소해석 기반의 공정

한계 평가 및 학습 데이터 생성과 검증에 적합한 시험 방식이다[23][24]. 각 소재의 물성치는 실제 산업 현장에서 널리 사용되는 금속 재료들의 대표적인 물성값을 기반으로 설정하였다. 해석에 사용된 소재는 표 1과 같이 순수 알루미늄(Al 1100), 스테인리스강(STS304), 아연도금강판(GI), 냉연강판(SPCC), 열연강판(SS400), 마그네슘 합금(AZ31B), 동(Cu), 황동(Brass), 주석도금강판(SPTE), 티타늄(Ti Grade 2), 고장력강(DP590), 베릴륨구리(BeCu), 인코넬 718(Inconel 718), 연강(SS41 기준), 알루미늄 합금(AA5052-O, AA6061-T4, AA7075-T6) 및 DC01 강판 등 총 18종의 금속 재료를 포함한다.

표 1. 유한요소해석에 사용된 금속 재료의 물성치
Table 1. Mechanical properties of metallic materials used for finite element analysis

Material	Density ρ (g/cm ³)	Young's modulus E (GPa)	Yield strength (MPa)
Al 1100	2.7	70	35
STS304	7.93	193	205
GI	7.85	210	270
SPCC	7.85	205	280
SS400	7.85	200	250
AZ31B	1.77	45	190
Cu	8.96	110	70
Brass	8.4	97	200
SPTe	7.85	210	280
Ti Grade 2	4.51	105	275
DP590	7.85	210	590
BeCu	8.25	128	450
Inconel 718	8.19	200	1035
Mild Steel, SS41	7.85	210	240
AA5052-O	2.68	70.3	89.6
AA6061-T4	2.7	69	145
AA7075-T6	2.81	71.7	503
DC01	7.85	210	140

해석 조건으로는 마찰계수 변화에 따른 성형 결과 예측을 위한 데이터 취득을 목적으로 시험 설계하였다. 판금 성형 공정에서 마찰계수는 소재 유입, 두께 감소, 국부 네킹 및 조기 파단에 직접적인 영향을 미치는 핵심 인자이며, 특히 알루미늄 합금 판재는 공구강 표면으로의 재료 전이 및 응착마모, 깎림(Galling)에 취약하여 윤활 조건에 따른 성형 거동 변화가 크게 나타난다[5]-[7][25]. 본 연구에서는 판금 성형 공정에서의 마찰 조건이 성형 거동 및 파단 예측에 미치는 영향을 정량적으로 분석하기 위

하여, 건식 조건(Dry), 일반 윤활 조건(Lubricated), 우수 윤활 조건(Well-lubricated)의 세 가지 마찰 조건을 설정하여 유한요소해석을 수행하였다. 각 조건에 대응하는 마찰계수는 각각 $\mu = 0.40, 0.20, 0.05$ 로 선정하였다. 건식 조건에 적용한 마찰계수 $\mu = 0.40$ 은 알루미늄 합금 판재와 공구강 금형 간 직접 접촉이 발생하는 경우를 대표하는 값으로, 링 압축 시험 및 스트립 드로우 시험 결과에서 보고된 건식 마찰계수 범위(약 0.34 - 0.40)를 반영한 것이다[4][7]. 이러한 조건에서는 응착마모 및 깎림 발생 가능성이 높아 소재 유입이 제한되고, 국부 변형 집중 및 조기 파단이 발생하기 쉬운 것으로 알려져 있다[5][25]. 일반 윤활 조건에 해당하는 $\mu = 0.20$ 은 경미한 프레스 작업 또는 표준 윤활제가 적용된 판금 성형 공정을 대표하는 값으로 설정하였다. 선행연구에 따르면 중간 수준의 윤활 조건에서는 마찰계수가 약 0.12 - 0.25 범위에 분포하며, 이는 컵 드로잉 시험(CDT) 및 역해석 기반 연구에서 실제 양산 공정 조건을 모사하는데 적합한 범위로 보고되었다[6][7]. 본 연구에서는 공정 안정성과 현실성을 동시에 고려하여 해당 범위의 상한에 해당하는 값을 채택하였다. 우수 윤활 조건에 적용한 $\mu = 0.05$ 는 봉산 기반 건식 필름 윤활, Graphite 또는 PTFE 계열 윤활제가 적용된 경우를 모사하기 위한 값으로, 링 압축 시험 및 Erichsen 시험을 포함한 선행 연구에서 보고된 저마찰 조건($\mu \approx 0.03 - 0.07$)을 근거로 선정하였다[4][5]. 이러한 조건에서는 금형 - 소재 간 마찰이 효과적으로 감소하여 소재 유동이 원활해지고, 성형 한계가 확장되며 국부 네킹 및 파단이 지연되는 경향을 보인다[6]. 이와 같이 설정된 세 가지 마찰계수 조건은 실제 판금 성형 공정에서 관찰되는 윤활 상태를 대표하는 범위를 포괄하며, 마찰 조건 변화에 따른 변형 이력, 에너지 누적, 국부 네킹 및 파단 거동의 차이를 체계적으로 비교·분석하기 위한 해석 조건으로 활용하였다[4]-[7][25].

마찰계수를 주요 공정 조건으로 설정한 유한요소 해석을 수행한 이후, 본 연구에서는 해석 결과로 산출되는 다양한 물리량 중 에너지 응답을 주요 평가 지표로 활용하였다. 기존의 변형을 기반 성형한계선(FLD, Forming Limit Diagram)이나 응력 기반 파단

기준은 네킹 발생 시점의 국부 상태를 평가하는 데에는 효과적이지만, 실제 판금 성형 공정과 같이 마찰, 접촉 조건 및 변형 경로가 시간에 따라 복잡하게 변화하는 경우에는 적용에 한계가 있다. 반면, 내부 에너지, 운동 에너지 및 총 에너지는 성형 과정 전반에 걸쳐 누적되는 변형 이력과 손상 효과를 반영하는 전역 물리량으로서, 공정 조건 변화에 따른 재료 거동을 보다 일관되게 표현할 수 있다. 특히 복잡한 성형 경로를 갖는 공정에서는 국부 기준보다 누적 손상 관점의 에너지 기반 지표가 판단 가능성을 평가하는 데 보다 안정적인 기준을 제공할 수 있다. 이러한 이유로 본 연구에서는 마찰계수 조건에 따른 성형 해석 결과를 에너지 응답 중심으로 정리하고, 이를 대리모델 학습 및 판단 가능성 평가를 위한 입력·출력 변수로 활용하였다. 그림 1은 유한요소해석을 통해 도출된 성형 결과를 나타내며, 그림 2는 마찰 조건에 따른 에너지 응답의 시간 변화를 비교하여 보여준다.

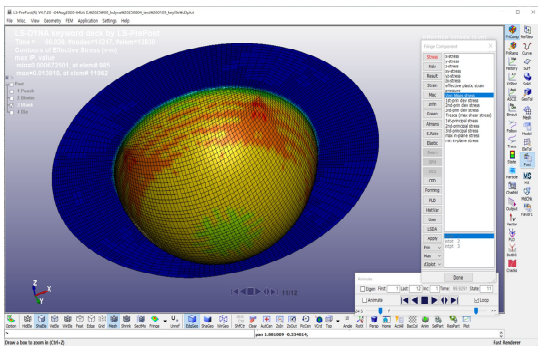
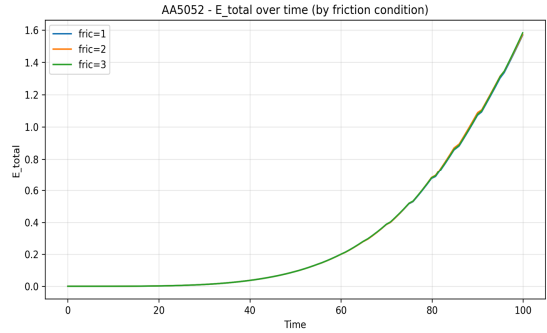



그림 1. 유한요소해석 결과
Fig. 1. Result of finite element analysis

그림 2(a)는 총 에너지(E_{total})의 시간 이력을 나타내며, 성형이 진행됨에 따라 전체 에너지가 비선형적으로 증가하는 경향을 보인다. 이는 공정 후반부에서 변형이 급격히 증가하고 에너지 축적이 가속화됨을 의미한다. 그림 2(b)는 내부 에너지(IE)의 변화를 나타낸 것으로, 소성 변형이 본격적으로 발생하는 구간 이후 급격한 증가를 보이며, 특히 마찰 조건에 따라 에너지 증가율에 차이가 나타난다. 이는 내부 에너지가 국부 변형 및 재료 거동에 민감하게 반응하는 지표임을 시사한다. 그림 2(c)는 운동 에너지(KE)의 시간 이력을 나타내며, 전체적으로

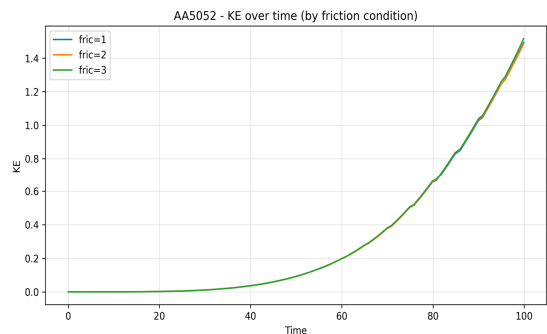
총 에너지와 유사한 증가 경향을 보이나, 상대적으로 작은 변동 폭을 가진다. 이는 운동 에너지가 공정 중 동적 효과 및 관성 영향에 의해 결정되며, 내부 에너지 대비 변형 축적과의 직접적인 연관성은 상대적으로 낮음을 의미한다.



(a)



(b)



(c)

그림 2. AA5052 판재 돔 성형 해석에서 마찰 조건별 운동에너지, 내부에너지 및 총에너지의 시간 이력 (a) 총 에너지(E_{total}), (b) 내부 에너지(IE), (c) 운동 에너지(KE) (시간: ms, 에너지: kN-mm)
Fig. 2. Time histories of energy responses in dome forming of AA5052 under different friction conditions: (a) Total energy (E_{total}), (b) Internal energy (IE), and (c) Kinetic energy (KE) (Time: ms, Energy: kN-mm)

III. 대리모델 학습 및 성능 비교 결과

대리모델 학습을 위해 유한요소해석을 통하여 수집된 데이터 54쌍을 사용하였다. 입력 변수는 해석에 사용된 금속 표 1의 물성정보와 마찰계수를 변수로 구성하였고, 본 연구에서는 특히 윤활 조건에 따른 마찰계수 변화가 에너지 응답에 미치는 영향을 주요 인자로 고려하였다. 출력 변수는 시간 이력 기반 에너지 응답 중 공정 안정성과 파단 가능성을 반영할 수 있는 결과값들을 대리모델의 예측 대상으로 설정하였다. 사용된 에너지 지표는 LS-DYNA 해석 결과에서 추출되었으며, 공정 종료 시점의 값과 공정 전 구간에서의 최대값으로 구분된다.

표 2와 그림 3의 대리모델별 성능 비교를 위해 사용된 각 모델의 출력 변수이자 예측값들인 KE_end는 성형 공정 종료 시점에서의 운동에너지를 의미하며, 공정 말기에서의 관성 효과를 간접적으로 반영한다. IE_end는 종료 시점에서 재료 내부에 축적된 내부에너지로, 주로 소성 변형에 따른 에너지 저장 특성을 나타내며 국부적 변형 집중 및 두께 감소와 밀접한 관련을 가진다. E_total_end는 종료 시점에서의 전체 에너지로, 공정의 총 에너지 상태를 대표하는 지표이다. 한편, max_KE와 max_E_total은 공정 전 시간 이력 동안 각각 운동에너지와 전체 에너지의 최대값을 의미하며, 성형 과정 중 발생한 최대 하중 전달 및 동적 응답 특성을 반영한다. 이러한 에너지 지표들은 공정 안정성 및 성형 거동을 간접적으로 설명하는 물리적 지표로 활용된다. 학습과 검증 데이터 분할은 단순 무작위 분할이 아니라 윤활조건을 그룹으로 하는 GroupShuffleSplit 기반 8:2 분할을 적용하였다(test_size=0.2, random_state=42). 이는 동일한 윤활조건에 속하는 데이터들이 학습과 검증 세트에 동시에 포함되지 않도록 구성하여, 동일 케이스 기반 정보가 평가에 유입되는 문제를 방지하였다. 이를 통해 모델이 미관측 케이스에 대한 일반화 성능을 평가할 수 있도록 설계하였다. 데이터의 정규화는 학습 세트에 대해서만 정규화를 수행한 후 동일 파라미터로 검증 세트를 변환하는 방식으로 적용하였다. 입력 변수 X는 StandardScaler를 이용해 평균 0, 분산 1로 표준화하였으며, 출력 변수 Y 또한 회귀 안정화(특히 신경망, 서포트벡터 회귀의

수렴 안정성 확보)를 위해 StandardScaler로 표준화한 값을 사용하여 다중 출력 회귀를 수행하였다. 이때 스케일링 파라미터(평균, 표준편차)는 학습 데이터에서만 추정되며, 검증 데이터에는 transform만 적용하여 데이터 누수를 방지하였다. 대리모델의 경우에는 선형 모델과 비선형 모델을 포함한 총 8종 Ridge regression, ElasticNet, KNN(K-Nearest Neighbors), SVR(Support Vector Regression), Random Forest, ExtraTrees, Histogram-based GBDT, MLP(Multilayer Perceptron) 등 총 8종의 기계학습 모델을 대리모델 후보로 선정하였다. 이러한 모델들은 선형 모델, 커널 기반 모델, 트리 기반 앙상블 모델, 신경망 기반 모델을 포함하며, 회귀 문제에서 널리 활용되는 대표적인 방법들이다[26]-[29]. 모델 일반화 및 과적합 방지 전략으로 그룹 기반 분할을 통한 누수 방지 외에도, 복잡도가 큰 모델에 대해서는 규제, 조기종료를 적용하여 검증 성능이 개선되지 않을 경우 학습을 조기에 종료하도록 사전 설정 하였고, L2 규제항을 사용하여 과도한 파라미터 적합을 억제했다. 또한, 선형모델들의 경우, 규제 기반 모델로서 소규모 데이터에서 안정적인 일반화 성능을 확보할 수 있도록 모델별 비교군에 포함하는 방법을 적용했다. 마지막으로 하이퍼파라미터 튜닝 전략은 (i) Ridge 및 ElasticNet과 같은 선형 규제 모델은 과적합을 방지하기 위해 규제 강도(alpha)를 중심으로 설정하였다. Ridge 모델은 $\alpha=1.0$ 으로 설정하였으며, ElasticNet은 $\alpha=0.01$, l1_ratio=0.2로 설정하였다. 이는 L2 중심의 안정적 회귀 특성을 유지하면서 부분적인 희소성을 허용하는 절충적 설정이다. 반복 수(max_iter)는 20,000으로 충분히 크게 설정하여 수렴 문제를 방지하였다. (ii) 트리 기반 앙상블 모델인 RandomForest 및 ExtraTrees는 분산 감소를 위해 비교적 충분한 추정기 개수(n_estimators)를 사용하였으며, 각각 600 및 800으로 설정하였다. 최대 깊이(max_depth)는 기본 설정(None)을 사용하였으나, 과적합을 유발하지 않는 범위 내에서 성능을 확인하였다. HistGradientBoosting 모델의 경우, 소규모 데이터에서 과도한 모델 복잡도를 방지하기 위해 max_depth=6, learning_rate=0.05로 제한하였다. (iii) 신경망 모델 MLP는 (128, 64, 32)의 3개 은닉층 구조를 사용하였다. 활성화 함수는 ReLU, 최적화 기법은 Adam을 적용하였다. 또한 과

적합 방식을 위해 `early_stopping=True`를 적용하여 검증 성능이 개선되지 않을 경우 학습을 조기에 종료하도록 하였다. 최대 반복 횟수(`max_iter`)는 10,000으로 설정하였다.

제한된 대리모델의 계산 효율성을 평가하기 위하여 모델별 학습 시간(`Train time`)과 예측 시간(`Inference time`)을 측정하였다. 실험은 Intel Core i7 (4.2 GHz), RAM 48GB, NVIDIA RTX 4000 Ada 환경에서 수행되었으며, LS-DYNA 해석은 단일 코어 기반으로 수행되었다. 한편, LS-DYNA 로그에 따르면 단일 공정 조건에 대한 해석에는 약 41 - 42초의 계산 시간이 소요되었다. 반면, 대리모델의 학습 시간은 평균 약 0.65초 수준이었으며, 예측 시간은 대부분 0.001 - 0.09초 범위로 나타났다. 특히 학습이 완료된 이후의 추론 시간은 밀리초(ms) 단위로 수행 가능하였다. 이는 동일한 공정 조건 탐색 문제에서 대리모델이 FEA 기반 반복 해석 대비 수십 배 이상의 계산 시간 절감 가능성을 가짐을 의미하며 고비용의 해석프로그램의 라이선스를 고려하였을 때, 경제적 효율성도 제고할 수 있다.

성능 평가는 MAE(Mean Absolute Error), RMSE (Root Mean Squared Error), R^2 (Coefficient of Determination) 세 가지 지표를 사용하여 비교했다. 표 2와 그림 3은 각 대리모델의 예측 성능을 정량적으로 비교한 결과를 나타낸다. 전체적으로 비선형 모델이 선형 모델 대비 우수한 성능을 보였으며, 특히 MLP와 ExtraTrees 모델이 가장 높은 예측 정확도를 나타냈다. 본 연구에서 예측 대상으로 사용한 에너지 지표(KE, IE, E_{total})는 시간에 따른 순간 응답이 아니라, 공정 전 구간에 걸친 에너지 이력의 누적값 또는 최대값에 해당한다. 즉, 이들 변수는 특정 지점의 국부적 물리량이 아니라, 공정 전체의 변형 및 하중 이력이 집계된 전역 물리량으로 볼 수 있다. 이러한 집계형 에너지 지표는 입력 변수 간의 비선형 상호작용이 통합된 결과로 나타나므로, 비선형 함수 근사 능력이 우수한 MLP 모델이나 입력 공간을 다중 분할하여 상호작용을 포착할 수 있는 ExtraTrees 모델이 상대적으로 유리하게 작용한 것으로 볼 수 있다. 저조한 성능을 보인 HistGBDT의 경우에는 입력 변수를 히스토그램 기반 binning으로 변환한 뒤 분할을 수행함으로써 계산 효율성

과 대규모 데이터 처리에 강점을 가지는 모델이지만 본 연구와 같이 데이터 수가 매우 제한적인 소규모 회귀 문제(N=54)에서는 binning 과정에서 일부 포함되어 있는 연속적인 물리 정보가 과도하게 단순화되어 성능 감소로 이어진 것으로 추정된다. 또한 소규모 데이터 환경에서는 트리 기반 모델의 분할이 소수의 샘플에 의해 결정되면서 과적합 또는 반대로 과도한 일반화가 동시에 발생할 수 있으며, 이로 인해 평균 예측 성능이 기준선(Mean predictor)보다도 낮아져 음의 R^2 값이 나타난 것으로 판단된다. 소규모, 연속적인 데이터 특성이 있는 회귀 문제에서는 모델 특성에 따라 성능 차이가 크게 나타날 수 있음을 보여주는 사례로 해석할 수 있으며, 본 연구에서는 이를 통해 에너지 기반 대리모델 연구에 보다 적합한 모델 선정에 반영할 수 있다.

표 2. 에너지 응답 예측 대리모델별 성능 비교 결과
Table 2. Performance comparison of surrogate models for energy response prediction

Model	MAE	RMSE	R^2
MLP	0.1969	0.2806	0.9218
ExtraTrees	0.1924	0.2872	0.9204
ElasticNet	0.2259	0.2918	0.9206
Ridge	0.2260	0.2946	0.9191
SVR (RBF, MultiOutput)	0.2057	0.3307	0.8916
KNN	0.3469	0.4522	0.8026
RandomForest	0.3441	0.4760	0.7883
HistGBDT (MultiOutput)	1.0144	1.1525	-0.1884

표 3은 각 에너지 지표별 모델 성능을 결정계수 (R^2) 기준으로 정리한 결과이다. 출력변수 E_{total_end} 및 max_E_{total} 과 같은 전체 에너지 기반 지표에서는 ExtraTrees 및 MLP 모델이 가장 우수한 성능을 보였다($R^2 > 0.96$). 이는 공정 전 구간의 에너지 누적값이 입력 변수 간의 비선형 상호작용을 반영하는 집계형 물리량이기 때문으로 해석된다. 비선형 함수 근사 능력을 가진 MLP와 입력 공간을 유연하게 분할하는 ExtraTrees는 이러한 상호작용을 효과적으로 포착한 것으로 판단된다. 반면, 예측값 중 IE_end 의 경우 모든 모델에서 상대적으로 낮은 R^2 값을 보였으며(최대 0.792), 이는 내부 에너지가 국부 소성 변형 이력의 누적값으로서 입력 변수에 직접적으로 반영되지 않은 국부 변형 특성의 영향을 받기 때문으로 해석된다.

표 3. 에너지 지표별 상위 모델 성능 비교 (R² 기준)

Table 3. Comparison of top model performance by energy indicator (R²-based ranking)

Target	1st model (R ²)	2nd model (R ²)	3rd model (R ²)	Lowest model (R ²)
E_total_end	ExtraTrees (0.963)	MLP (0.960)	ElasticNet (0.959)	HistGBDT (-0.202)
max_E_total	MLP (0.979)	ExtraTrees (0.963)	ElasticNet (0.959)	HistGBDT (-0.202)
max_KE	ExtraTrees (0.969)	SVR (0.967)	MLP (0.961)	HistGBDT (-0.151)
IE_end	ElasticNet (0.792)	Ridge (0.790)	ExtraTrees (0.769)	HistGBDT (-0.166)
Vz_end	ElasticNet (0.940)	Ridge (0.938)	ExtraTrees (0.938)	HistGBDT (-0.221)

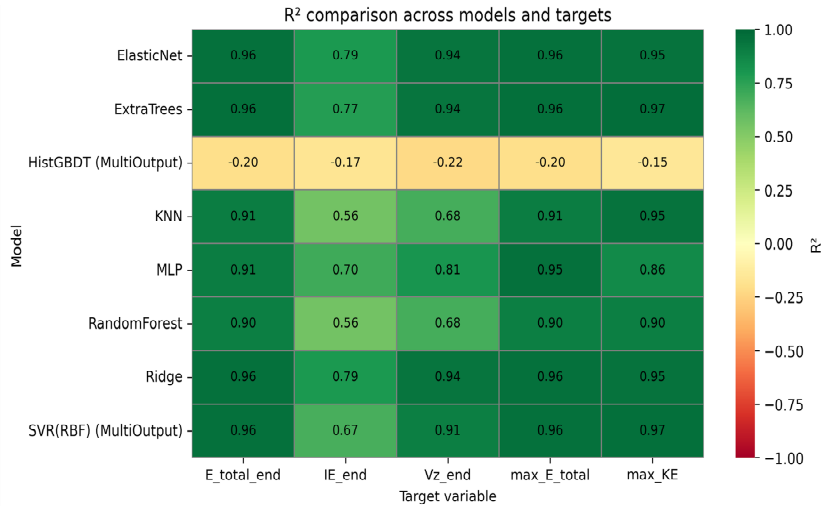


그림 3. 대리모델별 및 목표 변수별 결정계수(R²) 비교 결과 히트맵

Fig. 3. Heatmap of coefficient of determination (R²) across surrogate models and target variables

출력변수 max_KE는 비교적 높은 예측 정확도를 보였으며(최대 R² = 0.969), 이는 운동에너지가 공정 하중 조건과 보다 직접적으로 연관된 집계 지표이기 때문으로 볼 수 있다.

그림 3의 결과를 통해 총 에너지 기반 변수 E_total_end, max_E_total은 대부분의 대리모델에서 높은 결정계수 수치를 보였다. 이는 총 에너지가 공정 전반에 걸쳐 누적되는 전역(global) 물리량으로, 국부적인 수치 진동이나 순간적인 비선형 이벤트의 영향을 상대적으로 덜 받고 마찰 조건, 편치 운동 이력, 재료 소성 거동과 같은 저차원 공정 변수와의 상관성이 높기 때문으로 해석된다. 따라서 총 에너지 및 최대 에너지 계열 변수는 대부분의 대리모델에서 높은 설명력을 보인 반면, 내부 에너지와 같이 국부 소성 변형에 민감한 변수는 상대적으로 예측 난이도가 높았다. 이는 에너지 기반 변수라 하더라도, 물리적 의미와 공간적 누적 특성에 따라 대리모델 학습 특성이 달라질 수 있음을 시사한다.

IV. 결론 및 향후 과제

본 연구에서는 판금 성형 공정에서 윤활조건에 따른 에너지 응답을 예측하기 위해, 유한요소해석 기반 데이터를 활용한 대리모델을 구축하였다. 소규모 데이터 환경에서도 에너지 기반 지표를 활용한 공정 거동 예측이 효과적으로 수행될 수 있음을 확인하였으며, 특히 MLP 및 ExtraTrees 모델이 높은 예측 성능을 보였다. 또한 에너지 응답은 공정 전반의 변형 이력을 반영하는 전역 물리량으로서, 기존 변형률 기반 성형한계 접근을 보완할 수 있는 가능성을 확인하였다. 향후 연구에서는 Erichsen 및 Nakazima 시험과 같은 실제 실험 데이터를 포함하여 모델의 신뢰성을 검증하고, 국부 두께 감소 및 변형률 분포와 같은 국부 물리량을 입력 변수로 확장함으로써 모델의 설명력을 향상시킬 예정이다. 또한 에너지 기반 지표와 실제 파단 발생 간의 정량적 상관관계를 규명하여, 에너지 응답을 활용한 성

형성 평가의 물리적 타당성을 보다 명확히 하고자 한다. 더불어 다양한 소재 및 공정 조건을 포함한 데이터 확장을 통해 모델의 일반화 성능을 확보하고, 실제 산업 현장에서의 적용 가능성을 검증할 계획이다.

References

- [1] A. E. Marques, T. G. Parreira, A. F. Pereira, B. M. Ribeiro, and P. A. Prates, "Machine learning applications in sheet metal constitutive Modelling: A review", *International Journal of Solids and Structures*, Vol. 303, No. 15, pp. 1-16, Oct. 2024. <https://doi.org/10.1016/j.ijsolstr.2024.113024>.
- [2] A. E. Marques, M. A. Dib, A. Khalfallah, M. S. Soares, M. C. Oliveira, J. V. Fernandes, and P. A. Prates, "Machine learning for predicting fracture strain in sheet metal forming", *Metals*, Vol. 12, No. 11, pp. 1-13, Oct. 2022. <https://doi.org/10.3390/met12111799>.
- [3] M. Safari, S. J. Hosseinipour, and H. D. Azodi, "Experimental and numerical analysis of forming limit diagram (FLD) and forming limit stress diagram (FLSD)", *Materials Sciences and Applications*, Vol. 2, No. 5, pp. 497-503, May 2011. <https://doi.org/10.4236/msa.2011.25067>.
- [4] G. Mesmer and J. Colton, "Variation of the friction conditions in cold ring compression tests of aluminum 1100-O and aluminum 6061-T6 as applied to room temperature forging in low-and middle-income countries", *Cogent Engineering*, Vol. 11, No. 1, pp. 1-9, Sep. 2024. <https://doi.org/10.1080/23311916.2024.2399961>.
- [5] K. P. RAO and J. J. WEI, "Performance of a new dry lubricant in the forming of aluminum alloy sheets", *Wear*, Vol. 249, No. 1, pp. 85-92, Apr. 2001. [https://doi.org/10.1016/S0043-1648\(01\)00526-9](https://doi.org/10.1016/S0043-1648(01)00526-9).
- [6] L. Ju, T. Mao, J. Malpica, and T. Altan, "Evaluation of lubricants for stamping of Al 5182-O aluminum sheet using cup drawing test", *Journal of manufacturing science and engineering*, Vol. 137, No. 5, pp. 1-8, Oct. 2015. <https://doi.org/10.1115/1.4030750>.
- [7] T. Trzepieciński, J. Slota, L. Kašćák, I. Gajdoš, and M. Vojtko, "Friction behaviour of 6082-T6 aluminium alloy sheets in a strip draw tribological test", *Materials*, Vol. 16, No. 6, pp. 1-18, Mar. 2023. <https://doi.org/10.3390/ma16062338>.
- [8] S. Liu, Y. Xia, Z. Shi, H. Yu, Z. Li, and J. Lin, "Deep learning in sheet metal bending with a novel theory-guided deep neural network", *IEEE/CAA Journal of Automatica Sinica*, Vol. 8, No. 3, pp. 565-581, Feb. 2021. <https://doi.org/10.1109/JAS.2021.1003871>.
- [9] L. Quagliato, M. Perin, V. Modanloo, and T. Lee, "Expert-informed neural network (EINN) for the forming depth prediction from a small-scale sheet metal forming database", *Proc. 54th Materials Research Proceedings ESAFORM 2025*, Paestum, Italy, pp. 1490-1499, May 2025. <https://dx.doi.org/10.21741/9781644903599-161>.
- [10] S. R. Lee, D. I. Hyun, and S. M. Hong, "Prediction of cracks and wrinkles in sheet metal forming based on AI-driven drawbead modeling", *Proc. Korean Society for Technology of Plasticity (KSTP) Conference*, Jeju, Korea, pp. 131, Oct. 2024.
- [11] I. El Mrabti, A. El Hakimi, A. Touache, and A. Chamat, "A comparative study of surrogate models for predicting process failures during the sheet metal forming process of advanced high-strength steel", *The International Journal of Advanced Manufacturing Technology*, Vol. 121, No. 1, pp. 199-214, Jan. 2022.
- [12] R. Zhang, Z. Shao, and J. Lin, "A review on modelling techniques for formability prediction of sheet metal forming", *International Journal of Lightweight Materials and Manufacture*, Vol. 1, No. 3, pp. 115-125, Sep. 2018. <https://doi.org/10.1016/j.ijlmm.2018.06.003>.

- [13] S. S. Han and H. K. Kim, "Artificial neural network-based sequential approximate optimization of metal sheet architecture and forming process", *Journal of Computational Design and Engineering*, Vol. 11, No. 3, pp. 265-279, May 2024. <https://doi.org/10.1093/jcde/qwae049>.
- [14] C. Kamath and Y. J. Fan, "Regression with small data sets: a case study using code surrogates in additive manufacturing", *Knowledge and Information Systems*, Vol. 57, No. 2, pp. 475-493, Mar. 2018. <https://doi.org/10.1007/s10115-018-1174-1>.
- [15] P. C. Chua, S. K. Moon, Y. T. Ng, and H. Y. Ng, "A surrogate model to predict production performance in digital twin-based smart manufacturing", *Journal of Computing and Information Science in Engineering*, Vol. 22, No. 3, Art no. 031007, Jun. 2022. <https://doi.org/10.1115/1.4053038>.
- [16] E. Lwele, A. Shenfield, and C. E. da Silva, "AI-Based Surrogate Models for the Food and Drink Manufacturing Industry: A Comprehensive Review", *Journal of Processes*, Vol. 13, No. 9, pp. 1-33, Oct. 2025.
- [17] R. T. Hill, "On discontinuous plastic states, with special reference to localized necking in thin sheets", *Journal of the Mechanics and Physics of Solids*, Vol. 1, No. 1, pp. 19-30, Oct. 1952. [https://doi.org/10.1016/0022-5096\(52\)90003-3](https://doi.org/10.1016/0022-5096(52)90003-3).
- [18] H. Swift, "Plastic instability under plane stress", *Journal of the Mechanics and Physics of Solids*, Vol. 1, No. 1, pp. 1-18, Oct. 1952.
- [19] P. Hora, L. Tong, and J. Reissner, "A prediction method for ductile sheet metal failure in FE-simulation", *Proc. 3rd International Conference NUMISHEET '96*, Michigan, Dearborn, USA, pp. 252-256, Sep.-Oct. 1996.
- [20] P. Hora, L. Tong, and B. Berisha, "Modified maximum force criterion, a model for the theoretical prediction of forming limit curves", *International Journal of Material Forming*, Vol. 6, No. 2, pp. 267-279, Nov. 2011. <https://doi.org/10.1007/s12289-011-1084-1>.
- [21] S. Stören and J. R. Rice, "Localized necking in thin sheets", *Journal of the Mechanics and Physics of Solids*, Vol. 23, No. 6, pp. 421-441, Dec. 1975. [https://doi.org/10.1016/0022-5096\(75\)90004-6](https://doi.org/10.1016/0022-5096(75)90004-6).
- [22] N. Kotkunde, G. Krishna, S. K. Shenoy, A. K. Gupta, and S. K. Singh, "Experimental and theoretical investigation of forming limit diagram for Ti-6Al-4 V alloy at warm condition", *International Journal of Material Forming*, Vol. 10, No. 2, pp. 255-266, Nov. 2015. <https://doi.org/10.1007/s12289-015-1274-3>.
- [23] S. Davey, R. Das, W. J. Cantwell, and S. Kalyanasundaram, "Forming studies of carbon fibre composite sheets in dome forming processes", *Composite Structures*, Vol. 97, No. 1, pp. 310-316, Mar. 2013. <https://doi.org/10.1016/j.compstruct.2012.10.026>.
- [24] C. G. Dengiz and K. Yıldızlı, "Experimental and numerical study of process limits for deep drawing of dome-structured sheet metals", *The International Journal of Advanced Manufacturing Technology*, Vol. 92, No. 9, pp. 4457-4472, May 2017. <https://doi.org/10.1007/s00170-017-0450-7>.
- [25] A. S. Sabet, J. Domitner, A. Ristić, K. I. Öksüz, M. R. Ripoll, and C. Sommitsch, "Effects of temperature on friction and degradation of dry film lubricants during sliding against aluminum alloy sheets", *Tribology International*, Vol. 180, No. 1, pp. 1-12, Feb. 2023. <https://doi.org/10.1016/j.triboint.2022.108205>.
- [26] A. E. Hoerl and R. W. Kennard, "Ridge regression: Biased estimation for nonorthogonal problems", *Technometrics*, Vol. 12, No. 1, pp. 55-67, Feb. 1970.
- [27] C. M. Bishop and N. M. Nasser, "Pattern Recognition and Machine Learning", *Information Science and Statistics*, Springer, pp. 5-17, Aug. 2006.

[28] T. Hastie, R. Tibshirani, and J. Friedman, "The Elements of Statistical Learning", Statistics, Springer, Feb. 2009.

[29] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors", Nature, Vol. 323, pp. 533-536, Oct. 1986.

이 원 희 (Wonhee Lee)



2010년 2월 : 숭실대학교
정보통신전자공학부(공학사)
2013년 9월 : 숭실대학교
정보통신공학과(공학석사)
2013년 10월 ~ 현재 :
한국전자기술연구원 선임연구원
관심분야 : Wired/Wireless

Fieldbus system, 자율제조

저자소개

장 성 수 (Seongsu Jhang)



2017년 2월 : 광운대학교
전기공학과(공학사)
2019년 2월 : 광운대학교
전기공학과(공학석사)
2019년 2월 ~ 2021년 1월 :
(주)HD현대일렉트릭 연구원
2021년 2월 ~ 현재 :

한국전자기술연구원 선임연구원
관심분야 : ICT융합, 제조데이터, 산업 인공지능

유 동 휘 (Donghwi Yoo)



2021년 2월 : 광주과학기술원
기계공학과(공학사)
2023년 9월 : 광주과학기술원
기계공학과(공학석사)
2023년 9월 ~ 현재 :
한국전자기술연구원 전임연구원
관심분야 : 기계 예지보전,

고장진단, 데이터분석

권 재 영 (Jaeyoung Kwon)



2018년 2월 : 영남대학교
전기공학과(공학사)
2024년 2월 : 경남대학교
기계공학과(공학석사)
2020년 9월 ~ 현재 :
한국전자기술연구원 전임연구원
관심분야 : 공작기계, 데이터 표준,

OPC UA, 제조 데이터, 산업 인공지능