

액중 방전 성형과 인공신경망 기법을 활용한 Cowper-Symonds 구성 방정식의 변형률 속도 파라미터 역추정

변한비¹ · 김 정^{2, #}

Estimating Strain Rate Dependent Parameters of Cowper-Symonds Model Using Electrohydraulic Forming and Artificial Neural Network

H. B. Byun, J. Kim

(Received February 4, 2022 / Revised February 28, 2022 / Accepted March 2, 2022)

Abstract

Numerical analysis and dynamic material properties are required to analyze the behavior of workpiece during an electrohydraulic forming (EHF) process. In this study, EHF experiments were conducted under three conditions (6, 7, 8 kV). Dynamic material properties of Al 5052-H34 were inversely estimated through an ANN (Artificial Neural Network) model constructed based on LS-Dyna analysis results. Parameters of Cowper-Symonds constitutive equation, C and p , were used to implement dynamic material properties. By comparing experimental results of three conditions with ANN model results, optimized parameters were obtained. To determine the reliability of the derived parameters, experimental results, LS-Dyna analysis results, and ANN results of three conditions were compared using MSE and SMAPE. Valid parameters were obtained because values of indicators were within confidence intervals.

Keywords : Electrohydraulic Forming, Artificial Neural Network, Dynamic Material Properties, Cowper-Symonds

1. 서 론

전세계적으로 환경 문제 및 규제 강화에 따라 자동차, 조선, 항공기 분야에서는 중량을 줄이기 위해 가볍고 내구성이 뛰어난 알루미늄 소재를 활발히 사용하고 있으며 이에 맞는 판재 성형 기술이 발달하고 있다. 전통적으로 가장 많이 사용된 판재 성형 방법은 한 쌍의 펀치와 금형을 사용하는 matched die 성형으로, 자동차, 전기 전자 및 생활 용품 등 생산성이 높은 제품에 많이 사용되고 있다[1]. 그러나 matched die 성형은 성형 한계가 낮아 제품 설계에 제약이 많고 부품 수의 증가 및 성형 공정 시간의

증가를 야기할 뿐 아니라 피로균열의 원인이 되는 접합부의 증가로 제품의 내구성이 떨어진다. 반면에 굉장히 짧은 시간 동안 성형이 진행되는 고속 성형은 관성 효과와 높은 변형률 속도(strain rate)로 인한 연신을 증가로 인해 성형 한계가 높기 때문에 다양한 제품 설계가 가능하며 부품 수와 공정 단계를 줄일 수 있다[2-3].

고속 성형은 전자기 성형(electro-magnetic forming), 폭발 성형(explosive forming), 액중 방전 성형(electro-hydraulic forming) 등이 있다. 그 중 액중 방전 성형은 전자기 성형에 비해 유체라는 매개체가 있기 때문에 바운싱 현상(bouncing effect)이 저감되어 주름 등 성형 불량률이 잘 나타나지 않고 소재의 전기전도도에 영향을 받지 않고 성형이 가능하다는 장점이 있다[4]. 최근에는 이러한 액중 방전 성형 장비의 장점을 이용하여 금속 재료의 고속 성형 한계 선도를

1. 부산대학교 항공우주공학과, 석사과정
2. 부산대학교 항공우주공학과, 교수
Corresponding Author : Pusan National University
E-mail: greatkj@pusan.ac.kr
ORCID : 0000-0002-7292-7441

획득하는 연구가 활발하게 진행되고 있다[5-6].

액중 방전 성형은 1000 s^{-1} 이상의 변형률 속도로 성형이 일어나며 폐공간에서 실험이 진행되기 때문에 육안으로 관찰하기에는 한계가 있어 성형 과정을 분석하여 관재의 고속 거동을 파악하기 위해서 유한요소 해석이 필요하다. 고속 상황에서의 유한요소 해석은 재료의 변형률 속도를 고려한 물성치가 필수적이다. 일반적으로 고 변형률 속도에서의 물성은 고속 인장 시험기[7], SHTB(Split-Hopkinson tensile bar)[8], SHPB(Split-Hopkinson pressure bar)[9] 장비를 통해 획득할 수 있다. 그러나 장비를 보유하고 있지 않을 경우 혹은 장비에 맞는 시편 확보가 어려울 경우 물성치를 얻는 데 비용과 시간이 많이 소요된다. 본 연구에서는 이를 해결하기 위한 방안으로 인공신경망(artificial neural network) 기법을 적용하였다. 인공신경망 기법이란 뇌의 뉴런에서 신호를 주고받는 원리에 기인하여 다수의 층과 노드로 이루어진 신경망을 생성하여 비선형 문제를 예측할 수 있는 기법이다. Moon 등[10]은 인공신경망 기법을 활용하여 유한요소 해석에서 구성방정식 연산 과정을 인공지능 모델로 대체하는 연구를 수행하였고 Yang 등[11]은 인공신경망 기법을 통해 최적의 사출성형 공정을 도출하기 위한 연구를 수행하였다.

본 연구에서는 고속 성형 기법을 유한요소 해석으로 구현할 수 있도록 인공신경망 기법을 사용하여 Al 5052-H34의 동적 물성치를 표현하는 구성방정식의 파라미터를 역추정하였다. 파라미터에 따른 유한요소 해석 결과를 통하여 인공신경망 모델을 구

축하였고 고속 성형 기법 중 하나인 액중 방전 성형의 실험 형상과 비교하여 최적의 파라미터를 획득하였다. 획득한 파라미터를 통해 동적 물성을 구현하였으며 이를 인공신경망 모델에 적용시켜 얻은 결과 및 유한요소 해석한 결과와 액중 방전 성형 실험 결과를 비교함으로써 파라미터의 신뢰성을 확보하였다.

2. 액중 방전 성형 실험

액중 방전 성형 기법은 1000 s^{-1} 이상의 변형률 속도를 가지는 고속 성형 기법 중 하나로, 커패시터(capacitor), 전극(electrode), 금형(die), 챔버(chamber), 시편으로 구성되어 있다. 전기 에너지 저장 장치인 커패시터에 충전시킨 에너지를 매우 짧은 시간 내에 전극을 통해 유체로 방전시켜 두 전극 사이에서 고온, 고압의 플라즈마가 생성된 후 팽창되며 만들어내는 충격파로 인해 소재의 성형이 이루어진다. 액중 방전 성형 장비의 개략도는 Fig. 1 와 같다. 두 전극 사이에는 철사를 연결하여 전기 에너지가 집중되게 한다. 철사의 연결이 없다면 플라즈마가 철사 부근의 유체에 생성되지 않고 전극 주변에서 소실되어 충분한 에너지가 소재에 전달되지 않아 성형성이 떨어진다[12]. 액중 방전 성형 기법은 고속 성형이기 때문에 저속 성형에 비해 소재가 변형 후 어느정도 탄성 회복하며 생기는 스프링 백(spring back) 현상이 저감되어 성형성이 향상된다. 또한 매개체가 존재하기 때문에 관재와 금형이 성형되는




Fig. 1 Schematic of electro-hydraulic forming process




Fig. 2 Experimental results of EHF at 6, 7, 8 kV

Table 1 Maximum bulge height of EHF

Case	6kV	7kV	8kV
Bulge height (mm)	28	34.6	40

Table 2 Parameters of quasi-static hardening curve

A	B	n
188.03 MPa	327.07 MPa	0.58

과정에서 부딪히며 생기는 바운싱 현상이 줄어들어 주름과 파단 등 성형 불량률이 덜 나타난다는 장점이 있다.

본 연구에서는 세 전압을 사용하여 액중 방전 성형 실험을 수행하였다. 실험에 사용된 소재는 가로 길이와 세로 길이가 각각 250 mm 이고 두께 1 mm 의 Al 5052-H34 이며, 자유 벌징 금형을 사용하여 실험을 수행하였다. 실험에 사용된 전압은 6, 7, 8 kV 이며 전압에 따른 커패시터 시스템의 전기 에너지는 약 12 kJ, 16.3 kJ, 21.3 kJ 이다. 3 차원 스캐너 장비를 사용하여 소재의 성형 변위를 측정 한 결과는 Fig. 2 와 같다. 최대 성형 높이를 Table 1 에 나타냈다.




Fig. 3 Finite element analysis model of EHF

3. 유한요소 해석

3.1 성형 소재의 구성방정식

고속 성형 기법인 액중 방전 성형을 해석적으로 구현하기 위하여 변형률 속도를 고려한 물성이 필요하다. 변형률 속도에 따른 응력-변형률 곡선을 구현하기 위하여 Cowper-Symonds 구성방정식을 사용하였다. Table 2의 A, B, n은 준정적 인장 조건에서의 경화 곡선 구성 요소로, 준정적 인장 시험을 통해 얻을 수 있다. C와 p는 구성방정식의 변형률 속도 파라미터로, 값이 변함에 따라 소성 영역에서의 변형률 경화 곡선이 변하며 변형률 속도에 따른 물성치를 구현할 수 있다.

$$\sigma = (A + B\varepsilon^n) \left(1 + \left(\frac{1}{C} \right)^{\frac{1}{p}} \right) \quad (1)$$

3.2 유한요소 모델 구축

본 연구에서는 액중 방전 성형을 해석적으로 구현하기 위해서 LS-DYNA 프로그램을 사용하여 유한요소 모델을 구축하였고 해석 결과를 통해 인공신경망 모델을 구축하기 위한 데이터를 확보하였다.

액중 방전 성형 장비의 유한 요소 모델은 구조부와 유체부로 나뉜다. 구조부는 금형(die), 챔버(chamber), 시편(blank)으로 구성되며 유체부는 플라즈마, 공기, 유체로 구성된다(Fig. 3). 해석의 효율을 위해 1/4 모델을 사용하였다.

구조부는 shell 요소를 사용하였으며 금형과 챔버는 폭발력에 영향을 받지 않도록 강체라고 가정하였다. 성형되는 소재의 구성방정식을 사용한 소성 변형을 구현하기 위해 *MAT_024_PIECEWISE_LINEAR_PLASTICITY 키워드를 사용하였으며 식 (1)을 사용하여 0.001, 10, 100, 1000, 10000 s⁻¹에서의 응력-변형률 곡선을 입력하였다.

유체부는 solid 요소를 사용하였다. 액중 방전 성형 실험 장비는 전극과 철사를 통해 유체 내에 플라즈마가 생성되지만 이를 구현하는 것은 매우 복잡하기 때문에 반경 1 mm의 구를 플라즈마라고 가정하여 모델링하였으며 Mamutov 등[13]의 선행 연구에 따르면 해석 결과와 실험 결과의 오차가 작은 것을 확인할 수 있다. Fig. 4의 실험으로 획득한 전력 데이터를 *EOS_LINEAR_POLYNOMIAL_WITH_ENERGY_LEAK 키워드에 입력시켜 플라즈마의 폭발을 구현하였다. 플라즈마의 폭발에 따른 유체의 이동을 관찰하기 위해서는 플라즈마와 유체의 상호 작용 및 유체 파트의 이동이 구현되어야 한다. 따라서 본 연구에서는 유체 간 상호 작용이 가능하고 유체 파트의 이동을 관찰할 수 있는 ALE(Arbitrary Lagrange




Fig. 4 Electrical power curve at 6, 7, 8 kV




Fig. 5 Deformation of blank in finite element analysis




Fig. 6 Structure of Artificial Neural Network model

Eulerian) 기법을 사용하였다. ALE 기법은 요소의 뒤 틀림 현상이 없어 순간적으로 큰 힘에 의해 유체가 왜곡 변형하는 액중 방전 성형 해석에 적합하다. 플라즈마의 폭발에 의한 유체의 이동으로 소재가 성형될 수 있도록 유체부와 구조부의 상호작용(FSI; Fluid Structure Interaction)을 위해서 *CONSTRAINED_LAGRANGE_IN_SOLID 키워드를 사용하였다. Fig. 5에서 플라즈마의 폭발에 의한 유체의 이동으로 소

재가 성공적으로 성형되는 것을 확인할 수 있다.

본 연구에서는 6, 7, 8 kV의 입력 전압과 임의의 Cowper-Symonds 파라미터 값에 따른 유한요소 모델의 성형 해석 결과를 대리 모델 구축 데이터로 활용하였다.

4. 인공신경망 기법을 통한 파라미터 역추정

4.1 인공신경망 모델 구축

인공신경망(artificial neural network)은 동물 및 인간의 신경망에서 비롯된 통계학적 학습 알고리즘으로 머신 러닝(machine learning) 기법 중 하나이다. 최초의 인공신경망 모델은 1943년 워런 맥컬록(Warren McCulloch)와 월터 피츠(Walter Pitts)가 구축하였으며 프랑크 로젠블라크(Frank Rosenblatt)가 피드 포워드(feed-forward) 네트워크 및 패턴인식에 관한 알고리즘을 개발하였다. 인공신경망은 2000년대 이후 컴퓨터가 발전되며 급속히 성장하였고, 현재 활발하게 연구되는 학문 분야 중 하나이다. 인공신경망 기법은 학습이 완료된 모델은 학습되지 않은 입력에 대한 출력을 예측할 수 있어 비선형 문제 해결에 큰 활약을 하고 있다[14].

$$Y = \left(\sum_i w_i x_i + b \right) \tag{2}$$

$$\phi(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{3}$$

인공신경망 모델은 Fig. 6과 같이 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)로 구성된다. 입력층에서 입력 데이터(x_i)를 받아 은닉층의 가중치(w_i)와 바이어스(b)를 곱해 활성 함수(ϕ)를 통해 처리된 결과(Y)를 출력층으로 출력한다(식 (2)). 출력 값과 목표 값의 비교를 통하여 오차를 최소화하는 방향으로 가중치와 바이어스 값을 조절하는 역전파(back propagation) 알고리즘을 통해 인공신경망 모델이 훈련된다.

본 연구에서는 매트랩(Matlab) 프로그램의 Neural Network Toolbox를 사용하여 인공신경망 모델을 구

축하였다. 입력 데이터는 식 (1)의 파라미터인 C 와 p 이며 Fig. 7과 같은 훈련 샘플 20개를 라틴 방격 추출법(Latin hypercube sampling)을 통해 추출하여 사용하였다. 은닉층은 100개의 노드를 가진 2개의 층으로 구성하였으며 활성화 함수는 쌍곡탄젠트 시그모이드 함수를 사용하였다(식 (3)). 목표 데이터는 식 (1)에 C, p 값을 대입하여 얻은 응력-변형률 곡선을 6, 7, 8 kV의 세 전압에 대하여 유한요소 해석한 결과의 z 축 변위로, 한 전압당 66개의 노드를 가져 총 198개의 노드를 가진다. 출력 데이터는 목표 데이터와 마찬가지로 198개의 노드를 가지는 데이터로, 입력 데이터에 따른 인공신경망 모델의 결과이다.

$$R^2 = 1 - \frac{\sum_i (Z_i - \hat{Z}_i)^2}{\sum_i (Z_i - \bar{Z}_i)^2} \quad (4)$$

훈련된 인공신경망 모델을 검증하기 위하여 식 (4)와 같은 결정 계수(coefficient of determination, R^2)를 사용하였다. Z_i 는 유한요소 해석 결과, \hat{Z}_i 는 인공신경망 모델의 결과, \bar{Z}_i 는 Z_i 의 평균값이다. 일반적으로 결정계수 값이 0.9 이상일 때 모델은 신뢰성을 가진다[15]. 훈련 샘플 20개를 바탕으로 결정계수를 계산하였을 때의 결과값의 평균은 0.999961이다. 결정 계수의 값이 0.9 이상이므로 신뢰성 있는 모델이

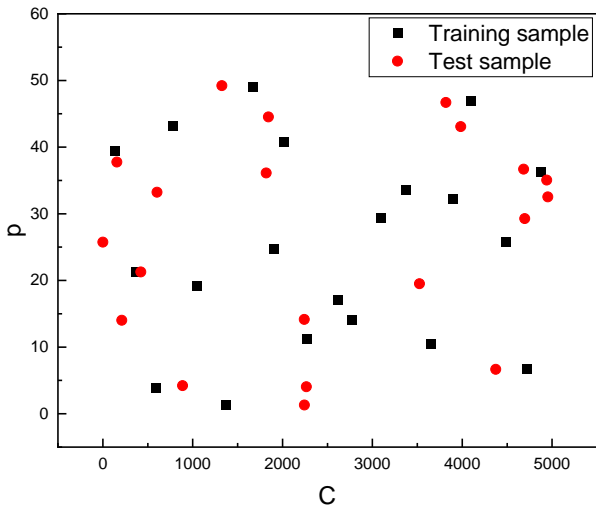


Fig. 7 Training and Test samples of parameter C and p

라고 판단할 수 있지만 이는 훈련된 인공신경망 모델이 훈련 데이터를 기반으로 구성되었기 때문에 당연한 결과이다. 인공신경망 모델이 임의의 입력 데이터에서도 결과를 잘 예측하는지 파악하기 위하여 랜덤 샘플링(random sampling)으로 20개의 시험 데이터를 추출하여 검증하였다. 시험 샘플을 바탕으로 결정계수를 계산하였을 때 결정 계수의 평균값은 0.999237로, 신뢰 범위 안에 있기 때문에 인공신경망 모델이 신뢰성을 갖추었다고 판단하였다(Fig. 8).

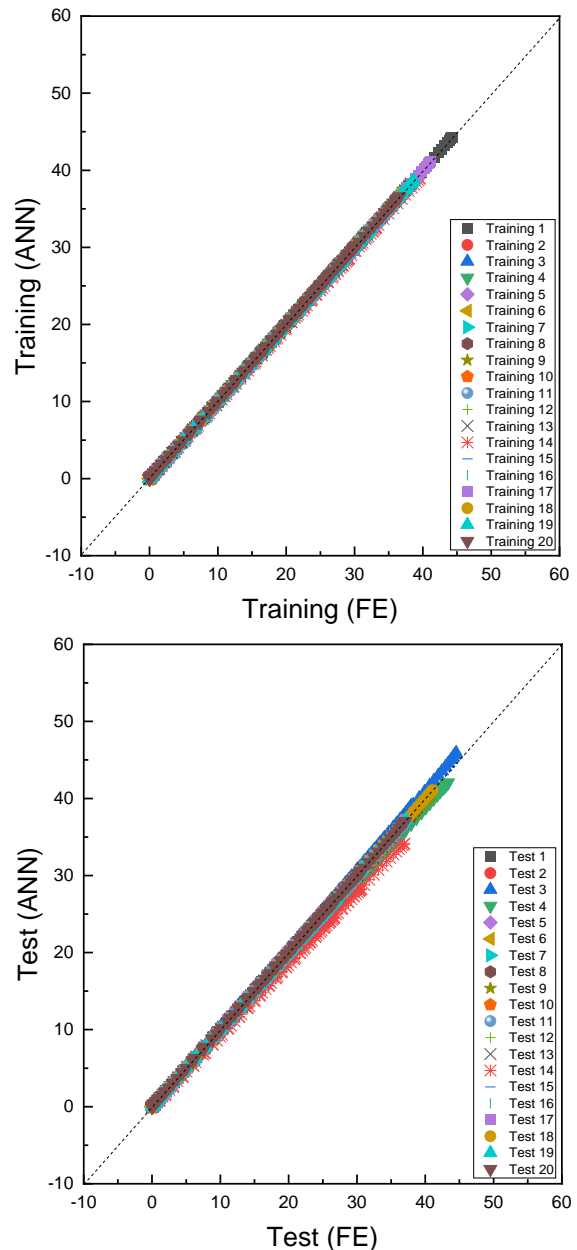


Fig. 8 Coefficient of determination of ANN model

4.2 파라미터 역추정

$$MSE = \frac{1}{n} \sum_i \left(Z_i - \hat{Z}_i \right)^2 \quad (5)$$

$$SMAPE = \frac{2}{n} \sum_i \frac{\left| Z_i - \hat{Z}_i \right|}{\left(\left| Z_i \right| + \left| \hat{Z}_i \right| \right)} \quad (6)$$

구축 및 신뢰성 검증을 마친 인공신경망 모델로부터 액중 방전 성형 실험 결과와 최소한의 오차를 지니는 파라미터를 역추정하기 위하여 식 (5)와 같은 평균 제곱 오차(mean squared error, MSE)와 유전자 알고리즘(genetic algorithm)을 사용하였다. 유전자 알고리즘은 생물의 진화 과정을 모방한 것으로 부모 세대에서 임의의 해를 추출하여 다음 세대로 넘어 갈수록 진화하여 정답에 근접하게 하는 최적화 기법이다. 유전자 알고리즘을 통해 임의의 파라미터를 뽑아 인공신경망에 입력한 후 도출된 결과와 실험 값과의 평균 제곱 오차 값이 최소가 되도록 반복 계산하여 최종 파라미터를 획득하였다. Z_i 는 실험 결과, \hat{Z}_i 는 인공신경망 모델의 결과, n 은 데이터의 개수이다. 평균 제곱 오차는 0에 가까울수록 신뢰성이 높고, 대체로 1.0 이하일 때 신뢰성이 있다고 판단한다[16].

유전자 알고리즘을 통해 평균 제곱 오차가 최소인 파라미터를 도출하였고 그 값은 $C = 3377.4$, $p = 8.6$ 이다. 이를 식 (1)에 입력하여 변형률 속도 그래프로 나타내면 Fig. 9와 같다. 획득한 파라미터의 신뢰성을 판단하기 위해 두 종류의 성능 평가 지표 함수를 사용하였다. 파라미터를 유한요소 해석에 입력한 결과, 인공신경망 모델의 결과와 실험 결과의 평균 제곱 오차와 식 (6)과 같은 대칭 평균 절대 백분율 오차(symmetric mean absolute percentage error, SMAPE)를 비교하여 각각 Table 3, 4에 나타냈다. 대칭 평균 절대 백분율 오차는 0에서 2의 값을 가지며, 0에 가까울수록 신뢰성이 높다[17]. Fig. 10, 11, 12에 각각 6, 7, 8 kV에서 획득한 파라미터로 유한요소 해석한 결과, 실험 결과와 인공신경망 모델의 결과를 비교하였다. 최대 평균 제곱 오차와 대칭 평균 절대 백분율 오차는 6 kV의 실험과 ANN의 비교에서 각각 약 0.71, 0.34이다. 이 경우의 최대 변형률

이 차이는 약 1.67 mm이다.

세 전압 조건에서 MSE가 모두 신뢰 범위 안에 있고 SMAPE가 대체로 0에 가까우며, 세 전압에 대한 성형 형상과 최대 변형 높이를 비교하였을 때 거의 동일하기 때문에 인공신경망 기법을 통하여 획득한 파라미터가 신뢰성을 가진다고 판단된다.

Table 3 MSE between experiment, LS-DYNA and ANN

MSE			
Case	6 kV	7 kV	8 kV
Experiment vs LS-DYNA	0.62	0.33	0.06
Experiment vs ANN	0.71	0.21	0.02
LS-DYNA vs ANN	0.02	0.01	0.01

Table 4 SMAPE between experiment, LS-DYNA and ANN

SMAPE			
Case	6 kV	7 kV	8 kV
Experiment vs LS-DYNA	0.22	0.21	0.12
Experiment vs ANN	0.34	0.07	0.08
LS-DYNA vs ANN	0.19	0.15	0.11




Fig. 9 Estimated stress-strain curve at various strain rates of Al 5052-H34




Fig. 10 Comparison of z-displacement at 6 kV




Fig. 11 Comparison of z-displacement at 7 kV

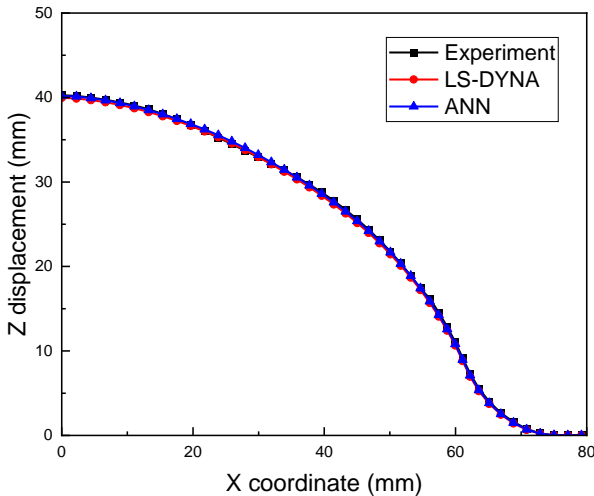


Fig. 12 Comparison of z-displacement at 8 kV

5. 결론

본 연구에서는 액중 방전 성형과 유한요소 해석 및 인공지능망 기법을 사용하여 AI 5052-H34 소재의 세 전압 조건에 대한 동적 물성을 역추정하였고 그에 따른 결론은 다음과 같다.

(1) LS-Dyna 프로그램을 사용하여 액중 방전 성형 기법을 해석적으로 구현할 수 있는 유한요소 모델을 구축하였다. 6, 7, 8 kV의 세 전압에 대한 실험으로 획득한 전력 그래프를 통하여 세 실험 조건에서의 유한요소 해석이 가능하다.

(2) Cowper-Symonds 구성방정식의 파라미터 C , p 로 인공지능망 모델을 구성하였고 실험 결과와 비교하여 오차가 가장 작은 파라미터 값은 $C = 3377.4$, $p = 8.6$ 이다.

(3) 획득한 파라미터의 신뢰성을 판단하기 위하여 파라미터를 대입한 유한요소 해석 결과, 실험 결과 및 인공지능망 모델의 결과를 비교하였다. 최대 결정 계수와 대칭 평균 절대 백분율 오차는 6 kV의 실험 결과와 인공지능망 모델의 비교에서 각각 0.71, 0.34이다. 세 전압 조건에서 성형 형상과 최대 성형 높이가 비슷하고, 오차 함수의 값이 신뢰 범위에 있기 때문에 획득한 파라미터는 신뢰성을 가진다고 판단된다.

(4) 역추정한 파라미터로 획득한 물성이 다른 실험 조건에서도 유효한지 판단하기 위하여 다른 조건에서의 실험 결과와 비교가 필요하다.

후 기

이 연구는 2020년 정부(과학기술정보통신부)의 재원으로 한국연구재단 4 단계 BK21 사업의 지원과 2019년도 정부(미래창조과학부)의 재원으로 한국연구재단의 선도연구센터지원사업(No.2019R1A5A6099595)과 2020년도 정부(미래창조과학부)의 재원으로 한국연구재단의 이공학개인기초연구지원사업(No.NRF-2020R111A3A04036865)의 지원을 받아 수행된 연구임. 이에 관계자 여러분께 감사드립니다.

REFERENCES

- [1] J. W. Park, 2002, Progress in Sheet Metal Forming Technology, Trans. Mater. Process., Vol. 11, No. 3, 223~230, <https://doi.org/10.5228/KSPP.2002.11.3.223>

- [2] S. F. Golovashchenko, A. J. Gillard, A. V. Mamutov, 2013, Formability of dual phase steels in electrohydraulic forming, *J. Mater. Process. Technol.*, Vol. 213, No. 7, pp. 1191~1212, <https://doi.org/10.1016/j.jmatprotec.2013.01.026>
- [3] J. Y. Shim and B. Y. Kang, 2017, Development of Electrohydraulic Forming Process for Aluminum Sheet with Sharp Edge, *Adv. Mater. Sci. Eng.*, Vol. 2017, Article ID 2715092, 10 pages, <https://doi.org/10.1155/2017/2715092>
- [4] M. A. Woo, H. G. Noh, W. J. Song, B. S. Kang, J. Kim, 2017, Development of Electrohydraulic Forming Apparatus and Its Experimental Study, *Trans. Kor. Soc. Auto. Eng.*, Vol. 25, No. 2, pp. 236~241, <https://doi.org/10.7467/ksae.2017.25.2.236>
- [5] M. A. Woo, W. J. Song, B. S. Kang, J. Kim, 2019, Acquisition and Evaluation of Theoretical Forming Limit Diagram of Al 6061-T6 in Electrohydraulic Forming Process, *Met.*, Vol. 9, No. 4, p. 401, <https://doi.org/10.3390/met9040401>
- [6] H. Yu, Q. Zheng, 2019, Forming Limit Diagram of DP600 Steel Sheets During Electrohydraulic Forming, *Int. J. Adv. Manuf. Technol.*, Vol. 104, No. 1-4, pp. 743~756, <https://doi.org/10.1007/s00170-019-03885-x>
- [7] W. J. Kang, S. T. Kim, 2011, High Strain Rate Tensile Test of Composite Material for Automotive Front End Module Carrier, *Kor. Soc. Compos. Mater.*, Vol. 24, No. 3, pp. 12~16, <https://doi.org/10.7234/KSCM.2011.24.3.012>
- [8] S. Y. Ha, J. H. Jang, H. J. Yoon, K. T. Kim, 2016, High-Strain Rate Tensile Behavior of Pure Aluminum Single and Multi-Crystalline Materials with a Tensile Split Hopkinson Bar, *Trans. Kor. Soc. Mech. Eng. A*, Vol. 40, No. 1, pp. 23~31, <https://doi.org/10.3795/KSME-A.2016.40.1.023>
- [9] Y. B. Kim, J. Kim, 2020, Acquisition and Verification of Dynamic Compression Properties for Split Hopkinson Pressure Bar of Urethane, *Trans. Kor. Soc. Mech. Eng. A*, Vol. 44, No. 12, pp. 923~931, 2020
- [10] H. B. Moon, G. P. Kang, K. Lee, and Y. H. Kim, 2021, Development of Artificial Intelligence Constitutive Equation Model Using Deep Learning, *Trans. Mater. Process.*, Vol. 30, No. 4, pp. 186~194, <https://doi.org/10.5228/KSTP.2021.30.4.186>
- [11] D. C. Yang, J. H. Lee, K. H. Yoon, and J. S. Kim, 2020, A Study on the Prediction of Optimized Injection Molding Condition using Artificial Neural Network (ANN), *Trans. Mater. Process.*, Vol. 29, No. 4, pp. 218~228, <https://doi.org/10.5228/KSTP.2020.29.4.218>
- [12] M. A. Woo, S. M. Lee, K. H. Lee, W. J. Song, J. Kim, 2018, Application of an Artificial Neural Network Model to Obtain Constitutive Equation Parameters of Materials in High Speed Forming Process, *Trans. Mater. Process.*, Vol. 27, No. 6, pp. 331~338, <https://doi.org/10.5228/KSTP.2018.27.6.331>
- [13] A. V. Mamutov, S. F. Golovashchenko, V. S. Mamutov, J. J. F. Bonnen, 2015, Modeling of electrohydraulic forming of sheet metal parts, *J. Mater. Process. Technol.*, Vol. 219, pp. 84~100, <https://doi.org/10.1016/j.jmatprotec.2014.11.045>
- [14] S. H. Yoo, C. K. Ahn, 2017, Introduction and development trend of artificial neural network, *Kor. Inst. Electr., Eng.*, Seoul, pp. 36~41
- [15] A. Forrester, K. Andy, 2008, *Engineering design via surrogate modelling: a practical guide*. John Wiley & Sons.
- [16] S. C. Lee, J. Kim, 2021, Acquisition of Parameters for Impact Damage Analysis of Sheet Molding Compound Based on Artificial Neural Network, *Compos. Res.*, Vol. 34, No. 2, pp. 115~122, <https://doi.org/10.7234/composres.2021.34.2.115>
- [17] K. H. Shin, C. Kim, S. H. Nam, S. J. Park, S. S. Yoo, 2018, Estimation Method of Predicted Time Series Data Based on Absolute Maximum Value, *J. Energy Eng.*, Vol. 27, No. 4, pp. 103~110, <https://doi.org/10.5855/ENERGY.2018.27.4.103>