

고속 성형 공정에서 재료의 구성 방정식 파라미터 획득을 위한 인공신경망 모델의 적용

우민아¹ · 이승민¹ · 이경훈¹ · 송우진² · 김정^{1#}

Application of an Artificial Neural Network Model to Obtain Constitutive Equation Parameters of Materials in High Speed Forming Process

M. A. Woo, S. M. Lee, K. H. Lee, W. J. Song, J. Kim

(Received August 22, 2018 / Revised September 21, 2018 / Accepted October 1, 2018)

Abstract

Electrohydraulic forming (EHF) process is a high speed forming process that utilizes the electric energy discharge in fluid-filled chamber to deform a sheet material. This process is completed in a very short time of less than 1ms. Therefore, finite element analysis is essential to observe the deformation mechanism of the material in detail. In addition, to perform the numerical simulation of EHF, the material properties obtained from the high-speed status, not quasi static conditions, should be applied. In this study, to obtain the parameters in the constitutive equation of Al 6061-T6 at high strain rate condition, a surrogate model using an artificial neural network (ANN) technique was employed. Using the results of the numerical simulation with free-bulging die in LS-DYNA, the surrogate model was constructed by ANN technique. By comparing the z-displacement with respect to the x-axis position in the experiment with the z-displacement in the ANN model, the parameters for the smallest error are obtained. Finally, the acquired parameters were validated by comparing the results of the finite element analysis, the ANN model and the experiment.

Key Words: Electrohydraulic Forming, High Speed Forming, Constitutive Equation, Artificial Neural Network

1. 서 론

최근 성형 기술이 발달함에 따라 액중 방전 성형 (electrohydraulic forming), 전자기 성형 (electromagnetic forming), 폭발 성형 (explosive forming) 과 같은 고속 성형 기술이 많이 개발되었다. 고속 성형은 수백 ms 이내의 짧은 시간동안 소재를 성형하는 기술이며, 이러한 조건에서 변형하는 소재의 변형률 속도는 1000 s^{-1} 이상이다. 선행 연구들에 의하면 소재가 고속으로 성형될 때 관성 효과와 높은 변형률 속도에

서의 연신을 증가로 인해 소재의 성형성이 향상될 수 있다. [1-4] 이러한 성형성 향상은 참고문헌 [4]의 준 정적 조건과 고속 조건에서의 성형 한계선도 (forming limit diagram) 비교로부터 확인할 수 있다.

고속 성형 공정은 일반적인 성형 공정에서 사용되는 펀치가 아닌 충격파를 이용하여 판재를 성형한다. 여러 고속 성형 중에서 액중 방전 성형은 유체 내부에서의 전기 에너지 방전으로 인한 유체의 압력파를 이용하여 판재를 목적 형상으로 성형한다.

Fig. 1에 액중 방전 성형 공정의 개략도가 제시되

1. 부산대학교 항공우주공학과

2. 부산대학교 일반대학원 융합학부

Corresponding Author: Pusan National University, E-mail: greatkj@pusan.ac.kr

어 있다. 전기 에너지 저장장치인 커패시터로부터 전기에너지를 방전시키면 전극봉을 통해 유체로 에너지가 전달된다. 그 후, 두 전극봉 사이에 위치한 유체가 전달된 에너지로 인해 플라즈마 상태로 변하고 내부의 에너지에 의해 플라즈마가 팽창된다. 플라즈마가 팽창하여 유체에 충격파를 발생시키고,




Fig. 1 Schematic diagram for electrohydraulic forming process




Fig. 2 Experimental apparatus for electrohydraulic forming

이 충격파가 고속으로 소재를 성형한다. 이러한 과정은 수백 ms 이내의 아주 짧은 시간동안 고속으로 발생하며, 성형 속도는 100 m/s 이상이다.

액중 방전 성형의 경우 소재의 성형이 아주 짧은

시간 내에 완료되고, 실험이 폐공간에서 이루어지기 때문에 실험 과정 중에는 소재의 성형 과정을 제대로 관찰할 수 없다. 따라서 액중 방전 성형 공정을 제대로 연구하기 위해서는 실험 뿐만 아니라 유한 요소 해석이 필수적이다. 또한, 유한 요소 해석을 수행하기 위해서는 변형되는 소재의 물성치가 중요하다. 유한 요소 해석 모델에 물성치를 제대로 입력하지 않으면 실험에서 획득한 결과와의 비교에서 오차가 크게 발생하기 때문에 유한 요소 해석의 신뢰성을 확보할 수 없다.

일반적으로 $10^3 \sim 10^4 \text{ s}^{-1}$ 범위의 고 변형률 속도에서 소재 물성치는 홉킨슨바(split Hopkinson pressure bar, SHPB) 실험으로부터 획득한다. 홉킨슨바 실험은 소재를 강도가 높은 긴 원형 봉 사이에 위치시키고 봉에 가해지는 충격에 의해 발생하는 탄성파를 측정하여 소재의 물성치를 획득하는 방법이다[5~7]. 그러나 홉킨슨바 실험은 실험 장치와 탄성파를 측정하기 위한 측정 장비를 구비하는데 많은 비용이 발생하며, 압축힘에 의해 변형된 소재의 물성치를 획득하기 때문에 인장력이 주로 발생하는 판재 성형 해석에는 적합하지 않다는 단점이 있다.

따라서 본 논문에서는 비용이 많이 발생하는 물성치 획득 실험 대신 대체 모델(surrogate model)을 이용하여 Al 6061-T6의 물성치를 표현하는 구성방정식의 파라미터를 역 추정하여 획득하였다. 인공신경망(artificial neural networks, ANN) 기법을 적용하여 파라미터 값에 따른 유한 요소 해석 결과를 대신할 수 있는 대체 모델을 구성하고, 실험 결과와의 비교를 통해서 오차가 가장 작은 파라미터를 선정하였다. 선정된 파라미터를 이용하여 변형률 속도에 따른 소재의 물성치를 획득할 수 있고 이 물성치를 해석에 적용함으로써 해석의 신뢰성을 확보할 수 있다.

2. 자유 벌징 금형을 이용한 액중 방전 성형 실험

일반적으로 액중 방전 성형 실험 장치는 금형, 챔버, 커패시터, 전극봉으로 구성되며, 본 연구에 사용된 금형, 챔버, 그리고 전극봉을 Fig. 2에 나타내었다. 고속 성형의 경우, 소재가 변형될 때 금형과의 접촉 조건에 의해 성형성이 달라진다. [8~9] 따라서 소재의 물성치를 정확하게 획득하기 위해서는 변형되는

소재가 금형과 접촉이 없어야 하므로 본 연구에서는 자유 벌징 금형을 사용하였다. Fig. 2(b)와 같이 전극봉 사이에 아주 얇은 스테인리스 소재의 와이어가 연결되어 있는데 이는 전극봉 사이로 전기 에너지가 집중되게 하기 위함이다. 와이어를 제외하고 실험을 수행하면 전극봉 사이의 유체가 플라즈마 상태로 변하기 전에 전극봉 주변의 유체로 전기 에너지가 전달되어 폭발을 발생시킬 에너지가 소실되므로 큰 폭발력이 발생하지 않는다. 따라서 Fig. 2(b)와 같이 와이어를 연결하여, 와이어가 터짐과 동시에 폭발력이 전극봉 사이에 집중하여 발생할 수 있도록 하였다.

커패시터는 최대 32 kJ의 에너지를 발생시킬 수 있으며, 본 논문에서는 8 kV의 입력 전압을 사용하여 약 10 kJ의 에너지로 소재를 성형하였다. 커패시터에 전압을 충전한 후 방전 스위치를 이용해 방전시키면 커패시터와 연결된 전극봉을 통해 Fig. 3과 같은 전류가 액중 방전 성형 장치를 구성하고 있는 RLC 회로에 발생한다. 전달된 전기 에너지에 의해 전극봉 끝단부 사이에 위치한 유체가 플라즈마 상태로 변하고, 팽창된 플라즈마로 인해 발생한 유체의 압력파가 소재를 성형한다.

실험에 사용된 소재는 두께 1 mm의 Al 6061-T6이며, 크기는 250 X 250 mm² 이다. 8 kV의 전압을 방전했을 때 성형된 소재의 형상은 Fig. 4와 같으며, 최대 변형 높이는 약 29.7 mm이다. 3D scanning 장비를 이용하여 소재의 z축 변위를 측정하였으며, 변형 형상이 대칭이므로 중앙의 최대점을 기준으로 오른쪽의 결과만 나타내었다.




Fig. 3 Current curve from the experiment at 8 kV

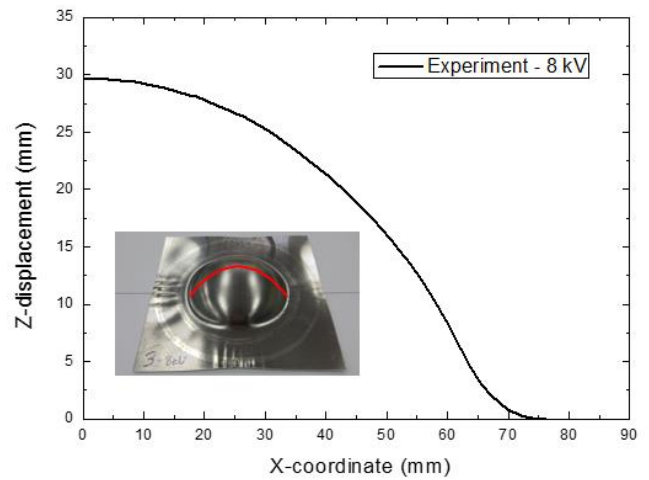


Fig. 4 Final deformation shape of Al 6061-T6 at 8 kV




Fig. 5 Finite element model for electrohydraulic forming

3. 액중 방전 성형의 유한 요소 해석

인공신경망 기법을 이용한 대체 모델 구성을 위해서 LS-DYNA 프로그램을 이용하여 유한 요소 해석을 수행하였다. 액중 방전 성형의 유한 요소 모델은 Fig. 5와 같이 크게 유체부(물, 플라즈마, 공기)와 구조부(판재, 금형, 챔버)로 이루어져 있으며 해석의 효율을 위해 1/4 모델을 사용하였다.




Fig. 6 Training samples with respect to C and p values

유체부를 모델링하기 위하여 일반적인 유체 해석에 사용되는 오일러리안(eulerian) 요소가 아닌 Arbitrary Lagrange-Eulerian (ALE)를 이용하였다. ALE 요소는 요소 뒤틀림 현상이 없기 때문에 대변형이 발생하는 해석에 주로 사용된다. 액중 방전 성형은 유체부의 폭발로 인해 아주 짧은 시간 내에 유체부의 변형이 크게 발생하기 때문에 오일러리안 요소를 사용하는 것 보다는 ALE를 사용하는 것이 더 효율적이다.

구조부의 소재, 금형, 챔버는 shell 요소를 이용해 모델링하였으며, 금형과 챔버는 강체로 가정하였다. 또한, 실험과 동일한 조건에서 성형이 이루어질 수 있도록 금형의 무게와 볼트 체결력을 합하여 Blank Holder Force를 계산하였고, 금형의 윗면에 하중으로 부과하였다.

액중 방전 성형은 100 m/s 이상의 고속으로 소재를 성형하므로 변형률 속도를 고려한 소재의 물성치를

해석에 입력해야 한다. 따라서 식 (1)과 같이 변형률 속도항이 고려된 Cowper-Symonds 구성방정식을 적용하였다.

$$\bar{\sigma} = \sigma_0 \left[1 + \left(\frac{\dot{\epsilon}}{C} \right)^{1/p} \right], \quad \sigma_0 = A + B\epsilon^n \quad (1)$$

식 (1)에서 σ_0 는 준 정적 인장 조건에서의 변형률 경화 곡선($A = 291.85\text{MPa}$, $B = 451.52\text{MPa}$, $n = 0.666$), $\dot{\epsilon}$ 은 변형률 속도, 그리고 C와 p는 대체 모델을 이용하여 획득해야 할 변형률 속도 파라미터이다. 최적의 파라미터 값을 찾기 위해 Fig. 6과 같이 Latin hypercube sampling (LHS) 기법을 이용하여 훈련 데이터(training sample) 20개를 추출하였고, 추출한 [C, p] 데이터를 식 (1)에 대입한 후 변형률 속도 0.00067, 10, 100, 1000, 4000 s^{-1} 에서의 응력-변형률 선도를 해석에 입력하였다. LS-DYNA의 경우, 입력한 변형률 속도 영역 내에서는 보간법을 적용하여 응력-변형률 선도가 계산된다.

Fig. 7과 같이 유한 요소 해석 결과로부터 파라미터 값에 따른 소재의 변형 형상(z-displacement)을 추출하여 4장의 대체 모델 구성 과정에 사용하였다.

4. 인공신경망을 이용한 대체 모델 구성

인공 신경망(artificial neural network, ANN)은 머신러닝(machine learning) 방법 중 하나로 인간이 의사 결정을 하는 신경세포 회로를 모델화한 기법으로 입력 데이터를 받아 반복적인 학습을 통해 결과값




Fig. 7 Deformation results in the numerical simulation




Fig. 8 A general structure of artificial neural network




Fig. 9 A system of neural networks to estimate the parameters




Fig. 10 Final deformation shapes of the blank at different parameters




Fig. 11 Test samples from random sampling

을 출력한다. 인공신경망 모델은 1943년에 처음으로 제안되어 현재까지도 많은 분야에 적용되며[10], 선형 결과 뿐만 아니라 복잡한 비선형 결과도 매우 효과적으로 예측할 수 있다. 학습 초반에는 입력과 출력 사이의 관계를 정확하게 예측하지 못하지만, 점진적인 학습을 통해서 입력-출력 사이의 관계를 형성해주며, 학습이 완료된 후에는 학습되지 않은 입력에 대해서도 출력을 예측할 수 있다.

인공신경망 모델은 Fig. 8과 같이 크게 입력 계층 (Input layer), 은닉 계층(Hidden layer), 출력 계층 (Output layer)으로 이루어져 있다. 입력 계층으로 입력 신호 x_i 를 받아 가중치 w_{ij} 를 이용해 계산을 한 후 출력계층으로 신호 Z_j 를 출력한다. 출력값과 원하는 목표값의 비교를 통해서 오차를 줄이는 방향으로 은닉계층 내부의 가중치를 조절하는 역전파 (back propagation) 알고리즘을 통해서 예측의 정확도를 높인다. 이러한 과정에는 식 (2)와 (3)이 적용된다.

$$u = \sum x_i w_{ij} \tag{2}$$

$$Z_j = f(u) \tag{3}$$

식 (2)로부터 획득된 순 입력값 u 를 전달 함수 (transfer function)인 f 로 처리하여 결과 Z_j 를 출력한다. 이 때 전달함수는 계단 함수(step function), 시그모이드 함수(sigmoid function) 등이 있으며, 본 연구에서는 전달 함수로 식 (4)와 같은 시그모이드 함수를 적용했다.

$$f(u) = \frac{1}{1 + e^{-u}} \tag{4}$$

MATLAB 프로그램 내의 Neural Networks Toolbox를 이용하여 Fig. 9과 같이 2개의 은닉층으로 이루어진 인공신경망 기반 대체 모델을 구성하였다. 이 모델에서 입력값 x_i 는 식 (1)의 파라미터 C와 p이며, 결과값 Z_j 는 변형된 소재의 z축 변위다.

Table 1 Numerical validation of the surrogate model with training samples based on ANN

Training samples			
Case	R ²	RMSE	MARR
1	9.9999 × 10 ⁻¹	1.3540 × 10 ⁻³	3.4606 × 10 ⁻⁴
2	9.9999 × 10 ⁻¹	5.7596 × 10 ⁻⁴	5.0635 × 10 ⁻⁴
3	9.9999 × 10 ⁻¹	1.1243 × 10 ⁻³	1.3471 × 10 ⁻⁴
4	9.9999 × 10 ⁻¹	2.3382 × 10 ⁻³	2.0797 × 10 ⁻⁴
5	9.9999 × 10 ⁻¹	6.9922 × 10 ⁻⁴	1.1008 × 10 ⁻⁴
6	9.9999 × 10 ⁻¹	1.6556 × 10 ⁻³	4.3106 × 10 ⁻⁴
7	9.9999 × 10 ⁻¹	1.7496 × 10 ⁻³	4.1496 × 10 ⁻⁴
8	9.9999 × 10 ⁻¹	1.3914 × 10 ⁻³	6.0716 × 10 ⁻⁴
9	9.9999 × 10 ⁻¹	9.2085 × 10 ⁻⁴	3.3763 × 10 ⁻⁴
10	9.9999 × 10 ⁻¹	1.5931 × 10 ⁻³	1.5027 × 10 ⁻⁴
11	9.9999 × 10 ⁻¹	1.7084 × 10 ⁻³	2.1953 × 10 ⁻⁴
12	9.9999 × 10 ⁻¹	2.0712 × 10 ⁻³	4.2918 × 10 ⁻⁴
13	9.9999 × 10 ⁻¹	1.6043 × 10 ⁻³	2.2650 × 10 ⁻⁴
14	9.9999 × 10 ⁻¹	1.8370 × 10 ⁻³	2.1221 × 10 ⁻⁴
15	9.9999 × 10 ⁻¹	1.1766 × 10 ⁻³	1.8662 × 10 ⁻⁴
16	9.9999 × 10 ⁻¹	1.4299 × 10 ⁻³	5.8771 × 10 ⁻⁴
17	9.9999 × 10 ⁻¹	1.8611 × 10 ⁻³	3.6697 × 10 ⁻⁴
18	9.9999 × 10 ⁻¹	1.7134 × 10 ⁻³	1.6026 × 10 ⁻⁴
19	9.9999 × 10 ⁻¹	1.4331 × 10 ⁻³	1.3236 × 10 ⁻⁴
20	9.9999 × 10 ⁻¹	1.3191 × 10 ⁻³	5.0646 × 10 ⁻⁴

Table 2 Numerical validation of the surrogate model with test samples based on ANN

Test samples			
Case	R ²	RMSE	MARR
1	9.9827 × 10 ⁻¹	3.9977 × 10 ⁻¹	3.1410 × 10 ⁻²
2	9.9979 × 10 ⁻¹	1.4899 × 10 ⁻¹	2.8611 × 10 ⁻²
3	9.9730 × 10 ⁻¹	5.2183 × 10 ⁻¹	3.8140 × 10 ⁻²
4	9.9794 × 10 ⁻¹	4.4362 × 10 ⁻¹	4.9774 × 10 ⁻²
5	9.9870 × 10 ⁻¹	3.4128 × 10 ⁻¹	4.2309 × 10 ⁻²
6	9.9557 × 10 ⁻¹	6.3280 × 10 ⁻¹	7.2790 × 10 ⁻²
7	9.9783 × 10 ⁻¹	4.5736 × 10 ⁻¹	5.4148 × 10 ⁻²
8	9.9155 × 10 ⁻¹	9.8690 × 10 ⁻¹	1.1707 × 10 ⁻¹
9	9.9494 × 10 ⁻¹	7.6110 × 10 ⁻¹	7.8428 × 10 ⁻²
10	9.9864 × 10 ⁻¹	3.8353 × 10 ⁻¹	3.2330 × 10 ⁻²
11	9.9993 × 10 ⁻¹	7.7537 × 10 ⁻²	1.2564 × 10 ⁻²
12	9.9978 × 10 ⁻¹	1.5480 × 10 ⁻¹	1.7959 × 10 ⁻²
13	9.9574 × 10 ⁻¹	6.3406 × 10 ⁻¹	8.8138 × 10 ⁻²
14	9.9948 × 10 ⁻¹	2.2888 × 10 ⁻¹	1.8357 × 10 ⁻²
15	9.9422 × 10 ⁻¹	7.1848 × 10 ⁻¹	7.8115 × 10 ⁻²
16	9.9882 × 10 ⁻¹	3.4635 × 10 ⁻¹	3.2630 × 10 ⁻²
17	9.9669 × 10 ⁻¹	6.1505 × 10 ⁻¹	5.1391 × 10 ⁻²
18	9.9627 × 10 ⁻¹	6.2701 × 10 ⁻¹	6.1974 × 10 ⁻²
19	9.9987 × 10 ⁻¹	1.1025 × 10 ⁻¹	8.7548 × 10 ⁻³
20	9.9658 × 10 ⁻¹	5.7375 × 10 ⁻¹	6.6024 × 10 ⁻²

Fig. 10은 3장의 LHC 기법을 통해 추출한 훈련 데이터 20개를 이용하여 획득한 LS-DYNA 해석 결과를 나타낸 것이다. 이 결과를 인공신경망 모델을 구성하는데 적용하였고, 모델의 신뢰성 판단을 위해 식 (5)~(7)의 R²(coefficient of determination), RMSE(root mean square error), 그리고 MARR(mean absolute relative residual)을 계산하여 표 1에 나타내었다.

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (5)$$

$$RMS = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2} \quad (6)$$

$$MARR = \frac{1}{n} \sum \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

여기서 y_i 는 유한 요소 해석 결과, \bar{y}_i 는 y_i 의 평균, \hat{y}_i 는 대체 모델의 결과, 그리고 n 은 샘플의 개수다. 일반적으로 R²은 0.9 이상일 때, RMSE와 MARR은 0에 가까울 때 대체 모델이 신뢰성을 가진다고 판단한다[11]. 표 1의 결과에서 R²는 9.999e-1 이상, RMSE는 1e-2 이하, MARR은 1e-3 이하이므로 인공신경망 모델이 유한 요소 해석 결과를 잘 예측한다고 판단할 수 있는데 이는 훈련 데이터를 바탕으로 모델을 생성했기 때문에 당연한 결과라고 할 수 있다. 따라서 구성된 모델이 임의의 데이터 입력에서도 결과를 잘 예측할 수 있는지 신뢰도를 확인하기 위하여 Fig. 11과 같이 random sampling으로부터 획득한 임의의 실험 데이터 (test sample) 20개를 이용하여 인공신경망 모델의 결과와 유한요소 해석을 비교하여 오차를 표 2에 나타내었다. 실험 데이터를 입력하였을 때도 R²는 9.99e-1 이상, RMSE은 1.0 이하, MARR은 0.1 이하이므로 대체 모델이 제대로 구성되었다고 판단할 수 있다.

모델의 신뢰성이 확인되었으므로, 인공신경망 모델로부터 실험과 가장 유사한 결과를 나타내는 구성 방정식 파라미터를 찾기 위해 식 (8)과 같이 평균 제곱근 오차(mean square error, MSE)을 이용하였다.




Fig. 12 The plot of error according to C and p values




Fig. 13 Stress-strain curves at different strain rate condition of Al 6061-T6

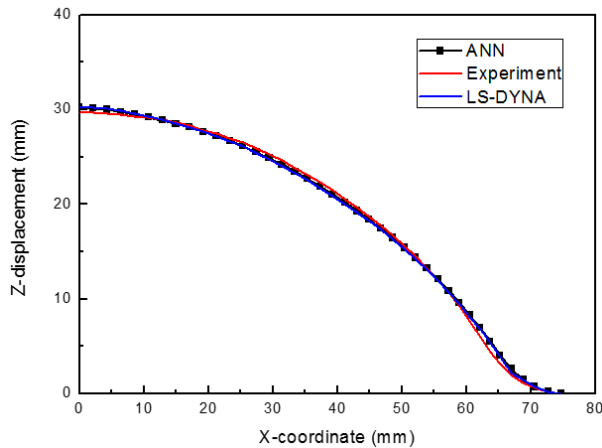


Fig. 14 Comparison of experiment, numerical simulation, and ANN model

$$MSE = \frac{1}{n} \sum (Z(\text{experiment}) - Z'(C, p))^2 \quad (8)$$

Z(experiment)는 실험 결과의 z축 변위, Z'(C, p)는 대체 모델의 결과, 그리고 n은 데이터 개수다. 계산한 평균 제공근 오차를 Fig. 12에 2D 그래프로 나타내었다. Fig. 12로부터 파라미터가 C = 12266, p = 19.19인 경우 오차가 가장 작게 발생하는 것을 알 수 있다. 따라서 획득한 파라미터를 Al 6061-T6의 Cowper-Symonds 구성 방정식에 입력하여 변형률 속도에 따른 그래프로 나타내면 Fig. 13과 같다.

마지막으로, 획득한 물성치의 신뢰성을 확인하기 위하여 해석에 입력한 후, 해석 결과와 인공지능망 모델, 그리고 실험 결과를 비교하여 Fig. 14에 나타내었고, 세가지 경우를 비교한 오차는 표 3과 같다. 최대 평균 제공근 오차는 LS DYNA - Experiment의 비교에서 약 0.2 수준이다. 그러나 Fig. 14에서 알 수 있듯이 변형 형상과 최대 변형 높이가 아주 유사하기 때문에 획득한 파라미터가 신뢰성을 가진다고 판단할 수 있다.

Table 3 Comparison of MSE between ANN, LS-DYNA, and experiment

	ANN - LS-DYNA	LS-DYNA - Experiment	Experiment - ANN
MSE	2.1389×10^{-2}	1.9894×10^{-1}	1.8366×10^{-1}

4. 결론

본 연구에서는 액중 방전 성형 공정 하에서의 Al 6061-T6 소재의 물성 획득을 위해 인공지능망 모델을 이용한 역 매개변수 예측 기법을 적용하였다. 소재의 물성을 표현하는 식으로 Cowper-Symonds 구성 방정식을 선정하였으며, 방정식 내의 변형률 속도 파라미터 C와 p를 예측하여 소재의 응력-변형률 선도를 획득하였다.

먼저 C와 p에 따른 액중 방전 성형의 유한 요소 해석을 수행하였다. Latin Hyper Cube로부터 20개의 훈련 데이터(C, p)를 획득한 후 유한 요소 모델에 입력하여 해석을 수행하였고, 20개의 해석 결과를 바탕으로 인공지능망 기법을 적용하여 유한 요소 해석을 대체할 수 있는 모델을 구성하였다. 또한,

random sampling으로부터 실험 데이터 20개를 추출하여 유한 요소 모델과 대체 모델의 오차를 비교함으로써 인공지능망 기반 대체 모델의 신뢰성을 확보하였다. 마지막으로, 평균 제공근 오차를 계산하여 주어진 [C, p] 범위에서의 인공지능망 모델과 실험 결과를 비교하여 오차가 가장 작은 C와 p를 선정하였다. 획득한 파라미터를 유한 요소 모델에 입력하여 해석한 결과와 대체 모델, 그리고 실험 결과를 비교함으로써 파라미터의 신뢰성을 검증하였다.

본 연구에서는 인공지능망 모델 기반의 역 예측 기법으로 Al 6061-T6의 구성방정식 파라미터를 획득하였다. 획득된 파라미터가 또 다른 조건에서도 유효한지 확인하기 위하여 형상이 다른 금형을 이용한 실험과 유한 요소 해석의 수행이 필요할 것으로 판단된다.

후 기

이 논문은 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단의 선도연구센터지원사업(No.2012R1A5A1048294), 2017년도 정부(미래창조과학부)의 재원으로 한국연구재단의 이공학개인지초연구지원사업(No. NRF-2017R1D1A3B03034265), 그리고 2017년 정부(교육부)의 재원으로 한국연구재단의 글로벌 박사양성사업(NRF-2017H1A2A1042054)의 지원을 받아 수행된 연구임. 이에 관계자 여러분께 감사드립니다.

REFERENCES

- [1] T. Altan, A. E. Tekkaya, 2012, "Sheet metal forming: processes and applications", ASM International.
- [2] S. Golowin, M. Kamal, J. Shang, J. Portier, A. Din, G. S. Daehn, R. Bradley, K. E. Newman, S. Hatkevich, 2007, "Application of a Uniform Press Actuator for Electromagnetic Processes of Sheet Metal", J. Mater. Eng. Perform., Vol. 16, No. 4, pp. 455~460.
- [3] V. Psyk, D. Risch, B. L. Kinsey, A. E. Tekkaya, M. Kleiner. 2011, Electromagnetic forming a review, J. Mater. Process. Tech., Vol. 211, No. 5, pp. 787~829.
- [4] V. S. Balanethiram, G. S. Daehn, 1994, Hyperplasticity: Increased forming limits a high workpiece velocity, Scripta Metallurgica et Materialia(United States), Vol. 30, No. 4. pp. 515~520.
- [5] H. Kolsky, 1949, Stress wave in Solids, Dover, pp.41~65.
- [6] D. T. Chung, 1994, Split Hopkinson Pressure Bar Technique for Stress- strain Measurement, Trans. Korean Soc. Mech. Eng. A, Vol. 18, pp. 33~41
- [7] G. T. Gray, 2012, Classic Split-Hopkinson Pressure Bar Technique, ASM handbook, Mechanical Testing and Evaluation, ASM International, Vol. 8.
- [8] S. F. Golovashchenko, J. G. Alan, V. M. Alexander, 2013, Formability of dual phase steels in electrohydraulic forming, J. Mater. Process. Tech., Vol. 213, No. 7 pp. 1191~1212.
- [9] J. M. Imbert, S. L. Winkler, M. J. Worswick, D. A. Oliveira, S. F. Golovashchenko, 2005, The effect of tool-sheet interaction on damage evolution in electromagnetic forming of aluminum alloy sheet. J. Eng. Mater. Tech., Vol. 127, No. 1, pp. 145~153.
- [10] W. S. McCulloch, P. Walter, 1943, A logical calculus of the ideas immanent in nervous activity, The bulletin of mathematical biophysics, Vol. 5, No. 4, pp. 115~133.
- [11] A. Forrester, K. Andy, 2008, Engineering design via surrogate modelling: a practical guide. John Wiley & Sons.