

# 관성 마찰용접 공정에서 심층 신경망을 이용한 업셋 길이와 업셋 시간의 예측

양영수\*, 배강열\*\*,#

\*전남대학교 기계공학과, \*\*경남과학기술대학교 메카트로닉스공학과

## Prediction of Upset Length and Upset Time in Inertia Friction Welding Process Using Deep Neural Network

Young-Soo Yang\*, Kang-Yul Bae\*\*,#

\*Department of Mechanical Engineering, CN UNIV., \*\*Department of Mechatronics Engineering, GNUST

(Received 30 August 2019; received in revised form 3 September 2019; accepted 12 September 2019)

### ABSTRACT

A deep neural network (DNN) model was proposed to predict the upset in the inertia friction welding process using a database comprising results from a series of FEM analyses. For the database, the upset length, upset beginning time, and upset completion time were extracted from the results of the FEM analyses obtained with various of axial pressure and initial rotational speed. A total of 35 training sets were constructed to train the proposed DNN with 4 hidden layers and 512 neurons in each layer, which can relate the input parameters to the welding results. The mean of the summation of squared error between the predicted results and the true results can be constrained to within  $1.0e-4$  after the training. Further, the network model was tested with another 10 sets of welding input parameters and results for comparison with FEM. The test showed that the relative error of DNN was within 2.8% for the prediction of upset. The results of DNN application revealed that the model could effectively provide welding results with respect to the exactness and cost for each combination of the welding input parameters.

**Key Words** : Inertia Friction Welding(관성 마찰용접), Upset(업셋), Numerical Analysis(수치해석), Process Parameters(공정 매개변수), Deep Neural Network(심층 신경망)

### 1. 서 론

자동차 및 항공 산업 등 여러 분야에서 소재 간 축 이음에 적용되고 있는 마찰용접은 한 축을 고정 위치에서 고속으로 회전하고, 다른 축을 축 방향으로 이동하여 가압한 상태에서 서로 마찰하게 함으로써, 두 축을 결합하는 공정이다<sup>[1]</sup>. 마찰용접은 구동

원의 특징과 상대 운동 방법에 따라 관성 마찰용접, 연속구동 마찰용접, 선형 마찰용접 등으로 구별되고, 관성 마찰용접에서는 Fig. 1에 보인 바와 같이, 한 쪽의 소재는 관성차(flywheel)에 접촉되어 있고 다른 쪽 소재는 회전이 구속되어 있다. 관성차는 미리 정해진 회전수로 가속되어 필요한 에너지를 축적하게 되고, 용접과 동시에 모터와 스피들 등 구동부와의 결합이 해제되면, 자유 회전을 하게 된다. 관성 마찰용접에서 열원은 관성차에 저장된 운

# Corresponding Author : kybae@gntech.ac.kr

Tel: +82-55-751-3384, Fax: +82-55-751-3389

Copyright © The Korean Society of Manufacturing Process Engineers. This is an Open-Access article distributed under the terms of the Creative Commons Attribution-Noncommercial 3.0 License (CC BY-NC 3.0 <http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

동에너지를 용접 소재 접촉부에서의 열에너지로 변환함으로써 얻게 되고, 가압력, 초기 회전 속력, 질량관성모멘트가 용접 입력 매개변수가 된다. 연화된 접촉부가 압력에 의해 항복하여 소성 변형이 되면, 두 소재의 접촉면에는 플래시(접촉 표면이 반경 방향으로 밀려남)가 발생하면서 새로운 접합면이 형성되고, 소재에는 업셋(축방향 길이 감소)이 야기된다. 따라서 업셋은 마찰용접의 결과를 나타내는 중요한 기하학적 특성이 된다. 용접부의 접합 강도 등을 기준으로 할 때, 최적의 업셋길이는 재질, 소재 크기, 표면 상태 등에 따라 다양하게 선정될 수 있다. 따라서, 최적 용접조건 설정에 앞서, 먼저 용접조건과 업셋현상과의 관계를 규명하는 것이 필요하다.

마찰용접 공정에서 축의 회전속력 변화 등 용접 조건 선정에 대한 실험적 연구가 다수 보고되어 왔고, 축 압력과 회전 속력의 변화와 최종 용접부 길이 변화와의 연관성을 규명하고자 공정을 모델링하고 해석하는 연구가 진행되어 왔다<sup>[2-4]</sup>.

공정 매개변수의 연속적인 변화에 대한 실험이나 해석을 전부 수행하는 것은 불가능하므로, 가능한 실험적 또는 해석적 결과를 활용하여 추가적인 예측을 하는 것이 효율적이다. 인공지능은 강력한 비선형성과 자기학습력으로 복잡한 공학문제의 해석에 탁월하며, 회귀 모델에 비하여 공정예측 능력이 더 우수한 것으로 보고되고 있다<sup>[5, 6]</sup>. 용접 비드형상 예측과 용접부의 기계적 성질 예측 등에 인공지능모델이 활용되고 있다<sup>[7, 8]</sup>. 마찰용접에도 인공지능이 적용되어, 공정 변수와 접합부 기계적 성질과의 관계를 예측하고 있다. 수치해석 결과를 사용하여 업셋 예측에 관한 3개 층으로 구성된 반경 기반 함수(Radial Basis Function)의 인

공지능 알고리즘이 제시되었고<sup>[3]</sup>, 스테인리스강과 연강의 연속구동 마찰용접 공정에서 1개의 은닉층을 활용한 인공지능망을 이용하여 인장강도와 경도를 예측하는 연구가 수행된 바 있다<sup>[5, 9]</sup>.

본 연구에서는 관성 마찰용접에서 공정 매개변수의 변화에 따른 업셋의 변화를 용이하게 예측할 수 있는 심층 신경망(Deep Neural Network) 모델을 제안하였다. 이를 위해, 중공 실린더 간을 마찰용접하는 공정에 대한 수치해석 모델로써 가압력 및 초기 속력 등의 공정 입력변수에 대한 소재 내 온도 분포와 변형 해석을 수행하고, 해석 결과로부터 업셋 길이와 업셋 발생 및 종료 시간을 도출하였다. 또한, 다양한 용접 입력 파라미터의 조합에 대한 해석을 수행하여, 입력과 용접 결과 사이의 데이터베이스를 구축하였다. 다음으로, 공정 파라미터의 조합으로써 용접 결과를 용이하게 예측할 수 있는 심층 신경망 모델을 구축하고, 해석에서 도출한 데이터베이스를 활용하여, 학습하고 시험하였다.

## 2. 관성 마찰용접공정 해석

### 2.1 공정의 수치해석

관성 마찰용접 공정에서 가열을 위해 활용하는 외부 에너지는 관성차의 운동에너지( $E$ )이고, 마찰에 의해 열로 변환되는 에너지를 고려하면, 다음과 같이 점진적으로 감소하게 된다.

$$E_{t+\delta t} = E_t - \omega(t)\delta t \int_S f_s r dS \tag{1}$$

여기서  $\omega(t)$ 는  $t$  시간에서의 회전 속력,  $\delta t$ 는 증분 시간,  $f_s$ 는 마찰력,  $r$ 은 중심축에서의 반경방향 거리,  $S$ 는 반경  $r$  범위의 미소 면적이다. 관성차가 가진 초기 운동에너지는 관성차의 질량관성모멘트와 초기 회전속력으로 얻어진다.

마찰의 초기 단계에서는, 마찰용력은 가압력에 비례한 크기로 나타나고, 마찰이 지속될 수록, 즉 마찰부에서의 온도가 급격히 상승하여 재질의 유동용력이 급격히 감소하면, 마찰용력( $\tau$ )은 다음과 같은 크기로 나타난다<sup>[10]</sup>.




Fig. 1 Schematic diagram of a typical inertia friction welding machine<sup>[11]</sup>

$$\tau = -\alpha p \mu V_i / |V_i| \quad (2)$$

여기서,  $\alpha$ 는 상수,  $p$ 는 접촉 압력,  $\mu$ 는 마찰계수,  $V_i$ 는 상대 미끄럼 속도이다.

마찰에 의한 열에너지는 용접 접합부에서 다음과 같은 열속(heat flux)으로 나타낼 수 있다.

$$q(r, t) = 2\pi r \tau(r, t) w(t) \quad (3)$$

이와 같은 열속을 접촉 경계조건에서의 입열로 하여, 작업 소재 내의 온도분포를 해석하고, 해석 결과를 열하중으로 활용하여, 소재 내의 변형 및 응력 해석을 수행하게 된다. 본 연구에서는 길이 21 mm, 내부 반경 42 mm, 두께 6 mm이고, 고장력 합금강인 중공 축 2개를 마찰용접하는 공정에 대하여, 온도분포 및 열변형 해석을 수행하였다. 수치해석에서는 상용유한요소해석 프로그램을 활용하였고<sup>[4]</sup>, 두 소재의 형상과 공정을 고려하여, 소재의 해석영역을 2차원 축대칭 모델로 구현하였다. Fig. 2는 용접 공정과 소재 형상을 나타내고, 위는 수치해석을 위해 해석영역으로 설정된 축대칭 면을 유한요소로 분할한 결과를 보여 주고 있다. 온도 구배가 크게 예상되는 접촉부는 0.5 mm의 요소로, 접촉부로부터 먼 위치는 열전도가 낮을 것으로 예상하여 2.0 mm의 요소로 분할하였다. 변위-온도 연성 사각형 요소를 사용하였고, 용접 도중에 발생하는 용접부 주위 요소의 과도한 변형을 방지하기 위해 재요소 기법을 적용하였다<sup>[3, 4]</sup>.




Fig. 2 Workpieces and models for friction welding

온도 변화에 따른 소재의 기계적 열적 특성의 변화를 해석에서 고려하였으며<sup>[4, 11]</sup>, 해석영역 주위로의 대류 열전달을 고려하였고, 우측 소재의 끝을 고정하는 구속 경계조건을 적용하였다.

좌측 소재에 고정된 관성차의 질량관성모멘트는  $102 \text{ kg} \cdot \text{m}^2$ 으로 두고, 우측 소재에 가하는 가압력은 280 Mpa에서 440 Mpa까지 20 Mpa 간격으로 변화하였고, 관성차의 초기 회전 속력은 40 rad/s에서 50 rad/s까지 2.5 rad/s 간격으로 변화하였다. 용접 공정의 해석 시간은 10초이었다.

## 2.2 해석 결과

Fig. 3은 중공 실린더의 마찰용접 과정에서 길이방향 축대칭 단면에서 나타나는 시간의 경과에 따른 업셋의 변화를 보여 주고 있다. 이때의 축압력은 360 Mpa, 초기 회전 속력은 45 rad/s이었고, 2.2초 이전에는 업셋의 발생이 없는 상태이고, 4.4초 이후는 더 이상의 업셋이 없음을 나타낸다.

Fig. 4는 초기 회전 속력을 45 rad/s로 일정하게 두고, 축방향 압력을 320 ~ 400 Mpa로 변화할 때의 공정 해석 결과이다. Fig. 4(a)는 용접 시간에 따른 소재 속력 변화와 접촉부 최대 온도 변화를 보여 주고 있다. 마찰 운동에 의한 마찰열과 전도로 인해 가열부가 접촉부로부터 점차 확대되면, 접촉부에서는 열의 평형이 유지되어, 약 1150°C까지 상승하고 일정 시간 동안 평형상태를 유지하고 있다. 소재의 속력은 시간에 따라 선형적으로 감소하나, 회전 종료 직전에 급격히 감소하고 있다. 이는 마찰 응력의 증가에 기인하고, 또 이로 인해 최대 온도가 다소 상승하는 효과로 나타나고 있다. 소재 속력과 접촉부 최대 온도는 설정된 축방향 압력의 변화에 크게 차이를 보이지 않고 있다.

Fig. 4(b)는 접촉부 최대 온도와 업셋 길이의 변화를 보여 주고 있다. 업셋은 압력이 클수록 이른 시간에 발생하나 대략 2초 전후에 발생하여 4.4초에 종료되고 있다. 관성차의 회전이 정지하면, 더 이상의 업셋이 발생하지 않게 된다. 업셋이 완료된 직후에는 최대 온도가 급감하고, 이후에는 다소 완만하게 감소되고 있다. 이는 접촉부에서의 작은 열 발생보다 전도에 의한 급격한 열의 소멸에 의한 열적 불균형의 초래에 기인한 결과이다.






Fig. 3 Upset and flash developed during friction welding with elapsed time



(a) Rotational speed and maximum interface temperature




(b) Maximum interface temperature and upset length  
Fig. 4 Results of friction welding for different axial pressures with elapsed time

업셋은 시간의 경과에 선형적으로 발생하고, 최종의 업셋 길이는 3.3 ~ 3.9 mm의 크기로 나타나며, 축 압력이 클수록 다소 크게 나타나고 있다.


Fig. 5는 축방향 압력을 360 Mpa로 일정하게 두고, 초기 회전 속력을 40 rad/s에서 50 rad/s로 변화할 때의 공정 해석 결과이다. Fig. 5(a)는 용접 시간에 따른 소재 속력 변화와 접촉부 최대 온도 변화를 보여 주고 있다. 소재는 접촉 후 초기 속력에 따라 4 ~ 5초 사이에서 정지하고 있다. 접촉부 최대 온도는, 발생열과 전도열의 평형이 지속되지 않음에 따라, 소재가 마찰을 종료하는 순간 급감한 후 다시 완만하게 감소됨을 보이고 있다.

Fig. 5(b)는 접촉부 최대 온도와 업셋 길이의 변화를 보여 주고 있다. 업셋은 초기 회전 속력에 따라 1.4 ~ 3.1초 사이에 발생하여, 선형적으로 커진 후, 회전 정지 전인 3.9 ~ 4.8초 사이에서 종료되어, 최종 1.1 ~ 6 mm의 크기로 나타나고 있다.

업셋의 발생이 시작되면, 접촉부의 최고 온도가



(a) Rotational speed and maximum interface temperature



(b) Maximum interface temperature and upset length  
Fig. 5 Results of friction welding for different initial rotational speeds with elapsed time

등은 상태를 유지하고 있음을 알 수 있다. 초기 속력이 클수록, 업셋은 빠르게 발생하며, 늦게 종료되고, 길이가 더 크게 나타나고 있다.

Table 1은 유한요소해석을 통해 예측한 증공 축의 마찰용접에서 축 압력과 초기 회전 속력의 변화에 따른 업셋의 길이, 업셋의 발생 및 종료 시간을 나타내고 있고, 인공지능망 예측 모델을 구축하기 위한 데이터베이스로 활용하였다.

### 3. 업셋 예측 심층 신경망 모델

Fig. 6은 제안된 심층 신경망의 형태를 보여 주고 있고, 수치해석을 통해 확보한 공정 파라미터와 업셋 길이, 업셋 발생 및 종료 시간과의 관계 데이터베이스로써 이를 학습하고 시험하였다. 신경망은 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)으로 구성되며, 축 압력과 초기 회전속력 등 2개 변수를 입력층의 입력 요소로 하고, 업셋 길이, 업셋 시작 시간과 종료 시간 등 3개 변수를 출력층의 출력요소로 한다. 각 층은 가중치 매트릭스로 결합되며, 하나의 층에서 다음 층으로의 출력( $L_k^j$ )은, 다음 방정식 (4)와 같이 앞선 층으로부터의 입력 값( $L_i^{j-1}$ )들에 연결강도인 가중치( $w_{ik}^j$ )를 곱하여 이를 총합하고 편향값( $b^j$ )을 더하여 나타내게 된다.

$$L_k^j = \sum_{i=1}^n L_i^{j-1} w_{ik}^j + b^j \quad (4)$$


여기서  $L_k^j$ 는  $j$ 번 째 은닉층의  $k$ 번 째 요소이고,  $L_i^{j-1}$ 는  $j-1$ 번 째 은닉층의  $i$ 번 째 요소이다.  $w_{ik}^j$ 는 두 층  $j-1$ 와  $j$ 의 각 요소  $i$ 와  $k$ 사이의 가중치이고,  $b^j$ 는 은닉층  $j$ 의 편향값(bias)이다.

이와 같은 과정에서 얻은 요소 값에 활성화 함수를 적용하게 되고, 이 결과가 다음 층의 요소 값이 된다. 여기서 활성화 함수는 ReLU(Rectified Linear Unit) 함수를 적용하였다. 이는 결과 값이 0보다 작을 때는 0으로 만들고, 0보다 큰 값에 대해서는 해당 값을 그대로 출력하는 함수로,

$ReLU(L_k^j) = \max(0, L_k^j)$ 와 같이 나타낼 수 있다. 한편, 마지막 은닉층에서는 최종 출력을 얻기 위해, 식 (5)와 같이, 활성화 함수의 적용 없이 선형 변환을 사용하였다.

**Table 1 Predicted upset lengths, upset beginning times, and upset completion times for different sets of friction welding parameters by finite element analyses**

No.	Axial pressure, Mpa	Initial rotational speed, rad/sec	Upset length, mm	Upset beginning time, sec	Upset completion time, sec
1	280	40	0.59	3.46	3.91
2	280	42.5	1.78	2.82	4.20
3	280	45	3.01	2.12	4.42
4	280	50	5.32	1.54	4.91
5	300	40	0.68	3.38	3.91
6	300	42.5	1.97	2.70	4.17
7	300	47.5	4.36	1.74	4.66
8	300	50	5.50	1.50	4.93
9	320	42.5	2.02	2.60	4.06
10	320	45	3.33	2.02	4.43
11	320	47.5	4.47	1.70	4.67
12	340	40	0.96	3.22	3.89
13	340	42.5	2.23	2.52	4.11
14	340	45	3.42	1.98	4.41
15	340	50	5.92	1.46	4.87
16	360	40	1.10	3.14	3.89
17	360	45	3.63	1.92	4.39
18	360	47.5	4.84	1.64	4.64
19	360	50	5.98	1.42	4.87
20	380	42.5	2.50	2.34	4.10
21	380	45	3.74	1.88	4.40
22	380	47.5	5.01	1.60	4.62
23	380	50	6.27	1.40	4.88
24	400	40	1.33	2.98	3.86
25	400	45	3.85	1.84	4.40
26	400	47.5	5.08	1.58	4.65
27	400	50	6.34	1.38	4.87
28	420	40	1.47	2.90	3.88
29	420	42.5	2.77	2.22	4.13
30	420	47.5	5.31	1.54	4.63
31	420	50	6.56	1.36	4.87
32	440	40	1.68	2.82	3.84
33	440	45	4.22	1.76	4.34
34	440	47.5	5.47	1.52	4.64
35	440	50	6.70	1.32	4.88



**Fig. 6 Proposed architecture of deep neural network for prediction of upset length, upset beginning time, and upset completion time in friction welding**

$$H_k^5 = L_k^5 = \sum_{i=1}^n L_i^4 w_{ik}^5 + b^5 \quad (k=1,2,3) \quad (5)$$

신경망의 학습에 앞서, 임의의 가중치를 부여하여 초기화를 하는 바, 제안된 모델에서는 Xavier 초기화를 적용하였다<sup>[12]</sup>.

제안된 망을 학습하기 위하여, Table 1에 제시된 데이터 중, 입력 변수 값을 망에 통과하게 하여 최종 예측 값을 구하고, 실제 출력 값과 비교하여, 망의 예측능력을 평가하였다. 이 때는 오차 함수로서 식 (6)과 같은 비용(cost) 함수를 적용하였고, 이는 총 학습 데이터의 신경망 출력과 학습 출력과의 오차 제곱의 평균값으로 정의하였다.

$$E(W, b) = \frac{1}{m} \sum_{i=1}^m (H(W, b) - Y)^2 \quad (6)$$

여기서,  $m$ 은 학습 데이터 세트 수이다.

심층 신경망은 오류 역전파 알고리즘으로 반복 학습이 가능하다. 가중치(weight)들은 식 (7)에 나타난 경사 하강법(gradient descent)을 통하여 갱신될 수 있다. 이는 비용함수의 미분값과 학습률(learning rate)의 곱으로써 가중치를 갱신하는 것으로, 최종단계에서의 출력 오차를 줄이기 위해 이전 단계로 돌아가서 가중치를 수정하는 과정이고, 모든 은닉층에서의 가중치를 수정하게 된다<sup>[8]</sup>.

$$\Delta w_{ik} = -\alpha \frac{\partial E}{\partial w_{ik}} \quad (7a)$$

$$\hat{w}_{ik} \leftarrow w_{ik} + \Delta w_{ik} \quad (7b)$$

여기서  $\Delta w_{ik}$ 는 은닉층 가중치 값의 수정치,  $\alpha$ 는 학습률,  $E$ 는 비용함수인 목적함수이다.

제안된 신경망은 주어진 데이터를 통해 반복 학습을 거듭하여, 지능망의 함수가 주어진 결정 함수와 가능한 한 근접하게 되는 가중치의 최적 조합이 지능망의 최종해가 된다. 한편, 이와 같은 학습과정을 통해서, 적합한 은닉층의 수와 뉴런의 수를 결정하기 위하여, 이들의 개수를 일정하게 변화하여 학습 시험을 실시하였다. 이때 학습률은  $1.0e^{-4}$ , 학습회수는 10,000이었다.

심층 신경망 모델의 정도를 높이기 위하여 학습 데이터와 시험 데이터를 식 (8)을 활용하여 0 ~ 1 사이의 값으로 정규화하였고, 출력값은 식을 활용하여 역으로 환산하였다.

$$\bar{x}_k = \frac{x_k - \min(x_k)}{\max(x_k) - \min(x_k)} \quad (8)$$

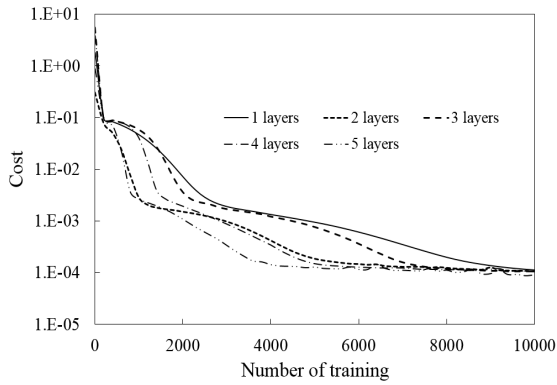
여기서  $\bar{x}_k$ 는 정규화된 데이터, 그리고  $x_k$ 는 학습 또는 시험 데이터를 나타낸다.

한편, 제안된 신경망의 예측 성능은 Table 2에 나타난 시험 데이터를 활용하여 검증하였다.

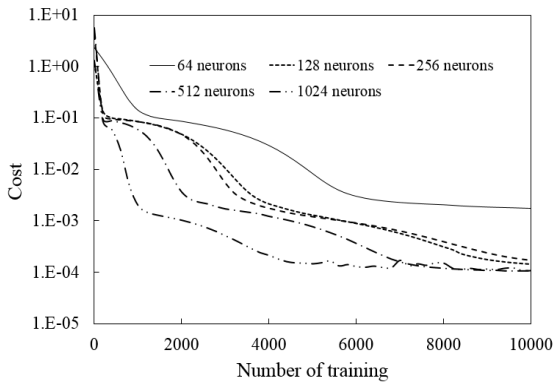
## 4. 결과 및 고찰

마찰용접에 대한 수치해석 결과에서 얻은, Table 1에서 보인 35개 입력과 출력 데이터 세트로써 제안된 신경망을 학습하고, 은닉층의 수와 뉴런의 수에 따른 학습 효과를 조사하였다.

Fig. 7(a)와 (b)에서는 각각 은닉층의 수와 뉴런 요소의 수가 서로 다른 심층 신경망 구조를 학습할 때, 학습도중에 나타나는 비용함수의 변화를 로그 척도로 보여 주고 있다. 대체로 층의 개수와 뉴런의 개수가 증가하면, 빠르게 비용함수의 값이

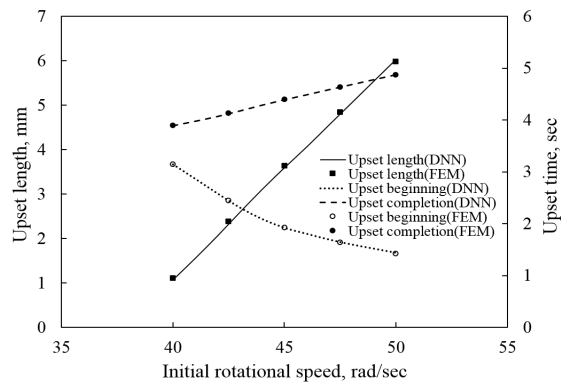


(a) Variation of hidden layers

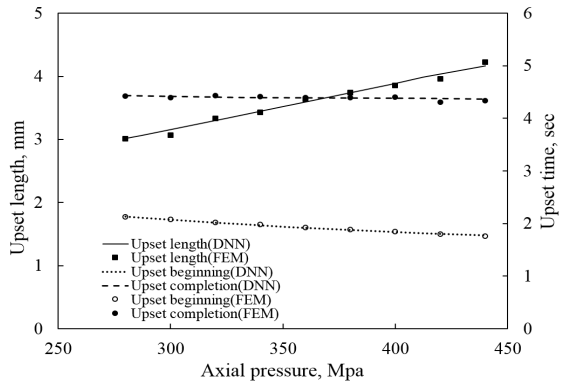


(b) Variation of neurons

Fig. 7 Reduction of mean squared error(cost) for variation of DNN structure during the training procedure



(a) Initial rotational speed



(b) Axial pressure


Fig. 8 Comparison of DNN and FEM predictions for upset length and upset time with variation of welding parameter

Table 2 Predicted results of DNN for the test data sets of 10 cases and comparison with desired target results obtained by FEM

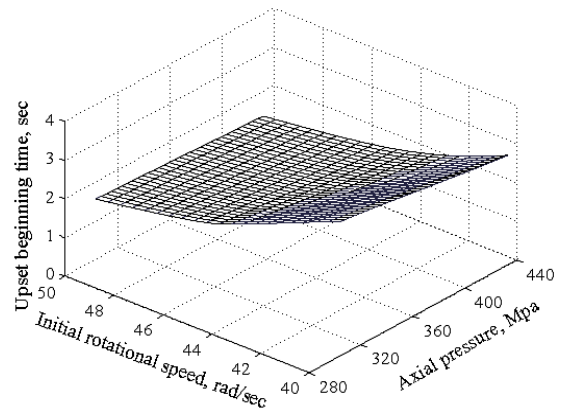
Case	Axial pressure, MPa	Initial rotational speed, rad/sec	Upset length, mm			Upset beginning time, sec			Upset completion time, sec		
			FEM	DNN	Relative error, %	FEM	DNN	Relative error, %	FEM	DNN	Relative error, %
1	280	47.5	4.14	4.15	0.31	1.76	1.80	2.05	4.68	4.68	0.01
2	300	45	3.07	3.15	2.82	2.08	2.08	0.09	4.39	4.42	0.62
3	320	40	0.83	0.82	1.07	3.30	3.32	0.57	3.90	3.89	0.22
4	320	50	5.66	5.68	0.27	1.48	1.49	0.51	4.92	4.90	0.39
5	340	47.5	4.65	4.63	0.35	1.66	1.68	1.22	4.66	4.64	0.40
6	360	42.5	2.39	2.33	2.41	2.44	2.44	0.12	4.13	4.12	0.23
7	380	40	1.22	1.20	2.00	3.06	3.06	0.06	3.87	3.87	0.00
8	400	42.5	2.60	2.64	1.62	2.28	2.29	0.62	4.13	4.12	0.22
9	420	45	3.96	4.04	2.02	1.80	1.81	0.35	4.30	4.38	1.69
10	440	42.5	2.89	2.93	1.35	2.16	2.19	1.36	4.12	4.11	0.27

줄어 들고 있음을 보여 주고 있다. 한편, 은닉층의 변화에도 학습 회수가 10,000회에 이르면 거의  $1.0e^{-4}$ 의 값에 근접하는 크기를 갖게 되고, 뉴런 요소의 변화에 따라서는 학습 종료시에 비용함수의 값이 다소 차이가 나타나고 있다. 본 연구에서는 4개의 은닉층과 512 뉴런 요소를 가진 심층 신경망을 채택하여 시험에 적용하였다. 제안된 심층 신경망의 유용성과 예측 정도를 시험하기 위하여, Table 2에 보인 바와 같이, 새롭게 선정한 10개의 용접 입력 매개변수 세트에 대하여, 출력 데이터 세트를 유한요소해석을 통해 확보하였다. 한편, 유한요소해석에 활용한 입력을 심층 신경망에 인가하여 신경망 출력을 동시에 도출하였다. 각 입력 데이터 세트에 대한 유한요소해석과 신경망에 의한 예측결과를 Table 2에서 보여 주고 있다. 각 입력 경우에 대하여 신경망은 해석결과와 매우 유사한 예측결과를 보여주고 있다. 특히, 상대오차율이 최대 약 2.8%로, 대체로 심층 신경망으로 해석결과를 잘 예측할 수 있음을 보여 주고 있다.

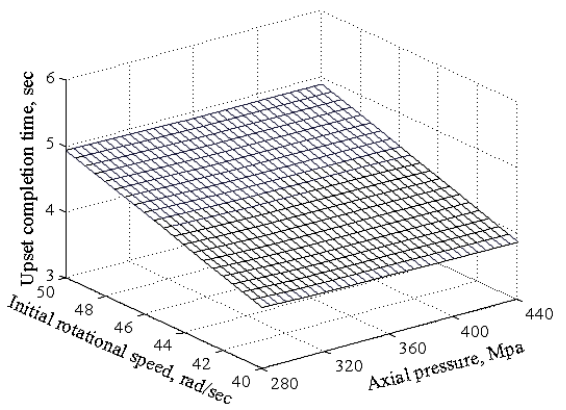
Fig. 8은 제안된 심층 신경망으로 예측한 업셋 길이, 업셋 발생 및 종료 시간을 보여주고 있고, 동시에 유한요소해석에 의한 결과와 비교하고 있다. Fig. 8(a)는 축 압력을 360 Mpa로 일정하게 둔 상태에서, 초기 회전속력을 40 ~ 50 rad/s로 변화한 경우의 결과이고, Fig. 8(b)는 초기 회전속력을 45 rad/s로 일정하게 두고, 축 압력을 280 ~ 440 Mpa로 변화한 경우에 대한 예측 결과이다. 초기 회전속력이 증가할수록, 업셋 발생 시간은 비선형적으로 줄어들고 있고, 업셋의 길이는 급격하게, 종료 시간은 완만하게 선형적으로 증가하고 있다. 이는 초기 회전속력의 증가가 용접 에너지를 크게 하고 지속한 결과로 판단된다. 한편, 축 압력이 증가할수록, 업셋 길이는 완만하게 선형적으로 증가하나, 업셋의 발생 및 종료 시간은 완만하게 선형적으로 줄어들고 있음을 알 수 있다. 이는 압력의 증가가 마찰에너지의 증가로 빠른 업셋을 발생하게 하고, 또한 속력의 감소에 기여하는 현상에 기인한 결과로 판단된다. 업셋 길이는 초기 회전속력의 증가에 따라 뚜렷하게 증가하고, 축 압력의 증가에 따라서도 선형적으로 증가하고 있다. 심층 신경망에 의한 업셋 길이 예측 결과는 유한요소법



(a) Upset length



(b) Upset beginning time



(c) Upset completion time

Fig. 9 DNN predictions for upset length and upset times with variations of initial rotational speed and axial pressure



에 의한 결과와 잘 일치하고 있고, 특히 업셋의 발생 및 종료 시간의 예측은 더욱 잘 일치하고 있음을 알 수 있다.

Fig. 9는 압력과 회전 속력을 입력으로 하여 심층 신경망으로 예측한 업셋 길이, 업셋 시작 시간, 업셋 종료 시간의 면 그래프를 보여 주고 있다.

Fig. 9(a)에서 초기 회전속력과 축 압력이 증가함에 따라 선형적으로 업셋 길이가 증가하게 됨을 보이고 있다. 따라서 주어진 범위에서 용접 입력 매개 변수의 선정에 따라 예상되는 업셋 길이를 용이하게 알 수 있게 된다. Fig. 9(b)는 업셋의 발생 시간을 예측한 그래프로, 초기 회전속력의 증가에 따라서는 비선형적으로, 축 압력의 증가에 따라서는 선형적으로 감소되고 있음을 보이고 있다. Fig. 9(c)는 업셋의 종료 시간을 예측한 결과로, 초기 회전속력이 증가함에 따라 선형적으로 증가하고, 축 압력이 증가함에 따라 선형적으로 다소 감소하게 됨을 보여 주고 있다. 이와 같은 업셋의 발생 및 종료 예측 시간을 활용하여 공정 설계 및 해석에 활용할 수 있을 것으로 판단된다.

## 5. 결 론

관성 마찰용접에서, 공정의 업셋 현상을 용이하게 예측할 수 있는 모델을 제안하였다. 이를 위한 수치 해석과 심층 신경망 모델 구축을 통해 다음과 같은 결론을 도출하였다.

1. 제안된 4개의 은닉층과 512개의 뉴런으로 구성된 심층 신경망으로써 마찰용접에서의 업셋 길이, 업셋 발생 및 종료 시간을 예측한 결과, 해석 결과에 대비하여 상대 오차율이 2.8% 이내로 예측되어, 해석 결과와 잘 일치하고 있음을 보였다.
2. 관성차의 초기 회전속력이 40에서 50 rad/s로 증가할 수록, 업셋 길이는 1.1에서 5.98 mm로 급격하게, 업셋 종료 시간은 3.89에서 4.87초로 완만하게 선형적으로 증가하고, 업셋 발생 시간은 3.14에서 1.42초로 비선형적으로 감소하였다.
3. 축 압력이 280에서 440 Mpa로 증가할 수록, 업셋 길이는 3.01에서 4.22 mm로 완만하게 선형적으로 증가하나, 업셋 발생 및 종료 시간은 각각 2.12에서 1.76초, 4.42에서 4.34초로 완만하게

선형적으로 감소하였다.

4. 제안된 심층 신경망을 활용하여, 주어진 입력 범위 내의 임의의 초기 회전속력과 축 압력의 조합에 대해 업셋 길이, 업셋 발생 및 종료 시간을 용이하게 예측할 수 있었다.

## 후 기

“이 논문은 2018~2019년도 경남과학기술대학교 대학 회계 연구비 지원에 의하여 연구되었음.”

## REFERENCES

1. Irachet, O., Bennett, C. J. and Sun, W., "A Sensitivity Study of Parameters Affecting Residual Stress Predictions in Finite Element Modelling of the Inertia Friction Welding Process", *International Journal of Solids and Structures*, Vol. 71, No. 10, pp. 180-193, 2015.
2. Li, W. and Wang, F., "Modeling of Continuous Drive Friction Welding of Mild Steel", *Materials Science and Engineering A*, Vol. 528, pp. 592-5926, 2011.
3. Liu, W., Wang, F., Yang, X. and Li, W., "Upset Prediction in Friction Welding Using Radial Basis Fuction Neural Network", *Advances in Materials Science and Engineering*, Vol. 2013, pp. 1-9, 2013.
4. ABAQUS, *Abaqus Example Problems Manual Ver. 6.10*, "Inertia Welding", Dassault Systemes, pp. 1.3.18-1 - 1.3.18-17, 2010.
5. Anand, K., Barik, B. K., Tamilmannan, K. and Sathiya, P., "Artificial Neural Network Modeling Studies to Predict the Friction Welding Process Parameters of Incoloy 800H Joints", *Engineering Science and Technology an International Journal*, Vol. 18, pp. 394-407, 2015.
6. Oh, S. C., "Prediction of Machining Performance using ANN and Training using ACO", *Journal of the Korean Society of Manufacturing Process Engineers*, Vol. 16, No. 6, pp. 125-132, 2017.

7. Keshmiri, S., Zheng, X., Feng, L. X., Pang, C. K. and Chew, C. M., "Application of Deep Neural Network in Estimation of the Weld Bead Parameters", IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2015, Hamburg, Germany, pp. 3518-3523. d
8. Kim, M. S., Shin, S. M., Kim, D. H. and Rhee, S., "A Study on the Algorithm for Determining Back Bead Generation in GMA Welding Using Deep Learning", Journal of Welding and Joining, Vol. 36, No. 2, 2018, pp. 74-81.
9. Ajith, P. M., Barik, B. K., Sathiya, P. and Aravindan, S., "Multiobjective Optimization of Friction Welding of UNS S32205 Duplex Stainless Steel", Defence Technology, Vol. 11, pp. 157-165, 2015.
10. Moal, A. and Massoni, E., "Finite Element Simulation of the Inertia Welding of Two Similar Parts", Engineering Computations, Vol. 12, No. 6, pp. 497-512, 1995.
11. Oluwasegun, K. M., Olawale, J. O., Ige, O. O., Shittu, M. D., Adeleke, A. A. and Malomo, B. O., "Microstructural Characterization of Thermo-mechanical and Heat-Affected Zones of an Inertia Friction Welded Astroloy", Journal of Materials Engineering and Performance, Vol. 23, No. 8, pp. 2834-2846, 2014.
12. Glorot, X. and Bengio, Y., "Understanding the Difficulty of Training Deep Feedforward Neural Networks", Proceedings of the 13th International Conference on Artificial Intelligence and Statistics, Vol. 9, pp. 249-256, 2010.