

심층 신경망 기반 딥 드로잉 공정 블랭크 두께 변화율 예측

박근태¹· 박지우²· 곽민준¹· 강범수^{1,#}

Prediction of Blank Thickness Variation in a Deep Drawing Process Using Deep Neural Network

K. T. Park, J. W. Park, M. J. Kwak, B. S. Kang

(Received December 19, 2019 / Revised March 5, 2020 / Accepted March 6, 2020)

Abstract

The finite element method has been widely applied in the sheet metal forming process. However, the finite element method is computationally expensive and time consuming. In order to tackle this problem, surrogate modeling methods have been proposed. An artificial neural network (ANN) is one such surrogate model and has been well studied over the past decades. However, when it comes to ANN with two or more layers, so called deep neural networks (DNN), there is distinct a lack of research. We chose to use DNNs our surrogate model to predict the behavior of sheet metal in the deep drawing process. Thickness variation is selected as an output of the DNN in order to evaluate workpiece feasibility. Input variables of the DNN are radius of die, die corner and blank holder force. Finite element analysis was conducted to obtain data for surrogate model construction and testing. Sampling points were determined by full factorial, latin hyper cube and monte carlo methods. We investigated the performance of the DNN according to its structure, number of nodes and number of layers, then it was compared with a radial basis function surrogate model using various sampling methods and numbers. The results show that our DNN could be used as an efficient surrogate model for the deep drawing process.

Key Words : Deep Drawing, Deep Neural Network, Finite Element Method, Surrogate Model, Radial Basis Function

1. 서 론

딥 드로잉 공정은 펀치를 이용하여 블랭크를 다 이 공동부로 밀어 넣어 이음매가 없고 직경에 비해 깊이가 깊은 제품을 성형하는 공법이며, 대량 생산에 적합하기 때문에 다양한 제품 제작에 활용되고 있다. 딥 드로잉 공정에 영향을 미치는 공정 변수는 블랭크 형상, 펀치 및 다이 곡률 반경, 펀치와 다이 간격, 블랭크 홀딩력, 마찰 계수 등이 있다. 공정 변수들은 복잡하게 상호작용을 하기 때문에 성형품의

상태를 예측하는 것은 어렵다. 산업 현장에서는 주로 경험에 의존해서 공정 변수들을 선택하여 사용해 왔다. 산업 현장에서의 시행착오에 드는 비용을 줄이기 위해서 최근에는 성형 공정의 결과를 예측하기 위해 유한요소법(finite element method)이 이용되고 있다. 유한요소법을 통해 신뢰성 있는 결과값을 도출하기 위해서는 요소의 크기가 적절한 수준만큼 작아야 한다. 하지만 요소의 크기가 작아져 총 요소 수가 많아질수록 컴퓨팅 시간이 오래 걸리며 메모리 사용량이 많아지게 된다. 따라서 성형 공정 결과 예측을 위한 유한요소 해석의 반복 수가 많아질 경우 비효율성이 커지는 단점이 있다.

위와 같은 문제점을 해결하기 위한 방법으로 대

1. 부산대학교 항공우주공학과, 석사과정, #교수
2. 부산대학교 부품소재산업협력연구소, 전임연구원
Corresponding Author : Department of Aerospace Engineering,
Pusan National University, E-mail: bskang@pusan.ac.kr, ORCID ID :
0000-0003-2649-6166

체 모델(surrogate model)이 제안되었다. 대체 모델은 유한요소 해석의 입력값과 출력값의 관계를 추정하여 유한요소 해석을 대신해 예측점에서의 출력값을 근사하는 수학적 모델이다. 대체 모델을 통해 비효율적인 유한요소법을 대신하여 출력값을 예측하여 효율성을 확보할 수 있다. 대체 모델 기법은 응답 표면 방법(response surface method)으로 최초로 제안된 이후 크리깅(kriging), 방사형 기저 함수(radial basis function), 서포트 벡터 머신(support vector machine), 인공 신경망(artificial neural network) 등 다양한 방법으로 발전하여 판재 성형 분야에서 꾸준히 활용되고 있다[1-8].

인공 신경망의 경우 관련 이론이 발전함에 따라 2개 이상의 레이어와 다수의 노드를 갖는 심층 신경망(deep neural networks) 구현이 가능해졌지만 판재 성형 분야에서는 대부분 단순한 구조를 갖는 인공 신경망이 대체 모델로서 사용되어 왔다. 또한 심층 신경망이 딥 드로잉 공정의 주름 예측을 위한 대체 모델로 사용되었지만 다른 대체 모델과의 비교 자료가 없어 상대적인 성능을 비교하여 확인할 수 없었다[9]. 따라서 심층 신경망이 판재 성형 공정의 대체 모델로서 활용되기 위해서는 이에 대한 추가적인 연구가 필요한 실정이다.

본 연구에서는 심층 신경망을 딥 드로잉 공정의 블랭크 두께 변화율 예측을 위한 대체 모델로 제안하였으며 이때 공정 변수는 다이 곡률 반경, 다이 코너 곡률 반경, 블랭크 홀딩력으로 설정하였다. 샘플링 방법을 통해 샘플링 포인트를 결정하고 딥 드로잉 공정 유한요소 해석을 수행하여 학습 데이터 및 테스트 데이터를 획득하였으며 이를 심층 신경망 학습 및 성능 평가에 사용하였다. 심층 신경망의 구성, 샘플링 방법, 샘플 데이터 수에 따라 블랭크 두께 변화율 예측 성능을 평가하였으며 이를 방사형 기저 함수와 비교하였다.

2. 딥 드로잉 공정 유한요소 해석

2.1 샘플링 방법

유한요소 해석은 심층 신경망 학습에 사용될 데이터를 획득하기 위해 수행하며 유한요소 해석을 수행하기 앞서 샘플링 방법을 고려해야 한다. 샘플링 방법은 실험 계획법(design of experiment)이라고 불리기도 하며 디자인 공간(design space) 내에서 샘플링

포인트를 결정하는 방법을 의미한다. 샘플링 방법에 의한 심층 신경망의 성능을 평가하기 위해 FF(full factorial), LHS(latin hypercube), MC(monte carlo) 방법을 고려하였다. FF, LHS를 통해 27, 64개의 샘플링 포인트를 결정하였으며 MC를 통해 200개 샘플링 포인트를 결정하였다. FF는 가장 고전적이며 기본적인 샘플링 방법으로 샘플링 포인트를 설계 공간의 경계값을 위주로 설정한다. LHS는 설계 공간을 균일하게 분할하고, 분할된 공간 내에서 난수를 이용하여 임의의 샘플링 포인트를 설정하는 방법으로 샘플링 포인트는 설계 공간 내에서 균일하게 분포하는 특징을 가진다. MC는 난수를 이용해서 확률적으로 샘플링 포인트를 설정하는 방법이다.

2.2 딥 드로잉 공정 유한요소 해석

결정된 샘플링 포인트에 맞게 딥 드로잉 공정의 유한요소 해석을 수행하여 블랭크 두께에 관한 데이터를 획득하였다. 딥 드로잉 공정에 관한 세부 사항은 Fig. 1에 나타나 있고 표기된 단위는 mm 이다. Fig. 1에서 R_d 는 다이 곡률 반경을 의미하고 R_c 는 다이 코너 곡률 반경을 의미하며 블랭크 홀딩력과 함께 공정 변수로 설정하였으며 공정 변수들의 범위는 Table 1과 같다. 설정된 공정 변수들은 재료 흐름(material flow)에 가장 큰 영향을 주기 때문에 변수로 선정했다. 마찰 계수는 냉간 성형에서 통상적으로 사용되는 값인 0.1로 설정하였다[10]. 딥 드로잉 공정이 정확히 대칭인 점에 착안하여 해석 시간 단축을 목적으로 Fig. 2와 같이 1/4로 축소하여 공정을 모델링 하였다.

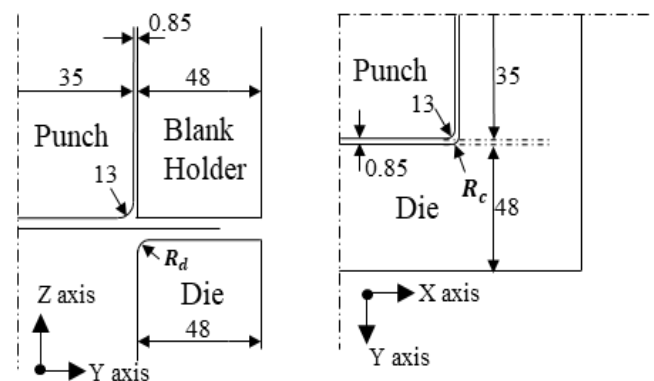


Fig. 1 Geometry of deep drawing tools

Table 1 Design space of variables

Variable	Lower bound	Upper bound
Blank holder force [kN]	3.0	15.0
Radius of die [mm]	3.0	6.5
Radius of die corner [mm]	8.0	13.5




Fig. 2 Finite element 1/4 model of deep drawing tools

Table 2 Material properties of the blank[11]

Young's modulus [GPa]	207	
Poisson's ratio	0.33	
True stress-strain curve	$\bar{\sigma} = 565.32(0.007117 + \bar{\epsilon}_p)^{0.2589}$	
Lankford Coefficient	0°	1.79
	45°	1.51
	90°	2.27

블랭크는 반경이 65 mm 인 원형 형상에 두께가 0.78 mm 의 연강(mild steel) 재질이며 물성치는 Table 2에 표기되어 있다. 블랭크의 항복 조건은 블랭크의 이방성을 고려한 Hill-1948 model을 적용하였다[12]. 유한요소 해석을 위해 범용 유한요소 해석 프로그램 ABAQUS를 이용하였으며 해석은 접촉과 같은 비선형을 포함한 문제에서 수렴성이 좋은 외연적 시간 적분법(explicit)을 이용하였다.

2.3 두께 변화율

블랭크 두께 변화율을 최소화 한다면 성형성을 높일 수 있다. 파단은 블랭크의 두께가 얇아지는 부분에서 시작되며, 주름은 블랭크의 두께가 두꺼워지는 부분에서 시작되기 때문이다[8]. 두께 변화율을 예측하는 심층 신경망은 성형성을 높이기 위한 대체 모델 기반 최적화에 활용될 수 있다.

유한요소 해석 수행 결과를 통해 가공 후 블랭크

엘리먼트의 두께를 구할 수 있으며 아래 식(1)로 정의되는 연산을 통해 블랭크 두께 변화율을 계산할 수 있다. 식(1)에서 x 는 유한요소 해석에서의 공정 변수를 의미하며 t^i 는 공정 변수 x 에 대한 유한요소 해석 수행 후 블랭크 엘리먼트 두께이며 t_0^i 는 유한요소 해석 수행 전 초기 블랭크 엘리먼트 두께이다.

$$f(x) = \left(\sum_{i=1}^{n-element} \left(\frac{t^i - t_0^i}{t_0^i} \right)^2 \right)^{1/2} \quad (1)$$

2.4 유한요소 해석 결과

유한요소 해석을 통해 얻은 결과인 엘리먼트 두께 값에 (1)의 연산을 수행하여 심층 신경망 학습에 사용될 LHS, MC, FF 샘플 데이터를 구성하였다. LHS, MC, FF 샘플 중 대표적으로 FF 64개의 샘플을 고려하여 공정 변수와 두께 변화율 결과를 함께 Fig. 3에 나타내었다. FF는 샘플링 포인트가 중복되는 부분이 있기 때문에 결과를 2차원 그래프로 표현할 수 있다. 따라서 LHS나 MC에 비해 공정 변수들에 대한 두께 변화율의 변화 양상을 파악하기 쉬운 장점이 있다.

Fig. 3에서 (b), (c), (d)의 경우를 살펴보면, 동일한 다이 곡률 반경과 다이 코너 곡률 반경에 대해서 블랭크 홀딩력이 7 kN, 11 kN, 15 kN 으로 증가할 경우 두께 변화율에는 큰 차이가 없는 것을 확인할 수 있다. 반면에 Fig. 3 (a), (b)의 경우를 비교해 보면, 블랭크 홀딩력이 3 kN 에서 7 kN 으로 변함에 따라 두께 변화율의 변동 폭이 상대적으로 컸다. 특히 다이 코너 곡률 반경이 11.66 mm 이고 다이 곡률 반경이 3 mm 인 경우, 블랭크 홀딩력이 3 kN 에서 7 kN 으로 증가할 때 두께 변화율 값이 12.8 % 만큼 감소하였다. 이는 블랭크 코너 부분에서 블랭크 홀더 압력이 작용하지 않는 영역이 블랭크 홀딩력에 의해 감소하였기 때문이다. Fig. 3 (b), (c), (d)에서 다이 곡률 반경이 증가함에 따라 두께 변화율 값도 함께 증가했다. 하지만 예외적으로 (a)의 다이 코너 곡률 반경이 11.66 mm 일 때, 다이 곡률 반경이 3 mm 인 경우가 다이 곡률 반경이 4.17 mm, 5.33 mm 인 경우보다 두께 변화율의 값이 크게 나타났다. Fig. 3 (b), (c), (d)에서 다이 코너 곡률 반경이 증가함에 따라 두께 변화율이 증가하였지만, 13.5 mm 일 때 11.66 mm 보다 두께 변화율이 감소하였다. 이는 블랭크 형상과 펀치 형상이 복합적으로 재료 흐름에 영향을 끼친 결과로 판단된다.

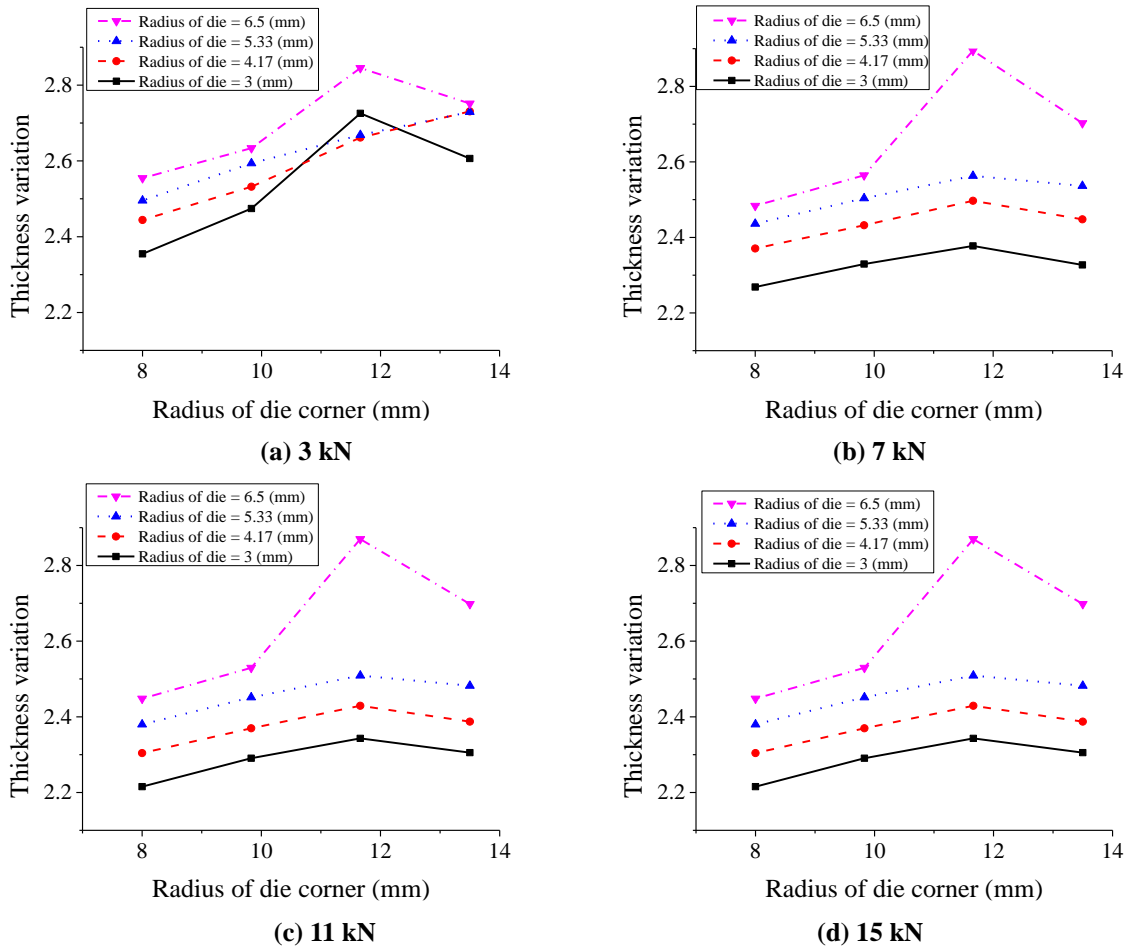


Fig. 3 Thickness variation plot of full factorial 64 samples by the blank holder force

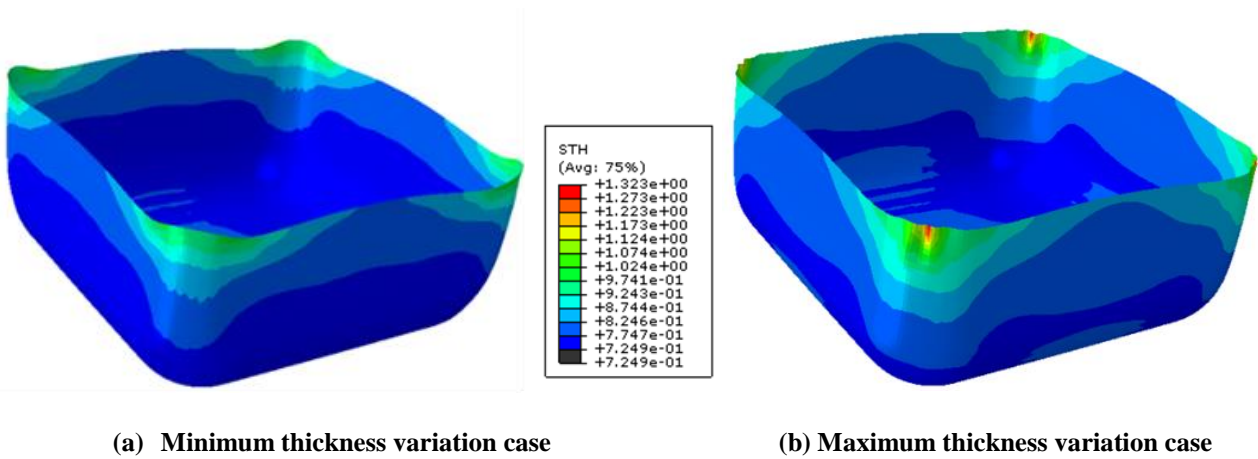


Fig. 4 Final shape of blank of maximum and minimum thickness variation cases in full factorial 64 samples

2.5 성형 후 블랭크 형상

앞서 고려한 FF 64개의 샘플에서 최대와 최소의 두께 변화율을 갖는 블랭크 형상을 각각 Fig. 4의 (a)와 (b)에 나타내어 비교하였다. Fig. 4에서 (a)의 해석 조건은 블랭크 홀딩력 11 kN, 다이 곡률 반경 3 mm, 다이 코너 곡률 반경 8 mm 이고, (b)는 블랭크 홀딩력 3 kN, 다이 곡률 반경 6.5 mm, 다이 코너 곡률 반경이 11.66 mm 이다. Fig. 4에서 (b)는 블랭크 홀딩력이 적정 수준보다 더 낮고 다이 및 다이 코너 곡률 반경이 필요 이상으로 컷기 때문에 블랭크 코너 부분에서 재료의 유입량이 (a)에 비해 많았다. 이로 인해서 (b)의 두께 변화율의 값이 (a)의 값보다 크게 나타났다.

3. 대체 모델링 방법

대체 모델은 비효율적인 유한요소 해석을 대신할 수학적 모델이며 오직 유한요소 해석의 입력값과 출력값만을 고려하여 예측점에서의 출력값을 근사(approximation)한다. 본 연구에서는 심층 신경망을 대체 모델로 제안하였으며 예측 성능을 비교하기 위해 대체 모델로서 자주 활용되고 있는 방사형 기저 함수도 함께 고려하였다. 유한요소 해석의 공정 변수인 다이 곡률 반경, 다이 코너 곡률 반경, 블랭크 홀딩력을 대체 모델의 입력 데이터로 설정 하고 유한요소 해석을 통해 얻은 블랭크 두께 변화율을 대체 모델의 출력 데이터로 설정하여 대체 모델을 구성하였다.

3.1 심층 신경망

심층 신경망은 신경세포인 뉴런의 신호전달 방법을 모방하여 만든 회귀 모델이다. 심층 신경망은 노드와 레이어로 구성되며 입력 레이어를 제외하고 각 노드에서 식(2)와 같은 연산을 거치게 된다.

$$Y_j = f \left(\sum_{i=1}^{n-node} Y_i w_{ij} + b_j \right) \quad (2)$$

식(2)에서 w_{ij} 는 가중치, Y_i 는 이전 층 노드 i 의 출력값, f 는 활성화 함수, b_j, y_j 각각 j 노드에서의 바이어스와 출력을 나타낸다. 각 노드에서 입력 데이터는 가중치와 곱해지고 바이어스값과 합산되어 활성화 함수

를 거쳐 다음 레이어의 노드에 전달되며 최종적으로 구해진 값이 심층 신경망의 출력값이 된다. 이때 가중치와 바이어스는 상수값이며 학습이 진행될 때마다 값이 결정된다. 활성화 함수는 전달되는 노드의 값에 특성을 추가하기 위해 사용되는 함수이며 sigmoid, tanh, relu(rectified linear unit) 등 다양한 함수가 활용된다. 학습은 손실 함수(cost function)를 최소화하는 조건으로 진행된다. 이때 손실 함수는 식(2)의 연산을 거친 예측 결과와 학습의 정답으로 설정된 결과의 차이를 나타내는 평균 제곱 오차(mean squared error)가 주로 사용된다. 따라서 학습은 심층 신경망의 예측 결과와 학습의 정답으로 설정된 결과 차이가 최소가 되게 하는 가중치와 바이어스 값을 결정하는 것을 의미한다. 심층 신경망의 학습 알고리즘으로 오류 역전파 알고리즘(back propagation)이 주로 사용되고 활성화 함수는 relu 함수가 주로 사용되기 때문에, 본 연구에서도 이를 이용하였다. 오류 역전파 알고리즘은 가중치와 바이어스의 기울기(gradient)를 역방향으로 결정하는 방법으로 복잡한 문제에 효율적이다[13]. 비선형 활성화 함수는 중첩되어 사용될 경우 기울기 값이 빠르게 0으로 수렴하는 문제(vanishing gradient)가 발생하기 때문에 오류 역전파 알고리즘과 함께 사용될 수 없다. 따라서 이를 방지하기 위해 2개 이상의 레이어를 갖는 심층 신경망에서는 선형 활성화 함수인 relu가 주로 사용되고 있다.

심층 신경망은 사용자가 직접 설정해 주어야 하는 값인 하이퍼 파라미터(hyper parameter)를 결정해야 하며 하이퍼 파라미터는 심층 신경망의 성능에 영향을 끼친다. 심층 신경망의 주요 하이퍼 파라미터로는 레이어와 노드 수, 전체 데이터를 이용하여 학습한 횟수를 의미하는 에폭(epoch), 강건한 모델 구성을 위해 각 레이어 별로 일부 노드의 출력을 임의로 제거하는 드랍 아웃(drop out) 등이 있다. 하이퍼 파라미터는 정해진 최적의 값이 없기 때문에 경험 법칙(rules of thumb)이나 시행착오를 통해 결정한다.

3.2 방사형 기저 함수

방사형 기저 함수는 예측 값을 중심으로부터 유클리드 거리를 변수로 가지는 방사형으로 대칭인 함수와 가중치의 연산에 의해서 표현되며 아래와

같이 식(3)으로 표현 가능하다. 이때 중심점인 x^i 는 샘플링 포인트를 이용하였다.

$$y(x) = \sum_{i=1}^n w_i K(\|x - x^i\|) \quad (3)$$

w_i 는 가중치를 나타내며 K 는 방사형 함수를 의미한다. 방사형 함수의 K 는 식(4)와 같은 멀티 쿼드릭 (multi quadric)을 선택하였다.

$$K = \exp(-\|x - x_c\|^2 / \theta) \quad (4)$$

3.3 성능 평가 지표

대체 모델 성능 평가를 위한 지표로 RMSE(root mean square error), MAE(mean absolute error), R^2 (coefficient of determination)을 고려하였으며 각각의 값은 식(5), 식(6) 식(7)과 같이 계산할 수 있다. 이때 y_j 는 유한요소 해석을 통해 얻은 데이터의 값이며, \hat{y}_j 는 대체 모델의 예측 값, \bar{y} 는 y_j 의 평균값을 나타낸다.

$$\text{RMSE} = \left(\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \right)^{1/2} \quad (5)$$

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (6)$$

$$R^2 = 1 - \left(\frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{\sum_{j=1}^n (y_j - \bar{y})^2} \right) \quad (7)$$

RMSE와 MAE는 낮은 값을 가질수록, R^2 는 높은 값을 가질수록 모델의 정확도가 높다는 것을 의미한다[14]. RMSE는 MAE에 비해 큰 오차를 가지는 데이터(outliers)에 민감하다는 차이가 있다. R^2 는 입력값으로 예측 가능한 출력값의 분산(variance)의 비율을 의미한다.

4. 결과

4.1 심층 신경망 구성 평가

Table 3 RMSE performance of different structure DNN models

		Number of node at each layer			
		100	200	300	400
Number of layer	2	0.0875	0.0764	0.0768	0.0821
	3	0.0811	0.0801	0.0788	0.0783
	4	0.0842	0.0766	0.0826	0.0826

Table 4 MAE Performance of different structure DNN models

		Number of node at each layer			
		100	200	300	400
Number of layer	2	0.0394	0.0315	0.0323	0.0356
	3	0.0367	0.0341	0.0318	0.0322
	4	0.0418	0.0306	0.0353	0.0353

Table 5 R^2 Performance of different structure DNN models

		Number of node at each layer			
		100	200	300	400
Number of layer	2	0.9286	0.9457	0.9450	0.9430
	3	0.9387	0.9403	0.9421	0.9429
	4	0.9340	0.9454	0.9372	0.9365

심층 신경망의 노드와 레이어 구성이 블랭크 두께 변화율 예측 성능에 미치는 영향을 비교하기 위해 노드와 레이어를 변수로 설정하여 블랭크 두께 변화율 예측 성능을 테스트 하였다. 모델 학습에는 LHS 64개의 데이터가 사용되었으며 MC 200개의 데이터가 테스트에 사용되었으며 모든 구성에서 예폭은 동일하게 1000으로 설정하였고 드랍 아웃은 사용하지 않았다. 테스트 결과는 각 성능 평가 지표 별로 Table 3, 4, 5에 표기된 바와 같다. 심층 신경망은 레이어 2개 노드 200개일 때 예측 성능이 각 지표 별로 가장 우수하게 나타났다. 심층 신경망 구성에 따른 예측 성능의 최대 차이는 RMSE 14.5 %, MAE 26.7 %, R^2 1.8 % 로 나타났으며, 최고 점수와 최소 점수의 차이를 최고 점수를 기준으로 나누어 연산했다.

Table 6 Performance of surrogate models 27 samples

Model	LHS		FF	
	DNN	RBF	DNN	RBF
RMSE	0.1223	0.1219	0.1477	0.1465
MAE	0.0659	0.0577	0.0957	0.0929
R ²	0.9012	0.9020	0.9356	0.9366

Table 7 Performance of surrogate models 64 samples

Model	LHS		FF	
	DNN	RBF	DNN	RBF
RMSE	0.0764	0.0815	0.1118	0.0998
MAE	0.0315	0.0340	0.0569	0.0522
R ²	0.9457	0.9381	0.9376	0.9502

4.2대체 모델 간 성능 비교 평가

심층 신경망의 블랭크 두께 변화율 예측 성능을 방사형 기저 함수와 비교하여 평가하였다. 모델 학습에는 LHS, FF를 통해 얻은 27개, 64개의 데이터가 사용되었으며 테스트에는 모델 구성 평가의 경우와 같이 MC 200개의 데이터를 사용하였다. 샘플링 방법에 따른 대체 모델의 성능 지표는 Table 6, Table 7과 같다. 심층 신경망과 방사형 기저 함수 모두 학습에 사용된 데이터의 수가 같을 경우 LHS를 이용했을 때가 FF를 이용했을 경우보다 RMSE, MAE 지표에서 예측 성능이 우수하였다. 이는 FF의 경우 샘플링 포인트가 오버랩(overlaps) 되었기 때문이라고 판단된다. 샘플링 방법에 의한 블랭크 두께 변화율 예측 성능의 차이는 최고 점수와 최소 점수의 차이를 최고 점수를 기준으로 나누어 연산했을 때, 심층 신경망의 경우 64개의 데이터에 대해 RMSE 31.7 %, MAE 44 % 차이를 가졌으며 방사형 기저 함수는 RMSE 18.3 %, MAE 34.9 % 차이를 가졌다. 따라서 심층 신경망은 방사형 기저 함수에 비해 샘플링 방법에 따라 더 민감하게 성능이 변한다고 평가할 수 있다. 심층 신경망은 LHS 64개를 학습 데이터로 이용했을 때 RMSE 0.0764, MAE 0.0315, R² 0.9457로 방사형 기저 함수에 비해 RMSE, MAE, R² 평가 지표 모두 우수한 결과를 보였다. 하지만 LHS 27개, FF 27개, FF 64개의 학습 데이터를 이용했을 경우 방사형 기저 함수가 심층 신경망의 경우보다 각 성능 평가 지표 모두에서 우수한 결과를 보였다. 따라서 심층 신경망은 학습에 사용된 데이터 샘플링 포인트가

균일하게 분포하고 데이터의 양이 일정 수준보다 많을 경우에 방사형 기저 함수에 비해 우수한 성능을 가진다고 할 수 있다.

5. 결론

본 연구에서는 심층 신경망을 딥 드로잉 공정의 대체 모델로 제안하였다. 실험 계획법에 따라 디자인 공간 상에서 샘플링 포인트를 설정하고 유효요소 해석을 통해 학습 데이터 및 테스트 데이터를 획득 한 후 심층 신경망의 예측 성능을 평가하였으며 결과를 요약하면 다음과 같다.

(1) 심층 신경망은 레이어 2개 노드 200개의 구성을 가질 때 예측 성능이 각 지표 별로 가장 우수하게 나타났다. 신경망 구성에 따라 최대 RMSE 14.5 %, MAE 26.7 %, R² 1.8 % 차이를 보였다.

(2) LHS 64개를 학습 데이터로 사용한 테스트에서 RMSE 0.0764, MAE 0.0315, R² 0.9457로 방사형 기저 함수에 비해 RMSE, MAE, R² 성능 평가 지표 모두에서 우수한 결과를 보였다. 하지만 LHS 27개, FF 27개, FF 64개의 학습 데이터를 사용했을 경우 방사형 기저 함수보다 예측 성능이 좋지 못하였다.

데이터의 양이 27개보다 많은 64개를 사용하고 균일하며 중복되지 않는 샘플링 포인트를 갖는 LHS를 사용했을 경우, 심층 신경망은 RMSE, MAE, R² 평가지표 모두에서 방사형 기저 함수에 비해 성능이 더 우수하게 나타났다. 따라서 데이터의 양이 일정 수준보다 많으며 중복되지 않고 균일하게 분포한다면, 심층 신경망은 방사형 기저 함수에 비해 예측 정확도가 높다고 평가할 수 있다. 따라서 심층 신경망은 판재 성형 결과를 예측하는 대체 모델로서 활용될 수 있을 것이다. 심층 신경망이 다른 대체 모델에 비해 더 높은 예측 성능을 갖기 위해 필요한 최소한의 데이터 양은 판재 성형 가공 방법의 종류나 예측하고자하는 값에 따라 다르기 때문에 이와 관련한 연구가 추가적으로 필요하다.

후 기

이 논문은 2019 년도 정부(산업통상자원부)의 재원으로 한국에너지기술평가원의 지원(20161520202610, 원자로 건물 내부 증기발생기 인양설비 국산화)과 2019 년도 정부(미래창조과학부)의 재원으로

한국연구재단의 선도연구센터지원사업(No. 2019R1A5A6099595)의 지원을 받아 수행된 연구임. 이에 관계자 여러분께 감사드립니다.

REFERENCES

- [1] G. E. P. Box, K. B. Wilson, 1951, On the Experimental Attainment of Optimum Conditions, *J. R. Stat. Soc. Ser. B stat. Methodol.*, Vol. 13, No. 1, pp. 1~38.
- [2] Y. M. Xie, 2011, Multi-Objective Optimal Approach Based on Kriging Model in a Deep Drawing Process, *Key Eng. Mater.*, Vol. 474, pp. 205~210.
- [3] Y. Tang, J. Chen, 2009, Robust Design of Sheet Metal Forming Process Based on Adaptive Importance Sampling, *Struct. Multidiscip. Optim.*, Vol. 39, No. 5, pp. 531~ 544.
- [4] G. Sun, G. Li, Q. Li, 2012, Variable Fidelity Design Based Surrogate and Artificial Bee Colony Algorithm for Sheet Metal Forming Process, *Finite Elem. Anal. Des.*, Vol. 59, pp. 76~90.
- [5] K. M. Liew, H. Tan, T. Ray, M. J. Tan, 2004, Optimal Process Design of Sheet Metal Forming for Minimum Springback Via an Integrated Neural Network Evolutionary Algorithm, *Struct. Multidiscip. Optim.*, Vol. 26, No. 3~4, pp. 284~294.
- [6] J. Pfrommer, C. Zimmerling, J. Liu, L. Karger, F. Henning, J. Beyerer, 2018, Optimisation of Manufacturing Process Parameters Using Deep Neural Networks as Surrogate Models, *Procedia CIRP*, Vol. 72, pp. 426~431.
- [7] 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, *Proc. Kor. Soc. Tech. Plast. Conf.*, Vol. 27, No. 6, pp. 331~338.
- [8] H. Wang, F. Ye, L. Chen, E. Li, 2017, Sheet Metal Forming Optimization by Using Surrogate Modeling Techniques, *Chin. J. Mech. Eng.*, Vol. 30, No. 1, pp. 22~36.
- [9] S. Sivasankaran, R. Narayanasamy, R. Jeyapaul, C. Loganathan, 2009, Modelling of Wrinkling in Deep Drawing of Different Grades of Annealed Commercially Pure Aluminium Sheets When Drawn Through a Conical Die Using Artificial Neural Network, *Mater. Des.*, Vol. 30, No. 8, pp. 3193~3205.
- [10] G. S. Shin, J. G. Park, J. H. Kim, Y. S. Kim, Y. H. Park, N. K. Park, 2015, Effect of Processing Conditions on the Deep Drawability of Ti-6Al-4V Sheet at Warm Temperatures, *Proc. Kor. Soc. Tech. Plast. Conf.*, Vol. 24, No. 1, pp. 5~12.
- [11] Y. Q. Li, Z. S. Cui, X. Y. Ruan, D. J. Zhang, 2006, CAE-based Six Sigma Robust Optimization for Deep-Drawing Process of Sheet Metal, *Int. J. Adv. Manuf. Technol.*, Vol. 30, No. 7~8, pp. 631~637.
- [12] R. Hill, 1948, A Theory of the Yielding and Plastic Flow of Anisotropic Metals, *Proc. R. Soc. London, Ser. A. Math. Phys. Sci.*, Vol. 193, No. 1033, pp. 281~297.
- [13] Y. A. LeCun, L. Bououou, G. B. Orr, K. R. Muller, 2012, Efficient Backprop, *Neural networks: Tricks of the trade*, Springer, Berlin, Heidelberg, pp. 9~48.
- [14] M. Y. M. Ahmed, N. Qin, 2009, Surrogate-based Aerodynamic Design Optimization: Use of Surrogates in Aerodynamic Design Optimization, *Int. Conf. Aersp. Sci. Aviat. Technol.*, Military Technical College, Kobry Elkobba, Cario, Vol.13, pp. 1~26.