

세장비가 큰 사각케이스 성형 공정에서의 인공지능망을 적용한 초기 블랭크 형상 최적설계 모델 개발

곽민준¹· 박지우²· 박근태¹· 강범수^{1,#}

A Development of Optimal Design Model for Initial Blank Shape Using Artificial Neural Network in Rectangular Case Forming with Large Aspect Ratio

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

(Received July 30, 2020 / Revised September 8, 2020 / Accepted September 11, 2020)

Abstract

As the thickness of mobile communication devices is getting thinner, the size of the internal parts is also getting smaller. Among them, the battery case requires a high-level deep drawing technique because it has a rectangular shape with a large aspect ratio. In this study, the initial blank shape was optimized to minimize earing in a multi-stage deep drawing process using an artificial neural network(ANN). There has been no reported case of applying artificial neural network technology to the initial blank optimal design for a square case with large aspect ratio. The training data for ANN were obtained through simulation, and the model reliability was verified by performing comparative study with regression model using random sample test and goodness-of-fit test. Finally, the optimal design of the initial blank shape was performed through the verified ANN model.

Key Words : Multi-Step Deep Drawing, Initial Blank Design, Artificial Neural Network, Multi Regression, Numerical Simulation, Goodness-of-fit test

1. 서론

최근 전세계적으로 휴대용 이동 통신 기기 및 멀티미디어 기기가 급격히 발달하고 있다. 이에 따라 휴대용 기기에 들어가는 부수적인 부품들의 수요 또한 증가하고 있는 추세이다. 이러한 부품들 중에서 제품을 구동할 수 있는 전원을 공급해주는 리튬 계열 2차 전지는 중요한 부품 중 하나이다. 그 중 리튬 이온 2차 전지는 전해질 물질의 성능이 개선되면서 이동 통신용 및 다양한 분야의 전원 공급원으로 각광받고 있다. 전원 공급용 리튬 이온 2차 전

지는 크게 전해질 물질의 저장 역할을 하는 사각형 케이스와 상부 캡(top-cap)으로 구성되어 있다. 이 중 사각 케이스는 휴대용 통신 기기에 부착되는 특성상 세장비가 큰 직사각형의 형태를 가진다. 그리고 이러한 사각 케이스의 특징은 현재 이동 통신 기기 및 전자제품의 개발 방향성이 초경량화와 더 얇은 두께로 향함에 따라 더 두드러지고 있다. 세장비가 큰 사각 케이스의 수요가 증가하면서 생산성 향상 및 비용 절감을 위해 사각케이스 형상 다단계 딥드로잉(multi-step deep drawing) 공정 기술의 개발이 요구된다[1].

세장비가 큰 사각 형상에 대한 다단계 딥드로잉 공정은 원형 딥드로잉 공정과 비교해 성형 결과 예측이 힘들고 그에 따라 원하는 최종 형상을 얻기

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 : 0000-0003-2649-6166

위한 단계 별 공정 설계가 어렵다. 이에 Ku등[2]은 세장비가 큰 사각케이스 딥드로잉 공정에서의 초기 블랭크 형상을 개선하는 연구를 진행하였으며, Kishor등[3]은 유한요소법을 이용한 초기 블랭크 형상 최적화를 통해 방향귀(earing)를 최소화하는 연구를 하였고, Kang등[4]은 큰 세장비를 가진 사각 용기 다단 딥드로잉 공정에 대한 실험적 연구를 진행하였다.

본 연구에서는 사각형 케이스 다단 드로잉 성형 시 성형성을 향상시키기 위해 인공지능망(artificial neural network, ANN) 기법을 적용하여 제품의 성형성에 영향을 미치는 초기 블랭크 형상을 최적화할 수 있는 모델을 개발했다.

인공지능망은 일반적으로 입력된 변수(input data)와 출력할 변수(output data) 사이의 관계를 각각의 가중치(weight)를 통해 연결된 입력층(input layer), 은닉층(hidden layer), 출력층(output layer)을 통해 나타낸다. 이러한 가중치는 각 층의 뉴런(neuron)에 연결되어 있고 역전파(back propagation) 기법을 통해 학습시켜 최적 값을 찾는 알고리즘으로 최근 많은 분야에서 적용되고 있다. 실제 많은 연구를 통해 회귀분석(regression analysis)과 같은 기존의 예측모델과 비교해 좋은 성능을 보여주고 있다[5~8].

본 논문에서는 블랭크 형상을 조절하여 성형성과 성형비용에 영향을 주는 방향귀(earing) 현상을 줄이는 연구를 진행했다. 실제 이온 리튬 배터리 케이스 도면을 통해 시뮬레이션을 설계하였고, 시뮬레이션을 통해 인공지능망에 학습시킬 데이터를 획득했다. 이후 학습 데이터를 인공지능망 모델에 학습시키고 모델의 성능 검증을 위해 적합도 검정(goodness-of-fit test)을 통해 회귀분석(regression) 모델과 비교하였다. 최종적으로 검증된 모델을 통해 초기 블랭크 형상을 최적화하였다.

2. 다단 딥드로잉 모델링 및 해석

2.1 사각 케이스 성형 공정

본 연구를 적용한 리튬 이온 2 차 전지 사각 케이스의 성형 공정은 마지막 트리밍(trimming) 단계를 제외하고 총 7 단계의 드로잉(drawing)과 아이어닝(ironing) 공정으로 이루어져 있다. 단계별 제품의 형상을 Fig. 1에 나타냈다.

세장비가 큰 사각 케이스의 경우 한번의 드로잉

공정으로 최종 제품 형상을 만들기 어렵기 때문에 여러 개의 펀치(punch)와 다이(die)를 통해 몇 단에 걸쳐 원하는 제품 형상을 성형하게 된다. 하지만 사각 케이스 성형 공정의 경우 원형 제품 성형 공정과 비교해 각 단계가 진행될수록 성형하는 제품의 단변과 장변 상단에서 높이차가 발생해 성형 결과



Fig. 1 Product shape for each stage

를 예측하기 어렵다. 이러한 높이차는 성형이 진행되면서 재료가 단변 쪽으로 모이면서 발생하게 되며 두께 불균형으로 인해 제품의 불량률을 상승시키고 성형 비용을 증가시킨다. Fig. 1을 보면 공정의 4 단계부터 높이차가 발생해 점점 차이가 심해지는 것을 볼 수 있다. 따라서 본 논문에서는 4 단계 공정 후 높이차를 최소화함으로써 최종 공정 후 발생하는 방향귀 현상을 최소화시킬 수 있는 연구를 수행하였다. 시뮬레이션을 통해 초기 블랭크의 크기를 특정 범위내에서 변화시키고 그로 인해 발생하는 4 단계 공정에서의 높이차를 인공지능망에 학습시켜 높이차가 최소가 되는 초기 블랭크 형상을 찾는 모델을 개발했다.

2.2 유한요소 해석 모델 검증

리튬 이온 2 차 전지의 다단 딥드로잉 모델링 및 해석은 ABAQUS 상용 해석 프로그램을 사용하여 수행되었다. 펀치와 다이, 블랭크 홀더(blank holder)는 실제 제품의 도면을 참고하여 3D 모델링 프로그램인 CATIA를 통해 Fig. 2와 같이 구현하였다.

공정에 사용된 블랭크의 소재는 두께 0.6 mm 인 알루미늄 합금(aluminum alloy) Al 3005-H14이며 사용

된 물성식은 식 (1) 과 같고 Table 1 에 소재의 물성치를 나타냈다.

$$\sigma = K \varepsilon^n \quad (1)$$

σ 는 응력, ε 은 변형률, K 는 강도계수, n 은 가공경화지수이다.

Table 1 Material properties of Al 3005-H14

Property of matter	Value
Young's Modulus (GPa)	71.8
Strength Coefficient - K (MPa)	223.0
n-Value	0.485
Yield Stress (MPa)	186.5
Tensile Stress (MPa)	193.1
Poisson's Ratio	0.34

각 파트 별 마찰 조건은 모두 일정하게 쿨롱 마찰계수(coulomb friction coefficient) 0.1 을 적용하였다 [9]. 또한 블랭크를 제외한 펀치와 다이 및 블랭크 홀더는 4 절점 강체 쉘 요소(shell element)로 정의하였고, 블랭크의 경우 8 절점 솔리드 요소로 정의하였으며 성형 시 발생하는 굽힘 변형과 아이어닝 공정의 효과를 고려하기 위해 두께방향으로 4 개 층의 요소를 사용하였다. 최종적으로 블랭크에 사용된 요소 수는 총 18000 개이다.

모델의 신뢰성을 검증하기 위해 실제 제품의 초기 블랭크 형상을 입력변수로 하여 4 단계 공정 후 시뮬레이션의 높이차와 실제 생산된 제품의 높이차를 Fig. 3에서 비교하였다. 시뮬레이션의 단변과 장변의 높이차는 5.809 mm이며 실제 생산된 제품의 높이차는 5.7 mm로 약 1.9 % 정도의 오차를 가지므로 상당히 신뢰성 있는 모델로 볼 수 있다.




Fig. 2 Multi-step deep drawing modeling (1 to 4 step)




Fig. 3 Comparison of height difference between actual product and simulation result

Table 2 Training data set and ANN prediction result

Minor axis length (mm)	34.175
	35.175
	36.175
	37.175
Major axis length (mm)	33.75
	34.25
	34.75
	35.25
	35.75
	36.25
	36.75

실제 제품의 성형 공정에서 초기 블랭크는 단축 34.175 mm, 장축 36.75 mm의 타원형 형상을 가진다. 높이차를 줄이기 위해 변형되는 각 축의 크기는 최종 완성 제품 크기에 영향을 미치지 않도록 각축당 변화율 10 % 미만에서 범위를 정하였다. 4 공정의 높이 차이가 블랭크의 장축 길이 변화에 대해서 더 민감하게 반응했기 때문에 장축 길이 변화를 단축에 비해 더 세분하게 나누었다. 그에 따른 인공신경망 학습을 위한 학습데이터는 단축 길이 변화에 대한 입력변수 4 요소, 장축 길이변화에 대한 입력변수 7 요소로, 완전요인설계를 통해 총 28 개의 데이터를 시뮬레이션을 통해 확보했다. 확보한 입력변수에 대한 데이터는 Table 2에 나타났다.




Fig. 4 Composition of ANN model

3. 인공지능망 기반 예측 모델 개발 및 초기 블랭크 형상 최적화

3.1 초기 블랭크 예측 모델 개발

인공지능망은 생물학의 신경망에서 영감을 얻어 이를 수학적 모델로 재구성한 학습 알고리즘이다. 시냅스의 결합으로 네트워크를 형성한 이공 뉴런이 학습을 통해 시냅스의 결합 세기를 변화시켜 문제를 해결할 수 있는 능력을 가지는 비선형 모델로 볼 수 있다.

인공지능망을 이용한 최적화 모델 설계에는 구글(google)에서 오픈소스(open source)로 제공하는 파이썬(python) 기반 딥러닝(deep learning) 라이브러리인 텐서플로우(tensorflow)를 사용했다.

본 연구에서는 기본적인 다층인공지능망을 사용했다. Fig. 4와 같이 입력층, 은닉층, 출력층 3 개의 층으로 구성되어 있으며 초기 블랭크의 장축 길이와 단축 길이인 2 개의 입력변수를 받아 지정된 수의 노드(node)와 층(layer) 수를 가진 은닉층을 거쳐 출력층에서 높이차에 대한 예측 값을 출력한다. 인공지능망 모델은 학습 초반에는 입력과 출력 사이의 관계를 정확하게 예측하지 못하지만, 점진적인 학습을 통해서 입력-출력 사이의 관계를 가중치를




Fig. 5 Graph of ReLU function

통해 형성해주며, 학습이 완료된 후에는 학습되지 않은 입력에 대해서도 출력을 예측할 수 있다. 인공지능망은 비선형(nonlinear)적인 구조를 해석하는데 사용되기 때문에 학습과정에서 비선형성을 부여해 줄 수 있는 장치가 필요한데 이를 활성화 함수(activation function)라 한다. 입력 변수를 x_i , 가중치를 w_{ij} , 편향(bias)을 b_i 라고 하면 출력 변수 h_i 는 아래 식 (2), (3)과 같다

$$u_i = \sum w_{ij}x_i + b_i \tag{2}$$

$$h_i = f(u_i) \tag{3}$$

식 (3)의 $f(u_i)$ 가 활성화 함수로 본 연구에서는 식 (4)와 같이 표현되는 ReLU(rectified linear unit) 함수를 사용했다.

$$f(u_i) = \max(0, u_i) \tag{4}$$

ReLU 함수는 Fig. 5와 같은 형태를 가지며 음수 값은 0으로 바꾸고, 양수 값은 입력되는 값을 그대로 사용하는 함수이다.

다층 인공지능망의 성능을 향상시키기 위해서는 예측하는 모델에 따라 은닉층의 노드 수와 레이어 수를 정해주어야 한다. 본 연구에서는 적합도 검정을 통해 최적 노드, 레이어 수를 선정했다. 적합도 검정은 일반적으로 회귀분석의 적합도를 판별하는데 많이 사용되는 방법으로 모델의 회귀식이 종속 변수 값을 얼마나 정확하게 예측할 수 있는지에 대한 지표를 보여준다. 본 연구에서는 적합도 검정에서 사용되는 지표들 중 결정계수(coefficient of determination)를 사용하였다.

결정계수는 R^2 로 표현되며 표본관측으로 추정된 예측선이 실제로 관측된 표본과 얼마나 일치하는지를 계수로 나타낸 값으로 0 과 1 사이의 값을 가진다. 결정계수가 1 에 가까울수록 적합도가 높은 모델로 판단할 수 있다. 식 (12)는 결정계수를 구하는 방법이다.

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \tag{12}$$

Table 3 R^2 according to the number of nodes

Number of nodes	R^2
100	0.9925
200	0.9856
300	0.9736
400	0.9808
500	0.9788

Table 4 R^2 according to the number of layers

Number of layers	R^2
1	0.9925
2	0.9725
3	0.9623

$SSR = \sum (\hat{y}_i - \bar{y}_i)^2$, $SST = \sum (y_i - \bar{y}_i)^2$, 그리고 $SSE = \sum (y_i - \hat{y}_i)^2$ 이다. SSR 은 회귀 제곱 합, SSE 는 오차 제곱 합, SST 는 전체 제곱합을 의미하며 y_i 는 시뮬레이션 결과, \bar{y}_i 는 y_i 의 평균, \hat{y}_i 는 인공신경망 모델의 예측 값이다. 아래의 Table 3은 각 노드 수에 따른 예측 결과에 대한 결정계수를 비교한 것이고 Table 4는 Table 3의 결과에서 결정계수가 가장 높게 나온 100 개의 노드를 기준으로 하여 레이어 수에 따른 결과를 나타낸 것이다. Table 4의 결과를 보면 레이어 수가 많아질수록 적합도가 떨어지는데 이는 모델이 과적합(overfitting)되었기 때문이다. 인공신경망에서는 단순히 노드 수와 레이어 수를 늘린다고 성능이 향상되지 않는다. 실험적 방법을 통해 최적의 성능을 가지는 형태를 찾는 것이 중요하다. 위의 결과를 통해 은닉층의 노드 수를 100개 레이어 수를 1개로 선정했다.

3.2 모델 성능 검증

3.1에서 최종적으로 구성한 인공신경망 모델에 시뮬레이션에서 얻은 28 개의 데이터를 학습시켰다. Table 5는 학습데이터를 나타낸 것이고 학습 결과를 Fig. 6에 나타냈다.

에포크(epoch) 수를 1000번으로 하여 학습 데이터(training set)를 80 %, 검증 데이터(validation set)는 20 %로 학습을 진행했다.

Table 5 Training data set

Minor axis length(mm)	Major axis length(mm)	Simulation result(mm)
34.175	36.75	5.8095
34.175	36.25	4.7404
34.175	35.75	3.9861
34.175	35.25	2.8066
34.175	34.75	1.7532
34.175	34.25	0.9102
34.175	33.75	0.0695
35.175	36.75	5.2208
35.175	36.25	3.9348
35.175	35.75	3.0764
35.175	35.25	2.1387
35.175	34.75	1.2499
35.175	34.25	0.1247
35.175	33.75	0.6282
36.175	36.75	4.5890
36.175	36.25	3.5515
36.175	35.75	2.4100
36.175	35.25	1.5678
36.175	34.75	0.7277
36.175	34.25	0.4172
36.175	33.75	1.5044
37.175	36.75	4.4522
37.175	36.25	3.1949
37.175	35.75	2.2595
37.175	35.25	0.9983
37.175	34.75	0.0529
37.175	34.25	0.9716
37.175	33.75	1.9905




Fig. 6 Loss graph according to epoch

Table 6 Regression coefficient of equation (13)

Coefficient	Value
β_0	-0.5742
β_1	-0.4891
β_2	0.0757
β_3	-0.6411
β_4	0.1160
β_5	-0.1576

1000번의 에포크 후 학습 데이터의 평균 제곱근 편차(mean square error, MSE)는 0.0114, 검증 데이터의 MSE는 0.0297이 나왔고 Fig. 6의 에포크에 따른 그래프 형상을 봤을 때 학습이 잘 되었다고 판단된다. 학습을 완료한 인공지능망 모델을 검증하기 위해 적합도 검정을 통해 기존에 예측 모델로 많이 사용되던 회귀모델과 비교하였다. 인공지능망과의 비교를 위해 사용한 회귀모델의 회귀식은 식 (13)과 같다.

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_1^2 + \beta_3 X_2 + \beta_4 X_2^2 + \beta_5 X_1 X_2 + E \quad (13)$$

y 는 종속 변수로 회귀 모델의 예측 값, X_i 는 독립 변수로 입력 값, β_i 는 회귀계수(regression coefficient)를 의미하며 E 는 오차를 보정해주는 값이다. Table 6은 회귀계수를 정리한 것이다.

28개의 임의의 데이터를 통해 인공지능망 모델과 회귀모델의 성능을 검증했다. 검증에는 적합도 검정을 사용했고 결정계수인 R^2 와 평균 제곱근 편차(root mean square error, RMSE)를 통해 비교했다. RMSE는 모델이 예측한 값과 실제 값의 차이를 나타내며 값이 0에 가까울수록 모델의 적합도가 높다고 판단한다. 본 연구에서는 RMSE를 예측하는 값의 범위에 맞게 정규화 시킨 NRMSE(normalized root mean square error)를 사용했고 식 (14)와 같이 표현된다.

$$NRMSE = \sqrt{\frac{SSE}{n}} \cdot \frac{1}{(y_{\max} - y_{\min})} \quad (14)$$

n 은 모델에 학습시킨 데이터 수, y_{\max} 는 예측 값의 최대 값, y_{\min} 은 예측 값의 최소 값이다. Table 7과 Fig. 7은 인공지능망 모델과 회귀모델에 대한 적합도 검정 결과이고 Table 8은 검증에 사용된 임의의 28개 데이터와 그에 따른 예측결과를 정리한 것이다.

결과를 확인하면 인공지능망 모델의 경우 R^2 가 0.9824, 회귀모델의 경우 0.9719으로 인공지능망 모델의 예측 결과가 더 높은 적합도를 보였다. 인공지능망의 경우 검증 데이터로 20%의 학습데이터가 제외되어 80%의 데이터로만 학습되었음에도 위의 결과를 보였다. Fig. 7의 그래프는 시뮬레이션 결과에 대한 예측 값의 오차를 보여주며 붉은 점이 푸른색 선에 가까울수록 예측 정확도가 높다고 판단할 수 있다. 전체 결과를 비교했을 때 인공지능망의 성능이 회귀모델보다 뛰어났다. 이러한 결과는 인공지능망 모델의 장점을 잘 보여주는 결과이다.

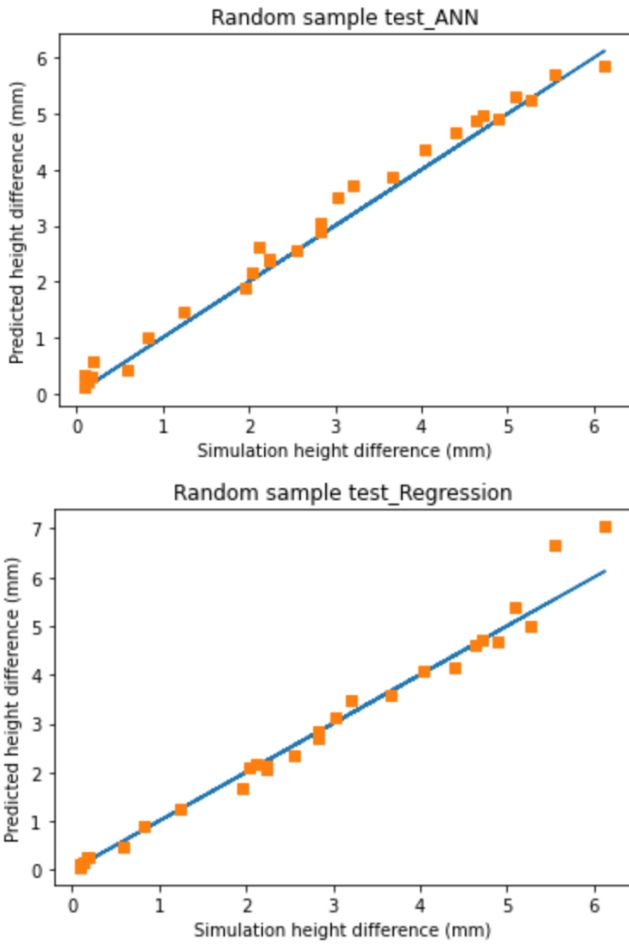


Fig. 7 Graph of the simulation result vs ANN and regression result for random sample data




Fig. 8 Prediction result of ANN model

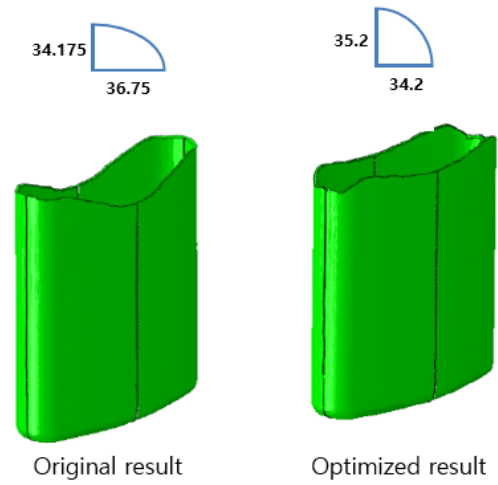


Fig. 9 Comparison of original and optimized shape

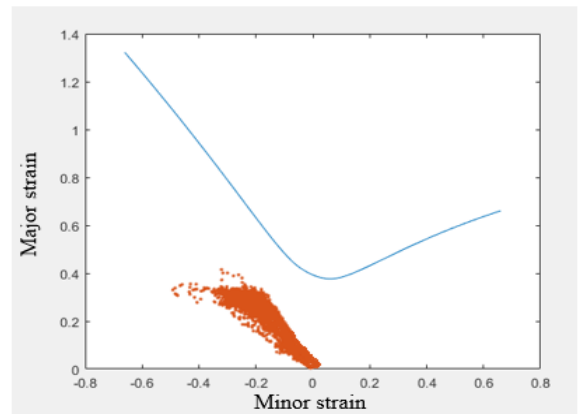


Fig. 10 FLD of optimized forming

Table 7 Result of goodness-of-fit test

Model	R^2	$NRMSE$
ANN	0.9925	0.0270
Regression	0.9719	0.0442

회귀모델의 경우 처리하는 데이터에 따라 그에 맞는 회귀식을 설계자가 찾아서 검증을 해야 하지만 인공지능망 모델의 경우 데이터에 따라 스스로 학습을 통해 그 데이터에 맞는 모델로 변경 가능하다. 따라서 회귀모델보다 우수한 성능을 가진 대체 모델로써 사용될 수 있다고 판단된다.

3.3 초기 블랭크 형상 최적화

3.2에서 검증된 인공신경망 모델을 통해 예측한 입력 데이터에 따른 높이차 결과를 Fig. 8와 같이 3차원 그래프로 나타냈다. 학습 범위 내에서 입력변수를 0.05 mm 단위로 나누어 입력변수에 대한 높이차 데이터를 출력했고, 그 중 최소값을 획득하여 초기 블랭크 형상을 최적화하였다. Fig. 9는 예측한 최적 블랭크 크기에 대한 시뮬레이션 결과이다. 최적 설계된 값으로 공정을 진행했을 때 양끝단의 두께 감소로 인해 제품이 파손될 수 있다. 이에 성형한계도(forming limit diagram, FLD)를 통해 파손가능성을 확인하였다. 성형한계선(forming limit curve, FLC)는 Marciniak-Kuczynski 모델(M-K model)을 통해 획득했다[10]. Fig. 10은 FLD 결과이며 최적 설계된 제품에 파손가능성이 없는 것을 확인했다. 인공신경망 모델을 통해 최적화된 초기 블랭크 형상의 4 공정 후 높이차는 Fig. 9의 조건에서 0.0246 mm로 최적화 전인 5.8095 mm와 비교해 99.6% 감소한 것을 볼 수 있다. 추후 연구를 통해 최종 공정 데이터의 수집 및 학습이 진행되면 초기 블랭크 개선을 통해 성형성 향상 및 성형 비용 절감의 효과가 기대된다.

4. 결론

본 연구에서는 다단 딥드로잉 공정 시 초기 블랭크 설계에 인공신경망을 적용하여 성형성에 영향을 주는 방향귀를 최소화할 수 있는 최적 설계 모델을 개발했다. 학습된 인공신경망 모델의 신뢰성을 검증하기 위해 기존에 예측 모델로 많이 사용되는 회귀 모델과 적합도 검정을 통해 성능을 비교하였다.

적합도 검정 결과 인공신경망 모델의 R^2 와 $NRMSE$ 는 각각 0.9824와 0.0427로 회귀모델과 비교하여 더 높은 적합도를 보였다. 인공신경망의 경우 과적합을 막기 위한 검증 데이터를 제외하고 학습하여 회귀모델에 비해 더 적은 데이터를 학습했음에도 더 우수한 성능을 보였다.

완성된 모델을 통해 4공정 후 방향귀가 최소가 되는 초기 블랭크 형상을 구했으며 FLD를 통해 파손가능성 여부를 판단했다. 최적화된 블랭크 형상을 실제 공정과 비교했을 때 방향귀가 99.6% 감소한 것을 확인할 수 있었다.

Table 8 Random sample test data set and result

No.	Minor length (mm)	Major length (mm)	Simulation result (mm)	ANN result (mm)	Regression result (mm)
1	34.3	34	0.1800	0.3917	0.2627
2	34.7	33.9	0.1352	0.0884	0.1636
3	36.9	34.9	0.5892	0.4686	0.4589
4	35.5	36.1	3.6549	3.7278	3.5727
5	35.2	35.4	2.5495	2.3015	2.3451
6	36.7	35.1	0.8246	0.9600	0.8817
7	34.5	36.5	5.0841	4.9620	5.3897
8	37.0	35.9	2.1102	2.2368	2.1621
9	35.9	34.2	0.2013	0.2909	0.2667
10	36.3	34.5	0.0905	0.0541	0.0510
11	35.3	36.5	4.6402	4.5548	4.6241
12	34.3	35.3	2.8341	2.8251	2.8551
13	33.9	36.9	6.1252	5.9553	7.0408

14	35.0	35.5	2.8373	2.8294	2.7027
15	34.0	36.8	5.5515	5.7366	6.6692
16	36.2	35.6	2.2445	2.1576	2.0611
17	35.4	36.7	5.2614	4.8651	4.9899
18	35.8	36.0	3.0306	3.3671	3.1303
19	35.2	36.5	4.7050	4.6057	4.7145
20	34.2	34.9	2.0440	2.0120	2.0960
21	34.6	35.7	3.2076	3.4417	3.4620
22	35.4	36.3	4.0418	4.1426	4.0899
23	35.6	35.2	1.9582	1.8187	1.6739
24	36.4	36.7	4.4019	4.3562	4.1529
25	35.9	34.3	0.0975	0.0846	0.1018
26	35.5	35.4	2.2270	2.1747	2.1305
27	36.3	35.2	1.2477	1.3307	1.2588
28	35.5	36.6	4.8979	4.6336	4.6725

후 기

이 논문은 정부(미래창조과학부)의 재원으로 한국연구재단의 선도연구센터지원사업(No. 2019R1A5A6099595)의 지원을 받아 수행된 연구임. 이에 관계자 여러분께 감사드립니다.

REFERENCES

- [1] C. S. Park, T. W. Ku, B. S. Kang, 2002, FE Analysis of Multi-Stage Deep Drawing Process for High Rectangular Case with Aspect Ratio, *Trans. Mater. Process.*, Vol. 2002, No 10, pp. 171~174.
- [2] T. W. Ku, C. S. Park, B. S. Kang, 2004, A Study on Initial Blank Design and Modification for Rectangular Case Forming with Extreme Aspect Ratio, *Trans. Mater. Process.*, Vol. 13, No. 4, pp. 307~318.
- [3] N. Kishor, D. R. Kumar, 2002, Optimization of initial blank shape to minimize earing in deep drawing using finite element method, *J. Mater. Process. Technol.*, 130, pp. 20~30
- [4] B. S. Kang, T. W. Ku, 2011, Experimental study on multi-stage deep drawing for rectangular cup with high aspect ratio, *Int. J. Adv. Manuf. Technol.*, 53.1-4, pp. 131~143.
- [5] M. J. Kwak, J. W. Park, G. T. Park, B. S. Kang, 2020, A Development of Longitudinal and Transverse Springback Prediction Model Using Artificial Neural Network in Multipoint Dieless Forming of Advanced High Strength Steel, *Trans. Mater. Process*, Vol. 29, pp. 76~88
- [6] K. Mohammadi, H. R. Eslami, D. S. Dayani, 2005, Comparison of regression, ARIMA and ANN models for reservoir inflow forecasting using snowmelt equivalent (a case study of Karaj), *J. Agric. Sci. Technol.*, Vol. 7, pp. 17~30.
- [7] M. A. Woo, S. M. 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, pp. 331~338.
- [8] J. W. Park, B. S. Kang, 2019, Comparison between regression and artificial neural network for prediction model of flexibly reconfigurable roll forming process, *Int. J. Adv. Manuf. Technol*, 101.9-12, pp. 3081-3091.
- [9] 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, *Trans. Mater. Process*, Vol. 24, pp. 5~12.
- [10] 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, *Metals*, 9.4: 401.