

# Multi-Layer Perceptron과 Random Forest를 이용한 실린더 판재의 성형 조건 예측

김성겸<sup>1</sup>·황세윤<sup>2</sup>·이장현<sup>1,†</sup>

인하대학교 조선해양공학과<sup>1</sup>

인하대학교 공과대학 산업과학기술 연구소<sup>2</sup>

## Application of Multi-Layer Perceptron and Random Forest Method for Cylinder Plate Forming

Seong-Kyeom Kim<sup>1</sup>·Se-Yun Hwang<sup>2</sup>·Jang-Hyun Lee<sup>1,†</sup>

Department of Naval Architecture and Ocean Engineering, INHA University<sup>1</sup>

Research Institute of Industrial Science and Technology, INHA University<sup>2</sup>

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<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.

In this study, the prediction method was reviewed to process a cylindrical plate forming using machine learning as a data-driven approach by roll bending equipment. The calculation of the forming variables was based on the analysis using the mechanical relationship between the material properties and the roll bending machine in the bending process. Then, by applying the finite element analysis method, the accuracy of the deformation prediction model was reviewed, and a large number data set was created to apply to machine learning using the finite element analysis model for deformation prediction. As a result of the application of the machine learning model, it was confirmed that the calculation is slightly higher than the linear regression method. Applicable results were confirmed through the machine learning method.

**Keywords** : Roll bending(롤 벤딩), Machine learning(기계 학습), Multi-layer perceptron(다층 퍼셉트론), Random forest(랜덤 포레스트), Finite Element Analysis(유한요소해석, FEA), Center roller displacement(중앙 롤러 변위)

## 1. 서론

선박의 생산공정에서 곡판 생산 기술은 일반적으로 가스 화염, 유도가열, 등의 열원을 이용한 열간 가공 방법이나 롤 벤딩 장비를 이용한 냉간가공 방법이 적용된다. 단방향 곡률을 가지는 곡판의 경우 롤 프레스(Roll-press) 장비를 이용한 가공 방법이 적용되고, 다중 곡률을 가지는 곡판의 생산 과정은 롤 프레스(Roll-press) 장비를 이용한 일차 곡면의 냉간 가공과 가스, 레이저, 고주파 열원 등을 사용하는 열간 가공을 순차적으로 이용하여 곡판을 성형하고 있다 (Kang et al., 2000; Lee & Shin, 2002; Shin et al., 2003).

선박의 곡판 가공 공정은 생산공정에서 높은 정밀도를 요구하기 때문에 많은 공수가 필요한 공정이다. 특히, 다중 곡률을 가지는 곡판 생산을 위해서 일차 가공의 완성도에 따라 후속 공

정인 열간 가공의 작업량과 작업성이 결정되므로 일차 가공의 정확한 정보산출은 주요한 분야로서 정밀도를 높이기 위한 연구가 다양하게 진행되어 왔다 (Kim et al., 1996; Yang & Shima, 1988).

Kim et al. (1996)은 피라미드 형 롤러에 의한 굽힘을 빔 이론 기반의 수치해석 방법을 통해서 목적 곡률을 가지는 곡판을 생산하기 위한 가공 정보를 계산하는 방법을 제시하였다. Shin et al. (2001)은 롤 벤딩을 이용한 실린더형 가공의 변형 예측을 위해서 유한요소해석 방법을 적용하였다. 그리고, Hardt et al. (1992)은 롤 벤딩의 가공 정보를 추출하기 위해서 데이터 기반의 접근방법으로 통계적인 방법을 통해서 목적 곡면의 곡률 분포에 따른 롤 굽힘 영역을 결정하였다.

본 연구에서는 롤 벤딩 장비를 이용하여 단방향의 곡률을 가지는 실린더 형상의 판재 가공을 가공하기 위해서 데이터 기반의 접근방법으로서 기계 학습을 이용한 예측 방법에 대해서 검

토하였다. 가공 정보는 산출 과정은 가공하고자 하는 판재의 두께와 실린더 형상의 목적 곡률이 정해지면 이를 가공하기 위한 롤러의 변위를 계산하는 방법으로 접근하였다. 적용 방법은 일차 곡 가공 과정에서 나타나는 가공 대상의 외판과 롤 밴딩 기계의 기하학적 관계를 이용한 해석을 통해 원하는 곡률의 외판 생산을 위한 중앙 롤러의 수직 방향 변위를 도출하는 실험을 수행하여 실린더 가공의 초기 데이터를 확보하였다. 그리고 유한요소해석법을 적용하여 변형 예측 모델의 정확성을 검토하고, 다수의 데이터 셋(Data Set)을 확보하기 위해서 변형 예측을 위한 유한요소해석 모델을 이용해서 기계 학습에 적용할 데이터 셋을 생성하였다. 생성된 데이터 셋을 기반으로 기계 학습 알고리즘인 Multi-layer perceptron과 Random forest를 이용하여 가공하고자 하는 목적 곡률을 얻기 위한 중앙롤러의 수직 변위 예측 방법에 대해서 검토하였다.

## 2. 기계 학습을 이용한 성형 조건 예측

본 연구에서는 기계 학습 방법을 적용하여 단방향의 1차 곡률을 가진 실린더 판재의 성형 조건을 예측하고자 한다. 기계 학습을 이용한 정보 예측 과정은 일반적으로 예측하고자 하는 목적 변수의 특징을 파악하고 (Hwang et al., 2018), 이를 예측하기 위한 관련 데이터를 수집하는 것으로 진행된다. 획득된 데이터로부터 기계 학습 모델을 구성하기 위해 전체 데이터를 훈련 데이터(Training data)와 테스트 데이터(Test data)로 나누고, 교차검증(Cross validation) 과정을 통해 예측력이 가장 좋은 모델을 개발한다. 본 연구에서도 이러한 일반적인 기계 학습 모델 개발 절차를 적용하여 Fig. 1과 같이 성형 조건 예측 모델을 개발하기 위한 절차를 구성하였다. 구성된 절차는 실린더 판재의 성형 조건 특징에 대한 분석과 성형 조건 예측을 위한 데이터 수집, 그리고 Multi-layer perceptron과 Random forest 등의 기계 학습 알고리즘을 기반으로 획득된 데이터를 적용하여 기계 학습 모델을 개발하고 검증하는 절차로 구성된다.




Fig. 1 Overall procedure of the roll bending parameters

본 연구에서는 실린더 판재의 성형 정보를 산정하는데 기계 학습 방법의 적용에 대해서 검토하였다. 실린더 판재 성형 시 주요 성형 상부 중앙롤러의 변위, 판재의 두께, 결과 곡률의 세 가지 변수로 정의하였으며, 데이터 셋을 수치적으로 확보하고 확보된 데이터를 기계 학습 알고리즘에 적용하여 가공 정보를 예측하였다. 따라서 본 논문은 3절에서 판재 가공 데이터 확보 단계에 대해서 상세히 서술하였으며, 4, 5절에서는 확보된 데이터 셋을 기계 학습에 적용하는 단계로 구성하여 그 과정을 설명하였다.

### 2.1 실린더 판재 가공 장비

본 연구에서는 단방향 곡판의 가공 정보를 예측하기 위해서 소형 실험 장비를 사용하였다. 가공 장비는 Fig. 2에 보인 바와 같이 2개의 하부 롤러(Bottom roller)와 1개의 상부 중앙롤러(Upper center roller)로 구성되어 있으며, 상부 중앙롤러의 변위를 제어하는 방식으로 그 가공량을 산출하며, 약 3t의 두께를 갖는 판재까지 가공할 수 있는 실험 장비이다. 장비의 치수 정보는 Table 1에 정리하였다.

Table 1 Dimension of three-roll bending machine

Parameter	Dimension
Length of rollers	650mm
Radius of rollers	50mm
Dist. between Bottom rollers	51mm




Fig. 2 Pyramid type three-roll bending machine

### 2.2 실린더 판재의 성형 특징

롤 밴딩 장비를 이용한 성형 공정은 가공되는 판재 관점에서 단순화 시킨다면 Fig. 3에서와 같이 세 개의 실린더가 구성된 가공 장비로 나타낼 수 있다. 그리고 Fig. 3의 각 가공 과정에서 2. Loading에서 4. Unloading 과정까지는 상부 중앙롤러의 수직 방향 변위가 판재를 가공하기 위한 주요 변수가 된다. 주요 변수를 결정하는 요인으로는 가공하는 판재의 두께와 가공 후 판재의 곡면 가공 정도를 표현하는 곡률이 있다.




Fig. 3 Process of roll bending

### 3. 실린더 판재 성형 데이터

실린더 판재의 성형 과정은 가공하고자 하는 목적 곡률을 가지도록 상부 중앙롤러의 변위를 제어하여 판재를 가공하는 것이다. 이는 가공을 하기 위한 상부 중앙롤러의 변위를 입력하면 입력된 변위 및 판재의 두께, 재료의 강성 등을 고려하여 어떤 곡률을 가지는 판재가 성형되는 절차로 설명할 수 있다. 이 과정에서 발생하는 주요 성형 변수는 상부 중앙롤러의 변위, 판재의 두께, 결과 곡률의 세 가지 변수로 정의할 수 있다. 여기서 초기 상부 중앙롤러의 변위를 계산하기 위해서는 목적 곡률을 가공하기 위한 상부 롤러의 위치를 계산하여야 한다. 따라서 성형 데이터의 계산 절차는 첫 번째, 목적 곡률을 가공하기 위한 상부 중앙롤러의 위치 계산, 두 번째 실험을 통한 가공 데이터 셋 확보, 세 번째 유한요소 해석을 통한 데이터 셋의 확장의 단계로 진행하였다.

본 연구에서는 위의 세 가지 변수를 조건별로 수집하기 위해서 빔 이론 기반의 가공량 계산과 Fig. 2의 실험 장비를 이용한 가공 실험을 통해 타당 데이터를 확보하였다. 그리고 실험 장비 규모 및 가용률의 한계를 극복하기 위해서 유한요소해석방법을 적용하여 기계 학습에 적용하기 위한 데이터를 생성하였다.

#### 3.1 빔 이론 기반 상부 중앙롤러 변위 계산

앞서 언급한 세 가지 변수 중 초기 상부 중앙롤러 변위에 대한 데이터를 확보하기 위해서, 빔 이론 기반 상부 중앙롤러 변위 계산법을 적용하였다. 본 방법은 두께를 가지는 판재의 목적하는 곡률 정보와 가공 장비의 기하학적 특징을 입력받아서 탄소성 변형을 고려한 빔(Beam) 이론을 기반으로 반복적으로 분석하여 상부 중앙롤러의 변위를 계산하는 방법으로, 그 계산과정은 다음과 같다 (Hansen & Jannerup, 1979; Oh & Kobayashi, 1980).

실린더 형상 가공 과정에서 외판이 겪는 작은 변형은 빔으로 가정할 수 있다. 이때, 외판에 작용하는 굽힘 모멘트의 분포는 Fig. 4와 같이 분포하는 것을 가정할 수 있다. 여기서,  $s$ 는 외판의 호의 길이로  $s_0$ 는 하부 좌측롤러와 외판의 접촉점,  $s_1$ 는 상부




Fig. 4 Distribution of bending moment in three roll bending

중앙롤러와 외판의 접촉점, 그리고  $s_2$ 는 하부 우측롤러와 외판의 접촉점이다.  $M_p$ 는 외판의 호의 길이에 따른 굽힘 모멘트로 식 (1)과 같이 나타낼 수 있다.

$$M_p(s) = \begin{cases} M_p(s_1) \frac{s-s_0}{s_1-s_0} & \text{for } s_0 \leq s \leq s_1 \\ M_p(s_2) \frac{s_2-s}{s_2-s_1} & \text{for } s_1 \leq s \leq s_2 \end{cases} \quad (1)$$

빔 이론의 모멘트와 곡률의 관계식을 이용하여 위치  $s$ 에서 단면적의 모멘트 분포는 식 (2)와 같이 나타낼 수 있다.

$$M(s) = 2b \int_0^{t/2} \sigma \eta d\eta = \frac{2b}{\kappa^2(s)} \int_0^{\epsilon_{\max}} \sigma(\epsilon) \epsilon d\epsilon \quad (2)$$

$$\kappa_r(s) = \kappa_p(s) - \frac{M_p(s)}{EI} \quad (3)$$

여기서  $b$ 는 외판의 폭,  $t$ 는 외판의 두께,  $\sigma$ 는 외판의 응력,  $\eta$ 는 단면적 중심에서 수직 방향 거리,  $\kappa(s)$ 는 위치  $s$ 에서 곡률값, 그리고  $\epsilon_{\max}$ 는  $(t/2) \kappa(s)$ 를 의미한다. Fig. 5는 위치의 단면적에서 전형적인 모멘트와 곡률의 관계를 나타낸다.  $M_p$ 는 소성 모멘트(Plastic moment),  $k_p$ 는 소성 모멘트에서의 곡률,  $M_r$ 는 항복 모멘트(Yield moment),  $k_r$ 는 항복 모멘트에서의 곡률, 그리고  $k_r$ 은 단면적 중심에서의 잔여 곡률(Residual curvature)이다. Fig. 5의 가공 과정에서 외판에 작용하는 모멘트에 의한 곡률 변화를 화살표를 이용하여 나타냈다. 탄소성 거동에서 나타나는 잔여 곡률을 식 (3)과 같이 나타낼 수 있다.  $E$ 는 탄성계수, 그리고  $I$ 는 2차 면적 모멘트이다.

$$\theta_1 = \theta_0 + \int_{s_0}^{s_1} \kappa_p(s) ds \quad (4)$$

$$x_1 = x_0 + \int_{s_0}^{s_1} \cos(\theta_0 + \int_{s_0}^{s_1} \kappa_p(s) ds) ds \quad (5)$$

$$y_1 = y_0 + \int_{s_0}^{s_1} \sin(\theta_0 + \int_{s_0}^{s_1} \kappa_p(s) ds) ds \quad (6)$$

$$\theta_2 = \theta_1 + \int_{s_1}^{s_2} \kappa_p(s) ds \quad (7)$$

$$x_2 = x_1 + \int_{s_1}^{s_2} \cos(\theta_1 + \int_{s_1}^{s_2} \kappa_p(s) ds) ds \quad (8)$$

$$y_2 = y_1 + \int_{s_1}^{s_2} \sin(\theta_1 + \int_{s_1}^{s_2} \kappa_p(s) ds) ds \quad (9)$$

$$a = r \sin \theta_0 + (x_1 - x_0) + r \sin \theta_1 \quad (10)$$

$$a = r \sin \theta_0 + (x_2 - x_1) + r \sin \theta_2 \quad (11)$$

$$y_2 = r \sin \theta_2 \quad (12)$$

가공 중 변형 형상과 가공 조건의 기하학적 관계를 Fig. 6에 나타냈다.  $\theta_0$ 는  $s_0$ 에서 외판과 x축이 이루는 각도,  $\theta_1$ 과  $\theta_2$ 역시  $s_1$ 과  $s_2$ 에서 외판과 x축이 이루는 각도,  $x_0$ 와  $x_1$ , 그리고  $x_2$ 는 각각  $s_0$ 와  $s_1$ , 그리고  $s_2$ 의 x축 좌표 값,  $y_0$ 와  $y_1$ , 그리고  $y_2$ 는 각각  $s_0$ 와  $s_1$ , 그리고  $s_2$ 의 y축 좌표 값,  $r$ 은 롤러의 반지름, 그리고  $a$ 는 하부 좌측롤러와 하부 우측롤러 사이의 거리이다. 가공 장비와 외판 사이의 기하학적 관계에서 나타나는 변수를 식 (4)~(12)에 나타냈다. 빔 이론을 이용한 상부 중앙롤러의 변위 계산 알고리즘은 성형 조건의 대략적인 예측을 위한 용도로 사용하였다.




Fig. 5 Moment-Curvature curve for elastic-plastic beam




Fig. 6 Geometric relationship between rollers and workpiece

Table 2 Dimension of aluminum workpiece

Length	Width	Thickness
700mm	100mm	2mm

Table 3 Displacement of center roller with target curvature

Case	Target of curvature (Beam theory)	Displacement of center roller
1	4	5.2mm
2	5	5.8mm

위 방법을 이용하여 상부 중앙롤러의 변위를 계산하기 위해 A5052 H32의 알루미늄 판재를 대상으로 선정하였으며 그 치수는 Table 2와 같으며, Table 3에서와 같이 2가지 Case를 대상으로 실험에 적용하였다.

Table 3과 같이 2가지 조건에 대해 빔 이론을 기반으로 가공에 필요한 상부 중앙롤러의 수직 방향 변위를 계산하였다. 대상 판재에 대한 조건별 목적 곡률은 4와 5로 설정하였으며, 계산된 상부 중앙롤러의 수직 방향 변위를 기반으로 Fig. 2의 가공 장비를 통해서 실험을 수행하였다. 실험 결과 Fig. 8, 9에서 Experimental result와 같이 실험 결과를 확인하였다. 가공된 형상의 변위는 Table 4에서와 같이 RMS 오차가 약 0.05 정도로 예측되었다.

### 3.2 유한요소해석

앞서 빔 이론을 적용하여 상부 중앙롤러의 수직 방향 변위 계산하고 이를 적용한 실험 결과를 기초로 기계 학습에 적용하기 위한 다수의 데이터를 확보하기 위해서 유한요소해석 방법을 적용하여 기계 학습을 위한 약 300건의 가공 데이터 셋을 생성하였다. 적용된 유한요소해석은 상용 유한요소해석 프로그램인 ANSYS Workbench를 사용하였고, 사용된 요소는 20 절점을 가진 Solid 186 요소를 사용하였다. 적용된 유한요소해석 모델의 형상은 Fig. 7과 같다. 롤러의 반지름  $r$ 은 50 mm, 시편의 길이  $L$ 은 700 mm이다. 형상에서의 폭은 해석시간의 단축을 위해 10mm로 설정한 후 대칭 조건을 적용하였다. 본 모델에 적용한 재료 물성은 알루미늄 A5052 H32의 물성치를 고려하여 탄성계수는 70 Gpa, 항복 응력은 190 Mpa, 접선계수는 200 Mpa, 밀도는 2,680 kg/m<sup>3</sup>, 소성 모델은 등방성(bilinear isotropic hardening) 조건으로 가정하였다. 하중 조건은 Table 3에서 계산된 상부 중앙롤러의 수직 방향 변위를 적용하였다. 그리고 하부 롤러에는 조인트(Joint) 조건을 가정하여 판재가 이동할 수 있도록 접촉 조건을 부여하였다.

기계 학습에 적용하기 위한 데이터 셋을 확보하기 전 적용하고자 하는 유한요소해석 모델의 타당성을 검토하기 위해서 실험과 유한요소해석 결과의 변위 차이를 비교하였다. 판재 시편의 양 끝단을 기준으로 변위를 비교하면 중앙부에서 일부 오차가 있는 것으로 확인되나, Fig. 8, 9와 Table 4에서와 같이 RMSE(Root Mean Square Error) 오차를 기준으로 비교하면 그 차이가 크지 않은 것을 확인함으로써 적용된 유한요소 해석 방법이 타당성이 있음을 확인하였다.




Fig. 7 Model of pyramid type three-roll bending machine




Fig. 8 Comparison of displacement between experimental shape and FEA for target shape (Case 1)




Fig. 9 Comparison of displacement between experimental shape and FEA for target shape (Case 2)

Table 4 Root mean square error of experimental shape and FEA for target shape

Case	Root mean square error (Experimental shape)	Root mean square error (FEA)
1	0.0569	0.0087
2	0.0462	0.0064

### 3.3 실린더 판재 성형 데이터 셋

데이터 생성에서는 2장에서 수행한 유한요소해석 모델의 타당성 검증을 기반으로 유한요소해석 모델을 통하여 가공 조건(시편의 두께)과 변형량(중양롤러의 Y축 방향 변위) 사이의 총 296개의 학습 데이터를 생성하였다. 시편의 두께는 2~10 mm에서 1 mm 간격으로 선정하였고 데이터 부재의 가능성을 검토하기 위해서 5 mm 데이터를 제외하였다. 중양롤러의 Y축 방향

변위는 유한요소해석 모델에 사용된 롤러의 치수와 시편의 두께 사이의 관계에서 가능한 가동범위에서 1 mm 간격으로 설정하였다(Table 5, Fig. 10).

Table 5 Dataset list created through FEA model

No.	Thickness [mm]	Curvature	Displacement of center roller [mm]
1	2	0.2360	3.0
2	2	0.3906	3.1
3	2	0.5456	3.2
4	2	0.6887	3.3
5	2	0.8456	3.4
⋮			
292	10	8.7399	6.1
293	10	8.8508	6.2
294	10	9.1210	6.3
295	10	9.4284	6.4
296	10	9.9515	6.5




Fig. 10 Dataset created through FEA model

## 4. 기계학습 알고리즘

본 논문에서는 원하는 목적 곡률을 얻기 위한 상부 중양롤러의 수직 방향 변위를 예측하기 위해 기계 학습 회귀 알고리즘을 사용하였으며, 모델 학습에 사용한 회귀 알고리즘은 Random forest와 Multi-layer perceptron이다.

### 4.1 Random forest

Random forest는 앙상블 학습법인 Bagging(Bootstrap aggregation)을 기반으로 기계 학습을 수행하는 알고리즘이다. Random Forest는 지도 학습(supervised learning) 모델로서 분류(classification)와 회귀(regression)가 모두 가능한 다수의 Decision tree로 이루어져 있으며, 이는 Decision tree의 과적합

(overfitting) 문제를 해결하기 위해 고안되었다 (Pedregosa et al., 2011). Fig. 11에서와 같이 Random forest는 여러 모델을 이용하여 데이터를 학습하고, 모든 모델의 예측 결과를 평균하여 값을 예측하는 학습 기법이다.

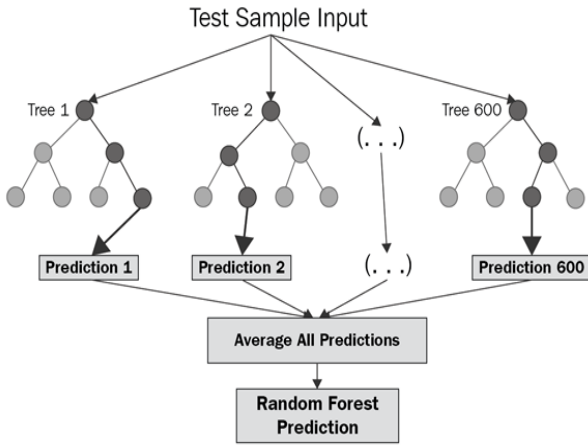


Fig. 11 Random forest explanation

### 4.2 Multi-layer perceptron

Multi-layer perceptron은 인공신경망(Artificial neural network, ANN)의 한 종류인 퍼셉트론(Perceptron) 기반의 기계 학습 알고리즘이다. Multi-layer perceptron은 입력층(input layer)과 출력층(output layer)으로 이루어진 퍼셉트론에 은닉층(hidden layer)을 추가한 것으로, 비선형 문제를 해결하기 위해 고안된 알고리즘이다. Multi-layer perceptron은 입력  $x$ 와 출력  $y$ 에 대해 식 (13)과 같이 정의된다.

$$y = f(W^T x) = f\left(\sum_{i=1}^n W_i x_i + b\right) \tag{13}$$

여기서,  $f$ 는 활성화 함수(activation function)이며 일반적으로 시그모이드 함수(Sigmoid function)가 이용된다.  $W_i$ 는 Multi-layer perceptron 모델의 가중치(Weight) 벡터이고,  $b$ 는 절편(Bias) 값이다. 가중치는 입출력 학습 데이터를 기반으로 반복적인 최적화 절차에 의해 계산된다 (Choi et al., 2009).

## 5. 기계 학습을 이용한 성형 조건 예측

### 5.1 적용 절차

기계 학습을 이용한 실린더 판재의 성형 조건 예측 절차는 데이터 전처리, 모델 학습 및 검증의 두 단계로 구성하였다.

데이터 전처리에서는 앞서 생성한 데이터로부터 모델 학습에 사용될 훈련 데이터(training data)와 검증에 사용될 테스트 데이터(Test data)를 분류하였다. 훈련 데이터로는 시편의 두께가

2~8 mm인 데이터를 사용하였고, 테스트 데이터로는 두께가 2~10 mm를 순차적으로 적용하였으며, 본 논문에서는 4 mm와 9 mm의 데이터의 결과를 Fig. 13, 14에서와 같이 도시하였다.

모델 학습 및 검증에서는 전처리된 훈련 데이터를 기반으로 여러 가지 기계학습법의 회귀 알고리즘을 적용하여 성형 조건 예측 모델을 학습시켰고, 이를 검증하기 위해 전처리된 테스트 데이터를 이용하여 성형 조건 예측을 수행한 다음 결과에 대한 비교평가를 수행하였다(Fig. 12).

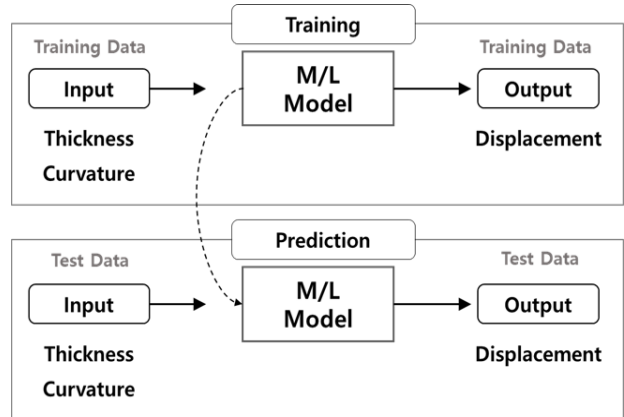


Fig. 12 Machine learning procedure

Table 6 Parameters for each machine learning algorithm for regression

Method	Parameter	Value
Random Forest	n_estimators	70
	max_features	2
	max_depth	8
Multi-Layer Perceptron	Activation	Sigmoid
	Number of hidden layer	1
	Hidden layer sizes	128
	Batch size	2
	Solver	SGD

### 5.2 적용 결과

성형 조건 예측 모델을 학습시키기 위해서는 각 알고리즘별로 성능을 결정할 수 있는 주요 파라미터를 설정해야 하며, 이러한 파라미터를 어떻게 설정하는지에 따라 모델의 정확성이 결정된다. Random forest의 주요 파라미터는 Decision tree의 개수를 나타내는 n\_estimators와 무작위로 선택할 Feature의 개수, 그리고 Decision tree의 깊이를 나타내는 Max depth가 있다. Multi-layer perceptron의 주요 파라미터는 은닉층의 입력 값을 비선형으로 변환해주는 활성화 함수, 은닉층의 개수, 은닉층의 크기, 훈련 데이터를 몇 개씩 나누어서 학습하는지 결정하는 Batch size, 그리고 최적화된 가중치를 계산하는 방법을 나타내는 Solver가 있다. 본 논문에서 적용한 각 알고리즘의 주요

파라미터와 최적의 주요 파라미터 조합은 Grid-search를 사용하여 선정하였으며, 그 결과를 Table 6에 정리하였다.

총 296개의 데이터 중 220개의 훈련 데이터가 학습에 사용되었고, 나머지 4 mm, 9 mm에 해당하는 76개의 테스트 데이터는 검증에 사용되었다. 기계 학습 모델 기반의 검증 값과 유한요소해석 값의 비교를 Fig. 13과 Fig. 14에 나타냈다. 성형 조건 예측 모델의 정확성을 평가하기 위해 테스트 데이터에 대한 성형 조건 예측 모델의 평균 제곱근 오차(Root Mean Square Error, RMSE)와 오차율(error rate)을 측정하여 각 알고리즘별로 Table 7에 정리하였다. 본 논문에서 적용한 기계 학습 알고리즘을 비교한 결과 Random forest 모델이 가장 낮은 평균 제곱근 오차를 나타냄을 확인하였다.




Fig. 13 Comparison of displacement between FEA and M/L model (thickness = 4mm)




Fig. 14 Comparison of displacement between FEA and M/L model (thickness = 9 mm)

Table 7 Root mean square error for each model

	Linear regression	Random forest	Multi-layer perceptron
RMSE	0.2618	0.1693	0.2160
Error rate	5.20%	3.05%	4.06%

## 6. 결론

본 연구에서는 실린더 형상을 가지는 판재를 가공하기 위해서 Random forest와 Multi-layer perceptron의 기계 학습 알고리즘을 적용한 상부 중앙롤러의 변위 예측 모델에 대해서 검토하였다.

기계 학습 방법을 적용하기 위한 데이터 셋 구축과정은 실가공데이터 확보의 한계로 소형 롤 밴딩 실험 장비를 이용한 실험 데이터 확보 이외에 유한요소해석 방법을 적용하여 약 300 가지 경우에 대한 데이터 셋을 확보하였다. 소형 롤 밴딩 실험 시 곡률에 대한 초기 가공 조건을 계산하기 위해서 Kim et al. (1996)이 제시한 빔 이론 기반의 변위 계산 방법을 적용하여 목적 곡률을 가공하기 위한 초기 상부 중앙롤러의 변위를 계산하고 이 결과를 실험에 적용하여 2가지 데이터 셋을 확보하였다. 확보된 실험 데이터는 유한요소해석 방법을 검증하는데 활용하고, 검증된 유한요소해석 모델을 이용하여 약 300개의 데이터 셋을 확보하였다.

기계 학습에 적용하기 위한 롤 밴딩 가공 변수의 종류는 실린더 판재를 가공하기 위한 상부 중앙롤러의 변위, 판재의 두께, 변형 형상의 곡률 세 가지의 변수를 기준으로 검토하였다.

확보된 데이터 셋은 학습 데이터(training data)와 테스트 데이터(Test data)로 분류한 뒤 Random forest와 Multi-layer perceptron 알고리즘을 적용하여 모델을 학습하고 학습한 모델로 검증한 결과를 비교하여 정확성을 검토하였다. 검토된 기계 학습 모델의 검증 결과는 데이터의 경향을 쉽게 예측할 수 있는 선형 회귀모델(linear regression) 결과와 비교하였을 때, 선형 회귀모델의 결과보다 Random forest와 Multi-layer perceptron 모델의 결과가 약 1~2%의 높은 정확도를 가지는 것을 확인하였다.

본 연구에서 적용한 기계 학습 방법의 적용 가능성을 검토할 때, 검증 정확도는 선형 회귀모델보다 다소 높게 평가되었으나, 적용 방법의 경제성과 효율성을 고려한다면 신중한 검토가 필요할 것으로 사료 된다. 그러나 본 연구에서 검토한 데이터 인자의 한계와 데이터 셋의 부족 등의 한계에도, 기계 학습 방법을 적용하였을 때, 일반적인 선형 회귀모델로 검증한 방법보다 정확도가 향상될 수 있다는 가능성이 확인되었다. 이러한 관점에서, 추후 현업에서 실제 데이터가 확보되고 다양한 인자가 고려된다면 가공 조건의 검증 정확도는 충분히 향상될 것이라 기대한다.

## 후기

본 논문은 산업통산자원부 산업소재핵심기술개발사업 (10063532) “극한환경용 ICE 내충돌, 고인성 해양플랜트 강재 및 적용 기술 개발” 과제와 2020년도 정부(산업통산자원부)의 재원으로 한국산업기술진흥원의 지원 (P0001968, 2020년 산업 혁신인재성장지원사업)을 받아 수행되었습니다.

## References

- Choi, G. S. et al., 2009. Short-term water demand forecasting algorithm using AR model and MLP. *Journal of Korean Institute of Intelligent Systems*, 19(5), pp.713-719.
- Hansen, N. E., & Jannerup, O., 1979. Modelling of elastic-plastic bending of beams using a roller bending machine. *Journal of Engineering for Industry*, 101(3), pp.304-310.
- Hardt, D.E., Constantine, E., & Wright, A., 1992. A model of the sequential bending process for manufacturing simulation. *Journal of Engineering for Industry*, 114(2), pp.181-187.
- Hwang, S. Y., Heo, J. Y., Hong, K. T., & Lee, J. H., 2018, Time series data analysis and fault diagnosis of plant process equipment using statistical machine learning method. *Korean Journal of Computational Design and Engineering*, 23(3), pp.193-201.
- Kang, J. G., Lee, J. H., & Shin, J. G., 2000. Numerical analysis of induction heating for the application of line heating. *Journal of the Society of Naval Architects of Korea*, 37(3), pp.110-121.
- Kim, Y. I., Shin, J. G., & Lee, J. H., 1996. Analysis of plate bending by pyramid type three-roll bending machine. *Transactions of the Society of Naval Architecture of Korea*, 33(4), pp.1-9.
- Lee, J. H., & Shin, J. G., 2002. Relations between input parameters and residual deformation in line heating process using finite element analysis and multi-variate analysis. *Journal of the Society of Naval Architects of Korea*, 39(2), pp.75-80.
- Oh, S. I., & Kobayashi, S., 1980. Finite element analysis of plane-strain sheet bending. *International Journal of Mechanical Sciences*, 22(9), pp.583-594.
- Pedregosa, F. et al., 2011. Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 12, pp.2825-2830.
- Shin, J. G., Lee, J. H., Kim, Y. I., & Yim, H. J., 2001. Mechanics-based determination of the center roller displacement in three-roll bending for smoothly curved rectangular plates. *KSME International Journal*, 15(12), pp.1655-1663.
- Shin, J. G., Ryu, C. H., Lee, J. H., & Kim, W. D., 2003. User-friendly, advanced line heating automation for accurate plate forming. *Journal of Ship Production*, 19(1), pp.8-15.
- Yang, M., & Shima, S., 1988. Simulation of pyramid type three-roll bending process. *International Journal of Mechanical Sciences*, 30(12), pp.877-886.

