

# 머신러닝을 활용한 가변 롤포밍 공정 web-warping 예측모델 개발

우영윤<sup>1</sup>, 문영훈<sup>1,#</sup>

## Application of Machine Learning to Predict Web-warping in Flexible Roll Forming Process

Y. Y. Woo, Y. H. Moon

(Received July 20, 2020 / Revised September 17, 2020 / Accepted September 18, 2020)

### Abstract

Flexible roll forming is an advanced sheet-metal-forming process that allows the production of parts with various cross-sections. During the flexible process, material is subjected to three-dimensional deformation such as transverse bending, inhomogeneous elongations, or contraction. Because of the effects of process variables on the quality of the roll-formed products, the approaches used to investigate the roll-forming process have been largely dependent on experience and trial-and-error methods. Web-warping is one of the major shape defects encountered in flexible roll forming. In this study, an SVR model was developed to predict the web-warping during the flexible roll forming process. In the development of the SVR model, three process parameters, namely the forming-roll speed condition, leveling-roll height, and bend angle were considered as the model inputs, and the web-warping height was used as the response variable for three blank shapes; rectangular, concave, and convex shape. MATLAB software was used to train the SVR model and optimize three hyperparameters ( $\lambda$ ,  $\epsilon$ , and  $\gamma$ ). To evaluate the SVR model performance, the statistical analysis was carried out based on the three indicators: the root-mean-square error, mean absolute error, and relative root-mean-square error.

**Key Words :** Flexible Roll Forming, Support Vector Regression, Web-warping, Blank Shape, Forming Roll Speed, Bend Angle, Leveling Roll

## 1. 서론

롤포밍 (roll forming) 공정은 판재를 다단의 성형롤에 통과시켜 점진적인 굽힘을 통하여 목표 단면형상으로 성형하는 공정이다[1]. 롤포밍 공정은 전통적인 스탬핑, 프레스 공정에 비해 투자비가 작고, 냉간에서 공정이 진행되기 때문에 제품표면이 미려하고 품질이 우수하다. 또한 롤포밍 공정은 고강도강과 같은 난성형재의 복잡한 형상의 부품제작이

가능하다. 현재 자동차, 항공, 선박, 건설분야와 같이 다양한 산업분야에서 제품 경량화를 위한 가변 단면 형상의 제품수요가 증가되고 있다[2,3].

하지만 롤포밍 공정은 길이방향으로 일정한 단면을 가지는 제품의 성형만이 가능하다는 한계를 가지고 있다. 이러한 롤포밍 공정의 한계를 극복하기 위해, 가변 롤포밍 (flexible roll forming) 공정이 개발되었다[4-6]. Fig.1에 나타난 바와 가변 롤포밍 공정에서는 기존 롤포밍 공정의 고정된 성형롤에 회전 및 폭방향 이송을 가능하게 하여 가변의 롤궤적(roll trajectory)를 따라 제품 성형이 가능하다.

1. 부산대학교, 기계공학부, 박사과정, #교수

# Corresponding Author : School of Mechanical Engineering, Pusan National University, Busan 609-735, Korea, E-mail : yhmoon@pusan.ac.kr, ORCID : 0000-0001-9766-9891

가변 롤포밍 공정간 소재는 횡굽힘(transverse bending) 뿐만 아니라 길이방향 굽힘(longitudinal bending), 길이방향 연신(longitudinal elongation), 길이방향 수축(longitudinal shrinkage)과 같이 다양한 3 차원 변형을 수반하면서 목표 형상으로 점진적 성형이 된다. 이 과정에서 과도하게 발생한 변형률은 성형 후 관재에 다양한 형태의 형상결함을 야기시킨다. 대표적인 형상결함은 web-warping), wrinkling, camber, springback 등이 있다[7,8]. 가변 롤포밍 공정에서 공정변수가 이러한 형상결함에 미치는 영향을 분석하고 형상결함 감소방안을 제시하기 위해 많은 선행연구가 수행되었다. 박 등[9]은 ICF(Incremental Counter Forming)시스템을 제안하여 가변 롤포밍에 적용하였다. 가변 롤포밍 공정에서 ICF 시스템 관련 공정변수의 영향을 분석하고 플랜지 부위 길이방향 변형을 분포를 제어함으로써 형상오차를 감소시켰다. 우 등[10]은 가변 롤포밍 공정에서 길이방향 web-warping 특성 분석을 위하여 블랭크 형상, 소재 물성, 성형각과 같은 인자들의 영향도 분석을 실험 및 해석을 통해 진행하였으며, 레벨링 롤시스템을 제안하여 길이방향 web-warping 결함을 감소시켰다.

가변 롤포밍 공정에서는 다양한 공정변수가 고려되어야 하고 공정간 소재의 변형거동이 복잡하여 공정을 이해하는데 많은 어려움이 있어 유한요소해석(finite element analysis)이나, 인공지능(artificial intelligence) 기술의 활용도가 높다. 머신러닝(machine learning)은 인공지능기술 중 하나로 데이터로부터 기계가 스스로 학습하도록 프로그래밍하는 기술이다. 현재 다양한 분야에서 수많은 양질의 데이터획득이 가능하고, 머신러닝 기법이 발전함에 따라 머신러닝을 이용한 예측 모델의 정확도가 인간

(human)을 능가하게 되었다. 이로 인해 현재 제조공정(manufacturing) 분야에도 머신러닝을 활용하려는 다양한 연구들이 진행되고 있다.

Kumar et al.[11]은 gray relational analysis, SVMs(support vector machines), RSM(response surface methodology)을 활용하여 점진판재성형(single point incremental forming process) 공정에서 거칠기를 예측하는 모델을 개발하였다. Ye et al.[12]은 새로운 머신러닝 알고리즘을 개발하여 시멘트 복합체(cementitious composite) 제조 공정에서 염화물 침투 깊이(chloride ingress depth) 및 염화물 함유량을 예측하였다. 가변 롤포밍 공정에서는 Dadgar et al.[13]은 인공신경망(artificial neural network)을 이용하여 가변 롤포밍 공정의 다양한 인자들을 고려하여 길이방향 web-warping 형상결함을 최소화하기 위한 최적화방안을 제시하였다. 머신러닝을 활용한 가변 롤포밍 공정 최적화 연구는 현재 소수만 진행되고 있으며, 다양한 머신러닝 기법을 활용한 공정 최적화에 대한 연구가 필요한 상황이다. 본 논문은 가변 롤 포밍 공정에서 MATLAB 소프트웨어를 통해 머신러닝 기법 중 SVR (support vector regression)을 활용하여 직사각, 오목, 볼록 블랭크 형상에 대하여 성형률 속도, 레벨링 롤 높이, 굽힘각 공정변수에 따른 web-warping 높이 예측 모델을 개발하였다. 개발된 SVR 모델의 root-mean-square error (RMSE), mean absolute error (MAE), relative root-mean-square error (RRMSE)를 계산하여 성능평가를 진행하였다.

## 2. 실험방법

본 논문에서는 실험실 규모의 가변 롤포밍 장비를 이용하여 실험이 진행되었다. 가변 롤포밍 장비는 Fig. 2(a)와 같이 크게 구동롤(driving roll), 성형롤(forming roll), 레벨링 롤(leveling roll), 가이드 롤(guide roll)로 구성되어 있다. 구동롤과 성형롤은 DC 모터로 구동된다. 성형롤은 최대 3단까지 설치할 수 있다. Fig.2(b)에 나타난 바와 같이 가변의 롤 레적을 따라 성형이 가능하도록 Servo모터에 의해 성형롤이 폭방향 이송 및 회전이 가능하다. 폭방향 이송 범위는 0 mm ~ 120 mm 이며, 회전 범위는 -30° ~ 30° 이다. Labview 프로그램을 이용하여 구동롤 속도, 각 성형롤의 폭방향 이송, 각도, 속도를 제어한다. 레벨링 롤은 공회전하는 한 쌍의 롤로 구성되어 있으며

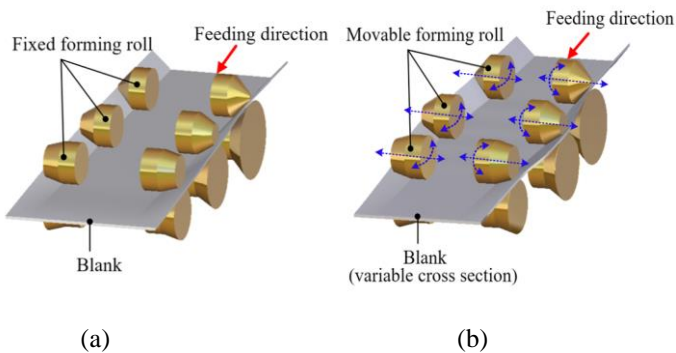
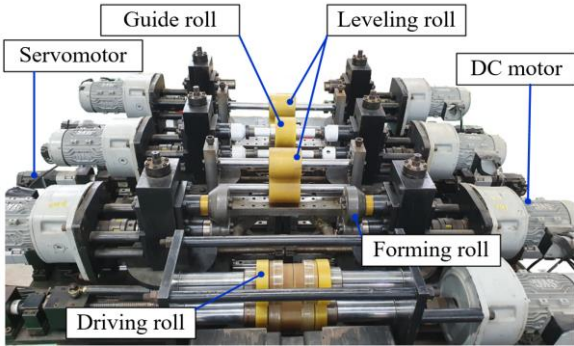
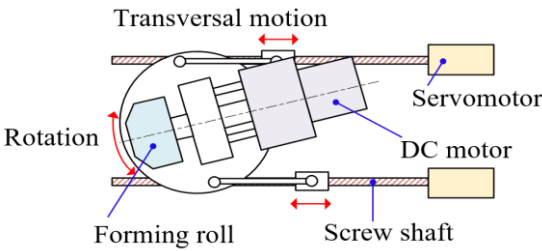


Fig.1 (a) Roll forming process and (b) flexible roll forming process

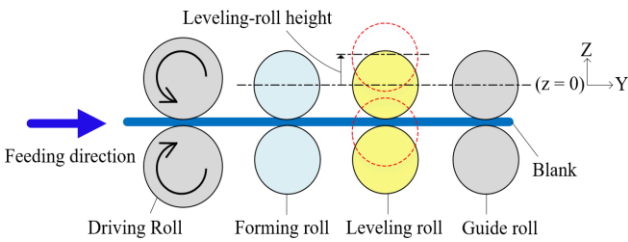
성형 시 소재가 좌우로 비틀리는 것을 방지하고 수직으로 높이 조절이 가능하여 Fig. 2(c)와 같이 소재 이송간 길이방향으로 굽힘을 유도한다. 가이드롤은 구동롤을 빠져나온 판재가 성형롤을 모두 통과할 때까지 판재의 이송을 원활히 진행시킨다.



(a)



(b)



(c)

Fig. 2(a) Lab-scale flexible roll forming machine, schematic of (b)forming roll movement, and (c) leveling roll

실험에서 사용된 소재는 0.8 mm 두께의 마일드강 SPCC가 사용되었다. SPCC 소재의 탄성계수는 207

GPa, 항복강도는 207MPa, 인장강도는 339MPa, 연신율은 33.2% 이다.

본 논문에서는 고려한 가변 롤포밍 공정변수는 블랭크 형상, 레벨링롤 높이, 굽힘각, 성형롤 속도이다. 블랭크 형상은 직사각형, 볼록형, 오목형 3가지가 사용되었으며, 블랭크 길이는 700 mm, 플랜지부 너비는 25 mm, 최소 웹부위 너비는 145 mm로 각 블랭크 형상 별 치수는 Fig. 3과 같다. 사용된 레벨링롤 높이는 -3 mm, 0 mm, 3 mm이고 굽힘각은 15°, 30°, 45° 이다. 성형롤 속도 조건은 공정간 성형롤 속도가 일정 조건과 성형롤 회전각에 따라 성형롤 속도가 변하는 조건을 사용하였다.

Fig. 4에 성형롤의 속도성분을 나타냈으며,  $r$ 은 롤의 반지름,  $\omega$ 은 각속도,  $v$ 은 선속도,  $\theta$ 은 성형롤 회전각이다. 롤포밍 공정에서는 공정간 블랭크 단면이 일정하기 때문에 성형롤이 회전하지 않아 속도 제어가 불필요하다. 하지만 가변 롤포밍 공정에서 길이방향으로 단면이 변하는 제품의 성형을 위해서는 성형롤이 가변의 롤레적에 수직이 되어야 하므로 성형롤은 롤레적에 따른 회전이 필요하다[14,15].

(a) (b) (c)

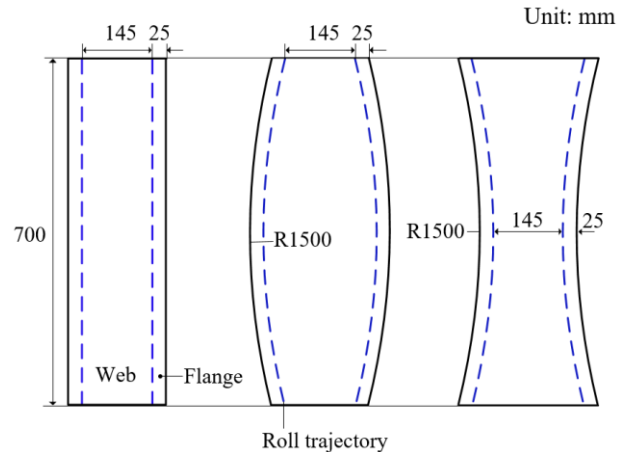


Fig. 3 Three blank shapes; (a) rectangular, (b) convex, and (c) concave

**Table 1** Process parameters and allocation of levels in experimental study

Process parameter	Type	Level	Level 1	Level 2	Level 3
Forming-roll speed ( $v$ )	Categorical	2	Constant	Variable	
Leveling-roll height ( $h$ )	Numerical	3	-3 mm	0 mm	3 mm
Bend angle ( $\alpha$ )	Numerical	3	15°	30°	45°

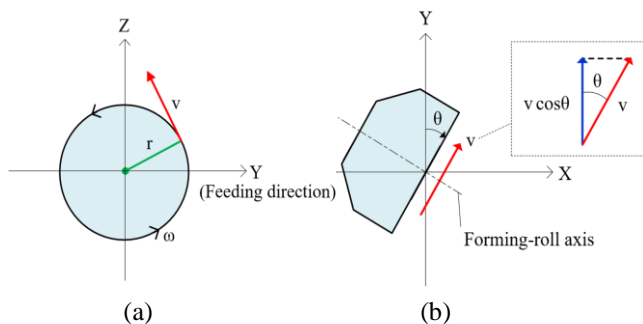
따라서 가변 롤포밍 공정에서는 블랭크 형상 곡률에 따라 성형롤이 회전하기 때문에 관재 이송속도를 일정하게 하기 위해서는 성형롤의 회전각에 따른 성형롤 속도제어가 필요하다. 이 때 구동롤에 의한 관재 이송속도와 성형롤의 이송방향 속도성분이 일치하지 않으면 블랭크에 버클링이 발생할 수 있다.

구동롤 및 성형롤에 의한 이송속도  $v_1, v_2$  식(1)과 같이 표현되고 아래첨자 1, 2는 각각 구동롤, 성형롤을 나타낸다. 블랭크 형상에 따라 성형롤이  $\theta$  만큼 회전할 때, 성형롤의 관재이송방향 속도성분이 관재의 이송속도와 같아지기 위한 각속도  $\omega_2$ 는 식(2)와 같이 표현된다.

$$v_1 = r_1\omega_1, \quad v_2 = r_2\omega_2, \quad (1)$$

$$v_1 = v_2 \cos \theta = r_2\omega_2 \cos \theta, \quad \omega_2 = \frac{v_1}{r_2 \cos \theta} \quad (2)$$

본 논문에서는 실험계획법 중에 완전요인배치 설계법을 기반으로 실험을 진행하였다. 3가지 블랭크 형상에 대하여 2수준 성형롤 속도 조건, 3수준 레벨링 롤 높이, 3수준 굽힘각 3가지 요인을 선정하였다.

**Fig. 4** A schematic of forming roll velocity;(a) side view, and (b) top view

각 블랭크 형상 당 18개의 실험으로 총 54개의 실험이 수행되었으며 각 요인에 따른 수준은 Table 1에 나타내었다.

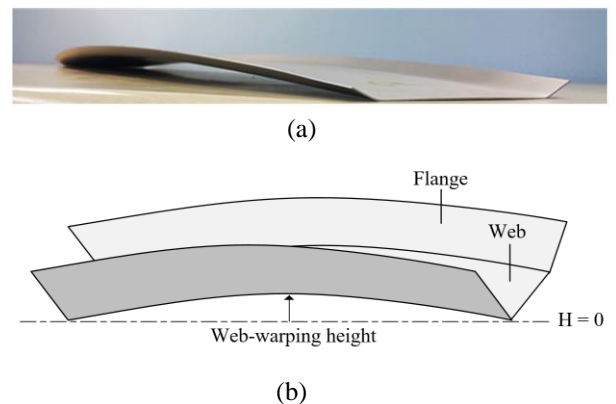
본 논문에서 실험결과의 길이방향 web-warping 높이를 비교하기 위하여 Fig. 5와 같이 길이방향 web-warping 높이를 웹부위의 높이 편차 중 최대값으로 정의하였다.

### 3. Support Vector Regression 모델링

머신러닝 알고리즘의 하나인 SVR은 분류(classification)기법 중 하나인 SVM (Support Vector Machine)을 일반화한 기법으로, 훈련데이터를 고차원 형상공간에 사상시킨 뒤 데이터를 최대한 많이 포함하게 하는 최적의 선형함수  $f(x)$ 를 추정하여 데이터를 예측하는 기법이며  $f(x)$ 는 식(3)과 같이 표현된다[16,17].

$$f(x) = \omega^T x + b \quad (3)$$

여기서 Fig. 6과 같이 소프트마진(Soft Margin) SVR을 위해 여유변수 (slack variable)  $\xi, \xi^*$  만큼의 오류를 허

**Fig. 5** (a) Experimental appearance of web warping and (b) measurement method for web-warping height

용하며 예측데이터와 훈련데이터의 편차가  $\epsilon$ -tube (epsilon tube) 이내로 유지하고 비용함수(Cost) C를 도입하여 최소화된  $\omega$ 를 찾기 위해 최적화 문제 구성하면 식(4)와 같다.

$$\min_{\omega} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \tag{4}$$

$$s.t. \begin{cases} y_i - f(x) \leq \epsilon + \xi_i \\ f(x) - y_i \leq \epsilon + \xi_i^* \end{cases}, \xi_i, \xi_i^* \geq 0$$

본 논문에서는 비선형 길이방향 web-warping 결과 값 데이터를 선형화하기 위해 가장 보편적으로 사용되는 가우시안 (Gaussian) 커널을 사용하였으며 [18], 가우시안 커널은 식(5)와 같이 표현된다.  $x_i, x$ 는 데이터를 의미하며,  $\gamma$ 는 가우시안 폭을 제어하는 매

개변수이다.

$$k(x_i, x) = \exp(-\gamma \|x_i - x\|^2) \tag{5}$$

본 논문에서는 가우시안 커널을 이용한 SVR 모델을 훈련시키기 위해 MATLAB 소프트웨어에 Statistics and Machine Learning Toolbox를 사용하였으며, SVR의 초모수 (hyper parameter) C,  $\epsilon$ ,  $\gamma$ 를 최적화하기

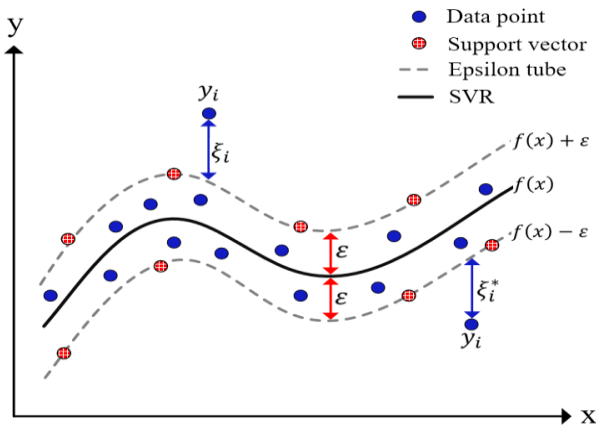


Fig. 6 A generic illustration of the SVR model

Table 3 Optimized hyper parameters in SVR model

Blank shape	Rectangular	Concave	Convex
C	34.3	758.9	958.3
$\epsilon$	5.41	6.49	7.92
$\gamma$	0.00468	0.06661	0.24471

위해서 MATLAB의 Hyperparameter Optimization Option을 사용하였다.

### 4 연구결과

본 논문에서 길이방향 web-warping 높이 예측을 위해 입력변수를 성형롤 속도, 레벨링 롤 높이, 굽힘각에 따른 길이방향 web-warping 높이 실험결과를 하나의 블랭크 형상에 대하여 18×4 매트릭스 (matrix)로 구성하여 SVR 모델을 훈련시켰다.

블랭크 형상에 따른 SVR모델의 최적화된 초모수 값은 Table 3에 정리된 바와 같이 직사각형상에 대하여 C = 34.3,  $\epsilon$  = 5.41,  $\gamma$  = 0.00468, 오목형상에 대하여 C = 758.9  $\epsilon$  = 6.49,  $\gamma$  = 0.0661, 볼록형상에 대하여 C = 958.3,  $\epsilon$  = 7.92,  $\gamma$  = 0.24471로 나타났다.

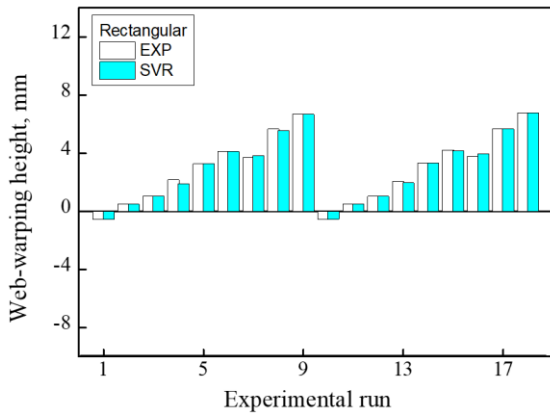
Fig.8에 블랭크 형상에 따른 길이방향 web-warping 높이 실험값과 SVR 모델 예측값을 나타냈다. SVR 모델의 R<sup>2</sup> 값은 Fig.9에 나타낸 바와 같이 직사각형상 일 때 0.9983, 오목형상 일 때 0.9966, 볼록형상 일 때, 0.9967로 나타났다.

훈련된 SVR 모델의 성능을 평가하기 위해 식 (6)-(9)과 같이 표현되는 RMSE(root mean square error), MAE(mean absolute error), RRMSE(relative root mean square error)를 계산하였다. 여기서  $y_i^{observed}$ ,  $y_i^{predicted}$ 는 각각 i번째 web-warping 측정값 및 예측값, n은  $y^{observed}$  혹은  $y^{predicted}$ 의 총 개수,  $\bar{y}^{observed}$ 는  $y^{observed}$ 의 평균값이다.

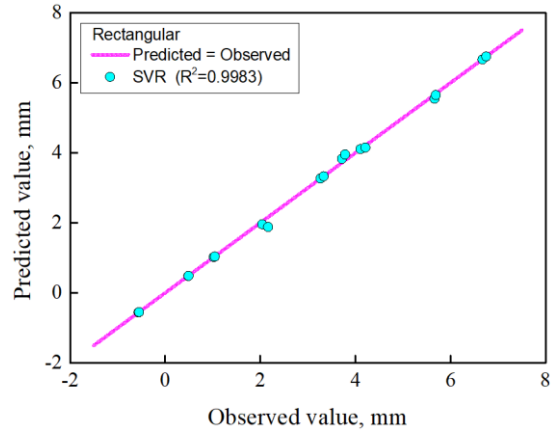
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{i=n} (y_i^{predicted} - y_i^{observed})^2} \tag{6}$$

$$MAE = \frac{1}{n} \sum_{i=1}^{i=n} |y_i^{predicted} - y_i^{observed}| \tag{7}$$

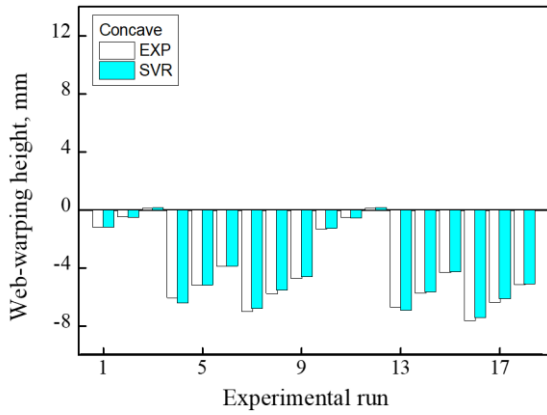
$$RRMSE = 100 \times \frac{RMSE}{\bar{y}^{observed}} \tag{8}$$



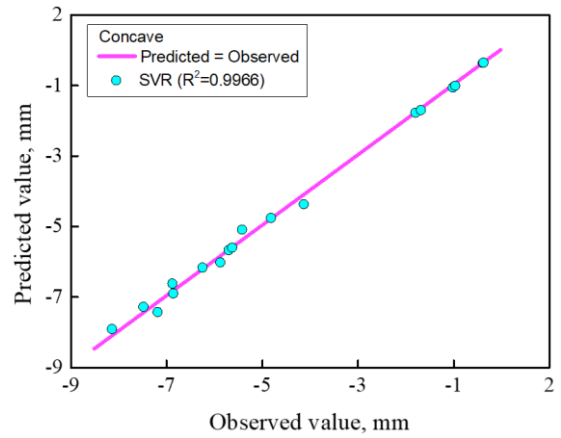
(a)



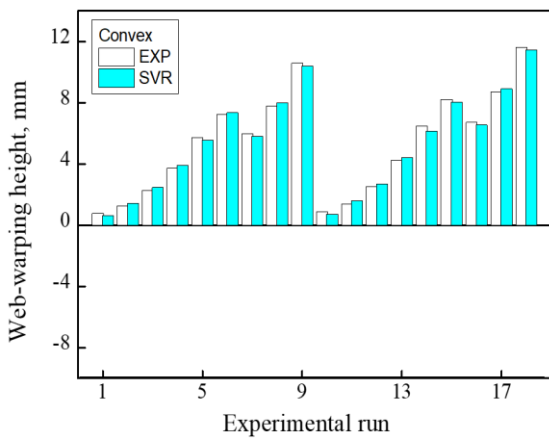
(a)



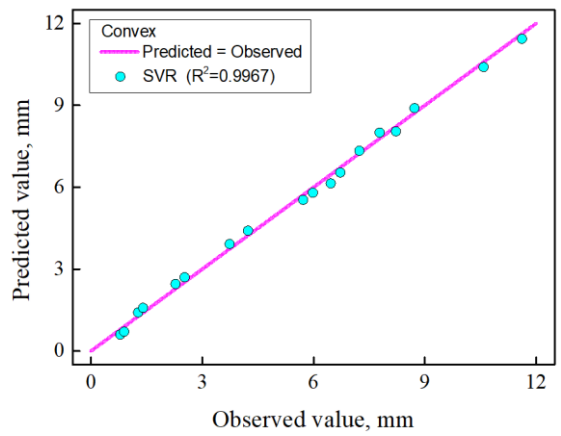
(b)



(b)



(c)



(c)

**Fig. 8 Comparison of actual experimental data (EXP) and predicted values for the web-warping height of SVR for (a) rectangular, (b) concave, (c) convex blank**

**Fig. 9 Regression plots of the predicted values for the web-warping height of SVR against the observed experimental values for (a) rectangular, (b) concave, (c) convex blank**



**Table 4 Statistical analysis results for SVR model**

Blank shape	Rectangular	Concave	Convex
RMSE	0.0597	0.0046	0.0277
MAE	0.0740	0.0357	0.1807
RRMSE	6.11	3.89	3.56

SVR모델의 RMSE, MAE, RRMSE 값은 Table 4에 나타난 바와 같이 직사각형상에 대하여 RMSE = 0.0597, MAE = 0.0740, RRMSE = 6.11, 오목형상에 대하여 RMSE = 0.0046, MAE = 0.0357, RRMSE = 3.89, 볼록형상에 대하여 RMSE = 0.0277, MAE = 0.1807, RRMSE = 3.56으로 나타났다. 선행연구에 의하면 RRMSE는 SVR모델의 성능 평가하는 지표로 이용될 수 있으며, RRMSE < 10% 일 때 excellent, 10% < RRMSE < 20% 일 때 good, 20% < RRMSE < 30% 일 때 fair, RRMSE > 30% 일 때 pool로 평가 할 수 있다고 보고 되었다[19, 20]. 3가지 형상에 대한 SVR모델의 RRMSE가 10% 미만으로 예측모델의 성능은 아주 우수로 판단할 수 있다.

## 5 결론

본 논문은 가변 롤포밍 공정의 형상결함 중 하나인 길이방향 web-warping 높이를 예측모델을 개발하기 위해 머신러닝의 SVR 기법을 이용하여 예측모델을 개발하고 성능을 평가하였다. 본 논문의 결과를 바탕으로 아래의 결론을 도출하였다.

(1) 훈련된 SVR 모델의 RMSE, MAE, RRMS를 계산하여 성능을 평가를 하였고 본논문의 SVR모델의 RRMSE는 10% 미만으로 예측 성능이 아주 우수하다고 판단된다.

(2) 성형롤 속도, 레벨링 롤 높이, 굽힘각 3가지 요인을 완전요인배치실험계획법으로 설계하여 SVR 모델훈련을 위한 효과적인 데이터를 얻을 수 있었다.

(3) SVR 모델의 초모수  $C$ ,  $\epsilon$ ,  $\gamma$  최적화를 통하여 성공적으로 예측모델을 훈련하였다.

(4) 본 논문의 연구결과는 가변 롤포밍 공정에서 머신러닝의 활용한 형상결함 예측방안을 제시하였으며 향후 가변 롤포밍 연구에서 보다 다양한 공정 변수를 고려한 형상결함 예측에 응용될 수 있다고 판단된다.

## 후 기

이 과제는 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음.

## REFERENCES

- [1] G. Halmos, 2005, Roll Forming Handbook, CRC Press. Boca Raton.
- [2] J. H. Jang, J. H. Lee, B. D. Joo, Y. H. Moon, 2009, Flow Characteristics of Aluminum Coated Boron Steel in Hot Press Forming, T. Nonferr. Metal. Soc., Vol. 19, no. 4, pp. 913~916.
- [3] B. H. Kang, M. Y. Lee, S. M. Shon, Y. H. Moon, 2007, Forming Various Shapes of Tubular Bellows using a Single-step Hydroforming Process, J. Mater. Process. Technol., Vol. 194, no. 1-3, pp. 1~6.
- [4] P. Groche, G. von Breitenbach, M. Jckel, A. Zettler, 2003, New Tooling Concepts for Futureroll Forming Applications. In ICIT 2003—The 4th international conference on industrial tools, Maribor, Slovenia.
- [5] H. Ona, 2005, Study on Development of Intelligent Roll Forming Machine. In ICTP 2005—The 8th international conference on technology of plasticity, Verona, Italy.
- [6] H. Ona, R. Sho, T. Nagamachi, K. Hoshi, 2010, Development of Flexible Cold Roll Forming Machine Controlled by PLC. Steel research international, Vol. 81, no. 9, pp. 182-185.
- [7] Y. Y. Woo, S. W. Han, I. Y. Oh, Y. H. Moon, 2019, Shape Defects in the Flexible Roll Forming of Automotive Parts, Int. J. Automot. Technol., Vol. 20, no. 2, pp. 227~236.
- [8] J. H. Kim, Y. Y. Woo, T. W. Hwang, S. W. Han, Y. H. Moon, 2016, Effect of Loading Pattern on Longitudinal Bowing in Flexible Roll Forming, J. Mech. Sci. Technol., Vol. 30, no. 12, pp. 5633~5639
- [9] J. C. Park, D. Y. Yang, M. Cha, D. Kim, & J. B. Nam, 2014, Investigation of a New Incremental Counter Forming in Flexible Roll Forming to Manufacture Accurate Profiles with Variable Cross-sections. Int. J. Mach. Tools. Manuf., Vol. 86, pp.

- 68~80.
- [10] Y. Y. Woo, S. W. Han, T. W. Hwang, J. Y. Park, Y. H. Moon, 2018, Characterization of the Longitudinal Bow during Flexible Roll Forming of Steel Sheets, *J. Mater. Process. Technol.*, Vol. 252, pp. 782~794.
- [11] K. A. Kumar, C. Ratnam, K. V. Rao, B. S. N. Murthy, 2019, Experimental Studies of Machining Parameters on Surface Roughness, Flank Wear, Cutting Forces and Work Piece Vibration in Boring of AISI 4340 Steels: Modelling and Optimization Approach, *SN Appl. Sci.*, Vol. 1, no.1, pp. 26.
- [12] Y. Yu, D. Wu, Q. Wang, X. Chen, W. Gao, 2019, Machine Learning Aided Durability and Safety Analyses on Cementitious Composites and Structures, *Int. J. Mech. Sci.*, Vol. 160, pp. 165~181.
- [13] Y. Asl. Dadgar, Y. Y. Woo, Y. Kim, and Y. H. Moon, 2020, Non-sorting Multi-objective Optimization of Flexible Roll Forming using Artificial Neural Networks, *Int. J. Adv. Manuf. Tech.*, pp. 1~14.
- [14] P. Groche, A. Zettler, S. Berner, G. Schneider, 2011, Development and Verification of a One-step-model for the Design of Flexible Roll Formed Parts, *Int. J. Mater. Form.*, Vol. 4, no. 4, pp. 371~377.
- [15] H. Ona, I. Shou, K. Hoshi, 2012, On Strain Distributions in the Formation of Flexible Channel Section Development of Flexible Cold Roll Forming Machine, *Adv. Mater. Res.*, Vol. 576, pp. 137~140.
- [16] K. H. Kim, H. Jin, 2019, A Study on the Development of the short-term Photovoltaic Power Forecasting System using Support Vector Regression (SVR), *J. Kor. Ins. Illum. Electr. Install. Eng.*, Vol. 33, no. 6, pp. 42~48.
- [17] B. C. Oh, S. Y. Kim, Development of SVR based Short-term Load Forecasting Algorithm, *THE Trans. Kor. Ins. Electr. Eng.*, Vol 68, no. 2, pp.95~99.
- [18] C. H. Wu, J. M. Ho, D. T. Lee, 2004, Travel-time Prediction with Support Vector Regression," *IEEE Trans. Intell. Transp. Syst.*, Vol. 5, no. 4, pp. 276~281.
- [19] P. D. Jamieson, J. R. Porter, D. R. Wilson, 1991, A Test of the Computer Simulation Model ARCWHEAT1 on Wheat Crops Grown in New Zealand, *Field. Crops. Res.*, Vol. 27, no. 4, pp. 337~350.
- [20] A. B. Heinemann, P. A. Van Oort, D. S. Fernandes, A. D. H. N. Maia, 2012, Sensitivity of APSIM/ORYZA Model due to Estimation Errors in Solar Radiation, *Bragantia*, Vol. 71, no. 4, pp. 572~5.