

열간압연 강판 두께 예측 및 베이지안 최적화 기반 압연패턴 도출

김경수 · 김성범[†]

고려대학교 산업경영공학과

Hot-Rolled Steel Plate Thickness Prediction and Bayesian Optimization-Based Rolling Pattern Derivation

Kyungsoo Kim · Seoung Bum Kim

Department of Industrial and Management Engineering, Korea University

In the steel manufacturing process, the hot rolling process involves the thin rolling of materials at a high temperature. Producing hot rolled products with the optimal thickness is one of the most important tasks to meet the customers' needs. To control the thickness, accurate measuring is essential. Because the thickness gauge is located at the exit of the rolling mill, the head part of hot rolled products cannot be controlled after measurement. Consequently, most thickness defects occur at the head part. In this study, we attempt to predict the thickness of the head part before finishing rolling process by using various machine learning methods. Further, explainable artificial intelligent methods are used to identify the factors that significantly affect to the thickness. Having identified these significant factors, we use Bayesian optimization to discover the optimal rolling pattern in finishing rolling process for the target thickness. It can be seen that the thickness deviation during rolling can be reduced by 29.6% using the optimized rolling pattern.

Keywords: Bayesian optimization, machine learning, thickness prediction, hot rolling mill, XAI

1. 서론

철을 만드는 제철 공정은 제선, 제강, 연주, 압연공정으로 구분할 수 있다. 연주공정에서 만든 반제품(slab)을 다시 고온으로 가열하여 철의 상을 변환하고 열간상태에서 압연하는 공정이 열간압연 공정이다. 소재를 얇게 압연하는 공정이기 때문에 고객이 요구하는 두께를 정확히 생산해야 한다(Li *et al.*, 2022). <Figure 1>은 열간압연 공정의 구성과 계측기의 위치를 나타낸 그림이다. 열간압연 공정은 가열로(furnace), 조압연(roughing mill), 마무리 압연(finishing mill), 냉각 및 권취(cooling and coiling)의 세부공정으로 나눈다.

가열로 공정에서는 1,200도 이상의 고온으로 반제품을 가

열하여 압연하기 좋은 상태로 만들며, 조압연 공정에서는 가열된 반제품의 폭을 압연한다. 본 논문의 주요 연구 영역인 마무리 압연은 고객이 원하는 두께로 압연하는 공정이고 두께 제어를 위한 압연기는 7개로(F1, ..., F7 in <Figure 1>) 구성되어 있다. 두께를 제어하기 위해서는 두께계측기가 필수적이지만 압연기 사이에는 고온과 분진, 수증기로 인해서 두께계측기를 설치할 수 없기 때문에 두께계측기는 마지막 압연기 출측에 설치되어 있다. 이 두께계측기는 두 가지 용도로 활용되는데 첫 번째는 품질을 계측 및 저장하기 위한 용도이고, 두 번째는 두께를 계측하여 편차에 따라서 마무리 압연기를 제어하는 용도로 사용된다. <Figure 2>는 측정된 두께 계측 결과의 예시를 보여주고 있다.

This research was supported by BK21 FOUR.

[†] 연락처 : 김성범 교수, 02841, 서울특별시 성북구 안암로 145 고려대학교 산업경영공학부, Tel : 02-3290-3397, Fax : 02-929-5888,

E-mail : sbkim1@korea.ac.kr

2022년 11월 24일 접수; 2023년 1월 19일 수정본 접수; 2023년 1월 25일 게재 확정.




Figure 1. Hot Rolling Process Layout and Thickness Gauge Location

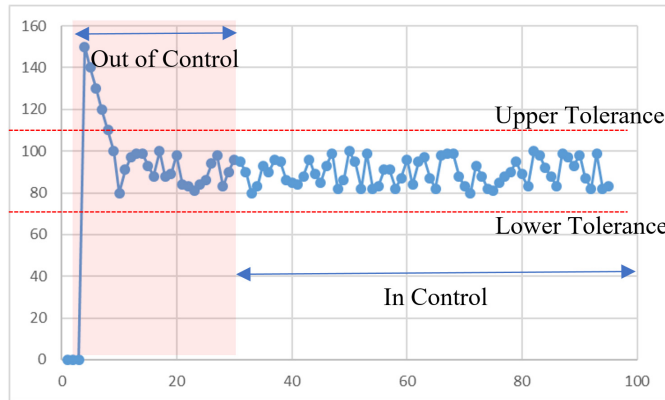


Figure 2. Example of a Thickness Chart Measured from a Thickness Gauge

해당 그림은 제어불가영역(out of control)과 제어가능영역(in control)으로 나눌 수 있다. 압연된 강판의 가장 앞부분(head)은 이미 두께계측기에 도달한 상태이기 때문에 계측 후 제어가 불가능하다. 이런 이유로 열간압연 공정에서 발생하는 두께 불량률의 대부분이 강판의 head부에서 발생하고 있다(Lee *et al.*, 2002). 불량률이 발생한 경우에는 고객에게 전달할 수 없기 때문에 불량률 절사하는 공정을 추가로 진행하거나 생산된 강판 전체를 폐기해야 한다.

강판 head부의 두께를 제어하기 위해서는 마무리 압연기의 초기 설정이 중요하고 이는 마무리 압연기에 압연되기 전 결정되는데, 주요 결정 항목으로는 압연 온도, roll force(목표로 하는 두께로 압연하기 위해 필요한 힘), roll gap(압연기의 상/하부 roll사이 간격), 압연기 속도가 있다(Lee *et al.*, 2002). 설정된 속도 값에 따라서 압연기는 가/감속을 하고 설정된 roll gap으로 압연기가 동작한다. 초기 설정 계산 순서는 다음과 같다. 첫 번째로 온도 계산의 경우 조압연 작업 완료 후 계측된 온도에서 각 압연기에 도달할 때까지 시간과 물로 인한 냉각 여부를 고려하여 압연할 때 온도를 계산한다. 두 번째로 계산된 온도(800℃~900℃)하에 각 압연기에서 목표로 하는 두께로 압연하기 위해 roll force를 계산한다. 마지막으로 계산된 roll force로 roll gap을 설정한다. 이 계산 과정에서 다양한 문제들이 발생하는데 대표적으로 온도를 계산할 때 이전 공정(가열로, 조압연)의 열 이력을 반영하지 않기 때문에 실제 온도와 차이가 발생하게 된다. 또한 정확한 roll force의 계산을 위해서는 소재가 가열된 상태에서 소성변형을 위한 최소로 필요한 힘(열간항복강도)을 알아야 하지만, 정확한 열간항복강도를 생산되는

제품마다 실험을 통해 측정할 수 없기 때문에 생산 후에 계측된 roll force로 열간항복강도를 추정한다. 작업을 위해 계산된 roll force는 계산한 값과 실제 작업 후 계측된 값에 차이가 발생하고 이는 두께 불량을 야기한다. 열간압연 공정에서 현재 사용되는 계산방식은 대부분 물리 현상과 선형 회귀 기반의 모델들로 제한적인 변수들과 다양한 가정들로 간소화된 수식이 활용된다. 두께에 영향을 주는 다양한 요소들을 반영하지 않고 계산된 온도, roll force, roll gap으로 압연을 하기 때문에 최종 품질인 head부의 두께는 정확하지 않고 편차가 발생한다. 기계학습 방법론들은 이러한 문제를 서로 교호작용이 존재하는 다양한 변수들의 효과적인 반영으로 해결할 수 있다. 또한 마무리 압연을 하기 전에 두께를 정확히 예측하는 모델과 최적화 기법들을 활용하면 최적의 압연 패턴 도출이 가능하다.

본 연구에서는 강판의 head부 실제 두께와 고객이 주문한 두께 간에 차이를 줄이기 위해서 3가지 단계로 실험을 진행한다. 첫 번째는 기계학습 방법론들을 활용하여 head부 두께를 예측하는 예측모델을 학습한다. 두 번째는 예측을 위해 사용되는 변수들 중 예측에 중요하게 영향을 주는 인자를 확인한다. 중요 변수의 확인을 위해 XAI(explainable artificial intelligence) 기법을 사용하여 변수의 중요도를 확인한다. 세 번째는 중요 변수들을 활용하여 예측된 두께가 목표 두께에 가까워지기 위해 필요한 중요 변수의 최적 값을 베이지안 최적화(Bayesian optimization)를 통해 제안한다. 본 논문의 기여점은 다음과 같다.

- 열간압연 공정에서 정확한 두께의 제품을 생산하기 위해 두께 불량을 압연 작업 전에 예측하고 예측모델을 활용하여 목표 두께와 동일하게 작업되기 위한 최적의 압연

패턴을 베이지안 최적화를 통해 도출한 첫 사례이다.

- 최적화된 압연패턴으로 작업 시 결함의 수준을 29.6% 감소할 수 있는 가능성을 입증하였다.
- 실제 철강 산업 현장에서 작업된 데이터를 활용하여 기계학습으로 두께를 예측했기 때문에 실제 생산라인에 적용이 가능하다.

본 논문의 구성은 다음과 같다. 제2장에서는 철강산업에서 관련된 연구들을 소개하고, 제3장에서는 제안 방법론을 소개한다. 제4장에서는 실험결과를 비교하고, 제5장에서는 본 연구의 결론에 대해 다루도록 한다.

2. 관련 연구

열간압연 공정의 주요 목적 중 한 가지는 고객이 요청하는 두께의 강판을 생산하는 것이며, 이를 위해 제품 품질이나 조업 조건을 추정하려는 다양한 연구가 수행되었다. 가장 많은 연구는 인공지능망 모델을 이용하여 roll force를 예측하는 연구이다(Son *et al.*, 2004; Bagheripoor *et al.*, 2016; Lee *et al.*, 2002; Yang *et al.*, 2004; Zhang *et al.*, 2016). Roll force의 예측은 정확한 두께의 제품을 생산하기 위한 목적으로 활용되었고 다른 품질 특성들을 예측하기 위한 연구도 다양하게 진행되었다. 대표적으로 특정 조업조건으로 생산 시 기계적 특성이 어떻게 변하는지 알기 위해 활용되었는데 Wu *et al.*(2017)은 베이지안 신경망에 기초한 C-Mn 강재의 기계적 특성을 예측하는 모델을 학습했다. Deng *et al.*(2019)은 열간압연 강판의 crown 예측을 위한 세 가지 다른 신경망 구조를 확립하고, 비교를 통해 최적의 심층 신경망 예측 모델을 제안하였다. Ståhl *et al.*(2019)에서는 slab 모양을 예측하기 위해 순환신경망(recurrent neural network, RNN) 및 어텐션(attention) 메커니즘을 사용했다. Li *et al.*(2022)에서는 물리적 기반의 모델들이 다양한 가정과 환경적인 요소들 때문에 예측 성능이 좋지 않고 다양한 계수들을 직접 튜닝해야 한다는 점을 지적하며, SCN(stochastic configuration network)을 통해 두께를 예측하는 모델을 제시하였다.

제조업에서는 정확한 예측모델을 구축하는 것도 필요하지만, 예측에 중요한 역할을 한 변수를 찾아내는 것도 매우 중요하다. Jesus *et al.*(2021)은 다양한 설명 가능 인공지능 기법을 소개하였고, 이들을 모델의 설명력 관점에서 비교 분석하였다. 비교한 기법은 SHAP(shapley additive explanation), LIME(local interpretable model), tree interpreter로 분석을 진행하고 비교한 결과를 정리하였다. 속도와 정확도 측면에서 좋은 성능을 나타내는 것은 SHAP 알고리즘이라고 설명하였다. SHAP은 특정 변수를 제외하고 모델을 구성했을 때, 성능을 비교하면서 해당 변수의 중요도를 분석하는 알고리즘이다(Lundberg *et al.*, 2017). Tiensuu *et al.*(2021)은 stainless steel의 품질향상을 위한 XAI 알고리즘의 활용을 소개하였고, 품질 제어를 위한 증거 기반 의사결정 지원을

위해 실험을 수행하였다. 데이터에서 SHAP을 활용하여 강판의 거칠기와 연관된 인자들을 확인하고 원인을 분석하였다.

모델 학습시 최적의 매개변수(hyperparameter)를 찾는 것은 중요하다. 선행연구 대부분은 열간압연 공정과 관련된 모델들을 구축하고 매개변수를 찾기 위해 최적화를 진행했다. Wang *et al.*(2018)에서는 SVR(support vector regression)로 강판의 crown을 예측하는 모델을 제안하고, 최적화 알고리즘을 통해 모델 매개변수를 최적화하였다. Li *et al.*(2021a)에서는 베이지안 최적화를 활용하여 LightGBM의 매개변수를 최적화 했고, CVC roll의 변동량을 예측했다. Li *et al.*(2021b)에서는 random forest, XGBoost, LightGBM 등을 활용하여 판 crown을 예측하는 모델을 구축했고, 매개변수 최적화를 위해 베이지안 최적화를 활용했다. Wang *et al.*(2017)에서는 굽힘력 예측을 위한 인공지능망을 활용했고 유전 알고리즘으로 최적화 했다.

3. 제안 방법론

3.1 데이터 수집 및 전처리

데이터는 포스코 광양제철소 2열연 공장에서 작업된 2021년 7월부터 2022년 5월까지 제품 데이터를 추출했고, 가열로 작업 실적, 조업연 작업 실적, 마무리 압연 설정, 두께계측기의 계측 실적을 수집했다. 두께는 0.05초 단위로 2,400개의 데이터를 사용했으며, 총 155,252개의 행과 278개의 열로 이루어졌다. <Figure 2>에서 제어불가영역(out-of-control area)을 예측해야 하기 때문에 head부 30 point의 평균을 종속 변수로 사용했다. 전체 독립 변수 중 수치형 데이터는 194개고 범주형 데이터는 23개이다. 범주형 데이터는 원-핫 인코딩(one-hot encoding)을 활용하여 전처리했으며, 최종 데이터의 행은 155,048개, 열은 249개이다.

3.2 방법론

본 연구의 목적은 목표 두께와 실제 두께간의 편차를 최소화 하는 압연 패턴을 도출하는 것이다. <Figure 3>은 압연 패턴을 도출하기까지 3단계 과정을 나타낸다. Step 1에서 제조 데이터를 활용하여 예측모델을 학습하고, Step 2에서는 학습한 모델과 데이터를 활용하여 SHAP 알고리즘으로 두께를 예측하는 중요 변수들을 도출한다. Step 3에서는 도출된 변수를 활용하여 목적함수를 최소화 하는 방향으로 압연 패턴을 변경하여 최적의 압연 패턴을 도출한다.

두께를 예측하는 모델로는 XGBoost(eXtreme Gradient Boosting), Random Forest, MLP(Multi-Layer Perceptron), AdaBoost(Adaptive Boosting), 그리고 Elastic Net을 활용하였다. 전처리가 완료된 데이터에 대해 8:1:1의 비율로 학습/검증/평가 데이터를 분리하고 학습 데이터를 활용하여 standard scaler를 적용했다. 해석모델로 사용한 SHAP 알고리즘은 전체 관측치를 활용하여 대리 모델

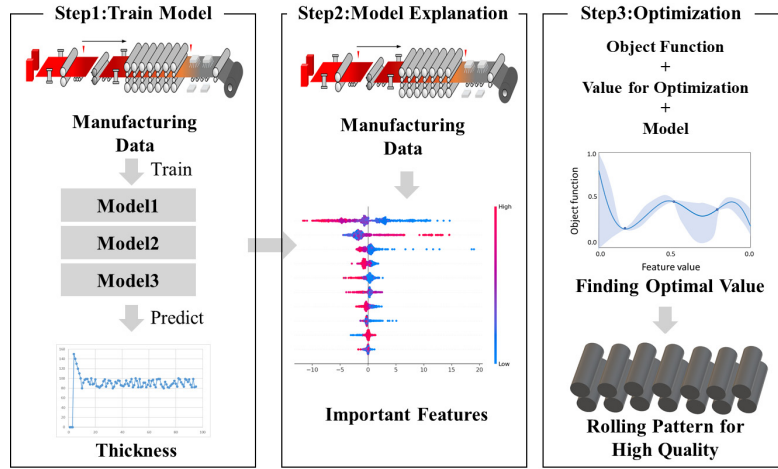


Figure 3. Overall Process of Hot-rolled Steel Plate Thickness Prediction




Figure 4. Overall Structure of Rolling Pattern Optimization to Reduce Thickness Defects

(surrogate model)을 구성하고 결과를 해석한다. SHAP에서는 특정 변수를 제외하고 모델을 구성했을 경우에 모델의 예측 정확도가 크게 변하는 경우 해당 변수의 기여도가 높다고 판단하는데 이 값을 샤플리 값(shapley value)으로 정의하고 이 값에 따라서 변수의 기여도를 설명할 수 있다.

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)] \quad (1)$$

식(1)에서 ϕ_i 는 샤플리 값이고 S 는 F 에서 특정 변수를 제외한 변수 집합이고 F 는 변수 전체의 집합이다. 샤플리 값은 설명 대상 변수가 포함되어 있을 때의 값과 포함되지 않을 경우의 값의 차이를 특정 변수가 선택될 확률을 곱함으로써 계산된다. 특정 변수의 활용 여부에 따라서 두 모델의 값의 차이는 커지고 해당 변수가 중요한 변수임을 알 수 있다 (Lundberg *et al.*, 2017). SHAP 알고리즘은 다양한 모델의 해석을 위해서 LinearSHAP, TreeSHAP, DeepSHAP과 같은 변형된 알고리즘이 있으며, 본 연구에서는 XGBoost의 해석을 위해서 TreeSHAP을 사용했다.

SHAP 알고리즘을 통해 도출된 변수들의 크기를 일정 범위 안에서 변경하면서 두께가 목표와 유사해지는 압연 패턴을 도출하기 위해 베이지안 최적화를 활용했다. <Figure 4>에서 데이터 1은 마무리 압연 이전 공정(가열로, 조압연)으로부터 수집한 실적 데이터들이고, 데이터 2는 마무리 압연 작업을 위해 계산된 값들이다.

본 연구의 목표는 현실을 잘 반영한 모델을 활용하여 그 모델에서 예측된 값과 고객이 주문한 목표 두께간 차이를 최소화 하는 압연 패턴을 도출하는 것이다. 본 연구에서는 최적 압연 패턴을 도출하기 위해 베이지안 최적화를 사용했다. 베이지안 최적화를 위해서는 대체 모델(surrogate model)과 획득 모델(acquisition function)이 사용되고 순서는 다음과 같다. 첫 번째로 이미 알고 있는 입력 값을 활용하여 대체 모델로 목적 함수의 형태를 추정한다. 이어 추정된 대체 모델에서 목적 함수를 최대화 하는 값을 찾기 위해 획득 모델을 활용하여 최적의 후보를 선정하고 그 값을 활용하여 대체 모델을 업데이트한다. 이 과정을 반복적으로 진행하면서 목적함수를 최대화 하는 값을 찾는다(Frazier, 2018). 베이지안 최적화는 일반적으로 hyperparameter를 최적화하는데 사용되지만 본 연구에서 활용된 입력 변수들은 hyperparameter와 유사하게 입력 변수 값을 변경할 수 있기 때문에 이를 변경하면서 목적 함수를 최대화 하는 값을 도출했다. <Figure 4>에서 데이터 1, 2를 활용하여 두께를 예측하는 모델을 학습하고 이 예측 모델(predictive model)을 최적화에 활용하였다. 예측 모델에 입력값으로는 데이터 1과 최적화된 데이터 2를 사용하는데 최적화된 데이터 2는 예측 모델이 예측한 값이 목표에 가까워 질 수 있도록 데이터 2의 변수 중 압연기 1번부터 7번까지 roll gap들을 변경한 값이다. 최적화 과정에서 활용되는 목적함수는 식 (2)와 같고 이 목적함수를 최대화하기 위해서 베이지안 최적화를 사용했는데 예측 모델이 예측한 값과 목표 두께간 차이가 최소화될 수

있도록 roll gap을 변경하고 예측하여 목표로 하는 두께와 비교하는 과정을 반복하였다. 해당 과정은 베이지안 최적화 방법을 활용했고 파이썬의 라이브러리(BayesianOptimization)를 사용하여 1개의 소재에 대해서 30회 반복했다. Roll gap의 변경 범위는 기존 변수 값의 $\pm 10\%$ 이내에서 변경되도록 설정했다.

$$\text{Object function} = -|\text{Thickness predicted by XGBoost} - \text{Thickness target}| \quad (2)$$

제한적인 컴퓨팅 자원으로 인해 평가 데이터 전체에 대해 최적화를 수행할 수 없었으며, 평가 데이터 중 목표 두께와 실제 두께 간의 편차가 10 이상인 소재들(불량재) 1,650개 중 100개를 추출하여 최적화를 진행했다.

4. 결 과

4.1 예측모델 학습 결과

예측 모델의 성능을 평가하기 위한 지표로는 MAE(mean absolute error), MAPE(mean absolute percentage error), MSE(mean squared error), RMSE(root mean squared error), R^2 (R squared value)를 활용했다. <Table 1>에서는 XGBoost, Random Forest, MLP, Adaboost, Elastic Net을 사용하여 두께를 예측하는 모델을 학습한 결과이다. 가장 좋은 성능의 모델을 도출하기 위해 grid search를 활용하여 각 모델에 적합한 최적의 hyperparameter를 도출했고 모델 평가를 위해 랜덤으로 나눈 학습데이터로 10회 반복 평가 후 평균과 표준편차를 산출했다. 결과적으로 XGBoost가 가장 좋은 성능을 나타냈고, Random Forest도 좋은 성능을 보였다. <Figure 5>에서는 R^2 가 0.9989로 가장 좋은 성능을 나타낸 XGBoost를 활용하여 두께를 예측하고 실제 값과 차이를 그래프로 나타냈다. 예측 값과 실제 값의 차이의 대부분이 ± 10 안에 들어왔으며 이를 통해 본 연구에서 도출한 예측 모델 두께가 실제 두께와 유사함을 확인할 수 있었다.

4.2 SHAP 분석결과

XGBoost 모델에 대한 SHAP summary 분석결과는 <Figure 6>과 같다. 왼쪽 그래프에서 각 변수별 샤플리 값이 그래프 형

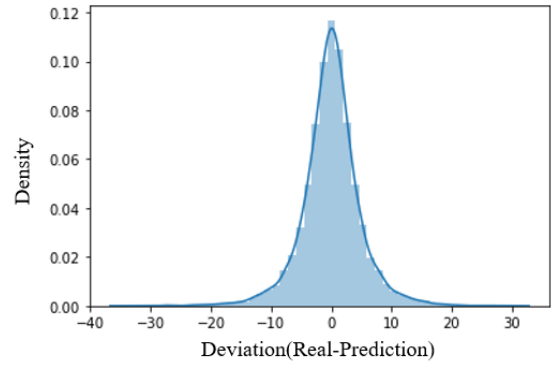


Figure 5. Deviation between Actual Thickness and XGBoost Predicted Thickness

대로 표시되어 있는데 y축은 각 변수들이고, x축은 샤플리 값을 나타내고 있다. 실제 변수값이 클수록 빨간색으로 표시되고, 작을수록 파란색으로 표시된다. 예를 들어 Variable A_6은 파란색일수록 샤플리 값이 높은 것을 알 수 있고 이 결과는 Variable A_6이 작은 값일수록 예측에 양의 영향을 준다는 의미이다. 반면에 빨간색인 경우에는 샤플리 값이 낮다는 것을 알 수 있고 Variable A_6이 높은 값일수록 예측에 음의 영향을 준다는 의미이다. 예측에 사용된 전체 변수들 중 가장 높은 샤플리 값을 갖는 20개가 오른쪽 그래프에 표시되었다. 이 변수들은 예측 모델에서 해당 변수를 제외하고 예측할 경우 예측 정확도에 큰 영향을 미치는 변수들이고 따라서 두께 예측에 중요한 변수들이라고 해석할 수 있다. 도출된 중요변수 20개에 대해서 어떤 변수를 최적화하는 것이 적합할지 분석했다. 식(3)은 roll force를 계산하기 위한 식이며 F 는 roll force, Q 는 기하학적 요소, s 는 평균 변형 저항, W 는 강판의 폭, 그리고 L 은 roll과 강판의 접촉 반경을 의미한다. 변수 A, C, G, H, J는 이 식에 의해서 roll force를 계산하기 위한 입력 변수로 사용된다. 식(4)는 roll gap을 계산하는 수식으로, F 는 압연하기 위한 roll force, F_0 는 roll의 영점 조정 시 사용한 힘, M 은 압연 상수(mill constant), 그리고 G_0 는 부하가 없는 상태에서 roll gap이며 G_r 는 부하가 있는 상태에서 roll gap이다. 변수 E, I와 roll force는 roll gap을 계산하기 위한 변수로 사용된다. 따라서 SHAP분석을 통해 도출된 20개의 변수 중 15개의 변수가 roll force 및 roll gap을 계산하기 위한 변수이며, 해당 분석결과를 기반으로 최적화를 진행하였다.

Table 1. Performance Evaluation of the Thickness Prediction Model

Model	MAE	MAPE	MSE	RMSE	R^2
Elastic Net	4.26692±0.02016	1.43876±0.00871	33.77782±0.43620	5.81174±0.03755	0.99855±0.00003
Adaboost	7.31732±0.32428	2.87640±0.19458	96.94994±12.06426	9.82764±0.60606	0.99585±0.00054
MLP	5.28419±0.27805	1.64921±0.07832	55.61422±7.32862	7.44147±0.48861	0.99762±0.00032
Random Forest	3.54978±0.02657	1.16801±0.00890	26.07957±0.47135	5.10660±0.04624	0.99888±0.00003
XGBoost	3.60840±0.02668	1.19734±0.00995	25.46254±0.39019	5.04589±0.03866	0.99891±0.00002

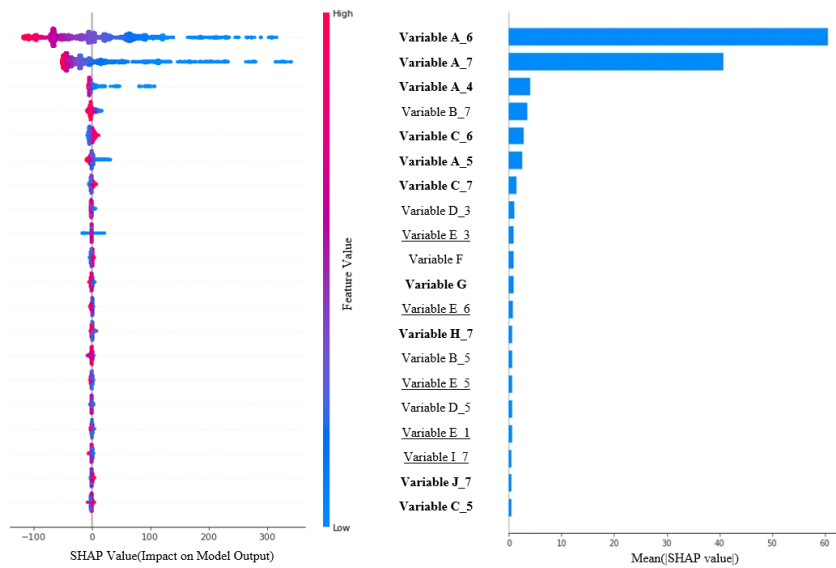


Figure 6. SHAP Analysis Result of XGBoost Model

$$F = Q \times S \times W \times L \quad (3)$$

$$G_F = G_0 + \frac{F - F_0}{M} \quad (4)$$

4.3 베이지안 최적화 결과

본 연구에서는 SHAP 분석으로 도출된 Variable A, roll force, roll gap을 최적화 했다. 각각의 최적화 대상 변수들은 압연기가 7개로 구성되어 있기 때문에 총 7개의 변수로 구성되어 있다. SHAP 분석에서 가장 큰 영향력을 큰 변수는 Variable A_6, Variable A_7이었고 그에 따라서 Variable A 7개(Variable A_1, ..., Variable A_7)를 최적화했다. 또한 SHAP으로 도출된 변수들이 roll gap과 roll force를 계산하는데 사용되기 때문에 roll gap과 roll force도 각각 7개를 최적화 대상 변수로 설정했다. 최적화 진행시 예측 성능이 가장 뛰어난 XGBoost 모델을 활용

하여 실험을 진행하였고, 최적화로 변경되는 변수 값으로 실제 두께 변화를 추정하였다. 최적화를 진행했을 때, 가장 좋은 성능을 보인 것은 roll gap을 최적화한 경우였고 제4.2절의 결과와 최적화 결과로 roll gap이 두께에 가장 큰 영향을 주고있다는 것을 알 수 있었다. <Table 2>는 최적화 이후 편차가 가장 많이 감소한 상위 10개 샘플이다. 최적화 전에는 목표 두께와 예측 값 간에 차이가 컸었는데 최적화를 한 roll gap으로 작업한 경우 편차가 감소한 것을 확인할 수 있었다. 예를 들어 Sample 1의 경우 목표 두께와 XGBoost의 예측 값이 19.1이었는데 최적화 후 1.0으로 감소했다. <Table 3>은 편차가 가장 적게 감소한 하위 10개 샘플이고 99번, 100번 샘플의 경우 최적화를 했지만 편차 감소가 없었기 때문에 전체 100개의 소재 중 98개의 소재에서 최적화가 완료되었다.

최적화를 통해 도출된 roll gap이 실제 불량률의 방향과 맞는지 확인했다. 불량률의 형태와 적합한 제어의 방향은 <Figure 7>

Table 2. Optimization Result for 10 Sample with Best Performance

Sample No.	Target	Deviation of target and prediction (before optimization)	Deviation of target and prediction (after optimization)	Improvement rate (%)
1	722.0	19.1	1.0	77.1
2	303.0	17.9	4.4	84.0
3	842.0	13.0	0.3	54.1
4	452.0	11.5	0.2	70.8
5	353.0	10.5	0.3	89.5
6	472.0	12.5	3.1	66.8
7	423.0	13.9	4.9	33.0
8	423.0	14.1	5.3	46.7
9	423.0	9.1	0.4	54.4
10	423.0	21.9	13.4	31.2


Table 3. Optimization Result for 10 Sample with Worst Performance

Sample No.	Target	Deviation of target and prediction (before optimization)	Deviation of target and prediction (after optimization)	Improvement rate (%)
91	254.0	1.4	0.8	4.4
92	552.0	0.5	0.1	3.2
93	143.0	6.5	6.2	2.8
94	197.0	2.5	2.1	3.0
95	253.0	7.1	6.8	2.7
96	160.0	4.1	3.9	1.5
97	173.0	5.3	5.2	1.1
98	453.0	0.1	0.0	1.2
99	453.0	0.0	0.1	-0.5
100	353.0	0.1	0.2	-1.1

에 설명되어 있다. <Figure 7(a)>는 제품이 두껍게 작업된 경우이고 불량을 줄이기 위해서는 roll gap은 close되어야 하고 <Figure 7(b)>는 목표보다 얇게 작업된 경우이며, 이때는 roll gap이 open되어야 한다. <Figure 8>에서 왼쪽 표는 5개 샘플의 두께 불량 발생 형태와 양을 나타내고 오른쪽 표는 최적화 전후의 roll gap의 방향을 나타낸다. 5개의 샘플 모두 최적화 후 roll gap의 변화가 불량을 감소시키는 방향으로 최적화 되었다. 제품이 두껍게 작업된 경우 roll gap을 close하게 최적화 되었으며, 반대로 제품이 목표보다 얇게 작업된 경우 roll gap을 open하도록 최적화되었다. 이러한 결과로 볼 때 결함이 목표

보다 두껍게 발생된 경우 최적화는 gap을 close하여 결함을 줄이는 방향으로 최적화 되었고, 반대로 결함이 목표보다 얇게 발생된 경우 최적화는 gap을 open하여 제품의 불량을 방지하는 방향으로 옳게 최적화되었음을 알 수 있었다.

<Table 4>는 추출한 100개 제품 전체의 최적화 결과를 나타낸다. 첫 번째 행은 전체 샘플에 대한 목표 두께와 실제 두께의 차이이고 두 번째 행은 목표 두께와 XGBoost 모델의 최적화 전 차이이다. 세 번째는 최적화된 roll gap으로 작업할 때 목표 두께와 예측 값의 차이이다. 각각은 100개 샘플에 대한 평균값이며 최적화 전에 7.1의 편차에서 최적화된 roll gap으로 작업한 경



(a) Head thickness is larger than target thickness (b) Head thickness is less than target thickness

Figure 7. Optimization Direction According to the Shape of Thickness Defect

Sample	Target	Real	Thickness Deviation	Shape of Thickness Defect	Roll Gap(After Optimization) - Roll Gap(Before Optimization)
1	722	698.59	-23.41	Less than target	70.47(Open)
2	303	291.39	-11.61	Less than target	27.77(Open)
3	842	865.52	23.52	Lager than target	-72.73(Close)
4	452	435.96	-16.04	Less than target	5.34(Open)
5	353	341.63	-11.37	Less than target	58.68(Open)

Figure 8. Thickness Defect Deviation and Optimization Direction

Table 4. Optimization Results for All Samples (100 samples)

Deviation of target and real (total)	Deviation of target and prediction (before optimization)	Deviation of target and prediction (after optimization)	Improvement rate (%)
14.4	7.1	2.9	29.6

우 2.9로 4.2만큼 편차가 줄었으며, 이는 전체 결함 수준인 14.4에서 두께 편차가 29.6% 감소함을 의미한다.

5. 결론

국내 철강산업은 중국의 도약으로 다양한 문제에 직면해 있다. 좋은 품질의 제품을 생산하고 동시에 원가 절감을 위해서는 생산 중에 발생하는 비용과 불량률을 저감해야 한다. 열간압연 공정에서 발생하는 다양한 불량률 중에서 두께 불량률은 가장 많이 발생하지만, 설비의 위치와 계측 환경 때문에 불량을 예방하기 위한 방법들이 제한적이며 불량 발생 후 조치가 대부분이다. 또한 고객들은 좋은 품질의 2차제품(자동차, 가전제품, 건설, 송유관 등)을 제조하기 위해 압연된 강판의 두께 공차를 최소한으로 요구하고 있어 두께를 제어하기 더 어려운 상황이다. 본 연구에서는 열간압연에서 발생하는 두께 불량을 효과적으로 제어하기 위해 압연 전에 두께를 예측하는 모델을 구축하고, 어떤 조업 조건 때문에 두께가 결정되는지를 SHAP를 통해 분석하였다. 도출된 조업 조건들이 압연기의 roll gap과 상당한 연관성을 갖고 있다는 것을 확인했으며, 고객이 원하는 두께의 제품을 생산하기 위해서 roll gap을 얼마나 조정해야 하는지를 베이지안 최적화 방법으로 분석하였다. 결론적으로 최적화된 roll gap으로 작업할 경우 기존의 두께 편차를 29.6% 감소할 수 있었다. 또한 본 연구는 열간압연 공장에서 수집된 실제 데이터를 활용하여 연구를 진행했기 때문에 향후 현장에 적용할 예정이다. 추가적인 연구방향은 고객의 원하는 두께를 최적화 하기 위해 예측 모델을 활용했는데 보다 높은 정확도를 갖는 모델을 만들어 최적화를 진행하면 향상된 결과가 예상된다. 본 연구를 현장에 적용할 때 발생하는 현장 이슈는 최적조건을 도출하는데 소요되는 시간인데 두께 예측 및 최적화를 위한 시간이 길어진다면 다음 제품의 작업이 늦어질 수 있다. 본 연구에서는 최적화를 진행하기 위한 방법으로 베이지안 최적화를 활용했고 현장 적용에 큰 문제는 없지만 최적화에 소요되는 시간이 짧을수록 좋기 때문에 다양한 최적화 기법을 추가로 연구한다면 보다 좋은 결과가 기대된다.

참고문헌

Bagheripoor, M. and Bisadi, H. (2013), Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process, *Applied Mathematical Modelling*, **37**(7), 4593-4607.

Deng, J., Sun, J., Peng, W., Hu, Y., and Zhang, D. (2019), Application of neural networks for predicting hot-rolled strip crown, *Applied Soft Computing*, **78**, 119-131.

Frazier, P. I. (2018), A tutorial on Bayesian optimization. arXiv preprint arXiv:1807.02811.

Jesus, S., Belém, C., Balayan, V., Bento, J., Saleiro, P., Bizarro, P., and Gama, J. (2021), How can I choose an explainer? An application-

grounded evaluation of post-hoc explanations, In Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, 805-815.

Lee, D. and Lee, Y. (2002), Application of neural-network for improving accuracy of roll-force model in hot-rolling mill, *Control Engineering Practice*, **10**(4), 473-478.

Li, G., Gong, D., Lu, X., and Zhang, D. (2021), Ensemble learning based methods for crown prediction of hot-rolled strip, *ISIJ International*, **61**(5), 1603-1613.

Li, G., Gong, D., Xing, J., and Zhang, D. (2021), Optimization of CVC shifting mode for hot strip mill based on the proposed LightGBM prediction model of roll shifting, *The International Journal of Advanced Manufacturing Technology*, **116**(5), 1491-1506.

Li, X., He, Y., Ding, J., Luan, F., Peng, W., and Zhang, D. (2022), Predicting hot-strip finish rolling thickness using stochastic configuration networks, *Information Sciences*.

Lundberg, S. M. and Lee, S. I. (2017), A unified approach to interpreting model predictions, *Advances in Neural Information Processing Systems*, **30**.

Son, J. S., Lee, D. M., Kim, I. S., and Choi, S. K. (2004), A study on genetic algorithm to select architecture of an optimal neural network in the hot rolling process, *Journal of Materials Processing Technology*, **153**, 643-648.

Ståhl, N., Mathiason, G., Falkman, G., and Karlsson, A. (2019), Using recurrent neural networks with attention for detecting problematic slab shapes in steel rolling, *Applied Mathematical Modelling*, **70**, 365-377.

Tiensuu, H., Tamminen, S., Puukko, E., and Röning, J. (2021), Evidence-based and explainable smart decision support for quality improvement in stainless steel manufacturing, *Applied Sciences*, **11**(22), 10897.

Wang, Z. H., Gong, D. Y., Li, X., Li, G. T., and Zhang, D. H. (2017), Prediction of bending force in the hot strip rolling process using artificial neural network and genetic algorithm (ANN-GA), *The International Journal of Advanced Manufacturing Technology*, **93**(9), 3325-3338.

Wang, Z. H., Liu, Y. M., Gong, D. Y., and Zhang, D. H. (2018), A new predictive model for strip crown in hot rolling by using the hybrid AMPSO-SVR-based approach, *Steel Research International*, **89**(7), 1800003.

Wu, S., Cao, G., Zhou, X., Shi, N., and Liu, Z. (2017), High dimensional data-driven optimal design for hot strip rolling of C-Mn steels, *ISIJ International*, **57**(7), 1213-1220.

Yang, Y. Y., Linkens, D. A., and Talamantes-Silva, J. (2004), Roll load prediction—data collection, analysis and neural network modelling, *Journal of Materials Processing Technology*, **152**(3), 304-315.

Zhang, X., Yao, L., and Zhou, Z. (2016), Rolling force prediction algorithm based on Bayesian regularization neural network, In *2nd International Conference on Electronics, Network and Computer Engineering (ICENCE 2016)* Atlantis Press, 790-795.

저자소개

김경수 : 한국항공대학교 항공재료공학과에서 2013년 학사 학위를 취득하고, 고려대학교 산업경영공학과에서 석사과정에 재학 중이다. 연구 분야는 인공지능, 머신러닝을 철강 제조공정에 응용하는 연구를 수행하고 있다.

김성범 : 고려대학교 산업경영공학부 교수로 2009년부터 재직하고 있으며, 인공지능공학연구소 소장 및 기업산학협력센터 센터장을 역임했다. 미국 University of Texas at Arlington 산업공학과에서 교수를 역임하였으며, 한양대학교 산업공학과에서 학

사학위를 미국 Georgia Institute of Technology에서 산업시스템공학 석사 및 박사학위를 취득하였다. 인공지능, 머신러닝, 최적화 방법론을 개발하고 이를 다양한 공학, 자연과학, 사회과학 분야에 응용하는 연구를 수행하고 있다.