

기계학습을 활용한 공정 변수별 오스템퍼링 경도 예측 비교 연구

김경훈 · 박종구 · 허우로 · 양해웅[†]
(재)포항금속산업진흥원 DX기술팀

Comparative Study of Aus-Tempering Hardness Prediction by Process Using Machine Learning

K. Kim, J.- G. Park, U. R. Heo, H. W. Yang[†]

DX Technology Team, Pohang Institute for Materials Industry Advancement, Pohang 37666, Korea

Abstract Aus-tempering heat treatment is suitable for thin and small-sized in precision parts. However, the heat treatment process relies on the experience and skill of the operator, making it challenging to produce precision parts due to the cold forging process. The aims of this study is to explore suitable machine learning models using data from the aus-tempering heat treatment process and analyze the factors that significantly impact the mechanic properties (e.g. hardness). As a result, the study analyzed, from a machine learning perspective, how hardness prediction varies based on the quenching temperature, carbon (C), and copper (Cu) contents.

(Received November 6, 2023; Revised November 20, 2023; Accepted November 23, 2023)

Key words : Forging, Heat treatment, Machine learning, Mechanical properties, Data accuracy

1. 서 론

단조 산업은 대량 생산이 가능하여 절삭 가공, 성형 가공으로 제조되는 부품에 비해 생산성이 우수하며 생산 비용이 적은 장점이 있다[1-4]. 또한, 금속 부품의 가공 경화를 유도하여 높은 기계적 특성을 확보할 수 있어 자동차, 비행기, 선박 등 중장비 부품 산업에 많이 적용되어진다[5, 6]. 전기 자동차 산업의 발전으로 부품 경량화 및 고강도화에 대한 연구를 필요하고 있어 철강 부품을 활용한 단조 공정을 채택하고 있다[7-12]. 냉간 단조를 통하여 기존 철강 소재의 부품들을 제조시 장점으로는 높은 기계적 특성획득과 단조제품의 불량률을 줄일 수 있는 반면에, 단점으로는 높은 성형 하중이 요구되어지고 있다[13-15]. 냉간 단조의 단점을 보완하기 위해 기계적 특성과 정밀도를 동시에 올릴 수 있는 열처리(Quenching & Tempering, Q/T) 공정 단계를 필수적으로 도입시킨다. 오스템퍼링(Austempering) 열처리는 강을 오스테나이트 상태에서 약 500°C까지 급

랭시켜, 변태 종료점까지 항온유지를 하는 열처리이다[16]. 보통의 열처리 과정과 달리 오스템퍼링은 베이나이트(Bainite) 조직을 가져, 연신율과 충격치가 커서 담금질 균열이 적어 두께가 얇고 크기가 작은 정밀한 부품에 사용하기 적합하다[17].

냉간 단조 부품은 성능, 크기 및 작업 환경을 고려하여 열처리 조건을 정확하게 제어해야 한다[18]. 하지만, 열처리 공정에 활용되는 공정 조건들은 작업자의 경험, 노하우 및 숙련도에 의존하는 전통적인 작업 방식을 채택하여 안정성과 일관성을 확보하기 어려운 상황이다[19]. 이로 인해 열처리 공정에 적용되는 온도 및 공정 조건을 다양하게 맞춰 정확하게 제어할 필요가 있다.

최근 10년간 기계학습(Machine learning)과 인공지능(Artificial Intelligent, A.I.)기술을 활용하여 새로운 분야에 대한 탐구와 관련된 학문 발전에 집중되고 있다[20-21]. 제조업에서는 산업 생산 속도 저하와 숙련도 의존으로 인한 문제를 극복하기 위해, 스마트팩토리 도입에 대한 노력이 진행 중이다[22]. 사

[†]Corresponding author. E-mail : hwyang@pomia.or.kr
Copyright © The Korean Society for Heat Treatment

람의 전문성과 공정에서 얻을 수 있는 객관적 데이터를 학습하고, CRM, SCM, ERP 등 데이터 베이스를 기반으로 생산, 고객, 직원 관리를 하여 불량 검출, 영업관리, 인력양성을 향상시킬 수 있는 연구를 꾸준히 진행하고 있다[23-26].

본 연구에서는 오스탬퍼링 열처리 공정에서 수집한 로내 온도 및 소입 온도와 12개의 화학조성을 가지고 정도를 예측할 수 있는 6개의 기계학습 모델들을 적용하였다. 그리고, 실험 데이터와 예측 정확도 사이의 관계를 비교하여 오스탬퍼링 열처리 공정에서 정도 예측에 필요한 조건을 데이터와 재료적인 측면에서 분석하였다.

2. 기계 학습

기계 학습은 일반적으로 지도 학습과 비지도 학습으로 구분된다. 지도 학습은 일부 데이터로 모델을 학습하고 예측값을 생성하는 방법이다. 반면, 비지도 학습은 데이터 내 내재된 패턴을 스스로 학습하는 방식이다. 본 연구에서는 지도 학습 방법 중 하나인 회귀 분석을 통해 온도 변수 2개와 12개의 화학 조성으로 구성된 예측 변수(Feature)와 정도값을 반응 변수(Target)로 지정해 기계 학습 알고리즘을 활용하였다. 기계 학습 알고리즘의 학습 방법은 크게 선형 회귀법(Linear regression)과 결정 트리 학습법(Decision tree learning)으로 구성되어 있으며, 다음 챕터에서 선형 회귀와 결정 트리 학습법에 대한 설명과 종류들에 대해 알아보려 한다.

2.1 선형 회귀법

선형 회귀 모델은 두 변수 (X , Y) 간의 상관관계를 선형 조합으로 나타내는 방식이다. 선형 회귀 모델은 우리가 흔히 알고 있는 1차원 함수($Y = W \times X + b$)와 유사하다. 선형회귀법은 예측되어진 값(Y)과 실제 값(X)의 오차를 감소 시키기위해, 기울기(W)와 Y 절편 (b)을 변화시키며 최적의 관계를 형성시켜주는 방식이다. 오차 감소를 위해 사용되는 비용 함수는 편미분 하강 알고리즘(Gradient descent algorithm)을 활용해 기울기 대해 편미분한 방향의 정반대 방향으로 W 를 조금씩 바꿔 나가면서 오차값을 감소시키는 알고리즘이다[27].

대부분의 데이터들은 선형적인 관계보다 비선형 관계를 가지는 경우가 많다. 비선형 관계는 n 차원 함수로 고려되어지기 때문에, 각 차수를 모두 고려하지 않고 선적인 모델로써 단순화 시키는 과정을 정규화(Regularization) 방법이라 한다. 이런 정규화 방법을 적용한 알고리즘은 대표적으로 Ridge regression과 Lasso regression이 있다[28-29]. 또한, 전통적인 선형 회귀 원리에서 개념을 확장해 Bayesian 추론을 포함하여, 변수 간의 관계를 따지는 거에 멈추지 않고, 예측을 하는데 있어 관련된 불확실성을 양적화하여 데이터를 보다 입체적으로 제공해주는 기능을 해준다[30].

2.2 결정 트리 학습법

결정 트리 학습법은 지도 학습 알고리즘 중 하나로, 데이터를 분할하고 각 분할에서 결정을 내리는 트리 구조의 모델이며, 규칙 노드(Decision node)와 리프 노드(Leaf node)로 나뉘어진다. 그리고, 노드들은 새로운 규칙 조건마다 하위 트리(Subtree)가 생성되는데, 데이터 세트에 예측 변수가 있으며 이러한 변수들이 결합해 규칙 조건 마다 서브 트리가 생성된다. 하지만, 많은 규칙이 있다는 것은 분류를 결정하는 방식이 더욱 복잡해진다는 뜻이며 이는 기계 학습 분야에서 과적합(Overfitting)으로 이어지기 쉽다[31]. 그렇기 때문에 적절한 결정 트리 학습법의 트리 깊이, 규칙 노드 개수, 균일한 트리 분할을 할 수 있는 데이터 세트의 구성이 필요하다.

결정 트리 학습법은 규칙 노드를 얼마나 무작위하게 형성하는지, 서브 트리에 필수적으로 들어가야 하는 데이터 수를 제한한다는 등 각 노드에 어떤 방식으로 알고리즘을 최적화시킬 것인가에 따라 다양한 알고리즘이 존재한다[32-34]. 랜덤 포레스트(Random forest)는 비교적 쉬운 전처리 과정과 배깅 방법으로 기존의 의사결정 나무에서 발생하는 과적합 문제에 강점을 보인다[32]. 그라디언트 부스팅 회귀법(Gradient boosting regression)은 잔차(Residual)를 이용하여 이전 모형의 약점을 보완해 새로운 모형을 순차적으로 적합화 시키는 알고리즘이다[33]. 경사 하강법을 사용해 손실 함수를 최소화하여 이전 모형의 예측 오차가 큰 데이터에 초점을 맞춰 학습하여 예측값을 도출한다. 엑스트라트리 회귀법(Extra regression)은 랜덤 포레스트와 유사한 원리를 사용하지

만 차이가 있다[34]. 결정 트리 모델을 조합 할 때 보다 더욱더 무작위하게 트리를 형성하고, 리프 노드로 분할 할 때, 조건에서 속성과 노드를 분할하여 데이터를 처리하는 특징이 있다.

본 연구에서는 3개의 선형 회귀 방식(릿지 회귀법(RIDGE), 라쏘 회귀법(LASSO), 베이시안-릿지 회귀법(BR))과 3개의 결정 트리 회귀 방식(랜덤 포레스트 회귀법(RF), 그라디언트 부스팅 회귀법(GBR), 엑스트라트리 회귀법(ET))을 활용하였다.

모델 성능 평가 지표는 평균 절대 오차(MAE), 평균 제곱 오차(MSE), 평균 제곱근 오차(RMSE), 결정 계수(R^2)를 활용하여 모델 성능 지표를 계산하였다. 식 (1), (2), (3)는 각각 MAE, MSE, RMSE에 대한 식을 정리하였다. $H(X)$ 는 각 feature들의 변수의 실제값이고 Y 는 예측값이다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |(H(X) - Y)| \quad (1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (H(X) - Y)^2 \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (H(X) - Y)^2} \quad (3)$$

3. Experimental Method

3.1 재료 및 열처리 조건

본 연구에 사용된 소재는 SCM435 강을 사용하였다. 합금원소로는 C, Si, Mn, P, S, Cr, Ni, Cu, Mg, Ti, Sn, Mo 합금 원소가 포함되어 있다. 열처리 공정 과정은 40~60°C에서 1분 동안 세척 이후, 930°C까지 온도를 올려 10~15분 동안 열처리를 하게 된다. 그리고, 50~60°C의 퀴칭 오일에 1분 이상 냉각을 시키고 60~80분 동안 350~380°C 환경에 다시 한 번 열처리를 진행하였다.

3.2 모델 파라미터

각 기계학습 모델들은 sklearn과 pycaret을 활용하

여 모델을 구축하였고, 모델의 파라미터들은 모두 기본값을 기준으로 잡아 기계학습 모델을 형성하였다. 선형 회귀법 모델들의 파라미터 종류는 기울기(alpha), 비용 함수 반복 회수(max_iter), 최적화에 대한 허용 오차 범위(tol), 의사 난수 생성기(random_state)가 있다. 결정 트리 학습법에서는 결정 트리의 깊이(max_depth), 최상의 분할을 고려한 feature 개수(max_features), 규칙 노드의 조건 값에 불순물 감소 값(min_impurity_decrease), 리프 노드의 필요 개수(min_sample_leaf), 규칙 노드의 최소 개수(min_samples_split), 모든 노드의 개수(n_estimators), 트리 구축 시 사용되는 부트스트랩 임의성과 각 노드의 최적분할 고려 시 기능 샘플링 제어(random_state)가 있다.

4. 결과 및 고찰

4.1 기계학습 모델 평가결과

각 모델들을 학습하기 위해 교차검증을 통해 도출된 경도와 실험 데이터를 비교하여 모델을 평가하였다. Fig. 1은 피어슨 상관 계수(Product moment correlation coefficient, PCC) 기법으로 각 모델들의 경도 예측 결과를 비교하였다. Table 1은 각 모델들에 대한 MSE, RMSE, R^2 지표를 정리한 표이다. MAE는 경도의 데이터 범위가 30~35 HRC로 기계 학습에서 데이터를 비교하는 데 값이 크기 때문에 성능을 평가하는 지표로 사용하기 부적절하다 판단하였

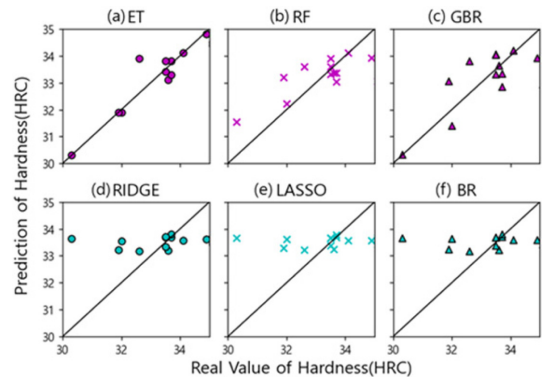


Fig 1. Results of training for each machine learning models based on the Pearson's correlation (PCC) analysis with input features: (a) ET, (b) RF, (c) GBR, (d) RIDGE, (e) LASSO, and (f) BR models.

Table 1. MAE, MSE, RMSE, and R² for each models

Model	MAE (HRC)	MSE (HRC)	RMSE (HRC)	R ² (%)
ET	0.573	0.884	0.940	65.98
RF	0.811	1.132	1.064	56.42
GBR	0.659	0.746	0.864	71.28
RIDGE	0.874	1.516	1.231	41.66
LASSO	0.914	1.604	1.266	38.27
BR	0.891	1.564	1.251	39.80

다. MSE와 RMSE에는 ET, RF, GBR 모델은 약 0.7~1.1를 가지고 있는 반면, RIDGE, LASSO, BR 모델은 약 1.3~1.6을 가진다. 그리고, ET, RF, GBR 모델(Fig. 1a-c)들의 R²는 각각 66%, 56.4%, 71.3%이고, RIDGE, LASSO, BR 모델(Fig. 1d-f)들의 R²는 각각 41.7%, 38.3%, 39.8% 이다.

전반적으로 결정 트리 학습법 모델(ET, RF, GBR)이 선형 회귀법 모델(RIDGE, LASSO, BR) 보다 좋은 성능을 보여준다. 결정 트리 학습법 모델 (ET, RF, GBR)이 선형 회귀법 모델(RIDGE, LASSO, BR) 보다 좋은 성능을 보여준다. MSE, RMSE는 실제값과 예측값의 차이에 대한 수식(식 (2), (3))이기 때문에, 값이 작아질수록 좋은 성능을 보여주는 모델이다. 반면 R²는 값이 0~100 (%) 사이의 값을 보여주고, 값이 커질수록 좋은 성능을 보여주는 모델이다. 선형 회귀법 모델(RIDGE, LASSO, BR)들은 결정 트리 학습법 모델(ET, RF, GBR) 들에 비해 MSE, RMSE가 높고 R²가 낮기 때문에 결정 트리 학습법 모델이 좋은 성능을 가지는 것을 알 수 있다.

이러한 차이가 발생하는 이유는 앙상블(Ensemble) 기법의 유무에 있어서 발생된다고 판단된다. 선형 회귀법과 결정 트리 학습법의 큰 차이점은 각 feature 들을 최적화시키는 방법의 차이가 있다. 선형 회귀법은 각각의 feature와 target으로만 비교하는 1대1 대응방식이다. 반면, 결정 트리 학습법은 앙상블 기법을 적용시켜 2개 이상의 feature들과 target을 비교한다. 또한, 결정 트리 학습법은 과적합이 발생할 문제를 감소시켜주는 역할도 해준다 [35]. 따라서, 결정 트리 학습법은 선형 회귀법에 비해 좋은 성능을 보여주는 모델이다.




Fig 2. The trend of coefficient determination (R²) according to feature change. The color of magenta and cyan is decision tree learning and linear regression, respectively.

4.2 feature수 변화에 따른 R² 비교

기계학습 모델 성능 평가를 진행하여 결정 트리 학습법이 선형 회귀 학습보다 좋은 성능을 확인하는 것을 확인할 수 있었다. 하지만, 가장 좋은 성능을 보여주는 GBR 모델의 결정 계수가 71%로 전반적으로 낮은 모델 성능을 보여주고 있다.

기계학습의 모델 성능을 높이기 위해 모델 파라미터 변화, 교차 검증 등 다양한 방법으로 모델 성능을 높일 수 있다. 특히, feature의 개수 변화를 주어 모델 성능을 평가하는 방법이 있다. Q/T 열처리 공정 변수 14개를 모두 고려할 경우, 각 공정 변수 값들이 넓은 분포를 가지지 못해 모델 성능이 저하될 수 있기 때문에 경도를 결정시키는 데 있어 연산 결과에 영향을 미치지 못하는 요인들을 제거하면서 feature 수 변화에 따른 모델 성능을 점검하였다.

Fig. 2는 feature 수를 5개부터 14개까지 변화시킬 때, 각 모델 별 R²를 정리한 그림이다. 선형 회귀 모델에서 LASSO 모델은 feature수가 증가하면서 결정 계수가 떨어지는 경향성을 보여주지만, RIDGE와 BR 모델은 약 40%의 일정한 R²를 가진다. 이러한 이유는 RIDGE와 LASSO는 각각 L2 normalization과 L1 normalization 방법으로 정규화를 진행하기 때문이다. RIDGE는 feature의 다양성을 판단하여 정규화를 시키는 반면, LASSO는 특정 파라미터에서만 크게 반응하여 정규화를 진행한다. RIDGE는 다양한 feature들에 대해 영향을 받는 반면, LASSO는 소입 온도에만 영향을 받는 것을 의미하기 때문에, LASSO는 feature수가 감소되면서 소입 온도가

주는 영향이 커져 결정 계수에 변화가 발생하는 것이다. 결정 학습 모델에서 GBR, RF, ET 순으로 모델이 좋은 성능을 보여주는 것을 확인할 수 있다. 가장 좋은 성능을 보여주는 GBR 모델은 7개의 특성 변수일 때 86.5%의 모델 성능을 보여주었으며, 7개의 특성 변수들은 소입온도, C, S, Cu, Mg, Ti, Sn이다. 그렇다면, 어떤 특성 변수가 정도에 중요하게 작용하는지 판단하였다.

Fig. 3는 각 모델의 특성 중요도(Feature importance)를 정리한 그림이다. RIDGE, GBR 모델을 제외한 4개의 모델들은 최고 중요 변수가 소입온도이며, 그 값은 ET, RF, GBR, LASSO, BR 모델 순으로 R² 값이 각각 57.45%, 34.59%, 34.93%, 100%, 89.17% 이다. RIDGE와 GBR의 최고 중요 변수는 탄소 함유량이며 R² 값이 각각 57.45%와 35.76% 이다. 그 다음 세 번째로 높은 변수는 구리 함유량이며 약 20% 미만의 중요도를 보여준다.

4.3 고찰

기계학습 모델 측면을 통해 모델 성능과 특성 변수가 재료 측면에서 오스테퍼링 열처리 공정 변수에 영향을 주는지 판단하였다. 기계학습 두 가지 학습법을 통해 고찰하였다.

선형 회귀법 모델은 오스테퍼링 열처리공정에서 적합하지 않고, 결정 트리 학습법 모델(GBR, RF)이 오스테퍼링 열처리 공정을 통해 경도를 예측하는 데 있어 좋은 성능을 보여주는 모델임을 확인했다. Fig. 1과 Table 1을 통해 선형 회귀법 모델(RIDGE, BR, LASSO) 들은 전반적으로 낮은 모델 성능을 보여주고 Fig. 2에서 RIDGE, BR 모델은 특성 변수에 감소에도 영향을 미치지 않는 것을 확인할 수 있다. 그리고, Fig. 3와 Table 2를 통해 RF, GBR을 제외한 최고 중요 변수도의 값이 50%를 넘는다는 것을 확인할 수 있다. Q/T 열처리를 진행할 경우, 합금 원소의 다양성 및 분포도, 소입 온도, 주변 환경 등 열처리 과정에서 발생할 수 있는 다양한 변화에 대응할 수 있어야 한다. 따라서, 선형 회귀 모델의 성능이 떨어지는 이유는 소입 온도와 탄소 농도에만 의존적이기에 모델 성능이 전반적으로 떨어져 과적합이 발생될 뿐만 아니라, 14개 이상의 특성 변수를 고려해야만 정도에 영향을 준다는 것을 확인

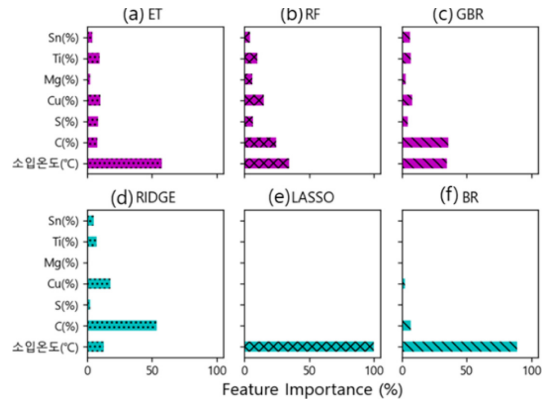


Fig 3. Comparison of feature importance for (a) EF, (b) RF, (c) GBR, (d) RIDGE, (e) LASSO, and (f) BR.

Table 2. Top 3 of importance features by model

Model	소입온도	탄소함유량	구리함유량
ET	57.45	7.93	9.88
RF	34.59	24.23	14.82
GBR	34.93	35.76	8.22
RIDGE	12.91	53.94	18.05
LASSO	100.0	0	0.0
BR	89.17	6.80	2.25

할 수 있다. 반면, 결정 트리 학습법 모델 중 GBR 모델은 소입온도, C, S, Cu, Mg, Ti, Sn 인 특성이 주어졌을 때, 정도 예측력이 좋아지는 것을 확인했다. 뿐만 아니라, GBR 모델은 금속 소재의 기계적 물성(e.g. 인장강도, 정도)을 예측하는데 있어 우수한 모델이다 [37, 38].

특성 중요도에서 소입온도, 탄소 및 구리 함유량이 재료적인 측면에서 기계학습 모델과 어떤 연관성이 있는지 살펴보았다. 우선, 소입 온도는 평균 356°C로 400°C 이상 올라갈 경우 정도값이 급격하게 저하되어지기 때문에 정도 예측을 하는 데 있어 중요한 변수로 작용할 수 있다[36]. 그리고, 철강에서 탄소의 함유량에 따라 기계적 특성이 현저하게 달라지는 것은 통상적으로 잘 알려진 사실이므로, 특성 중요도에서 중요한 변수로 작용한다. 마지막으로 구리는 철강의 베이나이트 조직 형성을 위해 변태점을 낮춰주는 역할을 하기 때문에 중요한 변수로 작용한다. 이처럼 오스테퍼링 열처리 공정에서 소입온도, 탄소 및 구리 함유량이 재료적인 측면에서 중요한

역할을 하는 것을 확인할 수 있다.

5. 결 론

오스텝퍼링 열처리 공정 데이터를 활용하여 기계학습을 진행하였으며, 총 14개의 특성 변수를 고려하면 기계 학습 모델 성능을 저하시키는 것을 확인했다. 7개의 특성 변수 중 소입온도, 탄소 및 구리 함유량에 대해 데이터 측면과 정도 측면에서 열처리 공정을 분석하였다. 데이터 측면에서 결정 트리 학습법 모델을 활용하여 정도 예측을 진행하는 것이 좋고, GBR 모델이 오스텝퍼링 열처리 공정에 대응하기 적합하다. 재료 측면에서 중요 특성 변수 7개 중 가장 높은 3개의 변수들에 대해 분석하였다. 그 결과, 오스텝퍼링 열처리 공정에서 소입 온도, 탄소 및 구리 함유량에 따라 정도를 예측하는 데 중요하게 작용할 것이라는 것을 판단하였다.

후 기

본 연구는 경상북도의 재원으로 경북동해안철강벨트경쟁력강화사업의 지원을 받아 수행된 연구임.

References

1. D. W. Han: Journal of the Korean Society for Heat Treatment, **12** (1999) 1225-1070.
2. G. Kwon: Journal of the Korean Society for Heat Treatment, **36** (2023) 121-127.
3. W. Zhou: Materials, **14** (2021) 1603-1632.
4. G. Y. Kim: Journal of the Korean Society for Heat Treatment, **26** (2013) 219-224.
5. C. Y. Kang: Journal of the Korean Society for Heat Treatment, **7** (1994) 298-306.
6. C. W. Chang: Procedia Engineering, **207** (2017) 502-507.
7. M. Killmann: Procedia Structural Integrity, **38** (2022) 212-219.
8. B. S. Han: Materials (Basel), **21** (2021) 97-104.
9. S.-H. Park: Journal of the Korean Society for Heat Treatment, **332** (2019) 256-262.
10. J. C. Ryu: Mater. Manuf. Processes, **37** (2022) 1664-1678.
11. J. Oh: Journal of the Korean Society for Heat Treatment, **36** (2023) 270-276.
12. I. G. Lee: Journal of the Korean Society for Heat Treatment, **17** (2004) 10-16.
13. S. Fujikawa: J. Mater. Process. Technol., **35** (1991) 317-342.
14. T.-W. Cu: Materials, **13** (2020) 2244.
15. S.-Y. Hsia: Nuts. Mater, **8** (2015) 6640-6657.
16. J. Yang: Materials & Design, **25** (2004) 219-230.
17. J. M. Lee: Transactions of Materials Processing, **28** (2019) 219-225.
18. T. J. Drozda: Manufacturing Eng., (1983) 32-39.
19. S. M. Kang: Transactions of Materials Processing, **31** (2022) 5-10.
20. S. K. Muhammad: Trans. Energy Web, **1** (2022) 24-33.
21. W. Xie: Food and Bioprocess Technology, **14** (2021) 1361-1374.
22. W. Lee: Journal of the Korean Society for Heat Treatment, **31** (2018) 1-5.
23. K. Kim: Journal of the Korean Society for Heat Treatment, **31** (2018) 180-186.
24. D. Praveen: IEEE, Manhattan, (2021) 1-6.
25. J.-Y. Kang: Journal of the Korean Society for Heat Treatment, **31** (2018) 275-282.
26. X. Feng: Symmetry, **13** (2021) 706-72.
27. P. Baldi: IEEE, **6** (1995) 182-195.
28. Gary C. McDonald: Wires Computational Stastic, **1** (2009) 93-100.
29. J. Ranstam: British Journal of Surgery, **105** (2018) 1348.
30. J. Lampinen: Neural Networks, **14** (2001) 257-274.
31. A. J. Myles: John Wiley and Sons Ltd., **18** (2014) 275-285.
32. L. Breiman: Mach. Learn., **45** (2001) 5-32.
33. J. H. Friedman: Computational Statistics & Data Analysis, **38** (2002) 367-378.
34. P. Geurts: Mach. Learn., **63** (2006) 3-42.
35. R. Polikar: Ensemble Machine Learning, (2012) 1-34.
36. M. C. Cakir: Materials Science and Engineering : A, **407** (2005) 147-153.
37. N. M. Shahani: Advances in Civil Engineering, **2021** (2021) 2565488.
38. J. de-Prado-Gil: Materials, **15** (2022) 4164.