

Borlanmış AISI H11 Takım Çeliğinin Kaplama Özellikleri ve Korozyon Oranının Makine Öğrenmesi Temelli Modellenmesi

Faruk ÇAVDAR^{1,a}, Ali GÜNEN^{2,b}, Mustafa SERT^{3,c}

¹Osmaniye Korkut Ata Üniversitesi, Osmaniye Meslek Yüksekokulu, Makine ve Metal Teknolojileri Bölümü, Osmaniye

²İskenderun Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Metalürji ve Malzeme Mühendisliği Bölümü, Hatay

³İskenderun Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Hatay

^aORCID: 0000-0002-4981-6428; ^bORCID: 0000-0002-4101-9520; ^cORCID: 0009-0003-6536-354X

Makale Bilgileri

Geliş : 19.01.2024

Kabul : 27.09.2024

DOI: 10.21605/cukurovaumfd.1560038

Sorumlu Yazar

Faruk ÇAVDAR

farukcavdar@osmaniye.edu.tr

Anahtar Kelimeler

AISI H11

Kutu borlama

Korozyon oranı

Makine öğrenmesi

Regresyon modeli

Atf şekli: ÇAVDAR, F., GÜNEN, A., SERT, M., (2024). Borlanmış AISI H11 Takım Çeliğinin Kaplama Özellikleri ve Korozyon Oranının Makine Öğrenmesi Temelli Modellenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(3), 625-638.

ÖZ

Yüksek sertlik, aşınma ve korozyon direncinde önemli ölçüde artışlar sağlaması nedeniyle borlama işlemi kullanılan en yaygın termokimyasal kaplama işlemlerinden birisidir. Bu çalışmada sıcak iş takım çeliklerinden AISI H11 malzemenin kutu borlama tekniğiyle borlanmasında işlem sıcaklığı ve süresinin kaplama kalınlığı, yüzey pürüzlülüğü, sertliği ve korozyon oranına etkisi makine öğrenmesi yöntemleriyle modellenmiş ve incelenmiştir. Çalışma kapsamında çoklu doğrusal, K en yakın komşu, destek vektör makinesi, karar ağacı, rastgele orman ve ekstrem eğim artırma regresyon algoritmaları ile modeller oluşturulmuş ve bu modellerin performansları R², ortalama mutlak hata ve ortalama kare hatası kriterleri kullanılarak kıyaslanmıştır. Kaplama tabakası kalınlık ve sertlikleri işlem sıcaklığı ve süresi ile artmaktadır. Diğer yandan bu özellikleri üzerinde borlama sıcaklığı süreye göre daha etkilidir. Regresyon modeli sonuçları incelendiğinde kaplama parametrelerinin kaplama kalınlığına ve pürüzlülüğe olan etkilerinin birleşerek korozyon oranı üzerinde kümülatif bir etkiye dönüştüğü görülmüştür. Çalışma sonucunda AISI H11 çeliğinin borlanmasında korozyon direnci için optimum parametre değerlerinin 1000 °C ve 2,2 saat olduğu sonucuna varılmıştır.

Machine Learning Based Modeling of Coating Properties and Corrosion of Borided AISI H1 Tool Steel

Article Info

Received : 19.01.2024

Accepted : 27.09.2024

DOI: 10.21605/cukurovaumfd.1560038

Corresponding Author

Faruk ÇAVDAR

farukcavdar@osmaniye.edu.tr

Keywords

AISI H11

Pack boronizing

Corrosion rate

Machine learning

Regression model

How to cite: ÇAVDAR, F., GÜNEN, A., SERT, M., (2024). Borlanmış AISI H11 Takım Çeliğinin Kaplama Özellikleri ve Korozyon Oranının Makine Öğrenmesi Temelli Modellenmesi. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 39(3), 625-638.

ABSTRACT

Due to the significant increases in hardness, wear, and corrosion resistance it provides, boronizing is one of the most commonly used thermochemical coating processes. In this study, the effect of process temperature and duration on coating thickness, surface roughness, microhardness, and corrosion rate in boronized hot work tool steel AISI H11 material with pack boronizing technique has been modeled and investigated using machine learning methods. Multiple linear, K-nearest neighbors, support vector machine, decision tree, random forest, and extreme gradient boosting regression algorithms were employed to create models, and their performances were compared using R², mean absolute error, and mean squared error criteria. Coating thickness and hardness increase with process temperature and duration. However, process temperature has a more significant effect on these properties compared to duration. Upon examining the results of the regression model, it was observed that the effects of coating parameters on thickness and roughness cumulatively transformed into an effect on the corrosion rate. As a result of the study, optimum parameter values for corrosion resistance in boronized AISI H11 steel were determined to be 1000°C and 2.2 hours.

1. GİRİŞ

Yüksek alaşımlı çeliklerden birisi olan AISI H11 çeliği yüksek tokluk, dayanım ve süneklik özelliklerine sahip olduğundan sıcak ve soğuk işlem uygulamalarında yaygın olarak kullanılmaktadır [1,2]. AISI H11'in uygulamaları arasında uçak iniş takımları, helikopter rotor kanatları ve milleri, ekstrüzyon mandrilleri, plastik kalıpları, maçalar, kalıp tutucu bloklar, sıcak iş zımbaları, dişliler, merdaneler ve diskler yer almaktadır [3-5]. Bununla birlikte, diğer birçok metalde olduğu gibi, AISI H11 çeliği, yapısı kararsız olduğundan, kararlı, oksitlenmiş bileşikler oluşturmak için çevre ile etkileşime girme eğilimindedir. Bu durum malzemenin servis hayatında korozyon olarak kendisini göstermektedir. Pratikte korozyonu tamamen ortadan kaldırmak mümkün değildir. Fakat korozyonun ilerlemesi, çeşitli kaplamalar vasıtasıyla yavaşlatılabilir [6,7]. Bunlardan en etkili olanı metal yüzeyinin korozyon direnci yüksek bir malzeme ile kaplanmasıdır.

Aşındırıcı ortama maruz kalan çeliklerin veya diğer sert malzemelerin direncini artırmak için çok çeşitli kaplamalar uygulanır. Nitrüleme [8], alüminyumlama [9], iyon implantasyonu [10], seçici lazer eritme, fiziksel buhar biriktirme [11], kimyasal buhar biriktirme [12,13] ve derin kriyojenik ısıtma işlemi bu yöntemler arasındadır [14]. Kaplama tabakasının ana malzeme üzerindeki varlığını 1000 °C'ye varan sıcaklıklara kadar koruyabilmesi ve altlık malzeme ile adhezyonu yüksek olması avantajlarından dolayı termokimyasal işlemler diğerler kaplama metodlarına göre tercih sebebidir [3,7].

Borlama işlemi sonucu elde edilen borür kaplamaların yüksek sertlik, korozyon ve aşınma dirençleri sebebiyle termokimyasal kaplamalar içerisinde en yaygın olarak kullanılan kaplama yöntemlerinden birisidir. Bu yöntem Bor (B) verici bir ortamdan yüksek sıcaklık ve süreye bağlı olarak bor'un metalik malzemelere difüze olması ve metalik malzeme ile kimyasal bağlı bir borür tabakası oluşturması esasına dayanır. B'nin bir veya birden fazla bileşiminin oluşan sert bir yüzey elde edilmesini sağlar [15-18]. Borlama ile yüksek sertliğe ve mukavemete, ayrıca çeliklerde karbonlama, nitrüleme ve karbonitasyon gibi geleneksel yüzey işlemleriyle kolayca elde edilemeyen üstün tribolojik performansa sahip yüzeyler elde edilir [19-22]. Ayrıca bazı çalışmalarda borit tabakalarının çeşitli aşındırıcı sıvılara karşı çeliklerin korozyon direncini arttırdığını ortaya konulmuştur [23-26].

Değişik türdeki kaplamaların özelliklerinin makine öğrenmesi modelleri kullanılarak modellenmesi ile çalışmalara literatürde ancak son zamanlarda rastlanmaktadır. Kaplamalar ile ilgili yapılan makine öğrenmesi çalışmalarında, Magnezyum alaşımlarına uygulanan termal spreyle kaplamaların aşınma davranışları [27], çeliklere uygulanan çok katmanlı $Ti_xAl_{1-x}N$ kaplamanın mekanik ve tribolojik özellikleri [28], karbid kesme takım uçlarının katı yağlayıcı ile kaplanmasında kaplama kalınlığı [29], yüksek entropili alaşımların ve çok elemanlı alaşımların termal spreyle oluşturulmasında toz formasyonlarının ve bunlara karşılık gelen faz oluşumları [30], kaplanmış alüminyum alaşımlı vidalama elamanlarının galvanik korozyon davranışları [31], değişik kalınlıklarda iki katmandan oluşan $TiAlN$ kaplama sistemlerinin mekanik özellikleri [32] gibi hususların tahmin edilmesi gibi konular araştırılmıştır.

Borlanmış çeliklerin korozyon direncini inceleyen araştırmalar daha çok asit ortamlarında, özellikle bir HCl ortamındaki korozyon davranışlarına yöneliktir [33,34]. Yapılan çalışmalar sonucunda borlama işleminden sonra çeliklerin (düşük karbonlu çelik, soğuk takım çeliği, dişli çelik, AISI 1018, AISI 304'ten AISI M2'ye) korozyon direncinin arttığı belirlenmiştir. Birçok çelik malzeme NaCl ortamında kullanılıyor olmasına rağmen borürlenmiş çeliklerin NaCl ortamında korozyon davranışı üzerine yapılan çalışmaların sınırlı olduğu görülmüştür [35-38].

Önceki çalışmalarda borlanmış AISI H11 takım çeliğinin NaCl ortamında korozyon direnci analitik olarak incelenmiştir fakat kaplama işlemindeki uygulanan parametrelerinin korozyon direncine etkisinin herhangi bir yöntemle modellenmesine yönelik çalışmaya rastlanmamıştır [39]. Bu çalışmada AISI H11 çeliğinin kutu borlama tekniği ile borlanması 800 °C ile 1000 °C arasındaki sıcaklık ve 1 ile 5 saat arasındaki işlem süresi parametrelerinin kaplama kalınlığı, pürüzlülük, mikrosertlik gibi kaplama özelliklerinin yanı sıra korozyon direncine etkisi de değişik makine öğrenmesi yöntemleri ile modellenmiştir. Modelleme uygulamalarında, ekstrem gradyan artırma (XGBoost), destek vektör makinesi regresyonu (SVR), karar ağacı regresyonu (DT), K en yakın komşu (k-NN), çoklu doğrusal regresyon (MLR) ve rastgele orman (RF) algoritmaları kullanılmış ve bunların tahmin performansları karşılaştırılmıştır.

2. MATERYAL VE YÖNTEM

2.1. Veri Seti

Bu çalışmada kullanılan veri seti daha önce yayınlanmış olan AISI H11 takım çeliğinin borlanmasında sıcaklık ve işlem süresi parametrelerinin korozyon dayanımına etkisi ile ilgili çalışmasındaki deney sonuçlarından oluşturulmuştur [39]. Kullanılan altlık malzemesinin DV-6S 3063A, Thermo Jarrell ASH/BAIRD Corp., ABD spektral analiz cihazı ile tespit edilen kimyasal bileşimi Tablo 1’de verilmiştir. Çalışmada bor kaynağı olarak %90 amorf nanobor ve aktivatör olarak ağırlıkça %10 NaBF₄ tozundan oluşan borlama maddesi kullanılmıştır.

Tablo 1. Deneysel çalışmada kullanılan AISI H11 sıcak iş takım çeliğinin kimyasal kompozisyonu

Element	Cr	Mo	V	Si	C	Fe
% Ağırlık	5.07	1.25	0.3	1.0	0.35	Kalan

Belirtilen çalışma kapsamında AISI H11 çeliği numuneleri nano boyutlu borlama tozları kullanılarak 800, 900 ve 1000 °C’de 1, 3 ve 5 saat süreyle kutu borlama tekniği ile borlanmıştır. Belirtilen sıcaklık ve işlem sürelerinin kombinasyonları ile gerçekleştirilen deneysel kaplamalar ile elde edilen numunelerin kaplama tabakası kalınlıkları, ortalama yüzey pürüzlülükleri ve ortalama mikrosertlik değerleri tespit edilmiştir. Sonrasında borlanmış AISI H11 çelik numunelerinin korozyon direnci performansı CH 608E analiz cihazı kullanılarak ağırlıkça %3,5 NaCl çözeltisinde elektrokimyasal korozyon testi yapılarak belirlenmiştir. Her test üç kez tekrarlanmış ve korozyon değerlerinin her biri, üç ölçümün ortalaması olarak rapor edilmiştir. Her numune için uygulanan borlama parametreleri ve ölçüm sonuçları Tablo 2’de sunulmuştur.

Tablo 2. Deneyselerde kullanılan bağımsız işlem parametreleri ve ölçüm sonuçları

Deney no	İşlem sıcaklığı (°C)	İşlem süresi (Saat)	Kaplama kalınlığı (µm)	Mikrosertlik (HV _{0.05})	Yüzey pürüzlülüğü, Ra (µm)	Korozyon oranı (g/h) 10 ⁻⁶
S1	800	1	10.25±0,5	1704±150	0.65	6.371
S2	800	3	12.18±0,6	1710±95	0.52	4.544
S3	800	5	15.8±1	1719±70	0.45	4.28
S4	900	1	32.55±0,9	1935±75	0.312	4.759
S5	900	3	42.75±1,2	1942±61	0.298	3.027
S6	900	5	47.5±2,1	1955±52	0.285	2.769
S7	1000	1	54.6±1,5	1950±75	0.327	5.255
S8	1000	3	85.8±1,9	1993±55	0.335	5.272
S9	1000	5	94.9±2,2	2015±105	0.358	6.062

Çalışma kapsamında işlem sıcaklığı ve işlem süresi bağımsız değişkenlerinin kombinasyonlarından ve kaplama kalınlığı, mikrosertlik, yüzey pürüzlülüğü ve korozyon oranı bağımlı değişkenlerinin ölçülen değerlerinden oluşan 9 satırlık veri seti elde edilmiştir. Veri seti çok küçük olduğu için verilerin tümü eğitim seti olarak kullanılmıştır.

Veri setindeki sıcaklık ve süre değerlerinin büyüklük farkı oldukça fazladır. Buna gibi durumlarda bir değişkenin diğerini baskılamasının önüne geçmek için standartlaştırma işlemi uygulanır. Bu çalışmada da sıcaklık ve süre verileri Denklem 1’e göre ölçeklendirme yapan ScikitLearn kütüphanesi kullanılarak standartlaştırılmıştır.

$$z = \frac{x-u}{s} \quad (1)$$

Denklemden z , x numunesinin standartlaştırılmış değerini, u numunelerin ortalamasını, s de numunelerin standart sapmasını ifade etmektedir.

2.2. Makine Öğrenmesi Modelleri

Bu çalışmada matematiksel işlemler için Numpy, makine öğrenmesi modellerinin uygulanmasında ScikitLearn kütüphaneleri kullanılmıştır. Tablo 2’de listelenen deney parametreleri kullanılarak kaplama kalınlığı, mikrosertlik, yüzey pürüzlülüğü ve korozyon oranı bağımlı değişkenlerinin her biri için aşağıda belirtilen makine öğrenmesi algoritmaları uygulanmıştır.

2.2.1. Çoklu Doğrusal Regresyon (MLR)

Birden fazla bağımsız değişken ile bunlara bağlı olarak değişen çıktılar arasındaki ilişkinin doğrusal olduğunu varsayan istatistiksel bir yaklaşımdır. Çoklu doğrusal regresyon modeli regresyon katsayılarını bu ilişkiyi en iyi şekilde yansıtmak için veri setinden tahmin eder [40].

Çoklu doğrusal regresyon modeli matematiksel olarak denklem 2 ile formüle edilir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (2)$$

Denklemden, Y bağımlı değişkeni, X_1, X_2, \dots, X_k bağımlı değişkenleri, $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ regresyon katsayılarını ve ε hata terimini ifade eder.

2.2.2. K En Yakın Komşu Regresyonu (kNN)

K En Yakın Komşu Regresyonunun temel prensibi, yeni bir veri noktasının tahminini, en yakınındaki k veri noktasının ortalaması veya medyanı gibi bu noktalara ait değerlerin bir türü ile yapmaktır. Bu yöntem, veri setindeki benzer örneklerin çevresindeki yapıyı kullanarak tahmin yapar [41].

Bu yöntemde bir veri noktasının tahmini yapılırken önce en yakın k sayıda veri noktası genellikle Euclidean mesafesi veya diğer benzer mesafe ölçütleri kullanılarak belirlenir. Bu komşulara ait bağımlı değişken değerleri kullanılarak bir tahmin yapılır. Bu tahmin, k veri noktasının ortalaması veya medyanı gibi istatistiksel bir değer olabilir. Kullanıcı tarafından belirlenen bir k değeri vardır. Bu k değeri, tahminin ne kadar hassas olacağını etkiler. Daha küçük k değerleri modelin karmaşıklığını artırırken, daha büyük k değerleri düzleştirme etkisi yapar [41].

2.2.3. Destek Vektör Makinesi Regresyonu (SVR)

Bu algoritma, veri setindeki noktaları bir hiperdüzlem etrafında bir regresyon çizgisine yerleştirmeye çalışır. Bu çizgi, veri setindeki noktalara olan uzaklıkların toplamını minimize ederken, bir tolerans parametresi (ε) kullanılarak bir hata payına izin verilir.

Destek Vektör Makinesi, regresyon problemleri için önce bir hiperdüzlem oluşturur. Bu hiperdüzlem, bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini temsil eden bir regresyon çizgisini ifade eder. Algoritma, hiperdüzleme yakın olan noktalara daha az ağırlık verir ve belirli bir hata payına (ε) izin verir. Bu şekilde, modelin veri setindeki gürültülü noktalara daha az hassas olması sağlanmış olur. SVM, hiperdüzlemi çevreleyen destek vektörleri arasındaki mesafenin maksimize edilmesini hedefler. Buna maksimum margin prensibi denir ve modelin genelleme yeteneğini artırır, aşırı uyum riskini azaltır [42].

2.2.4. Karar Ağacı Regresyonu (DT)

Temelde, veri setini belirli koşullar altında bölerek ve bu bölünmelerdeki ortalamaları veya medyanları kullanarak bağımlı değişkeni tahmin eden bir ağaç yapısı oluşturur. Her bir yaprak düğümü, bir regresyon değerini temsil eder [42].

Karar ağacı regresyonu, veri setini belirli koşullar altında bölerek homojen alt gruplara ayırır. Bu bölünmeler, her bir düğümde belirli bir özellik (değişken) ve bir eşik (threshold) kullanılarak yapılır. Veri noktaları, ağacın dallarında ilerlerken belirli koşullar altında ağacın çeşitli düğümlerine yönlendirilir. Her bir düğüm, belirli bir alt kümeyle ilişkilidir. Ağacın yaprak düğümlerine ulaşıldığında, bu düğümlerdeki alt kümelerle ait bağımlı değişken değerlerinin ortalaması veya medyanı, o düğümün regresyon tahmin değerini oluşturur [41].

2.2.5. Rastgele Orman Regresyonu (RF)

Rastgele ormanlar, ağaçlardan oluşan bir ensemble modelidir. Her bir ağaç, veri setinin rastgele alt kümeleri üzerinde eğitilir ve bu ağaçların tahminleri birleştirilerek genel bir tahmin yapılır [41,43].

Rastgele orman regresyonu, veri setinin rastgele alt kümeleri üzerinde birden çok karar ağacı eğitir. Bu alt kümeler, veri setinden rastgele örnekleme yaparak oluşturulur. Her bir alt küme üzerinde ağaçlar eğitilir. Ağaçlar, veri setinin belirli özelliklerine ve hedef değişkenine göre bölünerek eğitilir. Bu bölünmeler, ağaçların belirli koşullar altında veriyi ayırmasını sağlar. Tüm ağaçlar eğitildikten sonra, her bir ağaç bağımsız olarak tahminlerde bulunur. Rastgele orman, bu tahminleri birleştirerek genel bir regresyon tahminini elde eder. Bu birleştirme genellikle ağaçların tahminlerinin ortalamasıdır [42,43].

2.2.6. Ekstrem Eğim Arttırma (XGBoost)

Orijinal adı “Extreme Gradient Boosting” olan bu algoritma “gradient boosting” algoritmasının performansını iyileştirmek ve bazı özellikler katmak amacıyla Chen ve Guestrin tarafından geliştirilmiştir [44,45]. Gradient boosting zayıf tahminicileri birleştirerek önceki tahminicilerin hatalarını düzelteren bir öğrenme algoritmasıdır. XGBoost algoritmasında ise her ağaç eğitim sırasında belirli bir örnek kümesi üzerinde çalışır ve her ağaç bir önceki ağacın hatalarını telafi eder. Hesaplanan gradyanlar her bir örnek için tahmin hatalarını belirlemek ve bunlara göre modeli güncellemek için kullanılır. Algoritmada modelin aşırı uyumunu (overfit) önlemek için ağaçların karmaşıklığını kontrol eder [46,47].

2.3. Model Başarı Ölçütleri

Herhangi bir bağımlı değişkenin matematiksel modelinin başarısının değerlendirilmesi için değişik ölçütler tanımlanmıştır. Bu çalışmada geliştirilen makine öğrenmesi modellerinin başarıları, Belirleme katsayısı (R^2), Ortalama kare hatası (MSE), mutlak hata ortalaması (MAE) ile belirlenecek ve birbirleri ile kıyaslanacaktır.

Belirleme katsayısı (R^2), tahmin edilen değerlerin gerçek değerlere olan uyumunu ölçer. 1'e yaklaşan bir R^2 değeri, modelin veri setindeki değişkenliğin büyük bir kısmını açıkladığını, sifıra yaklaşan bir değer ise açıklamanın daha düşük olduğunu gösterir. R^2 , Eşitlik 3 ile hesaplanır:

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (3)$$

Ortalama Mutlak Hata (MAE), bir regresyon modelinin tahminlerinin ne kadar doğru veya yanlış olduğunu ölçen bir metriktir. MAE, tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasını ifade eder ve Eşitlik 4 ile hesaplanır.

$$MSE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

Ortalama Kare Hatası (MSE) ise tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını ifade eder ve Eşitlik 5 ile hesaplanır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

Denklem 4 ve 5'te n veri setindeki gözlem sayısını, y_i gerçek değerleri, \bar{y} veri setindeki y 'lerin ortalamasını, \hat{y}_i model tahminini ifade etmektedir.

3. SONUÇLAR VE TARTIŞMA

Şekil 1'de görüldüğü üzere AISI H11 çeliği üzerinde tüm işlem sıcaklıklarında borür kaplama tabakalarının elde edildiği görülmektedir. Ancak, 800 °C'de elde edilen kaplama kalınlıklarının 900 °C ve 1000 °C'ye göre çok düşük kalınlıklarda olduğu görülmektedir. Bu durum borun çeliğin α (Ferrit) ve γ (Östenit) fazları içerisindeki çözünürlükleri ile ilgilidir. Borun ferrit ve östenit fazları içerisindeki çözünürlüğü ile ilgili birçok sayısal bulgu bu alanda çalışan bilim insanları tarafından sunulmuştur. Ancak, tüm bilim insanlarının hem fikir oldukları nokta borun östenit fazı içerisindeki çözünürlüğünün ferrite göre daha yüksek olduğudur [48–56]. Sharma ve diğerleri (2019) α/γ dönüşüm aralığına yakın sıcaklıklarda borun, düşük alaşımlı çelikteki çözünürlüğü ağırlıkça % \approx 0,001 olduğu 925 °C'nin üzerine çıkıldığında çözünürlüğün hızla arttığı ve 1150–1170 °C'de γ -Fe'de ağırlıkça %0,0055–0,260 ile en yüksek değere


eriştiği bildirmiştir[48]. Şimdiki çalışmada 800°C’de elde edilen kaplama tabakalarının 900 ve 1000 °C’ye göre düşük kalması bundan dolayıdır.

3.1. Makine Öğrenmesi Modelleme Sonuçları

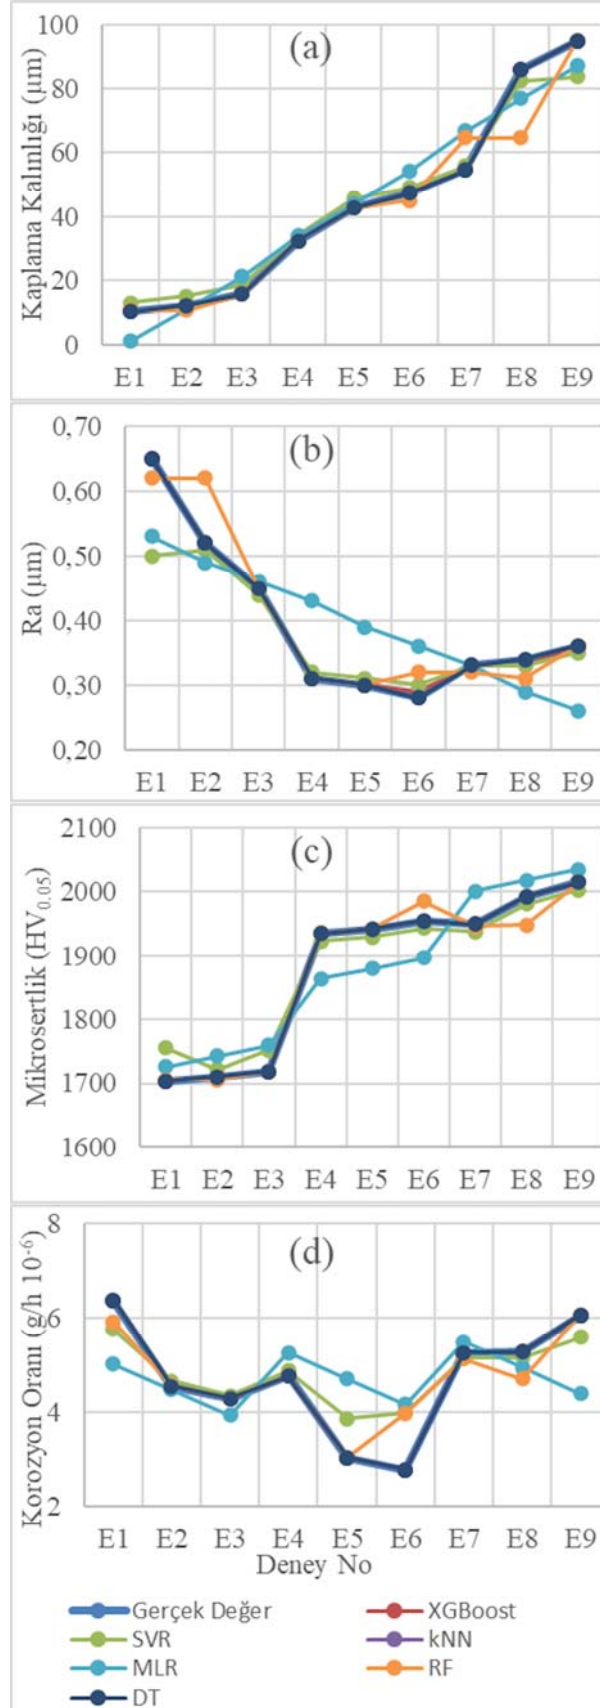
Veri setindeki parametre değerlerine karşılık ölçülen bağımlı değişken değerleri kullanılarak makine öğrenme modelleri eğitilmiştir. Elde edilen modellerin kullanılabilirliğinin belirlenmesi için önce gerçek değerler ve model tahminleri Şekil 2’de görselleştirilmiştir. Daha sonra her bir bağımlı değişken için belirlenen model başarı ölçüleri hesaplanmış ve Tablo 3’te listelenmiştir.

Şekil 2 genelinde gerçek ölçüm değerleri ve regresyon modeli tahminleri incelendiğinde XGBoost, kNN, DT regresyon modeli tahminlerinin tümünün gerçek değerler ile bire bir çakıştığı görülmektedir. Bunların yanında Tablo 3’te XGBoost, kNN ve DT modelleri için R² değerlerinin 1 olduğu ve MAE ile MSE değerlerinin de ya 0 ya da ölçüm aralık değerlerine kıyasla çok küçük değerler aldığı görülmektedir. Bu veriler XGBoost, kNN ve DT makine öğrenme modellerinde aşırı öğrenme ihtimalinin yüksek olduğunu göstermektedir.

Şekil 2 genelinde gerçek ölçüm değerleri ve regresyon modeli tahminleri incelendiğinde XGBoost, kNN, DT regresyon modeli tahminlerinin tümünün gerçek değerler ile bire bir çakıştığı görülmektedir. Bunların yanında Tablo 3’te XGBoost, kNN ve DT modelleri için R² değerlerinin 1 olduğu ve MAE ile MSE değerlerinin de ya 0 ya da ölçüm aralık değerlerine kıyasla çok küçük değerler aldığı görülmektedir. Bu veriler XGBoost, kNN ve DT makine öğrenme modellerinde aşırı öğrenme ihtimalinin yüksek olduğunu göstermektedir.



Şekil 1. AISI H11 çeliğine a) 800 °C’de 1 saat, b) 800 °C’de 3 saat, c) 800 °C’de 5 saat, d) 900 °C’de 1 saat, e) 900 °C’de 3 saat, f) 900 °C’de 5 saat, g) 1000 °C’de 2 saat, h) 1000 °C’de 4 saat ve i) 1000 °C’de 5 saat kutu borlama uygulanarak elde edilen kaplamaların kesitsel SEM mikroyapı görüntüleri



Şekil 2. a) kaplama kalınlığı, b) yüzey pürüzlülüğü, c) mikrosertlik ve d) korozyon oranı için oluşturulan değişik makine öğrenmesi modeli tahminleri ve bunlara karşılık ölçülen değerler

Tablo 3. Geliştirilen makine öğrenmesi modellerinin performans değerleri


Bağımlı Değişken	Algoritma	R ²	MAE	MSE
Kaplama Kalınlığı	MLR	0.97	2.45	7.10
	kNN	1,00	0,00	0,00
	SVR	0.99	1.85	4.47
	DT	1,00	0,00	0,00
	RF	0.96	1.99	7.86
	XGBoost	1,00	0.15	0.03
Yüzey Pürüzlülüğü	MLR	0.74	0.26	0.08
	kNN	1,00	0,00	0,00
	SVR	0.89	0.16	0.05
	DT	1,00	0,00	0,00
	RF	0.95	0.15	0.04
	XGBoost	1,00	0.01	0,00
Mikrosertlik	MLR	0.93	6.51	46.04
	kNN	1,00	0,00	0,00
	SVR	0.98	4.36	23.22
	DT	1,00	0,00	0,00
	RF	0.99	3.07	18.14
	XGBoost	1,00	0.22	0.09
Korozyon oranı	MLR	0.42	0.92	1.05
	kNN	1,00	0,00	0,00
	SVR	0.87	0.64	0.56
	DT	1,00	0,00	0,00
	RF	0.91	0.51	0.47
	XGBoost	1,00	0.03	0,00

Şekil 2a ve d’de SVR modeli tahminlerinin gerçek değerlere grafik genelinde çok yakın olduğu görülmektedir. Ayrıca kaplama kalınlığı ve korozyon oranı için modellerin performans kriterleri Tablo 3’te incelendiğinde SVR algoritmasının R², MAE ve MSE değerlerinin oldukça iyi olduğu görülmektedir. Bahsedilen durumlar göz önünde bulundurularak SVR algoritmasıyla gerçekleştirilen modelin kaplama kalınlığı ve korozyon oranı için daha uygun olduğu kanaatine varılmıştır. Diğer yandan Şeki2 1b ve c incelendiğinde Yüzey pürüzlülüğü ve mikrosertlik için RF algoritmasıyla oluşturulan model tahminlerinin gerçek ölçüm sonuçlarla oldukça yakın olduğu fark edilmektedir. Bu modellerin performans R², MAE ve MSE değerleri Tablo 3’te incelendiğinde modellerin gerçek değerlerle oldukça uyumu olduğu anlaşılmaktadır. Bu nedenlerle RF algoritmasıyla elde edilen makine öğrenmesi modellerinin yüzey pürüzlülüğü ve mikrosertlik için en uygun olduğu sonucuna varılmıştır.

3.2. Tartışmalar


Yapılan makine öğrenmesi modellerine göre kaplama kalınlığı, yüzey pürüzlülüğü, mikrosertlik ve korozyon oranı tahminlerinin deney parametrelerine bağlı değişimlerini inceleyebilmek için sırası ile Şekil 3, 4, 5 ve 6 oluşturulmuştur.

Şekil 3’te SVR algoritmasıyla geliştirilen makine öğrenmesi modeline göre kaplama kalınlığının 800 °C, 900 °C ve 1000 °C’de zaman göre değişimi görülmektedir. Grafiğe göre bütün sıcaklık değerlerinde kaplama kalınlığı 1 saat ile iki saat aralığındaki sürelerde zamanla belirsiz bir şekilde artmaktadır. Sürenin 2 saatin üzerine çıkmasıyla birlikte işlem süresinin kaplama kalınlığı üzerindeki olumlu etkisi artmaktadır. Bu durum yaklaşık 4 saat işlem süresine kadar devam etmekte ve 4,6 saatin üzerindeki işlem sürelerinde kaplama kalınlığı neredeyse sabitlenmektedir. Grafiğin özellikle işlem süresinin 2 saatin üzerindeki kısmı [57,58] tarafından raporlanan bulgularla uyumludur. Bu durum, birinci Fick kanununun bir sonucudur. Borlama işlemi başladığında, borun konsantrasyon gradyanı yüksektir ve bu nedenle başlangıçtaki akı da yüksektir. Ancak, zamanla bor gradyanı azalır ve bu da borür kaplama tabakasının oluşumunun azalmasıyla sonuçlanır.




Şekil 3. SVR ile oluşturulmuş modele göre kaplama kalınlığının işlem sıcaklığı ve süresine bağlı değişimi


Yüzey pürüzlülüğünün RF algoritmasıyla geliştirilen modele göre sıcaklık ve işlem süresine bağlı değişimi Şekil 4'te verilmiştir. Grafikte yüzey pürüzlülüğünün 800 °C ve 900 °C sıcaklıklarda zamana göre değişiminin neredeyse aynı olduğu görülmektedir. Bu sıcaklıklarda yüzey pürüzlülüğü 2 saat işlem süresine kadar 0,63 µm değerinde sabit kalmaktadır. Daha sonra yüzey pürüzlülüğü hızla 0,3 µm'ye düşmekte ve 4 saat bekleme süresine kadar sabit devam etmektedir. Bu süre sonunda yüzey pürüzlülüğünde belirgin olmayan bir artış gerçekleşmekte ve 3,1 µm değerinde sabit kalmaktadır. İşlem sıcaklığı 1000 °C'ye çıktığında 2 saate kadar olan işlem süresinde yüzey pürüzlülüğü 0,45 µm olarak gerçekleşmektedir. İşlem süresinin 2 ile 4 saat olduğu aralıkta 0,32 µm'ye düşmekte ve 4 saat sonrasında ile hafifçe artarak 3,6 µm olarak devam etmektedir. Borlama sıcaklığının 800 °C'den 900 °C'ye çıkmasıyla yüzey pürüzlülük değerlerinde azalma meydana gelirken, 900 °C'den 1000 °C'ye çıkması ise yüzey pürüzlülük değerlerinde bir miktar artışa neden olmuştur. Bu karmaşık durum, Şahin (2009) tarafından incelenmiştir ve termokimyasal kaplamalar sonrası numunelerin yüzey pürüzlülük değerlerinde genellikle artış olabileceği öngörülse de bazı durumlarda azalma meydana gelebileceği bildirilmiştir. Bu bulgular numunelerin kaplama öncesi yüzey pürüzlülük değerlerinin önemine işaret etmektedir. Yapılan çalışmalarda her bir çelik türüne bağlı olarak değişebilen bir kritik yüzey pürüzlülüğü değeri olduğu bildirilmiştir. Eğer kaplama işlemi öncesi yüzey pürüzlülük değeri bu eşğin altındaysa, borlama işlemi sonrası yüzey pürüzlülük değerlerinde artış beklenirken, yüzey pürüzlülük değeri bu eşğin üstündeyse, dışarı doğru büyüyen borür tabakasının bu sirtları azaltacağından kaplama işlemi sonucunda yüzey pürüzlülük değerlerinin azalabileceği belirtilmiştir [59,60].



Şekil 4. RF algoritması ile oluşturulmuş modele göre yüzey pürüzlülüğünün işlem sıcaklığı ve süresine bağlı değişimi



Şekil 5. RF algoritması ile oluşturulmuş modele göre mikrosertliğin işlem sıcaklığı ve süresine bağlı değişimi



Şekil 6. SVR ile oluşturulmuş modele göre korozyon oranının işlem sıcaklığı ve süresine bağlı değişimi

Şekil 5'te mikrosertlik için RF algoritması kullanılarak geliştirilmiş regresyon modeline göre mikrosertliğin sıcaklık ve işlem süresine göre değişimi görülmektedir. Bütün sıcaklık değerleri için 2 saat işlem süresine kadar 1710 HV_{0,05} değerinde devam etmektedir. İşlem süresinin 2 ile 4 saat olduğu aralıkta mikrosertlik değeri 800 °C ve 900 sıcaklıklar için 1940 iken 1000 °C için 1985 değerini almaktadır. İşlem süresinin 4 saatin üzerinde olduğu durumlarda mikrosertlikler küçük artışlar göstererek 800 °C ve 900 °C için 1948, 1000 °C için 2015 HV_{0,05}'e çıkmaktadır. Li ve ark. çalışmalarında Cr12Mn2V2 üzerine gerçekleştirilen borlama işleminde zamanın ve sıcaklığın artmasıyla mikrosertlik değerlerinin arttığını gözlemlemiştir [61]. Borlama süresi ve sıcaklık artışı ile beraber sertlik değerlerinin artması kaplama tabakası içeriğindeki FeB fazının kalınlığının artışıyla ilgilidir. Nitekim FeB fazının sertliği 1900-2100 HV_{0,05} aralığında iken düşük sıcaklık ve işlem sürelerinde oluşması daha muhtemel olan Fe₂B fazının sertliği 1650- 1800 HV_{0,05}'dir [7,62,63]. Sıcaklık ve sürenin daha da artması sonu sertlik değerlerinin az artması yukarıda anılan 2 fazın daha sert bir faza dönüşmemesinin bir sonucudur.

SVR algoritması kullanılarak oluşturulan regresyon modeline göre, korozyon oranının işlem sıcaklığı ve süresine bağlı değişimi Şekil 6'da gösterilmiştir. Korozyon direncinin 800 °C'lik borlama sıcaklığında 4.2 saate kadar diğer diğer sıcaklık değerlerine göre daha üstün olduğu görülmektedir. Bu durum 800°C'lik borlama sıcaklığında Fe₂B/FeB oranının 900 ve 1000 °C'de yapılan borlamalara göre daha yüksek olmasından kaynaklandığı düşünülmektedir. Çünkü Fe₂B fazının korozyon direnci FeB fazına göre daha yüksektir [64,65].

Öte yandan, 1000 °C'nin 900°C'ye göre 2,6 saatten sonraki borlama sıcaklıklarında daha iyi korozyon direnci göstermiş olması korozyon direncinde kaplama kalınlıklarının da önemli bir rol oynadığına işaret etmektedir. Literatürdeki çok sayıda termokimyasal kaplama araştırması, kaplama kalınlıklarındaki artışın kaplamalarda mikro çatlaklar oluşmasına neden olmadığı sürece daha iyi bariyer koruması sağladığı bildirilmiştir [59,66,67].

Grafikte, 800°C'de 3,5 saat işlem süresine kadar korozyon oranında hafif bir azalma görülmekte, sonrasında süre arttıkça korozyon oranında artış meydana gelmektedir, 5 saatlik işlem süresinde 5,16'ya ulaşmaktadır. Korozyon oranı, 900°C işlem sıcaklığı için 1 saatlik işlem süresinde 4,66'dan başlayarak 2,8 saatlik süre için 3,85'e kadar düşmekte, ardından 5,16'ya çıkmaktadır. İşlem sıcaklığı 1000 °C'ye çıktığında ise korozyon oranı önce azalarak sürelerin 2,5 saat ve 3,9 olduğu noktalarda minimuma ulaşmakta ve sonrasında 5.58'e yükselmektedir.

Şekil 3, 4, 5 ve 6 bir arada değerlendirildiğinde kaplama parametrelerinin kaplama kalınlığına ve pürüzlülüğe olan etkilerinin birleşerek korozyon oranı üzerinde kümülatif bir etkiye dönüştüğü görülmektedir. Düşük sıcaklık ve işlem sürelerinde kaplama kalınlıkları düşük olmaktadır ve kaplama kalınlığının artması yalnız başına değerlendirildiğinde korozyonu arttırıcı bir etkiye sahiptir. Diğer yandan yüzey pürüzlülüğünün azalması korozyonu azaltıcı bir etkiye sahiptir [35]. Bu durum da düşük sıcaklık ve işlem süreleri için geçerlidir. Düşük işlem sürelerinde kaplama kalınlıkları bütün sıcaklıklar için birbirine yakındır fakat pürüzlülük değeri özellikle 800 ve 900 C'de 1000 C'ye göre yüksektir. Bu durum kısa işlem sürelerinde korozyon oranının düşük sıcaklıklarda daha yüksek olması sonucu doğurmuştur. Şekil 4'de işlem süresinin orta değerlerinde yüzey pürüzlülüğünün bütün sıcaklıklar için birbirine yakın olduğu, Şekil 3'de bu sürelerde kaplama kalınlığının sıcaklık artışıyla olumsuz etkilendiği görülmektedir. Bu durum Şekil 6'da işlem süresinin orta değerlerinde korozyon oranının özellikle 800 C'de belirgin şekilde yüksek olmasıyla kendisini göstermektedir. Uzun işlem sürelerinde bu parametrelerin etkilerinin oldukça karmaşık bir şekilde ortaya çıktığı görülmektedir.

4. SONUÇLAR

Bu çalışmada AISI H11 çeliği kutu borlama tekniği kullanılarak 800, 900 ve 1000°C sıcaklıklarda, 2, 3 ve 5 saat işlem sürelerinde borlama işlemine tabii tutulmuştur. Elde edilen kaplamaların kalınlık, yüzey pürüzlülüğü ve mikrosertlikleri ile korozyon oranları tespit edilmiştir. Elde edilen sonuçlar MLR, kNN, SVR, DT, RF ve XGBoost algoritmaları ile regresyon modellerinin geliştirilmesinde kullanılmıştır. Oluşturulan regresyon modellerinin R², MAE ve MSE başarı değerlendirmeleri yapılmış ve oldukça tatmin edici sonuçlar elde edildiği görülmüştür. Değerlendirmeler sonucunda kaplama kalınlığı ve korozyon oranı için SVR, yüzey pürüzlülüğü ve mikrosertlik için RF algoritmalarının en iyi sonuçları verdiği kanaatine ulaşılmıştır.

Regresyon modelleri kullanılarak bağımsız değişkenlerin sıcaklık ve işlem süresine bağlı değişimleri grafiklere aktarılmıştır. Grafikler kullanılan yapılan çıkarımlar şunlardır:

- AISI H11 çeliğinin α/γ dönüşüm sıcaklığı 845°C olması sebebiyle 800°C'de oluşan kaplama tabakaları 900 ve 1000°C'ye göre oldukça düşük kalmıştır.
- Kaplama tabakası kalınlık ve sertlikleri artan borlama sıcaklığı ve süresi ile artmıştır. Kaplama tabakası kalınlık ve sertlik değerlerinde borlama sıcaklığı süreye göre daha etkilidir.
- Korozyon dirençleri oluşan borür fazları ve kaplama tabakası kalınlıklarına bağlı olarak değişiklik göstermiştir. 800 °C'de borlanmış numune diğer iki numuneye göre 4,6 saate kadar daha yüksek korozyon direnci göstermiş olması bu sıcaklıktaki borlama sonucu Fe₂/FeB değerlerinin 900 ve 1000 °C'ye göre daha yüksek olması ile ilgilidir. Bu durum Fe₂B'nin korozyon direncinin FeB'den daha yüksek olduğunu göstermiştir.
- Korozyon direncine etki eden diğer parametre ise kaplama kalınlıkları bariyer etki gösterdiğinden faz yapısı birbirine yakın olan, 900 ve 1000 °C'de borlanan numuneler arasında 1000 °C'de borlanmış numuneler daha iyi korozyon direnci göstermiştir.

Çalışmanın sonucunda AISI H11 çeliğinin borlanmasında korozyon direnci için optimum borlama sıcaklık ve süresinin 1000 °C ve 2,2 saat olduğu sonucuna varılmıştır.

5. REFERANSLAR

1. Ma, L., Luo, Y., Wang, Y., Du, W., Song, Z., Zhang, J., 2018. Fatigue and ratcheting assessment of AISI H11 at 500°C using constitutive theory coupled with damage rule. *Fatigue Fract Eng Mater Struct*, 41(3), 642-652.
2. Tillmann, W., Grisales, D., Stangier, D., Butzke, T., 2019. Tribomechanical behaviour of TiAlN and CrAlN coatings deposited onto AISI H11 with different pre-treatments. *Coatings*, 9(8), 519.
3. Gök, M.S., Küçük, Y., Erdoğan, A., Öge, M., Kanca, E., Günen, A., 2017. Dry sliding wear behavior of borided hot-work tool steel at elevated temperatures. *Surf Coat Technol*, 328, 54-62.
4. Podgornik, B., Puš, G., Žužek, B., Leskovšek, V., Godec, M., 2018. Heat treatment optimization and properties correlation for H11-type hot-work tool steel. *Metallurgical and Materials Transactions A*, 49(2), 455-462.
5. Šebek, M., Falat, L., Kováč, F., Petryshynets, I., Horňák, P., Girman, V., 2017. The effects of laser surface hardening on microstructural characteristics and wear resistance of AISI H11 hot work tool steel. *Archives of Metallurgy and Materials*, 62(3), 1721-1726.
6. Davis, J.R., 2001. *Surface engineering for corrosion and wear resistance*, ASM International.
7. Günen, A., Kanca, Y., Karahan, İ.H., Karakaş, M.S., Gök, M.S., Kanca, E., Çürük, A., 2018. A comparative study on the effects of different thermochemical coating techniques on corrosion resistance of STKM-13A steel. *Metallurgical and Materials Transactions A*, 49(11), 5833-5847.
8. Deng, J., Wu, F., Lian, Y., Xing, Y., Li, S., 2012. Erosion wear of CrN, TiN, CrAlN, and TiAlN PVD nitride coatings. *Int J Refract Metals Hard Mater*, 35, 10-16.
9. Salem, M., Le Roux, S., Dour, G., Lamesle, P., Choquet, K., Rézaï-Aria, F., 2019. Effect of aluminizing and oxidation on the thermal fatigue damage of hot work tool steels for high pressure die casting applications. *Int J Fatigue*, 119, 126-138.
10. Peng, D.Q., Bai, X.D., Sun, H., Chen, B.S., 2007. Effect of copper ions implantation on corrosion behavior of zirconium in 1M H₂SO₄. *Int J Refract Metals Hard Mater*, 25(1), 32-38.
11. Picas, J.A., Forn, A., Baile, M.T., Martín, E., 2005. Substrate effect on the mechanical and tribological properties of arc plasma physical vapour deposition coatings. *Int J Refract Metals Hard Mater*, 23(4-6), 330-334.
12. Azadi, M., Rouhaghdam, A.S., Ahangarani, S., Mofidi, H.H., 2014. Mechanical behavior of TiN/TiC multilayer coatings fabricated by plasma assisted chemical vapor deposition on AISI H13 hot work tool steel. *Surf Coat Technol*, 245, 156-166.
13. Qiu, L., Du, Y., Wang, S., Li, K., Yin, L., Wu, L., Zhong, Z., Albir, L., 2019. Mechanical properties and oxidation resistance of chemically vapor deposited TiSiN nanocomposite coating with thermodynamically designed compositions. *Int J Refract Metals Hard Mater*, 80, 30-39.
14. Çiçek, A., Kara, F., Kivak, T., Ekici, E., 2013. Evaluation of machinability of hardened and cryo-treated AISI H13 hot work tool steel with ceramic inserts. *Int J Refract Metals Hard Mater*, 41, 461-469.
15. Altinsoy, I., Efe, F.G.C., Ipek, M., Ozbek, I., Zeytin, S., Bindal, C., 2013. An investigation on borided AISI 1020 steel. *AIP Conf Proc*, 1569(1), 43-46.
16. Arslan, D., Uzun, R.O., 2021. Microwave boriding to improve the corrosion resistance of AISI 304L austenitic stainless steel. *İğdir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(1), 490-499.
17. Gómez-Vargas, O.A., Solis-Romero, J., Figueroa-López, U., Ortiz-Domínguez, M., Oseguera-Peña, J., Neville, A., 2016. Boro-nitriding coating on pure iron by powder-pack boriding and nitriding processes. *Mater Lett*, 176, 261-264.
18. Su, Z.G., Tian, X., An, J., Lu, Y., Yang, Y.L., Sun, S.J., 2009. Investigation on boronizing of N80 tube steel. *ISIJ International*, 49(11), 1776-1783.
19. Gunes, I., Yıldız, I., 2016. Investigation of adhesion and tribological behavior of borided AISI 310 stainless steel. *Matéria (Rio de Janeiro)*, 21(1), 61-71.
20. Hernández-Sánchez, E., Velázquez, J.C., Castrejón-Flores, José. L., Chino-Ulloa, A., Avila, I.P.T., Carrera-Espinoza, R., Yescas-Hernández, J.A., Orozco-Alvarez, C., 2019. Tribological behavior of borided AISI 316L steel with reduced friction coefficient and enhanced wear resistance. *Mater Trans*, 60(1), 156-164.
21. Kara, G., Purcek, G., Yanar, H., 2017. Improvement of wear behaviour of titanium by boriding. *Industrial Lubrication and Tribology*, 69(1), 65-70.
22. Zuno-Silva, J., Ortiz-Domínguez, M., Simón-Marmolejo, I., Martínez-Martínez, L.E., Flores-Rentería, M.A., Arenas-Flores, A., Cruz-Avilés, A., 2018. The powder-pack boriding process: a microstructure comparison of boride layers formed on AISI 4150 and M2 steels. *Microscopy and Microanalysis*, 24(S1), 1064-1065.

23. Bayça, S.U., Bican, O., 2022. Increasing corrosion resistance of AISI 1010 steel by boride coatings. *Materials and Corrosion*, 73(12), 2032-2040.
24. Flores-Renteria, M.A., Ortiz-Dominguez, M., Simon-Marmolejo, I., Martinez-Martinez, L.E., Zuno-Silva, J., 2018. Microstructural characterization of nitro-boriding coating on ARMCO® pure iron. *Microscopy and Microanalysis*, 24(S1), 2240-2241.
25. Medvedovski, E., Leal Mendoza, G., Vargas, G., 2021. Influence of boronizing on steel performance under erosion-abrasion-corrosion conditions simulating downhole oil production. *Corrosion and Materials Degradation*, 2(2), 293-324.
26. Medvedovski, E., Leal Mendoza, G., Vargas, G., 2021. Influence of boronizing on steel performance under erosion-abrasion-corrosion conditions simulating downhole oil production. *Corrosion and Materials Degradation*, 2(2), 293-324.
27. Gurgenc, T., Altay, O., Ulas, M., Ozel, C., 2020. Extreme learning machine and support vector regression wear loss predictions for magnesium alloys coated using various spray coating methods. *J Appl Phys*, 127(18).
28. Pashkov, D.M., Belyak, O.A., Guda, A.A., Kolesnikov, V.I., 2022. Reverse engineering of mechanical and tribological properties of coatings: results of machine learning algorithms. *Physical Mesomechanics*, 25(4), 296-305.
29. Paturi, U.M.R., Reddy, N.S., Cheruku, S., Narala, S.K.R., Cho, K.K., Reddy, M.M., 2021. Estimation of coating thickness in electrostatic spray deposition by machine learning and response surface methodology. *Surf Coat Technol*, 422, 127559.
30. Kamnis, S., Sfikas, A.K., Gonzalez, S., 2022. Design of high entropy alloys for thermal spray processes using machine learning, *ITSC 2022*, 522-533.
31. Jokar, M., Guo, X., Frankel, G.S., 2022. Machine learning approaches to model galvanic corrosion of coated alloy systems. *Corrosion*, 78(12), 1176-1189.
32. Kolesnikov, V.I., Pashkov, D.M., Belyak, O.A., Guda, A.A., Danilchenko, S.A., Manturov, D.S., Novikov, E.S., Kudryakov, O.V., Guda, S.A., Soldatov, A.V., Kolesnikov, I.V., 2023. Design of double layer protective coatings: finite element modeling and machine learning approximations. *Acta Astronaut*, 204, 869-877.
33. Kariofillis, G.K., Kiourtsidis, G.E., Tspas, D.N., 2006. Corrosion behavior of borided AISI H13 hot work steel. *Surf Coat Technol*, 201(1-2), 19-24.
34. Kulka, M., 2019. Trends in thermochemical techniques of boriding. In *Current Trends in Boriding*, 17-98.
35. Günen, A., 2020. Properties and high temperature dry sliding wear behavior of boronized inconel 718. *Metallurgical and Materials Transactions A*, 51(2), 927-939.
36. Jiang, J., Wang, Y., Zhong, Q., Zhou, Q., Zhang, L., 2011. Preparation of Fe₂B boride coating on low-carbon steel surfaces and its evaluation of hardness and corrosion resistance. *Surf Coat Technol*, 206(2-3), 473-478.
37. Tavakoli, H., Mousavi Khoie, S.M., 2010. An electrochemical study of the corrosion resistance of boride coating obtained by thermo-reactive diffusion. *Mater Chem Phys*, 124(2-3), 1134-1138.
38. Wang, H., Zhao, Y., Yuan, X., Chen, K., Xu, R., 2013. Effects of boronizing treatment on corrosion resistance of 65Mn steel in two acid mediums. *Phys Procedia*, 50, 124-130.
39. Günen, A., 2020. Properties and corrosion resistance of borided AISI H11 tool steel. *J Eng Mater Technol*, 142(1), 011010.
40. James, G., Witten, D., Hastie, T., Tibshirani, R., 2021. *An introduction to statistical learning*. Springer US, New York, NY.
41. Müller, A.C., Guido, S., 2016. *Introduction to machine learning with python: a guide for data scientists*. O'Reilly Media.
42. Géron, A., 2019. *Hands-on machine learning with scikit-learn. Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, O'Reilly Media.
43. Breiman, L., 2001. Random forests. *Mach Learn*, 45(1), 5-32.
44. Chen, T., Guestrin, C., 2016. XGBoost: a scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ACM, New York, NY, USA, 785-794.
45. Friedman, J.H., 2001. Greedy function approximation: a gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232.
46. Demirelli, E., Solak, H.İ., Tiryakioğlu, İ., 2023. Makine öğrenmesi algoritmaları ile deprem katalogları kullanılarak deprem tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(4), 979-989.

47. Kelle, A.C., Yüce, H., 2022. MQTT trafiğinde DoS saldırılarının makine öğrenmesi ile sınıflandırılması ve modelin SHAP ile yorumlanması. *Journal of Materials and Mechatronics: A*, 3(1), 50-62.
48. Sharma, M., Ortlepp, I., Bleck, W., 2019. Boron in heat-treatable steels: a review. *Steel Res Int*, 90(11), 1900133.
49. Luitjohan, K.E., Krane, M.J.M., Ortalan, V., Johnson, D.R., 2018. Investigation of the metatectic reaction in iron-boron binary alloys. *J Alloys Compd*, 732, 498-505.
50. Lucci, A., Venturello, G., 1971. Comments on the condition of boron in α -iron. *Scripta Metallurgica*, 5(1), 17-24.
51. Hallemans, B., Wollants, P., Roos, J.R., 1994. Thermodynamic reassessment and calculation of the Fe-B phase diagram. *International Journal of Materials Research*, 85(10), 676-682.
52. Busby, P.E., Warga, M.E., Wells, C., 1953. Diffusion and solubility of boron in iron and steel. *JOM*, 5(11), 1463-1468.
53. Goldhoff, R.M., Spretnak, J.W., 1957. Distribution of boron in gamma iron grains. *JOM*, 9(10), 1278-1283.
54. Nicholson, M.E., 1954. Constitution of iron-boron alloys in the low boron range. *JOM*, 6(2), 185-190.
55. Strocchi, P.M., Melandri, B.A., Tamba, A., 1967. On the nature of boron solid solution in α -iron. *Il Nuovo Cimento B Series 10*, 51(1), 1-11.
56. Lucci, A., Della Gatta, G., Venturello, G., 1969. On the solubility of boron in high-purity alpha-iron. *Metal Science Journal*, 3(1), 14-17.
57. Başman, G., Arıkan, M.M., Arısoy, C., Şeşen, K., 2023. A kinetic study of thermochemically borided AISI 316L stainless steel. *Journal of Scientific Reports-A*, (052), 279-296.
58. Gunes, I., Kanat, S., 2015. Diffusion kinetics and characterization of borided AISI D6 steel. *Protection of Metals and Physical Chemistry of Surfaces*, 51(5), 842-846.
59. Turgut, S., Günen, A., 2020. Mechanical properties and corrosion resistance of borosintered distalloy steels. *J Mater Eng Perform*, 29(11), 6997-7010.
60. Şahin, S., 2009. Effects of boronizing process on the surface roughness and dimensions of AISI 1020, AISI 1040 and AISI 2714. *J Mater Process Technol*, 209(4), 1736-1741.
61. Li, C., Shen, B., Li, G., Yang, C., 2008. Effect of boronizing temperature and time on microstructure and abrasion wear resistance of Cr12Mn2V2 high chromium cast iron, *Surf Coat Technol*, 202(24), 5882-5886.
62. Mathew, M., Rajendrakumar, P.K., 2014. Effect of precarburation on growth kinetics and mechanical properties of borided low-carbon steel. *Materials and Manufacturing Processes*, 29(9), 1073-1084.
63. Bourithis, L., Papaefthymiou, S., Papadimitriou, G.D., 2002. Plasma transferred arc boriding of a low carbon steel: microstructure and wear properties. *Appl Surf Sci*, 200(1-4), 203-218.
64. Kaouka, A., Alaoui, O., 2019. Characterization and corrosion resistance of boride layers on carbon steel. *IOP Conf Ser Mater Sci Eng*, 477, 012029.
65. Kayalı, Y., Kul, M., Talaş, Ş., Yalçın, M.C., 2022. Investigation of corrosion and adhesion behaviors of boronized asp ® 2012 Steel. *Surface Review and Letters*, 29(12), 2250155.
66. Alkan, S., Günen, A., Gülen, M., Gök, M.S., 2024. Effect of boriding on tribocorrosion behaviour of HSLA offshore mooring chain steel. *Surf Coat Technol*, 476, 130276.
67. Campos, I., Palomar, M., Amador, A., Ganem, R., Martinez, J., 2006. Evaluation of the corrosion resistance of iron boride coatings obtained by paste boriding process. *Surf Coat Technol*, 201(6), 2438-2442.