

Inconel 718 Malzemenin Borlanması İşlem Parametrelerinin Kaplama ve Aşınma Özelliklerine Etkisinin Makine Öğrenmesi Yöntemleri Kullanılarak Araştırılması

Faruk ÇAVDAR^{1*} , Ali GÜNEN² 

Öz

Borlama, nikel esaslı süper alaşımların yüzey ve aşınma özelliklerini iyileştiren etkili bir işlemdir. Ancak, bu işlemin optimize edilmesi ve kaplama kalitesinin artırılması için detaylı bir anlayışın gerekliliği ortaya çıkmaktadır. Çalışmanın temel amacı, borlama işlem parametrelerinin optimize edilmesi ve kaplama kalitesinin artırılması için makine öğrenmesi kullanımını ortaya koymaktır. Çalışma kapsamında, kaplama kalınlığı, yüzey pürüzlülüğü, mikrosertlik gibi özellikler yanında 25, 400 ve 750 °C sıcaklık şartlarındaki ortalama sürtünme katsayısı ve aşınma hacim kaybının borlama sıcaklığı ve süresine bağlı değişimi incelenmiştir. Çalışmada öncelikle her bağımlı değişken için en uygun makine öğrenmesi algoritması belirlenmiş ve bu algoritmalar kullanılarak oluşturulan üç boyutlu yüzey grafikleri yardımıyla bağımlı değişkenlerin borlama sıcaklığı ve süresi ile değişimi görselleştirilmiştir. Grafikler üzerinde yapılan incelemeler sonucunda işlem sıcaklığı ve süresinin artmasıyla kaplama kalınlığı ve sertliğiyle birlikte yüzey pürüzlülüğünün de arttığı görülmüştür. Oda sıcaklığında ve 750 C’de yapılan aşınma deneylerinde sürtünme katsayısının en düşük değerinin (0,26) 1000-1050 °C arasında 5-6 saat aralığındaki işlem süresinde 0,26 elde edileceği saptanmıştır. Aşınma testlerinin 400 °C’de yapılması durumunda ise en düşük sürtünme katsayısının 900-1000 °C sıcaklık ve 3-5 saat işlem süresi aralığında (0,31) olacağı tespit edilmiştir. Ek olarak borlama sıcaklığının aşınma hacim kaybı üzerindeki etkisinin borlama işlem süresinden daha fazla olduğu tespit edilmiştir.

Anahtar Kelimeler: Inconel 718, Borlama, Makine öğrenmesi, Aşınma, Sürtünme katsayısı.

Investigation of Effects of Process Parameters on Coating and Wear Properties in Boriding of Inconel 718 Through Machine Learning Methods

Abstract

Boronizing is an effective process that enhances the surface and wear properties of nickel-based superalloys. However, there is a need for a detailed understanding to optimize this process and improve coating quality. The primary objective of this study is to demonstrate the use of machine learning for optimizing boronizing process parameters and enhancing coating quality. Within the scope of the study, variations in coating thickness, surface roughness, microhardness, as well as the average coefficient of friction and wear volume loss at temperatures of 25, 400, and 750 °C were investigated in relation to boronizing temperature and duration. Initially, the most suitable machine learning algorithm was determined for each dependent variable, and three-dimensional surface graphs were generated using these algorithms to visualize the variations of dependent variables with boronizing temperature and duration. Upon examination of the graphs, it was observed that an increase in process temperature and duration led to an increase in coating thickness and hardness, along with an increase in surface roughness. The lowest coefficient of friction value (0.26) in friction tests conducted at room temperature and 750°C was found to be achieved within the 1000-1050 °C range with a process duration of 5-6 hours. When friction tests were conducted at 400°C, the lowest coefficient of friction (0.31) was determined to occur within the temperature range of 900-1000 °C and a process duration of 3-5 hours. Additionally, it was found that the effect of boronizing temperature on wear volume loss is more significant than that of the boronizing process duration.

Keywords: Inconel 718, Boriding, Machine learning, wear, Coefficient of friction.

¹Osmaniye Korkutata Üniversitesi, Osmaniye Meslek Yüksekokulu, Osmaniye, Türkiye, farukcavdar@osmaniye.edu.tr

²İskenderun Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, İskenderun-Hatay-Türkiye, ali.gunen@iste.edu.tr

*Sorumlu Yazar/Corresponding Author

Geliş/Received: 27.06.2024

Kabul/Accepted: 09.11.2024

Yayın/Published: 15.12.2024

1. Giriş

Süper alaşımlar, özellikle aşındırıcı ve oksidatif ortamlar için geliştirilmiş metalik malzemelerdir; yüksek sıcaklık ve mekanik stresin zorlayıcı koşullarında etkili bir şekilde çalışacak şekilde tasarlanmışlardır. Süper alaşımların geliştirilmesi, jet motorları, gaz türbinleri ve diğer yüksek performanslı uygulamalarda karşılaşılan zorlayıcı koşullara dayanabilecek malzemelere duyulan ihtiyaçla 20. yüzyılın başlarına dayanmaktadır. Süper alaşımların ilk geliştirilmesi östenitik paslanmaz çeliklere dayanırken, sonraki ilerlemeler nikel esaslı alaşımların geliştirilmesine yol açmış, bu daha sonra kobalt esaslı ve demir esaslı alaşımları da içerecek şekilde genişletilmiştir (Donachie ve Donachie, 2002; Reed, 2008). Bu bağlamda, süper alaşımların ana bileşimlerine dayalı olarak sınıflandırılması nikel esaslı süper alaşımlar, kobalt esaslı süper alaşımlar ve demir esaslı süper alaşımlar olarak adlandırılmıştır (Çavdar ve ark., 2022).

Nikel esaslı süper alaşımlar en yaygın kullanılan ve araştırılan süper alaşım grubudur. Bunlar nikelin yanı sıra önemli miktarda krom, kobalt, alüminyum, titanyum ve molibden içerirler. Nikel esaslı süper alaşımlar, mükemmel yüksek sıcaklık dayanımı, oksidasyon direnci ve termal yorulma direncine sahiptir. Bu özellikler, bu alaşımların havacılık, enerji üretimi ve kimyasal işleme endüstrilerinde yaygın olarak kullanılmalarını sağlar (Satyanarayana ve Eswara Prasad, 2017). Öte yandan kobalt esaslı süper alaşımlar, yüksek sıcaklık dayanımı ve korozyon direncinin kritik olduğu ortamlarda uygulama bulmaktadırlar. Genellikle baz metal olarak kobalt bulundurmalarına ilaveten krom, tungsten ve bazen nikel içerirler. Bu alaşımlar, gaz türbinlerinde türbin kanatları ve yanma odaları gibi bileşenlerde yaygın olarak kullanılmaktadırlar (Giriskan ve Çam, 2023; Günen ve Ergin, 2023; Sato ve ark., 2006). Fe-Ni-Cr alaşımları olarak da bilinen demir esaslı süper alaşımlar, nikel ve kobalt esaslı süper alaşımlara göre daha az yaygın olmalarına rağmen, endüstriyel fırınlar ve ısı işlem ekipmanları gibi iyi oksidasyon direnci gerektiren özelleşmiş uygulamalarda kullanılmaktadırlar (Ganji ve Rajyalakshmi, 2020; Günen ve ark., 2022). Maliyet açısından değerlendirildiğinde, demir esaslı süper alaşımlar, bileşen elementlerinin göreceli düşük maliyetleri nedeniyle süper alaşım grupları içerisinde en ucuz olanlardır. Kobalt esaslı alaşımlar, benzer performansı sağlarken nikel esaslı alaşımlardan daha maliyet etkili olabilir. Ancak yüksek maliyetlerine rağmen, nikel esaslı süper alaşımlar, üstün performansları nedeniyle kritik uygulamalar için tercih edilmektedir (Satyanarayana ve Eswara Prasad, 2017; Selvaraj ve ark., 2021). Bu nedenle, nikel esaslı süper alaşımların kullanım alanları daha geniş olup, havacılık uygulamaları, uçak motorları, gaz türbinleri ve roket itme sistemleri gibi alanlarda sıklıkla tercih edilmektedir (Satyanarayana ve Eswara Prasad, 2017). Ayrıca, endüstriyel gaz türbinleri, nükleer reaktörler ve kimya ve petrokimya endüstrilerinde yüksek sıcaklık işleme ekipmanlarında da bu nikel esaslı alaşımların kullanımına rastlamak mümkündür. Nikel esaslı süper alaşımların birçok üstün özelliğe

sahip olmalarına rağmen, düşük yüzey sertliği, aşındırıcı ortamlardaki kullanımları konusunda endişelere yol açmıştır (Güven ve Kanca, 2017; Kayalı ve ark., 2022). Bu sorunu çözmek için, nitrüleme, alüminyumlama ve borlama gibi yüzey sertleştirme yöntemlerinden yararlanılmaktadır. Bu yöntemler bu malzemelerin ayrıca yüksek sıcaklık aşınma koşullarındaki performansları üzerinde olumlu bir etkiye sahiptir (Bölükbaşı ve ark., 2023; Döleker ve ark., 2021; Eliassen ve ark., 2010; Güven ve Kanca, 2017; Kayalı ve ark., 2022; Tuncay Turan ve ark., 2019).

Borlama, nitrüleme ve alüminyumlama, nikel esaslı süper alaşımların yüzey özelliklerini, yüzey sertliği, aşınma direnci ve yüksek sıcaklık performansı iyileştirmek için yaygın olarak kullanılan termo-kimyasal işlemlerdir. Bu işlemler, süper alaşımın yüzey katmanlarına belirli elementlerin (bor, azot ve alüminyum) difüzyonu ve yüzeydeki metalik elementlerle sert borür, nitrür veya alüminid bileşenli katmalar (kaplamalar) oluşturulmasını sağlarlar. Bu kaplamaların, sert ve stabil olmaları nikel esaslı alaşımların aşınma, korozyon ve oksidasyona karşı daha iyi direnç göstermelerine olanak sağlar. Bu katmanların kalınlığı, yüzey sertliği ve yüzey pürüzlülüğü gibi karakteristik özellikleri, nikel esaslı süper alaşımların çeşitli uygulamalardaki genel performansını ve dayanıklılığını belirlemede kritik bir rol oynar.

Borlama, yüksek sıcaklık ve sürenin etkisi ile bor atomlarının süper alaşımın yüzeyine difüze olarak borür katmanları oluşturması olarak tanımlanabilir. Borlama ile elde edilen kaplama tabakası kalınlığı, borlama ortamındaki bor içeriği, borlama sıcaklığı ve işlem süresi gibi faktörlere bağlı olarak değişir. Tipik olarak, borlama, nitrüleme ile karşılaştırıldığında daha kalın bir kaplama tabakası oluştururken alüminyumlamaya göre ise daha ince bir tabaka oluşturur. Bununla birlikte, inceliğine rağmen, borür bileşiklerinin alüminid ve nitrür bileşiklere göre daha sert olması sebebiyle aşınmaya dayanıklılığı bakımından borlama daha iyi bir performans sağlar (Güven ve Kanca, 2017; Kayalı ve ark., 2022). Borlama sonrası nikel esaslı süper alaşımların yüzey sertliği önemli ölçüde artar, bu da aşınma direncinin kritik olduğu uygulamalar için onları kullanım ömrünü iyileştirir. Ayrıca, borlanmış yüzeylerin inaktifliği, sürtünmeyi azaltma, tribolojik özellikleri iyileştirme ve oksidasyon dirençlerine katkıda bulunur.

Öte yandan, nitrüleme, süper alaşımın yüzey katmanlarına nitrojen atomlarının difüzyonunu içerir. Kullanılan nitrüleme yöntemine bağlı olarak, gaz nitrüleme veya plazma nitrüleme gibi, nitrüleme ile orta kalınlıkta veya kalın bir kaplama tabakası oluşturabilir. Gaz nitrüleme yöntemiyle genellikle plazma nitrülemeye göre daha kalın kaplamaların eldesi mümkündür. Çünkü gaz nitrüleme işlemi daha yüksek sıcaklık ve uzun sürelerde uygulanır. Nikel esaslı süper alaşımların yüzey sertliği, nitrür bileşenlerin oluşumu nedeniyle nitrüleme sonrası önemli ölçüde artar. Bu nitrürler, özellikle yorulma ve yüksek sıcaklıklarda aşınma direncine katkıda bulunur (Eliassen ve ark., 2010; Tuncay Turan ve ark., 2019). Ancak, özellikle işlem parametreleri dikkatlice kontrol edilmediğinde nitrüleme yüzey pürüzlülüğünde ciddi bir artışa neden olabilir.

Alüminyumlama, yüksek sıcaklıklarda alüminyumun süper alaşımın yüzeyine difüze ettirilerek koruyucu bir alüminit tabakası oluşturma işlemidir. Bu tabaka, oksidasyon ve korozyona karşı dayanıklılığı artırır. Alüminyumlama ile elde edilen kaplama tabakası kalınlığı, paket sementasyonu, çamur kaplama veya buhar fazı alüminyumlama gibi kullanılan alüminyumlama yöntemine bağlı olarak değişebilir. Paket sementasyonu ve çamur kaplama yöntemleri, genellikle buhar fazı alüminyumlamaya göre daha kalın kaplamalarla sonuçlanır. Alüminyumlama sırasında nikel alüminitler gibi metal arası fazların oluşumu, nikel esaslı süper alaşımların yüzey sertliğinde ve oksidasyon direncinde önemli bir artışa katkıda bulunur. Alüminyumlama yüzeyleri, mükemmel korozyon direnci ve oksidasyon direncine sahiptir bu da onları yüksek sıcaklık uygulamaları için uygun hale getirir. Ancak, boridlere göre alüminit fazların daha düşük sertliği ve daha kırılğan yapısı, yüksek sıcaklık uygulamaları için zorluklar oluşturabilir (Bölükbaşı ve ark., 2023; Döleker ve ark., 2021). Bu nedenle, borlama, diğer iki yöntemle göre nikel esaslı süper alaşımların yüksek sıcaklık uygulamaları için tercih edilen bir yöntem olarak öne çıkmaktadır ve literatürde birçok çalışmanın konusu olmuştur.

Literatürdeki çalışmalar, borlama işleminin süperalaşımların aşınma dayanımını artırdığını net bir şekilde ortaya koymaktadır (Campos-Silva ve ark. 2019; Günen,2020; Kayalı ve ark. 2022; Giriskan, ve Çam 2023; Kanca ve ark. 2023; Tang ve ark. 2024). Literatürdeki çalışmaların büyük bir kısmında aşınma direncindeki artışı borür tabakası sertlik değerlerinin yüksekliğine atfetmiştir. Campos-Silva ve ark. (2019) ise sertlik artışıyla birlikte kaplama tabakası kalınlığının artışıyla yapıda daha derin iç kısımlara kadar oluşturulan kalıntı gerilmelerinin aşınma dirençlerini daha da iyileştirdiği sonucuna varmışlardır. Diğer bir çalışmada ise Wu ve ark. (2025) borlanmış Inconel 718'in aşınma direncindeki iyileşmenin daha çok oluşan borür faz yapısı ile ilişkili olduğu sonucuna varmışlardır. Rai ve ark. (2021) ise yüksek yüzey pürüzlülüğünün borlanmış malzemenin genel performansı üzerinde olumsuz etkilere yol açabileceğini belirtmişlerdir. Literatürdeki çalışmalar, borlanmış süper alaşımların aşınma direncindeki artışın, borlama parametrelerine bağlı olarak değiştiğini göstermektedir. Bu parametreler, borlama yöntemi, borlama sıcaklığı, borlama süresi ve kullanılan bor tozlarının içeriğini içerir. Aşınma direnci, bu faktörlerin sinerjik etkisiyle oluşan borür tabakasının kaplama kalınlığı, faz yapısı, sertlik değerleri ve yüzey pürüzlülüğüne bağlı olarak farklılık göstermektedir. Literatürdeki çalışmaların deneysel sonuçlara dayalıdır ve genellikle borlama parametrelerinin biri veya ikisi üzerine odaklanmışlardır. Bu nedenle aşınma direncini etkileyen parametrelerin tamamının tek bir yayında incelemesini yapan bir çalışmaya rastlanmamıştır. Borlanmış süper alaşımların aşınma direnci büyük oranda, kaplama tabakasının kalınlığı, sertliği, yüzey pürüzlülüğü ve kırılma tokluğu gibi özelliklerin bir kombinasyonundan etkilenmektedir. Bu çalışma, bu bağlamda literatürdeki bir boşluğu doldurarak, kaplama sıcaklığı ve işlem süresi parametrelerinin Inconel 718'in yüzey yüzeyinde oluşan borür kaplama katmanlarının, sürtünme ve aşınma direnci üzerindeki etkilerini

makine öğrenimi yöntemleri kullanarak modellemeyi amaçlamaktadır; böylece literatürde eksik olan borlama sonucu birçok parametrenin etkisinin aynı anda modellenerek sinerjik etkilerinin belirlenmesi çalışılmıştır.

Bu bağlamda Inconel 718'in borlanması ile ilgili bir çalışmada elde edilen veriler kullanılarak elde edilen kaplamanın kalınlığı (T_h), mikrosertliği (H), Ra ve Rz pürüzlülük değerleri, 25 °C, 400 °C ve 750 °C'deki ortalama sürtünme katsayısı (COF25, COF400 ve COF750) ile aşınma hacim kaybı (V25, V400 ve V750) bağımlı değişkenleri için değişik makine öğrenmesi algoritmaları kullanılarak modeller geliştirilmiştir. Geliştirilen makine öğrenmesi modelleri değerlendirilerek en uygun makine öğrenmesi modeli kullanılarak bağımlı değişkenlerin işlem süresi ve sıcaklığına bağlı değişimleri 3 boyutlu yüzey grafiği oluşturularak incelenmiştir.

2. Materyal ve Metot

2.1. Veri Seti

Bu çalışmada kullanılan veri seti daha önce yayınlanmış olan Inconel 718 nikel esaslı süper alaşımın borlanması sıcaklık ve işlem süresi parametrelerinin yüksek sıcaklık aşınma dayanımına etkisi ile ilgili çalışmasındaki deney sonuçlarından oluşturulmuştur (Günen, 2020). Kullanılan altlık malzemesinin temin edildiği Birçelik A.Ş (Türkiye) tarafından raporlanan kimyasal bileşimi Tablo 1'de verilmiştir. Numunelerin yüzeyinde oluşturulan bor kaplama tabakası için bor kaynağı olarak %90 nano boyutlu B₄C ve aktivatör olarak ağırlıkça %10 KBF₄ tozundan oluşan borlama toz karışımı kullanılmıştır.

Tablo 1. Çalışmada kullanılan Inconel 718'in kimyasal bileşimi (%ağ.) (Günen, 2020)

Ni	Cr	Fe	Nb	Mo	Ti	Al	Diğer elementler
54.5	20.1	12.5	5.5	2.8	1.05	0.5	Kalan

Kaplama işlemleri için Ni esaslı Inconel 718 numuneleri nano boyutlu B₄C borlama tozları kullanılarak 850, 950 ve 1050 °C'de 2, 4 ve 6 saat süreyle paket borlama tekniği ile borlanmıştır. İşlem sıcaklığı ve süresinin Tablo 2'de belirtilen değerlerine bağlı olarak elde edilen borür katmanlarının kaplama tabakası kalınlığı, mikrosertlik değerleri ve Ra ve Rz yüzey pürüzlülük değerleri sırasıyla optik mikroskop, mikrosertlik cihazı ve 2D yüzey profilometresi ile tespit edilmiştir. Sonrasında, borlanmış nikel esaslı Inconel 718 numunelerin sürtünme ve aşınma dirençlerinin belirlenmesi için ball-on disk aşınma cihazında (TURK-YUS-TÜRKİYE) 6 mm çapındaki WC karbür bilya kullanılarak, 5N yük, 0,6 m/s kayma hızı, 1800 m kayma mesafesinde,

oda sıcaklığı, 400 °C ve 750 °C’de aşınma testleri gerçekleştirilmiştir. Her test üç kez tekrarlanmış ve sürtünme katsayısı (COF25, COF400, COF750) ve aşınma hacim kayıpları (V25, V400, V750) değerlerinin her biri, üç ölçümün ortalaması olarak rapor edilmiştir. Her numune için uygulanan aşınma testleri sonucu elde edilen sürtünme ve aşınma hacim kayıpları değerleri ölçüm sonuçları Tablo 3’de verilmiştir.

Çalışma kapsamında borlama sıcaklığı ve borlama süresi bağımsız değişkenlerinin kombinasyonlarından ve kaplama kalınlığı, mikro-sertlik, yüzey pürüzlülüğü, sürtünme katsayısı ve aşınma hacim kayıpları bağımlı değişkenlerinin ölçülen değerlerinden oluşan 9 satırlık veri seti elde edilmiştir. Veri seti çok küçük olduğu için verilerin tümü eğitim seti olarak kullanılmıştır.

Tablo 2. Bağımsız işleme parametreleri ve bunlarla elde edilen kaplamanın kalınlık, mikrosertlik, Ra ve Rz ölçüm değerleri (Güven, 2020).

Numune No	Borlama sıcaklığı (°C)	Süre (h)	Kaplama tabakası kalınlığı (µm)	Mikrosertlik (HV _{0.1})	Ortamala Yüzey pürüzlülüğü Ra (µm)	Yüzey pürüzlülüğü Rz (µm)
S1	850	2	20.7±0,2	2330,4±112	0,45	1,25
S2	850	4	21.6±0.2	2342,5±105	0,59	1,57
S3	850	6	26.5±0.3	2354,6±72	0,74	2,03
S4	950	2	36.2±0,4	2378,5±75	0,65	1,98
S5	950	4	69.2±0.9	2392,1±58	0,85	2,47
S6	950	6	72.1±2.0	2395,8±50	1,01	3,02
S7	1050	2	53.1±1.2	2405,6±63	0,89	2,58
S8	1050	4	105.6±2.1	2481,7±61	1,02	3,18
S9	1050	6	130.1±2.8	2587,9±79	1,07	3,21

Tablo 3. Her bir deney seti için ölçülen ortalama sürtünme katsayısı ve aşınma hacmi kayıpları (Güven,2020).

Numune No	Ortalama COF			Aşınma hacim kaybı (µm ³)		
	25 °C	400 °C	750 °C	25 °C	400 °C	750 °C
S1	0,399±0,09	0,631±0,09	0,716±0,09	728±6,54	819±8,55	950±9,85
S2	0,439±0,08	0,321±0,08	0,593±0,13	700±7,82	649±7,32	740±6,55
S3	0,326±0,08	0,437±0,08	0,512±0,11	582±4,54	600±7,05	530±7,04
S4	0,323±0,09	0,373±0,09	0,443±0,12	465±4,58	549±6,10	600±6,46
S5	0,375±0,09	0,302±0,07	0,532±0,10	412±4,24	530±5,08	575±6,88
S6	0,280±0,09	0,446±0,14	0,515±0,14	373±3,54	415±4,08	550±5,55
S7	0,302±0,08	0,308±0,09	0,515±0,09	334±3,82	300±3,92	500±4,78
S8	0,328±0,07	0,401±0,15	0,413±0,12	250±5,20	286±3,91	533±6,02
S9	0,258±0,08	0,398±0,15	0,400±0,07	228±2,32	276±2,96	498±4,87

Veri setindeki borlama sıcaklığı ve borlama süresi değerlerinin büyüklük farkı oldukça fazladır. Bu 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 StandardScaler metodu 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 Modellemeleri

Bu çalışmada veri işleme ve analiz için Pandas, matematiksel işlemler için Numpy, makine öğrenmesi modellerinin uygulanmasında ScikitLearn kütüphaneleri kullanılmıştır. Tablo 2'de listelenen deney parametreleri kullanılarak kaplama kalınlığı, mikrosertlik, Ra ve Rz yüzey pürüzlülüğü değerleri ile 25 °C, 400 °C ve 750 °C'de yapılan aşınma testlerinden elde edilen ortalama sürtünme katsayısı ve aşınma hacmi bağımlı değişkenlerinin her biri için aşağıda belirtilen makine öğrenmesi algoritmaları uygulanmıştır.

2.2.1 Çoklu doğrusal regresyon

Çoklu doğrusal regresyon (MLR), birden fazla bağımsız değişkenin, bu değişkenlere bağlı olarak değişen çıktılarla doğrusal bir ilişkiye sahip olduğunu varsayan bir istatistiksel yaklaşımdır. Çoklu lineer regresyon modeli, bu ilişkiyi en iyi şekilde yansıtmak için veri setinden regresyon katsayılarını tahmin eder (James ve ark., 2021).

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 Polinom regresyon

Polinom regresyon (PL), bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi ifade etmek için bir polinom kullanır. Bu regresyon yöntemi, veri setinin doğrusal olmayan ilişkilerini modellemek için kullanılır ve genellikle basit doğrusal regresyonun yetersiz kaldığı durumlarda tercih edilir. Birden fazla bağımsız değişken olduğunda, çok değişkenli polinom regresyonu için genel bir formül kullanılır. Bu formül, her bir bağımsız değişkenin farklı

derecelerdeki polinom terimlerini içerebilir. Örneğin, iki bağımsız değişken x_1 ve x_2 için bir ikinci dereceden çok değişkenli polinom regresyonu şu şekilde ifade edilebilir:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1^2 + \beta_4 x_2^2 + \beta_5 x_1 x_2 + \epsilon \quad (3)$$

Burada, y bağımlı değişkeni, x_1 ve x_2 bağımsız değişkenleri, $\beta_0, \beta_1, \dots, \beta_5$ regresyon katsayılarını ve ϵ hata terimini temsil eder. Bu formülde, x_1^2 ve x_2^2 gibi çapraz terimler ve $x_1 x_2$ gibi etkileşim terimleri de bulunur. Çok değişkenli polinom regresyonunda, dereceler ve etkileşim terimleri modelin karmaşıklığını artırır ve veri setine daha iyi uymasını sağlar. Ancak, bu da modelin daha fazla parametreye ve dolayısıyla daha fazla aşırı uyuma eğilimli olmasına neden olabilir.

Polinom regresyonu, karmaşık ilişkileri modellemek için esnek bir yaklaşım sağlar ve birçok bilimsel ve mühendislik alanında yaygın olarak kullanılmaktadır.

2.2.3. k en yakın komşu regresyonu (kNN)

Bu regresyon modeli, yeni bir veri noktasının tahminini yaparken, çevresindeki k en yakın veri noktasının değerlerinin bir türü olan ortalama veya medyan gibi bir istatistiksel ölçü kullanır. Bu yöntem, benzer örneklerin veri setindeki yapısal özelliklerini dikkate alarak tahmin yapar.

Tahmin yapılırken, öncelikle veri noktasının etrafındaki en yakın k sayıda veri noktası belirlenir. Bu komşuların bağımlı değişken değerleri kullanılarak bir tahmin yapılır. Tahmin, bu komşuların değerlerinin bir özetine dayanır ve genellikle ortalama veya medyan gibi istatistiksel bir değerdir.

Modelin k değeri, kullanıcı tarafından belirlenir ve tahminin hassasiyetini etkiler. Daha küçük k değerleri modelin karmaşıklığını artırırken, daha büyük k değerleri daha pürüzsüz bir tahmin yapılmasına olanak tanır. Bu, tahminin daha az aşırı uç değerlere ve gürültülü verilere duyarlı olmasını sağlar (Müller ve Guido, 2016).

2.2.4. Destek vektör makinesi regresyonu

Destek vektör makinesi regresyonu (SVR), veri noktalarını bir hiperdüzlem etrafında bir regresyon çizgisi ile uyumlu hale getirmeye çalışır. Bu çizgi, veri noktalarına olan uzaklıkların toplamını minimize ederken, bir tolerans parametresi (ϵ) kullanılarak belirli bir hata payına izin verir.

Destek vektör makineleri (SVM), 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 sağlanır.

SVM, hiperdüzlemi çevreleyen destek vektörler arasındaki mesafenin maksimize edilmesini hedefler. Bu, maksimum margin prensibi olarak adlandırılır ve modelin genelleme yeteneğini artırırken aşırı uyum riskini azaltır (Géron, 2019).

2.2.5. Karar ağacı regresyonu (DT)

Karar ağacı regresyonu (DT), esasen, veri setini belirli koşullar altında bölen ve bu bölmelerdeki ortalamaları veya medyanları kullanarak bağımlı değişkeni tahmin eden bir ağaç yapısı kurar. Her bir yaprak düğümü, bir regresyon değerini içerir (Géron, 2019).

Karar ağacı regresyonu, veri setini belirli koşullar altında böler ve homojen alt gruplara ayırır. Bu bölünmeler, her bir düğümde belirli bir özellik (değişken) ve bir eşik (threshold) kullanılarak gerçekleştirilir. Veri noktaları, ağacın dallarında ilerlerken belirli koşullar altında çeşitli düğümlere yönlendirilir. Her bir düğüm, belirli bir alt kümeyle ilişkilidir. Ağacın yaprak düğümlerine ulaşıldığında, bu düğümlerdeki alt kümelerin bağımlı değişken değerlerinin ortalaması veya medyanı, o düğümün regresyon tahmin değerini belirler (Müller ve Guido, 2016).

2.2.6. Rastgele orman regresyonu

Rastgele orman regresyonu (RF), ağaçlardan meydana gelen bir toplu modeldir. Her bir ağaç, veri setinin rastgele alt kümeleri üzerinde eğitilir ve bu ağaçların tahminleri birleştirilerek genel bir tahmin elde edilir (Breiman, 2001; Müller ve Guido, 2016).

Rastgele orman regresyonu, veri setinin rastgele alt kümeleri üzerinde birden fazla karar ağacı eğitir. Bu alt kümeler, veri setinden rastgele örnekleme yaparak oluşturulur. Her bir alt küme üzerinde ağaçlar eğitilir. Ağaçlar, belirli özelliklere ve hedef değişkenine göre bölünerek eğitilir. Bu bölünmeler, ağaçların belirli koşullar altında veriyi ayırmasını sağlar. Tüm ağaçlar eğitildikten sonra, her biri bağımsız olarak tahminlerde bulunur. Rastgele orman, bu tahminleri birleştirerek genel bir regresyon tahmini oluşturur. Bu birleştirme genellikle ağaçların tahminlerinin ortalaması alınarak gerçekleştirilir (Breiman, 2001; Géron, 2019).

2.2.7. Ekstrem eğim artırma

Ekstrem eğim artırma (XGBoost), son yıllarda makine öğrenimi alanında popülerlik kazanan bir yöntemdir. Bu yöntem, gradient boosting framework'ünü kullanarak karar ağaçları oluşturur ve

bu ağaçların tahminlerini bir araya getirerek güçlü bir tahmin modeli oluşturur. XGBoost'un başarısının arkasındaki anahtar özelliklerden biri, ağaçların oluşturulması sırasında kullanılan özel bir hata fonksiyonu ve ağaçların karmaşıklığını kontrol etmek için düzenleme terimlerinin eklenmesidir (Chen ve Guestrin, 2016; Wade ve Glynn, 2020).

XGBoost, birçok makine öğrenimi yarışmasında ve endüstriyel uygulamada etkileyici sonuçlar elde etmiştir. Bu yöntem, hızlı eğitim süreleri ve yüksek tahmin doğruluğu ile bilinir. Ayrıca, büyük veri setlerinde ve yüksek boyutlu özellik uzaylarında etkili bir şekilde çalışabilir. XGBoost'un esnek parametre ayarları, modelin belirli veri setlerine uyum sağlamasını ve overfitting riskini azaltmasını sağlar. Bu nedenle, XGBoost, çeşitli endüstriyel ve akademik alanlarda yaygın bir şekilde kullanılan bir regresyon yöntemidir (Wade ve Glynn, 2020).

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 (R²), Ortalama Kare Hatası (MSE), mutlak hata ortalaması (MAE) ile belirlenecek ve birbirleri ile kıyaslanacaktır.

Belirleme katsayısı (R²), tahmin edilen değerlerin gerçek değerlere olan uyumunu ölçer. 1'e yaklaşan bir R² değeri, modelin veri setindeki değişkenliğin büyük bir kısmını açıkladığını, 0'a yaklaşan bir değer ise açıklamanın daha düşük olduğunu gösterir. R², eşitlik 4 ile hesaplanır:

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (4)$$

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.

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

Ortalama Kare Hatası (MSE) ise tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını ifade eder ve denklem 6 ile hesaplanır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

Denklem 5 ve 6'da 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 Tartışma

Nikel esaslı Inconel 718 alaşımı üzerinde oluşturulan borür kaplamaların SEM görünümüleri Şekil 1'de gösterilmiştir.

Ni esaslı Inconel 718 süperalaşımı üzerinde tüm işlem sıcaklıklarında borür kaplama tabakalarının elde edildiği Şekil 1'de görülmektedir. Şekilde, 850 °C'de 2 ve 4 saat süre ile edilen borür kaplama kalınlıklarının 20 μm 'nin altında olduğu, diğer işlem parametrelerinde bunun belirgin şekilde arttığı, özellikle 1050 °C'de 6 saat işlem gören numunede neredeyse 150 μm 'ye ulaştığı görülmektedir.

Borlama sıcaklığı ve süresi artışı ile kaplama kalınlıklarında artış gözlemlenmiştir. Ancak, borlama sıcaklığının borlama süresine göre kaplama tabakası kalınlıklarında daha etkili bir parametre olduğu anlaşılmaktadır. Şöyle ki 850 °C'de 6 saat süre ile 26 μm kaplama kalınlığı elde edilmişken 950 °C'de 2 saat süre ile borlanan numunede ise 36 μm kaplama kalınlığı elde edilmiştir.

Elde edilen kaplama tabakaları morfoloji bakımından incelendiğinde ise borlama sıcaklığı ve süresindeki artış ile daha yoğun ve homojen kaplamaların elde edildiği görülmektedir. Bu durum aktivasyon enerjisi yüksek olan CrB fazının NiB fazı içerisindeki oluşumu için belirli bir süre ve sıcaklık gerektiğini göstermektedir. İşlem sıcaklığının 1050 °C olduğu kaplama tabakaları içerisindeki dikey siyah çizgilerin CrB fazı olduğu daha önceki çalışmamızda EDS analizleri ile belirlenmiştir (Güven, 2020). Ancak, 1050 °C'de 6 saatlik süre sonunda kaplamaların yüzeyinde porozite oluşumlarının başlamadığı görülmüştür. Bu durumun kaplama ortamında bor'un konsantrasyonunun azalmasına bağlı olarak kaplamaların yüzeyine O₂ difüzyonu sonucu meydana geldiği düşünülmektedir. Daha önceki çalışmamızda mekanik özellikleri ve yüksek sıcaklık aşınma davranışlarını incelediğimiz çalışmamızda faz yapısının Ni₄B₃, Cr₂B₃, Cr₂B, Fe₂B ve FeB'den oluştuğu tespit edilmiştir (Güven, 2020). Çalışmada oluşan faz yapısının literatürde silisid içermeyen borür tozlarının kullanıldığı çalışmalarda oluşan faz yapısı ile uyumlu olduğu tespit edilmiştir (Campos-Silva ve ark 2019; Kayalı ve ark. 2022; Tang ve ark. 2024). Silisid fazı içermesi kaplamaların sertliği ve aşınma direnci bakımından önemlidir. Çünkü Deng ve ark. (2015) Nikel esaslı Inconel 718 alaşımının en üst kısmında oluşan silisid tabakasının 500 K sertlik değerinde olduğu ve kırılğan olması sebebiyle aşınma dirençlerinin olumsuz etkileyebileceğinden aşınma dirençleri öncesi kaldırılması gerektiğini bildirmişlerdir.



Şekil 1. Inconel 718 üzerinde a) 850 °C’de 2 saat, b) 850 °C’de 4 saat, c) 850 °C’de 6 saat, d) 950 °C’de 2 saat, e) 950 °C’de 4 saat, f) 950 °C’de 6 saat, g) 1050 °C’de 2 saat, h) 1050 °C’de 4 saat ve i) 1050 °C’de 6 saat ile oluşturulmuş borit kaplamanın kesitinden alınan SEM görüntüleri.

3.1. Makine öğrenmesi modelleme sonuçları

Tablo 1’de verilen işlem sıcaklığı ve süresi parametreleri ile elde edilen bağımlı değişken değerleri kullanılarak makine öğrenmesi modelleri eğitilmiştir. Elde edilen modellerin gerçeği

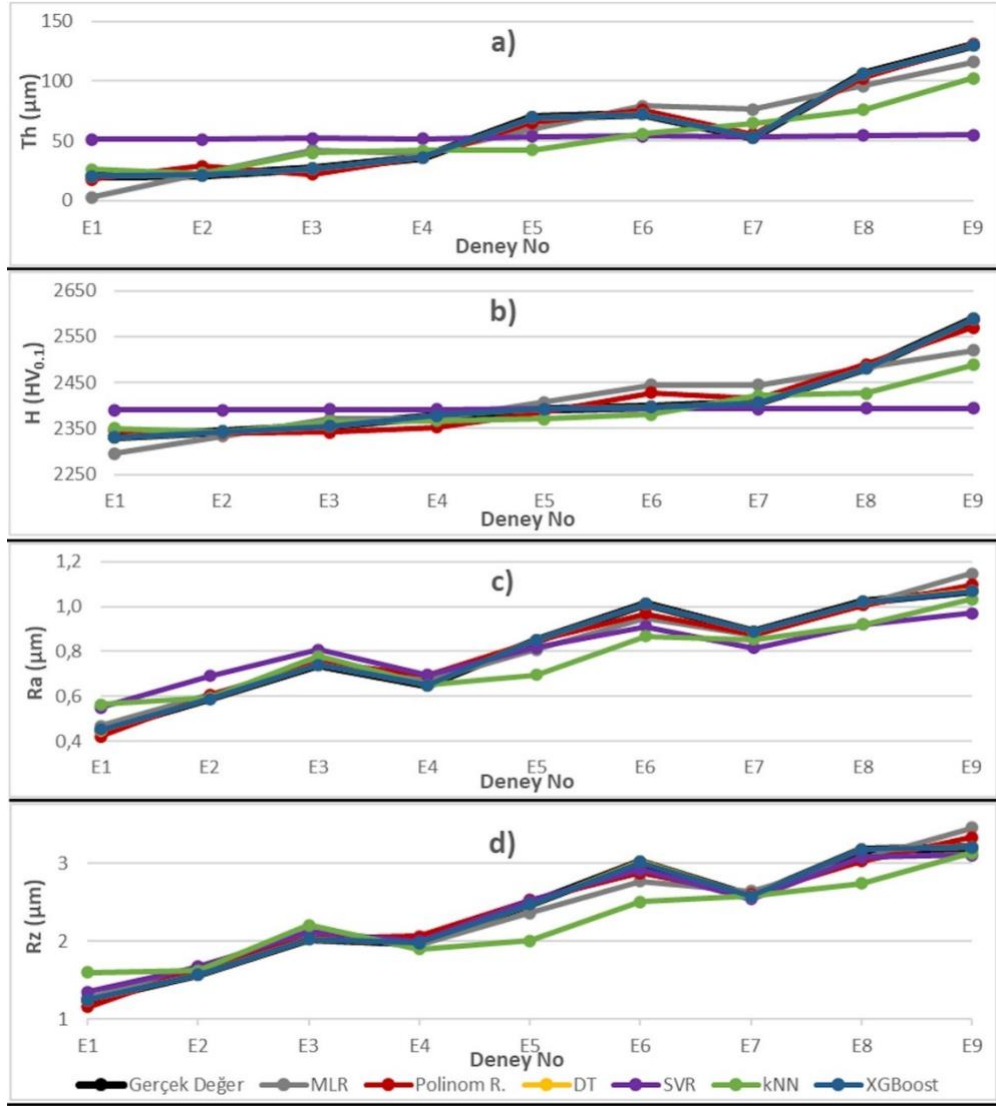
yansıtma kabiliyetinin ortaya konabilmesi için her bir ML modelinin R^2 , MAE ve MSE ölçütleri hesaplanarak Tablo 4’de listelenmiştir. Buna ek olarak yüzey özellikleri ve aşınma karakteristikleri ile ilgili gerçek değerler ve tahmin değerleri sırası ile Şekil 2 ve Şekil 3’te görsel olarak karşılaştırılmıştır.

Tablo 4. Geliştirilen makine öğrenmesi modellerinin performans değerleri.

Bağımlı Değişken	Algoritma	R^2	MAE	MSE	Bağımlı Değişken	Algoritma	R^2	MAE	MSE
Kaplama Kalınlığı	DT	1	0	0	Cof250	DT	1	0	0
	MLR	0,870	11,358	173,573		MLR	0,164	0,071	0,008
	PR	0,989	3,264	14,646		PR	0,656	0,049	0,003
	SVR	0,038	29,007	1279,830		SVR	0,384	0,066	0,006
	XGBoost	1,000	0,001	0,000		XGBoost	0,999	0,002	0,000
	kNN	0,749	15,359	334,236		kNN	0,123	0,072	0,008
Mikrosertlik	DT	1	0	0	Cof450	DT	1	0	0
	MLR	0,799	26,779	1164,708		MLR	0,670	0,041	0,003
	PR	0,950	14,464	289,682		PR	0,718	0,043	0,002
	SVR	-,011	50,402	5868,077		SVR	0,451	0,052	0,005
	XGBoost	1,000	0,001	0,000		XGBoost	1,000	0,001	0,000
	kNN	0,722	27,589	1611,256		kNN	0,422	0,054	0,005
Ra	DT	1	0	0	V25	DT	1	0	0
	MLR	0,964	0,031	0,001		MLR	0,968	27,309	952,099
	PR	0,984	0,022	0,001		PR	0,991	14,469	266,420
	SVR	0,828	0,080	0,007		SVR	-,039	142,069	30889,32
	XGBoost	1,000	0,001	0,000		XGBoost	1,000	0,001	0,000
	kNN	0,807	0,070	0,008		kNN	0,828	64,111	5105,691
Rz	DT	1	0	0	V400	DT	1	0	0
	MLR	0,957	0,111	0,019		MLR	0,951	33,407	1524,895
	PR	0,978	0,087	0,010		PR	0,986	16,747	442,688
	SVR	0,984	0,079	0,007		SVR	-,032	147,624	32098,31
	XGBoost	1,000	0,001	0,000		XGBoost	1,000	0,002	0,000
	kNN	0,791	0,238	0,093		kNN	0,784	75,111	6700,889
Cof25	DT	1	0	0	V750	DT	1	0	0
	MLR	0,633	0,029	0,001		MLR	0,667	68,321	6458,377
	PR	0,985	0,006	0,000		PR	0,948	27,210	1017,123
	SVR	-0,047	0,049	0,003		SVR	-0,158	88,261	22443,52
	XGBoost	1,000	0,001	0,000		XGBoost	1,000	0,001	0,000
	kNN	0,682	0,026	0,001		kNN	0,660	57,000	6587,519

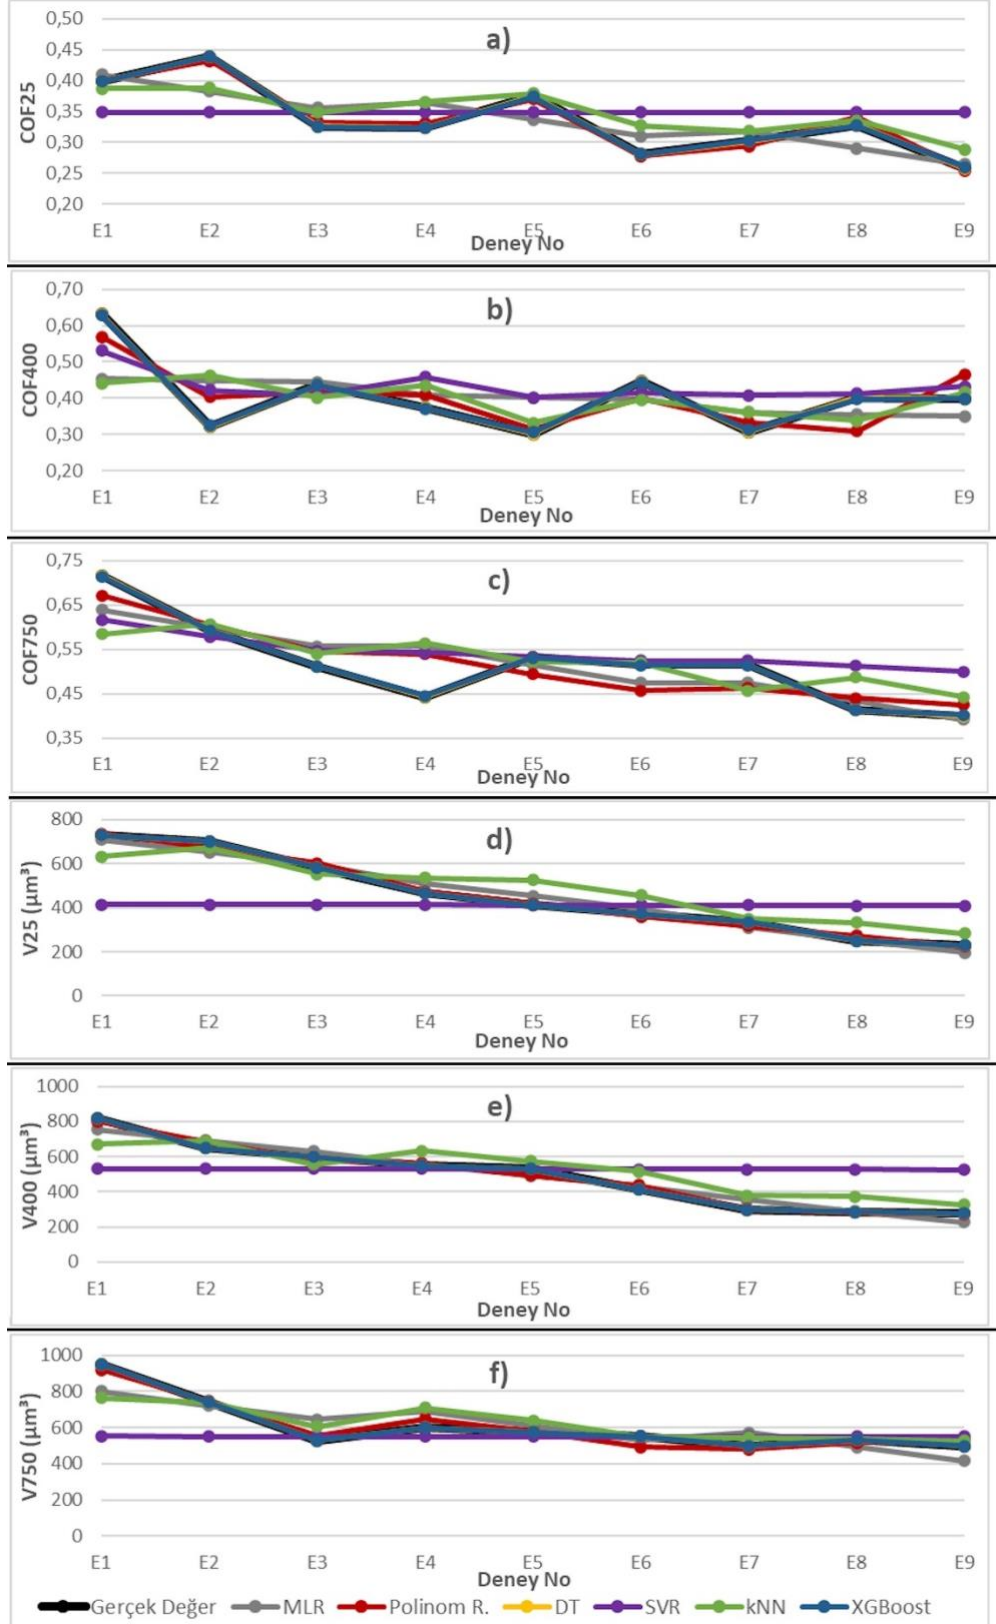
Kaplama kalınlığı için eğitilen regresyon modellerin arasında DT ve XGBoost algoritması R^2 değerlerinin 1 olduğu ve MAE ve MSE’nin ya 0 ya da 0’a çok yakın değer aldığı Tablo 4’te görülmektedir. Polinom regresyon modeli R^2 , MAE ve MSE değerleri ise sırası ile 0.989, 3.264 ve 14,646’dır. Öte yandan Şekil 2 a’da DT ve XGBoost algoritması tahminlerin gerçek değerlerle birebir örtüştüğü PR tahminlerinin ise grafiğin her noktasında çok yakın olduğu görülmektedir. Bu

sebeplerden DT ve XGBoost algoritmasının diğerlerine göre karmaşık yapıda olduğu ve aşırı öğrenme ihtimalinin yüksek olduğu değerlendirilmiştir. Polinom regresyon performans göstergelerinin de oldukça tatmin edici olduğu göz önünde bulundurularak kaplama kalınlığı ile ilgili analizlerde bu modelin sonuçlarının kullanılmasına karar verilmiştir.



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

Benzer bir durum mikrosertlik için geliştirilen modeller için de geçerlidir. DT ve XGBoost algoritmalarının R^2 deęerleri 1 iken polinom regresyon modelinin R^2 deęeri 0,950 MAE ve MSE deęerleri 14,464 ve 289,682'dir. En düşük ve en yüksek mikrosertlik deęerlerinin 2330 ve 2588 olduğu dikkate alındığında bu başarı metriklerinin tatmin edici olduğu düşünölmektedir. Mikrosertlik modelleri için oluşturulan gerçek deęer tahmin karşılaştırması grafięi (Şekil 2b) de kaplama kalınlığınıninkine benzer bir durum göstermektedir. Diğer modeller ile ilgili başarı metriklerinin yetersiz olduğu Tablo 4'te görölmektedir.



Şekil 3. a) 25 °C'deki COF, b) 400 °C'deki COF, c) 755 °C'deki COF, d) 25 °C'deki V, e) 400 °C'deki V ve f) 750 °C'deki V için oluşturulan deęişik makine öğrenmesi modeli tahminleri ve bunlara karşılık ölçülen deęerler


Ra ve Rz değişkenlerinin borlama sıcaklığı ve borlama işlem süresinden nasıl etkilendiğinin bir arada değerlendirilebilmesi için aynı tür regresyon modelinin seçilmesi değerlendirilmiştir. Tablo 4'ten Ra ve Rz'ye ait DT, MLR, polinom regresyon ve XGBoost algoritmalarının R^2 değerlerinin 0,95'ten büyük olduğu, MAE ve MSE değerlerinin ise ölçülen Ra ve Rz değerlerine göre yeterince küçük olduğu anlaşılmaktadır. Ayrıca Şekil 2c ve d'deki grafiklerin genelinde DT, MLR polinom regresyon ve XGBoost regresyon tahminlerinin gerçek değerlerle çok yakın bulunduğu görülmektedir. Modeller arasında en basit olanın ve aşırı öğrenme ihtimali en düşük seçeneğin MLR olması nedeniyle sonraki çalışmalara bu regresyon model sonuçları ile devam edilmesine karar verilmiştir.

Aşınmayla ilgili model sonuçlarının değerlendirilmesinde de aşınma sıcaklığının etkisinin de anlaşılması için COF ve V çalışmaları için de kendi aralarında aynı tür algoritmaların kullanılması düşünülmüştür.

Tablo 4 incelendiğinde COF25, COF250 ve COF400 modelleri R^2 değerleri içinde 0,95 üzerinde olanların DT ve XGBoost olduğu görülmektedir. Bu modellerin MAE ve MSE değerleri de oldukça düşüktür. Ayrıca Şekil 3a, 3b ve 3c incelendiğinde DT ve tahminlerinin gerçek değerlerle çakıştığı görülmektedir. Ölçeklenebilirlik özelliğinden dolayı bunlar arasında XGBoost algoritmasının kullanılmasına karar verilmiştir. V25, V400 ve V250 performans metrikleri bir arada incelendiğinde DT, Polinom regresyon ve XGBoost modellerinin R^2 değerlerinin 1'e yakın olduğu görülmektedir. V25 ve V400 için geliştirilen ML regresyon R^2 değerleri 0,95'in üzerinde olmasına rağmen bu değer V750 için 0,667'dir. Bu faktörler göz önünde bulundurularak aşınma hacmiyle ilgili analizlere polinom regresyon algoritmasıyla devam etmeye karar verilmiştir.


4. Tartışmalar

Şekil 4'te polinom regresyon algoritmasıyla geliştirilen makine öğrenmesi modeline göre kaplama kalınlığının borlama sıcaklığı ve borlama süresine bağlı değişimi görülmektedir. Kaplama kalınlığı, 850 °C işlem sıcaklığında 2 saat işlem süresi için 17,94 μm 'den başlayarak tepe noktası 4,5 saat işlem süresinde olacak ve 6 saat işlem süresinde için 2191 μm değerlerine düşecek şekilde ters parabolik olarak değişmektedir. Grafikte borlama sıcaklığı arttıkça borlama süresinin kaplama kalınlığı üzerinde etkisinin arttığı görülmektedir. Bu durum difüzyon için gerekli olan sıcaklık ve sürenin sinerjik etkisinden kaynaklanmaktadır. Sıcaklık 1050 °C'ye ulaştığında kaplama kalınlığı 2 saat süre için 55,56 μm 'den 6 saat için 130,84 μm 'e ters parabolik olarak artmaktadır. Deney ölçümlerinde ise bu değerler sırasıyla 53,1 μm ve 130,1 μm 'dir. Dolayısıyla sıcaklığın bütün sabit süreler için kaplama kalınlığı üzerinde doğrusala yakın bir olumlu etkisi olduğu grafiği deneysel veriler ile de doğrulanmıştır.



Şekil 4. Polinom regresyon modeline göre kaplama kalınlığının işlem süresi ve sıcaklığına bağlı değişimi.

Şekil 5'te polinom regresyon modeline göre mikrosertliğin borlama sıcaklığı ve süresine bağlı değişimi görülmektedir. Borlama süresinin 2 saat iken mikrosertlik 850 ile 1050 C arasında 2345 HV'den 2416 HV'ye parabolik olarak yükselmektedir. Öte yandan borlama süresinin artmasıyla sertliğin artış hızı da yükselmekte ve 6 saat işlem süresinde sıcaklığın 850 °C'den 1050 °C'ye çıkmasıyla mikro-sertlik değeri 2341 HV'den 2570 HV'e parabolik olarak yükselmektedir. Diğer yandan 850 °C sıcaklıkta sertlik değerinin işlem süresi ile neredeyse değişmediği 2340 HV ile 2345 HV arasında değer aldığı görülmektedir.

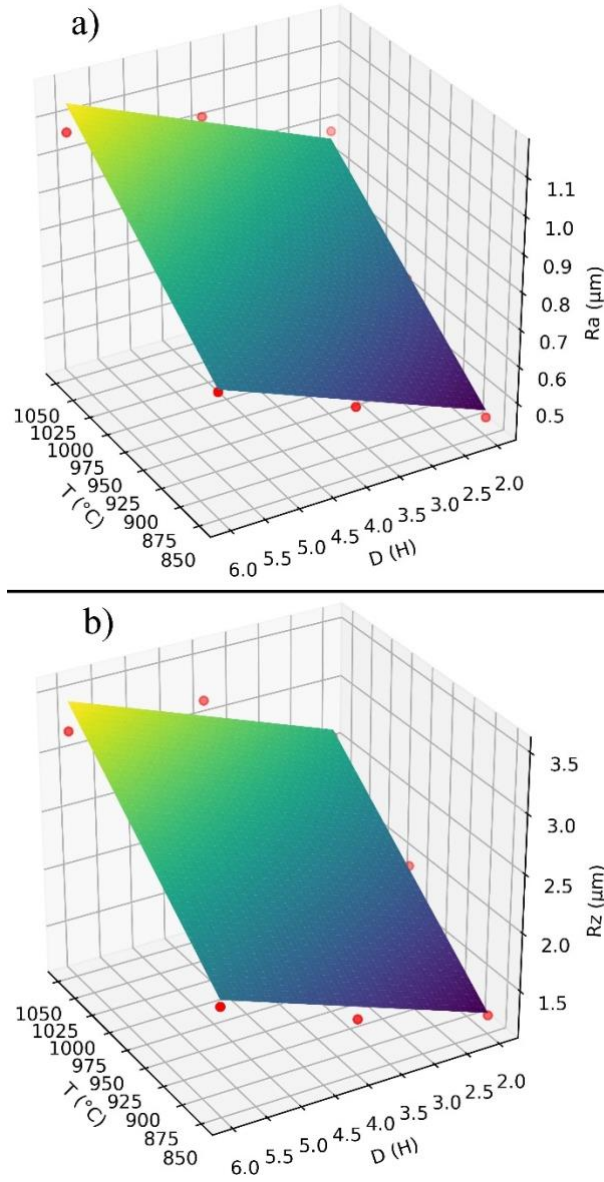


Şekil 5. Polinom regresyon modeline göre mikrosertliğin işlem sıcaklığı ve süresine bağlı değişimi.

Grafik (Şekil 5) genelinde sıcaklık değeri yükseldikçe işlem süresi sertlik üzerinde daha etkili hale gelmektedir. İşlem süresi ve sıcaklığının artmasıyla borür tabakası içerisindeki bor'un atomsal boşlukları doldurarak daha yoğun ve üniform bir kaplama tabakası oluşturmakta bu da sertlik artışı sağlamaktadır. Daha düşük sıcaklık ve işlem sürelerinde kaplama tabakası içerisindeki atom boşlukları doldurulamamaktadır (Bourithis ve ark., 2002; Günen ve ark., 2018; Mathew ve Rajendrakumar, 2014).

Şekil 6a ve Şekil 6b'de çoklu lineer regresyon modeline göre Ra ve Rz'nin borlama işlem sıcaklığı ve borür kaplama tabakası kalınlığına bağlı değişimi gösterilmektedir. Şekil 6a'da Ra pürüzlülük değeri 850 °C işlem sıcaklığında 2 saat işlem süresinde 0,47 µm olarak gerçekleşirken sıcaklık 1050 °C'ye çıktığında 0,87'ye çıkmaktadır. Aynı şekilde 6 saat işlem süresinde aynı sıcaklıklardaki Ra değerleri sırası ile 0,75 ve 1,14 olarak gerçekleşmiştir. Benzer şekilde Şekil 6b'de Rz'nin 2 saat işlem süresinde ve 850 °C sıcaklıkta 1,27 olduğu sıcaklık 1050 °C'ye çıktığında Rz'nin de 2,64 µm'ye çıktığı görülmektedir. Diğer yandan 6 saat işlem süresi ve 850 °C sıcaklıkta gerçekleştirilen kaplama için Rz değerinin 2,09 aynı süre 1050 °C'deki kaplama işlemi için ise 3,46 µm olduğu görülmektedir. Dolayısıyla borlama sıcaklığı ve borlama süresindeki artışın yüzey pürüzlülük değerlerinde bir artışa neden olduğu açık bir şekilde tespit edilmiştir. Bunun durum borlama işlemi için kaplama tabakası difüzyon kontrollü olarak büyümesinden dolayı kaplamanın büyük ölçüde malzemenin iç kısmına doğru olduğu kabul edilmekle birlikte kısmen de dışarı doğru büyümesinin bir sonucudur (Şahin, 2009; Turgut ve Günen, 2020).

Şekil 7a, b ve c'de sırasıyla 25, 400 ve 750 °C'de gerçekleştirilen aşınma deneylerine ait sürtünme katsayısı (COF) değerlerinin borlama sıcaklığı ve borlama süresi ile değişimini göstermektedir. Şekil 7a'da 25 °C'de gerçekleştirilen aşınma testleri grafiğinde 2 ile 3 saatlik işlem sürelerinde borlama sıcaklığının 850, 950 ve 1050 °C'ye artmasıyla COF değerleri sırasıyla 0,4'ten 0,32'ye, ardından 0,30'a düşmektedir. Borlama sıcaklığının 3-5 saat arasındaki işlem süresi için COF değerleri yine aynı şekilde 850, 950 ve 1050 °C'ye çıkmasıyla 0,44'ten başlayıp 0,37 ve ardından 0,33'e düşmektedir. Borlama süresinin 5 saatten büyük olduğunda ise aynı şekilde COF değerleri 850, 950 ve 1050 °C'ye çıkmasıyla 0,33, 0,28 ve 0,26 değerlerine inmektedir. Şekil 7a'dan borlama süresinin COF'a etkisi açısından değerlendirildiğinde, borlama süre arttıkça COF'un önce yükseldiği, sonra tekrar başlangıç değerinin altına düştüğü görülmektedir. Grafikten, oda sıcaklığında çalışacak kaplamaların 1000 °C'nin üzerindeki işlem sıcaklığında 5 ile 6 saat tutulmasının en düşük sürtünme katsayısı değerleri sağlayacağı tespit edilmiştir.



Şekil 6. a) Ra ve b)Rz yüzey pürüzlülük değerlerinin çoklu doğrusal regresyon modeline göre kaplama sıcaklığı ve süresine bağlı değişimi.

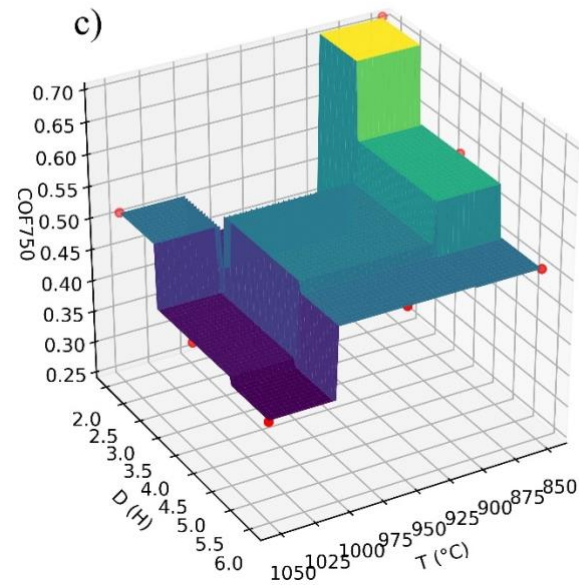


Şekil 7b'de, aşınma deneyi sıcaklığının 400 °C'ye çıkarılması COF üzerindeki etkisi incelenmiştir. Düşük borlama sıcaklık ve sürelerde borür tabakasının COF'u 0,63 gibi oldukça yüksek bir değer alırken, kaplama işlem sıcaklığının 900 °C'ye çıkmasıyla COF aniden 0,37'ye düşmektedir. Sıcaklık 1000 °C'ye çıktığında COF 0,31'e kadar düşmektedir. COF değeri, 3 ile 5 saat arasındaki işlem süresinde 0,32 gibi düşük bir değer almıştır. Sıcaklık arttıkça COF değeri biraz daha düşerek 0,31'e ulaşırken, sıcaklık 1000 °C'ye çıktığında birden yükselerek 0,4'e ulaşmaktadır. COF değeri, 5 saatin üzerindeki işlem sürelerinde işlem sıcaklığından daha az etkilenmektedir. COF değeri, 1000 °C'ye kadar olan sıcaklıkta 0,44 olarak belirlenirken, bu değer üzerindeki sıcaklıklarda 0,4'e düşmektedir. Grafikten, 400 °C civarında çalışacak kaplamalar için en düşük sürtünme katsayılarının,

900 ile 1000 °C işlem sıcaklığı ve 3 ile 5 saat işlem süresi arasında gerçekleştiği; alternatif olarak, 1000 °C ile 1050 °C işlem sıcaklıklarının 2 ile 3 saat arasında uygulanabileceği görülmektedir.

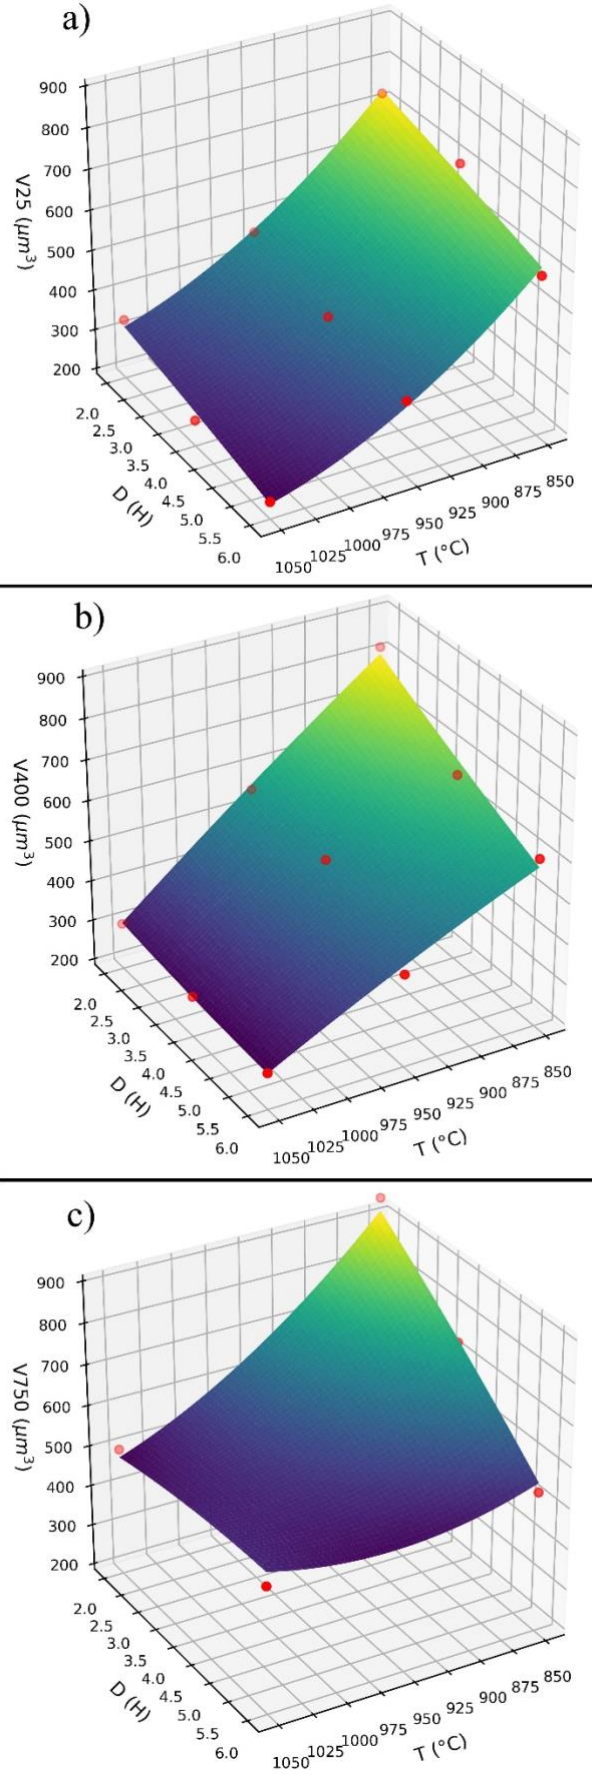
Şekil 7c'de, yüksek sıcaklıkta (750 °C) gerçekleştirilen aşınma deneyinde özellikle 900 °C'ye kadar işlem sıcaklıklarında kaplanan malzemelerde COF'un düşük işlem sürelerinde 0,71 gibi büyük değerlerde olduğu, fakat işlem sıcaklığının 900 °C'yi geçmesiyle COF'un aniden 0,45 gibi değerlere düştüğü ve 1000 °C'den sonra tekrar 0,51'e yükseldiği görülmektedir. Benzer şekilde, 3 ile 5 saat arasındaki işlem süresinde COF, 900 °C'ye kadar 0,59 iken, işlem sıcaklığının artmasıyla 0,53'e, 1000 °C'den sonra ise 0,41'e düşmektedir. İşlem süresi 5 saatin üzerine çıktığında, 850 °C'den 1000 °C'ye kadar COF 0,51 olarak gerçekleşmekte, sonrasında ise 0,40'a düşmektedir. Yüksek sıcaklıkta çalışması planlanan kaplamalar için en düşük COF değerlerinin 1000 °C'nin altında ve 2 saatin üzerindeki işlem sürelerinde elde edildiği görülmektedir.

Şekil 8a, b ve c'de 25, 400 ve 750 °C sıcaklıklarında gerçekleştirilen aşınma deneylerinin sonuçlarına dayanarak, aşınma hacim kayıplarının kaplama süresi ve sıcaklığına bağlı değişimi polinom regresyon modellerine göre grafiklenmiştir. Oda sıcaklığındaki aşınma hacim kaybı, Şekil 8a'da, 2 saatlik kaplama süresinde 1050 °C işlem sıcaklığında 317 μm^3 iken sıcaklık 850 °C'ye düştüğünde, parabolik olarak 737 μm^3 'e yükselmektedir. Borlama süresi 6 saate çıktığında, işlem sıcaklığı 1050 °C'den 850 °C'ye indiğinde, aşınma hacmi parabolik olarak 223 μm^3 'ten 602 μm^3 'e yükselmektedir. Grafikten, bütün işlem sıcaklıklarında, işlem süresi arttıkça aşınma hacminin doğrusal olarak azaldığı görülmektedir. Bu durum aynı sıcaklıklarda yapılan borlama işlemlerinde borlama süresindeki artış ile daha kalın ve daha sert kaplama tabakalarının elde edilmesi dolayısıyla sert kaplamaların plastik deformasyonlarının daha az olmasına atfedilebilir.

Şekil 8b'de, 400 °C'deki aşınma koşullarında, aşınma hacim kayıplarının borlama sıcaklığının artmasıyla ters parabolik olarak, işlem süresinin artmasıyla ise doğrusal olarak azaldığı görülmektedir. Borlama süresinin 2 saat olduğu bölgede, işlem sıcaklığının 850 °C'den 1050 °C'ye çıkmasıyla aşınma hacmi 803 μm^3 'den 303 μm^3 'e düşmektedir. Grafikten, işlem süresi arttıkça, işlem sıcaklığının etkisinin azaldığı anlaşılmaktadır. Bu durum ise işlem süresi artışı ile ortamda düfuz olacak bor atomları konsantrasyonun zaman artışı ile azalmasının bir sonucu olarak uzayan sürelerde daha az difuze olmaları anlamına gelmektedir. Bu durum II. Fick kanunu ile uyumludur. İşlem süresi 6 saate çıktığında, aşınma hacmi aynı sıcaklık aralığında 579 μm^3 'ten 275 μm^3 'e ters parabolik olarak azalmaktadır.



Şekil 7. a) 25 °C, b) 400 °C ve c) 750 °C'deki COF'un XGBoost modellerine göre işlem süresi ve sıcaklığına bağlı değişimi.



Şekil 8. a) 25 °C, b) 400 °C ve c) 750 °C'deki V'nin PL modellerine göre işlem süresi ve sıcaklığına bağlı değişimi.

Aşınma sıcaklığı 750 °C'ye yükseldiğinde, Şekil 8c'de, aşınma hacim kayıplarının genel olarak yükseldiği görülmektedir. Bu durum artan aşınma sıcaklıklarının borür kaplamaların mekanik özelliklerini zayıflattığına işaret etmektedir. Ancak, borlama süresi ve sıcaklığın diğer parametrelerde olduğu artan borlama sıcaklığı ve süresi ile aşınma hacim kayıplarında azalma olduğu görülmektedir. 2 saatlik borlama işlem süresinde, işlem sıcaklığının 850 °C'den 1050 °C'ye çıkmasıyla, aşınma hacmi 919 μm^3 'ten 480 μm^3 'e parabolik olarak azalmaktadır. Borlama işlem süresi 6 saate çıktığında ise, aşınma hacminin 850 °C sıcaklıkta 553 μm^3 olduğu ve sonrasında sıcaklığın artmasıyla parabolik olarak azaldığı, 975 °C civarında en düşük seviyeye ulaştığı görülmektedir. Aşınma hacmi daha sonra sıcaklıkla birlikte artarak, 1050 °C'de 532 μm^3 'e ulaşmaktadır.

Diğer yandan, düşük borlama sıcaklıklarda aşınma hacmi, borlama işlem süresinin artmasıyla hızla azalırken, yüksek borlama sıcaklıklarda neredeyse sabit kalmaktadır.

5. Sonuçlar ve Öneriler

Çalışma kapsamında Ni esaslı Inconel 718 süper alaşımı %90 B₄C ve %10 NaBF₄ ağırlık oranında karıştırılmış nano boyutlu tozlar kullanılarak paket borlama tekniği ile borlanarak işlem sıcaklığı ve süresinin kaplama kalınlığı, Ra ve Rz yüzey pürüzlülüğü, mikrosertlik gibi kaplama özellikleri ile 25, 400 ve 750 °C sıcaklıklardaki sürtünme katsayısı ve aşınma hacim kaybı gibi tribolojik özellikleri incelenmiştir. Bu çalışmada kaplama işlem parametrelerinin incelenen özelliklere etkisinin daha iyi anlaşılabilmesi için her bir özellik için MLR, polinom regresyon, SVR, DT, RF ve XGBoost makine öğrenme modelleri geliştirilmiştir. Geliştirilen modellerin başarı metrikleri kıyaslanarak her bir özelliğin detaylı analizi için kullanılacak makine öğrenmesi modeli seçilmiş ve 3 boyutlu yüzey grafikleri oluşturulmuştur. Yapılan çalışmanın sonuçları şu şekilde özetlenebilir:

1- Inconel 718 süper alaşımının 850 ile 1050 °C sıcaklık 2 ile 6 saat işlem süresi aralıklarında borlanması sonucunda borür kaplama kalınlıklarının 20,7 ile 130,1 μm arasında değişen kompleks borür tabakaları elde edilmiştir.

2- Kaplama kalınlığı ve mikrosertlik değerleri üzerinde borlama sıcaklığının borlama süresine göre daha etkili olduğu tespit edilmiştir.

3- Borlama sıcaklığı ve borlama süresinin Ra ve Rz pürüzlülük değeri üzerinde doğrusal bir etkisinin olduğu tespit edilmiştir.

4- Kaplama parametrelerinin COF üzerinde oldukça karmaşık bir etkisinin olduğu görülmüştür. Oda sıcaklığında borlama sıcaklığının artışının COF'u azalttığı, borlama süresinin artması ise COF'u önce arttırdığı daha sonra azalttığı tespit edilmiştir.

5- Aşınma deneyi 400 °C’de yapıldığında en düşük COF 3 ile 5 saat aralığı ve 900 ile 1000 °C işlem süreleri birleşiminde görülmektedir. Aşınma deneyi 750 °C’de yapıldığında ise en düşük COF 1050 °C üzerindeki işlem sıcaklığı ve 5 saatin üzerindeki işlem sürelerinde elde edilmiştir.

6- Oda sıcaklığında ve 400 °C’de yapılan aşınma deneyinde en düşük aşınma hacim kaybı 1050 °C’de 6 saat borlanmış numunede elde edilebileceği tespit edilmiş iken 750 °C de ise en düşük aşınma hacim kayıplarının 975 °C’de 6 saat ile borlanan numunede elde edileceği tespit edilmiştir.

7- Bu çalışma ile aşınma hacim kayıpları bakımından borlama sıcaklığının borlama süresinden daha etki bir parametre olduğu ve aşınma deney sıcaklığı arttıkça borlama süresinin öneminin iyice azaldığı tespit edilmiştir.

Yazarların Katkısı

Faruk ÇAVDAR, çalışma konsepti ve tasarımı, taslağın oluşturulması hususlarında katkıda bulunmuştur. Ayrıca yazar Faruk ÇAVDAR, makine öğrenmesi modellerinin ve 3 boyutlu grafiklerinin oluşturulması ve yorumlanmasını gerçekleştirmiştir. Ali GÜNEN ise çalışma konsepti ve tasarımı, veri toplama, verilerin analizi ve yorumlanması, taslağın oluşturulması ve revizyon hususlarında katkıda bulunmuştur. Bunlara ek olarak Ali GÜNEN verilerin elde edilmesi için deneyleri tasarlamış ve gerçekleştirmiştir.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Bölükbaşı, Ö. S., Serindağ, T., Gürol, U., Günen, A., ve Çam, G. (2023). Improving oxidation resistance of wire arc additive manufactured Inconel 625 Ni-based superalloy by pack aluminizing. *CIRP Journal of Manufacturing Science and Technology*, 46, 89–97. <https://doi.org/10.1016/j.cirpj.2023.07.011>
- Bourithis, L., Papaefthymiou, S., ve Papadimitriou, G. D. (2002). Plasma transferred arc boriding of a low carbon steel: microstructure and wear properties. *Applied Surface Science*, 200(1–4), 203–218. [https://doi.org/10.1016/S0169-4332\(02\)00901-7](https://doi.org/10.1016/S0169-4332(02)00901-7)
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Campos-Silva, I., Contla-Pacheco, A. D., Figueroa-López, U., Martínez-Trinidad, J., Garduño-Alva, A., & Ortega-Avilés, M. (2019). Sliding wear resistance of nickel boride layers on an Inconel 718

- superalloy. *Surface and Coatings Technology*, 378, 124862. <https://doi.org/10.1016/j.surfcoat.2019.06.099>
- Chen, T., ve Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Çavdar, F., Günen, A., Kanca, E., Er, Y., Gök, M. S., Campos-Silva, I., ve Olivares-Luna, M. (2022). An Experimental and Statistical Analysis on Dry Sliding Wear Failure Behavior of Incoloy 825 at Elevated Temperatures. *Journal of Materials Engineering and Performance*, 1–24.
- Deng, D. W., Wang, C. G., Liu, Q. Q., & Niu, T. T. (2015). Effect of standard heat treatment on microstructure and properties of borided Inconel 718. *Transactions of Nonferrous Metals Society of China*, 25(2), 437–443. [https://doi.org/10.1016/S1003-6326\(15\)63621-4](https://doi.org/10.1016/S1003-6326(15)63621-4)
- Döleker, K. M., Erdogan, A., Yener, T., Karaoglanlı, A. C., Uzun, O., Gök, M. S., ve Zeytin, S. (2021). Enhancing the wear and oxidation behaviors of the Inconel 718 by low temperature aluminizing. *Surface and Coatings Technology*, 412, 127069. <https://doi.org/10.1016/j.surfcoat.2021.127069>
- Donachie, M. J., ve Donachie, S. J. (2002). *Superalloys: A Technical Guide*, 2nd Edition. ASM International. <https://books.google.com.tr/books?id=vjCJ5pI1QpkC>
- Eliassen, K. M., Christiansen, T. L., ve Somers, M. A. J. (2010). Low temperature gaseous nitriding of Ni based superalloys. *Surface Engineering*, 26(4), 248–255. <https://doi.org/10.1179/026708409X12490360426043>
- Ganji, D. K., ve Rajyalakshmi, G. (2020). Influence of Alloying Compositions on the Properties of Nickel-Based Superalloys: A Review (pp. 537–555). https://doi.org/10.1007/978-981-15-1071-7_44
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media. <https://books.google.com.tr/books?id=HHetDwAAQBAJ>
- Giriskan, I., ve Çam, G. (2023). Characterization of microstructure and high-temperature wear behavior of pack-borided Co-based Haynes 25 superalloy. *CIRP Journal of Manufacturing Science and Technology*, 45, 82–98. <https://doi.org/10.1016/j.cirpj.2023.06.012>
- Günen, A. (2020). Properties and High Temperature Dry Sliding Wear Behavior of Boronized Inconel 718. *Metallurgical and Materials Transactions A*, 51(2), 927–939. <https://doi.org/10.1007/s11661-019-05577-3>
- Günen, A., ve Ergin, Ö. (2023). A Comparative Study on Characterization and High-Temperature Wear Behaviors of Thermochemical Coatings Applied to Cobalt-Based Haynes 25 Superalloys. *Coatings*, 13(7), 1272. <https://doi.org/10.3390/coatings13071272>
- Günen, A., ve Kanca, E. (2017). Characterization of borided Inconel 625 alloy with different boron chemicals. *Pamukkale University Journal of Engineering Sciences*, 23(4), 411–416. <https://doi.org/10.5505/pajes.2017.56689>
- Günen, A., Kanca, Y., Karahan, İ. H., Karakaş, M. S., Gök, M. S., Kanca, E., ve 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. <https://doi.org/10.1007/s11661-018-4862-2>
- Günen, A., Keddani, M., Alkan, S., Erdoğan, A., ve Çetin, M. (2022). Microstructural characterization, boriding kinetics and tribo-wear behavior of borided Fe-based A286 superalloy. *Materials Characterization*, 186, 111778. <https://doi.org/10.1016/j.matchar.2022.111778>
- James, G., Witten, D., Hastie, T., ve Tibshirani, R. (2021). *An Introduction to Statistical Learning*. Springer US. <https://doi.org/10.1007/978-1-0716-1418-1>
- Kanca, Y., Uçgun, M. C., & Günen, A. (2023). Microstructural and tribological behavior of pack-borided Ni-based Hastelloy C-276 superalloy. *Metallurgical and materials transactions A*, 54(2), 671–687. <https://doi.org/10.1007/s11661-022-06915-8>
- Karakaş, M. S., Günen, A., Kanca, E., & Yılmaz, E. (2018). Boride layer growth kinetics of AISI H13 steel borided with nano-sized powders. *Archives of Metallurgy and Materials*. <https://doi.org/10.24425/118923>
- Kayalı, Y., Kanca, E., ve Günen, A. (2022). Effect of boronizing on microstructure, high-temperature wear and corrosion behavior of additive manufactured Inconel 718. *Materials Characterization*, 191, 112155. <https://doi.org/10.1016/j.matchar.2022.112155>
- Mathew, M., ve Rajendrakumar, P. K. (2014). Effect of Precarburization on Growth Kinetics and Mechanical Properties of Borided Low-Carbon Steel. *Materials and Manufacturing Processes*, 29(9), 1073–1084. <https://doi.org/10.1080/10426914.2014.901538>

- Meriç, C., Sahin, S., & Yilmaz, S. S. (2000). Investigation of the effect on boride layer of powder particle size used in boronizing with solid boron-yielding substances. *Materials Research Bulletin*, 35(13), 2165-2172. [https://doi.org/10.1016/S0025-5408\(00\)00427-X](https://doi.org/10.1016/S0025-5408(00)00427-X)
- Müller, A. C., ve Guido, S. (2016). *Introduction to Machine Learning with Python: A Guide for Data Scientists*. O'Reilly Media. <https://books.google.com.tr/books?id=1-4IDQAAQBAJ>
- Rai, A. K., Paul, C. P., Mishra, G. K., Singh, R., Rai, S. K., & Bindra, K. S. (2021). Study of microstructure and wear properties of laser borided Inconel 718. *Journal of Materials Processing Technology*, 298, 117298. <https://doi.org/10.1016/j.jmatprotec.2021.117298>
- Reed, R. C. (2008). *The Superalloys: Fundamentals and Applications*. Cambridge University Press. <https://books.google.com.tr/books?id=SgFiPwAACAAJ>
- Şahin, S. (2009). Effects of boronizing process on the surface roughness and dimensions of AISI 1020, AISI 1040 and AISI 2714. *Journal of Materials Processing Technology*, 209(4), 1736–1741. <https://doi.org/10.1016/j.jmatprotec.2008.04.040>
- Sato, J., Omori, T., Oikawa, K., Ohnuma, I., Kainuma, R., ve Ishida, K. (2006). Cobalt-Base High-Temperature Alloys. *Science*, 312(5770), 90–91. <https://doi.org/10.1126/science.1121738>
- Satyanarayana, D. V. V, ve Eswara Prasad, N. (2017). Nickel-Based Superalloys. In N. E. Prasad ve R. J. H. Wanhill (Eds.), *Aerospace Materials and Material Technologies : Volume 1: Aerospace Materials* (pp. 199–228). Springer Singapore. https://doi.org/10.1007/978-981-10-2134-3_9
- Selvaraj, S. K., Sundaramali, G., Jithin Dev, S., Sri Swathish, R., Karthikeyan, R., Vijay Vishaal, K. E., ve Paramasivam, V. (2021). Recent Advancements in the Field of Ni-Based Superalloys. *Advances in Materials Science and Engineering*, 2021, 1–60. <https://doi.org/10.1155/2021/9723450>
- Tang, Z., Yang, C., Duan, Y., Ma, L., Zheng, S., Peng, M., & Li, M. (2024). Effects of boriding and aluminizing on the electrochemical and wear behavior of IN-718 nickel-based alloy. *Surface and Coatings Technology*, 494, 131314. <https://doi.org/10.1016/j.surfcoat.2024.131314>
- Tuncay Turan, Hasan Güteryüz, ve Hüseyin Çimenoğlu. (2019). Effect of Nitriding on Surface Characteristics and High Temperature Wear Behaviour of Inconel 718 Superalloy. *UDCS'19 Fourth International Iron and Steel Symposium*, 379–382.
- Turgut, S., ve Günen, A. (2020). Mechanical Properties and Corrosion Resistance of Borosintered Distalloy Steels. *Journal of Materials Engineering and Performance*, 29(11), 6997–7010. <https://doi.org/10.1007/s11665-020-05186-x>
- Wade, C., ve Glynn, K. (2020). *Hands-On Gradient Boosting with XGBoost and Scikit-learn: Perform Accessible Machine Learning and Extreme Gradient Boosting with Python*. Packt Publishing, Limited. <https://books.google.com.tr/books?id=jqrRzQEACAAJ>
- Wu, Z., Liu, Y., Shao, M., Wang, J., Li, Y., Peng, J., ... & Chen, S. (2025). Insights into the microstructure and load-dependent wear characteristics of the boride layer on Inconel 718 alloy. *Tribology International*, 202, 110298. <https://doi.org/10.1016/j.triboint.2024.110298>