



**METALİK MALZEMELERİN SÜRTÜNME VE AŞINMA
ÖZELLİKLERİNİN MAKİNE ÖĞRENME
YÖNTEMLERİ İLE TAHMİN EDİLMESİ**

Şenay ER

**Yüksek Lisans Tezi
Makine Mühendisliği Ana Bilim Dalı
Danışman: Doç. Dr. Halim KOVACI
2023**

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI

**METALİK MALZEMELERİN SÜRTÜNME VE AŞINMA ÖZELLİKLERİNİN
MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİN EDİLMESİ**

(Prediction of Friction and Wear Properties of Metallic Materials by Machine Learning
Methods)

YÜKSEK LİSANS TEZİ

Şenay ER

Danışman: Doç. Dr. Halim KOVACI

Erzurum
Ağustos, 2023



FEN BİLİMLERİ ENSTİTÜSÜ

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü Müdürlüğü
TEZ KABUL VE ONAY TUTANAĞI

**METALİK MALZEMELERİN SÜRTÜNME VE AŞINMA ÖZELLİKLERİNİN MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİN EDİLMESİ**

Doç. Dr. Halim KOVACI danışmanlığında, Şenay ER tarafından hazırlanan bu çalışma, 04/08/2023 tarihinde aşağıdaki jüri tarafından Makine Mühendisliği Anabilim Dalı'nda Yüksek Lisans tezi olarak **oybirliği** ile kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Ayhan ÇELİK <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Danışman:	Doç. Dr. Halim KOVACI <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Prof. Dr. İrfan KAYMAZ <i>Erzurum Teknik Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Prof. Dr. Ali Fatih YETİM <i>Erzurum Teknik Üniversitesi</i>	Aslı Islak İmzalıdır
Jüri Üyesi:	Doç. Dr. Ferhat BOZKURT <i>Atatürk Üniversitesi</i>	Aslı Islak İmzalıdır

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof.Dr. Saltuk Buğrahan CEYHUN
Enstitü Müdürü

Aslı Islak İmzalıdır

**FEN BİLİMLERİ ENSTİTÜSÜ**

Graduate School of Natural and
Applied Sciences

T.C.
ATATÜRK ÜNİVERSİTESİ REKTÖRLÜĞÜ
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Yüksek Lisans Tezi olarak Doç. Dr. Halim KOVACI danışmanlığında sunulan “Metalik Malzemelerin Sürtünme Ve Aşınma Özelliklerinin Makine Öğrenmesi Yöntemleri İle Tahmin Edilmesi” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	17	30
Kuramsal Temeller	11	30
Materyal ve Metot	14	35
Araştırma Bulguları ve Tartışma	16	20
Sonuçlar ve Öneriler	15	20
Tezin Geneli	8	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Sunulan bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ettiğimizi beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Şenay ER	Doç. Dr. Halim KOVACI
4.8.2023	4.8.2023
İmza: Aslı Islak İmzalıdır	İmza: Aslı Islak İmzalıdır

* Tez ile ilgili YÖKTEZ’de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun .../.../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun .../.../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Çalışmalarımnda beni akademik bilgi ve rehberliği ile destekleyen, kıymetli bilgi ve tecrübeleri ile bana yol gösteren ve yol açan danışman hocam Sayın Doç. Dr. Halim KOVACI'ya teşekkür eder ve saygılar sunarım.

Tez çalışmam boyunca deneysel çalışmalarımnda yardımlarını ve bilgilerini esirgemeyen Sayın Dr. Öğr. Üyesi Yusuf Burak BOZKURT'a, Arş. Gör. Burak ATİK'e ve Arş. Gör. Yeşim SEÇER KAVASOĞLU'na teşekkürü borç bilirim.

Öğrenim hayatım boyunca bana her zaman ve her konuda destek olan ve teşvik eden annem Sema YETİŞİR'e, babam Servet YETİŞİR'e, sevgili ablama ve ağabeylerime sonsuz teşekkür ve minnetlerimi sunarım.

Son olarak tez çalışmam boyunca hep yanımda olan ve desteğini esirgemeyen sevgili eşim Arş. Gör. Hasan ER'e çok teşekkür ederim.

Şenay ER

ÖZET

YÜKSEK LİSANS TEZİ

METALİK MALZEMELERİN SÜRTÜNME VE AŞINMA ÖZELLİKLERİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TAHMİN EDİLMESİ

Şenay ER

Danışman: Doç. Dr. Halim KOVACI

Amaç: Bu çalışmada, metalik malzemelerin sürtünme ve aşınma davranışlarının değişken deney şartları (kayma ortamı, süre, hız ve yük) altında Yapay Zekâ uygulamalarından olan Makine Öğrenmesi teknikleri ile tahmin edilmesi amaçlanmıştır. Elde edilen sonuçların özellikle mühendislik uygulamalarında malzeme seçimi, tasarım optimizasyonu, deney sayısının azaltılması ve bakım stratejileri gibi konularda daha hassas ve etkili kararlar alınmasına olanak sağlayabileceği düşünülmektedir.

Yöntem: Bu çalışmada, özellikle otomotiv sanayi başta olmak üzere farklı birçok sektörde sıklıkla kullanılan AISI 4140 düşük alaşımlı çeliğinden hazırlanan numuneler, malzemenin sürtünme ve aşınma özelliklerini etkileyen parametreler değiştirilerek farklı deney şartları altında aşınma deneylerine tabii tutulmuştur. Deneyler, farklı kayma ortamları (kuru, tuzlu su ve yağ), süreler (30, 60 ve 120 dk.), hızlar (8, 16 ve 32 mm/sn.) ve yükler (1,3 ve 5 N) altında gerçekleştirilmiştir. Veri seti, değişken deney şartlarından elde edilen verilerin %70'i eğitim, %30'u test olacak şekilde ayrılmış ve bu veriler makine öğrenmesi modellerinin eğitiminde ve test edilmesinde kullanılmıştır. Sürtünme katsayısı ve aşınma oranı tahmini için altı farklı denetimli makine öğrenmesi regresyon modeli kullanılmıştır. Aynı zamanda veri seti üzerinde, k-fold cross-validation yöntemi kullanılarak her bir modelin hata metrikleri dikkate alınarak performansları değerlendirilmiştir. Elde edilen sonuçlar, modellerin performans ölçütleri kıyaslayarak en iyi sonucun hangi modelde olduğu tespit edilmiştir.

Bulgular: Yapılan analizler sonucunda, sürtünme katsayısı tahminleri için en yüksek R^2 değeri 0.80 ile Destek Vektör Regresyon (SVR) modelinde elde edilmiştir. Bu sonuç, SVR modelinin sürtünme katsayısı tahminlerinde diğer modellere göre daha iyi bir uyum gösterdiğini göstermektedir. Ayrıca, aşınma oranı tahminleri için en yüksek R^2 değeri 0.95 ile Lineer Regresyon modelinde elde edilmiştir. Bu sonuç, Lineer Regresyon modelinin aşınma oranı tahminlerinde diğer modellere göre daha yüksek bir başarı gösterdiğini göstermektedir. Bu durum, farklı modellerin farklı tahminlerde daha iyi performans gösterebileceğini ve kullanılan veri seti ve değişkenlere bağlı olarak farklı sonuçlar elde edilebileceğini göstermektedir.

Sonuç: Bu çalışmada uygulanan modellerden elde edilen istatistiksel performans ölçütleri, geliştirilen makine öğrenimi modellerinin AISI 4140 çeliğinin sürtünme katsayısı (CoF) ve aşınma oranının malzeme ve tribolojik değişkenler dikkate alındığında tatmin edici bir düzeyde tahmin edebileceğini göstermektedir. Çalışmanın sonuçlarının, mühendislik uygulamalarında daha fazla eğitim veri seti kullanılarak, farklı yük, hız ve ortam koşullarında sürtünme ve aşınma davranışları ile ilgili tribolojik uygulamalara katkı sağlayabileceği düşünülmektedir.

Anahtar Kelimeler: makine öğrenmesi, triboinformatik, triboloji, sürtünme, aşınma

Ağustos 2023, 85 sayfa

ABSTRACT

MASTER THESIS

PREDICTION of FRICTION and WEAR PROPERTIES of METALLIC MATERIALS by MACHINE LEARNING METHODS

Şenay ER

Supervisor: Assoc. Prof. Dr. Halim KOVACI

Purpose: The aim of this study is to predict the friction and wear behavior of metallic materials under variable experimental conditions (slip environment, time, speed and load) using machine learning techniques, one of the artificial intelligence applications. It is thought that the results obtained can enable more sensitive and effective decisions to be made, especially in engineering applications, such as material selection, design optimization, reducing the number of experiments/tests and maintenance strategies.

Method: In this study, samples of AISI 4140 low-alloy steel, which is widely used in many different industries, especially in the automotive industry, were subjected to wear tests under different test conditions by changing the parameters that affect the friction and wear properties of the material. The experiments were performed under different sliding environments (dry, salt water and oil), times (30, 60 and 120 min), speeds (8, 16 and 32 mm/s) and loads (1.3 and 5 N). The data set was split into 70% of the data obtained from the variable experimental conditions and 30% of the test, and these data were used in training and testing machine learning models. Six different supervised machine learning regression models were used to estimate the coefficient of friction and wear rate. At the same time, the performances of each model were evaluated by using the k-fold cross-validation method on the data set, taking into account the error metrics of each model. The results obtained were compared to the performance criteria of the models and it was determined which model achieved the best result.

Findings: As a result of the analysis, the highest R^2 value for the friction coefficient estimates in the Support Vector Regression (SVR) model was 0.80. This result shows that the SVR model fits the coefficient of friction estimates better than the other models. In addition, the highest R^2 value for wear rate estimates, 0.95, was obtained in the linear regression model. This result shows that the linear regression model has greater success in estimating wear rate than other models. This shows that different models may perform better for different predictions, and different results may be obtained depending on the data set and variables used. The SVR model performed better on datasets with nonlinear relationships, while the linear regression model performed better on variables with linear relationships.

Results: The statistical performance measures obtained from the models used in this study demonstrate that the developed machine learning models can predict the coefficient of friction (CoF) and wear rate of AISI 4140 steel at a satisfactory level when the material and tribological variables are taken into account. It is believed that the results of the study can contribute to tribological applications related to friction and wear behavior under different load, speed and environmental conditions by using more training datasets in engineering applications.

Keywords: machine learning, triboinformatic, tribology, friction, wear

August 2023, 85 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ.....	xi
GİRİŞ.....	1
KURAMSAL TEMELLER.....	7
Triboloji	7
Sürtünme	7
Aşınma	13
Yağlama	17
Endüstri 4.0	19
Triboinformatik	21
Makine Öğrenmesi	22
Denetimli öğrenme.....	24
Denetimsiz öğrenme.....	37
Yarı denetimli makine öğrenmesi	39
Takviyeli makine öğrenmesi	40
MATERYAL VE YÖNTEM	41
Malzeme.....	41
Numunelerin Hazırlanması	41
Aşınma Testleri	43
Makine Öğrenmesi	44
Veri Toplama	45
Veri Ön İşleme	46
Algoritma Seçimi	49
Model Eğitimi	50
Model Değerlendirmesi.....	50

ARAŖTIRMA BULGULARI VE TARTIŖMA.....	53
Tribolojik Parametreler Arasındaki İliŖkiler:	53
Model Performans Ölçütlerinin Deęerlendirilmesi.....	58
SONUÇLAR VE ÖNERİLER	63
KAYNAKÇA	66
ÖZGEÇMİŖ.....	72



TABLÖLAR DİZİNİ

Tablo 1. R^2 Değerlerinin Anlamları.....	26
Tablo 2. AISI 4140 Çeliğinin Kimyasal Özellikleri	41
Tablo 3. AISI 4140 Çeliğinin Mekanik Özellikleri	41
Tablo 4. Aşınma Deney Parametreleri.....	44
Tablo 5. Veri parametreleri: Boş Olmayan Değerlerin Sayısı- Veri Türleri	46
Tablo 6. ML Veri Seti	47
Tablo 7. CoF ve Aşınma Oranı Tahminleri İçin ML Algoritmalarının Parametreleri.....	50
Tablo 8. Aşınma Oranı Tahmini İçin Makine Öğrenimi Modellerinin Performans Ölçütleri.....	59
Tablo 9. Sürtünme Katsayısı (CoF) Tahmini İçin Makine Öğrenimi Modellerinin Performans Ölçütleri	60

ŞEKİLLER DİZİNİ

Şekil 1. Tribolojide incelenen sürtünme, aşınma ve yağlama ilkeleri.....	7
Şekil 2. Sürtünme mekanizmaları	8
Şekil 3. Kuru sürtünme mekanizması	8
Şekil 4. Kuru sürtünme modeli	9
Şekil 5. Sürtünme kuvveti-Uygulanan kuvvet grafiği.....	10
Şekil 6. Sürtünme katsayısı-Kayma hızı grafiği: Statik sürtünme katsayısı ve Kinematik sürtünme katsayısı	10
Şekil 7. Sınır sürtünme mekanizması.....	11
Şekil 8. Sıvı sürtünme mekanizması	11
Şekil 9. Stribeck eğrisi	13
Şekil 10. Adezif aşınma	14
Şekil 11. İki cisimli abrazif aşınma modeli.....	15
Şekil 12. Üç cisimli abrazif aşınma modeli	16
Şekil 13. Yorulma aşınma modeli	16
Şekil 14. Korozyon aşınma modeli	17
Şekil 15. Stribeck Eğrisi: sürtünme katsayısı ve film kalınlığı - yağlama parametresi.....	19
Şekil 16. Endüstri devrimleri	21
Şekil 17. Triboinformatik.....	22
Şekil 18. Yapay zekânın kümeleri.....	23
Şekil 19. Makine öğrenmesi türleri	24
Şekil 20. Denetimli makine öğrenmesi	25
Şekil 21. Regresyon analiz türleri	26
Şekil 22. Regresyon modelleri	32
Şekil 23. Sınıflandırma modelleri	35
Şekil 24. Ensemble modelleri: rastgele orman- gradyan artırma	37
Şekil 25. Denetimsiz makine öğrenmesi	37
Şekil 26. Kümeleme algoritmaları: K-ortalama - hiyerarşik.....	39
Şekil 27. Yarı denetimli makine öğrenmesi	40
Şekil 28. Takviyeli makine öğrenmesi	40
Şekil 29. Hassas kesme cihazı.....	42
Şekil 30. Numune kesme aşamaları	42

Şekil 31. Zımparalama cihazı.....	43
Şekil 32. Aşınma test cihazı ve şematik görünümü.....	43
Şekil 33. Denetimli makine öğrenmesi regresyon modelleme akış şeması	45
Şekil 34. Aşınma oranı – girdi parametreleri arasındaki ilişkiler	54
Şekil 35. Aşınma oranı: ortam ve aşınma mesafesi arasındaki ilişkiler.....	55
Şekil 36. Sürtünme Katsayısı – girdi parametreleri arasındaki ilişki	56
Şekil 37. Sürtünme Katsayısı: Hız ve Aşınma Mesafesi arasındaki ilişkiler	56
Şekil 38. Tribolojik parametreler arasındaki ilişkiler.....	57
Şekil 39. Korelasyon matrisi: Tribolojik parametreler arasındaki korelasyon ilişkisi	58



KISALTMALAR VE SİMGELER DİZİNİ

AI	: Yapay Zekâ (Artificial Intelligence)
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
BN	: Bor Nitrür
CNT	: Karbon Nanotüpler
CoF	: Sürtünme Katsayısı
Cr	: Krom
cv	: Çapraz Doğrulama (Cross-Validation)
DL	: Derin Öğrenme (Deep Learning)
DOE	: Deney Tasarımı (Design of Experiments)
GBM	: Gradyan Artırma (Gradient Boosting Machine)
GBRT	: Gradyan Artırma Regresyon Ağacı (Gradient Boosting Regression Trees)
IoT	: Endüstriyel Nesnelerin İnterneti (Internet of Things)
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
LR	: Lineer Regresyon
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
ML	: Makine Öğrenmesi (Machine Learning)
Mn	: Manganez
Mo	: Molibden
MoS₂	: Molibden Disülfid
MSE	: Ortalama Karesel Hata (Mean Squared Error)
RF	: Rastgele Orman (Random Forest)
RMSE	: Kök Ortalama Karesel Hata (Root Mean Squared Error)
RSM	: Yanıt Yüzey Metodu (Response Surface Method)
SVM	: Destek Vektör Makinesi (Support Vector Machines)
SVR	: Destek Vektör Regresyon (Support Vector Regression)
XGboost	: Aşırı Gradyan Artırma (Extreme Gradient Boosting Machine)

GİRİŞ

Yapay zekâ (Artificial Intelligence-AI), insani özellikleri gerektiren işlerin yapılmasına imkân sağlayan kapsamlı bir teknoloji alanını ifade etmektedir. Özellikle de son yıllarda, yapay zekâ teknolojisi büyük bir gelişme kaydetmiştir. Beynimizin öğrenme süreçleri taklit edilerek oluşturulan yapay sinir ağları ve makinelerin insanların karar vermesini taklit etme yeteneğini temsil eden sistemler, sahip oldukları bilgiler aracılığıyla olayları öğrenerek sorunları çözebilmektedirler. Bu gelişmeler, gerçek yapay zekâyâ daha da yaklaşılmalarını sağlamıştır. Makine Öğrenimi/Öğrenmesi ve Sinir Ağı gibi yapay zekâ teknolojileri, makineleri eskisinden daha akıllı hale getirebilmektedir. Yapay zekâ alanlarından biri olan Makine Öğrenimi, bilgisayar sistemlerine belirli bir görevi öğrenme yeteneği kazandıran bir teknolojidir. Bu teknoloji, bilgisayar sistemlerinin veriye dayalı olarak öğrenme yapmalarını, sonuçlarını analiz etmelerini ve gelecekteki kararlarını buna göre vermelerini sağlar. Makine Öğrenimi, Endüstri 4.0 gibi diğer teknolojilerle birleştirilerek daha akıllı ve verimli sistemlerin oluşturulmasına katkı sağlamaktadır (UNCTAD 2019).

Endüstri 4.0 ya da 4. Endüstri Devrimi terimi ilk olarak 2011 yılında Almanya Hannover Fuarında kullanılmıştır. Endüstri 4.0, bilişim teknolojileri ile endüstriyi bir araya getirerek üretimde daha fazla dijitalleşme amaçlamaktadır. Yani dördüncü sanayi devrimi; üretimle ilişkili olan bütün birimlerin birbiri ile ortak çalışmasını planlanmaktadır (Schwab 2017). Endüstri 4.0, diğer sanayi devrimlerinden ayıran en önemli dört ana unsur; veri, sensör, bilgi ve işlemdir. Bu dört unsurun bir araya getirilmesiyle, üretim sistemleri daha esnek ve işbirliğine dayalı hale gelmektedir. Endüstri 4.0 ile Yapay Zekâ (AI), Büyük Veri (BIG DATA) Analizi, Veri Madenciliği, Gelişmiş Analitik, Makine Öğrenmesi (Machine Learning-ML) ve Endüstriyel Nesnelerin İnterneti (Internet of Things-IoT) gibi teknolojilerin entegrasyonu sayesinde akıllı üretim ortamları oluşturulabilir. Bu sayede, yüksek kaliteli ve düşük maliyetli ürünler üretmek mümkün hale gelebilmektedir (Wu vd 2017). Endüstri 4.0'da makineler çevreleriyle akıllı bir şekilde etkileşime girebilmekte ve davranışlarını ve süreçlerini uyarlamayı öğrenebilmektedir. Endüstri 4.0, yapay zekâ teknolojileri sayesinde makinelerin daha akıllı hale gelmesini sağlamaktadır. Yapay zekâ teknolojilerinin, Endüstri 4.0 dönüşümü ile imalat, üretim, lojistik ve endüstri gibi sektörlerde kullanılarak, üretkenliği ve verimliliği artırabilir, üretim maliyetlerini optimize edebilir ve manuel hataları azaltarak üretim sürecini otomatikleştirebilir. Bu doğrultuda günümüzde imalat, seri üretimden özelleştirme ile

karakterize edilen bir endüstriye hızla dönüşmektedir (Balamurugan vd 2019; Hassani vd 2019).

İmalat sanayisinin gelişmesi ve teknolojinin hızla ilerlemesiyle birlikte ülkelerin rekabet gücünün önemi ortaya çıkmıştır. Artan rekabet ortamında imalatta sürdürülebilir olmayı hedefleyerek, uygun maliyet ve üretimi artırmak gibi yenilikleri keşfetmek için yapay zekâ teknolojileri önem kazanmaktadır. Uygulamada zaman alan mühendislik çalışmalarının, yapay zekâ teknolojisiyle çok hızlı bir şekilde yapılması mümkün hale gelmiştir. Örneğin imalat sektöründe, yapay zeka kullanılarak, ekipman bakımlarının gerçek zamanlı olarak yapılması ve sanal gerçeklik aracılığıyla tasarımın hızlı bir şekilde oluşturulması gibi işlemler gerçekleştirilmesi ile zamandan tasarruf sağlanmaktadır. Ayrıca yapay zekâ algoritmalarının sanayi teknolojilerinde kullanımı ürün kalitesi, yönetimi, tasarımı ve verimliliği gibi birçok alan da önemli rol oynamaktadır (Li vd 2017).

Sanayideki teknolojik gelişmeler, geleneksel olan üretim sistemlerini değiştirmesi ile üretim kapasitelerini artırmakta ve makineleşmeye bağlı olarak da enerji, hammadde ve çevre sorunlarını giderek artırmaktadır. İnsanlık, teknolojik koşullar altında hızla gelişen sanayileşmenin üretim ve tüketim alışkanlığında ki köklü değişime sebep olmasından dolayı her geçen gün enerji, hammadde ve çevre sorunları ile daha da fazla yüzleşmektedir.

Sanayideki hızlı teknolojik gelişmeler, geleneksel üretim sistemlerinin yerini modern ve verimli yöntemlere bırakarak üretim kapasitelerini artırmakta ve endüstrinin büyümesine önemli katkılar sağlamaktadır. Ancak, bu sürekli ilerleme beraberinde enerji kaynaklarının tükenmesi, hammadde sıkıntıları ve çevre sorunları gibi çeşitli önemli konuları da beraberinde getirmektedir.

Bu sebeple, triboloji alanındaki araştırmalar ve uygulamalar, sanayinin çevresel etkilerini azaltmak için çeşitli yöntemler sunmaktadır. Özellikle yüzeylerdeki sürtünmenin kontrol altına alınması ve aşınmaların azaltılması sayesinde enerji verimliliği artırılmakta ve böylece enerji kaynaklarının daha etkin kullanımı sağlanmaktadır. Aynı zamanda, triboloji sayesinde malzeme ve kaplama teknolojilerindeki gelişmelerle birlikte enerji ve malzeme tasarrufu elde edilerek, hammadde sıkıntılarına yönelik çözümler üretilmektedir (Baydemir 2021).

Triboloji, yüzeylerin birbirleriyle temasında meydana gelen sürtünme, aşınma ve yağlama gibi olayların incelenmesidir. Bu olaylar, birçok endüstriyel uygulamada önemli bir role sahip olup, ciddi enerji ve malzeme kayıplarına neden olmaktadır. Sürtünme, yüzeylerin birbirine temas etmesi ve bu temas sırasında ortaya çıkan kuvvetlerdir. Sürtünme kuvvetleri, hareketi engelleyebilir veya yavaşlatabilir, dolayısıyla enerji kaybına neden olabilir. Sürtünme

kayıpları, araç motorlarından endüstriyel makinelere kadar birçok uygulamada ciddi bir sorun olarak karşımıza çıkmaktadır. Aşınma ise, yüzeylerin sürtünme sonucu yavaş yavaş yıpranmasıdır. Bu yıpranma, malzeme kaybı ve ömrünün kısılmasına neden olur. Aşınma, özellikle endüstriyel makinelerde ciddi bir sorun olarak kabul edilir ve yıllık milyarlarca dolarlık kayıplara neden olmaktadır. Yağlama, yüzeyler arasındaki sürtünmeyi azaltmak veya ortadan kaldırmak için kullanılan bir yöntemdir. Yağlama, sürtünme kayıplarını azaltarak enerji verimliliğini artırır ve buna bağlı olarak aşınma oranının azalmasına neden olmaktadır. Bu nedenle, yağlama teknolojisi, endüstriyel uygulamalarda yaygın olarak kullanılmaktadır. Özetle, tribolojik olaylar, endüstriyel uygulamalarda önemli bir role sahiptir. Bu nedenle, triboloji, endüstriyel verimliliği artırmak için önemli bir araştırma alanıdır (Bhushan 2013; Stachowiak ve Batchelor 2013; Holmberg ve Matthews 2006).

Triboloji alanında yapılan araştırmaların verimliliğini artırmak için, farklı malzemelerin sürtünme ve aşınma özelliklerini geliştirmek amacıyla veriye dayalı analizler yapılmaktadır. Bu analizler, çok sayıda veri elde edilmesi ve bilgisayar sistemlerinin modern hesaplama gücü sayesinde veri odaklı yeni yaklaşımların geliştirilmesini mümkün kılmaktadır. Büyük Veri analizinin geleneksel teknikler için engeller oluşturmamasından dolayı veri odaklı Yapay Zekâ (AI) ve Makine Öğrenimi/Öğrenmesi (ML) algoritmaları yeni korelasyonlar geliştirmektedir. Bu veri odaklı yaklaşımlar tribolojide yeni bir alan olan "Triboinformatik" veya "Akıllı Triboloji" uygulamasını ortaya çıkarmıştır. Triboinformatik, triboloji standartlarını ve veri tabanlarını oluşturarak triboloji bilgilerini toplamak, sınıflandırmak, depolamak ve analiz etmek için bilgisayar biliminin kullanılmasıdır. Triboinformatiğin amacı; tribolojinin araştırma verimliliğini ve sürecini geliştirmektir. Triboinformatik, Triboloji 4.0 kavramıyla da ilişkilidir. Triboloji 4.0, Endüstri 4.0'ın bir parçası olarak triboloji alanının dijitalleştirilmesini ve veri tabanlı yönetimini ifade eder. Bu kavram, triboinformatiği de içine alarak, tribolojik bilgilerin Endüstri 4.0 prensipleriyle kullanılmasını ve üretim süreçlerinin daha akıllı ve veri odaklı hale getirilmesini hedeflemektedir (Hasan vd 2021; Zhang vd 2021; Marian ve Tremmel 2021).

Triboloji alanında, çeliklerin önemi oldukça büyüktür. Çünkü tribolojik olaylar, yüzeylerin teması sırasında oluşur ve çelikler, uygulamalarda yaygın olarak kullanılan yapısal malzemelerin başında gelmektedir. Bu nedenle, triboloji ve çelikler birbirleriyle yakından ilişkilidir ve birçok uygulamada bir arada kullanılırlar. Çelikler, makine elemanlarının üretilmesi ve geliştirilmesi alanında çok çeşitli yapı ve özelliklere sahip olduklarından en çok kullanılan metalik malzemelerdir. Çelik malzemeler içerisinde önemli kullanım alanına sahip olan AISI 4140 çeliği, düşük alaşımlı çelikler arasında yer alan bir çelik türüdür. AISI 4140 çeliği, yüksek karbonlu çeliklerle karşılaştırıldığında daha düşük karbon içeriğine sahiptir.

Ancak Krom (Cr), Molibden (Mo) ve Manganez (Mn) gibi diğer alaşım elementleriyle güçlendirilmiştir. Bu alaşımlar, AISI 4140 çeliğine yüksek mukavemet, sertlik ve dayanıklılık kazandırır. AISI 4140 çeliği, sertleştirilerek yüzey sertliği artırılabilen bir çeliktir ve sertleştirme sonrası mukavemeti yüksektir. Genellikle yüksek mukavemet gerektiren otomotiv, havacılık ve imalat gibi birçok endüstriyel alanda yaygın olarak kullanılmaktadır (Kessler vd 2004).

Yukarıda da bahsedildiği üzere malzemelerin sürtünme ve aşınma davranışlarının incelenmesi hem mevcut malzemelerin özelliklerinin iyileştirilmesi hem de yeni malzemelerin tasarımı açısından büyük önem taşımaktadır. Bununla birlikte, bu incelemelerin Triboinformatik kapsamında ele alınması büyük önem taşımaktadır. Bu sayede elde edilen veriler anlamlı bir şekilde sunulabilecek ve Yapay Zekâ algoritmaları/yaklaşımları ile bu verilerden faydalanılarak malzemelerin tribolojik özellikleri tahmin edilebilecektir. Bu kapsamda, özellikle son yıllarda Yapay Zekâ kullanarak malzemelerin tribolojik özelliklerini inceleyen çalışmalar yapılmaya başlanmıştır.

Argatov ve Chai (2019), Yapay Sinir Ağı (Artificial Neural Network-ANN/YSA) destekli bir regresyon modeli kullanarak yaptıkları araştırmada aşınma oranı için Archard Aşınma Yasasını esas alarak, Yapay Sinir Ağı destekli regresyon modeli geliştirmişlerdir. Pirinç kabuğu külü (RHA) ile güçlendirilmiş alüminyum alaşımlı kompozitin aşınma deneylerinden elde edilen veri setini kullanmışlardır. Tribolojik davranışın modellenmesi için, doğrusal olmayan regresyonun yanı sıra yapay sinir ağlarının da etkili bir şekilde kullanılabileceği sonucuna varmışlardır.

Kannaiyan ve Raghuvaran (2020), gerçekleştirdikleri çalışmada Yanıt Yüzey Metodu (Response Surface Method-RSM) ve Yapay Sinir Ağı (ANN) algoritmalarının aşınma oranı tahminlerini kıyaslamışlardır. Bu çalışmada, LM25/ZrO₂ kompozitin tribolojik davranışının farklı yüklerde ve kayma mesafelerinde tahmin edilmesi amaçlanmıştır. Deneysel veriler kullanılarak RSM ve ANN modelleri oluşturulmuş ve bu modellerin korelasyon sonuçları sırasıyla 0.8468 ve 0.9999 olarak hesaplanmıştır. Bu sonuçlara göre, RSM tahmininin ANN tahminine göre daha fazla sapma gösterdiği bildirilmiştir. Ayrıca ANN ve RSM tarafından tahmin edilen aşınma kaybı değerlerinin sonuç karşılaştırması, %99 güven seviyesi ile deneysel olarak kaydedilen değere yakın olduğu kanıtlanmıştır.

Hasan vd (2021), triboinformatik modelleme yaklaşımıyla alüminyum esaslı alaşımların kuru sürtünme ve aşınma davranışlarını tahmin etmek için Makine Öğrenimi (ML) algoritmaları üzerine bir çalışma yapmışlardır. Gerçekleştirdikleri çalışmada, literatürde bildirilen tribolojik verileri kullanılarak; sürtünme katsayısı ve aşınma oranı tahmini için beş

farklı ML algoritması eğitilmiştir. Deneysel tribolojik veriler kullanılarak: K-En Yakın Komşu (KNN), Destek Vektör Makinesi (SVM), Yapay Sinir Ağı (ANN), Rastgele Orman (RF) ve Gradyan Artırma (GBM) makine öğrenmesi algoritmalarını eğitilmiştir. Eğitilen ML algoritmalarının model daha iyi performans gösterdiğini, KNN'nin ise sürtünme katsayısı tahmininde en iyi performansı performanslarının karşılaştırmalı analizi: RF'nin aşınma oranı tahmininde diğer ML modellerinden sergilediğini göstermiştir. Tribolojik davranış açısından normal yük, sertlik ve kayma hızının alaşımların aşınma oranını tahmin etmede maksimum etkiye sahip olduğu ifade edilmiştir. Ayrıca alaşımların sertliğindeki ve kayma mesafesindeki değişimlerin, ML tahminini en çok etkileyen parametreler olduğu vurgulanmıştır.

Thankachan vd (2021), bakır esaslı kompozitlerde kuru kayma şartında aşınma oranlarını tahmin etme ve analiz etmede ML modellerinin ve istatistik yöntemlerinin uygulanması üzerine araştırma gerçekleştirmiştir. Grafit, Molibden Disülfid (MoS_2), Bor Nitrür (BN) ve Karbon Nanotüpler (CNT) gibi birçok kendi kendini yağlayan parçacığı çeşitli taban malzemelere etkili bir şekilde dağıtılması ile malzemenin tribolojik özelliklerini artırmak için bu yapıların takviye olarak kullanıldığını belirtmişlerdir. Aşınma oranının deneysel analizinde, Deney Tasarımı (Design of Experiments-DOE) olarak adlandırılan bir istatistiksel araç kullanılmıştır. DOE'nin temel amacı, deneylerin sayısını ve maliyetini azaltırken, sistemin performansını en üst düzeye çıkarmaktır. Bu çalışma, deney tasarımına dayalı denemeleri eğitmek, simüle etmek ve belirli kontrol faktörlerine dayalı olarak kuru kayma aşınma oranını tahmin edebilen bir model elde etmek için ANN tabanlı hesaplama modelinin başarılı bir şekilde kullanıldığını göstermiştir.

Singh vd (2022), grafen dolgulu cam elyaf takviyeli polimer kompozitin deneysel verileri ile aşınma oranlarını tahmin etmek için ML algoritmaları kullanarak tahmine dayalı modelleme oluşturmuşlardır. Veri kümelerinin tahmine dayalı modelini oluşturmak için Derin Sinir Ağı (DNN), Gradient Boosting Machine (GBM), Random Forest (RF) ve Aşırı Gradyan Artırma (Extreme Gradient Boosting Machine- XGboost) olmak üzere dört farklı ML algoritması kullanarak modellerin karşılaştırmalı performansını incelemişlerdir. Bu çalışmada kullanılan ML algoritmalarının, sonuçları %98'e kadar doğru bir şekilde tahmin ettiği bildirilmiştir. ML algoritmasının verdiği en başarılı sonuçların DNN ve XGboost ile elde edildiği ifade edilmiştir.

Santhosh vd (2022), gerçekleştirdikleri çalışmada yüksek performanslı hibrit Alüminyum AA5083/Uçucu Kül/WC kompozit malzemenin aşınma ve sürtünme davranışını değerlendirmek için ML algoritmalarından faydalanmışlardır. Alüminyum AA5083 esaslı kompozit numuneler basınçlı kaplar, denizaltılar ve otomotiv motor bileşenleri gibi

uygulamalarda sıklıkla kullanıldığından dolayı, matriste Uçucu Kül ve WC hibrit takviyelerinin otomotiv motor bileşenlerinde, uçak braket montaj çerçevelerinde, vagon gövdelerinde ve basınçta kullanım için yüksek performanslı bir hibrit kompozitin geliştirilmesine yönelik yeni bir yaklaşımı araştırmışlardır. Bu çalışmaların da aşınma oranını ve sürtünmeyi tahmin etmek için Yapay Sinir Ağı (ANN), K-En Yakın Komşu (KNN), Destek Vektör Makinesi (SVM) ve Derin öğrenme (DL) algoritmaları kullanılmıştır. Sürtünme katsayısı ve aşınma oranının; ANN ve DL algoritmaları ile gerçek sonuçlara daha yakın bir tahmin edildiği ve bu sebeple de bu modellerin yüksek performans gösterdiği sonucuna varılmıştır.

Wang vd (2022), Molibden Disülfid (MoS_2) ile kaplanmış bakırın tribolojik performansını ML yaklaşımı kullanarak tahmin etmeye çalışmıştır. Değişen kalınlıklarda hazırlanmış numunelerin farklı yükler altında elde edilen test parametreleriyle kaplamaların sürtünmesi ve aşınması arasındaki korelasyonlar, ML algoritmasından Gradyan Artırma Regresyon Ağacı (Gradient Boosting Regression Trees - GBRT) modeliyle sürtünme katsayısı (COF) ve aşınma oranı tahmini araştırılmıştır. GBRT, ML modellerinin test setlerindeki sürtünme katsayısı ve aşınma oranı performansları değerlendirilerek modelin başarılı bir uygulama olduğu sonucuna varıldığı bildirilmiştir.

Baydoun vd (2023), düşük alaşımlı çeliğin farklı yükleme koşulları altında brüt kaymalı aşınma hacmini tahmin etmek için fiziksel ve ML modellemesini birbiri ile kıyaslamıştır. Yapılan karşılaştırma ile fiziksel modellemenin kalibrasyon işlemi için sınırlı sayıda deneysel veri mevcut olduğunda ANN'den daha yüksek performansa sahip olduğu sonucuna varılmıştır.

Literatür çalışmalarında farklı olarak kullanılan AISI 4140 düşük alaşımlı çelik malzemenin sürtünme ve aşınma davranışını anlamak ve tahminlemek amacıyla farklı makine öğrenmesi algoritmaları ve çeşitli tribolojik parametreler kullanacaktır. Tribolojik parametreler farklı ortamlarda, farklı yük seviyelerinde, farklı sürelerde ve hızlarda gerçekleştirilecektir. Tribolojik elde edilen veri setleri, sürtünme ve aşınma oranını içerecektir. Bu veriler, farklı makine öğrenmesi algoritmaları aracılığıyla analiz edilecek ve sürtünme katsayısı ile aşınma oranını tahminlemek için kullanılacaktır. Çalışmanın amacı deneylerin maliyetini azaltabilmesini ve malzeme araştırma ve geliştirme sürecini hızlandırabilmesini ve materyal tasarımı konusunda iyi bir rehberlik sağlayabilmesini amaçlanmaktadır.

KURAMSAL TEMELLER

Triboloji

Triboloji, birbirleri ile bağıl hareket hâlindeki yüzeylerin sürtünme, aşınma ve yağlama olaylarını inceleyen bilim ve mühendislik alanıdır (Şekil 1). Yüzeylerin birbirine karşı kaymadığı veya hareket etmediği mekanik sistemler nadirdir ve bu nedenle triboloji, çok geniş uygulamalara ve araştırmalara olanak sağlayan bir teknoloji alanıdır. Tribolojideki gelişmeler, dünyadaki mühendislik gelişmelerinin birçoğunun temelini oluşturmaktadır. Günümüz teknolojisi, yüzeylerin birbirleriyle olan hareketliliğiyle ilgili etkileşimli yüzey bilimini kapsayan bir alana yayılmıştır. Kısacası triboloji, sürtünme ve aşınmayı azaltmak için yüzey-yüzey temasının incelenmesidir (Gohar ve Rahnejat 2018; Hutchings ve Shipway 2017).




Şekil 1. Tribolojide incelenen sürtünme, aşınma ve yağlama ilkeleri

Sürtünme

Mekanik olarak birbirleriyle temasta halinde bulunan ve kayma hareketi yapan yüzeyler arasındaki etkileşimler sürtünme ve aşınmaya neden olur. Buradan hareketle sürtünme, temas halinde bulunan malzemelerin izafi hareketleri sonucunda oluşan enerji kaybı olarak tanımlanabilir. Bu karmaşık ve mikroskobik etkileşimler malzemelerin veya sistemlerin çalıştıkları ortam, sıcaklık, yükleme şartı, temas tipi, geometrisi gibi parametrelere bağlıdır. Yüzey etkileşimleri ve atmosferik değişkenler tribolojik sisteme ait tüm mekanik, kimyasal, fiziksel ve geometrik özellikleri etkiler. Genel anlamda sürtünme kuvveti, bir dış kuvvetin etkisi altında bir cismin diğerine göre izafi hareket ettiğinde veya hareket etme eğiliminde olduğunda, harekete karşı arayüze teğet olarak etki eden kuvvet olarak tanımlanır.


İzafi hareket yapan yüzeyler arasına bir ara eleman olarak yağlayıcı madde konulması veya konulmaması durumuna göre Şekil 2’de gösterildiği gibi sürtünme kuru, sınır ve sıvı sürtünme olmak üzere üç şekilde incelenebilmektedir (Buckley 2000; Hutching vd 2011).



Şekil 2. Sürtünme mekanizmaları (Akkurt, 1990)

Kuru sürtünme

Kuru sürtünme, izafi hareket halinde bulunan ve yağlanmamış kuru parça yüzeyleri arasında oluşan sürtünme durumudur (Şekil 2 ve Şekil 3). Doğrudan temas halinde bulunan yüzeylerin pürüzleri birbirleri üzerinde kayarlar ve yüzeyler arasında üçüncü bir malzeme olarak yağlayıcı madde yoktur (Czichos 1986; Buckley 2000).




Şekil 3. Kuru sürtünme mekanizması

Genel olarak, sürtünmeyi tanımlamak için sürtünme katsayısı terimi kullanılır. Teorik olarak kuru sürtünme modeli Coulomb-Amontons kanunu esas alınır: F_n normal kuvvet etkisi altında izafi hareket yapan iki cismin temas yüzeyleri arasındaki harekete ters şekilde tanımlanan bir sürtünme kuvvetinin olduğu görülür (Şekil 3). İzafi hareket, cismin konumunun ve/veya hızının değiştiği hareket şeklidir. Sürtünme katsayısı μ boyutsuz bir sayıdır ve sürtünme kuvveti (F_s) ile iki cismi birbirlerine karşı uyguladıkları normal kuvvet (F_n) arasındaki oran olarak tanımlanır. Kuru sürtünme, Denklem 1’de verilen ve “Coulomb-Amontons Yasası” olarak bilinen formül ile tanımlanır (Jeyaparakash ve Yang 2020; Hutchings vd 2011).

$$\mu = \frac{F_s}{F_n} \quad (1)$$

Normal kuvvetin (F_n) etkisi altında bulunan iki cismin temas yüzeyleri arasında harekete karşı, $F_s = F_n \cdot \mu$ şeklinde bir statik sürtünme kuvveti oluşur. Şekil 4'te görüldüğü gibi bir F_n kuvveti uygulandığında eğer $F_s > F_n$ ise yani sürtünme kuvveti normal kuvvetten daha büyükse, F_n kuvvetine rağmen izafi hareket oluşmaz. Ancak hareket olmamasına rağmen yüzeyler arasında bir sürtünme kuvveti mevcuttur. Buna statik sürtünme denir. $F_s < F_n$ olması durumunda ise F_n kuvveti daha büyük olduğundan yüzeyler birbirleri üzerinde kayarlar bu tip sürtünmeye ise kinematik/kinetik sürtünme denir (Young vd 2013).




Şekil 4. Kuru sürtünme modeli

Sürtünme katsayısı, yüzeyler arasındaki sürtünme kuvvetini hesaplamak için uygun bir yöntemdir. Bu katsayı, temas halindeki yüzeylerin bileşimine, topografyasına, maruz kaldıkları ortama ve yükleme koşullarına bağlıdır. İki yüzey arasındaki sürtünme katsayısı, yüzeylerin pürüzlülüğüne bağlıdır. Pürüzlü yüzeyler arasındaki sürtünme katsayısı, düz yüzeylere göre daha yüksektir. Ayrıca, sıcaklık, nem ve basınç gibi çevresel faktörler de sürtünme katsayısını etkileyebilir. Sürtünme katsayısı aynı zamanda, iki yüzey arasındaki temas kuvvetinin büyüklüğüne de bağlıdır. Temas kuvveti arttıkça, sürtünme katsayısı da genellikle artar. Bu nedenle, sürtünme katsayısı, yüzeyler arasındaki sürtünme kuvvetini hesaplamak için önemli bir parametredir ve bu katsayı, yüzeylerin özelliklerine ve uygulanan yük koşullarına bağlı olarak değişir. Genellikle, iki farklı sürtünme katsayısı vardır: Statik sürtünme katsayısı ve kinetik sürtünme katsayısı (Hutchings vd 2011).


Statik sürtünme katsayısı (μ_s), bir cismi harekete geçirmek için uygulanan maksimum kuvvetin hesaplanması için kullanılır. Bir cisim, üzerine etki eden kuvvetin büyüklüğü statik

sürtünme kuvvetini aşımadığı sürece hareketsiz kalır. Statik sürtünme katsayısı, yüzeyler arasında yapışma eğilimini ifade eder. Statik sürtünme katsayısı ne kadar yüksek ise, yüzeylerin birbirine yapışma eğilimi de o kadar büyük olur ve cismin hareketsiz kalma eğilimi artar. Kinematik/Kinetik sürtünme katsayısı (μ_k) ise, hareket halindeki bir cismin sürtünme kuvvetinin hesaplanması için kullanılır. Hareket halindeki bir cismin üzerindeki sürtünme kuvveti, cismin hızına veya ivmesine bağlı olarak değişir. Kinematik sürtünme katsayısı, yüzeyler arasındaki sürtünmenin sürekliliğini ifade eder (Şekil 6). Bu katsayılar, sürtünme olayının çeşitli yönlerini veya özelliklerini gösterir ve cisimlerin hareketini etkileyen önemli faktörlerdir (Rebai 2014).



Şekil 5. Sürtünme kuvveti-Uygulanan kuvvet grafiği


Statik sürtünme katsayısı genellikle kinematik sürtünme katsayısından daha büyüktür. İlk hareketi başlatmak daha fazla kuvvet gerektirir çünkü sürtünme, cismin hareketini engeller. Ancak, bir kez hareket başladıığında, kinematik sürtünme katsayısı devreye girer ve sürtünme kuvveti hareketle birlikte değişir (Şekil 6).



Şekil 6. Sürtünme katsayısı-Kayma hızı grafiği: Statik sürtünme katsayısı ve Kinematik sürtünme katsayısı

Sınır sürtünme


Teorik kuru sürtünme ile sıvı sürtünmesi arasındaki bölge sınır sürtünme olarak adlandırılır. Sınır sürtünme, kısmen kuru sürtünme ile kısmen sıvı sürtünme şartlarının etkili olduğu sürtünme şeklidir (Şekil 7). Başka bir ifadeyle yağlayıcı yüzeyleri birbirinden tam olarak ayırmıyorsa sınır sürtünme meydana gelir. Bu durumda birbiri ile temas halinde bulunan yüzeyler arasında belirli yük ve hız koşullarında kesintisiz bir yağ filmi mevcut değildir (Heywood 1988; Larsen 1992).



Şekil 7. Sınır sürtünme mekanizması


Sıvı sürtünme

Sıvı sürtünmesi, birbirine karşı izafi hareket eden iki katı cisim arasında bulunan yüzey pürüzlerinin birbiriyle temas etmeyecek şekilde bir yağ tabakası tarafından tamamen ayrılmış olduğu sürtünme halidir (Şekil 8). Sıvı sürtünmesi hidrodinamik ve hidrostatik sıvı sürtünmeleri olmak üzere iki duruma bağlıdır. Hidrodinamik sıvı sürtünmesinde, yağlama yağının hareketi tarafından yaratılan basınç, temas yüzeyleri arasında bir yağ filmi oluşturmak için yeterli olduğunda oluşur. Temas yüzeyleri arasında yağ tabakasında oluşan basınç dış kuvveti dengeleyecek bir değere ulaştığında yüzeyler birbirinden tamamen ayrılmış olur (Lyashenko 2011). Hidrostatik sıvı sürtünmesinde ise, dış kuvvetin dengelenmesi ve yüzeylerin birbirinden ayrılması için gereken basınç, dışardan yüksek basınçlı bir pompa yardımıyla sağlanır. Bu iki durumda da yağ filmi, temas yüzeylerinin tamamen ayrılmasını ve dolayısıyla sürtünmeyi azaltır (Khonsari vd 2010).



Şekil 8. Sıvı sürtünme mekanizması

Stribeck eğrisi ise triboloji ve yağlama alanlarında temel ve en çok bilinen kavramdır ve sürtünme davranışını tanımlayan bir eğri olarak bilinir. Stribeck eğrisi, sürtünme kuvveti ile kayma hızı arasındaki ilişkiyi gösteren bir eğridir (Şekil 9) ve karmaşık, doğrusal olmayan bir ilişkiyi tanımlar. Bu eğri, tribolojik uygulamalarda sıklıkla kullanılmakta ve tribolojik sistemlerin performansının değerlendirilmesinde önemli bir rol oynamaktadır. Stribeck eğrisi; kuru, sınır ve sıvı sürtünme bölgeleri olmak üzere üç farklı sürtünme mekanizmasını gösterir ve bu bölgelerin her birinde sürtünme katsayısı ve kayma hızı arasındaki ilişki farklıdır. Eğrinin başlangıç noktası, hareketsizken var olan statik sürtünmeye karşılık gelir. Eğrinin ilk bölgesi düşük kayma hızlarında kuru sürtünme bölgesidir. Bu bölgede, sürtünme katsayısı sürekli olarak artar ve maksimum değere ulaşır. Çünkü yüzeyler arasında doğrudan temas vardır ve sürtünme genellikle kuru yüzeyler arasında gerçekleşir. Yüzeyler arasında yağlama veya sıvı film yoktur. Kuru sürtünme bölgesinden daha yüksek kayma hızlarında, sınır sürtünmesi bölgesine girilir. Bu bölgede sürtünme katsayısı yavaş yavaş azalır ve minimuma ulaşır çünkü yüzeyler arasında bir sıvı tabakası bulunur. Ancak bu tabaka yeterli miktarda basınç altında olmadığından tamamen ayrılmaz. Yüzeyler arasındaki temas ve sürtünme azalır. Sıvı filmi yetersiz olduğu için yüzeyler arasındaki temas noktaları önemli bir rol oynar. Son olarak, sıvı sürtünme bölgesine girilir. Bu bölgede sürtünme katsayısı tekrar yükselir çünkü yüzeyler arasında tam bir sıvı filmi oluşur ve sürtünme çoğunlukla bu film arasında gerçekleşir. Yüzeyler arasındaki sıvı filmi tam olarak oluştuğu için sürtünme artar. Bu bölgede, yüksek hızlara bağlı olarak sıvı filmi etkili bir şekilde ayrılmaz ve sürtünme miktarı artar (Bograd vd 2011).



Şekil 9. Stribeck eğrisi: Sürtünme Katsayısı-Kayma Hızı (Bahşiyev ve Selçuk 2017)

Aşınma

Aşınma, katı bir maddenin yüzeyinde meydana gelen hasar olarak tanımlanır. Aşınma, birbirine temas eden hareketli yüzeylerde malzeme israfı ve mekanik performans kaybına sebebiyet verdiğinden malzemelerin kullanım ömrünü etkileyen başlıca neden olarak gösterilmektedir. Temas halindeki yüzeyler birbiri üzerinde hareket etmesiyle aşınmaya maruz kalırlar (Halling 1977; Hutchings 1993).


Yüzeyler birbiri üzerinde izafi olarak hareket ettiklerinde, yüzeylerin birinde veya her iki yüzeyde genellikle malzeme kaybını içeren hasar meydana gelir. Aşınma bazen fark edilemeyecek kadar az hasar oluşturabilir ancak aynı zamanda son derece hızlı bir şekilde ilerleyebilir.

Aşınma, çoğu zaman malzemeler için istenmeyen bir durumdur. Hareketli bileşenler arasındaki aşınma arttıkça, bu bileşenlerdeki boşluklar artar ve sonuçta hassasiyet kaybına ve hatta tamamen arızalanmaya neden olabilir. Genellikle titreşim ve artan mekanik yüklemeler, aşınma hızını artırarak bileşenlerin ömrünü kısaltabilir. Ayrıca, yorulma nedeniyle sürekli değişen yüklemelerinin neden olduğu hasarlar nedeniyle meydana gelir ve büyük ve karmaşık makinelerin tamamen arızalanmasına yol açabilir. Sürtünmeyi ve aşınmayı azaltmanın en temel ve bilinen yöntem, sistemi yağlamaktır. Aşınma hasarının çok farklı türleri bulunmaktadır.

Ancak burada, temel ve en önemli olarak kabul edilen dört temel aşınma türü ele alınmıştır: Adezif Aşınma, Abrazif Aşınma, Yorulma Aşınması ve Korozyon Aşınma (ASTM 2005; Hutching vd 2011).

Adezif aşınma

Yapışma aşınması olarak da bilinen adezif (adhesive) aşınma birbirleri ile temas halinde olan iki malzeme yüzeyinde bulunan pürüzlerin uygulanan normal kuvvetin etkisiyle temas arayüzünde adezyon meydana geldiğinden daha yumuşak olan yüzeyden parça kopmasıdır. Daha az sertliğe sahip olan yüzeyden kopan pürüzlerin uçlarının plastik olarak kesilmesi ve ardından karşı yüzeye yapışması esasına dayanmaktadır (Şekil 10). Yüzeylerin yapışması sonucu kopan parçalar, malzemenin kaybına ve yüzeylerin pürüzlü hale gelmesine neden olur. Adezif aşınmayı azaltmak için yüzeyler arasında uygun bir yağlama yapılması, malzemenin sertliğinin artırılması ve/veya yüzeye uygulanan yükün azaltılması gerekmektedir. (Hirani 2019; Jiménez ve Bermúdez 2011).



Şekil 10. Adezif aşınma (Kopeliovich 2023)

Adezif aşınma: Archard modeli ile açıklanabilir. Holm ve Archard'ın aşınması teorisi, aşınmayı etkileyen ana değişkenleri esas almaktadır. Bununla birlikte, aşınma oranını Archard'ın modelinde tarif edildiği gibi normal yük, gerçek temas alanı ve kayma mesafesi ile ilişkilendirmek mümkündür (Marinescu vd 2012). Adhezyon aşınmasında pürüzlerden koparak uzaklaşan malzemenin hacmi (V) Denklem 2'de tanımlanmıştır.

$$V = K * A * S \quad (2)$$

V = Aşınan malzeme hacmi

K = Archard sabiti olarak bilinen birimsiz Aşınma Katsayısı

A = Gerçek temas alanı

S = Kayma mesafesi

Gerçek temas alanı olan A , normal kuvvetin (F_n) malzeme sertliğine (H) oranıdır (Denklem 3).


$$A = \frac{F_n}{H} \quad (3)$$

Aşınma teorisi asıl olarak metaller için geliştirilse de diğer malzemeler için de sınırlı olarak kullanılabilmektedir. Aynı zamanda, Aşınma katsayısı (K), diğer parametrelerin yanı sıra kayma koşullarının, yüzey topoğrafyasının ve ortamın bir özelliğini de içermektedir. Aşınma oranı (W_r), Denklem 4'te verildiği gibi aşınma hacminin (V) normal yük (F_n) ile kayma mesafesi (S)'nin çarpımına bölünmesiyle elde edilir (Burris ve Sawyer, 2009).

$$W_r = \frac{V}{F_n * S} \text{ (mm}^3\text{/N * m)} \quad (4)$$


Abrazif aşınma

Malzeme yüzeylerine yüksek miktarda hasara neden olabilen abrazif (abrasive) aşınma kazıma ya da çizilme aşınması olarak da bilmektedir. Abrazif aşınmanın iki cisimli aşınma ve üç cisimli aşınma olarak iki temel şekli vardır. Birbirleri ile temas halinde bulunan iki yüzeyden daha sert olan yüzeyin yumuşak olan yüzeyinde bulunan pürüzlerden kayma hareketi esnasında parçacık koparması ile meydana gelmektedir (Şekil 11). Kopan parçacık ara temas yüzeyini çizerek yüzeyde iz oluşturur. Abrazif aşınma, sert partiküllerinin veya sert çıkıntıların katı bir yüzey boyunca hareket etmesi ve bu harekete karşı koymasından dolayı oluşmaktadır. Abrazif aşınmada partiküller yüzeye dışarıdan girerek de aşınmaya sebep olabilmektedir (Yusoff ve Jamaludin 2011).



Şekil 11. İki cisimli abrazif aşınma modeli (Kopeliovich 2023)


Üç cisimli abrazif aşınma ise Şekil 12'de gösterildiği gibi temas eden yüzeyler arasında sert parçacıklara ek olarak üçüncü bir parçacığın veya partikülün serbestçe hareket etmesiyle yüzeylerde oluşan kazıma veya çizme etkisinin oluşma durumudur (Stachowiak ve Batchelor 2013).



Şekil 12. Üç cisimli abrasif aşınma modeli (Kopeliovich 2023)

Yorulma aşınması


Yorulma aşınması, temas yüzeylerinin tekrarlı olarak sabit veya değişken yüklere maruz kalmasıdır (Şekil 13). Temas sonucu yüzeylerin içyapısında plastik deformasyona bağlı olarak oluşan küçük boşlukların zamanla yüzeye ilerlemesi ile yüzeyden küçük parçaların kopması sonucu meydana gelen aşınmadır (Xianqiang vd 2005).



Şekil 13. Yorulma aşınma modeli (Kopeliovich 2023)

Korozif aşınma

Malzemenin en az bir temas yüzeyinin korozyonlu bir ortamda bulunması nedeniyle meydana gelen aşınma türüdür (Şekil 14). Yüzeyde kimyasal tepkimeler ile oluşan oksit tabakası gibi yüzey filmleri korozyonu önemli ölçüde yavaşlatmaktadır. Ancak mevcut yüzey filminin ara yüzey bağlarının kuvvetli olmaması veya kırılğan bir yapıda olması durumunda kayma hareketi ile film tabakası yüzeyden ayrılır ve malzeme yüzeyinde deformasyon meydana gelir. Ayrıca, malzeme yüzeyine etki eden bir kimyasal ile tepkimeye girmesi sonucu ortaya çıkan malzeme kaybı da bir korozif aşınma bir örneğidir (Boynueyri 2019).



Şekil 14. Korozyif aşınma modeli (Kopeliovich 2023)

Yağlama

Tribolojide yağlama, sürtünme ve aşınma problemlerinin azaltılması için önemli bir teknik olarak kabul edilir. Yağlama, bir yüzeyin diğer yüzeyler üzerinde kaymasını kolaylaştırarak sürtünme ve aşınmayı azaltır. Yağlama, viskozite, yağlama yağı tipi, yağlama yağı sıcaklığı, yağlama yağı seviyesi ve yağlama yağı filtresi durumu gibi faktörlere bağlıdır. Birbiri ile temas halinde olan cisimlerin temas şartlarına ve yağlayıcı olarak kullanılan malzemenin fiziksel şartlarına göre yağlama türleri değişmektedir. Genel olarak yağlama; sınır yağlama, karışık yağlama, elasto-hidrokinamik yağlama ve hidrokinamik yağlama olmak üzere dört başlıkta incelenmektedir (Şekil 15).

- **1. Bölge:** Sınır Yağlaması, bir yağlama sistemi ile yağlanan yüzeyler arasında bir film tabakası oluşturulamadığı veya bu film tabakasının çok ince olduğu durumlarda meydana gelen bir sürtünme şeklidir. Sınır tabaka yağlaması, birbirine temas eden malzemelerin yüzeylerindeki çıkıntıların birbiriyle doğrudan temas etmesi sonucu oluşur. Bu durumda yağ filminin taşınması gereken yükü filmde çok yüzeydeki çıkıntılar taşır. Sınır tabaka yağlaması, özellikle yüksek basınç ve yüksek sıcaklık uygulamalarında ve yüksek hızlı dönen makine parçalarında sıklıkla meydana gelir. Sınır tabaka yağlamasını önlemek için yağlama sistemi ve yağlama yağı özellikleri uygun şekilde seçilmeli ve düzenli bakım yapılmalıdır (Rabinowicz 1995; Taylor ve Wedeven 1996; Bhushan 2000).
- **2. Bölge:** Karışık tabaka yağlaması, sınır tabaka ve elasto-hidrokinamik yağlama arasında bir geçiş bölgesidir. Bu tip yağlama, yüzeyler arasındaki temasın olduğu noktalarda ince bir yağ tabakası oluşturur. Ancak yağ tabakası yeterince kalın değildir, bu nedenle yüzeyler arasında temas kısmen devam eder ve sürtünme kuvvetleri yüksek kalır. Yağ filmi, bazı noktalarda kopabilir ancak yine de malzemelerin yüzeyleri arasında bir film tabakası oluşur. Karışık tabaka yağlaması,

özellikle yüksek yükleme koşullarında ve düşük hızlarda ortaya çıkar. Bu koşullarda, elasto-hidrokinamik yağlama yeterli olmaz ve sınır tabaka yağlaması da yüzeylerin aşınmasını önleyemez. Karışık tabaka yağlama, yüzeylerin aşınmasını en aza indirmek için özel yağlar ve yüzey kaplamaları kullanılarak kontrol edilebilir. Bu tip yağlama, yüzeylerin ömrünü uzatmak ve enerji verimliliğini artırmak için optimize edilebilir (Elcoate vd 2012; Stachowiak ve Batchelor 2013).

- **3. Bölge:** Elasto-hidrokinamik yağlama (EHD), yüksek basınçlı yağlama durumlarında kullanılan bir yağlama yöntemidir. Bu yöntemde, yağlama malzemesi (genellikle yağ) sıkıştırılır ve yüzeyler arasındaki temasın önüne geçmek için kullanılır. EHD yağlama, yüzeyler arasındaki temasın önlenmesine ve aşınmanın azaltılmasına yardımcı olan bir filtreleme işlemi olarak düşünülebilir. Yüksek basınçlı yağlama durumlarında, yüzeyler arasındaki temasın önlenmesi için yağlama malzemesi genellikle yüksek viskoziteli bir yağdır. Ancak, bu durumda yağlama malzemesi sıkıştırıldığı için, yüzeyler arasında bir film tabakası oluşur ve temasın önlenmesine yardımcı olur. Elasto-hidrokinamik yağlama, birçok endüstriyel uygulamada kullanılan bir yöntemdir. Özellikle, otomotiv sektöründe, yüksek hızlı motorlarda ve dişli kutularında sıklıkla kullanılır. Elasto-hidrokinamik yağlama (EHD), yüksek yük ve hızlarda iki yüzey arasında oluşan elastik deformasyonların yağlama etkisine katkıda bulunduğu bir yağlama türüdür. Bu durum, yüzeylerin birbirine temas etmesini önleyerek aşınmayı ve hasarı azaltır (Mang ve Dresel, 2007; Gohar vd 2015).
- **4. Bölge:** Hidrokinamik yağlama, yağ filminin tamamen ayrıldığı ve yüzeylerin doğrudan temas etmediği bir yağlama türüdür. Bu tür yağlamada, yüzeyler arasındaki boşluğa bir yağlama filmini koruyacak kadar yağ doldurulur ve hareketli yüzeyler birbirlerine sürtünmeden kayarlar. Bu yağlama türü, yağ filminin malzeme yüzeylerindeki çıkıntıları tamamen kapladığı ve yükü taşıdığı durumlarda meydana gelir. Bu sürtünme azaltıcı etki, enerji kayıplarını ve ısı üretimini azaltarak makinelerin daha verimli çalışmasına yardımcı olur. Hidrokinamik yağlama, yağlama yüzeyi ile yatak yüzeyi arasındaki hız farkından dolayı ortaya çıkan bir hidrokinamik basınç oluşturarak yatak yüzeyleri arasında bir yağ filmi oluşturma yöntemidir. Hidrokinamik yağlama, sınır tabaka yağlama gibi diğer yağlama yöntemlerine göre daha etkilidir ve yüksek yük taşıma kapasitesine sahiptir. Hidrokinamik yağlama, makinelerin verimliliğini ve ömrünü artırmak için yaygın olarak kullanılan bir tekniktir (Mang ve Dresel 2007; Stachowiak ve Batchelor 2013).


Stribeck yasası, yağlama koşullarında sürtünme katsayısının yağlama film kalınlığına, yüzey hızına ve yağın viskozitesine bağlı olarak değiştiğini ifade eder. Stribeck yasası aşağıdaki şekilde ifade edilir(Çöl, 2013):

$$\log U + \log v - \log W = \text{sabit} \quad (5)$$

U: Yüzeylerin birbirine izafi hızı (m/s)

v: Kinematik viskozite (m^2/s)

W: Yük (N)



Şekil 15. Stribeck Eğrisi: sürtünme katsayısı ve film kalınlığı - yağlama parametresi (Coles vd 2010)


Endüstri 4.0

Endüstri devrimleri, tarih boyunca sanayi üretiminde önemli değişimlerin yaşandığı dönemlerdir. Bu değişimler, hem iş süreçlerini hem de toplumun genelindeki yaşam koşullarını etkiler. Geleneksel olarak dört ayrı devrim kabul edilen endüstri devrimlerine ek olarak, son yıllarda "Endüstri 5.0" olarak adlandırılan bir sonraki endüstri devrimi de tartışılmaktadır (Şekil 16).

1.Endüstri Devrimi (1780), makineleşme, fabrikasyon üretim, buhar gücü ve mekanizasyon gibi yeniliklerin yaygınlaşmasıyla karakterize edilen bir dönemdir. Bu devrimle birlikte el yapımı ürünler yerini makine üretimine bırakmış, üretim miktarı artmış ve üretim süreci hızlanmıştır. Bu dönemde, tekstil, madencilik, tarım ve ulaştırma gibi alanlarda önemli

gelişmeler kaydedilmiştir (Nahavandi 2019). 2.Endüstri Devrimi (1870), bu dönemde üretim süreçleri ve teknolojilerinde önemli yenilikler gerçekleştiği dönemdir. Özellikle demiryolları, telegraf, telefon ve elektrik gibi iletişim ve enerji teknolojilerinin gelişimi ile bilinmektedir. Seri üretim ve kitlesel üretim teknikleri de bu dönemde ortaya çıkmıştır (Mokyr ve Strotz 1998). 3.Endüstri Devrimi (1970), dijital teknolojilerin yaygınlaşması ve bilişim teknolojilerinin hızlı bir şekilde gelişmesiyle karakterize edilen bir dönemdir. Bu dönemde, elektronik devrelerin ve bilgisayarların icadı, mikroişlemcilerin geliştirilmesi, internetin yaygınlaşması ve mobil cihazların ortaya çıkması gibi birçok teknolojik gelişmeler yaşanmıştır (Rifkin 2011). 4.Endüstri Devrimi (Günümüz), üretim süreçlerinde otomasyonun artması, verimliliğin ve kalitenin artması, yeni iş modellerinin oluşması, tedarik zincirlerinin optimize edilmesi, özelleştirilmiş ürünlerin üretilebilmesi ve daha hızlı üretim süreçleri gibi birçok fayda sağlamıştır. Aynı zamanda, bu dönemde endüstriler arası işbirliği de artmakta ve küresel ekonomik bağlantılar güçlenmektedir. Nesnelerin interneti, yapay zekâ, robotik sistemler ve büyük veri gibi teknolojilerin kullanımı, daha akıllı ve bağlantılı üretim süreçleri sağlamaktadır. Bu dönemde aynı zamanda sürdürülebilirlik ve yeşil teknolojilere odaklanma da önem kazanmaktadır (Schwab 2017).

Endüstri 4.0'a benzer şekilde, Endüstri 5.0'da (Gelecek)otomasyon, yapay zekâ, büyük veri, nesnelerin interneti ve diğer ileri teknolojileri içermektedir. Ancak, Endüstri 5.0, insan faktörünün daha fazla dâhil edilmesini ve insanların daha fazla karar verici rol oynamasını amaçlamaktadır. Endüstri 5.0, fabrikaların ve üretim tesislerinin akıllı, insan odaklı ve sürdürülebilir bir şekilde tasarlanmasını hedefleyen geleceğin üretim modelidir. Endüstri 5.0, insan-robot işbirliği, esnek üretim sistemleri, yerleştirilmiş üretim ve gerçek zamanlı veri analizi gibi yenilikleri içermektedir. Bu modelde, robotlar ve insanlar birbirleriyle etkileşime girerek daha akıllı ve verimli bir üretim süreci sağlayacaktır. İnsanlar, yapay zekâ ve robotların sağladığı verileri analiz ederek, daha verimli ve esnek bir üretim planlaması yapabileceklerdir. Endüstri 5.0, sürdürülebilirlik konusunda da önemli bir rol oynayacaktır. Üretim sürecinin daha verimli ve esnek hale getirilmesi, kaynak kullanımının optimize edilmesi ve atıkların azaltılması gibi konularda iyileştirmeler sağlanması amaçlanmaktadır. Endüstri 5.0 henüz tam olarak uygulanabilen bir model değildir ve hala araştırma ve geliştirme aşamasındadır. Ancak, bu modelin gelecekte üretim sektörüne önemli faydalar sağlayabileceği düşünülmektedir (Nahavandi 2019).



Şekil 16. Endüstri devrimleri

Triboinformatik

Triboinformatik, triboloji ve bilgi teknolojileri (Information Technology-IT) arasındaki kesişim alanını ifade etmektedir (Şekil 17). Bu disiplin, tribolojik verilerin toplanması, işlenmesi ve analiz edilmesi için bilgi teknolojilerini kullanır. Tribolojik verilerin büyük miktarda ve karmaşık olması nedeniyle, triboinformatik, verilerin doğru bir şekilde analiz edilmesi ve anlamlı sonuçlar elde edilmesi için gerekli olan makine öğrenmesi, veri madenciliği ve yapay zekâ tekniklerini kullanır. Triboinformatik, aşınma, yağlama, sürtünme ve yüzey analizleri gibi tribolojik konularda uygulanmaktadır. Bu disiplin, tribolojik verilerin daha hızlı ve doğru bir şekilde analiz edilmesine ve tribolojik sistemlerin daha iyi anlaşılmasına yardımcı olmaktadır. Ayrıca, triboinformatik, tribolojik sistemlerin daha iyi tasarlanması ve optimize edilmesi için de kullanılabilir (Yin vd 2023).




Şekil 17. Triboinformatik

Triboinformatik, Endüstri 4.0'ın bir parçasıdır. Endüstri 4.0, otomasyon, veri analizi, yapay zekâ ve dijitalleşme gibi teknolojilerin kullanımını içeren bir endüstriyel dönüşüm sürecidir. Endüstri 4.0'ın bir parçası olarak, triboinformatik, üretim süreçlerinin daha verimli ve sürdürülebilir hale getirilmesine yardımcı olur. Endüstri 4.0 ve triboinformatik arasındaki ortak nokta, her ikisinin de üretim süreçlerinde verimlilik, kalite ve sürdürülebilirlik gibi faktörleri iyileştirmeye odaklanmasıdır. Her iki alan da, veri toplama ve analiz etme konusunda büyük bir öneme sahip olduğundan, bu verilerin doğru bir şekilde toplanması ve kullanılması çok önemlidir. Her iki alan da, geleneksel üretim modellerine kıyasla daha verimli ve sürdürülebilir bir üretim sağlamayı hedeflemektedir.

Makine Öğrenmesi

Günümüzde Yapay Zekâ ve teknolojileri, öğrenme yeteneğine sahip olan ve durumlar karşısında kendi kararlarını alarak sorunları çözebilen sistemler olarak karşımıza çıkmaktadır. Yapay Zeka (Artificial Intelligence - AI), insanların sahip olduğu zekâ benzeri yetenekleri, algoritmalar ve bilgisayar programları aracılığıyla taklit eden bir bilim dalıdır (Kaushik ve ark., 2022). Yapay zekânın uzun vadedeki hedefi makinelerin insanların gerçekleştirdikleri faaliyetleri insanlar kadar iyi veya daha iyi yapabilmesidir (Nillson 1998). Yapay Zekânın öne çıkardığı iki alt alan Şekil 18'de gösterildiği üzere Makine Öğrenmesi (Machine Learning-ML) ve Derin Öğrenmedir (Deep Learning-DL). Makine Öğrenmesi/Öğrenimi, yapay zekânın bir alt dalı olup yapay zekâ kavramlarını bilgi işlem sistemlerine uygulamak için algoritmalar kullanır. Makine öğrenimi algoritmaları belirli bir hedefi gerçekleştirmesi için veri setlerini modele dönüştüren motorlardır. Makine öğrenimi, bilgisayarların verileri otomatik olarak analiz etmesine, modelleri tanımlamasına ve sonuçları tahmin etmesine olanak tanır. Bu

süreçte, bilgisayarlar verilerin açık programlama olmadan da doğruluklarını geliştirebilirler, ancak yine de insanların verileri işlemek için ihtiyaç duyduğu rehberli öğrenmeye ihtiyaçları vardır (Xhafa 2021).




Şekil 18. Yapay zekânın kümeleri

Derin Öğrenme (Deep Learning) ile Makine Öğrenmesi (Machine Learning) terimlerini birbirinden ayırmak önemlidir. Derin öğrenme ve makine öğrenmesinin birbirinden ayrıldığı nokta, algoritmalarının öğrenme şeklidir. Makine öğrenmesi bir bilgisayarın zeki olması için programlanması ve aynı zamanda o makinenin çevresinden öğrenmesi ve böylelikle performansını zaman içinde geliştirmesi üzerine inşa edilmiş bir yaklaşımdır. Derin öğrenme, işlemin özellik ayıklama kısmını büyük ölçüde otomatikleştirir ve gerekli olan bazı manuel insan müdahalesini ortadan kaldırarak daha büyük veri kümelerinin kullanılmasını sağlamaktadır (IBM 2021).

Makine Öğrenimi teknolojisi dört türe ayrılır ve aralarındaki belirgin fark, her birinin tahminlerde bulunmak üzere verileri nasıl öğrendiği ile tanımlanır (Şekil 19):


- Denetimli Öğrenme (Supervised Learning)
- Denetimsiz Öğrenme (Unsupervised Learning)
- Yarı Denetimli Öğrenme (Semi-supervised Learning)
- Takviyeli Öğrenme (Reinforcement Learning)



Şekil 19. Makine öğrenmesi türleri

Denetimli öğrenme

Denetimli makine öğrenmesi, belirli bir çıktı için sonuçları bilinen veriler üzerinden doğru bir şekilde sınıflandırılan ve sonuçları tahmin eden algoritmaların eğitilmesi amacıyla kullanılmaktadır (Şekil 20). Model, girdi verileri ile çıktı etiketleri arasındaki temel düzen ve uyumu algılayana kadar eğitilir ve daha önce hiç karşılaşmamış veriler tanıtıldığında doğru etiketleme sonuçları vermesini sağlar. Regresyon ve sınıflandırma denetimli öğrenme alt kategorileridir (Mechelli ve Viera 2019).



Şekil 21. Regresyon analiz türleri

- R-kare (R^2), regresyon analizinin başarısını ölçen bir istatistiksel ölçüdür. R^2 değeri, bağımlı değişkenin bağımsız değişkenler tarafından açıklanan varyansının yüzdesini temsil eder. Yüksek bir R^2 değeri, regresyon modelinin bağımlı değişkeni iyi bir şekilde açıkladığını gösterir (Montgomery vd 2021). Bu değer 0 ile 1 arasında değişir. R^2 değerlerinin anlamları Tablo 1’de açıklanmıştır.

Tablo 1. R^2 Değerlerinin Anlamları

R^2	Anlamı
$R^2=0$	Hiçbir ilişki olmadığını ve modelin verideki değişkenliği açıklayamadığını gösterir.
$R^2 < 0.5$	Zayıf bir ilişkiyi işaret eder ve makine öğrenimi modeli çıktığı tahmin etmede yetersiz kabul edilir.
$0.70 < R^2 < 0.90$	R^2 değeri tatmin edici bir performansı gösterir.
$R^2 = 1$	Mükemmel uyumu gösterir.

- Korelasyon katsayısının simgesi "r" ile gösterilir. Korelasyon katsayısı, iki sürekli değişken arasındaki lineer ilişkiyi ölçer. Korelasyon katsayısı değeri, -1 ile +1 arasında değişir. Pozitif bir korelasyon için +1, negatif bir korelasyon için -1 ve ilişki olmadığında (tamamen bağımsız değişkenler) 0 alır (Gravetter vd 2020).
- Aşırı uyum (Overfitting), bir regresyon modelinin eğitim verilerine aşırı derecede uyum sağlaması ve yeni verilere uygulandığında tahmin yeteneğinin düşmesidir. Model, eğitim verileri üzerinde yüksek doğruluk ve başarı elde edebilir, ancak farklı veri örneklerinde performansı düşüktür. Bu durumda, model eğitim verilerine çok fazla uyum sağladığı için tahminler yanıltıcı veya hatalı olabilmektedir (Jabbar ve Khan 2015).
- Yetersiz uyum (Underfitting), bir regresyon modelinin eğitim verilerine uygun bir şekilde uyum sağlayamaması ve farklı veri örneklerinde iyi bir şekilde tahmin edememesidir. Model, veri setinin karmaşıklığını yeterince kavrayamaz. Bu

durumda, model genellikle basit ve düşük dereceli bir denklemlerle temsil edilir ve veri setindeki varyasyonu yeterince açıklayamamaktadır (Jabbar ve Khan 2015).

- Aykırı değerler (Outliers), genel veri setinden belirgin bir şekilde farklı olan veya diğer gözlemlerden büyük ölçüde sapan nadir veri noktalarıdır. Aykırı değerler, regresyon analizi sonuçlarını yanıltıp ve modelin doğruluğunu etkileyebilmektedir. Aykırı değerler, ölçüm hatalarından, veri kayıtlarındaki hatalardan veya gerçek olağandışı olaylardan kaynaklanabilmektedir (Carlini vd 2019).

Bu terminolojiler, regresyon analizi sırasında kullanılan temel kavramları ve terimleri ifade etmektedir. Regresyon modelleri ise bağımlı değişkenlerin sürekli değerlerini tahmin etmek için kullanılır. Denetimli öğrenmede sık kullanılan regresyon algoritmaları (Şekil 22):

- Lineer regresyon (Linear Regression), istatistik ve makine öğrenmesi alanlarında sık kullanılan temel bir regresyon yöntemidir. Bu yöntem, bir bağımlı değişkenin (çıkıtı) bağımsız değişkenlerle (girişler) doğrusal bir ilişki içinde olduğu varsayımına dayanır. Amaç, bu doğrusal ilişkiyi kullanarak bağımlı değişkenin tahminini yapmaktır. Matematiksel olarak, lineer regresyon, bağımlı değişkeni bir veya daha fazla bağımsız değişkene göre en iyi şekilde açıklamaya çalışırken, hata kareler toplamını (sum of squared errors) minimize etmeye çalışır. Basit lineer regresyon, tek bir bağımsız değişkenin olduğu durumu ifade eder. İki değişken arasındaki ilişkiyi bir doğru ile temsil etmeye çalışır. Çoklu lineer regresyon, Birden fazla bağımsız değişkenin olduğu durumu ifade eder. Bu durumda, bağımlı değişkeni açıklamak için bir düzlem veya uzay içinde en iyi uyum sağlayan bir düzlem kullanılmaktadır (Montgomery vd 2021).

Lineer regresyonun formülü, Denklem 5’te açıklanmıştır:

$$y = b_0 + b_1 \cdot x_1 + b_2 \cdot x_2 + \dots + b_n \cdot x_n \quad (5)$$

Burada:

y: Bağımlı değişken (tahmin edilmek istenen hedef değişkeni).

$x_1, x_2, \dots, x_n$: Bağımsız değişkenler (girdi değişkeni).

$b_0, b_1, b_2, \dots, b_n$: Regresyon katsayıları (modelin öğrenilmesi gereken parametreler).

Lineer regresyonun temel amacı, bu regresyon katsayılarını, veri kümesine en iyi uyum sağlayacak şekilde hesaplamaktır. Bu hesaplama genellikle en küçük kareler yöntemi kullanılarak yapılmaktadır. Model eğitildikten sonra, yeni giriş verileri kullanılarak bağımlı değişkenin tahmini yapılabilir.

- Doğrusal olmayan regresyon yöntemleri, doğrusal bir ilişkinin ötesindeki daha karmaşık ilişkileri modellemektedir. Bu modeller, veri setindeki örüntüleri daha esnek bir şekilde yakalamak için kullanılır. Bu yöntemler, veriye daha iyi uyan eğriler veya yüzeyler oluşturarak çıktıyı tahmin etmeye çalışmasıdır. Örnek olarak, polinom regresyon, destek vektör regresyonu veya karar ağaçları verilebilir.
- Polinom regresyon (Polynomial Regression), bağımsız değişkenlerin polinomik terimlerini kullanarak doğrusal olmayan ilişkileri ifade etmek için kullanılan bir regresyon yöntemidir. Örneğin, birinci dereceden (lineer) regresyon yerine ikinci veya üçüncü dereceden polinomlar kullanılarak eğri bir ilişki yakalanabilir (Montgomery vd 2021). Polinom regresyon denklemi Denklem 6'da açıklanmıştır:

$$y = b_0 + b_1 * x + b_2 * x^2 + b_3 * x^3 + \dots + b_n * x^n \quad (6)$$

Burada:

y: Bağımlı değişkeni (tahmin edilmek istenen hedef değişkeni) temsil eder.

x: Bağımsız değişkeni (girdi değişkeni) temsil eder.

$b_0, b_1, b_2, \dots, b_n$: Polinom regresyon katsayılarını temsil eder.

n terimi: Polinomun derecesini(n. dereceden polinom regresyonu) temsil eder. Bu katsayılar, polinom regresyon modelinin eğitimi sırasında belirlenir ve veri noktalarına en uygun şekilde uyan polinomu oluştururlar.

- Destek Vektör Regresyonu (Support Vector Regression - SVR), destek vektör makineleri (SVM) yöntemini regresyon problemlerine uyarlayan bir doğrusal olmayan regresyon yöntemidir. Veri noktalarını en iyi şekilde ayıran bir hiper düzlem bulurken, marjinal hataları minimize ederek çıktıyı tahmin etmeyi hedeflenmektedir (Zhang ve O'Donnell 2020). SVR'nin matematiksel formülü Denklem 7'de açıklanmıştır. SVR, öngörülen değerler ile gerçek değerler arasındaki farkları minimize ederek çalışır. Öncelikle, SVR için destek vektörlerinin ve marjinal hataların hesaplandığı bir sınırlama probleminin çift biçimini ele alınır.

$$\text{minimize: } (0.5) * ||w||^2 + C * \sum(\epsilon_i + \epsilon_i^*) \quad (7)$$

Şartlar:

$$y_i - (w * x_i + b) \leq \epsilon_i$$

$$(w * x_i + b) - y_i \leq \epsilon_i^*$$

Burada:

x_i : Giriş verisidir.

y_i : Çıktı (hedef) verisidir.

minimize: Hedefin (amaçlanan değerler) minimize edilmek istendiğini belirtir.

w : Veri noktalarını desteklemek için kullanılan ağırlık vektörüdür.

b : Modelin sapmasıdır.

C : Hiperparametre, hatayı dengeleyen bir düzenleme terimidir.

ϵ_i : Marjinal hata terimi (hat) olarak adlandırılır ve $y_i - f(x_i)$ şeklinde ifade edilir.

ϵ_i^* : Aynı veri noktası için üst sınırdaki marjinal hata terimidir ve $f(x_i) - y_i$ şeklinde ifade edilir.

- Karar ağaçları (Decision Trees), hem sınıflandırma hem de regresyon modelleri olarak kullanılabilen bir yöntemdir. Karar ağaçları, veri setini ağaç yapısında temsil eden ve her bir düğümde bir özellik ve bu özelliğin değerine göre yapılacak bir karar bulunan bir yapıya sahiptir. Regresyon modellerinde, karar ağaçları sürekli bir çıktı değişkenini tahmin etmek için kullanılır. Her bir düğüm, bir özelliğin değerini kontrol eder ve veri noktasını farklı dallara yönlendirerek çıktı tahminini gerçekleştirir. Sonuç olarak, bir veri noktası için karar ağacının yaprak düğümüne ulaşıldığında, regresyon çıktısı tahmin edilmiştir (Loh 2011). Karar ağaçlarının matematiksel formülü, diğer makine öğrenmesi modellerine kıyasla daha basittir ve bu nedenle doğrudan denklem olarak ifade edilebilecek şekilde sade bir yapıya sahiptir. Karar ağaçlarının matematiksel formülü Denklem 8’de açıklanmıştır.

$$f(x) = \Sigma(y_i) \quad (8)$$

Bu formülde:

$f(x)$: Giriş veri örneği (x) için karar ağacının tahmin ettiği sonuçtur.

Σ : Tüm sonuç düğümleri (leaf node) için toplama işlemidir.

y_i : Her bir sonuç düğümünde bulunan tahmin değeridir.

- Lasso regresyon, lineer regresyonda kullanılan bir düzenleme (regularization) yöntemidir. Lasso regresyonu, modelin karmaşıklığını azaltmak ve aynı zamanda bağımsız değişken seçimini otomatik olarak gerçekleştirmek için kullanır. Lasso regresyonu, düzenleme terimi olarak L1 normunu kullanır ve bazı bağımsız değişkenlerin katsayılarını sıfıra yaklaştırarak onları etkisiz hale getirebilir. L1 düzenlemesi, Lasso regresyonunda kullanılan bir düzenleme terimidir. Bu düzenleme, katsayıların mutlak değerlerinin toplamını ifade etmektedir. L1 düzenlemesi, bazı katsayıları tamamen sıfıra eşitleyerek, modelde bazı

özniteliklerin etkisiz hale getirilmesine ve böylece daha az önemli özniteliklerin dikkate alınmamasına yardımcı olmaktadır. Bu nedenle L1 düzenlemesi, öznitelik seçimi için kullanılabilecek bir özelliğe sahiptir (Muthukrishnan ve Rohini 2016).

Lasso regresyon formülü Denklem 9'da açıklanmıştır.

$$\text{minimize: } \sum (y_i - (\beta_0 + \sum (x_i * \beta_i)))^2 + \lambda * \sum |\beta_i| \quad (9)$$

Burada:

minimize: Hedefin (amaçlanan değerler) minimize edilmek istendiğini belirtir.

y_i : Veri kümesindeki i . örneğin çıktı (hedef) değeridir.

x_i : Veri kümesindeki i . örneğin girdi (özellik) değeridir.

β_0 : Sabit terimdir.

β_i : i 'inci özelliğin katsayısıdır.

λ : Düzenleme terimi olarak bilinir. Bu terim, Lasso regresyonunun etkinliğini ve katsayıları sıfırlama eğilimini kontrol eder. Daha yüksek λ değerleri, daha fazla katsayının sıfıra yaklaşmasına neden olur ve böylece modeli daha basit hale getirir.

- Ridge regresyon, lineer regresyonda kullanılan başka bir düzenleme yöntemi. Ridge regresyonu, genellikle çoklu korelasyonlu bağımsız değişkenler arasındaki aşırı uyum (overfitting) sorununu azaltmak için kullanılır. Bu yöntem, modelin karmaşıklığını kontrol etmek ve istatistiksel yanlılığı (bias) ile varyans arasındaki dengeyi sağlamak için bir düzenleme terimi ekler. L2 düzenlemesi, Ridge regresyonunda kullanılan bir düzenleme terimidir. Bu düzenleme, katsayıların karelerinin toplamını ifade etmektedir. L2 düzenlemesi, katsayıların büyüklüklerini kontrol ederek aşırı uyumu azaltmaya ve modelin daha iyi genelleme yapmasına yardımcı olur. L2 düzenlemesi, katsayıların sıfıra doğru yakınsamasına neden olur, ancak tamamen sıfıra eşitlemez (Fan ve ark., 2015).

Matematiksel olarak, Ridge regresyonun genel formülü Denklem 10'da verilmiştir:

$$\text{minimize: } \|y - xw\|^2 + \lambda * \|w\|^2 \quad (10)$$

Bu formülde:

minimize: hedefin (amaçlanan değerler) minimize edilmek istendiğini belirtir.

y : Bağımlı değişkenin (hedef değerler) vektörünü temsil eder.

x : Bağımsız değişkenlerin (girdi değerleri) matrisini temsil eder.

w : Regresyon katsayılarının (ağırlıkların) vektörünü temsil eder.

$\|y - xw\|^2$: Hedef ve tahmin değerleri arasındaki farkın karelerinin toplamını ifade eder ve bu kısım, doğrusal regresyondaki en küçük kareler yöntemine karşılık gelir.

$\|w\|^2$: Regresyon katsayılarının L2 normunu ifade eder ve büyük ağırlıkları önlemek için düzenleştirme sağlar.

λ : Düzenleştirme parametresidir ve Ridge regresyonda eklenen L2 düzenleştirme terimini kontrol eder. Düzenleştirme parametresi λ , genellikle eğitim verilerine göre belirlenir ve modele uygun bir değer seçilmesi önemlidir. λ 'nın değeri arttıkça, regresyon katsayıları daha fazla küçültülür ve böylece düzenleştirmenin etkisi artar.

- Elastic Net regresyonu, hem Ridge regresyonunun hem de Lasso regresyonunun avantajlarını birleştirir. Bu yöntem, L1 ve L2 normlarının kombinasyonunu kullanarak bir düzenleştirme terimi eklenir. Elastic Net, hem değişken seçimini yapabilme özelliği hem de çoklu korelasyonlu bağımsız değişkenlerle başa çıkabilme özelliği sağlamaktadır (Fan ve ark., 2015). Matematiksel olarak, Elastic Net regresyonunun genel formülü Denklem 11'de verilmiştir.

$$\text{minimize: } \|y - xw\|^2 + \lambda_1 * \|w\|_1 + \lambda_2 * \|w\|^2 \quad (11)$$

Bu formülde:

minimize: hedefin (amaçlanan değerler) minimize edilmek istendiğini belirtir.

y: Bağımlı değişkenin (hedef değerler) vektörünü temsil eder.

x: Bağımsız değişkenlerin (girdi değerleri) matrisini temsil eder.

w: Regresyon katsayılarının (ağırlıkların) vektörünü temsil eder.


$\|y - xw\|^2$: Hedef ve tahmin değerleri arasındaki farkın karelerinin toplamını ifade eder ve bu kısım, doğrusal regresyondaki en küçük kareler yöntemine karşılık gelir.

λ_1 : L1 düzenleştirme parametresidir ve Lasso regresyonda kullanılan L1 düzenleştirme terimini kontrol eder.

$\|w\|_1$: Regresyon katsayılarının L1 normunu ifade eder ve Lasso düzenleştirmenin etkisini kontrol eder.

λ_2 : L2 düzenleştirme parametresidir ve Ridge regresyonda kullanılan L2 düzenleştirme terimini kontrol eder.

$\|w\|^2$: regresyon katsayılarının L2 normunu ifade eder ve Ridge düzenleştirmenin etkisini kontrol eder.



Şekil 22. Regresyon modelleri

b) Sınıflandırma Modelleri, denetimli öğrenme veri kümesinin etiketli örnekleri kullanılarak bir girişin belirli bir sınıfa ait olup olmadığını tahmin etmeyi amaçlayan bir makine öğrenme yaklaşımıdır. Sınıflandırma algoritmaları, denetimli öğrenme kategorisinde yer alır ve verileri belirli sınıflara atamak için kullanılır.

Denetimli öğrenmede sık kullanılan sınıflandırma algoritmaları şu şekildedir (Şekil 23):

- ❖ Lojistik Regresyon (Logistic Regression), isim benzerliğine rağmen sınıflandırma problemlerinde yaygın olarak kullanılan bir modeldir. İki sınıf (binary sınıflandırma) veya birden fazla sınıf (çok sınıflı sınıflandırma) tahmin etmek için kullanılır. Lojistik regresyon, bir lojistik fonksiyon kullanarak çıktıyı $[0, 1]$ aralığında sınırlar (Nasteski 2017). Matematiksel olarak, lojistik regresyonun genel formülü Denklem 12’de verilmiştir.

$$P(y=1 | x) = 1 / (1 + e^{(-z)}) \quad (12)$$

Bu formülde:

$P(y=1 | x)$: Giriş özellikleri x verildiğinde veri noktasının $y=1$ sınıfına ait olma olasılığını ifade eder.

e : Euler sayısıdır (yaklaşık olarak 2.71828)

z : Lojit fonksiyonu içinde yer alan lineer kombinasyondur ve Denklem 13’de verilmiştir.

$$z = w_0 + w_1x_1 + w_2x_2 + \dots + w_n \cdot x_n \quad (13)$$

Burada:

$w_0, w_1, w_2, \dots, w_n$: Regresyon katsayılarıdır ve modelin eğitim sürecinde belirlenir.

$x_1, x_2, \dots, x_n$: Giriş özellikleridir (bağımsız değişkenler).

n : Giriş özelliklerinin sayısını temsil eder.

Lojistik regresyon, veri noktasının $y=1$ sınıfına ait olma olasılığını hesaplamak için lojit fonksiyonunu kullanır. Lojit fonksiyonu, lineer kombinasyonu sınırlar (0 ile 1 arasında) ve böylece veri noktasının sınıfa ait olma olasılığını tahmin eder.

- ❖ Destek Vektör Makineleri (Support Vector Machines, SVM), sınıflandırma problemlerinde etkili bir şekilde kullanılan bir modeldir. SVM, veri noktalarını en iyi şekilde ayıran bir hiper düzlemi bulmayı hedeflemektedir. Bu hiperdüzlem, mümkün olan en geniş boşluğu (margin) elde edecek şekilde sınıflar arasına yerleştirilir. Maksimum marginal sınıflandırma yaparak sınıfları ayırmayı amaçlar (Pisner ve Schnyer, 2020). Matematiksel olarak, SVM sınıflandırma Denklem 14'de verilmiştir.

$$f(x) = \text{sign}(w \cdot x + b) \quad (14)$$

Bu formülde:

$f(x)$: Giriş veri örneğinin (x) sınıfını tahmin eden fonksiyonu ifade eder.

x : giriş veri örneğinin özelliklerini içeren vektördür.

$\cdot$ (nokta işareti): vektörler arasındaki iç çarpımı (dot product) ifade eder.

w : ağırlık vektörüdür. Bu vektör, doğrusal hiper düzlemi belirlemek için kullanılır ve model tarafından öğrenilir.

b : doğrusal hiper düzlem tarafından belirlenen eşik değeridir (bias). Model tarafından öğrenilir.

w ve b parametreleri, SVM modelinin öğrenildiği süreçte eğitim verilerine göre belirlenir. Özellikle doğrusal olarak ayrılabilir olmayan veri dağılımları için SVM, çekirdek (kernel) yöntemi kullanarak doğrusal olmayan bir hiper düzlem oluşturabilir. Bu çekirdek yöntemleri, veriyi yüksek boyutlu uzaylara dönüştürerek lineer olarak ayrılabilir hale getirir ve sınıflandırma işlemini gerçekleştirir.

- ❖ Karar Ağaçları (Decision Trees), veri setini ağaç yapısında temsil eden modeldir. Her bir düğüm, bir özelliği ve bu özelliğin değerine göre yapılacak bir kararı temsil etmektedir. Karar sınıflandırma problemlerinde, karar ağaçları veri noktalarını

sınıflara ayırmak için kullanılır. Her bir düğüm, bir özelliğin değerini kontrol eder ve veri noktasını farklı dallara yönlendirerek sınıf etiketini belirlemeye çalışır. Sonuç olarak, bir veri noktası için karar ağacının yaprak düğümüne ulaşıldığında, sınıf etiketi tahmin edilmiş olur. Karar ağaçları ile ilgili matematiksel formülü Denklem 8’de verilmiştir. (Charbuty ve Abdulazeez 2021).

- ❖ K-En Yakın Komşu (K-Nearest Neighbors, KNN), sınıflandırma problemlerinde kullanılan bir modeldir. Bir örneği sınıflandırmak için, o örneğe en yakın komşularını belirler ve çoğunluk oylaması ile sınıf etiketini tahmin eder (Taunk vd 2019).

KNN Sınıflandırma algoritmasının matematiksel formülü Denklem 15’de verilmiştir.

$$d_{(i,j)} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (15)$$

Burada:

$d_{(i,j)}$: i ve j indekslerine sahip iki veri noktası arasındaki uzaklık.

p: Veri noktalarının boyutunu ifade eder, yani her bir veri noktası p boyutlu bir vektördür.

x_{ik} : i. veri noktasının k. boyuttaki değeri.

x_{jk} : j. veri noktasının k. boyuttaki değeri.

k: Komşu sayısının seçimidir ve KNN' nin performansını etkileyen önemli bir parametredir. Bu hiperparametre uygulamaya bağlı olarak seçilmesi gerekmektedir.

- ❖ Yapay Sinir Ağları (Artificial Neural Networks, ANN),biyolojik sinir sistemlerinden ilham alan ve sınıflandırma problemlerinde kullanılan bir modeldir. Çok katmanlı bir yapıya sahip olan yapay sinir ağları, girdi katmanı, gizli katman(lar) ve çıktı katmanından oluşmaktadır. Ağırlıkların ve bias'ların iteratif olarak ayarlanmasıyla öğrenmeyi gerçekleştirir (Mahesh 2020). Yapay sinir ağlarının matematiksel formülü, farklı katmanlardaki ağırlıklar (weights) ve bias'lar (biases) aracılığıyla ifade edilir. Yapay sinir ağının matematiksel formülü Denklem 16’da verilmiştir.


$$\text{çıkış} = \text{aktivasyon fonksiyonu} (\sum (w * X) + b) \quad (16)$$

Burada:

çıkış: Yapay sinir ağının çıkışını temsil eder.

$\Sigma (w * X) + b$: Gizli katmanlardaki ağırlıkların (w) girişlerle (X) iç çarpımı ve bias (b) eklenmesiyle hesaplanır.

aktivasyon fonksiyonu: Her gizli katmanın çıktısına uygulanan doğrusal olmayan fonksiyondur. Yapay sinir ağlarına özgü olan bu fonksiyon, ağın doğrusal olmayan ilişkileri öğrenmesine yardımcı olur ve ağın karmaşıklığını artırır.



Şekil 23. Sınıflandırma modelleri

c) Ensemble öğrenme modelleri, veri setinin farklı özelliklerini veya örüntülerini yakalamak için çeşitli öğrenicilerin tahminlerini birleştirerek genel olarak daha iyi bir performans sergileyebilmesidir. Topluluk öğrenmesi (ensemble learning) yöntemleri hem sınıflandırma hem de regresyon modellerinde kullanılabilir. Ensemble yöntemleri, birden fazla öğrenici (model veya algoritma) kullanarak daha güçlü ve genellemesi daha iyi bir model oluşturmayı hedefleyen bir makine öğrenmesi yaklaşımıdır. Bu yaklaşım, tek bir modelin hatalarını veya sınırlamalarını azaltarak daha iyi bir performans sağlayabilmesi amaçlar. Ensemble yöntemlerinin bazı örnekleri olarak Rastgele Orman (Random Forest) ve Gradyan Artırma (Gradient Boosting) modelleri verilebilir (Şekil 24):

- ✓ Rastgele Orman (Random Forest), birden fazla karar ağacını bir araya getirerek oluşturulan bir ensemble yöntemidir. Her ağaç kendi tahminini yapar ve sonuçların çoğunluğu veya ortalaması alınarak ensemble modelin tahmini oluşturulur (Bentéjac vd 2021).

Matematiksel formül Denklem 17’de verilmiştir.

$$y = \Sigma(y_i) / N \quad (17)$$

Burada:

y: Rastgele Orman'ın tahmin ettiği sonucu ifade eder.

y_i : Her bir karar ağacının tahminini temsil eder.

Σ : Tüm ağaç tahminlerinin toplama işlemidir.

N: Kullanılan ağaç sayısını ifade eder.

Rastgele Orman, birden fazla karar ağacının bir araya gelerek tahminler yapması, overfitting'e (aşırı uyum) karşı dirençli olmasını ve veriye daha genel bir şekilde uyan bir model oluşturmasını sağlar. Bu nedenle Rastgele Orman, geniş uygulama alanlarına sahip ve güçlü bir makine öğrenmesi algoritmasıdır.

✓ Gradyan Artırma (Gradient Boosting), zayıf öğrencileri (genellikle karar ağaçlarını) bir araya getirerek güçlü bir model oluşturmayı hedefler. Gradyan Artırma, ardışık olarak öğrencileri eğitir ve her bir öğrenci, önceki öğrencinin hatalarını düzeltmeye çalışır (Bentéjac vd 2021).

Genel olarak, Gradyan Artırma algoritmasının matematiksel formülü Denklem 18'de verilmiştir.

$$f_0(x) + \Sigma(\text{learning rate} * h_i(x)) \quad (18)$$

Burada:


$f_0(x)$: Başlangıç tahminini ifade eder. Genellikle veri setindeki hedef değişkenin ortalama değeri veya buna yakın bir değerle başlanır.

Σ : Tüm ağaçların (zayıf öğrencilerin) toplamını ifade eder.

learning rate: Bir hiperparametredir ve her yeni ağacın katkısını kontrol eder. Düşük bir learning rate, ağaçların katkısını azaltırken, yüksek bir learning rate ağaçların katkısını artırır.

$h_i(x)$: i'inci ağacın tahminini temsil eder. Bu tahmin, önceki ağaçların hatalarını düzeltmek için veri noktası x'in özelliklerine bağlı olarak öğrenilir.


Gradyan Artırma algoritması, kayıp fonksiyonunu optimize etmek için ağaçları aşamalı olarak ekler ve her aşamada önceki ağaçların hatalarını düzelterek yeni bir ağaç ekler. Bu şekilde, zayıf öğrencilerin birleştirilmesiyle daha güçlü bir model oluşturulur ve sınıflandırma veya regresyon problemlerinde daha yüksek doğruluk elde edilir.



Şekil 24. Ensemble modelleri: rastgele orman- gradyan artırma

Denetimsiz öğrenme

Denetimsiz makine öğrenimi yaklaşımı, algoritmanın etiketlenmemiş verilerle sunulduğu ve bu verileri kümeler halinde gruplayarak anlamlı yapılar oluşturduğu bir öğrenme şeklidir. Bu yaklaşım, genellikle büyük miktarda veri olduğunda ve verilerin manuel olarak etiketlenmesinin zor olduğu durumlarda kullanılır. Denetimsiz makine öğrenimi algoritmaları, insan müdahalesi olmadan veri gruplamaları için kullanılır (Şekil 25). Algoritmalar, verileri benzer özelliklere sahip gruplara ayırmak için kümelenme veya boyut azaltma gibi teknikler kullanılır. Kümeleme ve boyut azaltma denetimsiz öğrenme alt kategorileridir (Monkeylearn 2021; Mohammed 2016).



Şekil 25. Denetimsiz makine öğrenmesi (Nozari ve Sadeghi 2021)

Denetimsiz öğrenme algoritmaları

Denetimsiz öğrenme yöntemleri, verilerin etiketlenmemiş olduğu bir öğrenme türüdür. Denetimsiz öğrenme algoritmaları, boyut azaltma, kümeleme, veri yoğunluğu analizi ve anormallik tespiti gibi görevler için kullanılır. Bunlar, sınıflandırma veya regresyon gibi etiketli verilerle ilişkilendirilen çıktıları doğrudan üretmezler. Ancak, denetimsiz öğrenme sonuçları, daha sonra denetimli öğrenme modellerini eğitmek veya verilerin analizini ve anlaşılmasını kolaylaştırmak için kullanılabilir. En sık kullanılan denetimsiz öğrenme algoritmalarından bazıları şu şekildedir:

- K-ortalama Kümeleme (K-means clustering), veri noktalarını belirli bir sayıda kümeye bölmek için kullanılan popüler bir algoritmadır (Şekil 26). Her bir veri noktası, ona en yakın olan merkez noktaya atanır ve merkez noktalarının konumu iteratif bir süreçte optimize edilir (Sinaga ve Yang 2020).

K-ortalama kümeleme algoritmasının matematiksel formülü Denklem 19’da verilmiştir.

$$\text{minimize: } \sum \|x_i - c_j\|^2 \quad (19)$$

Bu formülde:

Σ : Tüm veri noktaları üzerinde toplama işlemidir.

x_i : x ’in, i ’inci veri noktasını temsil eder.

c_j : c ’nin, j ’inci merkez (centroid) noktasını temsil eder.

$\|x_i - c_j\|^2$: i ’inci veri noktasının j . merkeze olan uzaklığının karesini ifade eder.


K-ortalama kümeleme algoritmasının amacı, yukarıdaki formülü minimize etmektir. Yani, her veri noktasını bir merkeze en yakın olacak şekilde atamak ve böylece kümeleri oluşturmak için merkezleri doğru şekilde yerleştirmektir. K-ortalama kümeleme, tekrarlı bir algoritmadır ve merkezlerin yer değiştirmesi ile ilerler. Her adımda veri noktaları bir kümeye atanır ve sonra merkezler güncellenir. Bu adımlar tekrar edilerek algoritma, merkezlerin değişmediği bir duruma (konverjansa) ulaşır ve kümelerin oluşturulması tamamlanmış olur.

- Hiyerarşik kümeleme (Hierarchical Clustering), verileri benzerliklerine göre gruplara ayırmanın bir yöntemidir. Bu yöntem, nesneleri (veri noktalarını) bir hiyerarşik yapıda gruplara ayırarak çalışmaktadır. Hiyerarşik kümeleme, veri noktalarını birbirlerine olan benzerlikleri temel alarak ağaç yapısı oluşturarak kümeler. Hiyerarşik kümeleme iki temel yaklaşıma sahiptir (Şekil 26):

1. Birleştirici (Agglomerative) Hiyerarşik Kümeleme: Başlangıçta, her veri noktası kendi başına bir küme olarak kabul edilerek ve benzerlikleri temel alarak benzer küme çiftleri

birleştirilmesidir. Bu işlem, tüm veri noktaları tek bir büyük küme oluşana kadar devam etmektedir. Sonuç olarak, birleştirilen küme sayısı azalırken, küme içindeki veri noktalarının benzerliği artmaktadır.

2.Bölücü (Divisive) Hiyerarşik Kümeleme: Birleştirici Hiyerarşik Kümelemenin tam tersi olarak başlangıçta, tüm veri noktaları tek bir büyük küme olarak kabul edilerek ve benzerlikleri temel alarak bu büyük küme altında alt kümelere bölünmesidir. Bu işlem, veri noktaları belirli bir küme sayısı veya başka bir kritere göre bölünene kadar devam eder (Kaushik ve Mathur 2014).




Şekil 26. Kümeleme algoritmaları: K-ortalama - hiyerarşik

- Yoğunluk Tabanlı Kümeleme (Density-based clustering): Veri noktalarını yoğunluk tabanlı olarak kümelere ayırmak için kullanılan bir algoritmadır. Yoğunluk temelli kümeleme sayesinde veri noktaları gürültüye dayanıklı olarak kümelendir (Campello vd 2020).
- Temel Bileşen Analizi (Principal Component Analysis-PCA), veri kümesindeki değişkenlik ve yapıyı anlamak için kullanılan bir veri boyut azaltma ve veri dönüştürme yöntemidir. Amacı, veri setindeki yüksek boyutlu değişkenleri (öznitelikleri) daha az boyutlu değişkenlerle temsil etmek ve veri analizini daha kolay ve anlaşılır hale getirmektir. Aynı zamanda veri boyutunu azaltarak hesaplama süreçlerini hafifletir ve veri üzerindeki gürültüyü azaltabilir (Wong 2021).

Yarı denetimli makine öğrenmesi

Yarı denetimli makine öğrenmesi yönteminde model, algoritmada az miktarda etiketlenmiş veri ile büyük miktarda etiketlenmemiş veri kullanılarak eğitilmektedir. Bu özelliğiyle hem denetimli hem denetimsiz öğrenme olma özelliklerini barındırır (Şekil 27). Yarı


denetimli makine öğrenmesinde genelde ilk adım olarak denetimsiz makine öğrenmesi algoritması kullanılarak benzer veriler kümelenmektedir. Sonraki adımda ise mevcut olan az miktarda etiketli veriler kullanılarak etiketli olmayan verileri etiketlenmektedir. Son aşama olarak tüm verilerin etiketlenme aşaması tamamlandıktan sonra denetimli makine öğrenmesi yaklaşımı uygulanılmaktadır (Zhu ve Goldberg 2009).



Şekil 27. Yarı denetimli makine öğrenmesi (Singh ve Saleh 2020)

Takviyeli makine öğrenmesi

Takviyeli makine öğrenmesi yönteminde bir ajanın, belirli bir çevre ile etkileşime girerek ödül kazanma hedefi doğrultusunda, karar alma sürecini öğrenmesi işlemidir. (Şekil 28). Takviyeli makine öğrenmesinde, ajan (agent) bir sistemdir ve bir çevre ile etkileşim halindedir. Ajan, gözlemlediği çevreden bilgi toplar, bu bilgiyi işler ve kararlar verir. Bu kararlar, ajanın hedeflediği belirli bir amaç doğrultusunda en iyi sonucu veren hareketleri yapması için tasarlanır. Öğrenme aşamasının başlangıcında en uygun çözümün ne olduğu bilinmemektedir. Bundan dolayı çözümler tekrarlanarak nasıl öğrenmesi gerektiğini göstermektedir. Takviyeli makine öğrenmesi, beklenen hedefe ulaşması için doğru ve en uygun yolun nasıl seçileceğini göstermektedir (Wenzel vd 2019).



Şekil 28. Takviyeli makine öğrenmesi (Asghar ve Jung 2022)

MATERYAL VE YÖNTEM

Malzeme

Bu çalışmada; otomotiv, havacılık ve imalat endüstrileri gibi farklı endüstriyel uygulamalarda yaygın olarak kullanılan düşük alaşımlı AISI 4140 ıslah çeliği kullanılmıştır. Malzemeye ait kimyasal ve mekanik özellikler, sırasıyla Tablo 2 ve Tablo 3'te verilmiştir.

Tablo 2. AISI 4140 Çeliğinin Kimyasal Özellikleri (Ağırlıkça %) (Kovacı, 2016)

Kimyasal Bileşim	Ağırlıkça (%)
C	0.36
Cr	0.014
Mn	0.80
Mo	0.85
Ni	0.30
Si	0.005
S	0.07
V	0.075
Cu	0.143
Fe	Kalan

Tablo 3. AISI 4140 Çeliğinin Mekanik Özellikleri (Kovacı, 2016)


Mekanik Özellikler	Değerler
Çekme Gerilmesi	655 MPa
Elastisite Modülü	210 GPa
Akma Gerilmesi	415 MPa
Sertlik	207 HV

Numunelerin Hazırlanması

Numune hazırlama işleminde öncelikle 3x4x5 cm³ boyutundaki işlemsiz AISI 4140 çelik numuneler Atatürk Üniversitesi Mühendislik Fakültesi Makine Mühendisliği Bölümü bünyesinde kullanılmakta olan ve Şekil 29'da gösterilen Metkon Metacut 302 ıslak kesme cihazı ile kesilmiştir. Kesme işlemi 4 aşamada gerçekleştirilmiştir ve bu aşamalar Şekil 30'da gösterilmiştir. Kesme işlemleri sonrasında 1x1x0,5 cm³ boyutunda 81 adet deney numunesi elde edilmiştir.



Şekil 29. Hassas kesme cihazı



1.AŞAMA



2.AŞAMA



3.AŞAMA



4.AŞAMA

Şekil 30. Numune kesme aşamaları

Kesme işleminden sonra numuneler, ultrasonik banyoda metanol içerisinde 10 dk süresince yüzeylerde bulunan kalıntılardan arındırılmıştır. Daha sonra numunelerin yüzeyleri, kabadan hassasa doğru 80-120-220-400-600-800-1200 grid SiC aşındırıcı kâğıt zımparalar kullanılarak zımparalanmıştır. Zımparalama işlemleri, Erzurum Teknik Üniversite Mühendislik ve Mimarlık Fakültesi Makine Mühendisliği Bölümü bünyesinde bulunan ve Şekil 31’de gösterilen Metkon Forcipol-2V cihazında gerçekleştirilmiştir. Zımparalama işlemi sonrası numunelerin parlatma işlemi 3 mikron çaplı alümina (Al_2O_3) tozu kullanılarak

gerçekleştirilmiştir. Parlatma işlemi öncesi ve sonrası numuneler 10 dk süresince ultrasonik banyoda metanol ile temizlenmiştir.



Şekil 31. Zımparalama cihazı

Aşınma Testleri

Tüm numunelerin aşınma deneylerinin gerçekleştirilmesi amacıyla Turkeyus PODWT&RWT aşınma test cihazı kullanılmıştır. Aşınma test cihazı doğrusal zıt yönlü düzlem-pim (reciprocating ball-on-flat) aşınma prensibi ile işlem gerçekleştirmektedir. Sürtünme kuvvetleri ve sürtünme katsayısı değerleri yük hücresinin iletimi ile test süresince bilgisayarda kaydedilmiştir. Aşınma test cihazı ve şematik görünümü Şekil 32’de gösterilmiştir.



Şekil 32. Aşınma test cihazı ve şematik görünümü (Bozkurt 2021)

Aşınma deneyleri kuru, tuzlu su ve yağ ortamında üç farklı koşulda olmak üzere; farklı kayma hızları-kayma mesafeleri ve aşınma yükleri ile gerçekleştirilmiştir. Kuru ortam aşınma

deneyleri herhangi bir sıvı ve/veya yağlayıcı kullanılmaksızın gerçekleştirilmiştir. Kuru aşınma deneyleri yaklaşık %50 bağıl neme sahip olan ortam koşullarında gerçekleştirilmiştir. Sıvı ortam aşınma deneyleri %3,5 NaCl tuzlu su çözeltisi ile gerçekleştirilmiştir. Yağ ortamındaki aşınma deneyleri ise ticari olarak kullanılan Mobil Super™ 2000 XE 5W-30 yağı ile gerçekleştirilmiştir. Aşınma deney parametreleri Tablo 4'te verilmiştir. Deneylerde, aşındırıcı malzeme olarak 6 mm çaplı Al₂O₃ (alümina) bilya kullanılmıştır. Tüm deneyler oda sıcaklığında gerçekleştirilmiştir (~18°C). Numunelerin aşınma oranlarını hesaplamak için numunelerin ağırlıkları deneyler öncesinde ve sonrasında belirlenmiştir. Daha sonra numunelerin aşınma oranları Archard eşitliği (Denklem 2) kullanılarak hesaplanmıştır.


Tablo 4. Aşınma Deney Parametreleri

Kayma Hızı (mm/s)	Kayma Süresi (dk)	Aşınma Yüğü (N)	Aşınma izi uzunluğu (mm)
8	30	1	8
16	60	3	8
32	120	5	8

Makine Öğrenmesi

Sürtünme ve aşınma özelliklerini tahmin etmek için ML algoritmaları kullanılmıştır. Makine öğrenmesi algoritması kullanımına karar verirken, veri setinin yapısı, problemin türü ve performans ölçütleri dikkate alınmıştır. Verilerin etiketli olması, yani bağımlı değişkenlerin veri kümesinde mevcut olması, Denetimli Makine Öğrenmesi yaklaşımını kullanmanın ön koşullarındandır. Aynı zamanda, problem türünde çıktının sürekli sayısal değerlerden oluşması ve tahminlerin nicel olarak değerlendirilmesi, regresyon problemlerinin tipik özellikleridir. Bu nedenle, verilerin etiketli olması ve çıktının sürekli olması durumundan, Denetimli Makine Öğrenmesi Regresyon Algoritmaları veri analizinde kullanılmıştır. Regresyon tahmini için Python 3.8.8 programlama dili Anaconda Navigator 4.10.1 aracılığıyla Jupyter Notebook 6.3.0 ortamında kullanılmıştır. Jupyter Notebook, interaktif bir arayüz sağlaması ve Python kodunu parçalar halinde çalıştırmasına, sonuçları görsel olarak görüntülemesine ve açıklamalarla belgelendirmesine olanak tanır.

Denetimli makine öğrenmesi regresyon algoritmalarının sürtünme ve aşınma özelliklerinin tahmininde kullanılan genel akış; veri toplama, veri ön işleme, algoritma seçimi, model eğitimi ve model değerlendirmesi adımlarını içermektedir. Aşağıda bu adımların detaylı bir biçimde açıklanmıştır (Şekil 33).



Şekil 33. Denetimli makine öğrenmesi regresyon modelleme akış şeması

Veri Toplama

Bu çalışmada, $1 \times 1 \times 0,5 \text{ cm}^3$ boyutlarında AISI 4140 düşük alaşımlı çelik numunelerin Atatürk Üniversitesi Mühendislik Fakültesi Makine Mühendisliği Bölümü'nün bünyesinde kullanılan Turkeyus PODWT&RWT aşınma test cihazından elde edilen aşınma deney veri seti kullanılmıştır. Sürtünme ve aşınma tahminleri için kullanılan veri setinde 81 veri noktası bulunmaktadır. Deney veri seti, AISI 4140 düşük alaşımlı çelik numunelerinin üç farklı ortam (kuru, tuzlu su ve yağ), üç farklı süre (30, 60 ve 120 dk.), üç farklı hız (8, 16 ve 32 mm/sn.) ve üç farklı yük (1, 3 ve 5 N) üzerinden elde edilen parametrelerden oluşmaktadır. Veri parametreleri; hız, süre (saniye), ortam, kütle kaybı, aşınma mesafesi, yük, sürtünme katsayısı ve aşınma oranı olmak üzere 11 adettir.

Veri parametrelerinden hız (mm/s), süre (saniye), ortam, kütle kaybı (gr), aşınma mesafesi (m) ve yük (N) girdi parametreleridir. Girdi parametrelerinden “ortam”, ML algoritmaları için kategorik veriler olarak tanımlanırken, geri kalanı sayısaldir (Tablo 5). Sürtünme katsayısı (Coefficient of Friction - CoF) ve aşınma oranı, sırasıyla hedef veya çıkış parametreleridir.

Tablo 5. Veri parametreleri: Boş Olmayan Değerlerin Sayısı- Veri Türleri

	Sütun	Boş Olmayan Değerlerin Sayısı (Non-null Count)	Veri Türleri (Dtype)
0	Hız (mm/s)	81 non-null	int64
1	Süre (saniye)	81 non-null	int64
2	Ortam	81 non-null	object
3	Kütle Kaybı (gr)	81 non-null	float64
4	Aşınma Mesafesi (m)	81 non-null	float64
5	Yük (N)	81 non-null	int64
6	Sürtünme Katsayısı	81 non-null	float64
7	Aşınma Oranı (mm ³ /Nm)	81 non-null	float64

Veri Ön İşleme

Veri ön işleme, modelin doğru ve güvenilir sonuçlar üretebilmesi için önemlidir. Veri ön işleme teknikleri toplanan verilerin analiz ve modelleme için uygun hale getirilmesi adımdır. Bu adımda kütüphaneleri ve veri yüklemeyi içe aktarma, veri temizleme, öznitelik seçimi, kategorik değişken dönüşümü, verinin normalizasyonunu (özellik ölçeklendirme) gibi işlemler yapılır. Veri ön işleme adımları şu şekildedir:

- **1. Adım - Kütüphaneleri ve Veri İçe Aktarma:** Python makine öğrenmesi kütüphaneleri ve veri yükleme adımı, Python dilinde makine öğrenimi ve veri analizi için kullanılan kütüphaneleri ve toplanan verileri sisteme dâhil etmeyi ifade eder. Kütüphaneleri içe aktarma, Python'da kullanılacak olan kütüphaneleri, "import" komutu ile içe aktararak kullanılabilir hale getirme işlemidir. Python dilinde popüler ve yaygın olarak kullanılan makine öğrenimi kütüphanelerinden Scikit-learn (sklearn), NumPy, Pandas ve Matplotlib kullanılmıştır. Scikit-learn, Makine öğrenimi algoritmaları ve araçları içeren çok kullanışlı bir kütüphanedir. Sınıflandırma, regresyon, kümeleme ve boyut indirgeme gibi birçok makine öğrenimi algoritmasını içerir. NumPy, sayısal hesaplamalar için kullanılan temel bir kütüphanedir. Diziler ve matrisler üzerinde işlemler yapmak için kullanılır ve çeşitli matematiksel işlevler içerir. Pandas, veri analizi ve veri manipülasyonu için kullanılan kütüphanedir. Veri çerçeveleri (dataframes) üzerinde çalışmak için güçlü bir araçtır. Matplotlib ise, görselleştirmeler oluşturmak için kullanılan bir kütüphanedir. Grafikler, çizimler ve görsel sunumlar yapmak için kullanılır.

Veri yüklemeyi içe aktarma ise Python'da kullanılacak olan veri setini, Pandas kütüphanesi yardımıyla, CSV, Excel veya diğer veri formatlarında bulunan verileri bir

DataFrame nesnesi olarak yüklemek işlemidir. Bu çalışmada kullanılan veri seti CSV formatında içe aktarılmış ve Tablo 6'da gösterilmiştir.

Tablo 6. ML Veri Seti

Hız (mm/s)	Süre (Saniye)	Ortam	Kütle Kaybı (gr)	Yük (N)	Aşınma Mesafesi (m)	Sürtünme Katsayısı	Aşınma Oranı (mm ³ /Nm)
8	1800	KURU	0.000036	1	14.4	0.343819	0.000319
8	1800	KURU	0.00012	3	14.4	0.394082	0.000355
8	1800	KURU	0.00021	5	14.4	0.537136	0.000372
8	3600	KURU	0.000077	1	28.8	0.419293	0.000341
8	3600	KURU	0.00026	3	28.8	0.496328	0.000384
8	3600	KURU	0.00044	5	28.8	0.588263	0.00039
8	7200	KURU	0.000165	1	57.6	0.436389	0.000366
8	7200	KURU	0.00053	3	57.6	0.532002	0.000392
8	7200	KURU	0.001	5	57.6	0.628384	0.000443
16	1800	KURU	0.00006	1	28.8	0.370836	0.000266
16	1800	KURU	0.00022	3	28.8	0.407385	0.000325
16	1800	KURU	0.00038	5	28.8	0.475094	0.000337
16	3600	KURU	0.000145	1	57.6	0.371629	0.000322
16	3600	KURU	0.00047	3	57.6	0.417765	0.000347
16	3600	KURU	0.00078	5	57.6	0.501842	0.000346
16	7200	KURU	0.00028	1	115.2	0.380535	0.00031
16	7200	KURU	0.001	3	115.2	0.51802	0.00037
16	7200	KURU	0.0019	5	115.2	0.571764	0.000421
32	1800	KURU	0.00011	1	57.6	0.381022	0.000244
32	1800	KURU	0.0004	3	57.6	0.444586	0.000296
32	1800	KURU	0.0007	5	57.6	0.513977	0.00031
32	3600	KURU	0.00026	1	115.2	0.395568	0.000288
32	3600	KURU	0.00083	3	115.2	0.457798	0.000307
32	3600	KURU	0.00161	5	115.2	0.576541	0.000357
32	7200	KURU	0.00055	1	230.4	0.399242	0.000305
32	7200	KURU	0.0018	3	230.4	0.472213	0.000333
32	7200	KURU	0.0035	5	230.4	0.587552	0.000388
8	1800	TUZ	0.000028	1	14.4	0.309514	0.000248
8	1800	TUZ	0.0001	3	14.4	0.320293	0.000296
8	1800	TUZ	0.0002	5	14.4	0.359959	0.000355
8	3600	TUZ	0.000067	1	28.8	0.315227	0.000297
8	3600	TUZ	0.00022	3	28.8	0.33539	0.000325
8	3600	TUZ	0.00041	5	28.8	0.368982	0.000364
8	7200	TUZ	0.00015	1	57.6	0.334894	0.000333
8	7200	TUZ	0.00052	3	57.6	0.365797	0.000384
8	7200	TUZ	0.00093	5	57.6	0.380412	0.000412
16	1800	TUZ	0.000054	1	28.8	0.310967	0.000239
16	1800	TUZ	0.00018	3	28.8	0.336059	0.000266
16	1800	TUZ	0.00036	5	28.8	0.365049	0.000319
16	3600	TUZ	0.00013	1	57.6	0.322015	0.000288

Tablo 6. (devamı)

16	3600	TUZ	0.00043	3	57.6	0.349659	0.000318
16	3600	TUZ	0.0008	5	57.6	0.398044	0.000355
16	7200	TUZ	0.0003	1	115.2	0.350369	0.000333
16	7200	TUZ	0.001	3	115.2	0.402822	0.00037
16	7200	TUZ	0.0018	5	115.2	0.795437	0.000399
32	1800	TUZ	0.0001	1	57.6	0.336419	0.000222
32	1800	TUZ	0.00034	3	57.6	0.357095	0.000251
32	1800	TUZ	0.00068	5	57.6	0.390175	0.000302
32	3600	TUZ	0.00022	1	115.2	0.351431	0.000244
32	3600	TUZ	0.0008	3	115.2	0.377055	0.000296
32	3600	TUZ	0.0014	5	115.2	0.407202	0.00031
32	7200	TUZ	0.0005	1	230.4	0.39494	0.000277
32	7200	TUZ	0.0016	3	230.4	0.411935	0.000296
32	7200	TUZ	0.003	5	230.4	0.435241	0.000333
8	1800	YAĞ	0.000022	1	14.4	0.230669	0.000195
8	1800	YAĞ	0.00008	3	14.4	0.243842	0.000237
8	1800	YAĞ	0.000157	5	14.4	0.286361	0.000278
8	3600	YAĞ	0.00005	1	28.8	0.232807	0.000222
8	3600	YAĞ	0.00017	3	28.8	0.265905	0.000251
8	3600	YAĞ	0.00032	5	28.8	0.294112	0.000284
8	7200	YAĞ	0.0001	1	57.6	0.239419	0.000222
8	7200	YAĞ	0.00035	3	57.6	0.283333	0.000259
8	7200	YAĞ	0.00067	5	57.6	0.298852	0.000297
16	1800	YAĞ	0.000037	1	28.8	0.23866	0.000164
16	1800	YAĞ	0.00014	3	28.8	0.251137	0.000207
16	1800	YAĞ	0.00026	5	28.8	0.28999	0.000231
16	3600	YAĞ	0.00008	1	57.6	0.242295	0.000177
16	3600	YAĞ	0.0003	3	57.6	0.265174	0.000222
16	3600	YAĞ	0.00055	5	57.6	0.300262	0.000244
16	7200	YAĞ	0.00018	1	115.2	0.251113	0.0002
16	7200	YAĞ	0.00061	3	115.2	0.288034	0.000225
16	7200	YAĞ	0.0012	5	115.2	0.318052	0.000266
32	1800	YAĞ	0.00006	1	57.6	0.254936	0.000133
32	1800	YAĞ	0.00022	3	57.6	0.264237	0.000163
32	1800	YAĞ	0.0004	5	57.6	0.300115	0.000177
32	3600	YAĞ	0.00014	1	115.2	0.266287	0.000155
32	3600	YAĞ	0.0005	3	115.2	0.270747	0.000185
32	3600	YAĞ	0.001	5	115.2	0.331901	0.000222
32	7200	YAĞ	0.0003	1	230.4	0.28334	0.000166
32	7200	YAĞ	0.0011	3	230.4	0.343447	0.000203
32	7200	YAĞ	0.0023	5	230.4	0.372401	0.000255

- **2. Adım - Veri Temizleme:** Veri setinin içeri aktarılmasından sonra veri setinde herhangi bir eksik veya anormal değer kontrol edilmiştir ve gerekli düzeltmeler

yapılmıştır. Eksik değer kontrolü “df.isnull().sum()” komutu ile sayısal ve görsel olarak yapılmıştır.

- **3. Adım - Öznitelik Seçimi:** Aşınma oranının (Şekil 32) ve CoF (Şekil 33) parametreler arasındaki ilişkileri “Matplotlib” kütüphanesi ‘plt.subplots()’ fonksiyonu kullanılarak grafikler halinde sunulmuştur. Ayrıca, ‘sns.pairplot()’ fonksiyonu kullanılarak parametrelerin birbirleriyle ilişkisi de grafik halinde sunulmuştur.
- **4. Adım- Kategorik Değişken Dönüşümü:** pd.get_dummies() fonksiyonu kullanılarak kategorik değişkenler sayısal forma dönüştürülmüştür. Ortam değişkeni "Kuru", "Tuz" ve "Yağ" gibi kategorik değişkenler içermektedir. “pd.get_dummies()” fonksiyonu bu değişkeni üç ayrı sütun şeklinde dönüştürerek ve her satırda "Kuru", "Tuz" ve "Yağ" için varlık durumuna göre 1 veya 0 değerlerini içerecektir. Örneğin, bir satırda "Ortam" değeri "Tuz" ise "Tuz" sütununda 1, diğer sütunlarda 0 olacaktır. Bu şekilde, kategorik değişkenin sayısal forma dönüştürülmesi sağlanır ve makine öğrenme algoritmalarının bu verileri daha iyi işlemesi mümkün olur.
- **5. Adım - Verinin Normalizasyonu (Özellik Ölçeklendirme):** Veri setinin makine öğrenimi modellerine daha iyi uymasını sağlaması ve algoritmanın performansını artırabilmesi için “Scikit-learn” kütüphanesinin "StandardScaler" aracı kullanılarak, veri setindeki her bir özelliğin ortalaması 0 ve standart sapması 1 yapılarak veri standartlaştırılmıştır.

Algoritma Seçimi

Sürtünme ve aşınma davranış tahmini modelleri oluşturmak için en yaygın olarak kullanılan Denetimli makine öğrenmesi Regresyon Algoritmalarından; Lineer Regresyon, Ridge Regresyon, Lasso Regresyon, Polinom Regresyon, Rastgele Orman Regresyon ve SVR Regresyon dâhil olmak üzere altı çeşit makine öğrenmesi algoritması kullanılmıştır. Seçilen algoritmalara hiperparametre optimizasyonunda Grid Search yöntemi kullanılmıştır. Grid Search yöntemi, belirli bir hiperparametre kombinasyonunu kullanarak modeli eğitir ve çeşitli hiperparametre kombinasyonlarını deneyerek en iyi performansı veren kombinasyonu seçer.

Tablo 7. CoF ve Aşınma Oranı Tahminleri İçin ML Algoritmalarının Parametreleri

ML model	Parametre optimasyonu	Parametre açıklaması
Polinom Regresyon (PR)	degree=2	▪Derece (degree): Polinomun derecesini belirler.
Ridge Regresyon	alpha: [0.001, 0.01, 0.1, 1.0, 10.0, 100.0]	▪alpha(α):Düzenleme terimi veya düzenleme parametresi olarak da adlandırılır.
Lasso Regresyon	alpha: [0.001, 0.01, 0.1, 1.0, 10.0, 100.0, 1000.0]	▪alpha(α): Ridge Regresyondaki gibi düzenleme seviyesini kontrol eder.
Destek Vektör Regresyon (SVR)	C: [0.01, 0.1, 1.0, 10.0, 100.0] kernel: [linear, rbf] epsilon: [0.01, 0.1, 1.0]	▪C: Hata toleransını kontrol eden bir düzenleme parametresidir. ▪kernel: Kernel fonksiyonunu belirler (örneğin, lineer, polinomiyal veya RBF). ▪Epsilon= Margin (marj) oluştururken kabul edilebilir hata toleransını belirler.
Rastgele Orman (RF)	n_estimators: [100, 200, 300, 500] max_depth: [None, 5, 10, 20]	▪n_estimators: Oluşturulacak ağaç sayısını belirler. ▪max_features: Her bir ağaçta kullanılacak maksimum özellik sayısını belirler.

Model Eğitimi

Seçilen algoritmayı veri kümesi üzerinde eğitme adıdır. Bu adımda veri kümesi eğitim ve test kümelerine ayrılır. Model, eğitim kümesi üzerinde öğrenilir ve bu öğrenme, modele verilen girdilere bağlı olarak çıktılar üretmesini sağlar. Makine Öğrenimi modeli, eğitim kümeleri kullanılarak oluşturulur ve doğrulanırken, modellerin performansı test kümesi üzerinde değerlendirilmiştir. Veri bölme işleminde, eğitim setinin %70'i eğitim amacıyla kullanılırken, geri kalan %30'u ise modelin test seti için kullanılmıştır. Sürtünme katsayısı (CoF) ve Aşınma oranı tahmini için ML algoritmaları eğitim ve test setinde sırasıyla 56, 25 (toplam 81) veri noktasına sahiptir.

Model Değerlendirmesi

Eğitilen modelin performansının değerlendirilmesi adıdır. Bu adımda ortalama kare hata (MAE), hataların karelerinin ortalaması (MSE), RMSE MSE'nin karekökü, R-kare performans ölçütleri kullanılmıştır. Dört farklı hata metriklerinin formülleri aşağıda verilmiştir. Ayrıca bir modelin performansını değerlendirmek ve modelin genelleştirme yeteneğini ölçmek için cross-validation(çapraz doğrulama)(cv) tekniği kullanılmıştır ve cv değeri 5 olarak seçilmiştir.

1.Ortalama Kare Hatası (Mean Squared Error - MSE): MSE, gerçek değerler ile tahmin edilen değerler arasındaki farkın karesinin ortalama değerini hesaplayan bir hata metriğidir. Daha düşük MSE değeri, daha iyi bir model performansını gösterir. Matematiksel formülü Denklem 20'de verilmiştir (Salman vd 2017).

$$MSE = \frac{1}{n} \sum (y_i - \hat{y}_i)^2 \quad (20)$$

Burada:

n: Veri noktalarının sayısı

y_i : Gerçek değerler

$\hat{y}_i$: Tahmin edilen değerler

2.R-kare (R-squared - R^2): R^2 , modelin bağımsız değişkenler tarafından açıklanan hedef değişkenin oranını gösteren bir istatistiktir. 0 ile 1 arasında değer alır. Daha yüksek R-kare değeri, modelin verilere daha iyi uyduğunu gösterir (Montgomery vd 2021). Matematiksel formülü Denklem 21’de verilmiştir.

$$R^2 = 1 - \frac{SSR}{SST} \quad (21)$$

Burada:

SSR: Regresyon Hatasının Kareler Toplamı (Sum of Squared Residuals)

SST: Toplam Kareler Toplamı (Total Sum of Squares)

SSR ve SST değerleri, tahmin edilen değerler ile gerçek değerler arasındaki farkın karesinin toplamıyla hesaplanır.

3.Ortalama Mutlak Hata (Mean Absolute Error - MAE): MAE, gerçek değerler ile tahmin edilen değerler arasındaki mutlak farkların ortalama değerini ifade eder. Daha düşük MAE değeri, daha iyi bir model performansını gösterir (Chai ve Draxler 2014). Matematiksel formülü Denklem 22’de verilmiştir.

$$MAE = \frac{1}{n} \sum |y_i - \hat{y}_i| \quad (22)$$

Burada:

n: Veri noktalarının sayısı

y_i : Gerçek değerler

$\hat{y}_i$: Tahmin edilen değerler

4.Kök Ortalama Kare Hatası (Root Mean Squared Error - RMSE): RMSE, MSE'nin karekökü alınarak elde edilir. Gerçek değerler ile tahmin edilen değerler arasındaki farkın karesinin ortalama değerinin kareköküdür. Daha düşük RMSE değeri, daha iyi bir model performansını gösterir. Matematiksel formülü Denklem 23’de verilmiştir (Chai ve Draxler 2014).

$$RMSE = \sqrt{MSE} \quad (23)$$

Burada:

MSE: Ortalama Kare Hatası

Bu hata metrikleri, model performansını değerlendirmede yaygın olarak kullanılan ölçütlerdir. Hangi hata metriğinin kullanılacağı, veri seti ve modelin özelliklerine bağlı olarak değişebilmektedir.

Cross-validation, model performansını değerlendirmek ve genelleştirme yeteneğini ölçmek için kullanılan bir yöntemdir. K-Fold Cross-Validation, en yaygın kullanılan cross-validation yöntemlerinden biridir. K-Fold Cross-Validation formülü matematiksel olarak ifade edilemez. Ancak bu yöntem, veri setini rastgele parçalara böler ve her bir parçayı sırayla test verisi olarak kullanarak, diğer parçalarda modeli eğitir. Bu işlem K kez tekrarlanır, her bir iterasyonda farklı parçalar test ve eğitim verisi olarak kullanılır. Elde edilen sonuçlar ortalaması alınarak modelin genel performansı hesaplanır.


ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, makine öğrenmesi regresyon modelleme adımları süresince elde edilen tribolojik parametreler arasındaki ilişkiler ve model performans ölçütlerinin bulguları detaylı bir şekilde incelenmiştir.

Tribolojik Parametreler Arasındaki İlişkiler:

Tribolojik parametrelerin birbirleriyle olan ilişkilerini belirlemek ve bu parametrelerin aşınma oranı ve sürtünme katsayısına olan etkilerini anlamak büyük önem taşınmaktadır. Bu bakımdan, tribolojik parametrelerin aşınma oranı ve sürtünme katsayısı üzerindeki etkileri iki aşamada incelenmiştir.


- 1. Aşama:** Hedef değişkeni olan aşınma oranı ile tribolojik girdi parametreleri arasındaki ilişkiler Şekil 34, Şekil 35 ve Şekil 38’de gösterilmiştir. Şekil 34’te altı farklı grafik bulunmaktadır. Bu grafiklerde, aşınma oranı ile her bir tribolojik parametre arasındaki ilişkiyi gösteren regresyon çizimleri yer almaktadır. Bu regresyon çizimleri ile veriler arasındaki eğilimi göstermek ve olası bir ilişkiyi anlamak için kullanılmıştır. Şekil 34-a, aşınma oranı-hız grafiğinde, elde edilen verilere göre hız arttıkça aşınma oranının azaldığı görülmektedir. Şekil 34-b, aşınma oranı-kütle kaybı grafiğinde, kütle kaybı arttıkça aşınma oranı artmaktadır. Archard eşitiliğinden de (Denklem 2)görülebileceği üzere bu beklenen bir sonuçtur ve literatür çalışmaları ile de uyum göstermektedir(Elhefnawey vd 2021). Şekil 34-c, aşınma oranı-aşınma mesafesi grafiğinde, aralarında ilişkide kısmi azalma görülmektedir. Bu doğrultuda, aşınma mesafesi değerlerinin ortam parametresi etkisiyle normalize olmuş olabileceği sonucuna varılabilir. Şekil 34-d, aşınma oranı-süre grafiğinde süre arttıkça aşınma oranı artmaktadır. Bu sonuç da beklenen bir sonuçtur (Odabas 2018). Şekil 34-e, aşınma oranı- yük grafiğinde doğrusal bir artış belirlenmiştir. Şekil 34-f, aşınma oranı- ortam grafiğinde, kuru ortamda aşınma oranını en yüksek değerlere, yağlı ortamda ise aşınma oranı değerlerinin daha düşük olduğu görülmektedir (Kovacı vd 2018).



Şekil 34. Aşınma oranı – girdi parametreleri arasındaki ilişkiler

a: Aşınma oranı - hız ilişkisi, b: Aşınma oranı - kütle kaybı ilişkisi, c: Aşınma oranı - aşınma mesafesi ilişkisi, d: Aşınma oranı - süre (saniye) ilişkisi, e: Aşınma oranı - yük ilişkisi, f: Aşınma oranı - ortam (kuru, tuz, yağ) ilişkisi


Aşınma oranına kayma ortamı ve aşınma mesafesinin etkisi Şekil 35’te gösterilmiştir. Aşınma oranı ile ortam arasındaki ilişkiyi gösteren violin grafiği incelendiğinde; aşınma oranındaki medyan ve yoğunluk kuru ortamda, tuzlu su ve yağ aşınma ortamına göre daha yüksek değerlere sahip olduğu belirlenmiştir. Aşınma oranı ve aşınma mesafesi violin grafiğinde ise en yüksek yığılma ve yoğunluk değerlerinin 14.4 m’de iken yüksek medyan değeri 115.2 m’de olduğu belirlenmiştir (Benal ve Shivanand 2007; Guo vd 2019; Arun ve Singh 2017).



Şekil 35. Aşınma oranı: ortam ve aşınma mesafesi arasındaki ilişkiler

a: Aşınma oranı - ortam ilişkisi, b: Aşınma oranı – aşınma mesafesi ilişkisi,


- Aşama:** Hedef değişkeni olan sürtünme katsayısı tribolojik parametresinin, girdi parametreleri arasındaki etkileşimleri anlamak için Şekil 36, Şekil 37 ve Şekil 38’de grafikler verilmiştir. Şekil 36-a, sürtünme katsayısı-hız grafiğinde, hız arttıkça sürtünme katsayısı artmaktadır (Nuruzzaman vd 2012). Şekil 36-b, sürtünme katsayısı-kütle kaybı grafiğinde kütle kaybı arttıkça sürtünme katsayısı artmaktadır(Coronado 2015). Genel olarak sürtünme katsayısı ile kütle kaybı arasında belirgin bir ilişki bulunmamaktadır. Ancak deney koşullarında gözlem yapabilmek amacıyla kütle kaybı, girdi parametresi olarak tanımlanmıştır. Şekil 36-c, sürtünme katsayısı-aşınma mesafesi grafiğinde aşınma mesafesi arttıkça sürtünme katsayısı artmaktadır (Yigezu vd 2013). Şekil 36-d, sürtünme katsayısı-süre grafiğinde süre arttıkça sürtünme katsayısı artmaktadır (Yigezu vd 2013). Şekil 36-e, sürtünme katsayısı-yük grafiğinde doğrusal bir artış belirlenmiştir. Şekil 36-f, sürtünme katsayısı-ortam grafiğinde, kuru ortamda aşınma oranını en yüksek değerlere, yağlı ortamda ise aşınma oranı değerlerinin daha düşük olduğu görülmektedir. Bu sonuç literatürde farklı kayma ortamlarında yapılan araştırmayı desteklemektedir (Kovacı vd 2018).



Şekil 36. Sürtünme Katsayısı – girdi parametreleri arasındaki ilişki


a: Sürtünme katsayısı - hız ilişkisi, b: Sürtünme katsayısı - kütle kaybı ilişkisi, c: Sürtünme katsayısı - aşınma mesafesi ilişkisi, d: Sürtünme katsayısı - süre (saniye) ilişkisi, e: Sürtünme katsayısı - yük ilişkisi, f: Sürtünme katsayısı - ortam (kuru, tuz, yağ) ilişkisi

Sürtünme katsayısına hız ve aşınma mesafesinin etkisi Şekil 37’de gösterilmiştir. Sürtünme katsayısı ile hız arasındaki ilişkiyi gösteren violin grafiği incelendiğinde; sürtünme katsayısındaki medyan ve yoğunluk değerlerinin en yüksek 32 mm/s’de, en düşük değerin ise 8 mm/s’de sahip olduğu belirlenmiştir. Sürtünme katsayısı ve aşınma mesafesi violin grafiğinde ise en yüksek medyan ve yoğunluk değerlerinin 230.4 m’de, en düşük medyan değeri 14.4 m’de olduğu belirlenmiştir.




Şekil 37. Sürtünme Katsayısı: Hız ve Aşınma Mesafesi arasındaki ilişkiler

a: Sürtünme katsayısı - hız ilişkisi, b: Sürtünme katsayısı – aşınma mesafesi ilişkisi,



Şekil 38. Tribolojik parametreler arasındaki ilişkiler

Tribolojik parametreler arasındaki korelasyon ilişkisi Şekil 39'daki korelasyon matrisinde gösterilmiştir. Korelasyon matrisi incelendiğinde; aşınma oranının küçükten büyüğe doğru sırasıyla süre, kütle kaybı, yük ve sürtünme katsayısı değişkenleri ile arasında doğrusal pozitif bir ilişkiye sahip olduğu tespit edilmiştir. Aynı zamanda, aşınma oranının hız ve aşınma mesafesi ile doğrusal negatif bir ilişkiye sahip olduğu görülmektedir. Sürtünme katsayısının ise küçükten büyüğe doğru sırasıyla hız, aşınma mesafesi, süre, yük, kütle kaybı ve aşınma oranı ile doğrusal pozitif bir ilişkiye sahip olduğu tespit edilmiştir.



Şekil 39. Korelasyon matrisi: Tribolojik parametreler arasındaki korelasyon ilişkisi

Model Performans Ölçütlerinin Değerlendirilmesi

Model performans ölçütleri, makine öğrenimi modellerinin gerçek verilerle ne kadar iyi uyum sağladığının sayısal bir tahminidir. Tablo 8'de aşınma oranının ve Tablo 9'da ise sürtünme katsayısının (CoF) farklı makine öğrenimi regresyon modellerinden elde edilmiş skorları gösteren performans metrikleri bulunmaktadır. Bu metrikler şunlardır: Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE), Test R-Kare (R^2 Test), Eğitim R-Kare (R^2 Train) ve Ortalama Çapraz Doğrulama/Cross-validation (cv) R^2 .

Aşınma oranı tahmini için makine öğrenimi modellerinin performans ölçütleri Tablo 8'de verilmiştir. Tablo 8'de bulunan metrikler incelendiğinde, Lineer regresyon modelinin oldukça düşük MAE, MSE ve RMSE değerlerine sahip olması, modelin verilere iyi uyduğunu ve iyi tahminler yaptığını gösterir. Ayrıca, R^2 Test ve R^2 Train değerleri 0.95 ve 0.96 olarak yüksektir, bu da modelin verileri oldukça iyi açıkladığını gösterir. Çapraz doğrulama (cv) ortalama R^2 değeri de 0.94 olarak yüksek bir değere sahiptir, bu da modelin genelleme yeteneğinin iyi olduğunu gösterir. Polinom regresyon modeli ise lineer regresyon modeline göre daha yüksek MAE, MSE ve RMSE değerlerine sahiptir. Ayrıca, R^2 Test, R^2 Train ve Mean R^2 cv değerleri 0.93, 0.99 ve 0.81 olarak oldukça yüksektir, bu da modelin iyi bir uyum sağladığını ve verilere iyi uyarlandığını gösterir. Ancak, R^2 Test değeri diğer metriklerden biraz daha düşüktür, bu da biraz aşırı uyuma işaret edebilir. Ridge regresyon modeli, lineer regresyon modeline benzer performans metriklerine sahiptir. MAE, MSE ve RMSE değerleri oldukça düşüktür ve R^2 Test ve R^2 Train değerleri 0.95 ve 0.96 olarak yüksektir. Çapraz doğrulama (cv)

ortalama R^2 değeri de 0.94 olarak yüksek bir değere sahiptir, bu da modelin genelleme yeteneğinin iyi olduğunu gösterir. Lasso regresyon modeli ise, negatif R^2 Test ve R^2 Train değerlerine sahiptir, bu da modelin verileri açıklayamadığını hatta tahminlerin beklenenden kötü olduğunu gösterir. Ayrıca, yüksek MAE, MSE ve RMSE değerleri de modelin düşük performansına işaret eder. Çapraz doğrulama (cv) ortalama R^2 değeri de negatif bir değere sahiptir, bu da modelin genelleme yeteneğinin çok düşük olduğunu gösterir. SVR regresyon modeli de Lasso regresyon modeline benzer olarak negatif ve sıfır R^2 Test ve R^2 Train değerlerine sahiptir. Yüksek MAE, MSE ve RMSE değerleri de modelin düşük performansına işaret eder. Çapraz doğrulama (cv) ortalama R^2 değeri de negatif bir değere sahiptir, bu da modelin genelleme yeteneğinin çok düşük olduğunu gösterir. Ayrıca Lasso Regresyon ve SVR Regresyon modellerinde yetersiz uyum görünmektedir. Rastgele orman regresyon modeli, diğer modellere göre daha yüksek MAE, MSE ve RMSE değerlerine sahiptir. Çapraz doğrulama (cv) ortalama R^2 değeri de ise 0.78 olarak oldukça yüksektir, bu da modelin genelleme yeteneğinin iyi olduğunu gösterir. Ayrıca, R^2 Test ve R^2 Train değerleri de 0.91 ve 0.97 olarak yüksektir. Ancak Rastgele Orman Regresyon modeli için R^2 Test ve R^2 Train değerleri arasında belirgin bir fark olduğu görülmektedir. Bu tür durumlar, aşırı uyumun (overfitting) bir işareti olabilir. Aşırı uyumda model, verileri ezberlediği için yeni verilere genellikle kötü bir şekilde uyar ve genelleme yapma yeteneği düşer.

Aşınma oranı tahmini için regresyon modellerinden verilen metrikler incelendiğinde, Polinom regresyon performansının aşırı uyum özelliğinden dolayı olabilir. Lasso regresyon modelinin düşük performans sergilemesinin sebebi küçük veri seti durumu olabilir. SVR modelin düşük performans sebebi uygun hiperparametreleri seçmek deneme yanılma gerektirmesi ve modelin optimize edilmesi zaman almasından dolayı olabilir. Rastgele orman regresyonun aşırı uyum eğilimi sorunu modelin performansını etkilemiştir. Lineer regresyon ve Ridge regresyon modellerin benzer yüksek performans göstermelerinin sebeplerinden biri her iki regresyon modelinde, doğrusal ilişkileri ifade etmek için etkili olmaları olabilir.

Tablo 8. Aşınma Oranı Tahmini İçin Makine Öğrenimi Modellerinin Performans Ölçütleri

ML Model	MAE($\times 10^{-5}$)	MSE($\times 10^{-10}$)	RMSE($\times 10^{-5}$)	R^2 Test	R^2 Train	Mean R^2 cv
Lineer Regresyon	1.032568	1.756397	1.325291	0.954005	0.962296	0.943392
Polinom Regresyon	1.125678	2.319161	1.522879	0.939268	0.993148	0.811585

Tablo 8. (devamı)

Ridge Regresyon	1.032817	1.759503	1.326462	0.953923	0.962291	0.942407
Lasso Regresyon	5.099491	3.824664	6.184387	-0.001564	0.0	-0.165244
SVR Regresyon	5.123331	3.831913	6.190244	-0.003463	-0.000261	-0.234356
Rastgele Orman Regresyon	1.502624	3.345473	1.829063	0.912392	0.978586	0.786619

Tablo 9. Sürtünme Katsayısı (CoF) Tahmini İçin Makine Öğrenimi Modellerinin Performans Ölçütleri

ML Model	MAE	MSE	RMSE	R ² Test	R ² Train	Mean R ² cv
Lineer Regresyon	0.031052	0.001638	0.040480	0.722075	0.799976	0.677699
Polinom Regresyon	0.048949	0.004396	0.066308	0.254265	0.796692	-3.406309
Ridge Regresyon	0.030387	0.001549	0.039359	0.737256	0.798763	0.668977
Lasso Regresyon	0.030062	0.001454	0.038131	0.753390	0.795624	0.670950
SVR Regresyon	0.022886	0.001157	0.034021	0.803681	0.756462	0.734843
Rastgele Orman Regresyon	0.027323	0.001526	0.039064	0.741173	0.943913	0.562140

Tablo 9 incelendiğinde; . Sürtünme katsayısı (CoF) tahmini için Lineer regresyon modeli, düşük hata değerleri (MAE, MSE ve RMSE) ile test ve eğitim verilerine iyi uyum sağlamaktadır. R² Test değeri, modelin test verilerini %72 oranında açıkladığını gösterirken, R² Train değeri, modelin eğitim verilerini %79 oranında açıkladığını gösterir. Çapraz doğrulama (cv) ortalama R² değeri de yüksek olup, modelin genel performansının güvenilir olduğunu göstermektedir. Tüm bu değerler göz önünde bulundurulduğunda, modelin eğitim verilerine aşırı uyum riski taşıdığını ve yeni verilere genelleme yapmakta zorlandığı söylenebilir. Polinom regresyon modelinin hata değerleri (MAE, MSE ve RMSE) diğer modellere göre yüksek ve

hatanın büyüklüğü daha fazladır. R^2 Test değeri 0.25 oldukça düşüktür, bu da modelin verilere uyum sağlamada başarısız olduğunu gösterir. Ayrıca, negatif cv ortalama R^2 değeri de modelin genel performansının düşük olduğunu gösterir. Ridge regresyon ve Lasso regresyon modelleri, düşük hata değerleri ve R^2 Test, R^2 Train ve Mean R^2 cv değerleri diğer modellere göre daha düşüktür. Tüm bu değerler göz önünde bulundurulduğunda, Ridge regresyon ve Lasso regresyon, Lineer regresyon'a benzer şekilde verilere uyum sağlama eğilimindedir, ancak diğer metriklerde düşük performans göstermektedir. SVR regresyon modeli, düşük hata değerleri ve diğer modellere göre yüksek R^2 değerleri 0.80 ile iyi uyum sağlamaktadır. Çapraz doğrulama (cv) ortalama R^2 değeri de diğer modellere göre yüksek olup, modelin genel performansının güvenilir olduğunu göstermektedir. Rastgele Orman regresyon modeli, düşük hata değerleri (MAE, MSE, RMSE) ile iyi uyum sağlamaktadır. Ancak, R^2 Test değeri 0.74 ve R^2 Train değeri 0.94 olarak yüksek olduğundan, modelin test verilerine uyum sağlamakta zorlandığı ve aşırı uyum (overfitting) riski olduğu görülmektedir. Çapraz doğrulama (cv) ortalama R^2 değeri de düşük, bu nedenle modelin genel performansının güvenilirliği düşük olabilir.

CoF tahmini için regresyon modellerinden verilen metrikler incelendiğinde, Lineer Regresyon doğrusal olmayan ilişkileri modelleyemediğinden ve aşırı uyum problemini iyi yönetemediğinden dolayı modelin genel performans düşüklüğü ve aşırı uyum sorunlarıyla karşılaşmıştır. Polinom Regresyon, yeterli sayıda veri noktasına sahip veri setlerinde daha iyi çalıştığından dolayı modelin performansının sebebi küçük veri seti olabilir. Ridge regresyon modeli doğrusal olmayan ilişkileri iyi modelleyemeyip bu ilişkileri tam olarak yakalayamadığından için düşük performans sergilemiş olabilir. Lasso regresyon modeli ise doğrusal olmayan ilişkileri iyi modelleyemediği ve veri seti yeterince büyük olmadığında bu durumlar düşük performans sergilemesinin sebepleri olabilir. Rastgele orman regresyonun aşırı uyum eğilimi ve doğrusal olmayan ilişkileri ifade etme zorluğu gibi dezavantajlarından dolayı model düşük performans sergilemiş olabilir. Destek vektör regresyon modelinin diğer modellere kıyasla daha iyi performans sergilemesinin sebebi sınırlı veri örnekleri ile çalışırken diğer modellere göre daha iyi genelleştirme yeteneğine sahip olması olabilir.

Farklı araştırmacıların yaptıkları çalışmalar incelendiğinde Hasan vd (2021), yaptıkları çalışmada alüminyum bazlı alaşımların kuru sürtünme ve aşınma davranışının Makine Öğrenimi algoritmaları kullanılarak triboinformatik modellemesini ele almışlardır. Çalışmada, alüminyum bazlı alaşımların sürtünme ve aşınma verileri kullanılarak beş farklı makine öğrenimi algoritmasını eğitmişlerdir. Makine öğrenimi modellerini, sürtünme katsayısı (CoF) ve aşınma oranı tahmini yapmak için kullanmışlardır. Performans analizi sonucunda, makine öğrenimi modellerinin alüminyum alaşımlarının sürtünme ve aşınma davranışını tatmin edici

bir şekilde tahmin edebildiği gösterilmiştir. K-En Yakın Komşu (KNN) algoritması COF tahmininde ($R^2=0,83$) en iyi performansı gösterirken, Rastgele Orman (RF) algoritması ise aşınma oranı tahmininde ($R^2=0,81$) en iyi sonucu vermiştir. Wang vd (2023) çalışmalarında, MoS₂ ile kaplanmış bakırın tribolojik performansını araştırmayı ve GBRT (Gradient Boosting Regression Trees) yöntemi kullanarak tahmin etmeyi amaçlanmıştır. Çalışmada, farklı MoS₂ kaplama kalınlıklarına sahip bakır örnekleri kullanılmıştır. Sürtünme testleri ve aşınma testleri gerçekleştirilmiş ve elde edilen veriler kullanılarak MoS₂ kaplamanın tribolojik performansı analiz edilmiştir. Sürtünme katsayısının ve aşınma oranının tahmin doğruluğu sırasıyla %94.6 ve %96.3'e ulaşmıştır. GBRT yöntemiyle elde edilen tahminler, deneysel verilere iyi uyum sağlamaktadır ve MoS₂ kaplama kalınlığının sürtünme ve aşınma davranışı üzerinde belirleyici bir faktör olduğunu ortaya koymaktadır. Araştırmalar, sürtünme katsayısı ve aşınma oranı tahminlerinde makine öğrenmesinin faydalı bir yaklaşım olduğunu göstermektedir. Bu doğrultuda çeşitli veri sayıları, farklı algoritmalar ve hiperparametre seçimleri ile çeşitli tribolojik değişkenlerin (kayma hızı, kayma mesafesi, yük, ortam ve malzeme özellikleri vb. parametreler) makine öğrenmesi tahminlemelerinde tatmin edici sonuçlar elde edebildiğini göstermektedir.

SONUÇLAR VE ÖNERİLER

Bu çalışmada, AISI 4140 düşük alaşımlı çeliğinin farklı parametreler ile gerçekleştirilen sürtünme ve aşınma deneylerinden elde edilen veri setinin altı farklı denetimli makine öğrenmesi regresyon algoritmaları ile tahmin sonuçları kıyaslanmıştır. Çalışmanın amacı, metalik malzemelerin farklı tribolojik parametrelere göre sürtünme katsayısı ve aşınma oranının doğru bir şekilde edilep edilemeyeceğini belirlemektir. Gerçekleştirilen çalışmalar sonucunda şu sonuçlar elde edilmiştir:

- Makine Öğrenimi modellerinin performans analizleri incelendiğinde CoF tahmininde SVR modeli R^2 değeri %80 ve aşınma oranı tahmininde de Lineer regresyon modeli R^2 değeri %95 ile en iyi performansı sergilediği sonucuna varılmıştır.
- CoF tahmininde en iyi sonucun SVR (Destek Vektör Regresyon) modelde verilmesinin olası sebepleri veri setinde bağımlı değişken ile bağımsız değişkenler arasında doğrusal olmayan ilişkiler içermesi, SVR modeli bu ilişkileri daha iyi ifade edebilmesi ve daha iyi tahminler yapabilmesidir.
- Ayrıca SVR, ölçeklendirilmiş verilere daha iyi uyum sağlaması ve diğer modellerin aşırı uyum yaşaması durumunda, genelleştirme yeteneği daha düşük olabilmelerinden dolayı SVR modeli daha iyi performans sergilemiş olduğu düşünülmektedir.
- CoF tahmini için elde edilen incelendiğinde uygulanan altı farklı model sonuçlarının %90 üzeri bir performans sergileyemediklerinden bağımsız değişkenler bağımlı değişkeni yeteri kadar temsil etmediği sonucuna varılmıştır.
- Aşınma oranı tahmininde Lineer Regresyon modelinin en iyi sonucu vermiş olmasının nedeni veri setinde bağımlı değişken ile bağımsız değişkenler arasında doğrusal ilişkiyi doğru bir şekilde ifade edebilmesi ve iyi tahminler yapabilmesi olarak öne çıkmaktadır.
- Ayrıca Lineer regresyon, küçük ve orta ölçekli veri setleri ve düşük karmaşıklığa sahip veri setleri üzerinde iyi performans göstermesi avantajlarından dolayı da en iyi performansı sergilemiştir.
- Uygulanan modellerden elde edilen istatistiksel performans ölçütleri, geliştirilen makine öğrenimi modellerinin AISI 4140 çeliğinin sürtünme katsayısı (CoF) ve

aşınma oranının malzeme ve tribolojik değişkenler dikkate alındığında tatmin edici bir düzeyde tahmin edebileceğini göstermektedir.

Literatür çalışmaları, Makine Öğrenmesinin malzemelerin sürtünme, aşınma ve yağlama özelliklerinin tahmininde kullanılabileceğini göstermiştir. Literatüre benzer şekilde, bu çalışmada da malzemelerin bu özellikleri deneysel veriler dikkate alınarak incelenmiş ve başarılı sonuçlar elde edilmiştir. Makine öğrenimi algoritmalarının performans metrikleri (R^2 değerleri ve hata terimleri), veri setinin homojenliğine büyük ölçüde bağlıdır. Elde edilen sonuçlardan genel anlamda başarılı tahmin modellerinin oluşturulduğu gözlemlenmiştir. Bu çalışma kapsamında incelenemeyen fakat farklı çalışmalarda ele alınabilecek araştırma önerileri şu şekildedir:

- Makine öğrenimi analizlerinde daha fazla veri setleri kullanılarak elde edilen modeller, malzeme tasarımında daha etkili bir şekilde uygulanabilir ve daha başarılı sonuçlar elde edilebilir. Bu şekilde, malzemelerin daha dayanıklı, verimli ve çevre dostu olarak tasarlanmasına ve geliştirilmesine katkı sağlanabilir.
- Makine öğrenmesi analizlerinde yüzey sertliği, yükleme koşulları, sıcaklık, yüzey kaplama kalınlığı, çalışma hızı, çalışma ortamı(vakum, kimyasal ortam, gaz vd.) ve çalışma koşulları(ani yük değişimi, titreşimli ortamlar vd.) gibi daha fazla tribolojik değişkenin kullanılması modellerin performansını artırabilir ve daha kapsamlı sonuçlar elde etmeye yardımcı olabilir.
- Makine öğrenmesinde sürtünme katsayısı ve aşınma oranı tahmininde farklı malzeme gruplarının kullanılması belirli bir uygulama için en uygun malzemeyi belirlemede ve malzeme optimizasyonunda yardımcı olabilir. Ayrıca gelecekteki malzeme tasarımı ve geliştirme çalışmalarında, farklı endüstri ve uygulama alanlarında daha özelleştirilmiş tahminler yapılmasını sağlayabilir.
- Ayrıca, farklı sektörlerde kullanılan fren balataları, kalça protezleri, diş implantları, uçak motorları ve rüzgâr türbinleri gibi ürünlerin tribolojik özelliklerinin makine öğrenmesi modellemesinde kullanılması bu ürünlerin tasarımı, geliştirilmesi ve performansının iyileştirilmesi için değerli bilgiler sağlayabilir.

Elde edilen makine öğrenimi analiz bulguları ve modellerin, özel tribolojik uygulamalar için malzeme tasarımında doğrudan kullanılabilmesi için daha fazla tribolojik değişkenin dikkate alınması, çeşitli makine öğrenimi modelleri ve algoritmalarının kullanılması ve daha fazla eğitim verisinin kullanılması önerilmektedir. Her malzeme ve uygulama için en uygun kombinasyonun belirlenmesi, tribolojik performansı en üst düzeye çıkarmasına yardımcı

olacaktır. Bu nedenle, tribolojik çalışmalarda daha fazla deneysel veri toplanması ve çeşitli faktörlerin etkilerinin anlaşılması için kapsamlı analizler yapılması önerilir.



KAYNAKÇA

- Akkurt, M. (1990). Makine Elemanları, Cilt I. İstanbul: Birsen Yayınevi.
- Argatov, I. I., & Chai, Y. S. (2019). An artificial neural network supported regression model for wear rate. *Tribology International*, 138, 211-214.
- Arun, A., & Singh, K. K. (2017). Friction and wear behaviour of glass fibre reinforced polymer composite (GFRP) under dry and oil lubricated environmental conditions. *Materials Today: Proceedings*, 4(8), 7285-7292.
- Asghar, H., & Jung, E. S. (2022). A Survey on Scheduling Techniques in the Edge Cloud: Issues, Challenges and Future Directions. *arXiv preprint arXiv:2202.07799*.
- ASTM, A. (2005). Standard terminology relating to wear and erosion. G40.
- Bahşiyev, İ., & Selçuk, B. (2017). Makine Elemanları Problemleri. Nobel Akademik Yayınları.
- Balamurugan, E., Flaih, L. R., Yuvaraj, D., Sangeetha, K., Jayanthiladevi, A., & Kumar, T. S. (2019, December). Use case of artificial intelligence in machine learning manufacturing 4.0. In *2019 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)* (pp. 656-659). IEEE.
- Baydemir, T. (2021, Aralık). Triboloji. *TÜBİTAK Bilim ve Teknik Dergisi*, 38-49.
- Baydoun, S., Fartas, M., & Fouvry, S. (2023). Sürtünme aşınma hacmini tahmin etmek için fiziksel ve makine öğrenimi modellemesi arasındaki karşılaştırma. *Tribology International*, 177, 107936.
- Benal, M. M., & Shivanand, H. K. (2007). Effects of reinforcements content and ageing durations on wear characteristics of Al (6061) based hybrid composites. *Wear*, 262(5-6), 759-763.
- Bentéjac, C., Csörgő, A., & Martínez-Muñoz, G. (2021). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937-1967.
- Bhushan, B. (2000). *Modern tribology handbook*, two volume set. CRC press.
- Bhushan, B. (2013). *Introduction to tribology*. John Wiley & Sons.
- Bograd, S., Reuss, P., Schmidt, A., Gaul, L., & Mayer, M. (2011). Modeling the dynamics of mechanical joints. *Mechanical systems and signal processing*, 25(8), 2801-2826.
- Boynueyri, D. (2019). PVD Yöntemi İle İnce Kaplanmış Kesici Takımların Mikro Ölçekli Aşınma Testi ile Aşınma Dayanımının Belirlenmesi (Yüksek Lisans Tezi). Bartın Üniversitesi, Fen Bilimleri Enstitüsü. Bartın.
- Bozkurt, Y.B., (2021). Seramik Kaplanmış AZ31 Alaşımının Tribolojik, Korozyon, Tribokorozyon Performansı Ve Biyouyumluluk Davranışının İncelenmesi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Doktora Tezi, Erzurum.
- Buckley, D. H., 2000. *Surface Effects in Adhesion, Friction, Wear, and Lubrication* (Vol. 5). Elsevier Science Publishing Company, 630p, Amsterdam, The Netherlands.
- Burris, D. L., & Sawyer, W. G. (2009). Measurement uncertainties in wear rates. *Tribology Letters*, 36(1), 81-87.

- Campello, R. J., Kröger, P., Sander, J., & Zimek, A. (2020). Density-based clustering. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(2), e1343.
- Carlini, N., Erlingsson, U., & Papernot, N. (2019). Distribution density, tails, and outliers in machine learning: Metrics and applications. *arXiv preprint arXiv:1910.13427*.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.
- Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20-28.
- Coles, J. M., Chang, D. P., & Zauscher, S. (2010). Molecular mechanisms of aqueous boundary lubrication by mucinous glycoproteins. *Current Opinion in Colloid & Interface Science*, 15(6), 406-416.
- Coronado, J. J. (2015). Abrasive size effect on friction coefficient of AISI 1045 steel and 6061-T6 aluminium alloy in two-body abrasive wear. *Tribology Letters*, 60, 1-6.
- Czichos, H. (1986). Introduction to friction and wear. In *Composite Materials Series* (Vol. 1, pp. 1-23). Elsevier.
- Çöl, M. N. (2013). Si₃N₄ Ve CNT Nano Partiküllerin Yağ Katkısı Olarak AISI 4140 Çeliğinin Aşınma Özelliklerine Etkisinin İncelenmesi. Eskişehir Osmangazi Üniversitesi. Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 104.
- Elcoate, C. D., Glover, A., & Baker, D. (2012). Lubrication fundamentals. *Tribology & Lubrication Technology*, 68(11), 14-21.
- Elhefnawey, M., Shuai, G. L., Li, Z., Nemat-Alla, M., Zhang, D. T., & Li, L. (2021). On dry sliding wear of ECAPed Al-Mg-Zn alloy: Wear rate and coefficient of friction relationship. *Alexandria Engineering Journal*, 60(1), 927-939.
- Fan, L., Chen, S., Li, Q., & Zhu, Z. (2015, December). Variable selection and model prediction based on lasso, adaptive lasso and elastic net. In *2015 4th International Conference on Computer Science and Network Technology (ICCSNT)* (Vol. 1, pp. 579-583). IEEE.
- Gohar, R., & Rahnejat, H. (2018). *Fundamentals of tribology*. World Scientific.
- Gohar, R., Abdul Hamid, K., & Rajoo, S. (2015). A review on the fundamentals of lubrication in rolling and sliding bearings. *Advances in Mechanical Engineering*, 7(10), 1687814015604116.
- Gravetter, F. J., Wallnau, L. B., Forzano, L. A. B., & Witnauer, J. E. (2020). *Essentials of statistics for the behavioral sciences*. Cengage Learning.
- Guo, L. C., Zhu, W. T., Shi, L. B., Liu, Q. Y., Cai, Z. B., & Wang, W. J. (2019). Study on wear transition mechanism and wear map of CL60 wheel material under dry and wet conditions. *Wear*, 426, 1771-1780.
- Halling, J. (1977). *Tribology: science and practice*. *Physics in Technology*, 8(3), 116.
- Hasan, M. S., Kordijazi, A., Rohatgi, P. K., & Nosonovsky, M. (2021). Triboinformatic modeling of dry friction and wear of aluminum base alloys using machine learning algorithms. *Tribology International*, 161, 107065.
- Hassani, I. E., Mazgualdi, C. E., & Masrour, T. (2019). Artificial intelligence and machine learning to predict and improve efficiency in manufacturing industry. *arXiv preprint arXiv:1901.02256*.
- Heywood J.B. (1988). *Internal Combustion Engine Fundamentals*, McGraw-Hill Inc, New

York.

- Hirani, H. (2019). "Tribology, Lecture 7, Adhasive wear". Alındığı yer: <http://web.iitd.ac.in/~hirani/lec07.pdf>.
- Holmberg, K., & Matthews, A. (2006). Coatings tribology: properties, mechanisms, techniques and applications in surface engineering. Elsevier.
- Hutchings, I. M. (1993). Mechanisms of wear in powder technology: a review. Powder Technology, 76(1), 3-13.
- Hutchings, I., & Shipway, P. (2017). Tribology: friction and wear of engineering materials. Butterworth-heinemann, 412p ,45-78.
- Hutchings, I., Gee, M., & Santner, E. (2011). Friction and wear. In Springer handbook of metrology and testing (pp. 743-768). Springer, Berlin, Heidelberg.
- IBM Watson Advertising. (2021). How AI is Changing Advertising (2021) <https://124.im/PRomd> Erişim: 10.05.2022
- Jabbar, H., & Khan, R. Z. (2015). Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). Computer Science, Communication and Instrumentation Devices, 70(10.3850), 978-981.
- Jeyaprakash, N., & Yang, C. H. (2020). Friction, lubrication, and wear. In Tribology in Materials and Manufacturing-Wear, Friction and Lubrication. IntechOpen.
- Jiménez, A. E., & Bermúdez, M. D. (2011). Friction and wear. In Tribology for engineers (pp. 33-63). Woodhead Publishing.
- Kannaiyan, M., & Raghuvaran, J. G. T. (2020). Prediction of specific wear rate for LM25/ZrO2 composites using Levenberg–Marquardt backpropagation algorithm. Journal of Materials Research and Technology, 9(1), 530-538.
- Kaushik, M., & Mathur, B. (2014). Comparative study of K-means and hierarchical clustering techniques. Int. J. Softw. Hardw. Res. Eng, 2(6), 93-98.
- Kaushik, M., Pathak, S., Bhatt, P. K., Singh, S. K., Tripathi, A., & Pandey, P. K. (2022). Artificial Intelligence (AI). Intelligent system algorithms and applications in science and Technology, 119-133.
- Kessler, O., Herding, T., Hoffmann, F., & Mayr, P. (2004). Microstructure and wear resistance of CVD TiN-coated and induction surface hardened steels. Surface and Coatings Technology, 182(2-3), 184-191.
- Khonsari, M. M., Booser, E. R., & Nikas, G. (2010). On the Stribeck curve. Recent Developments in Wear Prevention, Friction and Lubrication, 661, 263-278.
- Kopeliovich, D., 2023. Mechanisms of wear. Substances & Technologies, https://www.substech.com/dokuwiki/doku.php?id=mechanisms_of_wear (25.06.2023).
- Kovacı, H., 2016. Plazma nitrüleme, DLC kaplama ve dubleks yüzey işlemlerinin AISI 4140 çeliklerinin çeki ve bası aşırı yükleri altındaki yorulma çatlak ilerleme davranışı üzerindeki etkileri. Doktora Tezi, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum.
- Kovacı, H., Yetim, A. F., Baran, Ö., & Çelik, A. (2018). Tribological behavior of DLC films and duplex ceramic coatings under different sliding conditions. Ceramics International, 44(6), 7151-7158.
- Larsen-Basse, J.(1992). Friction, Lubrication and Wear technology, ASM Handbook Vol. 18,

- Li, B. H., Hou, B. C., Yu, W. T., Lu, X. B., & Yang, C. W. (2017). Applications of artificial intelligence in intelligent manufacturing: a review. *Frontiers of Information Technology & Electronic Engineering*, 18(1), 86-96.
- Loh, W. Y. (2011). Classification and regression trees. *Wiley interdisciplinary reviews: data mining and knowledge discovery*, 1(1), 14-23.
- Lyashenko, I. A. (2011). Tribological properties of dry, fluid, and boundary friction. *Technical Physics*, 56, 701-707.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381-386.
- Mang, T., & Dresel, W. (Eds.). (2007). *Lubricants and lubrication*. John Wiley & Sons.
- Marian, M., & Tremmel, S. (2021). Current trends and applications of machine learning in tribology—a review. *Lubricants*, 9(9), 86.
- Marinescu, I. D., Rowe, W. B., Dimitrov, B., & Ohmori, H. (2012). *Tribology of abrasive machining processes*. William Andrew.
- Mechelli, A., & Viera, S. (Eds.). (2019). *Machine learning: methods and applications to brain disorders*. Academic Press.
- Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). *Machine learning: algorithms and applications*. Crc Press.
- Mokyr, J., & Strotz, R. H. (1998). The second industrial revolution, 1870-1914. *Storia dell'economia Mondiale*, 21945(1).
- Monkeylearn. (2021). An Introduction to Machine Learning. [monkeylearn.com: https://monkeylearn.com/machine-learning/](https://monkeylearn.com/machine-learning/)
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis*. John Wiley & Sons.
- Muthukrishnan, R., & Rohini, R. (2016, October). LASSO: A feature selection technique in predictive modeling for machine learning. In *2016 IEEE international conference on advances in computer applications (ICACA)* (pp. 18-20). IEEE.
- Nahavandi, S. (2019). Industry 5.0—A human-centric solution. *Sustainability*, 11(16), 4371.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons*. b, 4, 51-62.
- Nilsson, N. J. (1998). *Artificial Intelligence: A New Synthesis*. San Francisco: Morgan Kaufmann Publishers
- Nozari, H., & Sadeghi, M. E. (2021). Artificial intelligence and Machine Learning for Real-world problems (A survey). *International Journal of Innovation in Engineering*, 1(3), 38-47.
- Nuruzzaman, D. M., Rahaman, M. L., & Chowdhury, M. A. (2012). Friction coefficient and wear rate of polymer and composite materials at different sliding speeds. *International Journal of Surface Science and Engineering*, 6(3), 231-245.
- Odabas, D. (2018). Effects of load and speed on wear rate of abrasive wear for 2014 Al alloy. In *IOP conference series: materials science and engineering* (Vol. 295, No. 1, p. 012008). IOP Publishing.
- Pisner, D. A., & Schnyer, D. M. (2020). Support vector machine. In *Machine learning* (pp. 101-121). Academic Press.

- Rabinowicz, E. (1995). *Friction and Wear of Materials*, Jhon Wiley & Sons. Inc., New York, 65-123.
- Rebai, H. (2014). *Tribology and machine elements*.
- Rifkin, J. (2011). *The third industrial revolution: how lateral power is transforming energy, the economy, and the world*. Macmillan.
- Salman, M. S., Kukrer, O., & Hocanin, A. (2017). Recursive inverse algorithm: Mean-square-error analysis. *Digital Signal Processing*, 66, 10-17.
- Santhosh, N., Praveena, B. A., Jain, R., Hasan, M. A., Islam, S., Khan, M. A., ... & Daniyal, M. (2022). Analysis of friction and wear of aluminium AA 5083/WC composites for building applications using advanced machine learning models. *Ain Shams Engineering Journal*, 102090.
- Schwab, K. (2017). *The fourth industrial revolution*. Currency.
- Sinaga, K. P., & Yang, M. S. (2020). Unsupervised K-means clustering algorithm. *IEEE access*, 8, 80716-80727.
- Singh, K. S. K., Kumar, S., & Singh, K. K. (2022). Computational data-driven based optimization of tribological performance of graphene filled glass fiber reinforced polymer composite using machine learning approach. *Materials Today: Proceedings*, 66, 3838-3846.
- Singh, S., & Saleh, M. S. S. (2020). Prediction of Depth Maps using Semi-Supervised Learning.
- Stachowiak, G. W., & Batchelor, A. W. (2013). *Engineering tribology*. Butterworth-heinemann.
- Taunk, K., De, S., Verma, S., & Swetapadma, A. (2019, May). A brief review of nearest neighbor algorithm for learning and classification. In *2019 international conference on intelligent computing and control systems (ICCS)* (pp. 1255-1260). IEEE.
- Taylor, C. M., & Wedeven, L. D. (1996). Boundary lubrication. *Tribology & Interface Engineering Series*, 30, 1-76.
- Thankachan, T., Soorya Prakash, K., Kavimani, V., & Silambarasan, S. R. (2021). Machine learning and statistical approach to predict and analyze wear rates in copper surface composites. *Metals and Materials International*, 27(2), 220-234.
- UNCTAD (2019). *Value Creation And Capture: Implications For Developing Countrie*, Digital Economy Report.
- Wang, G., Ruan, Y., Wang, H., Zhao, G., Cao, X., Li, X., & Ding, Q. (2022). Tribological performance study and prediction of copper coated by MoS₂ based on GBRT method. *Tribology International*, 108149.
- Wenzel, H., Smit, D., & Sardesai, S. (2019). A literature review on machine learning in supply chain management. In *Artificial Intelligence and Digital Transformation in Supply Chain Management: Innovative Approaches for Supply Chains*. Proceedings of the Hamburg International Conference of Logistics (HICL), Vol. 27 (pp. 413-441). Berlin: epubli GmbH.
- Wong, P. C. (2021). Unsupervised machine learning. *Computational Psychometrics: New Methodologies for a New Generation of Digital Learning and Assessment: With Examples in R and Python*, 173-193.
- Wu D, Jennings C, Terpenney J, Gao RX, Kumara S (2017) A comparative study on machine learning algorithms for smart manufacturing: tool wear prediction using random forests. *J Manuf Sci Eng* 139(7):9

- Khafa, F. (2021). Machine Learning, Big Data, and IoT for Medical Informatics. Academic Press.
- Xianqiang Pei, Qihua Wang, Jianmin Chen; (2005) Tribological responses of Phenolphthalein Poly (ether sulfone) on proton irradiation; Elsevier, Wear, 719-724.
- Yigezu, B. S., Mahapatra, M. M., & Jha, P. K. (2013). On modeling the abrasive wear characteristics of in situ Al–12% Si/TiC composites. Materials & Design, 50, 277-284.
- Yin, N., Xing, Z., He, K., & Zhang, Z. (2023). Tribo-informatics approaches in tribology research: A review. Friction, 11(1), 1-22.
- Young, H. D., Freedman, R. A., & Ford, A. L. (2013). University Physics with Modern Physics Technology Update. Pearson Education.
- Yusoff, Z., ve Jamaludin, S. (2011). “Tribology and development of wear theory: review and discussion”. International Journal of Current Research and Review, 3(2), 13-25.
- Zhang, F., & O'Donnell, L. J. (2020). Support vector regression. In Machine learning (pp. 123-140). Academic Press.
- Zhang, Z., Yin, N., Chen, S., & Liu, C. (2021). Tribo-informatics: Concept, architecture, and case study. Friction, 9(3), 642-655.
- Zhu, X., & Goldberg, A. B. (2009). Introduction to semi-supervised learning. Synthesis lectures on artificial intelligence and machine learning, 3(1), 1-130.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Şenay ER
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
Tel:	
E-mail:	
Eğitim	
Yabancı Dil Bilgisi	