

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİBRİT VE
KOMPOZİT ZA-27 ALAŞIMLARININ AŞINMA
DAVRANIŞLARININ KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

Sena Nur ADIYAMAN

Endüstri Mühendisliği Anabilim Dalı

EKİM 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİBRİT VE
KOMPOZİT ZA-27 ALAŞIMLARININ AŞINMA
DAVRANIŞLARININ KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

Sena Nur ADIYAMAN

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Gültekin ÇAĞIL

EKİM 2024

Sena Nur ADIYAMAN tarafından hazırlanan “MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİBRİT VE KOMPOZİT ZA-27 ALAŞIMLARININ AŞINMA DAVRANIŞLARININ KARŞILAŞTIRMALI ANALİZİ” adlı tez çalışması 23.10.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Ahmet Kürşad TÜRKER Kırıkkale Üniversitesi	
Jüri Üyesi :	Doç. Dr. Gültekin ÇAĞIL (Danışman) Sakarya Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Serap ERCAN CÖMERT Sakarya Üniversitesi	

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİBRİT VE KOMPOZİT ZA-27 ALAŞIMLARININ AŞINMA DAVRANIŞLARININ KARŞILAŞTIRMALI ANALİZİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(02/11/2024)

SENA NUR ADIYAMAN







TEŞEKKÜR

Eğitim hayatım boyunca bilgi ve tecrübeleri ile yol gösteren, tez çalışmamın her aşamasında benden hiçbir zaman desteklerini esirgemeyen değerli tez danışmanım Doç. Dr. Gültekin ÇAGIL’a,

Tez jürimde yer alarak yapmış oldukları katkı, yorum ve yönlendirmelerinden dolayı Prof. Dr. Ahmet Kürşad TÜRKER’e ve Dr. Öğr. Üyesi Serap ERCAN CÖMERT’e,

Tüm hayatım boyunca gerek maddi gerek manevi olarak yanımda olan ve bana en büyük sevgiyi veren sevgili babam Necati GÜLER, annem Halime GÜLER, ağabeyim Melih GÜLER ve kardeşim Emirhan GÜLER’e,

Tez hazırlama sürecimde motivasyonu, yardımları ve sonsuz sevgisiyle yanımda olan canım eşim Burak ADIYAMAN’a

Tüm kalbimle teşekkürlerimi sunarım.

Sena Nur ADIYAMAN



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ.....	1
1.1. Literatür Taraması	3
2. MATERYAL VE YÖNTEM.....	17
2.1. Veri Seti.....	17
2.2. Veri Ön İşleme	20
2.2.1. Aykırı değer analizi.....	22
2.2.2. Normalizasyon	22
2.3. Korelasyon Analizi.....	23
2.4. Geliştirme Ortamı.....	25
2.4.1. Matlab	25
2.4.2. Google Colaboratory	25
2.4.3. Kullanılan kütüphaneler ve tahmin metodu	26
2.5. Performans Ölçümleri ve Hata Analizleri	27
2.5.1. Mutlak değişim yüzdesi (R^2).....	28
2.5.2. Ortalama karesel hata (MSE)	28
2.5.3. Hata kareler ortalamasının karekökü (RMSE).....	28
2.5.4. Ortalama mutlak hata (MAE)	28
3. YAPAY ZEKA	31
3.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS).....	32
3.1.1. Bulanık kural yapısı	34
3.2. Makine Öğrenmesi	35
3.2.1. Denetimli öğrenme algoritmaları	38
3.2.1.1. Doğrusal regresyon (LR).....	38
3.2.1.2. Gauss süreç regresyonu (GPR)	39
3.2.1.3. Karar ağacı regresyonu (DTR).....	40
3.2.1.4. Rasgele orman regresyonu (RFR).....	41
3.2.1.5. Yapay sinir ağları (ANN).....	42
3.2.1.6. Destek vektör regresyonu (SVR)	43
3.2.2. Denetimsiz (gözetimsiz) öğrenme	44
4. UYGULAMA.....	47
4.1. Uygulama Amacı.....	47
4.2. Doğrusal Regresyon (LR)	47

4.3. Karar Ağacı Regresyonu (DTR).....	48
4.4. Destek Vektör Regresyonu (SVR)	48
4.5. Rasgele Orman Regresyonu (RFR)	49
4.6. Yapay Sinir Ağları (ANN)	50
4.7. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS).....	52
4.8. Gauss Süreç Regresyonu (GPR).....	63
4.9. Önerilen Modellerin Karşılaştırılması	64
4.10. Farklı Eğitim ve Test Verileri ile Kullanılan Yöntemlerin Karşılaştırılması	66
4.11. ANFIS Model Sonuçlarının Bağımlı Örneklem T Testi ile Analizi.....	70
5. SONUÇ VE ÖNERİLER.....	73
KAYNAKLAR.....	75
ÖZGEÇMİŞ.....	81



KISALTMALAR

AA 2618	: Alüminyum alaşım 2618
AI	: Yapay zekâ
AL	: Alüminyum
AlN	: Alüminyum nitrür
ANFIS	: Uyarlamalı ağ tabanlı bulanık çıkarım sistemi
ANN	: Yapay Sinir Ağları
BST	: Güçlendirilmiş karar ağacı
CaCO₃	: Kalsiyum karbonat
Dsigmf	: Dsigmoidal üyelik fonksiyonu
DT	: Karar ağaçları
DTR	: Karar ağacı regresyonu
Gauss2mf	: Gaussian 2 üyelik fonksiyonu
Gaussmf	: Gaussian üyelik fonksiyonu
Gbellmf	: Genelleştirilmiş çan üyelik fonksiyonu
GPR	: Gauss süreç regresyonu
GTK	: Grafit takviyeli kompozit
HKM	: Hibrit kompozit malzeme
IBA	: İnsan bilgisayar arabilimi
KNN	: K-en yakın komşu algoritması
L25	: Taguchi L25 ortogonal dizi tasarımı
LR	: Doğrusal regresyon
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama mutlak yüzde hatası
ML	: Makine öğrenmesi
MSE	: Ortalama karesel hata
Pimf	: Pi üyelik fonksiyonu
Psigmf	: P sigmoidal üyelik fonksiyonu
R²	: Determinasyon katsayısı
RFR	: Rasgele orman regresyonu
RMSE	: Hata kareler ortalamasının karekökü

Si₃N₄	: Silisyum nitrür
SiC	: Silisyum kalbür
Sigmf	: Sigmoidal üyelik fonksiyonu
STK	: Silisyum kalbür takviyeli kompozit
SVR	: Destek vektör regresyonu
TiO₂	: Titanyum Dioksit
Trapmf	: Yamuk üyelik fonksiyonu
Trimf	: Üçgen üyelik fonksiyonu
ZrB₂	: Zirkonyum diborür



SİMGELER

$\perp$	: Dikey çizgi
N	: Newton [kg.m/s ²]
S_p	: Silisyum karbür parçacık boyutu [μm]
S_x	: Standart Sapma
W_m	: Alüminyum yüzde ağırlığı [%]
W_p	: Silisyum karbür yüzde ağırlığı [%]
X	: Giriş değişkeni
Y	: Çıkış değişkeni
ε	: Hata katsayısı
Θ	: Theta vektörü
μ	: Mikro



TABLO LİSTESİ

Sayfa

Tablo 1.1. Literatür taraması özet tablosu.	11
Tablo 2.1. Bağımsız değişkenler özet tablosu.	19
Tablo 2.2. Veri setine ait tanımlayıcı istatistikler.....	21
Tablo 2.3. Değişkenlerin ortalama ve standart sapma değerleri.	23
Tablo 3.1. İnsan zekâsı ile yapay zekanın karşılaştırılması (Pirim, 2018).	31
Tablo 4.1. ANFIS parametreleri.	53
Tablo 4.2. Farklı üyelik fonksiyonlarında test veri seti için model performans sonuçları.	55
Tablo 4.3. 3 3 3 2 Üyelik fonksiyonu için tüm üyelik fonksiyon tiplerindeki model performans sonuçları.	56
Tablo 4.4. Kurulan modellerin performanslarının karşılaştırılması.	64
Tablo 4.5. Veri seti 1 ile elde edilen sonuçlar.	67
Tablo 4.6. Veri seti 2 ile elde edilen sonuçlar.	68
Tablo 4.7. Veri seti 3 ile elde edilen sonuçlar.	68
Tablo 4.8. Veri seti 4 ile elde edilen sonuçlar.	69
Tablo 4.9. Veri seti 5 ile elde edilen sonuçlar.	69
Tablo 4.10. Gerçek çıktılar ile model çıktıları karşılaştırması.	70
Tablo 4.11. Gerçek çıktılar ile model çıktıları karşılaştırması.	71



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. ZA-27 alaşımının mikroskopik yapısı (ASM International 2004).	17
Şekil 2.2. Bakır metali ile kaplanan grafit yüzeyi (Aslan, 2004).....	18
Şekil 2.3. CSM Instruments Tribometer aşınma cihazı (Suzin, 2011).	18
Şekil 2.4. Hacimsel aşınma hızı verileri.	20
Şekil 2.5. Korelasyon Analizi.	25
Şekil 2.6. Ağ eğitimi için akış şeması.....	27
Şekil 3.1. ANFIS yapısı (Shahbazikhah ve ark, 2011).	32
Şekil 3.2. Bulanık çıkarım sistemi.	35
Şekil 3.3. Yapay zekâ, makine öğrenmesi, yapay sinir ağları ve derin öğrenme ilişki şeması.	36
Şekil 3.4. Makine öğrenmesi işlem adımları.	36
Şekil 3.5. Makine öğrenmesi yöntem grupları.....	37
Şekil 3.6. Denetimli makine öğrenmesi (Langs ve ark, 2018).....	38
Şekil 3.7. Karar ağacı yapısı.	40
Şekil 3.8. Rasgele orman algoritma şeması.	41
Şekil 3.9. Yapay sinir ağları (ANN) şematik diyagramı (Kushwaha ve ark, 2024). .	43
Şekil 3.10. Denetimsiz makine öğrenmesi (Langs ve ark, 2018).	45
Şekil 4.1. Doğrusal regresyon gerçek ve tahmin değerleri ilişkisi.	48
Şekil 4.2. Karar ağacı regresyonu gerçek ve tahmin değerleri ilişkisi.....	48
Şekil 4.3. Destek vektör regresyonu gerçek ve tahmin değerleri ilişkisi.....	49
Şekil 4.4. Rasgele orman regresyonu gerçek ve tahmin değerleri ilişkisi.	49
Şekil 4.5. Tasarlanan ANN yapısı.....	50
Şekil 4.6. Eğitim ve test veri seti için R^2 değerleri.	51
Şekil 4.7. Gerçek çıktı ve ANN modeli çıktı değerleri hata histogram grafiği.	51
Şekil 4.8. Modelin performans ölçütleri.	52
Şekil 4.9. Hacimsel aşınma hızı tahmini için ANFIS model yapısı.....	54
Şekil 4.10. Test ve eğitim verilerinin ANFIS modeline aktarılması.	54
Şekil 4.11. Eğitim veri seti tahmin sonuçları.	57
Şekil 4.12. Test veri seti tahmin sonuçları.....	58
Şekil 4.13. ANFIS ile hacimsel aşınma hızı tahmini.	58
Şekil 4.14. ANFIS yapısı ağ modeli.	59
Şekil 4.15. ANFIS bulanık kuralları 1. Örneği.	59
Şekil 4.16. ANFIS bulanık kuralları 2. Örneği.	60
Şekil 4.17. ANFIS bulanık kuralları karşılaştırma örneği.	60
Şekil 4.18. Yüzey model grafikleri.	62
Şekil 4.19. Karar ağacı regresyonu gerçek ve tahmin değerleri ilişkisi.....	64
Şekil 4.20. Modellerin hata istatistikleri grafiği.	65
Şekil 4.21. Modellerin değişim yüzdesi (R^2) değerleri.....	66



MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİBRİT VE KOMPOZİT ZA-27 ALAŞIMLARININ AŞINMA DAVRANIŞLARININ KARŞILAŞTIRMALI ANALİZİ

ÖZET

Çinko alüminyum alaşımları, yüksek mukavemet, iyi dökülebilirlik ve üstün aşınma direnci gibi mekanik özellikleri nedeniyle endüstride önemli bir rol oynamaktadır. Özellikle ZA-27 alaşımı, bu özellikleriyle pirinç, dökme demir ve bronzla daha üstün performans göstermekte ve torna tezgâhı, su pompaları, çim biçme makineleri, tekstil ve otomotiv sanayisi gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Son yıllarda ZA-27 alaşımının aşınma direncini daha da artırmak amacıyla yapılan çalışmalar büyük bir ivme kazanmıştır.

Bu çalışmada, ZA-27 alaşımına SiC ve Grafit partikülleri eklenerek üretilen hibrit kompozit malzemelerin aşınma direnci performanslarının tahmin edilmesi amaçlanmıştır. Aşınma direncinin iyileştirilmesi için yapılan deneyler maliyet, zaman ve iş gücü açısından yüksek gereksinimler doğurduğundan, bu çalışmada makine öğrenmesi yöntemleri kullanılarak deney sayısının minimize edilmesi ve ara değerler hakkında tahminlerde bulunulması hedeflenmiştir.

Çalışmada, 240 adet veri seti %80 eğitim ve %20 test verisi olarak ayrılmış, Python ve MATLAB platformlarında çeşitli makine öğrenmesi modelleri uygulanmıştır. Bu modeller arasında Doğrusal Regresyon (LR), Karar Ağacı Regresyonu (DTR), Rasgele Orman Regresyonu (RFR), Destek Vektör Regresyonu (SVR), Yapay Sinir Ağları (ANN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Gauss Süreç Regresyonu (GPR) yer almaktadır. Modellerin performansları, Ortalama Kare Hatası (MSE), Hata Kareler Ortalamasının Karekökü (RMSE), Ortalama Mutlak Hata (MAE) ve Mutlak Değişim Yüzdesi (R^2) istatistikleri kullanılarak değerlendirilmiştir.

Elde edilen sonuçlar, ANFIS modelinin diğer modellere kıyasla üstün performans gösterdiğini ve en düşük hata değerleri ile en yüksek doğruluk oranlarına sahip olduğunu net bir şekilde ortaya koymuştur. ANFIS modelinin ortalama kare hata (MSE) değeri 0.0428 olarak hesaplanmış olup, bu değer, değerlendirmeye alınan diğer modellerden anlamlı derecede düşüktür. Ayrıca, R^2 değeri açısından 0.9291 gibi yüksek bir başarıya ulaşarak, ANFIS modelinin verilerin açıklanabilirliğinde ve tahmin doğruluğunda ne kadar güçlü bir araç olduğunu göstermiştir. Bu modelin ardından Yapay Sinir Ağları (ANN) ve Gauss Süreç Regresyonu (GPR) modelleri de yüksek doğruluk oranları ile öne çıkmıştır. ANN modelinin MSE değeri 0.0516 ve R^2 değeri 0.9168 olarak bulunurken, GPR modelinin MSE değeri 0.0652 ve R^2 değeri 0.9024 olarak hesaplanmıştır. Bu sonuçlar, SiC ve Grafit partiküllü takviyeli ZA-27 hibrit kompozit malzemelerinin aşınma direncini artırmadaki potansiyelini ve makine öğrenmesi yöntemlerinin bu tür malzeme performansı tahminlerinde etkin bir araç olduğunu ortaya koymaktadır.

Sonuç olarak, bu çalışma, ZA-27 alaşımının aşınma direncini artırmada yapay zekâ ve makine öğrenmesi yöntemlerinin etkinliğini vurgulamakla kalmamış, aynı zamanda

endüstriyel uygulamalarda deney maliyetlerini düşürmenin de mümkün olduğunu göstermiştir. Çalışma, gelecekte daha geniş veri setleri, farklı alaşım bileşimleri ve daha karmaşık modelleme yaklaşımları ile gerçekleştirilecek araştırmalar için önemli bir referans noktası oluşturmaktadır. Özellikle, makine öğrenmesi tabanlı yöntemlerin bu tür mühendislik problemlerinde yenilikçi ve uygulanabilir çözümler sunduğu bir kez daha kanıtlanmıştır.



COMPARATIVE ANALYSIS OF WEAR BEHAVIOR OF HYBRID AND COMPOSITE ZA-27 ALLOYS USING MACHINE LEARNING METHODS

SUMMARY

ZA-27 alloy is highly regarded for its exceptional mechanical properties, impressive wear resistance, and excellent castability, making it a standout material in zinc-aluminum alloys. Compared to traditional materials such as brass, cast iron, and bronze, ZA-27 alloy provides excellent durability and reduced weight. This advantageous profile renders it an appealing alternative for numerous industrial applications. Notably, the alloy's outstanding wear resistance, particularly in comparison to brass alloys widely employed as sliding-bearing materials, highlights its relevance in various engineering fields. As a result, ZA-27 alloy has found widespread applications in diverse sectors such as lathe machines, water pumps, lawnmowers, textile machinery, and the automotive industry.

Despite its many advantages, industries worldwide face significant economic challenges arising from wear-related issues. These problems lead to substantial maintenance, replacement, and downtime costs. Consequently, there is an urgent need to develop materials with enhanced wear resistance to address these challenges. This necessity drives ongoing efforts in materials engineering to design and produce advanced materials that can reduce wear-related losses and improve the longevity and performance of industrial components. These efforts often involve labor-intensive, costly, and time-consuming experimental studies aimed at optimizing the properties of materials.

In response to these challenges, hybrid composite materials reinforced with silicon carbide (SiC) and graphite particles have been developed to improve the mechanical properties and wear resistance of ZA-27 alloy. SiC particles are renowned for their high hardness and ability to enhance wear resistance, while graphite particles contribute to improving the sliding properties of the material due to their intrinsic lubricating characteristics. The synergistic effects of these reinforcements result in hybrid composites with superior performance under demanding conditions. The squeeze casting method was employed to fabricate these composites, ensuring the uniform distribution of reinforcement particles and the creation of a homogeneous microstructure. This process involved mixing SiC and graphite particles into the molten ZA-27 alloy using a vortex technique, followed by solidification under a pressure of 50 MPa. This approach optimized the mechanical properties of the resulting material and ensured consistent performance across varying operating conditions.

Although experimental methods have traditionally been the primary approach for evaluating the properties of materials, the high costs and extended timeframes associated with such studies have increasingly prompted researchers to explore alternative methodologies. Artificial intelligence (AI) and machine learning (ML) techniques have emerged as powerful tools for addressing these challenges. These computational methods have the potential to significantly streamline research

processes by enabling accurate predictions of material behavior with reduced reliance on extensive experimental trials. Machine learning algorithms, in particular, are adept at analyzing complex datasets to uncover patterns and relationships that may not be readily apparent through traditional approaches. Their ability to handle multifaceted problems makes them invaluable in advancing materials science.

This study employed AI and ML techniques to predict the volumetric wear rates of hybrid composite materials under various loading and sliding speed conditions. The primary objective was to determine the wear rate as a function of four independent variables: SiC ratio, graphite ratio, applied load, and sliding speed. A comprehensive dataset comprising 240 experimental results was compiled to achieve this goal. This dataset was divided into training and testing subsets, with 80% of the data allocated for training and 20% reserved for testing. The training dataset facilitated the development and optimization of predictive models, while the testing dataset provided an independent evaluation of the models' generalization capabilities, ensuring their reliability in predicting wear rates for unseen data.

The study implemented various machine-learning algorithms using Python and MATLAB software environments. Python-based analyses focused on algorithms such as Linear Regression (LR), Decision Tree Regression (DTR), Random Forest Regression (RFR), and Support Vector Regression (SVR). These models were selected for their ability to handle simple and complex relationships between the variables. In parallel, MATLAB was employed to explore more advanced AI models, including Artificial Neural Networks (ANN), Adaptive Neuro-Fuzzy Inference Systems (ANFIS), and Gaussian Process Regression (GPR). Each of these models offers unique advantages and limitations depending on the complexity of the data and the nature of the relationships among the input variables.

To assess the performance of the models, several statistical metrics were employed, including Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and the Coefficient of Determination (R^2). These metrics comprehensively evaluated each model's accuracy and error rates, enabling a robust comparison of their predictive capabilities. Among the evaluated models, the ANFIS model demonstrated the highest predictive accuracy, achieving an MSE value of 0.0428 and an R^2 value of 0.9291. These results highlight ANFIS's exceptional ability to model the complex relationships between the independent variables and the volumetric wear rate, making it the most effective predictive tool in this study.

Following ANFIS, the ANN and GPR models also delivered strong performances. The ANN model achieved an MSE value of 0.0516 and an R^2 value of 0.9168, indicating its robustness in handling nonlinear relationships within the dataset. Similarly, the GPR model yielded an MSE value of 0.0652 and an R^2 value of 0.9024, confirming its suitability for material property prediction tasks. By contrast, simpler algorithms such as LR and DTR exhibited comparatively lower accuracy, underscoring the limitations of these methods in capturing the intricate interactions between the variables. These results emphasize the importance of employing advanced models for complex and nonlinear datasets tasks.

The findings of this study underscore the significant benefits of hybrid composites reinforced with SiC and graphite particles in enhancing the wear resistance of ZA-27 alloy. These reinforcements not only improved the mechanical and tribological properties of the alloy but also highlighted its potential for use in demanding industrial applications. Moreover, the study demonstrated the transformative potential of AI and

ML techniques in materials engineering. These computational tools offer a means to address complex challenges with remarkable efficiency, providing accurate predictions that reduce the need for extensive experimental testing.

Among the various models evaluated, the ANFIS model emerged as a potent tool, delivering unparalleled predictive accuracy and minimal error rates. Its performance highlights the value of hybrid approaches that combine the strengths of neural networks and fuzzy logic systems. By effectively capturing the nonlinear relationships and uncertainties inherent in the dataset, ANFIS proved an indispensable asset in this study. The success of ANFIS and other advanced models underscores the broader applicability of AI methodologies in optimizing industrial processes and advancing materials science research.

The implications of this study extend beyond its immediate findings, offering valuable insights for future research and practical applications. One potential avenue for further investigation involves the incorporation of more extensive and more diverse datasets. Expanding the dataset could enhance the generalizability of the predictive models and provide a deeper understanding of the factors influencing material properties. Additionally, exploring alternative material compositions and introducing new independent variables could uncover further opportunities for optimization. For instance, parameters such as temperature, environmental conditions, or additional reinforcement materials could provide a more comprehensive evaluation of the material's performance.

Another promising direction involves the adaptation and comparison of other AI techniques from the literature. Methods such as deep learning, ensemble learning, or evolutionary algorithms could be explored to identify their relative strengths and weaknesses in addressing similar problems. By comparing the performance of these methods, researchers can gain valuable insights into the most effective approaches for specific applications. Moreover, integrating AI techniques with traditional experimental methods could pave the way for hybrid methodologies that combine computational tools' precision with empirical data's reliability.

This study highlights the critical role of interdisciplinary approaches in advancing materials engineering. By integrating AI and ML techniques with experimental research, this work demonstrates the potential to develop more efficient and sustainable engineering solutions. The findings emphasize the importance of continued investment in computational tools and their application to complex engineering problems. Such efforts are essential to meet the evolving demands of modern industries and drive technological innovation.

In conclusion, this study highlights the effectiveness of hybrid composites and the potential of artificial intelligence (AI) and machine learning (ML) techniques in materials engineering. The findings validate the effectiveness of advanced computational methods in predicting material properties while demonstrating their broader applicability in optimizing industrial processes and enhancing overall efficiency. These advancements underscore the value of addressing complex engineering problems by reducing costs while promoting sustainability.

Based on the findings of this research, future studies can further enhance the understanding and performance of advanced materials and contribute to developing innovative solutions to the challenges faced by modern industries. Furthermore, integrating these methods with larger datasets and real-time systems can support the

development of more durable and adaptive material designs for various industrial applications.



1. GİRİŞ

Çinko Alüminyum alaşımlarından olan ZA-27 alaşımı endüstride pirinç, dökme demir ve bronzla göre aşınma direnci, mukavemet ve dökülebilirlik gibi birçok mekanik özellik bakımından oldukça üstündür. Özellikle kaymalı yatak malzemesi olarak kullanılan pirinç alaşımlarına göre yüksek aşınma direnci göstermektedir (Arıkan, 2007; Miroslav ve ark, 2010; Dominguez ve Lopez, 2002). Günümüzde torna tezgâhı gibi iş makinelerinden su pompalarına, çim biçme makinelerinden tekstil ve otomotiv endüstrisine kadar çeşitli sektörlerde kullanılmaktadır (Aydın, 2001). Ancak küresel endüstride aşınma ciddi boyutta ekonomik kayıplara sbebe olmaktadır. Bu amaçla araştırmaların odak noktası, aşınmaya dayanıklı kompozit malzemelerin geliştirilmesidir. Ancak, aşınmanın tamamen önlenmesi mümkün olmadığı bilinmektedir. Bu nedenle, aşınmaya dayanıklı kompozit malzemelerin geliştirilmesi sürecinde belirli deney ve aşamalardan geçilmesi gerekmektedir (Türk, 1996). Ayrıca aşınma direncinin geliştirilmesi ve mukavemetinin artırılması amacıyla partikül takviyeli kompozit malzeme üretimi deneyleri yapılmaktadır. Bu bağlamda yüksek aşınmaya karşı yüksek direnç gösteren SiC partikülleri ve yağlayıcı faz olan Grafit partikülleri ZA-27 alaşımına katılarak hibrit kompozit malzeme üretilmiş ve aşınma direncinin geliştirilmesi hedeflenmiştir. Alaşım, kompozit ve hibrit kompozit malzemeler üretmek için sıkıştırma döküm yöntemi kullanılmaktadır. Üretimde ilk olarak SiC ve Grafit partikülleri ZA-27 alaşımına vorteks yöntemiyle karıştırılmış, sonrasında sıvı kompozit karışımı tekrar eritilerek 50 MPa basınç altında sıkıştırılarak katılaştırılmıştır (Aslan, 2004; Türk, 1996; Babic, 2010).

Kısıtlı kaynaklar ve yüksek maliyetlerden dolayı, deneylerin gerçekleştirilmesinin zaman, para ve emek açısından önemli bir süreç olduğu göz ardı edilememektedir. Ayrıca, malzeme seçimlerinin doğru yapılmaması durumunda gerçekleştirilen analizler başarısız sonuçlar verebilmekte ve sürekli olarak tekrarlanması gerekebilmektedir. Bu zorlu koşullar altında, deney verileri için doğru bir algoritma oluşturulması ve bu algoritma aracılığıyla ara değerler hakkında tahminlerde bulunulması, deney sayısını minimize etmede önemli bir rol oynamaktadır.

Son yıllarda artan teknolojik gelişmeler, insan beyninin işleyişi taklit ederek karmaşık problemleri çözmeyi hedefleyen Yapay Zekâ (AI) ve öğrenme yetenekleriyle birlikte veri kümelerinden doğru çıktılar sağlamayı hedefleyen Makine Öğrenmesinin (ML) bu tür problemlerin çözümündeki önemini arttırmıştır. Bu nedenle, deney sayısını minimize etmek amacıyla geliştirilen algoritmaların ve yapay zekâ yöntemlerinin kullanımı önem kazanmaktadır. Literatürde çeşitli alanlarda bu konuyla ilgili çok sayıda çalışma bulunmaktadır.

ZA-27 alaşımını daha dayanıklı hale getirmek ve endüstriyel kayıpları azaltmak amacıyla üretilen SiC ve Grafit partikülü takviyeli kompozit ve hibrit kompozit malzemenin farklı yük ve kayma hızlarında hacimsel olarak aşınma hızları ölçülmüştür. Bu çalışma, yapılan bu sınırlı sayıdaki deneylerin ara değerlerini bulmak amacıyla maliyet, zaman ve iş gücünü azaltmak için işlem hızlılığı ve karar verme becerisi yönünden güçlü olan Yapay Zekâ yöntemlerinden yararlanmayı ve en doğru yorumlamayı yapmayı hedeflemektedir.

Bu çalışmada, yapay zekâ yöntemlerinden yararlanılarak geliştirilen modellerde SiC Oranı, Grafit Oranı, Yük ve Kayma Hızı gibi dört bağımsız değişken kullanılarak Hacimsel Aşınma Hızı tahmin edilmiştir. Tezde, 240 adet deney verisi %80 eğitim ve %20 test olmak üzere iki gruba ayrılmış ve 192 adet eğitim veri kümesi ile 48 adet test veri kümesi oluşturulmuştur. İlk olarak eğitim verisi kullanılarak modeller eğitilmiş, ardından test verisi ile tahminler gerçekleştirilmiş ve başarı performansları karşılaştırılmıştır.

Veri setinden en doğru sonucu elde edebilmek amacıyla, Google Colaboratory platformunda Python programlama dili ve farklı ağ yapıları kullanılmış, ayrıca MATLAB yazılımı ile oluşturulan diğer modeller detaylı bir şekilde incelenmiştir. MATLAB'de Yapay Sinir Ağları (ANN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Gauss Süreç Regresyonu (GPR) yöntemleri analiz edilmiştir. Python dilinde ise, Makine Öğrenmesi algoritmalarından Doğrusal Regresyon (LR), Karar Ağacı Regresyonu (DTR), Rasgele Orman Regresyonu (RFR) ve Destek Vektör Regresyonu (SVR) yöntemleri kullanılarak Hacimsel Aşınma Hızı tahmin edilmiştir. Analiz edilen modellerin başarı performanslarını karşılaştırmak amacıyla Ortalama Karesel Hata (MSE), Ortalama Mutlak Hata (MAE), Hata Kareler Ortalamasının Karekökü (RMSE) gibi hata metrik yöntemleri ve Mutlak Değişim Yüzdesi (R2) kullanılmıştır.

Çalışmanın giriş bölümünden sonra, ZA-27 alaşımının, çinko alüminyum ve kompozit malzemelerin davranış özelliklerinin yanı sıra çalışma kapsamında kullanılan yöntemlerin incelendiği literatür taramasına yer verilmiştir. Çalışmanın 2. bölümünde, veri seti tanıtılmış, model geliştirme ortamlarından ve veri ön işleme adımlarından bahsedilmiştir. 3. bölüm, kullanılan yöntemler ve algoritmalar hakkında bilgi vermektedir. Nihayetinde model sonuçlarının paylaşıldığı 4. bölüm, model sonuçlarının karşılaştırıldığı ve yorumlandığı 5. bölüm bulunmaktadır.

1.1. Literatür Taraması

Reena Roy ve ark. (2023), çalışmalarında AA6063 matrisine %0.25, %0.5 ve %1 oranlarında ZrO_2 ekleyerek preslenmiş malzemeler üretmişlerdir. Bu malzemelerin aşınma performansını 80, 120 ve 150 mm/s'lik kayma hızlarında ve 10 N, 15 N, 20 N ve 25 N yüklerde incelemişlerdir. Destek Vektör Regresyonu (SVR), Rasgele Orman Regresyonu (RFR) ve Karar Ağaçları (DT) modelleri kullanılarak tahmin çalışmaları gerçekleştirilmiştir. Performans değerlendirmesinde RMSE, MSE, MAE ve R^2 istatistiklerinden yararlanılmıştır. Yöntemlerin MAE değerleri sırasıyla SVR için 0.30, RFR için 0.28 ve DT için 0.27 olarak bulunmuş olup, RFR ve DT yöntemlerinin SVR'ye göre daha başarılı sonuçlar verdiği gözlemlenmiştir.

Mishra ve Jatti (2023), AL/SiC metal matris kompozitlerinde aşınma oranlarını tahmin etmek için %0, %3 ve %5 ağırlık yüzdelerinde SiC içeren matris kompozitlerini Nöro-sembolik algoritma ve Yapay Sinir Ağları (ANN) ile karşılaştırmışlardır. Performans değerlendirmesi için R^2 ve MSE istatistikleri kullanılmıştır. ANN için yaklaşık %86 R^2 ve 0.99 MSE, Nöro-sembolik algoritma için ise %93 R^2 ve 0.46 MSE değerleri elde edilmiştir. Bu sonuçlar, Nöro-sembolik algoritmanın daha başarılı olduğunu göstermektedir.

Gangwar ve Pathak (2020), çalışmalarında %0, %2.5, %5, %7.5 ve %10 oranında mermer tozu takviyesinin ZA-27 alaşımlı kompozitlerin aşınma performansına etkisini belirlemek amacıyla Taguchi L25 ortogonal dizi tasarımıyla IBA optimizasyon algoritmasını ve ANN yöntemini kullanarak %96 oranında başarı elde etmişlerdir. Çalışmada MSE değeri 0.26 olarak bulunmuştur.

Babalola ve ark. (2017), alüminyumun yüzde ağırlığı (W_m), SiC yüzde ağırlığı (W_p) ve SiC parçacık boyutunu (Sp) girdi olarak kullanarak mikro sertlik, akma mukavemeti, çekme uzaması, modül, nihai çekme mukavemeti, çekme gerilimi,

kırılma süresi, maksimum uzatma yükü, sağlamlık, elektriksel direnç ve iletkenliği tahmin etmek amacıyla Yapay Sinir Ağları yöntemini kullanmışlardır. Çalışmada yaklaşık %94'lük bir test başarısına ulaşılmıştır.

Sosimi ve ark. (2020), Kalsiyum Karbonat takviyeli alüminyum kompozitin ($Al-CaCO_3$) aşınma direncini analiz etmek amacıyla Yapay Sinir Ağları ve ANFIS yöntemlerini birlikte kullanmışlardır. Farklı temas sürelerinde (30, 60, 90, 120 ve 150 s) ve 2,27 N, 4,54 N, 6,80 N değişken yüklerde aşınma testi verileri toplanarak 120 vektör elde etmişlerdir. Levenberg-Marquardt eğitim algoritmasının, 4-3-1 mimarisine sahip geri yayımlı sinir ağının kullanımında daha iyi performans gösterdiği bulunmuştur. Gbellmf, Gaussmf, Trapmf ve Trimf kullanılan Sugeno tipi ANFIS modelinin R2 değerleri sırasıyla %97.74, %97.75, %96.16 ve %95.01 iken ANN için %36.84 olarak bulunmuştur. Sonuçlar, kompozit malzemelerin aşınma direncini tahmin etmek için ANFIS modelinin daha uygun olduğunu göstermektedir.

Katmanlı üretim (AM) işlem parametrelerinin mikro yapı, kalıntı gerilme, yüzey pürüzlülüğü ve gözeneklilik gibi birçok faktöre bağlı olduğunu belirten Min ve ark. (2023), bu faktörlerin kombinasyonunu azaltmak amacıyla Makine Öğrenmesi tekniklerinden İleri Beslemeli Sinir Ağı (FNN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS), Konvolüsyonel Sinir Ağı (CNN), Destek Vektör Makinesi (SVM), Fizik Bilgili Sinir Ağları (PINN) ve Rasgele Orman (RF) kullanarak malzeme yorgunluk özelliklerini tahmin etmeyi amaçlamışlardır. Çeşitli malzemeler için lazer gücü, tarama hızı, maksimum gerilim, gerilim oranı, tarama alanı, kusur boyutu, kusur şekli, kusurun yeri ve gerilim genliği gibi özellikler girdi değişkenleri olarak kullanılırken, yorucu yaşam, yorgunluk varyansı ve yorulma çatlağı büyüme oranı gibi değişkenler çıktı olarak tahmin edilmiştir. R2 başarı oranı FNN için 0,65, CNN için %97, ANFIS için %79, SVR için %82 ve RF için %78 olarak bulunmuştur.

Radhakrishnan ve ark. (2016), Al 2219-SiC kompozit malzemenin aşınma direncini tahmin etmek amacıyla ağırlık oranı, sinterleme sıcaklığı, pime uygulanan normal yük ve disk hızı değişkenlerini dikkate alarak ileri beslemeli Yapay Sinir Ağları (ANN) uygulamışlardır. 81 veri setinin 49 adeti eğitim, 16 adeti doğrulama ve 16 adeti test için ayrılmış olup, %85 oranında başarı elde edilmiştir.

Kumar ve ark. (2017), çalışmalarında Al 6061 alaşımının aşınma direncini artırmak için TiO_2 takviyesi kullanılmıştır. Aşınma deneyleri, pim-disk aşınma izleme cihazı ve

Taguchi L27 ortogonal dizisi kullanılarak gerçekleştirilmiştir. %3 TiO₂ içeren Al6061 kompozitinin üstün aşınma direnci sergilediği bulunmuştur. ANN modeli ile yoğunluk, yük, takviye oranı, kayma mesafesi ve aşınma kaybı arasında doğrusal olmayan bir ilişki kurulmuştur. Deneysel sonuçlar ve ANN tahmini R²=0.9994 ile yüksek uyum göstermiştir. Bu model ile aşınma performansı başarılı şekilde tahmin edilmiştir.

Dorbane ve ark. (2022), çalışmalarında Al6061-T6 alüminyum alaşımının farklı sıcaklık seviyelerinde gerilme davranışlarını tahmin etmek için Gauss süreç regresyonu (GPR), Yapay sinir ağı (ANN) ve Güçlendirilmiş ağaçlar (BST) yöntemleri kullanılmıştır. Yöntemlerin performansı çekme testlerinden elde edilen gerçek gerilme ölçümleriyle doğrulanmıştır. Yöntemlerin istatistiksel skorları ise şu şekildedir: BST için RMSE 5.315, MAE 3.676, R² 0.899 ve MAPE 1.880; ANN için RMSE 0.720, MAE 0.340, R² 0.998 ve MAPE 0.213; GPR için RMSE 3.711, MAE 2.316, R² 0.936 ve MAPE 1.042. ANN ve GPR modellerinin farklı sıcaklıklarda tahmin hatasını azalttığını göstermiştir. Ayrıca, BST tabanlı tahmin yöntemi, YSA ve GPR yöntemleri ile karşılaştırılmıştır. Yapılan çalışma için en az hata ve en yüksek başarı oranını ANN modeli vermiştir.

Devi ve ark. (2020), çalışmalarında Alüminyum alaşımlarının gerilme direnci, sertlik ve verimlilik gibi mekanik özelliklerini tahmin etmek için LR, KNN ve ANN gibi üç farklı makine öğrenimi algoritması kullanılmıştır. KNN algoritması, gerilme direnci ve sertlik değerlerinin daha iyi tahminini verirken, verimlilik tahminlerinde ANN, diğer iki algoritmayla karşılaştırıldığında daha iyi sonuçlar verdiğini bulmuşlardır. Bu bağlamda, gerilme direnci tahmin modeli için KNN algoritmasının RMSE değeri 63.84, R² değeri ise 0.947; sertlik tahminleri için KNN algoritmasının RMSE değeri 15.86, R² değeri ise 0.96'dır. Verimlilik tahminlerinde ise ANN algoritmasının RMSE değeri 72.7, R² değeri ise 0.92 olarak bulunmuştur. KNN ve ANN modellerinin, LR modeline göre alüminyum alaşım mekanik özelliği tahmininde daha iyi sonuç verdiği görülmüştür. KNN algoritması, yüksek boyutlu verilerle iyi sonuçlar vermediği, verideki aykırı değerlere duyarlı olduğu saptanmıştır. Ancak, ANN, doğrusal olmayan ilişkilere bile daha iyi ve doğru sonuçlar verdiği görülmüştür.

Mathan Kumar ve ark. (2021), çalışmalarında, Silisyum Nitrür (Si₃N₄), Alüminyum Nitrür (AlN) ve Zirkonyum Borür (ZrB₂) ile güçlendirilmiş Alüminyum Alaşımının (AA 2618) termomekanik aşınma özellikleri üzerine tahmin çalışması yapmışlardır.

Üretilen metal matrisli kompozit (MMC) için aşınma özelliklerinin tahmini için Minitab aracından faydalanmışlardır. Aşınma özelliklerinin tahmini için regresyon modeli kullanılmış ve bu tahminler gerçek çıktılarla doğrusal ilişki göstermiştir. SVM ve ANN kullanılarak geliştirilen regresyon modeli ile aşınma karakteristiklerinin tahmini gerçekleştirilmiş ve ANN'in diğer yöntemlere kıyasla daha düşük bir Ortalama Mutlak Hata (MAE) sağladığı belirlenmiştir. RMSE, R², MSE ve MAE gibi istatistiksel performans parametrelerine dayanarak, regresyon modellerinin performansı SVM ve LR modelleri için benzerlik göstermiştir. RMSE değerleri SVM, LR ve ANN için sırasıyla 0.16, 0.15 ve 0.11; R² değeri ise SVM için %0.69, ANN için 0.87, LR modeli için ise 0.63 olarak bulunmuştur. MAE değerleri ise ANN, SVM, LR modelleri için sırasıyla 0.10, 0.26 ve 0.29 olarak bulunmuştur. Bu kapsamda, modellerin başarı performansı sırası ANN, SVM ve LR olarak belirlenmiştir.

Ružić ve ark. (2014), çalışmalarında mekanik alaşımlama yöntemiyle elde edilen tozların sıcak preslenmesiyle hazırlanan bakır bazlı kompozitlerin sertlik ve elektriksel özellikleri Yapay Sinir Ağları (YSA) yaklaşımıyla tahmin etmiştir. Modelde giriş değişkenleri olarak öğütme süresi, mekanik alaşımlı tozların parçacık boyutu, dislokasyon yoğunluğu ve basma akma gerilmesi kullanılmıştır. YSA modeli, genel regresyon sinir ağı (GRNN) mimarisi kullanılarak geliştirilmiştir. Mikro ve nano ZrB₂ partikülleri ile takviye edilmiş bakır bazlı kompozitler, mekanik alaşımlama ve sıcak presleme işlemlerinin birleştirilmesiyle toz metalürjisi yöntemiyle üretilmiştir. Alaşımların sertlik ve elektriksel özelliklerine ilişkin elde edilen sonuçlar, ZrB₂ partiküllerinin Cu matrisinde dağılımının varlığının öğütme süresine doğrudan bağlı olduğunu göstermiştir. Ayrıca, öğütme süresinin alaşımların sertlik ve elektriksel özellikleri üzerinde güçlü bir etkisi olduğu gözlemlenmiştir. ZrB₂ partiküllerinin ilavesi bakırın elektriksel iletkenliğini düşürsede, mekanik alaşımlı tozlardan 20 saatten uzun süre öğütülerek üretilen alaşımları yüksek iletkenliğe sahip bir alaşım olarak değerlendirilebilmektedir. Deneysel sonuçlar, YSA ile tahmin edilen sonuçlarla uyumlu bulunmuştur.

Kumar ve ark. (2022) çalışmalarında, ZA/ZrB₂ kompozitlerinin tribolojik davranışını tahmin etmek için bir istatistiksel modelleme geliştirilmiştir. Deneysel parametrelerin optimizasyonu yoluyla malzeme verimliliğinin artırılmasını amaçlayan çalışmada, Response Surface Methodology (RSM) kullanılarak varyans analizi (ANOVA) gerçekleştirilmiş ve ikinci dereceden model önerilerek regresyon denklemi

oluşturulmuştur. Giriş parametreleri olarak yük, kayma mesafesi ve ZrB_2 hacim oranı, çıktı parametreleri olarak ise aşınma ve sürtünme katsayısı değerlendirilmiştir. Sonuçlar, ZrB_2 hacim oranının aşınma üzerinde ana katkı sağlayan parametre olduğunu, sürtünme katsayısı üzerinde ise yükün en önemli faktör olduğunu göstermiştir. Ayrıca, PYTHON kullanılarak geliştirilen Yapay Sinir Ağı (ANN), RSM'nin optimize parametrelerini doğrulamak amacıyla kullanılmıştır. Deneysel sonuçlar ile RSM ve ANN'den elde edilen istatistiksel analiz sonuçlarının birbirine yakın tolerans gösterdiği ve bu bağlamda alaşım ve kompozitlerin özelliklerini öngören anlamlı bir model sunduğu tespit edilmiştir. Oluşturulan regresyon denkleminin, uygulamalara bağlı olarak verilen herhangi bir giriş değişkeni seti için aşınma ve sürtünme katsayısını tahmin etmekte başarılı bir şekilde kullanılabileceği belirtilmiştir.

Vencl ve ark. (2023), çalışmalarında üç farklı ve çok düşük miktarlarda (%0.2, %0.3 ve %0.5 ağırlık oranında) iki farklı boyutta (yaklaşık 25 nm ve 100 nm) alümina, ZA-27 alaşımı bazlı kompozitlerin aşınma özelliklerini iyileştirmek amacıyla kullanılmıştır. Üretim, mekanik alaşımlama ile ön işleme ve döküm süreçleriyle gerçekleştirilmiştir. Aşınma testleri, yağlanmış kayma koşullarında iki farklı kayma hızı (0.25 ve 1 m/s), iki normal yük (40 ve 100 N) ve 1000 m kayma mesafesi altında yapılmıştır. Deneysel sonuçlar, Response Surface Methodology (RSM) uygulanarak analiz edilmiş ve test edilen kompozitlerin aşınma oranı için uygun bir matematiksel model geliştirilmiştir. Uygun aşınma haritaları oluşturulmuş ve aşınma mekanizması tartışılmıştır. Tahmin doğruluğu, yapay sinir ağı (ANN) kullanılarak değerlendirilmiştir. Kullanılan ANN'in mimarisi 4-5-1 olup, elde edilen toplam regresyon katsayısı 0.98729 olarak bulunmuştur. Tahmin yöntemlerinin karşılaştırması, ANN'in aşınmayı tahmin etmede daha verimli olduğunu göstermiştir.

Thankachan ve ark. (2021), çalışmalarında yenilikçi bakır bazlı yüzey kompozitlerinde kuru kayma aşınma oranlarının tahmini ve analizi için makine öğrenimi modelleri ve istatistiksel yöntemlerin uygulanması gösterilmiştir. Bor nitrür (BN) partikülleri, sürtünme karıştırma işlemi (FSP) ile bakır yüzeyine farklı oranlarda yerleştirilmiştir. Deneysel ve istatistiksel analizler, BN partiküllerinin varlığının aşınma oranını önemli ölçüde azaltabileceğini kanıtlamıştır. Aşınmış yüzeyin analizi, düşük yük koşullarında hafif yapışkan aşınma, yüksek yük koşullarında ise aşındırıcı aşınma modunun etkili olduğunu ortaya koymuştur. İleri beslemeli geri yayılım modeli ile bir yapay sinir ağı

(ANN) modeli oluşturulmuş ve tahmin profilleri, deneysel sonuçlarla iyi bir uyum göstermiştir. Bu çalışma, deney tasarımına dayalı denemeleri eğitmek için ANN tabanlı hesaplama modelinin başarılı bir şekilde kullanılabileceğini ve belirli kontrol faktörlerine dayalı olarak kuru kayma aşınma oranını tahmin eden bir model elde edilebileceğini göstermektedir.

Ferati ve Adar (2022), çalışmalarında, cam elyaf ve epoksi reçine takviyeli lamine kompozit malzemelerin yer değiştirme ve Von Misses gerilme değerlerinin tahmini amacıyla makine öğrenimi modelleri kullanılmıştır. Çalışma kapsamında, farklı laminasyon yapıları için malzeme özellikleri değiştirilerek modeller oluşturulmuş ve çekme kuvveti altında toplam yer değiştirme ve Von Misses gerilme değerleri ile veri seti oluşturulmuştur. Lineer regresyon ve Gauss süreç regresyon modelleri kullanılarak bu verilerle toplam yer değiştirme ve Von Misses gerilme tahminleri gerçekleştirilmiştir. Elde edilen sonuçlar doğrultusunda, her iki modelin belirli bir doğruluk oranında tahminler ürettiği görülmüştür. Ancak, Gauss süreç regresyon modeli, lineer regresyon modeline kıyasla daha doğru sonuçlar vermiştir. Regresyon modellerinden elde edilen R^2 değerleri incelendiğinde, Gauss süreç regresyon modelinin 0.86 değeri ile sonlu elemanlar analizine daha yakın sonuçlar sağladığı tespit edilmiştir. Sonuç olarak, çalışma parametreleri açısından Gauss süreç regresyon modeli, cam elyaf ve epoksi reçine takviyeli kompozit malzemelerin yer değiştirme ve gerilme değerlerinin tahmin edilmesinde daha uygun bir model olarak belirlenmiştir.

Saravanan ve Giridharan (2022), çalışmalarında SiC, B₄C ve Mg'nin farklı yüzdeleri ile takviye edilmiş sürtünme karıştırma kaynaklı Al metal matris kompozitlerin davranışını incelenmiştir. Deneyler kapsamında, Al metal matris kompozitlerin üretimi, sürtünme karıştırma kaynağı uygulanması ve ardından mekanik dayanım, mikro yapı bütünlüğü ve kalite açısından ek yerinin özelliklerinin değerlendirilmesi gerçekleştirilmiştir. Yüksek SiC oranı, daha yüksek dayanım, daha iyi aşınma özellikleri ve sertlik sağlarken, B₄C oranı sertlikle ilişkilendirilmiştir. SiC oranı azaldıkça ve B₄C oranı arttıkça uzama yüzdesinin düştüğü gözlemlenmiştir. Daha düşük yük değerleri ve daha yüksek B₄C oranı durumunda aşınma oranının genellikle azaldığı tespit edilmiştir. Makine öğrenimi analizi kullanılarak alet hızı, alet doğrusal hızı ve enine hız gibi parametreler için optimal aralıklar belirlenmiştir. Çalışmada Lineer Regresyon, Random Forest ve Lasso Regresyon algoritmaları kullanılmış ve sonuçlar karşılaştırılmıştır.

Algur ve ark. (2022), çalışmalarında modifiye edilmiş ZA-27 alaşımının kayma koşulları altındaki aşınma performansını tahmin etmek amaçlanmıştır. Deneyler, farklı yükler, kayma hızları ve kayma mesafeleri gibi aşınma parametreleri kullanılarak gerçekleştirilmiş ve toplamda 75 deney yapılmıştır. Bu deneylerden elde edilen aşınma kaybı verileri, aşınma kaybını tahmin etmek için gözetimli makine öğrenimi algoritmaları olan Random Forest (RF), Gauss işlemci regresyonu, k-en yakın komşu (k-NN), destek vektör makineleri (SVM) ve lineer regresyon modellerine giriş verisi olarak kullanılmıştır. Sonuçlar, oluşturulan tüm modellerde eğitim ve test için elde edilen R^2 değerlerinin birbirine oldukça yakın olduğunu ortaya koymuştur. RF modeli, R^2 , Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hata (RMSE) açısından en iyi sonuçları vermiştir.

Sheikh ve Khan (2024), çalışmalarında yüksek aşınma koşulları altında TiC ile güçlendirilmiş ZA-27 alaşımının performansını incelenmiştir. Test edilen tüm malzemeler arasında ZA-27 + %10 TiC kompoziti üstün aşınma direnci göstermiştir. Response Surface Analizi (RSM), uygulanan yük arttıkça numunelerin aşınma direncinin azaldığını ortaya koymuştur. Aşınmış yüzeylerin analizi, düşük yüklerde hafif oluklar ve yüksek yüklerde daha derin olukların oluştuğunu göstermiştir. Malzeme kaybının ağırlıklı olarak aşındırıcı yüzeylerin kesme etkileriyle meydana geldiği belirlenmiştir. Aşınma oranı, sürtünme katsayısı ve sıcaklık tahminleri için K-en yakın komşu (KNN), Rasgele Orman (RF), Destek Vektör Regresyonu (SVR) ve Çok katmanlı ağırlılayıcı (MLP) makine öğrenimi modelleri kullanılmıştır. Bu modeller arasında MLP modeli, test verisinde R^2 değeri 0.88 ile üstün bir performans göstermiştir. Aşınma oranını tahmin etmede en etkili faktörün takviye ağırlık yüzdesi olduğunu ortaya koymuştur. MLP modelinin test veri setindeki performans metrikleri sırasıyla R^2 0.88, MAE 0.0281, MSE 0.1295 ve RMSE 0.0359 olarak elde edilmiştir. Ayrıca, modelin aşınma oranını tahmin etmede istatistiksel olarak anlamlı düşük hatalara sahip olduğu belirlenmiştir. Bu sonuçlar, TiC ile güçlendirilmiş ZA-27 alaşımının yüksek aşınma koşulları altındaki davranışını anlamada önemli bir katkı sağlamıştır.

Hulipalled ve ark. (2024), çalışmalarında ZA-27 alaşımının tribolojik davranışı hem istatistiksel hem de sinir ağı yöntemleri kullanılarak karşılaştırmalı olarak analiz edilmiştir. Çalışmanın amacı, aşınma oranı ve sürtünme katsayısı (COF) üzerine odaklanarak ZA-27 alaşımının tribolojik davranışını tahmin eden modeller

geliştirmektir. Aşımın özelliklerini analiz etmek ve tahmin etmek için Response Surface Methodology (RSM) ve Yapay Sinir Ağları (ANN) yaklaşımları kullanılmıştır. Aşınma çalışmaları için RSM'nin Merkezi Kompozit Tasarım (CCD) yöntemi uygulanmış ve manganez içeriği, normal yük, kayma hızı ve kayma mesafesi gibi temel parametrelerin etkisi değerlendirilmiştir. Optimize edilmiş parametreler ANN modeli ile doğrulanmıştır. Her iki yöntemden elde edilen sonuçlar, gözlemlenen ve tahmin edilen aşınma oranı ve COF değerleri arasındaki uyum gösterilmiştir. Bu durum, ZA-27 alaşımının tribolojik davranışını modellemede hem istatistiksel hem de sinir ağı yaklaşımlarının etkinliğini ortaya koymuştur. ANN tahmin modeli, aşınma oranı için %99.76 ve COF için %99.37'lik bir korelasyon katsayısı (R^2) ile RSM modelinden daha iyi performans göstermiştir. RSM modelinin performansı ise sırasıyla %92.06 ve %92.02 olarak elde edilmiştir.

Literatürde malzeme bilimi ve malzeme özelliklerin tahmininde istatistiksel yöntemler ile yapay zeka yöntemlerinin yaygın olarak kullanıldığı görülmektedir. Özellikle Yapay sinir ağları (ANN), Random forest (RF), Gauss süreç regresyonu (GPR) ve Destek vektör regresyonu (SVR) gibi yöntemlerin malzeme davranışlarına ve mekanik özelliklerin modellenmesinde başarılı sonuçlar verdiği, son yıllarda ise yapay zeka tabanlı yöntemlerin giderek daha fazla tercih edildiği dikkat çekmektedir. Bunun yanında, farklı yöntemlerin bir arada değerlendirildiği kapsamlı çalışmaların ise sınırlı olduğu görülmektedir. Bu çalışmada ise, farklı makine öğrenimi yöntemleri karşılaştırılarak aşınma özelliklerinin tahmini için daha kapsamlı bir yaklaşım sunulmuştur.

Tablo 1.1. Literatür taraması özet tablosu.

Eser Bilgisi	Çalışma Konusu	Yöntem	Bulgular
Reena Roy ve ark. (2023)	AA6063 matrisine farklı oranlarda ZrO ₂ eklenerek aşınma performansının incelenmesi ve tahmini.	Destek Vektör Regresyonu (SVR), Rastgele Orman Regresyonu (RFR), Karar Ağaçları (DT), RMSE, MSE, MAE istatistikleri.	MAE değerleri SVR için 0.30, RFR için 0.28 ve DT için 0.27 bulunmuş; RFR ve DT yöntemlerinin SVR'ye göre daha başarılı olduğu gözlemlenmiştir.
Mishra ve Jatti (2023)	Al/SiC metal matris kompozitlerinde aşınma oranlarının tahmini.	Nöro-sembolik algoritma, Yapay Sinir Ağları (ANN), MSE.	ANN için %86 R ² ve 0.99 MSE; Nöro-sembolik algoritma için %93 R ² ve 0.46 MSE değerleri elde edilmiştir. Nöro-sembolik algoritmanın daha başarılı olduğu bulunmuştur.
Gangwar ve Pathak (2020)	ZA-27 alaşımlı kompozitlerin aşınma performansına mermer tozu takviyesinin etkisinin belirlenmesi.	Taguchi L25 ortogonal dizi, IBA optimizasyon algoritması, Yapay Sinir Ağları (ANN), MSE.	%96 başarı oranı elde edilmiştir. MSE değeri 0.26 olarak bulunmuştur.
Babalola ve ark. (2017)	Alüminyum alaşımlarında mekanik ve elektriksel özelliklerin tahmini.	Yapay Sinir Ağları (ANN).	Yaklaşık %94 test başarısı elde edilmiştir.

Tablo 1.1. (Devamı) Literatür taraması özet tablosu.

Eser Bilgisi	Çalışma Konusu	Yöntem	Bulgular
Sosimi ve ark. (2020)	Kalsiyum Karbonat takviyeli alüminyum kompozitin aşınma direncinin analizi.	Yapay Sinir Ağları (ANN), ANFIS.	ANFIS modeli R^2 değerleri %97.74 - %95.01 aralığında bulunmuşken ANN için %36.84 olarak bulunmuştur. ANFIS modeli kompozit malzemelerin aşınma direnci tahmininde daha uygundur.
Min ve ark. (2023)	Katmanlı üretim (AM) işlem parametrelerinin malzeme yorgunluk özelliklerine etkisinin tahmini.	FNN, ANFIS, CNN, SVM, PINN, RF, lazer gücü, tarama hızı, maksimum gerilim gibi değişkenler.	R^2 başarı oranları: FNN için 0.65, CNN için %97, ANFIS için %79, SVR için %82, RF için %78 olarak bulunmuştur.
Radhakrishnan ve ark. (2016)	Al 2219-SiC kompozit malzemenin aşınma direncinin tahmini.	İleri beslemeli Yapay Sinir Ağları (ANN).	81 veri seti ile çalışılmış, %85 başarı oranı elde edilmiştir
Kumar ve ark. (2017)	Al6061 alaşımının aşınma direncinin artırılması ve tahmini.	ANN, Taguchi .	ANN modeli %99.94 R^2 değeri ile yüksek uyum sağlamış; aşınma performansının başarılı bir şekilde tahmin edildiği gözlemlenmiştir.
Dorbane ve ark. (2022)	Al6061-T6 alüminyum alaşımının farklı sıcaklık seviyelerinde gerilme davranışlarının tahmini.	Gauss Süreç Regresyonu (GPR), Yapay Sinir Ağı (ANN), Güçlendirilmiş Ağaçlar (BST), RMSE, MAE, MAPE.	ANN modeli RMSE 0.720, MAE 0.340, R^2 0.998 ile en iyi sonuçları vermiştir.

Tablo 1.1. (Devamı) Literatür taraması özet tablosu.

Eser Bilgisi	Çalışma Konusu	Yöntem	Bulgular
Devi ve ark. (2020)	Alüminyum alaşımlarında mekanik özelliklerin tahmini.	LR, KNN, ANN, RMSE.	Gerilme direnci ve sertlik tahmininde KNN; verimlilik tahmininde ANN daha iyi performans göstermiştir.
Mathan Kumar ve ark. (2021)	Alüminyum alaşımının termomekanik aşınma özelliklerinin tahmini.	ANN, SVM, LR, RMSE, MAE, regresyon modeli.	ANN en düşük MAE (0.10) ve en yüksek R ² (0.87) değeriyle diğer yöntemlere kıyasla daha iyi performans göstermiştir.
Ružić ve ark. (2014)	Bakır bazlı kompozitlerin sertlik ve elektriksel özelliklerinin tahmini.	Yapay Sinir Ağları (YSA), GRNN.	Öğütme süresinin kompozit özellikleri üzerinde güçlü etkisi olduğu bulunmuş; YSA tahmin sonuçları deneysel verilerle uyumlu bulunmuştur.
Kumar ve ark. (2022)	ZA/ZrB ₂ kompozitlerinin tribolojik davranışını tahmin etmek.	Response Surface Methodology (RSM), ANOVA, Yapay Sinir Ağı (ANN).	ZrB ₂ hacim oranı aşınmada ana katkı sağlayan, yük ise sürtünme katsayısında en etkili parametre. RSM ve ANN sonuçları birbiriyle uyumlu bulunmuştur.

Tablo 1.1. (Devamı) Literatür taraması özet tablosu.

Eser Bilgisi	Çalışma Konusu	Yöntem	Bulgular
Vencl ve ark. (2023)	ZA-27 alaşımı bazlı kompozitlerin aşınma özelliklerini iyileştirmek.	RSM	ANN tahmin yöntemi aşınmayı modellemede daha verimli bulunmuş, toplam regresyon katsayısı 0.98729 olarak elde edilmiştir.
Thankachan ve ark. (2021)	Bakır bazlı yüzey kompozitlerde kuru kayma aşınma oranlarının tahmini.	Yapay Sinir Ağı (ANN).	ANN modeli deneysel sonuçlarla uyum göstermiş ve BN partiküllerinin aşınma oranını önemli ölçüde azalttığı belirlenmiştir.
Ferati ve Adar (2022)	Cam elyaf ve epoksi reçine takviyeli kompozitlerin yer değiştirme ve gerilme değerlerinin tahmini.	Lineer Regresyon, Gauss Süreç Regresyonu (GPR).	GPR modeli R^2 değeri 0.86 ile daha doğru sonuçlar vermiş ve lineer regresyona kıyasla sonlu elemanlar analizine daha yakın tahminler sağlamıştır.
Saravanan ve Giridharan (2022)	Sürtünme karıştırma kaynaklı Al metal matris kompozitlerin mekanik dayanımı ve aşınma özelliklerini incelemek.	Lineer Regresyon, Random Forest, Lasso Regresyon.	SiC oranı aşınma özelliklerini artırmış, B ₄ C oranı arttıkça uzama yüzdesi azalmıştır. Random Forest modeli daha doğru tahminler sağlamıştır.

Tablo 1.1. (Devamı) Literatür taraması özet tablosu.

Eser Bilgisi	Çalışma Konusu	Yöntem	Bulgular
Algur ve ark. (2022)	Modifiye edilmiş ZA-27 alaşımının aşınma performansını tahmin etmek.	Random Forest (RF), GPR, k-NN, SVM, Lineer Regresyon.	RF modeli, diğer modellerle kıyaslandığında R^2 , MAE ve RMSE açısından en iyi performansı göstermiştir.
Sheikh ve Khan (2024)	TiC ile güçlendirilmiş ZA-27 alaşımının yüksek aşınma koşullarındaki performansını incelemek.	KNN, RF, SVR, Çok Katmanlı Algılayıcı (MLP).	MLP modeli test verisinde $R^2=0.88$ ile üstün performans göstermiştir. Aşınmada en etkili faktör takviye ağırlık yüzdesi olarak bulunmuştur.
Hulipalled ve ark. (2024)	ZA-27 alaşımının tribolojik davranışını modellemek.	RSM (Merkezi Kompozit Tasarım), ANN.	ANN modeli R^2 değerleriyle (%99.76 ve %99.37) RSM modelinden (%92.06 ve %92.02) daha başarılı bulunmuştur.




2. MATERYAL VE YÖNTEM

Bu bölümde, çalışmada kullanılan veri seti detaylı şekilde tanıtılmış ve bu veri setinin bağımlı ve bağımsız değişkenleri açıklanmıştır. Ayrıca veri seti üzerinde gerçekleştirilecek analiz ve modelleme yöntemlerine uygun hale gelmesi amacıyla veri ön işleme çalışmaları yapılmıştır. Sonrasında veri setindeki değişkenlerin ölçeklenebilirliğini sağlamak ve farklı modelleme yöntemlerine uygun hale getirmek amacıyla normalizasyon işlemi uygulanmıştır. Normalizasyon sürecinde, değişkenlerin belirli bir ölçek aralığına getirilmesi sağlanmış ve böylece yöntemlerin performansını olumsuz etkileyebilecek ölçek farklılıkları giderilmiştir. Bu işlemler, çalışmanın doğruluğu ve tutarlılığını artırmayı hedeflemiştir.

2.1. Veri Seti


Yatak malzemesi olarak kullanılan ve yüksek mukavemet özelliği nedeniyle yaygın olarak kullanıldığı bilinen ZA-27 alaşımı için 2005 yılında Aslan (2004) tarafından yapılan çalışmada SiC ve Grafit partikülleri eklenerek sıkıştırma döküm yöntemiyle kompozit ve hibrit kompozit malzemeler elde edilmiştir. ZA-27 alaşımının mikroskopik yapısı Şekil 2.1’de görülmektedir.



Şekil 2.1. ZA-27 alaşımının mikroskopik yapısı (ASM International 2004).

ZA-27 alaşıma %5-10-15 SiC partikülü eklenerek STK kompozit, %2.5-5-7.5-10 grafit partikülleri eklenerek GTK kompozit ve %5-10-15 SiC ile %2.5-5-7.5-10 grafit partikülün çeşitli oranlarda birlikte eklenmesi ile HTK kompozit malzemeler geliştirilmiştir. Üretimde ilk olarak SiC ve Grafit partikülleri ZA-27 alaşımına vorteks

yöntemiyle karıştırılmış, sonrasında sıvı kompozit karışımı tekrar eritilerek 50 MPa basınç altında sıkıştırılarak katılaştırılmıştır. Grafit ve ZA-27 alaşımı arasındaki yüksel yüzey geriliminden dolayı partikülün matrikse ilave edilmesi neredeyse imkânsız olduğundan grafit partikülleri bakır metali ile kaplanmıştır. Şekil 2.2'de, grafit partiküllerinin bakır metal ile kaplanmış kesit görüntüleri verilmiştir. Elde edilen malzemelerin incelenmesi sonucunda, hibrit kompozit malzemelerin yüksek aşınma direnci sergilediği gözlemlenmiştir.



Şekil 2.2. Bakır metali ile kaplanan grafit yüzeyi (Aslan, 2004).

ZA-27 alaşımı için STK, GTK ve HKM malzemelerinin aşınma deneylerini gerçekleştirmek için, Şekil 2.3'te verilen ASTM G 99- 05 standartlarına uygun olarak tasarlanmış ve pin-on-disk prensibiyle çalışan “CSM Instruments Tribometer” markalı aşınma cihazı kullanılmıştır (Kumar, 2006). Her bir numune için döküm hali sonrasında, 10,20 ve 30 N yük altında ve 0.5, 1, 1.5 ve 2 m/s kayma hızlarında, 500 m sabit deney mesafesinde ayrı ayrı aşınma testleri yapılmıştır (Aslan, 2004).




Şekil 2.3. CSM Instruments Tribometer aşınma cihazı (Suzin, 2011).

Bu tez çalışmasında, Aslan (2004) tarafından oluşturulan ve deney aşaması yukarıda bahsedilen 240 deney veri seti kullanılacaktır. ZA-27 alaşımına SiC ve Grafit partikülleri eklenerek kompozit ve hibrit kompozit malzemenin hacimsel aşınma hızına etkisini tahmin etmek için farklı Yapay Zekâ yöntemleri kıyaslanacaktır. Çalışmada ZA-27 alaşımına katılan SiC oranı, Grafit oranı, Yük ve Kayma hızı bağımsız değişken olarak kullanılırken, bağımlı değişken olarak Hacimsel Aşınma hızı kullanılmıştır. Çalışmada kullanılan bağımsız değişken özet tablosu Tablo 2.1’de verilmiştir.

Tablo 2.1. Bağımsız değişkenler özet tablosu.

Bağımsız Değişkenler	Birimi
SiC Oranı	Yüzde (%)
Grafit Oranı	Yüzde (%)
Yük	Newton(N)
Kayma Hızı	m/s

Toplam 240 deney verisi %80 eğitim ve %20 test olarak iki gruba ayrılmıştır. Böylece, 192 eğitim veri seti ve 48 test veri seti elde edilmiştir. Tahmini yapılmak istenen çıktı değişkeni hacimsel aşınma hızı verilerinin histogram grafiği Şekil 2.4’te verilmektedir. Belirtilen yöntemlerle yapılan analizde en az tahmin hatası veren model belirlenecektir.



Şekil 2.4. Hacimsel aşınma hızı verileri.

2.2. Veri Ön İşleme

Veri ön işleme, oluşturulan veri setinin analiz edilmesine yönelik gerçekleştirilen önemli bir adım olup, özellikle makine öğrenmesi algoritmaları ve yapay sinir ağları yöntemlerinin daha yüksek bir performans göstermesi için veri setinin uygun hale getirilmesini amaçlayan kapsamlı bir süreçtir.

Bu süreç veri setindeki hatalı, eksik, ayrıklı değerlerin tespit edilmesi ve bu değerlerin düzeltilmesi ya da çıkarılması gibi işlemleri içermektedir. Ayrıca veri setindeki değişkenlerin ölçeklenmesi, dönüştürülmesi ve yöntemlere uygun şekilde yeniden yapılandırılması da veri ön işlemenin temel unsurlarındandır. Bu adımlar model performansını artırmak ve analizlerin güvenilirliğini sağlamak için kritik bir yol oynamaktadır. Bu sebeple tahminden önce yapılan veri ön işleme sürecinin temel amacı, kullanılan yöntemlerin verilerle uyumlu çalışmasını sağlamak, model doğruluğunu artırmak ve sonuçların genelleştirilebilirliğini güçlendirmektir. Böylelikle yapılan analizlerin tutarlılığı ve güvenilirliği önemli ölçüde artırılmış olur.

Destek Vektör Regresyonu (SVR), Rasgele Orman Regresyonu (RFR), Karar Ağaçları Regresyonu (DTR) ve Doğrusal Regresyon (LR) modelleri, Google Colab platformu kullanılarak uygulanacaktır. İlk adım olarak, veri setinin yer aldığı Excel dosyası okunacak ve bu veriler, veri analizi ve işleme için yaygın olarak kullanılan Pandas kütüphanesi ile bir DataFrame'e (DF) yüklenecektir. Daha sonra, DF üzerinden sayısal işlemlerin gerçekleştirilmesi için Numpy kütüphanesinden yararlanılacaktır. Veri seti

analizi ve düzeltmeleri için Numpy kütüphanesi kullanılarak veri setinin yapısal özellikleri incelenmiş ve eksik veri olmadığı tespit edilmiştir. Ardından, MATLAB üzerinden sistematik örneklem yöntemi kullanılarak verilerin %20'si test, geri kalan %80'i ise eğitim verisi olarak ayrılmıştır. Bu işlem Python programında model_selection kütüphanesinin bir modülü olan train_test_split () fonksiyonu ile de gerçekleştirilebilirdi, ancak çalışmada MATLAB'de ayrılan eğitim ve test veri setlerinin kullanılması tercih edilmiştir. Bunun sebebi, ANFIS ve ANN modellerinde kullanılan test ve eğitim veri setleri ile aynı veri setlerinin kullanılmasının amaçlanmasıdır. Çalışmada hacimsel aşınma hızı bağımlı değişken olarak tanımlanırken, SiC oranı, grafit oranı, yük ve kayma hızı bağımsız değişkenler olarak belirlenmiştir. Eğitim veri seti olarak ayrılan örneklem, öncelikle belirlenen modellerde eğitilecek, ardından modellerin performansları, daha önce hiç görmedikleri test veri seti ile kıyaslanacaktır. Bağımsız değişken olan girdi değişkenleri X, bağımlı değişken olan çıktı değişkenleri ise Y ile gösterilmiştir. Veri setine ait tanımlayıcı istatistikler Tablo 2.2'de verilmektedir. Tabloda sırasıyla ortalama (X_{ort}), medyan (X_{med}), minimum (X_{min}), maksimum (X_{maks}), standart sapma (S_x) değerleri verilmektedir.

Tablo 2.2. Veri setine ait tanımlayıcı istatistikler.

Parametre	X_{ort}	X_{med}	X_{min}	X_{max}	S_x
SiC Oranı	7.5	7.5	0	15	5.6018
Grafit Oranı	5	5	0	10	3.5429
Yük	20	20	10	30	8.1820
Kayma Hızı	1.25	1.25	0.5	2	0.5601
Hacimsel Aşınma Hızı	0.8842	0.635	0.03	3.98	0.7870

Tablo 2.2 incelendiğinde, veri setinin farklı ölçeklerdeki sayısal değerlerden oluştuğu anlaşılmaktadır. Bu çeşitlilik, modelleme sürecinde hatalara neden olabilir veya makine öğrenmesi algoritmalarının doğruluğunu olumsuz etkileyebilir. Bu nedenle, girdi değişkenlerinin değerlerini ortak bir aralıkta formüle etmek amacıyla ilerleyen kısımlarda uygulanan normalizasyon yöntemi anlatılacaktır.

2.2.1. Aykırı değer analizi

Bu çalışmada kullanılan veri seti, laboratuvar ortamında gerçekleştirilen deneysel sonuçlardan oluşmaktadır ve toplamda 240 veri içermektedir. Ancak, veri setinin oluşturulması sürecinde her bir deneyin gerçekleştirilmesi hem yüksek maliyetli hem de oldukça zaman alıcıdır. Bu durum, veri setinin büyüklüğünü artırmayı veya mevcut veri setinden belirli verilerin çıkarılmasını sınırlayıcı bir etken haline getirmektedir.

Makine öğrenmesi ve yapay zeka yöntemlerinde sıklıkla kullanılan aykırı veri analizi, genellikle veri setindeki uç veya alışılmadık gözlemleri tespit etmek ve bu gözlemlerin veri setinden çıkarılmasıyla model performansını artırmayı hedefler. Ancak bu çalışmada, veri setinin kısıtlı büyüklüğü ve her bir veri noktasının yüksek üretim maliyeti, aykırı veri analizinin uygulanmasını sınırlayıcı bir faktör olarak karşımıza çıkmaktadır. Daha da önemlisi, çalışmanın temel amacına uygun olarak, deneysel veri setinde yer alan tüm gözlemler, deney sürecinde özenle elde edilmiş ve her bir gözlem, sistemin gerçek davranışını yansıtan önemli bilgiler içermektedir. Bu nedenle, herhangi bir gözlemin "aykırı" olarak değerlendirilip veri setinden çıkarılması, modelleme sürecinde bilgi kaybına neden olabilir ve sonuçların genelleştirilebilirliğini olumsuz etkileyebilir.

Veri setinin boyutunun küçültülmesi durumunda, makine öğrenmesi algoritmalarının eğitim performansı düşebilir ve bu da model sonuçlarının istatistiksel anlamlılığını azaltabilir. Bunun yanı sıra, aykırı veri olarak değerlendirilebilecek gözlemler, deneysel değişkenlerin nadir fakat anlamlı etkilerini temsil ediyor olabilir. Bu tür gözlemlerin çıkarılması, modelin sistemin gerçek davranışlarını yeterince temsil edememesine yol açabilir.

Sonuç olarak, veri setinin sınırlı boyutu, her bir veri noktasının yüksek üretim maliyeti ve gözlemlerin bilgi değeri göz önünde bulundurularak, bu çalışmada aykırı veri analizi uygulanmamış ve veri setindeki tüm gözlemler analiz sürecine dahil edilmiştir. Bu tercih, çalışmanın doğruluğunu, bütünlüğünü ve sonuçlarının genelleştirilebilirliğini sağlama amacıyla alınmıştır.

2.2.2. Normalizasyon

Uygulanacak olan farklı modellerde veri setindeki parametrelerin aldığı değerlerin aynı ölçekte olması modelin öğrenme sürecini hızlandırıp, başarısını arttırmaktadır. Böylelikle tüm veriler belli bir standart haline getirilmiş olur. Bu da doğru bir analiz

için önemli bir rol oynamaktadır. Min-Max, Medyan, Sigmoid ve Z-Score gibi birçok normalizasyon yöntemi bulunmaktadır. Bu çalışmada literatürde sıklıkla kullanılan min-max normalizasyon yöntemi kullanılacaktır.

Min-max normalizasyon yönteminde, tüm veri seti 0-1 aralığında dağıtılarak, her bir değişken için aldığı en küçük değeri 0 ve en büyük değeri 1 olacak şekilde formüle edilmektedir. Denklem 2.1'te normalizasyon denklemi verilmiştir.

$$X' = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (2.1)$$

X' : Normalize edilmiş değer

X_i : Girdi değeri

X_{min} : Parametrede yer alan veriler içindeki en küçüğü

X_{max} : Parametrede yer alan veriler içindeki en büyüğü

Tablo 2.3'de veriler için her bir değişkenin minimum ve maximum değeri gösterilmiştir.

Tablo 2.3. Değişkenlerin ortalama ve standart sapma değerleri.

	SiC Oranı	Grafit Oranı	Yük	Kayma Hızı	Hacimsel Aşınma Hızı
X_{min}	0	0	10	0.5	0.03
X_{max}	15	10	30	2	3.98

Standardizasyon işlemi verilerin karşılaştırılabilir hale getirilmesini amaçlamaktadır. Değişkenlerin farklı yapısal özelliklere ve ölçeklere sahip olması nedeniyle, bu değişkenlerin ölçeklendirilmesi ve kıyaslanabilir bir duruma getirilmesi gereklidir. Standardizasyon süreci, değişkenlerin ortalama değerinin 0, standart sapmasının ise 1 olacak şekilde dönüştürülmesini sağlar.

2.3. Korelasyon Analizi

Bu çalışmada, bağımlı ve bağımsız değişkenler arasındaki ilişkilerin daha iyi anlaşılabilmesi ve değişkenler arasındaki etkileşimlerin yönü ile gücünün tespit edilebilmesi amacıyla korelasyon analizi gerçekleştirilmiştir. Korelasyon analizi, iki


değişken arasındaki doğrusal ilişkinin derecesini ve yönünü belirlemeye yarayan temel bir istatistiksel yöntemdir. Korelasyon katsayısı, -1 ile +1 arasında bir değer alır ve pozitif veya negatif bir ilişkiyi ifade ederken, katsayının büyüklüğü ilişkinin kuvvetini gösterir (Gür ve Eşidir, 2024).

Bu analiz sonucunda, Şekil 2.5'e bakıldığında yük değişkeni ile bağımlı değişken olan hacimsel aşınma hızı arasında 0.63'lük bir korelasyon bulunmuştur. Bu değer, değişkenler arasında orta kuvvetli ve pozitif yönlü bir ilişki olduğunu göstermektedir. Bu, yük miktarındaki artışın aşınma hızını artırma eğiliminde olduğunu ortaya koymaktadır.

Bunun yanı sıra, grafit oranı ile hacimsel aşınma hızı arasında -0.35 düzeyinde bir korelasyon olduğu tespit edilmiştir. Bu durum, iki değişken arasında negatif yönlü ve zayıf bir ilişki olduğunu ifade etmektedir. Bu bulgu, grafit oranının artışının hacimsel aşınma hızında azalmaya neden olabileceğini göstermektedir.

Korelasyon analizi, modelleme aşamasında değişkenlerin birbiriyle ilişkilerini anlamak ve hangi değişkenlerin bağımlı değişken üzerinde daha etkili olabileceğini değerlendirmek açısından kritik bir öneme sahiptir. Ayrıca, yüksek korelasyon değerlerine sahip değişkenler arasında çoklu korelasyon riski olup olmadığını belirlemek için de bir ön adım olarak kullanılmaktadır. Bu tür bir riskin varlığı, model performansını olumsuz etkileyebilir ve bu nedenle dikkatle incelenmelidir (Kardeş ve Bilir, 2024).

Sonuç olarak, korelasyon analizi, çalışmada kullanılan bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerini anlamak için önemli bir yöntem olarak kullanılmış ve elde edilen sonuçlar, değişkenler arasındaki ilişkilerin belirlenmesinde yol gösterici olmuştur.



Şekil 2.5. Korelasyon Analizi.

2.4. Geliştirme Ortamı

2.4.1. Matlab

MathWorks firması tarafından geliştirilen MATLAB, mühendislik ve bilimsel alanlarda oldukça sık tercih edilen yazılım ve programlama dilidir. İçerisinde bulunan birçok yardımcı araç sayesinde veri analizi, modelleme, simülasyon gibi çeşitli alanlarda hizmet sunmaktadır. Geniş bir matematiksel fonksiyon ve araç takımı sunarak özellikle matris işlemleri üzerine odaklanır. Sahip olduğu kullanıcı ara yüzü ve komut satırlarıyla kullanıcıların kendi işlevlerini ve uygulamalarını yazmalarına olanak tanımaktadır. Bu özellikleri sayesinde akademik ve endüstriyel alanlarda yaygın bir şekilde tercih edilmektedir.


2.4.2. Google Colaboratory

Google Colaboratory, özellikle veri bilimi, modelleme ve istatistiksel algoritma geliştiren makine öğrenmesi gibi uygulamalar için sürekli ve ücretsiz GPU erişimi sunmaktadır. Bulut tabanlı platform olan Google Colaboratory, yoğun hesaplama gerektiren işlemleri daha hızlı ve etkili bir şekilde gerçekleştirme olanağı tanımaktadır. En büyük avantajı Python yazılımı ile bir internet tarayıcısı üzerinden çalışabilmesidir. Bu sayede kullanıcılar herhangi bir kurulum ya da güncelleştirme yapmadan internet

bağlantısı olan her yerden erişim sağlayabilir, çalışmalarını hızlı bir şekilde test etme ve uygulamaya koyma imkanına sahip olabilmektedirler.

2.4.3. Kullanılan kütüphaneler ve tahmin metodu

Bu tez çalışmasında, ZA-27 alaşımından üretilen SiC takviyeli kompozit (STK), Grafit takviyeli kompozit (GTK) ve Hibrit kompozit malzeme (HKM) kullanılarak hacimsel aşınma hızını tahmin etmek için makine öğrenmesi modelleri, Python programlama diliyle Colaboratory platformunda geliştirilmiştir. Verilerin Aktarılması, algoritmaların tasarlanıp uygulanması, model performansının analiz edilmesi ve sonuçların görselleştirilmesi gibi işlemleri kolaylaştırmak için çeşitli kütüphaneler tercih edilmiştir. Uygulama esnasında verilerin işlenmesi, analizi, düzenlenmesi, dosya okuma, matematiksel işlemler için imkân sağlayan Pandas ve NumPy, tasarım ve veri eğitimi için TensorFlow, model performans değerlendirmesi için Sklearn, görselleştirme ve grafik oluşturmak için Matplotlib gibi çeşitli kütüphanelerden yararlanılmıştır. Modellerin eğitimi için ilk olarak veri setinin bulunduğu dosya Google Drive ile Colaboratory'e aktarılmıştır. MATLAB yazılımı aracılığıyla 192 eğitim seti ve 48 test seti elde edilmiştir. Analiz edilen tahmin modelleri bu yüzde baz alınarak incelenmiştir. Veri setindeki bu bölünmenin nedeni diğer Yapay zekâ teknikleriyle kıyaslanacak olmasıdır. Hazırlanan veriler ile model eğitilmiş ve parametreleri optimize edilmiştir. Yöntemlerin karşılaştırılması için Eğitim veri setiyle oluşturulan ağlar tarafından hem eğitim hem de test veri seti için olası tahminler oluşturulmuştur. Çalışmada kullanılan tüm Yapay zekâ yöntemleri için ağ eğitimi ve tahmin işlemi bu şekilde gerçekleştirilmiş olup, sonrasında elde edilen test verisi tahminleriyle beraber hata ölçümleri yapılarak performans değerlendirme yapılmıştır. Modellerin ağ eğitim süreci akış şeması Şekil 2.6'da gösterilmiştir.



Şekil 2.6. Ağ eğitimi için akış şeması.

2.5. Performans Ölçümleri ve Hata Analizleri

Tahmin, geçmişte bilinen parametreler aracılığıyla bilinmeyen parametrelerin akla, sezgiye ve veriye dayanarak öngörülmesidir. Eldeki veri seti üzerinde farklı matematiksel hesaplamalar yaparak tahmin modelleri oluşturulmaktadır. Mevcut verinin en ufak bir dış etkenden etkilenebileceği varsayımını hesaba katarsak tahminde bulunmak öngörmeye bizlere mükemmel bir sonuç vermez. Fakat fikir sahibi olmamıza ve bizim için en doğru olan yolu seçmemize yardımcı olur. Bu sebeple tahmin modelleri yalnızca muhtemel sonuçları tahmin eder ve modellerin doğruluğu belirli bir güven aralığında gösterilebilir. Bu kapsamda elde edilen tahminlerin güvenilirliğini artırmak için, uygun verilerin seçilmesi, uygun metotların kullanılması

ve oluşturulan tahmin modelinin düzenli olarak performansının değerlendirilip güncellenmesine ihtiyaç duyulmaktadır.

2.5.1. Mutlak değişim yüzdesi (R^2)

0-1 arasında değişim gösteren bu değer bağımsız değişken olan girdilerin, bağımlı değişken olan çıktı üzerindeki etkisiyle birlikte verilerin uygun regresyon eğrisine yakınlığını gösteren istatistiksel bir ölçüdür. Yüksek performans gösteren bir model için değer 1'e yaklaşması beklenmektedir. Denklem 2.2'de mutlak değişim yüzdesi formülü verilmektedir.

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (Y_i - Y_i^*)^2}{\sum_{i=1}^n (Y_i - Y_{ave})^2} \right) \quad (2.2)$$

2.5.2. Ortalama karesel hata (MSE)

Ölçülen modelin gerçek verilerle ne derece iyi eşleştiğini ölçen bir istatistiksel ölçüdür. Üstün performans gösteren bir model için MSE değerinin düşük olması beklenmektedir. Denklem 2.3'de MSE formülü verilmektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i^*)^2 \quad (2.3)$$

2.5.3. Hata kareler ortalamasının karekökü (RMSE)

Model tahmini ile gerçek değerler arasındaki mesafe olarak tanımlanan hata değerini ölçmek için kullanılan bir yöntemdir. Yüksek performans gösteren bir model için RMSE değerinin düşük olması beklenmektedir. Denklem 2.4'de RMSE formülü verilmektedir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - Y_i^*)^2} \quad (2.4)$$

2.5.4. Ortalama mutlak hata (MAE)

Tahmin edilen değer ile gerçek değer arasındaki farkın mutlak değerinin ortalamasını ifade eden MAE, tahmin modelinin performansını ölçmek için kullanılır. Üstün performans gösteren bir model için MAE değerinin düşük olması beklenmektedir. Denklem 2.5'te MAE formülü verilmektedir.

$$MAE = \frac{\sum_{i=1}^n |Y_i - Y_i^*|}{n} \quad (2.5)$$

Denklem 2.2, 2.3, 2.4 ve 2.5'teki istatistiksel ölçümlerde n gözlem sayısını, Y_i gerçek değerleri, Y_i^* tahmin değerlerini ve Y_{ave} ise ortalama değeri temsil etmektedir.





3. YAPAY ZEKA

“Makineler düşünebilir mi?” sorusuyla ortaya çıkan yapay zekâ kavramı; insan beyninin gerçekleştirdiği görev ve işlevleri makineler ile taklit etmeye çalışan ve elde ettiği bilgilerle kendini sürekli yenileyebilen bir sistemdir. Temelinde öğrenme becerisi yatan yapay zekâ, istatistiğe dayanan bir yapıyla çalışmaktadır (İnce, 2021). Veri setlerinin giderek çeşitlenmesi, karmaşıklıklarının artması ve büyük hacimlere ulaşması, yapay sinir ağları ve bu ağların ileri düzey bir formu olan derin öğrenmenin önemini artırmıştır. Bu teknolojiler, insan beyninin işleyişinden ilham alarak, kapsamlı ve karmaşık veri kümeleri üzerinde etkili analizler ve tahminler yapabilme yeteneği sunmaktadır. Yapay sinir ağları, çok katmanlı yapıları sayesinde verilerdeki derin ilişkileri öğrenebilir. Bu yöntemler, günümüzde bilimsel araştırmalardan mühendislik uygulamalarına kadar geniş bir alanda kullanılmakta ve büyük veri analitiği, doğal dil işleme, görüntü işleme gibi alanlarda gelişmelere olanak sağlamaktadır (Craft, 2018). Tablo 3.1’de İnsan zekası ve yapay zekanın karşılaştırılması verilmiştir.

Tablo 3.1. İnsan zekâsı ile yapay zekanın karşılaştırılması (Pirim, 2018).


İnsan Zekası	Yapay Zeka
Çabuk etkilenip değişebilir	Kalıcı
Aktarılması zor	Aktarılması kolay
Dökümantasyonu zor ve zaman alır	Kolayca dökümente edilir
Tahmini zor	Tutarlı tahmin
Yeni fikir üretebilir	Esinlenemez
Uyumludur	Uyum dışarıdan sağlanır
Hassas gözlem yapabilir	Sembolik veriler ile çalışır
Sosyal duyum yeteneği	Teknik duyum yeteneği
Bilgi daha yavaş işler	Bilgi akışı hızlıdır
İnovasyon	Optimizasyon

3.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)

1992 yılında Jang, Takagi-Sugeno bulanık modelinden yola çıkarak Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) metodunu geliştirmiştir (Golafshani ve ark, 2020; Emamgholizadeh ve ark, 2023). Bu metot, insan zihniyle bulanık “eğer-ise” kurallarını birleştirip yapay sinir ağlarının öğrenme becerileriyle birleştirerek, bulanık mantık ve yapay sinir ağları yöntemlerinin güçlü yanlarını öne çıkaran çözüm sunmaktadır (Ly, 2019).

ANFIS Mamdani tipi modellemenin gelişmiş bir türü olan Sugeno tipi modellerle çalışmaktadır. Bu modellerde, girdilerin karmaşık fonksiyonları, çıktı üyelik fonksiyonları aracılığıyla temsil edilir. Bununla birlikte çıktı üyelik fonksiyonları sabit veya lineer olabilirler. ANFIS'in model oluşturma süreci, geleneksel yöntemlere göre daha hızlıdır. Bunun sebebi bu metotların veriler arası ilişkisinin tanımlanmasında ortaya doğrudan bir fonksiyon tanımlaya gerek duymamasıdır. Veriler arası ilişkiyi verilen test ve eğitim veri setleri sayesinde kendileri öğrenmektedir. Kısacası girdi ve çıktıları kullanan ANFIS, olası tüm kuralları adaptif bir şekilde modelleyebilmektedir (Jalal ve ark, 2021; Harandizadeh ve Armaghani, 2021).

ANFIS yapısı, Şekil 3.1’de gösterildiği gibi, beş katmanlı bir ileri beslemeli sinir ağı mimarisinden oluşmaktadır. Bu katmanlar sırasıyla buzlanma, kurallar, normalleştirme, bulanıklaşma ve birleştirme katmanlarıdır.



Şekil 3.1. ANFIS yapısı (Shahbazikhah ve ark, 2011).

1. Katman (Membership layer): İki özgün girdi olan x ve y sözel değişkenleri iki giriş düğümünden beslenir. Bu sözel değişkenler burada üyelik fonksiyonu ve üyelik derecesine dönüştürülerek katmandan çıkmaktadır. Denklem 3.1 ve Denklem 3.2’de

yer alan O_i katmandaki i çıkış düğümünü, A_i ve B_i herhangi bir üyelik fonksiyonunu, μA_i ve μB_{i-2} ise üyelik derecelerini göstermektedir (Çağıl ve ark, 2023).

$$O_{1i} = \mu A_i(x) \quad i = 1,2 \quad (3.1)$$

$$O_{1i} = \mu B_{i-2}(x) \quad i = 3,4 \quad (3.2)$$

2.Katman (Fuzzification layer): Bu katmanda bulunup sabit olan her düğüm aldığı sinyalleri çoğaltmakta ve bir kuralı temsil etmektedir. Buzlanma katmanından çıkan üyelik dereceleri çarpılarak katmandan çıkmaktadır. Düğümün O_{2i} çıktısı Denklem 3.3'deki gibi hesaplanmaktadır (Molla ve ark, 2021).

$$O_{2i} = \omega_i = \mu A_i(x) * \mu B_i(y) \quad i = 1,2 \quad (3.3)$$

3.Katman (Normalization layer): Bu katmanda, kural katmanından gelen her bir değer normalleştirilmektedir. Düğümlerin çıkışı Denklem 3.4'teki gibi bir ilişki kurarak elde edilmektedir.

$$O_{3i} = \overline{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2} \quad i = 1,2 \quad (3.4)$$

4.Katman (Defuzzification layer): Bu katmanda, birinci dereceden polinom ile önceki katmandan gelen normalize edilmiş üyelik derecesinin çarpılmasıyla bulanık çıkarım kurallarının ağırlıklandırılmış değerleri hesaplanmaktadır. Denklem 3.5'teki ilişki kullanılmaktadır (Bayramoğlu ve ark, 2017; Molla ve ark, 2021).

$$O_{4i} = \overline{\omega}_i * f_i = \overline{\omega}_i * (p_i x + q_i y + r_i) \quad i = 1,2 \quad (3.5)$$

5.Katman (Output layer): Bu katmanın tek düğümü olan sistemin ağırlıklı küresel çıktısı Denklem 3.6 ile hesaplanarak ANFIS ağının gerçek değerleri bulunmaktadır.


$$O_{5i} = f = \sum \overline{\omega}_i * f_i = \frac{\sum \omega_i * f_i}{\sum \omega_i} \quad i = 1,2 \quad (3.6)$$

3.1.1. Bulanık kural yapısı

Bulanık mantık, 0-1 ikili mantığı yerine, insanların günlük hayatta kullandığı belirsiz terimleri bilgisayar ortamına işleyerek insan ve makine becerilerini birleştirmeyi amaçlar. Karar vermenin zorlaştığı durumlarda bireylerin muhakeme yeteneğine dayanır (İnce ve ark, 2021). Bulanık mantık, doğru ve yanlış ifadeleri arasında net bir sınır koymadan, insan düşüncesinin yargı ve görüşlerine önem vererek makinelerin insan gibi düşünmesini sağlar (Ly, 2019). ANFIS ise, bulanık mantık ile yapay sinir ağlarını birleştirerek bu yetenekleri daha da geliştirir. ANFIS, bulanık çıkarım kurallarını ve uyarlamalı öğrenme yeteneklerini kullanarak belirsizlik durumlarında etkili sonuçlar üretir. Matematiksel modellerin yetersiz kaldığı ve sezgisel yorumların gerektiği belirsizlik durumlarında iyi sonuçlar verir ve birçok farklı tahmin tekniğiyle birlikte kullanılabilir (Mohd Ali ve ark, 2022). Bu sayede, ANFIS yapıları, bulanık mantığın sağladığı esneklikle sinir ağlarının öğrenme kabiliyetini birleştirerek, karmaşık problemlerde güçlü bir çözüm sunar (Kardani ve ark, 2021).

Bulanık kural yapısı oluşturulurken 'eğer...X....ise...Y...' gibi dilsel ifadeler kullanılır (Mohd Ali ve ark, 2022). Bu kurallar oluşturulurken, X ve Y dilsel ifadeleri belirtilir ve üyelik fonksiyonlarından faydalanılır. Bir kural yapısı örneği şu şekildedir (Elmas, 2018):

Eğer hava “yağmurlu” ise “şemsiye al”




Şekil 3.2. Bulanık çıkarım sistemi.

ANFIS'teki kural tabanının, belirli girdi ve çıktı parametrelerine bağlı olarak değişken aralıklarını ve bulanık kuralları nasıl belirlediği, Şekil 3.2'de detaylı olarak açıklanmaktadır.

3.2. Makine Öğrenmesi


Yapay zekanın (AI) bir türü olan Makine öğrenmesi (ML), verilerin yapısını öğrenerek geçmiş verileri bilgiye dönüştüren ve performanslarını geliştiren bir bilgisayar bilimidir (Mitchell, 1997). Geleneksel tahmin yöntemlerine göre farklılık gösteren Makine öğrenmesi, istatistiksel analizlerle birlikte veriden öğrenmeye odaklanmaktadır. Böylelikle geçmiş verilerden esinlenerek karar verme süreçlerini hızlandırmaktadır. Bu modeller öznitelik seçimi, veri analizi, model eğitimi ve test etme aşamalarından oluşmaktadır. Veri setinin özellikleri, dağılımı ve değişkenler arasındaki ilişkiler veri analizi aşamasında incelenir. Veri setindeki önemli özelliklerin belirlenip katkı sağlamayan özniteliklerin elenmesi ise öznitelik seçimi aşamasında yapılır. Sonrasında veri setindeki örüntünün öğrenilebilmesi için model eğitilir. Son olarak eğitilen modelin performansı test veri seti üzerinden değerlendirilerek modelin doğruluğu ölçülür.

Günümüzde makine öğrenmesi öncelikle teknoloji olmak üzere birçok alanda hızla gelişmektedir. Veri analizi, yüz tanıma, sınıflandırma, tahmin ve problem tespiti gibi çeşitli alanlarda kullanımı gün geçtikçe artan Makine Öğrenimi (ML), Yapay Zekanın alt dalıdır. Bu bağlamda, Derin Öğrenme (DL) algoritmasını içeren Makine Öğrenimi ilişki şeması, Şekil 3.3'te sunulmuştur.




Şekil 3.3. Yapay zekâ, makine öğrenmesi, yapay sinir ağları ve derin öğrenme ilişkisi şeması.

Makine öğrenmenin işlem adımları Şekil 3.4'te verilmiştir.



Şekil 3.4. Makine öğrenmesi işlem adımları.


Makine Öğrenmesi (ML) algoritmaları, Şekil 3.5'te de görüldüğü gibi Denetimli Öğrenme, Denetimsiz Öğrenme ve Takviyeli Öğrenme olmak üzere kendi içinde üç ana başlığa ayrılmaktadırlar.



Şekil 3.5. Makine öğrenmesi yöntem grupları.

3.2.1. Denetimli öğrenme algoritmaları

Denetimli Öğrenme algoritması, bir modeli oluştururken veri setinde bulunan bağımsız ve bağımlı değişkenlerin eşleştirmeleri ile modeli eğitir ve öğrenir. Bu yaklaşımda bağımsız değişkenlerin bağımlı değişkenlerin değerini belirlediği kabul edilir. Veri kümesindeki örüntüleri anlamak için kullanılan denetimli öğrenme teknikleri, belirli ayrımları yapmayı sağlayan tanımlanmış etiketler içerir. Böylelikle modelde olmayan veriler hakkında oluşturduğu bu etiketlerle birlikte tahminde bulunabilir. Karar ağaçları (DT), Destek Vektör Regresyonu (SVR), Rasgele Orman Regresyonu (RFR) ve yapay sinir ağları (ANN) gibi algoritmalar, denetimli öğrenme alanında sıkça kullanılan örnekler arasında yer almaktadır.



Şekil 3.6. Denetimli makine öğrenmesi (Langs ve ark, 2018).

Şekil 3.6’da da görüldüğü üzere her eğitim verisinin temel bir doğruluk değeri vardır. Model bir karar sınırını öğrenerek belirler. Tahmin edilecek değerleri bu sınır içerisinde eşleştirir.

3.2.1.1. Doğrusal regresyon (LR)

Doğrusal Regresyon (LR), istatistik bilimine dayanan bir denetimli makine öğrenme algoritmasıdır. Bu kapsamda LR, bir bağımlı değişken (Y) ile birden fazla özellik içeren bağımsız değişkenler (X) arasındaki ilişkiyi modellemek için kullanılmaktadır. Bu kapsamda model çalışırken bağımsız değişkeni bağımlı değişken ile ilişkilendirir ve aralarında kurduğu bu ilişkiyle birlikte tahmin modeli oluşturur. Bu model aracılığıyla değişkenlerin arasındaki ilişki yönünün pozitif veya negatif olduğu gösterilmektedir. Birden fazla bağımsız değişken olduğunda kullanılan Çoklu Doğrusal Regresyon (MLR), basit yapısı ve kolay yorumlama yapılabilmesinden dolayı yaygın olarak kullanılmaktadır (Luu ve ark, 2021). LR yöntemi Denklem 3.7 ile gösterilir.

$$Y = \beta_0 + \beta_1 X_1 + \varepsilon \quad (3.7)$$

Bu modelde Y çıktı değişkeni, X_1 girdi değişkeni, β_0 ise sabit olup bilinmeyen parametreler olan değişim yönünü verir. ε katsayısı hata terimini temsil etmektedir. MLR yöntemine ait eşitlik Denklem 3.8'de verilmektedir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (3.8)$$

Bu modelde Y çıktı değişkeni, $X_1, X_2, \dots, X_n$ girdi değişkenleri ve $\beta_0, \beta_1, \dots, \beta_n$ ise sabit olup bilinmeyen parametreler olan değişim yönünü verir, ε katsayısı hata terimini temsil etmektedir. Hata katsayısı olan ε , en küçük kareler yaklaşımı ile sıfıra yaklaştırılmaya çalışılır.

3.2.1.2. Gauss süreç regresyonu (GPR)

İstatistiksel bir makine öğrenme algoritması olan Gauss Süreç Regresyonu (GPR) modelleri genellikle doğrusal olmayan sınıflandırma ve regresyon problemleri için başarılı ve uygun modeldir (Arthur ve ark, 2020). GPR, sonuçlar üzerinde belirsizlik ölçümleri yaparak veriler arasındaki ilişkiyi tanımlayıp tahmini gerçekleştirirken Gauss süreci varsayımlarına dayanır (Williams ve Rasmussen, 2006; Korkmaz ve ark, 2022). Gauss Süreç fonksiyonu $f(x)$ Denklem 3.9'da verilmiştir.

$$f(x) = GP(m(x), k(x, x')) \quad (3.9)$$

Burada $m(x)$ ortalama işlevi, $k(x, x')$ ise kovaryans işlevidir. Farklı ortalama ve kovaryans işlevleri seçilerek, farklı tür olan veri setleri modellenebilir. Üstel Kernel işlevi kovaryans işlevleri için yaygın olarak kullanılmaktadır. Denklem 3.10'da $m(x)$ ortalama işlevi ve Denklem 3.11'de $k(x, x')$ kovaryans işlevi verilmiştir.


$$m(x) = E[f(x)] \quad (3.10)$$

$$(x, x') = E[(f(x) - m(x))(f(x') - m(x')))] \quad (3.11)$$

Küçük veri setlerinde başarılı sonuçlar vermesiyle birlikte, büyük veri kümelerinde hesaplama yapılması yavaş ve maliyetli olması GPR'nin dezavantajındandır. Bu yöntem, veri boyutunun artmasıyla birlikte hem bellek hem de işlemci gereksinimlerini önemli ölçüde artırır.

3.2.1.3. Karar ağacı regresyonu (DTR)

Makine öğrenmesi algoritmalarından olan ve sıklıkla tercih edilen yöntemlerin başında gelen Karar Ağacı Regresyonu (DTR), anlaşılabilirliğinden, hesaplama maliyeti düşüklüğünden ve yorumlanabilme yeteneğinden dolayı hem sınıflama hem de regresyon problemlerinde kullanılabilir. Model, tek bir tahmin değerine ulaşana kadar veri setine bir dizi soru sorar. Böylelikle, bağımsız değişken olan girdiler ile bağımlı değişken olan çıktı arasındaki ilişkiyi öğrenir. Karar ağacı gibi denetimli öğrenme algoritmaları, eğitim verileriyle veri setinin kuralını oluşturarak regresyon ağaç yapısı oluşturur. Karar Ağacı, veri setinin özelliklerine göre kendini uyarlayabildiğinden dolayı modelin fonksiyon yapısının önceden belirlenmesine gerek yoktur. Böylelikle esnek yapıdaki bu ağaç modeli farklı türdeki veri setleri için ayrı bir fonksiyon tanımlamaya gerek kalmadan uygun modeli oluşturabildiğinden işlem kolaylığı sağlamaktadır. Ayrıca bünyesinde bulundurduğu grafik yapıları sayesinde YSA'nın belirsiz olan çözümleme tekniğine göre daha fazla avantaj sağlayabilmektedir. Yapısında bulunan ve sınıflandırılacak kategori temsili olan düğüm ile bu kategoriler içindeki özellikleri temsil eden dallar dolayısıyla ağaç görseline benzetilmektedir (Jijo ve Abdulazeez, 2021). Şekil 3.7 örnek olarak gösterilebilir.



Şekil 3.7. Karar ağacı yapısı.


Destek Vektör Regresyon ağaçları (CART) algoritmalarında en sık kullanılan yöntem Gini algoritmasıdır. Bu algoritmada dallar ikiye bölünerek Denklem 3.12'deki saflık ölçütü olan Gini indeksi hesaplanmaktadır.

$$Gini\ indeks = 1 - \sum_{i=1}^n p_i^2 \quad (3.12)$$

P_i katsayısı bir dalın belli özelliğinin içindeki sınıf oranını temsil etmektedir. Gini indeks değeri tüm özellikler için hesaplanmaktadır. En düşük gini indeksine sahip olan özellik o düğümde kullanılacak olan karar kriteridir. Bu şekilde her adımda en uygun özellik seçilir ve modelin doğruluğu artırılmaktadır (Kushwah ve ark, 2022).

3.2.1.4. Rasgele orman regresyonu (RFR)

Rasgele Orman, regresyon ve sınıflandırma için kullanılabilen bir denetimli öğrenme algoritmasıdır. Diğer makine öğrenme algoritmalarında olduğu gibi, veri setini eğitimseti ve test seti olarak ikiye bölerek birden çok ağacı paralel olarak eğitir. Karar ağaçlarından farklı olarak, tüm özellikler arasından seçim yapmak yerine, rasgele olarak seçilen bir alt kümenin en iyi özelliğine odaklanır.



Şekil 3.8. Rasgele orman algoritma şeması.

Şekil 3.8'deki algoritma şemasında görüldüğü üzere Rasgele Orman yönteminin tahmin sonucu tüm tahminlerin ortalaması alınarak hesaplanmaktadır. Doğrusal verilerde olduğu kadar doğrusal olmayan verilerde de anlamlı sonuçlar verebilmektedir. Aynı zamanda farklı türdeki veri setlerine kolayca uyum sağlayarak ve başarılı sonuçlar vermektedir.

RFR algoritması regresyon amacıyla kullanıldığında Θ (theta) vektöründen yararlanır. Eğer n kadar karar ağacı ürettiyse önceki tahmin vektörleriyle ilişkili olarak $\Theta_1, \Theta_2, \dots, \Theta_n$ kadar da tahmin vektörü oluşturacaktır. X girdi vektörü ve Θ vektörüne bağlı olarak oluşturulan $h(x, \Theta)$, karar modelini temsil eder. Denklem 3.13’de N adet ağaç modelinin tahmin denklemi verilmektedir (Toprak, 2023).

$$\text{Sequence} = \{(X; \Theta_1), h(X; \Theta_2), \dots, h(X; \Theta_n)\} \quad (3.13)$$

Modelin nihai sonucu için N adet tahminin ortalaması alınmaktadır. Denklem 2.14 ‘de nihai sonuç gösterilmektedir.

$$\bar{h}(X) = \left(\frac{1}{N}\right) \sum_{n=1}^N h(X; \Theta_k) \quad (3.14)$$


3.2.1.5. Yapay sinir ağları (ANN)

Yapay Sinir Ağları (ANN), insanların nörobiyolojiye olan ilgisinin bir sonucu olarak ortaya çıkmıştır. Bu sistemler, insan beyni ve sinir sisteminin işleyişini taklit etmeye yönelik olarak geliştirilmiş bilgisayar sistemleridir (Golafshani, 2020). Yapay sinir ağları, büyük miktarda veri üzerinde karmaşık desenleri belirleyebilme ve ilişkileri analiz edebilme yeteneklerinden dolayı geniş bir uygulama alanına sahiptir. ANN’ler, çeşitli girdi verilerini analiz ederek bu veriler arasındaki ilişkileri öğrenmeye çalışır. Öğrenme sürecinde, genellikle ağırlıkların ve bağlantıların ayarlanması yoluyla gerçekleşen eğitim adımları vardır. Bu süreç, sistemin hızlı ve etkili bir şekilde karmaşık veri kümelerini işleyebilme yeteneğini geliştirir. Yapay sinir ağları, özellikle büyük veri setlerindeki desenleri belirleme, sınıflandırma, regresyon, kümeler arası ilişkileri keşfetme ve tahminleme gibi çeşitli görevlerde kullanılabilir. Bununla birlikte, ANN’lerin karmaşıklığı ve eğitim süreçlerinin zaman alıcı olması nedeniyle, bazı durumlarda programlaması zor veya imkânsız olaylar için veri işlemeyle ilgilenen bir bilgisayar bilimi dalı olarak kabul edilirler (Öztemel, 2019).

Yapay Sinir Ağları (YSA), bilgisayar biliminde önemli bir rol oynayan, insan beyninin karmaşık işleyişinden esinlenen yapay ve basit sinir hücrelerinin bir araya gelmesiyle oluşan bir modeldir (Jalal, 2021). Bu model, sinir sistemini taklit ederek, çeşitli problemleri çözmek için kullanılmaktadır. Yapay sinir hücrelerinin temel bileşenleri genellikle girdi, çıktı, ağırlıklar, toplama fonksiyonu ve aktivasyon fonksiyonu olmak üzere beş ana bölümden oluşur. Bu bileşenler, birbirleriyle etkileşime girerek, bilgiyi işleyen ve öğrenen bir sistem oluştururlar.

Yapay Sinir Ağlarında, girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç ana katmandan oluşur. Girdi katmanı, sisteme dış dünyadan gelen verileri alır ve işlemeye hazırlar. Her bir girdi, ağırlıklarla çarpılarak gizli katmana iletilir. Gizli katman(lar), alınan girdileri işleyerek, ağın karar verme yeteneğini geliştirir. Bu katmanlar, girdi verilerini uygun bir fonksiyonla işleyerek, çıktı katmanına iletilmek üzere hazırlarlar. Çıktı katmanı ise, işlenmiş verilerin son çıktısını üretir.

Yapay Sinir Ağlarında, girdi ve çıktı verileri arasındaki bağlantılar sonucunda oluşan ağırlıklar, başlangıçta genellikle rastgele atanır. Ancak, eğitim süreci boyunca bu ağırlıkların değerleri sürekli güncellenir. Bu güncellemeler, ağın veriyi daha iyi anlamasını ve öğrenmesini sağlar. Ağın test edilmesi, eğitim tamamlandıktan sonra gerçekleştirilir ve ağın ne kadar iyi öğrendiğini değerlendirmek için kullanılır. Ağın tahminleri, gerçek verilere ne kadar yakınsa, ağın öğrenme ve genelleme yeteneği o kadar iyi kabul edilir. Bu sayede, yapay sinir ağları çeşitli alanlarda başarıyla kullanılabilir. Yapay Sinir Ağları Şematik diyagramı Şekil 3.9'da gösterilmektedir.



Şekil 3.9. Yapay sinir ağları (ANN) şematik diyagramı (Kushwaha ve ark, 2024).

3.2.1.6. Destek vektör regresyonu (SVR)

Destek Vektör Makineleri (SVM), çekirdek tabanlı bir makine öğrenme algoritması olup, sınıflandırma ve regresyon problemlerinde kullanılabilir. Ancak, SVM'in tek bir referans noktasına dayalı olarak çalışmasıyla farklılık gösteren Destek Vektör Regresyonu (SVR), özellikle regresyon problemleri için uygundur. SVR, verilerin belirli bir aralıkta kalmasını sağlayarak, bağımlı değişken olan çıktı değişkeninin tahminini mümkün olduğunca az hata ile gerçekleştirmek için uygun olan

hiperdüzlemi bulur. Bu sayede, SVR, regresyon problemlerinde etkili bir şekilde kullanılabilir. SVR, doğrusal ve doğrusal olmayan çok sınıflı küçük veri setleri için kullanılabilir. Doğrusal olmayan problemleri çözmek için çekirdek fonksiyonlarından faydalanarak regresyon fonksiyonu bulmaya çalışmaktadır (Huang ve ark, 2018; Li ve ark, 2009). Regresyon denklemi Denklem 3.15’de yer almaktadır.

$$y = f(x) = W \cdot \phi(x) + b \quad (3.15)$$

W özellik vektörü, b kesişim vektörü, $\phi(x)$ ise yüksek boyutlu örnek uzayı temsil etmektedir. Denklem 3.16’da ise W özellik vektörü ve b kesişim vektörü tahmini için risk fonksiyonunun düzenlenmiş hali verilmiştir.

$$Minimise = \frac{1}{2} |W|^2 + C \frac{1}{N} \sum_{i=1}^N L_{\epsilon}(y_i, f(x_i)) \quad (3.16)$$

C modelin doğruluğunu belirleyen ceza faktörüken, $|W|^2$ ise düzenlenmiş terimdir. W ve b değerlerini tahmin etmek için Denklem 3.16 amaç fonksiyonuna dönüştürülür. Optimum hiper düzleme ait ise Denklem 3.17 ve 3.18’de verilmektedir (Li ve ark, 2009).

$$W \cdot x_i + b \geq +1, y = +1 \quad (3.17)$$


$$W \cdot x_i + b \geq +1, y = -1 \quad (3.18)$$

Bu denklemlerde $x \in \mathbb{R}^N$ N -boyutlu uzayı, $y \in \{-1, +1\}$ sınıf etiketlerini, b eğilim değerini temsil ederken, w ağırlık vektörünü göstermektedir (Huang ve ark, 2018).

3.2.2. Denetimsiz (gözetimsiz) öğrenme

Makine Öğrenmesinin bir diğer çeşidi olan Denetimsiz Öğrenme yöntemlerinde veri yapılarını anlamak ya da ilişkileri yorumlamak için tanımlanmış bir etiket bulunmamaktadır. Yalnızca girdi veri setine odaklanarak benzerlik, düzensizlik, aykırılıkları yorumlayarak verileri kümelere ayırır ve ortak bir alan bulmayı amaçlar. Yorumlanan bu verilerden doğru bir sonuç elde etmek için tahmine dayalı Anomali Tespiti, Boyutsal Küçülme, Birliktelik Kuralları ve Kümeleme işlemi yapmaktadır. Kümeleme işleminde benzer özelliklere sahip veriler bir araya getirilerek veri kümesinin doğal yapısı anlamaya çalışılır. Bu analizin temel amacı incelenen veri seti arasındaki benzerlik ya da farklılıkları belirlemektir. Yoğunluk tabanlı yöntemler, grid

tabanlı yaklaşım, iki aşamalı kümeleme teknikleri kümeleme modellerinde yaygın olarak kullanılan yöntemlerdendir. Farklı veri türü ve analiz ihtiyacına göre tercih edilen bu yöntemelerde veriler önceden belirlenmiş sınıflarla eşleştirilemez. Denetimli öğrenmeden farklı olarak denetimsiz öğrenme veri gruplama, analiz ve keşfi gibi çeşitli alanlarda etkili rol oynar.



Şekil 3.10. Denetimsiz makine öğrenmesi (Langs ve ark, 2018).

Şekil 3.10’da da görüldüğü üzere her eğitim verisinin gerçek bir doğruluk değeri yoktur. Model yapıları kümeleme ile öğrenerek oluşturur. Yeni veriler oluşturulan bu kümelerin içine atanabilir.



4. UYGULAMA


4.1. Uygulama Amacı

Veri analizi ve modelleme çalışmalarında deney sayısını azaltarak zamanı, maliyeti ve olası hataları en aza indirmek son derece önemlidir. Bu amaçla önemli bir kaynak tasarrufu sağlanabilir. Bu bağlamda, bir dizi araştırma ve model geliştirilmiştir. Ancak, önceki çalışmalarda genellikle Yapay Sinir Ağları (ANN) gibi yöntemler kullanılmış ve diğer makine öğrenimi teknikleriyle yeterince kıyaslanmamıştır. Makine öğrenimi yöntemlerinin kullanıldığı kompozit malzeme davranış tahmini çalışmalarında ise çoğunlukla Destek Vektör Regresyonu (SVR), Rasgele Orman (RFR) ve Karar Ağaçları (DT) gibi tekniklerin öne çıktığı gözlemlenmiştir.

Bu çalışmada, hacimsel aşınma hızları deneysel veri setiyle Yapay Zekâ yöntemlerinden olan Yapay Sinir Ağları (ANN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS), Gauss Süreç Regresyonu (GPR), Destek Vektör Regresyonu (SVR), Rasgele Orman Regresyonu (RFR), Karar Ağaçları Regresyonu (DTR) ve Doğrusal Regresyon (LR) modelleri geliştirilerek, kompozit malzeme davranış özelliklerinin tahmin performansları karşılaştırılacaktır. Bu kapsamlı karşılaştırmada modellerin tahmin performansını değerlendirmek için MSE, RMSE, MAE ve R^2 istatistiki hata ölçüm ve performans değerlerinden yararlanılacaktır.

4.2. Doğrusal Regresyon (LR)


Eğitim ve test verisi olarak ayrılan model üzerinden öncelikle eğitim veri setiyle model eğitilmiş sonrasında test verisi ile tahmin sonucunun başarı performansı ölçülmüştür. Model uygulama sonucunda LR için elde edilen MAE değeri 0.3689, MSE 0.2736, RMSE 0.5230 ve modelin başarısı %69.16 olarak hesaplanmıştır. Şekil 4.1’de tahmin ve gerçekleşen değerlerin grafik üzerindeki karşılaştırılması için oluşturulan grafik sunulmaktadır.



Şekil 4.1. Doğrusal regresyon gerçek ve tahmin değerleri ilişkisi.

4.3. Karar Ağacı Regresyonu (DTR)

Yorumlama kolaylığı ve yüksek doğruluk içermesi sebebiyle sıklıkla kullanılan makine öğrenmesi yöntemlerinden olan DTR modeli Google Colab ortamında uygulanmıştır. Sklearn kütüphanesinden faydalanılarak karar ağacı tabanlı regresyon modeli oluşturulmuştur. Model uygulama sonucunda DTR için elde edilen MAE değeri 0.1648, MSE 0.2960, RMSE 0.5440 ve model başarısı olan R^2 değeri %66.63 olarak hesaplanmıştır. Şekil 4.2’de tahmin ve gerçekleşen değerlerin grafik üzerindeki karşılaştırılması için oluşturulan grafik sunulmaktadır.




Şekil 4.2. Karar ağacı regresyonu gerçek ve tahmin değerleri ilişkisi.

4.4. Destek Vektör Regresyonu (SVR)

Sklearn kütüphanesinden faydalanılarak SVR modeli oluşturulmuştur. Temel modelde test veri seti üzerinden hata istatistikleri hesaplanmıştır. Tahmini değerler ve gerçek veriler karşılaştırılarak performans analizi gerçekleştirilmiştir. Model uygulama sonucunda SVR için elde edilen MAE değeri 0.3297, MSE 0.3297, RMSE 0.5742 ve


model başarısı olan R^2 değeri %62.83 olarak hesaplanmıştır. Şekil 4.3'te tahmin ve gerçekleşen değerlerin grafik üzerindeki karşılaştırılması için oluşturulan grafik sunulmaktadır.



Şekil 4.3. Destek vektör regresyonu gerçek ve tahmin değerleri ilişkisi.

4.5. Rasgele Orman Regresyonu (RFR)


Sklearn kütüphanesinden faydalanılarak RFR modeli oluşturulmuştur. Temel modelde test veri seti üzerinden hata istatistikleri hesaplanmıştır. Tahmini ve gerçek veriler karşılaştırılarak model performansına bakılmıştır. Model uygulama sonucunda RFR için elde edilen MAE değeri 0.2007, MSE 0.1871, RMSE 0.4326 ve model başarısı olan R^2 değeri %78.90 olarak hesaplanmıştır. Şekil 4.4'te tahmin ve gerçekleşen değerlerin grafik üzerindeki karşılaştırılması için oluşturulan grafik sunulmaktadır.



Şekil 4.4. Rasgele orman regresyonu gerçek ve tahmin değerleri ilişkisi.


4.6. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağının (ANN) tasarımı MATLAB R2023b sürümü ile yapılmıştır. Girdi parametresi olarak SiC oranı, Grafit oranı, yük ve kayma hızı kullanılırken, çıktı olarak aşınma hızı tahmin edilmeye çalışılmıştır. Giriş katmanı, gizli katman ve çıkış katmanı olmak üzere 3 katmandan oluşan sinir ağında geri yayımlı çok katmanlı ileri beslemeli ağ tasarlanmış ve veri seti sistematik örnekleme yöntemi ile %80 eğitim ve %20 test verisi olarak bölünmüştür. Eğitim seti olarak 192 veri seti, ağı test etmek için ise 48 veri seti kullanılmıştır. Tasarlanan ağda yer alan yapay sinir ağı hücrelerinde toplama fonksiyonu birleştirme fonksiyonu olarak kullanılmıştır. Ara katmandaki yapay sinir hücreleri için Hiperbolik Tanjant fonksiyonu aktarma fonksiyonu olarak belirlenmişken, çıktı katmanındaki hücreler için doğrusal fonksiyon tercih edilmiştir. Ayrıca, optimizasyon sürecinde lineer olmayan modeller için sıklıkla kullanılan Levenberg-Marquard algoritması uygulanmıştır. Tasarlanan sinir ağının yapısı Şekil 4.5'te gösterilmiştir.




Şekil 4.5. Tasarlanan ANN yapısı.

Eğitim sonrası, gerçek deney değerleri ve tahmin değerleri arasındaki ilişki Şekil 4.6'da gösterilmiştir. ANN modelinin ürettiği tahmin değerleri için Eğitim grafiğinde R değeri 0.9804, test grafiğinde R değeri 0.9168 ve tüm verilerin işlendiği grafikte R değeri 0.9651 bulunmuştur.




Şekil 4.6. Eğitim ve test veri seti için R^2 değerleri.



Şekil 4.7. Gerçek çıktı ve ANN modeli çıktı değerleri hata histogram grafiği.

YSA'nın amacı gerçek çıktı ile ağıın tahmini arasındaki farkı minimum yapmaktır. Gerçek Hacimsel Aşınma Hızı değerleri ile ANN'nin tahmin ettiği değerler arasındaki fark (hata) değerleri Şekil 4.7' de gösterilmiştir. Örneğin histogramın yorumlayacak

olursak; hata değeri 0.4193 olan yaklaşık 2 verinin tahmininde, 1 tanesi eğitim verisinde, 1 tanesi ise test verisinde oluşmuştur.



Şekil 4.8. Modelin performans ölçütleri.

Şekil 4.8’de modelin performans ölçütleri verilmiştir. Bu ölçütler ANN modellerinin eğitim ve değerlendirme süreçlerinde önemli rol oynamaktadır.

4.7. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)

ANFIS uygulama bölümünde model eğitimi için hazırlanan Alüminyum kompozit malzemenin aşınma hızı deney verileri kullanılmıştır. Girdi parametresi olarak SiC oranı, grafit oranı, yük ve kayma hızı kullanılırken, çıktı değeri olarak hacimsel aşınma hızı tahmin edilmiştir. 240 deney verisi içerisinde ANFIS metodu yapısı gereği ihtiyaç duyulan 192 eğitim verisi (%80) ve 48 test verisi (%20) için Yapay Sinir Ağları yönteminde halihazırda bölünmüş olan test ve eğitim veri seti kullanılmıştır.


Uygulama aşamasında MATLAB R2023b programında yer alan bulanık mantık araç kutusundaki ANFIS editöründen yararlanılmıştır. Öncelikle her üyelik fonksiyonu için farklı üyelik derecelerinde modeller oluşturulmuş ve model hatası sabitlenene kadar iterasyon sayısı artırılmıştır. MATLAB’de bulunan üyelik fonksiyonu tipleri arasında

trimf (Üçgen Üyelik Fonksiyonu), gbellmf (Çan şekilli Üyelik Fonksiyonu), trapmf (Yamuk Üyelik Fonksiyonu), gauss2mf (Gauss Üyelik Fonksiyonu), gaussmf (Gauss Üyelik Fonksiyonu Tam Simetrik), pimf (Pİ Üyelik Fonksiyonu), psigmf (Sigmoid Üyelik Fonksiyonu), dsigmf (Sigmoid Üyelik Fonksiyonu Tam Simetrik)'dir. Bu kapsamda optimizasyon yöntemi olarak hibrit modeli seçilmiştir. ANFIS uygulamada adımımda kullanılan parametreler Tablo 4.1'de verilmiştir.

Tablo 4.1. ANFIS parametreleri.


Parametre Adı	Parametrenin Değeri
FIS yapısı tipi	Sugeno
Girdi sayısı	4
Çıktı sayısı	1
Eğitim veri seti	192
Test veri seti	48
Üyelik Fonksiyonu tipi	Trimf, Trapmf, Gbellmf, Gaussmf, Gauss2mf, Pimf, Dsigmf, Psigmf
Çıktı Üyelik Fonksiyonu tipi	Constant
Eğitim optimizasyon modeli	Hybrid
FIS methodu	Grid Partitioning

Doğrusal ve doğrusal olmayan parametrelerin doğru bir şekilde optimize edilmesi için geri yayılmalı yöntemi ve en küçük kareler yönteminin birleşimi olan bir melez ağ yardımıyla sinir ağlarının öğrenme yeteneğinin artırılmıştır. Bu yaklaşım ile olası hataların minimize edilmesi amaçlanmaktadır. Şekil 4.9'da ANFIS model yapısı görülmektedir.



Şekil 4.9. Hacimsel aşınma hızı tahmini için ANFIS model yapısı.

SiC oranı, Grafit oranı, Yük ve Kayma hızı olmak üzere toplamda 4 adet girdi parametresi; çıktı parametresi olarak hacimsel aşınma hızı olmak üzere 192 eğitim ve 48 test veri setinin ANFIS modeline aktarımı Şekil 4.10’da görülmektedir.



Şekil 4.10. Test ve eğitim verilerinin ANFIS modeline aktarılması.

Her bir üyelik fonksiyonu tipi için farklı üyelik fonksiyonu sayıları denenmiş ve en başarılı performansı gösteren tahmin modelini belirlemek amaçlanmıştır. ANFIS sonucu ortaya çıkan modelin performansı değerlendirilirken, R^2 , RMSE, MSE ve MAE istatistiki hata ölçüm yöntemleri kullanılmıştır. Gerçek ve tahmini test verisi sonuçları bu yöntemler ile karşılaştırılmış olup en yüksek R^2 değeri ve en düşük RMSE, MSE ve MAE sonuçlarını veren tahmin modeli belirlenmiştir. Tüm üyelik fonksiyonları birçok farklı kombinasyonda üyelik fonksiyon sayısı ile denenmiş ve yalnızca en yüksek başarı performansı gösteren modellerden 32 tanesinin performans sonuçları Tablo 4.2’de gösterilmektedir.

Tablo 4.2. Farklı üyelik fonksiyonlarında test veri seti için model performans sonuçları.

Üyelik fonksiyonu Sayısı	Üyelik Fonksiyon Tipi	R ²	MAE	MSE	RMSE
2 3 2 3	trimf	0,6534	0.3165	0.2119	0.4603
3 3 2 2	trimf	0,8120	0.2110	0.1135	0.3369
3 2 3 2	trimf	0,7576	0.2453	0.1504	0.3878
3 2 2 2	trimf	0,7365	0.2589	0.1603	0.4004
3 3 3 2	trimf	0,9192	0.1543	0.0500	0.2237
3 3 2 4	trimf	0,7240	0.2529	0.1686	0.4106
3 3 3 3	trapmf	0,4735	0.4720	0.8652	0.9302
2 2 2 2	trapmf	0,6803	0.2809	0.1939	0.4403
4 2 3 3	trapmf	0,6681	0.2734	0.2121	0.4606
3 3 2 2	trapmf	0,8713	0.2294	0.0938	0.3063
3 2 3 2	trapmf	0,7662	0.2442	0.1419	0.3767
3 3 3 2	trapmf	0,8850	0.2052	0.0823	0.2869
3 2 2 2	trapmf	0,7255	0.2577	0.1637	0.4045
2 3 2 3	trapmf	0,6145	0.3807	0.3126	0.5591
3 3 2 2	gaussmf	0,8067	0.2119	0.1161	0.3407
3 2 3 2	gaussmf	0,7623	0.2526	0.1462	0.3824
3 4 2 4	gaussmf	0,5615	0.3648	0.2818	0.5309
3 3 3 2	gaussmf	0,9291	0.1384	0.0428	0.2069
3 3 3 2	gbellmf	0,9238	0.1476	0.0469	0.2165
3 3 2 2	gbellmf	0,8174	0.2095	0.1099	0.3314
3 2 3 2	gbellmf	0,7677	0.2459	0.1421	0.3770
3 3 3 2	gauss2mf	0,9109	0.1636	0.0566	0.2379
3 3 2 2	gauss2mf	0,8684	0.2038	0.0810	0.2846
3 2 3 2	gauss2mf	0,7653	0.2441	0.1425	0.3775
3 3 3 2	pimf	0,8851	0.2038	0.0824	0.2870

Tablo 4.2. (Devamı) Farklı üyelik fonksiyonlarında test veri seti için model performans sonuçları.

Üyelik Fonksiyonu Sayısı	Üyelik Fonksiyon Tipi	R ²	MAE	MSE	RMSE
3 3 2 2	pimf	0,8720	0.2290	0.0933	0.3054
3 2 3 2	pimf	0,7512	0.2429	0.1511	0.3887
3 3 3 2	dsigmf	0,9111	0.1639	0.0565	0.2377
3 3 2 2	dsigmf	0,8695	0.2030	0.0802	0.2832
3 2 3 2	dsigmf	0,7662	0.2435	0.1420	0.3769
3 3 3 2	psigmf	0,9111	0.1639	0.0565	0.2377
3 3 2 2	psigmf	0,8683	0.2046	0.0813	0.2851
3 2 3 2	psigmf	0,7644	0.2431	0.1431	0.3783

Yapılan denemeler sonucu üyelik fonksiyonu 3 3 3 2 olan modellerde diğer üyelik fonksiyon sayılarındaki performanslara göre R² değeri daha yüksek; MAE, MSE, RMSE hata ölçüm istatistiği değerlerininse daha düşük olduğu görülmektedir. Bu sebeple üyelik fonksiyonu sayısı 3 3 3 2 olarak belirlenen tahmin modeli için tüm üyelik fonksiyon tiplerindeki performans değerleri Tablo 4.3'te gösterilmektedir.


Tablo 4.3. 3 3 3 2 Üyelik fonksiyonu için tüm üyelik fonksiyon tiplerindeki model performans sonuçları.

Üyelik Fonksiyonu Sayısı	Üyelik Fonksiyon Tipi	R ²	MAE	MSE	RMSE
3 3 3 2	trimf	0,9192	0.1543	0.0500	0.2237
3 3 3 2	trapmf	0,8850	0.2052	0.0823	0.2869
3 3 3 2	gaussmf	0,9291	0.1384	0.0428	0.2069
3 3 3 2	gbellmf	0,9238	0.1476	0.0469	0.2165
3 3 3 2	gauss2mf	0,9109	0.1636	0.0566	0.2379
3 3 3 2	pimf	0,8851	0.2038	0.0824	0.2870


Tablo 4.3. (Devamı) 3 3 3 2 Üyelik fonksiyonu için tüm üyelik fonksiyon tiplerindeki model performans sonuçları.

Üyelik Fonksiyonu Sayısı	Üyelik Fonksiyon Tipi	R ²	MAE	MSE	RMSE
3 3 3 2	dsigmf	0,9111	0.1639	0.0565	0.2377
3 3 3 2	psigmf	0,9111	0.1639	0.0565	0.2377

Tablo 4.3'e baktığımızda denenen modellere göre test veri seti tahmin performansı bakımından en iyi sonucu veren constant model R², MAE, MSE ve RMSE değerleri sırasıyla 0.9290, 0.1384, 0.0428 ve 0.2069 olarak belirtilmiştir. Bu modelde kullanılan üyelik fonksiyonu sayısı "3 3 3 2" ve üyelik fonksiyon tipi "gaussmf" olarak belirlenmiştir. Bu değerler, modelin test veri setinde yüksek bir doğrulukla çalıştığını ve düşük hata oranlarına sahip olduğunu göstermektedir. Özellikle yüksek R² değeri modelin iyi bir tahmin performansı sergilediğini işaret ederken, düşük MAE, MSE ve RMSE değerleri modelin tahminlerinde tutarlı olduğunu ve sapmaların minimum düzeyde olduğunu göstermektedir. "Gaussmf" fonksiyon tipi, Gaussian üyelik fonksiyonlarını ifade eder ve bu fonksiyonlar, modelin esnekliğini ve doğruluğunu artırmak için kullanılmaktadır. Aynı modelin eğitim verileri için tahmin performansı sonuçları R², MAE, MSE ve RMSE istatistikleri için ise sırasıyla 0.9623, 0.1116, 0.0235, 0.1532 olarak hesaplanmıştır. Bu değerler, modelin eğitim veri setinin de iyi bir performans gösterdiğini göstermektedir.




Şekil 4.11. Eğitim veri seti tahmin sonuçları.




Şekil 4.12. Test veri seti tahmin sonuçları.

Şekil 4.11 ve Şekil 4.12’de yapılan test ve eğitim sonuçlarından bir örnek bulunmaktadır. Sonuç olarak, modelin %92.91 doğruluk oranı ile tahmin edebildiği Şekil 4.13’te gösterilmektedir.




Şekil 4.13. ANFIS ile hacimsel aşınma hızı tahmini.




Şekil 4.14. ANFIS yapısal ağ modeli.

Oluşturulan modele ait ağ yapısı Şekil 4.14'te görülmektedir. Buna göre, modelde bulunan dört girdiden, SiC oranı, grafit oranı ve yük değişkenlerinin her birinin üçer adet, kayma hızının iki üyelik fonksiyonu bulunurken, bir adet çıktı yer almaktadır. Modelin Oluşturduğu 51 bulanık tabanlı kural ise Şekil 4.15'te gösterilmektedir.




Şekil 4.15. ANFIS bulanık kuralları 1. Örneği.

Gerçek test veri setinde SiC oranı 15, Grafit oranı 5, yük 30 ve Kayma Hızı 0,5 iken Hacimsel aşınma hızı 0.75 idi. Şekil 4.15'te de görüldüğü üzere ANFIS modelinin oluşturduğu kural yapısının tahminine göre ise hacimsel aşınma hızı ise 0.77 çıkmıştır.

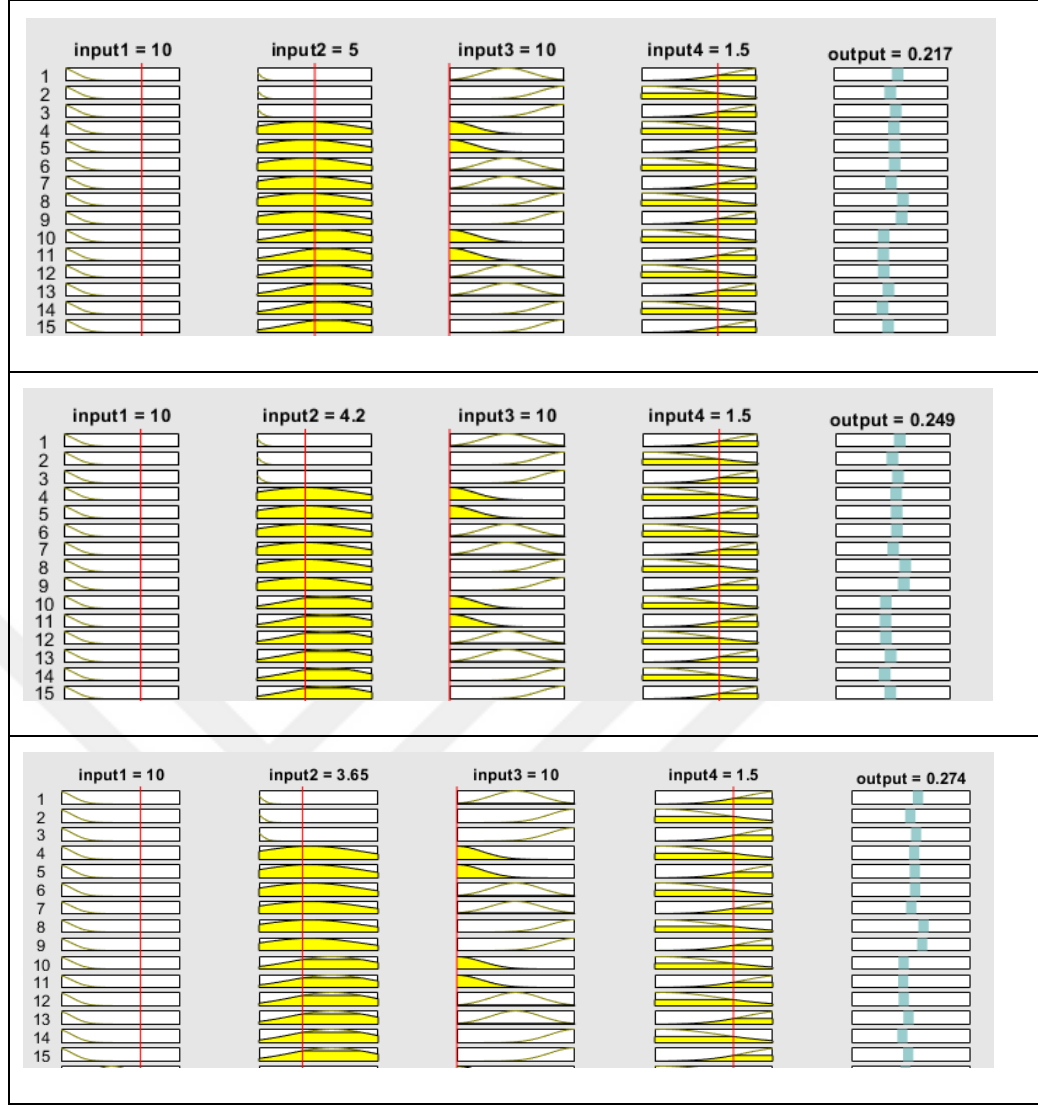


Şekil 4.16. ANFIS bulanık kuralları 2. Örneği.

Aynı şekilde Şekil 4.16’da görüldüğü üzere gerçek test veri setinde SiC oranı 15, Grafit oranı 2.5, yük 10 ve Kayma Hızı 2 iken Hacimsel aşınma hızı 0.15 idi. ANFIS tahminine göre ise Hacimsel aşınma hızı 0.17 çıkmıştır. Bu durum, ANFIS modelinin tahmin performansını ve gerçek verilere yakın sonuçlar üretebildiğini göstermektedir. Tahmin değeri ile gerçek değer arasındaki fark oldukça küçüktür ve bu da modelin doğruluğunu desteklemektedir.



Şekil 4.17. ANFIS bulanık kuralları karşılaştırma örneği.




Şekil 4.18. (Devamı) ANFIS bulanık kuralları karşılaştırma örneği.

Şekil 4.17'ye baktığımızda ise SiC oranı 10, Grafit oranı 2.5, yük 10 ve kayma hızı 1.5 iken model tahmini olan hacimsel aşınma hızı 0,33 çıkmıştır. Test veri setindeki gerçek çıktı değeri olan 0.3 ile karşılaştırdığımızda tahmin başarı performansı model için yeterlidir. Diğer tüm girdi değişkenleri sabit tutulup sadece Grafit oranı 5 yapıldığında ise model çıktısı olan hacimsel aşınma hızı değeri 0.21'e düşmektedir. Bu kapsamda grafit oranı arttırıldığında aşınma hızının azaldığı görülmektedir. Ayrıca, deney veri setinde olmayan farklı grafit oranları ile yapılan testlerde modelin tutarlılık göstermesi beklenmektedir. Bu amaçla grafit oranı 3.65 iken model hacimsel aşınma hızını 0.274 olarak tahmin etmiştir. Aynı şekilde grafit oranı 4.2'ye yükseldiğinde ise model çıktısı için hacimsel aşınma hızı tahmin sonucu 0.24'e düşmektedir.


Tüm girdi değişkenleri sabit tutulup yalnızca 2.5 ve 5 değerleri arasındaki bilinmeyen grafit oranı değerleri ile yaptığımız tahmin sonucunun, test verileri ile yaptığımız

tahmin sonuçlarının arasında bir değer alması beklenmektedir. Bulunan 0.27 ve 0.24 tahmin sonuçlarının ikisi de 0.21 ve 0.33 arasında yer aldığı için ANFIS modelinin, grafit oranının artırılması örneğinde hacimsel aşınma hızının azalmasının tahminini etkili bir şekilde gerçekleştirdiği ve bu değişimlerin tutarlı olduğunu gösterdiği anlaşılmaktadır.

Eğitimi tamamlanan model için parametre aralıkları ve bulanık kurallar ANFIS tarafından otomatik olarak belirlenmektedir. ANFIS, belirli girdilere dayalı olarak tahmin yaparken bulanık mantık kurallarını ve sinir ağlarını birleştirir. ANFIS ayrıca yüzey modelleme ile girdiler ve çıktılar arasındaki bağlantıları grafik olarak inceleyebilmektedir. Şekil 4.18’de MATLAB programında çıktı olarak üretilen yüzey grafikleri verilmiştir. Grafikte, input 1 SiC oranı, input 2 Grafit oranı, input 3 Yük, input 4 Kayma hızı ve output ise Hacimsel aşınma hızını temsil etmektedir.



Şekil 4.19. Yüzey model grafikleri.




Şekil 4.20. (Devamı) Yüzey model grafikleri.

Şekil 4.18’deki yüzey grafikleri incelendiğinde, SiC oranı ve yük değişkenlerinin çıktı değişkeni olan hacimsel aşınma hızını nasıl etkilediği gözlemlenebilir. Yük arttığında ve SiC oranı azaltıldığında hacimsel aşınma hızında maksimum yükseliş görülmektedir. Buna karşı, SiC oranı ve grafit oranı maksimum seviyede arttırıldığında hacimsel aşınma hızı minimum seviyeye gelmektedir. Ayrıca, yük düşükken kayma hızının artışı hacimsel aşınma hızını çok etkilemezken, yük ve kayma hızı birlikte arttırıldığında hacimsel aşınma hızının maksimum seviyeye geldiği görülmektedir. Bu, yük ve kayma hızının birlikte etkisinin hacimsel aşınma hızı üzerinde önemli bir rol oynadığını göstermektedir.

4.8. Gauss Süreç Regresyonu (GPR)

Hacimsel aşınma hızını tahmin edecek GPR modelini oluşturmak için MATLAB yazılımı kullanılmıştır. MATLAB yazılımında Kernel çekirdek fonksiyonu ile aşamalı bir süreçle oluşturulan GPR, algoritmik olarak oldukça karmaşık bir yapıya sahiptir. Model eğitiminden sonra test veri seti üzerinden hata istatistikleri hesaplanmıştır. Tahmini değerler ve gerçek veriler karşılaştırılarak performans analizi gerçekleştirilmiştir. Model uygulama sonucunda RFR için elde edilen MAE değeri 0.1660, MSE 0.0652, RMSE 0.2554 ve model başarısı olan R^2 değeri %90.24 olarak hesaplanmıştır. Şekil 4.19’da tahmin ve gerçekleşen değerlerin grafik üzerindeki karşılaştırılması için oluşturulan grafik yer almaktadır.



Şekil 4.21. Karar ağacı regresyonu gerçek ve tahmin değerleri ilişkisi.

4.9. Önerilen Modellerin Karşılaştırılması

Bu çalışmada Al 27 alaşımına katılan farklı SiC ve Grafit oranları ile elde edilen kompozit malzemenin hacimsel aşınma hızını tahmin etmek amacıyla doğrusal regresyon (LR), karar ağacı regresyonu (DTR), destek vektör regresyonu (SVR), rasgele orman regresyonu (RFR), Gauss süreç regresyonu (GPR), yapay sinir ağları (ANN) ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) gibi farklı regresyon modelleri karşılaştırılmıştır. Farklı tahmin modellerinin performanslarını ölçmek için literatürde çeşitli yöntemler kullanılmıştır. Bu çalışmada yaygın olarak kullanılan yöntemlerden olan R^2 , Ortalama Mutlak Hata (MAE), Ortalama Kare Hatası (MSE) ve Kök Ortalama Kare Hatası (RMSE) metrikleri kullanılarak model performansları değerlendirilmiştir. Sonuçlar Tablo 4.4'te özetlenmiştir:


Tablo 4.4. Kurulan modellerin performanslarının karşılaştırılması.


MODEL	R^2	MAE	MSE	RMSE
Doğrusal Regresyon (LR)	0.6916	0.3689	0.2736	0.5230
Karar ağacı Regresyonu (DTR)	0.6663	0.1548	0.2960	0.5440
Destek Vektör Regresyonu (SVR)	0.6283	0.3297	0.3297	0.5742
Rasgele Orman Regresyonu (RFR)	0.7890	0.2007	0.1871	0.4326

Tablo 4.4. (Devamı) Kurulan modellerin performanslarının karşılaştırılması.

MODEL	R ²	MAE	MSE	RMSE
Gauss Süreç Regresyonu (GPR)	0.9024	0.1660	0.0652	0.2554
Yapay Sinir Ağları (ANN)	0.9168	0.1560	0.0516	0.2271
Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	0.9291	0.1384	0.0428	0.2069

Bu sonuçlar ile farklı regresyon modellerinin performansı çeşitli istatistikler üzerinden değerlendirmiştir. ANFIS ve ANN modelleri, yüksek doğruluk ve düşük hata oranlarıyla öne çıkmaktadır. ANFIS, tüm istatistiklerde en iyi performansı gösterirken, ANN ve GPR modelleri de yakın sonuçlar vermiştir. Diğer yandan, SVR modeli diğer modellere kıyasla daha düşük performans sergilemiştir. Modellerin hata istatistiklerinin karşılaştırılması Şekil 4.20’de ve değişim yüzdesi (R²) değeri ise Şekil 4.21’de verilmiştir.

**Şekil 4.22.** Modellerin hata istatistikleri grafiği.



Şekil 4.23. Modellerin deęişim yüzdesi (R^2) deęerleri.

4.10. Farklı Eęitim ve Test Verileri ile Kullanılan Yöntemlerin Karşılaştırılması

Bu bölümde, sistematik örnekleme yöntemiyle elde edilen beş farklı eęitim ve test veri seti üzerinde, yedi farklı modelin performansları karşılaştırılmıştır. Elde edilen sonuçlar, kullanılan modellerin genellikle benzer bir sıralamaya sahip olduğunu, ancak her bir modelin performansının veri setine baęlı olarak belirli ölçüde deęişebileceğini göstermektedir. Model sonuçları, R^2 , MAE, MSE ve RMSE gibi çeşitli metrikler ile deęerlendirilen her bir modelin doğruluk seviyesini net bir şekilde ortaya koymuştur.

Sonuçlar, her bir veri seti için genellikle Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) modelinin en yüksek doğruluęa sahip olduğunu göstermektedir. ANFIS modeli, tüm veri setlerinde R^2 deęeri açısından %92.91'e kadar bir performans sergileyerek, dięer modelleri geride bırakmıştır. Yapay Sinir Ağları (ANN) da yüksek doğruluk oranlarıyla öne çıkmış, R^2 deęeri 0.89 ile 0.92 arasında deęişen sonuçlar elde edilmiştir. Gauss Süreç Regresyonu (GPR) ise her ne kadar yüksek doğruluk oranlarına sahip olsa da, ANFIS ve ANN'in gerisinde kalmıştır. Rasgele Orman Regresyonu (RFR) ve Destek Vektör Regresyonu (SVR), özellikle bazı veri setlerinde performans açısından dikkat çekerken, Karar Ağacı Regresyonu (DTR) ve Doğrusal Regresyon (LR) ise genellikle daha düşük sonuçlar almıştır.

Elde edilen bu sonuçlar, ANFIS ve ANN gibi yapay zeka tabanlı modellerin, doğrusal olmayan ilişkileri daha iyi modelleme kapasitesine sahip olduklarını ve bu nedenle daha yüksek doğruluk oranları sağladıklarını ortaya koymaktadır. Dięer yandan, GPR

ve RFR gibi daha karmaşık modellerin de belirli veri setlerinde etkili olabildiği gözlemlenmiştir. Ancak, genel olarak, ANFIS modelinin her bir veri seti üzerinde tutarlı bir şekilde en iyi performansı sergilemesi, bu modelin bu çalışmada önerilen veri seti üzerinde en uygun yaklaşım olduğunu göstermektedir.

Çalışmanın sonuçları, makine öğrenmesi modellerinin veri setine özgü performans farklarını ve model seçiminin doğruluğa olan etkisini açık bir şekilde ortaya koymaktadır. Bu bağlamda, kullanılan yöntemlerin doğruluğu, algoritmaların veri setindeki genelleme kapasitesine dayalı olarak değişim göstermekte olup, ANFIS'in yüksek doğruluk oranları, bu modelin karmaşık ve doğrusal olmayan ilişkileri öğrenme kapasitesinin güçlü bir göstergesidir. Bu çalışma, veri seti ve model seçiminin başarı üzerindeki etkisini vurgularken, aynı zamanda ANFIS modelinin üstün performansını destekleyen bir sonuç sunmaktadır.

Sistematiik örneklem ile elde edilen 5 farklı eğitim ve test veri setiyle analiz edilen Doğrusal Regresyon (LR), Karar Ağacı Regresyonu (DTR), Rasgele Orman Regresyonu (RFR), Destek Vektör Regresyonu (SVR), Yapay Sinir Ağları (ANN), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve Gauss Süreç Regresyonu (GPR) olmak üzere toplam 7 ayrı yöntemin istatistiksel sonuçları Tablo 4.5, 4.6, 4.7, 4.8 ve 4.9'da gösterilmiştir.

Tablo 4.5. Veri seti 1 ile elde edilen sonuçlar.

MODEL 1	R ²	MAE	MSE	RMSE
Doğrusal Regresyon (LR)	0.6916	0.3689	0.2736	0.5230
Karar ağacı Regresyonu (DTR)	0.6663	0.1548	0.2960	0.5440
Destek Vektör Regresyonu (SVR)	0.6283	0.3297	0.3297	0.5742
Rasgele Orman Regresyonu (RFR)	0.7890	0.2007	0.1871	0.4326
Gauss Süreç Regresyonu (GPR)	0.9024	0.1660	0.0652	0.2554
Yapay Sinir Ağları (ANN)	0.9168	0.1560	0.0516	0.2271

Tablo 4.5. (Devamı) Veri seti 1 ile elde edilen sonuçlar.

MODEL 1	R ²	MAE	MSE	RMSE
Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	0.9291	0.1384	0.0428	0.2069

Tablo 4.6. Veri seti 2 ile elde edilen sonuçlar.

MODEL 2	R ²	MAE	MSE	RMSE
Doğrusal Regresyon (LR)	0.6788	0.3355	0.2015	0.4489
Karar ağacı Regresyonu (DTR)	0.6569	0.2568	0.2152	0.4639
Destek Vektör Regresyonu (SVR)	0.6033	0.3391	0.2489	0.4988
Rasgele Orman Regresyonu (RFR)	0.8154	0.2098	0.1158	0.3403
Gauss Süreç Regresyonu (GPR)	0.8409	0.1657	0.1067	0.2554
Yapay Sinir Ağları (ANN)	0.9021	0.1560	0.0546	0.2271
Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	0.9128	0.1253	0.0501	0.2069

Tablo 4.7. Veri seti 3 ile elde edilen sonuçlar.

MODEL 3	R ²	MAE	MSE	RMSE
Doğrusal Regresyon (LR)	0.6187	0.3456	0.2567	0.5066
Karar ağacı Regresyonu (DTR)	0.7137	0.2889	0.2033	0.4508
Destek Vektör Regresyonu (SVR)	0.5686	0.3560	0.3064	0.5536
Rasgele Orman Regresyonu (RFR)	0.7625	0.2364	0.1686	0.4106
Gauss Süreç Regresyonu (GPR)	0.8567	0.1537	0.1283	0.3581
Yapay Sinir Ağları (ANN)	0.8976	0.1263	0.1036	0.3218
Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	0.9023	0.1046	0.0967	0.3109

Tablo 4.8. Veri seti 4 ile elde edilen sonuçlar.

MODEL 4	R ²	MAE	MSE	RMSE
Doğrusal Regresyon (LR)	0.6816	0.2647	0.1574	0.3967
Karar ağacı Regresyonu (DTR)	0.5694	0.2529	0.2129	0.4614
Destek Vektör Regresyonu (SVR)	0.6556	0.2623	0.1702	0.4126
Rasgele Orman Regresyonu (RFR)	0.7700	0.1988	0.1137	0.3372
Gauss Süreç Regresyonu (GPR)	0.7734	0.2034	0.1253	0.3239
Yapay Sinir Ağları (ANN)	0.8738	0.1345	0.0936	0.2059
Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	0.8656	0.1228	0.1120	0.3346

Tablo 4.9. Veri seti 5 ile elde edilen sonuçlar.

MODEL 5	R ²	MAE	MSE	RMSE
Doğrusal Regresyon (LR)	0.6556	0.3289	0.2736	0.5231
Karar ağacı Regresyonu (DTR)	0.6975	0.3689	0.2960	0.5440
Destek Vektör Regresyonu (SVR)	0.6578	0.3354	0.3297	0.5741
Rasgele Orman Regresyonu (RFR)	0.8204	0.2008	0.1071	0.3271
Gauss Süreç Regresyonu (GPR)	0.7891	0.2193	0.1842	0.4291
Yapay Sinir Ağları (ANN)	0.8891	0.1560	0.0935	0.3057
Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	0.8922	0.1365	0.1035	0.3217

4.11. ANFIS Model Sonuçlarının Bağımlı Örneklem T Testi ile Analizi

ANFIS modelinin etkinliğini değerlendirmek için, modelin çıktılarını geçmişteki gerçek verilerle kıyaslayarak ölçmek mümkündür. Bu karşılaştırma, modelin doğruluğunu ve tahmin gücünü ölçmek amacıyla kullanılır ve modelin gerçek verilere ne kadar uyum sağladığını belirlemek için kritik bir rol oynar. Böylelikle, modelin doğruluğu ve tahmin gücünü ortaya koymak için etkili bir yöntem sunar.

Bu amaçla, MATLAB ortamında eğitilen ANFIS modelinin eğitim ve test veri kümeleri üzerindeki çıktıları, "evalfis" komutu kullanılarak hesaplanmıştır. Evalfis komutu, modelin çıkardığı tahminleri elde etme sürecini otomatikleştirir ve eğitim ile test aşamaları boyunca tahmin edilen değerlerin hesaplanmasını sağlar. Böylece, modelin her iki aşamadaki tahminleri ile gerçek veriler arasındaki ilişki net bir şekilde ortaya konulmaktadır.

Modelin tahmin ettiği çıktılar ile gerçek veriler arasındaki farkları ölçmek için, 240 veriden oluşan gerçek çıktı değerleri ile ANFIS modelinden elde edilen tahminler, SPSS yazılımında Bağımlı Örneklem t Testi kullanılarak analiz edilmiştir. Bu test, iki veri seti arasındaki ortalama farkların istatistiksel olarak anlamlı olup olmadığını belirler ve modelin tahminlerinin doğruluğunu ölçmek için güçlü bir yöntem sunar. Bağımlı örneklem t testi, modelin ne kadar doğru ve güvenilir bir şekilde tahminler yaptığına dair güvenilir bir gösterge sunarak, modelin genel başarısını objektif bir şekilde değerlendirmemize olanak tanır. Test sonuçları ve bu testin çıktıları Tablo 4.10 ve Tablo 4.11’de gösterildiği gibidir.

Tablo 4.10. Gerçek çıktılar ile model çıktıları karşılaştırması.

	Ortalama	N	Std. Sapma	R	p
Gerçek Çıktı	,8739	48	,7787	,964	,000
ANFIS çıktısı	,8467	48	,7542		

Gerçek çıktılar ile ANFIS modelinin çıktıları arasında $\alpha = 0,05$ düzeyinde anlamlı bir ilişki olduğu belirlenmiştir ($p < 0,05$). Bu, ANFIS modelinin tahminlerinin gerçek verilerle arasında istatistiksel olarak anlamlı bir fark bulunmadığını göstermektedir. Pearson Korelasyon katsayısı (R) değeri ise 0,964 olarak bulunmuştur. Bu değer, iki veri seti arasındaki ilişkinin oldukça güçlü ve pozitif yönlü olduğunu ortaya koymaktadır. Yüksek bir korelasyon katsayısı, modelin tahminlerinin gerçek verilere

yakın ve tutarlı olduğunu, yani ANFIS modelinin doğruluğunun yüksek olduğunu göstermektedir. Bu sonuçlar, ANFIS modelinin gerçek veri setine ne denli iyi uyum sağladığını ve modelin tahmin gücünün güvenilirliğini desteklemektedir.

Tablo 4.11. Gerçek çıktılar ile model çıktıları karşılaştırması.

	Farkların ortalaması	Std. Sapma	t	p
Gerçek Çıktı- ANFIS Çıktısı	,00544	,11707	,9146	,3650

Tablo 4.11, gerçek çıktı değerleri ile ANFIS modelinin çıktıları arasındaki farkları, t testi sonucu ile birlikte göstermektedir. Burada yer alan p değeri 0,3650 olup, bu değer $\alpha = 0,05$ anlamlılık seviyesinden büyük olması, iki veri kümesi arasındaki farkın istatistiksel olarak anlamlı olmadığını ifade etmektedir. Yani, modelin tahminleri ile gerçek veriler arasında anlamlı bir fark bulunmamaktadır. Bu sonuç, ANFIS modelinin çıktılarının, gerçek veri setine son derece yakın ve doğru tahminler ürettiğini göstermektedir.

Bağımlı örneklem t testi, modelin doğruluğunu ve güvenilirliğini test etmek için önemli bir araçtır. Bu testin amacı, iki veri kümesi arasındaki farkları değerlendirmektir. Burada elde edilen p değeri, ANFIS modelinin eğitim ve test aşamalarındaki çıktılarının gerçek verilerle tutarlı olduğunu göstermektedir.



5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, ZA-27 alaşımına SiC ve Grafit partikülleri eklenerek üretilen hibrit kompozit malzemelerin aşınma dirençleri incelenmiş ve bu malzemelerin performansını tahmin etmek amacıyla çeşitli yapay zekâ ve makine öğrenmesi yöntemleri uygulanmıştır. Uygulanan modellerin başarı performansları, eğitim ve test veri kümeleri üzerinde yapılan analizler üzerinden kıyaslanmıştır. Elde edilen sonuçlar, belirli hata istatistikleri (MSE, RMSE, MAE ve R^2) kullanılarak değerlendirilmiştir.

Deneysel sonuçlara göre ANFIS modeli, test veri seti için en düşük hata değerleri ve en yüksek doğruluk oranları ile diğer modellere kıyasla üstün performans göstermiştir. ANFIS modeli ile elde edilen MSE değeri 0.0428 olup, bu değer diğer modellerin performans sonuçlarıyla kıyaslandığında önemli ölçüde düşük olarak elde edilmiş. Bu sonuç ANFIS'in ZA-27 alaşımının aşınma hızını tahmin etmede ne kadar etkili olduğunu göstermektedir.

Özellikle, doğrusal regresyon (LR), karar ağacı regresyonu (DTR), destek vektör regresyonu (SVR) ve rastgele orman regresyonu (RFR) gibi makine öğrenmesi algoritmaları, daha karmaşık ve ileri modellerle kıyaslandığında daha yüksek hata oranlarına sahip olduğu görülmüştür. LR, 0.6732 R^2 değeri ile en düşük performansı sergilemiştir. Buna karşılık, GPR, ANN ve ANFIS modelleri, sırasıyla 0.9024, 0.9168 ve 0.9291 R^2 değerleri ile çok daha yüksek doğruluk oranlarına sahiptir.

Bu bulgular, hibrit kompozit malzemelerin ZA-27 alaşımının mekanik özelliklerini önemli ölçüde iyileştirdiğini, SiC ve Grafit partikülleri, alaşımın aşınma direncini arttırarak, bu malzemelerin farklı endüstriyel uygulamalarda kullanım potansiyelini artırdığını ortaya koymuştur. Özellikle ANFIS modelinin, bu tür malzeme özelliklerinin tahmin edilmesinde gösterdiği başarı, modelin doğruluğunun ve güvenilirliğinin yanı sıra, yapay zekâ ve makine öğrenmesi yöntemlerinin malzeme bilimi ve mühendislik uygulamalarındaki büyük potansiyelini ortaya koymaktadır.

Bununla birlikte, modelin doğruluğunu test etmek için kullanılan bağımlı örneklem t testi sonuçları, ANFIS modelinin gerçek verilerle ne kadar uyumlu olduğunu bir kez daha kanıtlamaktadır. Gerçek verilerle model çıktılarının karşılaştırılmasında, yapılan t testi sonucunda, p değeri 0.3650 bulunmuş olup, bu da model ile gerçek veriler arasındaki farkın istatistiksel olarak anlamlı olmadığını ve modelin tahminlerinde yüksek doğruluk sağladığını göstermektedir. Ayrıca, beş farklı veri seti üzerinde yapılan analizlerde ANFIS modelinin tutarlı performansını vurgulamaktadır; her bir veri setindeki sonuçlar modelin genellenebilirliğini ve doğruluğunu pekiştirmektedir.

Sonuç olarak, bu çalışma, yapay zekâ ve makine öğrenmesi tekniklerinin malzeme bilimi alanında ne kadar güçlü ve etkili araçlar olabileceğini bir kez daha ortaya koymuştur. ANFIS modeli, ZA-27 alaşımının aşınma hızının tahmin edilmesinde en başarılı model olarak öne çıkmakta olup, bu modelin daha düşük hata değerleri ve yüksek doğruluk oranları, ileri malzeme teknolojileri ve yapay zekâ entegrasyonunun endüstriyel uygulamalarda nasıl faydalar sağlayabileceğini gözler önüne sermektedir.

Bu alanda gelecekteki çalışmalar, farklı parametrelerin modellenmesi, daha geniş veri setlerinin kullanılması ve farklı malzeme kompozisyonları üzerinde yapılan testlerle daha da genişletilerek, malzeme bilimi ve mühendislik alanındaki bilgi birikimi artırılabilir ve uygulama potansiyeli daha da geliştirilebilir.

KAYNAKLAR

- Algur, V., Hulipalled, P., Lokesha, V., Nagaral, M., & Auradi, V. (2022). Machine learning algorithms to predict wear behavior of modified ZA-27 alloy under varying operating parameters. *Journal of Bio-and Tribo-Corrosion*, 8, 1-10.
- Ali, N. S. M., Hamzah, K., Idris, F., Basri, N. A., Sarkawi, M. S., Sazali, M. A., ... & Zainal, J. (2022). Power peaking factor prediction using ANFIS method. *Nuclear Engineering and Technology*, 54(2), 608-616.
- Arıkan, R. (2007). Wear behaviour of ZA-12 alloy composites reinforced with Saffil (δ -Al₂O₃) fibres. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 22(3), 359-368.
- Arthur, C. K., Temeng, V. A., & Ziggah, Y. Y. (2020). Novel approach to predicting blast-induced ground vibration using Gaussian process regression. *Engineering with Computers*, 36(1), 29-42.
- Aslan, S. (2004). *SiC ve Grafit Takviyeli Çinko Alüminyum Hibrit Kompozit Malzemelerin Aşınma Davranışlarının İncelenmesi* [Doktora tezi] Sakarya Üniversitesi
- Aydın, M. (2001). *Çinko-Alüminyum Esaslı Alaşımların Değişik Ortamlardaki Yorulma Davranışlarının İncelenmesi* [Doktora tezi] Karadeniz Teknik Üniversitesi
- Babalola, P. O., Bolu, C. A., & Inegbenebor, A. O. (2017). Artificial neural network prediction of aluminium metal matrix composite with silicon carbide particles developed using stir casting method. *International Journal of Mechanical & Mechatronics Engineering (IJMME-IJENS)*, 15(06), 154502-1706.
- Babic, M., Mitrovic, S., & Jeremic, B. (2010). The influence of heat treatment on the sliding wear behavior of a ZA-27 alloy. *Tribology international*, 43(1-2), 16-21.
- Bayramoğlu, T., Pabuccu, H., & Boz, F. Ç. (2017). Forecasting Primary Energy Demand By Using ANFIS Model for Turkey. *Ege Academic Review*, 17(3), 431-446.
- Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(1), 20-28.
- Craft III, J. A. (2018). Artificial intelligence and the softer side of medicine. *Missouri medicine*, 115(5), 406.
- Çağıl, G., Güler, S. N., Ünlü, A., Büyükdibi, Ö., & Tüccar, G. (2023). Comparative analysis of Multiple linear Regression (MLR) and Adaptive Network-Based fuzzy Inference Systems (ANFIS) methods for vibration prediction of a diesel engine containing NH₃ additive. *Fuel*, 350, 128686.

- Devi, M. A., Prakash, C. P. S., Chinnannavar, R. P., Joshi, V. P., Palada, R. S., & Dixit, R. (2020, Eylül). An informatic approach to predict the mechanical properties of aluminum alloys using machine learning techniques. In 2020 International Conference on Smart Electronics and Communication (ICOSEC) (ss. 536-541). IEE.
- Dominguez, C., Lopez, M. M., & Rios-Jara, D. (2002). The influence of manganese on the microstructure and the strength of a ZA-27 alloy. *Journal of materials science*, 37, 5123-5127.
- Dorbane, A., Harrou, F., & Sun, Y. (2022). Machine Learning Methods for Predicting Mechanical Behavior of Aluminum Alloys. *WSEAS Transactions on Electronics*, 13, 84-88.
- Elmas, Ç. (2018). *Yapay Zekâ Uygulamaları*. Ankara: Seçkin Yayıncılık.
- Emamgholizadeh, S., Bazoobandi, A., Mohammadi, B., Ghorbani, H., & Sadeghi, M. A. (2023). Prediction of soil cation exchange capacity using enhanced machine learning approaches in the southern region of the Caspian Sea. *Ain Shams Engineering Journal*, 14(2), 101876.
- Ferati, K., & Adar, N. G. (2022). Makine Öğrenmesi ile Kompozit Malzemelerin Yük Altındaki Yer Değiştirme ve Gerilme Değerlerinin Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (42), 66-70.
- Gangwar, S., & Pathak, V. K. (2020). Dry sliding wear characteristics evaluation and prediction of vacuum casted marble dust (MD) reinforced ZA-27 alloy composites using hybrid improved bat algorithm and ANN. *Materials Today Communications*, 25, 101615.
- Golafshani, E. M., Behnood, A., & Arashpour, M. (2020). Predicting the compressive strength of normal and High-Performance Concretes using ANN and ANFIS hybridized with Grey Wolf Optimizer. *Construction and Building Materials*, 232, 117266.
- Gür, Y. E., & Eşidir, K. A. (2024). Türkiye Hurda Demir Çelik İthalatının Gelecek Değerlerinin Derin Öğrenme, Makine Öğrenmesi ve Topluluk Öğrenme Yöntemleri ile Öngörülmesi. *Alanya Akademik Bakış*, 8(3), 885-908.
- Harandizadeh, H., & Armaghani, D. J. (2021). Prediction of air-overpressure induced by blasting using an ANFIS-PNN model optimized by GA. *Applied Soft Computing*, 99, 106904.
- Huang, S., Cai, N., Pacheco, P. P., Narrandes, S., Wang, Y., & Xu, W. (2018). Applications of support vector machine (SVM) learning in cancer genomics. *Cancer Genomics & Proteomics*, 15(1), 41-51.
- Hulipalled, P., Algur, V., Lokesha, V., & Sharanappa, D. S. (2024). A statistical and neural network approach to investigate the tribological behavior of ZA-27 alloy. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 7(6), 5855-5870.
- İnce, H., İmamoğlu, S. E., & İmamoğlu, S. Z. (2021). Yapay Zeka Uygulamalarının Karar Verme Üzerine Etkileri: Kavramsal Bir Çalışma. *International Review of Economics and Management*, 9(1), 50-63.

- Jalal, F. E., Xu, Y., Iqbal, M., Javed, M. F., & Jamhiri, B. (2021). Predictive modeling of swell-strength of expansive soils using artificial intelligence approaches: ANN, ANFIS and GEP. *Journal of Environmental Management*, 289, 112420.
- Kardani, N., Bardhan, A., Kim, D., Samui, P., & Zhou, A. (2021). Modelling the energy performance of residential buildings using advanced computational frameworks based on RVM, GMDH, ANFIS-BBO and ANFIS-IPSO. *Journal of Building Engineering*, 35, 102105.
- Kardeş, S., & Bilir, K. B. Ö. (2024). Destek Vektör Regresyonu, Ridge Regresyon ve Çoklu Doğrusal Regresyon Yöntemleriyle Turizm Talep Tahmini. *Journal of Research in Business*, 9(1), 194-218.
- Korkmaz, M., Dogan, A., & Kirmaci, V. (2022). Performance Analysis of Counterflow Ranque–Hilsch Vortex Tube with Linear Regression, Support Vector Machines, and Gaussian Process Regression Method. *Gazi J. Eng. Sci*, 8(2), 361-370.
- Kumar, G. V., Pramod, R., Gouda, P. S., & Rao, C. S. P. (2017, Ağustos). Artificial neural networks for the prediction of wear properties of Al6061-TiO₂ composites. *IOP Conference Series: Materials Science and Engineering*, 225(1), 012046.
- Kumar, M. P., Sadashivappa, K., Prabhukumar, G. P., & Basavarajappa, S. (2006). Dry sliding wear behaviour of garnet particles reinforced zinc-aluminium alloy metal matrix composites. *Materials science*, 12(3), 209-213.
- Kumar, V., Gautam, G., Singh, A., Singh, V., Mohan, S., & Mohan, A. (2022). Tribological behaviour of ZA/ZrB₂ in situ composites using response surface methodology and artificial neural network. *Surface Topography: Metrology and Properties*, 10(4), 045001.
- Kushwah, J. S., Kumar, A., Patel, S., Soni, R., Gawande, A., & Gupta, S. (2022). Comparative study of regressor and classifier with decision tree using modern tools. *Materials Today: Proceedings*, 56, 3571-3576.
- Kushwaha, N. L., Kudnar, N. S., Vishwakarma, D. K., Subeesh, A., Jatav, M. S., Gaddikeri, V., ... & Abdelaty, I. (2024). Stacked hybridization to enhance the performance of artificial neural networks (ANN) for prediction of water quality index in the Bagh river basin, India. *Heliyon*.
- Langs, G., Röhrich, S., Hofmanninger, J., Prayer, F., Pan, J., Herold, C., & Prosch, H. (2018). Machine learning: from radiomics to discovery and routine. *Der Radiologe*, 58(Suppl 1), 1-6.
- Li, Q., Meng, Q., Cai, J., Yoshino, H., & Mochida, A. (2009). Applying support vector machine to predict hourly cooling load in the building. *Applied Energy*, 86(10), 2249-2256.
- Luu, Q. H., Lau, M. F., Ng, S. P., & Chen, T. Y. (2021). Testing multiple linear regression systems with metamorphic testing. *Journal of Systems and Software*, 182, 111062.
- Ly, H. B., Pham, B. T., Dao, D. V., Le, V. M., Le, L. M., & Le, T. T. (2019). Improvement of ANFIS model for prediction of compressive strength of manufactured sand concrete. *Applied Sciences*, 9(18), 3841.

- Mathan Kumar, N., Mohanraj, N., Sendhil Kumar, S., Daniel Das, A., Sabareesaan, K. J., & Adwan, O. (2021). Surface Wear Rate Prediction in Reinforced AA2618 MMC by Employing Soft Computing Techniques. In *Intelligent Computing Paradigm and Cutting-edge Technologies: Proceedings of the Second International Conference on Innovative Computing and Cutting-edge Technologies (ICICCT 2020)* (ss. 123-137). Springer International Publishing.
- Min, Y. I., Ming, X. U. E., Peihong, C. O. N. G., Yang, S. O. N. G., Zhang, H., Lingfeng, W. A. N. G., ... & Wanlin, G. U. O. (2023). Machine learning for predicting fatigue properties of additively manufactured materials. *Chinese Journal of Aeronautics*.
- Miroslav, B., Mitrović, S., Zivic, F., & Bobić, I. (2010). Wear behavior of composites based on ZA-27 alloy reinforced by Al₂O₃ particles under dry sliding condition. *Tribology Letters*, 38, 337-346.
- Mishra, A., & Jatti, V. S. (2023). Prediction of wear rate in Al/SiC metal matrix composites using a neurosymbolic artificial intelligence (NSAI)-based algorithm. *Lubricants*, 11(6), 261.
- Mitchell, T. M. (1997). *Artificial Neural Networks*. Machine learning. Burr Ridge, McGraw Hill, 45: 81-127.
- Molla, B., Cagıl, G., & Uyaroglu, Y. (2021). BİST 100 getiri zaman serisinin kaotik analizi ve ANFIS ile kısa dönemli öngörülebilirliği. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 36(2), 577-592.
- Öztemel, E. (2019). *Yapay Sinir Ağları*. İstanbul: Papatya Bilim Yayınevi.
- Radhakrishnan, G., Kesavan, C., Ramesh, V., & Anandan, T. (2016). Application of artificial neural network (ANN) for predicting the wear behaviour of Al 2219-SiCp composite. *Applied Mechanics and Materials*, 852, 397-401.
- Reena Roy, R., Shanmugam, L., Vinothini, A., Venkatachalam, N., Sumathy, G., Murugesan, B., ... & Kerga, G. A. (2023). Investigation of the wear behavior of AA6063/Zirconium oxide nanocomposites using hybrid machine learning algorithms. *Journal of Chemistry*, 2023.
- Ružić, J., Antanasijević, D., Božić, D., & Raić, K. (2014). Prediction of hardness and electrical properties in ZrB₂ particle reinforced metal matrix composites using artificial neural network. *Metallurgical and Materials Engineering*, 20(4), 255-260.
- Saravanan, K., & Giridharan, A. (2022). Machine learning for parametrical analysis of friction stir welded aluminum metal matrix composites. Annals of “Dunarea de Jos” University of Galati. *Fascicle XII, Welding Equipment and Technology*, 33, 59-74.
- Shahbazikhah, P., Asadollahi-Baboli, M., Khaksar, R., Alamdari, R. F., & Zare-Shahabadi, V. (2011). Predicting partition coefficients of migrants in food simulant/polymer systems using adaptive neuro-fuzzy inference system. *Journal of the Brazilian Chemical Society*, 22, 1446-1451.
- Sheikh, K. A., & Khan, M. M. (2024). Tribo-informatics analysis of in-situ TiC reinforced ZA27 alloy: Microstructural insights and wear performance modeling by machine learning. *Tribology International*, 199, 110021

- Sosimi, A. A., Gbenebor, O. P., Oyerinde, O., Bakare, O. O., Adeosun, S. O., & Olaleye, S. A. (2020). Analysing wear behaviour of Al–CaCO₃ composites using ANN and Sugeno-type fuzzy inference systems. *Neural Computing and Applications*, 32, 13453-13464.
- Suzin, S. H. (2011). *Grafit ve sic takviyeli ZA 27 hibrit kompozit malzemelerin ısıtılmasının aşınma davranışına etkisi* [Yüksek Lisans Tezi] Sakarya Üniversitesi.
- 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, 220-234.
- Toprak, Ş. (2023). *Makine Öğrenmesi Yöntemlerini Kullanarak Bir Petrokimya Firmasının Hisse Senedi Fiyat Tahmini* [Yüksek Lisans Tezi] Sakarya Üniversitesi.
- Türk, A. (1996). *Çinko-Aluminyum Esaslı ZA-8 Alaşımında Alaşım Elementlerinin Mekanik Özelliklere ve Mikroyapıya Etkisi* [Doktora tezi] İstanbul Teknik Üniversitesi.
- Vencel, A., Svoboda, P., Klančnik, S., But, A., Vorkapić, M., Harničárová, M., & Stojanović, B. (2023). Influence of Al₂O₃ nanoparticles addition in ZA-27 alloy-based nanocomposites and soft computing prediction. *Lubricants*, 11(1), 24.
- Williams, C. K., & Rasmussen, C. E. (2006). *Gaussian processes for machine learning*. MIT Press.



ÖZGEÇMİŞ

Ad-Soyad : Sena Nur ADIYAMAN

ÖĞRENİM DURUMU:

- **Lisans** : 2020, Sakarya Üniveristesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : Devam Ediyor, Sakarya Üniversitesi, Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı

DİĞER ESERLER:

Çağıl, G., Güler, S. N., Ünlü, A., Büyükdibi, Ö., & Tüccar, G. (2023). Comparative analysis of Multiple linear Regression (MLR) and Adaptive Network-Based fuzzy Inference Systems (ANFIS) methods for vibration prediction of a diesel engine containing NH3 additive. *Fuel*, 350, 128686.