



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**AA 7075 ALAŞIMLARINDA YAŞLANDIRMA VE MEKANİK
DAVRANIŞLARIN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
TABANLI MODELLENMESİ**

Müjde GÜZELGÜL

**Nisan-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**AA 7075 ALAŞIMLARINDA YAŞLANDIRMA VE MEKANİK
DAVRANIŞLARIN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
TABANLI MODELLENMESİ**

Müjde GÜZELGÜL

**Danışman
Dr. Öğr. Üyesi Hüseyin KÖSE**

Diğer Jüri Yeleri

Dr. Öğr. Üyesi İsmail BAYAR Dr. Öğr. Üyesi Ahmet TİĞLİ

**Nisan-2025
BATMAN**

TEZ KABUL VE ONAYI

Müjde GÜZELGÜL tarafından hazırlanan “AA 7075 Alaşımlarında Yaşlandırma ve Mekanik Davranışların Makine Öğrenmesi ve Derin Öğrenme Tabanlı Modellenmesi” adlı tez çalışması 15/04/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Makine Mühendisliği Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Ahmet TIĞLI

.....

Danışman

Dr. Öğr. Üyesi Hüseyin KÖSE

.....

Üye

Dr. Öğr. Üyesi İsmail BAYAR

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Müjde GÜZELGÜL
Tarih: 15.04.2025

ÖZET

YÜKSEK LİSANS TEZİ

AA 7075 ALAŞIMLARINDA YAŞLANDIRMA VE MEKANİK DAVRANIŞLARIN MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME TABANLI MODELLENMESİ

Müjde GÜZELGÜL

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Makine Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Hüseyin KÖSE

2025, 75 Sayfa

Bu çalışma, AA 7075 alüminyum alaşımının yapay yaşlandırma davranışını araştırmakta ve uygulanan ısıtma işlem koşullarının tahribatsız tahmini için makine öğrenmesi ve derin öğrenmeye dayalı yeni bir yöntem sunmaktadır. Çalışmada, alüminyum AA 7075 alaşımı numuneleri 3 saat boyunca 470°C'de çözelti işlemine tabi tutulmuş, ardından 100°C ile 225°C arasında değişen sıcaklıklarda 15°C'lik artışlarla, her biri 1, 2, 3, 6 ve 9 saatlik süreler boyunca yapay yaşlandırma işlemi uygulanmıştır. İşlenmiş numunelerin titreşim tepkileri bir piezoelektrik ivmeölçer cihazı kullanılarak titreşim tepki verileri olarak kaydedilmiş ve farklı ısıtma işlem koşullarıyla ilişkili titreşim tepkileri özellikleri ortaya çıkarmak için frekans alanı verileri elde edilmiştir.

Yaşlandırma işlem koşullarını sınıflandırmak için, ilk olarak titreşim frekansı görüntüleri kullanılarak Evrişimli Sinir Ağı (ESA) modeli geliştirilmiş ve ESA görüntü işleme metodu ile özellik çıkarımı yapılmış ve makine öğrenmesi modelleri oluşturulmuştur. ESA tahmin modeli ile 0,80'lik makro ortalama ile %89'luk bir sınıflandırma doğruluğu elde edilmiş ve model hassas ısıtma işlemleri arasında ayırma yapma konusunda güçlü bir performans göstermiştir. Buna paralel olarak, ESA tabanlı özellik çıkarımını klasik makine öğrenimi sınıflandırıcılarıyla birleştiren hibrit modellerin karşılaştırmalı yöntem ile performans analizi yapılmıştır. Oluşturulan modeller arasında, Rastgele Orman tahmin modeli, Karar Ağaçları ve K-en Yakın Komşu tahmin modelini (%83) ve Destek Vektör Makinesini (%72) geride bırakarak %89'luk bir doğrulukla en yüksek performansı göstermiştir.

Çalışma yapılan mekanik analizler malzemenin çekme dayanımı, sertlik ve aşınma özellikleri hakkında bilgi vermektedir. Mekanik özelliklerin ayrıca farklı makine öğrenmesi modelleriyle tahmin modelleri oluşturulmuş ve modellerin karşılaştırmalı performans analizleri yapılmıştır. Çekme testleri, en yüksek nihai çekme dayanımı 4 saat boyunca 100°C'de 590,9 MPa ile gözlemlendiğini, 3 saat boyunca 130°C'de ve 3 saat boyunca 175°C'de sırasıyla 548,1 MPa ve 549,1 MPa'lık çekme dayanımı değerleri verdiğini ortaya koymuştur. Uzun süreli yaşlandırma süreleri genellikle aşırı yaşlandırma nedeniyle mukavemetin azalmasına yol açtığı gözlemlenmiştir. Sertlik ölçümleri benzer eğilimleri takip etmiş, 175°C ve 190°C'de 1 saatte 145 HB'de en yüksek değeri almış ve 9 saatte 225°C'de 109,67 HB'ye düşerek mikroyapısal kabalaşmayı yansıtmıştır. Malzemenin en düşük aşınma oranı daha uzun süreler için 100°C'de elde edilirken, daha yüksek sıcaklıklar (örneğin, 225°C) kötüleşen aşınma direncine yol açtığı görülmüştür. Regresyon modelleri, yaşlandırma işlem parametrelerine dayalı sertlik ve aşınma oranı değerlerini tahmin etmek için eğitilmiş ve test edilen modeller arasında, Rastgele Orman

tahmin modeli hem eğitim hem de test performansında diğerlerinden sürekli olarak daha iyi performans göstermiş ve en düşük ortalama karesel hataya ulaşmıştır.

Bu kapsamlı çalışmada, ısıt işlemler görmüş alüminyum 7075 alaşımının titreşim verilerinin, ısıt işlemler parametrelerinin doğru sınıflandırılmasını sağlamak için yeterli spektral bilgi içerdiğini doğrulamaktadır. Önerilen makine ve derin öğrenme modelleri, endüstriyel kalite kontrol ve optimizasyon süreçlerinde ısıt işlemler tahmini için potansiyel yeni bir yol sunmaktadır.

Anahtar Kelimeler: alüminyum, AA 7075, makine öğrenmesi, derin öğrenme, yapay yaşlandırma, ısıt işlemler, mekanik özellikler



ABSTRACT

MASTER THESIS

MACHINE LEARNING AND DEEP LEARNING BASED MODELING OF AGING AND MECHANICAL BEHAVIOR IN AA 7075 ALLOYS

Müjde GÜZELGÜL

Batman University Graduate Education Institute

Mechanical Engineer Department of Science

Advisor: Asst. Prof. Dr. Hüseyin KÖSE

2025, 75 Pages

This study investigates the artificial aging behavior of AA 7075 aluminum alloy and presents a new method based on machine learning and deep learning for non-destructive prediction of applied heat treatment conditions. In the study, aluminum AA 7075 alloy samples were solution treated at 470°C for 3 hours, then artificially aged at temperatures ranging from 100°C to 225°C with 15°C increments for 1, 2, 3, 6 and 9 hours each. The vibration responses of the treated samples were recorded using a piezoelectric accelerometer device, and frequency domain data were obtained to reveal the vibration response features associated with different heat treatment conditions.

To classify artificial aging conditions, firstly, a Convolutional Neural Network (ESA) model was developed using vibration frequency images, and feature extraction was performed with the ESA image processing method, and machine learning models were created. With the ESA prediction model, a classification accuracy of 89% with a macro average of 0.80 was achieved, and the model showed strong performance in distinguishing between sensitive heat treatments. In parallel, performance analysis of hybrid models combining ESA-based feature extraction with classical machine learning classifiers was performed with a comparative method. Among the models created, the Random Forest prediction model showed the highest performance with an accuracy of 89%, leaving behind Decision Trees and K-Nearest Neighbor prediction model (83%) and Support Vector Machine (72%).

The conducted mechanical analysis provides information about the tensile strength, hardness and wear properties of the material. In addition, prediction models of mechanical properties were created with different machine learning models, and comparative performance analyzes of the models were performed. Tensile tests revealed that the highest ultimate tensile stress was observed at 100°C for 4 hours with 590.9 MPa, while 130°C for 3 hours and 175°C for 3 hours gave tensile stress values of 548.1 MPa and 549.1 MPa, respectively. It was observed that prolonged aging times generally resulted in decreased strength due to excessive aging. Hardness measurements followed similar trends, with a peak value of 145 HB at 1 hour at 175°C and 190°C, decreasing to 109.67 HB at 225°C for 9 hours, reflecting microstructural coarsening. The lowest wear rate of the material was obtained at 100°C for longer times, while higher temperatures (e.g., 225°C) were found to lead to deteriorating wear resistance. Among the regression models trained and tested to predict hardness and wear rate values based on aging process parameters, the Random Forest prediction model consistently outperformed the others in both training and testing performance and achieved the lowest mean square error.

This comprehensive study confirms that the vibration data of heat-treated aluminum 7075 alloy contains sufficient spectral information to provide accurate classification of heat treatment

parameters. The proposed machine and deep learning models offer a potential new avenue for heat treatment prediction in industrial quality control and optimization processes.

Keywords: aluminum, AA 7075, machine learning, deep learning, artificial aging, heat treatment, mechanical properties



ÖN SÖZ

Bu tez alüminyum 7075 alaşımasının mekaniksel özelliklerini inceleme ve mekanik özelliklerin makine ve derin öğrenme gibi yapay zeka temelli modellerle tahmin performanslarını analiz ederek sürekli gelişen alüminyum endüstrisinde tahribatsız mekanik özellik tahmini için yeni bir yol sunmaktadır.

Öncelikle tez konumun belirlenmesinde etkin rol olan, çalışma planlanmasında, araştırılmasında, yürütülmesinde, oluşumunda ve bitirmesinde ilgi, bilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yardım ve yönlendirmeleri ile çalışmamı bilimsel temeller ışığında şekillendiren, gerek akademik hayatımda gerek mesleki hayatımda desteğiyle her zaman yol göstericim olan hayattaki en büyük şansım Sayın danışman hocam Dr. Öğr. Üyesi Hüseyin KÖSE'ye sonsuz minnet ve teşekkürlerimi sunmayı borç bilirim.

Bu tez çalışmasında numunelerin tedariği ve işlenebilmesi için yönlendiren değerli Müdürüm Mustafa YASANKUL'a, numunelerin işlenmesinde yardım eden Dk Cnc Makine sahibi Sayın Ümit DÖNEZ'e, Değerli görüş ve bilgileri ile araştırmamın şekil almasını sağlayan Jüri Üyeleri Sayın Dr. Öğr. Üyesi Ahmet TİĞLİ ve Dr. Öğr. Üyesi İsmail BAYAR'a ve düzeneğimi yapabilmem için atölyesini açan HMR Yacht sahibi Sayın Hasan Bey'e teşekkürlerimi sunarım.

Bu tez sürecinde mental destekçilerim değerli arkadaşlarım Burak MEŞE ve Rıbaz TEMEL'e, hayatım boyunca haklarını ödeyemeyeceğim değerli Aileme, her zaman motivasyon kaynağım olan Abim Şiyar GÜZELGÜL'e ve her koşulda destekçim olan Teyzem Azize ARAT'a sonsuz minnet ve teşekkürlerimi belirtmek isterim.

Müjde GÜZELGÜL
BATMAN-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
İÇİNDEKİLER	ix
ÇİZELGELER LİSTESİ	xi
ŞEKİLLER LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ	1
1.1. Alüminyum Alaşımlarına Genel Bakış	1
1.1.1. Alüminyum alaşımları	3
1.1.2. Alüminyum alaşım serileri.....	5
1.1.3. Alüminyum alaşımlarına uygulanan ısıt işlemler	6
1.2. Alüminyum 7075 Alaşımına Genel Bakış	8
1.2.1. Alüminyum 7075 Alaşımının bileşimi	9
1.2.2. Alüminyum 7075 Alaşımının mekanik özellikleri	9
1.2.3. Alüminyum 7075 Alaşımının uygulamaları	10
1.2.4. Alüminyum 7075 Alaşımının sektördeki önemi.....	11
1.2.5. Alüminyum 7075 Alaşımına uygulanan ısıt işlem ve temperlemeler.....	12
1.2.6. Yaşlandırma işleminin Alüminyum 7075 Alaşımı için önemi	14
1.2.7. Isıt işlemlerin Alüminyum 7075 Alaşımı için önemi	15
1.3. Makine- Derin Öğrenme ve Sığ Öğrenme Temelli Tahmin Modelleri	16
1.3.1. Derin Öğrenme tarihsel gelişimi.....	16
1.3.2. Derin Öğrenme	17
1.3.3. Derin Öğrenme mimarileri.....	19
2. KAYNAK ARAŞTIRMASI	22
3. MATERYAL VE YÖNTEM.....	26
3.1. Malzeme.....	26
3.2. Isıt İşlem Prosedürü	27
3.3. Veri Toplama, Makine ve Derin Öğrenme Modelleri	29
3.4. Mekanik Testler	33
3.4.1. Çekme testi	33
3.4.2. Sertlik.....	34
3.4.3. Aşınma	34
4. BULGULAR VE TARTIŞMA.....	36
4.1. Titreşim Tepkileri ile Yaşlandırma Koşullarının Derin Öğrenme Tabanlı Sınıflandırılması.....	36
4.2. Çekme Dayanımı	45
4.3. Sertlik.....	50
4.4. Aşınma	59

5. SONUÇLAR VE ÖNERİLER.....	66
KAYNAKLAR	68



ÇİZELGELER LİSTESİ

ÇİZELGE 1.1 ALÜMİNYUM ALAŞIM SERİLERİ VE ÖZELLİKLERİ (UĞURLU, 2009).....	2
ÇİZELGE 1.2 AA 7075’TE ELEMENTLERİN AĞIRLIK ORANI (MATERIALS, N.D.)	9
ÇİZELGE 1.3 AA 7075’İN MEKANİK ÖZELLİKLERİ (ZHOU VD., 2021)	9
ÇİZELGE 3.1 TEMİN EDİLEN AA 7075 NUMUNELERDEKİ ELEMENTLERİN YÜZDE AĞIRLIK ORANLARI	27
ÇİZELGE 3.2 ISIL İŞLEM PROSEDÜRÜ İÇİN KULLANILACAK PARAMETRELER	28



ŞEKİLLER LİSTESİ

ŞEKİL 1.1 AMERİKAN ALÜMİNYUM BİRLİĞİNİN DÖVME ALAŞIMLARI İÇİN İSİMLENDİRME (SÜRME, 2016)	5
ŞEKİL 1.2 YZ, MÖ VE DÖ İLİŞKİSİ (SHİNDE & SHAH, 2018)	17
ŞEKİL 1.3 ESA ŞEMATİK GÖSTERİMİ (EKER & DURU, 2021).....	18
ŞEKİL 1.4 U-NET MİMARİSİNİN ŞEMATİK GÖSTERİMİ (EKER & DURU, 2021)	18
ŞEKİL 1.5 BİR ALGILAYICININ İŞLEYİŞİNİN ŞEMATİK GÖRÜNÜMÜ (BULUT, 2016).	20
ŞEKİL 1.6 ÖRNEK BİR ESA MODELİ GÖRÜNÜMÜ (AMİDİ & AMİDİ T.Y.).....	20
ŞEKİL 3.1 TESTLER İÇİN HAZIRLANAN NUMUNELERDEN ÖRNEK BİR GÖSTERİM.....	26
ŞEKİL 3.2 T6 ISIL İŞLEM PROSESİ ŞEMATİK GÖSTERİMİ.....	27
ŞEKİL 3.3 PİEZOELEKTRİK TİTREŞİM ÖLÇER	30
ŞEKİL 3.4 PİEZOELEKTRİK TİTREŞİM SENSÖRÜ İLE TİTREŞİM TEPKİLERİNİN ELDE EDİLDİĞİ DENEY DÜZENİĞİ.....	30
ŞEKİL 3.5 ESA MODELİNİN ŞEMATİK GÖSTERİMİ	32
ŞEKİL 3.6 MEKANİK TESTLERDE KULLANILACAK ASTM STANDARTLARINA UYGUN ALÜMİNYUM NUMUNE BOYUTLARI.....	33
ŞEKİL 4.1 ISIL İŞLEM GÖRMÜŞ AA 7075 NUMUNELERİNE AİT TİTREŞİM TEPKİLERİ	37
ŞEKİL 4.2 ESA İÇİN DOĞRULUK VE KAYIP ORANLARI	38
ŞEKİL 4.3 ESA MODELİ BAZI TAHMİN DEĞERLERİ İÇİN KARMAŞIKLIK MATRİSİ.....	40
ŞEKİL 4.4 KA MODELİ İÇİN KARİŞİKLİK MATRİSİ.....	42
ŞEKİL 4.5 RO TAHMİN MODELİNE AİT KARMAŞIKLIK MATRİSİ	43
ŞEKİL 4.6 DVM MODELİNE AİT KARMAŞIKLIK MATRİSİ	44
ŞEKİL 4.7 YAŞLANDIRMA SICAKLIKLARI VE SÜRELERİNE GÖRE MAKSİMUM KUVVET UZAMA EĞRİLERİ.....	46
ŞEKİL 4.8 FARKLI SICAKLIKLARDA 1 VE 2 SAAT SÜRELİ YAŞLANDIRMA İŞLEMİ GÖRMÜŞ NUMUNELERİN KOPMA VE AKMA DAYANIMLARI	48
ŞEKİL 4.9 FARKLI SICAKLIKLARDA 3,6 VE 9 SAAT SÜRELİ YAŞLANDIRMA İŞLEMİ GÖRMÜŞ NUMUNELERİN KOPMA VE AKMA DAYANIMLARI	48
ŞEKİL 4.10 1 SAAT YAŞLANDIRMA SÜRESİ İÇİN FARKLI SICAKLIKLARDAKİ SERTLİK DEĞERLERİ.	51
ŞEKİL 4.11 BELİRLENEN YAŞLANDIRMA SICAKLIKLARINA VE SÜRELERİNE GÖRE SERTLİK DEĞERLERİ.	52
ŞEKİL 4.12 TAHMİN MODELLERİNİN EĞİTİM PERFORMANSLARI	54
ŞEKİL 4.13 TAHMİN MODELLERİNİN TEST VERİLERİNDEKİ PERFORMANSI	55
ŞEKİL 4.14 TAHMİN MODELLERİNİN DOĞRULAMA PERFORMANSLARI.....	57
ŞEKİL 4.15 TAHMİN MODELLERİNE GÖRE TEST VE DOĞRULAMA İÇİN OKH DEĞERLERİ... 58	
ŞEKİL 4.16 ISIL İŞLEM SICAKLIĞI VE SÜRELERİNE GÖRE ORTALAMA AŞINMA DEĞERLERİ 59	
ŞEKİL 4.17 TAHMİN MODELLERİ İÇİN EĞİTİM VERİ SETİ PERFORMANSLARI	61
ŞEKİL 4.18 TAHMİN MODELLERİ İÇİN TEST VERİ SETİ PERFORMANSLARI.....	62
ŞEKİL 4.19 TAHMİN MODELLERİNE AİT DOĞRULAMA.....	63
ŞEKİL 4.20 TAHMİN MODELLERİNDE TEST VE DOĞRULAMA İÇİN OKH DEĞERLERİ.....	64

SİMGELER VE KISALTMALAR

Simgeler

η'	: Faz
σ	: Doğrusal olmayan bir aktivasyon fonksiyonu
x	: Görüntü verisi
H	: Görüntü yüksekliği
W	: Görüntü genişliği
C	: Kanal sayısı
K	: Filtre
z	: Düzleştirilmiş özellik vektörü
y	: Tahmin edilen sınıf
p_i	: Düğüm t 'deki sınıf i 'ye ait örneklerin oranı

Kısaltmalar

AA	: Alüminyum Association
YZ	: Yapay Zekâ
YSA	: Yapay Sinir Ağları
MLP	: Çok Katmanlı Algılayıcılar
ESA	: Evrişimli Sinir Ağları
TSA	: Tekrarlayan Sinir Ağları
DSA	: Derin Sinir Ağları
DQA	: Derin Q Ağları
GNN	: Grafik Sinir Ağları
KA	: Karar Ağaçları
RO	: Rastgele Orman
DVM	: Destek Vektör Makinası
KYK	: K-en Yakın Komşu
LSP	: Laser Şok İşleme
ASTM	: Uluslararası Amerikan Test ve Malzeme Topluluğu
GP	: Guinier Preston
GAN	: Üretken Çatışmalı Ağlar
OKH	: Ortalama Karasel Hata

1. GİRİŞ

1.1. Alüminyum Alaşımlarına Genel Bakış

Alüminyumun hikayesi elementin kendisiyle değil, doğal olarak oluşan bileşikleriyle başlar. Antik çağlarda Sümerler, Mısırlılar, Yunanlılar ve Romalılar gibi medeniyetler, tıbbi, boyama ve arıtma amaçlarıyla alum (potasyum alüminyum sülfat) kullanmışlardır. Yaşlı Plinius, kilden çıkarılan gizemli gümüş renkli bir metali, muhtemelen alüminyumunu tarif ederek, Roma İmparatorluğu'nda bile alüminyum benzeri malzemelerle ilkel karşılaşmaların yaşandığını öne sürmüştür (Kozina & Brodarac, 2022).

Oksijen ile olan ilişkisi nedeniyle yüzyıllar boyunca ulaşılması zor bir madde olarak kalan alüminyumun izole edilmesi zorlaştı. Bu metalin keşfi bilimsel devrim sırasında atılacaktı. Antoine Lavoisier, 1787'de varlığı hakkında iddialar ortaya attı ve 1825'te Hans Christian Orsted saf olmayan bir alüminyum formu üretmeyi başardı. Bunun ardından metalinin izolasyonu Friedrich Wöhler tarafından 1827'de ilk defa gerçekleştirildi (Runge, 2018). Metalin ilk endüstride kullanılması 1854'te Henri Sainte-Claire Deville'in sodyum kullanarak bir kimyasal indirgeme süreci geliştirmesiyle gerçekleşti aynı zamanda maliyetleri düşürdü ve sınırlı endüstriyel kullanımı mümkün kıldı. Deville alüminyumunu 1855 Paris Dünya Fuarı'nda halka tanıttı ve o zamanlar hala altından daha pahalıydı (Ashkenazi, 2019). Ticari üretim ancak 1886'dan sonra Amerika Birleşik Devletleri'nde Charles Martin Hall ve Fransa'da Paul Héroult'un bağımsız olarak elektrolitik Hall-Héroult prosesini icat etmesinden sonra uygulanabilir hale geldi. Geliştirilen bu yöntemde Kriyolit içinde çözülmüş alüminanın elektrolizini kullandı ve yöntem günümüzde alüminyum üretiminin temel faktörü olmaya devam etmektedir (Kozina & Brodarac, 2022; Schatzberg, 2003). Bu noktadan itibaren alüminyum, değerli bir metal olmaktan ziyade yaygın olarak kullanılan bir endüstriyel malzemeye formuna hızlıca evrildi. 1890'larda torpido botlarında kullanımı gibi deniz mimarisinde erken kullanılması hem umut vadetti hem de korozyonla ilgili zorluklar içeriyordu. 1930'lara gelindiğinde alüminyum perçinli paneller formunda gemi yapımına geri döndü ve daha sonra çatlama ve yangına dayanıklılık sorunlarına rağmen hafif yapısı nedeniyle kaynaklı

güverte yapımında standart hale geldi (Sielski, 1987). 20. yüzyıl boyunca alüminyum modernliğin bir simgesi haline gelmiştir. Hafifliği, korozyon direnci ve bilimsel ilerlemeyle ilişkisi nedeniyle kullanıcılar tarafından çabuk benimsendi. Kullanımı ulaşımda otomobiller, uçaklar ve uzay gemileri, mimaride bina yapımını ve genel günlük tüketim mallarını kapsıyordu. Sembolik olarak alüminyum hem yeniliği hem de erişilebilirliği temsil ediyordu (Ashkenazi, 2019; Schatzberg, 2003). Günümüzde alüminyum geri dönüştürülebilir yapısı, gemi, otomotiv, havacılık, inşaat ve altyapıda artan kullanımı nedeniyle sürdürülebilir bir "yeşil metal" olarak kabul edilmektedir. Araştırmalar yapısal davranışlarını, korozyon mekanizmalarını ve 3D baskı gibi gelişmiş üretim teknolojilerindeki potansiyelini keşfetmeye devam etmektedir (Sielski, 1987). Alüminyum alaşımı 2 farklı yöntemle elde edilir. Bunlar;

1. Dövme alaşımlı alüminyum
2. Dökme alaşımlı alüminyum

Dövme alüminyum alaşımlarının plastik deformasyon kabiliyeti iyi olduğundan kolayca şekil alabilirler. Bu nedenle özellikle korozyon direnci gerektiren ve şekil olarak kolay işlenmesi gereken durumlarda bu metal ideal hale gelmiştir. Döküm alaşımları ise karmaşık şekiller için kullanılır.

Alüminyum alaşımlarda elementlerin oranı, alaşımın mekanik ve kimyasal özellikleri tarafından belirlenir. Uygulama alanına göre farklı kombinasyonlar tercih edilmektedir. Dövme ve döküm alüminyum alaşımları ısıtılabilir ve ısıtılabilir uygulanamayan iki alt gruba ayrılırlar. 2XXX, 6XXX ve 7XXX alüminyum alaşımları ısıtılabilir uygulanabilen alaşımlardır. 1XXX, 3XXX ve 5XXX alüminyum alaşımları ısıtılabilir uygulanamayan alaşımlardır (Siddesh Kumar vd., 2022). Alüminyum başlıca alaşım elementleri; magnezyum, bakır, silisyum, mangan, çinko, krom, zirkonyum, kalay ve lityumdur. Serilerine göre alaşımlardaki element oranları Çizelge 1.1’te görüldüğü üzere değişmektedir.

Çizelge 1.1 Alüminyum alaşım serileri ve özellikleri (Uğurlu, 2009)

Alaşım	Açıklama
1xxx	Saf alüminyum

2xxx	Ana alařım elementi olarak bakır olarak bilinir. Magnezyum gibi diğeri elementlerde nem arz eder.
3xxx	Mangan elementi alařımda yoğun olarak bulunur.
4xxx	Silisyum elementi alařımda yoğun olarak bulunur.
5xxx	Magnezyum elementi alařımda yoğun olarak bulunur.
6xxx	Magnezyum ve Silisyum elementleri alařımda yoğun olarak bulunur.
7xxx	inko elementi alařımda yoğun olarak bulunur bunun yanında bakır, magnezyum, krom ve zirkonyum elementleri de nemlidir.
8xxx	Kalay elementi yoğun olarak ve yanında bir miktar lityum elementi bulunur.
9xxx	Oluřabilecek farklı element yoğunluğundaki alařımlar iin aık bırakılan seridir.

1.1.1. Alminyum alařımları

Alminyum alařımları, saf alminyuma farklı elementler eklenerek oluřturulan ve belirli zellikleri geliřtirmek iin tasarlanan malzemelerdir. Bu alařımların zelliklerini belirleyen temel faktr, eklenen elementlerdir. Alminyum alařımlarında yaygın olarak kullanılan elementler ve zellikleri literatrdeki verilere gre ařağıdaki řekilde verilmiřtir (Anyalebechi, 1995; Rana vd., 2012; Razumovskiy vd., 2011; Xu vd., 2021).

Magnezyum (Mg):

- Yksek mukavemet saėlar.
- Isıl iřlem uygulanarak sertleřme zellikleri artırılabilir.
- Mukavemeti artırır.
- Hafiflik saėlar.
- Korozyon direncini artırır.
- Kullanım Alanları; Havacılık, Denizcilik ve otomotiv.

Silisyum (Si):

- Dkm zelliklerini iyileřtirir.
- Ařınma direncini artırır.
- Mukavemeti artırır.
- Kullanım Alanları; Motor blokları, dkm paralar.

Manganez (Mn):

- Korozyon direncini artırır.
- Tane yapısını iyileştirir.
- Mukavemet artırıcı rol oynar.
- Demirin zararlı etkilerini azaltır
- Kullanım Alanları; Genel yapı malzemeleri.

Çinko (Zn)

- Sertlik ve mukavemeti artırır.
- Darbe ve yorulma dayanımını artırır.
- Özellikle ısıtıl işlem görmüş alaşımlarda etkili.
- Kullanım Alanları; Havacılık sektörü.

Titanyum (Ti):

- Tane boyutunu küçülterek mekanik özellikleri iyileştirir.
- Mukavemet ve korozyon direncini artırır.
- Kullanım Alanları; Havacılık ve ileri teknoloji ürünleri

Demir (Fe):

- Alüminyumun dayanıklılığını artırır.
- Aşınma direncini artırır.
- Kırılgan intermetalik fazlar oluşturur.
- Kaynaklanabilirliği azaltır.
- Fazla miktarda eklenirse kırılganlık yapabilir.

Krom (Cr):


- Korozyon direncini artırır.
- Isıya dayanıklılık sağlar.
- Kullanım Alanları; Yüksek sıcaklık uygulamaları.

Lityum (Li):

- Alaşımı hafifletir.
- Mukavemet ve sertlik artırır.
- İyi yorulma dayanımı.
- Kullanım Alanları; Havacılık ve uzay sektörü.

1.1.2. Alüminyum alaşım serileri

Alüminyum alaşımları, özelliklerini ve kullanım alanlarını belirlemek için serilere ayrılır. Bu seriler genellikle alüminyumuna eklenen alaşım elementine göre sınıflandırılır. Şekil 1.1 de alüminyum alaşım serilerine verilen isimlerin sistematik metodu gösterilmiştir.



Şekil 1.1 Amerikan Alüminyum Birliğinin dövme alaşımları için isimlendirme (Sürmen, 2016)

Alüminyum alaşımlarının serileri ve özellikleri aşağıda liste şeklinde verilmiştir (Rooy, 1990).

- 1xxx Serisi (Saf Alüminyum); saf alüminyum içerir. Yüksek korozyon direnci, iyi elektrik ve termal iletkenlik ve düşük mukavemet özelliği gösterir. Elektrik kabloları, kimyasal tanklar, gıda ambalajları için iyi bir kullanım tercihidir
- 2xxx Serisi (Alüminyum-Bakır Alaşımları); Alüminyum ve %1,2- %6,2 arasında bakır içerir. Yüksek mukavemet dayanımı, orta seviyede korozyon direnci özellikler gösterir. Isıl işlem ile sertleştirilebilir. Kullanım alanları; Havacılık, uzay sanayi, otomotivdir
- 3xxx Serisi (Alüminyum-Manganez Alaşımları); Alüminyum ve %1-%1,5 arasında manganez içerir. Yüksek korozyon direnci, orta mukavemet özellikler gösterir. Isıl işlemle sertleştirilemez. Kullanım alanları; Çatı kaplamaları, mutfak eşyaları, taşıma tanklarıdır.

- 4xxx Serisi (Alüminyum-Silisyum Alaşımları): Alüminyum ve %4-%13 arasında silisyum içerir. Yüksek aşınma direnci, düşük termal genleşme özelliklerini gösterir. Kullanım alanları; Otomotiv motor parçaları, yapı malzemeleridir.
- 5xxx Serisi (Alüminyum-Magnezyum Alaşımları): Alüminyum ve %0,2-%6 arasında magnezyum içerir. Yüksek korozyon direnci (özellikle deniz ortamında), İyi kaynaklanabilirlik, mukavemet dayanımı özellikler gösterir. Kullanım alanları; Deniz araçları, depolama tankları, yapısal uygulamalarıdır.
- 6xxx Serisi (Alüminyum-Magnezyum-Silisyum Alaşımları): Alüminyum, magnezyum (%0,35-%1,2) ve silisyum (%0,7-%1,4) içerir. İyi korozyon direnci, İyi şekillendirilebilirlik ve kaynaklanabilirlik, iyi mukavemet dayanımı özelliklerini gösterir. Isıl işlem ile sertleştirilebilir. Kullanım alanları; inşaat, taşıt gövdeleri, borulardır.
- 7xxx Serisi (Alüminyum-Çinko Alaşımları): Alüminyum, çinko (%4-%8), magnezyum ve bakır içerir. Yüksek mukavemet dayanımı, iyi korozyon direnci gösterir. Kullanım alanları; havacılık, savunma sanayi, spor ekipmanlarıdır.
- 8xxx Serisi (Özel Alaşımlar): genellikle lityum, demir elementleri içerir veya nadiren diğer elementleri. Özel amaçlar için geliştirilmiş yüksek performanslı alaşımlardır. Hafiflerdir ve yüksek dayanıma sahiptirler. Kullanım alanları; İleri teknoloji sektörleri, enerji depolama ve ambalajlardır.

1.1.3. Alüminyum alaşımlarına uygulanan ısıt işlemler

Alüminyum alaşımlarına farklı türlerde ısıt işlemler uygulanarak mekanik performansları iyileştirilebilir. Farklı içeriğe sahip alüminyum alaşımları için farklı ısıt işlem prosedürleri uygulanır. Genellikle mukavemeti artırmak, tane yapısını düzenlemek veya belirli kullanım koşullarına uygun özellikler kazandırmak amacıyla farklı ısıt işlem prosedürleri uygulanır. Ayrıca uygulanacak olan ısıt işlem türü malzemenin kullanım amacına göre de değişiklik gösterebilir. Genel olarak alüminyum alaşımlarında uygulanan ısıt işlemler, mukavemet artırma, şekillendirilebilirliği iyileştirme, iç gerilmeleri giderme veya malzeme yapısını homojenleştirme amacı taşır (Siddesh Kumar vd., 2022). Amacına göre bazı ısıt işlem türleri aşağıda sıralanmıştır.

- Tavlama: Tavlama, alüminyum alaşımlarının iç gerilimleri gidermek ve soğuk işleme sonrasında sünekliği geri kazandırmak için belirli bir sıcaklığa ısıtılmasını içerir. Bu işlem, malzemeyi yumuşatarak daha işlenebilir hale getirir.
- Çözelti Isıl İşlemi: Bu işlemde, alaşım çözünen elementlerin tek fazlı bir çözelti oluşturmak üzere çözündüğü bir sıcaklığa ısıtılır ve ardından çözeltiyi "dondurmak" için hızlı bir söndürme yapılır. Bu, sonraki yaşlandırma işlemleri için kritik olan aşırı doymuş bir katı çözelti oluşturur.
- Yaşlandırma (Doğal ve Yapay): Doğal Yaşlandırma (T4): Zamanla oda sıcaklığında meydana gelir ve alaşım kendiliğinden ince çökeltiler oluşturarak mukavemeti artırır.
- Yapay Yaşlandırma (T6): Daha hızlı çökeltiler oluşturmak için yüksek sıcaklıklarda hızlandırılmış yaşlandırma, mekanik özellikleri iyileştirir.
- Gerilim Giderme: Bu işlem, işleme veya şekillendirmeden kaynaklanan artık gerilimleri en aza indirerek parçaların boyutsal kararlılığını iyileştirir.

Alüminyum alaşımları için "T" tanımları, hedeflenen özellikleri elde etmek için belirli termal işlemleri ve bunların dizilerini açıklar. Aşağıda bu işlemlerin bir dökümü verilmiştir (Siddesh Kumar vd., 2022). T1 Isıl İşleminde alaşımlar yüksek sıcaklıklarda (örneğin ekstrüzyon veya haddeleme) şekillendirilir, soğutulur ve oda sıcaklığında doğal olarak yaşlandırılmaya bırakılır. Alaşımlar yüksek sıcaklıklarda (örneğin ekstrüzyon veya haddeleme) şekillendirilir, soğutulur ve oda sıcaklığında doğal olarak eskitilmeye bırakılır. T1 ısıtılmasının amacı mikro yapıyı stabilize ederek orta düzeyde mukavemet ve yeterli korozyon direnci elde etmektir. Otomotiv parçaları ve hafif yapısal bileşenlerin önemli olduğu alanlarda kullanılır. T2 ısıtılmasında yüksek sıcaklıkta şekillendirmeden sonra alaşım, doğal eskitmeden önce soğuk işleme (örneğin germe veya bükme) tabi tutulur. T2 ısıtılmasının amacı doğal eskitmeyle birleşen gerinim sertleştirilmesi nedeniyle mukavemeti artırmaktır. Daha yüksek mukavemet ve deformasyona karşı direnç gerektiren uygulama alanlarında bu işlem uygulanır. T3 ısıtılmasında alaşımlar çözelti ısıtılmasına tabi tutulur, ardından soğuk işleme ve doğal yaşlandırma yapılır. T3 ısıtılmasının amacı mukavemet, süneklik ve korozyon direncini dengelemektir. Uçak kaplamaları ve gövde parçaları genelde bu tür ısıtılmasın görmüş alüminyum parçalarından oluşur. T4 ısıtılmasında alaşım çözelti ısıtılmasına tabi tutulur ve ardından soğuk işleme tabi tutulmadan doğal yaşlandırılır. Uygulamanın amacı orta düzeyde mukavemet ve iyi süneklik sağlamaktır. Otomotiv panelleri ve genel mühendislik bu tür ısıtılmasın gerektiren

uygulama alanlarıdır. T5 ısıt işleminde şekillendirmeden sonra alaşıml hızla soğutulur ve mukavemeti ve sertliği artırmak için yapay olarak yaşılandırılır. T5 ısıt işlem amacı doğal yaşılandırmaya kıyasla hızlı bir şekilde yüksek mukavemete ulaşmaktır. İnşaat ve taşımacılık alanlarda kullanılan parçalarda bu tür ısıt işlemler uygulanır. T6 ısıt işleminde alaşıml çözelti ısıt işlemine tabi tutulur ve ardından yapay yaşılandırma yapılır. T6 ısıt işleminin amacı ince çökeltilerin yoğun bir dağılımını oluşturarak mukavemeti en üst düzeye çıkarmaktır. Havacılık bileşenleri, bisiklet çerçeveleri ve basınçlı kaplar gibi uygulama alanları vardır. T7 ısıt işleminde çözelti işleminden sonra alaşıml, bir miktar mukavemet azalma riskine rağmen stabilite ve korozyon direncini artırmak için aşırı yaşılandırılır. T7 ısıt işleminin amacı gerilim korozyona maruz kalan parçalardaki çatlağı minimize etmektir. Uçak bileşenleri ve denizcilik uygulamaları başlıca kullanım alanlarıdır. T8 ısıt işleminde mukavemeti en üst düzeye çıkarmak için çözelti ısıt işlemini, soğuk işlemeyi ve yapay yaşılandırmayı birleştirir. T8 ısıt işleminin amacı gerilim sertleştirme ve çökeltme yoluyla mukavemeti artırmaktır. Yüksek performanslı havacılık ve otomotiv bileşenleri bu tarz ısıt işlemin kullanıldığı alanlardır. T9 ısıt işleminde ek güçlendirme için çözelti ısıt işlemini, yapay yaşılandırmayı ve son soğuk işlemeyi içerir. T9 ısıt işleminin amacı yüksek mukavemet ve sünekliği dengelemektir. Ağır hizmet tipi yapısal parçalar ve yüksek yük uygulama alanları bu ısıt işlemin genel kullanım alanlarıdır. T10 ısıt işleminde şekillendirmeden soğutma, soğuk işleme ve yapay yaşılandırmayı birleştirir. T10 ısıt işleminin amacı belirli gereksinimler için mukavemeti ve sertliği optimize etmektir. Hassas mühendislikle üretilmiş otomotiv ve havacılık parçaları bu tarz ısıt işlemin uygulandığı alanlardır.

1.2. Alüminyum 7075 Alaşımlına Genel Bakış

AA 7075, başlıca alüminyum, çinko, magnezyum ve bakırdan oluşan, mevcut en yüksek mukavemetli alüminyum alaşımlarından biridir (Venkatesh vd., 2024). Muazzam mekanik özellikleri, özellikle de yüksek mukavemet-ağırlık oranı ile bilinir ve bu da onu çeşitli zorlu uygulamalarda tercih edilen bir malzeme yapar (Khalid vd., 2023). Aşağıda ayrıntılı bir genel bakış verilmiştir.

1.2.1. Alüminyum 7075 Alaşımının bileşimi

AA 7075, çinkonun birincil alaşım elementi olduğu 7xxx serisinden bir alaşım olarak sınıflandırılır (Venkatesh vd., 2024). Alüminyum alaşımlarda bulunan element bileşimlerinin ağırlık oranları genel olarak Çizelge 1.2 de gösterildiği gibidir.

Çizelge 1.2 AA 7075'te elementlerin ağırlık oranı (Materials, n.d.)

Al	Si	Fe	Mn	Mg	Cr	Zn	Ti
Kalan	< 0.4	< 0.5	< 0.3	2.1- 2.9	0,18- 0,28	5.1- 6.1	< 0.2

Çinko, magnezyum ve bakırın özel kombinasyonu alaşıma yüksek mukavemet kazandırır. Kromun varlığı korozyon direncini artırmaya yardımcı olur.

1.2.2. Alüminyum 7075 Alaşımının mekanik özellikleri

AA 7075 alaşımı yüksek mekanik mukavemeti ve yorulmaya karşı direnci nedeniyle değerlidir. Bazı önemli mekanik özellikler numunelerin alındığı Uygun Metal üretim verileri referans alınarak Çizelge 1.3'te verilmiştir. Young modülü literatürden AA 7075 alaşımı için verilmiştir.

Çizelge 1.3 AA 7075'in mekanik özellikleri (Zhou vd., 2021)

Nihai Çekme Dayanımı	∴ 530–570 MPa (T6 ısıtılmasında)
Akma Dayanımı	∴ 460–505 MPa (T6 ısıtılmasında)
Kopma Uzaması	∴ %10
Sertlik	∴ 140~160 HB (T6 ısıtılmasında)
Yoğunluk	∴ ~2,81 g/cm ³
Young Modülü	∴ ~71,7 GPa

Mekanik performansı, özellikle T6 ısıtılmasında (çözelti ısıtılma işlemi uygulanmış ve yapay olarak yaşlandırılmış) ısıtılma işlemle önemli ölçüde artırılmıştır; bu da onu yüksek performanslı uygulamalar için uygun hale getirir.

1.2.3. Alüminyum 7075 Alaşımının uygulamaları

Yüksek mukavemeti, hafifliği ve iyi yorulma direnci nedeniyle Alüminyum 7075, malzemelerin yüksek mekanik strese dayanmasını gerektiren endüstrilerde yaygın olarak kullanılır. Başlıca uygulamalar şunlardır:

1. Havacılık Endüstrisi:

Kanatlar, gövde çerçeveleri ve iniş takımları gibi uçak yapıları ve bileşenleri, yüksek mukavemet-ağırlık oranı nedeniyle genellikle Alüminyum 7075'ten yapılır. Aslında, bu alaşım ilk olarak havacılık uygulamaları için geliştirilmiştir (Khalid vd., 2023).

2. Otomobil ve Motor Sporları Endüstrisi:

Yarış arabaları ve yüksek performanslı araçlarda süspansiyon bileşenleri, şasi ve tahrik milleri gibi yüksek performanslı parçaların üretiminde kullanılır. Alaşımın önemli bir ağırlık eklemenden yüksek yüklere dayanma kabiliyeti bu alanda çok önemlidir (Yazid & Zainol, 2019).

3. Savunma ve Askeri Sanayi:

Alüminyum 7075, zırh plakaları, ateşli silahlar ve mühimmat gibi askeri sınıf ekipmanlarda kullanılır. Hafifliği ve dayanıklılığı onu balistik koruma ve hafif ateşli silah bileşenleri (örneğin tüfek alıcıları, hassas silahlar) için uygun hale getirir (Prasad & Sonwani, 2025).

4. Denizcilik Endüstrisi:

7075, 5083 gibi deniz sınıfı alüminyum alaşımları kadar korozyona dayanıklı olmasa da özellikle çerçeveler ve direkler gibi yük taşıyan yapılarda, yüksek mukavemetin korozyon direncinden daha önemli olduğu deniz uygulamalarında kullanılır (Xiang vd., 2023).

5. Spor Ekipmanları:

Yüksek mukavemetli alaşım, bisiklet çerçeveleri, kaya tırmanışı ekipmanları ve üst düzey okçuluk ve beyzbol sopaları gibi spor malzemelerinde kullanılır. Önemli bir ağırlık olmadan dayanıklılık sağlar, daha iyi performans ve kullanım sağlar (Chen, 2010).

6. Takımlar ve Kalıplar

Alüminyum 7075, üretim sırasında tekrarlanan strese ve yüksek yüklere dayanabildiği için plastik enjeksiyon ve takımlar için yüksek mukavemetli kalıplar oluşturmak için kullanılır.

1.2.4. Alüminyum 7075 Alaşımının sektördeki önemi

Yüksek Mukavemet-Ağırlık Oranı: Alüminyum 7075'in birincil avantajı, ağırlığına göre yüksek mukavemetidir. Bu, malzeme mukavemeti ve ağırlığının kritik performans faktörleri olduğu havacılık ve savunma gibi endüstrilerde vazgeçilmez hale getirir (Baradeswaran & Elaya Perumal, 2013; Baradeswaran & Perumal, 2014; Rometsch vd., 2014; Venkataraman & Sundararajan, 2000).

Yorulma Direnci: Uçak ve otomotiv parçaları gibi döngüsel yükleme yaşanan uygulamalarda, 7075 mükemmel yorulma direnci sunarak sürekli stres altında bile bileşenlerin ömrünü uzatır (Khalid vd., 2023; Venkataraman & Sundararajan, 2000).

İşlenebilirlik ve Şekillendirilebilirlik: Alüminyum 7075, tavlanmış halinde oldukça işlenebilirdir ve bu da hassas parçaların üretimini kolaylaştırır. Isıl işleminden geçirildikten sonra alaşım, hafif olmasının yanı sıra mukavemetini korur ve bu da onu birçok uygulamada çok yönlü hale getirir (Khalid vd., 2023; Rometsch vd., 2014).

Alüminyum 7075, titanyum alaşımları veya karbon kompozitlerle karşılaştırıldığında, yüksek mukavemet sağlarken daha uygun maliyetli bir seçenek sunar. Diğer bazı alüminyum alaşımları kadar korozyon direncine sahip olmasa da mekanik performansı genellikle uygun şekilde işlendiğinde veya kaplandığında zorlu ortamlarda kullanımını haklı çıkarır (Baradeswaran & Elaya Perumal, 2013).

Alaşımın özellikleri, farklı uygulamalara uyacak şekilde çeşitli ısıl işlemlerle özelleştirilebilir. Örneğin, T6 ile işlenmiş Alüminyum 7075 maksimum mukavemet sağlarken, T73 temperleme korozyon direncini artırarak hem dayanıklılığın hem de çevresel faktörlerin önemli olduğu ortamlar için uygun hale getirir (Baragetti vd., 2019; Leng vd., 2018; Nečemer vd., 2022).

Alüminyum 7075, mukavemet, hafiflik özellikleri ve yorulma direncinin gerekli olduğu endüstriler için hayati bir malzeme olmaya devam ediyor. Performans ve maliyet arasında bir denge kurarak daha pahalı yüksek mukavemetli malzemelere bir alternatif sunuyor. Havacılık, otomotiv, askeri ve spor endüstrilerindeki yaygın kullanımı, çok yönlülüğünü ve mühendislik uygulamalarındaki devam eden önemini vurguluyor (Baragetti vd., 2019; Nečemer vd., 2022).

1.2.5. Alüminyum 7075 Alaşımına uygulanan ısıt işlem ve temperlemeler

Alüminyum alaşımları için ısıt işlem, fiziksel ve mekanik özelliklerini değiştirmek için malzemenin ısıtılması ve soğutulmasıyla yapılan kontrollü bir işlemdir. Mukavemet, sertlik, süneklik ve korozyon direnci gibi özellikleri artırır. Isıt işlem sırasında faz değişimlerine uğrayan çeliğin aksine, alüminyum alaşımları çökelme sertleştirme veya yaşlandırma sertleştirme adı verilen bir işlemle özelliklerini iyileştirmek için alaşım elementlerinin çözünürlüğüne dayanan sistematik bir yapıya sahiptir (Rice vd., 2003).

Isıt işlem, çözelti ısıt işlemi, yaşlandırma ve tavlama gibi işlemlerle 7075 alaşımlarının mekanik özelliklerini iyileştirmede çok önemlidir. AA 7075 için birincil ısıt işlem adımları, çözelti ısıt işlemi, su verme ve yaşlandırma (doğal veya yapay) içerir. Çözelti işlemi sırasında, alaşım çözünen bileşenleri çözmek için yaklaşık 480°C sıcaklıklarına kadar ısıtılır ve ardından bunları aşırı doymuş bir durumda tutmak için hızlı bir şekilde soğutmak için su verilir. Oda sıcaklığında (doğal) veya yüksek sıcaklıklarda (yapay) yaşlandırma, mukavemeti ve sertliği artırmak için parçacıkları çökeltir (Rice vd., 2003). Bu işlem, alaşımın çinko ve magnezyum gibi çözünen elementlerin alüminyum matrisine çözüldüğü bir sıcaklığa (genellikle 465°C–475°C civarı) ısıtılmasını içerir. Hızlı söndürme, çözünen elementleri yerinde dondurarak ve malzemeyi yaşlandırmaya hazırlayarak takip eder. Çözelti ısıt işleminden sonra, yaşlandırma, MgZn₂ gibi ikincil fazların ince çökeltilerini oluşturarak mekanik mukavemeti artırır. Yaşlandırma doğal (oda sıcaklığında, T4 temperleme olarak adlandırılır) veya yapay (T6 ve T73 temperleme gibi yüksek sıcaklıklarda) olabilir.

AA 7075'in mekanik özelliklerini ayarlamak için çeşitli ısıt işlemlere tabi tutulabilir. En yaygın temperleme koşulları şunlardır:

T6 ısıt işlemi: T6 ısıt işlemi, alüminyum alaşımları için yaygın olarak kullanılan bir ısıt işlemdir ve iki temel adımı içerir: çözelti ısıt işlemi ve ardından yapay yaşlandırma. Bu işlemler, iyi korozyon direnci ve şekillendirilebilirliği korurken mukavemet ve sertlik gibi mekanik özellikleri geliştirir (Siddesh Kumar vd., 2022). Alaşım, alaşım elementlerini katı bir çözeltiye eritmek için 480–540°C sıcaklık aralığına ısıtılır (Siddesh Kumar vd., 2022; Totten & MacKenzie, 2003). Hızlı söndürmeden sonra, malzeme sertleştirme fazlarını çökeltmek ve mukavemeti artırmak için daha düşük sıcaklıklarda (120–200°C) yaşlandırılır (Siddesh Kumar vd., 2022; Totten & MacKenzie, 2003).

T4 ısıt işlemleri: Alüminyum alaşımlarının T4 ısıt işlemleri, özellikle 2xxx, 6xxx ve 7xxx serilerindekiler için, genellikle çözelti ısıt işlemleri ve ardından oda sıcaklığında doğal yaşlandırma yoluyla elde edilir. Bu işlem, alaşımın söndürmeden sonra stabilize edilmesine yardımcı olur ve yaşlandırma işlemi, önemli ölçüde güçlendirmeye katkıda bulunan Guinier-Preston (GP) bölgeleri oluşturur. Doğal yaşlandırma süresi alaşıma bağlı olarak değişir, 2024 gibi alaşımlar bazıları birkaç gün içinde neredeyse tam mukavemete ulaşırken, 6061 gibi alaşımlar daha uzun sürer ve kararlı mekanik özelliklerine ulaşmak için birkaç ay yaşlandırılmaya devam eder (Kaufman, 2000). Bu aşamada, alüminyum alaşımı bakır, magnezyum ve silikon gibi alaşım elementlerini katı bir çözeltiye dönüştürmek için yüksek bir sıcaklığa (genellikle yaklaşık 500–550°C) ısıtılır. Bu adım, bu elementlerin alaşım boyunca eşit şekilde dağılmasını sağlamak için önemlidir (Feng vd., 2021). Çözelti ısıt işleminden sonra alaşım, çözünmüş elementleri aşırı doymuş katı bir çözeltide tutmak için su veya havada hızla soğutulur (söndürülür). Bu adım, çökeltilerin erken oluşmasını önler ve malzemenin mukavemetini ve sertliğini artırır (Du vd., 2021; Liu vd., 2018; Mahathaninwong vd., 2012). Alaşım daha sonra oda sıcaklığında doğal olarak yaşlandırılır ve çökeltilerin zamanla yavaşça oluşmasına izin verilir. Yaşlandırma süreci genellikle birkaç gün sürer ve malzemenin mekanik özellikleri (mukavemet ve sertlik gibi) çökeltiler oluşup matrisi sertleştirdikçe iyileşir (Du vd., 2021; Liu vd., 2018; Mahathaninwong vd., 2012).

T73 ısıt işlemleri: T73 ısıt işlemi, stres korozyon direncini iyileştirmeyi amaçlayan iki aşamalı bir yaşlandırma sürecini içerir. İlk adım daha düşük sıcaklıklarda (~100°C) ve ikinci adım daha yüksek sıcaklıklarda (160–170°C) gerçekleştirilir. Bu işlem, bir miktar mukavemet pahasına korozyon direncini artıran η' fazı gibi çökeltileri stabilize eder. η' (eta prime) fazı, özellikle Al-Zn-Mg esaslı alaşımlarda oluşan, çökeltme sertleşmesi sırasında ortaya çıkan bir metastabil çökelti fazıdır. Maksimum mukavemet η' fazı ile sağlanır. Eğer alaşım çok uzun süre yüksek sıcaklıkta kalırsa, η' fazı büyür ve kararlı η fazına dönüşür. Bu durumda malzemenin dayanımı azalır (aşırı yaşlandırma). Bu, özellikle zorlu ortamlarda dayanıklılık gerektiren uygulamalarda önemlidir (Sunar vd., 2020). Araştırmalar, T73 temperlemenin T6 temperlemeye kıyasla daha düşük nihai çekme mukavemeti (tipik olarak 505 MPa) ve akma mukavemeti gösterdiğini ancak önemli ölçüde daha iyi süneklik ve taneler arası stres korozyon çatlamasına karşı direnç sağladığını göstermiştir. Bu özellikler onu havacılık ve otomotiv bileşenleri için uygun hale getirir (James & Roy, 2020). T73 işleminin aşırı yaşlandırılmış durumu, stres altında çatlamaya karşı duyarlılığın azaltılmasını sağlar. Bu, özellikle uçaklardaki yapısal

bileşenler gibi döngüsel yüklemeye veya aşındırıcı ortamlara maruz kalan parçalar için faydalıdır (Ku vd., 2018).

1.2.6. Yaşlandırma işleminin Alüminyum 7075 Alaşımı için önemi

AA 7075, yüksek mukavemet-ağırlık oranı ve mükemmel mekanik özellikleri nedeniyle havacılık, otomotiv ve savunma endüstrilerinde yaygın olarak kullanılmaktadır. Ancak, bu alaşımın performansı büyük ölçüde ısıl işlemine, özellikle de yaşlandırma sürecine bağlıdır. Yaşlandırma, çökeltme sertleştirilmesi olarak da bilinir, alaşımın mekanik özelliklerinin (çekme mukavemeti, sertlik ve süneklik gibi) sıcaklık ve zamana göre önemli ölçüde değiştiği ısıl işlemde kritik bir aşamadır.

Temel sorun, AA 7075'in mekanik özelliklerinin farklı yaşlandırma sıcaklıklarında tekdüze olmamasıdır. Yaşlandırma sırasında sıcaklıktaki küçük değişiklikler, alaşımın mukavemetinde, tokluğunda, yorulma direncinde ve korozyon davranışında önemli farklılıklara yol açabilir (Baradeswaran & Elaya Perumal, 2013; Baradeswaran & Perumal, 2014; Baragetti vd., 2019; Khalid vd., 2023; Neçemer vd., 2022). Bu, uçak yapıları veya yüksek performanslı otomotiv bileşenleri gibi kritik uygulamalar için hassas malzeme özelliklerine güvenen üreticiler için bir zorluk teşkil eder.

AA 7075'in mekanik özellikleri kontrollü yaşlandırma yoluyla optimize edilebilir, ancak tüm istenen özellikleri (örneğin, mukavemet, süneklik ve yorulma direnci) en üst düzeye çıkaran evrensel olarak optimum bir sıcaklık yoktur. Farklı uygulamalar farklı mekanik özelliklere öncelik verebilir. Örneğin: Havacılık bileşenleri yüksek çekme mukavemeti ve yorulma direnci gerektirir. Otomotiv parçaları darbe direnci için mukavemet ve süneklik arasında bir dengeye öncelik verebilir. Yaşlandırma sıcaklığının bu özellikleri nasıl etkilediğine dair kapsamlı bir anlayış olmadan, malzemeyi amaçlanan kullanımı için optimize etmek zorlaşır.

Yaşlandırma sıcaklığındaki küçük değişiklikler bile (örneğin, 20°C aralığında) büyük ölçüde farklı mekanik sonuçlara yol açabilir. Bir sıcaklıkta iyi çalışan bir işlem, başka bir sıcaklıkta istenmeyen malzeme davranışına neden olabilir. Üretimde tutarlılığı sağlamak, kritik uygulamalarda kusurları veya malzeme arızalarını önlemek için farklı sıcaklıklarda yaşlandırma sürecinin ayrıntılı bir şekilde anlaşılmasını gerektirir.

Daha yüksek sıcaklıklarda yaşlandırma genellikle alaşımın çekme mukavemetini ve sertliğini artırır, ancak aynı zamanda korozyon direncini de azaltabilir. Tersine, daha

düşük sıcaklıklarda yaşlandırma korozyon direncini artırabilir, ancak mukavemet pahasına. Koroziyon elementlere maruz kalmanın yaygın olduğu deniz veya havacılık ortamları gibi uygulamalarda, yeterli mukavemeti korurken erken malzeme bozulmasını önlemek için bu dengeyi anlamak çok önemlidir.

Üreticiler, yaşlandırmadan sonra alaşımın mekanik özelliklerini tahmin etmek için güvenilir yöntemlere ihtiyaç duyar. Bu, farklı sıcaklıklarda yaşlandırmanın mekanik performans üzerinde doğrusal olmayan etkiler üretmesi durumunda daha karmaşık hale gelir. Mühendislerin farklı yaşlandırma koşullarına dayalı malzeme davranışını tahmin etmelerine yardımcı olmak için tahmini modellere ihtiyaç vardır, bu da üretim süreçlerini optimize edebilir ve maliyetleri azaltabilir.

Yaşlandırma sürecinde, ikincil fazların (örn. $MgZn_2$) çökmesi gibi mikro yapısal değişiklikler meydana gelir ve bu da alaşımın mekanik özelliklerini güçlü bir şekilde etkiler. Bu mikro yapısal değişikliklerin farklı sıcaklıklarda nasıl geliştiğini anlamak, özellikle alaşımın ömrü boyunca değişen yükler ve gerilimler yaşayacağı uygulamalar için malzeme davranışını tahmin etmek açısından kritik öneme sahiptir.

1.2.7. Isıl işlemlerin Alüminyum 7075 Alaşımı için önemi

Güvenlik ve performansın pazarlık konusu olmadığı havacılık, savunma ve otomotiv gibi endüstrilerde, Alüminyum 7075'in doğru mekanik özellikleri sergilemesini sağlamak çok önemlidir. Uygunsuz yaşlandırma sıcaklıkları nedeniyle bu özelliklerin yanlış anlaşılması veya yanlış tahmin edilmesi, potansiyel olarak hayatları tehlikeye atan felaket niteliğinde malzeme arızasına yol açabilir. Üreticiler, yaşlandırma sıcaklığının mekanik özellikleri nasıl etkilediğini daha iyi anlayarak, aşırı malzeme testi ve üretim gecikmeleriyle ilişkili maliyetleri azaltarak ısıtma süreçlerini optimize edebilir. Optimize edilmiş yaşlandırma, malzemenin ömrünü uzatarak parça değiştirme veya arıza sıklığını azaltabilir. Bazı spesifik ortamlarda (deniz, havacılık veya endüstriyel ortamlar gibi), mekanik mukavemet ile korozyon direnci arasındaki denge çok önemlidir. Yaşlandırma sıcaklığının etkilerinin eksik anlaşılması, optimum olmayan malzemelerin kullanılmasına, erken arızaya ve daha yüksek bakım maliyetlerine yol açabilir.

Alaşıma uygulanan ısıtma işlem parametrelerini ve buna bağlı gelişen mekanik özellikleri, deneysel verilere dayalı olarak öğrenen makine öğrenmesi ve derin öğrenme tabanlı modeller aracılığıyla tahribatsız şekilde tahmin edebilmek; üretim maliyetlerinin azaltılması ve proses kalitesinin artırılması açısından endüstriyel uygulamalarda büyük

önem taşımaktadır. Bu kapsamda bu tez, farklı yaşlandırma sıcaklıklarının Alüminyum 7075 alaşımının mekanik özelliklerini farklı etkilemesinden yola çıkarak bu farklılardan yararlanan derin öğrenme ve makine öğrenmesi modelleri oluşturarak malzemenin tahribatsız olarak mekanik özelliklerinin tahmini sağlayan derin öğrenme modelinin geliştirilmesini amaçlamaktadır. Bu faktörlerin anlaşılması, istenen mekanik özelliklere sahip malzemeler üreten, kritik uygulamalarda arıza riskini azaltan ve Alüminyum 7075 bileşenlerinin genel güvenilirliğini artıran optimize edilmiş yaşlandırma işlemlerinin daha iyi anlaşılmasını sağlayarak endüstriye katkı sağlayacaktır.

1.3. Makine- Derin Öğrenme ve Sığ Öğrenme Temelli Tahmin Modelleri

1.3.1. Derin Öğrenme tarihsel gelişimi

Derin öğrenmenin (DÖ) tarihi, yapay zekâ (YZ) ve sinir ağlarının gelişimiyle derinden iç içedir. Yapay Sinir Ağları (YSA) kavramı, bir nöronun matematiksel bir modelini öneren McCulloch-Pitts modelinin tanıtıldığı 1940'lara dayanır (McCulloch & Pitts, 1943). Bu, hesaplamalı öğrenmedeki sonraki gelişmelerin temelini atmıştır. 1958'de Frank Rosenblatt, sınıflandırma görevleri için sinir ağlarının potansiyelini gösteren gözetimli öğrenme için erken bir algoritma olan Perceptron'u tanıttı. Ancak, tek katmanlı Perceptron'ların XOR problemi gibi doğrusal olmayan ayrılabilir problemleri çözmemesi, 1970'lerde sinir ağlarına karşı şüpheciliğe yol açtı (Minsky & Papert, 1988). Sinir ağlarına olan ilginin yeniden canlanması, 1980'lerde Rumelhart vd. (1986) ve arkadaşları tarafından çok katmanlı algılayıcıların (MLP'ler) ve geri yayılım algoritmasının tanıtılmasıyla gerçekleşti ve bu da derin ağların eğitilmesini mümkün kıldı. Bu dönemde ayrıca, özellikle LeCun vd. (1989) ve arkadaşları çalışması olmak üzere, görüntü tanıma alanında modern uygulamalara giden yolu açan Evrişimli Sinir Ağları (ESA) ortaya çıktı.

Bu gelişmelere rağmen, alandaki ilerleme hesaplama kısıtlamaları ve büyük veri kümelerinin eksikliği nedeniyle sınırlıydı. Derin öğrenme, donanımdaki (örneğin GPU'lar) atılımlar, ImageNet gibi büyük ölçekli veri kümelerinin kullanılabilirliği ve model mimarileri ve optimizasyon tekniklerindeki yenilikler tarafından yönlendirilen 2000'lere kadar gelişmedi. AlexNet'in 2012'de ImageNet yarışmasında performansı önemli ölçüde iyileştiren çığır açıcı başarısı, modern derin öğrenme devriminin başlangıcını işaret etti (Krizhevsky vd., 2012).

Günümüzde derin öğrenme, doğal dil işlemeyi devrimleştiren dönüştürücü modeller ve biyomedikal görüntüleme görevlerini dönüştüren U-Net gibi mimarilerle gelişmeye devam ediyor. Tarihi, teorik içgörülerin, algoritmik atılımların ve teknolojik ilerlemelerin etkileşiminin bir kanıtıdır.

1.3.2. Derin Öğrenme


Makine öğreniminin (MÖ) bir alt kümesi olan DÖ, YZ’de önemli bir sıçramayı temsil eder. İnsan beyninin, özellikle de sinir ağlarının yapısı ve işleyişinden esinlenmiştir ve tahmin edici veya üretken görevler için ham verilerden özellikleri otomatik olarak çıkarmak üzere tasarlanmıştır (LeCun vd., 2015). Şekil 1.2’de YZ, makine öğrenmesi ve derin öğrenme kavramlarının birbiri olan ilişkileri gösterilmiştir.



Şekil 1.2 YZ, MÖ ve DÖ ilişkisi (Shinde & Shah, 2018)


DÖ modelleri, özellikle de derin sinir ağları, hiyerarşik özellik gösterimlerini öğrenmelerini sağlayan birbirine bağlı düğümlerin (nöronların) birden fazla katmanından oluşur. DÖ temelleri, 1950'lerde ve 1960'larda YSA'ların geliştirilmesine kadar uzanır. Ancak, alan son on yılda üç faktör tarafından yönlendirilen önemli bir ivme kazandı: büyük ölçekli veri kümelerinin kullanılabilirliği, hesaplama gücündeki gelişmeler (özellikle GPU'lar) ve geri yayılım ve optimizasyon teknikleri gibi gelişmiş öğrenme algoritmaları (Goodfellow, 2016).

DÖ ayırt edici özelliklerinden biri, görüntü, ses, metin ve yapılandırılmış veriler dahil olmak üzere çeşitli veri türlerini işleme yeteneğidir. ESA, nesne tanıma ve görüntü sınıflandırması gibi görevlerde mükemmellik göstererek görüntü verileri için tasarlanmıştır (Krizhevsky vd., 2012). Tekrarlayan Sinir Ağları (TSA) ve Uzun Kısa Süreli Bellek (LSTM) ağları gibi varyantları, doğal dil işlemede çığır açan gelişmelere olanak tanıyarak sıralı veriler için oldukça uygundur (Hochreiter & Schmidhuber, 1997).



Şekil 1.3 ESA şematik gösterimi (Eker & Duru, 2021)

Derin öğrenmede önemli bir mimari, özellikle görüntü segmentasyonu görevleri için tasarlanmış olan U-Net'tir. Ronneberger vd. (2015) ve diğerleri tarafından tanıtılan U-Net, simetrik bir kodlayıcı-kod çözücü yapısı kullanır. U-Net mimarisi Şekil 1.4'te gösterilmiştir. Kodlayıcı, özellik derinliğini artırırken girişin mekânsal boyutlarını kademeli olarak azaltır ve yüksek seviyeli özellikleri yakalar. Kod çözücü ise, tersine, hassas yerelleştirmeyi mümkün kılan transpoze edilmiş kıvrımlar kullanarak mekânsal çözünürlüğü kademeli olarak yeniden oluşturur. U-Net'in kodlayıcı ve kod çözücüdeki karşılık gelen katmanlar arasındaki atlama bağlantıları, düşük seviyeli mekânsal özelliklerin yüksek seviyeli anlamsal bilgilerle birleştirilmesini kolaylaştırır ve bu da onu tıbbi görüntü segmentasyonu, uydu görüntü analizi ve piksel bazında tahminler gerektiren diğer alanlar için oldukça etkili hale getirir.



Şekil 1.4 U-net mimarisinin şematik gösterimi (Eker & Duru, 2021)

Derin öğrenmenin dönüştürücü etkilerinden biri, özellikle yüksek boyutlu ve yapılandırılmamış verilerle uğraşırken performansta geleneksel makine öğrenme tekniklerini geride bırakma yeteneğidir. Örneğin, ImageNet yarışması, AlexNet'in

sınıflandırma hata oranını önceki yöntemlere kıyasla neredeyse %10 oranında azaltmasıyla derin öğrenme yaklaşımlarının ne kadar etkili sonuçları olabileceğini gösterdi (Russakovsky vd., 2015).


Dikkat çekici yeteneklerine rağmen, DÖ'nün bazı dezavantajlara da vardır. Yüksek hesaplama maliyetleri, veri bağımlılığı, yorumlana bilirliğin eksikliği ve düşmanca saldırılara karşı savunmasızlık gibi konular aktif araştırma alanları olmaya devam ediyor. Dahası, özellikle karar açısından kritik uygulamalarda derin öğrenme modellerinin kullanılmasının etik etkileri dikkatli bir değerlendirmeyi gerektiriyor (Zhang vd., 2018).

Alan geliştikçe, derin öğrenme sağlık, otonom sistemler, finans ve eğlence gibi çeşitli alanlarda uygulamalar bulmaya devam ediyor ve endüstrileri devrim niteliğinde değiştirme ve karmaşık sorunları çözme potansiyelini gösteriyor.

1.3.3. Derin Öğrenme mimarileri


DÖ insan beyninin, özellikle de sinir ağlarının yapısı ve işleyişinden esinlenmiştir ve tahmin edici veya üretken görevler için ham verilerden özellikleri otomatik olarak çıkarmak üzere tasarlanmıştır (LeCun vd., 2015). DÖ modelleri, özellikle de derin sinir ağları, hiyerarşik özellik gösterimlerini öğrenmelerini sağlayan birbirine bağlı düğümlerin (nöronların) birden fazla katmanından oluşur. DÖ başarısı, belirli görevler için tasarlanmış çeşitli mimarilerin geliştirilmesine atfedilir. Aşağıda en etkili mimarilerden bazılarının genel bir görünümü verilmiştir.

MLP'ler, bir katmandaki her nöronun bir sonrakindeki her nörona bağlandığı tamamen bağlı katmanlardan oluşan en basit derin öğrenme modeli biçimidir. Yapılandırılmış veriler için etkilidirler ancak yoğun bağlantıları ve uzmanlaşmış yapı eksikliği nedeniyle uzamsal veya ardışık verileri içeren görevlerde zorlanırlar (Bulut, 2016).



Şekil 1.5 Bir algılayıcının işleyişinin şematik görünümü (Bulut, 2016).

ESA'lar görüntü verileri için tasarlanmıştır ve nesne algılama, görüntü sınıflandırma ve segmentasyon gibi görevlerde mükemmeldir.



Şekil 1.6 Örnek bir ESA modeli görünümü (Amidi & Amidi t.y.).

Girişin yerel bölgelerine filtreler uygulayarak uzamsal hiyerarşileri yakalamak için evrişimli katmanları kullanılır. Önemli ESA mimarileri şunlardır:

- AlexNet: ImageNet yarışmasında dikkate değer bir başarı elde eden ilk derin ESA (Krizhevsky vd., 2012).
- VGGNet: Basitliği ve daha küçük evrişimli filtrelerin kullanımıyla bilinir (Simonyan ve Zisserman, 2014).
- ResNet: Kaybolan gradyan sorununu ele almak için kalıntı bağlantıları tanıttı ve çok derin ağların eğitilmesini sağladı (He vd., 2016).

TSA'lar, zaman serisi veya metin gibi sıralı veriler için tasarlanmıştır. Zamansal bağımlılıkları yakalamak için gizli bir durumu korurlar. Üretken Çelişkili Ağlar

(GAN'lar): GAN'lar, sıfır toplamalı bir oyunda rekabet eden bir üret  ve bir ayırıcı olmak  zere iki ađdan oluşur. GAN'lar görünt  sentezi, stil transferi ve veri artırma için yaygın olarak kullanılır (Goodfellow, 2016).

U-Net, görünt  segmentasyonu için özel bir mimaridir. Atlamalı bağlantılara sahip kodlayıcı-kod       yapıları piksel bazında tahminler sağlar ve bu da onu tıbbi görünt lemede  zellikle etkili hale getirir (Ronneberger vd., 2015). Grafik Sinir Ađları (GNN), sosyal ađlar veya molek ler yapılar gibi grafik yapıları verileri i lemek için tasarlanmıştır ve  neri sistemleri ve ila  ke finde uygulamaları vardır. Derin Q-Ađları (DQN) ve politika eđimi y ntemleri, derin   renmeyi g  lendirme   renmesiyle b  nle tirerek, ajanların oyunlar ve robotik gibi karma ık ortamlarda optimum stratejileri   renmesini sağlar (Mnih vd., 2015).



2. KAYNAK ARAŞTIRMASI

Alüminyum alaşımların mekanik özelliklerini belirlemek için yaygın olarak kullanılan çekme dayanımı testleri, belirli bir ısı işlem sürecinden geçmiş alaşımların davranışlarını anlamamıza yardımcı olmaktadır. Ancak, geleneksel test yöntemlerinin yanı sıra, malzeme özelliklerini belirlemede alternatif ve yenilikçi yaklaşımların geliştirilmesi önemlidir. Günümüzde malzeme bilimi ve mühendislik alanlarında, malzeme karakterizasyonu ve performans tahminine yönelik farklı çalışmalar yapılmaktadır. Bu bağlamda, malzeme özelliklerinin belirlenmesi için geliştirilen yeni ve etkili yöntemler, endüstriyel uygulamalarda inovasyonun anahtarı olabilir. Bu yenilikçi yaklaşımlardan en önemlilerinin arasında makine öğrenmesi ve derin öğrenme modelleri gelmektedir. Literatürde alüminyum alaşımlarının mekanik özelliklerini tahmin edebilmek için geliştirilmiş farklı makine öğrenmesi ve derin öğrenme modelleri bulunabilir. Bu çalışmaların başlıcaları aşağıda belirtilmiştir.

Yu vd. (2021), kompozisyon ve işleme parametreleriyle ilgili küçük veri setleri kullanılarak alüminyum alaşımlarının mekanik özelliklerini tahmin etmek için hassas derin sinir ağları modeli geliştirildi. Bu çalışmada, mevcut derin sinir ağları modelinin çok katmanlı ve sıkı sinir ağı ile destek vektör makinası yöntemlerine kıyasla daha yüksek tahmin doğruluğuna ve daha iyi genelleme performansına sahip olduğunu göstermişlerdir. Bu yöntemin, diğer malzeme türleri için uygulamalara genişletilebilir ve veri odaklı malzeme tasarımında potansiyel uygulamalar için umut vadecici olduğunu belirtmişlerdir.

Latypov vd. (2022), nano gözenekli alüminyumun deformasyon davranışını taklit etmek için moleküler dinamik simülasyonlardan elde edilen verileri kullanarak YSA ve mikro mekanik modeli olmak üzere iki makine öğrenimi tabanlı yaklaşımı karşılaştırmıştır. Çalışmada, farklı boyutlardaki nano gözeneklerin sayısını içeren çeşitli senaryolar ele alınmıştır. Başlangıç gözenekliliği %1'in altından %30-50 aralığına kadar değişen veriler üzerinde analizler yapıldığı belirtilmiştir. Ayrıca, nano gözenekli metalin plastik sıkıştırmasını modellemek için fiziksel temellere dayanan yeni bir mikro mekanik model geliştirdiler, bu modelde gözenek şekilleri ve sıkıştırma işleminin anizotropisi dikkate alınmıştır. Her iki makine öğrenimi yaklaşımının da moleküler dinamik verilerine uygun bir şekilde çalıştığı gözlemlenmiştir. Bu çalışma, geliştirilen makine öğrenimi tabanlı yöntemlerin nano gözenekli alüminyumun dinamik sıkıştırma ve şok dalgası

işlemlerinin makroskobik simülasyonlarında kullanılabilirliğini göstermektedir. Bu alanda benzer çalışmalar (Indeck vd., 2021) literatürde bulunabilmektedir.

Diğer bir çalışmada Pandya vd. (2020) 7xxx serisi alaşımlardan yapılan karmaşık yapısal bileşenler, oda sıcaklığında düşük sünekliklerinden dolayı genellikle sıcak damgalama yoluyla üretmiş ve özel yapım indüksiyonlu ısıtma sistemi yardımıyla W-temperli alüminyum alaşımı 7075 üzerinde deneyler yapmışlardır. Çalışmada izotropik sinir ağı tabanlı bir kırılma modeli geliştirilmiş, dikkate alınan stres durumları, gerinim oranları ve sıcaklık aralığı boyunca kırılmanın başlangıcını tanımlamak için önerilmiş, eğitilmiş ve doğrulanmıştır.

Abd Elaziz vd. (2020) çalışmalarında sürtünme karıştırma kaynaklı AA5083 ve AA2024 alüminyum alaşımlı bağlantıların çekme uzaması ve nihai çekme mukavemeti açısından çekme davranışını tahmin etmek için yeni bir yöntem kullanmışlardır. Tahmin doğruluğunu artırmak için Marine Predators Algoritması (MPA) adı verilen yeni bir meta-sezgisel algoritma, Rastgele Vektör İşlevsel Bağlantı (RVFL) ağıyla entegre edilerek kullanılmıştır. MPA-RVFL modeli test edilmiş ve doğrulanmış ve deney sonuçları ile tahmin edilen sonuçlar arasında büyük bir uyum olduğu gösterilmiştir; bu da geliştirilen tekniğin kaynaklı alüminyum bağlantıların çekme davranışını tahmin etmede doğru ve güvenilir olduğunu göstermiştir.

Wu vd. (2021) 2J, 3J ve 4J lazer enerjisiyle (Laser Shock Processing; LSP) süper alaşım FGH4095 numunelerini işleyerek makine öğrenmesi modeli için veri seti oluşturdular. Süper alaşım FGH4095'in mekanik özelliklerini (artık gerilmeler, mikro sertlik ve çekme dayanımı) tahmin etmek için sinir ağıları, doğrusal regresyon ve multitask elastic network dahil olmak üzere makine öğrenme yöntemleri kullandılar. Lazer enerjisi, derinlik ve yüzey mikro sertliği giriş parametreleri olarak uyarlanırken, artık gerilim, mikro sertlik ve çekme dayanımı çıkış parametreleri olarak ayarlandı. İşlenmemiş numunenin deneysel verileri ve 2J ve 4J lazer enerjisiyle LSP tarafından kullanılan veriler eğitim seti olarak kullanılırken, 3J lazer enerjisiyle LSP'den elde edilen deneysel veriler geliştirilen modelleri doğrulamak için test seti olarak ayrıldı. Sonuçlar, makine öğrenmesi yöntemleriyle elde edilen tahmin edilen mekanik özelliklerin deneysel mekanik özelliklerle iyi bir uyum içinde olduğunu gösterdi. Literatürde bu alanda benzer çalışmalar (Hart vd., 2021; Jain vd., 2022; Stoll & Benner, 2021) farklı yöntemlerle yapılmış ve doğrulukları gösterilmiştir.

Decke vd. (2022) çalışmalarında çeşitli termal ve mekanik koşullar altında alüminyum AA 7075'in sıcak deformasyon davranışını modellemeye amaçlamıştır.

Çalışmada Zerilli-Armstrong denklemi gibi geleneksel fenomenolojik modelleri, Destek Vektör Regresyonu, Rastgele Orman ve Aşırı Gradyan Artırma dahil olmak üzere çeşitli makine öğrenme teknikleriyle karşılaştırmalı olarak analiz edilmiştir. Test edilen modeller arasında, Aşırı Gradyan Artırma en yüksek tahmin doğruluğunu ve hesaplama verimliliğini göstermiştir. Geliştirilen modellerin görünmeyen parametre kombinasyonları için bile karmaşık gerilim-gerinim ilişkilerini yakalayabildiğinden, akış davranışını karakterize etmede deneysel iş yükünü azaltmak için güçlü bir teknik oluğu kanıtlanmıştır.

Barboza (2020) yürüttüğü çalışmasında derin öğrenme modellerini kullanarak korozyonla ilgili mikro yapı özellikleri belirlemek için tahribatsız bir analiz tekniği geliştirmiştir. Çalışmada X-ışını tomografi görüntülerindeki mikroskobik özellikleri segmentlemek için DeepLabv3+ ve U-Net gibi evrişimli sinir ağı mimarileri uygulanmıştır. Tahmin modellerinin aşındırıcı parçacıkları ve kapanımları etkili bir şekilde ayırt ederek yüksek segmentasyon performansı elde ettiği görülmüştür. Sunulan yöntem AA 7075'teki bozulma süreçlerinin daha ayrıntılı bir şekilde anlaşılmasını sağlayarak malzeme karakterizasyonu ve kalite kontrolü için maliyetsiz ve etkili bir yol sunuyor.

Freed (2024) yaptığı çalışmada havacılık endüstrisinde yaygın olarak kullanılan 7075-T6 alüminyum alaşımındaki yorulma çatlak büyümesini tahmin etmeye dayalı model geliştirmiştir. Çalışmada stres yoğunluğu, R oranı ve numune kalınlığı gibi faktörlerin etkisini modellemek için Rastgele Ormanlar, Gauss İşlem Regresyonu ve Çekirdek Regresyonu gibi makine öğrenimi algoritmaları kullanılmıştır. Sonuçlar bu modellerin değişken genlikli yükleme altında çatlak yayılımını etkili bir şekilde tahmin edebileceğini ve geleneksel ampirik modellerden daha iyi performans gösterdiğini kanıtlamıştır. Çalışma veri odaklı modellerin hesaplama açısından yoğun simülasyonlar için etkili vekiller olarak potansiyelini vurgulamaktadır.

Li vd. (2022) yürütmüş olduğu çalışmalarında 7xxx serisi alüminyum alaşımlarının mekanik özelliklerini optimize etmek için deneysel verileri makine öğrenme teknikleriyle birleştiren bir hibrit metodoloji kullanmıştır. Alaşım bileşimi işleme parametreleri ve mekanik performans arasındaki ilişkileri modellemek için geri yayımlı sinir ağları, genetik olarak optimize edilmiş BP modeli (BP-GA) ve radyal temel fonksiyon ağları kullanılmıştır. Çalışmada BP-GA modeli en yüksek tahmin yeteneğini göstermiştir. Çalışma ML destekli alaşım tasarımının yüksek hassasiyetle hedef mekanik sonuçlara ulaşmada uygulanabilirliğini doğrulamaktadır.

Cao vd. (2020) mukavemet ve korozyon direncinin ikili optimizasyonunu araştırmışlardır. Çalışmada genelleştirilmiş regresyon sinir ağları, destek vektör makinası regresörü ve çoklu doğrusal regresyon kullanarak çeşitli yaşlandırma işlemlerinin etkileri modellenmiştir. Genelleştirilmiş regresyon sinir ağları ve destek vektör makinası hem eğitim hem de test aşamalarında çoklu doğrusal regresyondan daha iyi performans göstererek deneysel değerlerle güçlü bir uyum göstermiştir. Modeller, tek aşamalı yaşlandırmanın daha iyi mekanik mukavemet sağladığını, çift aşamalı yaşlandırmanın ise korozyon direncini iyileştirdiğini ortaya koymuştur. Araştırmada rekabetin yüksek olduğu malzeme endüstrisinde performans hedeflerini dengelemede makine öğreniminin yararları açık bir şekilde vurgulanmıştır.

Son olarak, Li vd. (2020) Al-Zn-Mg-Cu sistemi içinde alüminyum alaşımlarını tasarlamak için değiştirilmiş bir Kriging tabanlı verimli küresel optimizasyon algoritmasının kullanımını göstermişlerdir. Yinelemeli modelleme ve sentez yöntemi ile 952 MPa'lık nihai çekme mukavemeti ve %6,3 uzama elde eden bir bileşim belirlemişlerdir. Çalışma ayrıca makine öğrenimi odaklı kompozisyon tasarımını yeni yapısal fazlara bağlayan nanoölçekli bir Al₈Cu₄Y ağının mikroyapısal oluşumunu da bildirmiştir. Bu çalışma makine öğreniminin ticari olarak uygulanabilir yüksek performanslı malzemelerin keşfini hızlandırabileceğini göstermiştir.

3. MATERYAL VE YÖNTEM

3.1. Malzeme

Malzeme temin aşamasında makine ve derin öğrenme modellerinin eğitimi için mikro yapı hatalarının minimize edilmesi için temin edilecek numunelerin üretiminin çok hassas olması gerekmektedir. Döküm sırasında oluşabilecek gözenekli yapı ve malzeme yapısındaki bozukluklar test aşamasında tutarlı verilerin elde edilmesini engelleyecek ve derin öğrenme modelinde problemler çıkaracaktır. Bu nedenle çalışma kapsamında AA 7075 çubuklarının temini son derece hassas üretim yapan firmalardan sağlanmıştır. Ekstrüzyon yöntemi ile üretilmiş AA 7075 alüminyum alaşım numuneler tercih edilmiş ve Uygun Bakır Pirinç Metal Psl. Sanayi TİC. LTD. ŞTİ. şirketinden temin edilmiştir. İşlenmiş numunelerin örnek gösterimi Şekil 3.1’de ve temin edilen alüminyum numunelerin bileşimi Çizelge 3.1’de verilmiştir.




Şekil 3.1 Testler için hazırlanan numunelerden örnek bir gösterim

Çizelge 3.1 Temin edilen AA 7075 numunelerdeki elementlerin yüzde ağırlık oranları

Element	Si	Fe	Cu	Mn	Mg	Zn	Ni	Cr
Oran (%)	0,281	0,2912	1,3	0,155	2,3606	5,308	0,0201	0,1832
Element	Pb	Sn	Ti	Na	Sr	V	Zr	Al
Oran (%)	0,019 3	(c<)0,0051	0.0158	0.0001	(c<)0,003	0,0063	0,0020	Kalan

3.2. Isıl İşlem Prosedürü

Temin edilen alüminyum alaşımları T6 ısıtıl işlemine tabi tutulmuştur. Bunun için öncelikle temin edilen alüminyum alaşımları oda sıcaklığından çözelti sıcaklığı olan 470°C'ye çıkarılmış ve 3 saat bu sıcaklıkta bekletilmiştir. Daha sonra numuneler oda sıcaklığında hızlı soğumaya bırakılmıştır. Bu işlemi takiben alüminyum numunelere Çizelge 3.2'de listelenen sıcaklıklarda ve sürelerde yapay yaşlandırma işlemi uygulanmıştır. Bu sıcaklıklar ve süreler literatürde yapılan önceki çalışmalar baz alınarak belirlenmiştir (Isadare vd., 2013; Liu vd., 2020; Liu vd., 2018). T6 ısıtıl işlem prosedürü Şekil 3.2'de şematik olarak gösterilmiştir.



Şekil 3.2 T6 ısıtıl işlem prosesi şematik gösterimi

Yaşlandırma sıcaklıkları olabildiğince hassas aralıklarda tutularak makine ve derin öğrenme modellerinin eğitimi için veri üretimini maksimize ederek modellerin daha

tutarlı ve doğru tahminler yapması sağlanmıştır. Bu doğrultuda yaşlandırma sıcaklığı 100°C'den başlayarak 15°C'lik artışlarla 225°C'lere kadar çıkarılmıştır. Ayrıca yaşlandırma sıcaklık parametresine ek olarak farklı yaşlandırma süreleri de değişken olarak belirlenmiştir. Bu kapsamda her bir yaşlandırma sıcaklığına numuneler 1,2, 3, 6 ve 9 saat sürelerinde yaşlandırma sürelerine maruz bırakılmıştır.

Çizelge 3.2 Isıl işlem prosedürü için kullanılacak parametreler

Deney Numunesi	Çözelti Sıcaklığı (°C)	Su verme Sıcaklığı (°C)	Yaşlandırma Sıcaklığı (°C)	Yaşlandırma Süresi (saat)	Numune Sayısı
1	470-3 saat	20	100	1	3
2	470-3 saat	20	100	2	3
3	470-3 saat	20	100	3	3
4	470-3 saat	20	100	6	3
5	470-3 saat	20	100	9	3
6	470-3 saat	20	115	1	3
7	470-3 saat	20	115	2	3
8	470-3 saat	20	115	3	3
9	470-3 saat	20	115	6	3
10	470-3 saat	20	115	9	3
11	470-3 saat	20	130	1	3
12	470-3 saat	20	130	2	3
13	470-3 saat	20	130	3	3
14	470-3 saat	20	130	6	3
15	470-3 saat	20	130	9	3
16	470-3 saat	20	145	1	3
17	470-3 saat	20	145	2	3
18	470-3 saat	20	145	3	3
19	470-3 saat	20	145	6	3
20	470-3 saat	20	145	9	3
21	470-3 saat	20	160	1	3
22	470-3 saat	20	160	2	3
23	470-3 saat	20	160	3	3
24	470-3 saat	20	160	6	3
25	470-3 saat	20	160	9	3
26	470-3 saat	20	175	1	3
27	470-3 saat	20	175	2	3
28	470-3 saat	20	175	3	3
29	470-3 saat	20	175	6	3
30	470-3 saat	20	175	9	3

Çizelge 3.2 Isıl işlem prosedürü için kullanılacak parametreler çizelgenin devamı

31	470-3 saat	20	190	1	3
32	470-3 saat	20	190	2	3
33	470-3 saat	20	190	3	3
34	470-3 saat	20	190	6	3
35	470-3 saat	20	190	9	3
36	470-3 saat	20	205	1	3
37	470-3 saat	20	205	2	3
38	470-3 saat	20	205	3	3
39	470-3 saat	20	205	6	3
40	470-3 saat	20	205	9	3
41	470-3 saat	20	225	1	3
42	470-3 saat	20	225	2	3
43	470-3 saat	20	225	3	3
44	470-3 saat	20	225	6	3
45	470-3 saat	20	225	9	3

3.3. Veri Toplama, Makine ve Derin Öğrenme Modelleri

Bu çalışmada, farklı sıcaklık ve süre kombinasyonlarını içeren çeşitli yaşlandırma işlem koşullarına tabi tutulan AA 7075 alüminyum alaşım numunelerinden titreşim tepki verileri toplanmıştır. Deneysel tutarlılığı sağlamak amacı ile tüm numuneler için titreşim tepki verilerini alacağımız sistem mekanik olarak tamamen standartlaştırılmış ve tekrarlanabilir bir şekilde oluşturulmuştur. Her numuneye aynı etkiyi vermek için yerçekimi ivmesi altında sabit bir yükseklikten paslanmaz çelik uçlu mekanizmanın serbest bırakıldığı 50 cm uzunluğunda bir kola sahip özel olarak tasarlanmış bir darbe mekanizması kullanıldı. Hava akımları veya akustik gürültü gibi dış çevresel faktörlerin etkisini en aza indirmek için, tüm kurulum test sırasında kapalı bir bölmeye alındı.

Bu çalışmada modelin amacına yönelik iki farklı yöntem olarak ESA kullanılmıştır. İlk olarak, National Instruments şirketine ait piezoelektrik titreşim ölçer ile elde edilen zamana bağlı titreşim görüntü verileri işlenerek ESA modeli ısıtma işlem etiketlerinin doğrudan görüntü tabanlı tahmini için uçtan uca derin öğrenme sınıflandırıcıları kullanılarak tahmin modeli oluşturulmuştur. Sonrasında ise, ESA temelli özellik çıkarma yöntemleri kullanarak geleneksel makine öğrenme algoritmalarına veri besleme yöntemi ile hibrit tahmin modelleri geliştirilmiştir. Tahmin modellerinde kullanılan verileri toplamak için kullanılan National Instruments şirketine ait

piezoelektrik ivme ölçer cihazı Şekil 3.4'te titreşim tepkilerinin elde edildiği deney düzeneği ise Şekil 3.5'te verilmiştir.



Şekil 3.3 Piezoelektrik titreşim ölçer



Şekil 3.4 Piezoelektrik titreşim sensörü ile titreşim tepkilerinin elde edildiği deney düzeneği

Modelde piezoelektrik titreşim ölçer ile belirtilen deney düzeneği kullanılarak alınan titreşim tepkilerinden elde edilen görüntü verisi $x \in R^{H \times W \times C}$ olsun. Burada H

yüksekliği, W genişliği ve C de kanal sayısını simgelemektedir. Belirli sayıda K filtresi $\{W_k\}_{k=1}^K$ içeren Evrimsel Sinir Ağları katmanı özellik haritasını aşağıdaki formül ile üretmektedir.

$$F_k(i, j) = \sigma \left(\sum_{m=1}^C \sum_{u=1}^H \sum_{v=1}^W W_k(u, v, m) \cdot x(i + u, j + v, m) + b_k \right) \quad (3.1)$$

Burada σ doğrusal olmayan bir aktivasyon fonksiyonudur. Özellik çıkarma ve düzleştirmeden sonra, ESA'deki sınıflandırma adımı, softmax aktivasyon fonksiyonunun izlediği tam bağlı (yoğun) bir katmanı içerek şekilde oluşturulmuştur. Bu, tüm olası sınıflar üzerinde bir olasılık dağılımı üretmektedir. $z \in R^d$ 'nin düzleştirilmiş özellik vektörü ve $W \in R^{C \times d}$, $b \in R^C$ 'nin çıkış katmanının ağırlık matrisi ve önyargı vektörü olduğunu varsayalım. Logitler (normalleştirilmemiş puanlar) şu şekilde hesaplanır:

$$o = Wz + b \quad (3.2)$$


Buradan sınıf j için olasılık softmax fonksiyonu ile aşağıdaki şekilde tanımlanabilir.

$$P(y = j|z) = \frac{e^{oj}}{\sum_{k=1}^C e^{ok}} \text{ for } j = 1, \dots, C \quad (3.3)$$

Tahmin edilen sınıf y için en yüksek olasılığa sahip değer aşağıdaki ifade ile seçilir.

$$y = \operatorname{argmax} P(y = j|z) \quad (3.4)$$

Softmax tabanlı bu sınıflandırma katmanı, ESA'nın çok sınıflı problemler için olasılığa dayalı bir sonuç üretmesini sağlar; bu da özellikle görüntü tabanlı ısıl işlem modeli gibi kategorik tahminler için uygundur. ESA modeli şematik gösterimi Şekil 3.6'da verilmiştir.



Şekil 3.5 ESA modelinin şematik gösterimi

Karar Ağacı (KA), Gini safsızlığı veya bilgi kazanımı gibi ölçütlere göre özellik alanını yinelemeli olarak bölen parametrik olmayan bir denetimli öğrenme algoritmasıdır. Bir düğüm t için Gini safsızlığı aşağıdaki şekilde hesaplanır.

$$G(t) = 1 - \sum_{i=1}^c p_i^2 \quad (3.5)$$

Burada p_i , düğüm t 'deki sınıf i 'ye ait örneklerin oranıdır ve C , toplam sınıf sayısıdır. Ağaç, safsızlığı en aza indiren bölünmeleri seçer ve bir durdurma kriterine ulaşılan kadar devam eder.

Rastgele Orman (RO), birden fazla karar ağacı oluşturan ve tahminlerinin modunu çıktı olarak veren bir topluluk öğrenme yöntemidir. Her ağaç T_i için, eğitim işleminde rastgele bir özellik ve veri örneği alt kümesi kullanılır. Bir ağaç kümesi $(T_1, T_2, \dots, T_m)$ verildiğinde, giriş vektörü z için öngörülen sınıf aşağıdaki şekilde oluşturulur.

$$y = \text{mode}(T_1(z), T_2(z), \dots, T_m(z)) \quad (3.6)$$

DVM, iki sınıf arasındaki marjı en üst düzeye çıkaran bir hiper düzlemi bulmayı amaçlar. Verilen bir eğitim seti $\{(z_i, y_i)\}_{i=1}^n$ ile $y_i \in (-1, 1)$ ise DVM aşağıdaki çözümü sunar.

$$\min_{w, b} \frac{1}{2} \|w\|^2, y_i(wz_i + b) \geq 1 \quad (3.7)$$

Doğrusal olmayan şekilde ayrılabilen veriler için, verileri daha yüksek boyutlu bir uzaya yansıtmak için çekirdek bir fonksiyon olan $K(z_i, z_j)$ kullanılır.

K-En Yakın Komşular (KYK), özellik alanındaki k en yakın komşuları arasında çoğunluk sınıfına göre test örneğine bir etiket atayan basit ancak etkili bir parametrik olmayan sınıflandırma algoritmasıdır. Herhangi bir detaylı eğitim aşaması içermez ve bu da onu örnek tabanlı bir öğrenme yöntemi yapar. Bir test örneği $z \in R^d$ verildiğinde, algoritma z ile tüm eğitim örnekleri $\{x_i\}_{i=1}^n$ arasındaki mesafeyi hesaplar. En yaygın kullanılan mesafe aşağıda formülü verilmiş olan metriği Öklid mesafesidir.


$$d(z, x_i) = \sqrt{\sum_{j=1}^d (z_j - x_{ij})^2} \quad (3.8)$$

Mesafeler hesaplandıktan sonra algoritma en küçük mesafelere sahip k örneği seçer. Tahmin edilen etiket daha sonra karşılık gelen etiketler arasında çoğunluk oyu ile belirlenir:

3.4. Mekanik Testler

3.4.1. Çekme testi

Çekme testi numuneleri ASTM E8/E8M standartlarına göre CNC tezgâhta işlenerek Şekil 3.3'te belirtilen boyutlara getirilmiştir.



Şekil 3.6 Mekanik testlerde kullanılacak ASTM standartlarına uygun alüminyum numune boyutları

Çekme testi için hazırlanan numuneler, nihai çekme mukavemetini ve kırılmada uzamayı değerlendirmek için bilgisayar kontrollü Shimadzu AG-IC test makinesiyle tek eksenli yüklemeye tabi tutulmuştur. Her test parametresi için oda sıcaklığında, %50 nemde ve 2 mm/dakika sabit hızda en az üç çekme testi gerçekleştirildi.

3.4.2. Sertlik

Sertlik testleri Brinell sertlik standardına uygun olarak gerçekleştirilmiş ve testler Ernst marka AT250 model üniversal sertlik ölçüm cihazı kullanılarak yapılmıştır. Ölçümler sırasında Brinell yöntemi çerçevesinde 2 mm çapında çelik bilye uç tercih edilmiş ve her bir ölçümde 187.5 kgf sabit yük uygulanmıştır. Uygulanan yük bilye ucun test yüzeyine belirli bir süre temas etmesiyle gerçekleştirilmiş, ardından bilye ucunun oluşturduğu iz çapı mikroskop altında ölçülerek Brinell sertlik değeri (HB) hesaplanmıştır.

Sertlik ölçümlerinin tekrarlanabilirliğini ve güvenilirliğini artırmak amacıyla her bir numunede yüzeyden rastgele seçilen beş ayrı nokta üzerinden ölçümler alınmıştır. Bu yaklaşım, test edilen malzemenin mikro-yapısal homojenliğini değerlendirmek ve lokal sertlik farklılıklarını gözlemlemek açısından önemlidir. Elde edilen beş ayrı sertlik değerinin ortalaması alınarak her bir numunenin karakteristik sertlik değeri belirlenmiştir. Tüm ölçümler kontrollü laboratuvar ortamında %50 nem oranında ve oda sıcaklığında gerçekleştirilmiştir.

Bu yöntemle elde edilen Brinell sertlik değerleri, malzemenin yaşlandırma koşullarına bağlı mekanik davranışlarını yorumlamak ve diğer mekanik test sonuçları ile karşılaştırmalı analiz yapmak açısından önemli bir temel teşkil etmektedir.

3.4.3. Aşınma

Aşınma testleri, ASTM G99 standart protokolü doğrultusunda bilya-disk konfigürasyonu kullanılarak gerçekleştirilmiştir. Karşı yüzey olarak, 6 mm çapında, AISI 304 paslanmaz çelikten imal edilmiş bilyalar tercih edilmiştir. Test numuneleri, ıslak aşındırıcı kesme yöntemi ile Ø12 mm × 10 mm boyutlarında olacak şekilde, HT numunelerinin merkez bölgesinden hazırlanmıştır. Kesim işlemini takiben, tüm numunelerin yüzeyleri 0,2 µm yüzey pürüzlülüğü (Ra) seviyesine kadar taşlanmış ve

ardından parlatılarak test için uygun hale getirilmiştir. Tüm aşınma deneyleri oda sıcaklığında ve %50 nemde oranında sabit çevresel koşullarda gerçekleştirilmiştir.

Uygulanan normal yük 5 kN, aşınma izi çapı 6 mm, toplam kayma mesafesi 60 m ve kayma hızı 3 cm/s'dir. Testlerin ardından, her bir numunenin aşınma oranları aşınma öncesi ağırlık ve aşınma sonraki ağırlık değerlerine bağlı olarak analiz edilmiş ve buna bağlı olarak belirlenmiştir. Özgül aşınma oranları, oluşan aşınma izlerinin hacimsel ölçümleri üzerinden hesaplanmıştır.




4. BULGULAR VE TARTIŞMA

4.1. Titreşim Tepkileri ile Yaşlandırma Koşullarının Derin Öğrenme Tabanlı Sınıflandırılması

Numunelerin dinamik tepkileri, ivmeyi algılayabilen piezoelektrik dönüştürücüler kullanılarak yakalandı ve böylece titreşim frekanslarının doğru bir şekilde alınması sağlandı. Malzemenin darbe uyarımına geçici tepkisini temsil eden bu sinyaller, her bir ısıtım işlem koşuluyla ilişkili belirgin titreşim desenleri belirlemek için frekans alanında analiz edildi. Şekil 4.1’de kaydedilen titreşim tepkilerinden bazı örnekler gösterilmiştir.






Şekil 4.1 Isıl işlem görmüş AA 7075 numunelerine ait titreşim tepkileri

Şekildeki görselleştirilmiş sonuçlar, aynı yaşlandırma işlemi uygulanmış farklı numuneler için kaydedilen titreşim tepkilerinin birinci ve ikinci kayıtlarını yan yana göstermektedir. Görüldüğü gibi aynı yaşlandırma şartları için titreşim tepkilerinin tutarlılığı açık bir şekilde görülmektedir. Örneğin, 2 saat boyunca 145°C'de işlenen numuneler, titreşim tepkileri deseninin güvenilirliğini vurgulayan eşleşen konumlarda belirgin, dar yerleştirilmiş spektral tepeler sergilemektedir. Şekillerde küçük farklılıklar gözlenebilir ancak genel form korunmuştur. Bu küçük farklar sistemden kaynaklanan gürültüler, malzemenin iç yapısındaki minimal farklılıklar ve standartlaştırılmış olsa da

deney düzeneğinin neden olabileceği minimal farklardır. Benzer eğilimler, diğer numunelerde de açık bir şekilde gözlemlenebilir. Spesifik olarak küçük farklar mevcuttur ama genel olarak bakıldığında form korunmuş ve desenler farklı yaşlandırma işlemleri için karakteristik desenler haline gelmiştir.

Bu bulgular, yaşlandırma sürecinin malzemenin mekanik rezonans davranışını etkileyen belirli mikro yapısal değişikliklere neden olduğunu ve bunun da titreşimsel yanıtını etkilediğini doğrulamaktadır. Frekans alanı izlerinin tekrarlanabilirliği, numunelerin yaşlandırma işlemini sınıflandırmak için derin öğrenme modellerini eğitmek için sağlam bir temel sağlamaktadır. Bu tür modellerin bu desenleri tespit etme ve ayırt etmedeki başarısı, ısıl işlem görmüş metallerde ısıl işlem parametre sınıflandırmasını, kalite kontrolü ve malzeme karakterizasyonu için titreşime dayalı tahribatsız değerlendirme tekniklerinin potansiyelini vurgular.

Tahmin modeli olarak titreşim tepkilerine dayalı ısıl işlem koşullarını belirleme yeteneğini değerlendirmek için ilk olarak ESA mimarisi kullanıldı. ESA modeli için eğitim ve test doğruluğu ve kayıp eğrileri Şekil 4.2'de 10 epok için verilmiştir.




Şekil 4.2 ESA için doğruluk ve kayıp oranları

Doğruluk grafiğinde gösterildiği gibi, model eğitim süreci boyunca hem eğitim hem de doğrulama istikrarlı bir artış göstermektedir. Doğruluk çok düşük bir seviyede başlasa da kademeli olarak iyileşerek 9. Epokta %80'i aşmaktadır. Aşırı öğrenmeyi önlemek için epok sayısı minimize edilerek optimum değerde tutulmuştur. Eğitim ve doğrulama doğruluk eğrileri arasındaki yakın hizalama, modelin önemli ölçüde veriye uyum sağladığını ve görülmemiş verilere iyi genelleme yaptığını göstermektedir. Sonuç olarak ESA ile %89 doğruluk oranı elde edilmiştir.

Paralel olarak, kayıp eğrileri hem eğitim hem de doğrulama kümeleri için tutarlı bir düşüş göstermektedir ve bu da modelin yakınsamasını desteklemektedir. Doğrulama kaybı, herhangi bir sapma veya istikrarsızlık belirtisi olmaksızın eğitim kaybının eğilimini yakından takip etmektedir. Bu davranış, öğrenme sürecinin istikrarlı olduğunu ve modelin her iki veri kümesinde de hedef fonksiyonunu etkili bir şekilde en aza indirdiğini göstermektedir.

ESA modelinin performans ölçütleri, titreşim tepkilerine dayalı çeşitli yaşlandırma koşulları arasında ayırım yapmada genel olarak yüksek bir sınıflandırma yeteneği olduğunu göstermektedir. Model, 0,89'luk ağırlıklı ortalama hassasiyet, geri çağırma ve 0,89'luk F1 puanı ile desteklenen 0,89'luk bir doğruluk elde etmiştir. Bu, veri kümesi boyunca tahmin edilen ve gerçek etiketler arasında güçlü bir uyumu yansıtmaktadır. Öte yandan, makro ortalama değerler (0,80), modelin tüm sınıflarda makul derecede iyi performans gösterdiğini göstermektedir, ancak daha az temsil edilen veya daha zorlayıcı sınıflar için performansta hafif bir dengesizlik gözlemlenmiştir. Modele ait tahmin değerlerinden rastgele seçilmiş örnek değerler Şekil 4.3'te karışıklık matrisinde verilmiştir.




Şekil 4.3 ESA modeli bazı tahmin değerleri için karmaşıklık matrisi

Modelde özellikle yanlış tahminlerin olduğu örnek kısmının matrisi, modelin test örneklerinin çoğunu doğru bir şekilde tahmin ettiğini açıkça göstermektedir. Çoğu gerçek etiket, komşu veya benzer sınıflar arasında önemli bir karışıklık olmadan karşılık gelen tahmin edilen etiketlere doğru bir şekilde eşleşmektedir. Bu, modelin çok çeşitli ısı işlem koşulları arasında özellikleri çıkarma ve ayırt etme konusundaki yüksek kapasitesini yansıtmaktadır. Matriste nadir yanlış sınıflandırma gözlemlenmektedir ve bunlar, koşullar arasında, muhtemelen belirli sıcaklık-zaman kombinasyonlarındaki örtüşen mikro yapısal etkiler nedeniyle bir miktar titreşim tepkilerinde benzerlik olduğunu göstermektedir. Bu izole hatanın dışında, diğer tüm tahminler, temel gerçek etiketleriyle yüksek bir şekilde uyumludur. Çok sınıflı sınıflandırmada, özellikle önemli sayıda farklı sınıfla, bu kadar yüksek hassasiyet, titreşim tabanlı frekans verileri üzerinde eğitildiğinde ESA modelinin gücünü vurgulamakta ve sonuçlar, modelin piezoelektrik olarak edinilen dinamik tepki verilerini kullanarak ısı işlem parametrelerinin doğru, tahribatsız bir şekilde tanımlandığını göstermektedir.

Çalışmanın ilerleyen aşamalarında farklı tahmin modelleri denenerek öngörü yeteneğini artırmak için modeller arasında karşılaştırmalı analiz yapılmıştır. Bu bağlamda, sık sinir ağlarına dayanan karma bir yol kullanılmış ve bu kapsamda özellik çıkarma prosesi, titreşim tepkilerindeki açık ya da gizli desenleri yakalayan ESA yöntemi ile yapılmıştır. Çıkarılan özellikler, daha sonrasında klasik sınıflandırma algoritmalarında girdi verisi olarak kullanılarak tahmin modelleri oluşturulmuştur. Yapılan ön çalışmalar sonucunda Karar Ağaçları (KA), Rastgele Orman (RO) ve Destek Vektör Makineleri (DVM) makine öğrenmesi yöntemleri için girdi olarak kullanılmıştır. Bu hibrit yöntem, yapay sinir ağları gibi nispeten karmaşık bir sistemi klasik makine öğrenme yollarının basit ve hızlı yapısı ile birleştirme ve efektif kullanım potansiyeli sunmaktadır. K-en Yakın Komşu (KYK) modeli, yapılan ön çalışmalarda gözlemlenen önemli ölçüde düşük sınıflandırma doğruluğu nedeniyle çalışmanın bu kısmında analizde değerlendirilmemiştir. Düşük performans, esas olarak ResNet'ten çıkarılan özellik vektörlerinin yüksek boyutluluğuna atfedilir. Verideki yüksek boyutun KYK gibi mesafe tabanlı algoritmaları olumsuz etkilediği bilinmektedir. Bu tür yüksek boyutlu verilerde, yakınlık kavramı daha az anlamlı hale gelir.

İlk sık hibrit modelde, evrimsel sinir ağları aracılığıyla özellik çıkarımının ardından bir KA sınıflandırıcısı kullanılmıştır. Bu model, çok sınıflı problemin karmaşıklığı ve ısıtım koşullarının titreşim tepki tabanlı gösterimleri arasındaki hassas farklar göz önüne alındığında tatmin edici bir performans seviyesi gösteren %83'lük genel bir sınıflandırma doğruluğu elde etmiştir. Şekil 4.4'te modele ait karışıklık matrisi verilmiştir.




Şekil 4.4 KA modeli için karışıklık matrisi

Karışıklık matrisinde çok fazla sınıf olması nedeni ile modelin özellikle yanlış tahmin edilen kısımlarından alınmış değerlere yer verilmiştir. KA algoritmasının ESA ile çıkarılan özelliklerle yaşlandırma işlemi etiketlerinin çoğunu doğru şekilde sınıflandırdığını göstermektedir. Matris, çok çeşitli sınıflar arasında doğru tahminleri yansıtan güçlü bir diyagonal baskınlık göstermektedir. Bu, çıkarılan özelliklerin anlamlı sınıfa özgü özellikleri koruduğunu ve KA algoritmasının yakın değerlere sahip ısı işlem görmüş numuneler arasında bile sınıflandırma yapmasını sağladığını göstermektedir.

Bazı yanlış sınıflandırma değerleri de gözlemlendi, ancak yanlış tahminler incelendiğinde sayıları sınırlıdır ve benzer ısı işlem derece veya süre sınıfları arasında belirli bir karışıklık örüntüsünü takip etmemektedir. Bu, modelin iyi çalıştığını ve hibrit yaklaşımın karmaşık titreşim örüntülerini ilgili işlem etiketlerine eşlemedeki etkinliğini doğrulamaktadır.

Hibrit modellerde bir sonraki algoritmamız, ESA aracılığıyla çıkarılan özellikleri girdi olarak kullanan RO sınıflandırıcısıdır. Bu model, KA modeline göre önemli bir

iyileştirme gösterip topluluk tabanlı bir yöntem olması nedeniyle gelişmiş genelleme yeteneği göstererek %89'luk bir sınıflandırma doğruluğu elde etmiştir. Modele ait karmaşıklık matrisi Şekil 4.5'te verilmiştir.




Şekil 4.5 RO tahmin modeline ait karmaşıklık matrisi

Modele ait karmaşıklık matrisi RO modelinin hassas yaşılandırma koşullarını büyük bir çoğunlukla doğru bir şekilde belirlendiğini göstermektedir. Doğruluk oranı, oluşan minimal hatalarla oldukça belirgin kalmaya devam etmiştir. Sonuçlara baktığımızda, RO modelinin karmaşık karar sınırlarını yakalama ve birden fazla karar ağacının toplanması yoluyla aşırı uyumu azaltma yeteneğini yapmış olduğu doğru tahminlerle doğruladığı gözlemlenmektedir.

KA modeliyle karşılaştırıldığında, RO algoritması, özellikle benzer ısı işlem özelliklere sahip numuneleri ayırt etmede, çeşitli sınıflar arasında daha fazla sağlamlık ve tutarlılık göstermektedir. Topluluk öğrenme stratejisi, tek sınıflandırıcılarla ilişkili varyansı etkili bir şekilde azaltarak daha kararlı ve doğru tahminlerle sonuçlanmıştır. Bu

modellerin yanında DVM modeline de tahmin modelleri arasında kullanılmış ve %72 doğruluk alınarak Sekil 4.6'daki karmaşıklık matrisi elde edilmiştir.



Şekil 4.6 DVM modeline ait karmaşıklık matrisi


Karışıklık matrisi DVM sınıflandırıcısının farklı ısıtım koşullarını doğru tahmin edebilmesine rağmen, diğer modellerle karşılaştırıldığında yanlış sınıflandırmalarda belirgin bir artış olduğunu ortaya koymaktadır. DVM algoritmasında dikkat edilecek en önemli noktalardan biri benzer titreşim tepkilerine sahip numuneler arasında algoritmanın uygunluk gösteremediği ve hassas özellikleri tam olarak yakalayamadığı noktasıdır. Bu performans, yeterince ayırt edici özellik gösterimleri tarafından desteklenmediğinde, DVM'lerin hassas yaşlandırma sınıflarına sahip çok sınıflı veri kümelerini işlemedeki sınırlamalarından kaynaklanmaktadır. DVM'ler ikili ve doğrusal olarak ayrılabilir problemlerdeki güçleriyle bilinirken, performansları çok sınıflı uygulamalarda sınıf dengesizliğine duyarlı olabilmektedir. Yine de model hala anlamlı sınıflandırma yeteneği göstermekte ve veri kümesinin önemli bir bölümünü doğru bir

şekilde tanımlamaktadır. Bu bulgular, model seçiminin önemini vurgulamakta ve ağaç tabanlı yöntemlerin veya daha derin mimarilerin, özellikle karmaşık ısıtım işlem sistemlerinden yüksek boyutlu titreşim tabanlı tepki verileriyle çalışırken daha uygun olabileceğini öne sürmektedir.

4.2. Çekme Dayanımı

Bu kısımda, farklı sıcaklıklarda yapay yaşlandırma süreleri altında T6 ısıtım işlemine tabi tutulan AA 7075 alaşımının mekanik davranışı araştırılmıştır. Maksimum kuvvet-uzama eğrileri Şekil 4.7’de tüm yaşlandırma sıcaklığı ve süreleri için verilmiştir.






Şekil 4.7 Yaşlandırma sıcaklıkları ve sürelerine göre maksimum kuvvet uzama eğrileri

Şekil 4.7’deki sonuçlara göre yaşlandırma sıcaklığının hem maksimum çekme kuvveti hem de numunelerin uzaması üzerinde önemli bir etkisi olduğu gözlemlenmiştir. 100°C ve 115°C gibi daha düşük yaşlandırma sıcaklıklarında, çekme mukavemeti yaşlandırma süresiyle birlikte artar ve yaklaşık 6-9 saatte en yüksek noktasına ulaşır. Özellikle 100°C-6 saatlik numune, etkili çökeltme sertleştirmesini işaret eden, tümü arasında en yüksek mukavemetlerden birini göstermektedir. Ancak, mukavemet


artmasına rağmen, uzama hafifçe azalma eğilimindedir ve bu da klasik bir mukavemet-süneklik denge durumunu gösterir. Sıcaklık orta seviyelere (130°C-160°C) yükseldikçe, mukavemetin başlangıçta zamanla arttığı, ancak zirveye daha kısa sürelerde (yaklaşık 3-6 saat) ulaşıldığı ve ardından aşırı yaşlandırmanın az da olsa başladığı noktalarda mukavemeti azaltmaya başladığı benzer bir eğilim gözlemlenir. Bu, özellikle mukavemetin orta süreli numunelerden daha düşük olduğu 160°C-9 saatte, en yüksek kuvvette düzleşme veya hatta azalmada belirgindir. Bu eğriler, mukavemet ve uzama arasında daha dengeli bir davranış gösterir ve bunların orta düzeyde süneklik gerektiren bazı uygulamalar için en uygun koşullar olabileceğini düşündürür. Yüksek yaşlandırma sıcaklıklarında (175°C–225°C), aşırı yaşlandırma etkileri daha belirgin hale gelmektedir. 205°C ve özellikle 225°C eğrileri, daha uzun yaşlandırma süreleri için mukavemette bir azalma olduğunu göstermiştir. 225°C-9 saatlik numune, hala nispeten güçlü olsa da 0,5 saat veya 1,5 saat gibi daha kısa sürelerle kıyasla maksimum kuvvette belirgin bir düşüş gösterir. Buna karşılık, uzama, mukavemet azaldıkça hafifçe artma eğilimindedir; bu, çökeltilerin kabalaşmasının meydana geldiği ve güçlendirme etkilerinin azaldığı aşırı yaşlandırılmış yapılarda tipiktir (Lin vd., 2013).

Kısa Yaşlandırma Süreleri (1-2 saat) dinamik ortamlardaki yapısal bileşenler gibi daha yüksek süneklik ve şekillendirilebilirlik gerektiren uygulamalar için uygundur. Orta düzey yaşlandırma (3 saat) maksimum yük taşıma kapasitesinin önemli olduğu havacılık veya otomotiv parçaları gibi yüksek mukavemetli uygulamalar için idealdir. Uzun yaşlandırma Süreleri (6–9 saat) nispeten düşük mukavemet gösterirken, bu koşullar zamanla daha fazla boyutsal kararlılığa ihtiyaç duyan bileşenler için avantajlı olabilir

Yaşlandırma sıcaklığının AA7075 alaşımının mekanik performansı üzerindeki etkisi, 1, 2, 3, 6 ve 9 saatlik yaşlandırma süreleri için yaşlandırma sıcaklığını (100°C ila 225°C) değiştirerek sistematik olarak incelenmiştir. Kopma gerilmesi ve akma gerilme sonuçları, yaşlandırma sürecinin sıcaklık ve süre etkileriyle ilgili önemli eğilimleri ortaya koymuştur. Bu değişimler Şekil 4.8 ve Şekil 4.9'da gösterilmiştir.



Şekil 4.8 Farklı sıcaklıklarda 1 ve 2 saat süreli yaşlandırma işlemi görmüş numunelerin kopma ve akma dayanımları



Şekil 4.9 Farklı sıcaklıklarda 3,6 ve 9 saat süreli yaşlandırma işlemi görmüş numunelerin kopma ve akma dayanımları

100°C'de, alaşım artan yaşlandırma süresiyle maksimum gerilimde istikrarlı bir iyileşme sergilemiş ve 6 saatte (590,9 MPa) zirveye ulaşmıştır. Bu eğilim, daha düşük

sıcaklıkların daha yavaş çökme kinetiğini teşvik ettiğini, ince, tutarlı çökeltilerin oluşmasına izin verdiğini ve bunun da malzemeyi etkili bir şekilde güçlendirdiğini göstermektedir (Li vd., 2008). 115°C ve 130°C'deki gerilim değerleri benzer eğilimleri izlemiş ve en yüksek değerleri genellikle 2-6 saat civarında ortaya çıkmıştır. 3 saatlik yaşlandırma süresi, sırasıyla 115°C ve 130°C'de 548,9 MPa ve 548,1 MPa'lık karşılaştırılabilir maksimum gerilimler göstermiştir. Bu koşullar, çökeltilerin oluşumu ve dağılımının dengelenmesi için en uygun koşullar gibi görünmektedir. 145°C ile 175°C arasındaki sıcaklıklarda, maksimum gerilimi, 175°C'de (3 saat) 549,1 MPa gibi değerlerle, daha düşük sıcaklık aralığına kıyasla biraz azalma eğilimi göstermiştir. Bu sıcaklıklarda, çökelti sertleştirme süreci hızlanmış, ancak aşırı yaşlandırma etkileri, uzatılmış sürelerde (örneğin, 9 saat) daha belirgin hale gelmiştir. Daha kısa süreler (1–3 saat), ince, tutarlı çökeltilerin baskınlığı nedeniyle genellikle daha yüksek maksimum gerilim üretmiştir (Li vd., 2008). Ancak, stres uzun sürelerde (örneğin 9 saat) belirgin şekilde düşmüş ve bu da çökelti kabalaşmasına ve tutarlılık kaybına işaret etmektedir. 190°C gibi daha yüksek sıcaklıklarda, alaşım daha kısa yaşlandırma sürelerinde (örneğin 3 saatte 552,5 MPa) nihai çekme dayanımı değerleri göstermiştir. Yüksek sıcaklıklardaki hızlı çökme kinetiği daha erken sertleşmeyi desteklemekte; ancak, daha uzun sürelerde (örneğin 205°C için 9 saatte 460,4 MPa) azalan stres değerleriyle kanıtlandığı gibi, aşırı yaşlandırma gözlemlenmektedir. Çalışılan en yüksek sıcaklık olan 225°C'de maksimum stres değerleri özellikle uzun sürelerde, daha düşük sıcaklıklarda gözlemlenenlerden önemli ölçüde daha düşük belirlenmiştir. Örneğin, stres 555,6 MPa'dan (1 saat) 433,4 MPa'ya (9 saat) düşmüş ve bu da yüksek sıcaklıklarda aşırı kabalaşmanın ve çökeltilerin çözünmesinin mekanik özellikleri azaltıcı etkilerini işaret etmektedir (Zhang vd., 2024).

Verilerden, maksimum gerilim açısından en uygun mekanik özellikler 4 saat boyunca 100°C (590,9 MPa), düşük sıcaklıkta, uzun süreli yaşlandırma maksimum kuvvetin en iyi olduğu parametreler olarak gözlemlenmiş, 3 saat süreli 175°C (549,1 MPa) ısıtma işlemi, mukavemet ve yaşlandırma süresi arasında bir dengeyi sağladığı belirlenmiştir. 1 saat boyunca 205°C (563,7 MPa), minimum yaşlandırma süresiyle hızlı sertleşme potansiyelini ortaya koymaktadır. Daha düşük sıcaklıklarda (100°C–130°C) çökelti yapısını optimize eden yavaş kinetik sayesinde uzun yaşlandırma sürelerinde daha iyi sonuçlar elde edilmiştir. Orta sıcaklıklarda (145°C–175°C) orta sürelerde dengeli performans; ancak, aşırı yaşlandırma nedeniyle stres değerleri 3 saat sonra pik noktaya ulaşır veya düşer. Yüksek sıcaklıklarda (190°C–225°C) daha hızlı kinetikler daha erken yüksek çekme dayanımlara yol açacağı gibi aynı zamanda daha hızlı aşırı yaşlandırmaya

da neden olur ve bu koşulları yalnızca kısa işleme süreleri için uygun hale getirir. Bulgular, istenen mekanik özelliklere ulaşmak için yaşlandırma sıcaklığının ve süresinin dikkatlice seçilmesi gerektiğini göstermektedir.


Akma dayanımı sonuçları, yapay yaşlandırma sırasında güçlendirici çökeltilerin mikro yapısal evrimini yansıtan hem yaşlandırma sıcaklığına hem de süresine karşı belirgin bir duyarlılık göstermektedir. Daha kısa yaşlandırma süreleri (1-2 saat) için, akma dayanımı değerleri sıcaklık aralığında 400-440 MPa arasında nispeten sabit kalmış ve bu da eksik çökelmeyi ve ağırlıklı olarak yaşlandırma işlemi ile mekanik özelliklerin daha da iyileştirilebileceğini göstermektedir. Yaşlandırma süresi 3 ve 6 saate çıktıkça, akma dayanımı başlangıçta iyileşir ve özellikle 100°C sıcaklık 6 saat yaşlandırma süresinde (~465 MPa) zirve değerlerine ulaşmıştır. Bu iyileştirme, önceki paragraflarda da açıklandığı üzere etkili dislokasyon sabitlemesi sağlayan ve plastik deformasyonu engelleyen ince, tutarlı η' (MgZn₂) çökeltilerinin oluşumuna atfedilebilir ve böylece akma dayanımını en üst düzeye çıkarmıştır.

Ancak, sıcaklıktaki daha fazla artış ve uzun süreli maruziyetle (özellikle 190°C–9 saat ve 225°C–9 saatte), akma dayanımda belirgin bir düşüş gösterir ve bazı durumlarda 370 MPa'nın altına düşer. Bu azalma, çökelti kabalaşmasının ve tutarlı η' fazlarından tutarsız η fazlarına dönüşümün güçlendirme etkisini azalttığı aşırı yaşlandırmanın göstergesidir (Lin vd., 2013). Bu bulgular, aşırı yaşlandırmaya maruz kalan numunenin akma mukavemetini düşürerek alaşımın yük taşıyan uygulamalar için kritik bir faktör olan plastik deformasyona direnme yeteneğini tehlikeye atması nedeniyle yaşlandırma parametrelerinde yapılan optimizasyonun önemini vurgular.

4.3. Sertlik

Alüminyum AA 7075 alaşımlı numunelerde gerçekleştirilen Brinell sertlik testleri, sıcaklığın ve yaşlandırma süresinin sertlik üzerinde önemli bir etkisi olduğunu ortaya koymuştur. 100°C'de sertlik değerleri kısa yaşlandırma süreleri için 141 HB civarında olan sertlik değerinde uzun yaşlandırma sürelerinde hafif bir düşüş gözlemlendi. Örneğin, 6 saatlik yaşlandırmada sertlik 135,8 HB'ye düşerken, 9 saat sonra 140,6 HB'ye yükseldi. Bu değerler çekme kısmında bahsedilen aşırı yaşlandırmadaki çökeltilerin sertlik değerlerindeki hafif iyileşme öngörüsünü doğrulamaktadır.


Şekil 4.10'da AA 7075 alüminyum alaşımının yaşlandırma işlemine göre elde edilen sertlik sonuçları aynı süre için tüm ısıtım işlem sıcaklıklarında örnek olarak gösterilmiştir. Şekil 4.11'de ise tüm yaşlandırma şartları için değerler verilmiştir.



Şekil 4.10 1 saat yaşlandırma süresi için farklı sıcaklıklardaki sertlik değerleri.

Şekil 4.10'da gösterilen sonuçlara göre 100°C'de sertlik değeri nispeten yüksektir (141 HB). Bu, alaşımın daha düşük sıcaklıklarda bile bir miktar çökelme sertleşmesinden faydalandığını gösterir, çünkü tutarlı GP bölgelerinin (Guinier-Preston bölgeleri) oluşumu malzemeyi güçlendirmeye başlar (Healey, 1976). Çalışmalar, düşük sıcaklıkta yaşlandırmanın, sertliği artıran ince, dağılmış çökelti oluşumunun erken aşamalarını desteklediğini göstermiştir (Bartges, 1993). 115°C ile 145°C arasında sertlik değerleri hafifçe düşerek 130°C'de 135,2 HB ve 145°C'de 137,2 HB'ye ulaşır. Bu, bu orta sıcaklıklarda kısa bir yaşlandırma süresi boyunca yetersiz çökelme sertleşmesine bağlanabilir. Araştırmalar, bu orta sıcaklıklarda çökelti çekirdeklenmesinin 1 saat içinde tam olarak gelişmeyebileceğini ve bunun da sertliğin azalmasına yol açabileceğini göstermektedir (Tai vd., 2022). 160–190°C'de Gözlemlenen En Yüksek Sertlik: 160°C'de sertlik 142,6 HB'ye yükselir ve 175°C ve 190°C'de 145 HB değerleriyle en yüksek seviyeye ulaşır. Bu sıcaklıklar, alüminyum 7075 alaşımındaki birincil sertleştirme fazı olan η' ($MgZn_2$) çökeltilerinin oluşumu için en uygun aralığı temsil eder. 1 saatlik yaşlandırmada bu sıcaklıklardaki yüksek sertlik değerleri ile uyum, bu aralığın çözünen atomların difüzyonunu hızlandırarak çökelti yoğunluğunu optimize ettiğini bildiren

önceki çalışmalardan elde edilen bulgularla tutarlıdır (Tai vd., 2022). Daha Yüksek Sıcaklıklarda (205–225°C) aşırı yaşlandırma etkileri: 205°C'de sertlik değeri 141 HB'ye düşer ve 225°C'de 136 HB'ye daha da düşer. Bu azalma, η' fazının kabalaşmasının meydana geldiği ve dislokasyon hareketini engellemedeki etkinliğini azalttığı aşırı yaşlandırmanın karakteristik bir işaretidir. Kısa yaşlandırma süreleri boyunca daha yüksek sıcaklıklarda aşırı yaşlandırma, çalışmalarda kapsamlı bir şekilde tartışılmıştır; bu çalışmalarda, yüksek sıcaklıklarda çökeltilerin hızlı büyümesi ve birleşmesinin mekanik özellikleri bozduğu gösterilmiştir (Tai vd., 2022). Tanımlanan sıcaklıklarda diğer yaşlandırma sürelerine göre elde edilen sonuçlar Şekil 4.11'de verilmiştir.



Şekil 4.11 Belirlenen yaşlandırma sıcaklıklarına ve sürelerine göre sertlik değerleri.


Şekil 4.12'de gösterilen sonuçlara göre en yüksek sertlik değerleri, 6 saatlik yaşlandırma sırasında (sırasıyla 155 HB ve 153,67 HB) 175°C ve 190°C gibi orta sıcaklıklarda gözlemlendi. Bu, çökelme sertleşmesinin orta sıcaklıklarda en etkili olduğunu göstermektedir. Ancak, yaşlandırma sıcaklığı özellikle uzun yaşlandırma sırasında 205°C ve 225°C'ye çıktığında sertlikte önemli bir düşüş gözlemlenmiştir. Örneğin, 225°C'de ve 9 saatlik yaşlandırmada sertlik 109,67 HB'ye düşmüştür. Bu azalma, çökeltileri matrise geri çözen ve malzeme yapısını zayıflatan aşırı sıcaklıklara bağlanabilir.

Bu bulgular literatürdeki benzer çalışmalarla uyumludur. Örneğin, Aoba vd. (2017), Al 7075 alaşımında optimum sertliğin orta sıcaklıklarda ve belirli yaşlandırma

sürelerinde elde edildiğini bildirmiştir. Ek olarak, Kumar vd. (2019), aşırı yaşlandırma nedeniyle daha yüksek sıcaklıklarda sertlikte belirgin bir azalma olduğunu vurgulamıştır. Bu sonuçlar, yaşlandırma süreçlerini optimize etme ve sıcaklığı ve süreyi dikkatlice kontrol etme ihtiyacını vurgulamaktadır, çünkü bunlar doğrudan mekanik özellikleri etkiler.

Bu çalışmada çeşitli ısıtma işlem sıcaklıklarına ve sürelerine tabi tutulan alüminyum numunelerin sertlik değerleri için tahmini modelleri oluşturacak algoritmalar kullanılmıştır. YSA regresyon görevlerinde yaygın olarak kullanılmasına rağmen, küçük veri kümelerindeki zayıf performansları nedeniyle yapılan ön çalışma sonucunda alınan yüksek Ortalama Kareler Hata (OKH) değerleri sonucunda değerlendirmede dikkate alınmamıştır. Bunun yerine, özellikle sınırlı verilerle sağlamlıkları ve etkinlikleriyle bilinen dört klasik makine öğrenimi regresyon algoritmasına odaklanıldı: KA, DVM, RO ve KYK. Her modelin performansı, OKH değerleri kullanılarak ve hem eğitim hem de test veri kümeleri için tahmini ve gerçek değerler arasındaki görsel karşılaştırmalar kullanılarak değerlendirilmiştir.


Şekil 4.12’de verilen dağılım grafikleri, alüminyum veri kümesinde eğitilen her makine öğrenimi modeli için gerçek ve öngörülen sertlik değerleri arasındaki ilişkiyi göstermektedir.



Şekil 4.12 Tahmin modellerinin eğitim performansları

KA tahmin modeli veri seti karakteristik yapısına oldukça iyi uyum göstermiştir. Tahmin edilen değerler, tam uyum çizgisi etrafında yoğun bir şekilde kümelenmiştir ve bu, modelin eğitim verilerini çok iyi öğrendiğini gösterir. Bu, eğitim verilerini ezberleme eğiliminde olan ve çok düşük eğitim hatasına yol açan karar ağaçları için tipik bir davranıştır. DVM modeli, özellikle daha düşük sertlik değerlerinde daha az tutarlı bir uyum gösterir. 110-130 aralığındaki tahminler, gerçek değerleri aşma eğilimindedir ve bu da modelde olası bir önyargı olduğunu gösterir. Mükemmel uyum çizgisi etrafındaki yayılma nispeten büyüktür ve bu, eğitim verilerinde daha zayıf bir uyumu gösterir. Genel olarak, DVM, eğitim setindeki performansına bakarak bazı verilere uyum sağlamakta zorluk yaşadığı ve bunun da OKH yansıyacağı görülmektedir. KA algoritmasında olduğu gibi onun bir başka modifikasyonu olan RO eğitim verilerindeki temel ilişkileri doğru bir şekilde yakaladığı görülmektedir. Ancak, tek bir ağaçtan farklı olarak, rastgele orman ortalama mekanizması nedeniyle daha iyi genelleme eğilimindedir. Tüm aralıktaki tahminlerdeki tutarlılık, azaltılmış aşırı uyum riskiyle güçlü bir öğrenme kapasitesi

olduğunu göstermektedir. KYK modeli, çoğu tahminin tam uyum eğilimini takip etmesiyle genel olarak iyi bir performans sergilemektedir. Ancak, özellikle 110-120 civarında verilerde bazı tahminlerin diyagonalden önemli ölçüde düştüğü birkaç aykırı değer mevcuttur. Bu, KYK'nın yeterli benzer komşudan yoksun olduğu seyrek veri bölgelerindeki yerel dalgalanmalardan kaynaklanan bir uyumsuzluğu işaret etmektedir. Yine de model özellikle orta ila yüksek zorluk aralıklarında eğitim verilerinde iyi bir yaklaşım yeteneği göstermektedir. Şekil 4.14'te tahmin edilen test verileri grafikte gösterilmiştir.




Şekil 4.13 Tahmin modellerinin test verilerindeki performansı

KA modeli, tahminlerin genellikle gerçek değerlerin eğilimini takip etmesiyle test setinde iyi bir performans göstermektedir. Ancak, tahmin edilen ve gerçek değerler arasında, özellikle orta ila yüksek sertlik aralığında, fark edilir dalgalanmalar mevcuttur. Bu tutarsızlıklar, modelin eğitim verilerinde gürültü yakalamış olabileceği ve görülmeyen örneklerde daha az kararlı genellemeye yol açabileceği için aşırı uyumu gösteriyor


olabilir. DVM modeli, tüm test aralığında önemli bir değişkenlik göstermektedir. Tahmin edilen eğri, genellikle gerçek değerlerin daha düzgün ilerlemesinden sapan engebeli bir desen göstermektedir. Bu tutarsızlık, modelin verilerdeki temel eğilimleri yakalama yeteneğini sınırlayan yetersiz uyumu göstermektedir. Genel yörünge gerçek değerlerle uyumlu olsa da DVM hassas doğruluktan yoksundur ve tahminlerinde yüksek frekanslı gürültü sunmuştur. RO modeli, test edilen algoritmalar arasında en tutarlı performanslardan birini vermektedir. Tahmin edilen değerler, nispeten küçük sapmalarla gerçek değerlerin eğilimini yakından takip eder. Bazı salınımlar görülebilmeye rağmen, DVM veya KYK modellerine göre daha az belirgindir. Bu sonuç, topluluk modelinin güçlü genelleme yeteneğini ve muhtemelen birden fazla karar ağacı üzerinde ortalama yapması nedeniyle aşırı uyuma karşı sağlamlaştırmıştır. KYK modeli, tahminlerin genellikle gerçek değerleri izlemesi ancak test seti boyunca görünür dalgalanmalarla orta düzeyde performans gösterir. Bu dalgalanmalar veri noktalarının seyrek olabileceği alanlarda daha belirgindir. Yoğunluğun KYK'nın tahminlerini önemli ölçüde etkilediğini gösterir. Model eğitim örneklerinin dağılımına bağlı olarak tahmin artışlarına veya düşüşlerine yol açabilen değişikliklere karşı duyarlılık gösterir. Bu bulgular, veri özelliklerine dayalı model seçiminin önemini vurgular.

Eğitim ve test veri kümelerine ek olarak verinin %10'unu oluşturan ayrı bir doğrulama kümesi daha önce görülmemiş veriler üzerinde ana veriden bağımsız olarak ayrılmıştır. Model seçimi sırasında kullanılan test analizi haricinde doğrulama modelin gerçek senaryoda ne kadar iyi performans göstereceğini değerlendirmek için bağımsız bir ölçüt görevi görür. Doğrulama analizi daha nesnel bir değerlendirme sağlar ve modeli belirli bir veri kümesi bölünmesine aşırı uydurma veya aşırı ayarlama riskini azaltır. Şekil 4.14'te tahmin modellerinin doğrulama performansları görülmektedir.



Şekil 4.14 Tahmin modellerinin doğrulama performansları

Şekil 4.14’te dört model arasında, RO ve KA, bazı sapmalar ve salınımlar hala mevcut olmasına rağmen, gerçek sertlik değerleriyle nispeten güçlü tahmin modelleri olmayı sürdürmekte. DVM genel eğilimi yakalarken, orta ila yüksek aralıkta tahminleri düzleştirme eğilimindedir ve bu, verilerdeki daha ince değişikliklere sınırlı yanıt verdiğini gösterir. KYK modeli, özellikle orta aralıkta daha büyük dalgalanmalar gösterir ve bu, yerel veri dağılımlarına olan duyarlılığını yansıtabilir. Genel olarak, tüm modeller küresel eğilimi takip etme yeteneği gösterse de tahmin tutarlılıkları değişir ve topluluk tabanlı modeller, görülmemiş doğrulama kümesinde daha sağlam bir genelleme gösterir. Bu sonuçlara göre Şekil 4.15’te modellere göre test ve doğrulama dayalı OKH değerleri verilmiştir.



Şekil 4.15 Tahmin modellerine göre test ve doğrulama için OKH değerleri


Değerlendirilen dört makine öğrenimi algoritması arasında OKH değerlerinin karşılaştırılması, test veri kümesindeki genelleme yeteneklerinde anlamlı farklılıklar ortaya koymaktadır. Modeller arasında, RO regresörü en düşük OKH değerini elde ederek üstün tahmin performansını göstermektedir. Bu, birden fazla karar ağacını bir araya getirerek varyansı etkili bir şekilde azaltan bir topluluk öğrenme yöntemi olarak bilinen güçlü yönleriyle algoritmanın gücünü ortaya koymaktadır. KA regresörü de düşük hata göstererek yakından takip etmiştir. Ancak, tek ağaç yapısı göz önüne alındığında, bu nispeten güçlü performans, sıkı bir şekilde uyan eğitim tahminleriyle desteklenen bir eğilim olan aşırı uyumdan etkilenebilir. Ancak doğrulama analizinde aşırı uyum şüphesini azaltmış öğrenimin güvenilirliğini artırmıştır. Bununla birlikte, her iki ağaç tabanlı model de sertlik veri kümesindeki temel doğrusal olmayan kalıpları yakalamak için güçlü bir potansiyel sergilemektedir.

Buna karşılık, KYK modeli orta düzeyde bir OKH üreterek, özellikle seyrek veriye sahip bölgelerde küresel veri eğilimlerini tutarlı bir şekilde yakalamada daha az etkili olduğunu göstermektedir. KYK yerel ilişkileri iyi modelleyebilirken, veri dağılımına olan duyarlılığı genellikle daha yüksek tahmin değişkenliğiyle sonuçlanır. Bu

aynı zamanda verilen grafiklerinde de görülebilir. DVM en yüksek OKH'yı kaydederek, suboptimal uyumunu ve bu bağlamda doğru bir şekilde genelleme yapamamasını doğrular. Diğer algoritmalarla göre elde edilen düşük performans, veriye yetersiz uyumdan kaynaklanıyor olabilir. Buna kanıt olarak algoritmanın eğitim veri seti üzerindeki performansını gösteren Şekil 4.12 gösterilebilir. Genel olarak, OKH analizi, bu çalışmada ısıtım işlem görmüş alüminyum numunelerinin sertlik değerlerini tahmin etmek için en sağlam ve geliştirilebilir model olarak KA ve RO modelini göstermektedir.

4.4. Aşınma

Farklı yaşlandırma sıcaklıklarına tabi tutulan Alüminyum 7075 alaşımının özgül aşınma oranının hem sıcaklığa hem de yaşlandırma süresine bağlı olarak değiştiği gözlemlenmiştir (Baydoğan vd., 2004; Reddy vd., 2014; Zhang vd., 2023). Şekil 4.16'da gösterilen değerlere göre, özgül aşınma oranı değerleri yaşlandırma koşulları değiştikçe doğrusal olmayan eğilimler göstermektedir. Bu da Al 7075 gibi çökeltme sertleştirme alaşımlarının tipik mikro yapısal dönüşümleriyle tutarlıdır.




Şekil 4.16 Isıl işlem sıcaklığı ve sürelerine göre ortalama aşınma değerleri

100°C'de yaşlandırma süresi 1 ila 9 saat arttıkça aşınma direncinin zayıfladığı görülmektedir. Bu, nispeten düşük yaşlandırma sıcaklığına uzun süre maruz kalmanın, yüzey sertliğine ve aşınma direncine sebep olan güçlendirici çökeltilerin oluşumunu ve

dağılımını sağlamadığını gösterir. 130°C'de, benzer bir eğilim gözlemlenir, ancak aşınma oranı değerleri genellikle 100°C'deki değerlere kıyasla daha yüksektir. Bu 130°C'de yaşlandırmanın hala çökeltme sertleşmesini teşvik etmesine rağmen kinetiklerin daha uzun sürelerde aşırı yaşlandırılmış bölgelerin veya daha iri çökeltilerin oluşumuna yol açabileceğini ve aşınma direncindeki faydaları kısmen azaltabileceğini göstermektedir. Buna karşılık 160°C ve 190°C'de başlangıçtaki aşınma direnci daha kısa sürelerde zayıf iken, yaşlandırma süresi arttıkça, özgül aşınma oranı önce azalmış daha sonra da artmıştır. Bu davranış muhtemelen, çökeltilerin daha iri hale geldiği veya matrisle tutarlılığını kaybettiği, böylece güçlendirme etkilerinin azaldığı ve malzemenin aşınmaya daha duyarlı hale geldiği aşırı yaşlandırmaya atfedilmektedir. İlginç bir şekilde, 225°C'deki davranış önemli ölçüde sapmaktadır. Başlangıçta aşınma direncinin 0,5 saatte yaşlandırılan numunede nispeten zayıf, 1,5 saatte yaşlandırılan numunede daha da zayıfladığı ancak daha sonra 6 saatte yaşlandırılmış numunelerde tekrar arttığı gözlemlenmiştir. Bu, hızlı çökelti büyümesinin ve matris yumuşamasının aşınma tepkisine hâkim olduğu yüksek sıcaklıklarda hızlandırılmış aşırı yaşlandırma hipotezini daha da desteklemektedir.


Şekil 4.17'de sunulan dağılım grafikleri, dört makine öğrenimi modelinin KA DVM, RO ve KYK farklı yapay yaşlandırma koşullarına tabi tutulan Alüminyum 7075 alaşımlarının özgül aşınma oranını tahmin etmedeki eğitim performansını göstermektedir.



Şekil 4.17 Tahmin modelleri için eğitim veri seti performansları

Tüm modeller arasında, RO ve KYK, ideal tahminleri temsil eden tam uyum çizgisi boyunca en yüksek tahmin değerlerine sahip olduğunu göstermektedir. Bu modellerin veri noktaları diyagonal etrafında sıkı bir şekilde kümelenmiştir ve bu da eğitim verilerine sağlıklı uyum gösterdiğini ve tahmin edilen ile gerçek değerler arasında minimum sapma olduğunu göstermektedir. KA modeli, bazı kesin eşleşmeler nedeniyle hafif aşırı uyum eğilimleri çıkarılabilmesine rağmen, ideal çizgi boyunca noktaların neredeyse doğrusal bir dağılımıyla güçlü bir performans göstermektedir. Buna karşılık, DVM modelinin küçük verisetlerinde yaşadığı problem burada da devam etmekte ve modelin uyum sağlamadığı ve tahminlerde kötü sonuç verdiği gözlemlenmiştir. Bu, modelin verilerde bulunan doğrusal olmayan ilişkileri yakalayamadığını göstermektedir.


Şekil 4.18, makine öğrenimi modellerinin test veri kümesindeki tahmin performansını sunmakta ve bu modellerin eğitim verilerinin ötesinde ne kadar iyi genelleştirildiğine dair fikir vermektedir.



Şekil 4.18 Tahmin modelleri için test veri seti performansları

Genel olarak hem RO hem KYK modelleri, test verilerinde güçlü tahmin doğruluğu sağlar. Tahmin eğrileri, makul bir tutarlılıkla gerçek aşınma oranı değerlerinin dalgalanmalarını takip eder. Özellikle RF modeli hem yüksek hem de düşük aşınma oranı değerlerinin iyi bir şekilde izlenmesini gösterir ve bu, verilerdeki doğrusal olmayan ve muhtemelen karmaşık ilişkileri yakalamadaki gücünü gösterir. Benzer şekilde, KYK modeli, özellikle hassas geçişlerde hafif sapmalar göstermesine rağmen, çoğunlukla temel gerçekle uyumlu tahminler sağlar. KA modeli, makul derecede doğru tahminler yaparken, aşırı uyum belirtileri göstermektedir. Modelden alınan doğruluk oranı 0.99 da aşırı öğrenme belirtilerini desteklemektedir. Bu, modelin eğitim verilerinden kalıpları ezberlemesinden ve genelleştirilebilir eğilimleri tam olarak yakalamamasından kaynaklanabilecek bazı keskin geçişlerden ve tam eşleşmelerden açıkça anlaşılmaktadır. Bununla birlikte, test tahminleri çoğu durumda gerçek değerlere yakın kalmaktadır. Tersine, DVM açıkça düşük performans göstermektedir. Tahmin çizgisi tüm test örneklerinde neredeyse düz kalmaktadır ve bu da giriş özelliklerindeki değişikliklere yanıt verme eksikliğini göstermektedir. Bu, modelin muhtemelen verisetine uyum sorunu yaşadığı ve tahminlerde çok düşük doğruluk oranı verdiğini göstermektedir.

Eğitilen makine öğrenimi modellerinin genelleme yeteneğini değerlendirmek doğrulama veri seti deneyler bazında eğitim ve test veri setinden bağımsız değerlendirildi. Modeller yalnızca eğitim verileri üzerinde eğitilirken, eğitim sırasında görülmeyen ayrı bir %10 doğrulama kümesi, daha önce gözlemlenmemiş örneklerdeki performansı değerlendirmek için kullanıldı. Şekil 4.19’da doğrulama veri seti üzerinde modellerin performansı gösterilmektedir.




Şekil 4.19 Tahmin modellerine ait doğrulama

Şekilde görüldüğü üzere hem KA hem de RO modelleri, tüm doğrulama örneklerindeki gerçek aşınma oranı eğilimlerini yakından takip ederek gerçek verilerle yüksek tutarlılık göstermiştir. Bu, ağaç tabanlı modellerin ısıt işlem parametreleri ve aşınma tepkisi arasındaki temel ilişkileri yakalamada etkili olduğunu göstermektedir. Ancak KA modeli doğrulamada da yüksek doğruluk değeri elde ederek bu parametrelerde aşırı öğrenme şüphelerini devam ettirmektedir. KYK modeli de makul derecede doğru tahminler üretmiştir, ancak aşınma oranında bazı noktalarda küçük sapmalar gözlemlenmiştir. Yine de model genel dağılımı etkili bir şekilde yansıtmaktadır. Buna karşılık, DVM modeli önemli ölçüde düşük performans göstermiştir. Tahminleri, gerçek

değerlerdeki değişimden bağımsız olarak neredeyse sabit kalmaktadır ve bu da aşınma sürecinin karmaşık, doğrusal olmayan davranışını modellemede zayıf bir uyum ve esneklik eksikliği olduğunu göstermektedir.

Sonuç olarak, RO aracılığıyla topluluk öğrenimi ve KYK aracılığıyla örnek tabanlı öğrenme, bu uygulama için en güvenilir tahmin performansını sağlar. KA bu parametreler için doğruluk oranı yüksek görünse de aşırı öğrenme potansiyeli nedeniyle tavsiye edilmez. Model sonraki çalışmalarda genellemeyi iyileştirmek için ek düzenleme veya topluluk geliştirmeden faydalanabilir. Şekil 4.20’de tahmin modellerinde test ve doğrulama için OKH değerleri gösterilmiştir.



Şekil 4.20 Tahmin modellerinde test ve doğrulama için OKH değerleri

Test ve doğrulama kümeleri arasında OKH değerlerinin karşılaştırmalı analizi, değerlendirilen modellerin genelleme performansında anlamlı farklılıklar ortaya koymaktadır. KA ve RO modelleri her iki veri kümesinde de en düşük hata değerlerini göstermektedir. Ancak KA modeli test değerlerindeki aşırı uyum şüphesi parametrelere bağlı olarak burada da kendini gösterebilmektedir. Modelin tam doğruluğu gelecekteki deneysel doğrulama çalışmalarında tekrar ele alınabilir. RO modeli ise yalnızca doğru uyumu değil, aynı zamanda aşırı uyum belirtisi olmadan sağlam genellemeyi de başardığını göstermektedir. KYK modeli de kabul edilebilir bir performans göstermektedir, ancak biraz daha yüksek hata seviyelerine sahiptir. Buna karşılık, DVM

eđitim ve test aşamasındaki performansına paralel olarak dođrulama kümeleri için önemli ölçüde yüksek OKH değeri göstermektedir ve yüksek hata sebebi ile tahmin modeli olarak tavsiye edilmemektedir. Genel olarak, sonuçlar ağaç tabanlı ve örnek tabanlı modellerin RO ve KYK değışen yaşlandırma koşulları altında belirli özgül aşınma oranlarını tahmin etmede daha etkili olduğunu dođrulamaktadır.



5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, AA 7075 alüminyum alaşımının T6 yaşlandırma koşulları ile mekanik özellikleri arasındaki ilişki hem deneysel teknikler hem de makine öğrenimi tabanlı modelleme kullanılarak kapsamlı bir şekilde incelenmiştir. Numunelere geniş bir sıcaklık aralığında (100°C ila 225°C) ve sürelerde (1 ila 9 saat) yapay yaşlandırma işlemleri uygulanmış, ardından piezoelektrik sensörler aracılığıyla mekanik testler ve titreşim tabanlı spektral veriler toplanarak makine ve derin öğrenmeye dayalı tahmin modelleri oluşturulmuştur.

Deneysel sonuçlar, nihai çekme dayanımı, sertlik ve aşınma direnci gibi mekanik özelliklerin hem yaşlandırma sıcaklığına hem de süresine karşı oldukça hassas olduğunu açıkça göstermiştir. Optimum çekme dayanımı (590,9 MPa) 100°C'de 4 saatte elde edilirken, 130–175°C'de 3 saatte çekme dayanım ve süneklik arasında bir denge sağlanmıştır. Sertlik 175–190°C'de 145 HB civarında zirve yapmış ve 225°C'de aşırı yaşlandırma, çökelti kabalaşması nedeniyle sertlik değerlerinde azalmaya yol açmıştır.

Bu hassasiyeti tahribatsız değerlendirme için kullanmak amacıyla, piezoelektrik titreşim ölçümlerinden elde edilen titreşim tepki görüntüleri kullanılarak Evrişimsel sinir ağları sınıflandırıcısı (ESA) tabanlı derin öğrenme modeli geliştirildi. ESA hem makro ortalama hem de ağırlıklı ortalama F1 puanlarının her ikisinin de 0,89'a ulaşmasıyla, birden fazla ısıtıl işlem koşulunda mükemmel sınıflandırma kabiliyetini gösteren %89 doğruluk oranı elde etmiştir. Paralel olarak ESA tabanlı özellik çıkarma yöntemi ile özellikler çıkarılarak sıg sinir ağları temelli çıkarılan veriler klasik makine öğrenimi sınıflandırıcılarına beslenerek hibrit modeller oluşturulmuştur. Bunlar arasında, RO sınıflandırıcısı da ESA sınıflandırıcısı performansına yakın bir şekilde %89 doğruluk elde ederken, KA modeli %83 ve DVM modeli %72 doğruluk elde etmiştir. Regresyon görevleri açısından, özellikle yaşlandırma parametrelerine dayalı sertlik değerlerini tahmin etmek için, RO yine en düşük OKH ile en iyi sonuçları vermiş, bunu KA ve KYK tahmin modelleri izlemiştir, DVM ise nispeten zayıf genelleme göstermiştir. Aşınma oranı tahminleri için, RO ve KYK modelleri en düşük OKH elde ederek tatmin edici bir test performansı elde etmiş ve diğer modelleri geride bırakmıştır. Bu sonuçlar, alüminyum alaşımlarındaki ısıtıl işlem proses işleme koşullarının tahribatsız tahmini için titreşim tabanlı sinyallerin ve derin öğrenme mimarilerinin kullanılmasının uygulanabilirliğini göstermektedir. Modeller, yaşlandırma sırasında mikro yapısal

evrimden kaynaklanan spektral desenlerdeki ince deęişiklikleri tespit edebilir ve endüstriyel kalite kontrolü ve süreç optimizasyonu için yeni, güvenilir ve pratik bir araç sunmaktadır. Çalışmayı geliştirmek ve daha genişletmek amacı aşağıdaki öneriler sunulmuştur.

- Geliştirilen derin öğrenme çerçevesi, AA 7075'in yaygın olarak kullanıldığı havacılık ve otomotiv endüstrilerinde ısıtım süreçlerinin hat içi izlenmesi için uyarlanabilir. Bu, tahribatlı test ihtiyacını azaltarak zaman ve maliyet tasarrufu sağlayabilir.
- Gelecekteki çalışmalar, uygulanabilirliği genişletmek için farklı alüminyum alaşımlar sınıfları (örn. 6061, 2024) ve geometriler arasında modellerin genelleme yeteneğini araştırmalıdır.
- Mikro yapı görüntülemeyi (örn. SEM, TEM) model eğitime dahil etmek, spektral farklılıkları yönlendiren fiziksel olgulara ilişkin daha derin içgörüler sağlayabilir.
- Titreşim tepki verileri kaydetmek için kullanılan paslanmaz çelik malzemesi haricinde farklı metaller kullanarak titreşim tepkileri üzerindeki etkileri ve tahmin modelleri üzerindeki farklılıkları incelemek faydalı olabilir
- GAN'lar veya gürültü enjeksiyonu kullanılarak titreşim tepki verilerinin sentetik üretimi, eğitim veri setini zenginleştirmek ve aşırı uyum risklerini azaltmak için düşünülebilir.

Bu çalışma, özellikle AA 7075 gibi hassas alaşımlar için modern malzeme mühendisliğinde derin öğrenmeye dayalı tahribatsız test metodolojilerinin önemli potansiyelini vurgulamaktadır. Bu tür çalışmaların genişletilmesi, ısıtım proseslerinde ve kalite kontrolünde devrim yaratabilir.

KAYNAKLAR

- Abd Elaziz, M., Shehabeldeen, T. A., Elsheikh, A. H., Zhou, J., Ewees, A. A., & Al-qaness, M. A. A. (2020). Utilization of Random Vector Functional Link integrated with Marine Predators Algorithm for tensile behavior prediction of dissimilar friction stir welded aluminum alloy joints. *Journal of Materials Research and Technology*, 9(5), 11370-11381. <https://doi.org/10.1016/j.jmrt.2020.08.022>
- Amidi , A., & Amidi , S. (t.y.). *Evriřimli Sinir Ađları el kitabı*. Retrieved 12 Aralık from <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks>
- Anyalebechi, P. N. (1995). Analysis of the effects of alloying elements on hydrogen solubility in liquid aluminum alloys. *Scripta Metallurgica et Materialia*, 33(8), 1209-1216. [https://doi.org/10.1016/0956-716X\(95\)00373-4](https://doi.org/10.1016/0956-716X(95)00373-4)
- Aoba, T., Kobayashi, M., & Miura, H. (2017). Effects of aging on mechanical properties and microstructure of multi-directionally forged 7075 aluminum alloy. *Materials Science and Engineering: A*, 700, 220-225. <https://doi.org/10.1016/j.msea.2017.06.017>
- Ashkenazi, D. (2019). How aluminum changed the world: A metallurgical revolution through technological and cultural perspectives. *Technological Forecasting and Social Change*, 143, 101-113. <https://doi.org/10.1016/j.techfore.2019.03.011>
- Baradeswaran, A., & Elaya Perumal, A. (2013). Influence of B4C on the tribological and mechanical properties of Al 7075–B4C composites. *Composites Part B: Engineering*, 54, 146-152. <https://doi.org/10.1016/j.compositesb.2013.05.012>
- Baradeswaran, A., & Perumal, A. E. (2014). Wear and mechanical characteristics of Al 7075/graphite composites. *Composites Part B: Engineering*, 56, 472-476. <https://doi.org/10.1016/j.compositesb.2013.08.073>
- Baragetti, S., Borzini, E., Božic, Ź., & Arcieri, E. V. (2019). On the fatigue strength of uncoated and DLC coated 7075-T6 aluminum alloy. *Engineering Failure Analysis*, 102, 219-225. <https://doi.org/10.1016/j.engfailanal.2019.04.035>
- Barboza, D. (2020). *Deep Learning-Based Semantic Image Segmentation Techniques for Corrosive Particles of Aluminum Alloy AA 7075* (Publication Number 28151074) [M.S., Arizona State University]. ProQuest Dissertations & Theses Global. United States -- Arizona. <https://www.proquest.com/dissertations-theses/deep-learning-based-semantic-image-segmentation/docview/2476548165/se-2?accountid=86195>
- Bartges, C. (1993). Evidence of [eta]'or ordered zone formation in aluminum alloy 7075 from differential scanning calorimetry.[Aluminium alloy 7075]. *Scripta Metallurgica et Materialia;(United States)*, 28(9).

- Baydoğan, M., Çimenoglu, H., & Sabri Kayalı, E. (2004). A study on sliding wear of a 7075 aluminum alloy. *Wear*, 257(7), 852-861. <https://doi.org/10.1016/j.wear.2004.05.006>
- Bulut, F. (2016). [Çok katmanlı algılayıcılar İle doğru meslek tercihi]. *Anadolu University Journal of Science and Technology A - Applied Sciences and Engineering*, 17(1), 97-109. 10.18038/btda.45787
- Cao, X., Zhang, Y., & Chen, H. (2020). Predicting Mechanical Properties and Corrosion Resistance of Heat-Treated 7N01 Aluminum Alloy by Machine Learning Methods. *IOP Conference Series: Materials Science and Engineering*, 774(1), 012030. 10.1088/1757-899X/774/1/012030
- Chen, J. (2010). 16 - Surface engineered light alloys for sports equipment. In H. Dong (Ed.), *Surface Engineering of Light Alloys* (pp. 549-567). Woodhead Publishing. <https://doi.org/https://doi.org/10.1533/9781845699451.3.549>
- Decke, J., Engelhardt, A., Rauch, L., Degener, S., Sajadifar, S. V., Scharifi, E., Steinhoff, K., Niendorf, T., & Sick, B. (2022). Predicting Flow Stress Behavior of an AA7075 Alloy Using Machine Learning Methods. *Crystals*, 12(9), 1281. <https://www.mdpi.com/2073-4352/12/9/1281>
- Du, Z., Deng, Z., Xiao, A., Cui, X., Yu, H., & Feng, Z. (2021). Effect of the aging process on the micro-structure & properties of 7075 aluminum alloy using electromagnetic bulging. *Journal of Manufacturing Processes*, 70, 15-23. <https://doi.org/10.1016/j.jmapro.2021.08.015>
- Eker, A. G., & Duru, N. (2021). Medikal Görüntü İşlemede Derin Öğrenme Uygulamaları [Deep Learning Applications in Medical Image Processing]. *Acta Infologica*, 5(2), 459-474. 10.26650/acin.927561
- Feng, Z., Liu, C., Ma, P., Yang, J., Chen, K., Li, G., Chen, L., & Huang, Z. (2021). Initial holding time dependent warm deformation and post-ageing precipitation in an AA7075-T4 aluminum alloy. *Journal of Materials Processing Technology*, 294, 117111. <https://doi.org/10.1016/j.jmatprotec.2021.117111>
- Freed, Y. (2024). Machine Learning-Based predictions of crack growth rates in an aeronautical aluminum alloy. *Theoretical and Applied Fracture Mechanics*, 130, 104278. <https://doi.org/10.1016/j.tafmec.2024.104278>
- Goodfellow, I. (2016). Deep learning. In: MIT press.
- Hart, G. L. W., Mueller, T., Toher, C., & Curtarolo, S. (2021). Machine learning for alloys. *Nature Reviews Materials*, 6(8), 730-755. 10.1038/s41578-021-00340-w
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition,

- Healey, J. T. (1976). *GUINIER-PRESTON ZONE EVOLUTION IN 7075 ALUMINUM* (Publication Number 7706875) [Ph.D., University of Florida]. ProQuest Dissertations & Theses Global. United States -- Florida. <https://www.proquest.com/dissertations-theses/guinier-preston-zone-evolution-7075-aluminum/docview/302770016/se-2?accountid=86195>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. 10.1162/neco.1997.9.8.1735
- Indeck, J., Demeneghi, G., Mayeur, J., Williams, C., & Hazeli, K. (2021). Influence of reversible and non-reversible fatigue on the microstructure and mechanical property evolution of 7075-T6 aluminum alloy. *International Journal of Fatigue*, 145, 106094. <https://doi.org/10.1016/j.ijfatigue.2020.106094>
- Isadare, A. D., Aremo, B., Adeoye, M. O., Olawale, O. J., & Shittu, M. D. (2013). Effect of heat treatment on some mechanical properties of 7075 aluminium alloy. *Materials Research*, 16, 190-194.
- Jain, N., Verma, A., Ogata, S., Sanjay, M. R., & Siengchin, S. (2022). Application of Machine Learning in Determining the Mechanical Properties of Materials. In V. Kushvaha, M. R. Sanjay, P. Madhushri, & S. Siengchin (Eds.), *Machine Learning Applied to Composite Materials* (pp. 99-113). Springer Nature Singapore. https://doi.org/10.1007/978-981-19-6278-3_5
- James, S., & Roy, A. (2020). Study of Aging Heat Treatment Parameters for 7050 and 7075 Aluminum Alloys. ASME 2020 15th International Manufacturing Science and Engineering Conference,
- Kaufman, J. G. (2000). *Introduction to aluminum alloys and tempers*. ASM international.
- Khalid, M. Y., Umer, R., & Khan, K. A. (2023). Review of recent trends and developments in aluminium 7075 alloy and its metal matrix composites (MMCs) for aircraft applications. *Results in Engineering*, 20, 101372. <https://doi.org/10.1016/j.rineng.2023.101372>
- Kozina, F., & Brodarac, i. Z. (2022). Metallurgy development: Discovery and utilization of aluminum through history. *Engineering Power : Bulletin of the Croatian Academy of Engineering*, 17(3). <https://hrcak.srce.hr/302300>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Ku, M.-H., Hung, F.-Y., Lui, T.-S., & Lai, J.-J. (2018). Enhanced Formability and Accelerated Precipitation Behavior of 7075 Al Alloy Extruded Rod by High Temperature Aging. *Metals*, 8(8), 648. <https://www.mdpi.com/2075-4701/8/8/648>
- Kumar, N., Dwivedi, D., Sharma, A., Ahn, B., & Manoj, M. K. (2019). Influence of various heat treatment procedures on the corrosion behavior of Al–Zn–Mg–Cu alloys. *Materials Research Express*, 6(12), 126554. 10.1088/2053-1591/ab5458

- Latypov, F. T., Fomin, E. V., Krasnikov, V. S., & Mayer, A. E. (2022). Dynamic compaction of aluminum with nanopores of varied shape: MD simulations and machine-learning-based approximation of deformation behavior. *International Journal of Plasticity*, 156, 103363. <https://doi.org/10.1016/j.iplas.2022.103363>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. 10.1038/nature14539
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541-551. 10.1162/neco.1989.1.4.541
- Leng, L., Zhang, Z. J., Duan, Q. Q., Zhang, P., & Zhang, Z. F. (2018). Improving the fatigue strength of 7075 alloy through aging. *Materials Science and Engineering: A*, 738, 24-30. <https://doi.org/10.1016/j.msea.2018.09.047>
- Li, B., Du, Y., Zheng, Z. S., Ye, X. C., Fang, D., Si, X. D., & Wang, Y. Q. (2022). Manipulation of mechanical properties of 7xxx aluminum alloy via a hybrid approach of machine learning and key experiments. *Journal of Materials Research and Technology*, 19, 2483-2496. <https://doi.org/10.1016/j.jmrt.2022.06.015>
- Li, J.-f., Peng, Z.-w., Li, C.-x., Jia, Z.-q., Chen, W.-j., & Zheng, Z.-q. (2008). Mechanical properties, corrosion behaviors and microstructures of 7075 aluminium alloy with various aging treatments. *Transactions of Nonferrous Metals Society of China*, 18(4), 755-762. [https://doi.org/10.1016/S1003-6326\(08\)60130-2](https://doi.org/10.1016/S1003-6326(08)60130-2)
- Li, J., Zhang, Y., Cao, X., Zeng, Q., Zhuang, Y., Qian, X., & Chen, H. (2020). Accelerated discovery of high-strength aluminum alloys by machine learning. *Communications Materials*, 1(1), 73. 10.1038/s43246-020-00074-2
- Lin, Y. C., Jiang, Y.-Q., Chen, X.-M., Wen, D.-X., & Zhou, H.-M. (2013). Effect of creep-aging on precipitates of 7075 aluminum alloy. *Materials Science and Engineering: A*, 588, 347-356. <https://doi.org/10.1016/j.msea.2013.09.045>
- Liu, P., Hu, J.-y., Li, H.-x., Sun, S.-y., & Zhang, Y.-b. (2020). Effect of heat treatment on microstructure, hardness and corrosion resistance of 7075 Al alloys fabricated by SLM. *Journal of Manufacturing Processes*, 60, 578-585. <https://doi.org/10.1016/j.jmapro.2020.10.071>
- Liu, Q., Chen, S., Gu, R., Wang, W., & Wei, X. (2018). Effect of Heat Treatment Conditions on Mechanical Properties and Precipitates in Sheet Metal Hot Stamping of 7075 Aluminum Alloy. *Journal of Materials Engineering and Performance*, 27(9), 4423-4436. 10.1007/s11665-018-3588-z
- Mahathaninwong, N., Plookphol, T., Wannasin, J., & Wisutmethangoon, S. (2012). T6 heat treatment of rheocasting 7075 Al alloy. *Materials Science and Engineering: A*, 532, 91-99. <https://doi.org/10.1016/j.msea.2011.10.068>

- Materials, A. (n.d.). *Aluminium Alloy 7075*. Retrieved 3.12 from <https://www.aircraftmaterials.com/data/aluminium/7075.html>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133. 10.1007/BF02478259
- Minsky, M. L., & Papert, S. A. (1988). *Perceptrons: expanded edition*. In: MIT press.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., Petersen, S., Beattie, C., Sadik, A., Antonoglou, I., King, H., Kumaran, D., Wierstra, D., Legg, S., & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533. 10.1038/nature14236
- Nečemer, B., Vuherer, T., Glodež, S., & Kramberger, J. (2022). Fatigue behaviour of re-entrant auxetic structures made of the aluminium alloy AA7075-T651. *Thin-Walled Structures*, 180, 109917. <https://doi.org/10.1016/j.tws.2022.109917>
- Pandya, K. S., Roth, C. C., & Mohr, D. (2020). Strain rate and temperature dependent fracture of aluminum alloy 7075: Experiments and neural network modeling. *International Journal of Plasticity*, 135, 102788. <https://doi.org/10.1016/j.ijplas.2020.102788>
- Prasad, J., & Sonwani, R. K. (2025). Optimize chemical milling of aluminium alloys to achieve minimum surface roughness in Aerospace and Defense Industry. *Journal of the Indian Chemical Society*, 102(1), 101537. <https://doi.org/10.1016/j.jics.2024.101537>
- Rana, R., Purohit, R., & Das, S. (2012). Reviews on the influences of alloying elements on the microstructure and mechanical properties of aluminum alloys and aluminum alloy composites. *International Journal of Scientific and research publications*, 2(6), 1-7.
- Razumovskiy, V. I., Vekilov, Y. K., Razumovskii, I. M., Ruban, A. V., Butrim, V. N., & Mironenko, V. N. (2011). Effect of alloying elements and impurities on interface properties in aluminum alloys. *Physics of the Solid State*, 53(11), 2189-2193. 10.1134/S1063783411110266
- Reddy, M. S., Chetty, S. V., Premkumar, S., & Reddappa, H. N. (2014). Influence of Reinforcements and Heat Treatment on Mechanical and Wear Properties of Al 7075 based Hybrid Composites. *Procedia Materials Science*, 5, 508-516. <https://doi.org/10.1016/j.mspro.2014.07.294>
- Rice, R., Jackson, J., Bakuckas, J., & Thompson, S. (2003). Metallic materials properties development and standardization. *Federal Aviation Administration*, 1-4.
- Rometsch, P. A., Zhang, Y., & Knight, S. (2014). Heat treatment of 7xxx series aluminium alloys—Some recent developments. *Transactions of Nonferrous Metals*

- Society of China*, 24(7), 2003-2017. [https://doi.org/10.1016/S1003-6326\(14\)63306-9](https://doi.org/10.1016/S1003-6326(14)63306-9)
- Ronneberger, O., Fischer, P., & Brox, T. (2015, 2015//). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Cham.
- Rooy, E. L. (1990). Introduction to Aluminum and Aluminum Alloys. In A. S. M. H. Committee (Ed.), *Properties and Selection: Nonferrous Alloys and Special-Purpose Materials* (Vol. 2, pp. 0). ASM International. <https://doi.org/10.31399/asm.hb.v02.a0001057>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536. 10.1038/323533a0
- Runge, J. M. (2018). A Brief History of Aluminum and Its Alloys. In J. M. Runge (Ed.), *The Metallurgy of Anodizing Aluminum: Connecting Science to Practice* (pp. 1-63). Springer International Publishing. https://doi.org/10.1007/978-3-319-72177-4_1
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., & Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3), 211-252. 10.1007/s11263-015-0816-y
- Schatzberg, E. (2003). Symbolic Culture and Technological Change: The Cultural History of Aluminum as an Industrial Material. *Enterprise and Society*, 4(2), 226-271. 10.1093/es/khg002
- Shinde, P. P., & Shah, S. (2018). A review of machine learning and deep learning applications. 2018 Fourth international conference on computing communication control and automation (ICCUBEA),
- Siddesh Kumar, N. M., Dhruthi, Pramod, G. K., Samrat, P., & Sadashiva, M. (2022). A Critical Review on Heat Treatment of Aluminium Alloys. *Materials Today: Proceedings*, 58, 71-79. <https://doi.org/10.1016/j.matpr.2021.12.586>
- Sielski, R. A. (1987). THE HISTORY OF ALUMINUM AS A DECKHOUSE MATERIAL. *Naval Engineers Journal*, 99(3), 165-172. <https://doi.org/10.1111/j.1559-3584.1987.tb02127.x>
- Stoll, A., & Benner, P. (2021). Machine learning for material characterization with an application for predicting mechanical properties. *GAMM-Mitteilungen*, 44(1). 10.1002/gamm.202100003
- Sunar, T., Tuncay, T., Özyürek, D., & Gürü, M. (2020). Investigation of Mechanical Properties of AA7075 Alloys Aged by Various Heat Treatments. *Physics of Metals and Metallography*, 121(14), 1440-1446. 10.1134/S0031918X20140161
- Sürmen, Ö. (2016). *Dövme alüminyum parçalarının ısıtma işlem pratiğinin geliştirilmesi* [Fen Bilimleri Enstitüsü].

- Tai, C.-L., Tai, P.-J., Hsiao, T.-J., Chiu, P.-H., Tseng, C.-Y., Tsao, T.-C., Chung, T.-F., Yang, Y.-L., Chen, C.-Y., Wang, S.-H., & Yang, J.-R. (2022). Effect of Natural Ageing on Subsequent Artificial Ageing of AA7075 Aluminum Alloy. *Metals*, 12(10), 1766. <https://www.mdpi.com/2075-4701/12/10/1766>
- Totten, G. E., & MacKenzie, D. S. (2003). *Handbook of aluminum: vol. 1: physical metallurgy and processes* (Vol. 1). CRC press.
- Uğurlu, H. H. (2009). Titanyum ile alüminyum-magnezyum-silisyum alaşımlarının yapı kontrolü.
- Venkataraman, B., & Sundararajan, G. (2000). Correlation between the characteristics of the mechanically mixed layer and wear behaviour of aluminium, Al-7075 alloy and Al-MMCs. *Wear*, 245(1), 22-38. [https://doi.org/10.1016/S0043-1648\(00\)00463-4](https://doi.org/10.1016/S0043-1648(00)00463-4)
- Venkatesh, S., Kathiravan, A. A., Kavipriyan, M., Nandhini, S. S. G., & Avinasilingam, M. (2024). A review on aluminium 7075 alloy: Micro structure, mechanical properties and application. *AIP Conference Proceedings*, 3221(1), 020001. 10.1063/5.0235874
- Wu, J., Xu, Z., Qiao, H., Zhao, J., & Huang, Z. (2021). Mechanical properties prediction of superalloy FGH4095 treated by laser shock processing based on machine learning. *Materials Letters*, 297, 129970. <https://doi.org/10.1016/j.matlet.2021.129970>
- Xiang, L., Tao, J., Xia, X., Zhao, Z., Chen, Q., Su, Y., Chai, S., Zheng, Z., & Sun, J. (2023). Impact of Marine Atmospheric Corrosion on the Microstructure and Tensile Properties of 7075 High-Strength Aluminum Alloy. *Materials*, 16(6), 2396. <https://www.mdpi.com/1996-1944/16/6/2396>
- Xu, Y., Zhang, Z., Gao, Z., Bai, Y., Zhao, P., & Mao, W. (2021). Effect of main elements (Zn, Mg and Cu) on the microstructure, castability and mechanical properties of 7xxx series aluminum alloys with Zr and Sc. *Materials Characterization*, 182, 111559. <https://doi.org/10.1016/j.matchar.2021.111559>
- Yazid, M. Z. A., & Zainol, A. (2019). Environmentally Friendly Approaches Assisted Machining of Aluminum Alloy 7075-T6 for Automotive Applications: A Review. *International Journal of Integrated Engineering*, 11(6), 18-26. <https://penerbit.uthm.edu.my/ojs/index.php/ijie/article/view/3556>
- Yu, Z., Ye, S., Sun, Y., Zhao, H., & Feng, X.-Q. (2021). Deep learning method for predicting the mechanical properties of aluminum alloys with small data sets. *Materials Today Communications*, 28, 102570. <https://doi.org/10.1016/j.mtcomm.2021.102570>
- Zhang, P., Liu, J., Gao, Y., Liu, Z., & Mai, Q. (2023). Effect of heat treatment process on the micro machinability of 7075 aluminum alloy. *Vacuum*, 207, 111574. <https://doi.org/10.1016/j.vacuum.2022.111574>

- Zhang, Q., Yang, L. T., Chen, Z., & Li, P. (2018). A survey on deep learning for big data. *Information Fusion*, 42, 146-157. <https://doi.org/10.1016/j.inffus.2017.10.006>
- Zhang, Y., Yang, H., Sun, P., Huang, R., Zheng, S., Duan, Y., & Li, M. (2024). Effect of Aging Time on Precipitation of MgZn₂ and Microstructure and Properties of 7075 Aluminum Alloy. *Journal of Materials Engineering and Performance*, 33(13), 6601-6611. 10.1007/s11665-023-08426-y
- Zhou, B., Liu, B., Zhang, S., Lin, R., Jiang, Y., & Lan, X. (2021). Microstructure evolution of recycled 7075 aluminum alloy and its mechanical and corrosion properties. *Journal of Alloys and Compounds*, 879, 160407. <https://doi.org/10.1016/j.jallcom.2021.160407>

