



**KARBON ÇELİKLERİNİN MİKROYAPI GÖRÜNTÜLERİNDEN
MEKANİK ÖZELLİKLERİNİN DERİN ÖĞRENME İLE TAHMİNİ**

Rıdvan SERT

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2024

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Rıdvan SERT

24/07/2024

KARBON ÇELİKLERİNİN MİKROYAPI GÖRÜNTÜLERİNDEN MEKANİK ÖZELLİKLERİNİN DERİN ÖĞRENME İLE TAHMİNİ

(Yüksek Lisans Tezi)

Rıdvan SERT

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2024

ÖZET

Malzeme biliminde, bir malzemenin mikroyapısı ile mekanik özellikleri arasında yakın bir ilişki olduğu bilinmektedir. Bu çalışmada, AISI 1040 çeliğinin oda sıcaklığındaki çekme özelliklerinin, mikroyapı görüntülerinden yapay zeka ile tahmin edilmesi hedeflenmiştir. Bu amaçla, standartlara uygun çekme numuneleri hazırlanmış ve çekme testine tabi tutulmuştur. Numunelerin deforme olmayan bölgelerinden alınan mikroyapı resimleri ile ferrit ve perlit hacim oranları hesaplanmıştır. Oluşturulan veri kümesi kullanılarak, Evrişimli Sinir Ağı modeli ile akma, çekme ve kopma gerilimi değerleri tahmin edilmiştir. Sonuçlar, mikroyapı görüntülerinden AISI 1040 çeliğinin mekanik özelliklerinin başarıyla tahmin edilebileceğini göstermiştir. Çalışma sonucunda Ortalama Kare Hatası 4,36; Kök Ortalama Kare Hatası 2,08; Ortalama Mutlak Hata 1,66; R-Kare 0,99 skorları elde edilmiştir.

Bilim Kodu : 92432

Anahtar Kelimeler : AISI 1040 çeliği, mikroyapı, mekanik özellikler, derin öğrenme, evrişimli sinir ağı

Sayfa Adedi : 37

Danışman : Doç. Dr. Fecir DURAN

PREDICTION OF MECHANICAL PROPERTIES OF CARBON STEELS BY DEEP
LEARNING FROM MICROSTRUCTURE IMAGES

(M. Sc. Thesis)

Rıdvan SERT

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2024

ABSTRACT

In materials science, it is known that there is a close relationship between the microstructure of a material and its mechanical properties. This study aimed to predict the tensile properties of AISI 1040 steel at room temperature using artificial intelligence from microstructure images. For this purpose, tensile specimens were prepared according to the standards and subjected to tensile tests. Microstructure images were taken from the undeformed regions of the specimens and the ferrite and pearlite volume fractions were calculated. Using the created dataset, yield strength, tensile strength and fracture stress values were predicted with a Convolutional Neural Network model. The results showed that the mechanical properties of AISI 1040 steel can be successfully predicted from microstructure images. The study yielded Mean Squared Error of 4.36; Root Mean Squared Error of 2.08; Mean Absolute Error of 1.66; and R-Squared score of 0.99.

Science Code : 92432

Key Words : AISI 1040 steel, microstructure, mechanical properties, deep learning, convolutional neural network

Page Number : 37

Supervisor : Assoc. Prof. Fecir DURAN

TEŞEKKÜR

Sayın hocam Doç. Dr. Fecir DURAN'a, araştırma sürecindeki rehberliği, desteği ve sabrı için en içten teşekkürlerimi sunarım. Onun engin bilgi birikimi ve deneyimi, bu çalışmanın her aşamasında bana ilham verdi ve yol gösterdi. Her zaman yanımda olduğunu bilmek, beni motive etti ve zorlukların üstesinden gelmemi sağladı. Kendisine sonsuz minnettarlığımı ve derin saygılarımı sunarım. Çalışmamın gelişiminde önemli katkıları olan saygı değer hocalarım Doç. Dr. Volkan KILIÇLI ve Öğr. Gör. Ömer ŞAHİN'e de teşekkürlerimi sunmak isterim. Onların değerli önerileri ve desteği, araştırmamın kalitesini artırmada önemli bir etken olmuştur. Mensubu olduğum Gazi Üniversitesi Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü'nde görev yapan tüm hocalarıma teşekkür ederim. Bu çalışmanın her aşamasında yanımda olan ve bana sürekli destek olan babam Türkay SERT, annem Hicran SERT ve kardeşim Bekir SERT'e en derin teşekkürlerimi sunarım. Onların sabrı, sevgisi ve teşviki, bu süreci daha kolay ve anlamlı kılmıştır.

İÇİNDEKİLER

	Sayfa
ÖZET	v
ABSTRACT.....	vi
TEŞEKKÜR.....	vii
İÇİNDEKİLER	viii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
RESİMLERİN LİSTESİ.....	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	3
2.1. Kimyasal Bileşen ve Isıl İşlem Parametreleri Kullanılan Çalışmalar	5
2.2. Mikroyapı Resimleri Kullanılan Çalışmalar.....	6
3. MATERYAL VE METOT.....	9
3.1. Malzeme.....	9
3.2. Çekme Testi	10
3.3. Metalografik Numune Hazırlığı	11
3.4. Mikroyapı İnceleme ve Resimlerin Alınması.....	12
3.5. Veri Kümesinin Hazırlanması	13
3.6. Evrişimli Sinir Ağı (ESA).....	16
3.7. Google Colab	18
3.8. Performans Metrikleri	18

Sayfa

4. DENEYSEL SONUÇLAR.....	21
4.1. Çekme Deneyi Sonuçları	21
4.2. Mikroyapı Görüntülerinin Analizi ve ESA Sonuçları.....	23
5. SONUÇ VE DEĞERLENDİRME.....	31
KAYNAKLAR	32
ÖZGEÇMİŞ	37



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. AISI 1040 çeliğinin kimyasal kompozisyonu (ağırlıkça %)	10
Çizelge 3.2. Veri artırımı yapıldıktan sonra ferrit hacim oranına göre elde edilen görüntü sayıları	16
Çizelge 4.1. Çekme testi sonucunda elde edilen mekanik özellik verileri	22
Çizelge 4.2. Hadde yönü kesitindeki resimlerin ferrit hacim oranları (%) ve ortalamaları	24
Çizelge 4.3. Haddeye dik kesitindeki resimlerin ferrit hacim oranları (%) ve ortalamaları	25
Çizelge 4.4. ESA’da kullanılan hiper-parametreler, değerleri ve açıklamaları	26
Çizelge 4.5. Farklı batch size ve epoch değerlerinde elde edilen sonuçlar	27

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Çalışmanın metodolojisi	9
Şekil 3.2. Deneylerde kullanılan çekme numunesinin boyutları	11
Şekil 3.3. Hadde yönü ve haddeye dik kesitlerin çekme numunesi üzerinde gösterimi.	12
Şekil 3.4. Veri kümesinin hazırlanması işlemleri	13
Şekil 3.5. 3.numunenin haddeye dik kesitinden elde edilen bölgelerin ısı haritası	16
Şekil 3.6. ESA'nın katmanları	17
Şekil 4.1. 12 numunenin çekme eğrileri	21
Şekil 4.2. a) Haddeye dik ve hadde yönünde mikroyapı alınan bölgelerin şematik gösterimi ve b) Hadde yönü ve haddeye dik kesitlerden alınan mikroyapı resimleri	23
Şekil 4.3. Eğitim ve doğrulama kaybı fonksiyonlarının grafiği.....	29

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Instron 3369 üniversal test cihazı	11
Resim 3.2. Leica DMI500M optik mikroskobu.....	13



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

m	metre
mm	milimetre
MPa	megapaskal
dk	dakika

Açıklamalar

Kısaltmalar

Açıklamalar

AISI	American Iron and Steel Institute-Amerikan Demir ve Çelik Enstitüsü
ASTM	American Society for Testing and Materials-Amerikan Test ve Malzeme Derneği
ÇKA	Çok Katmanlı Algılayıcı
ÇSR	Çekirdekli Sırt Regresyonu
DSA	Derin Sinir Ağı
DVM	Destek Vektör Makinesi
DVR	Destek Vektör Regresyonu
EKKGA	En Küçük Kareler Güçlendirilmiş Ağaç
ESA	Evrişimli Sinir Ağı
GSR	Gauss Süreç Regresyonu
ISO	International Standart of Organization-Uluslararası Standart Organizasyonu
K-EYK	K-En Yakın Komşu
KOKH	Kök Ortalama Kare Hatası
KTB	Kapı Tekrarlayan Birim
MOTESA	Maksimum Oylamalı Tamamen Evrişimli Sinir Ağı
OKH	Ortalama Kare Hatası
OMH	Ortalama Mutlak Hata
R2	R-Kare

Kısaltmalar**Açıklamalar****RO**

Rastgele Orman

SR

Sembolik Regresyon

UKSB

Uzun-Kısa Süreli Bellek

YSA

Yapay Sinir Ağı



1. GİRİŞ

Malzemelerin mekanik özelliklerinin belirlenmesi, mühendislik ve malzeme bilimi alanlarında kritik bir rol oynar ve bu özelliklerin doğru bir şekilde ölçülmesi, malzemelerin performansını anlamak ve uygun uygulamalarda kullanmak için hayati önem taşımaktadır. Mekanik özellikler, çekme gerilimi, sertlik, süneklik, kırılma tokluğu ve yorulma gerilimi gibi parametreleri içermekte ve genellikle laboratuvar ortamlarında gerçekleştirilen mekanik testler yoluyla belirlenmektedir [1]. Örneğin, çekme testleri, malzemenin kopmadan önce ne kadar gerilim taşıyabileceğini belirlerken, sertlik testleri malzemenin yüzeyine uygulanan bir kuvvete karşı direncini ölçmektedir [2]. Darbe testleri malzemenin kırılma tokluğunu değerlendirirken, yorulma testleri tekrarlanan yüklemeler altında malzemenin dayanıklılığını incelemektedir [3]. Bu testler, standartlara uygun olarak dikkatle yürütülmelidir ve genellikle ASTM (American Society for Testing and Materials- Amerikan Test ve Malzeme Derneği) veya ISO (International Standart of Organization- Uluslararası Standart Organizasyonu) gibi uluslararası standartlara dayanmaktadır [2].

Mekanik özelliklerin belirlenmesinde çeşitli zorluklarla karşılaşılabilir. Bu zorluklar arasında testlerin doğru ve tekrarlanabilir bir şekilde yapılması, numunelerin hazırlanması ve çevresel koşulların kontrolü yer almaktadır. Özellikle, mikro yapısal heterojenlikler ve test ekipmanlarının kalibrasyonu, sonuçların doğruluğunu etkileyebilmektedir [4]. Ayrıca, test sırasında oluşabilecek hatalar ve insan faktörü de önemli bir etken olabilmektedir. Farklı malzeme türlerinin farklı test yöntemleri gerektirmesi de süreci karmaşıklştırabilmektedir. Örneğin, kompozit malzemeler ve polimerler, metalik malzemelere göre farklı mekanik davranışlar sergileyebilir ve bu nedenle farklı test protokolleri gerektirebilmektedir [5]. Bu zorlukların üstesinden gelmek için, test prosedürlerinin dikkatle planlanması, modern test ekipmanlarının kullanılması ve deneysel hataların minimize edilmesi gereklidir. Bunun yanı sıra, mikroyapısal analizler ve termal özelliklerin incelenmesi gibi tamamlayıcı yöntemler, mekanik özelliklerin daha iyi anlaşılmasına katkıda bulunabilmektedir [3].

Son yıllarda, Derin Öğrenme tekniklerinin kullanımı, malzemelerin mekanik özelliklerinin belirlenmesini önemli ölçüde kolaylaştırmıştır. Derin Öğrenme algoritmaları, büyük veri kümeleri üzerinde eğitilerek, malzemelerin mekanik özelliklerini tahmin etme ve analiz

etmede yüksek doğruluk oranları sunmaktadır. Bu yöntemler, özellikle karmaşık ve zaman alıcı test süreçlerinin yerini alabilecek hızlı ve etkili alternatifler sunmaktadır.

Bu tez çalışması, AISI (American Iron and Steel Institute-Amerikan Demir ve Çelik Enstitüsü) 1040 çeliğinin mikroyapı görüntülerinden oda sıcaklığındaki çekme özelliklerinin Derin Öğrenme Yöntemi olan Evrişimli Sinir Ağı (ESA) ile tahmin edilmesini konu almaktadır. AISI 1040 çeliği, yaygın kullanım alanı olan düşük karbonlu bir çelik türüdür ve mekanik özellikleri mikroyapısındaki ferrit ve perlit fazlarının oranı ve dağılımına bağlıdır. Mikroyapı görüntülerinden ferrit ve perlit fazlarının hacim oranları hesaplanmış ve bu verilerle birlikte çekme testi sonuçları kullanılarak bir veri seti oluşturulmuştur. Daha sonra, ESA tabanlı bir derin öğrenme modeli geliştirilerek, mikroyapı görüntülerinden akma gerilimi, çekme gerilimi ve kopma gerilimi gibi mekanik özellikler tahmin edilmiştir.

2. LİTERATÜR TARAMASI

Derin Öğrenme, Yapay Sinir Ağı'nın (YSA) daha büyük ve karmaşık modellerle geliştirilmesiyle ortaya çıkmış bir alan olup, büyük veri kümeleri üzerinde etkili öğrenme yapabilen algoritmaların geliştirilmesine olanak tanımıştır. Bu teknolojinin gelişimi birkaç önemli aşamadan geçmiştir. YSA'nın temel prensipleri, biyolojik beyin yapısına dayanan basit modellerle ortaya konulmuştur. Algılayıcı gibi erken dönem modeller, temel sınıflandırma görevlerinde kullanılmıştır. Algılayıcı, bir dizi giriş sinyali ve her bir giriş sinyali için bir ağırlık içermektedir. Ağırlıklar, her bir giriş sinyalinin önemini temsil etmektedir. Giriş sinyalleri, ağırlıkları ile çarpıldıktan sonra toplanmaktadır ve bir aktivasyon fonksiyonundan geçirilmektedir. Aktivasyon fonksiyonu, toplamı bir çıktı sinyaline dönüştürmektedir. Algılayıcılar, bir dizi örnek veri kullanılarak eğitilmiştir. Her örnek verisinde, bir dizi giriş sinyali ve istenen bir çıktı sinyali bulunmaktadır. Algılayıcı, giriş sinyallerini almaktadır ve tahmini bir çıktı sinyali üretmektedir. Tahmini çıktı sinyali, istenen çıktı sinyali ile karşılaştırılmaktadır ve bir hata hesaplanmaktadır. Bu hata, algılayıcının ağırlıklarını güncellemek için kullanılmaktadır. Bu işlem, algılayıcı istenen çıktıyı üretebilecek kadar iyi olana kadar tekrarlanmaktadır [6].

Geriye Yayılım Algoritması YSA eğitimi için yaygın olarak kullanılan ve hataları minimize etmek amacıyla ağırlıkların güncelleyen bir algoritmadır. İleri yayılım aşamasında giriş verileri ağırlıkların her bir katmanından geçirilerek nihai çıktı üretilmektedir ve her nöron, aktivasyon fonksiyonu kullanarak giriş sinyallerini işlemektedir. Çıktı ile istenen değer arasındaki fark hata olarak hesaplanmaktadır ve bu hata genellikle Ortalama Kare Hatası (OKH) veya Çapraz Entropi gibi bir kayıp fonksiyonu ile belirlenmektedir. Geri yayılım aşamasında, bu hata ağırlıkların son katmanından başlanarak geri yayılmaktadır ve her katmanda hata, ağırlıkların gradyanlarına göre hesaplanarak ağırlıklar güncellenmektedir. Böylece, ağırlıkların performansı optimize edecek şekilde ağırlıklar iteratif olarak ayarlanmaktadır [7].

ESA özellikle görsel veri analizi alanında güçlü bir YSA mimarisidir. ESA'lar, görsel verideki örüntüleri keşfetmek ve özneliklerini çıkarmak için giriş verisini evrişim ve havuzlama katmanları aracılığıyla işlemektedir. Bu mimari, özellikle görüntü tanıma, nesne tespiti, yüz tanıma ve video analizi gibi alanlarda kullanılmaktadır [8]. AlexNet,

VGG, ResNet gibi birçok gelişmiş ESA mimarisi, daha da karmaşık ve genelleyici öz nitelikler çıkarmak için ağların yeteneklerini artırmıştır [9-11]. Bu gelişmeler; tıbbi görüntüleme, otonom araçlar, yüz tanıma, tarım teknolojileri ve daha birçok alanda ESA'ların kullanımını yaygınlaştırmıştır.

Esteva ve arkadaşlarının yaptığı çalışmada, ESA kullanılarak cilt kanserlerinin sınıflandırılması yapılmıştır [12]. Çalışmada, 2032 hastalıktan oluşan 129450 klinik görüntüsü kullanılmıştır. Cilt lezyonu sınıflandırması konusunda, ESA kullanılmıştır ve üç farklı teşhis görevinde test edilen en az 21 dermatoloğun performansı eşleştirilmiştir. Bu yöntem, mobil cihazlara uygulanabilmiştir ve dermatoloji uzmanlarının klinik karar alma süreçlerinin güçlendirilmesi de dahil olmak üzere önemli klinik etki potansiyeline sahip olduğu tespit edilmiştir.

Bojarski ve arkadaşlarının yaptığı çalışmada, araçların otonom olarak yol ve şerit takibi görevlerini yerine getiren bir sistem üzerinde çalışılmıştır [13]. Çeşitli yol ve hava koşullarında 72 saat boyunca bir kamera kullanılarak veriler toplanmıştır. Toplanan verilere ESA uygulanmış, aracın direksiyonuna belirli komutlar gönderilmiş ve aracın yol üzerinde kalıp şerit takibi gerçekleştirmesine olanak sağlanmıştır.

Schroff ve arkadaşları, yüz görüntülerinden elde edilen mesafelerin doğrudan kompakt Öklid uzayına haritalamayı öğrenen, FaceNet adı verilen bir sistem sunmuşlardır [14]. Yüz tanıma, doğrulama ve kümeleme gibi görevler, öz nitelik vektörleri olarak FaceNet yerleştirmeleri ile standart teknikler uygulanmıştır. Yerleştirmenin kendisini doğrudan optimize etmek için eğitilmiş ESA kullanılmıştır. 128 bayt yüzey kullanılarak yüksek verimliliğe sahip yüz tanıma performansına ulaşılmıştır.

Jung ve arkadaşları, ESA kullanarak patates, domates ve dolmalık biberde hastalık tespiti üzerinde çalışmışlardır [15]. Yapılan çalışmada; ürün sınıflandırması, hastalık tespiti ve hastalık sınıflandırması olarak üç aşamalı bir model kullanılmıştır. Modellerde; ResNet50, AlexNet, GoogleNet, VGG19 ve EfficientNet Transfer Öğrenme yöntemleri kullanılmıştır. Bu modeli endüstriyel alana uygulamak için daha önce kullanılmayan mahsullerin görüntüleri kullanılarak veri kümesinde olmayan mahsuller belirlenmiştir.

Metalurji ve Malzeme biliminde, mekanik özelliklerin tahmini için yapılan birçok çalışma bulunmaktadır. Yapılan çalışmalarda malzemenin kimyasal bileşeni, maddeye ısı işlem uygulanırken kullanılan parametreler, mikroyapı resimleri gibi veriler kullanılmıştır. Bu veriler kullanılarak malzemenin mekanik özellikleri tahmin edilmeye çalışılmıştır. Yapılan çalışmalar iki başlık altında aşağıdaki başlıklarda verilmiştir.

2.1. Kimyasal Bileşen ve Isıl İşlem Parametreleri Kullanılan Çalışmalar

Wang ve arkadaşlarının yaptığı çalışmada, altı farklı Makine Öğrenmesi algoritması kullanılarak maksimum çekme gerilimi, akma gerilimi ve toplam uzama mekanik özelliklerinin tahmin edilmesi üzerinde durulmuştur [16]. YSA, Gauss Süreç Regresyonu (GSR), Destek Vektör Makinesi (DVM), Rastgele Orman (RO), En Küçük Kareler Güçlendirilmiş Ağaç (EKKGA) ve K-En Yakın Komşu (K-EYK) algoritmaları kullanılmıştır. Çelik veri kümesi ile yapılan tahminlerin en iyi sonuçları, optimize edilmiş bir GSR modeli ile elde edilmiştir. Bu modelin, yeni bilgilerin edinilmesi konusunda güçlü olmasının yanı sıra, fazla uyum göstermeyerek iyi bir genelleme kapasitesine sahip olduğu gözlemlenmiştir. Bu durum, malzeme tasarımı alanında etkili bir araç olabileceğini işaret etmektedir.

Xu ve arkadaşlarının yaptığı çalışmada, ilk olarak Uzun-Kısa Süreli Bellek (UKSB), Kapı Tekrarlayan Birim (KTB) ağı ve GSR modeli kullanılarak derin çekme çeliklerinin mekanik özellikleri tahmin edilmiş bununla birlikte farklı modeller üzerindeki tahminin doğruluğu ve öğrenme verimliliği tartışılmıştır [17]. Sonrasında yeniden öğrenme yöntemleri, transfer öğrenme modelleri ve model parametreleri için önerilmiştir. En başarılı sonuçlar KTB modelinde alınmıştır.

Shaheen ve arkadaşlarının yaptığı çalışmada, yüksek mukavemetli çelik plaka malzemesinin yüksek sıcaklıklardaki mekanik özelliklerini tahmin etmek için bir yöntem geliştirilmiştir [18]. Yöntem, sıcaklık ve kimyasal bileşimi girdi olarak kullanarak, Derin Sinir Ağı (DSA) ile yüksek sıcaklık malzeme verileri üzerinde eğitilmiştir. Sonuçlar, eğitilmiş DSA algoritmasının yüksek doğrulukla tahmin yapabildiğini ve bu sayede yangın güvenliğinde önemli katkılar sağlayabileceğini göstermektedir.

Diao ve arkadaşlarının yaptığı çalışmada, çeliklerin çekme gerilimi, kopma gerilimi, Charpy darbe tokluğu, sertlik, yorulma dayanımı ve toplam uzama gibi mekanik özelliklerini tahmin etmek için beş farklı Makine Öğrenmesi algoritması kullanılmıştır [19]. Destek Vektör Regresyonu (DVR), Çok Katmanlı Algılayıcı (ÇKA), K-EYK, Çekirdekli Sırt Regresyonu (ÇSR) ve RO modelleri üzerinde testler gerçekleştirilmiştir. Bu sayede çeliklerin gelişiminde yeni stratejiler sunulmuştur.

Choudhury'nin yaptığı çalışmada, sıcak haddeleme, soğuk çekme, tavlama ve küresel tavlama gibi farklı ısıtma işleme yöntemleriyle üretilen çeşitli çeliklerin akma mukavemeti ve uzama gibi mekanik özelliklerini tahmin etmek için bir model önerilmiştir [20]. Model, bu yöntemlerle üretilmiş geniş bir veri kümesi kullanılarak geliştirilmiştir. Modelin başarısı, OKH ve R2 gibi metriklerle değerlendirilmiştir. 129 farklı veri örneği için yapılan testlerde model, akma gerilimi ve uzama tahminlerinde sırasıyla %99,95 ve %99,05 R2 değerlerine ulaşmıştır. Bu sonuçlar, modelin yüksek doğruluk ve güvenilirliğe sahip olduğunu göstermiştir.

Xiong ve arkadaşlarının yaptığı çalışmada, Japonya Ulusal Malzeme Bilimi Enstitüsü veri tabanından alınan karbon çelikleri ve düşük alaşımlı çeliklere ait dört mekanik özellik (yorulma dayanımı, çekme gerilimi, kopma gerilimi ve sertlik) için 360 veri örneği incelenmiştir [21]. Bu malzemelerin mekanik özelliklerini tahmin etmek için beş farklı Makine Öğrenmesi algoritması kullanılmış ve RO modeli en iyi tahmin performansını göstermiştir. RO ve Sembolik Regresyon (SR) ile yapılan öznetelik seçimi, çeliklerin mekanik özelliklerini en çok etkileyen dört önemli faktörü belirlemiştir. Bu faktörler; çeliğin temperleme sıcaklığı ve karbon, krom ve molibden alaşım elementleridir. SR modelinin yeni ve gelişmiş malzemelerin keşfinde büyük bir potansiyele sahip olduğunu ortaya koymaktadır.

2.2. Mikroyapı Resimleri Kullanılan Çalışmalar

Azimi ve arkadaşlarının yaptığı çalışmada, düşük karbonlu çeliğin belirli mikroyapısal bileşenlerinin örneklerinde mikroyapısal sınıflandırma için bir Derin Öğrenme yöntemi önerilmiştir [22]. Bu yöntem, Maksimum Oylamalı Tamamen Evrişimli Sinir Ağı (MOTESA) piksel bazlı segmentasyon kullanmaktadır. Önerilen modelin çelik kalite değerlendirmesinde daha başarılı olduğu gösterilmiştir.


Muñoz-Rodenas ve arkadaşları tarafından, çelik mikroyapılarının görüntü sınıflandırılmasında farklı Makine Öğrenmesi tekniklerinin sonuçlarını karşılaştırma amaçlanmıştır. Bu çalışmada, üç farklı ısıtma işlemine tabi tutulmuş çelik örnekleri kullanılmıştır [23]. Isıtma işlemleri; tavlama, su verme ve temperleme ile su verme olarak verilmiştir. Çalışmada kullanılan görüntüler, 400x büyütme ile optik mikroskop kullanılarak farklı düşük karbonlu çeliklerden elde edilmiştir. Öğrenme modelleri, ilgili ısıtma işlemlere dayanarak üç sınıfa ayrılan bir görüntü veri kümesi ile oluşturulmuştur. Görüntü sınıflandırılmasında Klasik Makine Öğrenmesi yöntemleri ile GoogLeNet ve ResNet50 Transfer Öğrenme yöntemi kullanılmıştır. Transfer Öğrenme yöntemlerinde, Makine Öğrenmesi yöntemlerine kıyasla daha başarılı sonuçlar elde edilmiştir.

Cheloe Darabi ve arkadaşlarının yaptığı bu çalışmada, farklı ısıtma işlem koşullarında çift fazlı çelik mikroyapıları, mekanik davranışlarının deneysel olarak doğrulanmış faz alanı simülasyonları ve sonlu eleman analizinden oluşan bir veri kümesi oluşturulmuştur [24]. ResNet50 ve VGG16'nın, hibritleştirildiği bir Derin Öğrenme tabanlı yöntem sunulmuştur. Bu Hibrit yöntem kullanılarak, çift fazlı çeliklerin yeni işlem koşullarında akma gerilimi, çekme gerilimi ve kopma gerilimi %1'in altında hata ile tahmin edilmiştir.



3. MATERYAL VE METOT

Tez çalışmasında ilk olarak, çekme testi uygulanmış ve numuneler belirli bir gerilim altında kırılmıştır. Bu test sonucunda, akma, çekme ve kopma gerilim değerleri kaydedilmiştir. Ardından, mikroyapı görüntülerini elde etmek için metalografik numune hazırlama süreci tamamlanmıştır. Hazırlanan metalografik numunelerin mikroskop altında resimleri çekilmiş ve ferrit hacim oranlarının analizi gerçekleştirilmiştir. Elde edilen resimler ve analiz verileri kullanılarak bir veri kümesi oluşturulmuştur. Bu veri kümesinde, görüntü artırımı ve ferrit hacim oranına göre ayıklama işlemleri uygulanmıştır. Hazır hale getirilen veri kümesi, ESA algoritmasına giriş olarak kullanılmış ve bu algoritma üzerinde eğitim yapılmıştır. Sonuç olarak, ESA ile akma, çekme ve kopma gerilim değerleri tahmin edilmiştir, metodoloji Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Çalışmanın metodolojisi [29]

3.1. Malzeme

Karbon çelikleri, yaklaşık %2'den daha az miktarlarda karbon içeren çeliklerdir. İnşaat sektöründe; sac metal, borular, tel ve çivi üretiminde, otomotiv sektöründe; motor parçaları, dişliler ve yaylarda, makine imalatında ise şaftlarda, dişlilerde ve rulmanlarda kullanılırlar. Karbon çelikleri içerdikleri karbon miktarına göre genellikle düşük, orta ve yüksek karbonlu çelik olarak üçe ayrılırlar [25].

Düşük karbonlu çelikler, %0,02 ile %0,3 arasında karbon içeriği bulunan çeliklerdir. Kolay şekillenebilir ve kaynaklanabilirler. Bu yüzden mukavemetleri ve sertlikleri düşüktür [26].

Orta karbonlu çeliklerde, %0,29 ile %0,60 arasında karbon içerirler. Sünegliği ve mukavemeti dengelidir. Isıl işlem uygulanarak sertleştirilebilirler [27].

Yüksek karbonlu çelikler, %0,6 ile %1,25 arasında karbon içeriğine sahip çeliklerdir. Sertliği ve dayanıklılığı yüksektirler. Yüksek dayanım gerektiren uygulamalarda kullanılırlar ve karbon çelikleri arasında en yüksek sertliğe ve en düşük sünegliğe sahiptirler [26].

Bu tez çalışmasında, AISI 1040 çeliği kullanılmıştır. Aydınlar Makine ve Metal Ltd. Şti. firmasından temin edilen AISI 1040 çeliği, sıcak haddelenmiş ve 10mm çapında, 6m boyunda silindirik haldedir. Kullanılan çeliğin kimyasal bileşimi Çizelge 3.1’de verilmiştir.

Çizelge 3.1. AISI 1040 çeliğinin kimyasal kompozisyonu (ağırlıkça %) [28]

C	Si	Mn	P	S	Cu
0,395	0.251	0.6	0.025	0.015	0.012

3.2. Çekme Testi


Çekme testi, malzemelerin mekanik özelliklerini belirlemek için yapılan malzeme biliminde uygulanan bir testtir. Malzemeden hazırlanan numune, x eksenı boyunca kuvvet uygulanabilecek şekilde hazırlanır. Malzemenin en yüksek gerilime maruz kalabilmesi için numunenin merkez kısmının genişliğinin azaltılması gerekmektedir. Numunenin bir ucu sabit kalırken diğer ucu sabit bir hızla hareket edebilen çapraz kafaya sabitlenmektedir. Çekme testi, numune kopuncaya kadar devam ettirilmektedir. Kopma işlemi gerçekleştiğinde numune deformasyona uğramakta ve numunenin maksimum yük taşıma kapasitesi, akma, çekme ve kopma gerilimi gibi mekanik özellikleri hesaplanmaktadır [29-30].

Çekme testleri, 1mm/dk hızla Instron 3369 test cihazı ile yapılmıştır. Instron 3369 cihazının karşıdan görüntüsü Resim 3.1’de gösterilmiştir.



Resim 3.1. Instron 3369 üniversal test cihazı [31]

Instron 3369 test cihazında toplam 12 adet AISI 1040 çeliği üzerinde çekme işlemi uygulanmıştır ve çekme numunesinin boyutları Şekil 3.2’de verilmiştir.




Şekil 3.2. Deneylerde kullanılan çekme numunesinin boyutları [28]

3.3. Metalografik Numune Hazırlığı

Metalografi, metallerin yapısal özelliklerinin değerlendirilmesi üzerinde çalışmakta olan bir bilim dalıdır. Metalurjik testlerin sonucunda tutarlı veriler elde etmek için metalografik numunelerin doğru bir şekilde hazırlanması gerekmektedir. Yetersiz hazırlanmış numuneler, malzeme kusurlarının yanlış yorumlanması neden olabilmektedir [32].

İlk olarak çekme işlemi yapılan çeliklerin hadde yönü ve haddeye dik kesitleri belirlenmiştir. Bu kesitler Şekil 3.3’te gösterilmiştir.



Şekil 3.3. Hadde yönü ve haddeye dik kesitlerin çekme numunesi üzerinde gösterimi [28]

Daha sonra Şekil 3.3'te gösterildiği gibi kırmızı okların yönünde kesilerek her iki kesitten örnek alınmıştır. Bu örneklerle montaj işlemi yapılması gerekmektedir. Montaj işlemi, alınan örneklerin sıcak veya soğuk şekilde ayarlanan reçine içine gömülmesi işlemidir [33]. Bu işlem, alınan örneklerin bir arada durması ve örneklerin boyutlarının küçük olmasından dolayı hem taşınabilirliği artırmakta hem de kenarlarının korunmasını sağlamaktadır. Alınan örnekler, bir montaj yöntemi olan bakalite alma işlemiyle kalıplama yapılmıştır. Örnekler, reçine ile birlikte yüksek sıcaklık ve basınca maruz bırakılmıştır.

Montaj işleminden sonra zımparalama yapılmıştır. Zımparalama işlemi, kesme işlemi sırasında deforme olmuş yüzeylerin pürüzlülüğünü azaltmak amacıyla yapılan bir işlemdir [33]. Bu işlem yapılırken zımpara kağıtları, dönen bir yüzeyin üzerine oturtularak dönmesi sağlanır ve zımpara kağıtlarının üzerine de kalıplama yapılan örnekler yerleştirilir.

Zımparalama yapıldıktan sonra, zımparalama işlemi sırasında numunelerin üzerinde oluşan çiziklerin giderilmesiyle amacıyla parlatma yapılmıştır. Sonrasında mikroyapısal özelliklerin ortaya çıkarılması yani mikroskop altında inceleme yapılırken malzemenin tane yapıları, faz dağılımlarının görüntülenebilmesi için %2 Nital çözeltisi kullanılarak dağlama yapılmıştır.

3.4. Mikroyapı İnceleme ve Resimlerin Alınması

Mikroyapı, bir malzemenin mikroskobik ölçekteki iç yapısıdır. Malzemenin mekanik özelliklerini belirlemektedir. İçinde kristal yapılar, tane sınırları, fazlar gibi çeşitli bileşenler içermektedir [34]. Faz; bir malzemenin belirli bir kimyasal bileşimi, kristal yapısı ve fiziksel özellikleri olan homojen bir bölgesidir. Malzemelerin mikroyapısında çeşitli fazlar bulunabilir ve bu fazlar, malzemenin genel özelliklerini büyük ölçüde etkiler. Fazlardan ferrit fazı, düşük karbonlu çeliklerde genellikle baskındır ve sünekliğin yüksek, sertliğin ise düşük olmasına katkı sağlar [35].

Bu tez çalışmasında; optik mikroskopla mikroyapılar görüntülenip JPEG formatında resimler alınmış, incelenmiş ve ferrit hacim oranlarına bakılmıştır. Mikroyapılar, Resim 3.2'deki Leica DMI500M optik mikroskobu ile görüntülenmiştir. Her bir numunenin haddeye dik ve hadde yönü kesitlerinden 9 bölgenin resmi alınarak toplamda 198 adet resim elde edilmiştir.



Resim 3.2. Leica DMI500M optik mikroskobu [36]

Alınan resimlerdeki mikroyapıların ferrit hacim oranları, Leica Application Suite yazılımı ile belirlenmiştir [36]. Alınan sonuçlar Deneyisel Sonuçlar başlığı altında verilmiştir.

3.5. Veri Kümesinin Hazırlanması

Veri kümesinin hazırlanması sürecinde Şekil 3.4'teki işlemler uygulanmıştır.



Şekil 3.4. Veri kümesinin hazırlanması işlemleri

İlk aşamada optik mikroskoptan ile alınan 198 adet resim, alındıkları numunelerin bölgelerine göre isimlendirilmiştir. Dikey ekseninde olan bölgelerden alınan resimlerin dosya isimlerinin başına 'D' harfi, yatay ekseninde olan bölgelerden alınan resimlerin dosya isimlerinin başına ise 'Y' harfi eklenmiştir.

Dosyaların isimlendirmesinden sonra veri artırımı adımına geçilmiştir. Resimlerin boyutu 2560x1920 pikseldir. Resimlerin kalitesinden dolayı dosyaların boyutu büyükmektedir. Bu resimlerin ESA algoritması ile işlenmesi, boyutlarının büyük olmasından dolayı daha fazla işlem yüküne ihtiyaç duymaktadır. Aynı zamanda veri kümesinin büyük olması ESA ile alınan sonuçların daha iyi olmasına katkı sağlayacaktır. Bu yüzden resimlere veri artırımı yapılmıştır. Her bir resim 224x224'lük piksellere bölünmüştür. Bir resimden 108 adet resim elde edilerek toplam 21384 resim elde edilmiştir. Veri artırımı yapılarak hem resimlerin boyutunun indirgenmesi hem de adet olarak sayılarının artırılması amaçlanmıştır.

Sonraki aşamada, veri kümesinin son halini ortaya koyacak olan ferrit hacim oranlarına göre ayıklama işlemi yapılmıştır. Numunelerdeki her bir bölgenin ferrit hacim oranı değişiklik göstermektedir ve bu hacim oranı malzemenin mekanik özelliklerini belirlemede rol oynar. Ferrit hacim oranlarına göre ayıklama işleminin amacı, numunelerin mekanik özelliklerini en iyi belirleyen bölgeleri bulmaktır. Yapılan işlem, hangi bölgelerin ferrit hacim oranının mekanik özellikler üzerinde diğer bölgelere göre en büyük etkiye sahip olduğunu belirlemek için yapılmaktadır. Öncelikle 9 bölgenin ortalaması alınmış ve Denklem 3.1'de gösterilmiştir.

$$\bar{x} = \frac{1}{9} \sum_{i=1}^9 x_i \quad (3.1)$$

$\bar{x}$: 9 bölgenin ferrit oranlarının ortalaması

x_i : i'nci bölgenin ferrit oranı

Ortalamalarda alındıktan sonra histeresiz prensibi kullanılmıştır. Bu prensip doğrultusunda %0,3 değerinde histeresiz marjı seçilmiştir. Histeresiz marjına göre bir histeresiz bandı aralığı elde edilmiştir ve Denklem 3.2'de gösterilmiştir.

$$HBA = [\bar{x} - hm, \bar{x} + hm] \quad (3.2)$$

HBA : Histeresiz bandı aralığı

hm : Histeresiz marjı

Ferrit hacim oranı analizinde sonuçlar üzerinde en çok etkili olacak bölgelerin seçimi kombinasyonlar kullanılarak yapılmıştır. Bu kombinasyonlar belirlenirken, kombinasyon sayısı ve kombinasyonda bulunan bölgelerin sayısının en üst düzeye çıkarılması amaçlanmıştır. Bu sayede, analiz sürecinde elde edilen verilerin kapsamı ve derinliği artırılarak, ferrit hacim oranlarının etkilerinin daha detaylı ve kapsamlı bir şekilde değerlendirilmesi sağlanmıştır. Amaç doğrultusunda 9 bölgenin 5'li kombinasyonları alınmış ve kombinasyonlara dahil olan bölgelerin ferrit hacim oranlarının ortalaması alınmıştır. Denklem 3.3'te gösterilmiştir.

$$\bar{x}_C = \frac{1}{5} \sum_{j \in C} x_j \quad (3.3)$$

$\bar{x}_C$: Kombinasyonlardaki bölgelerin ferrit oranlarının ortalaması

x_j : Kombinasyona dahil olan her bir bölgenin ferrit ortalaması


C : 5 bölgeyi içeren her bir kombinasyon

Kombinasyonlara dahil olan bölgelerin ferrit hacim oranlarının ortalaması, belirlenen histerezis bandı aralığına dahil olduğunda, her bir bölge 1 olarak işaretlenmiştir; aralığa dahil olmadığında ise her bir bölge 0 olarak işaretlenmiştir. Bu işlem, Denklem 3.4'te gösterilmiştir.

$$I(\bar{x}_c) = \begin{cases} 1, & \bar{x}_c \in HBA \\ 0, & \bar{x}_c \notin HBA \end{cases} \quad (3.4)$$

$I(\bar{x}_c)$: İndikatör fonksiyonu

Isı haritasında, 1 olarak işaretlenmiş bölgeler gösterilmiş ve bu bölgelerin sayısı her bir bölgenin üzerinde rakamla belirtilmiştir. Şekil 3.5'te 3. numunenin haddeye dik kesitindeki bölgelerin ısı haritası sunulmuştur



Şekil 3.5. 3.numunenin haddeye dik kesitinden elde edilen bölgelerin ısı haritası [28]

Isı haritasında en çok 1 ile işaretlenen bölgelerin sayısına göre, bu 9 bölgeden en fazla sayıda olan 3 bölge seçilmiştir. Seçilen bölgelerdeki görüntüler, veri kümesinin boyutunu belirlemiştir. Ferrit hacim oranına göre ayıklama yapıldığında, toplamda 7128 görüntü kalmıştır. Veri kümesindeki görüntü sayılarına ilişkin bilgiler Çizelge 3.2'de verilmiştir.

Çizelge 3.2. Veri artırımı yapıldıktan sonra ferrit hacim oranına göre elde edilen görüntü sayıları

	Ferrit Oranına Bakılmadan Görüntü Sayısı	Ferrit Oranına Göre Görüntü Sayısı
Numune Başına Görüntü Sayısı	1944	648
Toplam Görüntü Sayısı	21384	7128

3.6. Evrişimli Sinir Ağı (ESA)

Bir Derin Öğrenme modeli olan ESA, görüntü işleme ve bilgisayarlı görü alanlarında yaygın olarak kullanılmaktadır. Sınıflandırma veya regresyon amaçlı kullanılırlar. Birden fazla katmanlardan oluşmaktadırlar [8]. Bu tez çalışmasında ESA modelinde; giriş, evrişim, havuzlama, tam bağlı ve çıkış katmanları kullanılmıştır.

Giriş katmanı, ESA'nın verileri ilk aldığı katmandır. Bu katman, veriler genellikle bir görüntü veya çok boyutlu verileri içermektedir [37]. Mikroyapı resimleri OpenCV kütüphanesi kullanılarak matrislere dönüştürülmüştür. Daha sonra veriler, giriş katmanına gönderilmiştir.

Giriş katmanından alınan veriler, evrişim katmanına gönderilir. Bu katmanda alınan veriler üzerinde çeşitli filtreler uygulanarak öznitelik haritaları çıkartılır. Verilerdeki belirli bir özelliği tespit etmek için bu filtreler uygulanır. Öznitelikler; kenarlar, köşeler gibi desenler olabilir. 3x3 boyutunda 32, 64, 128'lik filtrelerle sahip 3 adet evrişim katmanı kullanılmıştır. Evrişim katmanının formülü Denklem 3.5'te verilmiştir.

$$(I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (3.5)$$

I : Giriş görüntüsü

K : Filtre

i, j : Giriş görüntüsündeki i . satır ve j . sütundaki piksel değeri

m, n : Filtrenin m . satırdaki ve n . sütundaki değeri

Havuzlama katmanı, verilerin boyutunu düşürerek işlem yükünü azaltmaktadır [38]. Her bir evrişim katmanının hemen ardından 2x2'lik maksimum havuzlama katmanı kullanılmıştır. Maksimum havuzlama katmanında, 2x2'lik filtreler görüntü matrisi üzerinde kaydırılarak en yüksek olan değerler seçilmektedir. Maksimum havuzlama işleminin formülü Denklem 3.6'da verilmiştir.

$$P(i, j) = \max_{0 \leq m < k, 0 \leq n < k} I(s \cdot i + m, s \cdot j + n) \quad (3.6)$$

I : Giriş görüntüsü


k : Filtre penceresinin boyutu

i, j : İşlem sonrasında elde edilen öznitelik haritasının i . satır ve j . sütundaki piksel değeri

s : Filtre penceresinin kayma değeri

Bu katmandan sonra düzleştirme katmanına gelmektedir. Bu katman, tam bağlı katmanda verilerin kullanabilmesi için çok boyutlu öznitelik haritalarını tek boyutlu bir vektöre dönüştürmektedir [39].

Tam bağlı katman, bir YSA yapısıdır. 128 nöron bulunmaktadır. Çıktı katmanında ise sınıflandırma veya regresyon çıktıları üretilir [40]. Çıktı katmanında çeliklerin mekanik özelliklerinden olan akma, çekme ve kopma gerilimi tahmin edilmektedir. Yapılan çalışmadaki ESA katmanları Şekil 3.6'da gösterilmiştir.



Şekil 3.6. ESA'nın katmanları [28]

3.7. Google Colab

Google Colab, Google tarafından sunulan bulut tabanlı bir hizmettir. Bu hizmet, kullanıcıların web üzerinden Python kodlarını yazmaları ve çalıştırmalarını sağlamaktadır. Makine Öğrenmesi, Derin Öğrenme, Veri Analizi gibi konularda yoğun iş yükü gerektiren hesaplama işlerinde kullanılmaktadır. Numpy, Pandas, Tensorflow gibi kütüphaneleri içermektedir. Grafik İşlem Birimi ve Tensör İşlem Birimlerine erişim vermektedir. Bu sayede hesaplamalar hızlı bir şekilde yapılabilmektedir [41].

Tez çalışmasında, Google Colab platformu kullanılarak Derin Öğrenme algoritmaları çalıştırılmıştır.

3.8. Performans Metrikleri

Regresyon analizi, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi araştırmaktadır. Değişkenler arasındaki ilişkiyi modellemek ve analiz etmek için kullanılan istatistiksel bir tekniktir. Bu yöntem tahmin yapmak için kullanılmaktadır [42].

Tez çalışmasında; akma, çekme ve kopma gerilimi tahmini yapılmaktadır. Bu tahmin değerlerinin başarısını değerlendirmek için belirli metrikler bulunmaktadır.

OKH, tahmin edilen değerlerle gerçek değerler arasındaki farkların karelerinin ortalamasıdır ve formülü Denklem 3.7’de gösterilmiştir.

$$OKH = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.7)$$

y_i : Gerçek değerler

$\hat{y}_i$: Modelin tahmin ettiği değerler

n : Örnek sayısı

Kök Ortalama Kare Hatası (KOKH), OKH’nin kareköküdür. Modelin tahmin hatasının büyüklüğünü göstermektedir ve formülü Denklem 3.8’de gösterilmiştir.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.8)$$

y_i : Gerçek değerler

$\hat{y}_i$: Modelin tahmin ettiği değerler

n : Örnek sayısı

Ortalama Mutlak Hata (OMH), tahmin edilen değerlerle gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasıdır ve formülü Denklem 3.9’da gösterilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.9)$$

y_i : Gerçek değerler

$\hat{y}_i$: Modelin tahmin ettiği değerler

n : Örnek sayısı

R^2 , modelin bağımsız değişkenlerin bağımlı değişkeni açıklama oranını göstermektedir. Değer aralığı 0 ile 1 arasındadır; 1’e yakın değerler modelin daha iyi olduğunu göstermektedir. Formülü Denklem 3.10’da gösterilmiştir.

$$R^2 = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.10)$$

y_i : Gerçek değerler

$\hat{y}_i$: Modelin tahmin ettiği değerler


n : Örnek sayısı

$\bar{y}$: Gerçek değerler toplamının örnek sayısına bölünmesiyle elde edilen değer

4. DENEYSEL SONUÇLAR

4.1. Çekme Deneyi Sonuçları

Gerçekleştirilen deneysel çalışmalarda, çekme testleri Instron 3369 model çekme cihazı kullanılarak, 1mm/dk çekim oranı ile gerçekleştirilmiştir. Gerçekleştirilen çekme testleri sonucunda elde edilen değerleri gösterir çekme testi grafiği Şekil 4.1’de verilmiştir. İlgili grafik, kullanılan 12 adet numune için yüzdelik uzamayı temsil eden çekme gerinimini ve numunenin birim kesit alanına düşen yük miktarının MPa cinsinden gösterimi olan çekme gerilimini içermektedir.



Şekil 4.1. 12 numunenin çekme eğrileri [28]

Verilen grafik incelendiğinde, dikey ekseninde siyah üçgen sembolü ile gösterilen üç grubun oluştuğu gözlemlenmektedir. Buradaki dikey ekseninde görülen semboller, sırası ile akma gerilimi, çekme gerilimi ve kopma gerilimi değerlerini göstermektedir.

Akma gerilimi, malzemenin elastik bölgeden plastik bölgeye geçiş yaptığı ve kalıcı şekil değişikliğinin yaşandığı bölgedir. Buna göre, akma gerilimi noktasından itibaren malzeme kalıcı olarak şekil değiştirir ve daha fazla gerilim altında bırakılsa bile yeniden eski haline dönmez [43].

Çekme gerilimi, kullanılan numunenin en yüksek mukavemetini gösterdiği noktadır. Maksimum çekme gerilimi noktasında, numune potansiyel olarak taşıyabileceği en yüksek yükü taşımaktadır. Bu noktadan itibaren, numune üzerindeki gerilme azalır; buna bağlı olarak da malzeme kopma noktasına yaklaşır [44].

Kopma gerilimi, malzemenin kırıldığı ve çekme testinde başarısız olduğu noktayı temsil etmektedir. Kopma gerilimi noktasına ulaşıldıktan sonra malzeme daha fazla yük taşıyamaz ve buna bağlı olarak kopar [45].

Şekil 4.1, yukarıda verilen bilgiler ışığında incelendiğinde görülmektedir ki, numuneler yaklaşık olarak %0 ile %1 çekme gerinimi aralığında akma noktasına ulaşmaktadır. Bu noktadan itibaren test edilen numunelerin elastik sınırlarını aşarak plastik deformasyon bölgesine geçtikleri görülmektedir. Akma noktasının geçilmesinin akabinde, numuneler artan gerilime maruz kalmakta ve yaklaşık 800-850 MPa aralığında maksimum çekme gerilimine ulaşmaktadır. Malzemelerin maksimum taşıma kapasitesi gösterdiği çekme gerilimi eşiğinden sonra ise, dayanımlarının azaldığı ve kopma noktası olan kopma gerilimi noktasına varıldığı görülmektedir. Bu aralıkta, numuneler gerilim altında daha fazla gerinim göstermekte ve sonunda kopma noktasına ulaşmaktadır. Bu aralıkta, gerilme değerlerinde bir düşüş olduğu ancak, gerinimin artmaya devam ettiği görülmektedir.

Buna ek olarak, grafik üzerinde numuneler tarafından elde edilen sonuçlar incelendiğinde, 4. numune dışındaki numunelerin birbirine yakın değerler elde ettiği ancak 4. numunenin diğer numunelere göre erken bir kopma gerçekleştirdiği gözlemlenmektedir. Bu durumun bir sonucu olarak, 4. numunenin deneylerde kullanılmamasına karar verilmiştir. Çekme testi sonucunda elde edilen mekanik özellikler Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Çekme testi sonucunda elde edilen mekanik özellik verileri


Numune	Akma Gerilimi (MPa)	Çekme Gerilimi (MPa)	Kopma Gerilimi (MPa)
1	775,792	861,043	632,402
2	748,917	835,493	608,987
3	781,585	864,121	627,203
4	782,307	868,122	640,007
5	790,801	876,114	638,682
6	787,567	875,252	645,256
7	763,500	850,832	623,157
8	772,354	859,763	639,402
9	753,853	836,325	601,120
10	773,675	859,831	628,430
11	781,448	863,430	625,805
12	765,745	850,719	616,821

Buradaki değerler incelendiğinde, en yüksek akma geriliminin 5. numune tarafından (790.801 MPa) ve en düşük akma geriliminin 2. numune tarafından (748.917 MPa) elde edildiği görülmektedir. Akma gerilimi değerlerine benzer şekilde, en yüksek çekme gerilimi 5. numune (876.114 MPa) ve en düşük çekme gerilimi 2. numune (835.493 MPa) tarafından elde edilmiştir. Kopma gerilimi değerleri incelendiğinde ise, en yüksek kopma gerilimi 6. numunede (645.256 MPa) ve en düşük kopma gerilimi 9. numunede (601.120 MPa) görülmektedir. Bu değerler sonucunda, en yüksek akma ve çekme gerilimi değerlerini elde eden 5. numunenin en dayanıklı numune olduğu, en düşük akma ve çekme değerlerini elde eden 2. numunenin en dayanıksız numune olduğu görülmüştür. Buna ek olarak, kopma gerilimi açısından, en yüksek değere sahip olan 6. numunenin diğer çeliklere kıyasla daha geç kırıldığı gözlemlenmiştir.

4.2. Mikroyapı Görüntülerinin Analizi ve ESA Sonuçları

Mikroyapı resimlerinin alınmasında, Şekil 4.2 (a)'da verilen yöntem temel olarak alınmıştır. Buna göre, her bir numuneden, 9 adet haddeye dik ve 9 adet hadde yönünde olmak üzere toplamda 18 adet mikroyapı resmi alınmıştır. Bütün numunelerden alınan

mikroyapı resimleri ile toplamda 198 adet mikroyapı resminden oluşan bir veri seti oluşturulmuştur. Her bir görüntünün çözünürlüğü 2560x1920 piksel şeklindedir. Numunelerden alınan haddeye dik ve hadde yönündeki mikroyapı kesitlerinin örnek görüntüleri Şekil 4.2 (b)'de verilmiştir.



Şekil 4.2. a) Haddeye dik ve hadde yönünde mikroyapı alınan bölgelerin şematik gösterimi ve b) Hadde yönü ve haddeye dik kesitlerden alınan mikroyapı resimleri [28]

Çeliklerin mekanik özelliklerinin belirlenmesinde, çelik içerisinde bulunan ferrit ve perlit miktarları kritik bir rol oynamaktadır. Öyle ki, ferrit ve perlit fazları, çeliklerin akma gerilimi, çekme gerilimi ve kopma gerilimi gibi temel mekanik özelliklerinin belirlenmesi noktasında önemli bir etkindir. Ferrit fazı, yumuşak ve sünek bir faz olarak değerlendirilmektedir. Buna göre, çelik içerisindeki Ferrit miktarının artması, ilgili malzemenin akma, çekme ve kopma gerilimlerinin azalmasına neden olmaktadır. Bu durumun sebebi, ferrit fazının daha düşük mukavemet ve daha yüksek şekil değiştirme kapasitesine sahip olmasıdır. Ferrit miktarında bahsedilen durumun aksine, perlit fazında malzemeler, ferrit fazına göre daha sert ve mukavemetli bir yapıya sahip olmaktadır. Buna bağlı olarak da malzeme içerisindeki perlit miktarının artması, ilgili malzemenin akma, çekme ve kopma gerilimi değerlerinde bir artış yaşanmasına yol açmaktadır [46-47].

Çeliklerin mikroyapı görüntüleri kullanılarak akma, çekme ve kopma gerilimlerinin belirlenmesinde, ilgili çelikler içerisinde bulunan ferrit hacim oranının tespit edilmesi gerekmektedir. Kullanılan çeliklere ait akma, çekme ve kopma gibi mekanik özelliklerin belirlenmesinde kritik bir öneme sahip olan ferrit hacim oranının bulunabilmesi için görüntü analiz yazılımından faydalanılmıştır. Bu yazılım kullanılarak, mikroyapı görselleri önce gri tonlamaya çevrilmiş, sonrasında ise; malzeme içerisinde ferrit ve perlit fazları,

görseldeki kontrast farkı kullanılarak ayırt edilmiştir. Bu bağlamda, her bir numune ve her bir bölge için elde edilen ferrit hacim oranları sırası ile Çizelge 4.2 ve Çizelge 4.3'te verilmiştir.

Çizelge 4.2. Hadde yönü kesitindeki resimlerin ferrit hacim oranları (%) ve ortalamaları

Bölge\ Numune	1	2	3	4	5	6	7	8	9	10	11
1	66,424	65,427	63,625	61,503	62,932	56,067	56,397	51,689	58,067	70,076	60,883
2	68,082	66,061	64,820	57,192	55,671	62,481	55,841	57,996	57,137	59,438	54,238
3	68,910	63,403	64,359	60,049	61,865	61,022	55,076	57,770	56,306	63,766	56,640
4	67,848	63,271	63,290	61,223	66,582	56,443	53,095	58,397	54,208	63,738	60,402
5	70,502	62,127	60,491	75,143	70,349	50,539	51,859	59,177	54,865	67,539	59,146
6	68,143	66,286	67,205	64,165	59,006	59,707	60,304	58,500	55,496	62,735	56,922
7	61,472	65,371	66,212	61,467	71,171	61,769	60,610	55,549	56,722	71,834	52,311
8	70,108	65,168	62,206	56,944	58,466	56,383	55,185	57,490	59,724	67,144	60,183
9	68,625	61,712	61,205	60,557	54,798	61,494	52,990	55,807	58,335	65,130	53,423
Ortalama	67,790	64,314	63,713	62,027	62,316	58,434	55,706	56,931	56,762	65,711	57,128

Çizelge 4.3. Haddeye dik kesitindeki resimlerin ferrit hacim oranları (%) ve ortalamaları

Bölge\ Numune	1	2	3	4	5	6	7	8	9	10	11
1	71,225	62,587	59,360	60,685	57,699	47,772	54,153	50,480	75,897	73,912	51,122
2	60,094	63,388	68,373	62,555	54,366	54,338	56,393	50,373	72,180	64,416	51,222
3	71,221	65,566	70,068	66,132	57,862	56,243	52,413	55,138	71,142	73,074	50,198
4	63,613	62,786	62,980	58,767	63,354	55,132	54,113	57,194	74,103	69,124	57,483
5	64,219	65,446	62,518	64,108	73,895	46,253	57,029	58,497	72,079	62,504	59,746
6	66,014	64,538	60,365	68,725	63,062	58,349	60,276	53,427	72,568	73,006	55,737
7	63,639	64,249	60,744	73,754	67,730	51,383	59,646	59,460	74,777	74,005	50,875
8	57,415	62,658	71,399	63,255	63,950	57,396	54,911	55,287	72,132	67,069	59,900
9	65,035	65,508	57,072	66,017	69,408	54,707	51,783	55,264	74,820	65,325	53,525
Ortalama	64,719	64,081	63,653	64,889	63,481	53,508	55,635	55,013	73,300	69,159	54,423

Çizelge 4.2, hadde yönü kesitindeki mikroyapı görsellerinin yüzdesel olarak ferrit hacim oranlarını ve ortalamalarını içermektedir. Burada, Bölge başlığı ile verilen kısımlar, Şekil 4.2 (a)'da verilen mikroyapı görsellerindeki bölgeleri, Numune başlığı ile verilen kısımlar, her bir numune için elde edilen değerleri temsil etmektedir. Ortalama değerler ise, her bir numune için ortalama yüzdesel ferrit hacim oranlarını göstermektedir. Çizelge 4.2 incelendiğinde, en yüksek ortalama ferrit hacim oranının %67,790 ile 1. numunede ortaya çıktığı gözlemlenmektedir. Buna göre, 1. numunenin diğer numunelere göre daha yüksek

miktarda ferrit fazı içerdiğini göstermektedir. Öte yandan, en düşük ortalama ferrit hacim oranı %55,706 ile 7. numunede gözlemlenmektedir. Dolayısıyla 7. numenin diğer numunelere kıyasla daha az ferrit fazı içerdiği görülmüştür.

Çizelge 4.3'te verilen haddeye dik kesitteki mikroyapı görsellerinin yüzdesel olarak ferrit hacim oranları ve ortalamaları incelendiğinde, en yüksek ortalama değerin %73,300 ile 9. numune tarafından ve en düşük ortalama değerin ise %53,508 ile 6. numune tarafından elde edildiği görülmüştür.

Bu tez çalışmasında, AISI 1040 çeliği kullanılarak gerçekleştirilen çekme testi sonuçlarına göre; ilgili numunelerin akma, çekme ve kopma gerilimi değerleri elde edilmiştir. Sonrasında, elde edilen bu değerler ve ilgili çeliklerin mikroyapı resimleri kullanılarak; bir ESA eğitilmiştir. Eğitim işlemi Google Colab platformunda gerçekleştirilmiş olup, eğitimin gerçekleştirilmesi için A100 Grafik İşlem Birimi'nden faydalanılmıştır. Eğitimi gerçekleştirilen ESA modeli, numunelerin akma, çekme ve kopma gerilimlerinin tahmin edilmesinde kullanılmıştır. Eğitilen ESA'ya ait hiper-parametreler ve açıklamalar Tablo 6'da verilmiştir.

Çizelge 4.4. ESA'da kullanılan hiper-parametreler, değerleri ve açıklamaları

Hiper-parametreler	Değer	Açıklama
Optimizer	Adam	Ağırlık güncellemelerinde daha düzgün bir ilerleme yaparak eğitim sırasında kayıp fonksiyonunu en az indirmeyi amaçlar.
loss_function	OKH	Modelin tahmin ettiği değerler ile gerçek değerlerin farklarının karesinin ortalamasıdır.

ESA'nın eğitiminde kullanılacak olan veri kümesi, daha önce bahsedilen deneyler esnasında elde edilen veriler kullanılarak oluşturulmuştur. İlgili veri kümesi, toplamda 7128 örnekten oluşmaktadır. Eğitim işleminin öncesinde, veri kümesi, %80 eğitim ve %20 test olmak üzere bölünmüştür. Bu işlem sonucunda, 5702 örnek eğitim ve 1426 örnek test için ayrılmıştır. Farklı hiper-parametreler kullanılarak birden fazla ESA eğitilmiş olup, bu sinir ağları ile yapılan deneysel çalışmalarda farklı batch size ve epoch değerleri

kullanılmıştır. Bu batch size ve epoch değerleri kullanılarak eğitilen ESA modelleri tarafından elde edilen sonuçlar Çizelge 4.5'te verilmiştir.

Çizelge 4.5. Farklı batch size ve epoch değerlerinde elde edilen sonuçlar

Batch Size/Epoch	50	100	200	500	1000
8	OKH: 95,97 KOKH: 9,79 OMH: 7,63 R2: 0,98	OKH: 69,74 KOKH: 8,35 OMH: 6,42 R2: 0,99	OKH: 25,15 KOKH: 5,01 OMH: 3,89 R2: 0,99	OKH: 27,56 KOKH: 5,25 OMH: 4,11 R2: 0,99	OKH: 30,42 KOKH: 5,51 OMH: 4,35 R2: 0,99
16	OKH: 94,57 KOKH: 9,72 OMH: 7,66 R2: 0,98	OKH: 37,51 KOKH: 6,14 OMH: 4,77 R2: 0,99	OKH: 44,64 KOKH: 6,68 OMH: 5,17 R2: 0,99	OKH: 13,07 KOKH: 3,61 OMH: 2,80 R2: 0,99	OKH: 10,10 KOKH: 3,17 OMH: 2,52 R2: 0,99
32	OKH: 176,94 KOKH: 13,30 OMH: 10,35 R2: 0,98	OKH: 112,28 KOKH: 10,59 OMH: 8,28 R2: 0,98	OKH: 37,39 KOKH: 6,11 OMH: 4,87 R2: 0,99	OKH: 17,89 KOKH: 4,23 OMH: 3,36 R2: 0,99	OKH: 13,35 KOKH: 3,65 OMH: 2,74 R2: 0,99
64	OKH: 130,17 KOKH: 11,40 OMH: 8,98 R2: 0,98	OKH: 62,59 KOKH: 7,91 OMH: 5,97 R2: 0,99	OKH: 32,43 KOKH: 5,69 OMH: 4,38 R2: 0,99	OKH: 19,53 KOKH: 4,41 OMH: 3,39 R2: 0,99	OKH: 4,36 KOKH: 2,08 OMH: 1,66 R2: 0,99

Çizelge 4.5'te verilen bilgiler, her bir batch size değeri üzerinden incelendiğinde elde edilen gözlemler aşağıda her bir batch size değeri için maddeler halinde verilmiştir;

- Batch size 8 değeri için:
- R2 değerinin 50 epoch için 0,98 olduğu ancak, 100 epoch'tan itibaren 0,99'a yükseldiği görülmektedir.
- Sırasıyla en düşük OKH, KOKH ve OMH değerlerinin 200 epoch'ta (OKH 25,15; KOKH 5,01; OMH 3,89), en yüksek R2 değerinin ise 100, 200, 500 ve 1000 epoch için ortak olarak 0,99 şeklinde elde edildiği görülmüştür.
- Batch size 16 için:
- R2 değerinin 50 epoch için 0,98 olduğu ancak, 100 epoch'tan itibaren 0,99'a yükseldiği görülmektedir.
- Sırasıyla en düşük OKH, KOKH ve OMH değerlerinin 1000 epoch'ta (OKH 10,10; KOKH 3,17; OMH 2,52), en yüksek R2 değerinin ise 100, 200, 500 ve 1000 epoch için ortak olarak 0,99 şeklinde elde edildiği görülmüştür.

- Batch size 32 için:
- R2 değerinin 50 epoch için 0,98 olduğu ancak, 200 epoch'tan itibaren 0,99'a yükseldiği görülmektedir.
- Sırasıyla en düşük OKH, KOHK ve OMH değerlerinin 1000 epoch'ta (OKH 13,35; KOHK 3,65; OMH 2,74), en yüksek R2 değerinin ise 200, 500 ve 1000 epoch için ortak olarak 0,99 şeklinde elde edildiği görülmüştür.
- Batch size 64 için:
- R2 değerinin 50 epoch için 0,98 olduğu ancak, 100 epoch'tan itibaren 0,99'a yükseldiği görülmektedir.
- Sırasıyla en düşük OKH, KOKH ve OMH değerlerinin 1000 epoch'ta (OKH 4,36; KOKH 2,08; OMH 1,66), en yüksek R2 değerinin ise 200, 500 ve 1000 epoch için ortak olarak 0,99 şeklinde elde edildiği görülmüştür.


Bu incelemeler sonucunda, 8 batch size değerinde en başarılı sonuçların tüm metriklerde 200 epoch değerinde elde edildiği; öte yandan, 16, 32 ve 64 batch size değerleri için en başarılı sonuçların 1000 epoch değerinde elde edildiği görülmüştür. Buna ek olarak, farklı batch size değerleri için en başarılı sonuçlar sırasıyla 64 batch size / 1000 epoch, 16 batch size / 1000 epoch kombinasyonu ile gerçekleştirilen eğitimlerde elde edilmiştir. 64 batch size ve 1000 epoch kombinasyonu ile gerçekleştirilen eğitimde;

- OKH: 4,36
- KOKH: 2,08
- OMH: 1,66
- R2: 0,99

Değerleri elde edilirken, 16 batch size / 1000 epoch kombinasyonu kullanılarak gerçekleştirilen eğitimde ise;

- OKH: 10,10
- KOKH: 3,17
- OMH: 2,52
- R2: 0,99

Değerleri elde edilmiştir. Buna ek olarak, Tüm batch size ve epoch değerlerinde R2 metriği yakın sonuçlar vermiştir. En başarılı sonuçların eğitimi sırasında ortaya çıkan eğitim ve doğrulama kaybı fonksiyonlarının grafiği Şekil 4.3'te gösterilmiştir.



Şekil 4.3. Eğitim ve doğrulama kaybı fonksiyonlarının grafiği [29]

Şekil 4.3'te verilen grafikler incelendiğinde batch size 8 ve 200 epoch için grafik, eğitim kaybının başlangıçta yüksek olduğunu ve yaklaşık 25 epoch sonrasında hızla azaldığını göstermektedir. Eğitim kaybı bu noktadan sonra stabil bir seviyeye ulaşarak yatay seyretmiştir. Eğitim kaybındaki bu hızlı düşüş, modelin öğrenme hızının yüksek olduğunu göstermektedir. Doğrulama kaybı da eğitim kaybına benzer bir trend izlemiş, başlangıçta yüksek değerlerdeyken hızla azalmış ve stabil hale gelmiştir. Ancak, doğrulama kaybında zaman zaman küçük dalgalanmalar gözlenmektedir. Düşük batch size ile yapılan bu eğitimde, model hızlı bir öğrenme süreci geçirmiştir. Eğitim ve doğrulama kayıpları arasındaki uyum, modelin overfitting yapmadığını göstermektedir. Düşük batch size,

modelin her bir güncellemede daha fazla varyasyon görmesini sağlayarak daha genel bir öğrenme sağlamaktadır.

Batch size 16 ve 100 epoch için eğitim kaybı başlangıçta yüksek olup, yaklaşık 50 epoch sonrasında hızla azalmış ve daha sonra stabil bir seviyeye ulaşmıştır. Eğitim kaybının 50 epoch sonrasında stabil hale gelmesi, modelin daha uzun sürede öğrenme sürecini tamamladığını göstermektedir. Doğrulama kaybı da benzer bir şekilde azalmış ve daha stabil bir hale gelmiştir. Eğitim kaybına göre daha az dalgalanma göstermektedir. Orta büyüklükte batch size ile yapılan eğitimde, modelin öğrenme kapasitesi artmış ve doğrulama kaybı daha stabil bir hal almıştır. Bu durum, modelin daha iyi genelleme yapabildiğini ve aşırı uyum yapma olasılığının azaldığını göstermektedir.

Batch size 16 ve 100 epoch için eğitim kaybı başlangıçta yüksek olup hızla düşmüş ve yaklaşık 50 epoch sonrasında stabil hale gelmiştir. Eğitim sürecinin başında kayıpların hızla azalması, modelin başlangıçta hızlı bir öğrenme sürecine girdiğini gösterir. Doğrulama kaybı da benzer bir trend izleyerek azalmış ancak epoch sayısının artmasıyla birlikte daha stabil bir hale gelmiştir. Yine de doğrulama kaybında zaman zaman küçük dalgalanmalar görülmektedir. Daha büyük bir batch size ile eğitim, modelin daha stabil ve genelleme kapasitesinin artmasını sağlamıştır.

Batch size 64 ve 1000 epoch için, eğitim kaybı başlangıçta çok yüksek olup, hızla düşmüş ve ardından stabil bir seviyeye ulaşmıştır. Eğitim sürecinin başında kayıpların hızla azalması, modelin başlangıçta hızlı bir öğrenme sürecine girdiğini gösterir. Doğrulama kaybı da eğitim kaybına benzer bir trend izlemiş ve stabil bir seviyeye gelmiştir. Bu batch size ile doğrulama kaybı en stabil hale gelmiştir. En büyük batch size ile yapılan eğitimde, modelin doğrulama kaybı oldukça stabil bir şekilde azalmıştır. Bu durum, modelin genelleme kapasitesinin en yüksek seviyeye ulaştığını ve aşırı uyum olasılığının en düşük seviyede olduğunu göstermektedir. Büyük batch size, her bir güncellemede daha fazla veri görerek daha tutarlı bir öğrenme sağlar.

5. SONUÇ VE DEĞERLENDİRME

Bu tez çalışmasında, AISI 1040 çeliğinin mikroyapı görüntülerinden mekanik özelliklerini tahmin etmek için Derin Öğrenme tekniği olan ESA'yı kullanmayı amaçlamaktadır. Elde edilen sonuçlar, derin öğrenme algoritmalarının malzeme biliminde kullanılabilirliğini ve etkinliğini göstermiştir.

Öncelikle, mikroyapı görüntülerinin analizi ile elde edilen ferrit ve perlit oranlarının mekanik özellikler üzerindeki etkileri incelenmiştir. Çalışmada; çekme testleri sonucu elde edilen akma, çekme ve kopma gerilimi değerleri, 100x büyütmede alınan optik mikroyapı görüntüleriyle ilişkilendirilmiştir. Toplam 7128 görüntüden oluşan özgün bir veri kümesi oluşturulmuştur. Oluşturulan veri kümesi, derin öğrenme modeli olan ESA ile eğitilmiştir. Modelin performansı; OKH, KOKH, OMH ve R2 performans metrikleri ile değerlendirilmiştir. En başarılı sonuçlar, batch size 64 ve epoch 1000 değerlerinde elde edilmiştir; bu durumda OKH 4,36; KOKH 2,08; OMH 1,66 ve R2 0,99 olarak bulunmuştur.

Bu sonuçlar, mikroyapı görüntülerinin kullanılmasıyla AISI 1040 çeliğinin mekanik özelliklerinin yüksek doğrulukla tahmin edilebileceğini göstermektedir. Derin öğrenme algoritmaları, geleneksel mekanik testlerin yerini alabilecek hızlı ve etkili alternatifler sunmaktadır. Bu, mühendislik ve malzeme biliminde maliyetleri düşürmek ve zaman tasarrufu sağlamak açısından büyük bir avantajdır.

Çalışmanın bir diğer önemli bulgusu, mikroyapıdaki ferrit ve perlit oranlarının mekanik özellikler üzerindeki kritik rolüdür. Ferrit oranının artması, çeliğin sünekliğini artırırken mukavemetini azaltmaktadır. Perlit oranının artması ise, çeliğin mukavemetini artırmakta ancak sünekliğini azaltmaktadır. Bu bilgiler, çeliklerin istenilen mekanik özelliklere sahip olacak şekilde tasarlanmasında önemli bir rehber olabilir.

Gelecekteki çalışmalar için, farklı çelik türlerinin mikroyapı görüntülerinden mekanik özelliklerinin tahmin edilmesi üzerine odaklanılması önerilmektedir. Ayrıca, diğer derin öğrenme algoritmaları ve daha büyük veri kümeleri ile yapılan çalışmaların sonuçlarının karşılaştırılması, bu alandaki bilgi birikimini artıracaktır. Derin öğrenme tekniklerinin

sürekli gelişen yapısı göz önüne alındığında, malzeme biliminde daha geniş bir uygulama alanı bulacağı açıktır.



KAYNAKLAR

1. Callister, W. D., Rethwisch, D. G. (2016). *Fundamentals of Materials Science and Engineering: An Integrated Approach*. (5. baskı). Hoboken: Wiley Global Education, 960.
2. İnternet: Standard test methods for tension testing of metallic materials (E8/E8M-16a). (2016). *ASTM International*. URL: <https://standards.iteh.ai/catalog/standards/sist/9b1a190e-d97e-439b-bd31-17aa5e7c9557/astm-e8-e8m-16a> Son Erişim Tarihi: 18.06.2024.
3. Courtney, T. H. (2000). *Mechanical Behavior of Materials*. (2. baskı). New York: McGraw-Hill, 733.
4. Dieter, G. E. (1986). *Mechanical Metallurgy*. (3. baskı). New York: McGraw-Hill, 751.
5. Cai, W. (2010). *Deformation and Fracture Mechanics of Engineering Materials*. (4. baskı). Hoboken: Wiley, 564.
6. Basheer, I. A., Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31.
7. LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
8. Li, Z., Liu, F., Yang, W., Peng, S., Zhou, J. (2022). A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019.
9. Krizhevsky, A., Sutskever, I., Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
10. Simonyan, K., Zisserman, A. (2015, 7-9 Mayıs). *Very deep convolutional networks for large-scale image recognition*. 3rd International Conference on Learning Representations (ICLR 2015), San Diego, 1–14.
11. He, K., Zhang, X., Ren, S., Sun, J. (2016, 27-30 Haziran). *Deep residual learning for image recognition*. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 770–778.
12. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118.
13. İnternet: Bojarski, M. (2016). End-to-end deep learning for self-driving cars. *NVIDIA Technical Blog*. URL: <https://developer.nvidia.com/blog/deep-learning-self-driving-cars/> Son Erişim Tarihi: 18.06.2024
14. Schroff, F., Kalenichenko, D., Philbin, J. (2015, 7-12 Haziran). *FaceNet: A unified embedding for face recognition and clustering*. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, 815–823.
15. Jung, M., Song, J. S., Shin, A.-Y., Choi, B., Go, S., Kwon, S.-Y., Park, J., Park, S. G., Kim, Y.-M. (2023). Construction of deep learning-based disease detection model in plants. *Scientific Reports*, 13(1), 1–13.

16. Wang, S., Li, J., Zuo, X., Chen, N., Rong, Y. (2023). An optimized machine-learning model for mechanical properties prediction and domain knowledge clarification in quenched and tempered steels. *Journal of Materials Research and Technology*, 24, 3352–3362.
17. Xu, G., He, J., Lü, Z., Li, M., Xu, J. (2023). Prediction of mechanical properties for deep drawing steel by deep learning. *International Journal of Minerals Metallurgy and Materials*, 30(1), 156–165.
18. Shaheen, M. A., Presswood, R., Afshan, S. (2023). Application of Machine Learning to predict the mechanical properties of high strength steel at elevated temperatures based on the chemical composition. *Structures*, 52, 17–29.
19. Diao, Y., Yan, L., Gao, K. (2022). A strategy assisted machine learning to process multi-objective optimization for improving mechanical properties of carbon steels. *Journal of Materials Science Technology*, 109, 86–93.
20. Choudhury, A. (2022). Prediction and analysis of mechanical properties of low carbon steels using machine learning. *Journal of the Institution of Engineers (India) Series D*, 103(1), 303–310.
21. Xiong, J., Zhang, T., Shi, S. (2020). Machine learning of mechanical properties of steels. *Science China Technological Sciences*, 63(7), 1247–1255.
22. Azimi, S. M., Britz, D., Engstler, M., Fritz, M., Mücklich, F. (2018). Advanced steel microstructural classification by Deep Learning methods. *Scientific Reports*, 8(1), 1–14.
23. Muñoz-Rodenas, J., García-Sevilla, F., Coello-Sobrino, J., Martínez-Martínez, A., Miguel-Eguía, V. (2023). Effectiveness of machine-learning and deep-learning strategies for the classification of heat treatments applied to low-carbon steels based on microstructural analysis. *Applied Sciences*, 13(6), 3479.
24. Cheloe Darabi, A. C., Rastgordani, S., Khoshbin, M., Guski, V., Schmauder, S. (2023). Hybrid data-driven deep learning framework for material mechanical properties prediction with the focus on dual-phase steel microstructures. *Materials*, 16(1), 447.
25. Gandy, D. (2007). *Carbon Steel Handbook*. (1. Baskı). Kaliforniya: Electric Power Research Institute (EPRI), 172.
26. Calik, A., Duzgun, A., Sahin, O., Ucar, N. (2010). Effect of carbon content on the mechanical properties of medium carbon steels. *Zeitschrift Für Naturforschung A*, 65(5), 468–472.
27. İnternet: Carbon steel: Properties, examples and applications. *Matmatch*. URL: <https://matmatch.com/learn/material/carbon-steel>, Son Erişim Tarihi: 18.06.2024.
28. Sert, R., Şahin, Ö., Kılıçlı, V., Duran, F. (2024). AISI 1040 Çeliğinin Mikroyapı Resimlerinden Mekanik Özelliklerinin Derin Öğrenme ile Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C Tasarım ve Teknoloji*, 12(2), 707–718.
29. Singh, R. (2012). *Applied Welding Engineering*. (1. baskı). Oxford: Butterworth-Heinemann, 87-94.

30. Chawla, K. K. (2005). *Encyclopedia of Condensed Matter Physics*. (1. baskı). Amsterdam: Elsevier, 312–318.
31. İnternet: Instron 3369. *Instron*. URL: <https://www.instron.com/en/>, Son Erişim Tarihi: 19.06.2024.
32. Awuruonye, U., Sireli, Y. (2022, 5-8 Ekim). *Metallographic sample preparation using engineering management principles*. Proceedings of the International Annual Conference of the American Society for Engineering Management, Huntsville, 1-10.
33. Das, S. K. (1999). Metallographic sample preparation techniques. *Journal of Materials Science*, 34(3), 163-176.
34. Niezgoda, S. R., Kanjarla, A. K., Kalidindi, S. R. (2013). Novel microstructure quantification framework for databasing, visualization, and analysis of microstructure data. *Integrating Materials and Manufacturing Innovation*, 2(1), 54–80.
35. Kadkhodapour, J., Schmauder, S., Raabe, D., Ziaei-Rad, S., Weber, U., Calcagnotto, M. (2011). Experimental and numerical study on geometrically necessary dislocations and non-homogeneous mechanical properties of the ferrite phase in dual phase steels. *Acta Materialia*, 59(11), 4387–4394.
36. İnternet: Leica DMI500M. *Leica Microsystems*. URL: <https://www.leica-microsystems.com>, Son Erişim Tarihi: 20.06.2024.
37. Gonzalez, R. C. (2018). Deep Convolutional Neural Networks: A Survey. *IEEE Signal Processing Magazine*, 35(6), 79–87.
38. Aloysius, N., Geetha, M. (2017, 6-8 Nisan). *A review on deep convolutional neural networks*. 2017 International Conference on Communication and Signal Processing (ICCSP), Chennai, 0588–0592.
39. Abiyev, R. H., Ismail, A. (2021). COVID-19 and pneumonia diagnosis in X-ray images using Convolutional Neural Networks. *Mathematical Problems in Engineering*, 2021, 1–14.
40. Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, 9(4), 611–629.
41. İnternet: Google colab. *Google*. URL: <https://colab.google>, Son Erişim Tarihi: 23.06.2024.
42. Plevris, V., Solorzano, G., Bakas, N., El, M., Seghier, A. (2022, 5-9 Haziran). *Investigation of performance metrics in regression analysis and machine learning-based prediction models*. 8th European Congress on Computational Methods in Applied Sciences and Engineering, Oslo, 1-10.
43. Takakuwa, O., Kwaragi, Y., Soyama, H. (2013). Estimation of the yield stress of stainless steel from the Vickers hardness taking account of the residual stress. *Journal of Surface Engineered Materials and Advanced Technology*, 03(04), 262–268.
44. Pavlina, E. J., Van Tyne, C. J. (2008). Correlation of yield strength and tensile strength with hardness for steels. *Journal of Materials Engineering and Performance*, 17(6), 888–893.

45. Cool, T., Bhadeshia, H. K. D. H., MacKay, D. J. C. (1997). The yield and ultimate tensile strength of steel welds. *Materials Science Engineering. A, Structural Materials: Properties, Microstructure and Processing*, 223(1–2), 186–200.
46. Tu, X., Ren, Y., Shi, X., Li, C., Yan, W., Shan, Y., Yang, K. (2021). Enhancing strain capacity by the introduction of pearlite in bainite and polygonal ferrite dual-phase pipeline steel. *Materials*, 14(18), 5358.
47. Ishtiaq, M., Inam, A., Tiwari, S., Seol, J. B. (2022). Microstructural, mechanical, and electrochemical analysis of carbon doped AISI carbon steels. *Applied Microscopy*, 52(1). 98-102





Gazili olmak ayrıcalıktır