



Prediction of Mechanical Properties from Microstructure Images of AISI 1040 Steel Using Deep Learning

Rıdvan SERT^{1*}, Ömer ŞAHİN², Volkan KILIÇLI², Fecir DURAN¹

¹Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Yenimahalle/ANKARA

²Gazi Üniversitesi, Teknoloji Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Yenimahalle/ANKARA

Makale Bilgisi

Araştırma makalesi
Başvuru: 22/04/2024
Düzeltilme: 15/05/2024
Kabul: 16/05/2024

Anahtar Kelimeler

AISI 1040 Çeliği
Mikroyapı
Mekanik Özellikler
Derin Öğrenme
Evrşimsel Sinir Ağı

Article Info

Research article
Received: 22/04/2024
Revision: 15/05/2024
Accepted: 16/05/2024

Keywords

AISI 1040 Steel
Microstructure
Mechanical Properties
Deep Learning
Convolutional Neural
Network

Grafik Özet (Graphical/Tabular Abstract)

Çalışmaya ait akış şeması. / Flowchart of the study



Şekil A: İş akış şeması / Figure A: Flowchart diagram

Önemli noktalar (Highlights)

- Mikroyapı görüntülerinden mekanik özellik tahmini / Prediction of mechanical properties from microstructure images
- Ferrit oranlarının analizi / Analysis of ferrite ratios
- Evrşimsel Sinir Ağı ile regresyon / Regression with Convolutional Neural Network

Amaç (Aim): AISI 1040 Çeliğinin mikroyapı resimlerinden Evrşimsel Sinir Ağı kullanarak mekanik özelliklerin tahmin edilmesidir. / The aim is to predict the mechanical properties of AISI 1040 steel from microstructure images using a Convolutional Neural Network.

Özgünlük (Originality): Mekanik özellikler tahmin edilirken mikroyapıdaki ferrit hacim oranlarının dahil edilmesidir. / Including the ferrite volume fractions in the microstructure when predicting mechanical properties

Bulgular (Results): 100x büyütmede optik mikroyapı resimleri haddeye dik ve haddeye paralel olarak alınmış ve çekme testi sonucunda alınan veriler ile etiketlenmiştir. Bu veriler kullanılarak Evrşimsel Sinir Ağı ile yapılan deneyler sonucunda MSE'de 4,36; RMSE'de 2,08; MAE'de 1,66 ve R²'de 0,99'luk başarı oranı elde edilmiştir. / 100x magnified optical microstructure images were taken both transverse and parallel to the rolling direction, and these images were labeled with data obtained from the tensile test results. Using these data, experiments conducted with a Convolutional Neural Network resulted in a Mean Squared Error (MSE) of 4.36, Root Mean Squared Error (RMSE) of 2.08, Mean Absolute Error (MAE) of 1.66, and an R-squared (R²) value of 0.99.

Sonuç (Conclusion): Çekme testlerine gerek kalmadan doğrudan mikroyapı resimlerinden mekanik özellikler tahmin edilebilmektedir. / Mechanical properties can be predicted directly from microstructure images without the need for tensile tests.



AISI 1040 Çeliğinin Mikroyapı Resimlerinden Mekanik Özelliklerinin Derin Öğrenme ile Tahmini

Rıdvan SERT^{1*}, Ömer ŞAHİN², Volkan KILIÇLI², Fecir DURAN¹

¹Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, Yenimahalle/ANKARA

²Gazi Üniversitesi, Teknoloji Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Yenimahalle/ANKARA

Makale Bilgisi

Araştırma makalesi
Başvuru: 22/04/2024
Düzeltilme: 15/05/2024
Kabul: 16/05/2024

Anahtar Kelimeler

AISI 1040 Çeliği
Mikroyapı
Mekanik Özellikler
Derin Öğrenme
Evrişimsel Sinir Ağı

Öz

Malzeme biliminde işlem-mikroyapı ve mekanik özellikler arasındaki çok iyi bir ilişki bulunmaktadır. Çeliklerin oda sıcaklığındaki mekanik özellikleri doğrudan mikroyapıda bulunan ferrit, sementit ve perlit hacim oranlarına ve tane boyutlarına bağlıdır. Bu çalışmada, AISI 1040 çeliğinin mikroyapı görüntülerinden yapay zekâ ile oda sıcaklığındaki çekme özelliklerinin tahmini gerçekleştirilmiştir. AISI 1040 çeliğinden ASTM-E8/E8M standardına uygun olarak hazırlanan çekme numuneleri oda sıcaklığında çekme testine tabii tutulmuştur. Sonraki adımda aynı çekme numunelerinin deforme olmamış bölgelerinden metalografik numune hazırlanıp mikroyapı resimleri elde edilmiş, ferrit ve perlit hacim oranları görüntü analizi yazılımıyla hesaplanmıştır. Bu veriler ile özgün bir veri seti oluşturulmuştur. Evrişimsel Sinir Ağı kullanılarak, mikroyapı resimlerinden akma, çekme ve kopma gerilimi değerleri tahmin edilmiştir. Gerçekleştirilen deneyler sonucunda mikroyapı resimlerinden AISI 1040 çeliğinin mekanik özelliklerinin başarılı bir şekilde tahmininin gerçekleştirilebileceği ortaya konulmuştur. 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.

Prediction of Mechanical Properties from Microstructure Images of AISI 1040 Steel Using Deep Learning

Article Info

Research article
Received: 22/04/2024
Revision: 15/05/2024
Accepted: 16/05/2024

Keywords

AISI 1040 Steel
Microstructure
Mechanical Properties
Deep Learning
Convolutional Neural Network

Abstract

In materials science, there is a strong link between process-microstructure and mechanical properties. The mechanical properties of steels at room temperature are directly affected by the ferrite, cementite and pearlite volume fractions and grain sizes of the microstructure. In this study, artificial intelligence was used to predict the tensile properties of AISI 1040 steel at room temperature based on images of its microstructure. Tensile specimens prepared from AISI 1040 steel in accordance with ASTM-E8/E8M were subjected to tensile tests at room temperature. In the next stage, metallographic specimens were created from undeformed sections of the tensile specimens, microstructure images were captured and image analysis tools were used to calculate ferrite and pearlite volume fractions. The data obtained as a result of this procedure was combined to create a unique dataset. The images in the dataset were then used to predict yield, tensile and break stress values using a Convolutional Neural Network. The results of the experimental studies carried out in this research have shown that microstructural images can be used to accurately predict the mechanical properties of AISI 1040 steel. In the experimental studies carried out in this study, 4.36 Mean Square Error (MSE), 2.08 Root Mean Square Error (RMSE), 1.66 Mean Absolute Error (MAE) and 0.99 R-Square (R²) values were obtained respectively as a result of testing the Convolutional Neural Network model on the dataset obtained.

1. GİRİŞ (INTRODUCTION)

Malzemelerin mekanik özelliklerinin belirlenmesi genellikle tahribatlı test yöntemleriyle yapılmakta olup, test süreci zaman alan, maliyetli ve titizlikle sürdürülmesi gereken bir süreçtir. Sıcaklık, nem ve diğer çevresel faktörler, numunenin malzemeyi en

iyi temsil edecek yerden alınması, mekanik testlerde kullanılan cihazların hassas ve kalibrasyonlu olması gibi durumlar mekanik özellik tespitini zorlaştırmaktadır. Bu sorunların üstesinden gelmek için son yıllardaki çalışmalarda Makine Öğrenmesi ve Derin Öğrenme algoritmaları kullanılmıştır [1-10].

Wang ve arkadaşları [1], su verilmiş ve temperlenmiş çelikler üzerinde bir tahmin çalışması yapmıştır. Çalışmada maksimum çekme gerilimi, akma gerilimi ve toplam uzama olmak üzere üç farklı mekanik özellik tahmin edilmiş ve bunun için altı farklı Makine Öğrenmesi algoritması kullanılmıştır. Yapılan deneylere göre en iyi performans sonuçları optimum Gauss Süreç Regresyonu ile elde edilmiştir ve veri miktarının tahmin performansı üzerindeki etkisi tartışılmıştır.

Xu ve arkadaşları [2], üretim sürecinde çelik ürünler için çevrimiçi kalite ön belirlemesini sağlayan bir çalışma gerçekleştirmiştir. Bu çalışma için çekme gerilimi, akma gerilimi, uzama ve şekil değiştirme oranı olmak üzere dört farklı mekanik özellik değeri dikkate alınmıştır. Mekanik özelliklerin tahmin edilmesi için Uzun Kısa Süreli Bellek, Geçitli Tekrarlayan Birim ve Gauss Süreç Regresyonu modelleri kullanılmış ve testler gerçekleştirilerek karşılaştırma işlemleri yapılmıştır.

Yüksek sıcaklıklarda yüksek dayanımlı çelik üzerinde Shaheen ve arkadaşları [3] tarafından bir çalışma yapılmıştır. Çeliğin akma gerilimi, çekme gerilimi ve Young modülü tahmin edilmeye çalışılmıştır. Bu özelliklerin tahmin edilmesi amacıyla Makine Öğrenmesi tabanlı Derin Sinir Ağı yöntemi kullanılmıştır. Sıcaklık ve kimyasal bileşim gibi girdi parametreleri alan bir tahmin yöntemi geliştirilmiştir.

Diao ve arkadaşları [4], karbon çelik verilerine dayanarak farklı mekanik özellikler üzerinde bir çalışma yapmıştır. Çekme gerilimi, kopma gerilimi, toplam uzama, Charpy darbe tokluğu, sertlik ve yorulma dayanımı gibi mekanik özelliklerin tahmin edilmesi için beş adet Makine Öğrenmesi modeli kullanılmıştır. Destek Vektör Regresyonu, Çok Katmanlı Algılayıcı, K-En Yakın Komşu, Çekirdekli Sirt Regresyonu ve Rastgele Orman modelleri ile testler gerçekleştirilmiş ve elde edilen sonuçlar karşılaştırılmıştır. Böylelikle kapsamlı ve yüksek performansa sahip yeni çeliklerin geliştirilmesinde kullanılması beklenen yeni bir optimizasyon stratejisi sunulmuştur.

Choudhury [5], çeşitli termomekanik işlemlerle üretilen seçilmiş çelikler için akma gerilimi ve uzama gibi mekanik özellikleri tahmin etmeyi amaçlamıştır. Bunun için 129 farklı veri örneği üzerinde çalışılmış ve Makine Zekâsı tabanlı bir model önerilmiştir. Modeli elde ederken Çoklu Lineer Regresyon ve Destek Vektör Regresyonu algoritmaları test edilmiş ve elde edilen sonuçlar karşılaştırılmıştır.

Xiong ve arkadaşları [6], Japonya Ulusal Malzeme Bilimi Enstitüsü veri tabanında yer alan karbon çelikler ve düşük alaşımlı çelikler ile ilgili 360 adet veri üzerinde çalışmıştır. Veride yorulma dayanımı, çekme gerilimi, kopma gerilimi ve sertlik olmak üzere dört adet mekanik özellik seçilmiştir. 360 veri örneğini temsil eden malzemelerin mekanik özelliklerini tahmin etmek için Rastgele Orman, K-En Yakın Komşu, Yapay Sinir Ağı, Doğrusal En Küçük Kareler ve Sembolik Regresyon olmak üzere beş adet Makine Öğrenmesi algoritması kullanılmıştır. Elde edilen sonuçlara göre, Rastgele Orman Regresyonu en iyi tahmin performansını göstermiştir.

Azimi ve arkadaşları [7], düşük karbonlu çeliğin belirli örneklerinde mikroyapısal sınıflandırma yapmayı amaçlamıştır. Bunun için Derin Öğrenme yöntemi olan Maksimum Oylamalı Tamamen Evrişimsel Sinir Ağı yöntemi geliştirilmiş ve çalışmada sınıflandırma yapmak için kullanılmıştır. Elde edilen sonuçlar literatürdeki farklı çalışmalarla kıyaslanmış ve önerilen modelin çelik kalitesi değerlendirmesi için daha başarılı olduğu gösterilmiştir.

Muñoz-Rodenas ve arkadaşları [8], çelik mikroyapılarının görüntü sınıflandırması için farklı Makine Öğrenmesi tekniklerini ele almıştır. Tavlama, su verme ve temperleme olmak üzere üç adet ısı işlemleri yapılan çelik örnekleri çalışmada kullanılmıştır. Öğrenme modelleri, ilgili ısı işlemlere göre sınıflandırma yapmaktadır. Topluluk Öğrenmesi Yöntemleri, Karar Ağacı, Destek Vektör Makinesi, Naif Bayes, K-En Yakın Komşu ve Lojistik Regresyon Çekirdeği olarak 6 adet Makine Öğrenmesi modeli kullanılmıştır. Bunlara ek olarak Derin Öğrenme tabanlı GoogLeNet ve ResNet50 modelleri de değerlendirilmiştir. Elde edilen sonuçlara göre, Derin Öğrenme yöntemlerinin klasik Makine Öğrenmesi yöntemlerine göre daha yüksek performans sergilediği gösterilmiştir.

Cheloe Darabi ve arkadaşları [9], deneysel mikroyapılara dayalı olarak Faz Alanı Modelleme kullanmış ve çift fazlı çelik mikroyapılarından oluşan bir veri seti oluşturmuştur. Bu veri seti farklı ısı işlem koşullarında mekanik davranışları içermektedir. Tüm veri seti çift fazlı çeliklerin yeni işlem koşullarında çekme gerilimi, akma gerilimi ve kopma gerilimi olmak üzere üç mekanik özellikle etiketlenmiştir. Mekanik özelliklerin tahmini için VGG16 ve ResNet50 olarak adlandırılan iki transfer öğrenme yaklaşımı hibrit model olarak kullanılmıştır. Bu çalışma farklı alaşım veri setlerine uygulanarak araştırmacılara metal

özellikleri hakkında daha farklı bir bakış sunabilecek durumdadır.

Kibrete ve arkadaşlarının yaptığı çalışmada [10], yapay zekanın farklı türdeki kompozitlerin mekanik özelliklerini tahmin etmedeki uygulamaları yer almaktadır. Çalışmada yapay zekanın genel bir değerlendirmesi yapılmış ve ardından malzeme özelliklerinin tahmin edilme süreci açıklanmıştır. Kompozit malzemelerin mekanik özelliklerini tahmin etmede kullanılan çeşitli Makine Öğrenmesi ve Derin Öğrenme teknikleri değerlendirilmiştir. Araştırmacılar, bulgulara dayanarak malzeme özellikleri tahmin alanında karşılaşılan temel zorlukları tartışmakta ve gelecekteki araştırma yönleri hakkında öneriler sunmaktadır.

Literatürde mikroyapı resimlerinden doğrudan mekanik özelliklerin tahminine yönelik deneysel çalışmaların oldukça az olmasından dolayı bu çalışmada yaygın kullanılan bir karbon çeliğinde mekanik özellik değerlerinin mikroyapı resimlerinden Derin Öğrenme ile tahmin edilebilirliği araştırılmıştır. Bu amaç doğrultusunda AISI 1040 karbon çeliğinin hadde yönünde ve haddeye dik incelenen mikroyapı resimleri ile mekanik özellikler arasında ilişki kurulmaya çalışılmıştır. Hazırlanan veri seti üzerinde Derin Öğrenme algoritması olan Evrişimsel Sinir Ağı

eğitilip, test edilmiştir. Yapılan deneyler sonucunda akma, çekme ve kopma gerilimi tahmin edilmiştir.

2. MATERYAL VE METOD (MATERIAL AND METHODS)

Çalışmanın metodolojisi Şekil 1’de gösterilmektedir. Çalışmada ilk olarak çekme testi yapıp numuneler belirli gerilim altında kopma eylemi gerçekleştirmiştir. Test sonucunda akma, çekme ve kopma gerilimi değerleri ölçülmüştür. Sonrasında mikroyapı resimlerinin eldesi için metalografik numune hazırlama süreci gerçekleştirilmiştir. Metalografik numunenin hazırlandıktan sonra mikroskop altında görüntüleri alınıp, ferrit oranlarının analizi yapılmıştır. Elde edilen resimler ve analiz verilerinden veri seti hazırlanmıştır. Veri setinde üzerinde ferrit hacim oranına göre ayıklama ve görüntülerin artırımı işlemleri yapılmıştır. Veri seti hazır hale getirildikten sonra Evrişimsel Sinir Ağı algoritmasına giriş olarak verilmiş ve üzerinde eğitim yapılmıştır. Evrişimsel Sinir Ağı kullanılarak akma, çekme ve kopma gerilimi değerleri tahmin edilmiştir.



Şekil 1. Deneysel metodoloji (Experimental methodology)

2.1. Malzeme (Material)

American Iron and Steel Institute (AISI) 1040 çeliği, karbon içeriği açısından sertleşmeye uygun ve ısıtma işlemi sonunda belirli yükler altında yeterli dayanım ve tokluk sergileyen endüstride yaygın

kullanılan karbon çeliklerdir. AISI 1040 çeliği sıcak haddelenmiş olarak 10 mm çapında 6 metre boyunda silindirik halde Aydınlar Makine ve Metal Ltd. Şti. firmasından temin edilmiştir. Çalışmalarda kimyasal bileşimi Tablo 1’de verilmiş, AISI 1040 karbon çeliği kullanılmıştır.


Tablo 1. AISI 1040 çeliğinin kimyasal kompozisyonu (ağırlıkça %) (Chemical composition of AISI 1040 steel (by weight %))

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

2.2. Çekme Testi (Tensile Test)

Çekme testi, bir numunenin kopana kadar o numune üzerinde gerilimin uygulandığı bir malzeme bilimi testidir. Bu test sonucunda numunenin akma, çekme, kopma gerilimi ve toplam uzama gibi mekanik özellikleri belirlenir [11]. Çekme testleri

Instron 3369 model çekme test cihazı ile 1mm/dk hızla çekilerek veriler elde edilmiştir. Toplam 12 adet AISI 1040 çeliği test edilmiş olup çekme deneylerinde kullanılan çekme numunesinin boyutları Şekil 2’de verilmiştir.



Şekil 2. Deneylerde kullanılan çekme numunesinin boyutları (Dimensions of the tensile sample used in the experiments)


2.3. Metalografik Numune Hazırlığı ve

Mikroyapı İnceleme (Metallographic Sample

Preparation and Microstructure Analysis)

Her bir numunenin mikroyapılarının resimlerinin alınması için metalografik numuneler hazırlanması gerekmektedir. Bu numunelerin hazırlanması görüntülerin doğru bir şekilde alınması için önem

taşımaktadır. İlk olarak numunelerin hadde yönü ve haddeye dik kesitleri belirlenmiştir. Bu incelenen kesitler Şekil 3’te gösterilmiştir.



Şekil 3. Metalografik incelemelerde hadde yönü ve haddeye dik bölgelerin çekme numunesi üzerinde şematik gösterimi (Schematic representation of the rolling direction and transverse sections on the tensile sample in metallographic examination)

Şekil 3’te gösterildiği gibi numunelere karşıdan bakıldığında enine doğru olan kesit haddeye dik, boyuna olan kesit hadde yönü olmaktadır. Bu kesitlere göre kesme işlemi uygulanmıştır. Kesilmiş kısımlar alınıp bakalite alma işlemiyle kalıplanmıştır. Kalıplama yapıldıktan sonra zımparalama ve parlatma işlemi uygulanmıştır. Bu işlemlerin hemen ardından mikroyapıların açığa çıkarılması amacıyla %2 Nital çözeltisiyle dağlama yapılmıştır. Numunelerin, mikroyapıları Leica DFC 460 dijital kamera bağlantılı Leica DMI5000M optik mikroskop ile görüntülenmiş ve JPEG formatında mikroyapı resimleri kaydedilmiştir.

2.4. Veri Setinin Hazırlanması (Dataset Preparation)

Veri setinin hazırlanması sürecinde, mikroskoptan elde edilen görüntüler, alındıkları numunenin bölgelerine göre isimlendirilmiştir. İsimlendirme işlemi, dikey ve yatay eksenler dikkate alınarak gerçekleştirilmiştir. Dikey ekseninde yer alan bölgeler, isimlerinin önüne 'D' harfi eklenerek; yatay ekseninde yer alan bölgeler ise 'Y' harfi ile başlayacak şekilde adlandırılmıştır.

Alınan her bir 198 görüntünün boyutu 2560x1920 pikseldir. Görüntü sayısının az olması ve

boyutlarının büyük olması sebebiyle her bir görüntü 224x224 piksellere ayrılıp veri artırımı yapılmıştır. Görüntüler 224x224 piksel boyutlarını bölündüğünde bir görüntüden 108 görüntü oluşmaktadır. Veri artırımı yapıldığında toplamda 21384 görüntü elde edilmiştir.

Daha sonrasında elde edilen görüntüler, ferrit oranlarına göre ayıklanmıştır. Öncelikle 9 bölgenin ferrit oranlarının ortalaması alınmıştır ve denklem (1)'de belirtilmiştir.

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

\bar{x} : 9 bölgenin ferrit oranlarının ortalaması

x_i : i'nci bölgenin ferrit oranı

Histeresiz prensibi kullanılarak histeresiz marjı %0,3 seçilmiştir ve bu değere göre bir histeresiz bandı aralığı elde edilmiştir. Denklem (2)'de gösterilmiştir.

$$HBA = [\bar{x} - hm, \bar{x} + hm] \quad (2)$$

HBA : Histeresiz bandı aralığı

hm : Histeresiz marjı

9 bölgede gerçekleştirilen ferrit oranı analizinde, sonuçlara en çok katkıda bulunacak bölgelerin seçimi kombinasyonlar yardımıyla yapılmıştır. Bu kombinasyonlar yapılırken hem kombinasyon sayısının hem de kombinasyonda bulunan bölge adedinin en fazla olması amaçlanmıştır. Böylece, analiz süreci boyunca elde edilen verilerin genişliği

ve derinliği artırılarak, ferrit oranı üzerindeki etkilerin daha kapsamlı bir şekilde değerlendirilmesi sağlanmıştır. Bundan dolayı 9 bölgenin 5'li kombinasyonları alınıp bu kombinasyonlarda bulunan bölgelerin tamamının ferrit oranlarının ortalaması alınmıştır ve denklem (3)'te gösterilmiştir.

$$\bar{x}_C = \frac{1}{5} \sum_{j \in C} x_j \quad (3)$$

\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

Kombinasyonlardaki bölgelerin ferrit oranlarının ortalaması; belirlenen histeresiz bandı aralığına dahilse her bir bölge 1 olarak, dahil değilse her bir bölge 0 olarak işaretlenmiştir ve bu işleme dair indikatör fonksiyonu (4)'te gösterilmiştir.

$$I(\bar{x}_C) = \begin{cases} 1, & \bar{x}_C \in HBA \\ 0, & \bar{x}_C \notin HBA \end{cases} \quad (4)$$

$I(\bar{x}_C)$: İndikatör fonksiyonu

İsı haritasında 1 olan bölgeler belirtilmiş ve 1 olarak işaretlerin bölgelerin adedi o bölgelerin üzerinde sayı ile belirtilmiştir. Örneğin 3. numunenin haddeye dik kesitindeki bölgelerin ısı haritası Şekil 4'te verilmiştir.



Şekil 4. 3. numunenin haddeye dik kesitinden elde edilen ısı haritası (Heat map obtained from the transverse section of the third sample)

Isı haritasındaki en çok 1 ile işaretlenen bölgelerin adedine göre bu 9 bölgeden adedi en fazla olan 3 bölge seçilmiştir. Bu seçilen bölgelerdeki görüntüler veri setinin boyutunu belirlemiştir. Ferrit

oranına göre ayıklandığında toplam 7128 görüntü kalmıştır. Veri setindeki görüntü sayıları Tablo 2’de verilmiştir.

Tablo 2. Veri artırımı yapıldıktan sonra ferrit oranına göre elde edilen görüntü sayıları (The number of images obtained according to the ferrite ratio after data augmentation)

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


2.5. Evrişimsel Sinir Ağı (CNN) (Convolutional Neural Network (CNN))

Evrişimsel Sinir Ağı Derin Öğrenme alanındaki en önemli ağlardan biri olup ileri beslemeli bir sinir ağıdır. Sınıflandırma ve regresyon amaçlı kullanılabilir. Konvolüsyon yapılarıyla verilerden öznelikler çıkarabilirler [12]. Evrişimsel Sinir Ağı birden fazla katmandan oluşur. Evrişim Katmanı, Havuzlama Katmanı ve Tam Bağlı Katmanlar’dır [13-14].

Evrişim Katmanı, Evrişimsel Sinir Ağının birinci katmanıdır. Amaç görüntülerden öznelikleri çıkarmaktır. Bu öznelikleri çıkartırken filtreler kullanılmaktadır. Havuzlama Katmanı bilgi kaybı olmadan verilerin boyutunu indirgeyerek hesaplama karmaşıklığını azaltır. Maksimum Havuzlama, Ortalama Havuzlama, Stokastik havuzlama gibi yöntemler bulunmaktadır. Tam Bağlı katmanlar ise normal bir Sinir Ağındaki gibi

nöronlardan oluşmaktadır. Tam Bağlı Katmanlar’daki her düğüm kendinden hem önceki hem de sonraki katmandaki her düğüme bağlıdır [15-16].

Yapılan çalışmada 32, 64, 128’lik filtrelerle sahip Evrişim Katmanı ve bu katmanların ardından 2x2’lik Maksimum Havuzlama Katmanı kullanılmıştır. Ayrıca Tam Bağlı Katmanlar’dan önce Düzleştirme uygulanmıştır. Bu işlem çok boyutlu öznelik haritalarını tek boyutlu bir vektöre dönüştürerek Tam Bağlı Katmanlar’da kullanılabilir hale getirmektedir [17]. Düzleştirme işleminden sonra 128 nöronun bulunduğu Tam Bağlı Katmanlar bulunmaktadır. Bu katmanda Düzeltmiş Doğrusal Birim aktivasyon fonksiyonu kullanılmaktadır. Çıktı olarak akma, çekme ve kopma gerilimi tahmin edilmektedir. Evrişimsel Sinir Ağı’na ait katmanların görseli Şekil 5’te verilmiştir.



Şekil 5. Evrişimsel sinir ağı’nın katmanları (Layers of the convolutional neural network)

2.6. Test Ortamı (Test Environment)

Google Colab veya Colaboratory Makine Öğrenmesi ve Derin Öğrenme için kullanılabilir, kurulum gerektirmeyen bir Jupyter Notebook ortamıdır [18]. Deneyler bu ortamda Python programlama dili kullanılarak yapılmıştır.

2.7. Performans Metrikleri (Performance Metrics)

Bu çalışmada Evrişimsel Sinir Ağı modelinin performansını değerlendirmek için regresyon problemlerinde kullanılan, Ortalama Kare Hatası (Mean Square Error-MSE), Kök Ortalama Kare Hatası (Root Mean Square Error-RMSE), Ortalama Mutlak Hata (Mean Absolute Error-MAE) ve R-Kare (R2) metrikleri kullanılmıştır. Kullanılan metriklerin denklemleri sırasıyla (5), (6), (7) ve (8)'de verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

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

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

$$R2 = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} \quad (8)$$

y_i : Gerçek değerler

\hat{y}_i : Modelin tahmin ettiği değerler

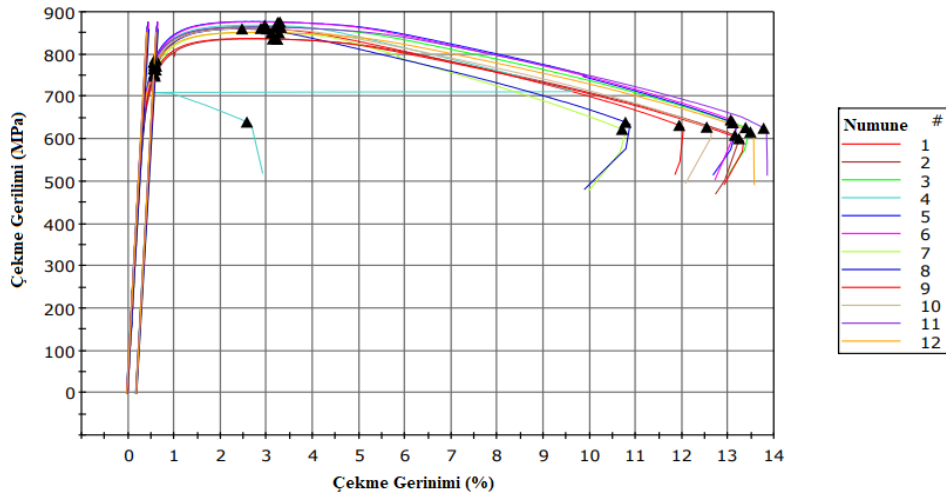
n : Örnek sayısı

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

3. DENEYSEL SONUÇLAR VE TARTIŞMA (EXPERIMENTAL RESULTS AND DISCUSSION)

3.1 Çekme Deneyi Sonuçları (Tensile Test Results)

Çekme testi sonucunda elde edilen verilerin çekme grafikleri Şekil 6'da gösterilmiştir. Şekil 6'daki grafikte çekme gerinimi yüzdelik uzamayı temsil ederken çekme gerilimi ise numunenin birim kesit alanına düşen yük miktarının MPa cinsinden gösterimidir. Grafığe bakılırsa 4. numunenin diğer numunelere göre erken bir kopma gerçekleştirdiği gözlemlenmektedir. Bu yüzden 4. numune deneylerde kullanılmamıştır. Çekme testi sonucunda elde edilen mekanik özellikler de Tablo 3'te gösterilmiştir.



Şekil 6. Çalışmalarda kullanılan toplam 12 numunenin çekme eğrileri (Tensile curves of the 12 samples used in the studies)


Tablo 3. Çekme testi sonucunda elde edilen mekanik özellik verileri (Mechanical properties data obtained from the tensile test)

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

3.2 Mikroyapı Görüntülerinin Analizi (Tensile Test Results)

Mikroyapı resimleri Şekil 7 (a)'da gösterildiği gibi alınmıştır. Her bir numuneden 9 adet haddeye dik, 9 adet hadde yönü olmak üzere toplamda 18 adet

mikroyapı resmi alınmıştır. Tüm numunelerde haddeye dik ve hadde yönü dahil olmak üzere 198 adet görüntü elde edilmiştir. Her bir görüntünün boyutu 2560x1920 pikseldir. Hadde yönü ve haddeye dik kesitlerin örnek görüntüleri Şekil 7 (b)'de verilmiştir.



Şekil 7. a) Haddeye dik ve hadde yönünde mikroyapı alınan bölgelerin şematik gösterimi ve b) Hadde yönü ve haddeye dik kesitlerden alınan mikroyapı resimleri ((a) Schematic illustration of the sections taken for microstructure analysis in the rolling and transverse directions, and b) microstructure images from the rolling direction and transverse sections)

Çeliklerin mekanik özelliklerinin belirlenmesinde çelikteki ferrit ve perlit miktarları önemli bir rol oynamaktadır. Bu iki yapının akma gerilimi, çekme gerilimi ve kopma gerilimi üzerinde büyük etkileri vardır. Ferrit yumuşak bir faz olduğundan ferrit miktarı arttıkça akma, çekme ve kopma gerilimi azalacaktır. Bunun aksine perlit miktarı arttıkça akma, çekme ve kopma geriliminde artış olacaktır. Perlit ise ferrite göre daha sert bir yapıdır [19-20].

Mikroyapı görüntüleri üzerinden akma, çekme, kopma gerilimi bulmak için ferrit hacim oranı, bu mekanik özelliklerin tahmininde yardımcı olacaktır. Her bir mikroyapı resmindeki ferrit hacim oranını bulmak için Leica Application Suite Versiyon 4.6 görüntü analiz yazılımı kullanılmıştır. Bu yazılımda resimler önce gri tonlamaya çevrilmiştir. Daha sonrasında ise ferrit ve perlit olan bölgeler kontrast farkıyla ayırt edilmiştir. Her numune ve her bölge için ferrit hacim oranları Tablo 4 ve Tablo 5'te verilmiştir.

Tablo 4. Hadde yönü kesitindeki resimlerin ferrit hacim oranları (%) ve ortalamaları (Ferrite volume fractions (%) and averages of the images in the rolling direction section)

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

Tablo 5. Haddeye dik kesitindeki resimlerin ferrit hacim oranları (%) ve ortalamaları (Ferrite volume fractions (%) and averages of the images in the transverse section)

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

Bu çalışmada, AISI 1040 çeliği çekme testi sonuçlarına göre akma, çekme, kopma gerilimi değerleri ile bu çeliğin mikroyapı resimleri kullanılarak Evrişimsel Sinir Ağı üzerinde eğitim yapılmıştır. Eğitimler sırasında A100 Grafik İşlem

Birimi kullanılmıştır. Eğitim sonucunda çıktı olarak akma, çekme ve kopma gerilimi değerleri tahmin edilmiştir. Evrişimsel Sinir Ağı'na ait hiper-parametreler ve açıklamalar Tablo 6'da verilmiştir.

Tablo 6. Evrişimsel Sinir Ağı'nda 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	mse	Modelin tahmin ettiği değerler ile gerçek değerlerin farklarının karesinin ortalamasıdır.

Evrişimsel Sinir Ağı eğitilmeden önce veri setinin %80'i eğitim, %20'si ise test için ayrılmıştır. Veri setinde toplamda 7128 örnek bulunmaktadır. Buna

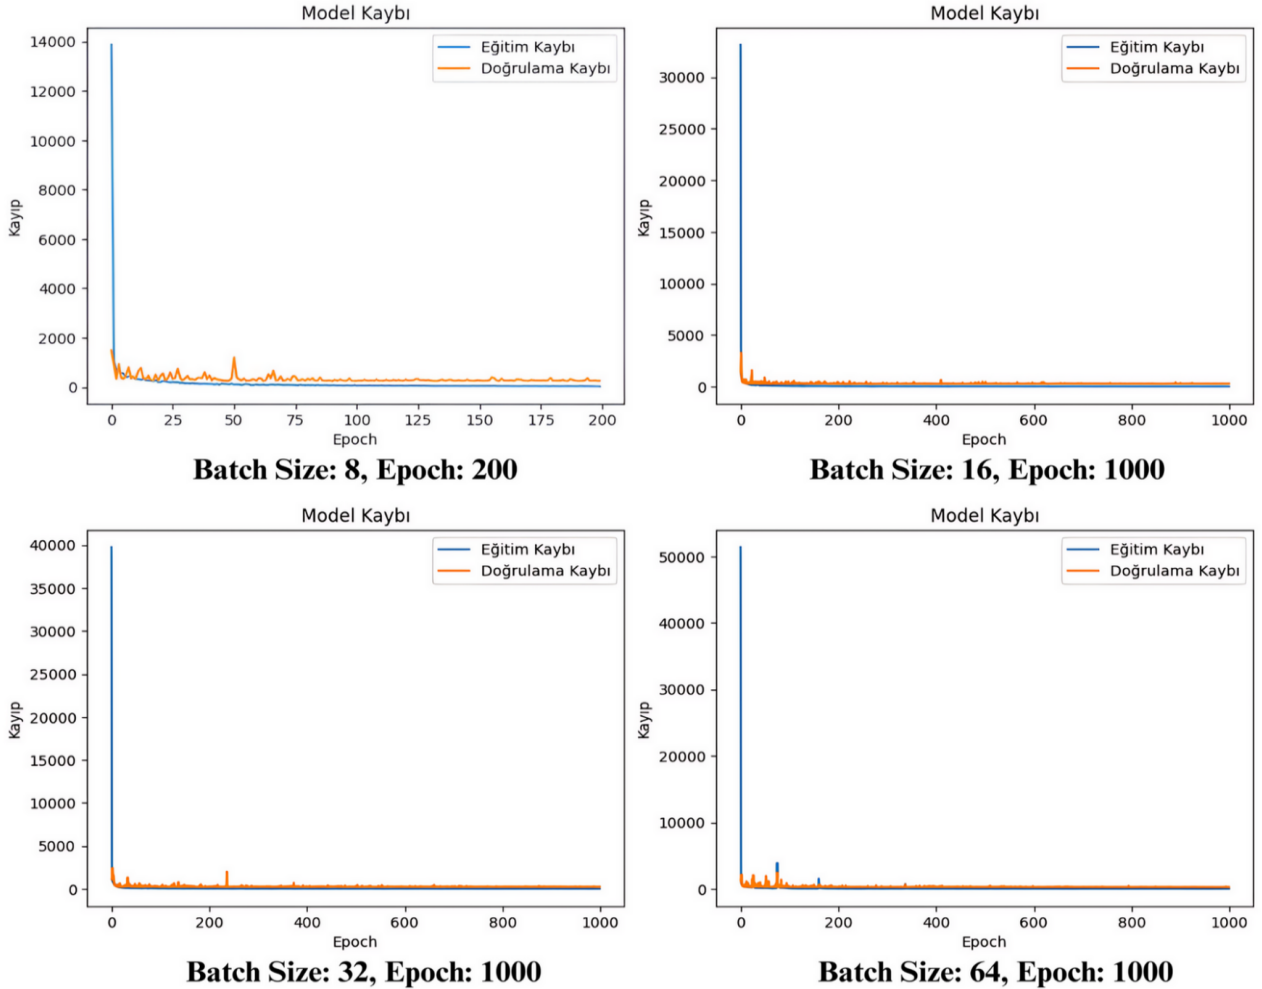
göre 5702 örnek eğitim, 1426 örnek de test olarak ayrılmıştır. Yapılan deneylerde farklı batch size ve epoch değerler kullanılmıştır (Tablo 7).

Tablo 7. Farklı batch size ve epoch değerlerinde elde edilen sonuçlar (Results obtained with different batch sizes and epoch values)

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

Buna göre sonuçlar incelendiğinde 8 batch size değerinde en başarılı sonuçlar tüm metriklerde 200 epoch'ta alınmıştır. 16, 32 ve 64 batch size değerlerinde ise tüm metriklerde en başarılı sonuçlar 1000 epoch sonunda alınmıştır. Farklı batch size değerlerinde en başarılı sonuçlar arasında

sırasıyla 64 batch size ve 1000 epoch, 16 batch size ve 1000 epoch ile eğitim gerçekleştirildiğinde elde edilmiştir. En başarılı sonuçların eğitimi sırasında ortaya çıkan eğitim ve doğrulama kaybı fonksiyonlarının grafiği Şekil 8'de gösterilmiştir.

**Şekil 8.** Eğitim ve doğrulama kaybı fonksiyonlarının grafiği (Graph of the training and validation loss functions)

64 batch size ve 1000 epoch eğitim sonucunda MSE: 4,36; RMSE: 2,08; MAE: 1,66; R2: 0,99 değerlerini almıştır. 16 batch size ve 1000 eğitim sonucunda ise MSE: 10,10; RMSE: 3,17; MAE: 2,52; R2: 0,99 değerlerini almıştır. Dikkat çeken sonuçlar ise R2 metriğinde olmuştur. Tüm batch size ve epoch değerlerinde R2 metriği yakın sonuçlar vermiştir.

4. SONUÇ (RESULT)

Bu çalışmada, endüstride yaygın olarak kullanılan AISI 1040 çeliğinin mikroyapısından bir Derin Öğrenme algoritması olan Evrişimsel Sinir Ağı ile akma, çekme ve kopma gerilimi tahmin edilmeye çalışılmıştır. AISI 1040 çeliğine çekme testi uygulanmış, test sonucunda akma, çekme ve kopma değerleri elde edilmiştir. 100x büyütmede optik

mikroyapı resimleri haddeye dik ve haddeye paralel olarak alınmış ve çekme testi sonucunda elde edilen değerler ile etiketlenmiştir. 7128 adet görüntüden oluşan veri seti literatüre kazandırılmıştır. Bu veri seti kullanılarak Evrişimsel Sinir Ağı ile deneyler gerçekleştirilmiştir. Deneyler sonucunda MSE'de 4,36; RMSE'de 2,08; MAE'de 1,66 ve R2'de 0,99'luk başarı oranı elde edilerek metalurji ve malzeme mühendisliğinde gelecekteki çalışmalara ışık tutmaktadır. Gelecekte yapılacak olan çalışmalarda; veri setindeki görüntü miktarının ve çelik türlerinin artırılması, transfer öğrenme modellerinin kullanılmasıyla birlikte başarı oranının artırılması sağlanabilir. Geliştirilen model yüksek performanslı gerçek zamanlı bir sisteme entegre edilerek üretim süreci dinamik hale getirilebilir ve ürün güvenilirliği artırılabilir.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The author of this article declares that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Rıdvan SERT: Veri arttırımı yaptı, veri setini oluşturdu. Modeli tasarladı ve deneylerde kullanıp sonuçlarını analiz etti. Makaleyi yazdı.

He performed data augmentation, created the dataset, designed the model, used it in experiments, and analyzed the results. He wrote the manuscript.

Ömer ŞAHİN: Çekme testlerini yaptı, numuneleri hazırladı. Numunelerin analizini yaptı.

He performed the tensile tests, prepared the samples, and analyzed the samples.

Volkan KILIÇLI: Çekme testlerini yaptı, analizlerini gerçekleştirdi. Makaleyi düzenledi ve eksik yerleri ekledi.

He performed the tensile tests and conducted the analyses. He edited the manuscript and added the missing sections.

Fecir DURAN: Modeli tasarladı, deneylerin sonuçlarını analiz etti. Makaleyi yazdı ve süpervizörlük yaptı.

He designed the model, analyzed the results of the experiments, wrote the manuscript, and supervised the work.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] S. Wang, J. Li, X. Zuo, N. Chen, and Y. Rong, "An optimized machine-learning model for mechanical properties prediction and domain knowledge clarification in quenched and tempered steels," J. Mater. Res. Technol., vol. 24, pp. 3352–3362, 2023.
- [2] G. Xu, J. He, Z. Lü, M. Li, and J. Xu, "Prediction of mechanical properties for deep drawing steel by deep learning," Int. J. Miner. Metall. Mater., vol. 30, no. 1, pp. 156–165, 2023.
- [3] M. A. Shaheen, R. Presswood, and S. Afshan, "Application of Machine Learning to predict the mechanical properties of high strength steel at elevated temperatures based on the chemical composition," Structures, vol. 52, pp. 17–29, 2023.
- [4] Y. Diao, L. Yan, and K. Gao, "A strategy assisted machine learning to process multi-objective optimization for improving mechanical properties of carbon steels," J. Mater. Sci. Technol., vol. 109, pp. 86–93, 2022.
- [5] A. Choudhury, "Prediction and analysis of mechanical properties of low carbon steels using machine learning," J. Inst. Eng. (India) Ser. D, vol. 103, no. 1, pp. 303–310, 2022.

- [6] J. Xiong, T. Zhang, and S. Shi, "Machine learning of mechanical properties of steels," *Sci. China Technol. Sci.*, vol. 63, no. 7, pp. 1247–1255, 2020.
- [7] S. M. Azimi, D. Britz, M. Engstler, M. Fritz, and F. Mücklich, "Advanced steel microstructural classification by Deep Learning methods," *Sci. Rep.*, vol. 8, no. 1, pp. 1–14, 2018.
- [8] J. Muñoz-Rodenas, F. García-Sevilla, J. Coello-Sobrinho, A. Martínez-Martínez, and V. Miguel-Eguía, "Effectiveness of machine-learning and deep-learning strategies for the classification of heat treatments applied to low-carbon steels based on microstructural analysis," *Appl. Sci. (Basel)*, vol. 13, no. 6, p. 3479, 2023.
- [9] A. C. Cheloe Darabi, S. Rastgordani, M. Khoshbin, V. Guski, and S. Schmauder, "Hybrid data-driven deep learning framework for material mechanical properties prediction with the focus on dual-phase steel microstructures," *Materials (Basel)*, vol. 16, no. 1, p. 447, 2023.
- [10] F. Kibrete, T. Trzepieciński, H. S. Gebremedhen, and D. E. Woldemichael, "Artificial intelligence in predicting mechanical properties of composite materials," *J. Compos. Sci.*, vol. 7, no. 9, p. 364, 2023.
- [11] D. Pandya and D. Shah, "Experimentation and its prediction of process parameters effects on elongation in tensile test of AISI 1008 steel using ANN model," *Procedia Technol.*, vol. 14, pp. 282–289, 2014.
- [12] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A survey of convolutional neural networks: Analysis, applications, and prospects," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 12, pp. 6999–7019, 2022.
- [13] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in *2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6.
- [14] A. Gülcü and Z. Kuş, "Konvolüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi," *Gazi Üniv. Fen Bilim. Derg. C Tasar. ve Teknol.*, vol. 7, no. 2, pp. 503–522, 2019.
- [15] N. Aloysius and M. Geetha, "A review on deep convolutional neural networks," in *2017 International Conference on Communication and Signal Processing (ICCSP)*, 2017, pp. 0588–0592.
- [16] A. Dhillon and G. K. Verma, "Convolutional neural network: a review of models, methodologies and applications to object detection," *Prog. Artif. Intell.*, vol. 9, no. 2, pp. 85–112, 2020.
- [17] R. H. Abiyev and A. Ismail, "COVID-19 and pneumonia diagnosis in X-ray images using Convolutional Neural Networks," *Math. Probl. Eng.*, vol. 2021, pp. 1–14, 2021.
- [18] "Google colab," *Google.com*. [Online]. Available: <https://colab.research.google.com/notebooks/welcome.ipynb>. [Accessed: 02-Apr-2024].
- [19] M. Ishtiaq, A. Inam, S. Tiwari, and J. B. Seol, "Microstructural, mechanical, and electrochemical analysis of carbon doped AISI carbon steels," *Appl. Microsc.*, vol. 52, no. 1, 2022.
- [20] X. Tu et al., "Enhancing strain capacity by the introduction of pearlite in bainite and polygonal ferrite dual-phase pipeline steel," *Materials (Basel)*, vol. 14, no. 18, p. 5358, 2021.