



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN:

URL:



U-Net modeli kullanılarak derin öğrenme ile AISI 4340 çeliğinde mikro yapı tahminlerinin ve inklüzyonların belirlenmesi

Prediction of microstructure and inclusion identification in AISI 4340 steel using a U-Net deep learning model

Yazar(lar) (Author(s)): Sefa Yücel AŞÇI¹, Furkan GÖKER², Tolga YILMAZ³, Ahmet GÜRAL⁴

ORCID¹: 0009-0003-2772-8763

ORCID²: 0009-0005-8002-0427

ORCID³: 0000-0001-9351-5887

ORCID⁴: 0000-0002-6211-8827

To cite to this article: Aşçı S. Y., Göker F., Yılmaz T. ve Güral A., “U-Net modeli kullanılarak derin öğrenme ile AISI 4340 çeliğinde mikro yapı tahminlerinin ve inklüzyonların belirlenmesi”, *Journal of Polytechnic*, *(*) : *, (*).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Aşçı S. Y., Göker F., Yılmaz T. ve Güral A., “U-Net modeli kullanılarak derin öğrenme ile AISI 4340 çeliğinde mikro yapı tahminlerinin ve inklüzyonların belirlenmesi”, *Politeknik Dergisi*, *(*) : *, (*).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1599580

U-Net Modeli Kullanılarak Derin Öğrenme ile AISI 4340 Çeliğinde Mikro Yapı Tahminlerinin ve İnküzyonların Belirlenmesi

Prediction of Microstructure and Inclusion Identification in AISI 4340 Steel Using a U-Net Deep Learning Model

Önemli noktalar (Highlights)

- ❖ AISI 4340 çeliğine ısıtma işlemi uygulanması / Heat treatment of AISI 4340 steel
- ❖ Numunelere metalografik işlemlerin uygulanması / Application of metallographic treatments to specimens
- ❖ Optik mikroskopta mikro yapı görüntülerinin elde edilmesi / Optical microscopic imaging of microstructures
- ❖ VGG16 ile mikro yapı sınıflandırma / Classification of microstructure with VGG16
- ❖ U-Net ile inküzyon segmentasyonu / Segmentation of inclusion with U-Net

Grafik Özet (Graphical Abstract)

AISI 4340 çeliğine çeşitli ısıtma işlemleri uygulanarak yapıda çeşitli mikro yapılar oluşturulmuştur. Elde edilen veriler derin öğrenme modelleriyle incelenmiştir. / Various heat treatments were applied to AISI 4340 steel to create a variety of microstructures. The resulting data was analyzed using deep learning models.



Şekil. Deneysel çalışmalar sürecinde uygulanan iş akış şeması. / **Figure.** Workflow chart utilized in experimental processes.

Amaç (Aim):

AISI 4340 çeliğinde bulunan martenzitik, bainitik, perlitik mikro yapıların ve inküzyonların derin öğrenme modelleri kullanarak tahmin edilmesi. / Prediction of martensitic, bainitic, pearlitic microstructures and inclusions in AISI 4340 steel using deep learning models.

Tasarım ve Yöntem (Design & Methodology):

Bu çalışmada VGG16 ve U-Net derin öğrenme mimarileri kullanılmıştır. / In this study, VGG16 and U-Net deep learning architectures were employed.

Özgünlük (Originality):

AISI 4340 çeliğinin mikro yapı görüntülerinin VGG16 ve U-Net modeli kullanılarak incelenmesi. / Analysis of AISI 4340 steel microstructure images using VGG16 and U-Net models.

Bulgular (Findings):

1000x ve 500x büyütme ile optik mikroskoptan alınan görüntüler yardımıyla mikro yapı sınıflandırma görevi için VGG16 modeli eğitildikten sonra %93,33 doğruluk değeri elde edilmiştir. İnküzyon tespiti için U-Net modeli mikro yapı görüntüleri ile eğitildikten sonra ise %73,59 dice skor değeri elde edilmiştir. / After training the VGG16 model for microstructure classification using images obtained from an optical microscope at magnifications of 1000x and 500x, an accuracy of 93.33% was achieved. Subsequently, the U-Net model was trained with the same microstructure images for inclusion detection, resulting in a Dice score of 73.59%.

Sonuç (Conclusion):

Mikro yapı görüntüleri derin öğrenme modelleriyle yüksek doğrulukta tahmin edilebilir. / Microstructure images can be predicted with high accuracy using deep learning models.

Etik Standartların Beyanı (Declaration of Ethical Standards):

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The authors of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

U-Net Modeli Kullanılarak Derin Öğrenme ile AISI 4340 Çeliğinde Mikroyapı Tahminlerinin ve İnküzyonların Belirlenmesi

Araştırma Makalesi / Research Article

Sefa Yücel AŞÇI^{1*}, Furkan GÖKER¹, Tolga YILMAZ¹, Ahmet GÜRAL¹

¹Gazi Üniversitesi, Teknoloji Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, 06500, Yenimahalle/ANKARA
(Geliş/Received : 10.12.2024 ; Kabul/Accepted : 01.02.2025 ; Erken Görünüm/Early View : 20.02.2025)

ÖZ

Malzeme özellikleri veya malzemelerin mikro yapıları incelenerek ve karakterize edilerek kesin bir şekilde belirlenebilir. Yeni bir malzemenin karakterizasyonu veya var olan bir malzemenin üretimi esnasında mikro yapı görüntüleri yol göstericidir. Bu görüntülerin incelenmesi maliyetlidir ve incelenecek malzeme konusunda uzman olmayı gerektirir. Uzman kişilerce incelenmelerine rağmen mikro yapı görüntülerinin analizlerinde öznel yargılar nedeniyle kusurlu sonuçlara varılabilmektedir. Mikro yapı fotoğraflarının doğru, hızlı ve optimum koşullarda değerlendirilmesi bu bağlamda önem arz eder. Gelişen yapay zeka teknolojisi ile mikro yapı görüntülerinin incelenmesi, zaman tasarrufu sağlar ve hataları minimuma indirmeyi hedefler. Derin öğrenme gelişmiş bir yapay zeka algoritmasıdır. Derin öğrenme modelleri, görüntü işleme problemlerinde yüksek doğrulukta sonuçlar vermektedir. Bu çalışmanın amacı AISI 4340 çeliğinde çeşitli mikro yapı görüntülerinin yapay zeka algoritmalarıyla incelenmesidir. AISI 4340 çeliğinde beynitik, martenzitik ve perlitik mikro yapıları üretmek amacıyla sırasıyla östemperleme, su verme ve normalizasyon ısı işlemleri uygulanmıştır. Isıl işlemler sonucu elde edilen farklı mikro yapılar ve inküzyonlar optik mikroskopta görüntülenmiş ve veri seti oluşturulmuştur. Mikro yapı sınıflandırma görevi için VGG16 ve inküzyon tanımlama görevi için ise U-Net modeli eğitilmiştir. Bu modellerden elde edilen sonuçlar ise şu şekildedir; VGG16 modeli %93,33 Doğruluk değeri ile mikro yapı tahmini yapmaktadır. U-Net modeli %98,50 Doğruluk ve %73,59 Dice skoru değerleri ile inküzyon saptaması yapmaktadır.

Anahtar Kelimeler: Derin Öğrenme, Mikro Yapı, Metalografi, Faz Dönüşümü, Isıl İşlem

Prediction of Microstructure and Inclusion Identification in AISI 4340 Steel Using a U-Net Deep Learning Model

ABSTRACT

The properties of materials can be definitively determined by examining their microstructure or characterisation. Microstructural imaging provides essential insights for both the characterization of novel materials and the optimization of manufacturing processes for existing materials. The analysis of these images is economically prohibitive and demands a high level of material-specific expertise. Despite expert analysis, the interpretation of microstructural images is susceptible to subjective bias, leading to erroneous conclusions. The precise, timely, and optimal assessment of microstructural images is of paramount importance in this field. Through the implementation of sophisticated artificial intelligence algorithms, the evaluation of microstructural images can be expedited, thereby reducing the likelihood of errors. Deep learning constitutes a sophisticated artificial intelligence algorithm. Deep learning models have exhibited a high degree of accuracy in image processing applications. The purpose of this research is to examine different microstructures of AISI 4340 steel by employing artificial intelligence algorithms. In order to produce bainitic, martensitic and pearlitic microstructures in AISI 4340 steel, austempering, quenching and normalization heat treatments were applied, respectively. Optical microscopy was employed to image diverse microstructures and inclusions resulting from different heat treatment processes, and the obtained images were compiled into a dataset. The VGG16 model was employed for microstructure classification, and the U-Net model was utilized for inclusion identification. The performance metrics of these models are as follows: The VGG16 model exhibited an accuracy of 93.33% in microstructure classification tasks. The U-Net model achieved an accuracy of 98.50% and a dice score of 73.59% for inclusion segmentation.

Keywords: Deep Learning, Microstructure, Metallography, Phase Transformation, Heat Treatment

1. GİRİŞ (INTRODUCTION)

Metalurji ve malzeme mühendisleri malzeme geliştirirken veya uygun malzeme seçerken yapı-işlem-özellik-performans ilişkisini göz önünde bulundurmak zorundadır. Bu ilişkinin ilk adımını malzemelerin mikro yapıları

oluşturmaktadır [1]. Mikro yapıdaki fazların hacmi, boyutu ve morfolojisi, malzemelerin mekanik özelliklerini doğrudan etkiler. Ancak malzeme karakterizasyonu, genellikle öznel değerlendirmeler içerir ve bu süreç hem zaman alıcı hem de maliyetlidir. Malzeme karakterizasyonunun nihai hedefi mikro yapı nicel analizini

*Sorumlu Yazar (Corresponding Author)
e-posta : sefayucelasci@gmail.com

en doğru şekilde yapmaktır [2]. Diğer taraftan günümüzde oldukça farklı alanlarda yer alan yapay zeka bu sürecin daha hızlı, kapsamlı gerçekleşmesi için veri işlemeden faydalanır ve veri işleme sürecini derin öğrenme modellerini kullanarak gerçekleştirir [3].

Derin öğrenme mimarileri, verilerden öğrendiği basit bilgileri kullanarak daha karmaşık bilgileri öğrenebilen birden çok katmana sahip olan yapay sinir ağlarıdır. Bu öğrenme modeli eğitim sırasında kullanılmak üzere değiştirilebilen evrişim ve aktivasyon değerleri gibi çok sayıda parametreye sahiptir [4]. Bu mimariyi iki aşamada incelemek mümkündür; mimarilerin oluşturulması ve eğitimi. Bu mimariyi oluşturduktan sonra eğitmenin amacı, katmanlardaki ağırlık parametrelerinin optimum şekilde kullanılabilir olmasıdır. Mimarinin giriş verisine göre derin öğrenme mimarileri değişiklik gösterirler. Örneğin ESA görüntü tanımlama görevini başarıyla yapabilen ve mimarisinde çeşitli katmanlar bulunduran bir derin öğrenme algoritmasıdır [5].

ESA derin öğrenme alanında en sık kullanılan algoritmalarından biridir. ESA'ların mimarisi canlıların nöral sistemden esinlenilerek tasarlanmıştır. Mimarisinde çeşitli eğitilebilir katmanlar barındırır; konvolüsyon katmanı, havuzlama katmanı, tam bağlantılı katman. ESA'lar bilgisayarlı görü, ses işleme, görüntü tanımlama gibi görevlerde yüksek verimlilikte çalışabilirler [6].

¹(Larmuseau vd., 2021), yaptığı çalışmada toplamda 134 mikro yapı fotoğrafı kullanarak eğittikleri derin öğrenme modelini insanları derin öğrenme ile kıyaslamak adına mikro yapı alanında uzman ve bu alanda uzman olmayan toplam 56 katılımcıdan oluşan bir grupla çalışmıştır. Bu test iki aşamadan oluşmaktadır. İlk aşamada uzman metalurji ve malzeme mühendislerinin aşına olduğu görüntüler kullanılmıştır. İlk aşamanın sonucunda uzmanlar görüntüleri ortalama %73 doğrulukla sınıflandırırken derin öğrenme modeli %81 doğrulukla doğru cevabı bulmuştur. En iyi performansı gösteren uzman ise %86 doğrulukla testi tamamlamayı başarmıştır. İkinci testte uzmanlar ortalama %67 doğruluk oranıyla tamamlarken derin öğrenme modeli testi %100 tam doğrulukla tamamlamıştır [7].

(Han vd., 2022), derin öğrenme kullanarak ayırışma çeliğinde mikro yapıdaki faz ve kusur tanımlaması yapmışlardır. Mikro yapı tanımlamasını evrişimli sinir ağlarından kendi oluşturdukları U-Net modeliyle gerçekleştirmişlerdir. Bu modeli eğitmek için çözünürlüğü 1024 x 1024 piksel olan 62,216 mikro yapı fotoğrafı kullanmışlardır. Bu çalışmanın sonucunda model perlit fazını %89,95, inklüzyonları ise %90,86 doğruluk oranıyla saptamıştır [2].

(Chowdhury vd., 2016), derin öğrenme modelleri kullanarak bakır alaşımının dendritik mikro yapısını

sınıflandırma yöntemini ile saptamışlardır. %91,85 doğruluk değeri elde etmişlerdir [8].

(Biswas vd., 2023), açık kaynak MetalDAM veri setini kullanarak eklemeli imalat yöntemiyle üretilen çelikler üzerine çalışmışlardır. Veri seti 1280×895 ve 1024×703 çözünürlüklerinde 42 etiketli görüntü içermektedir. U-Net modelini çeşitli eklentilerle destekleyerek model doğruluğunu arttırmayı hedeflemişlerdir. Bu görüntüleri kullanarak mikro yapıdaki fazların oranları yüksek doğrulukla tespit etmişlerdir [9].

(Durmaz vd., 2021), "ImageNet" veri seti ile eğitilmiş VGG16 omurgasını U-Net modeline entegre etmişlerdir. Bu modifikasyon ile yaklaşık %90 "IoU" skoruna ulaşmışlardır [10].

Bu çalışmada, malzemelerin mikro yapılarını daha hızlı ve doğru inceleyebilmek adına yapay zeka modellerinin kullanılabilirliği düşünülmüştür. Araştırmalarımız sonucunda, yapılan çalışmalarda derin öğrenme için model oluştururken çalışma için seçilen AISI 4340 çeliğinden elde edilen mikro yapı fotoğraflarından oluşan bir veri setinden faydalanılmadığı tespit edilmiştir. Ayrıca literatürde kullanılan veri setlerinin benzer veri tabanlarından alındığı saptanmıştır. Bu çalışmamızda AISI 4340 çeliği numunelerine ayrıca normalizasyon, östemperleme, su verme ısı işlemleri uygulanıp mikro yapıda perlit, beynit ve martenzit fazları elde edilmiştir. Bu görüntülerden, segmentasyon ve sınıflandırma görevi için iki farklı veri seti oluşturulmuştur. Oluşturulan veri setleriyle iki farklı derin öğrenme modeli eğitilmiş olup bu modellerle mikro yapıdaki fazlar ve inklüzyonlar saptanması üzerine çalışmalar yapılmıştır.


2. MALZEME VE YÖNTEM (MATERIAL AND METHOD)

2.1. Malzeme (Material)

AISI 4340 çeliği alaşımli çelikler arasında daha düşük maliyeti, yüksek mekanik özellikleri ve sertleştirilebilir olmasıyla geniş uygulama alanına sahiptir [11]. Yüksek dayanım ve tokluk kombinasyonu sayesinde havacılıkta uçak iniş takımlarında, vites kutusu dişlilerinde, otomotiv güç aktarım organlarında kullanılmaktadır. AISI 4340 çeliğinde bulunan alaşım elementlerinden Cr, Ni, Mo, ve Mn sertleşebilirliği ve yorulma direncini artırır [12]. Bu çalışmada beynitik, martenzitik ve perlitik mikro yapıların üretimine daha elverişli olması sayesinde, 12 mm çapında 15 mm uzunluğundan üç adet silindirik AISI 4340 çeliği kullanılmıştır. Çalışmada kullanılan çeliğin kimyasal kompozisyonu Tablo 1'de ve deneysel çalışmada uygulanan işlemlerin iş akış özeti Şekil 1'de şematik olarak verilmiştir.

Tablo 1. AISI 4340 malzemesinin kimyasal bileşimi (ağ.%). (**Table 1.** Chemical Composition of AISI 4340 Steel (wt.%).

C	Ni	Cr	Mn	Si	Cu	Mo	Al	Fe	N	Co	V	P	S
0.384	1.487	1.478	0.782	0.228	1.189	0.162	0.021	94.232	0.019	0.0074	0.0058	0.001	0.0039

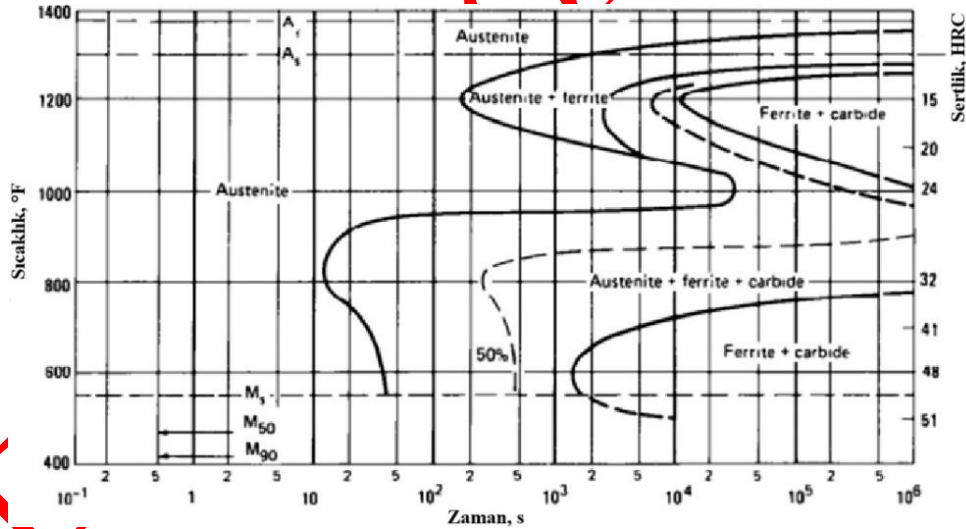


Şekil 1. Deneysel çalışmalar sürecinde uygulanan iş akış şeması. (**Figure 1.** Workflow chart utilized in experimental processes.)

2.2. Isıl İşlemler (Heat Treatments)

Derin öğrenme çalışmalarında kullanılmak üzere AISI4340 çeliğinde beynitik, martenzitik ve perlitik mikro yapılar seçilmiştir. AISI4340 numunelerinde farklı mikro yapılar üretilebilmesi için Şekil 2’de 4340 çeliğine ait verilen izotermal soğuma eğrileri kullanılmıştır. Numunede beynitik yapı oluşturmak için östemperleme işlemi uygulanmıştır. 845°C’de 30 dakika östenitleme, 300°C’de 60 dakika östemperleme işlemi uygulandı. Bu numune işlem sonrasında beynitik mikro yapı “BM” olarak kodlandı. İkinci ısıl işlem olarak, farklı bir numunede

martenzitik mikro yapı oluşturmak için su verme işlemi uygulanmıştır. Bunun için 845°C’de 30 dakika östenitleme, 80°C’de su verme ve 400°C’de 60 dakika süreyle temperleme işlemleri uygulandı. Bu işlem sonrasında martenzitik mikro yapı üretildiği için “MM” olarak kodlandı. Üçüncü ısıl işlem olarak, son numunede daha homojen ve homojen dağılımlı perlitik mikro yapı oluşturmak için normalizasyon ısıl işlemi uygulanmıştır. Bunun için, 845°C’de 30 dakika östenitleme ve östenitleme işleminden sonra oda sıcaklığına havada soğutulmuştur. Bu işlem sonrasında numuneden perlitik mikro yapı üretildiği için “PM” olarak kodlanmıştır [13].



Şekil 2. Farklı mikro yapıların üretilmesinde faydalanılan 4340 çeliğinin izotermal dönüşüm diyagramı [14]. (**Figure 2.** Isothermal transformation diagram of AISI 4340 steel used for producing different microstructures [14].)

2.3. Metalografik Numune Hazırlığı (Metallographic Sample Preparation)

Isıl işlem uygulanan numunelere, mikro yapıları optik mikroskopta görüntülemek için yüzey işlemleri uygulanmıştır. Numuneler sıcak kalıplama yöntemiyle 20 mm çapında bakalite alınmıştır. Numuneler, silisyum karbür zımpara kağıtlarıyla sulu zımparalanmıştır (120-

1200#). Zımparalanan numuneler 6 ve 3 µm’lik elmas solüsyonlar ile parlatılmıştır. Dağlama işlemi için tüm numuneler %2 nital ile dağlandıktan sonra yalnızca MM numunesi %15 sodyum metabisülfid ile dağlanmıştır. Bu sayede martenzit çıtalrı dağlamanın etkisiyle optik mikroskopta farklı renkte gözükmetedir [15].

2.4. Veri Seti Hazırlığı (Dataset Preparation)

Mikro yapı sınıflandırması ve inklüzyon segmentasyonu için iki farklı veri seti hazırlanmıştır. Mikro yapıların sınıflandırması için optik mikroskopta numunelerden 1000x büyütmede toplamda 96 fotoğraf alınmıştır. Tiff formatında, 2560x1920 çözünürlükte alınan fotoğraflar beynit, martenzit ve perlit olarak isimlendirilerek gruplandırılmıştır. Inklüzyon segmentasyonu için Tiff formatında 2560x1920 çözünürlükte 112 fotoğraf alınmıştır. Alınan fotoğraflar üzerinde inklüzyonlar manuel olarak etiketlenmiştir. Etiketlenen fotoğraflar segmentasyon işlemi için maskelendikten sonra Jpeg formatına dönüştürülmüş ve 640x640 çözünürlüğe düşürülmüştür. Model doğruluğunu artırmak için fotoğraflara “data augmentation” yöntemi uygulanmıştır. Data Augmentation yöntemi modelin eğitim sürecini benzer resimler oluşturarak desteklemektedir [16].

2.5. Derin Öğrenme Modelleri (Deep Learning Models)

2.5.1 Evrişimli sinir ağları (Convolutional neural networks)

Evrişimli sinir ağları (ESA'lar), karmaşık problemleri çözmek için tasarlanmış bir yapay zeka algoritmasıdır. Geçmişinin 1980'li yıllara kadar uzanmasına rağmen günümüzde işlemcilerin gelişmesiyle beraber hesaplama gücündeki artış, büyük veri setlerinin elde edilebilmesi ve gelişmiş yapay zeka öğrenme yöntemleri sayesinde çoğu alanda yüksek performans sergileyebilmektedir. Bu nedenle, ESA'lar birçok görsel uygulamada son teknoloji yaklaşımlar olarak kabul edilmektedir [17]. Çeşitli katmanların eğitilmesi temeline dayanan ESA mimarileri eğitim sonrasında pikselleri birleştirerek kenar motiflerini ve kenar motiflerini de birleştirerek resimleri baştan oluşturmaktadır [18].

Konvolüsyon katmanında, çekirdek (kernel) bir sonraki katman için özellik haritası çıkarmaya çalışır. Çekirdek bir matristir ve bu matris tüm görüntüye konvolüsyon işlemi ile uygulanır. Temelde bu işlem iki matrisin çarpımı şeklinde gerçekleşir. Konvolüsyon katmanının dezavantajı ise özellik haritalarında karşımıza çıkar. Evrişim katmanları giriş verisindeki yakaladığı özelliklerin (örn. piksel) kesin konumunu kaydeder. Ancak giriş verisinde yaşanacak herhangi bir değişiklik farklı bir özellik haritasını gerektirir, mevcut harita ile örtüşmez. Bu durumu önlemek adına havuzlama katmanları kullanılır. Havuzlama katmanı giriş verisindeki küçük değişiklikleri

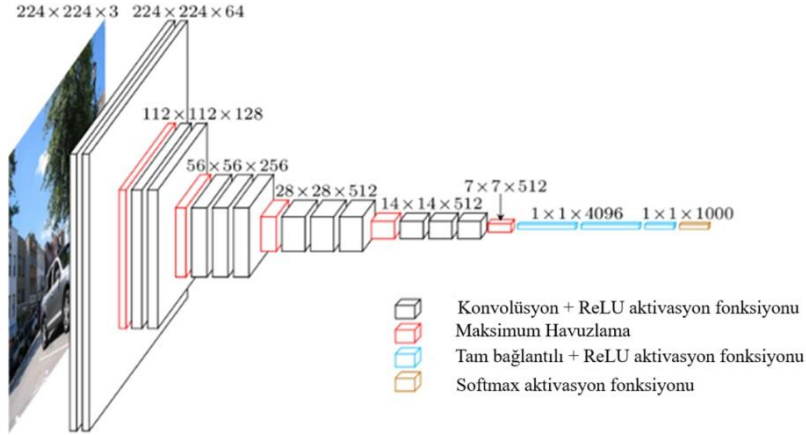
görmezden gelerek çıktı verisinde devamlılık sağlamak için kullanılır. Havuzlama katmanının (pooling layer) çıktısı tam bağlantılı (fully connected layer) katmanda girdi olarak kullanılır. Tam bağlantılı katman nöral ağdaki katmanları birbirine bağlamaktan sorumludur. ReLU, ESA mimarisinde kullanılan parçalı doğrusal bir aktivasyon fonksiyonudur. Katmanlar arasındaki giriş ve çıkış verilerinin düzenlenmesinde kullanılır [19].

2.5.2 Mikro yapı sınıflandırması için VGG16 (VGG16 for microstructure classification)

VGG16 modeli, büyük miktardaki verileri kullanarak onlardan yüksek doğrulukla sonuç elde edebilen bir derin öğrenme modelidir. Özellikle sınıflandırma görevlerinde diğer modellere kıyasla yüksek performans sağlamaktadır. VGG16 evrişim, havuzlama, tam bağlantılı, normalizasyon gibi katmanları mimarisinde kullanır. Bunun yanı sıra yüksek doğrulukla sonuçlar elde etmek için ReLU ve Softmax fonksiyonlarından faydalanır. VGG16 modelinde havuzlama katmanı haricinde 16 katman vardır. Bu modelde kullanılacak giriş görüntü boyutu 244x224 piksel olarak ayarlanır. Uygulanacak filtrenin boyutu ise 3x3 olmalıdır [20].

İnsanların görevler arasında bilgi transfer etme yeteneklerinden ilham alan aktarımlı öğrenme, bir kaynak alandan bilgi kullanarak öğrenme performansını artırmayı veya bir hedef alanda gerekli etiketli örneklerin sayısını en aza indirmeyi amaçlar. Bu, özellikle sınırlı etiketli örneklerle görevleri ele alırken büyük önem taşır [21].

ImageNet geniş çaplı veri kümesi oluşturmayı hedefleyen bir araştırma projesidir. VGG-16 ve VGG-19 gibi derin öğrenme modelleri ImageNet veri seti üzerinde eğitilmiştir [22]. Bu modeller yüksek işlem gücüne sahip grafik işlemciler kullanılarak sıfırdan geliştirilmiş ve büyük ölçekli görüntü sınıflandırma görevlerinde başarıyla uygulanmıştır. Model büyük bir veri kümesi üzerinde eğitildiği için, mekansal, kenarlar, döndürme, aydınlatma, şekiller gibi düşük seviyeli özelliklerin iyi bir temsilini öğrenmiştir ve bu özellikler, bilgi transferini sağlamak ve farklı bilgisayarla görme problemlerinde yeni görüntüler için bir özellik çıkarıcı olarak işlev görmek üzere paylaşılabılır. Yeni görseller orijinal veri setinden farklı sınıflara ait olabilir fakat yine de transfer öğrenme prensipleri doğrultusunda önceden eğitilmiş model bu görsellerden anlamlı özellikler çıkarmayı sürdürebilmektedir [19].

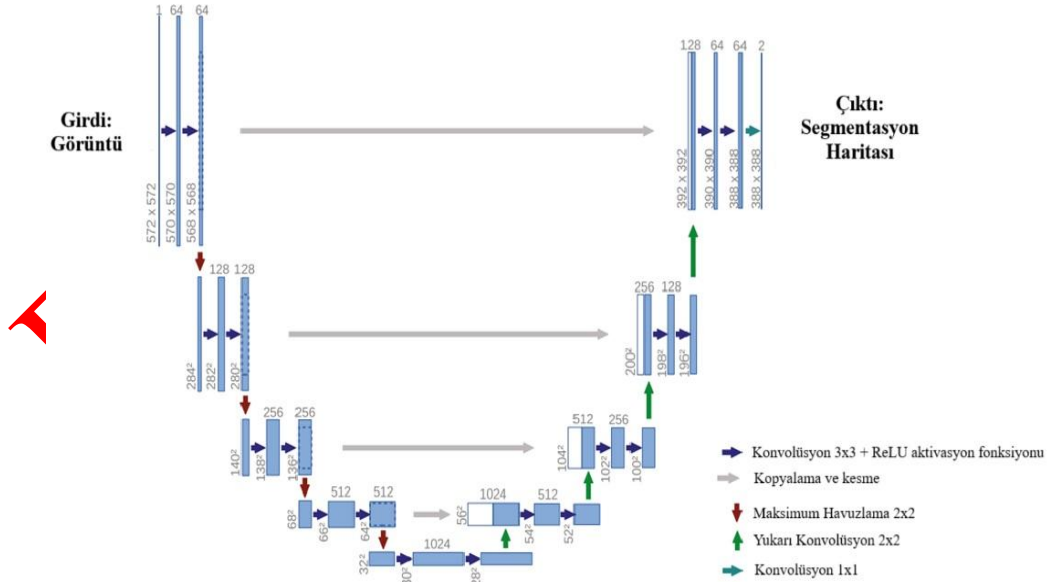


Şekil 3. VGG16 mimarisi [23]. (Figure 3. VGG16 architecture.)

2.5.3 İnküzyon segmentasyonu için U-Net (U-Net for inclusion segmentation)

Segmentasyon problemlerinde evrişimli sınır ağlarının aksine eğitilen modelin görüntü çıktısının piksel düzeyinde lokalizasyon bilgilerini de içermesi gerekir. U-Net mimarisi bu problemi çözmek için tasarlanmıştır ve iki ana bölümden oluşur: Alt örnekleme yolu ve üst örnekleme yolu. Alt örnekleme yolunun çalışma prensibi evrişimli sınır ağlarıyla benzerdir. 3×3 boyutunda konvolüsyon katmanı ardışık olarak uygulanır ve her katmandan sonra doğrusal olmayan ReLU aktivasyon fonksiyonu kullanılır. Ardından 2×2 boyutunda maksimum havuzlama işlemi gerçekleştirilir [24]. Bu alt örnekleme adımları sırasında modelin daha karmaşık özellikleri öğrenebilmesi için

özellik kanallarının sayısı her adımda iki katına çıkarılır. Üst örnekleme yolu alt örnekleme yolunun simetridir. 2×2 boyutunda bir konvolüsyon katmanı ile başlar ve bu işlem esnasında özellik kanallarının sayısı yarıya indirilir. Sonrasında alt örnekleme yolunda karşılık gelen özellik haritasıyla birleştirilir. Bu sayede model eğitilirken hem düşük hem yüksek seviyeli özellikleri aynı anda öğrenir. Sonrasında her biri ReLU aktivasyonu ile desteklenen iki adet 3×3 boyutunda konvolüsyon katmanı uygulanır. Üst örnekleme yolunda konvolüsyon işlemleri sırasında kaybolan sınır piksellerini telafi etmek için kırpma işlemleri yapılır. Son katmanda 64 bileşenli özellik vektörleri 1×1 boyutundaki bir konvolüsyon katmanı ile istenen sınıf sayısına indirgenir ve nihai çıktı üretilir [25].



Şekil 4. U-Net mimarisi [25]. (Figure 4. U-Net architecture.)

2.6. Metrikler (Metrics)

Bu çalışmada VGG16 model performansını değerlendirmek için Doğruluk (Accuracy) metriği kullanılmıştır. Bu metrik Imagenet ile eğitilmiş modellerde modelin eksikliğini bulma konusunda başarılıdır ve kullanım

kolaylığı sağlar [26]. Doğruluk, bir algoritma tarafından yapılan tüm tahminler içindeki doğru tahminlerin oranıdır. Hassasiyetin hatırlamaya bölünmesiyle veya 1 eksi yanlış negatif oranın yanlış pozitif orana bölünmesiyle hesaplanabilir. Doğruluk hesaplama denklemi Eşitlik 1’de gösterilmiştir [27].

$$\text{Doğruluk} = \frac{TP + TN}{TP + FN + TN + FP} \quad (1)$$

Burada; TP: Doğru Pozitif, TN: Doğru Negatif, FN: Yanlış Negatif, FP: Yanlış Pozitif.

Dice skoru, görüntü segmentasyonu yapmak üzere iki veri kümesi arasındaki benzerliği ölçen bir metriktir. Dice skoru görüntüdeki gerçek maske ve tahmin edilen maske arasındaki örtüşmeyi hesaplayarak 0 ile 1 arasında bir sonuç verir. 1 sonucu tam eşleşmeyi temsil ederken, 0 hiç eşleşme olmadığını belirtir [28]. Dice skoru, iki farklı

kümenin kesişiminin büyüklüğünün 2 katının kümelerin boyutlarının toplamına bölünmesi olarak açıklanabilir. Dice skoru yanlış pozitifleri ve yanlış negatifleri dengelediği için eğitilen modelin segmentasyon performansını değerlendirmede etkili sonuçlar vermektedir [29]. Eşitlik 2’de dice skoru metriği verilmiştir [30].

$$\text{Dice Skoru} = 2 \times \frac{|P \cap T|}{|P| + |T|} \quad (2)$$

P: Model tahmini, T: Temel gerçek etiketler.

3. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)


3.1. Isıl İşlem Sonuçları (Heat Treatment Results)

Mikro yapılarında beynitik, martenzitik ve perlitik faz ve yapılar üretmek amacıyla yapılan ısıl işlemler sonucunda elde edilen mikro yapılar Şekil 5, Şekil 6 ve Şekil 7’de sırasıyla verilmiştir. Şekil 5’de 845°C’de 30 dakika östenitleme, 300°C’de 60 dakika östempereleme işlemi ile BM numunesinde tipik alt beynitik yapı üretilebilmiştir. Beynitik dönüşümü Ms sıcaklığının üzerinde izotermal tavlama sonunda karbonca zengin östenitin lamelli olarak ince ferritik ve sementit karışımından oluşan ve genelde optik mikro yapısı temperlenmiş martenzitik faza benzeyen bir yapıdır.


Şekil 6’da MM numunesinde 845°C’de 30 dakika östenitleme ve 400°C’de 60 dakika süreyle temperleme işlemi uygulanarak martenzitik mikro yapısı üretildi. Tipik bir martensit fazı, yüzey merkezli kübik (YMK) kristal yapısına sahip östenit fazının yeteri kadar karbonca zenginleştirilmesinin ardından hacim merkezli tetragonal (HMT) faza döner. Optik mikro yapısında HMT fazın şiddetli çarpılması ile çita tipi mikro yapıya dönüşmektedir.

Aynı zamanda YMT kristal yapısının HMT yapısına anlık dönüşümünden dolayı alaşım elementlerinin de etkisinden dolayı martenzitik çita sınırlarında kalıntı östenit bulunabilir. Muhtemelen Şekil 6’da açık renkli alanlarda martenzite dönüşemeyen kalıntı östenitlerin varlığı da düşünülmektedir. Bununla birlikte, derin öğrenme ile öğretilen işlemle hem beynitik hem de martenzitik mikro yapıların ayırt edilebileceği de test edilmiş oldu.


Şekil 7’de PM numunesinde 845°C’de 30 dakika östenitleme işleminden sonra oda sıcaklığına havada soğutulmuş üretilen perlitik mikro yapılar gösterilmiştir. AISI 4340 çeliğinde alaşım elementleri ötektoid karbon bileşimini sade karbonlu çeliklerde % 0.8 olarak bilinenden daha düşürdüğünden mikro yapıda neredeyse tamamen perlitik yapı üretildiği görülmüştür. Normalizasyon işlemi ile AISI 4340 çeliğin mikro yapısını daha homojen daha eş aksel perlitik kolonileri üretimini sağlamıştır. Bununla birlikte, perlit kolonileri içinde düzgün lamelli olmayan sementit ve ferrit katmanları oluştuğu görülmüştür. Perlitik dönüşüm bazen hızlı soğutma ve bazen de alaşım elementlerinin etkisi ile düzgün lamelli perlit üretmeyebilir.



Şekil 5. %2 Nital ile dađlanmıř AISI 4340 eliđinin 1000x bytmede BM numunesinin optik Beynit mikro yapısı. (Figure 5. Optical microstructure of the BM specimen of AISI 4340 steel etched with 2% Nital at 1000x magnification.)



Şekil 6. %2 Nital ve %15 sodyum metabislfit ile dađlanmıř AISI 4340 eliđinin 1000x bytmede MM numunesinin martenzitik mikro yapısı. (Figure 6. Optical micrograph of a martensitic microstructure in AISI 4340 steel specimen MM, etched with a solution of 2% Nital and 15% sodium metabisulfite, at 1000x magnification.)

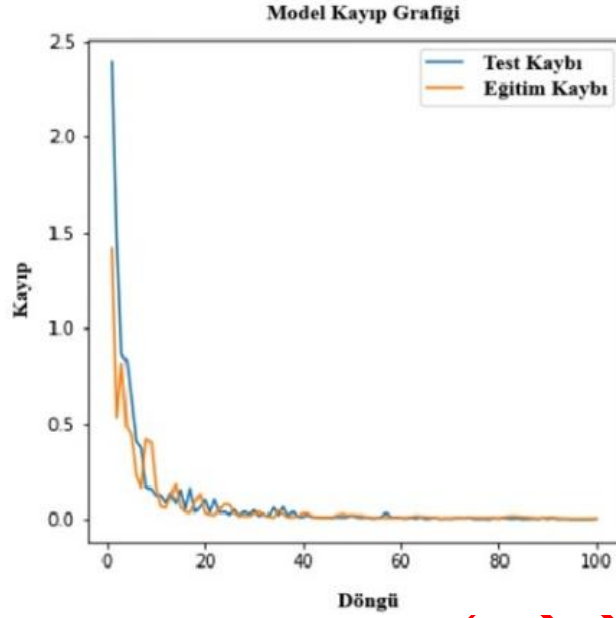


Şekil 7. %2 Nital ile dađlanmıř AISI 4340 eliđinin 500x bytmede PM numunesinin perlitik mikro yapısı. (Figure 7. Optical micrograph of a pearlitic microstructure in AISI 4340 steel specimen PM, etched with 2% Nital, at 500x magnification.)


3.2. VGG16 Modeli Sınıflandırma Sonuları (Classification Results of the VGG16 Model)

Mikro yapı grntleri ncelikle  kategoriye blnmřtr. Martenzit, beynit ve perlit olarak ayrılan mikro yapı grntleri VGG16 modeliyle eđitilmiřtir. Eđitilen model, sınıflandırma modelleri iin kullanılan ok

Sınıflı Logaritmik Kayıp, Dođruluk, Karıřıklık Matrisi fonksiyonları ile test edilmiřtir. Model; 100 dng, 32 Batch size, 512x512 znrlkte eđitilmiřtir. Eđitilen model %93,33 Dođruluk deđeri ile tahmin yapmaktadır. Kullanılan fonksiyonların grafikleri Şekil 8 ve Şekil 9'da verilmiřtir.



Şekil 8. Kayıp Fonksiyonu. (Figure 8. Loss Function.)



Şekil 9. Karışıklık Matrisi. (Figure 9. Confusion Matrix.)

3.3. U-Net Modeli Segmentasyon Sonuçları (Segmentation Results of the U-Net Model)

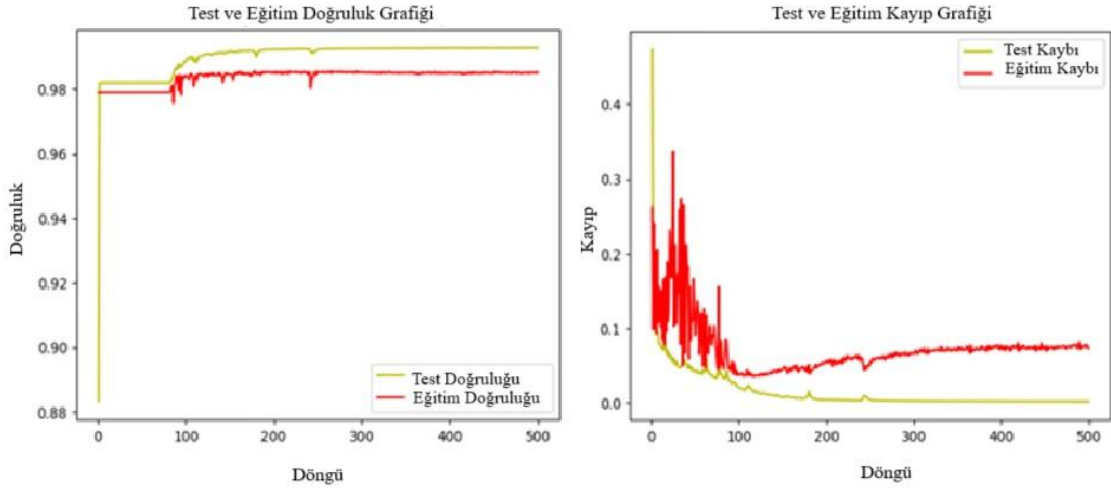
Mikro yapı görüntülerindeki inklüzyonun varlığını saptamak için, inklüzyon bulunan mikro yapı görüntüleri maskelenmiştir. Maskelenen görüntüler U-Net modeli kullanılarak farklı batch size ve döngü değerleriyle eğitilmiştir. Eğitilen model segmentasyon modelleri için kullanılan Dice Skoru ve Doğruluk metrikleri ile test edilmiştir. Her bir eğitim için doğruluk ve dice skoru metrikleri Tablo 2’de verilmiştir. Model en iyi sonucu 16 batch size ve 500 döngü ile eğitildiğinde vermiştir. Bu

parametrelerde %98,50 Doğruluk ve %73,59 Dice Skoru değerleri elde edilmiştir. Doğruluk ve Kayıp grafikleri Şekil 10’da görülmektedir. Bu parametrelere göre eğitilen modelin çıktıları Şekil 11’de görülmektedir.


Bu çalışmanın sonucunda AISI 4340 mikro yapısından elde edilen veriler bir derin öğrenme modeli kullanılarak eğitilmiştir. Bu eğitilen veriler kullanılarak çeliğin mikro yapıları sınıflandırılmıştır (ferrit-perlit, martenzit, beynit). Mikro yapının içerisinde inklüzyonun tayini yapılmıştır.

Tablo 2. Karşılaştırmalı analiz sonuçları. (Table 2. Comparative analysis results.)

	Döngü	Doğruluk (%)	Dice Skoru (%)
Batch size 4	150	98,43	66,83
	300	98,46	66,75
	500	98,46	67,23
	1000	98,54	67,64
Batch size 8	150	98,37	67,56
	300	98,41	66,79
	500	98,26	42
	1000	98,44	61,45
Batch size 16	150	98,22	66,18
	300	98,30	70,39
	500	98,50	73,59
	1000	98,52	70,71
Batch size 32	150	96,21	45,24
	300	98,29	67,12
	500	98,47	66,71
	1000	98,37	68,59



Şekil 10. Kesinlik ve Kayıp grafikleri. (Figure 10. Accuracy and Loss Graphs)



Şekil 11. Segmentasyon modeli çıktısı. (Figure 11. Segmentation output.)

4. SONUÇLAR (RESULTS)

Bu çalışmada AISI 4340 çeliğinde beynitik, martenzitik ve perlitik mikro yapıları üretmek amacıyla sırasıyla östemperleme, su verme ve normalizasyon ısıl işlemleri uygulanmıştır. Uygulanan ısıl işlem sonrasında elde edilen mikro yapı görüntüleri etiketlenmiştir ve bu görüntüler kullanılarak U-Net ve VGG16 derin öğrenme modelleri eğitilmiştir. Eğitilen modeller mikro yapı görüntülerini tanımlama görevini %93.33 doğrulukla ve çelik mikro yapısındaki inklüzyonları tanımlama görevini %73.59 doğrulukla gerçekleştirebilmektedir. Sonuçlar bize malzeme biliminde görüntü işlemede yapay zekanın etkili bir biçimde kullanılabileceğini göstermektedir. Çok disiplinli olan bu proje gelecekte yapılacak çalışmalara da katkı sağlayacağı düşünülmektedir. Artması beklenen işlem gücü, veri setlerinin genişletilmesi ve yapay zeka teknolojisindeki ilerlemelerle tüm metal ve alaşımlarının mikro yapı görüntülerinin incelenmesinin mümkün olacağı düşünülmektedir.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Sefa Yücel AŞÇI: Isıl işlemlerin yapılması, metalografik işlemlerin yapılması, görüntülerin elde edilmesi, VGG16 modelinin kurulması işlemlerini gerçekleştirdi.

Furkan GÖKER: Isıl işlemlerin yapılması, metalografik işlemlerin yapılması, görüntülerin elde edilmesi, U-Net modelinin kurulması işlemlerini gerçekleştirdi.

Tolga YILMAZ: Isıl işlemlerin yapılması, metalografik işlemlerin yapılması, optik mikroskop laboratuvarında görüntü alma işleminin yapılmasında mentörlük yaptı.

Ahmet GÜRAL: Proje sürecinde ve makale yazımında mentörlük yaptı.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

TEŞEKKÜR (ACKNOWLEDGMENTS)

1919B012317378 numaralı TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destek Programı kapsamındaki projemize katkılarından dolayı TÜBİTAK'a teşekkür ederiz.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

KAYNAKLAR (REFERENCES)

[1] Mishra, Surya Prakash, and M. R. Rahul. "A comparative study and development of a novel deep learning architecture for accelerated identification of microstructure in materials science." *Computational Materials Science* 200: 110815, (2021).

- [2] Han, Bing, et al. "A deep learning-based method for segmentation and quantitative characterization of microstructures in weathering steel from sequential scanning electron microscope images." *Journal of Iron and Steel Research International* 29.5: 836-845, (2022).
- [3] Agrawal, Ankit, and Alok Choudhary. "Deep materials informatics: Applications of deep learning in materials science." *Mrs Communications* 9.3: 779-792, (2019).
- [4] Ge, Mengshu, et al. "Deep learning analysis on microscopic imaging in materials science." *Materials Today Nano* 11: 100087, (2020).
- [5] Min, Seonwoo, Byunghan Lee, and Sungroh Yoon. "Deep learning in bioinformatics." *Briefings in bioinformatics* 18.5: 851-869, (2017).
- [6] Alzubaidi, L., Zhang, J., Humaidi, A.I. et al. "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions." *J Big Data* 8: 53, (2021).
- [7] Larmuseau, Michiel, et al. "Race against the Machine: can deep learning recognize microstructures as well as the trained human eye?." *Scripta Materialia* 193: 33-37, (2021).
- [8] Chowdhury, Anitra, et al. "Image driven machine learning methods for microstructure recognition." *Computational Materials Science* 123: 176-187, (2016).
- [9] Biswas, M., Pramanik, R., Sen, S. et al. "Microstructural segmentation using a union of attention guided U-Net models with different color transformed images." *Sci Rep* 13: 5737 (2023).
- [10] Durmaz, A.R., Müller, M., Lei, B. et al. "A deep learning approach for complex microstructure inference." *Nat Commun* 12, 6272 (2021).
- [11] Lee, Woei-Shyan, and Tzay-Tian Su. "Mechanical properties and microstructural features of AISI 4340 high-strength alloy steel under quenched and tempered conditions." *Journal of materials processing technology* 87.1-3: 198-206, (1999).
- [12] Sang, Yi, Guosheng Sun, and Jizi Liu. "A 4340 Steel with Superior Strength and Toughness Achieved by Heterostructure via Intercritical Quenching and Tempering." *Metals* 13.6: 1139, (2023).
- [13] Nalcaci, B., Aydin, O.C., Yilmaz, S. et al. "Effect of Interrupted Quenching on the Microstructure, Mechanical Properties and Dislocation Density of Steel AISI 4340." *Met Sci Heat Treat* (2023).
- [14] H. Chandler, *Heat Treater's Guide: Practices and Procedures for Irons and Steels*, 427-428, (2011).
- [15] Feng, Jian, Timo Frankenbach, and Marc Wetlauffer. "Strengthening 42CrMo4 steel by isothermal transformation below martensite start temperature." *Materials Science and Engineering: A* 683: 110-115, (2017).
- [16] Mumuni, Alhassan, and Fuseini Mumuni. "Data augmentation: A comprehensive survey of modern approaches." *Array* 16: 100258, (2022).
- [17] Azimi, Seyed Majid, et al. "Advanced steel microstructural classification by deep learning methods." *Scientific reports* 8.1: 2128, (2018).
- [18] İnik, Ö., and E. Ülker. "Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri., " *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104." (2017)
- [19] Tammina, Srikanth. "Transfer learning using vgg-16 with deep convolutional neural network for classifying

- images." *International Journal of Scientific and Research Publications (IJSRP)* 9.10: 143-150, (2019).
- [20] Sharma, Shagun, et al. "A deep learning based convolutional neural network model with VGG16 feature extractor for the detection of Alzheimer Disease using MRI scans." *Measurement: Sensors* 24: 100506, (2022).
- [21] Ying WEI, Yu Zhang, Junzhou Huang, Qiang Yang. *Proceedings of the 35th International Conference on Machine Learning*, PMLR 80:5085-5094, (2018).
- [22] Esen, Furkan Alp, and Aytuğ Onan. "Derin Öğrenme Yöntemleri ile Bitki Yaprakları Üzerindeki Hastalıkların Sınıflandırılması." *Avrupa Bilim ve Teknoloji Dergisi* 40: 151-155, (2022).
- [23] Sugata, T. L. I., and C. K. Yang. "Leaf App: Leaf recognition with deep convolutional neural networks." *IOP Conference Series: Materials Science and Engineering*. Vol. 273. No. 1. IOP Publishing, (2017).
- [24] Karagöl, Selennur, et al. "Aktarımlı öğrenme ile Sentinel-2 görüntülerinden kıyı çizgisi bölütlemesi." *Türkiye Uzaktan Algılama Dergisi*, 3.1: 1-7, (2021).
- [25] Ronneberger, O., Fischer, P., Brox, T., "U-Net: Convolutional Networks for Biomedical Image Segmentation." *Medical Image Computing and Computer-Assisted Intervention (MICCAI), Springer, LNCS*, Vol.9351: 234-241, (2015).
- [26] Ravuri, Suman, and Oriol Vinyals. "Classification accuracy score for conditional generative models." *Advances in neural information processing systems* 32 (2019).
- [27] Karadağ, C., & ÖZDEMİR, D. "Comparative Analysis of Deep Learning Methods for Brain Tumor Detection." *Artificial Intelligence Studies*, 6(1), 1-13, (2023).
- [28] Karaca N., Karacı A., "Derin Öğrenme ve Görüntü İşleme Yöntemlerini Kullanarak Göğüs X-İşini Görüntülerinden Akciğer Bölgesini Tespit Etme" *Int. J. of 3D Printing Tech. Dig. Ind.*, 6(3): 459-468, (2022).
- [29] Lu, H., She, Y., Tie, J., & Xu, S. "Half-UNet: A simplified U-Net architecture for medical image segmentation." *Frontiers in neuroinformatics*, 16: 911679, (2022).
- [30] Baştuğ Koç, A., Akgün, D. "U-net Mimarileri ile Glioma Tümör Segmentasyonu Üzerine Bir Literatür Çalışması." *Avrupa Bilim ve Teknoloji Dergisi*, (26), 407-414, (2021).

ERKEN GÖRÜNTÜ