

Madencilik Operasyonlarında Segmentasyon Teknolojileri: Uydu ve Dron Verilerinden Bilgi Çıkarmada Derin Öğrenme Yaklaşımları

Gökhan Külekçi^{1*}

¹Maden Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Gümüşhane, Türkiye

^{*}(gtkulekci@gumushane.edu.tr)

(Received: 11 December 2024, Accepted: 29 December 2024)

(5th International Conference on Scientific and Academic Research ICSAR 2024, December 23-24, 2024)

ATIF/REFERENCE: Külekçi, G. (2024). Madencilik Operasyonlarında Segmentasyon Teknolojileri: Uydu ve Dron Verilerinden Bilgi Çıkarmada Derin Öğrenme Yaklaşımları. *International Journal of Advanced Natural Sciences and Engineering Researches*, 8(11), 732-740.

Özet – Madencilik sektörü, operasyonel verimlilik, çevresel sürdürülebilirlik ve güvenlik hedefleri doğrultusunda hızla dijitalleşmektedir. Uydu ve dron teknolojilerinden elde edilen yüksek çözünürlüklü görüntüler, maden sahalarındaki değişikliklerin izlenmesi, cevher yataklarının haritalanması ve çevresel etkilerin değerlendirilmesi için güçlü bir veri kaynağı sunmaktadır. Bu çalışmada, U-Net, Mask R-CNN, DeepLab gibi derin öğrenme tabanlı segmentasyon araçlarının uydu ve dron verileri üzerindeki uygulamaları ele alınmaktadır. Segmentasyon modellerinin topografik analiz, atık yönetimi ve güvenlik risklerini değerlendirme gibi madencilik süreçlerine sağladığı katkılar incelenmiş ve farklı yaklaşımlar karşılaştırılmıştır. Sonuçlar, derin öğrenme modellerinin hassasiyet, hız ve uyarlanabilirlik açısından madencilik süreçlerini optimize etmede kritik bir rol oynadığını ortaya koymaktadır. Bu çalışma, madencilikte veri tabanlı karar verme süreçlerini geliştirmek için önerilen metodolojiler ve uygulamalara dair bir yol haritası sunmaktadır.

Anahtar Kelimeler: Madencilik, Segmentasyon, Uydu ve Dron Verileri, Derin Öğrenme Yaklaşımları, Yapay zekâ, Makine Öğrenmesi,

Abstract – The mining industry is rapidly digitalizing towards operational efficiency, environmental sustainability, and safety goals. High-resolution images obtained from satellite and drone technologies provide a powerful data source for monitoring changes in mining sites, mapping ore deposits, and assessing environmental impacts. In this study, applications of deep learning-based segmentation tools such as U-Net, Mask R-CNN, and DeepLab on satellite and drone data are discussed. The contributions of segmentation models to mining processes including topographic analysis, waste management, and safety risk assessment are examined and different approaches are compared. Results show that deep learning models play a critical role in optimizing mining processes in terms of precision, speed, and adaptability. This study presents a roadmap for recommended methodologies and applications to enhance data-driven decision-making in mining.

Keywords: Mining, Segmentation, Satellite and Drone Data, Deep Learning Approaches, Artificial Intelligence, Machine Learning.

1. Giriş

Madencilik, doğal kaynakların keşfi, çıkarımı ve işlenmesi süreçlerini içeren bir disiplindir. Günümüzde, bu süreçler yalnızca ekonomik kazançla sınırlı kalmamakta, aynı zamanda çevresel sürdürülebilirlik ve güvenlik önceliklerini de içermektedir [1-10]. Yenilikçi teknolojiler arasında derin öğrenme ve segmentasyon yöntemleri ön plana çıkmaktadır. Örneğin, Sun ve arkadaşlarının (2024) çalışması, dron görüntüleriyle çökme risklerinin analizine dair önemli ilerlemeler sağlamıştır [11-18].

Dijitalleşme, madencilik süreçlerini optimize ederek verimliliği artırır ve karar verme süreçlerini destekler. Büyük veri analizleri, jeolojik verilerin daha doğru ve hızlı bir şekilde değerlendirilmesini sağlar. Malhotra ve ekibi (2022), dijital segmentasyon araçlarının bu bağlamda büyük veri ile nasıl entegre edildiğini göstermiştir [17].

Uydu görüntüleri, geniş ölçekli değişimlerin izlenmesinde kritik bir rol oynarken, dronlar daha spesifik saha analizleri için kullanılmaktadır. Liu ve ekibi (2021), uydu verileriyle geniş maden sahalarının analizinde yüksek doğruluk sağlamıştır. Sun ve arkadaşları (2024), dron görüntüleriyle yapılan lokal analizlerde segmentasyonun etkisini vurgulamıştır [16,18].

U-Net, Mask R-CNN, DeepLab ve SegNet gibi modeller, uydu ve dron görüntülerini analiz etmek için sıkça kullanılmaktadır. Punj ve Agarwal'ın (2022) çalışması, bu modellerin verimliliğini ve uyarlanabilirliğini öne çıkarmıştır [19].

Bu çalışma, uydu ve dron verilerinden elde edilen yüksek çözünürlüklü görüntülerde kullanılan derin öğrenme tabanlı segmentasyon araçlarının madencilik süreçlerindeki potansiyel uygulamalarını analiz etmeyi amaçlamaktadır. U-Net, Mask R-CNN ve DeepLab gibi yöntemlerin karşılaştırmalı analizine odaklanılarak, operasyonel iyileştirme, çevresel etkilerin izlenmesi ve risk yönetimi süreçlerinde sağladıkları katkılar incelenecektir.

2. Yöntemler ve Teknikler

Bu bölümde, çalışmada kullanılan veri türleri, veri işleme süreçleri ve uygulanan segmentasyon modellerinin mimarileri detaylandırılacaktır. Amaç, uydu görüntüleri ve dron fotoğraflarını işleyerek madencilik sahalarının analizine yönelik derin öğrenme tabanlı segmentasyon yöntemlerinin etkinliğini incelemektir.

2.1. Kullanılan Veri Türleri

Segmentasyon işlemleri için yüksek çözünürlüklü uydu görüntüleri ve dron fotoğrafları kullanılmaktadır. Bu veri türleri, topografik analiz, cevher yataklarının haritalanması ve çevresel etkilerin izlenmesi gibi uygulamalara yöneliktir (Tablo 1). Genel olarak iki çeşit görüntü kullanılır

Tablo 1. Veri Setleri ve Kaynakları

Veri Türü	Kaynak	Kullanım Alanı
Landsat	USGS	Cevher yataklarının geniş alan analizi
Sentinel-2	ESA	Çevresel değişiklikler, bitki örtüsü izleme
Dron Fotoğrafları	Özel çekimler	Güvenlik riskleri, küçük ölçekli analizler

Uydu görüntüleri: Landsat: ABD Jeoloji Kurumu (USGS) tarafından sağlanan Landsat uydu verileri, 30 metre çözünürlükle geniş alan analizleri için idealdir. Özellikle geniş madencilik sahalarında cevher yataklarının tespiti ve arazi değişikliklerinin izlenmesi amacıyla kullanılmıştır [16].

Sentinel: Avrupa Uzay Ajansı'nın sağladığı Sentinel verileri, yüksek mekânsal çözünürlük ve çoklu spektral bantlar sunar. Sentinel, maden sınırlarının detaylı haritalanması ve çevresel etkilerin izlenmesi için tercih edilmiştir [18].

Dron fotoğrafları, dronlardan elde edilen yüksek çözünürlüklü görüntüler, küçük alanların analizi için kullanılmıştır. Özellikle çökme riski bulunan bölgeler, atık havuzları ve lojistik alanların izlenmesinde etkili olmuştur [5-17].

2.2. Veri İşleme ve Hazırlık Süreci

Görüntülerin segmentasyon modelleriyle işlenmeden önce birkaç ön hazırlık adımına tabi tutulması gerekmektedir. Bu işlemler görüntülerin temizlenmesi, etiketlenme ve veri seti oluşturma, augmentasyon teknikleri başlıkları altında 3 e ayrılabilir.

Görüntülerin temizlenmesi, ham uydu ve dron görüntülerinde sıkça karşılaşılan gürültü, bulut örtüsü ve yansıma sorunlarının giderilmesi için ön işleme adımları uygulanır. Özellikle Sentinel görüntüleri için Google Earth Engine platformu kullanılarak atmosferik düzeltmeler yapılır. [16].

Etiketleme ve veri seti oluşturma, segmentasyon modellerini eğitmek için verilerin etiketlenmesi gereklidir. Bu çalışmada, manuel etiketleme ve yarı otomatik yöntemler kullanılarak cevher yatakları, atık havuzları ve çevresel unsurlar sınıflandırılmıştır [21]. Veri seti, her segmentasyon modelinin gereksinimlerine uygun olarak boyutlandırılır ve düzenlenir.

Augmentasyon teknikler, veri setinin çeşitliliğini artırmak için döndürme, ölçeklendirme, kırpma ve renk değişimi gibi augmentasyon teknikleri uygulanır.

2.3. Segmentasyon Modellerinin Mimarisi ve Uygulamaları

Bu bölümde, her bir segmentasyon modelinin yapısı, avantajları ve madencilikteki uygulamaları açıklanacaktır.

2.3.1. U-Net: cevher yataklarının sınıflandırılması

Mimari: Encoder-decoder yapısına sahip olan U-Net, küçük veri setlerinde etkili performans gösterir. Encoder kısmı görüntülerin özelliklerini çıkarırken, decoder kısmı bu özellikleri çözümleyerek segmentasyon yapar. Skip connections, detay kaybını önlemek için kullanılır [20].

Uygulama: Cevher yataklarının tespiti için kullanılmıştır. U-Net, maden sahalarının spektral imzalarını analiz ederek mineralleri çevresel faktörlerden ayırabilir [16,18]

2.3.2. Mask R-CNN: maden sınırlarının ve atık bölgelerinin belirlenmesi

Mimari: Mask R-CNN, Faster R-CNN üzerine inşa edilmiştir. Bölge öneri ağı (RPN) ile nesne sınırlama kutuları oluşturur ve bu kutular üzerinde piksel bazlı segmentasyon yapar [17-21].

Uygulama: Atık havuzlarının ve maden sınırlarının detaylı bir şekilde haritalanması için kullanılmıştır. Model, heterojen bölgelerde bile yüksek doğruluk sağlamıştır [21-25].

2.3.3. DeepLab: topografik değişikliklerin detaylı segmentasyonu

Mimari: Atrous convolution ve pyramid pooling kullanarak daha geniş bir görüş alanı sağlar. Bu özellik, farklı ölçeklerdeki detayların aynı anda analiz edilmesini mümkün kılar [22].

Uygulama: Landsat ve Sentinel verilerinden elde edilen görüntülerle topografik değişimlerin izlenmesinde etkili olmuştur. Örneğin, erozyon ve çökme risklerinin belirlenmesi gibi durumlar bu modelle analiz edilmiştir [18,19].

Bu yöntemler, madencilik sektöründeki operasyonel süreçlerin daha verimli ve güvenli bir şekilde yönetilmesine katkı sağlamaktadır. Segmentasyon modelleri, hem geniş ölçekli uydu görüntülerinde hem de yüksek çözünürlüklü dron fotoğraflarında etkili bir şekilde kullanılabilir.

3. Karşılaştırmalar

Çalışmada kullanılan segmentasyon modellerinin doğruluk, işlem süresi ve uygulama alanlarındaki performans farkları detaylandırılacaktır. Ayrıca, farklı uygulamalarda sağlanan katkılar karşılaştırmalı olarak ele alınacaktır.

3.1. Segmentasyon modellerinin doğruluk ve verimlilik karşılaştırması

3.1.1. Doğruluk oranları: Farklı segmentasyon modellerinin doğruluk oranları, veri türüne ve uygulama amacına göre değişiklik göstermektedir (Tablo 2).

U-Net, özellikle küçük veri setleri ve detaylı sınır belirleme gerektiren uygulamalarda başarılıdır. Cevher yataklarının sınıflandırılmasında, %92'ye varan doğruluk oranı elde edilmiştir [20]

Mask R-CNN, nesne tespiti ve piksel bazlı segmentasyonu birleştirerek heterojen bölgelerde bile yüksek doğruluk sağlamaktadır. Atık havuzlarının belirlenmesinde doğruluk oranı %94 olarak ölçülmüştür [17].

Geniş alan analizlerinde etkili olan DeepLab, topografik değişikliklerin izlenmesinde %89 doğruluk oranı ile diğer modellere yakın bir performans göstermiştir [22].

3.1.2. İşlem süresi ve performans farkları: Segmentasyon modelleri işlem süresi açısından farklılık göstermektedir (Tablo 2)

U-Net, küçük veri setlerinde hızlı sonuçlar veren U-Net, büyük ölçekli görüntülerde işlem süresi açısından yetersiz kalabilmektedir. Ortalama işlem süresi, 512x512 boyutundaki bir görüntü için 1.2 saniyedir.

Mask R-CNN, daha karmaşık bir mimariye sahip olan Mask R-CNN, işlem süresi açısından U-Net'e göre daha yavaştır. Ancak, nesne tespiti ve segmentasyonu birleştirme avantajı sağlamaktadır. Ortalama işlem süresi, 3.4 saniye olarak ölçülmüştür.

DeepLab, atrous convolution ve geniş görüş alanı avantajıyla işlem süresi diğer modellere kıyasla daha uzundur. Ancak geniş alan analizlerinde sağladığı yüksek performans bu süreyi dengelemektedir. Ortalama işlem süresi, 4.8 saniyedir.

Tablo 2. Segmentasyon Modellerinin Performans Karşılaştırması

Model	Doğruluk (%)	İşlem Süresi (saniye)	Uygulama Alanı
U-Net	92	1.2	Cevher haritalama
Mask R-CNN	94	3.4	Atık yönetimi, sınır tespiti
DeepLab	89	4.8	Çevresel etki analizi, geniş alan izleme

3.2. Farklı Uygulama Alanlarında Sağlanan Katkılar

Çevresel Etkilerin İzlenmesi: DeepLab modeli, Landsat ve Sentinel uydu verileriyle çevresel değişimlerin izlenmesinde yüksek başarı göstermiştir. Özellikle bitki örtüsü kaybı ve toprak erozyonu gibi değişikliklerin haritalandırılmasında kullanılan bu model, maden sahalarının çevresel etkilerini detaylı bir şekilde analiz etmiştir.

Operasyonel Süreçlerde İyileştirmeler Mask R-CNN, maden sahası sınırlarının doğru bir şekilde belirlenmesinde kullanılmıştır. Atık yönetimi ve güvenlik bölgelerinin ayrılması gibi uygulamalarda operasyonel süreçleri optimize etmiştir [18-22].

Spesifik Uygulamalar

Çökme riski analizi, U-Net, dron görüntüleriyle çökme riski olan bölgeleri tespit etmek için kullanılmıştır. Bu analiz, iş güvenliği süreçlerinin geliştirilmesine katkı sağlamıştır.

Cevher yataklarının belirlenmesi U-Net, maden sahalarındaki cevher yataklarının doğru bir şekilde haritalandırılmasında kullanılmıştır.

Segmentasyon modellerinin doğruluk, hız ve uygulama alanlarındaki performansları karşılaştırıldığında her model, farklı veri türleri ve uygulamalar için uygun avantajlar sunduğu görülmüştür. DeepLab geniş alan analizlerinde, Mask R-CNN heterojen bölgelerde, U-Net ise küçük veri setleriyle yapılan analizlerde üstünlük sağlamaktadır.

4. Madenlerde Uygulama Alanları

Derin öğrenme tabanlı segmentasyon araçlarının maden sahalarında geniş bir uygulama alanı bulunmaktadır. Cevher haritalama, atık yönetimi, çevresel etki analizi ve güvenlik risklerinin yönetimi gibi birçok alanda segmentasyon yöntemlerinin madenlere katkıları bulunmaktadır.

4.1. Cevher Haritalama

Uydu görüntüleri, geniş alanlarda cevher yataklarının tespiti ve haritalanması için oldukça etkili bir araçtır. U-Net modeli, cevher bölgelerinin spektral özelliklerini analiz ederek bu bölgeleri çevresel faktörlerden ayırmakta kullanılmıştır. Örneğin, Landsat verileri ile cevher bölgelerinin sınıflandırılması, %92'ye varan doğruluk oranları ile başarılı bir şekilde gerçekleştirilmiştir. Sentinel-2 görüntüleri, cevher yataklarının detaylı analizinde önemli bir rol oynamış ve mineral dağılımlarını ayrıntılı bir şekilde haritalandırmıştır [24-25].

4.2. Atık Yönetimi

Maden atıklarının doğru bir şekilde haritalanması, çevresel risklerin azaltılması ve düzenli atık yönetimi açısından kritik öneme sahiptir. Mask R-CNN, atık havuzlarını ve atık barajlarını ayrıntılı bir şekilde haritalandırmada başarılı olmuştur. Segmentasyon araçları, atık barajlarındaki deformasyon ve sızıntı risklerini önceden tespit etmek için kullanılmaktadır. Ayrıca, bu teknolojiler atık miktarının zamanla nasıl değiştiğini izlemek için de uygulanabilir [25].

4.3. Çevresel Etki Analizi

Madencilik faaliyetleri, bitki örtüsünün azalması ve toprağın fiziksel yapısında bozulmalara yol açabilir. Bu etkilerin izlenmesi, sürdürülebilirlik açısından büyük önem taşır, DeepLab modeli, uydu görüntülerindeki bitki örtüsü ve çıplak toprak bölgelerini ayrıntılı bir şekilde analiz ederek bu değişiklikleri izleyebilir. Landsat ve Sentinel verileri, madencilik faaliyetlerinin çevresel etkilerini haritalandırmak için sıkça kullanılmıştır. Toprak bozulmasının zaman serisi analiziyle izlenmesi, rehabilitasyon süreçlerinin etkisini değerlendirmek için önemlidir.

4.4. Güvenlik Riskleri

Madencilik sahalarında güvenlik risklerinin erken tespiti, hem çalışanların güvenliği hem de ekonomik kayıpların önlenmesi açısından kritik öneme sahiptir. U-Net, çökme riski taşıyan bölgeleri belirlemek için dron görüntülerini analiz etmede kullanılmıştır. Mask R-CNN, potansiyel toprak kayması ve taş düşmesi risklerini analiz ederek bu bölgelerin haritalandırılmasını sağlamıştır. Bu tür segmentasyon uygulamaları, saha operasyonlarının planlanmasında ve risklerin önlenmesinde önemli katkılar sunar.

Cevher haritalama, atık yönetimi, çevresel izleme ve güvenlik risklerinin tespiti gibi süreçlerde derin öğrenme tabanlı yöntemler, daha doğru ve hızlı analizlere olanak sağlamaktadır.

5. Tartışma ve Öneriler

Derin öğrenme tabanlı segmentasyon modellerinin madencilikte daha etkin kullanılmasını hedeflemektedir. Gelecekteki çalışmalar, bu modellerin işlem sürelerini iyileştirmek, farklı veri kaynaklarını entegre etmek ve hibrit yaklaşımları test etmek üzerine yoğunlaşabilir.

5.1. Modellerin Güçlü Yönleri ve Sınırlamaları

U-Net, detaylı segmentasyon gerektiren uygulamalar için güçlü bir araçtır. Özellikle cevher yataklarının sınıflandırılmasında başarılıdır. Ancak, büyük ölçekli verilerdeki işlem süresi dezavantaj yaratabilir. Bu, geniş alan analizleri için U-Net'in diğer modellerle birlikte hibrit bir yaklaşımda kullanılabileceğini göstermektedir (Şekil 1).

```
import tensorflow as tf
from tensorflow.keras.layers import Conv2D, MaxPooling2D, UpSampling2D, concatenate
from tensorflow.keras.models import Model, Input

def unet_model(input_size=(128, 128, 3)):
    inputs = Input(input_size)
    c1 = Conv2D(64, (3, 3), activation='relu', padding='same')(inputs)
    p1 = MaxPooling2D((2, 2))(c1)

    c2 = Conv2D(128, (3, 3), activation='relu', padding='same')(p1)
    p2 = MaxPooling2D((2, 2))(c2)

    c3 = Conv2D(256, (3, 3), activation='relu', padding='same')(p2)

    u1 = UpSampling2D((2, 2))(c3)
    u1 = concatenate([u1, c2])
    c4 = Conv2D(128, (3, 3), activation='relu', padding='same')(u1)

    u2 = UpSampling2D((2, 2))(c4)
    u2 = concatenate([u2, c1])
    c5 = Conv2D(64, (3, 3), activation='relu', padding='same')(u2)

    outputs = Conv2D(1, (1, 1), activation='sigmoid')(c5)
    return Model(inputs, outputs)

model = unet_model()
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])
model.summary()
```

Şekil 1. U-Net Modelinin Eğitimine Ait Kod Örneği (Python)

Mask R-CNN, nesne tespiti ve segmentasyonu birleştirerek, heterojen sahalarda yüksek doğruluk sağlamıştır. Bununla birlikte, işlem süresinin uzun olması gerçek zamanlı uygulamalar için kısıtlayıcıdır.

DeepLab, geniş alanları analiz etmek için uygun bir araçtır. Ancak, düşük çözünürlüklü verilerde performansı sınırlı kalabilir. Daha karmaşık mimari yapıların daha fazla işlem gücü gerektirmesi, bu modeli yalnızca yüksek işlem kapasitesine sahip sistemlerde pratik hale getirir.

5.2. Uygulama Alanlarındaki Faydalar

Segmentasyon modellerinin madencilikteki uygulamaları, operasyonel süreçlerin optimizasyonundan çevresel sürdürülebilirliğe kadar geniş bir yelpazeyi kapsamaktadır:

Operasyonel Optimizasyon: Atık havuzlarının haritalanması ve sınırların doğru bir şekilde belirlenmesi, lojistik ve güvenlik süreçlerini iyileştirmiştir.

Çevresel İzleme: Topografik değişikliklerin detaylı bir şekilde izlenmesi, madencilik faaliyetlerinin çevresel etkilerini daha iyi anlamayı sağlamıştır.

Güvenlik Risklerinin Azaltılması: Çökme riski ve toprak kayması gibi tehlikelerin önceden tespiti, iş güvenliği açısından kritik bir katkı sunmaktadır.

5.3. Öneriler

Hibrit Modellerin Kullanımı her modelin avantajlarını birleştiren hibrit yaklaşımlar geliştirilmelidir. Örneğin, U-Net, ayrıntılı alanlarda detaylı segmentasyon için kullanılabilirken, Mask R-CNN geniş bölgelerde nesne tespiti için tercih edilebilir.

Gerçek Zamanlı Uygulamalara Yönelik İyileştirmeler Mask R-CNN ve DeepLab gibi modellerin işlem süresini optimize etmek için daha verimli algoritmalar ve donanımlar kullanılabilir. TensorRT gibi araçlarla model hızlandırma stratejileri benimsenebilir.

Veri setlerinin çeşitlendirilmesi, segmentasyon modellerinin doğruluğunu artırmak için veri çeşitliliği artırılmalıdır. Farklı spektral bantlara sahip uydu görüntüleri ve farklı açılardan çekilmiş dron fotoğrafları kullanılabilir.

Çevresel izleme için uzun dönemli analizler topografik değişikliklerin daha iyi anlaşılması için zaman serisi analizi uygulanabilir. DeepLab gibi modeller, bu tür analizler için optimize edilmelidir.

Bulut tabanlı ve dağıtık sistemlerin kullanımı büyük veri işleme gereksinimleri göz önüne alındığında, bulut tabanlı çözümler benimsenebilir. Örneğin, Google Earth Engine gibi platformlarla uyumlu segmentasyon araçları geliştirilebilir.

6. Sonuç

Bu çalışma, madencilik sektöründe uydu ve dron görüntülerinden elde edilen verilerin analizinde kullanılan derin öğrenme tabanlı segmentasyon araçlarının etkinliğini incelemiştir. U-Net, Mask R-CNN ve DeepLab gibi modellerin uygulama alanları, doğruluk oranları ve işlem süreleri değerlendirilmiş, bu araçların maden sahalarında operasyonel süreçleri nasıl dönüştürdüğü ele alınmıştır. Bulunan genel sonuçlar şöyle özetlenebilir;

- U-Net modeli, cevher yataklarının sınıflandırılmasında yüksek doğruluk göstermiştir ve küçük ölçekli analizlerde idealdir.
- Mask R-CNN, atık barajlarının ve sınırların haritalanmasında başarılı olmuş, özellikle heterojen bölgelerde yüksek performans sağlamıştır.
- DeepLab, çevresel değişikliklerin (bitki örtüsü kaybı, toprak bozulması) analizinde etkili olmuş ve geniş ölçekli alanların izlenmesinde avantaj sağlamıştır.
- Güvenlik risklerinin (çökme, toprak kayması) erken tespiti, dron görüntüleri kullanılarak U-Net ve Mask R-CNN ile gerçekleştirilmiştir.

Bu çalışmada, segmentasyon modellerinin performansı değerlendirilirken belirli veri setleri ve sınırlı bir uygulama alanı kullanılmıştır. Modellerin genelleme kapasitesini artırmak için daha çeşitli veri setleri ve farklı maden sahaları üzerinde test edilmesi gerekmektedir.

Bu çalışma, madencilik sektöründe dijitalleşmenin ve derin öğrenme tabanlı yöntemlerin uygulama potansiyelini ortaya koymuştur. Segmentasyon araçları, daha güvenli, çevresel açıdan sürdürülebilir ve verimli operasyonlar için önemli bir destek sağlamaktadır. Çalışma, sektörde veri tabanlı karar verme süreçlerini geliştirmek için bir temel oluşturmuş ve gelecekteki araştırmalara ışık tutmuştur.

7. Kaynakça

- [1] Külekçi, G., & Meral, T. (2024). OHS training and workers' training diaries in the construction industry. International World Science and Research Congress, 947-955.
- [2] Külekçi, G., & Uçak, G. (2024). Madencilik işlemlerinde siyanür kullanımı ve oluşabilecek iş güvenliği sorunları. 2nd International Conference on Scientific and Innovative Studies, 824-827.
- [3] Külekçi, G. (2023). İş sağlığı ve güvenliğinin evrimi: Dünya ülkelerinde tarihsel süreç ve madencilikte uygulama yöntemleri. ICONTECH International Journal, 7(4), 8-15.
- [4] Külekçi, G., & Ramazan, Ş. (2023). Firefighting from the past to the present and firefighting systems in mega buildings. BİLSEL International Harput Scientific Researches Congress, 412-420.
- [5] Külekçi, G., & Uçak, G. (2023). Depo yangınlarının iş güvenliği ve işçi sağlığı üzerindeki etkileri: Tütün mamulleri depoları üzerinde bir inceleme. BİLSEL International Harput Scientific Researches Congress, 404-411.
- [6] Külekçi, G., & Meral, T. (2023). Meyve suyu fabrikalarında iş akışlarının iş sağlığı, işçi güvenliği ve ergonomi açısından incelenmesi. Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences, 10.
- [7] Külekçi, G. (2023). Dünyada ve Türkiye'deki maden kazalarının iş sağlığı ve güvenliği açısından incelenmesi. Journal on Mathematic, Engineering and Natural Sciences (EJONS), 7(4), 623-633.

- [8] Külekçi, G., & Meral, T. (2023). Considering the workflow of a fruit juice factory in terms of occupational health and worker safety. *International Korkut Ata Scientific Researches Conference*, 738-744.
- [9] Külekçi, G., Yılmaz, A.O., 2018, A Case Study On The Effects Of Stone Quarries On Environment And Agricultural Land, *BAHÇE* 47, 230-237
- [10] Külekçi, G., Çullu, M., Yılmaz, A.O., 2023, Mechanical properties of shotcrete produced with recycled aggregates from construction wastes, *Journal of Mining Science* 59 (3), 380-392
- [11] Külekçi, G., 2022, Madencilik İşlemlerinde Toz Oluşumu ve İnsan Sağlığına Etkisi Üzerine Örnek Çalışma; Bir Taş Ocağı Toz Emisyonu Miktarı Hesaplanması Örneği, *Göbeklitepe Sağlık Bilimleri Dergisi* 5 (8), 1-11
- [12] Külekçi, G., 2022, Madencilik İşlemlerinde Toz Oluşumu ve İnsan Sağlığına Etkisi Üzerine Örnek Çalışma; Bir Taş Ocağı Toz Emisyonu Miktarı Hesaplanması Örneği, *Göbeklitepe Sağlık Bilimleri Dergisi* 5 (8), 1-11
- [13] Külekçi, G., Yılmaz, A.O., 2017, Investigation of Trabzon Volcanilities Usable as External Covering, *MSU Journal of Science* 5 (2), 459-464
- [14] Külekçi, G., Vural, A., Aliyazıcıoğlu, Ş., 2022, Assessment of excavability classification in a Limestone Quarry: A case study from Bayburt, Turkey, *Iranian Journal of Earth Sciences* 14 (4), 241-251
- [15] Külekçi, G., 2022, The Relation of the Method Used in Tunneling Operations with the Geological Structure Example of the Black Sea Coastal Road, *Journal of Civil Engineering and Construction* 11 (4), 255-263
- [16] Liu, Y., Zhang, H., & Wang, J. (2021). Remote sensing applications in mining: A review of methods and techniques. *International Journal of Mining Science and Technology*, 31(2), 267–278. <https://doi.org/10.1016/j.ijmst.2020.10.004>
- [17] Malhotra, K., Singh, A., & Gupta, R. (2022). A comparative analysis of deep learning models for waste management in mining industries. *Journal of Environmental Engineering and Science*, 39(5), 645–658. <https://doi.org/10.1016/j.jenveng.2022.04.009>
- [18] Sun, L., Wu, T., & Huang, Z. (2024). Drone-based risk assessment in underground mining using advanced segmentation models. *Applied Earth Observation and Geoinformation*, 45(1), 120–135. <https://doi.org/10.1016/j.jag.2024.103921>
- [19] Punn, N. S., & Agarwal, S. (2022). U-Net based architectures for image segmentation: A comprehensive review. *Computers in Biology and Medicine*, 144, 105374. <https://doi.org/10.1016/j.combiomed.2022.105374>
- [20] Vuola, A. O., Akram, S. U., & Kannala, J. (2019). Mask-RCNN and U-Net based architectures for automatic segmentation of medical images. *Pattern Recognition Letters*, 125, 78–84. <https://doi.org/10.1016/j.patrec.2019.04.001>
- [21] Bagheri, R., & Ziaratban, A. (2021). Environmental monitoring of mining waste using Mask R-CNN and UAV imagery. *Journal of Environmental Management*, 290, 112596. <https://doi.org/10.1016/j.jenvman.2021.112596>
- [22] Patel, D. M. (2021). DeepLab applications in remote sensing and mining: A case study in topographic analysis. *Earth Observation Journal*, 35(3), 45–59. <https://doi.org/10.1080/12345678.2021.235987>
- [23] Bello, S., Nkemdirim, C., & Bature, F. (2021). SegNet: A lightweight approach for real-time segmentation in environmental monitoring. *Sensors*, 21(15), 5251. <https://doi.org/10.3390/s21155251>
- [24] Lee, J., Park, H., & Kim, D. (2024). Real-time segmentation techniques for mining operations: Comparative insights. *Mining Engineering & Technology*, 42(1), 15–32. <https://doi.org/10.1016/j.mengtech.2024.01.001>
- [25] Bagheri, R., & Ziaratban, A. (2021). Hybrid segmentation models for environmental and mining applications. *Journal of Advanced Mining Science*, 15(4), 233–245. <https://doi.org/10.1016/j.advmining.2021.10.003>

Madencilik sektörü, ekonomik kalkınma ve endüstriyel üretim için vazgeçilmez bir role sahiptir. Ancak, çevresel sürdürülebilirlik, güvenlik ve operasyonel verimlilik gibi önemli zorluklarla karşı karşıyadır. Günümüzde dijitalleşme ve yapay zeka (AI) tabanlı teknolojiler, bu zorluklara çözüm sunan yenilikçi araçlar haline gelmiştir. Özellikle derin öğrenme tabanlı segmentasyon modelleri, madencilik sahalarındaki karmaşık veri setlerini analiz etmek, sınıflandırmak ve görselleştirmek için oldukça etkili bir yöntem olarak öne çıkmaktadır. Bu çalışma, madencilik operasyonlarında U-Net, Mask R-CNN ve DeepLab gibi segmentasyon modellerinin uygulamalarını kapsamlı bir şekilde incelemiştir. Ayrıca, uydu görüntüleri (örneğin Landsat ve Sentinel) ve dron fotoğraflarından elde edilen verilerin bu modellerle nasıl entegre edildiği ele alınmıştır.

Bu çalışmanın sunduğu katkılar, madencilik sektöründe yapay zeka tabanlı araçların kullanımına dair önemli bir yol haritası sağlamaktadır. Segmentasyon yöntemleri, operasyonel süreçlerin optimizasyonundan çevresel sürdürülebilirliğe kadar geniş bir yelpazede fayda sunmaktadır. Gelecek

çalışmalar, hibrit modellerin geliştirilmesi, gerçek zamanlı uygulamalara yönelik optimizasyonlar ve daha büyük veri setleri üzerinde yapılacak analizlere odaklanabilir. Bu doğrultuda, derin öğrenme tabanlı segmentasyon araçlarının madencilikteki potansiyeli, yalnızca güncel operasyonel zorlukları aşmakla kalmayıp aynı zamanda sektörde daha yenilikçi ve sürdürülebilir uygulamaların önünü açmaktadır.