

Derin Öğrenme ile Deprem Yüzey Kırıklarının Otomatik Belirlenmesi: 6 Şubat 2023 Kahramanmaraş Depremleri Örneği

*Automatic Detection of Earthquake Surface Ruptures with Deep Learning:
The Case of the February 6, 2023 Kahramanmaraş Earthquakes*

Ali POLAT

İl Afet ve Acil Durum Müdürlüğü, Sivas

Geliş (Received): 04/03/2025 / Düzeltme (Revised): 27/03/2025 / Kabul (Accepted): 21/04/2025

ÖZ

Depremler can ve mal kaybına en çok neden olan afet türlerinden birisidir. Depremlerin anlaşılması ve zararların en aza indirilmesi için yüzey kırıklarının tespit edilmesi ve incelenmesi büyük önem taşımaktadır. Bu çalışmada 6 Şubat 2023 tarihinde Kahramanmaraş ili merkezli 7,7 ve 7,6 büyüklüğünde meydana gelen ve 11 ili etkileyen depremlerde oluşmuş yüzey kırıklarının otomatik olarak tespit edilmesi amaçlanmıştır. Altlık olarak MAXAR uydu görüntüleri, segmentasyon modeli olarak YOLOv8n-seg kullanılmıştır. Uydu görüntüleri üzerinde yüzey kırıklarının gözle görülebildiği bir alan belirlenmiş ve bu alandaki kırıklar yardımı ile model eğitilmiştir. Görüntülerin %66'sı eğitim, %34'ü ise test için kullanılmıştır. Eğitilen modelin mAP@0,5 değeri 0,88 olarak tespit edilmiştir. YOLOv8 modeli, derin öğrenme teknikleriyle desteklenen bir yöntem olarak bu tür görevlerde yüksek verimlilik sunmaktadır. Bu yöntem kullanılarak deprem sonrası oluşacak yüzey kırıkları uydu görüntüleri üzerinde kolaylıkla tespit edilebilmektedir. Yöntem, araştırmacılara büyük alanlarda hızlı bir şekilde yüzey kırıklarının tespit edilmesine olanak sağlayarak arazi çalışmaları için önemli bir altlık sağlamaktadır. Bu sayede zaman ve ekonomik anlamdaki kayıplar en aza indirilmiş olacaktır.

Anahtar Kelimeler: Kahramanmaraş depremleri, Derin öğrenme, Segmentasyon, YOLOv8, Yüzey kırığı

ABSTRACT

Earthquakes are a type of disaster that cause highest loss of life and property. Detecting and examining surface ruptures has great importance in understanding earthquakes and minimizing damage. This study aims to automatically detect surface ruptures that occurred during earthquakes with magnitudes of 7.7 and 7.6 that occurred in Kahramanmaraş province on February 6, 2023 and affected 11 provinces. MAXAR satellite images were used as the base image and YOLOv8n-seg was used as the segmentation model. An area where surface ruptures were visible was identified on the satellite images and the model was trained with the help of ruptures in this area. Of the images, 66% was used for training and 34% for testing. The mAP@0.5 value for the trained model was determined to be 0.88. The YOLOv8 model, as a method supported by deep learning techniques, offers high efficiency for these tasks. Using this method, surface ruptures that occur during earthquakes can be easily detected on satellite images. The method provides researchers with an important basis for field studies by allowing them to quickly detect surface fractures in large areas. In this way, time and economic losses will be minimized.

Keywords: Kahramanmaraş earthquakes, Deep learning, Segmentation, YOLOv8, Surface rupture

GİRİŞ

6 Şubat 2023 tarihinde saat 04:17 ve 13:24'te merkez üssü Pazarcık (Kahramanmaraş) ve Elbistan (Kahramanmaraş) olan Mw 7,7 ve Mw 7,6 büyüklüğünde iki büyük deprem meydana gelmiştir. 7,7 büyüklüğündeki deprem 8,6 km derinlikte meydana gelirken 7,6 büyüklüğündeki deprem 7 km derinlikte meydana gelmiştir (AFAD, 2023). Deprem birçok can ve ekonomik kayba neden olmuştur. Deprem esnasında kilometrelerce uzunlukta yüzey kırığı oluşmuş, heyelan ve kaya düşmeleri meydana gelmiştir. Meydana gelen yüzey kırığı ile ilgili çalışmalar arazi gözlemleri ve uydu görüntüleri ile kullanılarak yapılmıştır (Koçbulut vd., 2023; Bayrakdar vd., 2023; Aksoy vd., 2023; Akıncı ve Ünlügenç, 2023; Feng vd., 2023; Kozacı vd., 2024; Mikhailov vd., 2023; Polat, 2023; Reitman vd., 2023; Softa, 2024; Yönlü ve Karabacak, 2024; Aydan 2024; Meng vd., 2024).

Bu çalışmada yüksek çözünürlüklü uydu görüntüleri kullanılarak 6 Şubat 2023 Kahramanmaraş depremleri sonrası oluşan yüzey kırıklarını otomatik olarak tespit etmeye yönelik bir yöntem uygulanmıştır. Segmentasyon amaçlı birçok derin öğrenme modeli bulunmasına rağmen daha hızlı sonuç veren YOLOv8 (You Only Look Once) (Redmon vd., 2016) derin öğrenme algoritması kullanılmıştır. YOLO gerçek zamanlı nesne tespiti için Konvolüsyonel Sinir Ağlarını (CNN) kullanan en yaygın algoritmalarından birisidir. Versiyon-8 ile resmi olarak segmentasyon görevleri için de kullanıma sunulmuştur. Segmentasyon ile tespit edilen obje sınırları piksel düzeyinde çizilir. Bu çalışmada YOLOv8n-seg modeli kullanılarak, çeşitli tip ve çözünürlüklerdeki görüntü verilerinden yüzey kırıklarını doğru bir şekilde tanımlayabilen ve haritalayabilen eğitilmiş bir model sunulmaktadır.

Depremler dünyada en fazla can ve mal kaybına neden olan afet türlerinden biridir. Bu

nedenle deprem öncesi ve sonrası yapılacak çalışmalar hem afet yönetimi hem de jeolojik çalışmalar açısından kritik öneme sahiptir. Özellikle deprem esnasında oluşan yüzey kırıklarının belirlenmesi ve anlaşılması, bu olayların etkilerini anlamak ve kontrol etmek için önemli bir adımdır.

Yüzey kırıkları; arazi gözlemleri, hava fotoğrafları ve uydu görüntüleri kullanılarak haritalanabilmektedir (Klinger vd., 2005; Polat vd., 2006; Kaneda vd., 2008; Kürçer vd., 2016; Yuan vd., 2021; Li vd., 2023; Patyniak vd., 2024; Wang vd., 2024). Son dönemlerde derin öğrenme modelleri kullanılarak uydu görüntüleri veya hava fotoğrafları üzerinden tespit çalışmaları yoğunluk kazanmıştır. Bilgisayarların işleme kapasitelerindeki artış bu işlemleri daha da kolay hale getirmiştir. Genel olarak bu çalışmalar segmentasyon modelleri ile yapılmaktadır. Bu yöntem kullanılarak yüzey kırıklarının tespit edilmesine yönelik yapılmış çeşitli çalışmalar aşağıda verilmiştir.


Mattéo vd. (2021), optik görüntülerden, topografik verileri ve fayları otomatik olarak haritalamak için U-Net'e (Ronneberger vd., 2015) dayalı bir model geliştirmişlerdir. Geliştirilen modelin mimarisi Tasar vd. (2019) tarafından geliştirilen başka bir modele dayanmaktadır. Jafrasteh vd. (2020), optik görüntülerdeki kırık ve fay izlerinin tanımlanması ve haritalanmasının otomatikleştirilmesi için Derin Sinir Ağları (DNN) tabanlı yeni bir yöntem geliştirmişlerdir. Bu yöntem Generative Adversarial Network (GAN) temelli olup Conditional Generative Adversarial Network (CGAN) olarak adlandırılmıştır. Kanoun vd. (2022), yüksek çözünürlüklü optik görüntüler ve topografik veriler aracılığıyla fayları ve kırıkları belirlemek ve haritalamak için geliştirilmiş bir derin öğrenme yaklaşımı önermiştir. Araştırmacılar modeli, eğitim için kullanılan alandan farklı

bir alanda test etmişler ve yüksek başarımlar elde etmişlerdir. Chen vd. (2022), yüzey kırıklarını tanımlamak için bir derin öğrenme yöntemini önermiş ve depremin neden olduğu büyük yüzey kırıklarını bazı yanlış ve eksik tanımlamalara rağmen etkili bir şekilde haritalayan bir semantik segmentasyon ağı geliştirmişlerdir. Yu vd. (2022), depremlerin neden olduğu kosismik kırılmaları tespit etmek için yoğun şekilde dağılmış çatlaklara odaklanan uzaktan algılama tabanlı otomatik çatlak tespit sistemi önermişlerdir. Chen vd. (2023), zeminde meydana gelen kırıkların manuel olarak tespit edilmesinin hataya açık olmasını savunarak U-Net tabanlı bir semantik segmentasyon yöntemi önermişlerdir. Önerilen modelin geleneksel görüntü işleme ve derin öğrenme modellerine göre daha başarılı olduğunu belirtmişlerdir. Choi vd. (2023), yüksek çözünürlüklü uydu görüntüleri kullanarak yüzey kırıklarını tespit etmeye yönelik bir çalışma yapmıştır. Geliştirilen model, yüzey kırıklarını %90 oranında doğru bir şekilde tespit etmiştir. Wang ve Liu (2023), 2023 Kahramanmaraş depremleri sonrasında yüzey kırıklarının hızlı bir şekilde haritalanması amacıyla uydu verileri kullanmıştır. Yazarlar, özellikle Sentinel-1 radar görüntüleri ve optik uydu verilerini analiz ederek yüzey deformasyonlarını tespit etmişlerdir. Geliştirilen yöntem, kırıkların konumunu ve uzanımını yüksek doğrulukla belirlemekte başarılı olmuştur. Zeng vd. (2023), 2021 yılında Çin'in Qinghai bölgesinde meydana gelen Mw 7,4 büyüklüğündeki Madoi depreminin yüzey kırıklarının belirlenmesi ve haritalanması için makine öğrenmesi teknikleri kullanmıştır. Araştırmacılar, uzaktan algılama verilerini analiz ederek yüzey kırıklarının mekânsal dağılımını tespit etmek amacıyla sınıflandırma algoritmaları uygulamıştır. Makine öğrenmesinin, manuel gözlemle karşılaştırıldığında daha hızlı ve sistematik bir haritalama sunduğu belirtilmiştir.

YÖNTEM

Bir görüntüdeki nesneleri anlamlandırmak (tespit etmek) için çeşitli görüntü işleme teknikleri kullanılır. Genel olarak görüntü üzerindeki nesneler sınıflandırma ve segmentasyon yöntemleri ile tespit edilir. Sınıflandırma bir görüntüyü veya belirli bir bölümünü önceden tanımlanmış sınıflara atama işlemidir. Segmentasyon ise görüntüyü yada bir bölümünü anlamlı parçalara ayırma işlemi olup her pikselin hangi nesneye ait olduğunu belirler. Sınıflamada görüntüler sınıflara atanırken (örneğin bir görüntüde kedi ve köpek olarak iki ayrı sınıf kullanılabilir) segmentasyonda nesnelerin tam sınırları belirlenir. Bu yöntemler bir çok alanda kullanılır (Chen vd., 2019; Polat vd., 2021; Kanakaraddi vd., 2024). Sınıflama veya segmentasyon işlemleri genellikle üç bölümden oluşur. Bunlar veri setinin hazırlanması, modelin oluşturulması ve test edilmesi şeklindedir. Bu çalışmaya ait iş akış diyagramı Şekil 1'de verilmiştir.

Tahmin süreci görüntülerin ve etiketlerin hazırlanması ile başlar. Uydu görüntüleri (raster) üzerinde tespit edilecek nesneler çizilerek bir vektör verisi oluşturulur. Uydu görüntüsü ve üzerindeki vektör veri birlikte işlenerek modelin okuyabileceği hale getirilir (ön işleme). Görüntüler hazırlandıktan sonra belirli bir oranda eğitim ve test verisi olarak bölünür. Eğitim verisi kullanılarak model eğitilir. Test verisi kullanılarak başarımlar test edilir. Gerekli görülen model parametreleri değiştirilerek en iyi başarımlar elde edilmeye çalışılır. Bu çalışmada eğitim ve test süreçleri tamamlandıktan sonra tamamen farklı bir bölgeye ait görüntüler ile test yapılmış ve elde edilen çizgisellikler koordinatlı bir şekilde vektör verisine dönüştürülmüştür. Bu aşamalar aşağıda detaylı bir şekilde anlatılmıştır.



Şekil 1. İş-akış diyagramı.

Figure 1. Work-flow diagram.

Veri Seti Hazırlama

Derin öğrenme modellerinin tahmin yapabilmesi için eğitilmesi gerekmektedir. Modeller kendine sunulan veriler yardımı ile öğrenir ve tahminleri bu verilere göre yaparlar. Veri setleri ne kadar çok olursa ve sağlıklı bilgi içerirse öğrenme ve tahminde o kadar başarılı olur. Bu yüzden makine öğrenmesi, derin öğrenme ya da yapay zekâ uygulamalarında veri seti hazırlama işlemi çok önemlidir (Kotsiantis vd., 2006; Garcia vd., 2015; Goodfellow vd., 2016; Zhang ve Yang, 2017; Brownlee, 2020; Kelleher, 2023; Polat vd., 2023; Zhang vd., 2023; Patel vd., 2024)

Bu çalışmada veri olarak yüksek çözünürlüklü uydu görüntüleri kullanılmıştır. 6 Şubat 2023 depreminden sonra MAXAR firmasına ait görüntüler ücretsiz olarak kullanıma açılmıştır. Kullanılan uydu görüntüsü depremde bir gün sonrasına ait (07.02.2023) olup 31 cm/piksel çözünürlüğe sahiptir. Büyük ölçekli uydu görüntüleri doğrudan modele


verilemez. Görüntülerin modelin istediği formata dönüştürülmesi gerekmektedir.

Segmentasyon öğrenme modelleri bir gerçek görüntüye bir de maskelenmiş görüntüye ihtiyaç duyar. Maskelenmiş görüntü tahmin edilecek objenin gerçek görüntüden ayrılması ile oluşturulur. Gerçek görüntü üzerinde objeler çizilerek etiketlenir. Çizilen alanlara 1 değeri atanır arka plan ise 0 değeri ile temsil edilir. Birden fazla obje tahmini yapılacaksa her bir objeye farklı numara verilir (Wang vd., 2021). Maske görüntüleri ikili (binary) sistemde hazırlanmış tek bir sınıf olduğundan 1 ve 0'lerden oluşmaktadır. 1'ler yüzey kırıklarını 0'lar ise arka planı temsil etmektedir.

Bu çalışmada da öncelikle etiketleme işlemi yapılmıştır. Tahmin edilecek obje deprem yüzey kırıkları olduğu için uydu görüntüsü üzerinde kırıkların net görülebildiği bir alan seçilmiştir Pazarçık güney doğusunda bir alan eğitim yapmak için, Türkoğlu doğusunda bir alan ise eğitilen modeli test etmek için belirlenmiştir (Şekil 2). Bu


kırıklar arazide de net olarak izlenebilmektedir (Şekil 3a). Seçilen alanda yüzey kırıkları arcGIS yazılımı ile detaylı bir şekilde çizilmiştir. Çizgiler çok dar bir alanı temsil ettiği için modelin öğrenmesinde problemler yaşanacağından dolayı

çizgilere tampon uygulanmıştır. Her bir kırığın sağına ve soluna 5 metre tampon uygulanarak, çizgisellikler poligona dönüştürülmüştür (Şekil 3b). Bundan sonraki süreçler Python kodları ile yürütülmüştür.



Şekil 2. Yer bulduru haritası.

Figure 2. Location map.



Şekil 3. Narlı doğusunda gözlenen yüzey kırığı (a), uydu görüntüsü üzerinde 5 metre tampon oluşturulmuş poligon (b).

Figure 3. Surface rupture observed east of Narlı (a), Polygon of the 5-meter buffer zone on satellite image (b).

Eğitim için seçilen alanın uydu görüntüsü 16690×36522 piksel boyutlarındadır. Bu görüntü modelin kullanabileceği boyutlarda parçalara ayrılmak zorundadır. Bu çalışmada, kırıklar daha iyi gözlemlendiği için 512×512 boyutunda parçalar kullanılmıştır. Tüm görüntü değil sadece kırıkları içeren bölüm bu ebatlarda parçalara ayrıldığında çok az görüntü oluşmaktadır. Görüntü sayısını artırmak için rastgele örnekleme yöntemi kullanılmıştır (Polat vd., 2023).

Derin öğrenme yönteminde veri sayısının fazla olması başarıyı artırmaktadır. Eğitim aşamasından önce çeşitli veri çoğaltma yöntemleri uygulanabilir. Bunlar görüntüyü bozmadan çeşitli özellikleri (parlaklık, kontrast, netlik, döndürme vb.) değiştirilerek yapılır. Bu çalışmada görüntünün özelliklerini bozmadan sadece farklı alanlardan aynı boyutlu görüntüler oluşturularak görüntüler çoğaltılmıştır. Uydu görüntülerinden veri üretmek genelde görüntünün

boyutu ile sınırlıdır. Görüntüler modelde kullanılacak boyutlarda parçalara bölünerek veri setleri oluşturulduğundan küçük alanlarda veri sayısını artırmak için belirli boyutta rastgele veriler üretilerek veri sayısının artırılması amaçlanmıştır. Ezberleme probleminden kaçınmak için eğitim aşamasında kullanılacak veri 9 eşit parçaya bölünmüştür (Şekil 4). Şekil 4’de görüldüğü gibi 1-5-9 numaralı alanlardan test verisi, diğer alanlardan ise eğitim verisi oluşturulmuştur. Bu yöntem ile hiçbir görüntü aynı köşe koordinatlarına sahip olmayacak şekilde yeterli sayıda veri üretilebilmektedir. Oluşturulan görüntülerin %66’sı eğitim için %34’ü test için kullanılmıştır. Toplamda 800 adet görüntü oluşturulmuş 528 adedi eğitim, 272 adedi test verisi olarak ayrılmıştır. Eğitim ve test verileri ile maske görüntüleri (etiketli görüntü) oluşturulduktan sonra model eğitimi işlemi yapılmıştır.

1	2	3
4	5	6
7	8	9

Şekil 4. Rastgele örnekleme yöntemi eğitim ve test verisi seçim alanları.

Figure 4. Random sampling method training and test data selection areas.


Model Oluşturma

Bu çalışmada YOLO v8n-seg segmentasyon modeli kullanılmıştır. Bu model gerçek zamanlı nesne takip işlemlerinde kullanılan birçok modelden (R-CNN, SSD, EfficientDet) daha iyi sonuç vermektedir. Önceki YOLO sürümlerinin üzerine inşa edilen YOLO v8, onu çok çeşitli uygulamalarda çeşitli nesne algılama görevleri için ideal bir seçim haline getiren yeni özellikler ve optimizasyonlar sunmuştur. YOLOv8'in hız, doğruluk ve kullanım kolaylığına odaklanması bu modeli çok çeşitli uygulamalar için tercih edilir hale getirmiştir. Bu özellikler nesne algılama ve izleme, segmentasyon, görüntü sınıflandırması ve

poz tahmini gibi çeşitli uygulamalarda başarıyla kullanılmasını sağlamıştır. Modelin mimarisi (Ultralytics, 2024) Şekil 5'te gösterilmiştir.

Model görüntü çözünürlüğü 640×640 olan COCO veri setinde eğitilmiş olarak sunulmaktadır. Bu veri seti, arabalar, bisikletler ve hayvanlar gibi yaygın nesnelerin yanı sıra şemsiyeler, el çantaları ve spor malzemeleri gibi daha spesifik kategoriler de dahil olmak üzere 80 nesne kategorisinden oluşmaktadır (Lin vd., 2014).

Bu çalışmada klasik nesnelerin segmentasyonu yapılmayacağından kendi eğitim veri setimiz üzerinde model tekrar eğitilmiştir.



Eğitim aşamasında NVIDIA GeForce RTX 3050 ekran kartı kullanılmış ve eğitim GPU üzerinden yapılmıştır. Küme boyutu (batch size) 12 olarak kullanılmıştır. Daha yüksek değerlerde bellek (memory) hatası vermiştir. Yüksek devir sayıları kullanıldığında ezberleme olasılığı artacağından dolayı devir sayısı 150 olarak seçilmiştir. Düşük devir sayılarında başarımlar düşmektedir. Model eğitiminde optimizasyon algoritması (optimizer) seçimi başarımları etkileyen diğer bir faktördür. YOLO algoritma seçimini otomatik olarak yapmaktadır.

Segmentasyon işlemlerinde performans değerlendirmesi için çeşitli ölçekler kullanılır. Bunlar mAP (Mean Average Precision), IoU (Intersection over Union), kesinlik (Precision), duyarlılık (Recall) F1 skoru ve Dice skorudur. Genelde IoU kullanılır. Bu çalışmada mAP@0,5 metriği kullanılmıştır. Bu metrik diğerlerine göre daha kapsamlı sonuçlar verebilmektedir.

mAP hem IoU hem de kesinlik metriklerini kullanır. Kesinlik modelin yaptığı tahminlerin doğruluğunu hesaplar. Doğru pozitiflerin (TP), doğru pozitif (TP) ve yanlış negatif (FP) in toplamına bölümü ile elde edilir (Eşitlik 1).

$$Kesinlik = \frac{TP}{TP+FP} \quad (1)$$

Burada, TP; Doğru Pozitif (True Positive), FP; Yanlış Pozitif (False Positive) dir.

IoU ise gerçek maske ve tahmin edilen maske arasındaki örtüşme oranıdır. Sıfır ve bir arası bir değerden oluşur ve bir değerine ne kadar yakın ise o kadar doğrudur (Eşitlik 2).

$$IoU = \frac{Tahmin\ edilen\ alan \cap Gerçek\ alan}{Tahmin\ edilen\ alan \cup Gerçek\ alan} \quad (2)$$

mAP, IoU'nun iki farklı eşik değeri için ölçülmüştür. mAP@0,5 IoU eşik değeri 0,5 olan doğruluğu, mAP@0,5-0,95 ise IoU eşik değeri

0,5 ile 0,95 arasında değişen 10 farklı değer için doğruluğu ölçer.

Elimizde uydu görüntüleri olması durumunda bu çalışmayı yapmak, hazırlanan Python kodları sayesinde oldukça kolaylaşmaktadır. Veri seti hazırlama, model oluşturma ve tahmin için ayrı Python kodları yazılmıştır. Tahminler vektör halinde .shp dosyasına dönüştürülmüş olarak verilir. Böylece kırıklar herhangi bir Coğrafi Bilgi Sistemleri (CBS) yazılımında görüntülenip düzenlenebilir haldedir. Bu kodlar sayesinde yüzey kırığı tahmini YOLOv8n-seg algoritması kullanılarak herhangi bir bölge için rahatlıkla yapılabilir. Çalışmada kullanılan Python kodlarına “https://github.com/apolat2018/predict_surface_rupture” adresinden ulaşılabilir.

BULGULAR

Eğitilen model için mAP@0,5 değeri 0,88 olarak ölçülmüş olup bir sınıflama problemi için tatmin edicidir. Modelin performans ölçütleri Şekil 6'da verilmiştir.

Kahramanmaraş ili Pazarcık ilçesine bağlı Narlı beldesinde yüzey kırıkları çok net gözlenmektedir. Yaklaşık 55 km²'lik bir alanda 12 km uzunluğunda deprem yüzey kırığı oluşmuştur (Polat, 2023). Bu alan model eğitimi için kullanılmıştır. 20 km batıda Türkoğlu doğusunda 14 km²'lik bir alanda aynı model denenmiştir Eğitim ve test verisinden tamamen farklı olan bu veriler ile yapılan tahminde yüzey kırığının tamamı başarılı bir şekilde tespit edilmiştir. Tespit edilen yüzey kırıkları AFAD ve Çukurova Üniversitesi raporlarında fotoğraflar ile teyit edilmiştir (AFAD, 2023; Ünlügenç vd., 2023).

YOLOv8 tahmin algoritmasında güven skoru (confidence) olarak adlandırılan bir parametre bulunmaktadır. Bu parametre sınıf

doğruluğu ve IoU'nun çarpımına eşittir. Bu değer ne kadar artarsa doğru tahmin yapma olasılığı artar ve yanlış negatifleri azaltır. Güven skoru 0,85 değerine kadar test edilmiştir. Daha düşük değerlerde yüzey kırığı olmayan alanların da tahminde yer aldığı gözlenmiştir. Çalışma alanında bulunan yüzey kırıkları tarla sınırlarına, su kanallarına ve tarla içerisinde bulunan işlenmiş toprak şekillerine büyük ölçüde benzerlik göstermektedir. Yüzey kırığı ve arka plandaki benzer şekillerin ayırımı yapabilmek için güven skoru yüksek bir değer olarak belirlenmiştir. Değerler test edilerek optimum bir değer elde etmeye çalışılmıştır. 0,85 değeri ile yapılan tahminde yüzey kırıklarının tamamı tespit edilmiş ve farklı bir çizgisellik tespit edilmemiştir (Şekil 7). Değer 0,5 olarak seçildiğinde farklı çizgisellikler de tespit edilmiştir. Şekil 8'de kırmızı çizgiler güven skoru 0,5 değeri ile, sarı çizgiler güven skoru 0,85 değeri ile yapılmış tahminleri göstermektedir. Şekil 7 (b)'de tahmin edilen yüzey kırıkları büyütülerek detaylı olarak gösterilmiştir.


Tahminlerin başarılı olmasının bir nedeni de yüzey kırıklarına tampon uygulanmasından kaynaklıdır. Tek bir çizgiden oluşan kırık ile veri

seti hazırlansa idi çok fazla buna benzer yapı tahmin edilecekti. Çalışma alanı için en uygun tampon değeri 5 metre olarak belirlenmiştir.

SONUÇLAR ve TARTIŞMA


Bu çalışmada deprem yüzey kırıkları uydu görüntülerinden yararlanılarak otomatik olarak tespit edilmiştir. 6 Şubat 2023 Kahramanmaraş depremleri sonrasında ait (7 Şubat 2023 tarihli) Pazarcık ilçesini içeren yüksek çözünürlüklü MAXAR firmasına ait uydu görüntüsünde Narlı civarında net olarak gözlenen yüzey kırıkları etiketlenerek bir veri seti hazırlanmıştır. Rastgele örnekleme tekniği kullanılarak 800 adet görüntü elde edilmiş ve bu görüntülerin %66'sı kullanılarak model eğitilmiş, %34'ü ile test edilmiştir.

Yüzey kırıklarını tespit etmek için YOLO v8n-seg algoritması kullanılmıştır. Model eğitimi ve tahmin süreçlerini hızlı bir şekilde yapabilmesinden dolayı bu algoritma tercih edilmiştir. Model performansı mAP@0,5 metriği ile değerlendirilmiş olup bu değer 0,88 olarak ölçülmüştür. Model performansı bu tür çalışmalar için tatmin edici bir sonuç vermiştir.



Şekil 6. Eğitilen modelin performans ölçütleri.

Figure 6. Performance metrics of the trained model.



Şekil. 7. Tahmin edilen yüzey kırıkları, (a) deneme alanının tamamı, (b) Mavi dikdörtgen içinde kalan alanın büyütülmüş hali.

Figure 7. Predicted surface ruptures, (a) entire test area, (b) magnification of the area within the blue rectangle.

Eğitilen model eğitim alanından 120 km batıda Türkoğlu doğusunda tamamen farklı bir bölgede sınanmıştır. Bu bölgedeki yüzey kırıkları başarılı bir şekilde tespit edilmiştir. YOLO tahmin algoritmasının bir parametresi olan güvenlik skoru değeri sonuçları doğrudan etkilemektedir. Bu değer düşük olduğunda FN sayısının arttığı gözlenmiştir. Yüksek olduğunda ise Doğru TP sayılarında azalma gözlenmektedir. Yapılan testler ile güvenlik skoru değeri (conf) 0,85 olduğunda yüzey kırıklarının net olarak tespit edildiği görülmüştür. Güvenlik skoru 0,5 seçildiğinde bazı tarla sınırlarının, veya su

kanallarının da yüzey kırığı olarak tanındığı gözlenmiştir.

Eğitilen model görüntüleri ve tahmin yapılacak alan görüntülerinin coğrafik özellikleri birbirine benzerlik sunmaktadır. Bu model ova içerisinde bir alandan seçilen görüntüler ile eğitilmiştir. Farklı coğrafi özelliklere sahip alanlarda test edilememiştir. Örneğin bir dağ yamacında oluşmuş yüzey kırığının tahmin doğruluğu test edilmelidir. Eğer tahmin oranı düşük ise o bölge için yeni bir veri seti hazırlamak gerekebilir.

Bu çalışmada görüntü hazırlamadan tahmin edilen yüzey kırıklarının vektör dosya haline getirilmesine kadar tüm aşamalar Python komut dosyaları ile yapılmış olup her bir aşama için ayrı ayrı Python kodları yazılmıştır. Bu kodlar sayesinde uydu görüntüleri olan bir bölge için kolaylıkla otomatik tahmin yapılabilmektedir. Deprem sonrasında yapılacak bu çalışma ile araştırmacılara ve karar vericilere yüzey kırıklarının nerelerde olduğu ile ilgili bilgiler kısa zamanda sunulabilecek ve önemli bir altlık sağlanacaktır. Böylece zaman ve ekonomik anlamda büyük bir kazanım sağlanmış olacaktır. Gelecekteki çalışmalar ile bu yöntem geliştirilebilir bir CBS yazılımına entegre edilebilir. Ayrıca farklı veri setleri ile farklı bölgeler için tahmin yaptırılabilir ya da farklı yüzey şekillerinin tahmininde de kullanılabilir.

KATKI BELİRTME

Çalışmada kullanılan uydu görüntülerini sağlayan MAXAR şirketine teşekkür ederim.

VERİ ERİŞİLEBİLİRLİK BİLDİRİMİ

Bu çalışmada kullanılan tüm Python kodları GitHub üzerinden erişime açıktır: https://github.com/apolat2018/predict_surface_rupture

KAYNAKLAR

- AFAD, (2023). 06 Şubat 2023 Pazarcık-Elbistan (Kahramanmaraş) Mw: 7.7 – Mw: 7.6 Depremleri Raporu. 140 s.
- Akinci, A. C., & Ünlügenç, U. C. (2023). 6 Şubat 2023 Kahramanmaraş Depremleri: Sahadan Jeolojik Veriler, Değerlendirme ve Adana için Etkileri. Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 38(2), 553-569. <https://doi.org/10.21605/cukurovaumfd.1334155>
- Aksoy, E., Akgün, E., Softa, M., Koçbulut, F., vd. (2023). 6 Şubat 2023 Pazarcık (Kahramanmaraş) depreminin Doğu Anadolu Fay Zonu Erkenek ve Pazarcık Segmentleri Üzerindeki Etkisi: Çelikhhan-Gölbaşı (Adıyaman) Arasından Gözlemler. Türk Deprem Araştırma Dergisi, 5(1), 85-104. <https://doi.org/10.46464/tdad.1280408>
- Aydan, Ö. (2024). Crustal Stress State associated with the surface ruptures of the 2023 Pazarcık and Ekinözü Earthquakes. Yerbilimleri, 45(1), 52-65. <https://doi.org/10.17824/yerbilimleri.1325646>
- Bayrakdar, C., Halis, O., Canpolat, E., Döker, M. F., vd. (2023). 6 Şubat 2023 Kahramanmaraş-Ekinözü depremi (Mw 7.6) ile ilişkili Çardak Fayı yüzey kırığının tektonik jeomorfolojisi. Türk Coğrafya Dergisi(83), 7-22. <https://doi.org/10.17211/tcd.1281680>
- Brownlee, J. (2020). Data preparation for machine learning: Data cleaning, feature selection, and data transforms in Python. Machine Learning Mastery.
- Chen, W., Zhong, C., Qin, X., & Wang, L. (2023). Deep learning based intelligent recognition of ground fissures. In Intelligent interpretation for geological disasters: from space-air-ground integration perspective (pp. 171-233). Singapore: Springer Nature Singapore. <https://doi.org/10.1007/978-981-99-5822-1>
- Chen, X., Hu, G., & Liu, X. (2022). Recognition of earthquake surface ruptures using deep learning. Applied Sciences, 12(22), 11638. <https://doi.org/10.3390/app122211638>
- Chen, Z. M., Wei, X. S., Wang, P., & Guo, Y. (2019). Multi-label image recognition with graph convolutional networks. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 5177-5186).

- Choi, Y., Choi, J. H., & Choi, Y. (2023). Fit-for-purpose approach for the detection and analysis of earthquake surface ruptures using satellite images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 9574-9589. <https://doi.org/10.1109/JSTARS.2023.3322347>
- Feng, J., Yan, J., & Zhao, X. (2023). Preliminary Investigation on the Surface Ruptures of the Turkey M7. 8 Earthquake on February 6, 2023. *Acta Scientiarum Naturalium Universitatis Pekinensis*, 59(6), 945-950.
- García, S., Luengo, J., & Herrera, F. (2015). Data preprocessing in data mining. Springer. <https://doi.org/10.1007/978-3-319-10247-4>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.
- Jafrasteh, B., Manighetti, I., & Zerubia, J. (2020). Generative adversarial networks as a novel approach for tectonic fault and fracture extraction in high resolution satellite and airborne optical images. In *ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (Vol. 43, pp. 1219-1227). <https://doi.org/10.5194/isprs-archives-XLIII-B3-2020-1219-2020>
- Kanakaraddi, S. G., Handur, V. S., Jalannavar, A., Chikaraddi, A., & Giraddi, S. (2024). Segmentation and Classification of Lung Cancer using Deep Learning Techniques. *Procedia Computer Science*, 235, 3226-3235. <https://doi.org/10.1016/j.procs.2024.04.305>
- Kaneda, H., Nakata, T., Tsutsumi, H., Kondo, H., Sugito, N., Awata, Y., Akhtar, S.S., Majid, A., Khattak, W., Awan, A.A. and Yeats, R.S. (2008). Surface rupture of the 2005 Kashmir, Pakistan, earthquake and its active tectonic implications. *Bulletin of the Seismological Society of America*, 98(2), pp.521-557. <https://doi.org/10.1785/0120070073>
- Kanoun, B., Cherif, M. A., Manighetti, I., Tarabalka, Y., & Zerubia, J. (2022). An enhanced deep learning approach for tectonic fault and fracture extraction in very high resolution optical images. In *ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 3403-3407). IEEE. <https://doi.org/10.1109/ICASSP43922.2022.9747007>
- Kelleher, J. D. (2023). Data science: An introduction. MIT Press.
- Klinger, Y., Xu, X., Tapponnier, P., Van der Woerd, J., Lasserre, C., & King, G. (2005). High-resolution satellite imagery mapping of the surface rupture and slip distribution of the M_w ~ 7.8, 14 November 2001 Kokoxili earthquake, Kunlun fault, northern Tibet, China. *Bulletin of the Seismological Society of America*, 95(5), 1970-1987. <https://doi.org/10.1785/0120040233>
- Koçbulut, F., Softa, M., Akgün, E., Koşaroğlu, S., & Otlı, N. 6 Şubat 2023 (Mw: 7.6) Ekinözü Depremi Yüzey Kırığının Çıgılık Fayı (Malatya-Doğanşehir-Eskiköy) Boyunca Karakteristik Analizi. *Türk Deprem Araştırma Dergisi*, 6(2), 387-404. <https://doi.org/10.46464/tdad.1467421>
- Kotsiantis, S. B., Kanellopoulos, D., & Pintelas, P. E. (2006). Data preprocessing for supervised learning. *International Journal of Computer Science*, 1(2), 111-117.
- Kozacı, O., Altunel, E., Koehler, R., Yildirim, C. and Clahan, K. (2024). M7. 8 Kahramanmaraş Earthquake Surface Fault Rupture and Near-Fault Effect Observations. *Japanese Geotechnical Society Special Publication*, 10(11), pp.276-281. <https://doi.org/10.3208/jgssp.v10.SS-6-03>
- Kürçer, A., Özalp, S., Özdemir, E., Uygun Güldoğan, Ç., & Duman, T. Y. (2016). Yüzey Kırığı Oluşturmuş Faylar üzerinde aktif tektonik ve paleosismolojik araştırmalar hakkında örnek

- çalışma: Yenice Gönen Fayı, KB Türkiye. Maden Tetkik ve Arama Genel Müdürlüğü, Doğal Kay. ve Eko. Bült, 21, 1-18.
- Li, K., Tapponnier, P., Xu, X., & Kang, W. (2023). The 2022, Ms 6.9 Menyuan earthquake: Surface rupture, Paleozoic suture re-activation, slip-rate and seismic gap along the Haiyuan fault system, NE Tibet. *Earth and Planetary Science Letters*, 622, 118412. <https://doi.org/10.1016/j.epsl.2023.118412>
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. In *European Conference on Computer Vision (ECCV)* (pp. 740–755). Springer. https://doi.org/10.1007/978-3-319-10602-1_48
- Mattéo, L., Manighetti, I., Tarabalka, Y., Gaucel, J.M., van den Ende, M., Mercier, A., Tasar, O., Girard, N., Leclerc, F., Giampetro, T. and Dominguez, S. (2021). Automatic fault mapping in remote optical images and topographic data with deep learning. *Journal of Geophysical Research: Solid Earth*, 126(4), p.e2020JB021269. <https://doi.org/10.1029/2020JB021269>
- Meng, J., Kusky, T., Mooney, W. D., Bozkurt, E., Bodur, M. N., & Wang, L. (2024). Surface deformations of the 6 February 2023 earthquake sequence, eastern Türkiye. *Science*, 383(6680), 298-305. <https://doi.org/10.1126/science.adj3770>
- Mikhailov, V. O., Babayantz, I. P., Volkova, M. S., Timoshkina, E. P., Smirnov, V. B., & Tikhotskiy, S. A. (2023, July). The February 6, 2023, Earthquakes in Turkey: A Model of the Rupture Surface Based on Satellite Radar Interferometry. In *Doklady Earth Sciences* (Vol. 511, No. 1, pp. 571-577). Moscow: Pleiades Publishing. <https://doi.org/10.1134/S1028334X2307019X>
- Patel, H., Shah, D., & Thakkar, A. (2024). Role of data preprocessing in modern machine learning pipelines. *Journal of Big Data*, 11, Article 25. <https://doi.org/10.1186/s40537-024-00889-0>
- Patyniak, M., Landgraf, A., Dzhumabaeva, A., Baikulov, S., Williams, A.M., Preusser, F., Abdrakhmatov, K.E., Arrowsmith, J.R. and Strecker, M.R. (2024). Surface rupture of the 2008 Mw 6.6 Nura earthquake: Triggered flexural- slip faulting in the Pamir- Tien Shan collision zone. *Tectonics*, 43(9), p.e2024TC008360. <https://doi.org/10.1029/2024TC008360>
- Polat, A., Keskin, İ., & Polat, Ö. (2023). Automatic Detection and Mapping of Dolines Using U-Net Model from Orthophoto Images. *ISPRS International Journal of Geo-Information*, 12(11), 456. <https://doi.org/10.3390/ijgi12110456>
- Polat, A., Tatar, O., Gürsoy, H., Koçbulut, F., Mesci, B.L., Sezen, T.F., Kavak, K.Ş., Akpınar, Z., Töre, Y., Geyik, M. ve Yakan, M. (2006). Kuzey Anadolu Fay Zonu (KAFZ) doğusunda ÇobanlıAkçağıl (Suşehri-Sivas) arasında 1939 Erzincan Depremi yüzey kırığı. ATAG Aktif Tektonik Araştırma Grubu Toplantıları 10. Çalıştayı (2-4 Kasım 2006 İzmir) Bildiri Özleri Kitabı, s.72.
- Polat, N. (2023). UAV-based investigation of earthquake-induced deformation and landscape changes: a case study of the February 6, 2023 Earthquakes in Hatay, Türkiye. *Earth Science Informatics*, 16(4), 3765-3777. <https://doi.org/10.3390/s150715520>
- Polat, Ö., Polat, A., & Ekici, T. (2021). Automatic classification of volcanic rocks from thin section images using transfer learning networks. *Neural computing and applications*, 33(18), 11531-11540. <https://doi.org/10.1007/s00521-021-05849-3>

- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-788). <https://doi.org/10.48550/arXiv.1506.02640>
- Reitman, N. G., Briggs, R. W., Barnhart, W. D., Hatem, A. E., Thompson Jobe, J. A., DuRoss, C. B., ... & Akçiz, S. (2023). Rapid surface rupture mapping from satellite data: The 2023 Kahramanmaraş, Turkey (Türkiye), earthquake sequence. *The Seismic Record*, 3(4), 289-298. <https://doi.org/10.1785/0320230029>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18 (pp. 234-241). Springer international publishing. <https://doi.org/10.48550/arXiv.1505.04597>
- Softa, M. (2024). Determining the surface fault-rupture hazard zone for the Pazarcık segment of the East Anatolian fault zone through comprehensive analysis of surface rupture from the February 6, 2023, Earthquake (Mw 7.7). *Journal of Mountain Science*, 21(8), 2646-2663. <https://doi.org/10.1007/s11629-024-8723-8>
- Tasar, O., Tarabalka, Y., & Alliez, P. (2019). Incremental learning for semantic segmentation of large-scale remote sensing data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(9), 3524-3537. <https://doi.org/10.48550/arXiv.1810.12448>
- Ultralytics, (2024, 26 Şubat). Brief summary of YOLOv8 model structure #189. <https://github.com/ultralytics/ultralytics/issues/189>
- Ünlügenç, U. C., Türkmen, S., Çetin, H., Güneşli, H., Nurlu, N., Akıncı, A.C. (2023). 06 ŞUBAT 2023 Kahramanmaraş Depremleri (Mw 7,8- Mw 7,6) Değerlendirme Ve Saha Gözlem Raporu.
- Wang, L., Xia, Y., Zhang, Q., & Zhang, L. (2021). Annotation-efficient deep learning for automatic medical image segmentation. *Computerized Medical Imaging and Graphics*, 89, 101886. <https://doi.org/10.1016/j.compmedimag.2021.101886>
- Wang, T., & Liu, S. (2023). Rapid surface rupture mapping from satellite data: The 2023 Turkey earthquakes. *The Seismic Record*, 3(4), 289–296. <https://doi.org/10.1785/0320230023>
- Wang, Y., Wu, S.H., Chou, H.L.B., Li, Y.Y., Cheng, W.S., Ho, A., Chen, J.M., Liu, S.C., Hsieh, C.Y., Duan, S. and Min, S.M. (2024). Surface ruptures of the 2022 Guanshan-Chihshang earthquakes in central Longitudinal Valley area, eastern Taiwan. *Terrestrial, Atmospheric and Oceanic Sciences*, 35(1), p.16. <https://doi.org/10.1016/j.soildyn.2021.106979>
- Yönlü, Ö., & Karabacak, V. (2024). Surface rupture history and 18 kyr long slip rate along the Pazarcık segment of the East Anatolian Fault. *Journal of the Geological Society*, 181(1), jgs2023-056. <https://doi.org/10.1144/jgs2023-056>
- Yu, D., Ji, S., Li, X., Yuan, Z., & Shen, C. (2022). Earthquake crack detection from aerial images using a deformable convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-12. <https://doi.org/10.1109/TGRS.2022.3183157>
- Yuan, Z., Liu-Zeng, J., Li, X., Xu, J., Yao, W., Han, L., & Li, T. (2021). Detailed mapping of the surface rupture of the 12 February 2014 Yutian M s 7.3 earthquake, Altyn Tagh fault, Xinjiang, China. *Science China Earth Sciences*, 64, 127-147. <https://doi.org/10.1007/s11430-020-9673-6>

Zeng, X., Liu, J., Wang, W., Yao, W., Wu, J., Liu, X., Han, L., Wang, W., Xing, Y., Du, R. and Yang, X. (2023). Machine learning in identifying and mapping the surface rupture of the 2021 M W 7.4 Madoi earthquake, Qinghai. Chinese Journal of Geophysics, 66(3), pp.1098-1112. <https://doi.org/10.6038/cjg2022Q0117>

Zhang, Y., & Yang, Q. (2017). A survey on multi-task learning. IEEE Transactions on Knowledge and Data Engineering, 29(12), 2027–2040. <https://doi.org/10.1109/TKDE.2017.2699320>

Zhang, Z., Wang, J., & Chen, X. (2023). Data quality management in AI applications: A survey. ACM Computing Surveys, 55(7), 1–36. <https://doi.org/10.1145/3531090>