

AKÜ FEMÜBİD 23 (2023) 025504 (427-437)

AKU J. Sci. Eng. 23 (2023) 025504 (427-437)

DOI: 10.35414/akufemubid.1171393

Araştırma Makalesi / Research Article

İHA ile Derin Öğrenme Algoritmaları Kullanılarak Hasarlı Yapıların Tespit Edilmesi

Erdem Emin MARAŞ¹, Halil İbrahim SARIYILDIZ²¹Samsun Üniversitesi, Sivil Havacılık Yüksekokulu, Samsun.²Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Samsun.Sorumlu yazar e-posta: erdem.maras@samsun.edu.tr ORCID ID: <https://orcid.org/0000-0002-5205-1622>e-posta: halilibrahim.yildiz@gmail.com ORCID ID: <https://orcid.org/0000-0002-1889-2786>

Geliş Tarihi:09.10.2022

Kabul Tarihi:06.04.2023

Öz

Bu çalışmada, hasarlı yapıların hızlı ve güvenilir bir şekilde tespit edilebilmesi için derin öğrenme algoritmalarında evrimsel sinir ağı mimarisinin bir modeli olan Mask Region-based Convolutional Neural Network (Mask R-CNN) modeli kullanılarak hasar tespiti yapılmaya çalışılmıştır. Eğitim alanı olarak 2010 yılında Haiti’de meydana gelen 316.000 insanın öldüğü, 280.000 civarı yapının hasar gördüğü 7.0 büyüklüğündeki deprem bölgesi seçilmiştir. Bölgede 5 cm ve 7 cm çözünürlüğe sahip insansız hava aracı görüntüleri çalışmada kullanılmıştır. Görüntüler ilk aşamada üç sınıfta “hasarlı”, “az hasarlı” ve “hasarsız” olarak eğitilip test edilmiştir. İnsansız hava aracı verileri ile yapılan test işleminde ise yapılar %58.62 oranıyla bulunmuş ve bulunan yapılar %83.53 genel doğrulukla sınıflandırılmıştır. İkinci aşamada görüntüler “hasarlı” ve “hasarsız” olarak iki sınıfta etiketlenip eğitim ve test işlemi gerçekleştirilmiştir. İnsansız hava aracı verileri ile yapılan test işleminde ise yapılar %74.50 oranıyla bulunmuş ve bulunan yapılar %95.12 genel doğruluk oranıyla sınıflandırılmıştır.

Anahtar kelimeler

Derin Öğrenme;
Uzaktan Algılama;
Evrimsel Sinir Ağı;
İHA

Detection of Damaged Structures Using Deep Learning Algorithms with UAV

Abstract

In the study, damage detection was tried to be done using Mask Region-based Convolutional Neural Network (Mask R-CNN) model, which is a model of convolutional neural network architecture in deep learning algorithms in order to detect damaged structures quickly and reliably. The 7.0 magnitude earthquake zone, which occurred in Haiti in 2010, in which 316,000 people died and 280,000 buildings were damaged, was chosen as the training area. Unmanned aerial vehicle images with a resolution of 5 cm and 7 cm used in the study. In the first stage, the images were trained and tested in three classes as “damaged”, “slightly damaged” and “undamaged”. In the test process with unmanned aerial vehicle data, the structures were found with a rate of 58.62% and the structures found were found with an overall accuracy of 83.53%. In the second stage, the images were labeled in two classes as “damaged” and “undamaged” and training and testing was carried out. In the test process with unmanned aerial vehicle data, the structures were found with a rate of 74.50% and the structures found were classified with an overall accuracy of 95.12%.

Keywords

Deep Learning;
Remote Sensing;
Convolutional Neural
Network; UAV

1. Giriş

Afetlerin neden olduğu hasarın tespitinde son zamanlarda derin öğrenme mimarilerinden evrimsel sinir ağının kullanıldığı çalışmaların başarılı sonuçlar verdiği görülmektedir. Buna karşılık afet hasarları uzaktan algılama verileri ile ilgili kamuya açık veri sınırlı erişimlidir (Nex et al. 2019). Derin öğrenme algoritmaları büyük veri çalışmalarında başarılı sonuçlar vermektedir.

Uydu görüntülerinden sağlanan anlık büyük miktarda verilerin işleme ihtiyacı uydu görüntüleri ile derin öğrenme çalışmalarına giderek artan ilgiye sebep olmaktadır (Bhangale et al. 2019).


Bu çalışmada deprem sonrası yapı hasarı oluşmuş binaların tespiti derin öğrenme algoritmalarından evrimsel sinir ağı kullanılarak yapılmaya çalışılmıştır. Model olarak Mask R-CNN modeli seçilmiş transfer öğrenimi yapılarak modelin başarısı arttırılmaya çalışılmıştır. Eğitim verileri 2010'da Haiti'de meydana gelen 7.0 büyüklüğünde depremden elde edilen uydu görüntüsü ve ağıın başarısının çözünürlükle artacağı düşüncesiyle yine Haiti'den elde edilmiş daha yüksek çözünürlüğe sahip insansız hava aracı görüntüleri ile yapılmıştır.

2. Materyal ve Metot

2.1 Derin Öğrenme

Derin öğrenme insanın öğrenme sürecini ilham alarak insanın karşılaştığı sorunların üstesinden gelirken kullandığı analiz, öğrenme, karar verme gibi süreçleri kullanarak çok fazla sayıda veri ile insan denetimi olarak veya olmayarak veri üzerinde özellik tespiti, analiz yapma ve sınıflandırma gibi işlemleri yapabilen makine öğrenmesi alanının bir alt dalıdır (Kayaalp ve Süzen 2018).

Derin öğrenmenin diğer makine öğrenimlerinden ayrılmasını sağlayan yanı kendi kendine özellik çıkarımı yapmasıdır. Makine öğreniminde bu özellikler kullanıcı tarafından yapılır. Yapay sinir ağlarından ayıran özelliği ise çok sayıda gizli katmanı olmasıdır (İnt. Kyn. 1). Şekil-1 ile makine öğrenmesi ve derin öğrenme arasındaki fark gösterilmiştir.



Şekil 1. Geleneksel makine öğrenmesi ve derin öğrenme yöntemlerinde özellik çıkarımı (İnt. Kyn. 1)

2.2 Evrimsel Sinir Ağları

Evrimsel sinir ağları görüntü işleme alanında son yıllarda ön plana çıkan yapay sinir ağlarındaki parametre sayısını azaltarak daha büyük verilerle çalışma imkânı sağlayan özel bir mimardır. Mimarinin ilk katmanları daha basit özellikler bulabilirken son katmanlarına doğru daha karmaşık ve soyut özellikleri bulabilmektedir (Albawi et al. 2018).

Evrimsel sinir ağlarının genel olarak çalışma mantığında giriş verileri girildikten sonra bu katmanlar eğitilir ve sonuç çıktısı elde edilerek elde edilen hata geriyeye yayılım algoritması ile bütün ağırlıklara aktarılır. Yapılan yinelemelerle en doğru sonucu veren ağırlıklar hesaplanmaya çalışılır (İnik ve Ülker 2017).

Evrimsel sinir ağları daha çok görüntü sınıflandırmada kullanılırlar da giriş verisi olarak görüntünün yanı sıra ses ve video gibi veriler de giriş verisi olarak kullanılmaktadır. Evrimsel sinir ağlarında görüntü sınıflandırma işlemi pikseller, kenar kombinasyonlarından oluşan motifleri, bu motifler birleşerek nesnelere oluşturmaktadır (LeCun et al. 2015).

Yapısında evrim, havuzlama ve tam bağlantı katmanı gibi kendine özgü görevleri olan ayrı katmanları barındırır. Bunlar birbirini takip edecek şekilde dizilerek evrimsel sinir ağları modelini oluştururlar. Bu yapının ilk kısımlarında öznelik çıkartım işlemleri gerçekleştirilirken sınıflandırma işlemi ise son katmanlarda gerçekleşir (Nie et al. 2011).

Evrişimsel sinir ağları mimarisinin katmanları;

- Giriş Katmanı (Input Layer)
- Evrişim Katmanı (Convulation Layer)
- Düzleştirilmiş Doğrusal Birim Katmanı (Rectified Linear Units Layer)
- Havuzlama Katmanı (Pooling Layer)
- Tam Bağlantılı Katman (Fully Connected Layer)
- DropOut Katmanı
- Sınıflandırma Katmanı (Classification Layer)'dir.

Evrişimsel sinir ağlarının genel olarak çalışma mantığında giriş verileri girildikten sonra bu katmanlar eğitilir ve sonuç çıktısı elde edilerek eldeki daha önce eğitilmiş verilerle karşılaştırılarak bir hata belirler.

Elde edilen hata geriye yayılım algoritması ile bütün ağırlıklara aktarılır. Yapılan yinelemelerle en doğru sonucu veren ağırlıklar hesaplanmaya çalışılır (İnik ve Ülker 2017).

Evrişimsel sinir ağları daha çok görüntü sınıflandırmada kullanılırlar da giriş verisi olarak görüntünün yanı sıra ses ve video gibi veriler de giriş verisi olarak kullanılmaktadır. Evrişimsel sinir ağlarında görüntü sınıflandırma işlemi pikseller, kenar kombinasyonlarından oluşan motifleri, bu motifler birleşerek nesnelere oluşturmaktadır (LeCun et al. 2015).

2.3 Mask Region-based Convolutional Neural Network

Mask R-CNN (Mask Region-based Convolutional Neural Network), nesne tanıma ve piksel bazlı görüntü segmentasyonu için kullanılan bir derin öğrenme modelidir. Mask R-CNN, Faster R-CNN modeline dayanır ve Faster R-CNN'nin çıktısına bir piksel seviyesi maske tahmin edici ağı ekler. Bu sayede, hem nesnelere konumlarını hem de piksel düzeyindeki segmentasyonlarını aynı anda tahmin edebilir.

Mask R-CNN, önce Faster R-CNN'nin ağına özellik haritalarını çıkarır. Daha sonra, bu özellik haritalarını iki ayrı dalda işler. İlk dal, Faster R-CNN'deki gibi nesnelere konumlarını tespit etmek için kullanılır. İkinci dal, özellik haritalarından nesne maskelerini tahmin etmek için bir piksel seviyesi ağı kullanır. Bu dal, nesnelere piksel bazlı segmentasyonu için

kullanılır ve Mask R-CNN modelini diğer nesne tanıma modellerinden ayıran özelliğdir (Neven et al. 2019).

Mask R-CNN, nesne tanıma ve piksel bazlı görüntü segmentasyonu için sıklıkla kullanılan bir derin öğrenme modelidir. Mask R-CNN'nin başarılı özellikleri:

- Nesne tanımanın yanı sıra, her pikselin hangi nesneye ait olduğunu belirleyerek piksel bazlı görüntü segmentasyonu yapabilir.
- Diğer modellere göre daha yüksek doğruluk oranlarına sahiptir. Bu durum farklı uygulamalarda daha iyi sonuçlar elde etmek için önemlidir.
- Aynı anda birden fazla nesneyi algılama ve sınıflandırma yeteneğine sahiptir.
- Benzer modellere göre daha hızlı çalışabilir ve gerçek zamanlı uygulamalarda kullanılabilir.

Başarısız Özellikleri:

- Diğer modellere göre daha fazla bellek gerektirir, bu da yüksek boyutlu görüntülerle çalışırken bir dezavantaj olabilir.
- Eğitim için daha fazla zaman gerektirebilir. Bu durum modelin ölçeklendirilmesi ve kullanımı için bir dezavantaj olabilir.
- Küçük nesnelere algılama ve segmentasyon konusunda diğer modellere göre daha az başarılıdır. Bu durum modelin bazı uygulamalarda daha az kullanışlı hale getirebilir.

şeklinde açıklanmaktadır (He et al. 2017).

2.4 Donanım ve Yazılım

Çalışmada ArcGIS Pro programının 2.7.0 sürümü kullanılarak eğitim verileri oluşturulmuş ve yine bu program kullanılarak eğitim işlemleri yapılmıştır. ArcGIS Pro programını derin öğrenme çalışmalarında etkin bir şekilde kullanabilmek için programın sürümüne uygun olan derin öğrenme kütüphaneleri yüklenmiştir (Şahin 2021).

Eğitimde ekran kartının kullanılıp daha hızlı bir şekilde yapılabilmesi yüklenen kütüphanelere uygun olarak CUDA 10.1 ve CUDNN 7.6 eklentileri

yüklenmiştir (İnt. Kyn. 2). Kullanıma hazır hale gelen programda görüntüler için önce etiketleme işlemi yapılmıştır. Bunun için programda Classification araçları altında Training Sample Manager aracı kullanılmıştır.

Etiketlenen veriler Geoprocessing araçlarında Image Analyst Toolbox altında bulunan Deep Learning araç setleri kullanılarak eğitime hazır hale getirilip eğitilmiştir. Eğitime hazır hale getirmek için önce Export Training Data For Deep Learning görüntü analisti kullanılıp eğitimde kullanılacak modele uygun olarak görüntüler düzenlenmiştir.

Eğitime hazır hale getirilmiş görüntü Train Deep Learning Model görüntü analisti kullanılarak eğitim gerçekleştirilmiştir. Eğitilmiş model Detect Objects Using Deep Learning görüntü analisti kullanılarak test edilmiştir.

3. Kaynak Araştırması

Robertson vd. (2019), doğal afet zamanında paylaşılan sosyal medya görüntülerinden acil durum verisi içerenleri sınıflandırmaya çalışmıştır. Bunun için 2017'deki Harvey Kasırgası sırasında paylaşılan Twitter görüntülerini VGG-16 evrişimsel modeli ile eğitip, test etmişlerdir. Sınıflandırma çalışması bu alanda öncü bir çalışma olmakla beraber istenilen sonuca ulaşamamıştır.

Zhai ve Peng (2004), Michael Kasırgası sonrası Google Street View ile elde edilen görüntülerle hasarlı alanların tespitini yapmaya çalışmıştır. Bunun için Amerika Birleşik Devletleri'nin Florida eyaleti Mexico Beach bölgesindeki Google Street View verilerini kullanarak VGG-19 evrişimsel modeli ile sokak seviyesinde görüntülerle %70 doğruluk oranı ile hasarlı yapıları tespit etmiştir. Sonucu uzaktan algılama verileri ile yapılan çalışmalarla kıyaslayarak kapı, pencere ve dış duvar hasarının sokak görüntülerinde değerlendirmeye alınabilmesinden dolayı daha avantajlı ve iyi sonuçlar verdiği ifade edilmiştir.

Khosravi vd. (2020), çalışmalarında evrişimsel sinir ağları algoritmasını kullanarak bir sel duyarlılık haritası oluşturmayı amaçlamışlardır. Söz konusu çalışma için İran ülkesi haritası kullanılmış olup, ülke genelinde daha önceki 2769 sel verisi toplanmıştır. Toplanan bu eğim, yükseklik, bakı, yağış, jeoloji,

arazi kullanımı, yollardan uzaklık ve benzeri veriler taşkın haritası yapımı için evrişimsel sinir ağı algoritmasıyla işlenmiş ve oluşturulan modelin doğruluğu test edilmiştir. Çalışmada evrişimsel sinir ağları mimarisi ile oluşturulan taşkın duyarlılık haritasının %75'lik kabul edilebilir bir doğruluğa sahip olduğu sonucuna varılmıştır.

Cheng vd. (2021), çalışmalarında insansız hava aracı (İHA) görüntülerini kullanarak derin öğrenme tabanlı bir heyelan afeti sonrası oluşan çatlakları tanıma modelini oluşturmayı ve olası bir heyelan tespiti yapmayı amaçlamaktadırlar. Çalışmada Çin'in Guizhou kentinde 10 Haziran 2018 tarihinde meydana gelen bir heyelan vakası ele alınmış, otomatik bir heyelan çatlak tanıma modeli oluşturmak için bir derin öğrenme mimarisi olan RetinaNET mimarisi temel alınarak geliştirdikleri model kullanılmıştır. Söz konusu çalışmada veri seti olarak insansız hava aracı görüntüleri ve uydu görüntüleri kullanılarak oluşturdukları modelle eğitilmiş ve %73 doğrulukla test sonuçlarına ulaşılmıştır.

Yeum vd. (2018), çalışmalarında geçmiş yıllarda yaşanan bazı büyük doğal afetler (deprem, kasırga ve benzeri) sonrası çekilmiş yaklaşık 90 bin yer seviyesindeki görüntüyü evrişimsel bir model olan Alexnet modelini kullanarak, görüntülerin otomatik olarak sınıflandırılmasının ne şekilde yapılabileceğini adım adım göstermiş olup, söz konusu çalışmada toplanan görüntülerden çöken binaları ve bina bileşenlerini (kolon ve benzeri) %86'dan fazla doğrulukla başarılı bir şekilde tespit etmiş ve sınıflandırmışlardır.

Bragagnolo vd. (2021), çalışmalarında heyelan sonrası yeryüzünde meydana gelen değişimleri tespit ederek dinamik olarak heyelan izlerinin takibini yapabilmeye çalışmışlardır. Bu amaç doğrultusunda bölütleme çalışmalarında kullanılan U-Net modelini eğitebilmek için gerekli olan heyelan veri setini Nepal'in bir bölgesinden Landsat-8 uydusu ile elde edilmiş 230 tane uydu görüntüsü ile oluşturulmuştur. Doğrulama için 35, test için 10 uydu görüntüsü daha kullanılmıştır. Eğitim sonucunda test edilen veriler %81 ile %93 arası değişen doğrulukta sonuçlar vermiş ve aynı çalışma bölgesinde konuyla alakalı daha önce yapılmış

araştırmalara oranla daha iyi bir sonuç elde edilmiştir.

Gupta vd. (2021), yapmış oldukları çalışmalarda Endonezya'nın Palu kentinde yaşanan tsunami felaketinde, hasar almış alanları ve erişim sağlanabilecek yolları belirleyebilmek için uydu görüntüleri ile farklı bölütleme modelleri kullanarak araştırmaya çalışmışlardır. Özellikle kentte bulunan yol ağının sağlıklı bir şekilde tahminini elde edebilmek adına OpenStreetMap (OSM)'de bulunan bilgilerden yararlanmaya çalışmışlardır. Yapılan karşılaştırmalarda VGG16'nın özellik çıkarmada diğerlerinden daha iyi sonuç verdiği görülmüştür. Ayrıca çalışmada ENetSeparable adını verdikleri bir model önermişlerdir. Önerilen model ile yapılan bölütleme işleminde %90'dan yüksek sonuçlar elde edebilmişlerdir.

Moradi ve Shah-Hosseini (2020), Haiti'nin VHR uydu görüntüleri ve evrişim ağı olan UNet üzerinde çalışmalar gerçekleştirmiştir. Ayrıca literatürdeki önceki çalışmalardan farklı olarak piksel bozulmasını inceleyerek, nihai hassasiyeti artıran bir yaklaşım geliştirerek genel olarak %68,71'lik doğruluğa ulaşmıştır.

Corbane vd. (2011) gerçekleştirdiği çalışmada, Haiti'de 2010 yılında meydana gelen depremle ilgili olarak kullanılan 0,15 m mekansal çözünürlüklü görüntüler kullanılarak tespit edilen hasarlı yapıların, geçici saha araştırmaları sırasında elde edilen GPS coğrafi etiketli verilerle karşılaştırıldığında yaklaşık %65 doğrulukla belirlenmiştir. Benzer bir genel doğruluk değeri de Ajmar vd. (2011), tarafından (%70) gerçekleştirilen çalışmalarla elde edilmiştir.

Boccardo ve Giulio Tonolo (2012) gerçekleştirdiği çalışmada, hasar derecelerini değerlendirmek için girdi verisi olarak kullanılan raster görüntülerin mekansal çözünürlüklerini karşılaştırarak, 0,15 m çözünürlüklü görüntülerden belirlenen hasar bilgilerinin 0,5 m çözünürlüklü uydu verilerinden belirlenen hasar bilgilerine kıyasla % 85 daha doğru olduğunu ortaya koymuştur.

4. Bulgular

Çalışmada Birleşmiş Milletlerin deprem sonrası insansız hava araçları ile elde ettiği görüntüler

kullanılmıştır. Görüntüler sabit kanatlı Swinglet CAM Sensefly İHA ile elde edilmiştir.

Sensefly Swinglet CAM, küçük bir insansız hava aracı (UAV) olarak tasarlanmıştır ve yüksek çözünürlüklü görüntüleme ve haritalama uygulamaları için kullanılmaktadır. Sensefly Swinglet CAM; 0,5 kg ağırlığındadır ve kanat açıklığı 0,72 metre, uzunluğu 0,5 metre olan bir delta kanatlı tasarıma sahiptir. Tam şarjlı bataryalarla yaklaşık 30 dakika uçuş süresi sağlar. Yüksek çözünürlüklü kamerası sayesinde 12 megapiksel fotoğraflar ve 720p video kaydedebilir. Swinglet CAM, bir radyo kontrol cihazı veya otomatik bir uçuş kontrol sistemi kullanılarak uzaktan kontrol edilebilir. Otomatik uçuş sistemi, programlanabilir bir rota takip sistemi, sabit bir uçuş yüksekliği ve hava koşullarına uygun bir stabilizasyon sistemine sahiptir. İHA üzerine monte edilen Canon IXUS 125 HS model kamera ile yüksek çözünürlüklü görüntüler elde edebilmektedir (İnt. Kyn. 3).

Çalışmada kullanılan İHA görüntüleri, Birleşmiş Milletler Eğitim ve Araştırma Enstitüsü tarafından paylaşılan 8 Şubat 2012'de Port-au-Prince'in Cité Soleil ve Gran Ravine bölgelerinden toplanmış sırasıyla 5 cm ve 7 cm konumsal çözünürlüğe sahiptir.


Cité Soleil bölgesine ait görüntü test çalışmaları için, Gran Ravine bölgesine ait görüntü ise eğitim çalışmaları için kullanılmıştır. Şekil-2'de test için kullanılan insansız hava aracı görüntüsüne, Şekil-3'te ise eğitim çalışmalarında kullanılan görüntüye örnekleri verilmiştir.



Şekil 2. Test için kullanılan Cité Soleil Bölgesine Ait Bir Görüntü



Şekil 3. Eğitim İçin Kullanılan Gran Ravine Bölgesine Ait Bir Görüntü



Şekil 4. İnsansız Hava Aracı Görüntüsünde Etiketleme Çalışmasının Yapıldığı Sahanın Tamamı

İnsansız hava aracı ile eğitim için yapılar üç sınıf hasarlı, hasarsız ve az hasarlı olarak sınıflandırılıp etiketlenmiştir. İnsansız hava aracı görüntüsü ile eğitim için 3829 hasarsız, 962 az hasarlı, 545 hasarlı yapı sınıflandırılıp etiketlenmiştir. Test için etiketlenmiş yapılar önce üç sınıfta test edilmiş daha sonra daha sonra az hasarlı olarak etiketlenmiş yapılar çıkarılarak test işlemi tekrar edilmiştir. İnsansız hava aracı görüntülerinden elde edilen eğitim ve test verilerinin dağılımı ve birbirlerine oranları Çizelge-1.'de gösterilmiştir.

Çizelge 1. İnsansız Hava Aracı Görüntülerinde Test ve Eğitim Verilerinin Dağılımı ve Birbirlerine Oranı

	Eğitim	Üç Sınıflı Test Verileri	Test / Eğitim (Üç Sınıf İçin)	İki Sınıflı Test Verileri	Test / Eğitim (İki Sınıf İçin)
Hasarlı	545	13	%0.02	13	%0.02
Hasarsız	3829	97	%0.03	97	%0.03
Az Hasarlı	962	35	%0.04	-	-

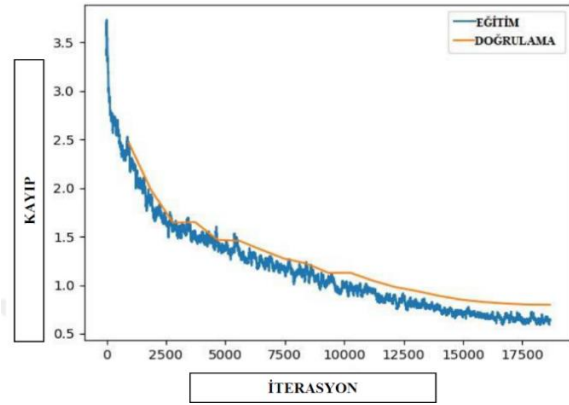
İnsansız hava araçları verilerinde altlık olarak kullanılacak harici olarak hazırlanmış yapı hasar tespiti olmadığından saha tek tek gözlemlenip değerlendirilerek etiketlenmiştir. Görüntülerin yüksek çözünürlüklü 7 cm konumsal çözünürlüğe sahip olması bunu mümkün kılmıştır. Etiket sınıfı üç sınıf olarak hasarlı, az hasarlı ve hasarsız şeklinde belirlenmiştir. Eğitim sahasının tamamına yakını etiketlenmeye çalışılmış sonuç olarak Şekil-4'de gösterildiği gibi 3829 yapı hasarsız, 962 yapı az hasarlı, 545 yapı hasarlı olarak tespit edilmiştir.

Etiketleme işlemi tamamlandıktan sonra her bir eğitim görüntüsü nesne tespiti için kullanacağımız model olan Mask R-CNN modeline uygun olarak dönüştürülerek eğitime hazır hale getirilmiştir. İnsansız hava aracı verileri önce üç sınıfta (hasarlı, az hasarlı ve hasarsız) eğitilmiş daha sonra az hasarlı veriler çıkarılarak sadece hasarlı ve hasarsız verilerle eğitilmiştir. Eğitim işleminde ImageNET ile eğitilmiş ResNet-101 ağından transfer öğrenimi gerçekleştirilmiştir. İnsansız hava aracıyla üç sınıfta yapılan eğitimin eğitim parametreleri Çizelge-2'de gösterilmiştir.

Çizelge 2. Üç Sınıfla Eğitilmiş Mask R-CNN Modelinin Eğitim Parametreleri

Eğitim Parametresi Türü	Parametre Değeri
Model	Mask R-CNN
Maksimum Epok	20
Mini Batch Boyutu	2
Çalıştırma Ortamı	GPU - NVIDIA GeForce GTX 1660 Ti 6GB GDDR6
Learning Rate	0.000075858 – 0.000075858
Chip size	256
Transfer Öğrenimi	ResNet-101
Doğrulama Verisi Oranı	%10
Eğitim Süresi	~5 Saat

Eğitim sonucunda hasarlı yapılar için %72.82, hasarsız yapılar için %78.47, az hasarlı yapılar için %61.93 ortalama doğruluk değeri elde edilmiştir. Eğitim boyunca oluşan kayıp fonksiyonun grafiği Şekil-5'de gösterilmiştir.



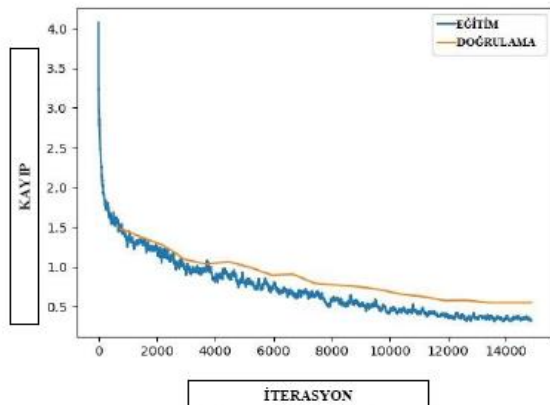
Şekil 5. Üç Sınıflı Yapılan Eğitimin Kayıp Fonksiyonunun Grafiği

İnsansız hava aracıyla yapılan üç sınıflandırmadan sonra az hasarlı yapılar çıkarılarak hasarlı ve hasarsız yapı verileri ile iki sınıflı olarak eğitim tekrarlanmıştır. İki sınıflı verilerle yapılan eğitimin eğitim parametreleri Çizelge-3'de verilmiştir.

Çizelge 3. İki Sınıflı Eğitilmiş Mask R-CNN Modelinin Eğitim Parametreleri

Eğitim Parametresi Türü	Parametre Değeri
Model	Mask R-CNN
Maksimum Epok	20
Mini Batch Boyutu	2
Çalıştırma Ortamı	GPU - NVIDIA GeForce GTX 1660 Ti 6GB GDDR6
Learning Rate	0.0000063096 – 0.000063096
Chip size	256
Transfer Öğrenimi	ResNet-101
Doğrulama Verisi Oranı	%10
Eğitim Süresi	~ 5 Saat

İki sınıflı insansız hava aracı görüntülerinin eğitimi sonucunda hasarlı yapılar için %76.11, hasarsız yapılar için %69.47 ortalama doğruluk değeri elde edilmiştir. Eğitim boyunca oluşan kayıp fonksiyonunun grafiği Şekil-6'da gösterilmiştir.



Şekil 6. İki Sınıflı Yapılan Eğitimin Kayıp Fonksiyonunun Grafiği

Şekil-6.'da verilen kayıp fonksiyonunun grafiğinde yaklaşık 14000 iterasyondan sonra eğitim verilerinin hata değerleri toplamı 0.5'in altına düşerken doğrulama verilerinin hata değerleri toplamı 0.5'e yaklaşmıştır.

Gerçekleştirilen çalışmada iterasyon sayısı, eğitim verilerinin boyutuna, modelin karmaşıklığına ve parametrelerine bağlı olarak belirlenmiştir. Daha büyük bir eğitim veri seti genellikle daha uzun bir eğitim süresi gerektirirken, daha karmaşık bir model daha fazla iterasyon gerektirebilir.

Özellikle iki sınıflı yapılan eğitimde kayıp fonksiyonunu 0,5 değerinin altına düşürülmesi amaçlanmıştır. Ayrıca, eğitim süresi boyunca modelin doğruluğu ve kaybı takip edilerek, iterasyon sayısı bu ölçümlere dayanarak belirlenmiştir.

Sınıflandırma problemlerinde, bir modelin performansı genellikle doğruluk (accuracy) ölçütü ile değerlendirilir. Dolayısıyla, kayıp fonksiyonunun 0,5'in altında olması, modelin doğru tahmin etme olasılığının %50'den daha yüksek olduğunu ve dolayısıyla doğruluk oranının %50'den daha yüksek olacağını gösterir. Bu değer iterasyon sayısı artırılarak yükseltilebilir ancak, iterasyon sayısının çok yüksek olması aşırı uyuma (overfitting) riskini oluşturacağı hususu dikkate alınarak, iterasyon sayısı eğitim süreci boyunca verimliliği ve doğruluğu en üst düzeye çıkarmak için optimize edilmiştir.

5. Test İşlemlerinin Gerçekleştirilmesi

İnsansız hava araçları görüntülerinde ise daha önce eğitim ve doğrulama için kullanılmamış farklı bir alandan alınmış görüntü kullanılarak test işlemi gerçekleştirilmiştir. Test işleminde sınıflandırma doğruluğu karmaşıklık matrisi üzerinden gerçekleştirilmiştir. Karmaşıklık matrisi Çizelge-4'de gösterilmiştir.

Çizelge 4. Karmaşıklık matrisi

	Gerçekte Hasar Var	Gerçekte Hasar Yok
Tahmin Hasar Var	True Positive (TP)	False Positive (FP)
Tahmin Hasar Yok	False Negative (FN)	True Negative (TN)

Karmaşıklık matrisi oluşturulduktan doğruluk oranı denklem (1)'deki gibi, precision oranı denklem

(2)'deki gibi, recall oranı denklem (3)'teki gibi ve F1 skoru denklem (4)'teki gibi hesaplanmıştır. Doğruluk, doğru yapılan tahminlerin tüm veriye oranını vermektedir.

Bunun dışında yanlış yapılan tahminlerinde hesaba katıldığı precision ve recall modelin değerlendirmesi için kullanılabilir. F1 skoru precision ve recall değerlerinin harmonik ortalaması alınarak hesaplanmaktadır (Metlek ve Kayaalp 2020).


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

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{F1 Skoru} = 2x \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$


İnsansız hava aracı verileri üç sınıfa ve iki sınıfa ayrılarak test edilmiştir. Üç sınıflı toplam 145 etiket oluşturulmuştur. Test işlemi Şekil-7'de gösterilen mavi çerçeveli alan için yapılmıştır.



Şekil 7. Üçlü Sınıflandırmada Kullanılan Test Alanı ve Etiketleri

Test işlemi sonucunda 58 hasarsız, 11 hasarlı, 18 az hasarlı yapı bulunmuştur. Bulunan yapılar Şekil 6'da gösterilmiştir. Tespit edilen 87 yapıdan 85'i etiket

verisi ile kesişmektedir. Etiketli yapıların tespiti %58.62 oranında olmuştur. Test işlemi sonuçları Şekil-8'de sunulmuştur.




Şekil 8. Üçlü Sınıflarla Yapılan Test İşlemi Sonucu Tespit Edilen Yapılar

Bulunan yapılar etiketli verilerle karşılaştırıldığında hasarlı olarak tahmin edilen 9 yapıdan 5'inin doğru 4'ünün yanlış tahmin edildiği, hasarsız olarak tahmin edilen 58 yapıdan 48'inin doğru 10'unun yanlış tahmin edildiği, az hasarlı olarak 18 yapının bulunduğu bunların 11'inin doğru 7'sinin yanlış olarak tahmin edildiği görülmektedir. Doğruluk değerleri Çizelge-5'de verilmiştir. Tablo incelendiğinde genel doğruluk değerinin %83.53 olduğu görülmüştür.

Çizelge 5. Üçlü Sınıflarla Yapılan Test İşleminin Doğruluk Değerleri


	Doğruluk	Precision	Recall	F1 Skoru
Hasarlı	0.9176	0.5556	0.6250	0.5883
Hasarsız	0.8235	0.8276	0.9057	0.8649
Az Hasarlı	0.7647	0.6111	0.4583	0.5238

Üç sınıfla yapılan test işleminden sonra aynı alan içerisindeki az hasarlı yapılar çıkarılıp hasarlı ve hasarsız şeklinde iki sınıf üzerinden test işlemi tekrarlanmıştır. İkili sınıf ile yapılan test işleminde kullanılan toplam 110 hasarlı ve hasarsız yapı Şekil-9'da mavi çerçeveli alan içerisinde gösterilmiştir. Test işlemi sonucunda 95 hasarsız, 56 hasarlı yapı bulunmuştur.



Şekil 9. İkili Sınıflandırmada Kullanılan Test Alanı ve Etiketleri

Test işlemi sonucunda 95 hasarsız, 56 hasarlı yapı bulunmuştur. Bulunan yapılar Şekil-10'da gösterilmiştir.



Şekil 10. İkili Sınıflarla Yapılan Test İşlemi Sonucu Tespit Edilen Yapılar

Tespit edilen yapılar incelendiğinde eğitime dâhil edilmemiş yapıların ve test alanına düşen zeminden moloz temizliği yapılmış çökmüş bina izlerinin de algılandığı anlaşılmaktadır. Tespit edilen yapılarla etiket verilerinin kesiştiği 82 yapı görülmektedir. Etiketli yapıların tespiti %74.55 oranında olmuştur. Bulunan yapılar etiketli verilerle karşılaştırıldığında hasarlı olarak tahmin edilen 15 yapının 11'i doğru 4'ünün yanlış tahmin edildiği, hasarsız olarak tahmin edilen 67 yapının tamamının doğru tahmin edildiği görülmektedir. Test işleminin doğruluk değerleri Çizelge-6'da verilmiştir.

Çizelge 6. İkili Sınıflarla Yapılan Test İşleminin Doğruluk Değerleri

	Doğruluk	Precision	Recall	F1 Skoru
Hasarlı	0.9512	0.73333	1.0000	0.8461
Hasarsız	0.9512	1.0000	0.9437	0.9710

Tablo incelendiğinde genel doğruluk değerinin %95.12 olduğu görülmüştür. Hasarlı tahmin edilen 15 yapıdan 11'inin doğru tahmin edilmesinden hasarlı yapıların precision değeri %73.33 olduğu görülmüştür. Hasarlı yapıların recall değeri gerçekte hasarlı olan yapıların tamamı bulunmasından dolayı %100 olmuştur.

6. Tartışma ve Sonuç

Deprem gibi doğal afetler sonucunda hasarlı yapılar oluşmaktadır. Afetin etkilerini hızlı ve doğru bir şekilde tespit etmek normal yaşama dönüşü hızlandırmak ve muhtemel can kayıplarının en aza indirgenmesi için önemli bir faktördür. Bu sebeple afet sonrası afet alanına bütüncül bir yaklaşımla değerlendirme olanağı sunan uzaktan algılama verilerini kullanmak etkili bir çözüm olmaktadır.

Olaydan sonraki ilk saatlerde/günlerde mevcut olan tek veri kaynağı uydu görüntüleridir. İHA görüntüleri ise olaydan birkaç gün sonra elde edilebilirken, saha bilgileri (doğrulama amacıyla kullanılan yer gerçeği verileri) genellikle birkaç hafta sonra, genellikle afet sonrası ihtiyaç değerlendirmesi aşamasında elde edilir. Ancak yüksek çözünürlüklü kameralar ve sensörler ile donatılmış İHA'lar, hasarlı bina ve altyapıların doğru ve ayrıntılı görüntülerini sağlayarak deprem hasar tespitinde önemli bir rol oynamaktadır. İHA'lardan toplanan veriler, yetkililerin müdahale çabalarına öncelik vermelerine ve kaynakları daha verimli bir şekilde tahsis etmelerine yardımcı olabilecektir.

Derin öğrenme makine öğrenmesinin bir alt dalı olarak gizli katman sayısını fazla olmasının avantajını kullanarak uydu verileri gibi düzenli ve çok sayıda elde edilen verilerin insandan bağımsız bir şekilde değerlendirilebilmesi için etkili sonuçlar üretmektedir.

Elde edilen sonuçlar, literatür taramasında uydu görüntüleri kullanılarak gerçekleştirilen çalışmalarla karşılaştırıldığında, konumsal çözünürlük arttıkça yapıların tespiti ve sınıflandırma başarısının arttığı tespit edilmiştir. Doğrulama konularına odaklanan birkaç araştırmanın sonuçları, %60 ila %70 aralığında genel doğruluk değerleri bildirmektedir.

Bu çalışmada insansız hava aracı verileri iki aşamada ele alınmıştır. İlk aşamada hasarlı, az hasarlı ve hasarsız şeklinde üç sınıfta incelenmiştir. İnsansız hava aracı verileri ile yapılan test işleminde ise yapılar %58.62 oranıyla bulunmuş ve bulunan yapılar %83.53 genel doğrulukla sınıflandırılmıştır. Çalışmanın ikinci aşamasında veriler hasarlı ve hasarsız şekillinde etiketlenmiş ilk aşamayla aynı test sahası kullanılarak test işlemleri yapılmıştır. İnsansız hava aracı verilerindeki yapılar %74.50 oranıyla bulunmuş ve bulunan yapılar %95.12 genel doğruluk oranıyla sınıflandırılmıştır.

Gelişen teknolojilerle birlikte insansız hava araçlarından alınan görüntülerin konumsal çözünürlüğünün artması sayesinde afet sonrası yapılarda meydana gelen hasarın tespit edilmesinde Mask R-CNN gibi derin öğrenme modellerinin kullanılabilirliği anlaşılmaktadır.

Özellikle afet yaşanma riski yüksek olan bölgeler için afet sonrasında hasarlı yapıların hızlı ve yüksek doğrulukta belirlenmesi için görüntü alımı, eğitim setlerinin hazırlanması ve en uygun derin öğrenme algoritmalarının kullanılmasına yönelik çalışmaların yapılmasının faydalı olacağı değerlendirilmektedir.

7. Kaynaklar

Albawi, S., Mohammed, T. A. and Al-Zawi, S., 2018. Understanding of a convolutional neural network. Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017, 1–6.

Bhangale, U., Durbha, S., Potnis, A. and Shinde, R., 2019. Rapid Earthquake Damage Detection Using Deep Learning from VHR Remote Sensing Images. International Geoscience and Remote Sensing Symposium (IGARSS), 2654–2657.

Boccardo, P., ve Giulio T. F., 2012. Haiti earthquake damage assessment: review of the remote sensing role. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **39**, 529-532.

Bragagnolo, L., da Silva, R. V. ve Grzybowski, J. M. V., 2021. Amazon forest cover change mapping based on semantic segmentation by U-Nets. *Ecological Informatics*, **62**, 101279.

Cheng, Z., Gong, W., Tang, H., Juang, C. H., Deng, Q., Chen, J. and Ye, X., 2021. UAV photogrammetry-based remote sensing and preliminary assessment of the behavior of a landslide in Guizhou, China. *Engineering Geology*, **289**, 106172.

Corbane, C., Carrion, D., Lemoine, G., Broglia, M., 2011. Comparison of damage assessment maps derived from very high spatial resolution satellite and aerial imagery produced for the haiti 2010 earthquake. *Earthquake Spectra*, **27**, 199-218.

Gupta, A., Watson, S. ve Yin, H., 2021. Deep learning-based aerial image segmentation with open data for disaster impact assessment. *Neurocomputing*, **439**, 22–33.

He, K., Gkioxari, G., Dollár, P. ve Girshick, R., 2017. Mask R-CNN, IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2980-2988.

İnik, Ö. ve Ülker, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Journal of Scientific Research*, **6(3)**, 85–104.

Kayaalp, K. ve Süzen, A. A., 2018. Derin Öğrenme Ve Türkiye'deki Uygulamaları. ISBN 978-605-7510-53-2, İksad Publishing House, 44-52.

Khosravi, K., Panahi, M., Golkarian, A., Keesstra, S. D., Saco, P. M., Bui, D. T. and Lee, S., 2020. Convolutional neural network approach for spatial prediction of flood hazard at national scale of Iran. *Journal of Hydrology*, **591**, 125552.

LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *Nature*, **521(7553)**, 436–444.

Metlek, S. ve Kayaalp, K., 2020. Derin Öğrenme ve Destek Vektör Makineleri İle Görüntüden Cinsiyet Tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, **8(3)**, 2208–2228.

Moradi, M., ve Shah-Hosseini, R., 2020. Earthquake damage assessment based on deep learning change detection method using VHR images. IECG-2020 Conference Proceedings Paper, 8545.

Neven, D., De Brabandere, B., Proesmans, M., ve Van Gool, L., 2019. Instance segmentation by jointly optimizing spatial embeddings and clustering

bandwidth, 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 8837-8845.

Nex, F., Duarte, D., Tonolo, F. G. and Kerle, N., 2019. Structural Building Damage Detection with Deep Learning: Assessment of a State-of-the-Art CNN in Operational Conditions. *Remote Sensing*, **11(23)**, 2765.

Nie, Y., Takaki, T., Ishii, I. ve Matsuda, H.,2011. Behavior recognition in laboratory mice using HFR video analysis. Proceedings - IEEE International Conference on Robotics and Automation, 1595–1600.

Robertson, B. W., Johnson, M., Murthy, D., Smith, W. R. and Stephens, K. K., 2019. Using a combination of human insights and ‘deep learning’ for real-time disaster communication. *Progress in Disaster Science*, **2**, 100030.

Şahin, N., 2009. Afet Yönetimi ve Acil Yardım Planları. TMMOB İzmir Kent Sempozyumu, 131–142.

Yeum, C. M., Dyke, S. J. ve Ramirez, J., 2018. Visual data classification in post-event building reconnaissance. *Engineering Structures*, **155**, 16–24.

Zhai, W. ve Peng, Z. R., 2020. Damage assessment using Google Street View: Evidence from Hurricane Michael in Mexico Beach, Florida. *Applied Geography*, **123**, 102252.

İnternet kaynakları

1-<https://www.xenonstack.com/blog/data-science/log-analytics-deep-machine-learning-ai> (02.09.2022)

2-<https://developer.nvidia.com/cuda-toolkit-archive> (07.09.2022)

3-<https://unitar.org/maps/map/1639> (31.08.2022)