




## Geomatik

<https://dergipark.org.tr/tr/pub/geomatik>

e-ISSN 2564-6761



# Derin öğrenme uygulamalarında kullanılan uzaktan algılama verilerinden oluşturulmuş açık kaynaklı bina veri setleri: Karşılaştırmalı değerlendirme

Esra Özaydın<sup>1,2</sup>, Burcu Amirgan<sup>\*1</sup>, Gülşen Taşkın<sup>3</sup>, Nebiye Musaoğlu<sup>1,2</sup>

<sup>1</sup> İstanbul Teknik Üniversitesi, Uydu Haberleşme ve Uzaktan Algılama UYG-AR Merkezi, İstanbul, Türkiye, [esra@cscrs.itu.edu.tr](mailto:esra@cscrs.itu.edu.tr); [burcu.amirgan@cscrs.itu.edu.tr](mailto:burcu.amirgan@cscrs.itu.edu.tr)

<sup>2</sup> İstanbul Teknik Üniversitesi, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, İstanbul, Türkiye, [musaoglune@itu.edu.tr](mailto:musaoglune@itu.edu.tr)

<sup>3</sup> İstanbul Teknik Üniversitesi, Deprem Mühendisliği ve Afet Yönetimi Enstitüsü, İstanbul, Türkiye, [gulsen.taskin@itu.edu.tr](mailto:gulsen.taskin@itu.edu.tr)

Kaynak Göster: Özaydın, E., Amirgan, B., Taşkın, G., & Musaoğlu, N. (2024). Derin öğrenme uygulamalarında kullanılan uzaktan algılama verilerinden oluşturulmuş açık kaynaklı bina veri setleri: Karşılaştırmalı değerlendirme. *Geomatik*, 9 (1), 1-11

<https://doi.org/10.29128/geomatik.1257555>

### Anahtar Kelimeler

Bina Çıkarımı  
Bina Veri Setleri  
Derin Öğrenme  
Uzaktan Algılama

### Derleme Makale

Geliş: 28.02.2023  
Revize: 17.04.2023  
Kabul: 16.05.2023  
Yayınlanma: 05.02.2024



### Öz

Bina çıkarımı; arazi kullanımı, şehir planlaması, afet izleme, navigasyon, coğrafi veri tabanlarının güncellenmesi ve kentsel dinamik izleme gibi çeşitli mekânsal uygulamalarda önemli rol oynar. Farklı bölgelerdeki binalar farklı yapısal ve geometrik özelliklere sahip olduğundan görüntülerden otomatik bina çıkarımı zor bir iştir. Son yıllarda uygun veri setleriyle eğitildiklerinde klasik makine öğrenme yöntemlerine göre daha yüksek doğruluklu sonuçlar üreten derin öğrenme modelleri, otomatik bina çıkarımında sıkça kullanılmaktadır. Modellerin yüksek doğrulukta eğitilmesi için kaliteli etiketlerin olduğu bina veri setleri büyük önem taşımaktadır. Bu çalışmanın amacı, bina tespiti için farklı çözünürlükteki uzaktan algılama görüntülerinden oluşturulmuş ve literatürde sıkça kullanılan açık kaynaklı bina veri setlerini tanıtmaktır. Veri setleri, kaydedildiği platformlara göre havadan, uydudan ve her iki platformdan kaydedilmiş görüntülerden oluşan veriler olarak üç kategoride gruplandırılıp, detayları açıklanmıştır. Bunun yanı sıra veri setleri ile yapılmış karşılaştırmalı çalışmaları içeren güncel literatür özeti verilmiştir. Bina tespiti işlemini doğru şekilde gerçekleştirmek için araştırmacılara rehberlik edecek ve bina veri seti oluşturulmasında dikkat edilmesi gereken kritik hususları içeren değerlendirmeler sunulmuştur.

## Open-source building dataset created from remote sensing data in deep learning applications: Comparative evaluation

### Keywords

Building Extraction  
Building Dataset  
Deep Learning  
Remote Sensing

### Review Article

Received: 28.02.2023  
Revised: 17.04.2023  
Accepted: 16.05.2023  
Published: 05.02.2024

### Abstract

Building extraction plays a significant role in various geospatial applications such as land use, urban planning, disaster management, navigation, updating geodatabases, and urban dynamic monitoring. Since buildings in different regions have different structural and geometrical properties, building extraction from remote sensing data is a challenging task. In recent years, deep learning models, when trained with proper datasets, are commonly used in building extraction because they achieve better results than traditional machine learning models. The quality of the labeling for the building datasets is an important parameter that affects the performance of the deep learning model. Our aim is to introduce frequently used, open-source building datasets, created from remote sensing images with different resolutions for building detection. The datasets are grouped into three categories according to the platforms on which they are acquired (aerial, satellite, and both platforms), and their details are explained. Moreover, this study provides a summary of the current literature, including comparative studies utilizing these datasets. The objective of this study is to help researchers to accurately perform the building detection process, while emphasizing critical issues to consider during the building dataset creation.

## 1. Giriş

Uzaktan algılama teknolojisi ve görüntü işleme yöntemlerindeki gelişmeler, binaların ya da diğer objelerin görüntülerden otomatik olarak çıkartılmasını önemli ölçüde kolaylaştırmıştır. Uzaktan algılama yöntemleri ile elde edilen görüntülerden bina çıkarımı, coğrafi veri tabanı güncellenmesi, değişim tespiti, nüfus yoğunluğu tahmini, arazi kullanımı yönetimi, şehir planlaması ve afet yönetimi gibi birçok uygulamada hayati bir rol oynar. 06 Şubat 2023 tarihinde ülkemizde yaşanan Kahramanmaraş Depremleri de uzaktan algılama verilerinin özellikle depremden sonra hızlı bilgi çıkarmada ne kadar önemli olduğunu göstermiştir. Ancak hava koşulları, görüntüye erişim sorunları, çatı tiplerinin farklı olması, algılama geometrilerindeki ve çözünürlük özelliklerindeki farklılıklar görüntülerden bilgi çıkartılmasını kısıtlamaktadır. Depremler sonrasında yeryüzünde oluşan deformasyonların farklı bölgelerde farklı büyüklüklerde oluşması da deprem öncesi/sonrası raster ve vektör verilerin çakıştırılarak analizini zorlaştırmıştır (URL-1). Bu nedenle özellikle tek bir görüntüden bilgi çıkartılmasının önemi daha da artmıştır.

Günümüzde çok yüksek mekânsal çözünürlüklü uydu görüntülerinin sağladığı zengin detay, makine öğrenmesi ve derin öğrenme yöntemlerinin hızlı ve doğru bilgi üretme özellikleri ile birleşince görüntüdeki nesnelere kısa sürede belirlenmesi olanaklı hale gelmiştir. Yapay sinir ağları birçok uygulamada uzun yıllardan beri kullanılırken (Karhunen ve ark., 2015) 2006 yılında yapay sinir ağlarına bağlı olarak geliştirilen ve “yapay sinir ağlarının yeniden doğuşu” ya da “yeni jenerasyon sinir ağları” olarak adlandırılan derin öğrenme kavramı uygulama sonuçlarındaki başarıyı önemli ölçüde arttırmıştır (Hinton ve ark., 2006; Sarker, 2021). Derin öğrenme yöntemlerinin hızlı gelişimi ve yeni ağ tasarımları, büyük boyutlu veriden kısa sürede ve yüksek doğruluklu sonuçlar üretilmesine olanak sağlamaktadır (Ps ve Aithal, 2022).

Derin öğrenme yöntemlerinin hedeflenen nesneyi görüntü üzerinden bulmasında en önemli aşama, doğru etiketlenmiş yüksek kalitede ve çok sayıda veri seti ile ağın eğitilmesidir. Bu amaçla, görüntülerden ayırt edilmek istenen hedefler için, farklı özellikte veri setleri oluşturulmaktadır. Gemi, yol, uçak ve binaların otomatik tespiti için çok yüksek çözünürlüklü optik ya da yapay açıklıklı radar görüntülerinden oluşturulmuş veri setleri ve bu veri setleri kullanılarak otomatik nesne tespitinin yapıldığı çalışmalar bulunmaktadır. Örneğin, Patel ve ark., (2022)’de, gemi tespiti için iki farklı veri seti (Airbus Gemi Veri Seti ve Shipsnet) kullanılarak aynı modelin (YOLO v3-v4-v5) farklı versiyonları ile deneyler gerçekleştirilmiştir. Mehran ve ark., (2023) çalışmasında, Kaggle üzerinden ücretsiz erişilebilen veri setinde (Ships in Satellite Imagery) gemi tespiti için, transfer öğrenme (transfer learning) ve veri artırma (data augmentation) yöntemlerini kullanarak %99 doğruluk elde etmişlerdir. Atik ve ark., (2022)’de, gemi ve uçak sınıflarının da bulunduğu dokuz farklı nesne sınıfının otomatik tespiti için, hava fotoğraflarından oluşan DOTA Veri Setini kullanarak YOLOv2 ve YOLOv3 versiyonlarıyla karşılaştırmalı bir çalışma yapmışlardır. Ozturk ve ark.,

(2020)’de, 1.2 m çözünürlükteki Toronto Yol Veri Setini kullanarak U-Net ve FCN modellerinde hiper parametre testleri gerçekleştirmiştir. Bayramoğlu ve Uzar (2023)’de, yol tespiti için kural tabanlı (rule-based method) yöntem ile U-Net mimarisini kullanarak karşılaştırmalı bir çalışma yapmışlardır. Azam ve ark., (2022)’de ise uçak tespiti amacıyla en uygun nesne dedektörlerini, omurga (backbone) özellik çıkarma ağlarını kullanmışlar ve hiper parametre testlerini gerçekleştirmişlerdir.

Binaların otomatik olarak yüksek doğrulukta tespit edilmesine ilişkin yapılan çalışmalar, uydu görüntülerinin çözünürlüğüne göre farklılıklar göstermektedir. Raghavan ve ark., (2022)’de, çok yüksek çözünürlüklü uydu görüntüleri kullanarak bina tespitinde veri setlerini çeşitli modellerle eğittiklerinde doğruluk açısından iyi performanslar elde etmişlerdir. Erdem ve Avdan (2020)’de, yüksek çözünürlüklü hava fotoğraflarından oluşan açık kaynaklı INRIA Veri Seti ile bina çıkarımı için U-Net VGG16, U-Net InceptionResNetV2, U-Net DenseNet121 ve topluluk oylaması (majority voting) yöntemlerinin performanslarını değerlendirmişlerdir. INRIA veri seti kullanılarak yapılan bir diğer bina segmentasyonu çalışmasında FCN mimarisinde, SegNet mimarisine göre daha yüksek doğruluk elde edilmiştir (Sarıtürk ve ark. 2020). Çalışmada, topluluk oylaması yöntemi, diğer üç yöntemden elde edilen sonuçların birleştirilerek oluşturulduğu yeni bir modeldir ve en yüksek doğruluk bu model ile elde edilmiştir. Yin ve ark., (2022)’de WHU, Massachusetts ve RSIB (Remote Sensing Imagery for Building Extraction) veri setlerini kullanarak klasik nesne tespiti (YOLOv4, Faster R-CNN, YOLACT ve Mask R-CNN) ve klasik derin öğrenme yöntemlerini (U-Net, PSPNet, HRNet ve DeepLabV3+) kullanarak karşılaştırmalı bir çalışma gerçekleştirmişlerdir.

Çok farklı tipte özellik gösteren binaların yüksek çözünürlüklü uzaktan algılama görüntülerinden otomatik olarak çıkartılması oldukça zor ve kapsamlı bir konudur. Örneğin, binalar özellikleri açısından ülkelere ve buldukları bölgelere göre coğrafi farklılıklar gösterirler. Fiziksel özellikleri açısından bakıldığında farklı geometrilerde yapılar olsa da birçok bina dikdörtgen şeklindedir. Binalar ayrıık veya bitişik düzende, tek katlı, çok katlı ya da gökdelen şeklinde olabilirler. Şehir alanlarında ya da kırsalda farklı özellikler ve farklı malzemelerden (kerpiç, betonarme, cam, çelik vb.) yapılmış binalarla karşılaşmak mümkündür. Ayrıca tarihi binalar ya da farklı çatı tipine sahip binalar da bulunmaktadır. Akbulut ve ark., (2018)’de, hava fotoğraflarından bina çıkarımı amacıyla yapılan çalışmada, geometrik olarak kompleks binaların homojen çatı tipine sahip binalara göre daha düşük doğrulukla tespit edildiğini gözlemlemiştir. Tüm bunlar ile birlikte, bitişik düzende yapıların ayırt edilmesi ya da yüksek katlı binaların neden olduğu gölge etkisi gibi faktörler problemi ayrıca zorlaştırmaktadır. Dolayısıyla uydu görüntüsü açısından değerlendirildiğinde hem kullanılan uydu görüntüsünün çözünürlük özellikleri hem de ayırt edilmek istenen objenin özellikleri göz önünde bulundurulmalıdır.

Afet durumunda hızlı bilgi üretilmesi, yerleşim alanlarının, kapalı yolların belirlenmesi ve değişim

analizlerinin kısa sürede yüksek doğrulukla yapılabilmesi için uzaktan algılama verilerinden binaların, hasar ya da enkaz durumunun otomatik tespiti önem taşır. Bu özelliklerin çıkartılmasında amaca uygun veri setinin seçilmesi ve veri seti özelliklerinin bilinmesi gerekmektedir. Bu çalışma kapsamında, uzaktan algılama görüntülerinden binaların otomatik olarak çıkartılması için oluşturulan açık kaynaklı bina veri setleri ve özellikleri detaylı olarak açıklanarak avantajlarının ve dezavantajlarının belirlenmesi amaçlanmıştır.

Bu derleme makalesinde farklı platformlardan ve farklı çözünürlükte elde edilmiş açık kaynaklı uzaktan algılama verilerinden bina tespiti konusuna odaklanılmıştır. Literatür taramasında online veri tabanlarından WoS (Web of Science), Scopus ve Google Scholar'dan yararlanılmıştır. Bu veri tabanlarındaki yayınların başlığında, özetinde ve anahtar kelimelerinde yer alan "bina tespiti", "bina çıkarımı", "bina veri seti" ve "segmentasyon" anahtar kelimeleri kullanılarak sorgulamalar yapılmıştır. Sorgulamalara ek olarak 2012 ile 2023 yılları arasında, "uzaktan algılama" kategorisi altında, gelişmiş araştırma aracında yüksek atıf alan (high citation), konu ile alakalı (relevant) ve güncel sıralama (newest to old) kriterlerine dikkat edilmiştir. Filtreleme işlemi sonucunda 200 makale incelenip, probleme en uygun yayınlar atıf olarak gösterilmiştir.

## 2. Açık kaynaklı bina veri setleri

Literatürde havadan, uydudan ve her iki platformdan kaydedilmiş görüntülerin birlikte kullanıldığı veri setleri bulunmaktadır. Tablo 1'de, sıklıkla kullanılan açık kaynaklı bina veri setleri kapsama alanı, etiket sayısı, mekânsal çözünürlük, karo (tile) sayısı ve karo boyutu özelliklerine göre gösterilmektedir.

Derin öğrenme mimarileri, derin katman yapısı sayesinde birçok katmanı iç içe bulundurur. Derin katmanlarda öğrenmenin gerçekleşmesi için mimariler çok sayıda veri ile eğitilmelidir (Wang ve ark., 2021). Derin öğrenme tabanlı otomatik bina çıkarımı için geniş kapsama alanlı, zengin içerikli, kaliteli etiketlenmiş çok fazla sayıda görüntü örnekleri gerekir (Tan ve ark., 2018). Veri setlerindeki kapsama alanı, etiket sayısı, mekânsal çözünürlük, karo sayısı ve karo boyutu binaların otomatik tespit edilme doğruluğunun önemli belirleyicileridir. Bunun yanı sıra, ayırt edilmek istenen objenin bu görüntülerden ne kadar yüksek doğrulukta ve fazla sayıda etiketlendiği de çalışma sonuçlarının doğruluğunu etkileyen önemli parametrelerdir.

Derin öğrenmede kullanılan uydu veya hava platformlarında kaydedilen görüntülerin yüksek mekânsal çözünürlüğe sahip olması veri boyutunu artırmaktadır. Derin öğrenme modellerini eğitmek için büyük boyuttaki bu veriler genellikle standart karo boyutlarına (128 x 128, 256 x 256, 512 x 512 ve 1024 x 1024) kesilerek kullanılır. Bununla birlikte standart karo boyutlarının dışında farklı boyutlarda oluşturulmuş veri setleri de bulunmaktadır.

Bu çalışmada, literatürde sıklıkla kullanılan açık kaynaklı bina veri setleri kaydedildiği platformlara göre gruplandırılmış ve bu veri setlerinin özellikleri detaylandırılmıştır.

## 2.1. Hava fotoğraflarından oluşturulan bina veri setleri

Bu bölümde hava fotoğraflarından türetilmiş bina veri setleri yer almaktadır. Hava fotoğrafları uydu görüntülerine göre daha yüksek mekânsal çözünürlüğe sahip olmasına karşın, alçak seviyeden görüntü kaydedildiği için küçük kapsama alanına sahiptir. Aşağıda açıklanan ISPRS, Massachusetts, INRIA, OpenAI, LandCover.ai, AIRS, Waterloo ve Open Spatial Data bina veri seti bu veri türü ile oluşturulmuştur.

### 2.1.1. ISPRS (2D Semantic Labeling) veri seti

Almanya'nın iki farklı şehriden görüntüler bulunduran veri mavi, yeşil, kırmızı (MYK) ve yakın kızılötesi (YKÖ) bantlarda kaydedilmiş ortofotolardan oluşturulmuştur (Gerke ve Sohn, 2014). Veri setinde geçirimsiz yüzeyler, bina, kısa bitki örtüsü, ağaç, araba ve arka plan olmak üzere altı sınıfta etiketleme yapılmıştır. YKÖ bandına sahip veri seti, bina etiketleri dışında farklı etiket sınıflarına sahip olmasına rağmen bina segmentasyonu uygulamalarında çokça tercih edilmektedir. Elle oluşturulan bu veri setinde en önemli eksiklik, performans değerlendirmede büyük önem taşıyan test için ayrılan verilerin etiketlerinin bulunmayışıdır.

### 2.1.2. Massachusetts veri seti

Massachusetts Eyaleti'nin Boston şehrine ait MYK bantlarda kaydedilmiş hava fotoğraflarından üretilen veri seti, sadece binaların etiketlendiği otomatik bina çıkarımı için oluşturulan ilk bina veri seti olma özelliğini taşımaktadır (Mnih, 2013). Veri setindeki 151 görüntünün 137'si eğitim, 4'ü doğrulama ve 10'u ise test verisi olarak kullanılmıştır. OSM (OpenStreetMap) bina verileri kullanılarak oluşturulan, farklı ölçekteki binaları kapsayan veri seti, bina ve arka plan olmak üzere iki sınıfa ayrılmıştır. Massachusetts kentsel ve banliyö alanlarını, müstakil evleri ve garajlar dahil olmak üzere farklı büyüklükteki bina etiketlerini kapsar.

### 2.1.3. INRIA (Aerial Image Labeling Dataset) veri seti

Eğitim verileri Austin, Chicago, Kitsap County, Western Tyrol, Vienna; test verileri Bellingham, Bloomington, Innsbruck, San Francisco, Eastern Tyrol şehirlerine ait MYK bantlarda ve 8 bit radyometrik çözünürlükte kaydedilen ortofotolardan türetilmiştir (Maggiori ve ark., 2017). Açık kaynaklı bina ayak izleri (kadastral veriler, OSM, vb.) ile semantik segmentasyon yöntemine uygun olarak hazırlanan bina etiketlerinin gdal kütüphanesi ile bina ve arka plan olarak maske görüntüleri oluşturulmuştur. Görüntü karolarının %50'si eğitim ve %50'si ise test verisi olacak şekilde bölünmüştür. INRIA, görüntülerdeki coğrafi çeşitlik ile beraber yapısal farklılıkları genelleyen bir veri seti oluşturmayı hedeflemektedir. Ayrıca, veri seti içerisinde eğitim ve test için farklı şehirler seçilmesi bu hedefi desteklemektedir. Veri setindeki en önemli eksiklik, 810 km<sup>2</sup>lik geniş kapsama alanına sahip olmasına rağmen test için ayrılan alanın yani kapsama alanının yarısının etiketlerinin bulunmayışıdır.

**Tablo 1.** Literatürdeki çalışmalarda sıklıkla kullanılan açık kaynaklı bina veri setleri ve özellikleri.

Kaynak	Veri Seti	İçerik	Alan (km <sup>2</sup> )	Etiket Sayısı	Mekânsal Çözünürlük (m)	Karo Sayısı	Karo Boyutu (px)
Hava Fotoğrafları	ISPRS (2012) (URL-2)	Vaihingen	1.38	-	0.09	33 yama	~2.494 x 2.064
		Potsdam	3.42	-	0.05	38 yama	6.000 x 6.000
	Massachusetts (2013) (URL-3)	Boston	340	-	1.00	151 görüntü	1.500 x 1.500
	INRIA (2016) (URL-4)	Austin, Chicago, Kitsap County, Western Tyrol, Vienna, Bellingham, Bloomington, Innsbruck, San Francisco, Eastern Tyrol	810	-	0.30	360	5.000 x 5.000
	Open AI dataset (2018) (URL-5)	Zanzibar	102.6	13.407	0.07	13 görüntü	40.551 x 40.592
	LandCover.ai (2020) (URL-6)	Polonya	216	-	0.25	33* görüntü	9.000 x 9.500
				-	0.50	8* görüntü	4.200 x 4.700
	AIRS (2020) (URL-7)	Yeni Zelanda	457	220.000	0.075	1.047 görüntü	10.000 x 10.000
	Waterloo Building Veri Seti (2021) (URL-8)	Ontario, Kanada'daki Kitchener-Waterloo bölgesi	2.058	117.000	0.012	69.938 yama	512 x 512
	Open Spatial Data Veri Seti (2022) (URL-9)	Polonya	31	21.010	0.10	6.365 görüntü	512 x 512
				0.50	1.263 görüntü	256 x 256	
Uydu Görüntüleri	SpaceNet V1 (2016) (URL-10)	Rio de Janeiro	2.54	382.534	0.50	6.940	438 x 406
	SpaceNet V2 (2017) (URL-11)	Vegas Paris Şanghay Khartoum	216 1.030 1.000 765	151.367 23.816 92.015 35.503	0.30	-	650 x 650
	CrowdAI (2018) (URL-12)	-	-	-	0.30	401.755	300 x 300
	SpaceNet 4 (2019) (URL-13)	Atlanta	665	126.747	0.50	62.000	900 x 900
	xBD Dataset (2019) (URL-14)	15 ülke	5.000	700.000	0.50	22.068 görüntü	-
	SpaceNet 6 (2020) (URL-15)	Rotterdam	120	48.000	0.50	-	900 x 900
	SpaceNet 7 (2020) (URL-16)	100 farklı lokasyon	40.000	11.079.262	4.00	101 veri küpü	1.024 x 1.024
	SemCity Toulouse (2020) (URL-17)	Fransa	50	9.455 (örnek seg.)	0.50	16	876 x 863
	Open Building Veri Seti (2021) (URL-18)	Afrika Kıtası ve Güney Asya	39.1 M	19.4 M	0.50	99.502 1M 8.7M 0.9M	600 x 600 600 x 600 640 x 640 448 x 448
	UHUZAM İstanbul Bina Veri Seti Versiyon 1 (2022)	İstanbul	85	40.000	0.50	150	1500 x 1500
Uydu ve Hava Görüntüleri	WHU (2018) (URL-19)	Aerial Imagery Dataset Satellite Dataset I (Global Cities)	193.2	187.000	0.30	8.189	512 x 512
		Satellite Dataset II (East Asia)	-	-	0.30-2.50	204 görüntü	512 x 512
	WHU-Mix (2021) (URL-20)	5 farklı kıtadaki 5 ülkeden toplanmıştır.	860	34.085	0.45	17.388	512 x 512
		1.213	-	0.09-2.5	51.445	512 x 512	

\* Toplamda (33+8) 41 görüntüden 10,674 karo sayısı elde edilmiştir.

#### 2.1.4. OpenAI (Open AI Tanzania Challenge) veri seti

Afrika'nın Zanzibar Adası'ndan örnekler bulunduran veri, 7 cm mekânsal çözünürlükte ve MYK bantlarda kaydedilmiş, hava fotoğraflarından oluşmaktadır. Bu veri setinde, görüntü boyutu 40.551 x 40.592 piksel ve görüntü sayısı 13 olarak sunulmaktadır. Bina geometrisine ve ana hatlarına uygun olarak hazırlanan bina etiketleri, FeatureCollections olarak kodlanan bir GeoJSON dosyası olarak verilmektedir. Veri setindeki en önemli eksiklik, bina etiketlendirinde çok sayıda hata içermesidir (Luo ve ark., 2023) Ayrıca, bu veri Open

Cities AI Dataset'in küçük bir bölümüdür (Open Cities AI Challenge Dataset, 2023).

#### 2.1.5. LandCover.ai (Land Cover from Aerial Imagery) veri seti

Polonya'da, 25 cm çözünürlüklü 33, 50 cm çözünürlüklü 8 olmak üzere toplam 216 km<sup>2</sup>'lik bir alanda 41 ortofotodan oluşturulan veri setinde hem kırsal alandan hem de şehir merkezinden örnekler bulunmaktadır (Boguszewski ve ark., 2021). Bina, ağaçlık alan, su, yol ve arka plan sınıflarını kapsayan veri seti elle

sayısallaştırma ile oluşturulmuştur. Etiketleme işlemi VGG Image Annotator (VIA) kullanılarak yapılmıştır. Maskeler tek bantlı .geotiff uzantısında sunulmaktadır. Karolar 512 x 512 olacak şekilde, %70-%15-%15 oranında eğitim-doğrulama-test verisi olarak bölünmektedir. Bu veri setinin diğer veri setlerinden en önemli farkı, kırsal alana ait yüksek çözünürlüklü veri içermesi ve birden fazla sınıfın elle etiketlenerek oluşturulmasıdır.

### 2.1.6. AIRS (Aerial Imagery for Roof Segmentation) veri seti

Yeni Zelanda'da 457 km<sup>2</sup>'lik bir alanda 7.5 cm mekânsal çözünürlükte, 1.047 sayıda hava fotoğraflarından oluşturulan veri seti, 220.000 adet etiketli bina içermektedir. Karolar 857-94-96 sayısınca eğitim-doğrulama-test verisi olarak bölünmektedir (Chen ve ark., 2019). Etiketleme işlemi yapılırken iki yöntemden faydalanılmıştır. İlk aşamada dijital ortofoto haritaları (Digital Orthophoto Maps) kullanılarak 2B bina ayak izi çıkarılır. İkinci aşamada ise çatı sınırları çizilir ve ardından bu sınırlar bina ayak izine göre hareket ettirilir. Bu veri seti çatı sınırları (roof outlines) yerine bina ayak izi temel alınarak manuel olarak oluşturulmuştur. Bu nedenle, çatı dış çizgisi ile bina ayak izi farklılığından kaynaklanan rölyef ötelenmesinden (relief displacement) etkilenmeyen veri seti, bu özelliğiyle diğer veri setlerinden ayrılmaktadır. Tüm bu işlemler bittikten sonra etiketler çalışma alanının tamamı için iki kez kontrol edilir.

### 2.1.7. Waterloo bina veri seti

Harvard Üniversitesi tarafından bina tespiti için hazırlanmış bu veri seti, Kuzey Amerika'nın yüksek mekânsal çözünürlüğe sahip ilk açık erişimli şehir ölçeğindeki veri setidir (He ve ark., 2021). Kanada'da 205.8 km<sup>2</sup>'lik bir alandan alınan veri seti, 12 cm çözünürlüğe sahip toplam 242 hava fotoğraflarından oluşmaktadır. Etiketleme işlemi manuel olarak Microsoft Word ve ArcGIS programları kullanılarak bina ve arkaplan sınıfları olacak şekilde yapılmıştır. Bu görüntüler ve etiketler 512 x 512 karo boyutunda düzenlenmiştir. Ayrıca etiketler ve görüntüler .tif uzantısında sunulmaktadır. Veri seti, AIRS hariç diğer açık kaynaklı veri setlerine göre hem daha yüksek mekânsal çözünürlüğe hem de kapsama alanına sahiptir (He ve ark., 2022a).

### 2.1.8. Open Spatial data veri seti

Polonya'da toplamda 31 km<sup>2</sup> alan kapsayan 8 bit radyometrik çözünürlükte MYK bantlara sahip ortofotodan oluşturulan veri seti iki farklı çözünürlükte 21.010 bina etiketi içermektedir (Glinka ve ark., 2022). Görüntülerin %80'i eğitim, %10'u doğrulama ve %10'u ise test verisi olarak bölünmüştür. Bu veri setinde ortofoto görüntülere ve etiketlere, "The Land and Building Register (EGiB)" (URL-21) kadastral veri sistemi üzerinden erişim sağlanmaktadır. Veri setindeki bina etiketleri, bina ayak izine göre oluşturulmuştur. Bu veri sisteminde bina etiketlerinin ve bina yükseklik bilgilerinin eksik olması dezavantaj sağlamaktadır.

## 2.2. Uydü görüntülerinden oluşturulan bina veri setleri

Bu bölümdeki bina veri setleri QuickBird, Worldview serisi, IKONOS, ZY-3, GeoEye-1 ve Pleiades gibi uydulardan sağlanan yüksek çözünürlüklü görüntülerden oluşturulmuştur. Uydular, havadan algılama yapan sistemlere göre daha yüksekten çekim yaptığı için geniş kapsama alanına sahiptir. Aşağıda detayları açıklanan SpaceNet Serisi, CrowdAI, xBD, SemCity Toulouse, Open Building ve İstanbul V1 gibi bina veri setleri uydü görüntüleri kullanılarak üretilmiştir.

### 2.2.1. SpaceNet V1 (Building Detection v1) veri seti

Brezilya'nın Rio de Janeiro şehrine ait MYK ve 8 bit radyometrik çözünürlükte kaydedilmiş WorldView 2 uydü görüntülerinden oluşturulmuştur (Van Etten ve ark., 2018). Görüntü karolarının %60'ı eğitim, %20'si doğrulama ve %20'si ise test verisi olarak bölünmüştür. Bu veri setinin örnek (instance) segmentasyon yöntemine uygun olarak yarı otomatik yöntemler ile elle hazırlanan etiketleri, bina ve arka plan olarak iki sınıfa ayrılmıştır.

### 2.2.2. SpaceNet V2 (Building Detection v2) veri seti

Vegas, Paris, Şanghay ve Khartoum şehirlerinden örnekler bulunan veri MYK, 16 bit radyometrik çözünürlükte kaydedilmiş WorldView 3 uydü görüntülerinden oluşturulmuştur (Van Etten ve ark., 2018). Vegas, 216 km<sup>2</sup> kapsama alanına ve 151.367 bina etiketine; Paris, 1.030 km<sup>2</sup> kapsama alanına ve 23.816 bina etiketine; Şanghay, 1.000 km<sup>2</sup> kapsama alanına ve 92.015 bina etiketine; Khartoum, 765 km<sup>2</sup> kapsama alanına ve 35.503 bina etiketine sahiptir. Veri setinin örnek segmentasyon yöntemine uygun olarak yarı otomatik yöntemler ile elle hazırlanan etiketleri, bina ve arka plan olarak iki sınıfa ayrılmış ve görüntü karolarının %60'ı eğitim, %20'si doğrulama ve %20'si ise test verisi olarak bölünmüştür. SpaceNet V2'deki en önemli özellik, dört ülkeye ait mimari ve yapısal farklılıklar bulunduran bina örnekleri içermesidir.

### 2.2.3. CrowdAI (Mapping Challenge Dataset) veri seti

CrowdAI, dört ülkeye ait geniş kapsama alanında sunulan SpaceNet V2'nin veri boyutu azaltılarak oluşturulan basitleştirilmiş bir versiyonudur (Mohanty ve ark., 2020). SpaceNet V2'deki tüm bantlar yerine sadece MYK bantları kullanılmış, karo boyutu 300 x 300 piksel olarak yeniden boyutlandırılmış ve 8 bit radyometrik çözünürlüğe düşürülmüştür. Veri setinde, toplam karo sayısı 401.755 olarak düzenlenmiş ve görüntü karolarının 280.741'i eğitim, 60.317'si doğrulama ve 60.697'si ise test verisi olarak kullanılmıştır.

### 2.2.4. SpaceNet 4 (Multi-View Overhead Imagery Dataset (MVOI)) veri seti

7°-54° arasında 27 farklı bakış açısına sahip görüntü içeren veri seti, bakış açısından bağımsız olarak bina tespitini hedefler (Weir ve ark., 2019). MYK, Pan, NIR

bantlarında kaydedilen WorldView 2 uydu görüntüleri nadir ( $0^{\circ}$ - $25^{\circ}$ ), nadir dışı ( $25^{\circ}$ - $40^{\circ}$ ), nadirden çok uzak ( $40^{\circ}$ - $55^{\circ}$ ) olmak üzere üç farklı özellikte görüntü içermektedir. Bina etiketleri nadir görüntüye uygun olarak bina ayak izine göre uzman bir ekip tarafından oluşturulmuştur. Daha sonra bir bağımsız doğrulayıcı ve bir uzaktan algılama uzmanı tarafından etiketlerin kalitesi kontrol edilmiştir. Veri setinin farklı açılarda algılanmış görüntülerden oluşması, afet gibi acil durumlarda ve ideal koşullarda görüntü alınmaması durumunda bilgi çıkarılmasına olanak sağlamaktadır.

### 2.2.5. xBD (Building Damage) veri seti

15 ülkeden  $45.362 \text{ km}^2$ 'lik alana ait afet öncesi ve afet sonrası uydu görüntülerinden etiketlenen, yaklaşık 850.736 bina ve bu binalara ait ek açıklamaların bulunduğu xBD Veri Seti bugüne kadarki en büyük bina hasar değerlendirme veri seti olma özelliği taşımaktadır (Gupta ve ark., 2019a). xBD, Maxar/DigitalGlobe Open Data Programı kapsamında 19 farklı alanda gerçekleşmiş, deprem/tsunami, sel, volkanik patlama, orman yangını ve rüzgâr olmak üzere beş afet türüne ait çok yüksek çözünürlüklü ( $0.5 \text{ m GSD}$ ) 22.068 adet uydu görüntüsü ile oluşturulmuştur. CrowdAI tarafından şirket içinde geliştirilmiş web tabanlı bir etiketleme aracı kullanılarak bina ve hasar seviyesi etiketlemeleri gerçekleştirilmiştir. Bu aşamadan sonra yanlış etiketlenen görüntüler uzmanlar tarafından düzeltilmiştir. Veri seti, doğal afetten sonra bina hasarını değerlendirme sürecini otomatikleştirme amacıyla yapılan xvview2 yarışmasında kullanılmıştır. Karolar %80-%10-%10 oranında eğitim-doğrulama (holdout)-test verisi olarak bölünmüştür. Eğitim veri seti, katılımcılar tarafından doğrulama setine bölünerek kullanılmaktadır. Doğrulama için ayrılan bu kısım, yarışma kapsamında doğrulamada bağımsız değerlendirmeler yapmak için bilinçli olarak katılımcılarla paylaşılmamıştır. xBD Veri Setinde farklı afet türlerinden kaynaklanan hasarı değerlendirmek için, hasar yok (0), küçük hasar (1), büyük hasar (2) ve yıkılmış (3) olacak şekilde dört seviyeli Ortak Hasar Ölçeği (The Joint Damage Scale) kullanılmıştır (Gupta ve ark., 2019b).

### 2.2.6. SpaceNet 6 (Multi-Sensor All-Weather Mapping) veri seti

SpaceNet 6, Avrupa'nın en büyük limanın bulunduğu Hollanda'nın Rotterdam kentine ait  $50 \text{ cm}$  mekânsal çözünürlükte WorldView 2 ve dört farklı polarizasyonda Cappella Space's X-bant görüntülerinden oluşmaktadır (Shermeyer ve ark., 2020). Sadece binaların etiketlendiği görüntüler farklı boyutlarda birçok bina, araç ve tekneyi de içermektedir. Bina etiketleri, lidar teknolojilerinden türetilen üç boyutlu binaların olduğu açık kaynaklı olarak sunulan 3DBAG (3D Basisregistratie Adressen en Gebouwen) verisinden derlenmiştir. 3DBAG, tüm Hollanda genelinde hem bina ayak izlerini hem de adreslerini içermektedir. Çok yüksek çözünürlüklü optik ve Yapay Açıklı Radar (YAR) görüntülerinin bir arada yer aldığı SpaceNet 6'da optik veriler, YAR verilerinden bina belirlenmesine yardımcı veri olarak bulunmaktadır. Bu

nedenle, veri setindeki test verileri sadece YAR verilerinden oluşmaktadır. Bu durum, afet sonrası optik veriye ulaşılamaması halinde sadece YAR verileri ile yüksek doğrulukta bina tespitine olanak sağlamaktadır.

### 2.2.7. SpaceNet 7 (Multi-Temporal Urban Development SpaceNet / MUDS) veri seti

Antarktika hariç olmak üzere 6 kıtada 101 farklı lokasyonu kapsayan 24 görüntü (ayda bir) içeren  $4 \text{ m}$  mekânsal çözünürlüğe sahip veri seti, MYK bantlarda Planet uydu görüntülerinden oluşmaktadır (Van Etten ve ark., 2021). Görüntülerden manuel olarak oluşturulmuş iki farklı grupta etiketler bulunmaktadır. İlk etiket grubu ile binaların ana hatları tanımlanır, ikinci etiketleme grubu ile bulutların örttüğü binalar ve geo-referanslama hatası gibi durumlarda kullanılmaz veri maskeleri (unusable data masks) ifade edilir. Etiketler bina ve arka plan olarak iki sınıfta üretilmiştir. Toplamda 11.079.262 bina etiketi bulunmaktadır ve her lokasyon ( $101 \text{ adet}$ ) bir veri küpü (data cube) olarak sunulmaktadır. Veri boyutunun çok yüksek olması nedeniyle ilk kez bir veri küpü olarak sunulan bina veri setinde zaman serisi analizleri ile değişim analizi de hedeflenmektedir.

### 2.2.8. SemCity Toulouse veri seti

$50 \text{ cm}$  mekânsal çözünürlükte MYK Worldview 2 uydu görüntüsünden Fransa'da  $50 \text{ km}^2$ 'lik bir alanda hem tarihi binaları hem de düzenli yerleşim bölgelerini içeren veri seti, elle sayısallaştırma ile oluşturulmuştur (Roscher ve ark., 2020). Geçirimsiz yüzey, bina, geçirimli yüzey, yüksek bitki örtüsü, araba, su, spor alanları ve arka plan olmak üzere toplam 8 sınıfı içermektedir. Görüntüler ve ilgili etiketler .tif formatındadır. Veri setinin %25'i örnek segmentasyon %75'i ise semantik segmentasyona uygun olarak hazırlanmıştır. Aynı alan için hem örnek segmentasyona hem de semantik segmentasyona olanak sağlaması SemCity Toulouse Veri Setinin diğer veri setlerinden üstünlüğüdür.

### 2.2.9. Open Building veri seti

Veri seti, Google araştırmacıları tarafından kıta bazında bina algılama modellerinin eğitimi ve analizi için hazırlanmıştır (Sirko ve ark., 2021). Veri seti, Afrika kıtasının %64'ünü kapsayan  $19.4 \text{ milyon km}^2$ 'lik bir alandan alınmış  $50 \text{ cm}$  çözünürlükte uydu görüntülerinden ve  $516 \text{ milyon}$  bina ayak izini tanımlayan poligonlardan oluşmaktadır. Etiketleme işlemi güven skoru değer  $[0.60-0.65]$ ,  $[0.65-0.70]$  ve  $[>=0.70]$  aralıklarına göre 3 farklı düzeyde gerçekleştirilmiştir. Veri seti 4 kategoriye ayrılarak hazırlanmıştır. İlk kategori kontrollü eğitim için kullanılan tam örnek etiketlerine sahip  $600 \times 600$  piksel boyutlarındaki  $99.902$  MYK uydu görüntülerini içerir. İkinci kategori önceden eğitilmiş (pre-train) bir model kullanarak eğitim yapmak için  $600 \times 600$  boyutunda  $1 \text{ milyon}$  görüntüden oluşmaktadır. Üçüncü kategori kontrolsüz eğitim için etiketi olmayan  $640 \times 640$  boyutunda  $8.7 \text{ milyon}$  görüntüyü içermektedir. Son kategoride ise değerlendirme için oluşturulmuş kısmen

etiketlenmiş (sparsely-labeled), yani gerçek bina yoğunluğu ile eşleşmeyen bölgeleri kapsayan 448 x 448 boyutundaki 0.9 milyon görüntüden oluşmaktadır. Etiketleme işleminde karşılaşılan bazı sorunların üstesinden gelmek için birtakım kurallar benimsenmiştir. Birbirine yakın ve yoğun konumlandırılmış binalarda sınırlar kesin olarak belli olmuyorsa bu binalar “yoğun sınıf (dense class)” sınıfına atanmaktadır. Bina içeren görüntülerde binaları örten ya da kolaylıkla birbirine karışabilecek bitki örtüsü, kaya gibi karışımlar olabilir. Böyle bir durumda her görüntü bir bina algılamasına merkezlenir. Etiketleme yapan kişiler, her görüntü için o merkezin bina içerip içermediğine bakar. Eğer bina içeriyorsa o binanın ayak izini içeren bir etiket oluşturur, bina içermiyorsa o etiket boş olarak işaretlenir.

### 2.2.10. UHUZAM İstanbul bina veri seti versiyon 1 (İstanbul V1)

İstanbul'un Anadolu ve Avrupa yakalarının 85 km<sup>2</sup> alan genişliğindeki çeşitli bölgelerini kapsayan, 8 bit radyometrik çözünürlükte ve 0.5 m mekânsal çözünürlükte MYK bantlarında kaydedilmiş Pan ile keskinleştirilmiş Pleiades uydu görüntülerinden oluşturulmuştur (Amirgan ve ark., 2022; Bakırman ve ark., 2022). Anadolu yakası için 21 karo 9764 bina etiketini ve Avrupa yakası için 129 karo 30.047 bina etiketini içermektedir. Etiketler, çatı sınırlarına göre ArcGIS ve QGIS programı ile elle çizilerek, semantik segmentasyona uygun şekilde oluşturulmuştur. Görüntülerin karo boyutu 1500 x 1500 pikseldir. Derin öğrenme uygulamalarında işlem kolaylığı sağlamak için her görüntü 512 x 512 piksel olarak daha küçük karolara bölünmüştür. Etiketlenmiş görüntülerin %70'i eğitim, %20'si doğrulama ve %10'u ise test verisi olarak düzenlenmiştir. Çok yüksek çözünürlüklü Pleiades uydu görüntüsü kullanılarak oluşturulan ilk bina veri seti olması ve bunun yanı sıra tarihi, bitişik, gökdelen, toplu konut, villa, gecekondu, sanayi gibi farklı mimarilerde bina türlerini bulundurması İstanbul V1 veri setinin en önemli özellikleridir. Bu veri setine henüz erişim sağlanamamaktadır fakat kısa süre içerisinde araştırmacılar için paylaşımına açılacaktır.

### 2.3. Hava ve uydu görüntülerinden oluşturulan bina veri setleri

Bu bölümde ise hava ve uydu görüntülerinden oluşturulan WHU ve WHU-Mix veri setleri açıklanmıştır. Bu veri kombinasyonu ile oluşturulmuş bina veri setlerinde amaç çeşitliliği artırarak mevcut veri setlerindeki genelleme problemini çözmektir. Bu amaçla farklı platformlardan elde edilmiş veri setleri bir araya getirilir. Böylece hem mekânsal çözünürlük hem de bina çeşitliliği açısından veri seti zengin hale getirilir.

#### 2.3.1. WHU veri seti

Farklı coğrafyalara ait biri hava (Hava Fotoğrafi Veri Seti) ve diğer ikisi uydu (Uydu Görüntüsü I-II) görüntülerinden oluşan veri setleri içerik olarak 30 cm'den 2.50 m'ye kadar geniş bir aralıkta mekânsal

çözünürlüğe sahiptir (Ji ve ark., 2018). Yeni Zelanda'nın Christchurch şehrinden görüntüler bulunduran Hava Fotoğrafi Veri Seti; 30 cm mekânsal çözünürlüğe sahip 4.736 eğitim, 2.416 doğrulama, 1.036 test verisi ile raster ve vektör formatında 187.000 bina etiketini içermektedir. Global şehirlerden görüntüler içeren Uydu Görüntüsü I Veri Seti; 0.30-2.50 m mekânsal çözünürlüğe sahip QuickBird, Worldview serisi, IKONOS ve ZY-3 uydularından sağlanan görüntülerden oluşturulmuştur. Farklı uydu görüntülerinden örnekler bulunduran bu veri seti ile atmosferik-radyometrik koşullardan ve uydu algılayıcılarından bağımsız olarak bina tespiti hedeflenmiştir. Doğu Asya için oluşturulan Uydu Görüntüsü II Veri Seti; 45 cm mekânsal çözünürlüğe sahip uydu görüntüleri ile 13.662 eğitim, 3.726 test verisi olmak üzere toplam 34.085 bina etiketi içermektedir. Veri Setindeki tüm etiketler, ArcGIS programında manuel olarak yüksek kalitede oluşturulmuştur.

#### 2.3.2. WHU-Mix bina veri seti

WHU-Mix, bina türü, farklı çözünürlük, değişik kaynaklardan algılama ve görüntüleme koşulları yönünden çeşitliliği arttırmak için WHU Bina Veri Seti ile INRIA Veri Setinin manuel olarak yeniden düzenlenmesi ile oluşturulmuştur (Luo ve ark., 2023). Bu düzenleme işlemi ArcGIS ortamında gerçekleştirilmiştir. 1.213 km<sup>2</sup>'lik alan için, 51.445 uydu ve hava fotoğraflarından oluşturulan veri setinde, mekânsal çözünürlük 0.09-2.5 m arasında değişmektedir. Karo boyutu 512 x 512 olacak şekilde %90-%10 oranında eğitim/doğrulama-test verisi olarak bölünmektedir. Hem etiketler hem de görüntüler .tif uzantısı ile depolanmaktadır Eğitim ve test veri setinde coğrafi bir örtüşme olmaması veri setinin genelleme yeteneğini artırmaktadır.

Bu aşamaya kadar literatürde sıkça kullanılan açık kaynaklı bina veri setleri üç gruba ayrılarak detaylandırılmıştır.

### 3. Literatürde bina veri setleri kullanılarak gerçekleştirilen çalışmalar

Literatürde birçok bina veri seti ve bu veri setlerinin farklı yöntemler ve derin öğrenme tabanlı mimariler ile incelendiği çalışmalar mevcuttur. Günümüzde bina tespiti çalışmalarında piksel ya da nesne tabanlı sınıflandırma, morfolojik operatörler (Perihanoğlu ve ark., 2018) ve makine öğrenmesi (Duman ve Başaraner, 2022) gibi klasik yöntemlerin yanı sıra derin öğrenme tabanlı yöntemler tercih edilmektedir. Bu bölümde, sadece bina veri setleri ile derin öğrenme modellerinin karşılaştırmalı olarak irdelendiği çalışmalardan örnekler sunulmuştur.

Ji ve ark., (2018)'de, binaların otomatik segmentasyonu için WHU, Massachusetts ve INRIA veri setlerinde UNet modelini kullanmıştır. Bu mimari üzerinde sırasıyla WHU Veri Seti'nde 0.8580, Massachusetts Veri Seti'nde 0.5520 ve INRIA Veri Seti'nde 0.7140 IoU metriği değerleri elde etmiştir. Modelin Massachusetts'de WHU'ya göre daha düşük doğrulukta tespit yapmasının nedeni Massachusetts'de düşük çözünürlükteki görüntülerin ve etiketlerin olmasıdır. INRIA Veri Seti, WHU ile benzer çözünürlükte

görüntülerden oluşmasına karşın etiket kalitesi düşüktür. Bu da INRIA ve WHU arasındaki 0.144'lük IoU doğruluk farkının sebebinin açıklanmaktadır.

Jiwani ve ark., (2021)'de, MYK bantlarına sahip uydu görüntülerinde otomatik bina çıkarımı için Res-Net omurgasına sahip modifiye DeepLabv3+ mimarisini önermiş ve bu mimariyi kullanarak SpaceNet V2 Veri Seti'nde 0.8900, CrowdAI Veri Seti'nde ise 0.8790 IoU doğrulukları elde etmişlerdir. Çalışmada benzer doğrulukların elde edilmesinin nedeni CrowdAI Veri Seti'nin, SpaceNet V2 Veri Seti'nden sadeleştirilerek türetilmesidir.

Bakirman ve ark., (2022)'de, binaların segmentasyonu için İstanbul V1 Veri Seti'ni oluşturmuş ve bina segmentasyonu için ideal mimarileri, kodlayıcıları ve hiper parametreleri araştırmıştır. Çalışmada, ImageNet veri seti ile önceden eğitilmiş SE-ResNeXt101 kodlayıcı kullanılan UNet++ mimarisinde en yüksek doğruluk elde edilmiştir. İstanbul Veri Seti'nin kullanılabilirliğini ve doğruluğunu test etmek için Massachusetts ve INRIA gibi literatürde kabul görmüş veri setleri kullanılarak çapraz doğrulama (cross evaluation) yapılmıştır. Doğrulama sonucunda, UNet++ mimarisi üzerinde İstanbul V1 Veri Seti'nde 0.9380, INRIA Veri Seti'nde 0.7539 ve Massachusetts Veri Seti'nde 0.9253 IoU değerlerini elde etmiştir.

Luo ve ark., (2023)'de, veri setlerinde genelleme ve çeşitlilik faktörlerinin bina çıkarımındaki etkisini gözlemlemek için AT-MAFCN mimarisini kullanarak WHU-Mix Veri Seti'ni farklı bina veri setleri ile test etmiştir. Çalışma sonucunda Massachusetts'te 0.2237, CrowdAI'da 0.4421, WHU'da 0.5133, INRIA'da 0.5246 ve WHU-Mix'de ise 0.5889 IoU metrik değerlerini elde etmiştir. Bu sonuçlar doğrultusunda yüksek doğrulukta bina çıkarımının hem büyük veri ile hem de çeşitlilik açısından zengin olan verilerle sağlandığını tespit etmiştir.

He ve ark., (2022b)'de, bina çıkarımında veri setlerindeki genelleme problemini çözmek için çalışmalarında farklı mekansal çözünürlüğe ve spektral bantlara sahip farklı tarihli veri setlerini kullanmıştır. Çalışma sonunda, HRNet V2 mimarisi ile WHU'da (30 cm) 0.6774, Waterloo'da (12 cm) 0.7663 ve Waterloo'da (30 cm) 0.3055 IoU değerlerini elde edilmiştir. Buna ek olarak, Waterloo Veri Seti'nde mekansal çözünürlük düşürülerek yapılan segmentasyon sonucunda IoU değerinde %46 azalma tespit edilmiştir. Ayrıca test verisi ile eğitim verisinin benzer içerikte olmasının model performansını arttırdığı gözlemlenmiştir.

Yukarıda verilen karşılaştırmalı çalışmalar bina çıkarımını etkileyen faktörlerin doğruluk üzerindeki etkisini ele almıştır. Yapılan deneyler ve testler sonucunda, veri setlerindeki etiketlerin kalitesinin yüksek olmasının yanı sıra, veri çeşitliliğinin ve miktarının fazla oluşunun modelin bina çıkarımındaki performansını pozitif anlamda etkilediği görülmüştür.

#### 4. Sonuç ve Öneriler

Bina çıkarımı, risk yönetimi, veri tabanlarının güncellenmesi, kent planlaması, değişim analizi gibi konularda önemli rol oynamaktadır. Özellikle afet sonrası arama-kurtarma işlemlerinin hızlı ve doğru

şekilde yapılabilmesi için binaların konumlarının otomatik tespiti hayati önem taşır. Binaların otomatik tespiti, afetten kaynaklanan ihtiyaçların konum bazlı belirlenmesi ve izlenmesi gibi afet yönetiminde yardımcı olur. Bu kapsamda araştırmacılar tarafından çeşitli veri setleri oluşturulmuş ve metodolojiler geliştirilmiştir. Bu kısımda, önceki bölümlerde açıklanan açık kaynaklı bina veri setlerinin çözünürlük, kapsama alanı, çeşitlilik, genelleme yeteneği ve etiket kalitesi açısından değerlendirilmeler yer almaktadır.

Literatürdeki açık kaynaklı bina veri setleri incelendiğinde, santimetre seviyesinden 4 metreye kadar mekansal çözünürlükte verilerin bulunduğu görülmektedir. Binaların yüksek doğrulukta belirlenebilmesi ve haritalarının oluşturulması için bina sınırlarının görüntülerde net olarak görülmesi gerekir, bu da görüntülerin yüksek mekansal çözünürlüğe sahip olması anlamına gelir. Tablo 1'de, en yüksek mekansal çözünürlüğe sahip 3 veri seti sırasıyla ISPRS (5 ve 9 cm), Open AI (7 cm) ve AIRS (7.5 cm) şeklindedir. ISPRS veri seti, en yüksek mekansal çözünürlüğe sahip olmasına rağmen çok küçük iki alan için oluşturulmuştur. Open Building Veri Seti ise kıta ölçeğinde bir çalışmadır ve Tablo 1'deki en büyük kapsama alanına sahip veri setidir. Kapsama alanı açısından Open Building Veri Seti'ni sırasıyla 40.000 km<sup>2</sup> ile SpaceNet7 ve 5.000 km<sup>2</sup> ile xBD takip etmektedir.

Otomatik bina tespiti için geliştirilen veri setlerinin çeşitlilikten yoksun olması, modellerin ve verilerin genelleme yeteneğini kısıtlar. Bu problemin aşılması için yapısal farklılıkları bünyesinde barındıran veri setlerine gereksinim vardır. Yapısal farklılıklar bazen coğrafi konum çeşitliliği ile sağlanabileceği gibi bazen de mimari çeşitlilikler ile de sağlanabilir. Böylece, yapısal çeşitlilik içeren bir veri seti üzerinde eğitilen model kullanılarak farklı veri setlerinde otomatik bina segmentasyonu mümkün olur. INRIA, SpaceNet V2, CrowdAI, WHU, xBD, SpaceNet 7, WHU-Mix, Open Building ve İstanbul V1 veri setleri çeşitli coğrafi alanlardan görüntüler bulundurması sebebiyle yapısal farklılıklar içeren bina etiketlerinden oluşmaktadır. İstanbul V1, çeşitlilik bulunduran diğer veri setlerine kıyasla kapsama alanı daha küçük olmasına rağmen yapısal çeşitliliğin çok yüksek olduğu mimari yapıları içerir.

Bina çıkarma modellerinin performansını daha doğru ve pratik bir şekilde değerlendirmek için, test verilerinin eğitim verileriyle (örneğin, farklı şehirlerden eğitim ve test verileri) belirli bir dağılım farklılığına sahip olması gerekir. Örneğin, eğitim ve test verileri, Massachusetts Veri Seti ve WHU Veri Seti'ndeki aynı şehirdendir ve bu nedenle çeşitlilikten yoksundur. INRIA Veri Seti, farklı şehirlerden bir eğitim seti ve bir test seti sağlasa da test seti etiketleri açık bir şekilde mevcut değildir. Test etiketlerinin bulunmaması durumunda sadece modelin eğitim performansından bahsedilebilir.

Binaların tespitinde görüntü geometrisi de önem taşır ancak afet gibi durumlarda algılama açısı ya da bulutluluk gibi faktörlerin ideal olması oldukça zordur. Bu nedenle veri setlerinin afet gibi acil durumlarda da kullanılabilmesi için farklı algılama koşullarında ve farklı afetlerden örnekler içerecek şekilde oluşturulması da önem taşır. Optik görüntüler dışında YAR verileri ya da nadir dışındaki bakış açılarının olduğu bina veri



setlerinin varlığı çok önemlidir. Örneğin, SpaceNet4 Veri Seti bakış açısına göre üç farklı aralıkta uydu görüntülerinden oluşmaktadır ve bu durum veri setinin genelleme yeteneğini artırmaktadır. YAR ile gece, gündüz, hava koşullarından bağımsız olarak algılama yapılabilmesi özellikle afet durumunda hızlı bilgi çıkartılması açısından optik algılayıcılara göre büyük avantaj sağlar. Yüksek çözünürlükteki optik ve YAR görüntülerinden oluşan SpaceNet 6 Veri Seti ile bu veri kombinasyonu sayesinde, yalnızca tek bir veri türüyle eğitilenlerden daha yüksek doğruluklu sonuçlar elde edildiği görülmektedir (Shermeyer ve ark., 2020).

Veri setlerindeki etiketlerinin kalitesi, doğruluğu etkileyen en önemli parametredir. Bina etiketleri manuel, otomatik veya yarı-otomatik olarak hazırlanabilir. Etiketler ArcGIS, QGIS gibi harita programları ile yapılabileceği gibi LabelImg, Hyper Label, Roboflow gibi arayüzler kullanılarak da oluşturulabilir. Veri setinde bina sınırlarının manuel etiketlenerek oluşturulması zor ve zaman alıcı bir işlemdir. Bu şekilde oluşturulmuş veri setlerine erişim de kısıtlıdır. Otomatik ve yarı otomatik yöntemler ise genellikle kaliteli etiket sağlamaz. Bina etiketleri ISPRS, WHU, SpaceNet 7, LandCover.ai, SemCity Toulouse, AIRS, Waterloo Bina Veri Seti, İstanbul V1 elle; SpaceNet V1, SpaceNet V2 veri setlerinde yarı otomatik yöntemlerin desteğiyle elle; Massachusetts, Open Bina Veri Seti OSM tabanlı; INRIA, CrowdAI, SpaceNet 6, Open Spatial Data ise açık kaynaklı bina ayak izleri kullanılarak oluşturulmuştur. Massachusetts, INRIA, SpaceNet (SpaceNet V1-V2) ve OpenAI gibi veri setlerinde, bazı bina etiketleri düşük kalitededir. Luo ve ark., (2023)'de düşük kalitedeki etiketlerin model üzerindeki negatif etkisini gözlemlemek için, INRIA Veri Seti'ndeki yanlış etiketleri manuel düzeltip, orijinal ve yeniden düzenlenen INRIA Veri Seti'ni kullanarak eğitim işlemi gerçekleştirmiştir. Eğitim sonucunda etiketleri yeniden düzeltilen veri seti ile IoU metriğinde %20 iyileşme olduğu tespit edilmiştir. Verileri etiketleyen kişilerin uzmanlık seviyesi, konu hakkındaki yetkinliği gibi faktörler etiket kalitesini büyük oranda etkiler. Etiketlerin analizi sürecinde, bağımsız doğrulayıcılar tarafından kontrol edilmesi de dikkat edilmesi gereken bir başka husustur. Tüm bunlara ek olarak, bazı veri setlerinde kaliteli etiket üretmenin zorluğundan kaynaklı, sadece eğitim ve doğrulama verileri etiketli olarak sunulmaktadır. Test etiketlerinin bulunması durumunda test için performans değerlendirmesi yapılabilirken, aksi halde bu değerlendirmeler yapılamaz. Doğal olarak model eğitiminin test doğruluklarının kıyaslanabilmesi için etiketli test veri setlerine ihtiyaç vardır.

Uzaktan algılama görüntülerinden binaların otomatik çıkarılması amacıyla veri seti üretilirken mekânsal çözünürlüğü yüksek görüntülere ihtiyaç bulunmaktadır. Yüksek mekânsal çözünürlük, etiketleme sırasında bina sınırlarının hassas olarak belirlenmesine olanak sağlar. Veri setinde, bina etiketleri yüksek kalitede oluşturulmalıdır. Ayrıca, farklı türdeki binaların etiketlenmesi ve kaliteli etiket sayısının fazla olması model eğitiminde sonuç doğruluğunu önemli ölçüde etkiler. Bina veri setlerinin oluşturulmasında çeşitlilik içeren, genelleme yeteneği yüksek ve doğru etiketlenmiş verilerin kullanılması sonuç doğruluğunu arttıracaktır.

## Bilgilendirme/Teşekkür

Yazarlar, Uydu Haberleşme ve Uzaktan Algılama UYG-AR Merkezi'ne desteği için teşekkür etmektedir.

## Araştırmacıların katkı oranı

**Esra Özaydın:** Literatür taraması, Makale yazımı, Analiz; **Burcu Amirgan:** Literatür taraması, Makale yazımı, Analiz; **Gülşen Taşkın:** Düzenleme, Kontrol ve Yorum; **Nebiye Musaoğlu:** Düzenleme, Kontrol ve Yorum.

## Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

## Kaynakça

- Akbulut, Z., Özdemir, S., Acar, H., Dihkan, M., & Karşlı, F. (2018). Automatic extraction of building boundaries from high resolution images with active contour segmentation. *International Journal of Engineering and Geosciences*, 3(1), 36-42. <https://doi.org/10.26833/ijeg.373152>
- Amirgan, B., Awad, B., Erer, I., & Musaoğlu, N. (2022). A comparative study for building segmentation in remote sensing images using deep networks: Cscrs Istanbul building dataset and results. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 46, 1-6. <https://doi.org/10.5194/isprs-archives-XLVI-M-2-2022-1-2022>
- Atik, M. E., Duran, Z., & Özgünlük, R. (2022). Comparison of YOLO versions for object detection from aerial images. *International Journal of Environment and Geoinformatics*, 9(2), 87-93. <https://doi.org/10.30897/ijegeo.1010741>
- Azam, B., Khan, M. J., Bhatti, F. A., Maud, A. R. M., Hussain, S. F., Hashmi, A. J., & Khurshid, K. (2022). Aircraft detection in satellite imagery using deep learning-based object detectors. *Microprocessors and Microsystems*, 94, 104630. <https://doi.org/10.1016/j.micpro.2022.104630>
- Bakirman, T., Komurcu, I., & Sertel, E. (2022). Comparative analysis of deep learning based building extraction methods with the new VHR Istanbul dataset. *Expert Systems with Applications*, 202, 117346. <https://doi.org/10.1016/j.eswa.2022.117346>
- Bayramoğlu, Z., & Uzar, M. (2023). Performance analysis of rule-based classification and deep learning method for automatic road extraction. *International Journal of Engineering and Geosciences*, 8(1), 83-97. <https://doi.org/10.26833/ijeg.1062250>
- Boguszewski, A., Batorski, D., Ziemia-Jankowska, N., Dziedzic, T., & Zambrzycka, A. (2021). LandCover. ai: Dataset for automatic mapping of buildings, woodlands, water and roads from aerial imagery. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1102-1110.
- Chen, Q., Wang, L., Wu, Y., Wu, G., Guo, Z., & Waslander, S. L. (2019). Temporary removal: Aerial imagery for

- roof segmentation: A large-scale dataset towards automatic mapping of buildings. *ISPRS Journal of Photogrammetry and Remote Sensing*, 147, 42-55. <https://doi.org/10.1016/j.isprsjprs.2018.11.011>
- Duman, H. S., & Başaraner, M. (2022). Şekil göstergeleri ve topluluk öğrenmesi sınıflandırma algoritmaları ile bina detaylarının şekil karmaşıklık analizi. *Geomatik*, 7(3), 197-208. <https://doi.org/10.29128/geomatik.947334>
- Erdem, F., & Avdan, U. (2020). Comparison of different U-net models for building extraction from high-resolution aerial imagery. *International Journal of Environment and Geoinformatics*, 7(3), 221-227. <https://doi.org/10.30897/ijegeo.684951>
- Gerke, M., Rottensteiner, F., Wegner, J., Sohn, G., 2014. ISPRS Semantic Labeling Contest. <https://doi.org/10.13140/2.1.3570.9445>
- Open Cities AI Challenge Dataset. Version 1.0, (2023). Radiant MLHub. <https://mlhub.earth/10.34911/rdnt.f94cxb>
- Glinka, S., Owerko, T., & Tomaszewicz, K. (2022). Using open vector-based spatial data to create semantic datasets for building segmentation for raster data. *Remote Sensing*, 14(12), 2745. <https://doi.org/10.3390/rs14122745>
- Gupta, R., Goodman, B., Patel, N., Hosfelt, R., Sajeev, S., Heim, E., ... & Gaston, M. (2019a). Creating xBD: A dataset for assessing building damage from satellite imagery. *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*, 10-17.
- Gupta, R., Hosfelt, R., Sajeev, S., Patel, N., Goodman, B., Doshi, J., ... & Gaston, M. (2019b). xbd: A dataset for assessing building damage from satellite imagery. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.1911.09296>
- He, H., Gao, K., Tan, W., Wang, L., Chen, N., Ma, L., & Li, J. (2022b). Super-resolving and composing building dataset using a momentum spatial-channel attention residual feature aggregation network. *International Journal of Applied Earth Observation and Geoinformation*, 111, 102826. <https://doi.org/10.1016/j.jag.2022.102826>
- He, H., Jiang, Z., Tan, W., Cai, Y., Fatholahi, S. N., Gao, K., ... & Li, J. (2021). Waterloo Building Dataset: A large-scale very-high-spatial-resolution image dataset for building rooftop extraction. *Abstracts of the ICA*, 3, 1-2. <https://doi.org/10.5194/ica-abs-3-105-2021>
- He, H., Jiang, Z., Gao, K., Narges Fatholahi, S., Tan, W., Hu, B., ... & Li, J. (2022a). Waterloo building dataset: A city-scale vector building dataset for mapping building footprints using aerial orthoimagery. *Geomatica*, 75(3), 99-115. <https://doi.org/10.1139/geomat-2021-0006>
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Ji, S., Wei, S., & Lu, M. (2018). Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1), 574-586. <https://doi.org/10.1109/TGRS.2018.2858817>
- Jiwani, A., Ganguly, S., Ding, C., Zhou, N., & Chan, D. M. (2021). A semantic segmentation network for urban-scale building footprint extraction using RGB satellite imagery. *Computer Vision and Pattern Recognition* <https://doi.org/10.48550/arXiv.2104.01263>
- Karhunen, J., Raiko, T., & Cho, K. (2015). Unsupervised deep learning: A short review. *Advances in Independent Component Analysis and Learning Machines*, 125-142. <https://doi.org/10.1016/B978-0-12-802806-3.00007-5>
- Luo, M., Ji, S., & Wei, S. (2023). A diverse large-scale building dataset and a novel plug-and-play domain generalization method for building extraction. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 16, 4122-4138. <https://doi.org/10.1109/JSTARS.2023.3268176>
- Maggiore, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2017). Can semantic labeling methods generalize to any city? The Inria aerial image labeling benchmark. 2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 3226-3229. <https://doi.org/10.1109/IGARSS.2017.8127684>
- Mehran, A., Tehsin, S., & Hamza, M. (2023). An effective deep learning model for ship detection from satellite images. *Spatial Information Research*, 31(1), 61-72. <https://doi.org/10.1007/s41324-022-00482-1>
- Mnih, V. (2013). Machine learning for aerial image labeling. University of Toronto (Canada).
- Mohanty, S. P., Czakon, J., Kaczmarek, K. A., Pyskir, A., Tarasiewicz, P., Kunwar, S., ... & Schilling, M. (2020). Deep learning for understanding satellite imagery: An experimental survey. *Frontiers in Artificial Intelligence*, 3, 534696. <https://doi.org/10.3389/frai.2020.534696>
- URL-1: [https://haberler.itu.edu.tr/docs/default-source/default-document-library/2023\\_itu\\_depren\\_on\\_raporu.pdf?sfvrsn=bf82d8e5\\_](https://haberler.itu.edu.tr/docs/default-source/default-document-library/2023_itu_depren_on_raporu.pdf?sfvrsn=bf82d8e5_)
- URL-2: <https://www.isprs.org/education/benchmarks/Urb anSemLab/semantic-labeling.aspx>
- URL-3: <https://www.cs.toronto.edu/~vmnih/data/>
- URL-4: <https://project.inria.fr/aerialimagelabeling/>
- URL-5: <https://competitions.codalab.org/competitions/20100>
- URL-6: <https://www.kaggle.com/datasets/adrianboguszewski/landcoverai>
- URL-7: <https://www.kaggle.com/datasets/atilol/aerialimageryforroofsegmentation>
- URL-8: <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/EXRA2V>
- URL-9: [https://github.com/sajmonogy/keras\\_segmentation\\_models](https://github.com/sajmonogy/keras_segmentation_models)
- URL-10: <https://spacenet.ai/spacenet-buildings-dataset-v1/>
- URL-11: <https://spacenet.ai/spacenet-buildings-dataset-v2/>

- URL-12: <https://www.aicrowd.com/challenges/mapping-challenge>
- URL-13: <https://spacenet.ai/off-nadir-building-detection/>
- URL-14: <https://xview2.org/dataset>
- URL-15: <https://spacenet.ai/sn6-challenge/>
- URL-16: <https://spacenet.ai/sn7-challenge/>
- URL-17: <http://rs.ipb.uni-bonn.de/data/semcity-toulouse-data-access/>
- URL-18: <https://sites.research.google/open-buildings/#download>
- URL-19: [http://gpcv.whu.edu.cn/data/building\\_dataset.html](http://gpcv.whu.edu.cn/data/building_dataset.html)
- URL-20: [http://gpcv.whu.edu.cn/data/whu-mix\(raster\)/whu\\_mix%20\(raster\).html](http://gpcv.whu.edu.cn/data/whu-mix(raster)/whu_mix%20(raster).html)
- URL-21: <https://www.geoportal.gov.pl/>
- Ozturk, O., Saritürk, B., & Seker, D. Z. (2020). Comparison of fully convolutional networks (FCN) and U-Net for road segmentation from high resolution imageries. *International Journal of Environment and Geoinformatics*, 7(3), 272-279. <https://doi.org/10.30897/ijegno.737993>
- Patel, K., Bhatt, C., & Mazzeo, P. L. (2022). Deep learning-based automatic detection of ships: An experimental study using satellite images. *Journal of Imaging*, 8(7), 182. <https://doi.org/10.3390/jimaging8070182>
- Perihanoğlu, G. M., Özerman, U., & Şeker, D. Z. (2018). Kenar algılama ve morfoloji operatörleri kullanılarak detay çıkarımı üzerine bir uygulama. *Geomatik*, 3(2), 120-128. <https://doi.org/10.29128/geomatik.358957>
- Ps, P., & Aithal, B. H. (2023). Building footprint extraction from very high-resolution satellite images using deep learning. *Journal of Spatial Science*, 68(3), 487-503. <https://doi.org/10.1080/14498596.2022.2037473>
- Raghavan, R., Verma, D. C., Pandey, D., Anand, R., Pandey, B. K., & Singh, H. (2022). Optimized building extraction from high-resolution satellite imagery using deep learning. *Multimedia Tools and Applications*, 81(29), 42309-42323. <https://doi.org/10.1007/s11042-022-13493-9>
- Roscher, R., Volpi, M., Mallet, C., Drees, L., & Wegner, J. D. (2020). SemCity Toulouse: A benchmark for building instance segmentation in satellite images. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 5, 109-116. <https://doi.org/10.5194/isprs-annals-V-5-2020-109-2020>
- Sarker, I. H. (2021). Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 2(6), 420. <https://doi.org/10.1007/s42979-021-00815-1>
- Saritürk, B., Bayram, B., Duran, Z., & Seker, D. Z. (2020). Feature extraction from satellite images using segnet and fully convolutional networks (FCN). *International Journal of Engineering and Geosciences*, 5(3), 138-143. <https://doi.org/10.26833/ijeg.645426>
- Shermeyer, J., Hogan, D., Brown, J., Van Etten, A., Weir, N., Pacifici, F., ... & Lewis, R. (2020). SpaceNet 6: Multi-sensor all weather mapping dataset. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition workshops*, 196-197.
- Sirko, W., Kashubin, S., Ritter, M., Annkah, A., Bouchareb, Y. S. E., Dauphin, Y., ... & Quinn, J. (2021). Continental-scale building detection from high resolution satellite imagery. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.2107.12283>
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). A survey on deep transfer learning. *Artificial Neural Networks and Machine Learning-ICANN 2018: 27<sup>th</sup> International Conference on Artificial Neural Networks*, Rhodes, Greece, October 4-7, 2018, *Proceedings, Part III* 27, 270-279. [https://doi.org/10.1007/978-3-030-01424-7\\_27](https://doi.org/10.1007/978-3-030-01424-7_27)
- Van Etten, A., Hogan, D., Manso, J. M., Shermeyer, J., Weir, N., & Lewis, R. (2021). The multi-temporal urban development spacenet dataset. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 6398-6407.
- Van Etten, A., Lindenbaum, D., & Bacastow, T. M. (2018). Spacenet: A remote sensing dataset and challenge series. *Computer Vision and Pattern Recognition*. <https://doi.org/10.48550/arXiv.1807.01232>
- Wang, X., Liu, Y., & Xin, H. (2021). Bond strength prediction of concrete-encased steel structures using hybrid machine learning method. *Structures*, 32, 2279-2292. <https://doi.org/10.1016/j.istruc.2021.04.018>
- Weir, N., Lindenbaum, D., Bastidas, A., Etten, A. V., McPherson, S., Shermeyer, J., ... & Tang, H. (2019). Spacenet mvoi: A multi-view overhead imagery dataset. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 992-1001.
- Yin, J., Wu, F., Qiu, Y., Li, A., Liu, C., & Gong, X. (2022). A multiscale and multitask deep learning framework for automatic building extraction. *Remote Sensing*, 14(19), 4744. <https://doi.org/10.3390/rs14194744>



© Author(s) 2024. This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>