

İHA GÖRÜNTÜLERİNDEN DERİN ÖĞRENME YAKLAŞIMIYLA KAÇAK YAPILAŞMA TESPİTİ

Hande N. AKKOÇ¹, Mustafa O. SAMUR¹, Işıl H. AKTAR¹, Özhan TAŞDEMİR¹, Uluğ BAYAZIT²

¹ İND Bilişim, 34662, İstanbul, hande.sen@indbilisim.com.tr

² İstanbul Teknik Üniversitesi, Bilgisayar ve Bilişim Fakültesi, Bilgisayar Mühendisliği Bölümü, Maslak/İstanbul, ulugbayazit@itu.edu.tr

ÖZET

Kaçak yapılaşma sonucunda afete karşı dayanıksız binaların çoğalması, doğal mirasın ve tarım alanlarının kaybolması, plansız şehirleşme ve altyapı yetersizlikleri gibi pek çok sorun ortaya çıkmaktadır. Ancak kaçak yapıların tespiti doğrudan şikâyet olmadığı sürece yetkililerin sokak sokak dolaşıp teftiş etmesini gerektiren zahmetli ve çok uygulanamayan bir yöntemdir. Bu çalışma kapsamında kaçak yapılaşma sorununa bir çözüm olarak İHA görüntülerinin derin öğrenme (Mask-RCNN) tabanlı bilgisayarlı görü teknikleriyle işlenip kaçak yapı ve katların yetkililere otomatik olarak bildirileceği bir sistem üzerinde çalışılmıştır. Öncelikle İHA'ya yerleştirilen mesafe ölçüm sensörüne sahip bir kamera ile İstanbul'da bir pilot bölge üzerinde İHA uçuşları gerçekleştirilip bina görüntüleri toplanmıştır. Toplanan görüntüler üzerinde binalar ve pencereler etiketlenerek bir eğitim verisi oluşturulmuştur. Mask RCNN ile geliştirilen modelin kat tespiti konusunda iyi sonuçlar verdiği görülmüştür. İncelenen binanın koordinatları lazer mesafe ölçüm sensörü yardımıyla belirlenmekte ve bu koordinatlar belediye veri tabanından ilgili binanın kat sayısı bilgisini çekmekte kullanılmaktadır. Tespit sonuçlarının belediyeden çekilen verilerle karşılaştırılmasıyla kaçak bir durum olup olmadığı tespit edilmektedir. Eğer belediye veri tabanında söz konusu koordinatlara ait bir bina kaydı bulunmuyorsa, binanın kaçak olabileceği; eğer kayıt varsa, fakat gelen bilgilerle tespit ettiğimiz kat sayısı arasında bir uyumsuzluk bulunmuyorsa da binanın kaçak bir kata sahip olabileceği uyarısı oluşturulmaktadır. Önerilen yöntem çalışmalarda %90,7 kat tespit başarısına ulaşarak, kaçak yapılaşmanın tespitinin otomatikleştirilmesine önemli katkı sağlamaktadır.

Anahtar Sözcükler: Akıllı şehirler, CBS, insansız hava araçları, derin öğrenme

ABSTRACT

DETECTING ILLEGAL CONSTRUCTION FROM DRONE IMAGES WITH DEEP LEARNING

Many problems arise due to illegal construction, such as the proliferation of buildings that are not resistant to disasters, the loss of natural heritage and agricultural areas, unplanned urbanization, and infrastructure deficiencies. However, detecting illegal buildings by manual inspection is a laborious and infeasible process. To detect illegal construction automatically, we propose a deep learning based method that processes drone images and reports illegal structures to the authorities. First, a drone, using a camera with a laser range finder sensor, was flown over a selected area in Istanbul and building images were collected. The buildings and windows were labelled in the collected images, and deep learning models using Faster RCNN and Mask RCNN were trained. The model developed with Mask RCNN gave better results in floor detection. For each detected building, its municipal records were extracted from the municipality database using the coordinates of the building determined by the laser range finder, and consistency between claimed and determined floor information was checked. If there is no building record at the given coordinates in the municipality database, the building may be illegal. If there is a record, but there is a discrepancy between the municipality information and our detection, the building may have one or more illegal floors. In both cases, a warning is generated to be sent to the authorities. The proposed method which achieves an accuracy of 90.7% is a powerful tool for detecting illegal construction.

Keywords: Smart cities, GIS, UAV, deep learning

1. GİRİŞ

İnsan nüfusunun hızlı artışı; iş, eğitim, sağlık imkanlarının büyük kentlerde yoğunlaşmış olmasıyla birleşince hızlı bir şehre göç dalgası oluşturmuştur. Bu hızlı göçler yüksek miktarda barınma ihtiyacını beraberinde getirerek kaçak yapılaşma sorununu ortaya çıkarmıştır. 1998 yılında bir çalışmada (Özşenol, 1998) İstanbul, İzmir ve Ankara gibi metropoliten şehirler baz alındığında kent nüfusunun dakikada bir kişi arttığı, bu artışın doğal oranda yılda 100.000'i doğal nüfus artışıyla 400.000'i göçlerle beraber ise 500.000'i bulduğu belirtilerek bu artışla doğru oranda barınma imkanı sağlamak için her yıl yaklaşık 100.000 ile 125.000 arası yeni konuta ihtiyaç duyulduğu söylenmiştir. Araştırmanın devamında ise bu ihtiyacın İstanbul'da her gün yapılan 220 yasadışı konut ile karşılandığı belirtilmektedir. 1998 yılında bu konudaki çalışmalara sebep olan sorun günümüzde de devam etmektedir. T.C. Kalkınma Bakanlığı (2018) 11. Kalkınma Planı'nda yer alan Konut Politikaları Bilgilerine göre tanımlanan ruhsatsız ve imar mevzuatına aykırı yapılar, afetlere karşı dayanıksız binalar, tarımsal ve tarihi alanların kaybı, plansız şehirleşme ve altyapı yetersizliği gibi birçok riske neden olmaktadır. Bu yapılar, yerel yönetimlerin en ciddi sorunlarının arasında yer almaktadır (Kurtar, 2017).

Kaçak yapılaşma, sadece Türkiye’de değil, hızla kentleşmenin gerçekleştiği birçok ülkede de yer almaktadır. Sırbistan’da yapılan bir araştırmada (Grubovic, 2006) 1990’larda genel ekonomik ortamın, siyasi tepki eksikliğinin ve konut teminine uygun hükümet müdahalesinin eksikliğinin bir sonucu olarak konut kıtlığının Belgrad’da kritik hale geldiğinden ve vatandaşların kaçak yapılaşma yoluna başvurduğundan bahsedilmiştir. Zanfi (2013) ise İtalya’da kaçak yapı sorununun olduğunu hatta devletin bunun önüne geçmek için af yasası çıkardığını belirtmiştir. Rusya’da yapılan bir araştırmada (Ostankovich ve Afanasyev, 2018) uydu görüntülerinden kaçak bina tespitinde devlet denetiminin otomatikleştirilmesi için görüntü işleme tekniklerini derin öğrenme araçlarıyla birleştiren bir metodoloji önerilmektedir.

Projemiz, kaçak kat ve kaçak bina sorununun çözümü için maliyetin ve insan gücü kaynaklarının optimize edilmesini sağlarken vatandaşlara belediyeler tarafından verilen kamu hizmetlerinde hız, doğruluk ve kalitenin artırılmasını hedeflemektedir. Bu doğrultuda İHA görüntüleri üzerinde yapay zekâ yaklaşımlarının kullanılarak binaların tespitinin yapılması, katlarının sayılması ve belediyeden gelen coğrafi bilgi sistemi (CBS) bilgileriyle kıyaslanarak kaçak yapıların keşfedilmesi hedeflenmiştir. Bu sayede denetim ve kapsam artırılırken iş yükü azaltılacak, insan kaynağı maliyetleri düşürülerek verimi artırılabilecektir. Usulsüzlüklerin erken tespiti ile hızlı müdahale mümkün hale gelecek, bu sayede vatandaş ve personel memnuniyeti artırılabilecektir.

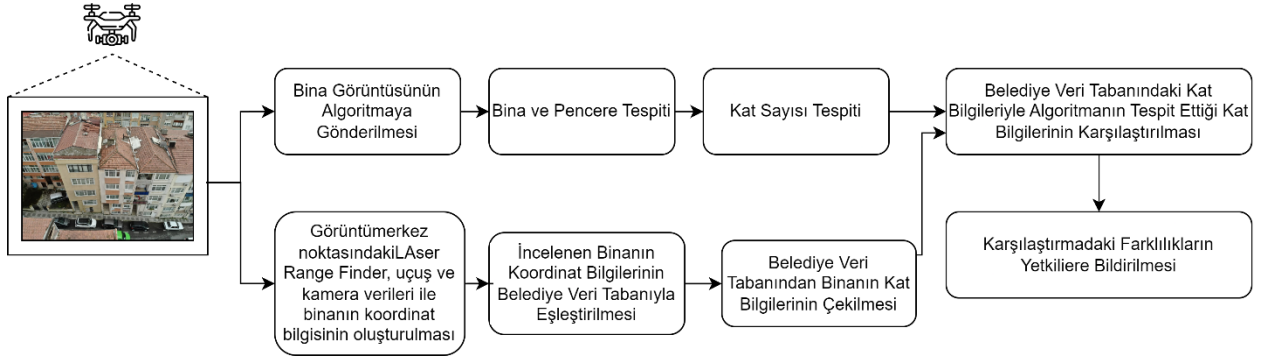
1.1 Literatür Çalışması

Bina tespiti alanında yapılmış çalışmalar, farklı amaçlar ve farklı veri setlerini içermektedir. Bochkarev ve Smirnov (2019), Rusya’da haritaların yol görüntülerinden alınan resimlerle binalar üzerindeki illegal objeleri ve reklam panolarını Faster RCNN modeli kullanarak tespit etmiştir. Bu çalışmada ayrıca mevzuata uygunluğunun kontrolü adına bina pencereleri, demir teller ve reklam panoları da tespit edilmiştir. Touzani vd. (2021) binanın ayak izini bulmak için İHA ile 35 derece açıyla 30 metre yukarıdan farklı yönlerde çekilmiş bina resimleriyle 3B nokta bulutu yöntemi kullanarak bina ayak izi tespiti yapmıştır. Nokta bulutunu kullanan bir başka çalışmada ise U-net bazlı piksel bazında segmentasyon yardımıyla büyük boyutlu ve yüksek çözünürlüklü İHA görüntüleri üzerinde binalar gözlemlenmiş ve yönetmeliklere aykırı bir durum olup olmadığı kontrol edilmiştir (Jiang vd., 2021). Aynı çalışmada yol tespiti, kaldırım çatlama tespiti, bina cephe penceresi tespiti gibi senaryolar da yer almaktadır. Cohen vd. (2016) bina tespitini uydu görüntüleri ile yapay zeka tabanlı bir obje tespiti ile yapmış, bina kontür hizalaması yöntemi kullanarak sınıflandırma başarısının arttırmıştır. Uydu görüntüsü kullanılarak yapılmış başka bir çalışmada ise yüksek çözünürlüklü görüntüler, 28x28 piksel boyutunda parçalara bölünerek derin evrişimli sinir ağlarında eğitilmiş böylelikle otomatik bina tespit sistemi oluşturulmuştur (Vakalopoulou vd., 2015). İçerisinde 200 bina bulunan 12 büyük ortofoto görüntüsü kullanılarak yapılmış bir bina tespiti çalışmasında (Dornaika vd, 2016) yerel ikili örüntü (Local Binary Patterns - LBP) yöntemi kullanılmış ve yarı otomatik etiketleme sistemi uygulanmıştır. Bu sistemde algoritmanın otomatik belirlediği segmentasyonlar, elle yapılmış etiketler ile belirli bir miktarda örtüşüyorsa etiket doğru kabul edilmiştir.

Hindistan’da, yasa dışı binaların önüne geçebilmek için yapılmış bir çalışmada (Kiran ve Rithvik, 2020) ise kontrol bölgelerinde İHA ile farklı zamanlarda gerçekleştirilen uçuşlarda toplanan görüntülerin kıyaslanması yönünde bir uygulama yapılmıştır. Görüntüler, açık havada, çatıdan 6.10 metre yukarıdan ve en az 8-10 megapiksel çözünürlükte çekilmiştir. Çalışma sonucunda oluşturulan Lidar CityGML ve KOMPSAT-3 nDSM veriler kıyaslamasıyla yasa dışı oluşturulan binaların tespitinde kullanılabilceği, ama son kararın yine bir insan elinden olması gerektiği savunulmuştur. Kaçak bina tespitine yönelik farklı bir yaklaşım ise LIDAR sensörü kullanılarak yapıların keşfedilmesi yönünde olmuştur (Varol vd, 2019). Söz konusu çalışmada İstanbul’un Üsküdar ilçesi üzerinde helikopterden çekilmiş görüntüler kullanılmıştır. Tespit sonuçları CBS’den alınan bilgiler ile kıyaslanarak binanın kaçak olup olmadığı kontrol edilmiştir. Bu çalışmada binalara çok yakın ve 2.30 metrenin üzerindeki ağaçlar sınıflandırmayı olumsuz etkilemiştir.

2. YÖNTEM

Kaçak katların bilgisayarlı görü yöntemleriyle tespiti özellikle Türkiye’deki binaların çeşitliliği göz önünde bulundurulduğunda zorlayıcı bir görev olabilmektedir. Bu çalışma kapsamında kaçak katların tespiti için bina görüntüleri üzerinden pencerelerin sayılmasıyla binanın kat sayısının belirlenmesi ve tespit edilen kat sayısının belediye verileriyle karşılaştırılmasıyla kaçak kat/yapı olup olmadığını tespiti hedeflenmiştir. Yöntemin planlanan akışı Şekil 1’de gösterilmektedir.



Şekil 1. Kaçak kat tespit akış şeması.


Bu doğrultuda yöntem bölümü içerisinde öncelikle verilerin toplanmasında kullanılan ekipmanlar ve stratejiler anlatıldıktan sonra kat tespit algoritması ve son olarak da belediye sistemiyle entegrasyon adımlarından bahsedilecektir.

2.1 Kullanılan Ekipman

Verilerin toplanması için DJI marka Matrice 300 RTK modeli İHA ile uçuşlar gerçekleştirilmiş ve İHA üzerine monte edilmiş olan DJI marka Zenmuse H20 modeli kamera ile fotoğraf çekimi yapılmıştır. 15 km iletişim mesafesine, 55 dakika uçuş kapasitesine ve IP45 sınıfı korumaya (toz gibi katı maddeler ve suya karşı) sahip olan DJI Matrice 300 RTK, -20°C/50°C aralığında, 54 km/h rüzgâr hızına kadar çalışabilmektedir. İHA'nın seçiminde rakiplerine göre sahip olduğu uzun uçuş süresi ve dayanıklılığı önemli bir kriter olmuştur. Kameranın seçiminde ise öncelikle İHA ile uyumlu modeller araştırılmış ve 20 MP yakınlaştırmalı kamera, 12 MP geniş açılı kamera, 3-1200 m aralığında lazer ile mesafe ölçümü sensörüne (LRF - Laser Range Finder) sahip olması nedeniyle Zenmuse H20 kamera üzerinde karar kılınmıştır.

2.2 Verilerin Toplanması

İstanbul'da seçilen pilot bölge üzerindeki İHA uçuşlarıyla 644 görüntü toplanmıştır. Verilerin toplanmasında dikkat edilmesi gereken en önemli nokta, pencerelerin bilgisayarlı görü algoritmalarıyla tanınmasını sağlayacak ideal çekim açısını yakalamaktır. Söz konusu açıda pencereler net bir şekilde gözükmeli ve perspektif etkisi mümkün olduğunca az olacak şekilde ayarlanmalıdır. Binanın cephe görüntüsünün en net şekilde alınabilmesi için İHA, caddenin bir tarafındaki binaların üzerinden uçarken karşı taraftaki binaların görüntüsünü çekmiştir. Özellikle dar sokaklarda alınacak görüntülerde perspektif etkisi kaçınılmazdır. Ancak perspektif etkisinin minimum tutulması için çekimlerde İHA, yatayda bina merkezinde, dikeyde ise çatı seviyesinin biraz üzerinde konumlandırılmıştır. LRF, görüntünün sadece merkez noktası için mesafe ölçümü yaptığından çekim yapılırken görüntünün merkezinde tek bir bina olacak şekilde ayarlanmalıdır. Sokakların genişliği ve binaların yüksekliği büyük farklılıklar gösterdiğinden İHA yüksekliği ve çekim açısı, bina cephesini en net alacak ve bütün pencereler gözükcek şekilde pilot tarafından ayarlanmaktadır. Söz konusu farklılıklar nedeniyle sabit bir yükseklik ve çekim açısı belirlenmesi ya da otopilot ile uçuş yapılması mümkün gözükmemektedir. Eğitim için video yerine fotoğraf formatında veri toplanmıştır. İdeal çekim açısı Şekil 2'de gösterilmektedir.



a) Temsili ideal senaryo gösterimi. b) İHA çekimleri üzerinde ideal senaryo gösterimi.

Şekil 2. İdeal çekim açısının a) temsili ve b) İHA çekimleri üzerinde gösterimi.


Binalar için farklı görüntüler alınarak, en az üçte ikisinin görünür olması sağlanmış, ağaç ve tabela gibi engellerle üçte birinden fazlası görünmeyen bina görüntüleri veri setine dahil edilmemiştir. Oluşturulan veri setindeki görüntülerin üzerinde “bina” ve “pencere” nesnelere etiketlenmiştir. Binalar etiketlenirken çatının üçgen kısmı da etikete dahil edilmiştir. Bitişik düzende yan yana binaların bulunduğu görüntülerde her bina ayrı ayrı etiketlenmiştir. Etiketlenecek nesnenin önünü kapatan engellerin nesne boyutunun üçte birinden az olduğu durumlarda engeller göz ardı edilerek gerçek sınırlar üzerinden etiketleme işlemi yapılmıştır. Toplanan görüntüler üzerinde etiketleme işlemleri tamamlandıktan sonra eğitim, doğrulama ve test verileri rastgele belirlenmiştir. Veri kümesinde bulunan farklı tiplerdeki bina örnekleri Şekil 3’te gösterilmektedir.



Şekil 3. Veri kümesinde bulunan farklı tipte bina örnekleri.

2.3 Önerilen Yöntem

Kaçak kat tespiti için bina üzerindeki pencerelerin sayılmasıyla kat sayısı tespiti yapılması planlanmıştır. Görüntüde birden fazla bina olsa da sadece görüntünün merkez noktasına denk gelen bina için tespit yapılmıştır. Sadece merkez noktada kalan binaya odaklanmamızın nedeni LRF’den gelen koordinat verilerinin görüntünün merkez noktasına ait olan koordinatlar olmasıdır. Öncelikle, görüntü üzerindeki bütün tahmin sonuçları arasında, görüntünün merkez noktasını içinde barındıran bina sınırının bulunmasıyla merkezde bulunan bina tespit edilmiştir. Ardından merkez binanın sınırları içinde kalan pencere koordinatları kullanılarak binaya ait pencereler belirlenmiş diğer binalardan gelebilecek pencereler filtrelenmiştir. Ardından bina sınırları boyunca dikey kesitler oluşturularak her bir kesitte bulunan pencere sayısı tespit edilmiştir. En fazla pencere sayısına sahip dikey kesitteki pencere sayısı, binanın kat sayısı olarak atanmıştır (Şekil 4). Perspektif, görüntüdeki engeller ve giriş katlarındaki kapı, dükkan kepenki gibi nesnelere ve bunların farklılıklarından dolayı binaların giriş katındaki pencerelerin kısmen gözükmemesi veya gözükmemesi, giriş katının tespit edilememesine neden olabilmektedir. Bu durumda, en büyük kat sayısını belirleyen kesitlerin en alt penceresinin bina maskesinin alt sınırına olan uzaklığı, pencereler arası (dikey) uzaklığın medyan değerinden büyükse, giriş katı temsilen fazladan 1 kat kesitten tespit edilmiş kat sayısına eklenmiştir.




Şekil 4. Kat tespit yöntemi.

2.4 Mask-RCNN ile bina ve pencere tespiti

Bina ve pencere tespiti için Detectron2 (Wu vd., 2019) kütüphanesinden COCO veri setiyle ön eğitilmiş Faster RCNN ve Mask RCNN sinir ağları kullanılarak modelimiz eğitilmiştir. Faster RCNN, nesne olmaya aday bölgelerin tespitinde seçici arama yaklaşımı yerine bölgesel öneri ağları (RPN: Regional Proposal Network) kullandığından önceki yaklaşımlara göre önemli ölçüde hızlıdır (Ren vd., 2015). Faster RCNN’de RPN ile aday bölgeler belirlendikten ve özellik haritaları çıkarıldıktan sonra bir yandan nesnenin sınıfı belirlenirken bir yandan da ideal sınırlayıcı kutular çizilir. Diğer bir deyişle Faster RCNN, her aday nesne için bir sınıf etiketi ve bir sınırlayıcı kutu olmak üzere 2 sonuç üretir. Bu durum bazen nesne kutularının kesişmesine (örneğin binaların iç içe geçmesi, bina

pencerelerin belirlenememesi gibi) neden olabilir. Mask RCNN ise Faster RCNN'in tam evrimsel ağlarla birleştirilmesiyle oluşturulur ve görüntüyü piksel seviyesinde anlamlandırarak semantik segmentasyon gerçekleştirir (He vd., 2017). Böylelikle sınırlayıcı kutunun ötesine geçerek her objenin maskesini çıkarabilir. Mask RCNN her aday nesne için nesne sınıfı, nesnenin sınırlayıcı kutusu ve nesnenin maskesi olmak üzere 3 sonuç üretmektedir. Şekil 5'te Mask RCNN ile gerçekleştirilen bir segmentasyon işleminin akışı görülmektedir. Öncelikle her bir ilgi alanından (Region of Interest - ROI) küçük bir özellik haritası çıkartılır. Bu özellikler haritaları evrimsel sinir ağlarından geçirilerek her bir pikselin ait olduğu sınıf belirlenir. Böylelikle her bir tespit objesi için segmentasyon işlemi gerçekleştirilmiş olur.



Şekil 5. Segmentasyon görevi için Mask RCNN mimarisi (He vd., 2017).

2.5 Model Sonuçlarının Değerlendirilmesi

Faster RCNN ve Mask RCNN yaklaşımları elimizdeki veri seti üzerinde, Çizelge 1'de verilen parametreler kullanılarak eğitilmiştir.

Çizelge 1. Detectron2 kütüphanesi Mask RCNN ve Faster RCNN Modellerinin Eğitimlerinde kullanılan parametreler

Model Parametreleri	Kullanılan Değer
solver.ims_per_batch	2
solver.base_lr	0.00025
solver.max_iter	3000
solver.steps	1500
solver.gamma	0.4
model.roi_heads.batch_size_per_image	128
model.roi_heads.num_classes	2

Eğitilen modeller test verileri üzerinde denenerek tespit edilen nesnelerin ne kadarının gerçekten tespit sınıfına ait olduğunu gösteren ortalama kesinlik (AP) ve aranan sınıfa ait örneklerin ne kadarının tespit edilebildiğini gösteren ortalama duyarlılık (Average Recall - AR) açısından karşılaştırılmıştır. Sonuçlar Mask RCNN'in, Faster RCNN'e kıyasla AP bakımından %4, AR bakımından ise %3 daha başarılı bir sonuç ortaya koyduğunu göstermektedir. Faster RCNN ve Mask RCNN modellerinden elde edilen AP ve AR sonuçlarının karşılaştırılması Çizelge 2'de gösterilmektedir. Söz konusu değerler pencere ve bina sınıfları birlikte hesaba katılarak bulunmuştur. Sınıflar özelinde ayrı ayrı AP değerlerine baktığımızda Mask RCNN ile eğitilen modelin Faster RCNN ile eğitilen modele kıyasla pencere sınıfı için %2, bina sınıfı için ise %4 daha başarılı olduğu görülmektedir. Pencere ve bina sınıfları özelinde AP sonuçlarının karşılaştırılması Çizelge 3'de gösterilmektedir.

Çizelge 2. Faster RCNN ve Mask RCNN modeli ortalama kesinlik (AP) ve ortalama duyarlılık (AR) sonuçlarının karşılaştırılması.

	Faster RCNN	Mask RCNN
Ortalama Kesinlik (AP)	0.63	0.67
Ortalama Duyarlılık (AR)	0.69	0.71

Çizelge 3. Faster RCNN ve Mask RCNN modellerinin pencere ve bina sınıfları özelinde ortalama kesinlik (AP) sonuçlarının karşılaştırılması.

	Faster RCNN Ortalama Kesinlik (AP)	Mask RCNN Ortalama Kesinlik (AP)
Pencere	0.65	0.67
Bina	0.62	0.66

Faster RCNN modelinden gelen sonuçlara baktığımızda her ne kadar binalar yüksek doğrulukla tahmin edilse de kamera perspektifi ve binanın önünü kapatan ağaç gibi nesnelere nedeniyle gerçek sınırlardan daha büyük bir alanı kapsayan bir sınırlayıcı kutu çizilmektedir. Öte yandan Mask RCNN ise doğrudan tespit ettiği bina sınırları üzerinden bir poligon çizerek maske oluşturmakta böylelikle daha hassas bir sonuç üretmektedir. Bu duruma bir örnek şekil 6'da gösterilmektedir. Söz konusu görselde bina üzerinde sırasıyla turuncu, mavi ve yeşil renklerle içi dolu maskeler şeklinde gösterilen sonuçlar Mask RCNN ile eğitilen modele aittir. Yine aynı renklerle çizilen dikdörtgen kutular ise Faster RCNN'den elde edilen sonuçları göstermektedir. Faster RCNN sonuçlarının genellikle binanın asıl alanından çok daha büyük alanı kapsadığı gözükmektedir. Bunun bir sonucu olarak mavi ve yeşil ile gösterilen bina örneklerinde olduğu gibi sınırlar arasında çakışma durumu ortaya çıkabilmektedir.



Şekil 6. Mask RCNN maskeleri ve Faster RCNN sınırlayıcı kutularıyla belirlenen bina sınırlarının karşılaştırılması.

Bina sınırlarını belirlemedeki hassaslığından ötürü, Mask RCNN modeli kullanılarak bina ve pencere tespiti yapılmıştır.

2.6 Belediye Sistemiyle Entegrasyon

Görüntü üzerinden binaya ait kat sayısının tespiti gerçekleştirildikten sonra kaçak bir kat ya da yapı olup olmadığının tespiti için belediye sistemleriyle entegrasyon gereklidir. Bunun için koordinat bilgileri girildiğinde belediye veri tabanında sorgu gerçekleştirip o koordinatlarla eşleşen binanın bilgilerini döndürecek bir API geliştirilmiştir. Kat sayısı tespiti yapılan merkez noktasındaki LRF sensör verisi yardımıyla görüntüden elde edilen koordinat bilgileri TUREF / TM30 EPSG:5254 formatına çevrilerek söz konusu API'ye gönderilir. API'den yanıt olarak dönen bina bilgileri arasından binaya ait kat bilgileri incelenir. Eğer algoritmamızın tespit ettiği kat sayısı ile belediye veri tabanından gelen kat sayısı arasında farklılık varsa kaçak bir kat olabileceği uyarısı oluşturulur. Eğer söz konusu koordinatlara ait bina kaydı belediye tabanında hiç bulunmuyorsa da binanın kaçak olma ihtimali bulunmaktadır. Kaçak kat/yapı tespit edilen durumlarda yetkililere bildiri gönderilmesi hedeflenmektedir.

3. SONUÇ

Çalışma kapsamında oluşturulan veri setiyle eğitilen Mask RCNN modelimizin ulaştığı ortalama kesinlik (average precision, AP) değerleri pencereler için 0.67 ve binalar için 0.65'tir. Ancak her görüntü için sadece merkezdeki bina için bina tespit kesinliği 0.94, kat sayısı tespit kesinliği ise 0.91 olarak elde edilmektedir. Başarımların artırılması için farklı bina ve pencere tiplerinin tümünü içerecek şekilde veri setinin sürekli güncellenmesi, belediye kat bilgilerinin ayrıntılı analizi ve bulunan kat sayılarına ek olarak giriş ve çatı katının belirlenmesi hedeflenmektedir.

4. TEŞEKKÜR

Bu çalışma TÜBİTAK 1501 Sanayi Ar-Ge Projeleri Destekleme Programı kapsamında desteklenen 3210262 numaralı "Şehrin Gözü, Görüntü İşleme Temelli Akıllı Şehir Çözümü" projesi kapsamında gerçekleştirilmiştir.

KAYNAKLAR

- Bochkarev, K., Smirnov E.**, 2019. Detecting advertising on building façades with computer vision. *Procedia Computer Science*, 156, 338–346. <https://doi.org/10.1016/J.PROCS.2019.08.210>
- Cohen, J. P., Ding W, Juhlman C., Chen A, Di L.**, 2016. Rapid building detection using machine learning. *Applied Intelligence*, 45(2), 443–457.
- Dornaika, F., Mujahi A, El Merabet Y., Ruichek Y**, 2016. Building detection from orthophotos using a machine learning approach: An empirical study on image segmentation and descriptors. *Expert Systems with Applications*, 58, 130–142.
- Grubovic L.**, 2006, *Belgrade in Transition: an analysis of illegal building in a post-socialist city*, Tez (Doktora), London School of Economics and Political Science, 289 sf.
- He K., Gkioxari G., Dollár P, Girshick R.**, 2017, Mask R-CNN, *IEEE International Conference on Computer Vision (ICCV)*, 2961-2969
- Jiang Y., Han S., Bai Y.**, 2021, Building and Infrastructure Defect Detection and Visualization Using Drone and Deep Learning Technologies, *Journal of Performance of Constructed Facilities* , 35(6)
- Kiran S. B., Rithvik M. V.**, 2020. Identification of Illegal Construction using Image Processing. *International Journal of Computer Applications*, 175(37), 975–8887.
- Kurtar, Z.**, 2017 Kent Düzeyinde İklim Aksiyon Planlama ve Bursa Büyükşehir Belediyesi Aksiyon Planının İncelenmesi, Tez (Yüksek Lisans), İstanbul Üniversitesi / Sosyal Bilimler Enstitüsü / İklim Değişikliği Ana Bilim Dalı, 169 sf.
- Özşenol, M.**, 1998, İstanbul metropolitan alanında yasadışı yapılaşan alanlarda kat mülkiyeti esaslı 18. madde uygulaması, Ümraniye Çakmak Mahtümüsü örneği, Tez (Yüksek Lisans) - Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 118 sf.
- Touzani S., Wudunn M., Fernandes S., Zakhor A., Najibi R., Granderson J.**, 2021, Machine learning approach to estimate windows-to-wall ratio using drone imagery, *Remote Sensing Technologies and Applications in Urban Environments VI*
- Ren S., He K., Girshick R., Sun J.**, 2015, Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks, *Advances in Neural Information Processing Systems 28 (NIPS 2015)*
- T.C Kalkınma Bakanlığı**, 2018. On Birinci Kalkınma Planı (2019-2023) Konut Politikaları, Özel İhtisas Komisyonu Raporu <https://www.sbb.gov.tr/wp/content/uploads/2020/04/KonutPolitikalarıOzelIhtisasKomisyonuRaporu.pdf> [Erişim tarihi: 11.10.2022]
- Ostankovich V., Afanasyev I.**, 2018, Illegal Buildings Detection from Satellite Images using GoogLeNet and Cadastral Ma, 9th *IEEE International Conference on Intelligent Systems 2018*
- Wu Y., Kirillov A., Massa F., Lo W.Y., Girshick R.**, 2019, Detectron2, <https://github.com/facebookresearch/detectron2>
- Vakalopoulou, M., Karantzas K, Komodakis N, Paragios N**, 2015. Building detection in very high resolution multispectral data with deep learning features. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2015-November, 1873–1876.
- Varol, B., Yılmaz E. Ö. , Maktav, D., Bayburt S., Gürdal S.**, 2019. Detection of illegal constructions in urban cities: comparing LIDAR data and stereo KOMPSAT-3 images with development plans. *European Journal of Remote Sensing*, 52(1), 335–344.
- Zanfi, F.**, 2013 The Città Abusiva in Contemporary Southern Italy: Illegal Building and Prospects for Change , *Urban Studies*. 50(16):3428-3445