



## ENVIRONMENTAL WASTE DETECTION FROM UAV IMAGES WITH YOLOV3 DEEP LEARNING ALGORITHM

Serkan Çelik<sup>\*1</sup> , Ayhan Altınörs<sup>2</sup> 

<sup>1</sup>100. Yıl Mesleki ve Teknik Anadolu Lisesi, Bilişim Teknolojileri Bölümü, Elazığ, Türkiye

<sup>2</sup>Fırat Üniversitesi, Teknik Bilimler MYO, Elektronik ve Otomasyon Bölümü, Elazığ, Türkiye

### Abstract

Original scientific paper

Since plastic and glass bottles are generally disposable materials, they are thrown away carelessly after use. One of the main reasons of environmental pollution is plastic and glass bottle waste. Furthermore, glass bottles have a huge impact on forest fires. For these reasons, it is necessary to detect plastic and glass bottles and collect them without harming the environment. The fact that no similar study was found on the detection of pet and glass bottle waste in the literature review motivated us to carry out this study. In the study, due to the use of Unmanned Aerial Vehicle (UAV), the images required for the test process were obtained more quickly and easily.

In this study, image processing techniques were used to detect plastic and glass bottles in images taken from UAVs. Principally, the images with the objects to be detected for training were determined. Objects in these images were labeled, necessary arrangements were made, then training and test data were obtained. Using these data, training was carried out with the YOLOv3 deep learning algorithm, and object detection test was applied with the obtained data. As a result of the study, pet and glass bottles in natural environments were successfully detected with an average accuracy rate (mAP) of 84.81%.

**Keywords:** Deep learning, ecosystem, image processing, object detection, UAV, YOLO.

## YOLOV3 DERİN ÖĞRENME ALGORİTMASI İLE İHA GÖRÜNTÜLERİNDEN ÇEVRESEL ATIK TESPİTİ

### Özet

Orijinal bilimsel makale

Pet ve cam şişeler genellikle tek kullanımlık malzemeler olduklarından kullanıldıktan sonra uygun olmayan yerlere özensiz bir şekilde atılmaktadır. Pet ve cam şişe atıkları, çevre kirliliğinin önemli sebeplerinden biridir. Ayrıca cam şişelerin orman yangınlarının çıkmasında çok büyük etkileri vardır. Bu nedenlerden dolayı pet ve cam şişelerin tespit edilmesi ve çevreye zarar vermeden toplanması çok büyük önem arz etmektedir. Yapılan literatür taramasında pet ve cam şişe atıklarının tespiti ile ilgili herhangi bir çalışmaya rastlanmaması bu çalışmayı yapmak için bizi motive etmiştir. Yapılan çalışmada, test işlemi için gerekli olan görüntüler, İnsansız Hava Aracı (İHA) kullanılarak daha hızlı ve kolay bir şekilde elde edilmiştir.

İHA'dan alınan görüntülerdeki pet ve cam şişelerin tespit edilmesi için görüntü işleme teknikleri kullanılmıştır. Öncelikle, eğitim için, tespit edilecek nesnelere bulunduğu görüntüler belirlenmiş, bu görüntülerde tespit edilmesi istenen nesnelere etiketlenmiş, gerekli düzenlemeler yapılarak eğitim ve test verileri elde edilmiştir. Bu veriler kullanılarak YOLOv3 derin öğrenme algoritması ile eğitim gerçekleştirilmiş, elde edilen veriler ile pet ve cam şişe atıklarının bulunduğu görüntülerden nesne tespit test işlemi yapılmıştır. Yapılan çalışma sonucunda, doğal ortamlardaki pet ve cam şişeler % 84.81 ortalama doğruluk oranı (mAP) ile başarılı bir şekilde tespit edilmiştir.

**Keywords:** Çevre, derin öğrenme, görüntü işleme, İHA, nesne tespiti, YOLO.

### 1 Giriş

Çevre ve iklim sorunlarının sürekli arttığı günümüzde en büyük çevre sorunlarının başında ambalaj atıklarının çevrede oluşturdukları tahribat gelmektedir. Toplum olarak sürekli tüketmekte ve bu süreçte ambalaj atık miktarları sürekli artmaktadır. Tüketilen ürünlerin çoğu pet ve cam ambalajlar içerisinde bulunmaktadır.

Günümüz toplumu bu pet ve cam ambalaj atıklarını çoğu zaman atık toplama kutuları yerine doğaya rastgele atmaktadır. Pet ambalajlar günümüzde ve gelecekte üretildikleri malzemelerin yapısından dolayı çevre kirliliği ve canlı yaşamları için çok büyük sorunlar teşkil etmektedir. Cam ambalajlar ise buldukları yerlerde çok büyük oranda yangın riski oluşturduklarından ve yine

\* Corresponding author.

E-mail address: aaltinors@firat.edu.tr (A. Altınörs)

Received 27 September 2022; Received in revised form 24 March 2023; Accepted 27 April 2023


2587-1943 | © 2023 IJIEA. All rights reserved.

Doi: <https://doi.org/10.46460/ijiea.1195428>

uzun süre çözünmediklerinden çevre için sorun teşkil etmektedir [1].

Hem yaşadığımız çevreyi, dünyamızı ve enerji kaynaklarımızı korumak hem de üstün özelliklerinden sürekli faydalanabilmek için plastik ve cam malzemelerin geri dönüşümünü sağlamak gerekli ve önemlidir [2].

İnsanların gelir seviyesi arttıkça kullanım alışkanlıkları da değişmiştir. İnsanoğlu daha fazla tüketmeye ve buna paralel olarak da daha fazla atığa sebep olmuştur. Özellikle kullan-at kültürünün de yaygınlaşmasıyla birlikte atık miktarında oldukça hızlı bir artış meydana gelmiştir.



Şekil 1. Ambalaj atıklarının cinslerine göre oranları.


Şekil 1'de Çevre, Şehircilik ve İklim Değişikliği Bakanlığı 2020 yılı verilerine göre ambalaj atıklarının %46'sını plastik ve cam ambalajların oluşturduğu görülmektedir. Bu ambalaj atıklarından plastik ambalaj atıklarının %66'sı, cam ambalaj atıklarının ise %30'u ancak geri dönüştürülebilmektedir. Bu oranlara dikkat edilirse geri dönüşüm oranının düşük olduğu görülmektedir [3].

Kullanımı oldukça yaygın olan pet ve cam şişelerin doğada uzun süre kalması hem ekonomik olarak hem de çevre kirliliği ve diğer etkilerinden dolayı istenmeyen bir durumdur. Bu atıkların tespit edilerek geri dönüşüme kazandırılması, hem çevre kirliliğinin ve orman yangınlarının önlenmesi hem de ekonomik açıdan büyük önem taşımaktadır.

İnsansız Hava Aracı (İHA), günümüz teknolojileri kullanılarak sürekli geliştirilen ve birçok alanda kullanılan hava aracıdır. Neredeyse tüm sektörlerde İHA'lar kullanılmaktadır. Bunun en önemli nedeni ise yapılan işleri daha hızlı ve daha güvenilir olarak yerine getirebilmeleridir. İlk üretildikleri zaman daha çok askeri alanda kullanılan İHA'lar teknolojinin gelişimi ve maliyetlerin düşmesiyle çok geniş bir kullanım alanı bulmuşlardır [4].

Bu çalışmamızda doğal ortamda çevreye atılmış pet ve cam şişe atıklarına ait resimlerin elde edilmesi için DJI firmasının üretmiş olduğu Mavic Air 2 model İHA kullanılmıştır.

Kullanılan İHA 570 gr ağırlığa sahip, maksimum 68 km/h hız yapabilen, uzun süre havada kalabilen, uzak mesafelerden görüntü iletebilen ve çok kaliteli resimler çekebilen gelişmiş bir İHA'dır. Şekil 2'de kullanılan DJI Mavic Air 2 İHA'sına ait resimler görülmektedir.



Şekil 2. DJI Mavic Air 2 İHA resimleri.

Çalışmamızda nesne tespitini gerçekleştirmek için derin öğrenme algoritmaları ile görüntü işleme yöntemi kullanılmıştır. Derin öğrenme, bir makine öğrenmesi tekniğidir. İnsanların beyninden ilham alınarak geliştirilmiştir. İnsan beyninin yapabildiği bazı işlemlerin makineler tarafından yapılabilmesi için günümüzde birçok çalışma yapılmaktadır. Nesne tanıma işlemi de bu çalışmalarındandır. Bu çalışmalar ile belirlenen nesnelerin tespiti yapıp hızlı bir şekilde sınıflandırılması sağlanmaktadır. Gelecekte yapılacak çalışmalarla insanların yaptıkları birçok iş bu sayede makineler tarafından yapılacaktır [5].

Gerçekleştirilen çalışmada çevre için çok büyük sorun oluşturan pet ve cam şişelerin İHA tarafından çekilen görüntüler kullanılarak tespit edilmesi amaçlanmıştır. Bu işlem için bir derin öğrenme algoritması olan YOLOv3 algoritması kullanılmıştır. İnternet ortamından elde edilen birçok resim düzeltilmiş ve derin öğrenmede eğitim için kullanılmıştır. Uzun bir eğitim süreci sonunda makine tarafından nesnelerin algılanıp algılanmadığı test edilmiştir.

Yapılan test ile doğada çekilen görüntülerden pet ve cam şişelerin tespitinin yapılabildiği görülmüştür. Bu sonuçlar bize nesne tanıma işlemi makinelerin insan kadar hızlı ve doğru olmasa da gerçekleştirebildiğini göstermiştir. Bu tespit işlemi ile ekosistem içerisindeki sorunların çözümünde derin öğrenme algoritmalarının başarılı bir şekilde kullanılabileceği de görülmüştür.

## 2 Literatür Araştırması

Günümüzde İHA'lar birçok alanda etkin olarak kullanılmaktadır. İHA'lar ilk zamanlarda sadece askeri alanlarda kullanılırken günümüzde hem sivil hem de askeri alanlarda sıklıkla kullanılmaktadır. İHA ile insanların ulaşmakta zorluk çektiği bölgelere ulaşip bu bölgelerde amaca uygun görüntüler ve resimler alınıp görüntü işleme algoritmaları ile bu veriler değerlendirilmekte ve sorunlara çözümler üretilmektedir. Özellikle çevrenin korunması ile ilgili İHA kullanılarak yapılan birçok çalışma mevcuttur. Bu çalışmalar incelendiğinde genellikle tarım, hayvancılık ve çevrenin korunması ile ilgili görüntü işleme çalışmalarının yoğunlukta olduğu görülmektedir.

Kabadayı ve Uysal tarafından yapılan çalışmada, İHA'lar ile elde edilen verilerden binaların tespiti yapılmıştır. İHA ile havadan görüntüleme yapılarak bindirmeli bir şekilde 15 küçük, 13 orta ve 4 büyük olmak üzere 32 adet binanın bulunduğu bir alanda toplanan görüntü verileri fotogrametrik yöntem ile değerlendirilmiş ve çalışma alanına ait ortofoto ve sayısal yüzey modeli oluşturulmuştur. Elde edilen veriler ile nesne tabanlı sınıflandırma yöntemi kullanılarak bina detayları tespit

edilmiştir. Çalışma sonucunda 32 adet binadan 30 tanesi tespit edilerek %90 oranında bina tespiti yapılmıştır [6].

Yanık ve diğerleri tarafından yapılan çalışmada, orman yangınlarında görsel algılamaya yeni ve kesin bir bakış açısı getirilmesi amaçlanmıştır. Bu amaçla bir İHA sistemi geliştirilmiş, sistemde bulunan mikrodenetleyici, derin öğrenme yöntemleri ile eğitim verilerek programlanmış ve İHA'ya yangın algılamasının erken işareti olan dumanı tanıma özelliği kazandırılmıştır. Bu sayede yangın algılama sistemlerinin ortak sorunu olan yanlış alarm ve gözden kaçma oranlarının azaltılabileceği ve hızlı bir şekilde yangına müdahale edilebileceği öngörülmüştür. İHA'nın mobil görüş kabiliyeti sayesinde görüntülerin her açıdan net ve sürekli olarak kontrol edilmesi sonucu duman tespitinde %98 doğruluk oranında başarı sağlanmıştır [7].

Körez ve Barışçı tarafından yapılan çalışmada, Faster R-CNN algoritması kullanılarak yayaların tespiti için otomatik bir nesne tanıma yöntemi ortaya koyulmuştur. Bu yöntem ile 6 sınıf kullanılarak (insan, kaykay kullanan insan, bisiklet süren insan, araba, otobüs ve golf arabası) İHA ile 8 farklı sahnedan çekilen 60 görüntü kullanılmıştır. 4 gün süren eğitim ve yaklaşık 7500 iterasyon sonucunda yayalar %58,02 doğruluk oranı ile tespit edilmiştir. Yayaların gölgeleri, tepeden bakış açısı ve veri setindeki resimlerin bulanık veya net olması gibi durumlar başarı oranının düşük olmasındaki etken olarak görülmüştür. Bu olumsuz durumlara rağmen R-CNN metodu kullanılarak diğer yöntemlerden %2 daha başarılı bir yöntem geliştirmiştir [8].

Kim ve diğerleri tarafından yapılan çalışmada, binalardaki yüzey çatlaklarının izlenmesi için yeni bir yöntem önerilmiştir. İnsansız Hava Aracı ile çekilen 40000 çatlak olan ve olmayan yüzey görüntüsü, Evrişimsel Sinir Ağı (CNN) tabanlı bir mimari kullanılarak analiz edilmiş ve binalardaki çatlakların tespiti ve sınıflandırılması sağlanmıştır. Bu yöntem sonucunda bina çatlaklarının %99,8 doğruluk oranı ile tespit edilebildiği görülmüştür [9].

Doğan tarafından bitkilerde görülen hastalıkların derin öğrenme yöntemleri ile tespiti ve sınıflandırılması üzerine bir çalışma yapılmıştır. Yapılan çalışmada domates ve elma yapraklarındaki hastalıkların tespiti ve sınıflandırılması derin öğrenme yöntemleri ile gerçekleştirilmiştir. Konvolüsyonel Sinir Ağı (KSA) modeli ve Learning Vector Quantization (LVQ) derin öğrenme algoritmaları kullanılarak deneysel çalışmalar domates ve elma yaprakları için ayrı ayrı yapılmıştır. Domates yapraklarından oluşan veri setinde 4 farklı hastalıklı yaprak ve 1 sağlıklı yaprak olmak üzere toplam 5 farklı sınıf için deneysel çalışmalar gerçekleştirilmiştir. Elma yaprakları üzerinde gerçekleştirilen çalışmalarda ise Yalova ilinde bulunan elma bahçelerindeki yaprakların İHA kamerası ile görüntüleri alınmış ve deneysel çalışmalar ağaç üzerindeki yaprak görüntüleri üzerinde gerçekleştirilmiştir. Çalışma sonucu konvolüsyonel sinir ağı tabanlı yöntemin yapraklardaki hastalıkların tespitinde başarılı olduğunu, tarımsal alanlarda hastalık tespiti ve sınıflandırma çalışmaları için etkili bir şekilde kullanılabileceğini göstermiştir [10].

Öztürk tarafından yapılan çalışmada makine öğrenmesi ve görüntü işleme tekniklerini kullanarak İHA ile çekilen resimler kullanılarak yaprakların

sınıflandırılması için bir yöntem geliştirilmiştir. Yapılan çalışmada, İHA ile otonom bir şekilde yaprak çeşitleri tanıyarak bitkisel hastalıklar ve böceklenme gibi ortaya çıkabilecek sorunlar önceden tespit edilip gerekli tedbirler alınarak, kimyasal ve biyolojik iyileşme sağlanmıştır. Öncelikle çekilen resimlerden özellik çıkarımı yapılmış, çıkarılan özellikler öğretilerek SVM ile sınıflandırma yapılmıştır. Yapılan çalışma sonucunda belirli bir bölgede görüntü işleme teknikleri ve makine öğrenmesi ile %91,3 doğruluk oranı ile yaprak sınıflandırma işlemini gerçekleştiren bir sistem tasarlanmıştır [11].

Burgaz tarafından yapılan çalışmada, Derin öğrenme algoritmaları ve İHA kullanılarak silah tespiti için bir yöntem geliştirilmiştir. İHA ile çekilen resimlerden R-CNN ve ResNet algoritmaları ile silah tespiti yapılmıştır. İnsanoğlunun çıplak gözle bile görmekte zorlandığı bu nesnelere daha az zaman ve maliyetle tespit işlemi gerçekleştirilmiştir. Çalışmada 200 adet görüntü kullanılarak gerçekleştirilen eğitim sonucunda resimlerdeki silah %99 doğruluk oranı ile tespit edilmiştir [12].

Güzel tarafından İHA ile çekilen görüntüler kullanılarak yeşil alanları tespit etmek için bir çalışma yapılmıştır. Çalışmada 159 adet görüntü kullanılmıştır. Çalışma sonucunda Yıldız Teknik Üniversitesi kampüs alanında gölgede yer alan hem seyrek hem de sık yeşil alanlar 1217 adet görüntü ile yapılan 2,5 saatlik eğitimler sonucunda UNet-VGG19 derin öğrenme mimarisi ile %95 doğruluk oranı ile tespit edilmiştir [13].

Albayrak ve diğerleri tarafından yapılan çalışmada, İHA ve derin öğrenme algoritmaları kullanılarak araç tespiti üzerine bir yöntem geliştirilmiştir. Bu yöntemde iki derin öğrenme modeli (R-CNN ve YOLO sinir ağı) kullanılmıştır. İHA ile çekilen görüntülerden her iki algoritmaya göre veri setleri oluşturulmuştur.

Bilecik ili Pazaryeri ilçesinde çekilen 80 adet görüntüden iki farklı algoritma kullanılarak araç tespiti yapılmıştır. Yapılan çalışma sonucunda YOLO algoritması R-CNN algoritmasına göre daha hızlı sonuç vermiş, R-CNN algoritması ise YOLO algoritmasına göre daha doğru sonuç üretmiştir [14].

Arvas tarafından derin öğrenme algoritmaları kullanılarak İHA görüntülerinden haşhaş, kenevir ve tütün bitkilerinin tespiti için bir çalışma yapılmıştır. Yapılan bu çalışmada İHA ile çekilen 300 haşhaş, 100 kenevir ve 100 tütün bitkisi olmak üzere 500 görüntü kullanılmıştır. Eğitim için ise 28774 haşhaş, 4172 kenevir ve 2902 tütün bitkisi olmak üzere 35848 görüntü etiketlenmiştir. Oluşturulan veri seti YOLOv5 algoritma ağı kullanılarak eğitilmiş ve eğitim sonucunda İHA ile çekilen görüntülerden %77,1 doğruluk oranı ile nesnelere tespiti yapılmıştır [15].


Baydoğan ve Alataş tarafından sosyal medyada sıklıkla kullanılan nefret söyleminin otomatik tespiti için yapay sinir ağı ve makine öğrenmesi yöntemlerinden oluşan yapay zeka temelli algoritmaların kullanıldığı bir çalışma yapılmıştır. Yapılan çalışmada Naive Bayes, Destek Vektör Makinesi, iki farklı Karar Ağacı ve Çok Katmanlı Algılayıcı olmak üzere beş farklı yapay zeka temelli algoritma kullanılmıştır. Çalışmanın sonucunda farklı eğitim ve test teknikleri kullanılarak performans değerlendirme metrikleri hesaplanmıştır. Çalışmada en yüksek doğruluk değeri %80 olarak Karar Ağaçları ve

Çok Katmanlı Algılayıcılar tarafından elde edilmiştir [16].

Yapılan literatür taramasında İHA'lar ile çekilen görüntüler kullanılarak görüntü işleme ve derin öğrenme algoritmaları ile birçok farklı nesnenin tespiti ve sınıflandırılmasının yapılabildiği görülmüştür. Fakat bu çalışmada gerçekleştirilen pet ve cam şişe tespitine ilişkin bir çalışmaya rastlanmamıştır.

### 3 Derin Öğrenme ve YOLO Nesne Algılama Algoritması

Derin öğrenme, 2006 yılından itibaren popüler olarak kullanılmaya başlanmış makine öğrenmesi alanının en güncel alt dallarından biridir. Derin öğrenme yöntemlerinde insan beyninin yapısından esinlenerek oluşturulan yapay sinir ağı algoritmaları kullanılmıştır. İnsan beyni bir nöron ağıdır, derin öğrenmede ise nöronlar düğümlere karşılık gelir. Lineer cebire dayanan bu sistemde insan beynindeki nöronlara benzeyen düğüm adı verilen yapılar bulunur. Düğüm yapılarının birleştirilmesi ile katmanlar, katmanların birleştirilmesi ile de sinir ağı denilen yapılar oluşturulur. Şekil 3'te yapısı verilen bu ağlara derin sinir ağı da denir [5].



Şekil 3. Basit derin sinir ağı yapısı [5].

Derin öğrenme, makine öğrenimi alanında yapılan çalışmalar ile yapay zekâ kapsamının genişlemesine de öncülük etmiştir. Yüzeysel öğrenme ile karşılaştırıldığında derin öğrenme kavramı daha soyut bilgilere ulaşmak için derin (gizli) katmanlar inşa etme avantajına sahiptir. Bu sayede çok katmanlı mimarilerde çok boyutlu veriler ile çalışma imkânı sağlamıştır [17].

Derin öğrenme tabanlı yöntemler yüz tanıma, plaka tanıma, nesne algılama, pozisyon tanıma, hareket algılama, şerit tespiti, yaya algılama, duyu algılama, otomatik park etme, resim tanıma ve görüntü işleme gibi birçok alanda karmaşık problemleri çözmek için kullanılmış ve ciddi bir başarı oranı elde edilmiştir [18].

Görüntü işleme algoritmaları içerisinde en sık kullanılanlar Faster R-CNN algoritması, SSD algoritması ve YOLO algoritmasıdır. YOLO algoritması diğer 2 algoritmadan daha hızlı algılama işlemi yapabilmektedir. Bunun nedeni ise resme bir defa bakarak algılamayı gerçekleştirmesidir. Bu durum gerçek zamanlı nesne tespitinde YOLO algoritmasının kullanımının en önemli nedenidir [19].


YOLO (You Look Only Once) "Sadece bir kere bak" kelimelerinin kısaltılmasından elde edilmiş, yüksek

performansa sahip derin öğrenmeye dayalı gelişmiş bir nesne algılama algoritmasıdır. Yakın zamanda geliştirilen YOLO, nesne tespitinde kullanılan bir algoritma olup özellikle gerçek zamanlı görüntü işleme uygulamalarında kullanılmaktadır [20].

Nesne tespiti için kullanılacak olan bir algoritma hem doğru hem de hızlı olmalı ayrıca birçok nesneyi de tanıyabilmelidir. Mevcut nesne algılama veri kümeleri, sınıflandırma ve etiketlendirme işlemleri için kullanılan veri kümelerine göre yetersizdir. Günümüzde kullanılan büyük boyutlardaki sınıflandırma verilerinden yararlanmak ve nesne dedektörlerini sadece sınıflandırma için değil aynı zamanda algılama konusunda da eğitmek için ortak bir eğitim algoritmasına ihtiyaç duyulmuş ve böylece YOLO algoritması ortaya çıkmıştır [21].

YOLOv1 algoritması ilk olarak 2015 yılında Joseph Redmon tarafından tasarlanmıştır. Daha sonra 2016 yılında Joseph Redmon ve Ali Farhadi YOLOv1 versiyonunda iyileştirmeler yaparak 9000 nesne tanıyabilen YOLOv2 versiyonunu, 2018 yılında da en son yöntemleri deneyerek diğer versiyonlardan daha kapsamlı, daha doğru sonuçlar veren ve daha hızlı bir versiyon olan YOLOv3'ü geliştirmişlerdir [22].

Bir resim üzerinde yapılan sınıflandırma işlemi sonucunda insan ya da giysiyi bulmak aşılması gereken bir problemdir. Ancak insan ve giysiyi aynı resimde yerleriyle beraber algılamak daha zor bir problemdir. Birinci problem sınıflandırma yöntemiyle yapay sinir ağlarıyla çözülebilirken, ikinci problemi çözmek daha farklıdır ve farklı bir yaklaşım gerektirmektedir. YOLO güçlü bir evrimsel sinir ağıdır ve bize resmin nerede olduğunu sınırlayıcı bir kutu çizerek göstermektedir [19].



Şekil 4. YOLO algoritmasının genel çalışma prensibi [23].

Şekil 4'te YOLO algoritmasının temel çalışma yapısı gösterilmektedir. Şekilde görüldüğü gibi YOLO giriş resmini öncelikle SxS boyutunda ızgaralara böler ve her bir ızgara hücresi o ızgara hücresinde ortalanmış nesneyi tahmin eder. Tahmin sonucunda tahmin değeri üretilir. Tahmin sonuçları toplanarak düşük olasılığa sahip sınırlayıcı kutular silinir. En yüksek tahmin olasılık değerlerine sahip sınırlayıcı kutu ise nihai sonuç olarak belirlenir [23].

### 4 YOLOv3

YOLOv2 algoritmasında 19 katman kullanılması, küçük nesnelerin tanınmasında meydana gelen sorunlar ayrıca gerçek zamanlı uygulamalardaki hız problemleri



YOLOv3 algoritmasının geliştirilmesini gerekli kılmıştır. Geliştirilen YOLOv3 algoritmasında 53 katmanlı DarkNet kütüphanesi kullanılarak daha küçük nesnelere tespit performansı ve doğruluğu artırılmıştır [22].


YOLOv3 algoritması çoklu kutu yapısı kullanarak birden çok nesneyi gerçek zamanlı olarak yüksek frame hızlarında tanıyabilmektedir [24].

YOLOv3 algoritmasında DarkNet-53 mimarisinin kullanılabilmesi için standart YOLO algoritmasında bulunan havuzlama, tam bağlantılı ve softmax katmanları kaldırılmıştır. YOLOv3 farklı boyutlardaki nesnelere algılamak için görüntüyü 3 farklı ölçekte ızgaralara böler.

Şekil 5'te bir görüntünün 3 farklı ölçekte ızgaralara bölünmüş hali görülmektedir.




Şekil 5. Görüntüyü üç farklı ölçekte ızgaralar ile bölme.



Şekil 6. DarkNet-53 kullanılmış 3 ölçekli tahmin yapabilen YOLOv3 evrişimsel sinir ağı yapısı [25].

Şekil 6'da DarkNet-53 kullanılmış 3 ölçekli tahmin yapabilen YOLOv3 evrişimsel sinir ağı yapısı görülmektedir. Bu yapıda YOLOv3 algoritması çoklu ölçekler kullanıldığından tahmin doğruluğu da artmıştır. YOLOv3 evrişimsel sinir ağına kullanılan DarkNet-53 yapısı DarkNet-19 yapısından daha güçlü, ResNet-101 ve ResNet-152 yapılarından daha verimlidir. YOLOv3 test sürecinde ilk önce girişteki görüntü standart boyutlara dönüştürülür. Daha sonra giriş görüntüsü 3 farklı ölçekte (13×13, 26×26 ve 52×52) ızgaralara bölünür. Nesne sınırları belirlendikten sonra özellik çıkarımı için görüntü ağı girilir. Ağda öncelikle 13×13 küçük ölçekte özellik haritası çıkarılır. Özellik haritası ilk olarak evrişim setine tabi tutulur, 2 kez örneklendir ve 1. tahmin sonucu ortaya çıkar. Daha sonra 26×26 orta ölçekte özellik çıkarım aşamasına geçilir ve özellik haritası çıkarılır. Özellik haritası evrişim setine tabi tutulur, 2 kez örneklendir ve 2. tahmin sonucu ortaya çıkar. Son olarak 52×52 büyük ölçekte özellik çıkarım aşamasına geçilir ve özellik haritası çıkarılır. 3. tahmin sonucu da ortaya çıktıktan sonra 3 tahmin sonucu birleştirilir. Daha sonra tahmin sonuçları kullanılarak kutu güven puanı elde edilir. Kutu güven puanı (IoU), bir sınırlayıcı kutuda nesne bulunma olasılığı ve sınırlayıcı kutunun doğruluğunu temsil eden bir puandır [25]. Şekil 7'de en solda kesişim alanı, ortada birleşim alanı ve en sağda ise kutu görev puanının nasıl hesaplandığı görülmektedir.



Şekil 7. Kutu güven puanının (IoU) hesaplanması [26].

Şekil 7'deki  $B_1$  gerçek nesne sınırlayıcı kutusunu,  $B_2$  ise tahmin edilen nesne sınırlayıcı kutusunu göstermektedir. Hücre içerisinde hiçbir nesne yoksa kutu güven puanı sıfırdır. Kutu güven puanının nesne tespitinde 1 veya 1'e yakın olması istenir. YOLOv3 algoritmasında IoU (Intersection over Union) değeri %50'nin üzerinde tutulmaktadır [26].

Elde edilen sınırlayıcı kutuların büyük bir kısmı çok düşük kutu güven puanına sahip olduğundan Non Maximum Suppression (NMS) yöntemiyle kutu güven puanı eşik değerinin altında olanlar silinir. NMS yönteminde nesne tanıma için belirlenen sınırlayıcı kutular için elde edilen kutu güven puanları en yüksekten en düşüğe doğru sıralanır ve kutu güven puanı en yüksek olan sınırlayıcı kutu belirlenir. Bu işlem sonucunda en yüksek kutu güven puanına sahip sınırlayıcı kutu nihai sonuç olarak elde edilir [25].

YOLOv3 algoritması dışındaki diğer derin öğrenme algoritmaları gerçek zamanlı nesne tespiti için gerekli 20 saniye başına kare (FPS) görüntü işleme hızına

ulaşamamışlardır. YOLOv3 algoritması ise görüntüleri 40-90 FPS aralığında işleyebilmektedir. Bu değerler, videonun gerçek zamanlı olarak birkaç milisaniye gecikme ile YOLOv3 algoritması tarafından işlenebileceğini ve YOLOv3 algoritmasının diğer evrimsel sinir ağı algoritmalarına göre oldukça hızlı çalıştığını göstermektedir. Anlık algılamaların önemli olduğu durumlarda algılama zamanının düşük olması çok büyük fayda sağlamaktadır [27].

Bu çalışmada hızlı işlem yapabilmesi ve tekrar eğitildiğinde yüksek nesne tespit doğruluğuna ulaşabilmesinden dolayı YOLOv3 evrimsel sinir ağı yapısı kullanılmıştır.

## 5 Materyal ve Metot

Yapılan literatür araştırmasına göre, son yıllarda sıklıkla kullanılan görüntü işleme ve derin öğrenme algoritmalarının nesne tespitinde hız ve doğruluk açısından gösterdikleri üstün başarı, gerçek zamanlı nesne tespitinde tercih edilmelerinin en büyük sebeplerinden biridir. Bu çalışmada hız ve doğruluk açısından diğer algoritmalarından daha üstün performans gösteren YOLOv3 nesne tanıma algoritması kullanılarak pet ve cam şişe tespiti yapılmıştır.

### 5.1 Geliştirilen Sistem

Gerçekleştiren çalışmada Şekil 8’de gösterilen sistem mimarisi kullanılmıştır. Bu mimari genel olarak 3 bölümden oluşmaktadır.

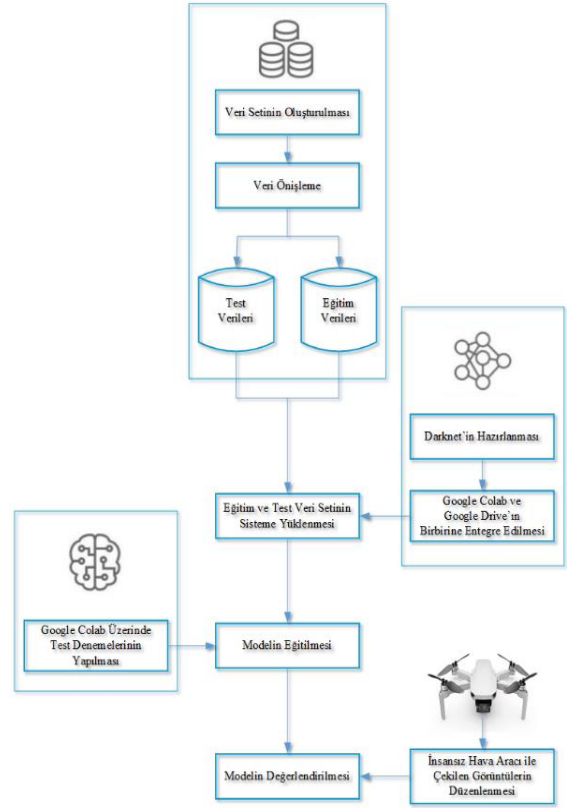
Birinci bölümde veri seti oluşturulmaktadır. İnternet ortamından elde edilen içerisinde pet ve cam şişelerin bulunduğu veri seti için kullanılacak 2250 görüntü belirlenmiştir. Bir sonraki aşamada her bir görüntüye ait nesne etiketleme dosyaları YOLOv3 formatına uygun olarak düzenlenmiştir. Bu düzenleme işleminden sonra veri setinin %70’i eğitim, %30’u da test verisi olmak üzere ikiye ayrılarak sisteme yüklenmiştir.

İkinci bölümde DarkNet dizin kurulumu, Makefile konfigürasyonu ve NVIDIA ekran kartı için CUDA kurulumu yapıldıktan sonra Colab arayüzü ile Google Drive’ın birbirine entegre işlemi gerçekleştirilmiştir. Bu bölümde ayrıca eğitim işlemine geçilmeden önce YOLOv3 standart ağırlıkları Colab ortamına yüklenmiş ve tüm veriler eğitim işlemine hazır hale getirilmiştir.

Üçüncü bölümde ise oluşturulan veri seti, YOLOv3 standart ağırlık dosyası ve diğer gerekli veriler kullanılarak evrimsel sinir ağı vasıtasıyla nesne tanıma için gerekli eğitim işlemi gerçekleştirilmiştir. Uzun süren eğitim işlemi ile değerlendirme işleminde kullanılacak ağırlıklar belirlenmiş ve değerlendirme işlemine geçilmiştir.

Değerlendirme işleminin gerçekleştirilmesi için İHA tarafından çekilen görüntüler kullanılmıştır. Bu görüntüler Fırat Üniversitesi Teknik Bilimler Meslek Yüksekokulu kampüs alanında belirlenen coğrafi bölgede çekilmiştir. DJI firmasının ürettiği Mavic Air 2 İHA ile farklı yerlerde belirlenen yükseklikten çekilen içerisinde cam ve pet şişelerin bulunduğu görüntüler kullanılmıştır. Bu görüntüler incelenmiş, belirlenen 50 görüntü ve eğitim sonucunda bulunan ağırlıklar kullanılarak değerlendirme işlemi gerçekleştirilmiştir. Yapılan değerlendirme işlemi

sonucunda görüntülerdeki pet ve cam şişe nesnelerinin tespit işlemi yapılmıştır. Tüm görüntü dosyaları tek tek değerlendirme işlemine tabi tutulmuş ve değerlendirme sonuçları elde edilmiştir [28].



Şekil 8. Sistem mimarisi.

### 5.2 Kullanılan Veri Seti


Evrimsel sinir ağları kullanılarak nesne tespiti çalışmaları için son yıllarda farklı veri setleri geliştirilmiştir. Nesne tanıma ve sınıflandırma işleminin başarılı olabilmesinin ön şartı kullanılan veri setleridir. Veri setlerindeki görüntü dosya sayısı arttıkça nesne tanıma doğruluğu da artmaktadır. Daha doğru sonuçlar elde etmek için çalışmamızda çok fazla görüntü dosyası kullanılarak veri seti oluşturulmuştur. Veri seti için çok fazla miktarda görüntü dosyasının toplanması ve etiketlenmesi uzun zaman alacağından bu işlem için kategori bazında hazırlanmış hazır veri seti kullanılmıştır.

Çalışmamızda, Google Open Image hazır veri setinden, içerisinde pet ve cam şişe bulunan 2250 görüntü ve bu görüntülere ait YOLOv3 formatına dönüştürülmüş etiketleme dosyaları kullanılarak veri seti oluşturulmuştur.

Oluşturulan veri setinde rastgele olarak verilerin %70’i eğitim, %30’u ise test verisi olarak belirlenmiştir.

### 5.3 Veri Etiketleme

Veri setinde kullanılan her bir görüntü dosyası için oluşturulan txt uzantılı etiketleme dosyasında, görüntü dosyasında etiketlenen bir veya birden fazla nesneye ait koordinat ve sınıf bilgileri bulunmaktadır. Şekil 9’da “txt” uzantılı etiketleme yapılmış örnek veri dosyası içeriği gösterilmiştir.



Şekil 9. Etiketlenmiş örnek veri dosyası içeriği.

Şekil 9’da gösterilen dosya içeriğinde tespit edilecek nesneye ait beş bilgi rakamsal olarak görülmektedir. Bu bilgiler; **c**: ait olduğu sınıf, **x**: etiketlenen bölgenin merkez noktasının x koordinatı, **y**: etiketlenen bölgenin merkez noktasının y koordinatı, **w**: etiketlenen bölgenin genişliği, **h**: etiketlenen bölgenin yüksekliğidir.

#### 5.4 Kullanılan Yöntem

Veri seti hazırlandıktan sonra eğitim işlemine geçmek için öncelikle eğitim önışlemlerinin gerçekleştirilmesi gerekmektedir. Eğitim önışlemleri ile gerekli tüm dosyalar yüklenip eğitim işlemi için gerekli ayarlar yapıldıktan sonra eğitim işlemi aşamasına geçilir.

Bu çalışmamızda eğitim işlemi gerçekleştirilmek için YOLOv3 derin öğrenme algoritması kullanılmıştır. Bu algoritma ile eğitimin gerçekleşmesi için Google Research tarafından sağlanan Colobratory (Colab) hizmeti kullanılmıştır. Colab vasıtasıyla eğitim işlemlerinde gerekli olan yüksek hızlı ram ve işlemci ile işlemlerin istenilen sürede ve sağlıklı gerçekleştirilmesi sağlanmıştır.

#### 5.5 Eğitim İşlemleri

Eğitim işlemi, evrişimsel sinir ağı tarafından veri seti ve standart YOLOv3 ağırlıkları kullanılarak gerçekleştirilmiştir. Bu işlem sonunda son ağırlık değerleri hesaplanmış ve bu ağırlıklar değerlendirme işleminde kullanılmıştır. Eğitimin süresi, kullanılan grafik işlemci birimi (GPU) ve seçilen veri setinin büyüklüğüne göre değişir. Hızlı ve kaliteli grafik işlemci birimi kullanılması eğitim süresini kısaltırken, çok fazla görüntü dosyasından oluşan büyük veri seti kullanılması ise eğitim süresini uzatır. Eğitim süresini uzatan bir diğer etken ise ağırlıkların istenilen değere düşmemesi sonucunda eğitimin sürekli tekrarlanmasıdır.

Eğitim işleminin sonucunda toplam hata ve ortalama hata (avg loss) değerlerinin mümkün olduğunca sıfıra yakın olması istenmektedir. Eğer toplam hata ve ortalama hata değerleri sıfıra yakınsamıyorsa nesne tespitinde istenilen başarı elde edilemez. Bu çalışmada eğitim işlemi için 3000 iterasyon gerçekleştirilmiştir. Bu işlem ile ağırlıklar 3000 defa güncellenmiştir. İşlem sonucunda hesaplanan toplam hata ve ortalama hatanın sıfıra yaklaştığı görülmüştür. Yapılan çalışmalarda toplam hata ve ortalama hata değerlerinin 2’nin altına düşmesi durumunda yapılan eğitimin başarılı olduğu kabul edilmektedir.

Şekil 10’da tüm eğitim süreci boyunca hata değerlerinin değişim grafiği görülmektedir. Grafik incelendiğinde başlangıçta yüksek olan hata değerlerinin eğitimin sonuna doğru sıfıra yaklaştığı görülmektedir.

Eğitim 3000 iterasyon sonucunda tamamlanmış ve nesne tespitinde kullanılacak ağırlık değerleri elde edilmiştir. Nesne tespiti için elde edilen bu ağırlık değerleri yolov3\_custom\_final isimli weight uzantılı bir dosya halinde kaydedilmiştir. Bu dosya gelecekte yapılacak test işlemlerinde uzun süren eğitim işlemine gerek kalmadan kullanılabilir [28].



Şekil 10. Eğitim süreci hata (loss) / iterasyon grafiği.

#### 5.6 Nesne Tespit Test İşlemleri

Nesne tespit test işlemlerini gerçekleştirmek için eğitim işlemi sonucunda oluşturulan yolov3\_custom\_final isimli weight uzantılı dosya kullanılmıştır. Bulunan ağırlık değerleri doğal ortamlarda çekilen içerisinde cam ve pet şişelerin bulunduğu 50 adet görüntü dosyası ile test edilmiştir.



Şekil 11. Görüntü çekimlerinin yapıldığı coğrafi bölge.

Bu çalışmada, ekosistem için sorun teşkil eden pet ve cam şişe atıklarının tespiti için, Fırat Üniversitesi Teknik Bilimler MYO kampüs alanında belirlenen coğrafi bölge içerisinde üç farklı ortamda 3 metre yükseklikten çekilen görüntüler kullanılmıştır. Daha yüksekten görüntü elde edildiğinde nesnenin boyutu da buna bağlı olarak küçülmekte bu da nesne tespit işlemi sonucunda doğruluk oranını düşürmektedir. Şekil 11’de görüntü çekimlerinin yapıldığı coğrafi bölge görülmektedir.



Şekil 12. Nesne tespit test görüntülerinin çekildiği ortamlar.




Şekil 12’de görüldüğü gibi nesne tespit test işlemleri için üç farklı ortam kullanılmıştır. 1. ortam yeşiliklerin fazla olduğu, 2. ortam toprak yapısının fazla olduğu, 3. ortam ise gri toprak yapısının olduğu ortamdır. Farklı ortamlar kullanılması nesne tespit işlemimizin güvenilirliğini ve doğruluğunu arttırmaktadır.


Üç farklı ortamda İHA tarafından çekilen görüntüler kullanılarak nesne tespit test işlemleri yapılmış ve test işlemleri sonucunda görüntülerdeki pet ve cam şişe nesnelerinin tespiti yüksek doğruluk oranlarıyla gerçekleştirilmiştir.

Nesne tespit işlemi için İHA ile doğal ortamda çekilen 50 görüntü kullanılmıştır. Bu görüntüler içerisinde seçilen örnekler Şekil 13’te görülmektedir.

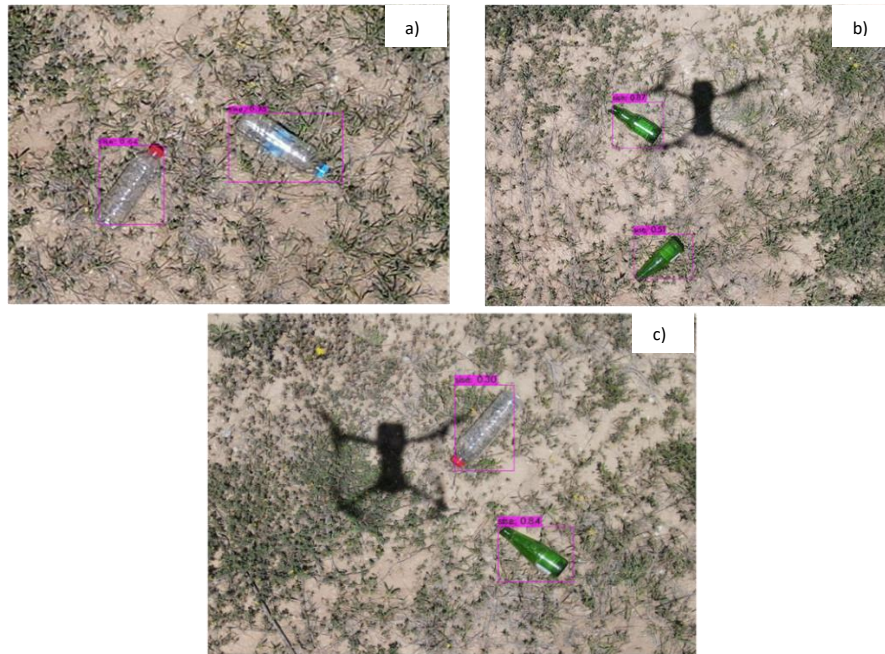
Şekil 14’te farklı ortamlarda bulunan cam ve pet şişelerin nesne tespit test sonuç görüntüleri verilmiştir. Çevreye atılmış cam ve pet şişelerin, Şekil 14(a)’da %90, Şekil 14(b)’de %80, Şekil 14(c)’de %90, Şekil 14(d)’de ise %85, doğruluk oranı ile tespiti gerçekleştirilmiştir.



Şekil 13. Nesne tespiti yapılan örnek görüntüler.



Şekil 14. Tek nesnenin bulunduğu farklı ortamlarda pet ve cam şişe tespiti.



Şekil 15. İki nesnenin bulunduğu farklı ortamlarda pet ve cam şişe tespiti.



Şekil 15'te iki nesnenin bulunduğu farklı ortamlarda cam ve pet şişelerin nesne tespit test sonuç görüntüleri verilmiştir. Çevreye atılmış birden fazla cam ve pet şişelerin, Şekil 15(a)'da %64 ve %73, Şekil 15(b)'de %87 ve %51, Şekil 15(c)'de ise %84 ve %30 doğruluk oranı ile tespiti gerçekleştirilmiştir.

Tüm nesne tespit test sonuçları incelendiğinde İHA ile çekilmiş 50 adet görüntüde bulunan 143 nesnenin 84 tanesi tespit edilerek %58.74 oranında tespit başarısı sağlanmıştır. İçerisinde tek bir nesnenin bulunduğu görüntülerde ise bu oran %100 dür. Ayrıca çekilen görüntülerin tamamına yakınında çok yüksek doğruluk oranıyla görüntüdeki nesnenin şişe olduğu tespit edilmiştir. Bu sonuçlar incelendiğinde nesne tespitini belirleyen en önemli etkenlerin nesnenin yapısı, görüntünün çekildiği yerin yapısı, nesnenin boyutu ve görüntüde bulunan nesne sayıları olduğu görülmüştür. Bu etkenler değiştirilerek daha başarılı sonuçlar elde edilebilir [28].

## 6 Sonuçlar ve Öneriler

Bu çalışmada YOLOv3 algoritması kullanılarak ekosistemin korunması için çevreye birçok açıdan zarar veren pet ve cam şişelerin tespit işlemi gerçekleştirilmiş ve başarılı sonuçlar elde edilmiştir.

Yapılan çalışma sonucunda YOLOv3 algoritmasını değerlendirmek için değerlendirme metrikleri hesaplanmış ve ortalama doğruluk değeri (mAP) 0.84816, kesinlik değeri 0.87, duyarlılık değeri 0.76 ve F-Score değeri de 0.81 olarak bulunmuştur. Tablo 1'de performans değerlendirmesi için hesaplanan karmaşıklık metrikleri ve matematiksel denklemleri birlikte sunulmuştur [16].

**Tablo 1.** Karmaşıklık metrikleri ve performans kriterleri [16]

Performans Kriterleri	Denklem	Karmaşıklık Metrikleri
Doğruluk	$\frac{TP + TN}{TP + FP + TN + FN}$	TP:Doğru Pozitif TN:Doğru Negatif FP:Yanlış Pozitif FN:Yanlış Negatif
Kesinlik	$\frac{TP}{TP + FP}$	
Duyarlılık	$\frac{TP}{TP + FN}$	
F-Score	$2 \times \frac{TP}{TP + FP + FN}$	

Belirlenen coğrafi bölgede İHA ile çekilen görüntüler üzerinde yapılan tespitler YOLOv3 algoritmasının pet ve cam şişe tespitinde kullanılabilirliğini desteklemiştir. Yapılan değerlendirme sonuçlarında 50 adet görüntü dosyasında bulunan 143 pet ve cam şişe nesnesinin yaklaşık %60'ı tespit edilmiştir. Bu oranın yeni geliştiren algoritmalar kullanılarak gelecekte yapılan çalışmalarda daha yukarılara çıkarılabileceği öngörülmektedir. Ayrıca görüntülerin tamamında en az bir cam veya pet şişe tespiti yapılarak istenilen amaca uygun başarılı sonuçlar elde edilmiştir.

Günümüz grafik işlemci birimleri derin öğrenmede eğitimin yapılabilmesi için gerekli hız ve

kaliteye sahiptirler. Bu sebeple nesne tespit başarısının artmasını sağlamak için eğitim için çok fazla sayıda görüntü dosyası kullanılabilir. Ne kadar fazla görüntü dosyası kullanılabilirse nesne tespit başarısı da o kadar artacaktır. Sosyal medyanın oldukça yaygın kullanıldığı günümüzde istenilen sayıda görüntü dosyasına ve nesne tespiti için hazırlanmış farklı kategorilerde hazır veri setlerine internet üzerinden rahatlıkla ulaşılabilir. Bu çalışmada kullanılan görüntüler Fırat Üniversitesi Teknik Bilimler Meslek Yüksekokulu kampüs alanında belirlenen coğrafi bölgede önceden belirlenen yükseklikte İHA kullanılarak çekilmiştir. Literatürde pet ve cam şişe atıklarının tespiti ile ilgili benzer bir çalışmaya rastlanmamış olması bu çalışmayı anlamlı hale getirmiştir. Gelecekte bu çalışmadan elde edilen sonuçlar dikkate alınarak farklı coğrafi bölgelerde, farklı zemin yapılarında, nesne tespitinin yapılabileceği görülmüştür. Ayrıca bu çalışma ilerleyen zamanlarda geliştirilip, İHA ile gerçek zamanlı nesne tespit uygulamaları gerçekleştirilerek ekosisteme zarar veren nesnelere daha hızlı tespit edilip çevreye verdiği zararlar en aza indirgenebilir.

Bu çalışmada kullanılan görüntüler Fırat Üniversitesi Teknik Bilimler Meslek Yüksekokulu kampüs alanında belirlenen coğrafi bölgede önceden belirlenen yükseklikte İHA kullanılarak çekilmiştir. Literatürde pet ve cam şişe atıklarının tespiti ile ilgili benzer bir çalışmaya rastlanmamış olması bu çalışmayı anlamlı hale getirmiştir. Gelecekte bu çalışmadan elde edilen sonuçlar dikkate alınarak farklı coğrafi bölgelerde, farklı zemin yapılarında, nesne tespitinin yapılabileceği görülmüştür. Ayrıca bu çalışma ilerleyen zamanlarda geliştirilip, İHA ile gerçek zamanlı nesne tespit uygulamaları gerçekleştirilerek ekosisteme zarar veren nesnelere daha hızlı tespit edilip çevreye verdiği zararlar en aza indirgenebilir.

## Bilgilendirme

Bu makale Serkan Çelik'in "Derin Öğrenme Yöntemlerini Kullanarak İHA Görüntülerinden Çevresel Atık Tespiti" isimli Yüksek Lisans Tez çalışmasından üretilmiştir. Gerçekleştirilen bu çalışmada Etik Kurul Onay belgesine gerek yoktur.

## Referanslar

- [1] Türkmen, B. A. (2020). Cam Ambalaj Üretiminde Çevresel Sürdürülebilirliğinin Değerlendirilmesi. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 7(2), 1026-1037.
- [2] Yüce, A.E., & Kılıç, M. (2014). PVC ve PET Atıkların Seçimli Flotasyonu. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 29.2, ss. 79-94.
- [3] Türkiye Cumhuriyeti Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Ambalaj Bülteni. Retrieved June 11, 2022 from <https://webdosya.csb.gov.tr/db/cygm/icerikler/ambalajbult-en-2020-20220226105845.pdf>.
- [4] Çamoglu, K., Akbayır, D., Yücelar, F., & Bayraklı, S. (2010). İnsansız Hava Araçlarının Genetik Algoritma Yöntemiyle Çoklu Hedeflere Planlanması. *Journal of Aeronautics & Space Technologies/Havacılık ve Uzay Teknolojileri Dergisi*, 4(3).
- [5] Ekici, E. (2022). *Deep Learning Based Fruit And Vegetable Recognition for Android Pos Devices*. (Master's dissertation, Istanbul Technical University).
- [6] Kabadayı, A., & Uysal, M. (2019). İnsansız Hava Aracı ile Elde Edilen Verilerden Binaların Tespiti. *Türkiye İnsansız Hava Araçları Dergisi*, 1(1), 8-14.
- [7] Yanık, A., Güzel, M. S., Yanık, M., & Bostancı, E. (2021). Machine Learning Based Early Fire Detection System using a Low-Cost Drone. *arXiv preprint arXiv:2101.09362*.
- [8] Körez, A., & Barış, N. (2018, October). İnsansız hava aracı (İHA) görüntülerindeki yayaların faster R-CNN algoritması ile otomatik tespiti. In *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-4)*. IEEE.

- [9] Kim, B., Yuvaraj, N., Sri Preethaa, K. R., & Arun Pandian, R. (2021). Surface crack detection using deep learning with shallow CNN architecture for enhanced computation. *Neural Computing and Applications*, 33, 9289-9305.
- [10] Doğan, M. (2019). *Bitkilerde Görülen Hastalıkların Derin Öğrenme Yöntemleriyle Tespiti ve Sınıflandırılması*. (Master's dissertation, Yalova University).
- [11] Öztürk, M. (2018). *Makine Öğrenmesi ve Görüntü İşleme Tekniklerini Kullanarak Drone ile Yaprak Sınıflandırma*. (Master's dissertation, Istanbul Technical University).
- [12] Burgaz, M. (2020). *Derin Öğrenme Algoritmaları Kullanarak İnsansız Hava Araçları İle Silah Tespiti*. (Master's dissertation, Batman University).
- [13] Güzel, Y. (2021). *Derin Öğrenme ile Yeşil Alanların Çıkarımı*. (Master's dissertation, Yıldız Technical University).
- [14] Albayrak, E., Yayla, R., & Yüzgeç, U. (2021). Mask R-CNN ile İHA Görüntülerinden Araç Tespiti. *International Symposium of Scientific Research and Innovative Studies*, 3.1, ss. 326-335.
- [15] Arvas, M. (2022). *Derin Öğrenme Algoritmaları Kullanılarak Döner Kanatlı İnsansız Hava Aracı Görüntülerinden Haşhaş, Kenevir ve Tütün Bitkilerinin Tespiti*. (Master's dissertation, Van Yuzuncu Yil University).
- [16] Baydoğan, C., & Alataş, B. (2021) Çevrimiçi Sosyal Ağlarda Nefret Söylemi Tespiti için Yapay Zeka Temelli Algoritmaların Performans Değerlendirmesi. *Firat Üniversitesi Müh. Bil. Dergisi*, 33(2), ss.745-754..
- [17] Başaran, G., & Cagıl, G. (2021). Koruyucu Gözlük Kullanımının Görüntü İşleme Yöntemiyle Tespit Edilmesi. *El-Cezeri*, 9(1), 86-95.
- [18] Çalışkan, D. (2022). *Derin Öğrenme Yöntemleri ile Şüpheli Davranış Tespiti*. (Master's dissertation, Marmara University).
- [19] Evren, E. (2020). *Otomotiv Sektöründe Saha Çalışanlarının Dijital Dönüşüm Kapsamında Güvenlik Yeleği Ve Baretlerinin Yapay Sinir Ağı Yöntemi İle Algılanması*. (Master's dissertation, Sakarya University).
- [20] Yıldırım, B., & Cagıl, G. (2020). Bir montaj parçasının derin öğrenme ve görüntü işleme ile tespiti. *Journal of Intelligent Systems: Theory and Applications*, 3(2), 31-37.
- [21] Murat, S. (2021). *İnsansız Hava Aracı Görüntülerinden Derin Öğrenme Yöntemleriyle Nesne Tanıma*. (Master's dissertation, Maltepe University).
- [22] Thuan, D. (2021). *Evolution of Yolo algorithm and Yolov5: The State-of-the-Art object detention algorithm*. (Master's dissertation, Oulu University).
- [23] Ketua, T. (2020). *Facial Expression Detection and Recognition System with Yolo Algorithm and Convolutional Neural Network*. (Master's dissertation, Tarumanagara University).
- [24] İnkaya, M. F. (2021). *Derin Öğrenme Algoritmaları Kullanarak Güvenli Çocuk Oyun Alanlarında Karşılaştırmalı Tehlikeli Nesne Tespiti Yapılması*. (Master's dissertation, Bursa Technical University).
- [25] Mao, Q. C., Sun, H. M., Liu, Y. B., & Jia, R. S. (2019). Mini-YOLOv3: real-time object detector for embedded applications. *Ieee Access*, 7, 133529-133538.
- [26] Azimjonov, J. (2021). *Kavşak ve Karayollar için Gerçek Zamanlı Görüntü Tabanlı Trafik Akış Bilgisi Hesaplama Sistemlerinin Geliştirilmesi*. (Doctoral dissertation, Bursa Technical University).
- [27] Havuç, E., Alpak, Ş., Çakırel, G., & Baran, M. K. (2021). Derin Öğrenme Vasıtasıyla Masa Tenisi Topu Takibi. *Avrupa Bilim ve Teknoloji Dergisi*, (27), 629-635.
- [28] Çelik, S. (2022) *Derin Öğrenme Yöntemlerini Kullanarak İHA Görüntülerinden Çevresel Atık Tespiti*. (Master's dissertation, Firat University).