



# Transfer öğrenme kullanılarak geri dönüşüm atıklarının sınıflandırılması

## Classification of recycling waste using transfer learning

Büşra Betül Çavuşoğlu<sup>1</sup> Hasan Badem<sup>2,\*</sup>

<sup>1,2</sup> Kahramanmaraş Sütçü İmam Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kahramanmaraş Türkiye

### Öz

Günümüzde artan sanayileşme ve nüfus, atık sayısının artması sebep olmuştur. Dolayısıyla atık yönetimi ve geri dönüşüm süreçleri büyük bir önem kazanmaktadır. Geliştirilmiş nesne atık tespit sistemleri; atıkların doğru bir şekilde sınıflandırılmasını, geri dönüşüm süreçlerinin verimliliğini artırılmasında önemli rol oynamaktadır. Bu çalışmada, geri dönüşümlü atıkların nesne tespiti için transfer öğrenme temelli YOLOv8 kullanılmıştır. YOLO yönteminin başarısının değerlendirmek için YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x ve RT-DETR modelleri kullanılmıştır. Gerçekleştirilen deneysel sonuçlarda en etkin olan modelin YOLOv8n olduğu gözlenmiştir. Ayrıca, önerilen modelde atık görüntüsü, video veya web kamerası kullanılarak gerçek zamanlı olarak sınıflandırılma gerçekleştirilmiştir. Modelleme için 7963 farklı görüntü kullanılmıştır. Eğitilmiş olan model ile geri dönüşümü hedeflenen sıklıkla kullanılan Batarya, Şişe Kapağı, Karton, Çöp Poşeti, Cam Şişe, Plastik Poşet, Plastik Şişe ve Teneke nesnelere tespit edilebilmektedir. Önerilen yöntem ile geri dönüşüm atık nesnelere %86.6 ortalama doğruluk oranı (mAP) ile tespit edilmiştir.

**Anahtar kelimeler:** YOLO, Atık yönetimi, Transfer öğrenme, Nesne atık tespiti, Çevresel sürdürülebilirlik

### 1 Giriş

Atıklar, çağımızın en önemli çevresel sorunlarından biri olarak karşımıza çıkmaktadır. Günümüzde hızla artan nüfus, sanayileşme ve tüketim alışkanlıklarının da etkisiyle atık yönetimi ve geri dönüşüm süreçlerinin iyileştirilmesi önemli bir problem haline gelmiştir. Birleşmiş Milletler Çevre Programı (UNEP) ve Uluslararası Katı Atık Birliği (ISWA) tarafından 2024 yılında ortaklaşa hazırlanan bir rapora göre dünya çapında her yıl iki milyar tondan fazla kentsel katı atık üretildiği hesaplanmıştır. 2050'ye kadar ise 3.8 milyar tona çıkacağı tahmin edilmektedir [1]. Bu atıklar, doğru atık yönetimi ve geri dönüşüm faaliyetleri olmadan doğrudan ve dolaylı yollarla çevresel dengenin bozulmasına ve iklim değişikliğine yol açabileceği düşünülmektedir. Özellikle yanlış yönetilen atıklar, çevreye zararlı gazların atmosfere salınmasına yol açar ve bu da sera etkisiyle doğrudan iklim değişikliğine neden olabilmektedir [2].

Aynı zamanda atıklar ve kötü atık yönetimleri ülkeleri sosyal ve ekonomik olarak etkilemektedir [3, 4]. Bu süreçte atıkların doğru bir şekilde sınıflandırılması ve geri dönüşüm süreçlerinin etkin bir şekilde yönetilmesi, çevresel

### Abstract

Nowadays, increasing industrialization and population have caused an increase in the amount of waste. Thus, waste management and recycling processes have gained great importance. Improved object waste detection systems play an important role in the correct classification of waste and in increasing the efficiency of recycling processes. In this study, transfer learning based YOLOv8 was used for object detection of recyclable waste. YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x and RT-DETR models have been used to evaluate the success of the YOLO. In the experimental results, YOLOv8n was the most effective model is observed. In addition, real-time classification has been implemented by using waste images, video or webcam in the proposed model. 7963 different images were used for modeling. The trained model can detect frequently used objects including Battery, Bottle Cap, Cardboard, Garbage Bag, Glass Bottle, Plastic Bag, Plastic Bottle and Box. In the proposed method, recycling waste objects have been detected with an average accuracy rate (mAP) of 86.6%.

**Keywords:** YOLO, Waste management, Transfer learning, Object waste detection, Environmental sustainability

kaynakların korunmasına ve atıkların azaltılması sürecinde çok önemlidir. Ancak, el ile yapılan fiziksel atık sınıflandırma süreci, oldukça zahmetli, zaman alıcı ve pek çok hatalara açık bir süreçtir [5,6].

Bu zorluğu aşmak için son zamanlarda yapay zekâ ve görüntü işleme teknolojileriyle desteklenen otomatik nesne atık tespit sistemleri geliştirilmektedir [7, 8]. YOLOv8 ve RT-DETR algoritması, nesnelere görüntü, video ya da gerçek zamanlı, hızlı ve yüksek doğrulukta tespit edilmesini sağlayan bir nesne algılama algoritmalarıdır. Bu nedenle önerilen yöntemde, transfer öğrenme temelli YOLOv8 mimarisi kullanılmıştır. YOLOv8 mimarisi üzerinde geliştirilmiş olan YOLOv8'in YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x modelleri ve RT-DETR modelini eğiterek en yüksek doğruluğa sahip model YOLOv8n olduğu gözlenmiştir. Geliştirilen sistem ile resim, video ve gerçek zamanlı video stream üzerinden geri dönüşüm atıklarının sınıflandırılması amaçlanmıştır.

Literatür taraması sonucunda, bu çalışmayı diğer çalışmalardan ayıran özellikler;

\* Sorumlu yazar / Corresponding author, e-posta / e-mail: hbadem@ksu.edu.tr. (H. Badem)

Geliş / Received: 25.06.2024 Kabul / Accepted: 24.10.2024 Yayınlanma / Published: xx.xx.20xx  
doi: 10.28948/ngumuh.1504730

- YOLO'nun en yeni sürümlerinde birini kullanıyor olması. YOLOv8 ile atık tespitinde yapılan az çalışmanın olması
- Hem resim, hem video hem de gerçek zamanlı bir şekilde atık tespiti yapabilmesi.
- Şu ana kadar az sayıda örneği olan fazla çeşitlilikte sınıfa sahip olması ve yüksek doğrulukta olmasıdır.
- Web tabanlı entegrasyonu ile geniş bir kullanıcı kitlesine erişim sağlamak ve atık yönetimi süreçlerinin etkinliğini artırmaktadır.

2. bölümde literatür taraması, 3. Bölümde kullanılan materyal ve önerilen yöntem, 4. Bölümde ise deneysel sonuçlara yer verilmiştir. Son bölümde ise çıkarımlar ve ileriki çalışmalardan bahsedilmiştir.

## 2 Literatür özeti

Günümüzde YOLO algoritmaları kullanılarak yapılan birçok atık tespit çalışması bulunmaktadır;

Çelik vd. [9] 2023 yılında YOLOv3 derin öğrenme algoritması kullanarak İHA görüntülerinden gerçek zamanlı çevresel atık tespiti yapmışlardır. Pet ve cam şişelerden oluşan 2 sınıflı ve 2250 görüntüden oluşan veri setleri vardır. Veri setlerini %70 eğitim, %30 test verisi olmak üzere ayırmışlardır. Bu çalışmada ortalama doğruluk değeri (mAP) 0.84816 elde edilmiştir.

Kusurini vd. [10] tarafından 2021 yılında yapılan çalışmada ise YOLOv4 ve YOLOv4-tiny derin öğrenme algoritmaları kullanarak atık nesne tespiti ve sınıflandırması çalışması yapılmıştır. Veri setleri, cam, metal, kağıt ve plastik olmak üzere 4 sınıftan oluşmaktadır. Verisetin de 3870 atık görüntüsü bulunmaktadır. Çalışma giriş olarak resim, video ve web kamerası gibi 3 farklı girişi kullanılmıştır. YOLOv4'ün nesne tespiti için YOLOv4-tiny'ye göre daha iyi performans gösterdiğini, ancak hesaplama hızı açısından YOLOv4-tiny'nin skorlarının daha iyi olduğu rapor edilmiştir. Modelin en iyi ortalama doğruluk değeri (mAP) ise %89.59'dir.

Erin vd. [11] tarafından 2022 yılında yapılan çalışmada ise gerçek zamanlı atık tespiti amaçlanmıştır. Atıklar, 3D kamera kullanılarak tespit edilip, türüne göre görüntünün 3D konumu ve merkezi belirlenmiştir. Bu çalışmada YOLOv4 algoritması kullanılmıştır. Kağıt, metal, cam ve plastik olmak üzere 4 farklı atık sınıfı ve 1974 örneklem bulunmaktadır. Modelin ortalama doğruluk değeri 0.9571'dir.

Demir vd. [12] çalışmasında YOLOv4 algoritması ile su altında çöp tespiti için YOLOv4 tabanlı bir yöntem geliştirmişlerdir. Su altında bulunan plastik şişe, cam şişe ve plastik paket ve büyük plastik bidon nesnelere ait görüntüler toplanarak bir veri seti oluşturmuşlardır. Dört nesne türü için toplamda 720 sualtı görüntüsü toplanmıştır. 720 görüntü içerisinde 962 nesne mevcuttur. Bu görüntüleri Labellmg programı kullanılarak etiketlemişlerdir. Bu çalışmada 2 farklı Train ve Test ayırma yöntemi kullanmışlardır; 80:20 eğitim test ve 90:10 eğitim test. Bu ayırma yöntemlerinin ortalama doğruluk değerleri (mAP) sırasıyla %88.7 ve %75.8'dir.

Jiang vd. [13] YOLOv5s modeli ile gerçek zamanlı bir kırsal evsel çöp tespit sistemi yapmışlardır. Bu çalışmada çöpün türü ve büyüklüğünün tespit edilmesi amaçlanmıştır.

Veri seti çevrimiçi toplama, evsel çöplerin videoya çekimi ve kırsal alanlardan çöp görüntüleri alınarak oluşturulmuştur. Bu görüntülerden toplam on üç atık sınıfı elde edilmiştir ve toplam 7671 örneklem bulunmaktadır. Eğittikleri model ile tek bir çöp görüntüsünü %96.4 tespit doğruluğuyla ve 0.021 saniyede tespit edilebilmektedir.

Flores tarafından yapılan [14] gerçekleştirilen çalışmada, YOLOv5'e temelli bir atık tespit ve sınıflandırma modeli önerilmiştir. Çalışmada cam, metal, plastik, kağıt, karton ve çöp olmak üzere 6 sınıf bulunmaktadır. Çalışmada 2527 görselden oluşan bir veri seti kullanılmıştır. Eğitilen model ile %90.2 doğruluk, %91.6 geri çağırma ve %95.2 ortalama hassasiyet (mAP) değerleri elde edilmiştir.

Chen vd. [15] yaptıkları çalışmada su kaynaklarındaki atık tespiti için bir model önerilmiştir. Özellikle su yüzeyinde olan atıkların insansız araçlarla atık sınıflandırması yapılmasını hedeflemişlerdir. Çalışmada YOLOv5 algoritması kullanılmıştır. Orca veri seti üzerinde doğrulanmıştır. Modelin eğitim sonucunda YOLOv5'in mAP değerinin %84.9'a, hassasiyetin %88.7'ye ulaşılmıştır.

Pan vd. [16] Çin'de atık yönetimini geliştirmeye yardımcı olacak bir çalışma yapmışlardır. Bu çalışmada YOLOv8 algoritmasını kullanarak çöp sınıflandırması yapan akıllı çöp kutusu geliştirmişlerdir. 4 kategoriye sahip yaklaşık 10.000 özel çöp veri seti kullanılmıştır. Ortalama doğruluk değeri (mAP) %100'e yakın çıkmıştır.

Shukhratov vd. [17] yaptıkları çalışmada plastik atıkların videolar üzerinde tespitini yapmışlardır. Bu çalışmada Faster R-CNN, RetinaNet ve YOLOv8 olmak üzere 3 farklı nesne algılama modelleri kullanılmıştır. Eğitimler sonucunda YOLOv8'in diğer modellerden daha iyi sonuç verdiği ve ortalama doğruluk değeri (mAP) %95.67 gözlenmiştir.

Panmuang vd. [18] yaptığı çalışmada Tayland'da Bangkok'un kentsel alanlarındaki CCTV kameralarından gelen 1383 görüntüyü YOLOv5n, YOLOv6n, YOLOv7 ve YOLOv8n'den oluşan YOLO versiyonlarıyla karşılaştırılmıştır. Karşılaştırma sonuçları, YOLOv5n'in sınıfları %94.50 doğrulukla sınıflandırabildiğini, sırasıyla %93.80 ile YOLOv8n, %71.60 ile YOLOv6n ve %24.60 ile YOLOv7 sonuç verdiğini rapor edilmiştir. Bu çalışmada YOLOv8 modeli hem hız hem de doğruluk bakımından önceki versiyonlarından daha iyi performans verdiğini göstermektedir.


Zhu vd. [19] 2024 yılında yaptıkları çalışmada insansız hava araçlarının (İHA) tespiti için iki İHA veri seti kullanılmıştır. İlk veri setinde 1360 adet İHA görüntüsü bulunurken, ikinci veri setinde ise 5238 eğitim görüntüsü, 1345 doğrulama görüntüsü ve 678 test görüntüsünden oluşmaktadır. YOLOv7, YOLOv8, RT-DETR ve Gold-YOLO'un farklı sürümleri ile iki veri seti üzerinden modelleme gerçekleştirilmiştir. RT-DETR yöntemi her iki İHA veri seti üzerindeki doğruluğunun sırasıyla %95.6 ve %97.8'e ulaşarak en yüksek doğruluğa sahip olduğunu rapor edilmiştir.

## 3 Materyal ve metod

Bu bölümde sırasıyla atık sınıflandırması için kullanılan YOLOv8 ve RT-DETR nesne tespit algoritmaları, veri seti,

performans değerlendirilmesinde kullanılan metrikler, önerilen yöntem ve web entegrasyona yer verilmektedir.

Atık nesnelere sınıflandırılması için YOLOv8 tabanlı önerilen sistemin işlem akışı modeli Şekil 1’de verilmiştir.



Şekil 1. Önerilen sistemin işlem akışı modeli

### 3.1 YOLOv8

YOLOv8, Ocak 2023'te Ultralytics [20] tarafından piyasaya sürülen açık kaynaklı bir nesne algılama modelidir. YOLO algoritmasının 8. Sürümüdür. Bilgisayarlı görme ve derin öğrenme alanlarında kullanılmaktadır. Doğruluk ve hız açısından yüksek performans sunmaktadır.

YOLO'nun açılımı "You Only Look Once" (Yalnızca Bir Kez Bak) dır. Bir resimde, videoda ya da gerçek zamanda gördüğü nesnelere hızlı ve tek seferde algılayıp tanıyan bir yapay zeka teknolojisidir [21].


Şekil 2'de görüldüğü üzere YOLOv8'i önceki sürümlerine göre parametre sayısı ile performans arasındaki başarımlar daha yüksektir. Bu nedenle hesaplama süresi görece daha düşüktür.

YOLOv8, nesne tespiti (object detection) ve takibi (tracking), örnek segmentasyonu (instance segmentation), görüntü sınıflandırması (image classification) ve poz tahmini (pose estimation) problemleri için ön eğitilmiş bir teknolojidir [23]. Bu çalışmada atık nesne tespiti için transfer öğrenme temelli YOLOv8 mimarisi kullanılmıştır.

YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x nesne tespiti için özelleştirilmiş versiyonlardır. Bu yöntemlerin karşılaştırması Tablo 1’de sunulmuştur.

Atık nesne tespiti için veri seti ile YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x modelleri eğitilmiştir.

Modelleme sonucunda en yüksek doğruluğa sahip olan YOLOv8n modelinin olduğu görülmektedir. Web tabanlı uygulama da eğitilmiş YOLOv8n mimarisi kullanılmıştır



Şekil 2. YOLO versiyonlarının performans karşılaştırması [22]

Tablo 1. YOLO nesne tespit modelleri [24]

Model	Boyut (Piksel)	mAP val 50-95	Hız CPU ONNX (ms)	Hız A100 Tensor RT (ms)	Parametreler (M)	FLOP'lar (B)
YOLO v8n	640x640	37.3	80.4	0.99	3.2	8.7
YOLO v8s	640x640	44.9	128.4	1.20	11.2	28.6
YOLO v8m	640x640	50.2	234.7	1.83	25.9	78.9
YOLO v8l	640x640	52.9	375.2	2.39	43.7	165.2
YOLO v8x	640x640	53.9	479.1	3.53	68.2	257.8

### 3.2 YOLOv8 mimarisi

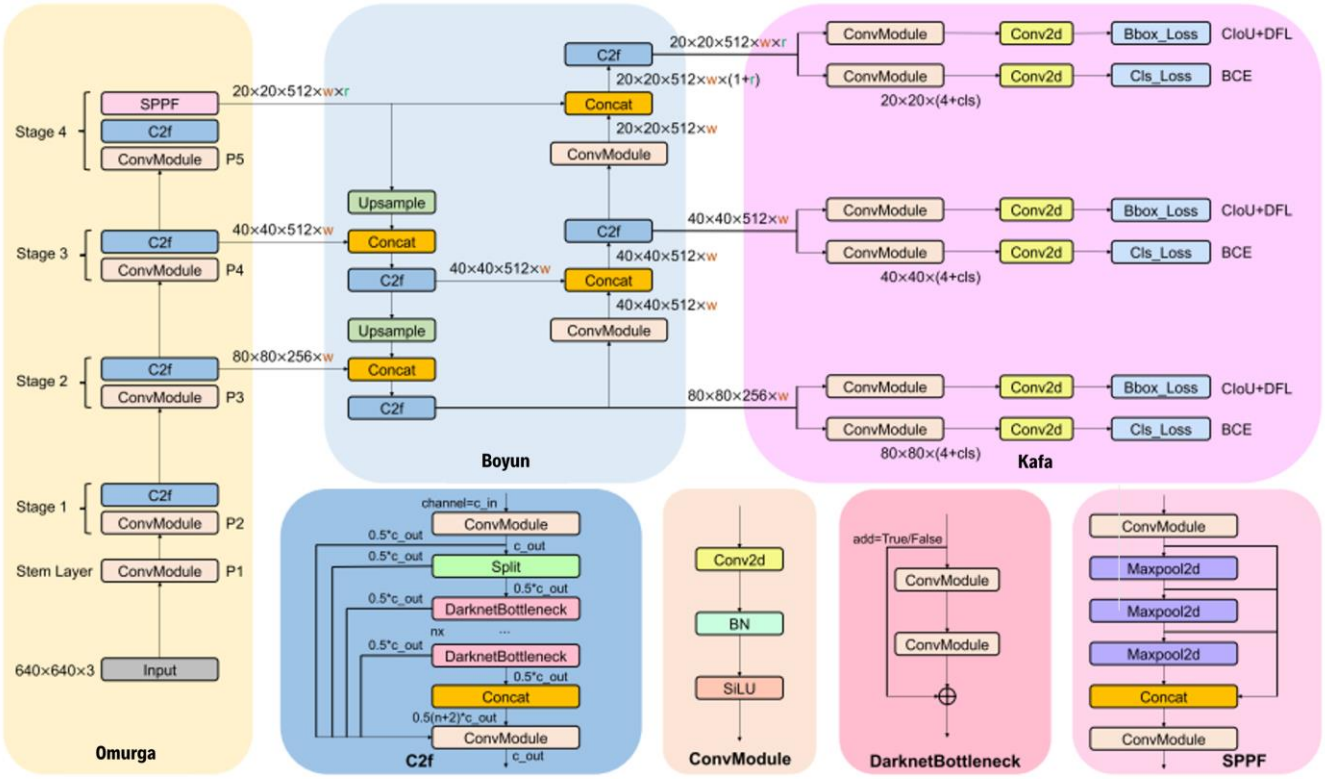
YOLOv8 mimarisi 3 ana bileşenden oluşmaktadır. Omurga (Backbone), Boyun (Neck), Kafa (Head) [25].

**Omurga (Backbone):** Görüntüdeki özellik çıkarma işleminden sorumludur. Omurga evrişimli sinir ağı (Convolutional neural network) katmanlarından oluşmaktadır. Bu katmanlar girdi olarak aldığı görüntüyü kenarlar, köşeler ve dokular gibi temel özelliklerini çıkarmaktadır. YOLOv8, omurgası olarak Darknet'in bir versiyonu olan CSPDarknet53'ü kullanılmaktadır [26].

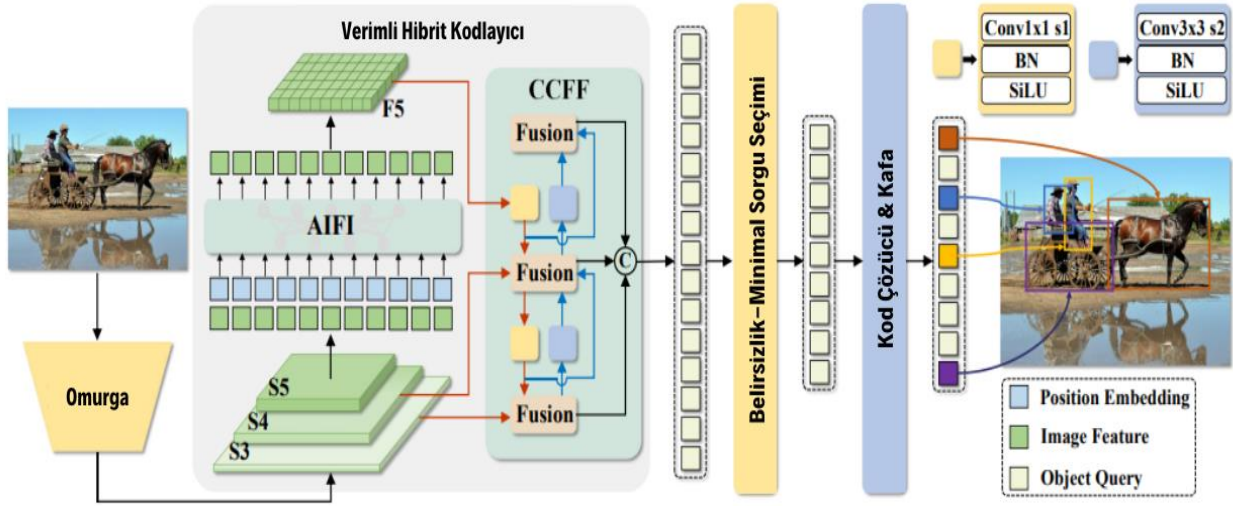
**Boyun (Neck):** Omurga ve kafa arasındaki bağlantıyı sağlamaktadır. Omurgadan gelen özellik bilgilerini alıp işler ve özellik hatalarını toplar. YOLOv8'de bu kısım, FPN (Feature Pyramid Network) veya PANet (Path Aggregation Network) yapılarının kullanımı ile gerçekleştirilmektedir [26].

**Kafa (Head):** YOLOv8 algoritmasındaki işleğin son kısmıdır. Nesne algılama ve sınıflandırma işlemi bu aşamada gerçekleştirilir. Bu bölümde Omurgada olduğu gibi evrişimli sinir ağı mimarisine yer verilmektedir. Bu katmanlar ızgara yapısı (srid structure) ve konum bilgisi (bounding boxes) yapılarını kullanarak nesne tahmini gerçekleştirilmektedir [26].

Şekil 3'te Genel YOLOv8 mimari modeli sunulmuştur [27].



Şekil 3. YOLOv8 mimarisi



Şekil 4. RT-DETR mimarisi [28]

### 3.3 RT-DETR

Gerçek Zamanlı Algılama Dönüştürücüsü (Real-Time Detection Transformer (RT-DETR)) modeli, Yi Liu vd. [28] tarafından önerilmiştir. RT-DETR modeli 2024 yılında geliştirilen ve gerçek zamanlı performans sağlayan bir nesne tanıma algoritmasıdır.

RT-DETR mimarisi 3 temel özellikten oluşmaktadır. Bunlar:

#### 1. Verimli Hibrit Kodlayıcı:

RT-DETR, ölçek içi etkileşimi ve ölçekler arası füzyonu ayırarak çok ölçekli özellikleri işleyen verimli bir hibrit kodlayıcı kullanır. Bu tasarım, hesaplama maliyetlerini

düşürür ve gerçek zamanlı nesne tespiti performansını artırır [28].

### 2. IoU Farkındalıklı Sorgu Seçimi:

RT-DETR, IoU (Intersection over Union; IoU farkındalı Sorgu Seçimi) farkındalıklı sorgu seçimi kullanarak nesne sorgularından sorumludur. Bu yaklaşım, modelin sahnedeki en alakalı nesnelere odaklanmasını sağlar, böylece algılama doğruluğunu önemli ölçüde artırır [28].

### 3. Uyarlanabilir Çıkarım Hızı:

RT-DETR, farklı kod çözücü katmanları kullanarak çıkarım hızının esnek bir şekilde ayarlanmasını destekler. Bu uyarlanabilirlik, yeniden eğitime gerek kalmadan çeşitli gerçek zamanlı nesne algılama senaryolarında pratik uygulamayı kolaylaştırmaktadır [28]. RT-DETR mimarisini Şekil 4'te görmektedir.

### 3.4 Veri seti

Bu çalışmada kullanılan veri seti, görüntü işleme projelerinde veri seti oluşturma, yönetme, veri etiketleme gibi işlemleri yapmamızı sağlayan yaygın kullanılan bir platform olan Roboflow [29] kullanılarak oluşturulmuştur. Roboflow web sitesi üzerinde var olan etiketlenmiş 25 farklı veri seti [30-54] problemimiz ile ilgili görüntüler seçilerek büyük bir seti elde edilmiştir. Elde edilen veri seti [55] de sunulmuştur.

Toplamda 7963 resim içeren veri seti, 8 sınıftan oluşmaktadır. Veri setinde olan sınıflar örneklem sayıları Tablo 2'de sunulmuştur.

**Tablo 2.** Veri seti atık sınıfları ve örneklem sayıları


Atık Sınıfları	Sayı
Batarya	988
Şişe Kapağı	928
Karton	851
Çöp Poşeti	713
Cam Şişe	1049
Plastik Poşet	889
Plastik Şişe	1274
Teneke	1243

Veri setinde bulunan sınıflara ait bazı örnek görseller Şekil 5'te görülmektedir.

Veri setinde bulunan sınıflar günümüzde en yaygın bilinen malzemelerden seçilmiştir. Veri seti Tablo 3'te de görüldüğü üzere Train (Eğitim) ve Test olarak ayrılmıştır. Veri seti %80 eğitim, %20 test klasörlerine ayrılmıştır.

**Tablo 3.** Veri seti eğitim ve test örneklem dağılımı

Train (Eğitim) Seti	Test Seti
6363	1600



**Şekil 5.** Veri setinden örnek görüntüler

### 3.5 Kullanılan metrikler

Bu çalışmada, geliştirilen nesne tespit sisteminin performansını değerlendirmek için literatürde yaygın kullanılan metrikler tercih edilmiştir. Bu metrikler; F1 Skor, Keskinlik (Precision), Geri Çağırma (Recall) ve Keskinlik-Geri Çağırma (Precision-Recall) eğrisidir. Aşağıda bu metriklerle ait denklemler ve açıklamalara yer verilmiştir.

Modelin performansını değerlendirmek için kullanılan bu metrikler Doğru Pozitif (TP), Yanlış Pozitif (FP), Doğru Negatif (TN) ve Yanlış Negatif (FN) değerleri kullanılarak tanımlanmaktadır [56].

F1 Skor eğrisi, Keskinlik ve Geri Çağırma'nın ağırlıklı ortalamasıdır. Formülü;

$$F1\ Skor = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (1)$$

Keskinlik (Precision) eğrisi, eğitilen modelin yaptığı pozitif tahminlerin toplam pozitif tahmine oranını karşılık gelmektedir.

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

Geri Çağırma (Recall) eğrisi, eğitilen modelin gerçek pozitifleri tahminlerinin TP ve FN nin toplamına oranına karşılık gelmektedir.

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

Keskinlik-Geri Çağırma (Precision-Recall) eğrisi, özellikle sınıflar arasında dengesizlik olduğunda model performansını değerlendirmek için kullanılan bir grafikdir. Bu eğri, modelin Keskinlik (Precision) ve Geri Çağırma (Recall) metriklerini çeşitli eşik değerlerinde gösterir. X eksen, Geri çağırma (Recall); Y eksen, Keskinlik (Precision) değerlerini göstermektedir.

### 3.6 Model eğitimi

Bu çalışmada, modelleme işlemini Google Colab Pro [57] kullanılarak gerçekleştirildi. Google Colab Pro, Google'ın sunduğu özellikle veri bilimi, derin öğrenme ve makine öğrenmesi alanlarında kullanılan bir platformdur. Modelleme için dağıtık çalışan bulut CPU ve GPU'lar sunmaktadır. Veri setimizi ise Roboflow'un bize sağladığı API ile Google Colab Pro'ya YOLOv8 ile koşturulmuştur.

Veri seti YOLOv8'in nesne tespiti için derin öğrenme modelleri olan YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x sürümleri ve RT-DETR üzerinden eğitilmiştir. Tüm modellerde eğitim süreci, toplam 50 epoch boyunca gerçekleştirilmiş olup, her bir epoch'ta görüntüler 640x640 piksel boyutuna yeniden boyutlandırılmıştır. Eğitim süresince F1 skor eğrisi, Keskinlik eğrisi, Keskinlik-Geri Çağırma eğrisi ve Geri Çağırma eğrisi gibi modelin performans metrikleri görselleştirilmiştir. Eğitimler sonucunda elde edilen değerler Tablo 7'de sunulmuştur. Tablo incelendiğinde eğitilen modeller içerisinde en yüksek doğruluğa sahip model ortalama doğruluk değeri (mAP) 0.866 ile YOLOv8n olduğu görülmektedir. Bu nedenle atık nesne tespit sistemi için YOLOv8n modelinin daha uygun olduğu değerlendirilmektedir.

#### 3.6.1 Kullanılan parametreler

Modelin eğitimi sırasında Epochs (Dönem sayısı): 50 ve Görüntü boyutu (Image size): 640x640 piksel olarak ayarlanmıştır. Bu boyut, yeterli detay seviyesini korurken, hesaplama maliyetini makul seviyede tutmak amacıyla tercih edilmiştir.

Eğitim süreci, 50 epoch boyunca devam etmiştir. Bu süreçte model, her epoch'ta eğitim setindeki tüm görüntüleri kullanarak öğrenme işlemini gerçekleştirmiştir.

Modelin eğitim sürecinde **batch size** olarak her iterasyonda 16 örnek kullanılmıştır (batch=16). Bu, modelin parametre güncellemeleri için her adımda 16 görüntü üzerinden hesaplama yapmasını sağlamıştır. Ayrıca, optimizasyon algoritması **auto** olarak belirlenmiştir (optimizer=auto). Bu ayar, en uygun optimizasyon algoritmasının otomatik olarak seçilmesini sağlamış ve modelin daha etkili bir şekilde öğrenmesi amaçlanmıştır. Ek olarak veri setine Auto-Orient işlemi uygulanarak görüntülerin meta verilerine göre otomatik olarak doğru yöne döndürülmesi sağlanmıştır. Bu sayede model eğitimi ve tahminlerinde daha tutarlı sonuçlar elde edilmiştir.

### 3.7 Geliştirilen modelin web uygulama entegrasyonu

Geliştirilen yapay zeka modelini, son kullanıcı hizmetine sunabilmek için web tabanlı uygulama geliştirilmiştir. Geliştirilen web uygulaması ve eğittiğimiz YOLOv8n modelinin entegrasyonu bu alt bölümlerde sunulmuştur.

#### 3.7.1 Kullanılan teknolojiler

Web tabanlı entegrasyon sürecinde aşağıdaki teknolojiler kullanılmıştır:

Backend: Flask, Python 3.10  
Frontend: HTML, CSS, JavaScript  
Model: YOLOv8n (best.pt)


Flask, Python tabanlı bir web uygulama geliştirme ortamı olup, hızlı ve kolay bir şekilde uygulama geliştirmeye olanak tanımaktadır. HTML, CSS ve JavaScript ise frontend geliştirme için kullanılmıştır. HTML yapıyı oluştururken, CSS stil vermek için ve JavaScript etkileşimli unsurlar için kullanılmıştır.

Ortam: Pycharm Editör

Web tabanlı atık tespit sistemi arayüz görüntüleri Şekil 6 ve Şekil 7'de görülmektedir.



Şekil 6. Atık sınıflandırma web sitesi Ana Sayfa bölümü



Şekil 7. Atık sınıflandırma web sitesi Servisler bölümü


**Ana Sayfa Bölümü:** Kullanıcıların uygulamaya giriş yaptığı ilk karşılarına çıkan bölümdür.

**Servisler Bölümü:** Kullanıcıların fotoğraf yüklemesi, video yüklemesi veya web kamerasını kullanarak gerçek zamanlı görüntü yakalaması için bir arayüz.

### 3.8 Önerilen yöntem

Bu çalışma kapsamındaki Yolov8 tabanlı nesne atık tespit sistemi, atık yönetiminde önemli bir yenilikçi adımı temsil etmektedir. Bu çalışma aynı zamanda hem akademik hem de pratik anlamda atık yönetimi süreçlerine katkı sağlamayı amaçlamaktadır. Yolov8 tabanlı bu sistem, hem kullanıcıların atık sınıflandırma sürecini kolaylaştırmakta hem de geri dönüşüm endüstrisindeki verimliliği artırarak çevreye olan olumlu etkileri güçlendirmeyi hedeflemektedir.

Önerilen yöntemin uygulama mimarisi Şekil 8'de sunulmuştur.



Şekil 8. Uygulama mimarisi

## 4 Deneysel sonuçlar


### 4.1 Model optimizasyonu ve değerlendirme

YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x sürümleri ve RT-DETR üzerinden gerçekleştirilen eğitim süreci tamamlandıktan sonra, modelin performansı Test veri seti üzerinde değerlendirilmiştir. Elde edilen doğruluk değerleri Tablo 4 de sunulmuştur. Tablo incelendiğinde, en yüksek ortalama doğruluk değeri (mAP) 0,866 ile YOLOv8n'den elde edilmiştir.


**Tablo 4.** Veri seti üzerinde eğitilen Yolov8 ve RT-DETR modellerinin doğruluk oranları

Nense Tespit Modelleri	Doğruluk
YOLOv8n	%86.6
YOLOv8s	%86.4
YOLOv8m	%85.4
YOLOv8l	%85.9
YOLOv8x	%85.7
RT-DERT	%85.8


YOLOv8n temelli önerilen yöntemin performans analizi değerlendirilebilmesi için eğitilen modelden elde edilen F1 skor eğrisi, Keskinlik (Precision) eğrisi, Geri Çağırma (Recall) eğrisi ve Keskinlik-Geri Çağırma (Precision-Recall) eğrisi hesaplanarak sırasıyla Şekil 9, Şekil 10, Şekil 11, Şekil 12'de sunulmuştur.



Şekil 9. F1 skor eğrisi




Şekil 10. Keskinlik (Precision) eğrisi



Şekil 11. Geri Çağırma (Recall) eğrisi

Tablo 5'te F1 skor eğrisi, Keskinlik (Precision) eğrisi, Geri Çağırma (Recall) eğrisi ve Keskinlik-Geri Çağırma (Precision-Recall) eğrisinin performans metriklerinin sayısal değerlerini rapor edilmiştir. Tablo 4 incelendiğinde F1 skoru için 0.82 değeri elde edilmiştir. Bu veri modelin hem hassas hem de duyarlılığının yüksek olduğu bilgisini vermektedir. Precision oranımız mutlak tam sonucuna ulaşılmıştır. Bu veri modelimizin bir sınıfı doğru olarak tahmin etmede son derece kesin ve güvenilir olduğunu göstermektedir. Recall değeri ise 0.92 olarak hesaplanmıştır. Keskinlik-Geri Çağırma değeri ise 0.866 olduğu görülmektedir. Bu değerlerin yüksek olması, modelimizin dengeli ve iyi bir performansa sahip olduğunu ortaya koymaktadır.



Şekil 12. Keskinlik-Geri Çağırma (Precision-Recall) eğrisi

**Tablo 5.** Performans metriklerinin sayısal değerleri

F1 Skor	Keskinlik	Geri Çağırma	Keskinlik-Geri Çağırma
0.82	1.0	0.92	0.866

Geliştirilen sistemin genel olarak değerlendirilebilmesi için karmaşıklık matrisi hazırlanarak Şekil 13'te rapor edilmiştir.



Şekil 13. Karmaşıklık matrisi

Şekil 13'te modelimizin Test veri setinde değerlendirilmesi sonucu oluşan Karmaşıklık Matrisi verilmiştir. Şekil incelendiğinde, model cam şişe verilerini ve plastik poşet olarak hatalı tahmin etti görülmektedir. Diğer tüm geri dönüşüm atıklarının neredeyse hatasız tahmin edebildiği anlaşılmaktadır. Şekil genel olarak değerlendirildiğinde oldukça yüksek doğru tahmin değeri elde edildiği görülmektedir.

#### 4.2 K-Kat çapraz doğrulama ile değerlendirme

Modelin kararlılığını değerlendirmek ve veri setine olan bağlı olmadan performansını değerlendirme amacıyla YOLOv8n modeline K-kat çapraz doğrulama (K-fold cross validation) yöntemi uygulanmıştır. Bu yöntem, veri kümesini eşit büyüklükteki K alt kümelere ayırarak, modelin her bir katı üzerinde eğitim ve test edilmesini sağlamaktadır. Böylece, modelin genel performansı farklı veri parçaları üzerinde ölçülmüş ve aşırı öğrenme (overfitting) riski azaltılmıştır. Çalışmamızda K değeri olarak 5 seçilmiş olup, her kat için model performansını ve ortalama performans ile

kayıpları sunulmuştur. Uygulanan K-kat çapraz doğrulama yönteminde kullanılan parametreler: batch = 16 ve epoch=50 ve K=5 olarak ayarlanmıştır.

K kat çapraz doğrulama uygulandıktan sonra her katmandaki oluşan keskinlik, geri çağırma, mAP50 ve mAP50-95 sonuçları Tablo 6'da rapor edilmiştir. Tüm bu katmanların ortalaması ve standart sapmaları ise Tablo 7'de sunulmuştur.

Tablo 6. Önerilen yöntemin K-kat çapraz doğrulama sonuçları

Model Performansı (Her kat için)	Keskinlik	Geri Çağırma	mAP50	mAP50-95
Kat 1	0.9306	0.9159	0.9506	0.8243
Kat 2	0.9557	0.9264	0.9606	0.8463
Kat 3	0.9724	0.9754	0.9860	0.9024
Kat 4	0.9711	0.9486	0.9749	0.8834
Kat 5	0.9837	0.9803	0.9907	0.9043

Tablo 7. Ortalama performans ve kayıplar

Metrik	Ort.	Stad. Sapma
Keskinlik	0.9627	0.0184
Geri Çağırma	0.9493	0.0256
mAP50	0.9726	0.0151
mAP50-95	0.8722	0.0317
Eğitim Kaybı	0.0013	0.0016
Doğrulama Kaybı	1.9411	0.5497

Geliştirilen sistemin modellenmesinin de 25 farklı veri seti birleştirilerek kapsamlı bir veri kaynağı oluşturulmuştur. Literatür araştırmalarında kullanılan veri setlerinden bir kısmının birleştirildiği veya sadece tekil kullanım modelleri rapor edilmiştir. Bu nedenle adil bir karşılaştırma yapılabilecek rakip modeller bulunamamıştır. Fakat, geliştirilen modelin literatüre göre başarımının da değerlendirilebilmesi adına Tablo 8 hazırlanmıştır. Bu tablo incelendiğinde örnek sayısı olarak en yakın rakibe göre yaklaşık 2 katı örneklem kullanıldığı ve 4 farklı sınıfta modele eklendiği görülmektedir. Ayrıca en kapsamlı sınıf adetine de bizim çalışmamızda yer verildiği görülmektedir. Bahsedilen sınırlılıklar dikkate alındığında %86.6 ile oldukça yüksek bir doğruluk değeri elde edildiği görülmektedir.

Tablo 8. Önerilen Yöntemin literatür ile karşılaştırılması

Referans	Metod	Sınıf	Örneklem Sayısı	Doğruluk Skoru
Çelik vd. [9]	YOLOv3	Pet ve Cam	2250	%84.8
Kusrini vd. [10]	YOLOv4	Cam, Metal, Kağıt ve Plastik	3870	%89.59
Erin vd. [11]	YOLOv4	Kağıt, Metal, Cam ve Plastik	1974	%95.7
Flores [14]	YOLOv5	Cam, Metal, Plastik, Kağıt, Karton ve Çöp	2527	%95.2
Shukhratov vd [17]	Faster R-CNN, RetinaNet ve YOLOv8	Cam, Plastik, Kağıt, karton, Metal ve Çöp	1900	%95.67
Panmuang vd. [18]	YOLOv5n, YOLOv6n, YOLOv7 ve YOLOv8n	Çöp Kutusu ve Çöp	1383	%93.80
Önerilen Yöntem	YOLOv8n	Batarya, Şişe Kapağı, Karton, Çöp Poşeti, Cam Şişe, Plastik Poşet, Plastik Şişe, Teneke	7963	%86.6
Önerilen Yöntem	RT-DETR	Batarya, Şişe Kapağı, Karton, Çöp Poşeti, Cam Şişe, Plastik Poşet, Plastik Şişe, Teneke	7963	%85.8

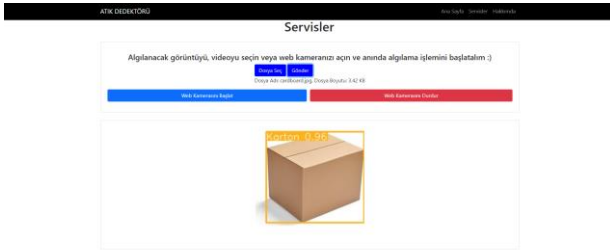




Şekil 14. Önerilen yöntemin test veri seti üzerinden örnek sınıflandırma tahminleri

Geliştirilen geri dönüşüm atıklarının sınıflandırılması sistemine ait birkaç örneklem ait sınıflandırma tahminleri Şekil 14’te sunulmuştur.

Şekil 15’te ise geliştirilen sınıflandırma modelinin web entegrasyonu üzerinden bir çalışma örneği sunulmuştur.



Şekil 15. Web uygulama üzerinden atık tespiti

## 5 Sonuç

Bu çalışmada derin öğrenme tabanlı transfer öğrenme ile geri dönüşüm atıklarının tespit edilmesi amaçlanmıştır. Modelin başarısını artırmak için 25 farklı veri setinin görüntüleri birleştirilerek büyük bir veri seti elde edilmiştir. Modelleme sürecinde nesne tespitten etkin olan YOLOv8n modeli kullanılmıştır. Bu çalışma ile atık sınıflandırmada insan gücüne dayalı ayrıştırma sürecine alternatif otonom bir model ortaya koyulmuştur. Bu çalışma atık yönetimi ve geri dönüşüm alanında alternatif yöntemlerin geliştirilmesine katkı sağlayabilir. İleriki çalışmalarda geri dönüşüm ayrıştırma kurumlarında gerçek zamanlı robotik sistemlere entegre sistemler geliştirilebilir. Paralel tahmin modelleri ortaya koyulabilir.

## Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

**Benzerlik oranı (iThenticate):** % 9

## Kaynaklar

[1] United Nations Environment Programme, Global Waste Management Outlook 2024: Beyond an age of

waste – Turning rubbish into a resource. Nairobi, 2024. <https://wedocs.unep.org/20.500.11822/44939>.

[2] U.S. Environmental Protection Agency, Global Greenhouse Gas Emissions Data, 2019. <https://www.epa.gov/ghgemissions/global-greenhouse-gas-overview>.

[3] Department of Environment, Science and Innovation, Queensland, Economic Impacts, WetlandInfo website, 2021. <https://wetlandinfo.des.qld.gov.au/wetlands/management/pressures/litter-illegal-dumping/effects-values/economic-impacts.html>.

[4] N. Ferronato ve V. Torretta, Waste mismanagement in developing countries: A review of global issues, International Journal of Environmental Research and Public Health, 16 (6), 1060, 2019. <https://doi.org/10.3390/ijerph16061060>.

[5] J. Bobulski ve M. Kubanek, Deep learning for plastic waste classification system, Applied Computational Intelligence and Soft Computing, 2021, 6626948, 7 sayfa, 2021. <https://doi.org/10.1155/2021/6626948>.

[6] N. Nnamoko, J. Barrowclough ve J. Procter, Solid waste image classification using deep convolutional neural network, Infrastructures, 7, 47, 2022. <https://doi.org/10.3390/infrastructures7040047>.

[7] BBC Türkçe, Yapay zeka atıkları azaltmak ve geri dönüşümü artırmak için nasıl kullanılabilir?. <https://www.bbc.com/turkce/articles/cn0k40m2ndjo>.

[8] Recycleye, <https://recycleye.com/>. Accessed 24 June 2024

[9] A. Altınörs ve S. Çelik, YOLOv3 derin öğrenme algoritması ile İHA görüntülerinden çevresel atık tespiti, International Journal of Innovative Engineering Applications, 7 (1), 76-85, 2023. <https://doi.org/10.46460/ijiea.1195428>.

[10] K. Andhy Panca Saputra ve K. Kusri, Waste object detection and classification using deep learning algorithm: YOLOv4 and YOLOv4-tiny, Turkish Journal of Computer and Mathematics Education

- (TURCOMAT), 12 (14), 1666–1677, 2021. <https://doi.org/10.17762/turcomat.v12i14.10504>.
- [11] K. Erin, B. Bingöl ve B. Boru, YOLO – Based waste detection, *Journal of Smart Systems Research*, 3 (2), 120-127, 2022.
- [12] K. Demir ve O. Yaman, A YOLOv4-based method for underwater litter detection, *International Informatics Congress (IIC2022) (Haz.)*, ss. 354-361, 2022.
- [13] X. Jiang, H. Hu, Y. Qin ve diğ., A real-time rural domestic garbage detection algorithm with an improved YOLOv5s network model, *Sci Rep*, 12, 16802, 2022. <https://doi.org/10.1038/s41598-022-20983-1>.
- [14] E. J. C. Flores, A YOLOv5s Model for classification of garbage, *Southeast Asian Journal of Science and Technology*, 8 (1), 9-18, 2023. <https://sajst.org/online/index.php/sajst/article/view/285>.
- [15] L. Chen ve J. Zhu, Water surface garbage detection based on lightweight YOLOv5, *Sci Rep*, 14 (1), 6133, 2024. <https://doi.org/10.1038/s41598-024-55051-3>.
- [16] S. Pan, N. Wang, Y. Lin ve J. Tang, Based on YOLOV8 intelligent trash can garbage classification detection algorithm, *Mathematical Modeling and Algorithm Application*, 2 (1), 28-32, 2024. <https://doi.org/10.54097/67mska34>.
- [17] I. Shukhratov, A. Pimenov, A. Stepanov, N. Mikhailova, A. Baldycheva ve A. Somov, Optical detection of plastic waste through computer vision, *Intelligent Systems with Applications*, 22, 200341, 2024. <https://doi.org/10.1016/j.iswa.2024.200341>.
- [18] M. Panmuang ve C. Rodmorn, Garbage detection using YOLO algorithm for urban management in Bangkok, *WSEAS Transactions on Computer Research*, 12, 236-243, 2024. <https://doi.org/10.37394/232018.2024.12.23>.
- [19] M. Zhu ve E. Kong, Multi-scale fusion uncrewed aerial vehicle detection based on RT-DETR, *Electronics*, 13 (8), 1489, 2024. <https://doi.org/10.3390/electronics13081489>.
- [20] Ultralytics, <https://www.ultralytics.com/tr>. Accessed 24 June 2024.
- [21] J. Terven, D. Córdova-Esparza ve J. Romero-González, A comprehensive review of YOLO architectures in computer vision: From YOLOv1 to YOLOv8 and YOLO-NAS, *Machine Learning and Knowledge Extraction*, 5 (4), 1680–1716, Kasım 2023. <https://doi.org/10.3390/make5040083>.
- [22] Ultralytics. <https://docs.ultralytics.com/tr/models/yolov8/>. Accessed 24 June 2024.
- [23] Supported Tasks and Modes. <https://docs.ultralytics.com/models/yolov8/#supported-tasks-and-modes>. Accessed 24 June 2024.
- [24] Ultralytics. <https://docs.ultralytics.com/tr/models/yolov8/#performance-metrics>.
- [25] YOLOv8 Architecture: A Deep Dive into its Architecture. <https://yolov8.org/yolov8-architecture/>. Accessed 24 June 2024.
- [26] B. Yu, S. Li, W. Wang ve diğ., The DCN-BiFPN Object Detection Algorithm based on YOLOv8, 14 Mart 2024, PREPRINT (Versiyon 1), Research Square. <https://doi.org/10.21203/rs.3.rs-4019974/v1>.
- [27] R.-Y. Ju ve W. Cai, Fracture detection in pediatric wrist trauma X-ray images using YOLOv8 algorithm, *Scientific Reports*, 13, 2023. <https://doi.org/10.1038/s41598-023-47460-7>.
- [28] Y. Zhao, W. Lv, S. Xu, J. Wei, G. Wang, Q. Dang, Y. Liu ve J. Chen, DETRs Beat YOLOs on Real-time Object Detection, arXiv. <https://arxiv.org/abs/2304.08069>.
- [29] Roboflow. <https://roboflow.com/>. Accessed 24 June 2024.
- [30] YOGI TRI A., Kardus Packing Dataset, Roboflow Universe, Kasım 2023. <https://universe.roboflow.com/yogi-tri-a/kardus-packing/dataset/2>. Accessed 24 June 2024.
- [31] packagedetection, package-detection Dataset, Roboflow Universe, Aralık 2023. <https://universe.roboflow.com/packagedetection/package-detection-kt9ut/dataset/2>.
- [32] YOGI TRI A., Box Carton Package Detection Dataset, Roboflow Universe, Kasım 2023. <https://universe.roboflow.com/yogi-tri-a/box-carton-package-detection/dataset/6>. Accessed 24 June 2024.
- [33] Chris Adam, Digital Capsx27;ule memories Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/chris-adam-b9cuh/digital-caps-ule-memories/browse?queryText=&pageSize=50&startingIndex=0&browseQuery=true>. Accessed 24 June 2024.
- [34] bottle cup detection, bottle cap color detection Dataset, Roboflow Universe, Ekim 2023. <https://universe.roboflow.com/bottle-cup-detection-gnira/bottle-cap-color-detection/dataset/9>. Accessed 24 June 2024.
- [35] AleksPilot, BottleI DEDataset, Roboflow Universe, Mayıs 2023. [https://universe.roboflow.com/alekspilot-kvgn4/bottle\\_ide/dataset/4](https://universe.roboflow.com/alekspilot-kvgn4/bottle_ide/dataset/4). Accessed 24 June 2024.
- [36] dogcat, glass bottle Dataset, Roboflow Universe, Şubat 2024. <https://universe.roboflow.com/dogcat-nlhtn/glass-bottle-juhvb/dataset/1>. Accessed 24 June 2024.
- [37] HTW Berlin University of Applied Sciences, plasticandglass Dataset, Roboflow Universe, Haziran 2023. <https://universe.roboflow.com/htw-berlin-university-of-applied-sciences/plasticandglass/browse?queryText=&pageSize=200&startingIndex=200&browseQuery=true>. Accessed 24 June 2024.
- [38] Beach Cleaning Robot, Glass detection Dataset, Roboflow Universe, Aralık 2023. <https://universe.roboflow.com/beach-cleaning-robot/glass-detection->

- momkc/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true. Accessed 24 June 2024.
- [39] Arun Kumar, plastic Annotations Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/arun-kumar-wnuph/plastic-annotations/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true>. Accessed 24 June 2024.
- [40] DenisWang, bottletest03Dataset, Roboflow Universe, Ağustos 2023. [https://universe.roboflow.com/deniswang/bottle\\_test03/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true](https://universe.roboflow.com/deniswang/bottle_test03/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true). Accessed 24 June 2024.
- [41] bottles, Bottles Dataset, Roboflow Universe, Ocak 2024. <https://universe.roboflow.com/bottles-t9lzo/bottles-ramni/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true>. Accessed 24 June 2024.
- [42] klasifikasi, botol 350 Dataset, Roboflow Universe, Nisan 2024. <https://universe.roboflow.com/klasifikasi-ghgpr/botol-350/browse?queryText=&pageSize=200&startingIndex=200&browseQuery=true>. Accessed 24 June 2024.
- [43] BEproject, BE Dataset, Roboflow Universe, Ocak 2024. <https://universe.roboflow.com/beproject-ontnq/be-m6kyc/browse?queryText=&pageSize=200&startingIndex=200&browseQuery=true>. Accessed 24 June 2024.
- [44] Project, Plastic object detection USING YOLOV8 Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/project-mwpp7/plastic-object-detection-using-yolov8/dataset/1>. Accessed 24 June 2024.
- [45] MTU1, MTU1projectDataset, Roboflow Universe, Ocak 2024. [https://universe.roboflow.com/mtu1-iu57z/mtu\\_1\\_project/dataset/1](https://universe.roboflow.com/mtu1-iu57z/mtu_1_project/dataset/1).
- [46] garbage bag, trashbag finder Dataset, Roboflow Universe, Nisan 2023. <https://universe.roboflow.com/garbage-bag/trashbag-finder/dataset/2>. Accessed 24 June 2024.
- [47] SnapCycleV2, Batteries Dataset, Roboflow Universe, Temmuz 2023. <https://universe.roboflow.com/snapcyclev2/batteries-ephqt/browse?queryText=&pageSize=200&startingIndex=400&browseQuery=true>. Accessed 24 June 2024.
- [48] ngoc411, battery Dataset, Roboflow Universe, Ocak 2024. <https://universe.roboflow.com/ngoc411/battery-bgk7x/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true>.
- [49] project-anaaa, battery Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/project-anaaa/battery-jrr08/browse?queryText=&pageSize=200&startingIndex=0&browseQuery=true>. Accessed 24 June 2024.
- [50] ELAKKIYA E., Plastic Litter Detection Dataset, Roboflow Universe, Ocak 2024. <https://universe.roboflow.com/elakkiya-e-qijt0/plastic-litter-detection-yl09a/dataset/3>. Accessed 24 June 2024.
- [51] mins workspace, ObjectDetectiondrinkDataset, Roboflow Universe, Ekim 2023. [https://universe.roboflow.com/mins-workspace/objectdetection\\_drink/browse?queryText=&pageSize=200&startingIndex=200&browseQuery=true](https://universe.roboflow.com/mins-workspace/objectdetection_drink/browse?queryText=&pageSize=200&startingIndex=200&browseQuery=true). Accessed 24 June 2024.
- [52] YoloV8, SolidWasteClassifier Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/yolov8-erigx/solidwasteclassifier/browse?queryText=&pageSize=200&startingIndex=800&browseQuery=true>. Accessed 24 June 2024.
- [53] varyrecycle, can Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/varyrecycle/can-cwf4o/browse?queryText=class%3Acan&pageSize=200&startingIndex=200&browseQuery=true>. Accessed 24 June 2024.
- [54] SnapCycle, SnapCycle Dataset, Roboflow Universe, Ağustos 2023. <https://universe.roboflow.com/snapcycle/snapcycle/browse?queryText=class%3Ametal-can&pageSize=200&startingIndex=400&browseQuery=true>. Accessed 24 June 2024.
- [55] Waste Detector, Cardboard-BottleCap-GlassBottle-PlasticBottle-PlasticBag-GarbageBag-Battery-Tin Dataset, Roboflow Universe, Haziran 2024. <https://universe.roboflow.com/waste-detector-2t9ly/cardboard-bottlecap-glassbottle-plasticbottle-plasticbag-garbagebag-battery-tin/browse?queryText=class%3Anull&pageSize=50&startingIndex=0&browseQuery=true>. Accessed 24 June 2024.
- [56] Karadağ, C., & Özdemir, D. (2023). Comparative analysis of deep learning methods for brain tumor detection. *Artificial Intelligence Studies*, 6(1), 1-13. <https://doi.org/10.30855/AIS.2023.06.01.01>
- [57] Google Colaboratory Pro. <https://colab.research.google.com>. Accessed 24 June 2024.

