

SU ALTI ÇÖP TESPİTİ İÇİN YOLOv4 TABANLI BİR YÖNTEM

Kübra Demir ^{*1}, Orhan Yaman ²

¹Fırat Üniversitesi, Elazığ-Türkiye, 202141107@firat.edu.tr

²Fırat Üniversitesi, Elazığ-Türkiye, orhanyaman@firat.edu.tr

* Sorumlu Yazar: 202141107@firat.edu.tr

Özet: Su altı görüntü işleme, su altı canlıları ve nesnelerin tespiti için önemli bir araştırma alanıdır. Bu çalışmada, insansız su altı robotu kullanılarak su altı çöp tespiti için derin öğrenme tabanlı bir yöntem önerilmiştir. Su altında bulunan plastik şişe, cam şişe ve plastik paket ve büyük plastik bidon nesnelere ait görüntüler toplanarak bir veri seti oluşturulmuştur. Dört nesne türü için toplamda 720 sualtı görüntüsü toplanmıştır. 720 görüntü içerisinde 962 nesne mevcuttur. Bu görüntüler LabelImg programı kullanılarak etiketlenmiştir. Bu çalışmada nesne tespiti için YOLOv4 (You Only Look Once) algoritması kullanılmıştır. Önerilen yöntem 80:20 eğitim test ve 90:10 eğitim test oranı ile uygulanmış ve sırasıyla %88.7 ve %75.8 doğruluk hesaplanmıştır.

Anahtar sözcükler: Su Altı Görüntüleri, Derin Öğrenme, Görüntü İşleme, Nesne Algılama, Çöp Tespiti.

A YOLOv4-BASED METHOD FOR UNDERWATER LITTER DETECTION

Kübra Demir ^{*1}, Orhan Yaman ²

¹Fırat University, Elazig-Turkey, 202141107@firat.edu.tr

²Fırat University, Elazig-Turkey, orhanyaman@firat.edu.tr

* Corresponding author: 202141107@firat.edu.tr

Abstract: Underwater image processing is an important research area for the detection of underwater creatures and objects. In this study, a deep learning-based method is proposed for underwater litter detection using an unmanned underwater robot. A dataset was created by collecting images of the plastic bottle, glass bottles and plastic packages, and large plastic drum objects underwater. A total of 720 underwater images were collected for four object types. There are 962 objects in 720 images. These images have been labeled using the LabelImg program. In this study, the YOLOv4 (You Only Look Once) algorithm was used for object detection. The proposed method has been applied with an 80:20 training test and 90:10 training test ratio and 88.7% and 75.8% accuracy have been calculated, respectively.

Keywords: Underwater Images, Deep Learning, Image Processing, Object Detection, Litter Detection.

1. Giriş

Dünyada en önemli çevre sorunlarından birisi plastik ve benzeri atıklardır. Plastikler deniz ortamına rüzgâr/sel ile taşıma, nakliye, kıyı faaliyetleri, atık su deşarjı ve insanların suya bırakması gibi nedenlerden dolayı suya karışmaktadır. Günümüzde, okyanus ve denizlerde, yaklaşık 100 ile 150 milyon ton plastik çöpün yüzdüğü tahmin edilmektedir. Bu rakamlara her yıl yaklaşık 6,5 milyon ton plastik atık eklenmektedir. BM Çevre Programı'nın verilerine göre, açık denizlerde her kilometrekare başına ortalama 13 bin plastik düşmektedir [1]. Denize bırakılan plastik atıklar, bozunma sıcaklıklarının yüksek olması ve ultraviyole ışınlarına karşı dayanıklı olması nedeniyle asırlarca denizlerdeki varlıklarını sürdürmektedirler. Denizlerin kirlenmesi; deniz kuşlarının ve denizde yaşayan canlıların tür ve sayısının azalmasına bağlı olarak nesillerinin tükenmesi, balıkçılık faaliyetlerinin yapılamaması, insan sağlığının olumsuz etkilenmesi gibi ekosistemde zararlı sonuçlara neden olmaktadır [2]. Bu sorunu gidermek için ilk adım, deniz kirliliklerine neden olan çöp nesnelere tespitidir. Yeryüzünün ¾'ü su ile kaplıken, yerüstü çalışmalar su altı çalışmalardan daha fazladır. Bunun sebebi ise; su altı çalışmalarının yerüstü ve su üstündeki çalışmalardan daha zorlu olmasıdır. Su altındaki nesnelere uzun süreli suya maruz kalma ile nesnelere şekilleri bozulur, renk emilimi artar, ışık su altında dağılır ve kırılır, görüntüler bulanık ve anlaşılması güç hale gelmektedir. Su altı görüntülerinin elde edilmesindeki bu zorluklar ve yüksek maliyet bu alanlardaki bilimsel çalışmaların sayısını olumsuz etkilemektedir. Literatürde su altı görüntülerinden genellikle boru hattı, köprü ve baraj çatlaklarının tespiti yapılması alanında çalışmalar yapılmıştır. Su altı nesne ve balık tespiti için yapılan güncel çalışmalar Tablo 1'de özetlenmiştir.

Tablo I. Su altı nesne tespiti için literatürdeki bazı çalışmalar

Referans	Yıl	Nesneler	Yöntem	Materyal	Veri Sayısı	Başarım Oranı
Kylili ve dig. [3]	2019	Şişe, kova ve pipet	CNN	Su altı aracı	4000	~%86
Politikos ve dig. [4]	2021	Fincan, çanta, şişe, çarşaf, küçük çarşaf, kutu, balık ağı, lastik, kap, büyük nesne ve diğer	Mask R-CNN	Su altı aracı	3910	%62
Fallati ve dig. [5]	2019	Çakmak, şişe, hasır ağ, naylon poşet, alüminyum teneke, plastik teneke, plastik kaplar, parmak arası terlik ve diğer	CNN	İnsansız hava aracı	-	%67
Van ve dig. [6]	2020	Deniz plastikleri	Faster R-CNN	Kamera	1272	%68.7
Pan ve dig. [7]	2020	Balık	M-Resnet	Su altı aracı	-	%96.5
Kazım ve dig. [8]	2020	Balık	YOLOv3	Su altı aracı	4005	%87.56

Tablo 1 incelendiğinde literatürde çöp ve balık tespiti için yapılan çalışmalar görülmektedir. Kylili ve dig. [3] su altı görüntülerini kullanarak Evrişimli sinir ağları (CNN) tabanlı çöp tespiti yöntemi geliştirmiştir. Yaklaşık 4000 görüntü içerisinde şişe, kova ve pipet gibi atıkların tespitini %86 oranında gerçekleştirmiştir. Politikos ve dig. [4], Fallati ve dig. [5] ve Van ve dig. [6] çalışmalarında su altındaki çöplerin tespiti için CNN tabanlı yöntemler önermişlerdir. Politikos ve dig. [4], Fallati ve dig. [5]

çalışmalarında sınıf sayılarını artırdıkça başarı oranlarının düştüğü görülmektedir. Atıkların tespiti için su altı araçlarının geliştirilmesi ve yaygın kullanımları hakkında literatürde birçok çalışma mevcuttur [9]. Literatürde çöplerin ve diğer nesnelerin tespiti için görüntü iyileştirme hakkında birçok yöntem önerilmiştir[10]. Tez kapsamında geliştirilecek çöp tespiti, sınıflandırılması ve görüntü iyileştirme algoritmalarının literatürdeki çalışmalar ile karşılaştırılabilmesi için ulusal tez izleme, uluslararası bilimsel çalışmalar araştırılmış ve elde edilen çalışmalar incelenmiştir. Lu ve dig. [11] derin sinir ağları kullanarak düşük aydınlatmalı su altı görüntülerinin iyileştirilmesi için bir yöntem önermiştir. Sualtı görüntüleme problemlerini çözmek ve derinlik tahmini için bir görüntüleme yöntemi geliştirmiştir. Düşük yoğunluklu bir ışık ortamında su altı görüntüleme sorunlarını gidermek için derin sinir ağları ile derinlik tahmini yapmıştır. Ayrıca ışık alanı görüntülerinden saçılma sorunlarını çözülmesi ve renk azalmasını gerçi kazandırmak için spektral karakteristik tabanlı bir renk düzeltme yöntemi kullanılmıştır. Li ve dig. [12] çalışmasında kalitesini arttırmak için renk düzeltme ve su altı görüntü iyileştirme içeren hibrit bir yöntem önermiştir. İlk olarak su altı görüntülerinin renk tonlarını gidermek için etkili bir renk düzeltme algoritması uygulamıştır. Daha sonra su altı görüntüleri için küresel bir arka plan ışık tahmin algoritması ve su ortamında ışık geçiren regrasyon modeli geliştirmiştir. Çalışmada 45 su altı görüntüsü içeren bir veri seti oluşturmuştur. Bu görüntüler üzerinde sonuçlar elde etmiştir.

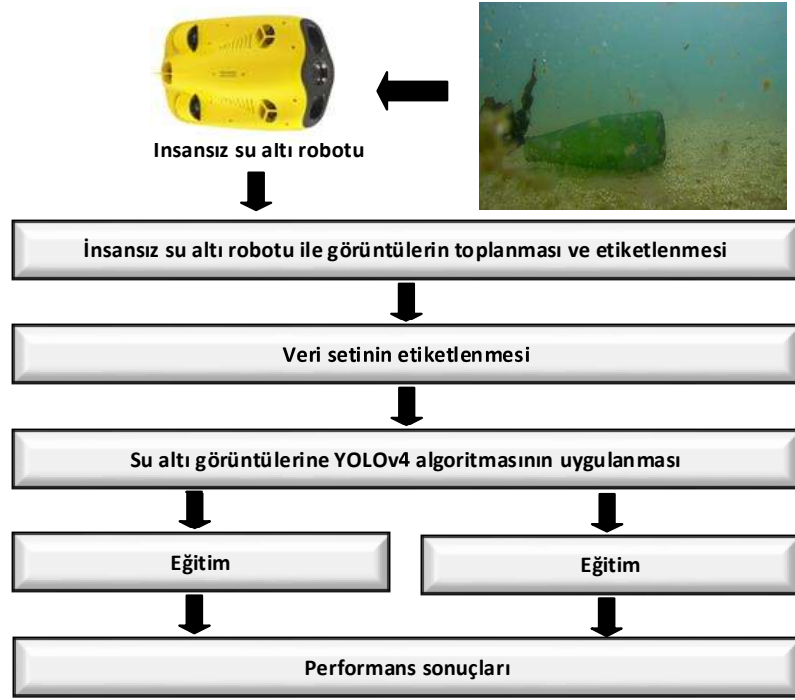
2. Materyal Metot

Bu çalışmada, GLADIUS MINI model kablolu su altı robotu kullanılarak veri seti oluşturulmuştur. Kullanılan su altı robotunun ön tarafında 4K Ultra HD kamera ve kameranın yan taraflarında Led ışıklar bulunmakta olup 100 metre kablo ile kontrol cihazına bağlanmıştır. Kontrol cihazı, kumanda ile kablosuz olarak haberleşir ve görüntüleri gerçek zamanlı olarak telefona veya bilgisayara aktarır. Robot telefon, tablet veya bilgisayar ile kontrol edilmektedir. Sualtı robotunun ve bileşenlerinin görüntüsü Şekil 1'de gösterilebilir.



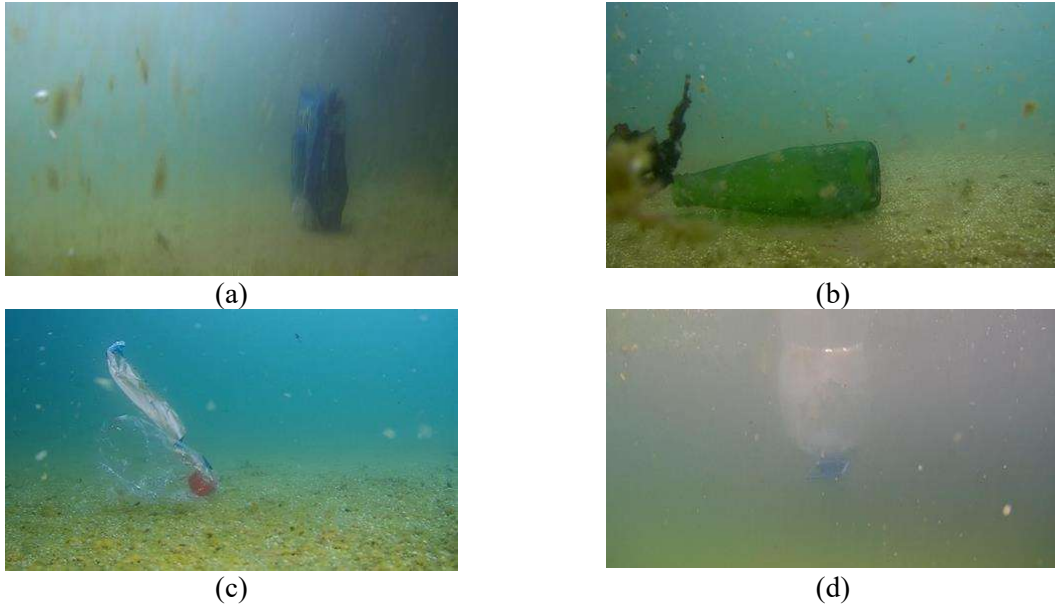
Şekil 1. Sualtı robotu ve görüntülerin alınmasında kullanılan bileşenler (a) Sualtı robotu (b) Kontrol cihazı (c) Uzaktan kumanda cihazı

Bu çalışma, Python programlama dili platformunda geliştirilmiş ve sonuçları hesaplanmıştır. Önerilen yöntemin blok şeması Şekil 2'de verilmiştir.



Şekil 2. Önerilen yöntemin blok şeması

Şekil 2’de görülebileceği gibi önerilen yöntemde ilk olarak su altı robotu ile görüntüler toplanmıştır. Su altında bulunan görüntüler farklı açılarla görüntülenerek çok sayıda görüntü elde edilmiştir. Bu çalışmada su altı robotu ile toplanan örnek görüntüler Şekil 3’te verilmiştir.




Şekil 3. Sualtı robotu ile çekilen örnek görüntüler (a) Islak mendil paketi (b) Cam şişe (c) Plastik şişe (d) Büyük plastik bidon

Bu veri seti 1920×1080 piksel çözünürlüğe sahip, 4 farklı sınıftan oluşmaktadır. Toplamda 720 adet görüntü ve bu görüntüler içerisinde 962 adet nesne bulunmaktadır. Veri setindeki nesne isimleri ve sayıları Tablo 2’de gösterilmiştir.

Tablo II. Sınıf isimleri ve her sınıfa ait görüntü sayıları

Sınıf Adı	Nesne adedi
Islak mendil paketi	134
Cam şişe	268
Plastik şişe	505
Büyük plastik şişe	55
Toplam etiketlenen nesne sayısı	962

Bu çalışmada, bu veri seti alt kümeler: (a) eğitim seti ve (b) test seti olarak rastgele ikiye bölünerek klasörlerine ayrıştırılmıştır. İlk senaryo için, eğitim veri setinde yüzde seksen (%80) test setinde yüzde yirmi (%20) kategori başına sırasıyla: 576 ve 144 görüntü kullanılmıştır. İkinci senaryo için, eğitim veri setinde yüzde doksan (%90) test setinde yüzde on (%10) kategori başına sırasıyla: 648 ve 72 görüntü kullanılmıştır. Birinci senaryoda 576 görüntü eğitim için, 144 görüntü test için kullanılmıştır. İkinci senaryoda ise 648 görüntü eğitim, 72 görüntü test için kullanılmıştır. Veri setinde bulunan görüntüleri Şekil 4’te gösterildiği gibi LabelImg [13] programıyla görüntü içerisindeki ilgili alan bir çerçeve içerisinde alınıp, 4 farklı sınıfta etiketlenerek “plastic bottle”, “big plastic bottle”, “green glass bottle ” ve “wet wipes package” etiketleri oluşturuldu.



Şekil 4. LabelImg programı ile nesnenin etiketlenmesi

Her etiketlenen resim için bir .txt dosyası oluşturulmaktadır. Bu txt dosyalarında nesnenin sınıf, x ve y koordinatlarının yükseklik ve genişliği içeren veriler bulunmaktadır. Bu işlem her bir görüntü için tekrarlanmış ve eğitime hazır hale getirilmiştir. Etiketlenen görüntülerin eğitilmesi için YOLOv4 algoritması kullanılmıştır. YOLO (You Only Look Once) algoritması ve Darknet modeli, yüksek işleme hızından dolayı yüksek FPS (Frame Per Second) sağlamakta ve daha net sonuçlar vermektedir [14].

YOLO algoritmasının bu kadar hızlı olmasının sebebi görüntüyü tek seferde sinir ağdan geçirerek resimdeki tüm nesnelere sınıfları ve koordinatlarını tahmin edebilmektedir. Bu tahmin işleminin temeli, resmi SxS'lik ızgaralara bölmektir. Oluşan her ızgara için ayrı bir tahmin vektörü oluşturmaktadır. YOLO algoritmasının tercih edilme sebebi gerçek zamanlı nesne takibi yapabilen mAP(ortalama hassasiyet) değeri en ideal algoritma olmasıdır.

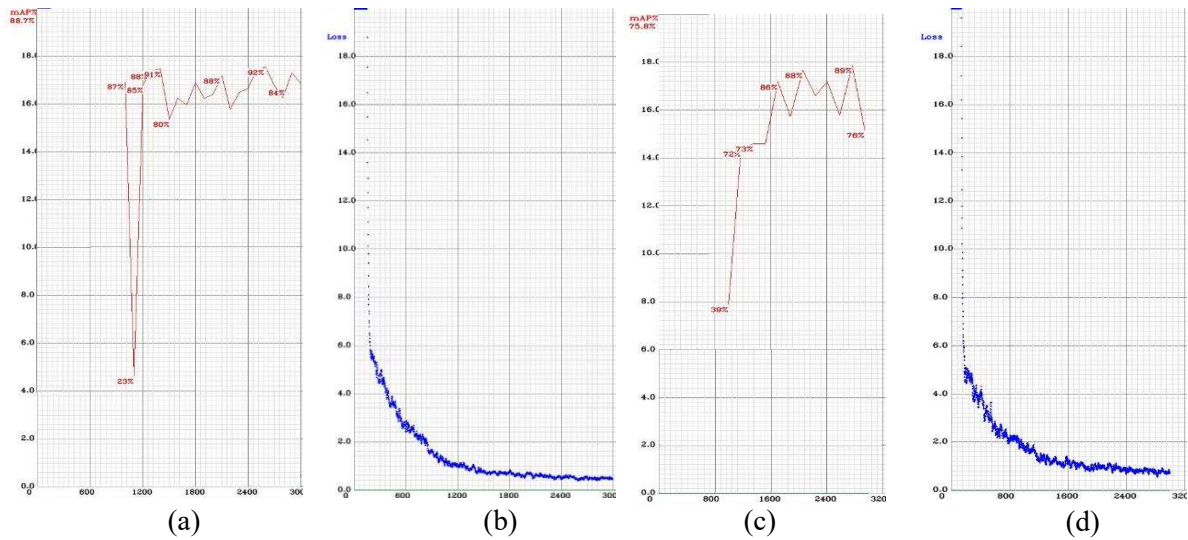
3. Deneysel Sonuçlar

YOLOv4 algoritması sayesinde bu çalışma ile su altındaki çöplerin tespiti yapılmıştır. Önerilen yöntem Python kullanılarak gerçekleştirilmiştir. Eğitim işlemi bittikten sonra testler yapıp video görüntüleri üzerinde nesne tanıma işlemi gerçekleştirilmiştir. Bu çalışmada, çeşitli uygulamalar geliştirmek için Google tarafından sağlanan Python programlama diline dayalı bir bulut hizmeti olan Google Colab, daha hızlı işlem için Grafik İşleme Birimi (GPU) ve PyCharm arayüzü kullanılmıştır. Gerçekleştirilen çalışmada kullanılan kütüphaneler, paketler ve donanım özellikleri Tablo 3'te gösterilmiştir.

Tablo III. Kullanılan kütüphaneler, paketler ve donanım özellikleri

Yazılım ve Kütüphaneler	Değerler
Python	3.9
OpenCv	4.4.0
Numpy	1.19.5
PyCharm	2021.2
Google Colab	-
System	Intel Core i5-7200U
CPU	2.50 GHz

Önerilen yöntemin mAP ve Loss grafikleri Şekil 5'de sunulmuştur.



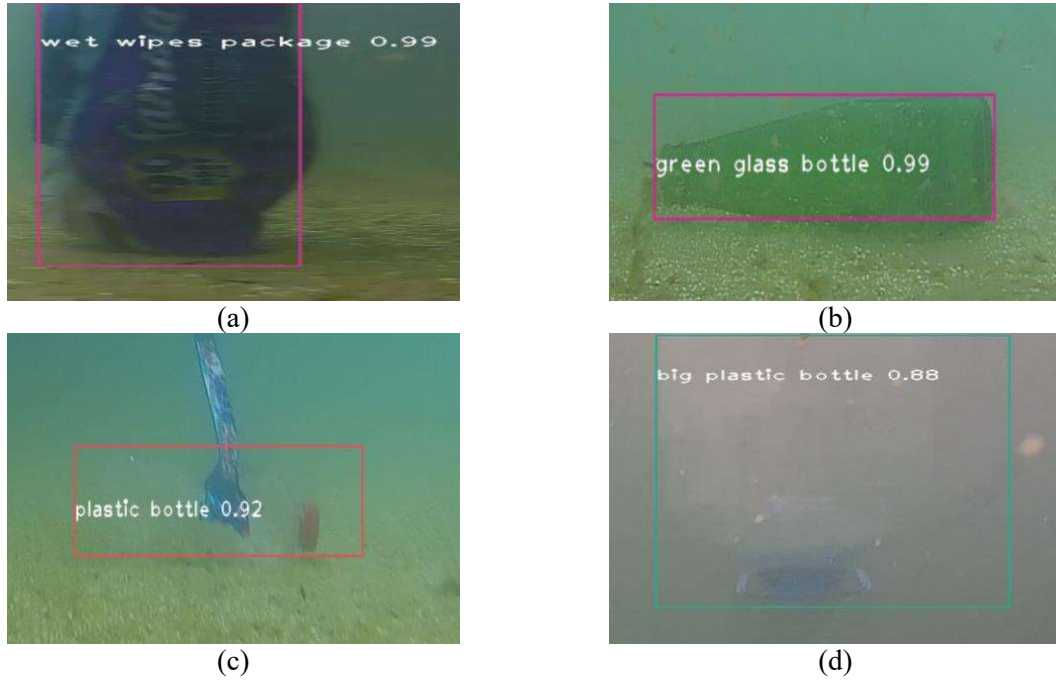
Şekil 5. Önerilen yöntemin mAP ve Loss grafikleri a) 80:20 eğitim test verisi için mAP sonucu b) 80:20 eğitim test verisi için Loss sonucu c) 90:10 eğitim test verisi için mAP sonucu d) 90:10 eğitim test verisi için Loss sonucu

Önerilen yöntemin performans sonuçları Tablo 4' te gösterilmiştir.

Tablo IV. Önerilen yöntemin performans sonuçları

Parametreler	80:20 Eğitim test verisi sonuçları	90:10 Eğitim test verisi sonuçları
mAP	%88.7	%75.8
Ortalama loss	0.3607	0.6991
İterasyon	3000	3000
Zaman	8.56 saat	10.88 saat

Tablo 4'te görülebileceği gibi 80:20 eğitim test verisi sonuçlarında %88.7 mAP hesaplanmıştır. Her iki eğitim test verisi için 3000 iterasyon çalıştırılmıştır. Şekil 6'da örnek test sonuçlarına ait görüntüler verilmiştir.



Şekil 6. Örnek test sonuçları (a) Islak mendil paketi (b) Cam şişe (c) Plastik şişe (d) Büyük plastik bidon

4. Sonuçlar

Bu çalışmada su altında bulunan nesnelerin sınıflandırılması ve tespiti için YOLOv4 algoritması uygulanmış, analiz edilmiş ve sonuçlar kaydedilmiştir. Kendi veri setimiz kullanılarak eğitimleri gerçekleştirilmiştir. Derin öğrenme sistemlerinde sonuçların başarılı olmasında görüntü boyutu, veri setinin boyutu ve çeşitliliği önemlidir. Aynı zamanda su altı görüntülerinin bulanık olması da yöntemin

başarısını etkilemektedir. Önerilen yöntemde 720 görüntü toplanmış ve 962 nesne etiketlenmiştir. En iyi mAP sonucu 80:20 eğitim ve test verisi ile elde edilmiştir. Gelecek çalışmalarda yöntemin başarısını arttırmak için veri setinin boyutu ve nesne çeşidi arttırılacaktır. Aynı zamanda su altı görüntü iyileştirme algoritmaları kullanılarak ön işleme yapılacaktır. Böylece yüksek doğruluk elde edileceği ön görülmektedir.

5. Kaynaklar

- [1] Tudav, 'Denizlerde Plastik ve Mikroplastikler Konusunda Neler Yapıyoruz', 2022. <https://tudav.org/calismalar/kirlilik/denizel-copler/denizlerde-plastik-ve-mikroplastikler-konusunda-neler-yapiyoruz/>.
- [2] Tudav, 'Denizel Çöpleri Ulusal Formu', 2022. <https://tudav.org/calismalar/kirlilik/denizel-copler/denizel-copleri-ulusal-formu/>.
- [3] K. Kylili, I. Kyriakides, A. Artusi, and C. Hadjistassou, 'Identifying floating plastic marine debris using a deep learning approach', *Environ. Sci. Pollut. Res.*, vol. 26, no. 17, pp. 17091–17099, 2019, doi: 10.1007/s11356-019-05148-4.
- [4] D. V. Politikos, E. Fakiris, A. Davvetas, I. A. Klampanos, and G. Papatheodorou, 'Automatic detection of seafloor marine litter using towed camera images and deep learning', *Mar. Pollut. Bull.*, vol. 164, no. January, p. 111974, 2021, doi: 10.1016/j.marpolbul.2021.111974.
- [5] L. Fallati, A. Polidori, C. Salvatore, L. Saponari, A. Savini, and P. Galli, 'Anthropogenic Marine Debris assessment with Unmanned Aerial Vehicle imagery and deep learning: A case study along the beaches of the Republic of Maldives', *Sci. Total Environ.*, vol. 693, p. 133581, 2019, doi: 10.1016/j.scitotenv.2019.133581.
- [6] C. van Lieshout, K. van Oeveren, T. van Emmerik, and E. Postma, 'Automated River Plastic Monitoring Using Deep Learning and Cameras', *Earth Sp. Sci.*, vol. 7, no. 8, 2020, doi: 10.1029/2019EA000960.
- [7] T. S. Pan, H. C. Huang, J. C. Lee, and C. H. Chen, 'Multi-scale ResNet for real-time underwater object detection', *Signal, Image Video Process.*, vol. 15, no. 5, pp. 941–949, 2020, doi: 10.1007/s11760-020-01818-w.
- [8] K. Raza and S. Hong, 'Fast and accurate fish detection design with improved yolo-v3 model and transfer learning', *Int. J. Adv. Comput. Sci. Appl.*, no. 2, pp. 7–16, 2020, doi: 10.14569/ijacsa.2020.0110202.
- [9] G. A. Canlı, İ. Kurtoğlu, M. O. Canlı, and Ö. S. Tuna, 'Dünyada ve Ülkemizde İnsansız Sualtı Araçları (İsaa-Auv & Rov) Tasarım ve Uygulamaları', *GİDB Dergi*, vol. 43, no. 04, pp. 43–75, 2016.
- [10] C. Li *et al.*, 'An Underwater Image Enhancement Benchmark Dataset and beyond', *IEEE Trans. Image Process.*, vol. 29, pp. 4376–4389, 2020, doi: 10.1109/TIP.2019.2955241.
- [11] H. Lu, Y. Li, T. Uemura, H. Kim, and S. Serikawa, 'Low illumination underwater light field images reconstruction using deep convolutional neural networks', *Futur. Gener. Comput. Syst.*, vol. 82, pp. 142–148, 2018, doi: 10.1016/j.future.2018.01.001.
- [12] C. Li, J. Guo, C. Guo, R. Cong, and J. Gong, 'A hybrid method for underwater image correction', *Pattern Recognit. Lett.*, vol. 94, pp. 62–67, 2017, doi: 10.1016/j.patrec.2017.05.023.
- [13] J. Dharmeeshkar, S. Dhakshana, S. Aniruthan, R. Karthika, and L. Parameswaran, 'Deep Learning based Detection of potholes in Indian roads using YOLO', *Proc. 5th Int. Conf. Inven. Comput. Technol. ICICT 2020*, pp. 381–385, 2020, doi: 10.1109/ICICT48043.2020.9112424.
- [14] M. A. Özel, S. S. Baysal, and M. Şahin, 'Derin Öğrenme Algoritması (YOLO) ile Dinamik Test Süresince Süspansiyon Parçalarında Çatlak Tespiti', *Eur. J. Sci. Technol.*, no. 26, pp. 1–5, 2021, doi: 10.31590/ejosat.952798.