

Çay ve Eğrelti Otunun YOLOv5 ve YOLOv8 Algoritmaları ile Karşılaştırmalı Tespiti

Özgür ÖNDER¹, Yasin KARAN^{1*}

¹ Recep Tayyip Erdoğan Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği, Türkiye

*Sorumlu Yazar/Corresponding Author
E-mail: yasin.karan@erdogan.edu.tr

Araştırma Makalesi/Research Article
Geliş Tarihi/Received:08.12.2023
Kabul Tarihi/Accepted:01.04.2024

ÖZ

Çay yaprağı toplanırken içerisine farklı otlar karışabilmektedir. Daha kaliteli, sağlıklı ve lezzetli çay üretimi için bu sorunu önlemek ve yönetmek için güvenilir ve doğru bir teşhis ve tanımlama sistemi gereklidir. Bu sistem hem otonom çay hasadı sistemlerinde hem de çay kurutma fabrikaları girişlerinde kullanılabilir. Bu çalışma, çay bahçelerinden toplanan çay yaprakları ve içerisine en çok karışan eğrelti otundan oluşan veri kümesi üzerinde en hızlı nesne algılama modeli olan sadece bir kez bak (You Only Look Once, YOLO) algoritmasında v5 ve v8 olmak üzere iki farklı versiyonda eğiterek çay yaprağı içerisine karışan eğrelti otu sorununa yapay zeka tabanlı bir çözüm sunmayı amaçlamaktadır. Çay bahçelerinden alınan 747 dijital görüntü toplanarak veri seti oluşturuldu. Daha sonradan veri artırma yöntemleri kullanılarak veriler çoğaltılıp 1395 görüntü haline getirildi. Model eğitimleri artırılmış son veri setine göre yapıldı. Her bir modelin eğitimi için aynı veri seti kullanıldı. YOLOv5 yaklaşımı için tanımlama sonuçları kesinlik, duyarlılık, genel ortalama kesinlik değeri (mean Average Precision, mAP) ve F1-skoru parametrelerine göre sırasıyla %84,4, %81,0, %84,4 ve %0,83 ve YOLOv8 için tanımlama sonuçları sırasıyla %86,7, %79,9, %86,7 ve %0,83 çıkmıştır. Deneysel sonuçlar, bitki tespiti için YOLOv8 algoritmasının daha yüksek performansı göstererek üstün olduğunu göstermektedir. Bu çalışmanın iş yükünü en aza indirmesi ve çaya karışan otların hızlı bir şekilde tanımlanmasına ve tespit edilmesine yardımcı olarak kalite ve lezzet sorunlarının en aza indirilmesinde yapılacak çalışmalara desteği öngörülebilir.

Anahtar Kelimeler: Yapay zeka, çay yaprağı, eğrelti otu, nesne tespiti, YOLO

Comparative Detection of Tea and Fern with YOLOv5 and YOLOv8 Algorithms

ABSTRACT

During tea leaves harvest, different herbs can be mixed in the tea bag. A reliable and accurate identification system is needed to prevent and manage such problem to produce better quality, healthier, and tastier tea. This system can be used both in autonomous tea harvesting systems and at the entrances of tea-drying factories. This study aims to provide an artificial intelligence-based solution to the problem of ferns in tea leaves by training the fastest object detection model, the You Only Look Once (YOLO) algorithm, in two different versions, v5, and v8, on a dataset consisting of tea leaves collected from tea gardens and the most common ferns mixed in them. A data set was created by collecting 747 digital images from tea gardens. Then, using data augmentation methods, the data was multiplied to 1395 images. Model training was performed according to the final augmented data set. The same dataset was used for training each model. The identification results for the YOLOv5 approach were 84.4%, 81.0%, 84.4%, and 0.83% based on the precision, sensitivity, mean average precision (mAP), and F1-score parameters, respectively, and the identification results for YOLOv8 were 86.7%, 79.9%, 86.7%, and 0.83%. The experimental results show that the YOLOv8 algorithm is superior for plant detection, showing higher performance. It is foreseeable that this study will minimize the workload and support future studies in minimizing quality and flavor problems by helping to quickly identify and detect herbs mixed in tea.

Keywords: Artificial intelligence, fern, object detection, tea leaf, YOLO

Cite as;

Önder, Ö., Karan, Y. (2024). Çay ve eğrelti otunun YOLOv5 ve YOLOv8 algoritmaları ile karşılaştırmalı tespiti. *Recep Tayyip Erdoğan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 5(1), 74-88. Doi: 10.53501/rteufemud.1402167

1. Giriş

Çay bitkisi, hem Türkiye'de hem de dünya genelinde ekonomik, kültürel ve sosyal açıdan önemli bir rol oynayan bir üründür. Türkiye'nin doğal ve kültürel mirası arasında yer alan önemli bir bitkidir. Türkiye, çay tüketimi konusunda dünya liderleri arasında yer almaktadır. Dünyada en önemli çay yetiştirici ülkeler Çin, Hindistan, Sri Lanka, Türkiye, Kenya, Japonya, Endonezya iken, Türkiye'de çay özellikle Doğu Karadeniz bölgesinde üretilmektedir. Çay, Türkiye'de sadece bir içecek değil, aynı zamanda bir kültür ve yaşam tarzıdır. Çay bitkisinin neslinin devamı, Türkiye'nin ekonomik ve kültürel açıdan önemli bir bitki olan çayın geleceği için de önemlidir (Yıldız ve Midilli, 2022). Çay bitkisi, Theaceae familyasından olan bir bitki türüdür. Doğada büyümeye bırakıldığı zaman bir ağaç görünümü alır ve gelişme yüksekliği türlere göre değişiklik gösterir. Yeterli düzeyde sıcaklık ve nemin bulunduğu yerlerde yıl boyunca sürgün oluşumu devam etmektedir.

Çay tarlalarında, çayın içine farklı bitkiler karışabilmektedir. Bu bitkilerin çayın içine girmesi bazı problemlere yol açmaktadır. Öncelikle, farklı bitkilerin çaya karışması çayın kalitesinin düşmesine neden olur. Çayın tadının ve kokusunun değişmesi, tüketicilerin beğenisini azaltabilir ve üreticilerin çay ihracatında sorun yaşamasına yol açabilir. Bu nedenle, çay üreticileri farklı bitkilerin çay tarlalarına girmesini önlemelidir. Çay tarlalarında sadece çay bitkisinin yetiştirilmesi önemlidir. Bu, çayın kalitesinin korunmasına ve insan sağlığının riske atılmamasına yardımcı olacaktır. Şekil 1'de görüldüğü gibi çay bitkisi içerisinde özellikle eğrelti otu gibi farklı bitkiler olabilmektedir. Çay bitkisi ve eğrelti otu, renk ve yetişen yer olarak birbirlerine benzeyebilir ancak çok farklı özellikleri bulunmaktadır.

Eğrelti otu, çay tarlalarında istenmeyen bir bitkidir. Çay bitkilerine karışmakta ve çayın kalitesini düşürmektedir. Ayrıca, eğrelti otu çay bitkisine göre daha hızlı büyür ve çay üretiminde sorunlara neden olabilir. Çay tarlalarında eğrelti

otunun kontrol altında tutulması, çay üretiminde önemlidir. Sonuç olarak, çay bitkisi ve eğrelti otunun ayrışmasını yapmak, çay üreticileri ve tüketicileri için önemlidir. Bu bilgi, çayın kalitesini ve tadını korumak ve sağlıklı bir çay tüketimini teşvik etmek için gereklidir. Çay bitkisi toplandıktan sonra içerisine karışan eğrelti otlarını ayırmak oldukça zor bir iştir. Ancak yapılması çayın kalitesi ve insan sağlığı için oldukça önemlidir. Yaptığımız çalışmada sorunun ana kaynağı olan çayın içerisine karışan eğrelti otu çaydan ayrıştırılması gerekmektedir. Bu ayrıştırma işleminin ilk aşaması çayı ve içerisine karışan eğrelti otunu tespit etmek olarak belirlenmiştir.



Şekil 1. İçerisinde eğrelti otu karışmış çay tarlası örneği

Figure 1. Example of a tea field with ferns mixed

İki nesneyi birbirinden ayırt etmek istediğinde kullanılacak yöntem olarak son yıllarda çok popülerlik kazanan ve çözüm odaklı hareket eden yapay zeka teknolojisi ilk akla gelen yöntemlerden birisidir (Aktaş vd., 2020). Gelişmiş makine öğrenimi algoritmaları, derin öğrenme teknikleri ve büyük veri işleme yetenekleri sayesinde, yapay zeka uygulamaları bu tür sorunlar için daha akıllı ve etkili hale geldi (Öztürk ve Şahin, 2018). Bu çalışmanın amacı, YOLO algoritması kullanarak eğrelti otu ve çay

bitkisini ayırt etmek ve sınıflandırmak üzerinedir. Bu çalışmanın sonuçları, bitki sınıflandırması ve doğal yaşamın korunması için önemli bir adım olacaktır. YOLO algoritması ile alakalı literatür çalışması yapıldığında farklı alanlarda bu algoritmanın kullanıldığı görülmektedir. Yapılan çalışmalardan bazıları aşağıda verilmiştir.

Hızlı bölge tabanlı evrişimli sinir ağı (Faster R-CNN) kullanarak elmalarda çürük tespiti çalışmasında, elma görüntülerinin çürük ve sağlam olarak sınıflandırılması hedeflenmiştir ve bu amaçla Faster R-CNN gibi evrişimsel sinir ağı yöntemleri kullanılmıştır. Önerilen modelin işlem adımları görüntü alımı-ön işleme, çürük bölgelerin tespiti ve elmaların sınıflandırılmasıdır. Görüntü alımı-ön işleme aşamasında, bir görüntü alma platformu içinde NIR kamerası kullanılmıştır. Toplamda, 100 çürük ve 100 sağlam olmak üzere 200 elma görüntüsü kullanılarak her bir elmanın 6 farklı açıdan toplam 1200 görüntü elde edilmiştir. Ön İşleme aşamasında, görüntülere sırasıyla adaptif histogram eşitleme, kenar bulma ve morfolojik işlemler uygulanmıştır. Ön işleme işlemi uygulanarak görünürlüğü iyileştirilen yeni görüntülerle eğitilen Faster R-CNN modeli ile çürük bölgeler tespit edilmiştir. Sınıflandırma aşamasında, çürük ve sağlam elmaların tespiti %84,95 doğru sınıflandırma oranı ile gerçekleştirilmiştir. Bu sonuçlar, önerilen modelin meyve suyu endüstrisinde çürük ve sağlam elmaların otomatik olarak tespit edilmesinde kullanılabileceğini düşündürmektedir (Cömert vd., 2019).

Bitkilerde görülen yaprak hastalıklarının erken teşhisi için ise görüntü tanıma tabanlı otomatik hastalık algılama sistemleri oldukça önemlidir. Bu nedenle Faster R-CNN Kullanarak Elma Yaprak Hastalıklarının Tespiti araştırmasında, Inception v2 mimarisi ve Faster R-CNN kullanılarak bir elma yaprağı hastalık tespit sistemi önerilmiştir. Hastalıkların teşhisi için uygulamalar Türkiye'nin Yalova ilindeki elma bahçelerinde gerçekleştirilmiştir. Yaprak görüntüleri, farklı elma bahçelerinden iki yıl boyunca elde edilmiştir. Yapılan gözlemler

sonucunda, Yalova'daki elma ağaçlarında özellikle kara leke hastalığının yaygın olduğu belirlenmiştir. Önerilen sistem, bir görüntü içinde bulunan çok sayıdaki yaprağı başarıyla tespit etmekte ve ardından hastalıklı ve sağlıklı olanları sınıflandırmaktadır. Eğitilen hastalık tespit sistemi, %84.5 ortalama doğruluk oranına ulaşmıştır (Sardoğan vd., 2020).

Tek atış dedektörü (Single Shot Detector, SSD) Mobilenet V2 Kullanılarak Domates Yaprak Hastalığı Tespitinin Geliştirilmesi çalışmasında ise, domates yapraklarında görülen hastalıkları belirlemek ve tespit etmek için bir yazılım prototipi geliştirmek amaçlanmıştır. Bu amaç doğrultusunda, TensorFlow 2 nesne tanıma uygulama programlama arabirimi kullanılarak SSD MobileNetV2 modeliyle bir domates yaprakları hastalık tespit sistemi oluşturulmuştur. Kullanılan özellik çıkarıcısı olarak, ImageNet veri kümesiyle önceden eğitilmiş TF2 MobileNetV2 modeli tercih edilmiştir. SSD ve özellik çıkarıcısı birleştirilerek, nesne yerleştirme ve sınıflandırma işlemleri gerçekleştirilmiştir. Prototipin geliştirilmesi için domates yaprağı görüntü veri kümesinin çeşitlendirilmesi ve hastalık türlerinin artırılması önerilmektedir. Pratik sonuçlar açısından, bu prototip çiftçilere ve tüketicilere domates yapraklarında görülen hastalıkları tespit etme ve erken müdahale etme konusunda yardımcı olabileceği ortaya konulmuştur. Böylece, sağlıklı domates üretimini artırarak verimliliği artırabilir ve hasat kalitesini iyileştirebilir sonucuna varılmıştır (Brucal vd., 2023).

Akıllı Tarım için Soya Fasulyesinin Büyüme Durumunu Yakalamaya Yönelik Bir Görüntü Algılama Yöntemi çalışmasında, soya fasulyesi bitkisinin gelişimiyle ilgili bilgileri toplamak amacıyla bir görüntü tanıma sistemi geliştirilmiştir. Geliştirilen sistem, çiçek ve tohum sapı tespiti olmak üzere iki ana aşamadan oluşuyor. Küçük nesnelerin hassas özelliklerini yakalamak için SSD1024 kullanılarak çiçekler tespit edilirken, tespit edilen nesnelere incelemek için evrişimsel sinir ağı (Convolutional Neural Network, CNN) kullanılmıştır. Çalışma için

Hokkaido Tarımsal Araştırma Merkezi'nde 2015-2017 yılları arasında çekilen soya fasulyesi görüntüleri ile oluşturulan veri seti üzerinde sistem performansı test edilmiştir. Elde edilen sonuçlara göre, tohum sapı ve çiçek görüntüleri için tespit doğruluğu sırasıyla 0,586 ve 0,646 olarak belirlenmiştir. SSD'nin kullanılması, hesaplama maliyetini önemli ölçüde azaltmış olsa da, büyüme bilgisini daha doğru bir şekilde elde etmek için algılama performansının iyileştirilmesi gerekmektedir sonucuna varılmıştır (Omura vd., 2018).

Zehirli mantarların tespiti üzerine yapılan bir çalışmada nesne tespiti yöntemleri kullanılarak zehirli mantarların tanınmasını sağlayarak yenilmesinin önüne geçilmesi amaçlanmıştır. Nesne tespiti için YOLOv5 kullanılmıştır. Makalede model eğitimi için 8 adet sınıftan oluşan veri setinde toplam 649 fotoğraf bulunmaktadır. Çalışma sonuçları incelendiğinde ayarlanmış modelin, sekiz farklı türün tanınmasını ortalama olarak 0,77 doğrulukta yaptığı görülmüştür (Cengil ve Çınar, 2021).

YOLOv4 nesne tespit algoritması ile patates böceğinin patates bitkisi üzerinde saptanması ve popülasyon inceleme olanakları çalışmasında patates tarımında önemli bir sorun olan patates böceğinin tespiti için bir otomatik tespit sistemi geliştirmesi amaçlanmıştır. Çalışmada toplamada ergin ve lava adlarında 2 adet sınıf için 1180 adet fotoğraf kullanılmıştır. Çalışma sonuçları incelendiğinde en yüksek duyarlılık (recall) değeri 2000 iterasyonda 0,89 olarak, ölçülmüştür. Kestirilmiş bölgeler (intersection over union, IoU) değeri her iterasyonda yükselerek 6000. iterasyonda 59,22 değerine ulaşmıştır (Biçgi ve Karaca, 2022).

Çilek hasat verimliliğinin artırılması amacıyla yapılan "Yolo-v7 Nesne Tespiti ile Çilek Hasat Verimliliğinin Artırılması" araştırmasında, Mısır'ın Giza kentindeki Tarımsal Araştırma Merkezi'nde bir sera ortamında çekilen 247 görüntüden oluşan "Strawberry-DS" adlı bir veri seti kullanılmıştır. Bu veri kümesi, altı farklı büyüme aşamasını içeren çeşitli bakış açılarını

kapsamaktadır: "yeşil", "kırmızı", "beyaz", "dönüşüm", "erken-dönüşüm" ve "geç-dönüşüm". Yapılan testler sonucunda elde edilen mAP@.5 değerleri aşağıdaki gibidir: "yeşil" için 0,37, "beyaz" için 0,335, "erken-dönüşüm" için 0,505, "dönüşüm" için 1,0, "geç-dönüşüm" için 0,337 ve "kırmızı" için 0,804. Tüm sınıflardaki kapsamlı performans sonuçları ise şu şekildedir: kesinlikte 0,792, hatırlamada 0,575, mAP@.5'te 0,558 ve mAP@.5:.95'te 0,46. Bu sonuçlar, dengesiz etiket dağılımları ve meyvelerin gelişim evrelerinin etiketlerinin belirsiz olması gibi zorluklarla karşılaşmasına rağmen, önerilen araştırmanın etkinliğini hem performans değerlendirmesi hem de görsel değerlendirme açısından göstermiştir (Nergiz, 2023).

Çay yaprak hastalığı tespiti için yapay zeka kullanılarak oluşturulan bir diğer modelde ise Bangladeş'teki dört çay bahçesinden toplanan 4000 adet dijital görüntü ile veri seti hazırlanmıştır. YOLOv7, en hızlı tek aşamalı nesne tespit modeli olarak seçilmiştir. Modelin tespit doğruluğu %97,3, kesinlik %96,7, duyarlılık %96,4, mAP değeri %98,2 ve F1-skoru 0,965 olarak ölçülmüştür (Soeb vd., 2023).

Üzüm yaprakları üzerine yapılan bir çalışmada, MobileNetv2 adlı bir CNN modeli kullanılarak üç farklı yöntemle sınıflandırılmıştır. Yapraklar siyah bir arka plan üzerinde görüntülenmiş ve 500 resim elde edilmiştir. Farklı veri artırma yöntemleriyle bu sayı 2500'e çıkarılmıştır. İlk yöntemde MobileNetv2 doğrudan kullanılmış, ikinci yöntemde özellikler çıkarılıp destek vektör makineleri (Support Vector Machine, SVM) ile sınıflandırılmış, üçüncü yöntemde ise özellik seçimi yapılarak SVM ile sınıflandırılmıştır. Sonuçlar, CNN tabanlı ve özellik seçimli SVM sınıflandırıcının üzüm yaprağı sınıflandırmasında 97,60 oranında başarılı olduğunu göstermiştir (Koklu vd., 2022).

Bu çalışma YOLOv5 ve YOLOv8 yapay sinir ağları kullanılarak, çay tarlalarında çay yaprakları arasına karışan eğrelti otu ile çay yaprağını tespit edip, iki farklı yapay sinir ağı modelin performans karşılaştırmasını yapmaktadır. YOLO

algoritmasında versiyonlar arası tespit doğruluğunda ne kadar fark oluştuğunu, performans metrikleri nasıl değiştiğini incelemek amacıyla oluşturulan veri seti ile iki farklı versiyon kullanılarak iki model oluşturuldu ve karşılaştırması yapıldı. Çalışma ilerleyen zamanlarda gerçek zamanlı uygulaması yapılması planlandığı için YOLO üzerinde yapılmış ve güncel ve literatürde yaygın kullanılan v5 ve v8 versiyonları kullanılmıştır.

2. Materyal ve Metot

2.1. YOLO Algoritması

YOLO, CNN kullanarak nesne tespiti yapan bir algoritmadır. YOLO, veriye sadece bir kez bakarak tespit işlemi gerçekleştirilebilmektedir (Kıvrak ve Gürbüz, 2022). Bu çalışmada YOLOv5 ve YOLOv8 algoritmaları kullanılarak nesne tespiti gerçekleştirilmiştir. Sıfırdan hazırlanan çay ve eğrelti otu görüntülerinden oluşan bir veri setinde bu modellerin performansları değerlendirilmiştir.

YOLO algoritması analiz ve tahmin etmek yerine, regresyon prensibine dayanan bir algoritmadır, yani net ve ilginç kısmı tespit etmek ve belirlemek yerine, tüm görüntüyü çevreleyen kategorileri ve kutuları analiz eder ve tahmin eder ve bunu algoritmanın bir kez çalıştırmasıyla yapar. YOLO algoritması ile oluşturulan model çalıştırıldığında görüntülerdeki, videolardaki nesnelere ve bu nesnelere koordinatlarını aynı anda tespit etmektedir.


YOLO algoritması, öncelikle resmi parçalara ayırmaktadır. Daha bu parçalardaki nesnelere çevreleyen kutuları çizer ve her bir parçadaki nesnenin bulunma olasılığı ile ilgili hesabı yapar. Ayrıca her bir parçadaki nesne için bir güven skoru hesaplar. Bu skor bize o nesnenin yüzde kaç olasılıkla tahmin edilen nesne olduğunu söylemektedir (Kıvrak ve Gürbüz, 2022).

Bunun yapılabilmesi için bazı alt işlemlerin uygulanması gerekir. Her bir bölgeye özel bir tahmin vektörü oluşturulur, bu vektörler güven

skoru içerir. Güven skorunun sıfır olması nesne olmadığı, bir olması ise nesne olduğu anlamına gelmektedir. Bir nesne içerisindeki aynı nesne için birden fazla kare içinde yer alabilir. Bu tür problemlerden kurtulmak için de maksimum olmayan bastırma (Non-Maximum Suppression, NMS) tekniği kullanılır. Bu teknik, en yüksek güven skoru olan kareyi tutar diğerlerini görüntüden atmaktadır. Tüm bu işlemlerden sonra kesinlik değeri alınır ve sonuç tanımlanmasında ulaşılır.

Örneğin, bir çay tarlasında çekilen bir fotoğrafta güven skoru 0,9 olarak bulundu. Bunun anlamı o nesnenin çay olma olasılığının oldukça yüksek olduğudur. YOLO modeli bu tespit için iyi çalıştığını belirtmektedir. Her bir parça içindeki nesnelere maksimum olmayan bastırma tekniği uygulanır. Bu teknik güven skoru düşük olan nesnelere değerlendirmeden çıkarır ve aynı bölgede güven skoru daha yüksek bir kare varlığını kontrol eder. Her bir parçada nesne olup olmadığını araştırır. Eğer bir nesne bulunursa o nesnenin orta noktası, yüksekliği ve genişliği bulunur daha sonra nesneyi kapsayacak şekilde kare içine alır.

NMS'nin ilk adımı olarak, kutuları güven seviyelerine göre azalan sıraya göre sıralanır. Daha sonra bir güven eşiği tanımlanır. Bu eşiğin altında bir güven seviyesine sahip olan kutular kaldırılır. Bu örnekte, güven eşiği olarak 0,9 alındığını varsayalım. Bu eşiği kullanarak, sarı kutuyu kaldıracağız, çünkü güveni, güven eşiğinden düşük. Kutular güven seviyelerine göre azalan sırada olduğundan, listedeki ilk kutunun en yüksek güven seviyesine sahip olduğunu biliyoruz. Bu listeden ilk kutuyu (yeşil kutuyu) kaldırıldı ardından mavi da kaldırıldı. İşlem adımların uygulanma Şekil 2'deki gibidir.



Şekil 2. Maksimum Olmayan Bastırma (Non-Maximum Suppression, NMS) tekniği ile en iyi karenin bulması modellenmesi

Figure 2. Best-frame finding modelling with Non-Maximum Suppression (NMS) technique

2.2. Veri Setinin Oluşturulması

Nesne tespiti çalışmalarında veri seti çok önemlidir. Veri seti, nesne tespiti modelinin eğitimi için kullanılacak olan en önemli bileşendir. Veri seti, nesne takibi algoritmasının eğitiminde kullanılan örnek görüntülerdir. Veri setinde yeterli sayıda nesne, nesnenin farklı açılardan, farklı ışık koşullarında ve farklı ortamlarda çekilmiş görüntüleri bulunmalıdır. Veri setinin doğru bir şekilde bölünmesi, modelin doğru bir şekilde eğitilmesi için oldukça önemlidir. Çay ve eğrelti otlarının farklı açılarda, farklı ortamlarda çekilmiş fotoğraflarından oluşturulan veri setinde ilk olarak 747 adet fotoğraf bulunmaktadır. Fotoğraflar sadece eğrelti otu, sadece çay yaprağı ve hem eğrelti otu hem de çay yaprağı etiketlerini içerecek şekilde hazırlanmıştır. Veri setindeki fotoğrafların çözünürlüğünün yüksek olmasına dikkat edildi. Sıfırdan bu çalışma için hazırlanan veri seti Github veri tabanına kayıt edilerek verilmiştir (URL-1).

2.3. Veri Etiketlenmesinin Yapılması

Veri seti oluşturulduktan sonra, her bir verinin etiketlenmesi gerekmektedir. Etiketleme işlemi, nesnenin konumunun ve boyutunun belirlenmesini sağlar. Bu sayede nesne takibi algoritması, nesnenin hareketini doğru bir şekilde takip edilebilir (Yıldırım ve Cagıl, 2020).

Verilerin işaretlenmesi için birçok seçenek bulunmaktadır. LabelImg programı bu programlardan biridir. Çalışmada hazırlanan veriler LabelImg programında etiketleme işlemi yapılmıştır. LabelImg programında etiketlemeye başlamadan ilk önce, YOLO algoritmasını kullanarak nesne tespiti yapacağımız için YOLO algoritmasına uygun olarak çıktı verecek şekilde YOLO seçimi yapıldı. Ardından veri setinin

bulduğu klasöre girilerek fotoğrafların LabelImg'ye aktarılması sağlandı. LabelImg'de işaretlenmiş fotoğrafların kayıt edileceği yer olan veri seti klasörü içindeki Label adlı klasör seçildi ve fotoğraflar işaretlenmeye başlandı. Her bir fotoğraf tek tek özenle etiketlendikten sonra, etiketleme işlemi tamamlandı.

2.4. Veri Setinin Düzenlenmesi ve Çoğaltılması

Etiketleme işlemi bittikten sonra veri seti eğitim, doğrulama ve test verileri olarak bölünür. Bu bölümlenme, algoritmaların doğru bir şekilde eğitilmesi ve test edilmesi için önemlidir. Eğitim seti, nesne tespiti modelinin eğitiminde kullanılacak olan veri setidir. Eğitim seti, nesne tespiti modelinin öğrenme sürecindeki temel veri kaynağıdır. Model, eğitim setindeki görüntülerdeki nesnelere tanımak ve bu nesnelere özelliklerini öğrenmek için kullanılır. Doğrulama veri seti, eğitim sırasında algoritmanın performansını değerlendirmek için kullanılan bir veri kümesidir. Algoritmanın doğru öğrenip öğrenmediğini veya aşırı öğrenme (overfitting) olup olmadığını kontrol etmek için kullanılır. Aşırı öğrenme, algoritmanın eğitim setine çok fazla uyum sağlayarak genelleme yapma yeteneğini kaybetmesi durumudur. Son olarak test seti, eğitim setinin tamamlayıcısıdır ve modelin gerçek dünya verileri üzerindeki performansının doğruluğunun test edilmesi için kullanılır. Test seti, veri setinin geri kalan %20-30'unu oluşturabilir. Model, test setindeki görüntülerdeki nesnelere tanımak ve bu nesnelere konumlarını belirlemek için kullanılır (Alan ve Karabatak, 2020).

Fotoğraflar ve etiketlenmiş dosyalardan oluşan veri seti Roboflow web sayfası üzerinde nesne tespiti için açılan proje içerisine yüklenerek düzenlendi. Fotoğraflar yüklendikten sonra hali hazırda işaretlenmiş oldukları için fotoğraflarda işaretli bölgeler bu kısımda belirli olmaktadır.

Eğitim için kullanılacak veri %70, doğrulama ve test için kullanılacak toplam veri de %30 şeklinde ayarlandıktan sonra son kayıt da yapıldı. Veri seti içeriği Tablo 1'de verilmiştir.

Tablo 1 hem ham veri setindeki hem de artırılmış veri setindeki fotoğraf sayılarını göstermektedir. Tablo 1'deki bitki resimlerinin toplamı, tüm sayıdan fazla olmaktadır. Bunun sebebi bazı resimlerde her iki bitkinin bulunmasıdır.


Tablo 1. Ham veri seti/artırılmış veri seti dağılımı

Table 1. Raw data set/enhanced data set distribution

Veri Seti	Çay Yaprağı	Eğrelti Otu	Tümü
Eğitim (%70)	180/515	164/457	324/972
Doğrulama (%19)	141	146	267
Test (%11)	97	72	156

Veri arttırmak için farklı yöntemler kullanılmaktadır. Fotoğraf sayısının biraz daha artırmak amacıyla çevir yatay-dikey çevir, saat yönünde-saat yönünün tersinde 90° döndürme, -

15° ile +15° arasında döndürme, $\pm 15^\circ$ yatay ile $\pm 15^\circ$ dikey kırpma eklentileri Şekil 3'te verilen örnekte olduğu gibi eklendi.



Şekil 3. Veri setini büyütmek için uygulanan işlemler

Figure 3. Processes applied to enlarge the data set

Ardından yaklaşık üç kat fotoğraf sayısını arttırılarak veri setinin son haline ulaşılmış oldu. Şekil 4'te veri setinin bir kısmının son hali gösterilmiştir.



Şekil 4. Çoğaltma işlemlerinden sonra veri setinin etiketli hali

Figure 4. Labeled version of the dataset after replication

Yapılan bu işlemler sonucunda veri setindeki fotoğraf sayısı 1395'e çıkarılmıştır. Bu fotoğraflardan 972 tanesi eğitim seti, 267'si doğrulama seti ve 156 tanesi de test seti şeklinde

ayarlanarak veri seti model eğitimi için hazır hale getirilmiştir.

2.5. Model Eğitimi

Veri çoğaltma işlemi tamamlandıktan sonra model eğitimi yapılması kısmına geçilmektedir. En yaygın kullanılan ortamlardan birisi Google Colaboratory (Colab)'dır. Google Colab ücretsiz bir bulut tabanlı geliştirme ortamıdır. Eğitime başlamak için öncelikle Roboflow web sitesine girilerek YOLO modeli seçilir. Eğitim ilk olarak YOLOv5 versiyonu x paketi kullanılarak yapılır. Roboflow üzerinden ilgili YOLO modeli sayfasından Google Colab sayfasına geçilir. Model eğitimi farklı parametrelere ve veri setlerine göre birden fazla çalıştırılacağından Google Drive depolama hizmeti üzerinde kaydedilen bir dosya oluşturulur. Oluşturulan bu dosya kodlardaki bazı yerlere yapılan ekleme ve çıkarmalara bağlı olarak Roboflow'da hazırlanan veri setinin son haline göre model eğitimi yapılır.

Google Colab üzerinde çalışmaya başlamadan önce ilk olarak çalışma zamanı türü ayarı yapılmalıdır. Çalışma zamanı türü olarak grafik işlemci ünitesi (Graphics Processing Unit, GPU) ayarlandı. Bunun nedeni, Colab'ın varsayılan olarak sınırlı bir GPU kaynağına sahip olmasıdır. Bu nedenle, bazı durumlarda, Colab'da çalışan kodun daha hızlı çalışması için bu ayar yapılmalıdır.

Bu ayarlardan sonra kodlar sırasıyla çalıştırılmaya başlanmaktadır. Bu kodlar, ilgili YOLO modelini kullanarak özelleştirilmiş nesne tespiti modelinin eğitim ve test aşamalarını içermektedir (Altay ve Yılmaz, 2023). İlk olarak, YOLO ile ilgili gereksinimler kurulur. Bu adımda, özellikle torch kütüphanesi kullanılır. Daha sonra, Roboflow'dan veri kümesi indirilir ve YAML dosyası ile birlikte yüklendikten sonra, sınıf sayısı belirlenir. Bu sınıflar, nesne tespiti yapılacak nesnelere temsil eder. Ardından, önceden tanımlanmış bir YOLO model yapılandırması kullanılarak model özelleştirilir ve özelleştirilmiş model eğitilir. Tensorboard kütüphanesi kullanarak eğitimi izleyebilir ve sonuçlar görselleştirilir. Eğitim tamamlandıktan sonra eğitilmiş model, test veri kümesinde kullanılarak nesne tespiti yapılabilmektedir.

Bu işlemler YOLOv5x ve YOLOv8n için gerçekleştirilmiştir (Yanılmaz vd., 2024). Böylelikle model oluşturma, eğitime işlemleri tamamlanmıştır. Her iki modelin eğitiminde de epok sayısı daha fazla arttırıldığında herhangi bir değişim gözlemlendiği ana kadar eğitim sürdürüldü. YOLOv5x modeli için 620 ve YOLOv8n modeli için 270 oluşturulan veri setine göre en uygun epok değerleri olduğu tespit edildi. Epok terimi, eğitim verilerinin tamamının model tarafından bir kez işlendiği aşamadır.

2.6. Model Değerlendirme Metrikleri

Nesne tespiti modellerinde performans değerlendirmesi için kullanılan bazı terimler kullanılmaktadır. Bunlardan gerçek pozitif (True Positive, TP) sayısı, algoritmanın doğru bir şekilde tespit ettiği nesne sayısıdır. Yanlış pozitif (False Positive, FP) sayısı, algoritmanın yanlış olarak algıladığı nesne sayısıdır. Yanlış negatif (False Negative, FN) sayısı, algoritmanın tespit etmeyi kaçırdığı nesne sayısıdır. Gerçek negatif (True Negative, TN), nesne olmayan bölgeleri doğru bir şekilde tespit ettiğinde ve bunları nesne olmadığını tahmin ettiğinde ortaya çıkar (Hanbay ve Üzen, 2017).

IoU: Bu ölçüt, bir nesne tespit modelinin doğruluğunu ölçmek için kullanılır. İki dikdörtgenin kesişen alanının, toplam alanına oranı hesaplanarak, modelin doğru bir şekilde nesnelere tespit etme yeteneği ölçülür. IoU hesaplanması Eş. 1'de gösterilmektedir.

$$IoU = (Alan1 \cap Alan2) / (Alan1 \cup Alan2) \quad (1)$$

Keskinlik (Precision): Bu ölçüt, bir nesne tespit modelinin, bir nesneyi doğru bir şekilde tespit etme yeteneğini ölçer. TP (gerçek pozitif) sayısının, TP sayısı + FP (yanlış pozitif) sayısına oranı hesaplanarak, modelin yanlış pozitif sonuçlar üretmeden ne kadar doğru nesne tespiti yapabildiği belirlenir. Eş. 2 keskinlik hesabını vermektedir.

$$Keskinlik = TP / (TP + FP) \quad (2)$$

Duyarlılık (Recall): Bu ölçüt de, bir nesne tespit modelinin, bir nesneyi doğru bir şekilde tespit etme yeteneğini ölçer. TP sayısının, TP sayısı + FN (yanlış negatif) sayısına oranı hesaplanarak, modelin ne kadar nesneyi tespit edebildiği belirlenir. Duyarlılık Eş. 3'te gösterildiği gibi hesaplanmaktadır.

$$Duyarlılık = TP / (TP + FN) \quad (3)$$

Ortalama Kesinlik (Average Precision-AP): Bu ölçüt, modelin tüm sınıflar için kesinliğini hesaplar. AP, Kesinlik- Duyarlılık eğrisinin altında kalan alanı ifade eder.

Genel Ortalama Kesinlik (mean Average Precision-mAP): Bu ölçüt, tüm sınıflar için AP değerlerinin ortalamasını hesaplar. Bu ölçüt, modelin tüm sınıflar için ne kadar iyi performans gösterdiğini ve tüm nesne tespitleri için ne kadar doğru olduğunu gösterir. Genel ortalama kesinlik Eş. 4'teki gibi hesaplanmaktadır.

$$mAP = (AP1 + AP2 + \dots + APn) / n \quad (4)$$

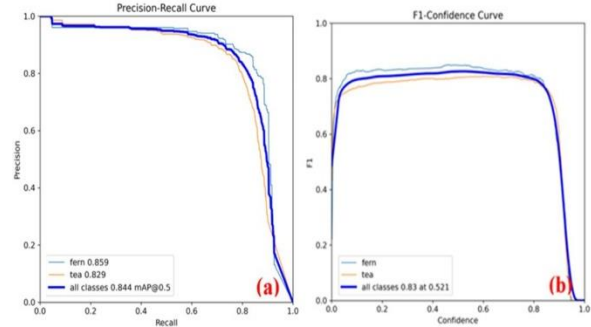
F1 değeri: Bu ölçüt, kesinlik ve duyarlılık değerlerinin harmonik ortalamasını hesaplar. F1 değeri, bir modelin doğru bir şekilde nesnelere tespit etme kabiliyetini ölçer. F1 değerinin hesaplanması Eş. 5'de gösterilmiştir. Eğer bir modelin hem kesinliği hem de duyarlılığı yüksekse, F1 değeri yüksek olacaktır (Hanbay ve Üzen, 2017).

$$F1 = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (5)$$

3. Bulgular ve Tartışma

YOLO geniş kullanım alanı ve yeni teknoloji gelişmeleri yoğun ilgi görmektedir. Yapılan çalışmaların birkaçı, giriş bölümünde tanımlanmıştır. Bu teorik çerçeveler ve çalışmalar, önerilen YOLOv5 ve YOLOv8 algoritmalarının bitki nesne tespiti için performansını araştırmaya yardımcı olduğundan, bu bölümde yapılan çalışmalardan elde edilen sonuçlar sunulmuştur.

YOLOv5x modeli ile başlanmıştır. Eğitim tamamlandıktan sonra, tüm sınıfların en iyi kesinlik ve duyarlılık değerleri sırasıyla 0,844 ve 0,810 olarak elde edilmiştir. Tüm sınıflar için mAP@0,5 değeri 0.844 ortalamasının üstü bir tespit sonucunu göstermektedir. Duyarlılık ve güven seviyesi arasındaki ilişkiyi gösteren grafik şekil 5a'da verilmiştir.




Şekil 5. YOLOv5x için eğitilen modelin (a) kesinlik ve duyarlılık arasındaki ilişki grafiği, (b) F1 skoru ve güven seviyesi arasındaki ilişki grafiği

Figure 5. The model trained for YOLOv5x (a) relationship graph between precision and recall, (b) relationship graph between F1 score and confidence level

Güven seviyesine dayalı olarak bireysel sınıfların eğitim performansı da sağlam bir model değerlendirmesi için kritik öneme sahiptir. Ancak, bu değer diğer bireysel sınıflar için değişkendir. Bu değişkenlik, farklı örnek sayısı ve görüntü gürültü seviyelerine bağlanabilir. Hangi güven seviyesinde kesinlik ve duyarlılık değerlerinin eşit dağıldığını tespit etmek için F1 skoru Şekil 5b'de görüldüğü gibi oluşturuldu. Sonuçlara göre, 0,521 güven seviyesinde tüm sınıflar için 0,83 F1 skoru elde edilmiştir.

Model eğitiminde YOLOv8n modeli için de aynı veri seti kullanılarak eğitim yapıldı. Eğitim tamamlandıktan sonra, tüm sınıfların en iyi kesinlik ve duyarlılık değerleri sırasıyla 0,867 ve 0,799 olarak elde edilmiştir. Duyarlılık ve güven seviyesi arasındaki ilişkiyi gösteren grafik şekil 6a'da verilmiştir. Tüm sınıflar için mAP@0,5 değeri 0.867 olarak görülmüştür.



Şekil 6. YOLOv8n için eğitilen modelin (a) kesinlik ve duyarlılık arasındaki ilişki grafiği, (b) F1 skoru ve güven seviyesi arasındaki ilişki grafiği

Figure 6. The model trained for YOLOv8n (a) relationship graph between precision and recall, (b) relationship graph between F1 score and confidence level

Hangi güven seviyesinde kesinlik ve duyarlılık değerlerinin eşit dağıldığını tespit etmek için F1 skoru Şekil 6b'de görüldüğü gibi oluşturuldu. Sonuçlara göre, 0,685 güven seviyesinde tüm sınıflar için 0,83 F1 skoru elde edilmiştir. Şimdiye kadar olan modeller içerisinde en yüksek düzeyi ve F1 skoru bu modelde elde edildi.

Çay yaprağı ve eğrelti otu üzerine yapılan çalışmada YOLOv5x ve YOLOv8n algoritmaları için kesinlik, duyarlılık, mAP@0,5 ve F1 skor sonuçları toplu olarak Tablo 2'de gösterilmektedir. YOLOv5x ve YOLOv8n yöntemlerinin karşılaştırılmasında, öncelikle kesinlik (precision) ve duyarlılık (recall) değerlerine odaklanmak önemlidir. YOLOv8n, genel olarak daha yüksek kesinlik değerine sahipken, YOLOv5x daha yüksek duyarlılık değerine sahiptir. Kesinlik, bir nesneyi doğru bir şekilde tespit etme yeteneğini ölçer. Yüksek kesinlik değeri, modelin yanlış nesne tespiti olasılığının düşük olduğunu ve dolayısıyla daha güvenilir sonuçlar ürettiğini belirtir. Duyarlılık da nesnenin doğru bir şekilde tespit etme yeteneğini ölçmektedir. Ancak gerçek pozitiflerin, tüm gerçek pozitifler ve yanlış negatif tahminlere oranını ifade eder. Yüksek duyarlılık değeri,

modelin gerçekten var olan tüm ilgili örnekleri tespit etme yeteneğinin yüksek olduğunu gösterir. Dolayısıyla, YOLOv8n'in daha yüksek kesinlik değeri, modelin daha az yanlış alarm verme olasılığına sahip olduğunu ve bu nedenle daha güvenilir şekilde doğru nesnelere tanımladığını vurgular. Öte yandan, YOLOv5x'in daha yüksek duyarlılık değeri, modelin daha fazla gerçek pozitif tespit ettiğini ve bu nedenle daha fazla gerçek örneği kaçırmadığını belirtir.

Eğrelti otu sınıfında, YOLOv5x modelinin kesinlik değerinde daha düşük duyarlılık açısından ise YOLOv8n'den daha üstün olduğu gözlemlenmiştir. Çay yaprağı sınıfında, YOLOv5x'in kesinlik değerinin daha yüksek olmasına rağmen YOLOv8n'in duyarlılık değerinin daha düşük olduğu görülmüştür.

mAP değeri, bir nesne tespiti modelinin tüm sınıflar için kesinlik ve duyarlılık dengesini gösteren bir ölçüdür. Yüksek mAP değeri, modelin tüm sınıflar için ne kadar iyi performans gösterdiğini ve tüm nesne tespitleri için ne kadar doğru olduğunu gösterir. F1 skoru ise, kesinlik ve duyarlılık arasındaki dengeyi ölçer. Benzer mAP ve F1 skoru değerleri, modelin genel olarak dengeli bir performans sergilediğini ve hem kesinlik hem de duyarlılık açısından iyi bir dengeye sahip olduğunu belirtir. Tablo 2 den yararlanarak yapılan karşılaştırmalarda, YOLOv8n mAP değeri az farkla daha iyiyken F1 skoru birine eşittir.

YOLOv5 ve YOLOv8 modellerine kararlılık performansına bakıldığında, çay ve eğrelti otu tespiti için benzer seviyede kararlılık göstermektedir. YOLOv8'in biraz daha yüksek kesinlik değerine sahip olması, bu modelin daha güvenilir bir performans sunabileceğine işaret etmektedir.

Tablo 2. YOLOv5 ve YOLOv8 modellerinin performans değerleri karşılaştırması

Table 2. Comparison of performance values of YOLOv5 and YOLOv8 models

Özellikler	Sınıf	YOLOv5x	YOLOv8n
Kesinlik (Precision)	Tümü	0,844	0,867

	Çay Yaprağı	0,827	0,847
	Eğrelti Otu	0,861	0,886
Duyarlılık (Recall)	Tümü	0,810	0,799
	Çay Yaprağı	0,785	0,722
	Eğrelti Otu	0,835	0,825
mAP@0,5	Tümü	0,844	0,867
	Çay Yaprağı	0,829	0,854
	Eğrelti Otu	0,859	0,881
F1 Skor	Tümü	0,83	0,83
Öğrenme Süresi (dk)	Tümü	185	243

Literatürde yer yerilen YOLOv4, YOLOv5, YOLOv7, Faster R-CNN ve Tek Atış Dedektörü (SSD) gibi nesne tespiti için kullanılan farklı metotlar içeren çalışmalar incelendi. Çalışmaların performans sonuçları ve kendi çalışmamızla karşılaştırılması Tablo 3'te özetlendi.

YOLO, Faster R-CNN, SSD ve MobileNetv2 gibi farklı nesne tespiti yöntemlerini kendi aralarında karşılaştırmak, her bir yöntemin performansını daha ayrıntılı bir şekilde anlamamıza yardımcı olmaktadır.

YOLOv4, YOLOv5, YOLOv7 ve YOLOv8 çalışmaları, YOLO tabanlı yöntemler olarak bir grup oluşturur. Bu yöntemler, nesne tespiti nispeten yüksek doğruluk oranlarına sahiptir. YOLOv7 ve YOLOv8, yüksek kesinlik, duyarlılık ve mAP değerlerine sahipken, YOLOv5 daha düşük bir mAP değerine sahiptir. Ancak, tablodaki her çalışmada genel olarak başarılı sonuçlar elde etmiştir. Faster R-CNN tabanlı çalışmalar, daha geleneksel bir nesne tespiti yaklaşımını temsil etmektedir. Elma Yaprağı Hastalıklarının Tespiti ve Elmalarda Çürük Tespiti çalışmaları, %84'e yakın doğruluk oranlarına sahiptir. SSD tabanlı çalışmalar nispeten düşük bir F skoru ile kabul edilebilir bir performans elde etmiştir. MobileNetv2 metodu da bir Convolutional Neural Network (CNN) türüdür. Yüksek doğruluk ve mAP değeri elde etmeyi başarmıştır.

Tablo 3. Literatürde yer verilen bu çalışma modellerinin performans değerleri karşılaştırması

Table 3. Comparison of the performance values of these working models in the literature

Çalışma	Yıl	Sınıf Sayısı	Metot	Performans
	2018	2	SSD	0,586 (F1 skoru tohum)

Domates yaprak hastalığı tespitinin geliştirilmesi çalışması, %97'ye yakın bir doğruluk oranına sahiptir, bu da MobileNetv2'nin tarım uygulamalarında etkili olduğunu göstermektedir. Ancak tüm çalışmaları performanslarına göre karşılaştırıldığında, en yüksek performans YOLOv7 çalışması ile elde edilmiştir. YOLOv7, yüksek doğruluk, kesinlik, duyarlılık ve mAP değerlerine sahip olmasıyla dikkat çekerken, YOLOv4, YOLOv5, YOLOv8 ve çalışmaları da genel olarak tespit edilen sorunun giderilmesi adına başarılı sonuçlar vermiştir.


Çalışmanın sonucunda elde edilen modeller ile oluşturulan test sonuçları YOLOv5 (620 epok), ve YOLOv8 (320 epok) için Şekil 7-8'de sırasıyla gösterildi. Daha iyi ve eş karşılaştırma yapabilmek amacıyla aynı fotoğrafın testi yapıldı. Bu şekilde sonuçlar daha net gözükmemektedir. YOLOv5 modeli için eğitim yapılırken 620 epok değerine gelindiğinde son 50 epokta değişim gözlemlenmediği için model durduruldu ve sonuçlar bu epok değerine göre alındı. YOLOv8 modeli için ise 320 epok değerine gelindiğinde son 50 epokta değişim gözlemlenmediği için model durduruldu ve sonuçlar bu epok değerine göre alındı. Epok terimi, eğitim verilerinin tamamının model tarafından bir kez işlendiği aşamadır.

Akıllı Tarım için Soya Fasulyesinin Büyüme Durumunu Yakalamaya Yönelik Bir Görüntü Algılama Yöntemi (Omura vd., 2018)					0,646 (F1 skoru çiçek)
Elmalarda Çürük Tespiti (Cömert vd., 2019)	2019	2	Faster R-CNN		Doğruluk 84,95
Elma Yaprağı Hastalıklarının Tespiti (Sardoğan vd., 2020)	2020	2	Faster R-CNN		Doğruluk 84,5
Poisonous Mushroom Detection (Cengil ve Çınar, 2021)	2021	8	YOLOv5		mAP@0.5 0,778
Patates Böceğinin Patates Bitkisi Üzerinde Tespiti ve Populasyon İzleme Olanakları (Biçgi ve Karaca, 2022)	2022	2	YOLOv4		Duyarlılık 0,78 Kesinlik 0,85 F1 skoru 0,81 mAP 87,53
Üzüm yaprakları sınıflandırması (Koklu vd., 2022)	2022	5	MobileNetv2 CNN		Doğruluk 97,60
Domates yaprak hastalığı tespitinin geliştirilmesi (Brucal vd., 2023)	2023	2	SSD MobileNetv2		Doğruluk 94,51 mAP 92,45
Çay yaprağı hastalığının tespiti ve tanımlanması (Soeb vd., 2023)	2023	5	YOLOv7		Doğruluk 97,3 Kesinlik 96,7 Duyarlılık 96,4 mAP 98,2 F1 skoru 0,965 Kesinlik 0,792
Çilek Hasat Verimliliğinin Artırılması (Nergiz, 2023)	2023	6	YOLOv7		Hatırlama 0,575 mAP@.5 0,558 mAP@.5:.95 0,46 Kesinlik 0,844 Duyarlılık 0,810 mAP@0,5 0,844 F1 Skor 0,83
Çay ve Eğrelti Otunun Karşılaştırmalı Tespiti (Bu çalışma)	2024	2	YOLOv5		Kesinlik 0,867 Duyarlılık 0,799 mAP@0,5 0,867 F1 Skor 0,83
			YOLOv8		



Şekil 7. YOLOv5x modelinin test sonucu örnekleri

Figure 7. Test results examples of the YOLOv5x model



Şekil 8. YOLOv8n modelinin test sonucu örnekleri

Figure 8. Test results examples of the YOLOv8n model

4. Sonuç

Çay toplama aşamasında çay yapraklarının içine karışan yabancı otların tespitini yaparak çay üretimini iyileştirmek oldukça önemlidir. Yapay zeka teknolojisinin yüksek oranda kullanıldığı günümüzde, bu çalışma önemli bir potansiyele sahip olabilir. Bu çalışmada, çay bahçelerinden çay yaprakları ve eğrelti otları nesne türlerini tespit etmek ve tanımlamak için YOLOv5 modeli ve YOLOv8 kullanılmıştır. Ancak nesne tespiti söz konusu olduğunda çok fazla sayıda metot kullanılmaktadır. Literatürde yer yerilen çalışmalarda YOLOv4, YOLOv5, YOLOv7, Faster R-CNN ve Tek Atış Dedektörü (SSD) gibi nesne tespiti için kullanılan farklı metotlar incelenmiştir. İncelenen çalışmalar her ne kadar benzer konularda olsalar dahi kullanılan metotlara göre alınan performanslar değişiklik göstermiştir. YOLO, gerçek zamanlı nesne tespiti için optimize edilmiş ve hızlı tepki verme yeteneği ile öne çıkmaktadır. Diğer yöntemlere kıyasla daha basit ve daha hızlı bir model bizlere sunmaktadır. Algılama yeteneği sayesinde farklı boyutlardaki ve kategorilerdeki nesnelere algılayabilir. Sürekli güncellemeler ve geliştirmelerle desteklenen YOLO geniş bir kullanım alanına sahiptir ve hız, verimlilik ve genel uygulanabilirlik avantajlarıyla diğer yöntemlere kıyasla tercih edilebilir hale gelmektedir. Bu sebeplerden dolayı tespit ettiğimiz soruna YOLO yaklaşımı ile devam ettik. Çalışmamızda kullanılan modeller iki farklı sınıfı tespit etmekte ve doğruluk oranlarını model referanslarına göre belirtmektedir. YOLO modellerinin performanslarını değerlendirmek için kesinlik, duyarlılık, mAP@0,5 ve F1 skor parametreleri kullanıldı. İlk eğitilen YOLOv5 modelinde elde edilen sonuçlar sırasıyla kesinlik, duyarlılık, mAP@0,5 ve F1 skor olmak üzere sırasıyla %84,4, %81,0, %84,4 ve %0,83'tür. Eğitilen YOLOv8 modelinde ise kesinlik, duyarlılık, mAP@0,5 ve F1 skor parametrelerinde sırasıyla %86,7, %79,9, %86,7 ve %0,83 sonuçları alınmıştır. Çalışmada YOLOv8'in performansı önceki sürüm olan YOLOv5 ile eğitilen modelle karşılaştırıldığında kesinlik ve mAP@0,5 parametrelerinde YOLOv8'in daha iyi performans gösterdiği gözlemlenmiştir. Duyarlılık parametresinde ise YOLOv5 modellerin daha iyi sonuç verdiği gözlemlenmiştir. F1-Skoru değerinde ise iki modelin de aynı sonucu verdiği gözlemlenmiştir. Her iki modelde aynı test verilerinin karşılaştırılması sonucunda da YOLOv8'n modelinin hem adet olarak daha fazla doğru nesne tanımladığı hem de yüksek doğruluk oranında

tespit yaptığı belirlendi. Eğiten modeller daha da geliştirilerek daha iyi sonuçlar elde edilebilir. Veri kümesinin genişletilmesi, gelecekteki geliştirme için odak noktalarından biridir. Ayrıca, daha gelişmiş etiketleme teknikleri kullanılarak görüntü kalitesi arttırılabilir. Model, nesnelere interneti cihazlarıyla uyumludur ve gerçek dünya uygulamaları için geçerlidir. Bu araştırma, çay bitkisinin içine karışan yabancı otların tespitini kolaylaştırır ve onların hızlı tespitine katkıda bulunur.

Yazar katkısı

Ö. Önder: Araştırma, Veri toplama, Veri işleme, Literatür taraması, Görselleştirme, Düzenleme; **Y. Karan:** Araştırma, Proje Yönetimi, İnceleme, Düzenleme, Malzeme tedarik.

Teşekkür

Bu çalışmada desteklerinden dolayı İNCE ARGE'den Berkan Emre İNCE ve Recep Tayyip Erdoğan Üniversitesi Merkezi Araştırma Laboratuvarı Uygulama ve Araştırma Merkezi'nden Öğr. Gör. Soner TOKÇALAR'a teşekkür ederiz.

Çıkar Çatışması Beyanı

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Etik standartlar

Bu çalışma için Etik Kurul Kararı gerekmemektedir.

Kaynaklar

- Aktaş, A., Demir, Ö., Doğan, B. (2020). Derin öğrenme yöntemleri ile dokunsal parke yüzeyi tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(3), 1685-1700.
<https://doi.org/10.17341/gazimmfd.652101>
- Alan, A. ve Karabatak, M. (2020). Veri seti-sınıflandırma ilişkisinde performansa etki eden faktörlerin değerlendirilmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(2), 531-540.
<https://doi.org/10.35234/fumbd.738007>
- Altay, A., Yılmaz, S. (2023). YOLO Algoritması Kullanılarak T Hücrelerinin

- Sınıflandırılması. *İleri Mühendislik Çalışmaları ve Teknolojileri Dergisi*, 3(2), 66-81.
<https://dergipark.org.tr/en/pub/imctd/issue/75051/1230096>
- Biçgi, M. ve Karaca, İ. (2022). Nesne tespit algoritması (YOLOv4) kullanarak patates böceğinin (*Leptinotarsa decemlineata*)(Say) patates bitkisi üzerinde tespiti ve populasyon izleme olanakları. *Türk Bilim ve Mühendislik Dergisi*, 4(2), 123-129.
<https://doi.org/10.55979/tjse.1210904>
- Brucal, S., De Jesus, L., De Los Santos, J., Mendoza, M., Harion, K., Reyes, G., Nevalasca, D., Reyes, J. (2023). Development of Tomato Leaf Disease Detection using Single Shot Detector (SSD) Mobilenet V2. *International Journal Of Computing Sciences Research*, 7, 1857-1869.
<https://www.stepacademic.net/ijcsr/article/view/405>
- Cengil, E. and Çınar, A. (2021). Poisonous mushroom detection using YOLOV5. *Turkish Journal of Science and Technology*, 16(1), 119-127.
<https://dergipark.org.tr/en/pub/tjst/issue/60560/873764>
- Cömert, O., Hekim, M., Adem, K. (2019). Faster R-CNN kullanarak elmalarda çürük tespiti. *International Journal of Engineering Research and Development*, 11(1), 335-341.
<https://doi.org/10.29137/umagd.469929>
- Hanbay, K. ve Üzen, H. (2017). Nesne tespit ve takip metotları: Kapsamlı bir derleme. *Türk Doğa ve Fen Dergisi*, 6(2), 40-49.
<https://dergipark.org.tr/en/pub/tdfd/issue/33022/367257>
- Kıvrak, O. ve Gürbüz, M.Z. (2022). Performance comparison of yolov3, yolov4 and yolov5 algorithms: A case study for poultry recognition. *Avrupa Bilim ve Teknoloji Dergisi*, (38), 392-397.
<https://doi.org/10.31590/ejosat.1111288>
- Koklu, M., Unlersen, M.F., Ozkan, I.A., Aslan, M.F., Sabancı K. (2022). A CNN-SVM study base on selected deep features for grapevine leaves classification. *Measurement*, 188, 110425.
<https://doi.org/10.1016/j.measurement.2021.110425>
- Nergiz, M. (2023). Enhancing Strawberry Harvesting Efficiency through Yolo-v7 Object Detection Assessment. *Turkish Journal of Science and Technology*, 18(2), 519-533.
<https://doi.org/10.55525/tjst.1342555>
- Omura, K., Yahata, S., Ozawa, S., Ohkawa, T., Chonan, Y., Tsuji, H., Murakami, N. (2018). An Image Sensing Method to Capture Soybean Growth State for Smart Agriculture Using Single Shot MultiBox Detector. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 1693-1698). IEEE.
<https://doi.org/10.1109/SMC.2018.00293>
- Öztürk, K. ve Şahin, M.E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
<https://dergipark.org.tr/tr/pub/takvim/issue/40063/427526>
- Sardoğan, M., Özen, Y., Tuncer, A. (2020). Detection of apple leaf diseases using faster R-CNN. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(1), 1110-1117.
<https://doi.org/10.29130/dubited.648387>
- Soeb, M.J.A., Jubayer, M.F., Tarin, T.A., Al Mamun, M.R., Ruhad, F.M., Parven, A., Meftaul, I.M., (2023). Tea leaf disease detection and identification based on YOLOv7 (YOLO-T). *Scientific Reports*, 13(1), 6078. <https://doi.org/10.1038/s41598-023-33270-4>
- URL-1, (2023). <https://www.kaggle.com/datasets/ozguronder1/tea-fern-dataset>, 3 Eylül 2023.
- Yanılmaz, S., Türkoğlu, M., Aslan, M (2024). Güneş Enerjisi Santrallerinde YOLO Algoritmaları ile Hotspot Kusurlarının Tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36(1), 121-132.
<https://doi.org/10.35234/fumbd.1318060>
- Yıldırım, B. ve Çağıl, G. (2020). Bir montaj parçasının derin öğrenme ve görüntü işleme ile tespiti. *Journal of Intelligent Systems: Theory and Applications*, 3(2), 31-37.
<https://doi.org/10.38016/jista.710144>
- Yıldız, S. ve Midilli, A. (2022). Türkiye'de organik çay üretimi ve pazarlaması. *Recep Tayyip Erdoğan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 3(2), 136-145.
<https://doi.org/10.53501/rteufemud.1174700>
- Yılmaz, S. (2023). Beyin tümörü tanıları için YOLOv7 algoritması tabanlı karar destek

sistemi tasarımı. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 6(1), 47-56.
<https://doi.org/10.53410/koufbd.1236305>