

Kabuklu Fındık Meyvesinde Derin Öğrenme Tabanlı Kusurlu Meyvelerin Tespiti

Oğuzhan KIVRAK^{1*}, Mustafa Zahid GÜRBÜZ²

¹Bandırma Onyedi Eylül Üniversitesi, Bandırma Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Balıkesir/TÜRKİYE

²Doğuş Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul/TÜRKİYE

Alınış tarihi: 24 Eylül 2023, Kabul tarihi: 27 Ekim 2023

Sorumlu yazar: Oğuzhan KIVRAK, e-posta: oguzhan.kivrak@gmail.com

Öz

Amaç: Bu çalışmada, fındıktaki kaliteyi artırabilmek amacıyla kabuklu fındıkta kusurlu olanları manuel bir süreç olmaktan çıkartıp otomatik olarak tanımlanması için bir yöntem geliştirilmesi hedeflenmiştir. Çatlak, kırık, delik gibi kusurlu fındıkların derin öğrenme tabanlı bir yapay zeka modeli ile sınıflandırması amaçlanmıştır.

Materyal ve Yöntem: Çalışmada kullanılacak veri kaynağı için cep telefonu vasıtasıyla fotoğraf çekilmesi suretiyle veriler kayıt altına alınmıştır. Kayıt altına alınan veriler bir etiketleme uygulaması sayesinde kusurlu ve sağlam olmak üzere 2 sınıfa ayrılmıştır. Son olarak etiketlenen veriler test, validasyon ve eğitim olmak üzere 3 parçaya ayrılmıştır. Facebook firmasının geliştirmiş olduğu Detectron2 uygulaması üzerinde Faster R-CNN modeli çalıştırılmıştır.

Araştırma Bulguları: Araştırmada dijital dönüşüm adımı olarak bir görüntü işleme teknolojisiyle kusurlu ve sağlam fındıklar mAP ölçeğine göre %92 başarı ile tespit edilmiştir.

Sonuç: Fındıkta kaliteyi ve randımanı arttırmak için sağlam fındık ile kusurlu fındığın ayıklanması gerekmektedir. Bu süreçte bir karar destek sistemi olarak görüntü işleme ile kusurlu fındığın tespit edilmesi çalışması yapılmıştır. Yapılan deney sonuçlarına göre kusurlu fındığın %92 başarı ile tespit edildiği gösterilmiştir. Yapılan bu çalışma kusurlu fındığın ayıklama sürecinde yardımcı bir yapay zeka uygulaması olarak kullanılabilir.

Anahtar kelimeler: Kusur Tespiti, Yapay Zeka, Süreç Yönetimi, Teknoloji ve Yenilik Yönetimi, Karar Destek Sistemleri

Deep Learning-Based Detection of Defective Fruits in Shelled Hazelnut Fruits

Abstract

Objective: This study aims to develop a method to automatically identify defects in shelled hazelnuts, eliminating the need for a manual process, in order to increase the quality of hazelnuts. It is also aimed to classify hazelnuts with defects such as cracks, breaks and holes with a deep learning-based artificial intelligence model.

Materials and Methods: In this paper, first, a literature review was conducted for hazelnuts. The dataset to be used in the study, was prepared by taking photographs via a mobile phone. The prepared data is divided into 2 classes: defective and regular, thanks to a labelling tool. Finally, the labelled data is divided into 3 parts: testing, validation, and training. As an image processing algorithm, Faster R-CNN model was run on the Detectron2 application developed by Facebook.

Results: In this research, a digital transformation step, using image processing technology, defective and regular hazelnuts were detected with a success rate of 92% according to the mAP scale.

Conclusion: To increase the quality and yield of hazelnuts, regular hazelnuts and defective hazelnuts must be sorted out. A study was carried out to detect defective hazelnuts using image processing as a decision support system. According to the test results, it was shown that defective hazelnuts were detected with 92% success. This study can be used as an artificial intelligence application to assist in the sorting process of defective hazelnuts.

Keywords: Defect Detection, Artificial Intelligence, Process Management, Technology and Innovation Management, Decision Support Systems

Giriş

Gıda endüstrisinin en önemli maddelerinden biri olan kabuklu fındık, dünya çapında yaklaşık olarak 900.000 ton olarak üretilmektedir. Toplam üretiminin %66,2'si Türkiye tarafından sağlanırken, İtalya ise yaklaşık %10,9'unu karşılayarak dünyada ikinci üreticidir. Ayrıca Çin, Amerika Birleşik Devletleri, Gürcistan, Azerbaycan ve İran'da da üretim yapılmaktadır (Giraud ve ark., 2018). Üretilen fındığın ulusal ve uluslararası piyasanın pazar gereksinimlerini karşılayabilmesi için belli kalitede olması önem arz etmektedir. Bunun içinde hasat sonrası çıkan kabuklu fındığın ayıklama ve temizleme işlemi satışa hazırlanmadan önce yapılmalıdır. Bu süreç fındık işleme fabrikalarında çoğunlukla manuel ayıklama ile yapılmaktadır. Manuel ayıklama işlemi de yüksek bir iş gücü gerektirir (Ünal ve Aktaş, 2023).

Fındık meyve tutumundan hasada kadar birçok faktörlerin etkisi altındadır. Hasat olumuna gelen meyvelerin bahçeden toplanması (hasat) ve toplanan fındığın zuruğunun ayrılması (harman) ve kurutulması ile süreç tamamlanır ve tüketim yada işleme aşamasına geçilir. Bu süreçte bazı meyve kusurları kaliteyi azaltmakta ve sorun teşkil etmektedir. (Yıldız, 2020). Fındıkta kusurlu meyveler genetik kaynaklı olabileceği gibi bahçeden meyve gelişimi aşaması yada kurutma aşaması kaynaklı da olabilir (İslam, 2021).



Şekil 1. Kusurlu meyveleri de içeren kabuklu fındık harmanından alınan kesit

Fındıkta meyve kusurlarının tespitinde manuel yada görüntü işleme tanımlamaları yapılabilmektedir. Solak ve Altınışık (2018)'in yaptığı çalışmada fındığı küçük, orta ve büyük olarak sınıflandırmışlardır. Pallottino ve arkadaşları (2010) yaptığı çalışmada kavruşan fındık tanelerinin soyunma yüzdeleri

tespit eden yöntem geliştirmişlerdir. Bir başka çalışmada, Bayrakdar ve arkadaşları (2015) kabuklu fındıkların şekil ve boyut özelliklerinden yararlanarak, görüntü işleme yöntemleri ile tür ve kalitesinin belirlemişlerdir. Giraud ve arkadaşlarının (2018) yaptığı çalışmada ise kusurlu iç fındıkları RGB görüntü analizi ve renklerine dayalı bir yöntem geliştirmiştir. Boyar ve Yıldız (2022) ise fındıktaki külleme tespitini YOLOv5 kullanarak gerçekleştirmiştir. Ünal ve Aktaş(2023) ise derin öğrenme ile fındıkları "hasarlı", "kabuk", "küçük boyutlu" ve "nihai ürün" olarak sınıflandırmışlardır.

Bu çalışmada, fındıkta meyve kusurlarının tespitine yönelik olarak görüntü işleme teknolojisine dayanan çözüm önerisinde, derin öğrenme algoritmalarına dayalı bir yöntem geliştirilmesi amaçlanmaktadır. Başka bir deyişle kabuklu fındık meyvesinde derin öğrenme teknikleri yardımı ile kusurlu meyvelerin ayrımının yapılabilmesi amaçlanmıştır.

Materyal ve Metot

Materyal

Fındıkta kalitenin artırılması için saklama koşullarının uygun olması gerekmektedir. Bu koşullardan bir tanesi de depolanacak fındığın kusurlarından ayıklanması gerekmektedir. Bu amaçla fındıktaki kusurları tespit edecek bir yöntem geliştirilmesi için yapılan çalışmanın detayları paylaşılmıştır. Görüntü işleme için en önemli adım veri toplama ve etiketlemedir. Bu çalışma kapsamında Şekil 2'de görüldüğü şekilde fındıklar aralarında boşluklar olacak şekilde bir zemine yayılarak kuşbakışı fotoğraflar, 40 cm yukarıdan bir cep telefonu aracılığıyla 1280*900 çözünürlükte çekilmiştir.



Şekil 2. Veri kümesi için kullanılan fındık fotoğrafları
Çekilen fotoğraflar bir sunucuda toplanmıştır. Ardından bu fotoğraflar sunucu üzerinde bir

uygulamanın yardımıyla fotoğrafın içerisindeki sağlam fındıklar ile kusurlu fındıklar etiketleme formatı olan YOLO formatında dikdörtgen şeklinde etiketlenerek kaydedilmiştir. Etiketlemede kusurlu ve sağlam olmak üzere iki adet etiket ismi kullanılmıştır. Etiketleme için, San Francisco, California'da yer alan bir ekip tarafından hayata geçirilmiş Label Studio isimli açık kaynak kodu proje olan bir uygulama kullanılmıştır. (Label Studio, t.y.). Etiketlenen veri setinin sınıflara ayrılması için görüntü işleme algoritması olarak Faster R-CNN (Hızlı Bölge Tabanlı Evrişimli Sinir Ağı) algoritması kullanılmıştır. Faster R-CNN, Bölge Teklif Ağı (Region Proposal Network, RPN) ve İlgi Havuzlama Bölgesi (Region of Interest Pooling, RoI Pooling) olarak iki ana kısımdan meydana gelmektedir. Faster R-CNN çalıştırıldığında çıktı olarak sınırlayıcı kutu, etiket değeri ve olasılık değerini vermektedir. Faster R-CNN Algoritmasının çalışması için gerekli olan girdi parametresi olan fotoğraflar ve COCO formatında etiketlenen koordinat verileri verilmiştir (Ren ve ark, 2015).

Çalıştırılan algoritmanın eğitim sırasında kullandığı modelin eğitiminin başarısı takip etmek için Loss değeri kullanılmaktadır. Loss değeri temel olarak eğitim kümesi ile validasyon kümesinin arasındaki hata değeridir. 1.00 ve altında bir değer başarılı bir eğitim süreci olduğunu ifade ederken, sıfır veya sıfıra çok yakın değerler eğitimin "ezberlenme" diye tabir edilen istenmeyen durumu ifade etmektedir.

Gerçek ve tahmin sınıfların değerleri karmaşıklık matrisi kullanılarak modellerin performans sonuçlarının tespitinde kullanılmaktadır (Korkmaz ve Büyükgöze, 2019). Test aşamasında ise modelin doğruluğunu hesaplamak için mean average precision (mAP) ölçeği kullanılmaktadır. mAP ölçeğini hesaplamak için öncelikle kesinlik değerini bulmak gerekmektedir. Kesinlik (precision) değeri pozitif tahminlerin başarı oranıdır. Pozitif ile kasıt tahmin edilen sınıfı temsil eder. Bu projede sağlam fındıklar sınıfı için düşünüldüğünde sağlam olanlar pozitif, olmayanlar negatiftir. Kesinlik ise (1) nolu formülde verildiği gibi pozitif sınıfın doğru tahmin edilenlerin tüm pozitif sınıfa oranıdır.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (1)$$

Burada DP değeri doğru pozitif, YP değeri yanlış pozitif olarak yazılmıştır. Doğru pozitif gerçekte sağlam olan fındığı sağlam tahmin etmektir. Yanlış pozitif ise gerçekte kusurlu olan fındığı sağlam olarak tahmin etmektedir. Ortalama kesinlik değeri (AP),

nesne tespiti gibi çoklu sınıf sınıflandırma problemlerinde kullanılan bir ölçüdür. Her bir sınıf için hesaplanan kesinlik değerinin ortalamasıdır.

$$mAP = \frac{\sum_k^n AP_k}{n} \quad (2)$$

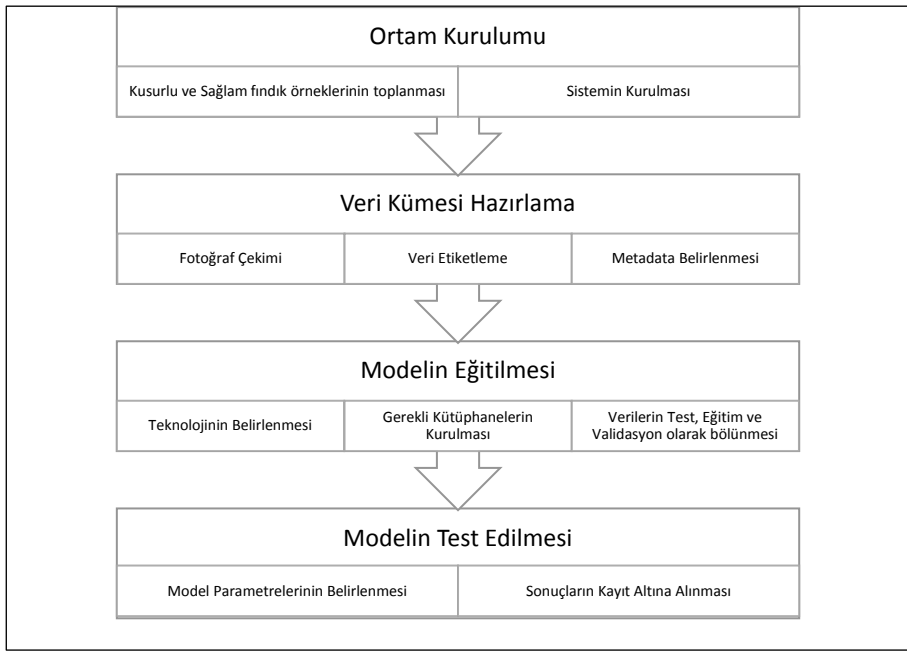
mAP değeri, (2) nolu formüldeki gibi tanımlanır ve çoklu sınıfın içeren algoritmanın performansını tek bir ölçekte belirtmek için kullanılmaktadır.

Metot

Kusurlu fındığın tespiti için öncelikle görüntü işleme algoritmasının eğitilmesi gerekmektedir. Eğitim işlemi gerçekleştikten sonra algoritmanın çıktı modeli kullanılarak test kümesi üzerinde model çalıştırılarak çıkan sonuçların başarı hesaplaması yapılır. Bu çalışma kapsamında izlenen adımlar Şekil 3'de gösterildiği gibi sırasıyla ortam hazırlama, veri kümesinin hazırlanması (fotoğraf çekimi ve veri etiketleme), modelin eğitilmesi ve modelin test edilmesi adımlarından oluşmaktadır.

Veri Kümesi Hazırlama:

Çalışmada, Ordu ili Perşembe ilçesinden toplanan fındıklar kullanılmıştır. Fındık sahipleri tarafından manuel olarak ayıklanan kusurlu fındıklar ile sağlam fındıklar veri kümesi oluşturmak için alınmıştır. Kusurlu ve sağlam fındıkların bulunduğu bir miktar kabuklu fındık aralarında boşluk olacak şekilde bir yüzeye yerleştirilmiştir. Yüzeye yerleştirilen fındıkların dik açıdan olacak şekilde fotoğrafları çekilerek veri kümesi hazırlanmıştır. Fotoğraf çekim aşamasından sonra hem model eğitimi hem de test için gerekli olan veri etiketlenmiştir. Etiketleme için web tarayıcı üzerinden çalışan Label Studio isimli uygulama kullanılmıştır. Etiketleme için dikdörtgen şeklinde sınırlayıcı kutular her bir fotoğraf karesinin içindeki fındık ile ilişkili her bir obje için çizilerek işlem tamamlanmıştır. Etiketleme sonucu seçilen koordinatlar YOLO formatında fotoğraf ile aynı isimde bir txt metin dosyasında kaydedilmiştir. Veri kümesindeki fotoğrafların içerisinde aralarında boşluk olacak şekilde birden fazla kabuklu fındık yer almaktadır. Fotoğraf görüntü açısında gözle görülebilen kusurlara sahip olan fındıklar kusurlu fındık olarak işaretlenmiştir. Fındığın kırık olması, çatlak olması, üzerinde delik olması, zurufundan ayrılmamış olması, rengi normalden daha kara olması, üzerinde küf benzeri lekelerin olması durumlarında kusurlu fındık olarak işaretlenmiştir. Veri kümesi bir kod parçacığı ile anlık olarak dinamik ve rastgele olacak şekilde eğitim (%70), test (%10) ve validasyon (%20) olarak 3 kümeye ayrılmıştır.



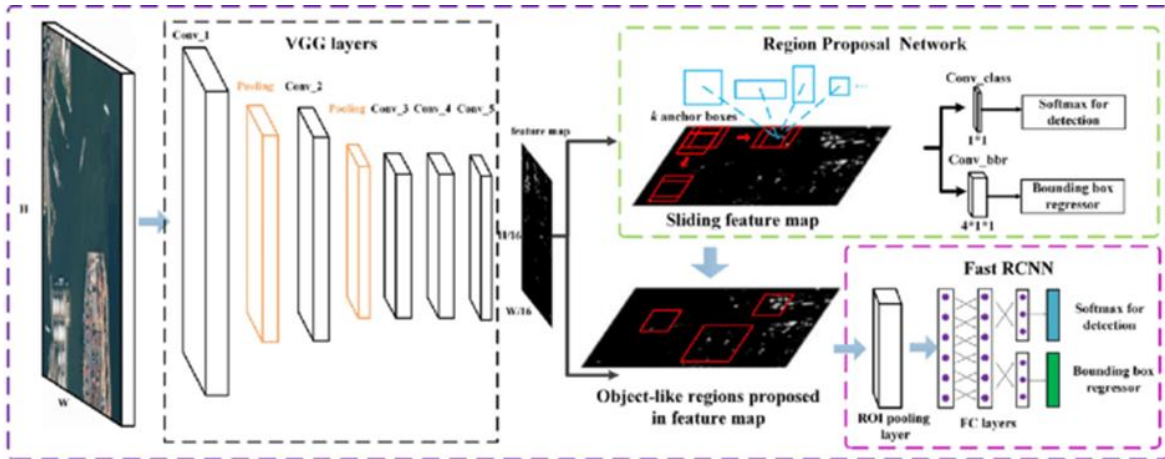
Şekil 3. Önerilen Modelin Akış Diyagramı

Bu ayırım yapılırken kusurlu ve sağlam fındık oranları dikkate alınarak dengeli bir şekilde seçim yapılması için kod parçacığı buna göre düzenlenmiştir.

Model Eğitimi ve Test Sonuçları:

Derin öğrenme görüntü tespiti, sınıflandırma, veri işleme, ses analizi gibi doğrusal olmayan fonksiyonlardan yararlanarak yapay sinir ağlarına dayalı bir yöntemdir. Derin öğrenmede girdi katmanı ve çıktı katmanı arasında gizli katman olarak birçok katman tasarlanabilir (Tan ve ark.,2021). Evrimsel Sinir Ağları (CNN) ve YOLO mimarileri gibi derin öğrenme tabanlı nesne algılama algoritmaları, trafik izleme, yaya algılama ve yüz tanıma gibi çeşitli alanlarda umut verici sonuçlar ortaya koymuştur (Korkmaz ve Ağdaş,2023). Bu çalışmada derin

öğrenme tabanlı bir model eğitimi yapılmıştır. Modelin eğitimi için hazırlanan veri kümesindeki eğitim ve validasyon verileri kullanılmaktadır. Evrimsel sinir ağındaki geri bildirimler ve model iyileştirilmesi aşamasında validasyon kümesi kullanılmaktadır. Model eğitiminin tamamlanması için loss değerinin 1.00 altında olması beklenmektedir. Modelin eğitimi 1400 iterasyon çalıştırılmıştır. Model eğitiminde Faster R-CNN algoritması kullanabilmek için Facebook yapay zeka ekibi tarafından geliştirilen Detectron2 teknolojisi kullanılmıştır (Y.Wu ve ark, 2019). Detectron2 kütüphanesi, içerisinde Faster R-CNN dahil çeşitli evrimsel ağ algoritmalarının bulunduğu bir kütüphanedir. Faster R-CNN, Şekil 4'de görüldüğü üzere algılama çerçevesi iki aşamaya ayrılmaktadır.



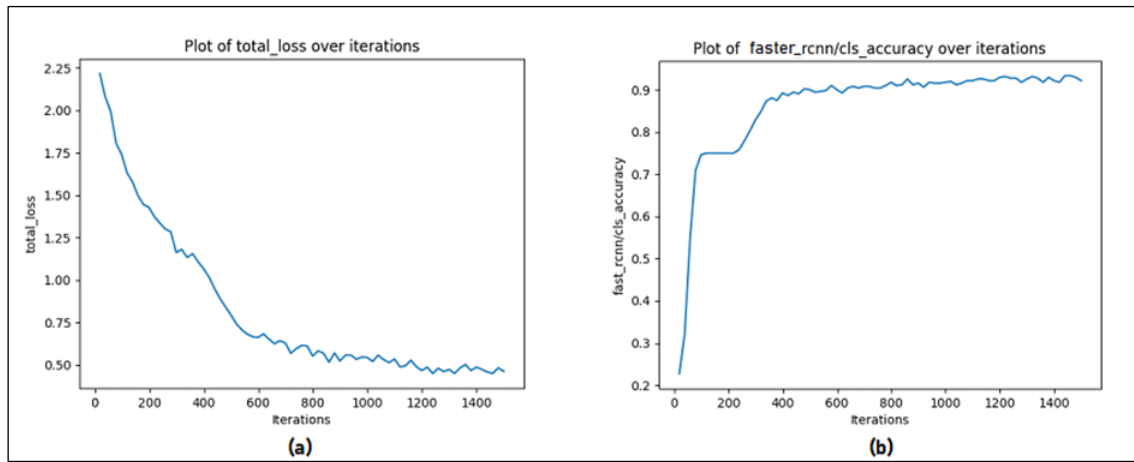
Şekil 4. Faster R-CNN algoritmasının mimari yapısı (Deng ve ark., 2018)

RPN adı verilen ilk aşamada görüntüler işlenmektedir. Özellik haritaları çıkartılarak, sınırlayıcı kutu önerilerini bulmak için kullanılır. İkinci aşamada ise bu önerileri azaltmak için sınıflandırma ve sınırlayıcı kutu regresyonu için Fast R-CNN algoritmasından yararlanılmaktadır (Deng ve ark., 2018). Bu kütüphanedeki en sık kullanılan ve en verimli algoritmalarından olan Faster R-CNN algoritmasının çalıştırılabilmesi için veri kümesinin etiketlerinin COCO formatında olması gerekmektedir. Bundan dolayı, Python ile hazırladığımız bir

dönüştürücü fonksiyonu yazılarak, Label Studio uygulamasından elde edilen etiket verisi COCO formatına dönüştürülerek işlem yapılmıştır.

Bulgular ve Tartışma

Veri kümesi için toplamda 17326 adet fındık etiketlenmiştir. Bu etiketlerde 2994 adet kusurlu, 14332 adet sağlam fındık yer almaktadır. Eğitim ve validasyon kümesi model eğitimi için kullanılmıştır. Algoritma 1400 iterasyon süresince çalıştırılmıştır. Model eğitiminde loss fonksiyonu değeri 1.00 altında olması beklenmektedir.



Şekil 5: Loss değeri ve mAP değeri grafiği

Şekil 5'de sol tarafta (a) görüldüğü gibi loss değeri yüksek bir değerden başlayarak hızla düşüş eğitimi göstermiştir. İlk iterasyonlarda bu şekilde hızlı iyileşme beklenen bir durumdur. Burada dikkat edilecek konu sürekli bir iyileşmenin elde edilmesidir. Deney sonucunda sürekli azalma 600. iterasyona kadar hızlı bir şekilde devam ettiği görülmüştür. Sonrasında azalma hızı yavaşlayarak devam etmiştir. 600 iterasyondan sonra 0,68 değerinden başlayarak algoritma sonunda 0,45 değerine yakınsamaktadır. Algoritmayı daha fazla iterasyon çalıştırmak için gereken süre dikkate alındığında elde edilen loss değeri bakımından istatistiksel olarak anlamlı olmayacağından bu iterasyon sayısı deneyi sonlandırmak için yeterlidir. Son iterasyonda elde edilen bu değer model eğitiminin başarılı olduğu hakkında bir belirteçtir. Şekil 5'de sağ tarafta (b) model eğitiminin başarısını ölçmek için test veri kümesi üzerinde yapılan deney sonuçları mAP ölçeğine göre verilmiştir. Loss değerine ters orantılı olarak model başarısı hızlı bir şekilde yükselmiş ve bir süre sonra yükselme hızı yavaşlayarak rutin bir seyir izlemektedir. 600.iterasyondan sonra %89 başarı oranı yakalanmış

ve algoritma sonunda bu değer %92 değerine ulaştığı görülmüştür. Bu sonuçlara göre 600 ila 800 iterasyon arası bir iterasyon sayısı yeterli görülmektedir. İterasyon sayısını arttırmak modelin başarısı üzerinde istatistiksel olarak anlamlı bir fark yaratmayacağı sonucu çıkartılabilir.

Elde edilen sonuçlar derin öğrenme tabanlı bir kusur tespit sisteminin endüstri uygulamalarında önemli bir potansiyeli olduğunu göstermektedir. Ancak, bu sonuçların gerçek dünya uygulamalarındaki performansını da izlemek gerekir. Ayrıca, veri kümesini diğer bölgelerde yetişen fındık cinsleri ile genişleterek modelin tespit yeteneği artırılabilir. Ayrıca modelin saha koşullarında kullanılacak pratik uygulama alanları hakkında yapılacak çalışmalar hakkında tartışma yapılabilir. Örneğin bu yöntemi temel alan bir donanım ile fındık ayıklama işlemi yapılabilir.

Sonuç ve öneriler

Dünyadaki fındık arzının büyük çoğunluğunu elinde bulunduran Türkiye için kalitenin belirli bir seviye tutulması önem arz etmektedir. Özellikle son dönemlerde kabuklu fındık ihracatı azalırken işlenmiş ürün ihracatı artmaktadır. Bu durumda

işlenen üründe belli bir kalitenin yakalanması gerekmektedir. Bu kalitenin düşmemesi için görüntü işleme ile çözüm yöntemi geliştirilmiştir. Bu çalışmada derin öğrenme yöntemi ile fındık meyvelerinin içindeki kusurlu fındıklar %92 oranında başarılı bir şekilde bulunmuştur. Gelecek çalışmalarda fındık kusurları üzerinde daha detaylı araştırmalar yapılarak etiketleme adımı genişletilebilir ve model eğitimi geliştirilebilir. Ayrıca veri kümesinin çeşitliliği ve hacmi, modelin genel performansını artırma potansiyeline sahiptir ve veri kümesinin artması başarı oranını da arttıracaktır. Bu çalışma, Perşembe ilçesinde yetiştirilen fındıklardan elde edilen görüntüler üzerine odaklanmıştır; ancak, gelecekteki araştırmalarda farklı coğrafi bölgelerden alınan fındık örneklerinin analizi yapılabilir. Bu bağlamda, mevcut Faster R-CNN modeli dışında diğer görüntü işleme model mimarilerinin değerlendirilmesi de önerilir. Son olarak, geliştirilen modelin gerçek dünya uygulamalarında nasıl performans gösterdiğini değerlendirmek amacıyla saha denemeleri yapılabilir. Endüstriyel ortamlarda ve üretim hatlarında kullanılabilirliği üzerine yapılan araştırmalar, bu teknolojinin pratik uygulamalardaki etkinliğini daha ayrıntılı bir şekilde anlamamıza yardımcı olacaktır.

Çıkar çatışması

Yazarlar arasında herhangi bir çıkar çatışması yoktur.

Yazarların katkı beyanı

Yazarlar tüm aşamalarda eşit oranda katkı sunmuşlardır.

Teşekkür

Bu çalışmada kullanılan verinin etiketleme süreci OGZA Teknoloji AŞ tarafından yapılmış olup, elde edilen veriler hibe edilmiştir.

Kaynaklar

- Bayrakdar, S., Çomak, B., Başol, D., & Yücedag, İ. (2015, May). Determination of type and quality of hazelnut using image processing techniques. In 2015 23rd Signal Processing and Communications Applications Conference (SIU) (pp. 616-619). IEEE.
- Boyar, T., & Yıldız, K. (2022). Powdery Mildew Detection in Hazelnut with Deep Learning. *Hittite Journal of Science and Engineering*, 9(3), 159-166.
- Deng, Z., Sun, H., Zhou, S., Zhao, J., Lei, L., & Zou, H. (2018). Multi-scale object detection in remote sensing imagery with convolutional neural networks. *ISPRS journal of photogrammetry and remote sensing*, 145, 3-22.

- Giraud, A., Calvini, R., Orlandi, G., Ulrici, A., Geobaldo, F., & Savorani, F., (2018). Development of an automated method for the identification of defective hazelnuts based on RGB image analysis and colourgrams. *Food Control*, 94, 233-240. <https://doi.org/10.1016/j.foodcont.2018.07.018>
- İslam, A., (2021). *Fındık*. Nobel yayınları, Yayın no: 3893, ISBN: 978-625-417-388-2, Ankara.
- Korkmaz A., & Ağdaş, M.T. (2023), Deep Learning-Based Automatic Helmet Detection System in Construction Site Cameras, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12(3), 773-782, Sep. 2023, doi:10.17798/bitlisfen.1297952
- Korkmaz, A., & Büyükgöze, S. (2019). Sahte web sitelerinin sınıflandırma algoritmaları ile tespit edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 16, 826-833. DOI: 10.31590/ejosat.598036
- Label Studio (t.y.). Image Labeling Tool. Erişim adresi <https://labelstud.io/>
- Pallottino, F., Menesatti, P., Costa, C., Paglia, G., De Salvador, F. R., & Lolletti, D. (2010). Image analysis techniques for automated hazelnut peeling determination. *Food and Bioprocess Technology*, 3, 155-159.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- Solak, S. ve Altınışık, U. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(1),56-65.
- Tan, F. G., Yüksel, A. S. Aydemir, E., Ersoy, M. (2021). Derin öğrenme teknikleri ile nesne tespiti ve takibi üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*, 25,159-171.
- Ünal, Z. & Aktaş, H., (2023). Classification of hazelnut kernels with deep learning. *Postharvest Biology and Technology*, 197, 1-9. <https://doi.org/10.1016/j.foodcont.2018.07.018>
- Wu, Y., Kirillov, A., Massa, F., Lo, W.Y., & R. Girshick, (2019), Detectron2, Erişim Adresi: <https://github.com/facebookresearch/detectron2>.
- Yıldız, T. (2020). Türkiye'de fındık tarımında hasat-harman mekanizasyonu. *Tarım Makineleri Bilim Dergisi*, 16(1), 12-22.