



Derin öğrenme teknikleri ile elmada (Granny Smith) kusur tespiti

Defect detection in apple (Granny Smith) with deep learning techniques

Zeynep Ünal^{1,*}, Tefide Kızıldeniz², Mustafa Özden³, Hakan Aktaş⁴, Ömer Karagöz⁵

^{1,2}Niğde Ömer Halisdemir Üniversitesi, Biyosistem Mühendisliği Bölümü, 51240, Niğde Türkiye

³Niğde Ömer Halisdemir Üniversitesi, Bitkisel Üretim ve Teknolojileri Bölümü, 51240, Niğde Türkiye

⁴Niğde Ömer Halisdemir Üniversitesi, Bilgisayar Mühendisliği Bölümü, 51240, Niğde Türkiye

⁵Niğde Ömer Halisdemir Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, 51240, Niğde Türkiye

Öz

Elma (*Malus communis* L.) derimi sırasında ürünün kalitesini düşüren fiziksel zararlanmaların oluşması kaçınılmazdır. Zarar gören meyvelerin erken tespit edilerek ayrılması ticari değerinin artırılması açısından önemlidir. Tespit edilemeyen kusurlu ürünler sağlam ürünlerin kalitesini etkilediğinden dolayı gıda kaybının yanı sıra üretim hacmini de düşürmektedir. Çalışmanın amacı, “Granny Smith” elma çeşidinden alınan görüntüler üzerinde, derin öğrenme teknikleri kullanarak elmalarda kusur tespit etmektir. Özel koşul gerektirmeyen, uygun maliyetle sınıflandırma ve kusur tespiti yapacak bir teknik araştırılmıştır. Çalışmada, InceptionV3 modelinin 100 çevrim sonunda test doğruluğu %100, AlexNet modelinin ise test doğruluğu %98.33 elde edilmiştir. Derin öğrenme teknikleriyle, derim sırasında meyve üzerinde oluşan zararlar tespit edilerek ayrılmasıyla, derim sonrası oluşabilecek ekonomik kayıpların önüne geçebilecek bir yöntem geliştirilmiştir.

Anahtar kelimeler: AlexNet, Kusur tespiti, Derin öğrenme, Elma sınıflandırması, Granny Smith, InceptionV3

1 Giriş

Son 60 yılda 12 kattan fazla artış gösteren elma üretimimiz, FAO'nun 2019 raporuna göre ülkemiz ilk sıralarda yer almaktadır. 2017 yılında Dünya genelinde üretilen 83 milyon ton elmanın 3.62 milyon tonu Türkiye’de üretilerek elma üreticileri sıralamasında Türkiye, Çin ve ABD’den sonra üçüncü sırada yer almıştır. Elma üretim alanı bakımından ise Türkiye, Çin, Hindistan ve Rusya’dan sonra dördüncü sırada yer almaktadır [1]. Dünya pazarlarında yer edinebilmek için pazarın isteklerine uygun kalitede ürün elde edilmelidir. Yaş meyve ve sebze üretimi, tür ve çeşitlere göre değişmekle birlikte üreticiden tüketiciye ulaşmaya kadar ürün kaybının %30’a ulaştığı ve bu oranın %22’nin ise hasat ve depolama esnasındaki kayıplardan olduğu tahmin edilmektedir [2]. Elma deriminde ve derim sonrası aşamalarda görülen fiziksel etkiler sonucu oluşan yara, bere

Abstract

During apple (*Malus communis* L.) harvesting, physical damage that reduces the quality of the product is inevitable. Early detection and separation of damaged fruits is important in terms of increasing their commercial value. Undetected defective products reduce the production volume as well as food loss, since they affect the quality of intact products. The aim of this study is to detect defects in apples using deep learning techniques on images taken from the “Granny Smith” apple cultivar. A technique that does not require special conditions and that will make classification and defect detection cost-effectively has been researched. In the study, the test accuracy of the InceptionV3 model was 100% after 100 epochs, and the test accuracy of the AlexNet model was 98.33%. A method has been developed that can prevent economic losses that may occur after harvesting by detecting and separating the damages that occur on the fruit during harvesting with deep learning techniques.

Keywords: AlexNet, Apple classification, Bruise detection, Deep learning, Granny Smith, InceptionV3

ve ezikler, çürümelere ve ağırlık kayıplarına neden olmaktadır. Fiziksel yaralanmalardan sonra yaklaşık olarak birkaç saat içinde fenolik maddelerin oksidasyonu sonucu renk bozulması başlamaktadır. Zarar görmüş meyvelerin depolama sırasında çürüme oranı %25 iken, zarar görmemiş meyvelerde ise %1.3 olduğu bilinmektedir [3]. Bu çürümelere özellikle hasat öncesi ve sonrasında meyve yüzeyinde meydana gelmiş fiziksel yaralanmalardaki latent enfeksiyonlardan kaynaklanmaktadır [4]. Meyve çürümesi, meyvenin piyasaya gönderilmeden önce derecelendirilmesinde önemli bir kalite indeksidir [5]. Bahçede veya paketleme evlerinde kayıpların nedenleri sıralandığında ilk sırada seçme, boylamadaki başarısızlık gelmektedir [2]. Bu nedenle depolara gönderilen ürünün sistematik bir şekilde ayıklanarak yerleştirilmesi, mevcut depolama kapasitesini verimli kullanılmasını sağlayacak, aynı zamanda depolama sırasındaki kayıpları azaltacaktır.

* Sorumlu yazar / Corresponding author, e-posta / e-mail: zeynepunal@ohu.edu.tr (Z. Ünal)

Geliş / Received: 15.02.2023 Kabul / Accepted: 13.09.2023 Yayınlanma / Published: 15.10.2023

doi: 10.28948/ngumuh.1250012

Elmada fiziksel zarar tespiti konusunda literatürde çok sayıda çalışma vardır. En yaygın olarak kullanılan yöntem, görüntüleme sistemine dayalı yapay görme (makine vizyonu) tekniğidir. Araştırmacılar, farklı görüntüleme teknikleri kullanarak meyvelerdeki zararlanma seviyelerini erken tespit etmeye yönelik araştırmalar yürütmüşlerdir. Bu araştırmalarda biyobenek görüntüleme [6], floresan görüntüleme [7], yapısal aydınlatma-yansıma görüntüleme [8], hiperspektral veya multispektral görüntüleme [9], [10], [11], X-ışını görüntüleme [12], manyetik rezonans görüntüleme ve termal görüntüleme [13], [14] gibi görüntüleme tekniklerini yapay görme ile entegre ederek fiziksel zararlanma seviyelerini belirlemeye çalışmışlardır [15]. Bu çalışmalar incelendiğinde çoğunlukla yüksek maliyetli görüntüleme sistemlerinin kullanıldığı görülmektedir ancak bu gerçek zamanlı uygulama, laboratuvar ortamında olup, ortam ışıklandırmasından etkilendiğinden dolayı ticari amaçlı kullanılması için yeterli bulunmamıştır. [15]. Işık gerektirmeyen tekniklerden biri ise termal görüntüleme tekniği olup, performans ve hız açısından uygun olsa bile ortam sıcaklığından etkilenmesi, ticari kullanımının önünde bir engel oluşturmaktadır [16]. Floresan görüntüleme tekniği ise klorofil içeren meyvelerin kullanımı için uygundur ancak meyvenin gelişme oranına göre farklı klorofil miktarı içermesi, uygulamayı etkilemektedir [15]. X-ray görüntülemenin pahalı olmasının yanında radyasyon yaydığından tarım uygulamaları için elverişli değildir [12]. Bu nedenle düşük maliyetli yeni elma sınıflandırma sisteminin tasarlanması, değerli bir araştırma konusu olarak ortaya çıkmaktadır.

Ülkemizin sahip olduğu iklim koşullarından dolayı elmanın anavatanı olması sebebiyle, Türkiye’de birçok elma çeşidinin yetiştiriciliği yapılmaktadır. Elma üretimimizin %53.22’sini “Starking Delicious”, %28.00’ini “Golden Delicious”, %7.99’ünü “Amasya”, %1.89’ünü “Granny Smith” ve %8.90’ını diğer çeşitler oluşturmaktadır. Türkiye’de ve Dünyada üretilen elma çeşitleri dikkate alındığında elma meyvesinde hasar tespiti yapılan çalışmalar, Tablo 1’de yer almaktadır.

Tablo 1. Zararlanmaları tespit etmek için yapılan çalışmalar

Elma Çeşitleri	Çalışmalar
Red Delicious	[6], [16], [17], [18], [19]
Fuji	[20], [21], [22], [16], [23], [24]
Jonagold	[25], [26], [12], [27], [28], [29], [30], [31], [10]
Golden Delicious	[32], [33], [7], [34], [35], [36], [37], [13], [38], [39], [40]
Royal Gala	[36], [37]
Pink Lady	[32]
Joly Red	[12], [31]
Champion	[38], [40]
Macintosh	[16]
Granny Smith	[39], [41], [42], [43]

Literatürdeki çalışmalar elma çeşitleri açısından değerlendirildiğinde, tek renk olması sebebiyle fiziksel

zararlanmaların tespitinde, kendine has çeşit özelliklerinden dolayı kısmen daha kolay tespit edilen “Golden Delicious” çeşidi oldukça fazla çalışılmıştır [35]. Birden fazla renk içeren “Jonagold” ve “Fuji” gibi çeşitlerde başarı oranını artırmak için yapay zekâ tekniklerinden k-NN, Fuzzy k-NN, SVM ve C4.5 gibi tekniklerden yararlanılmıştır. Son yıllarda birçok alanda başarı ile uygulanan derin öğrenme teknikleri, “Jonagold” ve “Fuji” elma çeşitlerinde fiziksel zarar veya kusur tespit etme uygulamalarında başarılı bir şekilde uygulandığı görülmüştür [26]. Dünyada önemli çeşitlerden birisi olan ve ülkemizde de üretiminin artması beklenen “Granny Smith” çeşidini [3] konu alan çalışmaların yetersiz olduğu görülmektedir. “Granny Smith” tek renkli olması sebebiyle “Golden Delicious”a benzer bir şekilde sınıflanabileceği varsayılmaktadır ancak “Granny Smith”in sert dokusu olması sebebiyle zarar görmüş dokudaki renk değişimi “Golden Delicious” çeşidine göre nispeten daha az olduğundan [44] ayıklama algoritmasında uygulanacak görüntü işleme tekniklerinin uygulanmasını zorlaştırmıştır

Son yıllarda görüntüler içerisindeki renk, desen, şekil gibi birçok özellik, herhangi bir ön işleme gereksinim duymadan anlamlandırılan derin öğrenme tekniği, elma dokusundaki zararlanmaları tespit etme için başarıyla uygulanabilmiştir.

En popüler derin öğrenme ağlarından biri Evrişimli Sinir Ağlarıdır (ESA) [45]. RGB görüntüleri ile eğitilen ESA, elmalarda gözle görülür kusurların tespitinde başarıyla uygulanmıştır. Fan vd. [24] ESA kullanarak ‘Fuji’ elma çeşidinde görünen kusurlar tespit etmişlerdir. We vd. [46] ESA mimari yapılarından biri olan AlexNet modelini kullanarak, ‘Aksu Fuji’ elma çeşidinin de kusurları sınıflandırmıştır. Kumar vd. [47] elmaları kalitesine göre sınıflandırmıştır. Stasenkov vd. [48] hasat sonrası zararlanmaları U-Net, Deeplab, and Mask R-CNN mimari yapıları kullanarak sınıflandırmıştır. Xin vd. [49] YOLOv3 mimari yapısını kullanarak zararlanma tespiti yapmışlardır. Xue vd. [50] GoogLeNet mimari yapısını kullanarak, Ayaz vd. [51] ise ResNet, SqueezeNet, and MiniVGGNet mimari yapısını kullanarak elma kusurlarını tespit etmişlerdir.

Bu çalışmada, “Granny Smith” elma çeşidinde, RGB kamera ile alınan görüntüler ESA eğitilerek kullanılarak, bunun sonucunda elmaların zararlanmış veya sağlam şeklinde sınıflandırılması amaçlanmıştır. Deney seti kullanılarak elmalardan alınan görüntüler üzerinde, derin öğrenme teknikleri kullanarak elmalarda kusur tespiti yapılmıştır. Elde edilen görüntüler öncelikle %70, %15 ve %15 oranlarında sırasıyla eğitim doğrulama ve test veri setleri olarak bölünmüştür. Bu veri setleri ile literatürde yer alan AlexNet ve InceptionV3 yapıları eğitilmiş ve devamında da bu yapılar test edilmiştir.

2. Materyal ve metod


2.1 Deney düzeneği

Araştırmada kullanılacak bitki materyali, Niğde Ömer Halisdemir Üniversitesi Tarım Bilimleri ve Teknolojileri Fakültesi, Uygulama ve Araştırma alanında yer alan meyve bahçesinden temin edilmiştir (37°56’N-34°37’E). 2014 yılında tesis edilen bahçe, damla sulama sistemine sahip olup, bahçenin yıllık bakım işleri her bir çeşit için homojen


şekilde yapılmıştır. Elmalar, çeşide özgü ticari olgunluk aşamasına geldiğinde derimleri yapılmıştır. Derim sonrasında, yüzer adet fiziksel zararlanmalara sahip elmalar ile sağlam elmalar görüntü elde etmek için soğuk hava deposuna alınmıştır. 3 saat sonra depodaki elmaların görüntüleri alınmıştır. Çekilen görüntülerin ortam aydınlatmasından etkilenmemesi için Şekil 1’de verilen deney düzeneği tasarlanmıştır. Deney düzeneği için duvarları beyaz renge boyanmış bir 60x60x60 cm ebatında kutu kullanılmıştır. Kutunun zeminine 2 cm kalınlığında siyah renge boyanmış bir sahne yerleştirilmiştir. Sahne renginin siyah olarak seçilmesinin sebebi, aydınlatmanın elma üzerindeki yansıma etkisini azaltmaktır. Elmaya

istenilen açıyı verebilmek için sahnenin tam ortasında 1 cm kalınlık ve 2 cm yarı-çapında bir oyuk açılmıştır.

Kutu duvarlarına 30 derecelik bir eğimle aydınlatma yerleştirilmiştir. Aydınlatmaların her birinin önüne elma üzerindeki yansımanın engellenmesi için %70 ışık geçirgenliği olan birer adet perde kullanılmıştır. Kutunun tavanına, kameranın USB kablo bağlantısı dışarıda ve kamera merceği sahneye bakacak şekilde kamera yerleştirilmiştir. Her bir elmanın 2 farklı yönden görüntüsü alınmıştır. Şekil 2’de deney seti kullanılarak alınan örnek görüntüler verilmiştir.



Şekil 1. Deney düzeneği



Şekil 2. Elma örnekleri: (a) Sağlam, (b) Hasarlı örnek 1, (c) Hasarlı örnek 2, (d) Hasarlı örnek 3, (e) Hasarlı örnek 4, (f) Hasarlı örnek 5

Şekil 2. (a)'da verilen görüntü sağlam elma sınıfına aittir. Elmanın yüzeyinde herhangi bir leke veya fiziksel zararlanma bulunmayıp, pürüzsüz görünümüne ait elmalar bu sınıfa seçilmiştir. Şekil 2. (b)'de verilen görüntüde, sert zemine çarpma sonucunda oluşup ve üstünden 3 saat geçtikten sonra oluşan hasarlı bölge gösterilmiştir. Şekil 2. (c)'de elmaların birbirine çarpması sonucu veya derimleri sırasında kasa kenarlarına çarpması sonucu oluşan, daha dar bir alanı kaplayan bir hasar gösterilmiştir. Şekil 2. (d)'de çarpma ve dolu zararı nedeniyle aynı elmanın yüzeyinde oluşturduğu zararlanma gösterilmiştir. Şekil 2. (e)'de sadece dolu zararı gösterilmiştir. Şekil 2. (f)'de elmalar bir hafta beklendikten sonra oluşan hasarı örneklemek için verilmiştir, ancak deneyde bu örnekler kullanılmamıştır. Çalışmada sadece hasar oluştuktan 3 saat sonra oluşan zararlanmaların olduğu görüntüler kullanılmıştır.

Şekil 2'de verilen elma görüntüleri ön işlem uygulanmamış ham görüntülerdir. Deney düzeneği endüstriyel elma ayıklama makinesinin çalışma prensibini örnek olarak tasarlandığı için ön işleme sürecine gerek kalmadan kullanılmaya olanak sağlamıştır. Kamera 90 derece açı ile elmayı görüntü karesinin tam ortasına alacak şekilde yerleştirilmiş ve sahne renginin siyah olması, gürültüsüz görüntüler elde edilmesine imkân sağlamıştır. Aydınlatmaların yansımalarının elma üzerinde oluşması, deney düzeneği tasarımı ile engellendiği için görüntü işleme filtrelerine ihtiyaç duyulmamıştır. Derin öğrenme modellerinde, eğitimde kullanılmak üzere 200 adet sağlam ve 200 adet kusurlu elma görüntüsü elde edilmiştir.

2.2 Derin öğrenme ve evrişimsel sinir ağı (ESA) modeli


Derin öğrenme, veriler içerisinde bulunan saklı bilgiden en üst düzeyde yararlanmaya imkân tanıyan, iç içe geçmiş karmaşık verilerin temel taşlarını tanımlayarak daha başarılı sonuçlar elde eden makine öğrenmesi tekniğidir [51]. Derin öğrenme tekniğinin kullandığı çok katmanlı makine öğrenmesi modellerinde denetimli veya denetimsiz öğrenme, her katmandaki verilere doğrusal olmayan dönüşümler gerçekleştirilip bir üst, daha soyut katmana aktarıldıktan sonra gerçekleşir. Derin öğrenme modelinde ilk katman giriş katmanıdır. Sınıflandırılacak görüntüler bu katmanda pikseller bazında haritalanmaktadır. Sonraki katmanlarda sınıflandırmanın gerçekleşebilmesi için çeşitli dönüşümlerin ve hesaplamaların yapıldığı "Gizli Katman"lar vardır. Son olarak, derin öğrenme modelinde sınıflandırmanın sonucunu gösteren çıkış katmanı bulunur [52].

Bir makine öğrenim tekniğinin iyi performans gösterme yeteneği, öncelikle girdi verilerinin ne kadar iyi temsil edildiğine bağlıdır. Verilerin ön işlenmesi bu nedenle öğrenme sistemlerinin geliştirilmesinde çok önemli bir aşamadır. Öznitelik çıkarma işlemi sırasında, girdi verilerindeki özniteliklerin miktarını azaltmak için uzmanlardan yararlanmaya çalışılmaktadır. Bu özellik çıkarma etkinliği, lojistik regresyon ve destek vektör makineleri (SVM'ler) gibi yüzeysel öğrenme modellerinin etkinliği için gereklidir. Bu prosedür çok zaman ve çaba gerektirir, ancak çok önemlidir. Bu sorunu çözmeye görevini

basitleştirmek için algoritmaları kullanmak daha yararlı bir yaklaşımdır. Yüksek boyutlu verilerle uğraşmanın ve ayırt edici bilgileri çıkarmanın en iyi yollarından biri, derin öğrenme algoritmalarını kullanmaktır [54].

Geleneksel makine öğreniminin temel fikirleri, derin ağların oluşturulması üzerinde etkili olmuştur çünkü derin öğrenme, makine öğreniminin bir alt kümesidir [53, p. 98]. Bununla birlikte, deneysel araştırmalara göre, derin tasarımları öğretmek sığ olanlardan daha zordur [55]. Aktivasyon fonksiyonu, kayıp fonksiyonu ve optimizasyon yöntemi, sinir ağı modelinin hızlı ve verimli eğitimi sırasında doğru sonuçlar vermede çok önemli unsurlardandır [56]. Optimizasyon prosedürü, kayıp fonksiyon değerini azaltmak amacıyla katmanları oluşturan nöronların optimal ağırlık matrislerini belirlemek için kullanılır. Derin öğrenme ağı önceden belirlenmiş sayıda çevrim boyunca eğitilir ve her çevrimden sonra nöronların ağırlıkları, kayıp fonksiyonun değerinin düşmesine ve sonunda sifıra ulaşmasına neden olacak şekilde değiştirilir [57]. Bu nedenle öğrenme ve test sırasında kayıp fonksiyonun değerinin düşük olması, ağı bilgiyi öğrendiğini göstermektedir.

Derin öğrenme algoritmalarından meyve ve sebze sınıflandırmasında yaygın olarak kullanılan CNN algoritmasıdır [58], [59]. Beynin görsel korteksinin görsel bilgileri işleme prensiplerinden ilham alınarak tasarlanan CNN yapıları çok katmanlı sinir ağının özel bir türü olup ilk olarak Le Cun tarafından 1998'de LeNet-5 mimarisi olarak önerilmiş ve el yazısı tanıma probleminde uygulanmıştır [60]. CNN algoritmasının tercih edilmesinin sebebi, bir girdi görüntüsünden herhangi bir ön işleme gerek kalmadan istenilen özellikleri çıkarabilmeleridir. Üç ana katman kullanılarak oluşturulmuş klasik CNN mimarisi Evrişim katmanları, Havuz katmanları ve Tam Bağlantılı (FC) katmanlarından oluşur. Üç katmanlı CNN mimarisinin grafiksek gösterimi Şekil 3'te verilmiştir. Bu katmanların derinliği ve genişliği değiştirilerek performansları geliştirebilmektedir [61].




Şekil 3. Üç katmanlı CNN

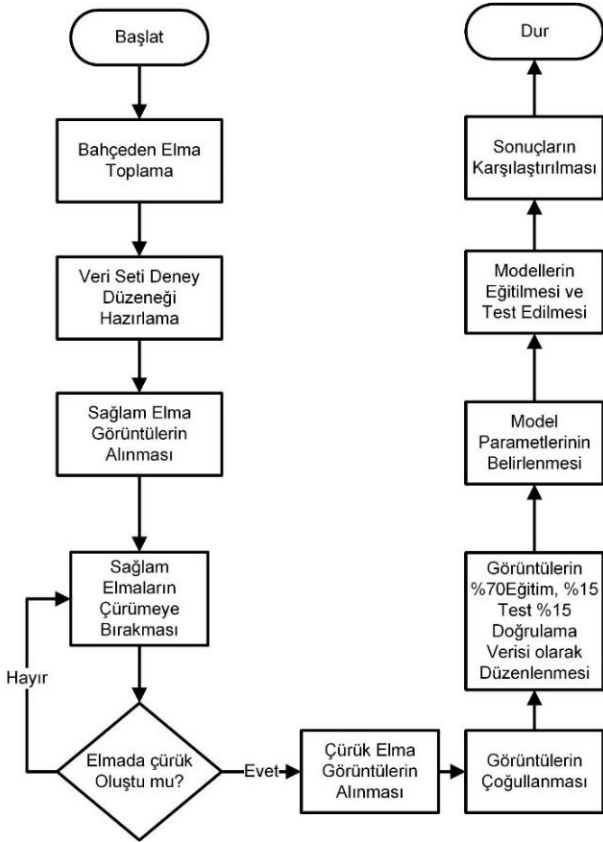
Evrişim ve havuzlama katmanları öznitelik çıkarma için kullanılırken, tam bağlantılı katmanları ise sınıflandırma için kullanılmaktadır. Giriş görüntülerini kademeli olarak daha düşük boyutlu özelliklere eşleme ve sonunda öznitelik vektörünü oluşturma işlemi, evrişim ve havuzlama

katmanlarında gerçekleşir. Tam bağlantılı katman ise özellik vektörünü kullanarak sınıflandırma yapar [62].

Evrişimli ağlar, görüntüleri yükseklik, genişlik ve derinlik olarak üç boyutlu hacim olarak algılar. Dijital renkli görüntüler Kırmızı-Yeşil-Mavi değerlerinden oluştuğundan nesnenin derinliği üç katman olarak kullanılır. Bu girdi görüntüsü, evrişim katmanını beslendikten sonra burada girdi görüntüsünden lineer evrişimli filtreler elde edilir. Daha sonra bu filtreler kullanılarak lineer olmayan Relu gibi aktivasyon fonksiyonları ile öznetelik vektörü elde edilir [61]. Şekil 4'te elma görüntüsü için 3. evrişim katmanının çıktısı örneği görülmektedir.



Şekil 4. Elma görüntüsü için 3. Evrişim katmanının çıktı örneği [63]



Şekil 5. Önerilen yöntem

Literatürdeki çalışmalar incelendiğinde sonuçları mümkün olduğunca iyileştirmek için evrişimsel filtrelerin

boyutlarını ve havuzlama türlerini değiştirerek çok çeşitli CNN modelleri önerilmiştir. CNN yapılarının yaygınlaşması, AlexNet mimarisinin, 2012'de ImageNet yarışmasını kazandıktan sonra olmuştur [64]. AlexNet'ten sonra son on yılda VGGNet [65], ResNet [66], Inception [67], Xception [68], ve Efficientnet [69] gibi yeni derin öğrenme mimarileri geliştirilmiştir. Görüldüğü gibi daha hassas sınıflandırma için daha büyük ve daha gelişmiş modeller her geçen gün önerilmeye devam edilmektedir. Bununla birlikte, eğitim verilerinin eksikliği bu tür modellerin boyutunu ve öğrenme yeteneğini sınırlayabilir, çünkü büyük modeller daha çok veriye ihtiyaç duymaktadır.

Bu çalışmada ESA yapılarının yaygınlaşmasında büyük etkisi olan AlexNet ve efektif eğitim özelliğine sahip InceptionNet V3 yapıları "Granny Smit" elma çeşidinde, hasat sırasında zarar görmüş elmaları tespit etme problemi için uygulanmış ve etkinlikleri karşılaştırılmıştır. Önerilen yöntem Şekil 5'te detaylı bir şekilde gösterilmiş olup; ilk aşamada veri setlerinin oluşturulması, devamında veri çoğullaması işlemleri yapılmaktadır. Yeterli sayıda veri elde edildikten sonra bu veriler %70 eğitim, %15 test ve %15 doğrulama olarak ayrılmıştır. Son aşamada ise AlexNet, VGG16 ve InceptionV3 evrişimli sinir ağı yapıları kullanılarak eğitim ve test sonuçları detaylı bir şekilde karşılaştırılmıştır.

2.3 Sınıflandırmada kullanılan başarı ölçütleri

Araştırmada fiziksel zararlanmalardan arı, sağlıklı elmalar negatif ve zarar görmüş elmalar pozitif olarak etiketlenmiştir. Sınıflandırıcının ürettiği sonuç, karışıklık matrisi bilinen bir yapıda temsil edilmektedir.

		Tahmin Edilen Sınıf	
		Pozitif Sınıf	Negatif Sınıf
Gerçek Sınıf	Pozitif Sınıf	a	b
	Negatif Sınıf	c	d

a: TP (True Pozitif) c: FP (False Pozitif)
 DP (Doğru Pozitif) YN (Yanlış Negatif)
 b: FN (False Negatif) d: TN (True Negatif)
 YP (Yanlış Pozitif) DN (Doğru Negatif)

Şekil 6. Karışıklık matrisi

Şekil 6'da verilen karışıklık matrisi dört kategoriye sahiptir [70]:

- Doğru pozitifler (DP), doğru olarak etiketlenmiş kusurlu elmalardır.
- Yanlış pozitifler (YP), hatalı olarak etiketlenmiş kusurlu elmalardır.
- Doğru negatifler (DN) doğru olarak etiketlenmiş sağlam elmalardır.
- Yanlış negatifler (YN) hatalı olarak etiketlenmiş sağlam elmalardır.

Model doğruluğu, modellerin performansını değerlendirmek için en yaygın kullanılan başarı ölçütüdür. Doğru sınıflandırılan kusurlu elmalarla doğru etiketlenmiş olanların toplamı ile edilen (DP + DN) örneklerin tüm örneklere oranı, doğruluk oranını hesaplamak için kullanılır. Hata oranı, yanlış sınıflandırılmış örnek sayısının (YP + YN), toplam örnek sayısına bölünmesiyle belirlenir. Doğruluk oranı ve hata oranı **Denklem (1)** ve **(2)** ifadesinde verilen formül yardımıyla hesaplanmıştır [71].

$$\text{Doğruluk Oranı} = \frac{DP + DN}{DP + DN + YP + YN} \quad (1)$$

$$\text{Hata Oranı} = \frac{YP + YN}{DP + DN + YP + YN} \quad (2)$$

Dengesiz veri kümesinin sınıflandırma başarısını değerlendirirken sadece doğruluk oranı yeterli ölçüt değildir. Bunun yanı sıra seçicilik, kesinlik, duyarlılık ve F-ölçütü değerlerinin de hesaplanması gerekmektedir [72]. Çalışmamızda 200 adet sağlıklı ve 200 hasarlı elma görüntüsü kullanılması dengeli sınıf olduğunu göstermektedir. Bu nedenle çalışmada başarı ölçütü olarak sadece doğruluk oranı ile hata oranı kullanılacaktır.

Modellerin eğitiminde kullanılmak üzere daha önce elde edilen 200 adet sağlam ve çürük elma görüntüleri görüntü çoğullama yöntemleri kullanılarak 500 adet sağlam ve 500 adet çürük elma görüntüsü elde edilmiştir. 500 adet sağlam elma görüntülerinin %70'i eğitim, %15'i doğrulama ve %15'i test için ayrılmış ve "sağlam" sınıf olarak etiketlenmiştir. Aynı şekilde 500 adet kusurlu elma görüntüsünden oluşan verileri de %70, %15, %15 oranları kullanarak bölünmüş ve "kusurlu" sınıf olarak etiketlenmiştir. Böylece her sınıfta eğitim veri seti 350, doğrulama 75 ve test ise 75 adet elma görüntüsünden oluşmuştur.

2 Bulgular ve tartışma

Deneysel çalışmalar Intel Core i7-7700HQ CPU, 16GB RAM, 2TB, 5,400-rpm HDD, 256GB SSD, Nvidia RTX

2060 özelliklere sahip bir bilgisayarda yapılmıştır. Çalışmada modellerin tasarımı için Python, TensorFlow ve Keras yazılım platformları kullanılmıştır. Uygulama yazılım geliştirme ortamı olarak Spyder kullanılmıştır.

Uygulamada kullanılacak CNN yapılarındaki optimum parametreleri belirlemek adına **Tablo 2**'deki gibi bir çalışma yapılmıştır. İlk önce uygun öğrenme katsayısını (initial learning rate) belirlemek adına öğrenme katsayısı 0.001'den başlamak üzere her seferinde 10 kat küçültülerek 0.0000001'e kadar küçültülmüştür. Tablodaki sonuçlara bakıldığında en optimum öğrenme katsayısının 0.000001 olduğu tespit edilmiştir.

Bir sonraki aşamada en optimum yığın boyutunu belirlemek adına; öğrenme katsayısı 0.000001 olmak üzere yığın boyutu 12, 32 ve 64 olarak seçilmiştir. **Tablo 2**'deki sonuçlara göre en optimum yığın boyutu 16 olarak hesaplanmıştır. Elde edilen bu iki parametre (öğrenme katsayısı = 0.000001, yığın boyutu = 16) InceptionV3 ve VGG16 eğitim aşamasında kullanılacaktır. Bu iki parametrenin kullanılması ile tüm modeller (AlexNet, InceptionV3 ve VGG16) bu parametreler ile 100 epoch eğitildiğinde elde edilen test doğruluğu sonuçları **Tablo 3**'teki gibidir. Yine **Tablo 3**'te elde edilen sonuçlara ait eğitim grafikleri ise **Şekil 7, 8 ve 9**'daki gibidir.

Modelin başarısı, değerlendirilirken öğrenme grafiğinin incelenmesi kullanılacak algoritmanın güvenilirliği açısından oldukça önemlidir. **Şekil 7**'de yeşil renk ile verilen doğrulama kayıp grafiği incelendiğinde 20. çevrime kadar azalma gösterirken, 30. çevrimden sonra yükselme olmuş ve 100. çevrim sonunda tekrar bir düşüş olmuştur.

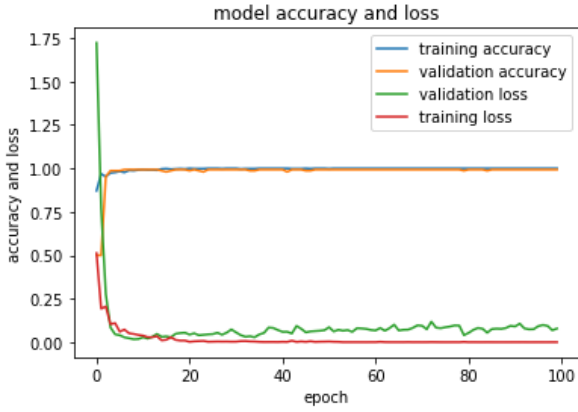
Şekil 8'de verilen InceptionV3 eğitim grafiğinde kırmızı renk ile gösterilen eğitim kaybı eğrisi 0.7 değeri ile başlayıp istikrarlı bir şekilde azalırken, mavi renk ile gösterilen eğitim doğruluğu, istikrarlı bir şekilde artmıştır. Grafikte turuncu ile gösterilen doğrulama kayıp eğrisinin ise ancak 20. çevrimde dengelendiği görülmüştür. Yine VGG16'ye ait eğitim grafikleri **Şekil 9**'daki gibidir.

Tablo 2. Optimum parametrelerin belirlenmesi


Deney No	Mimari	Öğrenme Katsayısı	Yığın Boyutu	Epochs	Test Kaybı	Test Doğruluğu
A	AlexNet	0.001	16	10	45.146	%56.67
1	AlexNet	0.0001	16	10	1.962	%86.67
2	AlexNet	0.00001	16	10	0.768	%86.67
3	AlexNet	0.000001	16	10	0.447	%90.00
4	AlexNet	0.0000001	16	10	0.814	%56.67
5	AlexNet	0.000001	32	10	0.598	%50.00
6	AlexNet	0.000001	64	10	0.644	%50.00

Tablo 3. Eğitim ve test sonuçları


Deney No	Mimari	Öğrenme Katsayısı	Yığın Boyutu	Epochs	Test Kaybı	Test Doğruluğu
1	InceptionV3	0.000001	16	100	0.053	%98.67
2	VGG16	0.000001	16	100	0.127	%97.34
3	AlexNet	0.000001	16	100	0.238	%98.00



Şekil 7. AlexNet eğitim ve kayıp eğrileri



Şekil 8. InceptionV3 eğitim ve kayıp eğrileri



Şekil 9. VGG eğitim ve kayıp eğrileri

Modellerin 100 çevrim sonunda oluşturduğu Karışıklık matrisleri, AlexNet için Şekil 10'de, InceptionV3 için Şekil 11'de ve VGG16 için Şekil 12'de verilmiştir.

		Tahmin Edilen Sınıf	
		Kusurlu	Sağlam
Gerçek Sınıf	Kusurlu	75	0
	Sağlam	3	72

Şekil 10. AlexNet karışıklık matrisi

		Tahmin Edilen Sınıf	
		Kusurlu	Sağlam
Gerçek Sınıf	Kusurlu	74	1
	Sağlam	1	74

Şekil 11. InceptionV3 karışıklık matrisi

		Tahmin Edilen Sınıf	
		Kusurlu	Sağlam
Gerçek Sınıf	Kusurlu	75	0
	Sağlam	4	71

Şekil 12. Vgg16 karışıklık matrisi

Şekil 10'da verilen karışıklık matrisinde görüldüğü gibi 100 çevrimin sonunda AlexNet modelinde kusurlu sınıftaki elmaların hepsi doğru olarak tespit edilmiştir. Bunun yanında, 3 adet sağlam sınıfta yer alması gereken elma kusurlu olarak tahmin edilmiştir. Şekil 11'de verilen karışıklık matrisinde görüldüğü gibi 100 çevrimin sonunda InceptionV3 modelinde her iki sınıfta 1'er adet yanlış sınıflandırma işlemi yapılmış ve en yüksek doğruluk InceptionV3 modelinde elde edilmiştir. VGG16 modeli

kusurlu elmaların hepsini doğru tahmin etmiş olup; sağlam elmalardan 4 tanesini yanlış tahmin etmiştir.

“Granny Smith” elma çeşidi sınıflandırma çalışmalarına bakıldığında literatürde yer alana sonuçlara göre daha başarılı sonuçlar elde edildiği görülmüştür. Lu ve Lu (2017) çalışmalarında, “Granny Smith” elma çeşidinde SIRI görüntüleme sistemi kullanarak elde edilen görüntüleri kullanmışlardır. Çalışmada görüntü işleme teknikleri kullanılarak doğal olarak zedelenmiş elmaları %90 doğrulukla sınıflandırılmıştır [37]. Fan ve arkadaşları (2022), “Granny Smith” elmada NIR görüntüleme sistemi kullanarak elde edilen görüntüler kullanmışlardır [43]. Çalışmada YOLO-V4 kullanılarak kusurlu elmalar %93.9 doğrulukla sınıflandırılmıştır [43].

Çalışmada elde edilen sonuçlar, RGB görüntüleri ile “Granny Smith” elma görüntülerini sınıflandırma, bu çalışmalarda üretilen sonuçlarla uyumlu olduğu görülmüştür. Fan ve diğerleri (2020), kendilerinin oluşturdukları ESA modelini kullanarak ‘Fuji’ elma çeşidinde kusurlu elmaları %96.5 doğruluk ile sınıflandırmıştır [24]. We ve diğerleri (2020), AlexNet modelini kullanarak ‘Aksu Fuji’ çeşidinde kusurlu elmaları %92.5 doğruluk ile sınıflandırmıştır [46]. Stasenko ve diğerleri (2021), U-Net, Deeplab, ve Mask R-CNN mimarilerini kullanarak kusurlu elmaları %98.81 doğruluk ile sınıflandırmıştır [48]. Xin ve diğerleri (2021), YOLOv3 mimarisini kullanarak kusurlu elmaları %97 doğruluk ile sınıflandırmıştır [49]. Xue ve diğerleri (2020), kusurlu elmaların tespiti için GoogLeNet modelini kullanmış ve elde edilen sonuçlara göre kesinlik oranı %91.91 olmuştur [50]. Ayaz ve diğerleri (2021), elma hastalığı sınıflandırması için ResNet, SqueezeNet ve MiniVGGNet gibi modeller kullanarak sınıflandırma yaptıklarında %99.99 genel doğruluk değerini elde etmişlerdir [51].

Sonuçlar

Bu çalışmada “Granny Smith” elma çeşidinden alınan görüntüler üzerinde derin öğrenme teknikleri kullanarak; özel koşul gerektirmeyen ve uygun maliyetle sınıflandırma ve kusur tespiti yapacak bir teknik araştırılmıştır. Böylesi bir tekniği geliştirmek için öncelikle el yordamıyla yapılmış bir deney düzeneği geliştirilmiştir. Geliştirilen deney düzeneğinin içine kamera ve aydınlatma uygun açılarda ve pozisyonlarda yerleştirildikten sonra kusurlu ve kusursuz elmalara ait görüntüler toplanmıştır. Elde edilen bu görüntülerden %70, %15 ve %15 oranlarında sırasıyla eğitim doğrulama ve test veri setleri elde edilmiştir. Elde edilen bu veri setleri ile literatürde yer alan AlexNet ve InceptionV3 yapıları eğitilmiş ve devamında da bu yapılar test edilmiştir. Çalışmada InceptionV3 modelinin 100 çevrim sonunda test doğruluğu %98.67, AlexNet modelinin ise test doğruluğu %98 ve VGG16 modelinin test doğruluğu %97.34 olarak elde edilmiştir. Çalışmada elde edilen sonuçlar, RGB görüntüleri ile “Granny Smith” elma çeşidi görüntülerini sınıflandırma çalışmalarında üretilen sonuçlara uygun olduğu görülmüştür. Literatürde “Granny Smith” elma çeşidi ile sınıflandırma çalışmalarına bakıldığında, bu çalışmada daha başarılı sonuçlar elde edildiği görülmüştür.

Bu çalışmadan elde edilen sonuçlar doğrultusunda, uygulamada hasattan hemen sonra kusurlu elmaların tespit edilip ayrılmasıyla, hasat sonrası oluşabilecek ekonomik kayıpların önüne geçilmesi sağlayabilecektir. Gelecek çalışmalarda elma kusurlarının nispeten daha zor görüldüğü elma çeşitleri seçilerek, kızıl ötesi kamera ile görüntü alınması hedeflenmektedir. Böylece elma rengine bağlı olmaksızın elma kusurlarının tespitinin yapılabileceği ve tüm elma çeşitlerinde kullanılabilmesi düşünülmektedir.

Teşekkür

Bu araştırma Niğde Ömer Halisdemir Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi Koordinatörlüğü’nce desteklenmiştir. Proje No: TGT 2021/22-BAGEP

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): % 12

Kaynaklar

- [1] FAOStat, <http://www.fao.org/faostat/en/#data/QC>, Accessed 13 June 2021.
- [2] M. Ünlü, Derim Sonrası Kayıplar, <https://arastirma.tarimorman.gov.tr/alata/Belgeler/Diger-belgeler/>, Accessed 1 January 2015.
- [3] A. E. Özdemir, E. Çandır, Ö. Dündar ve R. Dilbaz, Üreticiden tüketiciye ulaşıncaya kadar geçen süreçte elmalardaki kayıplar ve önleme yolları. *International Journal of Agricultural and Natural Sciences*, 2(1), pp. 165-168, 2009.
- [4] H. Özgönen ve H. Ç. Kılıç, Isparta ilinde elmalarda sorun olan hasat sonrası hastalıkların ve yaygınlık oranlarının belirlenmesi. *International Journal of Agricultural and Natural Sciences*, 2(2), pp. 53-60, 2009.
- [5] Z. Hu, Bruise detection in apples using 3D infrared imaging and machine learning technologies. Michigan Technological University, A Dissertation, Michigan, 2017. <http://dx.doi.org/10.37099/mtu.dc.etr/509>
- [6] F. Vega ve M. C. Torres, Automatic detection of bruises in fruit using Biospeckle techniques. In *Symposium of Signals, Images and Artificial Vision-2013: STSIVA-2013*, Bogotá, Colombia, 2013. <http://dx.doi.org/10.1109/STSIVA.2013.6644916>
- [7] Y. C. Chiy ve C. H. Chen, Development of on-line apple bruise detection system. *Engineering in agriculture, environment, and food*, 10(3), pp. 223-232, 2017. <http://dx.doi.org/10.1016/j.eaef.2017.03.003>
- [8] Y. Lu, R. Li ve R. Lu, Structured-illumination reflectance imaging (SIRI) for enhanced detection of fresh bruises in apples. *Postharvest Biology and Technology*, 117, pp. 89-93, 2016. <http://dx.doi.org/10.1016/j.postharvbio.2016.02.005>
- [9] J. Li, W. Huang, X. Tian, C. Wang, S. Fan ve C. Zhao, Fast detection and visualization of early decay in citrus using Vis-NIR hyperspectral imaging. *Computers and Electronics in Agriculture*, 127, pp. 582-592, 2016. <http://dx.doi.org/10.1016/j.compag.2016.07.016>

- [10] J. C. Keresztes, M. Goodarzi, W. Saeys, Real-time pixel based early apple bruise detection using short wave infrared hyperspectral imaging in combination with calibration and glare correction techniques. *Food Control*, 66, pp. 215-226, 2016. <http://dx.doi.org/10.1016/j.foodcont.2016.02.007>
- [11] W. Che, L. Sun, Q. Zhang, W. Tan, D. Ye, D. Zhang ve Y. Liu, Pixel based bruise region extraction of apple using Vis-NIR hyperspectral imaging. *Computers and Electronics in Agriculture*, 146., pp. 12-21, 2018. <http://dx.doi.org/10.1016/j.compag.2018.01.013>
- [12] E. Diels, M. van Dael, J. Keresztes, S. Vanmaercke, P. Verboven, B. Nicolai, W. Saeys, H. Ramona ve B. Smeets, Assessment of bruise volumes in apples using X-ray computed tomography. *Postharvest Biology and Technology*, 128, pp. 24-32, 2017. <http://dx.doi.org/10.1016/j.postharvbio.2017.01.013>
- [13] O. Doosti-Irani, M. R. Golzarian, M. H. Aghkhani, H. Sadriani ve M. Doosti-Irani, Development of multiple regression model to estimate the apple's bruise depth using thermal maps. *Postharvest Biology and Technology*, 116, pp. 75-79, 2016. <http://dx.doi.org/10.1016/j.postharvbio.2015.12.024>
- [14] D. Jawale ve M. Deshmukh, Real time automatic bruise detection in (Apple) fruits using thermal camera. In 2017 International Conference on Communication and Signal Processing (ICCSP), Tamilnadu, India, 2017. <http://dx.doi.org/10.1109/iccsp.2017.8286542>
- [15] Z. Du, X. Zeng, X. Li, X. Ding, J. Cao ve W. Jiang, Recent advances in imaging techniques for bruise detection in fruits and vegetables. *Trends in Food Science & Technology*, 99, pp. 133-141, 2020. <http://dx.doi.org/10.1016/j.tifs.2020.02.024>
- [16] J. Varith, G. M. Hyde, A. L. Baritelle, J. K. Fellman ve T. Sattabongkot, Non-contact bruise detection in apples by thermal imaging. *Innovative Food Science & Emerging Technologies*, 4(2), pp. 211-218, 2003. [http://dx.doi.org/10.1016/s1466-8564\(03\)00021-3](http://dx.doi.org/10.1016/s1466-8564(03)00021-3)
- [17] R. Lu, Detection of bruises on apples using near-infrared hyperspectral imaging. *Transactions of the American Society of Agricultural Engineers*, 46 (2), pp. 523-530, pp. 523-530, 2003. <http://dx.doi.org/10.13031/2013.12941>
- [18] G. ElMasry, N. Wang, C. Vigneault, J. Qiao and A. ElSayed, Early detection of apple bruises on different background colors using hyperspectral imaging. *LWT-Food Science and Technology*, 41(2), pp. 337-345, 2008. <http://dx.doi.org/10.1016/j.lwt.2007.02.022>
- [19] R. Lu, H. Cen, M. Huang ve D. P. Ariana, Spectral absorption and scattering properties of normal and bruised apple tissue. *Transactions of the ASABE*, 53(1), pp. 263-269, 2010. <http://dx.doi.org/10.13031/2013.29491>
- [20] W. Huang, J. Li, Q. Wang ve L. Chen, Development of a multispectral imaging system for online detection of bruises on apples. *Journal of Food Engineering*, 146, pp. 62-71, 2015. <http://dx.doi.org/10.1016/j.jfoodeng.2014.09.002>
- [21] W. Tan, L. Sun, F. Yang, W. Che, D. Ye, D. Zhang ve B. Zou, The feasibility of early detection and grading of apple bruises using hyperspectral imaging. *Journal of Chemometrics*, 32(10), p. e3067, 2018. <http://dx.doi.org/10.1002/cem.3067>
- [22] M. Zhang ve G. Li, Visual detection of apple bruises using AdaBoost algorithm and hyperspectral imaging. *International Journal of Food Properties*, 21(1), pp. 1598-1607, 2018. <http://dx.doi.org/10.1080/10942912.2018.1503299>
- [23] S. Zhang, X. Wu, S. Zhang, Q. Cheng ve Z. Tan, An effective method to inspect and classify the bruising degree of apples based on the optical properties. *Postharvest Biology and Technology*, 127, pp. 44-52, 2017. <http://dx.doi.org/10.1016/j.postharvbio.2016.12.008>
- [24] S. Fan, J. Li, Y. Zhang, X. Tian, Q. Wang, X. He, C. Zhang ve W. Huang, On line detection of defective apples using computer vision system combined with deep learning methods. *Journal of Food Engineering*, 286, p. 110102, 2020. <http://dx.doi.org/10.1016/j.jfoodeng.2020.110102>
- [25] J. Xing, V. Van Linden, M. Vanzebroeck ve J. De Baerdemaeker, Bruise detection on Jonagold apples by visible and near-infrared spectroscopy. *Food control*, 16(4), pp. 357-361, 2005. <http://dx.doi.org/10.1016/j.foodcont.2004.03.016>
- [26] K. Kayaalp ve S. Metlek, Classification of robust and rotten apples by deep learning algorithm. *Sakarya University Journal of Computer and Information Sciences*, 3(2), pp. 112-120, 2020. <http://dx.doi.org/10.35377/saucis.03.02.717452>
- [27] V. Leemans, H. Magein ve F. Destain, On-line fruit grading according to their external quality using machine vision. *Biosystem Engineering* vol. 83, no. 4, p. 397-404, 2002.
- [28] D. Unay ve B. Gosselin, Automatic defect segmentation of Jonagold apples on multi-spectral images: A comparative study. *Postharvest Biology and Technology*, 42(3), pp. 271-279, 2006. <http://dx.doi.org/10.1016/j.postharvbio.2006.06.010>
- [29] D. Unay, B. Gosselin, O. Kleynen, V. Leemans, M. F. Destain ve O. Debeir, Automatic grading of Bi-colored apples by multispectral machine vision. *Computers and electronics in agriculture*, 75(1), pp. 204-212, 2011. <http://dx.doi.org/10.1016/j.compag.2010.11.006>
- [30] X. Luo, T. Takahashi, K. Kyo ve S. Zhang, Wavelength selection in vis/NIR spectra for detection of bruises on apples by ROC analysis. *Journal of Food Engineering*, 109(3), pp. 457-466, 2012. <http://dx.doi.org/10.1016/j.jfoodeng.2011.10.035>
- [31] J. C. Keresztes, E. Diels, M. Goodarzi, N. Nguyen-Do-Trong, P. Goos, B. Nicolai ve W. Saeys, Glare based apple sorting and iterative algorithm for bruise region detection using shortwave infrared hyperspectral imaging. *Postharvest biology and technology*, 130, pp. 103-115, 2017. <http://dx.doi.org/10.1016/j.postharvbio.2017.04.005>

- [32] C. Ferrari, G. Foca, R. Calvini ve A. Ulrici, Fast exploration and classification of large hyperspectral image datasets for early bruise detection on apples. *Chemometrics and Intelligent Laboratory Systems*, 146, pp. 108-119, 2015. <http://dx.doi.org/10.1016/j.chemolab.2015.05.016>
- [33] Q. Zhu, J. Guan, M. Huang, R. Lu ve F. Mendoza, Predicting bruise susceptibility of Golden Delicious apples using hyperspectral scattering technique. *Postharvest Biology and Technology*, 114, pp. 86-94, 2016. <http://dx.doi.org/10.1016/j.postharvbio.2015.12.007>
- [34] Y. C. Chiu, X. L. Chou, T. E. Grift ve M. Chen, Automated detection of mechanically induced bruise areas in golden delicious apples using fluorescence imagery. *Transactions of the ASABE*, 58(2), pp. 215-225, 2015. <http://dx.doi.org/10.13031/trans.58.10578>
- [35] R. Li, Y. Lu ve R. Lu, Structured illumination reflectance imaging for enhanced detection of subsurface tissue bruising in apples. *Transactions of the ASABE*, 61(3), pp. 809-819, 2018. <http://dx.doi.org/10.13031/aim.20162460153>
- [36] Y. Lu, R. Li ve R. Lu, (2016a). Fast demodulation of pattern images by spiral phase transform in structured-illumination reflectance imaging for detection of bruises in apples. *Computers and Electronics in Agriculture*, 127, p. 652-658, 2016. <http://dx.doi.org/10.1016/j.compag.2016.07.012>
- [37] Y. Lu ve R. Lu, Using composite sinusoidal patterns in structured-illumination reflectance imaging (SIRI) for enhanced detection of apple bruise. *Journal of food engineering*, 199, pp. 54-64, 2017. <http://dx.doi.org/10.1016/j.jfoodeng.2016.12.008>
- [38] P. Baranowski, W. Mazurek, B. Witkowska-Walczak ve C. Sławiński, Detection of early apple bruises using pulsed-phase thermography. *Postharvest biology and technology*, 53(3), pp. 91-100, 2009. <http://dx.doi.org/10.1016/j.postharvbio.2009.04.006>
- [39] Y. Lu ve R. Lu, Histogram-based automatic thresholding for bruise detection of apples by structured-illumination reflectance imaging. *Biosystems Engineering*, 160, pp. 30-41, 2017. <http://dx.doi.org/10.1016/j.biosystemseng.2017.05.005>
- [40] A. Siedliska, P. Baranowski ve W. Mazurek, Classification models of bruise and cultivar detection on the basis of hyperspectral imaging data. *Computers and Electronics in Agriculture*, 106, pp. 66-74, 2014. <http://dx.doi.org/10.1016/j.compag.2014.05.012>
- [41] J. F. I. Nturambirwe, H. H. Nieuwoudt, W. J. Perold ve U. L. Opara, Detecting bruise damage and level of severity in apples using a contactless NIR spectrometer. *Applied Engineering in Agriculture*, 36(3), pp. 257-270, 2020. <http://dx.doi.org/10.13031/aea.13218>
- [42] J. F. Nturambirwe, E. A. Hussein, M. Vaccari, C. Thron, W. J. Perold ve U. L. Opara, Feature reduction for the classification of bruise damage to apple fruit using a contactless FT-NIR spectroscopy with machine learning. *Foods*, 12(1), p. 210, 2023. <http://dx.doi.org/10.3390/foods12010210>
- [43] S. Fan, X. Liang, W. Huang, V. J. Zhang, Q. Pang, X. He, L. Li ve C. Zhang, Real-time defects detection for apple sorting using NIR cameras with pruning-based YOLOV4 network. *Computers and Electronics in Agriculture*, 193, p. 106715, 2022. <http://dx.doi.org/10.1016/j.compag.2022.106715>
- [44] A. Beyaz, R. Ozturk ve U. Turker, Assessment of mechanical damage on apples with image analysis. *Food, Agriculture & Environment (JFAE)*, 8(3&4), pp. 476-480, 2010.
- [45] S. Albawi, T. A. Mohammed ve S. Al-Zawi, Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET), Antalya, Turkey, 2017. <http://dx.doi.org/10.1109/ICEngTechnol.2017.8308186>
- [46] A. Wu, J. Zhu ve T. Ren, Detection of apple defect using laser-induced light backscattering imaging and convolutional neural network. *Computers & Electrical Engineering*, 81, p. 106454, 2020. <http://dx.doi.org/10.1016/j.compeleceng.2019.106454>
- [47] A. Kumar, R. C. Joshi, M. K. Dutta, M. Jonak ve R. Burget, Fruit-CNN: An Efficient Deep learning-based fruit classification and quality assessment for precision agriculture. In 2021 13th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT), 2021. <http://dx.doi.org/10.1109/ICUMT54235.2021.9631643>
- [48] N. Stasenkov, M. Savinov, V. Burlutskiy, M. Pukalchik and A. Somov, Deep Learning for postharvest decay prediction in apples. In IECON 2021-47th Annual Conference of the IEEE Industrial Electronics Society, 2021. <http://dx.doi.org/10.1109/iecon48115.2021.9589498>
- [49] Y. Xin, S. Ma, Y. Wei, J. Hu, Z. Ding ve F. Wang, Detection of apple surface defect based on YOLOv3. In 2021 ASABE Annual International Virtual Meeting, 2021. <http://dx.doi.org/10.13031/aim.202100611>
- [50] Y. Xue, L. Wang, Y. Zhang and Q. Shen, Defect detection method of apples based on GoogLeNet Deep Transfer Learning. *Nongye Jixie Xuebao/Transactions of the Chinese Society of Agricultural Machinery*, 51(7), p. 30-35, 2020.
- [51] H. Ayaz, E. Rodríguez-Esparza and M. Ahmad, Classification of apple disease based on non-linear deep features. *Applied Sciences*, 11(14), p. 6422, 2021. <http://dx.doi.org/10.3390/app11146422>
- [52] N. D. Lewis, *Deep Learning made easy with R, USA: Auscov*, 2016.
- [53] I. Goodfellow, Y. Bengio ve A. Courville, *Deep Learning*, MIT Press, 2016.
- [54] S. S. Mousavi, M. Schukat ve E. Howley, (2016, September). Deep reinforcement learning: an overview. In *Proceedings of SAI Intelligent Systems Conference*, London, UK, 2016.

- [55] Y. Bengio, Learning deep architectures for AI. Foundations and trends® in Machine Learning, 2(1), 1-127. Boston: Now publishers inc., 2009.
- [56] A. Agrawal, Loss Functions and Optimization Algorithms, <https://medium.com/data-science-group-iitr/loss-functions-and-optimization-algorithms-demystified-bb92daff331c>, Accessed 9 September 2017
- [57] Y. B. Özçelik ve A. Altan, Diyabetik retinopati teşhisi için Fundus görüntülerinin derin öğrenme tabanlı sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi, (29), pp. 156-167, 2021. <http://dx.doi.org/10.31590/ejosat.1011806>
- [58] Z. Ünal, T. Kızıl Deniz Gürbüz, M. Özden ve H. Aktaş, Classification of red apple varieties with deep learning models. IV. International Turkic World Congress on Science and Engineering, Niğde, 2022.
- [59] O. Cömert, M. Hekim ve K. Adem, Faster R-CNN kullanarak elmalarda çürük tespiti. Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 11(1), pp. 335-341, 2019.
- [60] Y. LeCun , L. Bottou, Y. Bengio ve P. Haffner, Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), pp. 2278-2324, 1998. <http://dx.doi.org/10.1109/5.726791>
- [61] A. Kausar, M. Sharif, J. Park ve D. R. Shin, Pure-cnn: A framework for fruit images classification. In 2018 International Conference on Computational Science and Computational Intelligence (CSCI), 2018.
- [62] S. Lu, Z. Lu, S. Aok ve L. Graham, Lu, S., Lu, Z., Aok, S., Graham, L. 2018, November. Fruit classification based on six layer convolutional neural network. In 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP), 2018. <http://dx.doi.org/10.1109/icdsp.2018.8631562>
- [63] J. Naranjo-Torres, M. Mora, R. Hernández-García, R. J. Barrientos, C. Fredes ve A. Valenzuela, A review of convolutional neural network applied to fruit image processing. Applied Sciences, 10(10), p. 3443, 2020. <http://dx.doi.org/10.3390/app10103443>
- [64] A. Krizhevsky, I. Sutskever and G. E. Hinton, Imagenet classification with deep convolutional neural networks. Advances in neural information processing systems, 25, pp. 1097-1105., 2012. <http://dx.doi.org/10.1145/3065386>
- [65] K. Simonyan and A. Zisserman, Very deep convolutional networks for large-scale image recognition. In International Conference on Learning Representations (ICLR 2015), San Diego, 2014. <https://doi.org/10.48550/arXiv.1409.1556>
- [66] K. He, X. Zhang, S. Ren and J. Sun, Identity mappings in deep residual networks. In European conference on computer vision, Amsterdam, The Netherlands, 2016. http://dx.doi.org/10.1007/978-3-319-46493-0_38
- [67] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, Las Vegas, USA, 2016. <http://dx.doi.org/10.1109/cvpr.2016.308>
- [68] F. Chollet, Xception: Deep learning with depthwise separable convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, Honolulu, USA, 2017. <http://dx.doi.org/10.1109/cvpr.2017.195>
- [69] M. Tan ve Q. Le, Efficientnet: Rethinking model scaling for convolutional neural networks. In International conference on machine learning, 2019.
- [70] J. Davis ve M. Goadrich, The relationship between Precision-Recall and ROC curves. In Proceedings of the 23rd international conference on Machine learning., pp. 233-240, 2006. <http://dx.doi.org/10.1145/1143844.1143874>
- [71] N. Canbaz, Nesneye dayalı yazılımların tasarım kalitesini ölçmek için öğrenme tabanlı bir yöntem. İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, Bilgisayar ve Bilişim Fakültesi, Yüksek Lisans Tezi, İstanbul (Danışman: Doç. Feza Buzluca), 2015.
- [72] R. Halepmollası, Alt sekans profil haritaları kullanılarak protein katlanması tanıma. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul (Danışman: Yrd. Doç. Dr. Ömer Sinan Saraç), İstanbul, 2016

