

GAZİ

JOURNAL OF ENGINEERING SCIENCES

Quality Control Processes In Date Fruit With Artificial Intelligence

Bekir Aksoy^{a*} Mehmet Yücel^b Hamdi Sayın^c Nergiz Aydın^d Özge Ekrem^e

Submitted: 20.11.2023 Revised: 23.12.2023 Accepted: 23.12.2023 doi:10.30855/gmbd.0705S08

ABSTRACT

Keywords: Artificial Intelligence, Deep Learning, Agricultural Applications,

^{a*} Isparta University of Applied Sciences
Faculty of Technology Mechatronics
Engineering Department 32100 - Isparta
Türkiye
Orcid: 0000-0001-8052-9411
e mail: bekiraksoy@isparta.edu.tr

^b Isparta University of Applied Sciences
Faculty of Technology Mechatronics
Engineering Department 32100 - Isparta
Türkiye
Orcid: 0000-0002-4100-5831

^c Isparta University of Applied Sciences
Faculty of Technology Mechatronics
Engineering Department 32100 - Isparta
Türkiye
Orcid: 0000-0002-0826-8517

^d Isparta University of Applied Sciences
Faculty of Technology Mechatronics
Engineering Department 32100 - Isparta
Türkiye
Orcid: 0000-0002-3921-3295

^e Isparta University of Applied Sciences
Faculty of Technology Mechatronics
Engineering Department 32100 - Isparta
Türkiye
Orcid: 0000-0001-9142-405X

*Corresponding author:
bekiraksoy@isparta.edu.tr

Anahtar Kelimeler: Yapay Zeka, Derin Öğrenme, Tarım Uygulamaları

The physical properties of fruit and vegetable products play an important role in their quality classification. With the existing manual methods, disease, pesticide and quality status of agricultural products are checked during the control stages. Manual sorting and classification of products requires expertise and the process is time consuming and labor intensive. Today, with the developing technology, the processing and marketing of products can be realized in optimum time and efficiency with the software techniques used in the fields of agriculture and food. In this study, date palm fruit, which has an important share in the fruit and vegetable market, is considered. The use of image processing and artificial intelligence techniques in classifying the quality of date fruits makes the sales process more consistent and efficient. Within the scope of the study, four different artificial intelligence techniques were used with a uniquely prepared dataset. The dataset consists of three different classes: good, bad and medium quality dates. The dataset specially prepared for the study was trained with MobileNetV2, ResNetV2-50, DenseNet-201 and Inception-v3 deep learning models. Among the four models used in the study, MobileNetV2 model was determined as the most successful model with 95% accuracy rate.

Hurma Meyvesindeki Kalite Kontrol İşlemlerinin Yapay Zeka İle Tahminlenmesi

ÖZ

Meyve ve sebze ürünlerinin, kalite sınıflandırmasında sahip oldukları fiziksel özellikler önemli bir rol oynamaktadır. Mevcut manuel yöntemler ile tarım ürünlerinin kontrol aşamalarında; hastalık, pestisit ve kalite durumları kontrol edilmektedir. Manuel olarak ürünlerin ayrıştırılıp sınıflandırılması uzmanlık gerektirmekte olup işleyen süreç zaman alıcı ve büyük emek istemektedir. Günümüzde gelişen teknoloji birlikte, tarım ve gıda alanlarında kullanılan yazılım teknikleri ile ürünlerin işlenmesi ve pazara sürülmesi optimum zamanda ve verimlilikte gerçekleştirilebilmektedir. Gerçekleştirilen çalışmada, meyve ve sebze pazarında önemli bir payı olan hurma meyvesi ele alınmaktadır. Hurma meyvelerinin kalitelerinin sınıflandırılmasında görüntü işleme ve yapay zekâ tekniklerinin kullanılması, satış sürecinin daha tutarlı ve verimli hale gelmesini sağlamaktadır. Çalışma kapsamında özgün olarak hazırlanan veri seti ile dört farklı yapay zekâ tekniği kullanılmıştır. Veri seti, iyi, kötü ve orta kalite hurma olmak üzere üç farklı sınıftan oluşmaktadır. Çalışma için özel olarak hazırlanan veri seti MobileNetV2, ResNetV2-50, DenseNet-201 ve Inception-v3 derin öğrenme modelleri ile eğitilmiştir. Çalışmada kullanılan dört model içerisinde MobileNetV2 modeli %95 doğruluk oranı ile en başarılı model olarak belirlenmiştir.

1. Giriş (Introduction)

Hurma meyvesi, latince Phoenix dactylifera L. olarak geçen ve insanoğlu tarafından yetiştiriciliği yapıldığı tahmin edilen en eski tarım ürünlerinden birisidir. Yaklaşık 6000 yıldır gıda olarak tüketilmekte olan hurma, yetiştiği topraklarda yaşayan insanlar için ekonomik ve sosyal açıdan çok büyük bir önem taşımaktadır. Yaşam ağacı olarak da adlandırılan hurmanın tarımı 800.000 hektarlık bir alanda yapılmakta ve dünya üzerinde 2000'den fazla çeşidi bulunmaktadır [1]. Hurma özellikle Orta Doğu ülkelerinde ve Kuzey Afrika'da yetişebilen bir meyvedir [2]. Kurutulmuş ya da taze olarak tüketilmesinin yanı sıra hurma meyvesinden çeşitli gıda ürünleri de üretilmektedir. Hurma şurubu, hurma suyu konsantresi, pekmezi, sirkesi ve marmelatı gibi kullanım alanlarının yanında pasta sektöründe de katkı maddesi olarak kullanılmaktadır. Hurma üretiminde ortaya çıkan atıklardan ise kompost gübre üretimi yapılabilmektedir [3].

Tarımsal ürünlerin fiziksel özelliklerinin hasat aşamasında tespit edilmesi, sınıflandırma, nakliye, depolama, işleme ve paketleme sistemlerinin planlama ve tasarımında oldukça önemlidir [4]. Tarımsal çalışmalarda ele alınan temel konulardan birisi de hasat sonrası işleme, taşıma ve depolama sırasında hem niteliksel hem de niceliksel özelliklerde meydana gelen kayıplar göz önüne alındığında, meyve ve sebzelerin hasat sonrası en yüksek kalitede tüketiciye ulaştırılmasının en iyi şekilde nasıl gerçekleştirileceğidir [5]. Son yıllarda tüketiciler özellikle kendi sağlıkları konusunda son derece hassas olup, her zaman kaliteli ve taze organik ürünlere yönelmektedirler. Bu nedenle meyveleri kategorize etmek ve problemleri olanları satış amacıyla pazara göndermeden önce belirleyip elemek oldukça önemlidir [6]. Yıllardır taze veya işlenmiş meyve ve sebzelerin kalitesi, olgunluk, büyüklük, şekil, renk, kir ve hastalıkların varlığı gibi faktörlerin çoğu kalifiye personel tarafından görsel olarak incelenmiştir. Ancak günümüzde bunun yerini bilgisayarla görme ve görüntü analizine dayanan otomatik inceleme sistemleri almıştır [7]. Meyvelerin özelliklerine göre sınıflandırması sırasında el değmeden sınıflandırılması ihracatta verimi arttırmakta ve meyve kabuğunun daha steril olmasını sağlamaktadır. Bu problemi çözmek için modern tarımda teknolojiyi ve özellikle görüntü işleme tekniklerini kullanmak üreticiler için bir çözüm yöntemidir.

Fotoğraf makinesi ve kamera gibi cihazlardan toplanan sayısallaştırılmış görüntülerin bilgisayar yazılımları vasıtasıyla işlenmesi veya analiz edilmesi görüntü işleme olarak tanımlanmaktadır.[8] Karar destek sistemleri için bilgisayarla görme görevleri; dijital görüntüleri toplama, işleme, değerlendirme ve anlamlı sonuçlar çıkarma yöntemlerini içermektedir [9]. Görüntü işleme tekniklerini kullanarak kalite tespiti; görüntü elde etme, ön işleme, segmentasyon, özellik çıkarma ve sınıflandırma olmak üzere beş adımdan oluşmaktadır. Bu süreç, giriş görüntüsünün sonucunun, ön işlemlerine tabi tutularak, görüntüdeki nesne özelliklerini çıkarılıp ardından da tahminlerde bulunarak analiz edilmesine yardımcı olmaktadır [10]. Görüntülerden anlamlı sonuçlar çıkarmada özellikle derin öğrenme yöntemleri sıklıkla kullanılmaktadır. Derin öğrenme kavramı ile birlikte yapay zekâ tabanlı tarım uygulamalarının elde ettiği başarı oranları da hızlı bir şekilde artmaktadır [11].

Gerçekleştirilen çalışmada çalışmaya özgü olarak oluşturulan yüksek çözünürlükte 288 adet hurma meyvesi görüntülerini içeren veri seti MobileNet-V2, ResNetV2-50, DenseNet-201 ve Inception-v3 derin öğrenme yöntemleri kullanılarak eğitilmiştir. Eğitim sonucunda en başarılı derin öğrenme modeli çalışmada kullanılmıştır.

2. Literatür Araştırması (Literature Review)

Zhang vd.(2019) çalışmalarında, tasarladıkları 13 katmanlı bir Evrişimsel Sinir Ağı (ESA) modeli ile meyve kategorilerini belirlemeyi amaçlamışlardır. 3600 görüntü ve 18 sınıftan oluşan veri tabanının kullanıldığı çalışmada, eğitim ve test verilerinin %50 - %50 olarak belirlenmiş ve 30 eğitim döngüsü uygulanmıştır. Önerilen modelin genel doğruluk oranı % 94,94 olarak tespit edilmiştir [12].

Kayaalp vd. (2020) çalışmalarında, CAPA veri tabanından alınan elma görüntülerinden derin öğrenme algoritması kullanılarak elmaların çürük ve sağlam olarak sınıflandırılması amaçlamışlardır. Verilerin %80 eğitim ve %20 test olarak ikiye ayrıldığı modelde kullanılan sistemin eğitim ve test aşamaları için dört farklı dalga boyunda, 16 çeşit görüntü kombinasyonu kullanılmıştır. Test aşamasında yapılan ölçümlere göre çürük ve sağlam elmaların tespitinde modelin %91,25 başarı oranı elde etmişlerdir [13].

Büyükarıkan vd. (2020) çalışmalarında, 12 farklı renk sıcaklığıyla elde edilmiş 1000 görüntüden ve 29 sınıftan

oluşan meyve görüntülerini içeren ALOI-COL veri setindeki görüntüleri, ESA mimarilerinden AlexNet, VGG16 ve VGG19 kullanılarak sınıflandırılmışlardır. Veri setindeki görüntüler, görüntü işleme teknikleriyle zenginleştirilmiş ve her sınıftan 51 adet görüntü elde edilmiştir. 50 eğitim döngüsü sonucunda test verileri, VGG16 mimarisinde %100 doğrulukla sınıflandırılmışlardır [14].

Joseph vd. (2021) çalışmalarında, derin öğrenmede ESA kullanılarak meyve sınıflandırması için TensorFlow tabanlı olarak geliştirilen etkili bir model önermişlerdir. Çalışmada görüntüleri farklı kategorilerde sınıflandırabilen 131 farklı meyve ve sebze sınıfını içeren Fruits 360 veri kümesini kullanılmıştır. 50 eğitim döngüsü ile eğitilen model test aşamasında iken %94,35'lik bir doğruluk oranı elde etmişlerdir [15].

Kumari vd. (2022) çalışmalarında, mango meyvesinin sınıflandırılması için CNN ve bulanık sınıflandırıcının bir arada kullanıldığı hibrit bir model önermişlerdir. Çalışmada ilk olarak, görüntülerde segmentasyon gerçekleştirilerek meyvelerin kalitesine, daha sonra da yüzey kusurlarına ve olgunluk durumuna göre sınıflandırılmıştır. Olgunluk kriteri, hibrit bulanık sınıflandırıcı ve CNN kullanılarak olgun, kısmen olgun ve olgunlaşmamış olarak sınıflandırılmıştır. Farklı performans ölçümlerinin karşılaştırmalı analizi, önerilen modelin diğer geleneksel algoritmalara göre etkinliğini kanıtlamışlardır [16].

Kesler vd. (2023) çalışmalarında, muz meyvesinin yedi farklı olgunlaşma evresinin yapay zekâ ile tespiti sağlamışlardır. Muz meyvesinin yedi farklı olgunlaşma evresinden 700 fotoğraf kullanılarak bir veri seti oluşturmuşlardır. Bu veri seti ve AlexNet derin öğrenme mimarisi ile sınıflandırma işlemleri gerçekleştirilmiştir. Kullanılan yapay zekâ modeli ile %96,63 oranında doğru bir sınıflandırma gerçekleştirilmişlerdir [17].

Kahya ve Özdüven (2023) çalışmalarında, lahanaya ve brokoli sebzelerinin sınıflandırılması için derin öğrenme yöntemlerinden olan Inception-v3 görüntü tanıma ve sınıflandırma modeli kullanılmışlardır. 10 eğitim döngüsü ve 0,001 öğrenme hızı ile uygulanan Inception-v3 modelinin lahanaya ve brokolinin sebzelerinin sınıflandırılmasında %100 oranında başarılı olduğu gözlemlenmiştir [18].

Nasiri vd. (2019) yapmış oldukları çalışmada, sağlıklı hurma meyvelerini diğer kusurlu hurmalardan ayırmak için, VGG-16 mimarisine sahip bir ESA modeli kullanmışlardır. Önerilen model üzerindeki deneysel sonuçlar, ESA modelinin, hurma meyvesi görüntülerinin ayırt edilmesinde %96,98 genel sınıflandırma doğruluğu elde edildiğini göstermişlerdir [19].

Sattar vd. (2021) yapmış oldukları çalışmada, farklı türdeki hurmaları tanıtmak ve sınıflandırmak için kullanmış oldukları CNN modeli ile %82,67 doğruluk elde etmişlerdir. Bunun yanı sıra ele alınan farklı tip modeller için Inception-resnet-V2, Inception-v3 ve Mobilenet V1 modellerini kullanmışlardır. Bu üç model içerisinde Mobilenet-V1 modeli ile %82,67 en yüksek doğruluk oranı elde etmişlerdir [20].

Alaskar vd. (2021) çalışmalarında, e Ekhlâs, Nbut Sultan ve Shayshi olmak üzere üç ana hurma çeşidinin görüntülerini sınıflandırmak için geliştirilmiş bir otomatik sıralama sistemi sunmuşlardır. Bu amaçla farklı hurma çeşitlerini yüksek doğrulukla verimli bir şekilde öğrenmek ve ayırt etmek için ESA modeli kullanılmıştır. Model, her üç çeşitten 1055 adet resim içeren yaklaşık 3165 adet hurma meyvesi görüntüsü ile sıfırdan eğitilmiştir. Yapay Sinir Ağı (YSA) modeli üzerinde farklı gradyan iniş optimizasyon yöntemleri ile karşılaştırmalı bir analiz sunmuşlardır. En yüksek doğruluk oranı %100 ile CNN-Adam modelinden elde etmişlerdir. [21].

Albarrak vd. (2022) yapmış oldukları çalışmada, sekiz farklı hurma sınıfından oluşan bir veri seti oluşturmuşlardır. Çalışmada, MobileNet-V2 mimarisini temel alan bir model önerilmiştir ve önerilen modelin %99 doğruluk oranına ulaştığını ifade etmişlerdir. Önerilen model ayrıca AlexNet, VGG16, InceptionV3, ResNet ve MobileNetV2 gibi diğer mevcut modellerle de karşılaştırılmıştır. Sonuçlar, önerilen modelin doğruluk açısından diğer tüm modellerden daha iyi performans gösterdiğini belirlemişlerdir [22].


3. Materyal ve Metot (Material and Method)

3.1. Materyal (Material)

Çalışma kapsamında dört farklı derin öğrenme modeli üzerinden eğitimler gerçekleştirilmiştir. Kullanılan modeller literatür taramasına dayanarak yüksek doğruluk veren modellerden oluşmaktadır.

3.1.1 Veri seti (Data Set)

Veri seti 0,035 piksel boyutlarında 288 adet hurma meyvesinin hasara (yırtılma, bozulma, ezilme vb.) göre iyi, orta ve kötü olarak üç sınıfa ait görsellerden oluşmaktadır. Ayrıca veri seti üzerinde derin öğrenme mimarilerindeki doğruluk oranının arttırmak için veri artırımı işlemi ile görüntü sayısı 1152 çıkarılmıştır. Şekil 1'de çalışmada kullanılan veri setine ait örnek bir görsel verilmiştir.



Şekil 1. Veri setinden örnekler. a) kötü b) orta c) iyi (Examples from the data set. a) bad b) average c) good)

3.1.2 MobileNet Derin Öğrenme Modeli (MobileNet Deep Learning Model)

Bilgisayarlı görme, mobil ve gömülü sistem alanlarında ESA, nesne algılama ve tanımda önemli rol oynayan, basit ama etkili ve hesaplama açısından çok yoğun olmayan derin öğrenme modelidir. [23]. MobileNet derin öğrenme modelini diğer modellerden ayıran en büyük farklardan birisi transfer öğrenmeyi çalıştırmak veya uygulamak için çok az hesaplama gücüne sahip olmasıdır. MobileNet derin öğrenme modeli, derinlemesine ayrılabilir evrişimler kullanmaktadır. Ağlarda aynı derinliğe sahip düzenli evrişimlere sahip ağ ile karşılaştırıldığında parametre sayısını önemli ölçüde azaltmaktadır [24].

3.1.3 ResNetV2-50 Derin Öğrenme Modeli (ResNetV2-50 Deep Learning Model)

ResNet ağı, VGG-19 mimarisinden esas alınarak VGG ağlarından daha az filtreye ve daha düşük karmaşıklığa sahip 34 katmanlı düz bir ağ mimarisi olarak kullanılmaktadır. Daha sonrasında ise düz ağa atlama bağlantıları veya artık bloklar eklenerek mimari artık ağa dönüştürülmektedir. ResNet mimarileri çok daha derin ağlarda daha güçlü geçişler sağlamak için atlama bağlantılarını kullanmaktadır. Çalışmada kullanılan ResNetV2-50 modelinin 50 katmanı vardır [25].

3.1.4 DenseNet-201 Derin Öğrenme Modeli (DenseNet-201 Deep Learning Model)

DenseNet derin öğrenme mimarisi Huang vd. tarafından geliştirilen [26] ve özellikle CIFAR-100 ImageNet25 gibi veri kümelerinde nesne tanıma konusunda başarılı sonuçlar elde edilen bir derin öğrenme modelidir [27]. Bu mimari ile DenseNet, kaybolan gradyan problemini azaltmak, özellik yayılımını arttırmak ve yeniden kullanımına olanak sağlamak ve parametre sayısını önemli ölçüde azaltmak gibi birçok özellik DenseNet-201 derin öğrenme modelinin önemli özellikleri arasındadır [26].

3.1.5 Inception-v3 Derin Öğrenme Modeli (Inception-v3 Deep Learning Model)

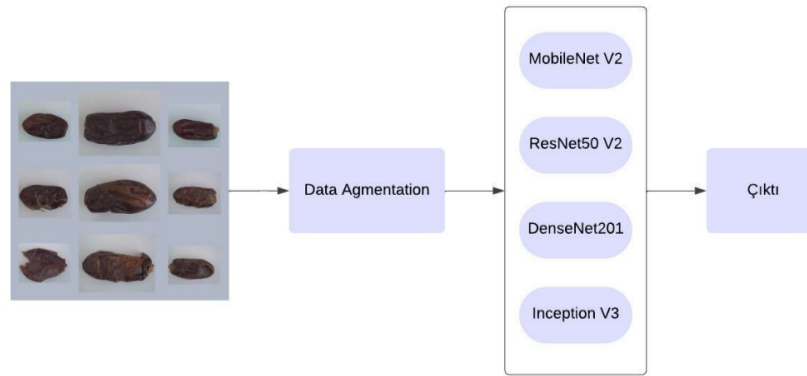
Inception-v3, yaygın olarak kullanılan bir ESA mimarisidir. Google tarafından oluşturulan Inception-v1 mimarisinin geliştirilmiş yeni bir versiyonudur. Inception-v3 mimarisi ilk olarak 2015 yılında kullanılmaya başlanmış olup 42 katmandan oluşmaktadır. Ayrıca önceki modellere göre daha düşük hata oranına sahiptir. Bu mimaride 3x3 evrişim katmanı kullanılmaktadır. Evrişim katmanını azaltmak hesaplama maliyetini de azaltmaktadır [28].

3.1.6 Veri artırma (Data augmentation)

Veri artırma, modelin başarımını arttırmak ve aşırı öğrenme problemine engel olmak amacıyla daha önceden var olmayan sentetik verilerin üretilmesi işlemidir. Bu amaçla girdi olarak verilen görüntüler; belirli açılarla döndürülme, yakınlaştırma, uzaklaştırma gibi işlemlere tabi tutularak var olan görüntünün farklı versiyonları üretilerek veri artırımı gerçekleştirilmektedir [29].

3.1. Metot (Method)


Çalışmanın iş akış diyagramını Şekil 2’de gösterilmiştir. Çalışmanın ilk aşamasında, 0,035 piksel boyutlarında 288 adet hurma meyvesine ait görsellere veri arttırma işlemi uygulanarak görüntü sayısı 1152 adet görüntüye çıkarılmıştır. Veri arttırımı gerçekleştirildikten sonra veriler sınıflara ayrılarak etiketlenmiştir. Etiketlenen veriler rastgele %80 (921 adet) eğitim ve %20 (231 adet) test görüntüsü olarak ayrılmıştır. Sonraki aşamada ise eğitim verileri MobileNetV2, ResNetV2-50, DenseNet-201, Inception-v3 öğrenme mimarileri ile 15 tekrarlı(epoch) eğitimle eğitilmiştir. Tüm modellerde Relu aktivasyon fonksiyonu kullanılmıştır. Eğitim esnasında her model için öğrenme oranı optimize edilerek en uygun öğrenme oranı belirlenmiştir. Eğitimler sonucunda elde edilen sonuçlar test verileri ile kıyaslanarak sınıflandırma için en doğru sonucu veren derin öğrenme modeli çalışmada kullanılmıştır.




Şekil 2. İş Akış Diyagramı (Workflow Diagram)

3. Araştırma Bulguları (Research Findings)

Yapılan çalışmada dört farklı derin öğrenme mimarisi hurma meyvesinin sınıflandırılmasında kullanılarak modeller arasındaki performanslar analiz edilmiştir. İlk olarak Inception-v3 modelinin eğitimindeki eğitim ve test verileri için Şekil 3 kayıp grafiği ve Şekil 4’de ise doğruluk grafikleri elde edilmiştir.




Şekil 3. Inception-v3 modeline ait kayıp grafiği (Loss graph for Inception-v3 model)



Şekil 4. Inception-v3 modeline ait doğruluk grafiği (Accuracy graph for Inception-v3 model)

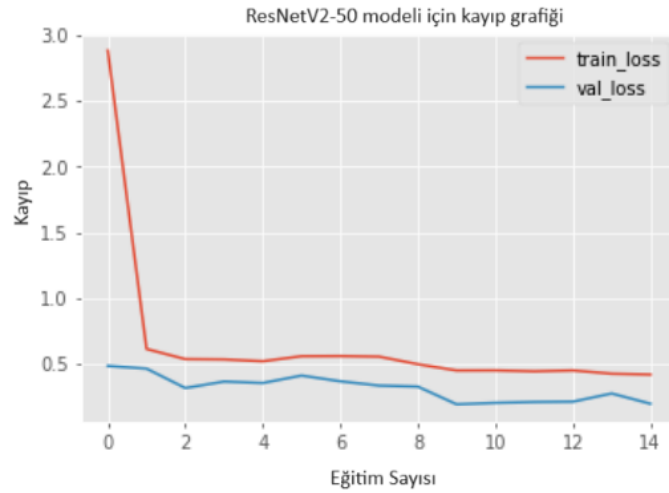
Şekil 3 ve Şekil 4 incelendiğinde Inception-v3 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrardan sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 5'te gösterilmiştir.




Şekil 5. Inception-v3 modeline ait karmaşıklık matrisi (complexity matrix for Inception-v3 model)

Karmaşıklık matrisi incelendiğinde Inception-v3 derin öğrenme modeli; kötü sınıfına ait 60 adet görüntüyü doğru sınıflandırmış, 7 adet görüntüyü ise orta sınıfı olarak yanlış sınıflandırdığı görülmektedir. İyi sınıfında ise görüntülerden 70 adetini doğru sınıflandırırken 10 adetini ise orta olarak yanlış sınıflandırmıştır. Orta sınıfında ise görüntülerden 83 adetini doğru sınıflandırırken 1 adetini ise iyi sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada ikinci olarak veri seti ResNetV2-50 modeli ile eğitim gerçekleştirilmiştir. Eğitimin esnasındaki eğitim ve test verileri için Şekil 6'da kayıp grafiği ve Şekil 7'de ise doğruluk grafikleri elde edilmiştir.




Şekil 6. ResNetV2-50 modeline ait kayıp grafiği (Loss graph for ResNetV2-50 model)



Şekil 7. ResNetV2-50 modeline ait doğruluk grafiği (Accuracy graph for ResNetV2-50 model)

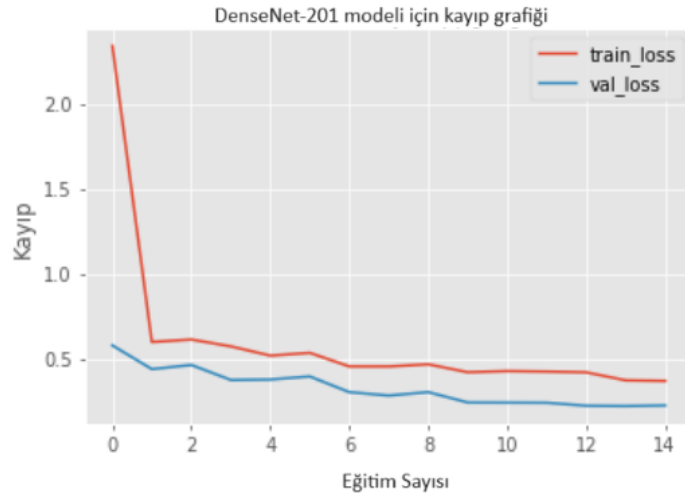
Şekil 3 ve Şekil 4 incelendiğinde ResNetV2-50 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrarından sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 8'te gösterilmiştir.




Şekil 8. ResNetV2-50 modeline ait karmaşıklık matrisi (Complexity matrix of the ResNetV2-50 model)

Karmaşıklık matrisi incelendiğinde ResNetV2-50 derin öğrenme modeli; kötü sınıfına ait 67 adet görüntüyü doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. İyi sınıfında ise görüntülerden 71 adetini doğru sınıflandırırken 9 adetini ise orta olarak yanlış sınıflandırmıştır. Orta sınıfında ise görüntülerden 77 adetini doğru sınıflandırırken 7 adetini ise iyi sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada üçüncü olarak veri seti DenseNet-201 modeli ile eğitim gerçekleştirilmiştir. Eğitimin esnasındaki eğitim ve test verileri için Şekil 9’da kayıp grafiği ve Şekil 10’de ise doğruluk grafikleri elde edilmiştir.




Şekil 9. DenseNet-201 modeline ait kayıp grafiği (Loss graph for the DenseNet-201 model)



Şekil 10. DenseNet-201 modeline ait doğruluk grafiği (Accuracy graph for the DenseNet-201 model)


Şekil 9 ve Şekil 10 incelendiğinde DenseNet-201 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrarından sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 11’de gösterilmiştir.




Şekil 11. DenseNet-201 modeline ait karmaşıklık matrisi (Complexity matrix of the DenseNet-201 model)

Karmaşıklık matrisi incelendiğinde DenseNet-201 derin öğrenme modeli; kötü sınıfına ait 67 adet görüntüyü doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. İyi sınıfında ise görüntülerden 79 adetini doğru sınıflandırırken 1 adetini ise orta olarak yanlış sınıflandırmıştır. Orta sınıfında ise görüntülerden 68 adetini doğru sınıflandırırken 16 adetini ise kötü sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada son olarak veri seti MobileNetV2 modeli ile eğitim gerçekleştirilmiştir. Eğitimin esnasındaki eğitim ve test verileri için Şekil 12’de kayıp grafiği ve Şekil 13’de ise doğruluk grafikleri elde edilmiştir.




Şekil 12. MobileNetV2 modeline ait kayıp grafiği (Loss graph for MobileNetV2 model)



Şekil 13. MobileNetV2 modeline ait doğruluk grafiği (Accuracy graph of the MobileNetV2 model)

Şekil 12 ve Şekil 13 incelendiğinde MobileNetV2 modelinin eğitimi esnasında hem kayıp hem de doğruluk değerinin 15 eğitim tekrarıdan sonra değişmediği için eğitim sayısı arttırılmamıştır. 15 eğitim sonucunda elde edilen sonuçlara ait karmaşıklık matrisi Şekil 14’te gösterilmiştir.



Şekil 15. MobileNetV2 modeline ait karmaşıklık matrisi (Complexity matrix of the MobileNetV2 model)

Karmaşıklık matrisi incelendiğinde MobileNetV2 derin öğrenme modeli; kötü sınıfına ait 67 adet görüntüyü doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. İyi sınıfında ise görüntülerden 80 adetini doğru sınıflandırmış olup hiç yanlış sınıflandırma yapılmadığı tespit edilmiştir. Orta sınıfında ise görüntülerden 74 adetini doğru sınıflandırırken 9 adedini kötü sınıf ve 1 adet görüntüyü de iyi sınıfı olarak yanlış sınıflandırmıştır.

Çalışmada kullanılan Inception-v3, ResNetV2-50, DenseNet-201 ve MobileNetV2 modelleri ile yapılan eğitimler sonucunda elde edilen Accuracy, Precision, Recall ve F1-Score performans değerlendirme metriklerine ait sonuçlar Tablo 1’de verilmiştir.

Tablo 1. Çalışmada kullanılan derin öğrenme modellerine ait performans değerlendirme sonuçları
(Performance evaluation results of the deep learning models used in the study)

Model İsmi	Accuracy	Precision	Recall	F1-Score
<i>Inception-v3</i>	0,92	0,93	0,91	0,92
<i>ResNetV2-50</i>	0,93	0,93	0,93	0,93
<i>DenseNet-201</i>	0,92	0,93	0,93	0,92
<i>MobileNetV2</i>	0,95	0,95	0,96	0,95

Tablo 1 incelendiğinde çalışma kullanılan dört farklı derin öğrenme modelinde doğruluk oranlarının %90’nın üzerinde olduğu görülmektedir. Bu durum veri seti ile çalışmada kullanılan derin öğrenme modellerinin uyumlu olduğunu göstermektedir. Çalışmada kullanılan dört farklı derin öğrenme modeli içerisinde Accuracy performans değerlendirme kriterine göre MobileNetV2 modelinin %95 doğruluk değerine göre en başarılı model olduğu tespit edilmiştir.

4. Sonuçlar (Conclusions)

Yapay zekâ uygulamaları günümüzde tarım sektörüne katkılarında dolayı sıklıkla kullanılan bir yöntem olmuştur. Yapay zekâ uygulamaları ile meyvelerde kusurların tespit edilmesi ve bu sayede doğru bir kalite kontrol süreci sürdürmek oldukça önemlidir.

Çalışmada özgün veri setindeki iyi, orta ve kötü sınıf olmak üzere üç sınıftan hurma meyvesine ait görüntüler MobileNetV2, ResNetV2-50, DenseNet-201, Inception-v3 derin öğrenme mimarileri ile eğitilmiştir. Modellerin başarıları, öğrenme oranı-kayıp grafiği ve karmaşıklık matrisi çizdirilerek sonuçlar değerlendirilmiştir. Her bir modelde %90’ın üzerinde doğruluk elde edilmesi veri setinin çalışmada kullanılan derin öğrenme modelleri ile uyumlu ve başarılı sonuçların elde edildiğini göstermektedir. Rastgele alınan test veri setinden model çıktıları incelendiğinde iyi ve kötü sınıfa ait doğruluk oranları çok yüksek çıkmaktadır. Ancak orta kalite sınıfta tüm modeller yanlış sınıflandırmalar gerçekleştirmektedir. Bunun nedeni orta kalite

sınıfa ait verilerde iyi ya da kötü sınıfa ait görüntülere çok yakın benzerlikte görüntülerin bulunmasıdır. Tüm mimarilerin geneline bakıldığında toplamda 61 adet yanlış etiketleme yapılmıştır.

Gerçekleştirilen çalışma ile hurma meyvesinde kalite kontrol sürecinin hızlı ve etkili bir şekilde gerçekleştirilmesine yönelik derin öğrenme tabanlı modeller sunulmuştur. Sunulan modeller ile meyvelerin sınıflandırması için akademik literatüre katkı sağlaması amaçlanmıştır. İlerideki çalışmalarda veri setinin genişletilip farklı yapay zekâ modelleri kullanılarak doğruluk oranlarının artırılması ve gerçek zamanlı bir biçimde ayrıtılabilecek bir sisteme entegre edilebileceği düşünülebilmektedir.

Teşekkür (Acknowledgment)

Çalışma 5. Uluslararası Mühendislikte Yapay Zeka ve Uygulamalı Matematik Konferansı'nda özet metin olarak sunulmuştur.

Çıkar Çatışması Beyanı (Conflict of Interest Statement)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

Kaynaklar (References)

- [1] W. M. Amer, "Taxonomic and documentary study of food plants in ancient egypt," Ph.D. Thesis, Cairo University, Giza, 1994.
- [2] M. Al-Farsi, C. Alasvar, A. Morris, M. Baron, and F. Shahidi, "Comparison of antioxidant activity, anthocyanins, carotenoids, and phenolics of three native fresh and sun-dried date (*Phoenix dactylifera* L.) varieties grown in Oman," *Journal of Agricultural and Food Chemistry*, vol. 53, pp. 7586–7599, August 2005. doi: 10.1021/jf050579q
- [3] E. Yıldız and M. Kaplankıran, "Hatay ili Trabzon hurması seleksiyonunda belirlenen tiplerin özellikleri," V. Ulusal Bahçe Bitkileri Kongresi, 4-7 Eylül, 2007, Erzurum, Turkey, pp. 266-270.
- [4] T. Saraçoğlu, "Bazı narenciye türlerinin seçilmiş fiziksel ve hidrodinamik özellikleri," *Anadolu Tarım Bilimleri Dergisi*. vol. 32, pp. 206-215. Haziran 2017. doi: 10.7161/omuanajas.303881
- [5] M.T. Masarirambi, V. Mavuso, V.D. Songwe, T.P. Nkambule and N. Mhazo, "Indigenous postharvest handling and processing of traditional vegetables in Swaziland: A review," *African Journal of Agricultural Research*, vol. 5, no. 24, pp.3333-3341, 2010
- [6] K.G. Liakos, P. Busato, D. Moshou, S. Pearson and D. Bochtis, "Machine learning in agriculture: a review," *Sensors*, vol. 18, no.8 pp. 2674, August 2018. doi: 10.3390/s18082674
- [7] E. Saldana, R. Siche, M. Luján and R. Quevedo, "Computer vision applied to the inspection and quality control of fruits and vegetables," *Brazilian Journal of Food Technology*, vol. 16, no. 4, pp. 254–272, December 2013. doi: 10.1590/S1981-67232013005000031
- [8] H. Armagan, "Color based segmentation with k-means clustering algorithm and numerical analysis of the effect of color spaces on image quantities," *El-Cezeri*, vol. 9, no. 4, pp.1506-1517, December 2022. doi: 10.31202/ecjse.11411 48
- [9] S. Adige, R. Kurban, A. Durmuş and E. Karaköse, "Görüntü işleme tekniklerinden faydalanarak elma çeşitlerinin türlerine göre sınıflandırılması," *Avrupa Bilim ve Teknoloji Dergisi*, no. 37, pp. 131-138, Temmuz 2022. doi: 10.31590/ejosat.1136913
- [10] M. Dhakate, "BIA diagnosis of pomegranate plant diseases using neural networks," In: Proceedings of the 5th National Conference on computer vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG), 16-19 December, 2015, Patna, India [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/abstract/document/7490056>. [Accessed: 09 July. 2023].
- [11] E. Güneş, "Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması," Ph.D. Thesis, Marmara Univ., İstanbul, Türkiye, 2022.
- [12] Y. D. Zhang, Z. Dong, X. Chen, W. Jia, S. Du, K. Muhammad and S. H. Wang, "Image based fruit category classification by 13-layer deep convolutional neural network and data augmentation," *Multimedia Tools and Applications*, vol. 78, pp. 3613-3632. September 2019. doi: 10.1007/s11042-017-5243-3
- [13] K. Kayaalp, and S. Metlek, "Classification of robust and rotten apples by deep learning algorithm," *Sakarya University Journal of Computer and Information Sciences*, vol. 3, no. 2, pp.112-120, August 2020. doi: 10.35377/saucis.03.02.717452
- [14] B. Büyükarıkan and E. Ülker, "Aydınlatma özneliği kullanılarak evrişimsel sinir ağı modelleri ile meyve sınıflandırma," *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, vol. 25 no. 1, pp. 81-100. April 2020. doi: 10.17482/uumfd.628166
- [15] J. L. Joseph, V.A. Kumar and S.P. Mathew, "Fruit classification using deep learning," *In Innovations in Electrical and Electronic Engineering: Proceedings of ICEEE 2021*, vol. 756, pp. 807-817, May 2021. doi: 10.1007/978-981-16-0749-3_62
- [16] N. Kumari, R.K. Dwivedi, A.K. Bhatt, and R. Belwal, "Automated fruit grading using optimal feature selection and hybrid

classification by self-adaptive chicken swarm optimization: grading of mango,” *Neural computing and applications*, vol. 34, pp. 1-22, 2022. doi: 10.1007/s00521-021-06473-x

[17] S. Kesler, A. Karakan, and O. Yüksel, “Alexnet mimarisi ile muz olgunlaşma evrelerinin sınıflandırılması,” *Avrupa Bilim ve Teknoloji Dergisi*, no. 51, pp. 135-141, Ağustos 2023. doi: 10.31590/ejosat.1252946

[18] E. Kahya and F. F. Özdüven, “Robotik hasat sistemlerinde kullanılmak amacıyla lahana ve brokolinin derin öğrenme metodu ile sınıflandırılması,” *Turkish Journal of Agriculture-Food Science and Technology*, vol. 11 no. 9, pp. 1639-1647, 2023. doi: 10.24925/turjaf.v11i9.1639-1647.6177

[19] A. Nasiri, A. Taheri-Garavand, and Y. D. Zhang, “Image-based deep learning automated sorting of date fruit,” *Postharvest biology and technology*, vol. 153, pp. 133-141, July 2019. doi: 10.1016/j.postharvbio.2019.04.003

[20] M. S. Hasan and A. Sattar, “Arabian date classification using CNN algorithm with various pre-trained models” *In 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), 04-06 February 2021, Tirunelveli, India* [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/abstract/document/9388413>. [Accessed: 09 July. 2023].

[21] H. Alaskar, S. Alhewaidi, B. Obaid, G. Alzahrani, A. Abdulahi, Z. Sbai, and T. Vaiyapuri, “Dates fruit classification using convolution neural networks,” *In Proceedings of Sixth International Congress on Information and Communication Technology: ICICT 2021, Vol. 3, pp. 757-775, 2022*. doi: 10.1007/978-981-16-1781-2_66

[22] K. Albarrak, Y. Gulzar, Y. Hamid, A. Mehmood, and A. B. Soomro, “A deep learning-based model for date fruit classification,” *Sustainability*, vol. 14, no. 10, pp. 6339. 2022. doi: 10.3390/su14106339

[23] S. Pa, “An overview on mobilenet: an efficient mobile vision CNN,” *medium.com*, Jun. 10, 2020. [Online] Available: <https://medium.com/@godeep48/an-overview-on-mobilenet-an-efficient-mobile-vision-cnn-f301141db94d>

[24] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, “Mobilenets: Efficient convolutional neural networks for mobile vision applications,” *arxiv.org*, 17 Apr 2017. [Online]. Available: <https://arxiv.org/abs/1704.04861> [Accessed: Dec. 26, 2023].

[25] S. Akdağ, “Resnet (residual network) nedir?” *medium.com*, Aug. 9, 2021, [Online]. Available: <https://suhedacilek.medium.com/resnet-residual-network-nedir-49105e642566>

[26] G. Huang, Z. Liu, L.V.D. Maaten and K. Q. Weinberger, “Densely connected convolutional networks,” *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 21-26 July 2017, Honolulu, HI, USA* [Online]. Available: IEEE Xplore, <https://ieeexplore.ieee.org/document/8099726>. [Accessed: 09 July. 2023].

[27] X. Yu, N. Zeng, S. Liu, and Y. D. Zhang, “Utilization of denseNet201 for diagnosis of breast abnormality,” *Machine Vision and Applications*, vol. 30, pp. 1135–1144, July 2019. doi: 10.1007/s00138-019-01042-8

[28] A. Sevinç and F. Özyurt, “Beton yüzey çatlaklarının tespitinde derin öğrenme mimarilerinin kullanılması,” *Uluslararası Yenilikçi Mühendislik Uygulamaları Dergisi*, vol. 6 no.2, pp. 318-325, 2022. doi: 10.46460/ijiea.1098046

[29] A.H. Hasan, E. İbra, E. Civil, and M. Cicioğlu, “İnsansız hava araçlarında nesne tespiti ve takibi,” *7. Geleceğin Mühendisleri Uluslararası Öğrenci Sempozyumu, 22-23 June 2023, Zonguldak, Turkey* [Online]. Available: [researchgate.net, https://www.researchgate.net/publication/373549374_Object_Detection_and_Tracking_in_Unmanned_Aerial_Vehicles](https://www.researchgate.net/publication/373549374_Object_Detection_and_Tracking_in_Unmanned_Aerial_Vehicles). [Accessed: 09 July 2023].

* This paper was presented at the 5th International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAAME 2023) and the abstract was published as an e-book.

This is an open access article under the CC-BY license

