



**DERİN ÖĞRENME YÖNTEMLERİ İLE  
MEYVELERİN TAZELİK DURUMUNUN  
BELİRLENMESİ**

**Ayşin BULUŞ**

**Yüksek Lisans Tezi**

**Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Doç. Dr. Erdinç UZUN  
2022**

T.C.

TEKİRDAĞ NAMIK KEMAL ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**DERİN ÖĞRENME YÖNTEMLERİ İLE MEYVELERİN TAZELİK  
DURUMUNUN BELİRLENMESİ**

Ayşin BULUŞ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: Doç. Dr. Erdiñ UZUN

TEKİRDAĞ-2022

Her hakkı saklıdır.

## ÖZET

Yüksek Lisans

### DERİN ÖĞRENME YÖNTEMLERİ İLE MEYVELERİN TAZELİK DURUMUNUN BELİRLENMESİ

**Ayşin BULUŞ**

Tekirdağ Namık Kemal Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Erdinç UZUN

Bilindiği üzere günümüzde derin öğrenme teknolojisi yüz tanıma, ses tanıma, güvenlik sektörü, savunma sanayi gibi pek çok alanda kullanılmaktadır. Pek çok katmanlardan oluşan derin öğrenme, makine öğrenmesinin bir dalıdır. Derin öğrenme ile modele bir veri kümesi vererek çıktıların tahmin edilmesi sağlanabilir. Günümüzde meyve tazeliği önemli sağlık, çevre ve ekonomik sorunlardan biridir. Bu çalışmada seçilen üç meyve; elma, portakal ve muz üzerinde çalışmalar yapılmıştır. Çalışmada iki tane VGG16 temel alınarak model geliştirilmiş ve iki tane VGG19 temel alınarak model geliştirilmiştir. Bu geliştirilen modeller, elde bulunan üç meyve türünün veri setleri üzerinde test edilerek en iyi sonucu hangisinden alınabileceği saptanmış ve modeller birbiri ile kıyaslanmıştır.

**Anahtar kelimeler:** Derin öğrenme, yapay zekâ, görüntü işleme, meyve tazeliği, VGG16, VGG19

2022, 42 sayfa

## **ABSTRACT**

MSc. Thesis

**DETERMINING THE FRESHNESS OF FRUITS WITH DEEP LEARNING METHODS**

**Ayşin BULUŞ**

Tekirdağ Namık Kemal University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

Supervisor: Assoc. Prof. Dr. Erdinç UZUN

As it is known, deep learning technology is used in many areas such as face recognition, voice recognition, the security sector, defense industry. Deep learning, which consists of many layers, is a branch of machine learning. With deep learning, it is possible to predict the outputs by giving a dataset to the model. Today, fruit freshness is one of the important health, environmental and economic problems. Three fruits were selected in this study; Studies have been done on apples, oranges, and bananas. In the study, two models were developed based on VGG16 and two models were developed based on VGG19. These developed models were tested on the data sets of the three fruit types at hand, and it was determined which one could get the best results, and the models were compared with each other.

**Key words:** Deep learning, artificial intelligence, image processing, fruit freshness, VGG16, VGG19

**2022, 42 pages**

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>İÇİNDEKİLER</b> .....	<b>iii</b>
<b>ÇİZELGE DİZİNİ</b> .....	<b>iv</b>
<b>ŞEKİL DİZİNİ</b> .....	<b>v</b>
<b>SİMGELER ve KISALTMALAR</b> .....	<b>vi</b>
<b>TEŞEKKÜR</b> .....	<b>vii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Bilgisayarlı Görü .....	1
1.2. Meyve Tazeliği ve Etkileri .....	2
1.3. Motivasyon ve Tezin Organizasyonu .....	4
<b>2. LİTERATÜR ARAŞTIRMASI</b> .....	<b>6</b>
<b>3. KULLANILAN YÖNTEMLER</b> .....	<b>11</b>
3.1. Kullanılan Kütüphaneler.....	13
3.2. Kullanılan Modeller.....	14
3.2.1. Gelişmiş VGG16 – Model 1 .....	17
3.2.2. Gelişmiş VGG19 – Model 2 .....	19
3.2.3. Gelişmiş VGG16 – Model 3 .....	20
3.2.4. Gelişmiş VGG19 – Model 4 .....	21
<b>4. DENEYLER</b> .....	<b>23</b>
4.1. Kullanılan Veri Seti .....	23
4.2. Performans Metrikleri.....	25
4.3. Deneyler.....	28
4.3.1. Gelişmiş VGG16 – Model 1 için Sonuçlar.....	28
4.3.2. Gelişmiş VGG19 – Model 2 için Sonuçlar.....	30
4.3.3. Gelişmiş VGG16 – Model 3 için Sonuçlar.....	32
4.3.4. Gelişmiş VGG19 – Model 4 için Sonuçlar.....	34
4.3.5. Tartışma .....	35
<b>5. SONUÇLAR</b> .....	<b>37</b>
<b>KAYNAKLAR</b> .....	<b>38</b>
<b>ÖZGEÇMİŞ</b> .....	<b>42</b>

## ÇİZELGE DİZİNİ

Çizelge 4.1 Sistemimizin Karmaşıklık Matrisi.....	27
Çizelge 4.2 Model 1 için karmaşıklık matrisi .....	29
Çizelge 4.3 Model 1 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk .....	30
Çizelge 4.4 Model 2 için karmaşıklık matrisi .....	31
Çizelge 4.5 Model 2 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk .....	32
Çizelge 4.6 Model 3 için karmaşıklık matrisi .....	33
Çizelge 4.7 Model 3 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk .....	33
Çizelge 4.8 Model 4 için karmaşıklık matrisi .....	34
Çizelge 4.9 Model 4 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk .....	35



## ŞEKİL DİZİNİ

Şekil 1.1 Zehirlenmeye Yol Açan Nedenlerin Dağılımı (%) .....	3
Şekil 1.2 Nedenlerine göre zehirlenme olgularının dağılımı.....	4
Şekil 3.1 Derin Öğrenme Ağı için Örnek .....	12
Şekil 3.2 VGG16 isimli modelin katmanları .....	14
Şekil 3.3 VGG16 modelinin (227,227,3) giriş şekli ile katmanlarının gösterimi .....	15
Şekil 3.4 VGG16 modelinin (224,224,3) giriş şekli ile katmanlarının gösterimi .....	16
Şekil 3.5 VGG16 ve VGG19 modelinin katmanlarının görselleştirilmesi.....	17
Şekil 3.6 Model-1 Gelişmiş VGG16 .....	17
Şekil 3.7 Model 1 kodundan bir parça.....	18
Şekil 3.8 Model-1 için test ve eğitim kayıplarının grafiksel gösterimi .....	18
Şekil 3.9 Model-2 katmanlarının gösterimi .....	19
Şekil 3.10 Model-2 için eğitim ve test kayıplarının epoch sayılarına göre gösterimi .....	19
Şekil 3.11 Model-3 katmanlarının gösterimi .....	20
Şekil 3.12 3. Modelin compile kısmı için koddan bir parça.....	20
Şekil 3.13 Model-3 için eğitim ve test kayıplarının epoch sayılarına göre gösterimi .....	21
Şekil 3.14 Model-4 katmanlarının gösterimi .....	21
Şekil 3.15 Model-4 için eğitim ve test kayıplarının epoch sayılarına göre gösterimi .....	22
Şekil 4.1 Veri setinin bölünme yüzdeleri .....	23
Şekil 4.2 Taze elma veri seti örneği .....	24
Şekil 4.3 Bayat elma veri seti örneği.....	25
Şekil 4.4 Karmaşıklık Matrisi.....	26

## SİMGELER VE KISALTMALAR

nm	: Nanometre
ABD	: Amerika Birleşik Devletleri
USDA	: ABD Tarım Bakanlığı
HSI	: Hyperspektral Görüntüleme Tekniği
SAEs	: Yığılanmış Otomatik Kodlayıcılar
LR	: Lojistik Regresyon
RGB	: Red-Green-Blue
ReLU	: Düzeltilmiş Doğrusal Birim Katmanı
VGG	: Visual Geometry Group
CMOS	: Tamamlayıcı Metal Oksit Yarı İletken
API	: Application Programming Interface - Uygulama Programlama Arayüzü
MSE	: Ortalama Kare Hatası Metodu
CPU	: Central Processing Unit – Merkezi İşlem Birimi
GPU	: Graphics Processing Unit – Grafik İşlemci Birimi
CNN	: Convolutional Neural Network - Evrimsel Sinir Ağları
RNN	: Recurrent Neural Network - Özyinelemeli Sinir Ağı
TPU	: Tensor Processing Unit – Tensor İşleme Birimleri
NN	: Neural Network – Sinir Ağı
DNN	: Deep Neural Network – Derin Sinir Ağı
TP	: True Positive (Gerçek Pozitif)
FP	: False Positive (Yanlış Pozitif)
TN	: True Negative (Gerçek Negatif)
FN	: False Negative (Yanlış Negatif)
GAN	: Generative Adversarial Network
LDC	: Az gelişmiş Ülkeler



## TEŐEKKÜR

GerçekleőtirmiŐ olduđum tez alıŐmasının her aŐamasında bilgi ve desteđiyle yanımda olan, tecrübelerini aktaran deđerli DanıŐman Hocam Do. Dr. Erdiń Uzun ve deđerli Hocam Do. Dr. Ercan BuluŐ'a ve manevi destekleri ile beni hi yalnız bırakmayan aileme teŐekkürlerimi sunarım.

Ocak, 2022

AyŐın BULUŐ

Bilgisayar Mühendisi



## 1. GİRİŞ

Bu çalışmada amacımız, meyve tazeliğini, taze/bozuk şekilde sınıflandırmaktır. Bunu yapabilmek için bir eşik değeri belirleyerek ve farklı modeller üzerinde çalışılarak, bu eşik değere ve modellere göre sınıflandırma yapılacaktır. Bu çalışma, elma, portakal ve muz olmak üzere 3 çeşit meyve kullanılacaktır.

Gıda durumu, insanların hayatındaki ve ekonomik açıdan önemi göz önüne alındığında, bu süreci manuel yürütmek zor ve zahmetli bir süreçtir. Bilgisayarlı yaklaşımlar sayesinde, bu süreç daha otomatik hale getirilebilir. Meyvelerin depolandığı buzdolaplarına veya bir marketin reyonuna kurulacak kamera sistemleri sayesinde meyvelerin tazelik takibi anlık olarak yapılabilir.

Bu bölümde, yapay zekânın bir alt dalı olan bilgisayarlı görü (Computer Vision) konusunda genel bilgiler verildikten sonra meyve tazeliğinin önemi konusunda ön bilgileri verilecektir.

### 1.1. Bilgisayarlı Görü

Bilgisayarlı görü bilgisayar bilimin en eski ve popüler konularındandır. Sayısal veya sembolik bilgi üretmek için resim ve video gibi dijital görüntüleri işleme, analiz etme ve anlamaya çalışma gibi konuları içerir (Sonka M, Hlavac V., Boyle R., 2008). GPU gibi donanım kaynaklarının artması (Ionica, M. Horea, David G., 2015) ve Derin Öğrenme tekniklerinin ilerlemesiyle birlikte bu alan (Joshi N., 2019) çok daha hızlı gelişmeye başlamıştır. Veri miktarının artması ile birlikte Derin Öğrenme teknikleri çok daha başarılı sonuçlar vermeye başlamıştır. Bu tezde, meyvenin tazelik durumunu bilgisayarlı görü ile yöntemleri ve günümüzün popüler konusu olan Derin Öğrenme teknikleri ile karar vermeyi amaçlıyoruz.

Meyve üzerine yapılan bilgisayarlı görü çalışmaları incelendiğinde farklı konuların karşımıza çıktığı görülür. Bu konular:

- Meyve/sebze otomatik sınıflandırmasında kategorileri tespiti (Cunha J. B., 2003) (Tewari V. K., Kumar A. A., Kumar S. P., Pandey V., & Chandel N. S., 2013)
- Meyve/Sebze hastalıkları ve kusurlarının tespiti (Mahaman B. ve diğerleri, 2004)
- Çeşitli meyve/sebze sınıflandırması (Brosnan T., & Sun D.-W. (2002).)

- Meyve/Sebze nitrojen içeriđi tahmini (Tewari V. K., Kumar A. A. , Kumar S. P., Pandey V., & Chandel N. S., 2013)
- Meyve/Sebze gerek zamanlı izleme (Özyildiz E., Krahnst-over N., & Sharma R., 2002)
- Meyze/Sebze tazeliđine derecelendirme (Fu Y., 2020)

şeklindedir. Bu tezde, elma, portakal ve muz için tazelik durumuna karar veren bir sistem geliřtirmeyi amalıyoruz.

Bir bilgisayarlı görü alıřmasında görsel özelliklerin belirlenmesi en önemli süreçlerden biridir. Meyve bozulması, görsel özellikleri Barrett, Beaulieu ve Shewfelt (2010) tarafından ortaya konulmuřtur. Meyve rengi zamanla deđiřikliklere uğrar, ancak bu deđiřiklik her zaman bozulma anlamına gelmez. Bu deđiřiklikte meyve olgunlařmaya bařlamıřta olabilir. Genelde, olgunlařma sonrası reaksiyonlar ile koyu renklerin oluřması bir bozulma göstergesidir. Bu görsel özellikler bozulma hızını yansıtabilir (Mitcham B., Cantwell M., & Kader A., 1996). Bu konudaki son alıřmalarda, kahverengi mantar lekeleri gibi bozulma türleri de tespit edilmiřtir (Sindhi K., Pandya J., & Vegad S., 2016) (Hartman J., 2010). Hargava (2018) meyve görünümleri ve renk tonları üzerine alıřmalar yapmıřtır. Tezimizde, veri setimizi geniř tutup farklı bozulma türlerini tahmin etmeyi amalıyoruz.

Bilgisayarlı görüde meyve bozukluklarının tespiti için meyve dokusu, rengi ve şeklinden yararlanılır. Bozulma iřlemi sırasında kademeli deđiřiklikler olur. Koyu renklerin ortaya ıkması veya su kaybı sebebiyle bozulma en belirgin özelliklerdir. Bu tezde, üç meyve için bozulma olup olmadıđını tespit etmeyi ve bu tespit için popüler derin öđrenme metotlarını kullanacađız.

## **1.2. Meyve Tazeliđi ve Etkileri**

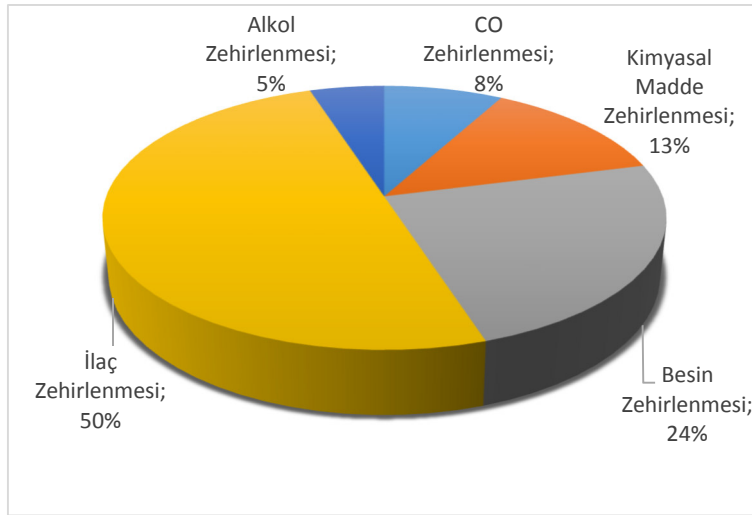
Meyve bozulmalarının ekonomik aıdan meyve maliyetlerine önemli etkileri vardır. Meyve maliyetlerinin üçte birinin bozulan meyvelere gittiđi tahmin edilmektedir. Ayrıca, bozulan meyvelerin sađlıđa zararlı olmasının yanı sıra meyve satıřlarını etkilediđi saptanmıřtır (Péneau S., Linke A., Escher F., & Nuessli J., 2009).

Herhangi bir fiziksel, kimyasal ya da organik madde solunduđunda, sindirildiđinde, enjekte edildiđinde veya emildiđinde; ufak miktarlardaki bile kimyasal etkileri ile yapılara zarar

verebiliyor ve fonksiyonları bozabiliyorsa, bu maddeye zehir denir. Bu meydana gelen olaya ise zehirlenme denilmektedir.

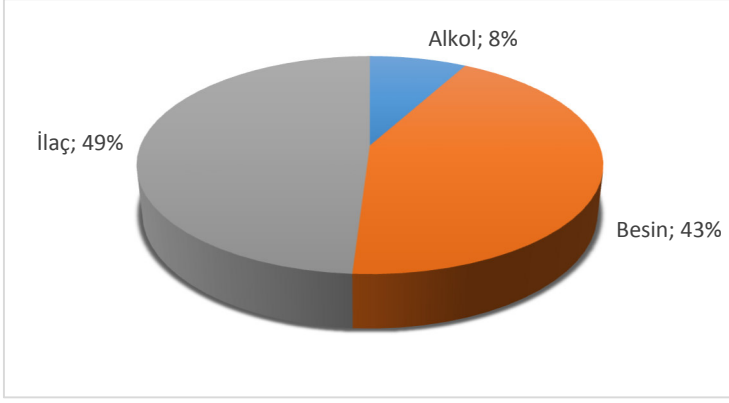
Tüketilen besinlerin hijyenik olması sağlıklı beslenmenin temel öğelerinden biridir. Besin zehirlenmesi hem gelişmiş hem de gelişmekte olan ülkeler için ciddi bir sağlık sorunudur.

Egemen, Demir ve arkadaşları (2001), besin zehirlenmesi üzerine yaptıkları çalışma ile, Ege Üniversitesi Tıp Fakültesi Acil Polikliniği'ne Ocak 1995- Temmuz 1997 tarihleri arasında gelen 2.568 zehirlenme vakasından 615 yani %23,9'unun besin zehirlenmesinden olduğunu tespit etmiştir.(Şekil 1.1)(Egemen A, Demir N., Akşit S., Kusin N., Sözbilen M. ve Solak İ., 2001)



Şekil 1.1 Zehirlenmeye Yol Açan Nedenlerin Dağılımı (%)

Yeşil, Akoğlu ve arkadaşları(2008), tarafından yapılan çalışmada, Marmara Üniversitesi Tıp Fakültesi Acil Servisi'ne 01.06.2005-31.12.2006 tarihleri arasında başvuru olan zehirlenme olgu sayısı 147'dir. Zehirlenme nedeni olarak 72 olguda ilaç, 63 olguda besin ve 12 olguda alkol tespit edilmiştir. (Şekil 1.2)(Yeşil O., Akoğlu H., Onur Ö. ve Güneysel Ö., 2008)



Şekil 1.2 Nedenlerine göre zehirlenme olgularının dağılımı

Meyve bozulmalarının ekonomik faaliyetler üzerinde de önemli etkileri bulunmaktadır, meyve maliyetlerinin yaklaşık olarak üçte birinin çürüyen meyvelerden gittiği tahmin edilmektedir.

Rawat(2015), tarafından yapılan çalışmada belirtildiği üzere, bozulmuş gıdalar hiçbir patojen veya toksin bulunmadığı takdirde yemek için güvenli olabilirler ancak doku, tat veya görünümdeki değişiklikler reddedilmelerine neden olur. Bazı ekolojistler, bu zararlı kokuların büyük hayvanları itmek için mikroplar tarafından üretildiğini ve böylece besin kaynağını kendilerine sakladıklarını öne sürmektedirler. Tarladan sofraya meydana gelen bu ciddi gıda kaybı, önemli çevresel ve ekonomik etkilere sebep olmaktadır. USDA Ekonomik Araştırma Servisi'nin 1995 yılında yaptığı araştırmaya göre ABD'de doksan altı milyar pounddan fazla gıda perakendeciler, gıda hizmetleri ve tüketiciler tarafından kaybedildiği tahmin edilmektedir. Gıda bozulması ve kaybıyla ilişkili çevresel ve kaynak maliyeti de vardır. Bir mahsulün %20'si kaybedilirse, o mahsulü yetiştirmek için kullanılan suyun %20'si de kaybedilir. (Rawat S., 2015)

Meyve tazeliğinin insanların hayatındaki, çevredeki ve ekonomideki etkisi göz önüne alındığında, meyve tazeliğinin sınıflandırılması büyük önem kazanmaktadır fakat manuel bir şekilde meyve tazeliğini sınıflandırmak büyük zaman kaybına sebep olacaktır. Bilgisayar programı kullanarak meyve tazeliğinin belirlenmesi bu sorunun çözümü olarak kabul edilmektedir.

### 1.3. Motivasyon ve Tezin Organizasyonu

Meyve durumunun otomatik belirlenmesi market reyonları ve buzdolabı gibi yerlere kurulacak sistemler sayesinde yapılabileceğini düşünüyoruz. Bu tez sayesinde, meyve bozulma

durumunun tamamen otomatik olarak kontrol edilmesi sağlanabilecektir. Bu konuda, gelişmiş sistemler olmaması bu tezi yapmamız için bize ilham verdi. Ayrıca, bu problemi çözerken kullandığımız derin öğrenme algoritmaları literatürde farklı bilgisayarlı görü araştırmalarında en güncel çalışmalarda kullanılmaktadır. Bu alandaki çalışmaların genelde eski çalışmalara ve algoritmalara odaklanması derin öğrenme kullanmak için bizi heveslendirmiştir. Derin öğrenme gibi diğer çalışmalarda yüksek doğruluklar veren bir konuyu meyvenin sağlık durumunun tespitinde kullandık.

Özet olarak tezimizin katkıları:

- Meyvenin sağlık durumunu tespit etmeyi amaçlıyoruz.
- Deneylerimizi elma, portakal ve muz gibi üç temel meyve için yapacağız.
- Literatürde önerilen derin öğrenme modellerini ve performans sonuçlarını karşılaştırmalı olarak inceleyeceğiz.
- İleride market reyonlarında veya buzdolaplarında kullanılacak bir sistem hedefliyoruz.

Bu tezin geri kalan kısmı şu şekilde organize edilmiştir: Bölüm 2, literatürde yapılmış ilgili diğer çalışmaları gösterir. Bölüm 3, kullanılan yöntemleri, kütüphaneleri ve modelleri içerir. Bölüm 4, deney için kullanılan veri setini, performans metriklerini ve deney sonuçlarını sunar. Bölüm 5'te çalışmanın sonuçları özetlendikten sonra çalışma hakkında ileriye yönelik yapılabilecek katkılar verilir.

## 2. LİTERATÜR ARAŞTIRMASI

Meyve tazeliği konusunda meyvenin sağlıklı mı kusurlu mu olduğunu tespit etmeye çalışan Moallem, Serajoddin ve Pourghassem (2017) çalışmalarında SVM + KNN kullanmışlardır. Domates üzerine çalışan Arakeri ve Lakshmana (2016) meyve dokusu, rengi ve şekli önemli özellikler olarak ele almış ve istatistiklere dayalı bir bilgisayarlı görü çözümü önermiştir. Bu çalışmada, domatesin kusurlu veya sağlıklı olarak kabul edildiği ikili bir sınıflama kullanılmıştır.

Derin öğrenme, bilgisayarlı görü alanının alt bir alanı olan görsel nesnelere tanımda çoğunlukla kullanılmaktadır. Bresilla ve arkadaşları (2019) meyve ve sebze tanıma için YOLO'yu kullanmışlardır. YOLO (Redmon J., Divvala S., Girshick R., & Farhadi A., 2016 ), sadece resim gibi statik görüntülerin değil hareketli video görüntülerinin işlenmesinde de kullanılan diğer yaklaşımlara kıyasla hızlı bir modeldir. Zeng (2017) meyve tanıma için derin bir sinir ağı olan VGG kullanıp sonuçların iyileştirilebileceğini göstermiştir. Mureşan (2018) özellik çıkarımı için dört evrişimli ve havuzlama katmanından oluşan bir model kurar. Bu modelde, iki tam bağlantılı katmandan oluşan sığ bir sinir ağı benimsenmiştir. Görüntülerde, arka plan rengi yoktur. Bu çalışmaların hepsi meyve tanıma üzerinedir.

Özellikle meyve tazeliği konusunda çalışmalar vardır. Nashat ve Hassan (2018) zeytin meyvesini inceleyip bir tazelik derecelemesi yapmaya çalışmışlardır. Prakash (2018) dokuz katmanlı bir sinir ağı, üç evrişim ve havuzlama katmanı olan, bir giriş ve bir çıkış katmanından oluşan bir derin öğrenme yöntemi ile ahududu bozulma tanıma yapmayı amaçlamıştır. Bu tezde ise üç meyve üzerine araştırmalar yapılacaktır.

Yu, Tang ve arkadaşları (2017), tarafından yapılan çalışmada hyperspektral görüntüleme tekniği (HSI) ve derin öğrenme algoritmaları kullanarak karideslerin çürük ve sağlam olarak sınıflandırılması amaçlanmıştır. Bu çalışmada veri tabanı olarak Pasifik beyaz karidesten HSI tekniği ile elde edilen 256 görüntü kullanılmıştır. 8 gün boyunca her gün 32 adet karides görüntüsü kullanarak karidesin kasları içinde biriken nitrojen oranı veri tabanına kaydedilmiştir. Görüntüler 443 bantla 450-1.010 nm spektral aralığa yeniden boyutlandırılarak tazelik sınıflandırılması için kullanıldı. 256 adet karides verisinin rastgele seçilen 800 piksel spektrası seçilerek, her dalga boyu değişkeni ortalamaları alınarak ortalama spektrum hesaplandı. Spektral özellikler ise HSI verilerinden elde edilen yığınlanmış otomatik kodlayıcılar (SAEs) tabanlı derin öğrenme algoritması ile çıkarıldı. Ardından karideslerin

tazelik sınıfını lojistik regresyon (LR) tabanlı derin öğrenme algoritması ile sınıflandırmak için kullanıldı. Sınıflandırma sonrası 116 karides datası (58 taze-58 çürük) rastgele 256 örnek içinden seçilerek kalibrasyon veri seti olarak tanımlandı. Her karidesten (116 adet) tekrar rastgele 800 piksel alınarak 92.800 pikselin , 46.400 pikseli eğitim verisine kalan 46.400 pikseli doğrulama verisine eşit olarak kullanılmıştır. SAEs-LR yöntemi ile %96,55 kalibrasyon setinde ve %93,97 tahmin setinde başarı yakalanmıştır.(Yu X., Tang L., Wu X. ve Lu H., 2018)

Kayaalp ve Metlek (2020), tarafından yapılan çalışmada, derin öğrenme algoritması kullanarak elmaların çürük ve sağlam olarak sınıflandırılması amaçlanmıştır. Bu çalışmada veri tabanı olarak Gembloux Tarım Üniversitesindeki bir araştırma sonucu elde edilen Jonagold elma görüntülerinin oluşturduğu CAPA veri tabanı kullanılmıştır. Bu veri tabanındaki görüntülerden 280 adet sağlam, 246 adet çürük olmak üzere toplamda 526 adet elma görüntüsü kullanılmıştır. Görüntülerin 4 farklı dalga boyu(450,500,750,800 nm) ve RGB formatı da elde edilerek veri tabanı kullanıma hazırlanmıştır. Verinin %80'i eğitim %20'si test için kullanılmıştır. Kullanılan derin öğrenme modelinin katmanları; giriş katmanı, evrimsel katman, aktivasyon katmanı, havuzlama katmanı, ezberleme katmanı, tam bağlantı katmanı ve sonuçlandırma katmanıdır. Uygulama Matlab ortamında geliştirilmiştir. Çalışmada kullanılan mimarı arka arkaya 3 adet evrimsel yapının eklenmesiyle oluşturulmuştur. Modelin tahminin ne kadar başarılı olduğunu tespit etmek için hata matrisi kullanılmıştır. Çalışma sonucunda, 450nm ve 500nm dalga boylarının birlikte kullanıldığı görüntülerden elde edilen öznelikler ile başarı oranının %91,25 olduğu tespit edilmiştir.(Kayaalp K. ve Metlek S., 2020)

Moon, Kim ve arkadaşları (2020), tarafından yapılan çalışmada, somon, ton balığı ve sığır etini “taze”, “muhtemelen çürümüş”, “çürümüş” şeklinde sınıflandırmak amacıyla Evrimsel Sinir Ağı(CNN) kullanılmıştır. Çalışmada eğitim veri seti 3 Atlantik somonu, 3 Pasifik somonu, 8 ton balığı, 8 sığır ile eğitim için veri seti oluşturulurken; 12 Atlantik somonu, 12 pasifik somonu, 9 ton balığı ve 8 sığır ile test için veri seti oluşturulmuştur. Bu çalışmada, 6 set evrimsel katman, düzeltilmiş doğrusal birim (ReLU) katmanları ve havuz katmanları, ardından üç tam bağlantılı katman içeren bir CNN yapısı kullanılmıştır. Tipik bilgisayar görme probleminde girdi 2-D yerine 1-Boyutlu (D) olduğundan, evrimsel katmanlarında sadece 1-D evrimi gerçekleştirecek şekilde küçük bir değişiklik yapılmıştır. Küçük modifikasyon dışında, bu çalışmada kullanılan sinir ağı mimarisi AlexNet16'inkine benzerdir. CNN tabanlı makine öğrenimi algoritmasının eğitimi NVidia GeForce GTX üzerinde bir çerçeve olan Torch kullanılarak uygulandı. Eğitim için ayrılan veri setinin %90'ı gerçek eğitim için %10'u ise



modelin mevcut performansının doğruluğunu değerlendirerek kontrol etmek içindir. Modelin tahminin ne kadar başarılı olduğunu tespit etmek için duyarlılık(sensitivity) ve özgüllük(specificity) değerleri incelenmiştir. Çalışma sonucunda doğruluk, somon için %85(Atlantik somonu için %84, Pasifik somonu için %85), ton balığı için %88 ve sığır eti için %92 elde edilmiştir.(Moon E., Kim Y., Xu Y., Na Y., Giaccia A. ve Lee J., 2020)

Ananthanarayana, Ptucha ve arkadaşları (2020), tarafından yapılan çalışmada, 6 meyve kategorisini taze ve çürümüş olarak sınıflandırabilmek amaçlanmıştır. Çalışmada CMOS (Tamamlayıcı Metal Oksit Yarı İletken) sensörü, görüntü sınıflandırma için MobileNetV2 ve mimari olarak CNN(Evrişimli Sinir Ağı) mimarisi kullanılmıştır. Çalışmada kaggle üzerinden açık kaynaklı görüntüler ve özel çekilen fotoğraflar ile elde edilen veriseti kullanılmıştır. Veri setinin 30.846'i eğitim 2.694'i test için kullanılmıştır. Model 1.000 epoch ile eğitilmiştir. Çalışmada arka planda Tensorflow nesne algılama API'sini kullanan MobileNetV2 ile model eğitilmiştir. Model, COCO veri setinden önceden eğitilmiş ağırlıklar ile başlamıştır. Çalışma sonucunda görüntü sınıflandırma modelinde %97, nesne algılama modelinde %97 doğruluk elde edilmiştir. (Ananthanarayana T., Ptucha R. ve Kelly S., 2020)

Fu (2020), tarafından yapılan çalışmada, derin öğrenme kullanılarak tazelik derecelendirmek için çeşitli meyve görüntülerinin kapsamlı analizi üzerinde çalışılmıştır. Çalışmada, dijital görüntüler dikkate alınarak ilgilenilen bölgeyi tespit etmek için YOLO, tazelik derecelendirme özelliği çıkarma için temel ağlar olarak ResNet, VGG, Google Net ve AlexNet dahil olmak üzere bir dizi algoritma gözden geçirilmiştir. Uygun meyve tazeliği için veri seti bulunmadığından, proje için özel veri tabanı hazırlanmıştır. Veri seti 6 tür meyvenin(elma, muz, ejderha meyvesi, portakal, armut ve kivi) farklı ortamlarda, alakasız bitişik nesnelere ve farklı ışık koşullarına sahip ortamlarda fotoğrafları ile oluşturulmuştur. Toplamda, her meyve türü için yaklaşık 700 görüntü toplanarak 4000 görüntülük bir veri seti oluşturulmuştur. Veri setinin %90'ı eğitim için, %10'u doğrulama için bölünmüştür. Tazelik derecelendirmesini 0,0 ile 10,0 arasında ölçeklendirilmiştir. 0,0 tamamen bozulmayı, 10,0 ise tamamen taze olmayı temsil etmektedir. Meyvelerin tazelik derecelendirmesinin sonuçları, muzun diğerlerinden en farklı meyve olduğunu, portakal ve armutun ise en az tanınan meyveler olduğunu muzun en yüksek doğruluklara ve hassasiyetlere sahip olan meyve olduğunu göstermektedir. YOLO sınıflandırıcısının ortalama performansı doğruluk, kesinlik ve geri çağırma ölçütlerinde gösterilir, puanlar doğruluk için %90'ın ve hassasiyetle geri çağırma için %80'in üzerindedir. Performans ölçütlerini kullanarak eğitim ve doğrulama arasında önemli bir

boşluk olmadığı tespit edilmiştir. Bu durum, eğitim oturumu sırasında YOLO'nun aşırı uyarlanma olasılığının düşük olduğunu gösterir. Çalışmayı değerlendirmek için, tahmini ortalama kaybı ölçümünde Ortalama Kare Hatası metodunu(MSE), tahminin ne kadar kararlı olduğunu ölçümünde standart sapma metodu kullanılmıştır. Çalışmada, GoogleNet ile 6 meyve türünün hepsi test edilmiştir ve tazelik özelliklerini tanımda daha iyi bir yeteneğe sahip olduğu belirlenmiştir. Ortalama olarak, GoogLeNet tabanlı regresyon CNN'nin performansı eğitim için 3,625 (MSE) ve doğrulama için 4,404 (MSE) değerindedir. Standart sapma çıktı kararlılığını gösterir; ortalama googleNet'e göre sapma eğitim için 1,323 ve doğrulama için 1,500'dür. Aynı çalışma AlexNet ile de yapılmıştır. AlexNet, diğer ağların aksine ne iyi ne de kötü performans gösterdi. Altı meyve türünün ortalama MSE'si eğitim prosedürü için 3,500 ve doğrulama için 4,099'dur. Regresyon kararlılığı açısından, AlexNet temel model eğitim için 1,480 ve doğrulama için 1,248 rapor eder. Çalışma sonucunda, ResNet-152'nin performansı, ResNet ailesi arasında en iyisidir ve ResNet'ler arasındaki en derin ağıdır. ResNet, diğer yöntemlere benzer şekilde üç belirli meyve görüntüsüne dayanarak iyi sonuçlar veremiyor: Elmalar, Kivi meyveleri ve armut. Muz tazeliğinin derecelendirilmesi en doğrusudur. Ortalama olarak, ResNet-152 için eğitim ve doğrulama MSE değerleri sırasıyla 3,582 ve 4,058'dir. Stabilitate ölçümü için standart sapma, eğitim seti için 1,329 ve doğrulama seti için 1,842'dir. VGG-11 ile yapılan aynı çalışmada yine VGG-11 için, muz bozulması tazelik derecelendirmesinde en doğru olanı iken, elma, kivi ve armut resimleri en zor olanıdır. Bununla birlikte, VGG-11, eğitim ve doğrulama setleri arasındaki sonuç boşluklarının küçük olduğu ölçümlerde aşırı uyumdan daha az etkilenme eğilimindedir. Ortalama olarak, eğitim ve doğrulama için MSE'ler sırasıyla 3,665 ve 3,934'tür, standart sapmalar sırasıyla 1,361 ve 1,266'dır. (Fu Y., 2020)

Valentino, Cenggoro ve arkadaşları (2021), tarafından yapılan çalışmada, meyve tazeliğini Evrişimsel Sinir Ağı(CNN) modeliyle derin öğrenmeyi kullanarak görüntü işleme ile saptamayı amaçlamaktadır. Veri seti Kaggle sitesinden elde edilmiştir. Kullanılan veri seti taze elma, bayat elma, taze muz, bayat muz, taze portakal, bayat portakal olmak üzere 6 gruptan oluşmaktadır. Çalışmada, taze elma için; 1.693 tanesi eğitim, 395 tanesi test, taze muz için; 1.581 tanesi eğitim, 381 tanesi test, taze portakal için; 1.466 tanesi eğitim, 388 tanesi test, bayat elma için; 2.342 tanesi eğitim, 601 tanesi test, bayat muz için; 2.224 tanesi eğitim, 530 tanesi test, bayat portakal için 1.595 tanesi eğitim, 403 tanesi test için gruplandırılmıştır. Yazılım dili olarak Python dilinin versiyon 3.6'sı seçilmiştir. Tasarlanan CNN modelinde batch size 32 belirlenmiş, MaxPooling2D katmanında pool size (2.2) belirlenmiş, 6 Dropout katmanı 0,25 ile kullanılmış, Conv2d katmanı ise 32, 64, 128, 256 ve 512 ile kullanılmıştır. Model aktivasyon

fonksiyonu olarak Relu, optimizer olarak Adam Optimizer'ını kullanmaktadır. Bu çalışmada Endonezya'daki meyvelerin önemli rolü düşünülerek, Derin Öğrenme tarafından atılan önemli adımlar ile modeli geliştirmek için bir deneme planı tasarlanmıştır. Deney tamamlandıktan sonra, gelecek çalışmalarda, geliştirilen derin öğrenme modelinin performans değerlendirilmesi takip edilmesi planlanmaktadır. (Valentino F., Cenggoro T. ve Pardamean B., 2021)

Jordan, Chloe ve arkadaşları tarafından yapılan çalışmada(2022), LDC ülkerinde artan finansal öneme sahip olan limon meyvesi için, hem otonom meyve kalitesi tanımayı geliştirmek hem de bilgisayarlı görme modelinin karmaşıklığını azaltmak için yöntemler önermiştir. Çalışmada veri seti olarak SoftwareMill 2'den limon görüntülerinin açık kaynaklı bir veri seti alınmıştır. Veri seti, 10.561.056 piksel çözünürlükte 2.690 limon görüntüsü içerir. İlgili algoritmaların hesaplama karmaşıklığı göz önüne alındığında, görüntüler daha sonra 256.256 piksele yeniden boyutlandırılır; bu çözünürlük, RGB piksel değerlerinin toplam sayısını 3.345.408'den (10.563) 196.608'e (2.563) düşürür. Çalışmada Koşullu GAN modeli kullanılmıştır. Model, sınıf etiketinin ikinci bir girişi ile üretici ve ayırmacı ağlarının birleştirilmesini desteklediği için tercih edilmiştir. Yani, sağlıklı ve sağlıklı olmayan bir meyvenin bağlamı belirlenir ve bu nedenle model, iki sınıftan birine ait olarak görüntüler üretmeyi öğrenecektir. İlk aşamada koşullu GAN 500 epoch için eğitilmiştir ve üretilen sentetik verilerin manuel olarak araştırılması umut vaat etmiştir fakat yine de birkaç ciddi görsel hata meydana gelmiştir. Bu nedenle eğitim, 64 batch size ve 2.000 epoch şeklinde değiştirilmiştir. Ayrıca 64 batch size altında seçilen büyüklükler ile, yaklaşık 10 epoch sonra eğitimin durdurulduğu ve daha fazla öğrenmemesine neden olduğu gözlemlenmiştir. Çalışmanın sonucunda, koşullu GAN tabanlı eğitim verisi ile tanıma doğruluğu %83,77'den %88,75'e çıkarılmıştır. Son olarak, koşullu GAN'ın üretilen sentetik meyvenin etinin istenmeyen özelliklerini hayal etmede başarılı olduğunu göstermek için yalnızca gerçek fotoğraflar üzerinde eğitilen model üzerinde Grad-CAM analizi gerçekleştirilmiştir. Bu nedenle, bu çalışma, koşullu GAN'ın, meyve sağlığı sınıflandırılması sorununda veri kıtlığını hafifletmek için veriler üretme yeteneğine sahip olduğu savunulmuştur.(Jordan J.B., Chloe M.B., Luis M., Anikó E. ve Diego R.F., 2022)

### 3. KULLANILAN YÖNTEMLER

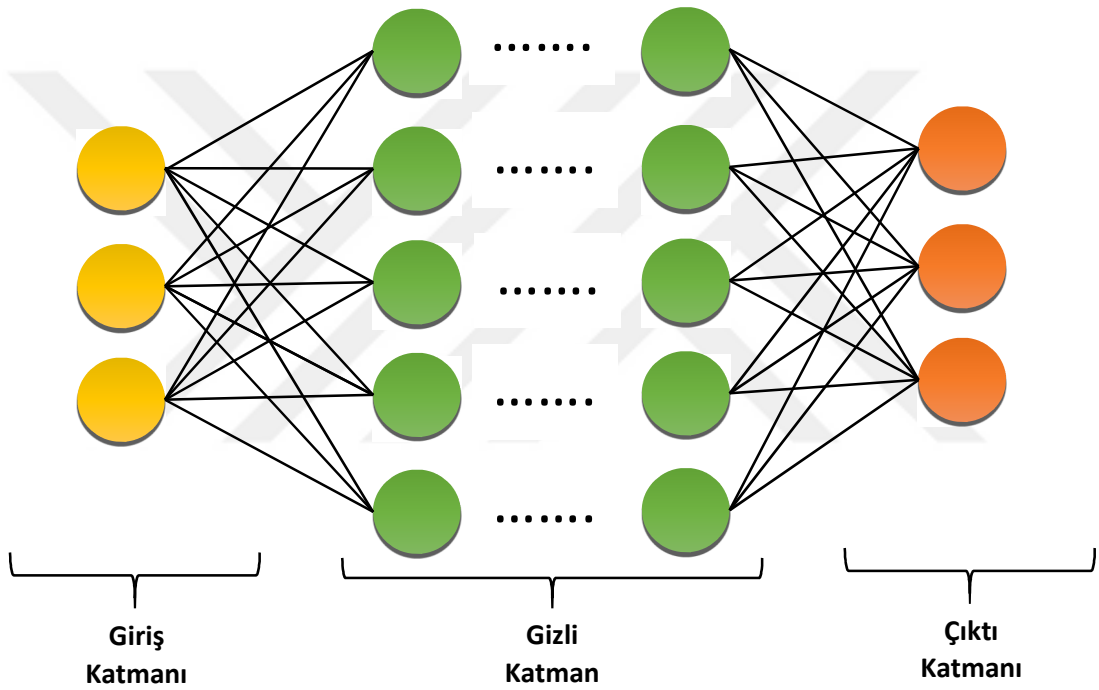
Bilgisayarların bir algoritmaya dayalı olarak yaptığı işlemlerde hata payı yoktur ve işlem belirli adımları takip eder. Bir girdiye dayalı çıktı almak için yazılan komutlardan farklı olarak, bilgisayarların mevcut örneklere dayanarak karar verdiği bazı durumlar vardır. Bu durumlarda, bilgisayarlar karar verme sürecindeki insanlar gibi hata yapabilir. Yani makine öğrenmesi, bilgisayarların insan beyni gibi verileri ve deneyimleri kullanarak öğrenme yeteneği ile donatılması sürecidir. Makine öğrenmesinin temel amacı, önceki verileri kullanarak kendini geliştirebilen, karmaşık örüntüleri algılayabilen ve yeni problemlere çözüm bulabilen modeller oluşturmaktır. (Çelik Ö., Altunaydın S., 2018)

Makine öğreniminin bir dalı olan derin öğrenmenin özellikle son yıllarda etkili olduğu kanıtlanmıştır. Derin öğrenme, her biri girdi verilerine yönelik basit ancak doğrusal olmayan dönüşümlerden oluşan çok sayıda gizli katmana sahip karmaşık sinir ağı mimarilerini kullanan bir temsil öğrenme algoritmaları ailesidir. Yeterince bu tür dönüşüm modülleri verildiğinde, sınıflandırma, regresyon, transkripsiyon ve diğer birçok öğrenme görevini çözmek için çok karmaşık işlevler modellenilebilir. Bizde bu çalışmamızda, meyve tazeliğini sınıflandırmak için derin öğrenme metotlarını kullanıp, en ideal sonuca yaklaşabilmek için birbiri ile karşılaştırmayı hedefledik.

Derin öğrenme, makine öğrenimi algoritmalarının bir alt kümesi olarak görülse ve onunla birçok ortak yönü paylaşırsa da, onu geleneksel makine öğrenimi yaklaşımından ayıran bazı farklılıklara sahiptir. En önemli fark, makine öğrenmesi algoritmalarının algoritmayı beslemek için özelliklerin manuel olarak seçilmesini gerektirmesi iken, Derin öğrenmede bu özelliklerin algoritma tarafından otomatik olarak algılanmasıdır. Ayrıca, derin öğrenme hiyerarşik bir öğrenme metodolojisini benimser. (Aslan Z., 2018)

Makine öğrenimi teknolojisi, modern toplumda kullanılan teknolojileri pek çok yönden desteklemektedir. Bu teknolojiler; kamera, akıllı telefon gibi birçok üründe yaygınlaşmakta ve sosyal ağ aramalarında içerik filtreleme gibi birçok uygulamada aktif olarak kullanılmaktadır. Ayrıca, özellikle nesne tanıma, kenar algılama, konuşma tanıma ve pek çok alan için faydalı bir şekilde kullanılmaktadır. Derin öğrenme, göreve özel algoritmaların aksine, öğrenme temsillerine dayanan daha geniş bir makine öğrenimi yöntemleri ailesinin bir parçasıdır. Derin öğrenme, makine öğreniminin birçok pratik uygulamasını ve genel olarak yapay zekâ alanını genişletti. Sığ öğrenmeye kıyasla(NN) derin öğrenme(DNN), daha soyut bilgileri öğrenmek

için derin mimariler oluşturma avantajına sahiptir. Derin öğrenme yöntemlerinin en önemli özelliği, özellik temsillerinin otomatik olarak öğrenilmesi ve böylece çok fazla zaman alan mühendislikten kaçınmasıdır. Daha iyi çip işleme yetenekleri, makine öğrenimi algoritmalarındaki önemli gelişmeler ve uygun maliyetli bilgi işlem donanımı, derin öğrenmenin yaygınlaşmasının temel nedenlerindedir. Geleneksel makine öğrenimi, bir girdi ve bir çıktı katmanlarından oluşan, girdi ve çıktı katmanları arasında birden fazla gizli katman içermeyen sığ ağlara dayanır. Derin öğrenme, bir ağda girdi ve çıktı katmanları dahil olmak üzere üçten fazla katman olduğunda niteliklidir. (Coşkun M., Özal Y, Uçar A ve Demir Y., 2017)



Şekil 3.1 Derin Öğrenme Ağı için Örnek

Derin öğrenmede, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayanan bir yapı söz konusudur. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir model oluşturur. Bu model, soyutlamanın farklı seviyelerine karşılık gelen birden çok temsil seviyesini öğrenmektedir. Derin öğrenme temel olarak verinin modelden öğrenmesine dayalıdır. Bir görüntü için model denildiğinde; piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi özellikler düşünülebilir. Bu özelliklerin içinden bazıları veriyi daha iyi temsil etmektedir. Bu aşamada yine avantaj olarak, derin öğrenme yöntemleri, elle çıkarılan özellikler yerine veriyi en iyi temsil eden hiyerarşik model çıkarımı için etkin algoritmalar kullanmaktadır.

Uygulamada ve literatürde derin öğrenmenin kullanıldığı birçok çalışma bulunmaktadır. Doğal dil işleme, video ve görüntü işleme, biyomedikal sinyal ve görüntü işleme, nesne tanıma, kimya, robotik, finans, reklam, arama motorları ve otonom araç sistemleri gibi çok çeşitli konularda derin öğrenme uygulamaları geliştirilmektedir. Derin öğrenme genel olarak verinin temsilinden öğrenmeye dayanmaktadır. Bu çalışmada, derin öğrenme görüntü işleme amacıyla kullanılmaktadır.

Kaggle sitesinde yapılan anket sonucunda ortaya çıkan verilere göre; Makine öğrenmesi ve derin öğrenme konularında en çok kullanılan 4 programlama dili şöyle sıralanabilir: Python (%76,3), R (%59,2), C/C++ (%19,2), Java (%18,3). Özellikle Python birçok derin öğrenme çatisının ve kütüphanesinde kullanılmasından dolayı en çok tercih edilen programlama diliyken istatistik alanında en çok tercih edilen dil R'dır. Python programlama dilinin bir diğer avantajı da hem akademik hem ticari uygulamalar için kullanımının avantajlı olmasıdır. Bu çalışmada, bu avantajlar göz önüne alınarak, Python dili kullanılmıştır.

### **3.1. Kullanılan Kütüphaneler**

Bu çalışmada, derin öğrenme kütüphaneleri arasında oldukça popüler olan, Google tarafından geliştirilmiş TensorFlow çerçevesi kullanılmıştır. TensorFlow, hızlı derleme yapabilme, tek bir API ile bir masaüstü, sunucu veya mobil cihazdaki bir veya daha fazla CPU'ya veya GPU'ya dağıtma olanağı sağlayabilme, veri ve model paralelliği sağlayabilme özellikleri ile ön plana çıkan bir çerçevedir. Aynı zamanda TensorBoard ile görselleştirilme yapılabilmektedir.

TensorFlow, Google Brain Ekibi tarafından bir C/C++ motoru üzerinden Python API ile yazılmış makine öğrenmesi ve derin öğrenme çerçevesidir. İki ana avantajı bulunmaktadır: birincisi, geliştirici ekibi tarafından sürekli olarak desteklenmesi ve ikincisi, CNN, RNN gibi bir çok mimari ile esnek çalışmasıdır. 2016'da Goldsborough, TensorFlow'un temel hesaplama paradigmasını, dağıtılmış yürütme modelini, programlama arayüzünü ve beraberindeki görselleştirme araçlarını tanıtan kapsamlı bir makale yayınladı. TensorFlow'un bir başka avantajı da, Google tarafından derin öğrenme ve makine öğrenmesi projeleri için özel olarak tasarlanmış tensor işleme birimlerinin(TPU'lar) olmasıdır. TPU, aynı anda daha büyük miktarlarda düşük seviyeli işleme elde etmeye yardımcı olmak için tasarlanmış bir işlemci türüdür. (Yapıcı M., Topaloğlu N. , 2021)


Bu çalışmada derin öğrenme için tercih edilen bir diğer kütüphane ise, yine Google-Francois Chollet tarafından geliştirilen Keras kütüphanesidir. Keras, Torch kütüphanesinden esinlenmiş sezgisel bir API'dır. Keras, TensorFlow kütüphanesini arkaplanda kullanmaktadır. Hızlı büyüyen bir yapıya sahiptir ve GPU veya CPU'da paralel çalışabilmektedir.

Görüntü işleme, gelişmiş bir görüntü elde etmek veya ondan başka yararlı bilgiler çıkarmak için bir görüntüyü dijital bir boyuta dönüştürmenin ve üzerinde belirli işlevleri gerçekleştirmenin bir yoludur.

Projede kullanılan OpenCV Kütüphanesi açık kaynak kodlu bir görüntü işleme kütüphanesidir. Bu çalışmada görüntü işleme aşamasında, görüntüyü okumada, görüntünün şeklini ayarlama bu kütüphane kullanılmıştır.

### 3.2. Kullanılan Modeller

Bu çalışmada VGG16 ve VGG19 modeli iki farklı yol ile geliştirilerek test edilmiş ve gerçeğe en yakın sonuçlar elde edilmesi amaçlanmıştır.



Şekil 3.2 VGG16 isimli modelin katmanları

VGG16, model mimarisi olarak 16 katman kullanan VGGnet modellerinden birisidir (Şekil 3.2). Modele verilen giriş katmanımız, 2 adet convolution katmanına (Conv 1-1 ve Conv1-2) ardından pooling katmanına girer. Convolution katmanında, giriş özelliği haritasından parçaları çıkarır ve bir çıktı özelliği haritası oluşturarak bu parçaların tümüne aynı dönüşümü uygular. Pooling katmanında ise giriş matrisinin kanal sayısı sabit tutulup, yükseklik ve genişlik bilgisi azaltılır. VGG16 modelinde girdi, iki convolution katmanı ve bir pooling katmanına girdikten sonra devamında tekrar iki convolution katmanı ve bir pooling katmanı ile devam eder, sonrasında ise 3 convolution, 1 pooling, 3 convolution, 1 pooling katmanına girip 3 adet dense katmanı ile devam ederek çıktıyı oluşturur.

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	(None, 227, 227, 3)	0
block1_conv1 (Conv2D)	(None, 227, 227, 64)	1792
block1_conv2 (Conv2D)	(None, 227, 227, 64)	36928
block1_pool (MaxPooling2D)	(None, 113, 113, 64)	0
block2_conv1 (Conv2D)	(None, 113, 113, 128)	73856
block2_conv2 (Conv2D)	(None, 113, 113, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0
global_average_pooling2d_1 ( (None, 512)		0

Şekil 3.3 VGG16 modelinin (227,227,3) giriş şekli ile katmanlarının gösterimi

Şekil 3.3'te VGG16'nın birinci gelişmiş modelde kullanılan (227,227,3) giriş şekli ile katmanları gösterilmiştir.

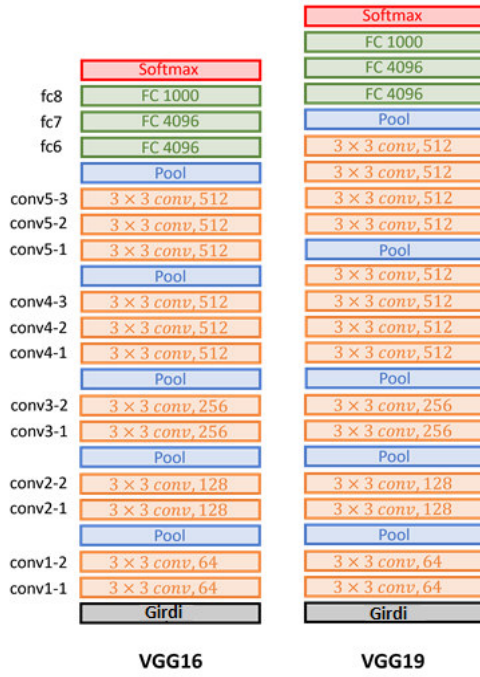


input_1 (InputLayer)	(None, 224, 224, 3)	0
block1_conv1 (Conv2D)	(None, 224, 224, 64)	1792
block1_conv2 (Conv2D)	(None, 224, 224, 64)	36928
block1_pool (MaxPooling2D)	(None, 112, 112, 64)	0
block2_conv1 (Conv2D)	(None, 112, 112, 128)	73856
block2_conv2 (Conv2D)	(None, 112, 112, 128)	147584
block2_pool (MaxPooling2D)	(None, 56, 56, 128)	0
block3_conv1 (Conv2D)	(None, 56, 56, 256)	295168
block3_conv2 (Conv2D)	(None, 56, 56, 256)	590080
block3_conv3 (Conv2D)	(None, 56, 56, 256)	590080
block3_pool (MaxPooling2D)	(None, 28, 28, 256)	0
block4_conv1 (Conv2D)	(None, 28, 28, 512)	1180160
block4_conv2 (Conv2D)	(None, 28, 28, 512)	2359808
block4_conv3 (Conv2D)	(None, 28, 28, 512)	2359808
block4_pool (MaxPooling2D)	(None, 14, 14, 512)	0
block5_conv1 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv2 (Conv2D)	(None, 14, 14, 512)	2359808
block5_conv3 (Conv2D)	(None, 14, 14, 512)	2359808
block5_pool (MaxPooling2D)	(None, 7, 7, 512)	0

Şekil 3.4 VGG16 modelinin (224,224,3) giriş şekli ile katmanlarının gösterimi

Şekil 3.4'te VGG16 modeli ile geliştirilen 2. Model için seçilen giriş şekli ile katmanlar listelenmiştir.

Çalışmada seçilen bir diğer model olan VGG19 modeli, kısaca 19 katmandan(16 convolution, 5 MaxPool ve 1 SoftMax katmanı) oluşan bir VGG model çeşididir (Şekil 3.5). VGG modellerinin, VGG11, VGG16 ve VGG19 gibi çeşitleri bulunmaktadır. Bu çalışmada VGG16 ve VGG19 tercih edilmiştir.



Şekil 3.5 VGG16 ve VGG19 modelinin katmanlarının görselleştirilmesi

VGG19 modelinin geliştirilmiş halinde ilk model için (227,227,3) giriş şekli, ikinci model için ise (224,224,3) giriş şekli kullanılmıştır.

Çalışmada iki adet geliştirilmiş VGG16 ve iki adet geliştirilmiş VGG19 modeli kullanılarak sonuçları birbiri ile kıyaslanmıştır. Bu bölümde modellerin detayları aktarılacaktır.

### 3.2.1. Gelişmiş VGG16 – Model 1

Layer (type)	Output Shape	Param #
vgg16 (Model)	(None, 512)	14714688
dense_1 (Dense)	(None, 128)	65664
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 6)	774

Şekil 3.6 Model-1 Gelişmiş VGG16


Bu çalışmada kullanılan 1. Modelde VGG16 modeli alınıp, son 5 katmanı eğitilemez hale getirilip ve üzerine yeni katmanlar eklenmektedir (Şekil 3.6) (Buluş E., 2021). Giriş şekli

olarak (227, 227, 3) kullanılmıştır. Eklenen katmanlar sırası ile Dense(128) katmanı, BatchNormalization katmanı ve Dense(6) katmanıdır.(Şekil 3.7)

```
model.add(layers.Dense(128, activation='relu'))
model.add(layers.BatchNormalization())
model.add(layers.Dense(6, activation='sigmoid'))
```

Şekil 3.7 Model 1 kodundan bir parça

Model compile edilirler optimizer olarak “adam” optimizer, loss olarak “binary\_crossentropy”, metrik olarak “accuracy” kullanılmıştır. Modelin eğitimi aşamasında epoch sayısı 4 seçilmiş, steps per epoch ise 1.000 seçilmiştir, yani eğitim her tur 1.000 olmak üzere 4 kere yapılmıştır. Doğrulama adım sayısı ise 100 seçilmiştir.



Şekil 3.8 Model-1 için test ve eğitim kayıplarının grafiksel gösterimi


Çalışılan model için test ve eğitim kayıplarının kullanılan epochlara göre gösterimi Şekil 3.8’de verilmiştir.

### 3.2.2. Gelişmiş VGG19 – Model 2

Layer (type)	Output Shape	Param #
vgg19 (Model)	(None, 512)	20024384
dense_1 (Dense)	(None, 128)	65664
batch_normalization_1 (Batch Normalization)	(None, 128)	512
dense_2 (Dense)	(None, 6)	774

Şekil 3.9 Model-2 katmanlarının gösterimi

Model-2’de baz katman VGG19 kullanılarak son 5 katmanı değiştirilemez hale getirilip Model-1 ile aynı katmanlar eklenmiştir (Şekil 3.9). Modele giriş şekli olarak (227, 227, 3) giriş şekli verilmiştir. Model için epoch sayısı 20, her epochtaki döngü 1.000 seçilmiştir fakat model en uygun sonuçta bırakması istenildiği için yazılımda ona göre ekleme yapıldı ve model 5. Epochtan sonraki epochlara geçmedi. Modelde doğrulama adım sayısı 100 seçilmiştir.



Şekil 3.10 Model-2 için eğitim ve test kayıplarının epoch sayılarına göre gösterimi

Çalışılan model için test ve eğitim kayıplarının kullanılan epochlara göre gösterimi Şekil 3.10’da verilmiştir.

### 3.2.3. Gelişmiş VGG16 – Model 3

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	(None, 224, 224, 3)	0
vgg16 (Model)	(None, 7, 7, 512)	14714688
flatten_1 (Flatten)	(None, 25088)	0
dense_1 (Dense)	(None, 256)	6422784
dropout_1 (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 6)	1542


Şekil 3.11 Model-3 katmanlarının gösterimi

Çalışmada kullanılan 3 numaralı modelde, 1 numaralı modeldeki gibi VGG16 modeli baz alınmıştır. Bu modelde baz alınan VGG16 modelinin tüm katmanları eğitilemez hale getirilip üzerine flatten katmanı, dense katmanı(256), dropout katmanı(0.5) ve dense katmanı(6) eklenmiştir (Şekil 3.11). Model compile edilirken “nadam” compiler, loss için “categorical\_crossentropy” ve metrik olarak “accuracy” kullanılmıştır. (Şekil 3.12)

```
model.compile(loss='categorical_crossentropy',  
              metrics=["accuracy"],  
              optimizer = 'nadam')
```

Şekil 3.12 3. Modelin compile kısmı için koddan bir parça

Eğitim aşamasında epoch sayısı 16 seçilmiş ve her epoch 526 kere döndürülmüştür.



Şekil 3.13 Model-3 için eğitim ve test kayıplarının epoch sayılarına göre gösterimi

Çalışılan model için test ve eğitim kayıplarının kullanılan epochlara göre gösterimi Şekil 3.13'te verilmiştir.


### 3.2.4. Gelişmiş VGG19 – Model 4

Layer (type)	Output Shape	Param #
input_2 (InputLayer)	(None, 224, 224, 3)	0
vgg19 (Model)	(None, 7, 7, 512)	20024384
flatten_1 (Flatten)	(None, 25088)	0
dense_1 (Dense)	(None, 256)	6422784
dropout_1 (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 6)	1542

Şekil 3.14 Model-4 katmanlarının gösterimi

Çalışmada kullanılan son model olan 4. Model VGG19 modelini baz alarak oluşturulmuştur.

Bu modele, model 3'teki yöntemlerin aynısı uygulanmıştır. Katmanların detayları Şekil 3.14'te görülmektedir, modele giriş şekli (224, 224, 3) verilmiştir.



Şekil 3.15 Model-4 için eğitim ve test kayıplarının epoch sayılarına göre gösterimi

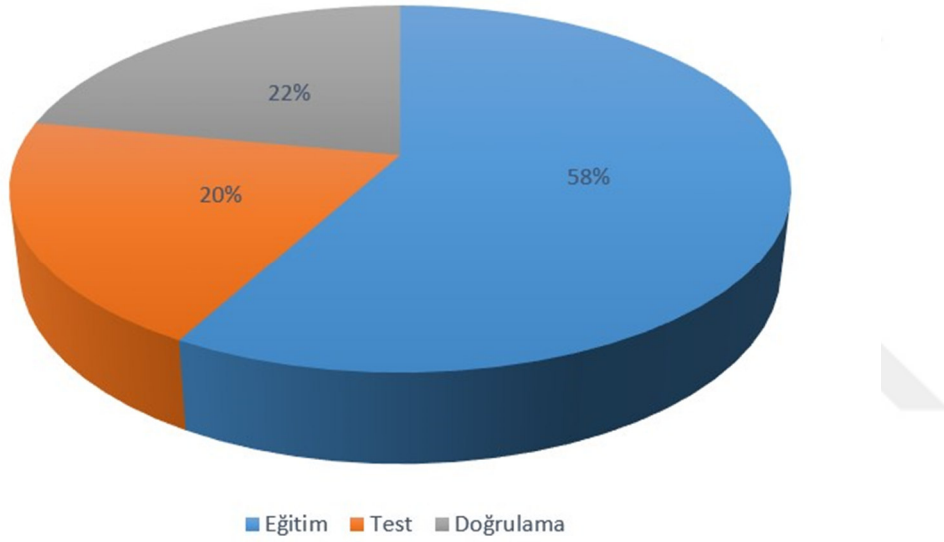
Çalışılan model için test ve eğitim kayıplarının kullanılan epochlara göre gösterimi Şekil 3.15'te verilmiştir.

## 4. DENEYLER

Bu bölüm, kullanılan modellerin deneylerine ayrılmıştır. Bu deneyler için öncelikle veri seti tanıtılır. Ardından deneylerden elde edilen performans sonuçları verilmiştir.

### 4.1. Kullanılan Veri Seti

Çalışmada veri seti olarak Kaggle sitesinde bulunan “Fruits fresh and rotten for classification” isimli veri seti kullanılmıştır. Bu veri setinde meyveler; taze portakal, taze muz, taze elma, bayat portakal, bayat muz ve bayat elma olmak üzere altı gruba ayrılmıştır.



Şekil 4.1 Veri setinin bölünme yüzdeleri


Çalışmada bayat ve taze olmak üzere toplamda veri olarak 13.599 fotoğraf kullanılmıştır. Bu fotoğrafların 2698 tanesi(yaklaşık olarak %20'si) test olarak, 7.901 tanesi(yaklaşık olarak %58'i) eğitim olarak ve 3000 tanesi(yaklaşık olarak %22'si) doğrulama olarak kullanılmıştır. (Şekil 4.1)

Taze portakal için; 388 fotoğraf test için, 966 fotoğraf eğitim için, 500 fotoğraf doğrulama için kullanılmıştır. Çalışmada toplamda 1.854 taze portakal fotoğrafı kullanılmıştır.

Taze muz için; 381 fotoğraf test için, 1.081 fotoğraf eğitim için, 500 fotoğraf doğrulama için kullanılmıştır. Çalışmada toplamda 1.962 taze muz fotoğrafı kullanılmıştır.



Taze elma için; 395 fotoğraf test için, 1.193 fotoğraf eğitim için, 500 fotoğraf doğrulama için kullanılmıştır. Çalışmada toplamda 2.088 taze elma fotoğrafı kullanılmıştır (Şekil 4.2).




Şekil 4.2 Taze elma veri seti örneği

Bayat portakal için; 403 fotoğraf test için, 1.095 fotoğraf eğitim için, 500 fotoğraf doğrulama için kullanılmıştır. Çalışmada toplamda 1.998 bayat portakal fotoğrafı kullanılmıştır.

Bayat muz için; 530 fotoğraf test için, 1.724 fotoğraf eğitim için, 500 fotoğraf doğrulama için kullanılmıştır. Çalışmada toplamda 2.754 bayat muz fotoğrafı kullanılmıştır.

Bayat elma için; 601 fotoğraf test için, 1.842 fotoğraf eğitim için, 500 fotoğraf doğrulama için kullanılmıştır. Çalışmada toplamda 2.943 bayat elma fotoğrafı kullanılmıştır (Şekil 4.3).



Şekil 4.3 Bayat elma veri seti örneği

Veri setinin adresine <https://www.kaggle.com/sriramr/fruits-fresh-and-rotten-for-classification> buradan ulaşılabilir.

## 4.2. Performans Metrikleri

Çalışmada ilerideki bölümlerde, modeller için testlerden elde edilen doğruluk (accuracy) değerleri kıyaslamaları yapılmıştır. Doğruluk, bir sınıflandırma modelinin performansını ölçmek için kullanılan bir yöntemdir. Genellikle yüzde ile ifade edilir, bu çalışmada da yüzde ile ifade edilmiştir. Doğruluk, tahmin edilen değerlerin gerçek değere eşit olduğu tahminlerin sayısına denir. Doğruluk, çalışmada doğru ve yanlış olmak üzere iki değere sahiptir.

Bölüm 3.2’de kullanılan modeller açıklanırken, grafiklerde kayıp (loss) değeri de verilmiştir. Maliyet işlevi olarak da bilinen kayıp işlevi, tahminin gerçek değerden ne kadar farklı olduğuna bağlı olarak bir tahminin olasılıklarını veya belirsizliğini hesaba katar. Kayıp değeri bize modelin ne kadar iyi performans gösterdiğine dair daha iyi bir görüş sağlar. Doğruluk aksine kayıp bir yüzde değildir, eğitim veya doğrulama setlerinde her örnek için yapılan hataların bir toplamıdır. Model için “en iyi” parametre değerini bulabilmek için genellikle eğitim sürecinde kayıp kullanılır. Eğitim sürecinde amaç bu değeri minimize etmektir.

Çoğunlukla, kayıptaki azalma arttıkça doğruluk değerinin arttığını gözlemleyebiliriz fakat bu durum her zaman bu şekilde değildir. Doğruluk ve kayıp farklı tanımlara sahiptir ve farklı şeyleri ölçmektedir. Bu iki metrik arasında matematiksel bir ilişti bulunmamaktadır.

Bölüm 3.2’de modellerle ilgili bilgiler verilirken, epoch terimi kullanılmıştır. Epoch, eğitim aşamasında elde bulunan tüm eğitim verilerinin ağı gösterilme sayısına denir. Epoch sayısı algoritma için çok önemlidir. Tüm eğitim verisi ile bir kez eğitim yapıldıktan sonra bir epoch tamamlanmış olmaktadır. Modellerde kullanılan epoch parametresi, bunun kaç kez tekrarlanması gerektiğini belirlemek için kullanılmaktadır. Doğruluk değerinin en yüksek olduğu yerde belirlenen epoch sayısı model için ideal olan epoch sayısıdır.

Çalışmada, modellerin sadece doğruluk değerlerini değil; Kesinlik (Precision), Duyarlılık (Recall) ve F-Ölçümü (F-Measure) değerlerini de bir sonraki başlıkta inceleyeceğiz.

Karmaşıklık Matrisi (Confusion Matrix) (Şekil 4.4), tahmini ve gerçek değerlerinin dört farklı kombinasyonunu içeren bir tablodur. Tablodaki Gerçek Pozitif (True Positive - TP), doğruya doğru denildiği durumları; Gerçek Negatif (True Negative - TN), yanlış yanlış denildiği durumları; Yanlış Pozitif (False Positive - FP), doğruya yanlış denildiği durumları; Yanlış Negatif (False Negative - FN), yanlış doğru denildiği durumları temsil etmektedir.

		Tahmin Durumu	
		Pozitif Tahmini (PT)	Negatif Tahmini (PN)
Gerçek Durum	Pozitif (P)	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
	Negatif (N)	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

Şekil 4.4 Karmaşıklık Matrisi

Kesinlik, en basit ifade ile gerçek pozitifler ile tüm pozitifler arasındaki orandır. Kesinlik, olumlu tanımlamaların ne kadarı gerçekten doğru sorusuna cevap arar. Kesinlik değerinin yüksek olması, model seçimlerinde önemli bir kriterdir. Eğer model, Yanlış Pozitif değerine sahip değilse, kesinlik 1.0’a eşit olur.

$$Kesinlik = \frac{Gerçek\ Pozitif(TP)}{Gerçek\ Pozitif(TP) + Yanlış\ Pozitif(FP)} \quad (4.1)$$

Duyarlılık, modelimizin Gerçek Pozitifleri doğru bir şekilde tanımlamasının ölçüsüdür. Duyarlılık, gerçek Pozitiflerin ne kadarı doğru bir şekilde tanımlandığına cevap arar. Eğer model Yanlış Negatif değerine sahip değilse, duyarlılık değeri 1.0’a eşit olur.

$$Duyarlilik = \frac{Gerçek Pozitif (TP)}{Gerçek Pozitif (TP) + Yanlış Negatif (FN)} \quad (4.2)$$

Bir modelin etkinliğini tam olarak değerlendirebilmek için hem kesinlik hem de duyarlılık birlikte incelenmelidir. Ne yazık ki, kesinliği arttırmak duyarlılığı azaltmayı veya bunun tam tersine sebep olmaktadır.

F-Ölçümü bize kesinlik ve duyarlılık değerlerinin harmonik ortalamasını vermektedir. Yukarıda bahsettiğimiz gibi, düşük hassasiyet ve yüksek kesinliğe sahip (ya da tam tersi) olan iki modeli karşılaştırmak zordur. Bu yüzden onları karşılaştırabilir kılmak için F-Ölçümü kullanırız. F-Ölçümü sayesinde, kesinlik ve duyarlılığı aynı anda ölçebiliriz. Mükemmel bir modelde F Skoru 1,0 olmalıdır.

$$f - Ölçümü = 2x \frac{Kesinlik \times Duyarlilik}{Kesinlik + Duyarlilik} \quad (4.3)$$

Bu deneylerde, durumlar incelerken 6 durum vardır. Bu sebepten dolayı bu formülasyonlar bu 6 duruma göre güncellenmiştir.

Çizelge 4.1 Sistemimizin Karmaşıklık Matrisi

		Tahmin Durum					
		Bayat Elma (A)	Bayat Muz (B)	Bayat Portakal (C)	Taze Elma (D)	Taze Muz (E)	Taze Portakal (F)
Gerçek Durum	A	$X_{00}=TP_A$	$X_{01}$	$X_{02}$	$X_{03}$	$X_{04}$	$X_{05}$
	B	$X_{10}$	$X_{11}$	$X_{12}$	$X_{13}$	$X_{14}$	$X_{15}$
	C	$X_{20}$	$X_{21}$	$X_{22}$	$X_{23}$	$X_{24}$	$X_{25}$
	D	$X_{30}$	$X_{31}$	$X_{32}$	$X_{33}$	$X_{34}$	$X_{35}$
	E	$X_{40}$	$X_{41}$	$X_{42}$	$X_{43}$	$X_{44}$	$X_{45}$
	F	$X_{50}$	$X_{51}$	$X_{52}$	$X_{53}$	$X_{54}$	$X_{55}$

Çizelge 4.1'de her durum için kesinlik, duyarlılık ve f-Ölçümü değerleri ayrı ayrı hesaplanır. Örneğin Bayat Elma (A) durumu için TPA değeri  $X_{00}$  değere eşittir. Bu durumda A durumu için formülasyon:

$$Kesinlik_A = \frac{X_{00}}{\sum_{i=0}^5 X_{0i}} \quad (4.4)$$

$$Duyarlilik_A = \frac{X_{00}}{\sum_{i=0}^5 X_{i0}} \quad (4.5)$$

Burada, her durumun kendi satırı ve sütunu değerlendirilir. Altı durum içinde benzer hesaplar yapılır. Bu değerler üzerinden f-Ölçümü değerleri hesaplanır. Sistemin doğruluğu ölçülürken tüm olumlu durumlar ile tüm durumların toplam sayısı kıyaslanır.

$$Dogruluk = \frac{\sum_{i=0}^5 X_{ii}}{\sum_{i=0}^5 \sum_{j=0}^5 X_{ij}} \quad (4.6)$$

### 4.3. Deneyler

Bir önceki bölümde anlatılan 4 model, test verileri için test edilmiştir ve doğruluk oranları kıyaslanmıştır, sonuçlar Çizelge 4.1, 4.2, 4.3 ve 4.4'te listelenmiştir. Sonuçlar 2 farklı doğruluk eşik değerine göre listelenmiştir. İlk 6 satırlar eşik değeri 0.5 için, son 6 satırlar ise eşik değeri 0.6 için listelenmiştir. Derin öğrenme sonucu 0,785 gibi bir sayı üretilmektedir. Bu sayı örneğin bir “Bayat Elma” için üretildiyse büyük ihtimal bayat olduğunu işaret eder. Bu eşik değerleri, bayat veya sağlam tahmini için kullanılmıştır. Örneğin 0,785 için hem 0,5 hem de 0,6 için “Bayat Elma” önerisi üretilir. Ama, bu derin öğrenme çıktısı 0.555 ise 0.5 için “Sağlam Elma”, diğer taraftan 0,6 eşik değeri için ise “Bayat Elma” tahmini üretilmiştir. 0,5 değerler için “Sağlam Elma” üretilir. Çizelgelerde 0,5 ve 0,6 eşik değeri için hangi eşik değerinin kullanılması gerektiği önerilecektir. Çizelgelerde yüzdelerle değerlerde ondalık basamak sayısı 2 seçilmiştir. Bu bölümdeki deneylerde, eğitim verisinden elde edilen modellerin test verisindeki sonuçlarına yer verilmiştir.

#### 4.3.1. Gelişmiş VGG16 – Model 1 için Sonuçlar

Çizelge 4.2, Model 1 için karmaşıklık matrisi sonuçlarını sunar.

Çizelge 4.2 Model 1 için karmaşıklık matrisi

Eşik Değeri	Kategori	Veri Sayısı	Bayat	Bayat	Bayat	Taze	Taze	Taze
			Elma (A)	Muz (B)	Portakal (C)	Elma (D)	Muz (E)	Portakal (F)
0.5	A	601	<b>601</b>	0	0	0	0	0
	B	530	80	<b>441</b>	0	1	4	0
	C	403	71	0	<b>329</b>	0	0	1
	D	395	29	0	0	<b>366</b>	0	0
	E	381	0	0	1	1	<b>379</b>	0
	F	388	49	5	0	29	5	<b>300</b>
0.6	A	601	<b>600</b>	0	0	1	0	0
	B	530	76	<b>443</b>	0	1	6	0
	C	403	69	0	<b>329</b>	0	0	1
	D	395	24	0	0	<b>371</b>	0	0
	E	381	0	0	0	1	<b>380</b>	0
	F	388	41	5	0	28	5	<b>309</b>

Çizelge 4.2, 601 bayat elmadan 0,5 eşik değeri için tümünün doğru tahmin edildiği görülmektedir. Eşik 0,6'ya çekildiğinde 601 bayat elmadan birinin taze diye tahmin ettiği görülmektedir. Fakat bu başarı var iken 395 taze elmadan 29 tanesinin yanlış tahmin edildiği görülür. Hatta 0,5 eşik değeri 530 bayat muzdan 80 tanesini bayat elma olarak tahmin ederken, 403 bayat portakaldan 71 bayat elma, 388 taze elmadan 49 tanesi bayat elma olarak tahmin edilmiştir. Teker teker durumların doğruluğunun yanı sıra asıl önemli olan nokta sistemde kesinlik ve duyarlılık üzerinden değerlendirmek olur. Çizelge 4.3, Model 1 için kesinlik, duyarlılık, f-Ölçümü ve sistem doğruluğunu verir.

Çizelge 4.3 Model 1 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk

Eşik Değeri	0.5			0.6		
	Kesinlik	Duyarlılık	f-Ölçümü	Kesinlik	Duyarlılık	f-Ölçümü
Bayat Elma	1.000	0.724	0.840	0.998	0.741	0.850
Bayat Muz	0.838	0.989	0.907	0.842	0.989	0.910
Bayat Portakal	0.820	0.997	0.900	0.825	1.000	0.904
Taze Elma	0.927	0.922	0.924	0.939	0.923	0.931
Taze Muz	0.995	0.977	0.986	0.997	0.972	0.984
Taze Portakal	0.773	0.997	0.871	0.796	0.997	0.885
Doğruluk	%89.75			%90.41		

Çizelge 4.3'te koyu işaretlenmiş bölümde doğru tahminleri verir. Bu durumlar tüm durumlara göre, 0,5 eşik değeri için %89,75 ve 0,6 eşik değeri için %90,41 doğruluk elde edilmiştir. Başka bir deyişle, 2.698 örnekten 0,5 ve 0,6 eşik değerleri için sırasıyla 2.416 ve 2.432 doğru tahmin yapılmıştır. f-Ölçümü üzerinden tahminler incelendiğinde eşik değeri 0,5 ve 0,6 için en başarılı tahmin 0,986 ve 0,984 ile taze muz tahminidir. En başarısız tahmin ise, her iki eşik değeri için sırasıyla 0,840 ve 0,850 ile bayat elma tahminidir. Her ne kadar kesinlik değeri her iki eşik değeri için sırasıyla 1,000 ve 0,998 gibi yüksek değerler olsa da, Duyarlılık değerleri de 0,724 ve 0,741 ile en kötü değerlere sahip tahmin durumu bayat elmadır. Bu aşamada, farklı modeller kurarak iyileştirmeler yapmaya çalışacağız.

#### 4.3.2. Gelişmiş VGG19 – Model 2 için Sonuçlar

Çizelge 4.4, Model 2 için karmaşıklık matrisi sonuçları verir.

Çizelge 4.4 Model 2 için karmaşıklık matrisi

Eşik Değeri	Kategori	Veri Sayısı	Bayat	Bayat	Bayat	Taze	Taze	Taze
			Elma (A)	Muz (B)	Portakal (C)	Elma (D)	Muz (E)	Portakal (F)
0.5	A	601	<b>601</b>	0	0	0	0	0
	B	530	0	<b>512</b>	1	0	5	0
	C	403	14	0	<b>386</b>	0	0	1
	D	395	8	0	0	<b>385</b>	0	0
	E	381	22	0	0	0	<b>359</b>	0
	F	388	5	0	0	1	0	<b>382</b>
0.6	A	601	<b>600</b>	0	0	1	0	0
	B	530	0	<b>511</b>	1	0	5	0
	C	403	13	0	<b>385</b>	0	0	1
	D	395	7	0	0	<b>386</b>	0	0
	E	381	12	0	0	0	<b>369</b>	0
	F	388	3	0	0	1	0	<b>384</b>

Çizelge 4.4'te hem 0,5 hem de 0,6 eşik değeri için önemli derecede iyileşmeler olduğu görülür. Özellikle köşegenlerdeki sonuçların sayısal olarak arttığı görülür. Bu noktada, f-Ölçümü ve doğruluk sonuçları incelenebilir (Çizelge 4.5).



Çizelge 4.5 Model 2 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk

Eşik Değeri	0.5			0.6		
	Kesinlik	Duyarlılık	f-Ölçümü	Kesinlik	Duyarlılık	f-Ölçümü
Bayat Elma	1.000	0.925	0.961	0.998	0.945	0.971
Bayat Muz	0.988	1.000	0.994	0.988	1.000	0.994
Bayat Portakal	0.963	0.997	0.980	0.965	0.997	0.981
Taze Elma	0.980	0.997	0.988	0.982	0.995	0.988
Taze Muz	0.942	0.986	0.964	0.969	0.987	0.977
Taze Portakal	0.985	0.997	0.991	0.990	0.997	0.994
<b>Doğruluk</b>	%97.87			%98.36		

Çizelge 4.5'e göre tüm durumlarda iyileşmeler olduğu görülmektedir. Örneğin Model 1'de en kötü tahmin olan bayat elma burada 0,5 ve 0,6 eşik değeri için sırasıyla 0,961 ve 0,971 gibi yüksek f-Ölçümü değerlerine kavuşmuştur. Eşik değeri değerini 0,6 olarak seçmenin f-Ölçümü değerlerini azda olsa iyileştirdiği görülmektedir. Sistemin genel doğruluğuna bakıldığında %98,36 ile eşik değerinin 0,6 seçilmesinin iyi olacağı görülmüştür.

#### 4.3.3. Gelişmiş VGG16 – Model 3 için Sonuçlar

Çizelge 4.6 Model 3 için karmaşıklık matrisini ve Çizelge 7'de kesinlik, duyarlılık, f-Ölçümü ve doğruluk sonuçlarını verir.

Çizelge 4.6 Model 3 için karmaşıklık matrisi

Eşik Değeri	Kategori	Veri Sayısı	Bayat	Bayat	Bayat	Taze	Taze	Taze
			Elma (A)	Muz (B)	Portakal (C)	Elma (D)	Muz (E)	Portakal (F)
0.5	A	601	332	187	0	82	0	0
	B	530	0	526	1	0	4	0
	C	403	149	186	28	33	0	7
	D	395	6	3	0	386	0	0
	E	381	0	59	0	0	322	0
	F	388	78	35	1	214	9	51
0.6	A	601	332	187	0	82	0	0
	B	530	0	526	1	0	4	0
	C	403	149	186	28	33	0	7
	D	395	6	3	0	386	0	0
	E	381	0	59	0	0	322	0
	F	388	78	35	1	214	9	51

Çizelge 4.7 Model 3 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk

Eşik Değeri	0.5			0.6		
	Kesinlik	Duyarlılık	f-Ölçümü	Kesinlik	Duyarlılık	f-Ölçümü
Bayat Elma	0.552	0.588	0.569	0.552	0.588	0.569
Bayat Muz	0.991	0.528	0.689	0.992	0.528	0.689
Bayat Portakal	0.069	0.933	0.129	0.069	0.933	0.129
Taze Elma	0.977	0.540	0.695	0.977	0.540	0.695
Taze Muz	0.845	0.961	0.899	0.845	0.961	0.899
Taze Portakal	0.131	0.879	0.229	0.131	0.879	0.229
Doğruluk	%60.95			%60.95		

Çizelge 4.6 ve 4.7 incelendiğinde Model 3'ün sonuçları Model 1 ve Model 2'ye göre çok daha kötüdür. Bayat Portakal, 0,5 ve 0,6 eşik değeri için 0,129 f-Ölçümü değerleri ile en kötü tahmin sonuçlarına sahip durumdur. Diğer bir kötü tahmin taze portakaldır. Model 3 genel olarak portakalları çok kötü tahmin etmiştir. Burada en iyi tahmin durumu taze muz içindir. Doğruluk değerleri %60 civarı düşmüştür. Model 4 ile bu durumları iyileştirmeye çalışacağız.

#### 4.3.4. Gelişmiş VGG19 – Model 4 için Sonuçlar

Çizelge 4.8 ve 4.9, Model 4'ün sonuçlarını sunar.

Çizelge 4.8 Model 4 için karmaşıklık matrisi

Eşik Değeri	Kategori	Veri Sayısı	Bayat	Bayat	Bayat	Taze	Taze	Taze
			Elma (A)	Muz (B)	Portakal (C)	Elma (D)	Muz (E)	Portakal (F)
0.5	A	601	<b>574</b>	3	6	18	0	0
	B	530	5	<b>490</b>	16	0	18	1
	C	403	312	3	<b>75</b>	12	0	1
	D	395	230	0	0	<b>165</b>	0	0
	E	381	0	166	0	2	<b>213</b>	0
	F	388	326	1	11	43	3	<b>4</b>
0.6	A	601	<b>574</b>	3	6	18	0	0
	B	530	5	<b>490</b>	16	0	18	1
	C	403	312	3	<b>75</b>	12	0	1
	D	395	230	0	0	<b>165</b>	0	0
	E	381	0	166	0	2	<b>213</b>	0
	F	388	326	1	11	42	3	<b>4</b>

Çizelge 4.9 Model 4 için kesinlik, duyarlılık, f-Ölçümü ve doğruluk

Eşik Değeri	0.5			0.6		
	Kesinlik	Duyarlılık	f-Ölçümü	Kesinlik	Duyarlılık	f-Ölçümü
<b>Bayat Elma</b>	0.955	0.397	0.561	0.955	0.397	0.561
<b>Bayat Muz</b>	0.925	0.739	0.821	0.925	0.739	0.821
<b>Bayat Portakal</b>	0.186	0.694	0.294	0.186	0.694	0.294
<b>Taze Elma</b>	0.418	0.688	0.520	0.418	0.688	0.520
<b>Taze Muz</b>	0.559	0.910	0.693	0.559	0.910	0.693
<b>Taze Portakal</b>	0.010	0.667	0.020	0.010	0.667	0.020
<b>Doğruluk</b>	%56.38			%56.38		

Çizelge 4.8 ve 4.9'a göre, Model 4 ne yazık ki bir iyileşme sağlayamamıştır. Model 3'teki bayat portakal için f-Ölçüm değeri 0,129 iken Model 4'te bu durum 0,294 çıkarılmıştır. Hatta Bayat Muz tahmini de f-Ölçümü Model 3'te 0,689 iken Model-4'te 0,821 gibi daha iyi bir duruma gelmiştir. Ancak, bu iyileşmelere rağmen diğer tüm durumların f-Ölçüm değerleri kötüleşmiştir.

#### 4.3.5. Tartışma

Tüm Modeller için istatistikler incelendiğinde aşağıdaki sonuçlar çıkmaktadır:

- Bayat elma için en iyi f-Ölçümü sonuçları 0,5 eşik değeri ile Model 2(0,961), 0,6 eşik değeri ile Model 2 (0,971) vermiştir.
- Bayat muz için en iyi f-Ölçümü sonuçları 0,5 eşik değeri ve 0,6 eşik değeri ile Model 2 (0,994) vermiştir.
- Bayat portakal için en iyi f-Ölçümü sonucu 0,5 eşik değeri ile Model 2(0,980) vermiştir.
- Taze elma için en iyi f-Ölçümü sonucunu 0,5 eşik değeri ve 0,6 eşik değeri ile Model 2(0,988) vermiştir.
- Taze muz için en iyi sonucu 0,5 eşik değeri ile Model 1 (0,986) vermiştir.
- Taze portakal için en iyi sonucu 0,6 eşik değeri ile Model 2 (0,994) vermiştir.

F-Ölçümü üzerinden modellerin tek tek, en başarılı olduğu ve en başarısız olduğu veri türünü inceleyecek olursak:

- Model-1 en yüksek f-ölçümünü 0,5 eşik değeri ile 0,986 değerini elde ettiği taze muzdan almıştır. En düşük f-ölçüm değerini ise 0,840 değeri ile 0,5 eşik değerine sahip bayat elmadan elde etmiştir. Yani model-1 taze muz konusunda diğer veri türlerinden daha başarılı iken, bayat elma konusunda diğer veri türlerinden daha başarısızdır.

- Model-2 en yüksek f-ölçümünü 0,994 değeri ile 0,5 eşik değerine sahip bayat muz, 0,6 eşik değerine sahip bayat muz ve taze portakaldan elde etmiştir. En düşük f-ölçümünü 0,961 değeri ile 0,5 eşik değeri ile bayat elmadan elde etmiştir. Yani model-1 bayat muz ve taze portakal veri türünde diğer veri türlerinden daha başarılı iken, bayat elma veri türünde diğer veri türlerinden daha başarısızdır.

- Model-3 en yüksek f-ölçümünü 0,899 değeri ile 0,5 eşik değeri ve 0,6 eşik değeri ile taze muzdan elde etmiştir. En düşük f-ölçümünü 0,129 değeri ile 0,5 eşik değeri ve 0,6 eşik değeri ile bayat portakaldan elde etmiştir. Yani model-3 taze muz veri türünde diğer veri türlerinden daha başarılı iken, bayat portakal veri türünde diğer veri türlerinden daha başarısızdır.

- Model-4 en yüksek f-ölçümünü 0,821 değeri ile 0,5 eşik değeri ve 0,6 eşik değeri ile bayat muzdan elde etmiştir. En düşük f-ölçümünü 0,020 değeri ile 0,5 eşik değeri ve 0,6 eşik değeri ile taze portakaldan elde etmiştir. Yani model-4 bayat muz veri türünde diğer veri türlerinden daha başarılı iken, taze portakal veri türünde diğer veri türlerinden daha başarısızdır.

Modellerin, test verisinden elde edilen doğruluk değerleri incelendiğinde, en yüksek doğruluk değerinin %97,87 ile 0,5 eşik değeri ile Model-2, en düşük doğruluk değerinin 0,5 eşik değeri ve 0,6 eşik değeri ile Model-4'ten elde edildiği gözlenmektedir.

## 5. SONUÇLAR

Bu çalışmada meyvelerin taze/bayat olarak sınıflandırılması üzerinde derin öğrenme modelleri kullanılmış ve birbiri ile kıyaslanmıştır. Meyve olarak elma, portakal ve muz seçilmiştir. VGG16 ve VGG19 modelleri üzerinde geliştirmeler yapılarak 4 model bu veri setine uygulanmış ve sonuçları üzerinden çıkarımlarda bulunulmuştur.

Modellerden elde edilen testler sonucunda doğruluk değerleri karşılaştırıldığında:

- VGG16 ile geliştirilen 0,5 eşik değerine sahip Model-1: 89,75
- VGG16 ile geliştirilen 0,6 eşik değerine sahip Model-1: 90,41
- VGG19 ile geliştirilen 0,5 eşik değerine sahip Model-2: 97,87
- VGG19 ile geliştirilen 0,6 eşik değerine sahip Model-2: 98,36
- VGG16 ile geliştirilen 0,5 eşik değerine sahip Model-3: 60,95
- VGG16 ile geliştirilen 0,6 eşik değerine sahip Model-3: 60,95
- VGG19 ile geliştirilen 0,5 eşik değerine sahip Model-4: 56,38
- VGG19 ile geliştirilen 0,6 eşik değerine sahip Model-4: 56,38

Modellerin yukarıdaki doğruluk değerleri incelendiğinde en düşük doğruluk değerine 0,5 ve 0,6 eşik değeri ile Model-3'te, en yüksek doğruluk modeline 0,6 eşik değeri ile Model-2'de elde edildiği gözlenmiştir. Model-2'de en yüksek f-Ölçüm değeri 0,5 eşik değeri de 0,994 ile bayat muzda, 0,6 eşik değeri de 0,994 ile bayat muz ve taze portakaldan elde edilmiştir.

Gelecekte bu sorunu çözebilmek ve en ideal sonuca yaklaştıktan sonra bu modeli farklı ürün gruplarına uygulayarak yaygınlaştırmayı hedefliyoruz. Çalışılacak model, Model-2 ile devam edilecektir. Öncelikle farklı meyveler üzerinde çalışma yapıp ardından sebzeler için çalışma yapılması hedeflenmektedir. Toprakta yetiştirilen besin tazeliği günümüzde hem sağlık, hem ekonomi hem de çevre açısından önemli önceliğe sahiptir. Bu uygulamayı geliştirip, farklı besin grupları ile çalışmayı bitirdikten sonra günlük yaşamımıza adapte edilmesi planlanmaktadır.

## KAYNAKLAR

Buluş, E. (2021). Gender Determination from Pictures with CNN models, 6th International Conference on Computer Science and Engineering Conference, 310-313

Egemen A, Demir N., Akşit S., Kusin N., Sözbilen M. ve Solak İ. (2001). Besin Zehirlenmeleri: Sağlıksız Beslenmenin bir Göstergesi, Beslenme ve Diyet Dergisi, 16-2

Yeşil O., Akoğlu H., Onur Ö. ve Güneysel Ö. (2008). Acil Servise Başvuran Zehirlenme Olgularının Geriye Dönük Analizi, Marmara Medical Journal, 21(1); 026-032

Yu X., Tang L., Wu X. ve Lu H. (2018). Nondestructive Freshness Discriminating of Shrimp Using Visible/Near-Infrared Hyperspectral Imaging Technique and Deep Learning Algorithm, Food Anal. Methods, 11:768-780

Kayaalp K. ve Metlek S. (2020). Classification of Robust and Rotten Apples by Deep Learning Algorithm, Sakarya University Journal of Computer and Information Sciences, Vol.3 No.2

Moon E., Kim Y., Xu Y., Na Y., Giaccia A. ve Lee J. (2020). Evaluation of Salmon, Tuna, and Beef Freshness Using a Portable Spectrometer, Sensors

Ananthanarayana T., Ptucha R. ve Kelly S. (2020). Deep Learning based Fruit Freshness Classification and Detection with CMOS Image sensors and Edge processors, Society for Imaging Science and Technology

Fu Y. (2020). Fruit Freshness Grading Using Deep Learning, A thesis submitted to the Auckland University of Technology in partial fulfillment of the requirements for the degree of Master of Computer and Information Sciences (MCIS)

Valentino F., Cenggoro T. ve Pardamean B. (2021). A Design of Deep Learning Experimentation for Fruit Freshness Detection, IOP Conf. Ser.: Earth Environ. Sci. 794 012110

Rawat S. (2015). Food Spoilage: Microorganisms and their prevention, Asian Journal of Plant Science and Research, 5(4):47-56

Coşkun M., Özal Y., Uçar A. ve Demir Y. (2017). An Overview of Popular Deep Learning Methods, European Journal of Technic, Vol 7, Number 2

Yapıcı M., Topaloğlu N. (2021). Performance Comparison of Deep Learning Frameworks, Computers and Informatics, Volume 1 Issue 1, 2757-8259, Research Article

Çelik Ö., Altunaydın S. (2018). A Research on Machine Learning Methods and Its Applications, Journal of Educational Technology & Online Learning, Volume 1 Issue3

Aslan Z. (2018). On The Use of Deep Learning Methods on Medical Images, The International Journal of Energy & Engineering Sciences IJEES-V3-12

AI Wiki (2019). Accuracy and loss, <https://docs.paperspace.com/machine-learning/wiki/accuracy-and-loss>

Jordan J.B., Chloe M.B., Luis M., Anikó E. ve Diego R.F. (2022). Fruit quality and defect image classification with conditional GAN data augmentation. Scientia Horticulturae, Volume 293

Great Learning Team (2021). Introduction to Image Processing/What is Image Processing?. <https://www.mygreatlearning.com/blog/introduction-to-image-processing-what-is-image-processing/>

Sonka M, Hlavac V., Boyle R. (2008). Image Processing, Analysis, and Machine Vision. 3rd ed. Toronto: Thomson Learning. ISBN 0-497-08252-X. OCLC 123776599

Ionica, M. Horea, David G. (1 Ocak 2015). The Movidius Myriad Architecture's Potential for Scientific Computing. IEEE Micro. 35 (1): 6-14. Doi:10.1109/mm.2015.4. ISSN 0272-1732

Joshi N. (Arşivlenme: 27 Haziran 2019, Erişim: 24 Mayıs 2021). The Present and Future of Computer Vision. Forbes

Huilgol P. (2020). Precision vs Recall – An Intuitive Guide for Every Machine Learning Person. Analytics Vidhya WebSite

Google Machine Learning Crash Course (2020). Classification: Precision and Recall. Developers.google.com, machine learning crash course

Pandey, A., Alok, A., Lakhwani, D., Singh, J., Asif, M. H., & Trivedi, P. K. (2016). GenomeWide Expression Analysis and Metabolite Profiling Elucidate Transcriptional



Regulation of Flavonoid Biosynthesis and Modulation Under Abiotic Stresses in Banana. *Scientific Reports*, 6, 313-321.

Mahaman B., Maliappis M., Passamc H., Sideridis A., Zorkadis V., & Koumpouro Y. (2004). Image Processing for Distance Diagnosis in Pest Management. *Computers and Electronics in Agriculture*, 5(5), 193-213.

Brosnan T., & Sun D.-W. (2002). Inspection and Grading of Agricultural and Food Products by Computer Vision Systems: A Review. *Computers and Electronics in Agriculture*, 36(2), 193-213.

Tewari V. K., Kumar A. A. , Kumar S. P., Pandey V., & Chandel N. S. (2013). Estimation of Plant Nitrogen Content Using Digital Image Processing. *International Commission of Agricultural and Biosystems Engineerin*, 15(2), 78-86.

Cunha J. B. (2003). Application of Image Processing Techniques in the Characterization of Plant Leafs. *IEEE International Symposium on Industrial Electronics*, 1, 612-616.

Özyildiz E., Krahnst-over N., & Sharma R. (2002). Adaptive Texture Andcolor Segmentation for Tracking Moving Objects. *Pattern Recognition*, 2013-2029

Barrett D. M., Beaulieu J. C., & Shewfelt R. (2010). Color, Flavor, Texture, and Nutritional Quality of Fresh-Cut Fruits and Vegetables: Desirable Levels, Instrumental and Sensory Measurement, and the Effects of Processing. *Critical Reviews in Food Science and Nutrition*, 50, 369-389.

Mitcham B., Cantwell M., & Kader A. (1996). Methods for Determining Quality of Fresh Commodities. *Perishables Handling Newsletter*, 85, 1-5.

Sindhi K., Pandya J., & Vegad S. (2016). Quality Evaluation of Apple Fruit: A Survey. *International Journal of Computer Applications*, 136, 32-36.

Hartman J. (2010). Apple Fruit Diseases Appearing at Harvest. *Plant Pathology Fact Sheet*, 1-5.

Péneau S., Linke A., Escher F., & Nuessli J. (2009). Freshness of Fruits and Vegetables: Consumer Language and Perception. *British Food Journal*, 111(3), 243-256.

Moallem P., Serajoddin A., & Pourghassem H. (2017). Computer Vision-Based Apple Grading for Golden Delicious Apples Based on Surface Features. 33-40.

Arakeri M., & Lakshmana P. (2016). Computer Vision Based Fruit Grading System for Quality Evaluation of Tomato in Agriculture Industry. Proceedings of the International Conference on Communication, Computing and Virtualization, Mumbai, India;, 79(2016), 426-433.

Bresilla K., Perulli G. D., Boini A., Morandi B., Grappadelli L. C., & Manfrini L. (2019). Single-Shot Convolution Neural Networks for Real-Time Fruit Detection Within the Tree. *Frontiers in Plant Science*, 10, pp. 611-623. doi:10.3389/fpls.2019.00611

Redmon J., Divvala S., Girshick R., & Farhadi A. (2016 ). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition* , 779-788.

Zeng G. (2017). Fruit and Vegetables Classification System Using Image Saliency and Convolutional Neural Network. *Proceedings of the Technology and Mechatronics Engineering Conference*, 324-331. doi:10.1109/ITOEC.2017.8122370

Mureşan H. &. (2018). Fruit Recognition from Images Using Deep Learning. *Acta Universitatis Sapientiae, Informatica.*, 1-, 26-42. doi:10.2478/ausi-2018-0002

Nashat A. A., & Hassan N. M. (2018). Automatic Segmentation and Classification of Olive Fruits Batches Based on Discrete Wavelet Transform and Visual Perceptual Texture Features. *International Journal of Wavelets, Multiresolution and Information Processing*, 16(1), 185-193.

Prakash K. K. (2018). Spoilage Detection in Raspberry Fruit Based on Spectral Imaging Using Convolutional Neural Network. *Dissertation M.Sc. in Computing (Data Analytics)*. doi:10.21427/D7D23R