

T.C.  
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MEKATRONİK MÜHENDİSLİĞİ

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME ve MAKİNE ÖĞRENMESİ  
KULLANARAK ELMALARDA ÇÜRÜK TESPİTİ

ONUR CÖMERT

TOKAT  
Aralık - 2019

Her hakkı saklıdır



**Bu tez çalışması;**

**Tokat Gaziosmanpaşa Üniversitesi Bilimsel Araştırma Projeleri tarafından 2016/28 numaralı proje ile desteklenmiştir.**

**Onur CÖMERT** tarafından hazırlanan “**Görüntü İşleme ve Makine Öğrenmesi Kullanarak Elmalarda Çürük Tespiti**” adlı tez çalışmasının savunma sınavı 5 ARALIK 2019 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü MEKATRONİK MÜHENDİSLİĞİ Anabilim dalında DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Doç. Dr. Mahmut HEKİM

Üye

Dr. Öğr. Üyesi Cem EMEKSİZ

Tokat Gaziosmanpaşa Üniversitesi

Üye

Dr. Öğr. Üyesi Bülent TURAN

Tokat Gaziosmanpaşa Üniversitesi

Üye

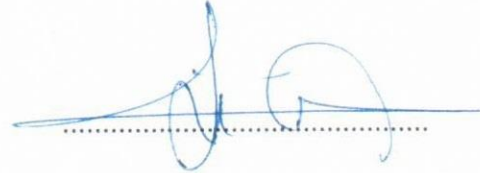
Dr. Öğr. Üyesi Canan ORAL

Amasya Üniversitesi

Üye

Dr. Öğr. Üyesi İsmail İŞERİ

Ondokuz Mayıs Üniversitesi



ONAY



Prof. Dr. Çetin ÇEKİÇ  
Fen Bilimleri Enstitüsü Müdürü

29.12.2019

## **TEZ BEYANI**

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdiği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

**ONUR CÖMERT**

**5 Aralık 2019**

## ÖZET

### DOKTORA TEZİ

## GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENMESİ KULLANARAK ELMALARDA ÇÜRÜK TESPİTİ

ONUR CÖMERT

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

MEKATRONİK MÜHENDİSLİĞİ

(TEZ DANIŞMANI: DOÇ. DR. MAHMUT HEKİM)

Bu tez çalışmasında, içerisinde bir yakın kızılötesi (NIR) kamera barındıran görüntü toplama platformu ile elde edilen elma görüntüleri evrişimsel sinir ağı (CNN) modeli tarafından desteklenen yapay arı kolonisi (ABC) ve parçacık sürüsü optimizasyonu (PSO) algoritmalarına dayalı bir hibrit model kullanarak çürük ve sağlıklı olarak sınıflandırılmıştır. Önerilen model görüntü elde etme, görüntü ön işleme, anatomik bölgelerin bölütlenmesi ve elma görüntülerinde çürük alanların tespiti aşamalarını içermektedir. Görüntü toplama platformu kullanılarak 100 çürük ve 100 sağlıklı olan 200 elmadan farklı açılardan toplam 1200 görüntü alınmıştır. Tespit ve sınıflandırma başarısını arttırmak için, ön işleme aşamasındaki görüntülere sırasıyla adaptif histogram eşitleme, kenar algılama ve şekilsel işlemler uygulanmıştır. İlk olarak, görüntülerin sap-çanak anatomik bölgelerini bölütlemek ve gözardı etmek için, CNN modeli önceden işlenmiş görüntüler kullanılarak eğitilmiştir. Eğitilen bu model ile sap-çanak bölgeleri görüntüden çıkarılmıştır. İkinci aşamada, sap-çanak bölgeleri gözardı edilen görüntüler üzerinde ABC / PSO-tabanlı yinelemeli eşikleme yaklaşımı ile bir eşik değeri saptanmış ve bu eşik değeri kullanılarak sap-çanak anatomik bölgeleri olmayan görüntülerdeki çürükler tespit edilmiştir. Önerilen yaklaşımların sınıflandırma başarısını göstermek için, aynı sınıflandırma deneyleri, ABC ve PSO yaklaşımı olmadan doğrudan Faster R-CNN modeli kullanılarak yeniden uygulanmıştır. Deneysel sonuçlar, tezde önerilen bu hibrit modelin, ABC ve PSO tabanlı yinelemeli eşikleme yaklaşımlarının kullanılmadığı Faster R-CNN modelinden daha başarılı olduğunu göstermiştir.

2019, 90 SAYFA

**ANAHTAR KELİMELELER:** Çürük elma, Sap-çanak, Evrişimsel sinir ağı, Yapay Arı kolonisi, Parçacık sürü optimizasyonu

## **ABSTRACT**

### **DOCTORATE THESIS**

#### **THE DETECTION OF BRUISES ON APPLES USING MACHINE LEARNING AND IMAGE PROCESSING**

**ONUR CÖMERT**

**TOKAT GAZIOSMANPASA UNIVERSITY**

**GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

**DEPARTMENT OF MECHATRONICS ENGINEERING**

**(SUPERVISOR:;) ASSOC. PROF. DR. MAHMUT HEKİM**

In this thesis, the apple images taken by using the image acquisition platform with near-infrared (NIR) camera were classified as bruised and healthy using a hybrid model based on artificial bee colony (ABC) and particle swarm optimization (PSO) iterative thresholding algorithms supported by a convolutional neural network (CNN) model. The proposed model includes image acquisition, image pre-processing, the segmentation of anatomical regions to be discarded and the detection of bruised areas on the apple images. A total of 1200 images at different angles were taken from 200 apples those of which were 100 bruised and 100 healthy by using the image acquisition platform. In order to increase the success of detection and classification, adaptive histogram equalization (AHE), edge detection and morphological operations were applied to the images in the pre-processing stage, respectively. First, in order to segment and discard the stem-calyx anatomical regions of the images, the CNN model was trained by using the preprocessed images. With this model, the stem-calyx regions were removed from the image. Second, the threshold value was determined by means of ABC/PSO-based iterative thresholding approach on the images whose stem-calyx regions were discarded, and then the bruised areas on the images with no stem-calyx anatomical regions were detected by using the determined threshold value. In order to illustrate the classification success of the proposed approaches, the same classification experiments were reimplemented by directly using Faster R-CNN model alone on the preprocessed images with no ABC and PSO approaches. Experimental results showed that this hybrid model proposed in the thesis was more successful than the Faster R-CNN model in which ABC and PSO-based iterative threshold approaches were not used.

2019, 90 PAGE

**KEYWORDS:** Bruised apple, Stem-calyx, Convolutional neural network, Artificial bee colony, Particle swarm optimization

## ÖNSÖZ

Doktora çalışmam boyunca, her türlü konuda yardımlarını esirgemeyen, değerli fikirleriyle çalışmama yön veren kıymetli hocam Sayın Doç. Dr. Mahmut HEKİM'e sonsuz teşekkür ederim.

Lisans döneminden itibaren beraberce yol aldığım ve tez çalışmamda bana her zaman destek olan sevgili dostum Kemal ADEM'e ve tezimin bu aşamaya gelmesinde katkılarından ötürü Dr. Öğr. Üyesi Cem EMEKSİZ ve Dr. Öğr. Üyesi Bülent TURAN'a teşekkürlerimi sunarım.

Bugünlere gelmemde maddi, manevi desteği olan babam Salih CÖMERT ve annem Güllü CÖMERT'e, tez çalışmalarım sırasında manevi desteğini bir an olsun esirgemeyen ve her zaman yanımda olan eşim Canan CÖMERT ve çocuklarım Azra, Ece Güneş ve Salih Bulut'a teşekkürlerimi bir borç bilirim.

**ONUR CÖMERT**

**5 Aralık 2019**

# İÇİNDEKİLER

## Sayfa

ÖZET .....	i
ABSTRACT.....	ii
ÖNSÖZ .....	iii
İÇİNDEKİLER .....	iv
SİMGELER VE KISALTMALAR .....	vi
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ .....	ix
1. GİRİŞ .....	1
2. KURAMSAL TEMELLER .....	4
2.1. Genel Yöntemler .....	4
2.1.1. CNN kullanılan çalışmalar.....	4
2.1.2. Optimizasyon algoritması kullanılan çalışmalar.....	5
2.2. Elma Sınıflandırması Yapılan Çalışmalar .....	6
2.3. Elmalarda Sap-Çanak Tespiti Yapılan Çalışmalar .....	8
2.4. Elmalarda Çürük Tespiti Yapılan Çalışmalar .....	8
3. MATERYAL VE YÖNTEM .....	13
3.1. Görüntülerin Elde Edilmesi.....	13
3.1.1. Görüntü alma ve işleme sistemi .....	14
3.2. Sayısal Görüntü İşleme .....	20
3.2.1. Sayısal görüntü işlemenin temel basamakları.....	21
3.2.2. Bölütleme .....	22
3.2.3. Şekilsel işlemler .....	30
3.2.4. Görüntünün türevi ve kenar bulucular .....	37
3.2.5. Laplasyan (ikinci türev) tabanlı kenar bulucular .....	40
3.2.6. Genel histogram eşitleme.....	41
3.2.7. Adaptif histogram eşitleme .....	42
3.3. Renkli Görüntü İşleme .....	43
3.3.1. Renk .....	43
3.3.2. Renk Uzayları .....	44



3.4. Harris Köşe Algılama Algoritması.....	46
3.5. Bresenham Çizgi Algoritması .....	47
3.6. Çok Katmanlı Algılayıcı Sinir Ağı.....	48
3.7. CNN Modeli .....	51
3.8. Faster R-CNN.....	52
3.9. Doğrusal Regresyon .....	54
3.10. ABC-tabanlı yinelemeli eşikleme yaklaşımı .....	55
3.11. PSO-tabanlı yinelemeli eşikleme yaklaşımı .....	57
4. BULGULAR VE TARTIŞMA .....	59
4.1. Elmalarda Sap ve Çanak Tespiti .....	60
4.1.1. Yöntem.....	60
4.1.2. Sonuç.....	62
4.2. Faster R-CNN ile Elmalarda Çürük Tespiti .....	62
4.2.1. Deneyler .....	64
4.2.2. Sonuç ve tartışma .....	65
4.3. CNN Modeli ve ABC / PSO-Tabanlı Yinelemeli Eşiklemeyi Kullanarak Çürük Tespiti .....	66
4.3.1. Ön işleme tekniklerini kullanarak görüntüyü geliştirme.....	66
4.3.2. CNN modeli kullanılarak sap-çanak anatomik bölgelerinin tespiti .....	67
4.3.3. ABC/PSO-tabanlı yinelemeli eşikleme kullanarak çürük bölgelerin tespiti.....	68
4.3.4. Deneyler .....	69
5. SONUÇ .....	79
6. KAYNAKLAR .....	80
7. ÖZGEÇMİŞ .....	86

## SİMGELER VE KISALTMALAR

### Simgeler

### Açıklama

$\ominus$	Aşındırma işleci
$\oplus$	Genişletme işleci
$\varphi$	Aktivasyon fonksiyonu
$w$	Ağırlık katsayısı
$\emptyset$	Haritalama fonksiyonu

### Kısaltmalar

### Açıklama

ABC	Yapay Arı Kolonisi (Artificial Bee Colony)
AHE	Adaptif Histogram Eşitleme (Adaptive Histogram Equalization)
ANN	Yapay Sinir Ağı (Artificial Neural Network)
ASM	Asimetrik İkinci Fark (Asymmetric Second Difference)
BPI	Mavi Piksel İndeksi (Blue Pixels Index)
CCD	Yüklenme İliştirilmiş Aygıt (Charge Coupled Device)
CIE	Uluslararası Aydınlatma Komisyonu (Commission Internationale De L'éclairage)
CNN	Evrişimsel Sinir Ağı (Convolutional Neural Network)
ÇTA	Çanak Tespiti Algoritması
DA	Veri Çoğaltma (Data Augmentation)
Faster R-CNN	Hızlı Bölge-Tabanlı CNN (Fast Region-based Convolutional Neural Network)
FFA	Ateşböceği Algoritması (Firefly Algorithm)
FN	Yanlış Negatif (False Negative)
FNN	Bulanık En Yakın Komşu (Fuzzy Nearest Neighbor)
FP	Yanlış Pozitif (False Positive)
HSI	Ton Doygunluk Yoğunluğu (Hue Saturation Intensity)
HSV	Ton Doygunluk Değeri (Hue Saturation Value)

IHLS	İyileştirilmiş Ton Parlaklık Doygunluğu (Improved Hue Luminance Saturation)
k-NN	k-En Yakın Komşuluk (k- Nearest Neighbors)
LAT	Yerel Adaptif Eşikleme (Locally Adaptive Threshold)
LDA	Doğrusal Ayırt Edici Analizi (Linear Discriminant)
LDC	Doğrusal Ayırt Edici Sınıflayıcı (Linear Discriminant Classifier)
LED	Işık Yayan Diyot (Light Emitter Diode)
LR	Doğrusal Regresyon (Linear Regression)
LSM	En Küçük Kareler Yöntemi (Least Squares Method)
LWPF	Uzun Dalga Geçiren Filtre (Long Pass Filter)
MLPNN	Çok Katmanlı Algılayıcı Sinir Ağı (Multilayer Perceptron Neural Network)
MSE	Ortalama Karesel Hata (Minimum Square Error)
NB	Naive Bayes
PCA	Temel Bileşen Analizi (Principal Components Analysis)
PLS	Kısmi En Küçük Kareler (Partial Least Squares)
PLSDA	Kısmi En Küçük Kare Ayırt Edici Analizi (Partial Least Square Discriminant Analysis)
PSNR	Tepe Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio)
PSO	Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)
RGB	Kırmızı Yeşil Mavi (Red Green Blue)
RMSE	Ortalama Karesel Hata Karekökü (Root Minimum Square Error)
RPN	Bölge Öneri Ağı (Region Proposal Network)
SDA	Kademeli Ayırt Edici Analizi (Stepwise Discrimination Analysis)
SIRI	Yapılandırılmış Aydınlatma Yansıtma Görüntüleme (Structured Reflection Imaging)
SSI	Yapısal Benzerlik İndeksi (Structural Similarity Index)
STA	Sap Tespiti Algoritması
TCC	Toplam Doğru Sınıflandırma (Total Correct Classification)
TN	Doğru Negatif (True Negative)
TP	Doğru Pozitif (True Positive)
TSE	Türkiye Standartları Enstitüsü

## ŞEKİL LİSTESİ

<b><u>Şekil</u></b>	<b><u>Sayfa</u></b>
Şekil 3.1. Sağlıklı ve çürük elma görüntüleri .....	13
Şekil 3.2. Görüntü alma sisteminin genel yapısı .....	14
Şekil 3.3. Platformun sahne kısmı .....	19
Şekil 3.4. Platformun üstten görünümü .....	19
Şekil 3.5. Platformun önden görünümü .....	20
Şekil 3.6. Görüntü işlemenin temel basamakları .....	21
Şekil 3.7. Gri tonlamalı görüntü üzerinde eşikleme işlemi.....	24
Şekil 3.8. RGB görüntü üzerinde eşikleme işlemi.....	25
Şekil 3.9. LAT yöntemi örneği .....	28
Şekil 3.10. Fit olma durumu .....	31
Şekil 3.11. Hit olma durumu.....	31
Şekil 3.12. Görüntü üzerinde aşındırma işlemi.....	33
Şekil 3.13. Görüntü üzerinde genişletme işlemi .....	34
Şekil 3.14. Görüntü üzerinde açma işlemi .....	35
Şekil 3.15. Görüntü üzerinde kapama işlemi .....	36
Şekil 3.16. Görüntü üzerinde doldurma işlemi .....	37
Şekil 3.17. Yönlü kenar bulucular için filtre tasarımları .....	38
Şekil 3.18. Yönsüz kenar bulucular için filtre tasarımları .....	39
Şekil 3.19. Prewitt kenar bulma örneği.....	40
Şekil 3.20. Histogram eşitleme örneği.....	42
Şekil 3.21. AHE uygulaması.....	43
Şekil 3.22. Görülebilir renklerin dalga boyları.....	44
Şekil 3.23. Görülebilir renk alanları (Bastı, 2005) .....	44
Şekil 3.24. Renk uzayları .....	45
Şekil 3.25. RGB renk uzayı .....	46
Şekil 3.26. Bresenham'ın çizgi algoritması kullanılıncaya ortaya çıkan bir çizgi (Anonim, 2019) .....	48
Şekil 3.27. Nöronun McCulloch-Pitts modeli.....	48
Şekil 3.28. Bir MLPNN'nin yapısı .....	50
Şekil 3.29. CNN mimarisinin genel yapısı .....	52
Şekil 3.30. Çalışmada kullanılan Faster R-CNN mimarisi (Yang ve ark., 2017).....	53
Şekil 4.1. Önerilen yöntemin genel adımları .....	59
Şekil 4.2. STA ile sap tespiti.....	61
Şekil 4.3. ÇTA ile çanak tespiti .....	61
Şekil 4.4. Çürük tespitinin adımları .....	62
Şekil 4.5. Önışlem adımları .....	63
Şekil 4.6. Etiketlenmiş test sonuçları.....	65
Şekil 4.7. Önerilen yaklaşımın usulüne ilişkin adımları.....	66
Şekil 4.8. Parçacıkların görüntüdeki pikseller üzerindeki başlangıç konumları.....	69
Şekil 4.9. Elma görüntülerinde CNN modeli kullanılarak anatomik alanların tespiti ....	71
Şekil 4.10. Elma görüntülerinde Otsu, PSO ve ABC-tabanlı yinelemeli eşikleme yaklaşımları kullanılarak elde edilen sonuçlar.....	74
Şekil 4.11. PSO ve ABC-tabanlı yinelemeli eşikleme yaklaşımlarının ROC eğrileri ....	76

## ÇİZELGE LİSTESİ

<b><u>Çizelge</u></b>	<b><u>Sayfa</u></b>
Çizelge 3.1. Teledyne DALSA Genie Nano NIR kamera özellikleri .....	15
Çizelge 3.2. Fujinon HF16HA-1B lens özellikleri .....	16
Çizelge 3.3. Bazı ışık kaynaklarının dalga boyu aralıkları (Anonim, 2017b) .....	17
Çizelge 3.4. Bazı LED'lerin dalga boyu aralık değerleri (Anonim, 2012).....	18
Çizelge 3.5. Bilgisayar teknik özellikleri.....	20
Çizelge 3.6. Tek boyutlu bir fonksiyon ikinci derece türevi .....	38
Çizelge 4.1. Çalışmada kullanılan modelin karışıklık matrisi .....	64
Çizelge 4.2. Çalışmada kullanılan CNN modelleri.....	67
Çizelge 4.3. ABC ve PSO-tabanlı yinelemeli eşikleme yaklaşımlarının karışıklık matrisi .....	75
Çizelge 4.4. ABC ve PSO-tabanlı eşikleme yaklaşımlarının duyarlılık, özgüllük ve TCC oranları .....	76
Çizelge 4.5. Çürük elmanın tespitinde literatür çalışmaları ile sunulan yaklaşımların karşılaştırılması .....	77

## 1. GİRİŞ

Ülkemiz ekonomisi ve gelişimi açısından tarım ve tarıma dayalı sanayi çok büyük önem taşımaktadır. Tarım sektörünün en önemli alanlarından biri olan meyve üretimi ve işleme sanayisinin ülkemizde büyük bir potansiyeli olduğu bilinmektedir. Türkiye ürettiği 16.3 milyon ton meyve ile dünya üretiminde altıncı sırada olup, dünya meyve üretiminin yaklaşık %3'ünü karşılamaktadır (Akdağ, 2008).

Elma, dünyada en fazla üretimi yapılan meyveler arasında muz, üzüm ve portakaldan sonra gelmektedir. Türkiye'de ise üzümünden sonra en fazla üretilen meyve durumundadır. Ülkemizde meyve suyuna dönüştürülmeye kullanılan meyveler arasında ise elma, yaklaşık %50 ile ilk sıradadır (Akdağ, 2008).

Meyve suyu, sağlıklı, olgun, taze ve temiz meyvelerden mekanik yolla elde edilen, o meyvenin, tat, koku ve renk gibi anatomik özelliklerine sahip ve fiziksel yolla bozulmaya karşı dayanıklı duruma getirilen içecektir. Meyve suları, berrak meyve suları, bulanık meyve suları ve nektarlar olarak üç gruba ayrılabilir. Berrak meyve suları vişne, üzüm, elma ve nardan yapılır. Berrak meyve suyu yapımında meyvelerin işlenmeye hazırlanması aşamasında meyve suyuna dönüştürülecek olan ürünün toz, toprak, yaprak ve kırıntılarının uzaklaştırılması için havuzlarda yıkama işlemi yapılır. Daha sonra yürüyen bantlarda kalite kontrol işçileri tarafından çürük, sağlıklı, ezik veya ham şeklinde ayıklama yapılır (Artık, 2017). İnsan doğası gereği hata yapar ve birim zamanda ayrıştırılacak olan meyve sayısının çok fazla olması nedeniyle yanlış sınıflandırmalar söz konusu olabilmekte ve tam bir standart yakalayabilmek mümkün olamamaktadır (Sobral, 2018; Hayıt ve ark., 2018).

Bu yüzden ayıklama işleminin görüntü işleme teknolojisi kullanılarak makineler tarafından otomatik olarak yapılması hem işlemin hızlanması hem de maliyetinin azalması bakımından önemlidir (Pandey ve ark., 2013). Görüntü işleme teknolojisinin kullanılabilmesi için de ek cihazlar (görüntü alma ve görüntü işleme cihazları) ve yazılımlar gerekmektedir. Görüntüler üzerinde uygulanacak görüntü işleme teknikleri ile

tarım ürünleri kalitelerine göre otomatik olarak sınıflandırılabilir (Pourdarbani, 2015).

Meyve sebze derecelendirme sistemleri geçtiğimiz son on yılda önemli derece robotikleşmiştir. Meyvelerde şekil, renk, şeker miktarını ve hatta asit içeriğini tespit etmek makine görmesi ve yakın kızılötesi (NIR) teknolojileri ile mümkün hale gelmiştir (Lu ve Ariana, 2002). Bu sistemler renkli yüklenme iliştilmiş aygıt (CCD) kameralar ve aydınlatıcılarla farklı açılardan meyvenin bütün yanlarından görüntü almak amacıyla bir hat üzerinde meyveyi denetlemektedir.

Makineler ile çürük tespiti amacı ile üzerinde en fazla çalışma yapılan meyvelerden biri de hiç kuşkusuz elmadır. Bu çalışmalar incelendiğinde, elmalardaki çürük tespitini zorlaştıran en önemli unsurlardan birinin çürük kısımlar ile elmanın kendi anatomik bölgelerinden olan sap çanak kısımlarının net olarak ayırt edilemediği görülmüştür. Bu yüzden çalışmalarda ya görüntüler elmaların sap-çanak bölgesi gözükmeyecek şekilde alınmış ya da alınan görüntülerde öncelikle elmanın sap ve çanak kısımlarının tespit edilip görüntüden çıkarılmasına odaklanılmıştır (Kondo, 2010; Mohana ve Prabhakar, 2015; Lu ve Lu, 2017; Zhang ve ark., 2017). Literatürde çürük tespiti üzerine yapılan çalışmalar incelendiğinde genellikle endüstriyel tip CCD (Xiaobo ve ark., 2007; Tonguç ve Yakut, 2009; Er ve ark., 2013; Sofu ve ark., 2013) veya Monochrome (Unay ve Gosselin, 2004; Unay ve Gosselin, 2005a) teknolojisine sahip kameralar kullanılmıştır. Bunun yanında hiperspektral ve multispektral görüntüleme sistemlerinin kullanıldığı görülmektedir (Xing ve Baerdemaeker, 2005; Lu ve Lu, 2017; Zhang ve ark., 2017). Bu sistemler sayesinde görüntüde ilgilenilen bölgenin ön plana çıkarılması sağlanmıştır. Görüntü işleme yöntemi olarak eşikleme (Unay, 2004; Er ve ark., 2013; Unay ve Gosselin, 2005b), istatistiksel ve şekilsel özellikler (Unay, 2004; Unay ve Gosselin, 2005a), renk uzayı dönüşümleri (Xiaobo ve ark., 2007; Tonguç ve Yakut, 2009; Er ve ark., 2013) ve filtreleme (Er ve ark., 2013) kullanılmıştır. Sınıflandırma için ise Destek Vektör Makinesi (SVM) (Unay, 2004; Unay ve Gosselin, 2005a, b; Xiaobo ve ark., 2007), Yapay Sinir Ağları (Unay ve Gosselin, 2005a; Xiaobo ve ark., 2007) ve Karar Ağaçları (Er ve ark., 2013) kullanılmıştır. Son yıllarda ise evrimsel sinir ağı (CNN) modeli kullanılarak başarılı çalışmalar yapılmıştır (Sa ve ark., 2016). Ek olarak, literatürde başarılı sonuçlara sahip

olan birçok çalışma, parçacık sürüsü optimizasyonu (PSO) ve yapay arı kolonisi (ABC) gibi optimizasyon algoritmalarının görüntülerde yinelemeli eşikleme için kullanıldığını göstermiştir (Maitra ve Chatterjee, 2008; Horng, 2011; Zihui ve ark., 2013; Akay, 2013; Adem ve ark., 2019).

Bu tez çalışmasında elma meyvelerinden alınan görüntüler üzerinde görüntü işleme ve derin öğrenme yöntemlerinin birlikte kullanıldığı bir model önerilmiş, elmaların çürük ve sağlıklı şeklinde sınıflandırılması amaçlanmıştır. Önerilen modelde işlem adımları sırasıyla görüntü alma-önişleme, sap-çanak anatomik bölgelerin bölütlenerek göz ardı edilmesi, çürük bölgelerin tespit edilmesi ve elmaların sınıflandırması şeklindedir. Görüntü alma-önişleme aşamasında, tasarlanan bir görüntü alma platformu içerisinde bulunan 830 nm uzun dalga geçiren filtre (LWPF) içeren NIR kamera kullanılmıştır. Çalışmada 100 adet çürük ve 100 adet sağlıklı olmak üzere toplam 200 adet elma kullanılmış, her bir elmanın 6 farklı yönünden toplam 1200 adet görüntü elde edilmiştir. Önişleme aşamasında sırasıyla, adaptif histogram eşitleme (AHE), kenar bulma, şekilsel işlemler yapılarak sınıflandırma başarısını artırmak amaçlanmıştır. Anatomik bölgelerin bölütlenmesi amacıyla önişlem yapılan görüntüler üzerinde bir derin öğrenme modeli olan CNN modeli eğitilmiş, elmanın sap ve çanak bölgeleri tespit edilmiştir. Eğitim sonucunda tespit edilen bölgeler bir sonraki aşamada göz ardı edilmiştir. Daha sonra bu model ile çürük bölgelerin tespiti yapılmıştır. Sınıflandırma aşamasında elmalar, çürük tespit edilen ve edilmeyen şeklinde %94.65 doğru sınıflandırma oranı ile sınıflandırılmıştır. Ayrıca, deneysel çalışmalar sonucunda önerilen modelin sadece CNN kullanılan modelden de daha başarılı olduğu tespit edilmiştir. Sonuç olarak bu çalışmada önerilen modelin makineye uyarlanması durumunda, meyve suyu gıda sanayisinde elmaların otomatik olarak ayrıştırılması amacıyla kullanılabileceği düşünülmektedir.



## **2. KURAMSAL TEMELLER**

Bu bölümde, ilk olarak çalışmada kullanılan yöntemlerin literatürdeki kullanımı araştırılmıştır. Daha sonraki başlıklarda ise makine görme teknikleri ile elma meyvesi üzerinde sınıflandırma, sap-çanak tespiti ve çürük tespiti üzerine yapılmış çalışmalar farklı başlıklar halinde sunulmuştur.

### **2.1. Genel Yöntemler**

Tez çalışmasında kullanılan genel yöntemlerle ilgili literatür çalışmaları alt başlıklar halinde aşağıda sunulmuştur.

#### **2.1.1. CNN kullanılan çalışmalar**

Sa ve ark. (2016), Hızlı Bölge-Tabanlı CNN (Faster R-CNN) modelini kullanarak meyve algılama üzerine bir çalışma yapmıştır. Çalışmada hem NIR hem de RGB görüntüleri birlikte kullanarak yedi farklı meyve üzerinde sistemin performansı test edilmiştir. NVIDIA GPU ile her bir meyve için eğitim zamanı 4 saat sürmüş ve sonuç olarak görüntülerdeki meyveler %83 oranında doğru olarak tespit edilmiştir.

Christiansen ve ark. (2016), tarlalardaki sınırların ve engellerin tespitine yönelik yaptıkları çalışmada kameralar ile gerçek zamanlı görüntüler almış ve Faster R-CNN mimarisini kullanarak karar verebilen bir sistem geliştirmiştir. Sistem, termal ve RGB kameralar ile görüntüler alacak şekilde tasarlanmış ve 1000 farklı nesne görüntüsü ile eğitilmiştir. Sonuç olarak, sınırlar ve engeller %72 doğruluk oranı ile tespit edilebilmiştir.

Fuentes ve ark. (2017), Faster R-CNN kullanarak domates görüntüleri üzerinde hastalık ve zararlıların yerinin ve türünün tespiti üzerine bir çalışma yapmıştır. Çalışmada farklı çözünürlükte ve farklı büyüklükteki domateslerden yaklaşık 5000 adet görüntü elde edilmiş, veri çoğaltma (DA) kullanarak eğitim verisinin çoğaltılması ve çeşitlendirilmesi sağlanmıştır. Veri setinin %80'i eğitim, %10'u doğrulama ve %10'u test işlemi için kullanılmıştır. Deneysel çalışmalarda DA işleminin başarı oranını %35 artırdığı

gösterilmiştir. Yapılan testler sonucunda %83-%90 arasındaki doğruluk oranı ile hastalık ve zararlılar tespit edilebilmiştir.

### **2.1.2. Optimizasyon algoritması kullanılan çalışmalar**

Apostolopoulos ve Vlachos (2011), elektrik enerjisi üretiminde en ekonomik emisyon yükü salınımı problemini çözmek için, yani hem yakıt masrafının hem de elektrik üreten ünitelerin emisyonunun en aza indirgenmesini sağlamak üzere, Ateş Böceği Optimizasyon Algoritması (FFA) ve diğer optimizasyon algoritmaları uygulanmış ve karşılaştırılmıştır. Sonuç olarak, 6 güç jeneratöründen oluşan iki farklı test sisteminin çeşitli yük talepleri için yapılan deneylerde, diğer rakip algoritmalar ile karşılaştırıldığında, FFA'nın çok verimli olduğu gösterilmiştir.

Hornig ve Liou (2011), entropiye dayalı yinelemeli eşikleme yöntemi olan, minimum çapraz entropi eşikleme, FFA'nın arama mekanizması ile birleştirerek yeni bir çok-seviyeli eşikleme algoritması önermiştir. Önerilen yöntemin sonuçlarını karşılaştırmak için, Etraflı Arama, PSO, Kuantum PSO ve Bal Arısı Çiftleştirme Optimizasyonu yöntemleri olmak üzere dört farklı yöntem uygulanmıştır. Sonuç olarak, önerilen yöntemin, eşik sayısı 5'in altında olduğu durumlarda Etraflı Arama yöntemi ile en iyi sonuca çok yakın olan çoklu eşikleri verimli bir şekilde bulabildiği ifade edilmiştir.

Raja ve ark. (2014), Brownian Dağılımı tabanlı FFA kullanarak histogram tabanlı çok seviyeli bir eşikleme yaklaşımı önermiştir. Önerilen algoritmanın performansı, 12 benchmark görüntüsü kullanılarak gösterilmiş ve Levy uçuş tabanlı FFA ve rastgele operatör tabanlı FFA gibi mevcut FFA algoritmaları ile karşılaştırılmıştır. Önerilen ve mevcut FFA algoritmaları arasındaki performans karşılaştırmasını, hedef fonksiyon, standart sapma, objektif kalite ölçütleri olan Tepe Sinyal-Gürültü Oranı (PSNR) ve Yapısal Benzerlik İndeksi (SSI) ve CPU'nun arama zamanı gibi mevcut parametreleri kullanarak gerçekleştirilmiştir. Sonuç olarak, Brownian Dağılımlı FFA'nın daha iyi bir hedef fonksiyon, PSNR ve SSI sağladığı, buna karşın Levy uçuş tabanlı FFA'nın nispeten daha düşük CPU zamanı ile daha hızlı bir yakınsama sağladığı ifade edilmiştir.

Malathi ve Nedunchelian (2016), Diyabetik Retinopati hastalığının tespiti üzerine yaptıkları çalışmada, Fundus retina görüntülerinde kan damarlarını etkili bir şekilde saptamak için yeni bir algoritma önermiştir. Hastalığın sınıflandırılması için Yapay Sinir Ağı (ANN) tabanlı ateş böceği kümeleme algoritması kullanılmıştır. Etkilenen bölgenin gruplandırılması için pamuk yünü lekeleri alanı ve damar çapı gibi parametreler kullanmıştır. Sonuç olarak sistemin, dört aşamalı diyabetik retinopati teşhisini desteklemek için yeterli sonuçlara ulaştığı ve retinanın normal veya anormal durumuna rağmen, doğru tespit edilebildiği ifade edilmiştir.

Chen ve ark. (2016), yaptıkları çalışmada, çok seviyeli eşikleri aramak için gelişmiş bir ateşböceği algoritması (IFA) önermiştir. IFA'da ateşböceklerinin yerel optimadan kaçmasına yardımcı olmak ve yaklaşmayı hızlandırmak için iki strateji (yani, Cauchy mutasyonu ve komşuluk stratejisi ile çeşitlilik artırıcı strateji) kullanılmıştır. Önerilen IFA, Darwinian PSO, hibrit diferansiyel evrim optimizasyonu ve FFA olmak üzere en iyi üç algoritma ile karşılaştırılmıştır. Sonuç olarak, önerilen yöntemin çok seviyeli görüntüleri etkili bir şekilde parçalayabildiği ve diğer üç yöntemden daha iyi performans elde edilebildiği ifade edilmiştir.

## **2.2. Elma Sınıflandırması Yapılan Çalışmalar**

Tonguç ve Yakut (2009), renk dönüşümlerini kullanarak elmaları renk ve boylarına göre sınıflandırmıştır. Kullandıkları 1.3 MP'lik CCD kamera ile her bir elmanın denetim işlemini 1.3 sn'de gerçekleştirmiştir.

Zarifneshat ve ark. (2012), elmanın çürük hacimlerini tahmin etmek için farklı ANN modellerini kullanmıştır. Ölçülen ve tahmin edilen test verisetleri önerilen ANN modeline uygulanmıştır. İstatistiksel analizden, öngörülen test verisetlerinin %95 güven düzeyinde olduğu bulunmuştur.

Er ve ark. (2013), yaptıkları çalışmada yürüyen bant üzerinden geçen elmaların gerçek zamanlı olarak boyut, renk, sınıf ve ağırlık tespiti sağlanmıştır. Bir eşikleme ile arka plan görüntüden çıkarılmıştır. Gürültüler medyan filtre ile temizlenmiştir. Sap ve çanak kısmı

kapatma uygulanarak göz ardı edilmiştir. C4.5 karar ağacı ile elma rengine göre sınıfı belirlenmiştir. Sınıflandırma %95.5 başarıyla yapılmış ve bir elmanın ortalama tanıma süresi ise 0.5 sn olmuştur.

Sofu ve ark. (2013), görüntü işleme yöntemi kullanarak çeşitli elmalar üzerinde renk, boyut ve lekelerin tespit edilmesi, tespit edilen lekelerin sınıflandırılmasına odaklanılmıştır. Elmaların mevcut standardı Türkiye Standartları Enstitüsü (TSE)'nin TS 100-2007 elma standardı ile elma yetiştiricilerinden toplanan verisetleri bir tablo şekline getirilerek yazılımın veri tabanı oluşturulmuştur. Elma görüntüleri çözünürlük olarak küçültülmüş ve istenmeyen alanlar çıkartılmıştır. Elma arka plandan ayrılmış daha sonra elma rengi belirlenmiştir. Lekeyi sap ve çanaktan ayırmak için aynı büyüklükte olan alanlar sınıflandırılmış ve böylece tek olan alan sap veya çanak, çok sayıda olan alanlar ise leke olarak tespit edilmiştir. Renk tahmininde yazılım %100'e yakın doğru tahmin yapmıştır. Elma cinslerinin sınıflandırılmasında ise %93 ile %100 arasında doğru tahmin etmiştir.

Dubey ve Jalal (2016), elma hastalıklarının renk, doku ve şekil tabanlı özellikleri ile tanınması üzerine bir çalışma yapmıştır. Hastalıklı meyve kısımları K-means kümeleme yardımıyla tespit edilmiş, bölütlenmiş görüntü üzerinde renk, doku ve şekil tabanlı özellikler çıkartılmış ve SVM ile elmalar hastalıklı ve sağlıklı olarak sınıflandırılmıştır. Elma yüzeyindeki kusurların bölütlenmesinde  $L^*a^*b^*$  renk uzayı kullanılmış, veri seti olarak farklı hastalıkların bulunduğu dört sınıf etiketine sahip 320 adet elma görüntüsü toplanmıştır. Sonuç olarak elmalar ortalama %95.95 doğruluk ile sınıflandırılmıştır.

Cömert ve ark. (2016), meyve görüntülerini kullanarak elmaların türlerine göre sınıflandırılmasını yapmıştır. Çalışmada 'Starking', 'Golden Delicious' ve 'Granny Smith' türlerinden toplam 45 adet elmadan 270 adet görüntü elde edilmiştir. Ön işlem aşamasında çalışılacak renk kanalının tayini ve filtreleme yapılmıştır. R, G ve B kanallarından birisi seçilmiş ve bu kanaldaki görüntü üzerinde ortalama filtre uygulanmıştır. İlk olarak Prewitt kenar bulma algoritması kullanılarak elmanın görüntüdeki sınırları elde edilmiştir. Elde edilen ikili görüntü üzerinde sırası ile kapama, doldurma ve açma işlemleri uygulanarak arka planın ortaya çıkması sağlanmıştır. Açma

işlemi ile ilgilenilen nesne dışındaki küçük nesnelerin yok edilmesi sağlanmıştır. Elde edilen arka plan tekrar RGB görüntü ile örtüştürülerek arka planı tamamen siyah bir RGB görüntü elde edilmiştir. Böylece meyvenin daha belirgin olması sağlanmıştır. Sınıflandırma aşamasında özellik olarak kullanılacak olan  $a$ ,  $u$ ,  $S$  ve  $b$  kanallarını elde etmek için RGB renk uzayındaki görüntü ayrı ayrı  $L*a*b$ ,  $Luv$  ve  $HSV$  renk uzaylarına taşınmıştır. Elde edilen bu kanallar ile R, G ve B kanallarının ayrı ayrı ortalamaları alınarak her bir görüntü için toplam yedi adet özellik içeren bir özellik vektörü elde edilmiştir. Sınıflandırma aşamasında bu özellik vektörü bilinen makine öğrenmesi yöntemlerinden olan MLPNN ve Naive Bayes (NB)'e giriş olarak verilmiştir. MLPNN ve NB makine öğrenmesi yöntemleri kullanılarak sonuçları karşılaştırılmış ve MLPNN ile %98.13 ve NB ile %96.30 başarı oranı elde edilmiştir.

### **2.3. Elmalarda Sap-Çanak Tespiti Yapılan Çalışmalar**

Unay ve Gosselin (2004), 'Jonagold' cinsi elmaların sap ve çanak kısmının tespitine yönelik yaptığı çalışmada bir CCD kameraya 450, 500, 750 ve 800nm'lik kızılötesi (IR) filtreler takarak görüntüler almıştır. Önce eşikleme ile arka plan çıkarılmış daha sonra her bir nesnenin yapısal, istatistiksel ve şekilsel özellikleri SVM sınıflayıcısına verilmiştir. Sonuç olarak sapların %99'u ve çanakların %100'ü doğru tespit edilmiştir.

Mohana ve Prabhakar (2015), 600 farklı renkli görüntü üzerinde şekilsel tanımlayıcıları kullanarak elmaların sap ve çanak bölgelerinin tespiti üzerine bir çalışma yapmıştır. Çoklu eşiklemeye dayalı bölütleme sonucunda elde edilen nesneler üzerinde Multifractal, Fourier ve Radon tanımlayıcılar kullanılarak şekilsel özellikler çıkarılmıştır. Elde edilen özellikler elmaların sap-çanak ve çürük-yara bölgelerini tespit etmek ve sınıflandırmak için SVM, ANN, k-en yakın komşuluk (k-NN), doğrusal ayırt edici sınıflayıcı (LDC) ve AdaBoost sınıflayıcılara giriş olarak uygulanmıştır. SVM bu sınıflayıcılar arasında %94 doğruluk ile en yüksek başarı oranına ulaşmıştır.

### **2.4. Elmalarda Çürük Tespiti Yapılan Çalışmalar**

Lu (2003), yaptığı çalışmada bir NIR hiperspektral görüntüleme sistemi geliştirmiş ve elmalardaki hem yeni hem de eski çürükleri tespit etmek için bir algoritma oluşturmuştur.

Sonuç olarak 1000 nm ile 1340 nm arasındaki spektral bölgenin çürük tespiti için daha uygun olduğu saptanmıştır. Oluşturulan sistem, yeni ve eski çürükleri, 'Red Delicious' için %62 ile %88 arasında ve 'Golden Delicious' için ise %59 ile %94 arasında doğru tanımlamıştır. Ayrıca, NIR hiperspektral görüntüleme sistemlerinin elma çürük tespiti için oldukça kullanışlı olduğu vurgulanmıştır.

Mehl ve ark. (2004), yaptıkları çalışmada çeşitli elma türleri üzerinde kir, yara, hastalık ve çürük gibi bölgelerin tespitini yapmıştır. Her elma türü için farklı farklı dalga boylarında görüntüler alınmıştır. Temel Bileşen Analizi (PCA) ve Asimetrik İkinci Fark (ASM) yöntemlerini kullanılmıştır. Daha sonra maskeleyme ve şekilsel işlemler ve son olarak bir eşikleme uygulanmıştır. PCA ve ASM yöntemlerinin sonuçları karşılaştırılmış ve sonuçların çok yakın olduğunu tespit edilmiştir.

Xing ve ark. (2005), yaptıkları çalışmada ilk olarak hem görüntüyü hem de hesaplanan veri miktarını düşürmek için her bir görüntü üzerinde yumuşatma işlemi yapmıştır. Bunun için 5 ve 10 komşu pikselin ortalamasını alan bir filtre kullanılmıştır. Basit bir eşik değeri ile arka planı esas görüntüden ayrılmış daha sonra hem otomatik hem de elle eşik değeri belirlenerek ikili görüntüdeki küçük alanlar yok edilmiştir. Sonuç olarak çürük olmayan elmaların yaklaşık %93'ü sağlıklı olarak tanınmış ve %86 doğrulukla çürükleri tespit edilmiştir.

Xing ve Baerdemaeker (2005), yaptıkları çalışmada 'Jonagold' türü elmalarda çürük tanıma için 400-1000 nm dalga boyu aralığında hiperspektral görüntüleme sistemi oluşturmuştur. Çalışma toplam 160 tane elma üzerinde yapılmıştır. Bunların 15 tanesi kesik çürüğü, 80 tanesi darbe çürüğü ve 65 tanesi ise sağlıklıdır. Çürük tanımanın yanında çanak ve sap ucu tanıma algoritması da geliştirilmişlerdir. İlk olarak görüntülerde arka plan basit bir eşikleme işlemi ile çıkarılmıştır. Daha sonra 5 ve 10 piksellik ortalama filtre ile yumuşatma uygulanmıştır. Yüzeyin yumuşaklığı, çürükler, sap ucu ve çanak kısmından sağlıklı bölgeyi ayırmak için bir özellik olarak düşünülmüştür. Elma kenarlarının pürüzsüzlüğü, sağlıklı ve çürüğü ayırmak için kullanılmıştır. Kenarlarda dış bükey şeklindeki yapılar çürük olduğunu gösterdiğinden kenarlarda dışbükeyler algılanmış ve dış bükeylerin başlangıç ve bitiş noktaları düz çizgilerle birleştirilerek

kapalı eğriler elde edilmiştir. Bu kapalı eğriler doldurularak elmanın kenarlarındaki dışbükeyler kırılmıştır. Daha sonra elmanın ilk hali ile son hali EXOR işlemine tabi tutularak elmanın deforme alanı hesaplanmıştır. Sağlıklı elmalar için doğru sınıflandırma %86.4 iken çürükler 1 günlük olduğunda %77.5 olmuştur. Sağlıklıkların hiç biri sap ve çanak olarak yanlış sınıflandırılmamıştır ama çürüklerin %2.5'i sap ve çanak olarak yanlış sınıflandırılmıştır. Görüntülerde sap ve çanak %98.3 doğru sınıflandırılmıştır.

Xing ve ark. (2006), elmalarda çürük tespiti üzerinde yaptıkları çalışmada 400–1700 nm dalga boyları arasında elmaların yansıma tayflarını elde etmiştir. Bir günlük çürüklerde yanlış sınıflandırma %16.3 olmuş ve zaman geçtikçe algılama hatası azalmıştır. Veri olarak 120 adet 'Golden Delicious' türü elma kullanılmıştır. Hem sağlıklı hem de çürük elmaların yansımaları ölçülmüş ve 400-1700 nm dalga boyu aralığındaki optik spektrumları elde etmek için iki farklı spektrofotometre kullanılmıştır. 3 saat ve 21 gün aralığında 7 defa hem görünür hem de NIR tayfta yansımalar elde edilmiştir. Toplam 2200 yansıma bilgisi elde edilmiştir. Yine Xing ve ark (2007), yaptıkları çalışmada 'Golden Delicious' elmalarında çürük tanıma için 400-1000 nm dalga boyu aralığında hiperspektral görüntüleme sistemi oluşturmuştur. Veri olarak toplanan 59 tane elma gözle çürük ve sağlıklı olarak iki guruba ayrılmıştır. Görüntü almak için bir monochrome kamera ve bir spektrograf kullanılmış ve 800x1040 piksellik görüntüler elde edilmiştir. Veri azaltma tekniği olarak etkili bir istatistiksel yöntem olan PCA tekniği kullanılmıştır. Örneklerin sınıflar arasında maksimum ayrılmasına izin veren kısmi en küçük kare ayırt edici analizi (PLSDA) tekniği kullanılmıştır. Ana hedef bir görüntüyü ilgilenilen nesnelere ya da alanlarla güçlü bir korelasyona sahip bölgelere bölmektir.

Unay ve Gosselin (2005a), yaptıkları çalışmada 'Jonagold' cinsi elmalar üzerinde otomatik elma sınıflandırması yapmak amacıyla bir bilgisayarlı görme sistemi tasarlamıştır. Bunun için yüksek çözünürlüklü bir monochrome dijital kamera ve dört farklı bant geçiren filtre (450 nm (BL), 500 nm (GR), 750 nm (RE), and 800 nm (IR)) kullanılmıştır. Elmaların kusurlarını tespit etmek için bir ANN kullanılmıştır. Kusurlu bölgelerden istatistiksel özellikler elde edilmiş ve daha sonra meyve denetimli bir algoritma ile derecelendirilmiştir. Meyveyi derecelendirmek için doğrusal ayırt edici analizi (LDA), k-NN, bulanık en yakın komşu (FNN) ve SVM tabanlı sınıflayıcılar

kullanılmış ve son ikisi %90 tanıma ile en başarılısı olmuştur. Elmanın sap ve çanak bölgeleri kusurlar ile aynı gibi gözükse de ANN bunu ayırmıştır.

EIMasry ve ark (2008), yaptıkları çalışmada bir hiperspektral görüntüleme sistemi ile McIntosh türü elmalar üzerindeki çürükleri önceden tanınmasını araştırmıştır. Sistem 400 ile 1000 nm lik spektral bölgede görüntü alacak biçimde tasarlanmıştır. Kısmi En Küçük Kareler (PLS) ve Kademeli Ayırt Edici Analizi (SDA) verinin boyutlarını azaltmak ve etkin dalga boylarını seçmek için kullanılmıştır. Multispektral görüntü testleri için kızılötesi bölgede üç etkin dalga boyu (750, 820, 960 nm) seçilmiştir. İlk olarak bir ikili filtre olan global eşikleme yoluyla arka plan ayrılmıştır. Sıradan RGB görüntüler renk benzerliği nedeniyle kötü sonuç verirken IR yumuşatılmış görüntüler daha iyi sonuç vermiştir. Bu görüntülerde çürüklerin pikselleri genellikle sağlıklı dokunun piksellerinden daha koyu olmuştur. Çoğu durumda basit eşikleme çürük alanın tamamını belirleyememiştir. Bu problemin çözümü için de adaptif bir eşikleme kullanılmıştır. Son olarak görüntüler ortalama filtre ile kaldırılarak, aşındırma ve genişletme işlemleri yapılmıştır. Sınıflandırma işlemi sonucunda çürük elmalar sağlıklı elmalardan %98.4'lük bir başarı ile ayrılmıştır. EIMasry ve ark. (2009), yaptıkları çalışmada toplam 64 tane 'Red Delicious' türü elma kullanmıştır. Meyvenin hem et rengi hem de kabuk rengi ölçülmüş, daha sonra görüntüler RGB renk uzayına ve buradan da  $L^*a^*b$  renk uzayına dönüştürülmüştür. Elmanın et renginin çürük ve sağlıklıyı ayırmada oldukça etkili bir veri olduğu, özellikle  $L$  ve  $a$  kanalında RGB de ise B kanalında oldukça fark olduğu tespit edilmiştir.

Lu ve Lu (2017), histogram tabanlı otomatik eşikleme yardımıyla elmaların çürüklerinin tespiti üzerine bir çalışma yapmıştır. Görüntüler, yapılandırılmış aydınlatma yansıtımlı görüntüleme (SIRI) kullanarak 730 nm dalga boyunda dört türde toplam 120 elmadan elde edilmiştir. Görüntülerde elmalar yatay pozisyonda olduğundan sap ve çanak kısımları görünmemektedir. Görüntüler üzerinde sırasıyla, ortalama filtre, yinelemeli eşikleme, açma ve doldurma işlemlerini uygulanmıştır. Eşikleme aşamasında görüntüler üzerinde 9 farklı yinelemeli eşikleme yöntemi denenmiş ve Intermode, Ridler ve Otsu tekniklerinin %90 doğruluk oranı ile en iyi sınıflandırma başarısına sahip olduğu saptanmıştır. Ridler tekniği kullanıldığında pozitif yanlış ve negatif yanlış oranının



ortalamada %6.7 ile en düşük olduđu, Unimode ve Ridler tekniklerinin birlikte kullanılması durumunda ise bu oranın %5.8'e kadar düřtüđu tespit edilmiştir.

Zhang ve ark. (2017), elma görüntüleri üzerinde elma optik özellikleri ve SVM kullanılarak elmaların çürüklük seviyesine göre sınıflandırılması üzerinde çalışmıştır. Çalışmada 155 adet 'Fuji' türü elma kullanılmış, bu elmalardan bir mikrotom ile 3 mm kalınlığında ve 2 cm çapında doku örnekleri alınmıştır. 400-1050 nm dalga boylarında örneklerin geçirgenliği ve yansıtkanlığı Entegre Küre Sistemi ile ölçülmüştür. Elde edilen özellikler SVM'ye verilerek yapılan sınıflandırmanın başarısı %92.5 olarak tespit edilmiştir.

Literatür taraması sonucunda, birçok çalışma ABC ve PSO gibi optimizasyon tabanlı yinelemeli eşikleme kullanılarak elma görüntülerinde çürük tespiti gerçekleştirildi. Ancak CNN modeli ile ABC/PSO-tabanlı yinelemeli eşikleme hibrit modeli ilk defa bu çalışmada kullanılmıştır. CNN modeli ile optimizasyon algoritması hibrit olarak kullanıldığında, çürük alanların ve sap-çanak anatomik bölgelerinin tespiti üzerindeki etkilerini ve tespit edilen eşik değeri kullanarak elmaların çürük ve sağlıklı olarak sınıflandırılması araştırıldı. Bu amaç için, elma görüntüleri AHE, kenar algılama ve şekilsel işlemler kullanılarak iyileştirildi. CNN modeli, elmaların sap-çanak anatomik bölgelerinin belirlenmesi için iyileştirilmiş görüntüler kullanılarak eğitilmiştir. CNN modeli ile belirlenen nesnelere görüntülerden atılmış, görüntülerdeki çürük alanlar PSO/ABC-tabanlı yinelemeli eşikleme ile belirlenen eşik değeri kullanılarak tespit edilmiş ve sonra elmalar tespit edilen nesnelere kullanılarak çürük ve sağlıklı olarak sınıflandırılmıştır. Bu çalışmanın literatüre en önemli katkısı, görüntülerde çürük alanların tespitinde ilk defa CNN modeli ve PSO/ABC-tabanlı yinelemeli eşikleme yaklaşımından oluşan hibrit bir modelin kullanılmasıdır. Aynı zamanda bu yöntem ile literatürdeki çalışmalardan daha başarılı sonuçlar elde edilmiştir.


### 3. MATERYAL ve YÖNTEM

Bu bölümde çalışmada materyal olarak kullanılan elma görüntülerinin nasıl elde edildiği, görüntü işleme ve sınıflandırma aşamalarında kullanılan yöntemler detaylı bir şekilde açıklanmaktadır.

#### 3.1. Görüntülerin Elde Edilmesi

Çalışmada, Türkiye’de en çok yetiştirilen ‘Starking’, ‘Golden Delicious’ ve ‘Granny Smith’ elma türleri üzerinde çalışılmıştır. Bu elmalardan eşit sayılarda çürük ve sağlıklı örnekler toplanmış, böylece eğitimin daha başarılı olması sağlanmıştır. Görüntü veri setlerinin elde edilmesi ve işlenmesi amacıyla Tokat Gaziosmanpaşa Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi’ne ait görüntüleme cihazları kullanılmıştır.

Görüntüler, 1920x1200 piksel çözünürlükte, 15 cm’lik bir mesafeden alınmıştır. Veri setinde 100 tanesi çürük, 100 tanesi sağlıklı olan toplam 200 elma kullanılmış ve her elmanın altı farklı açısından toplam 1200 görüntü elde edilmiştir. Görüntülerde çürük alanlar uzman tarafından işaretlenmiştir. Eğer çürük alan görüntünün %10’undan daha fazla ise görüntü çürük, değilse sağlıklı olarak etiketlenmiştir. Bu şekilde, toplam 1 200 görüntünün 450’si çürük olarak ve 750’si sağlıklı olarak etiketlenmiştir. Benzer şekilde, sap-çanak bölgeleri 1200 görüntüden 960’ında görülmezken ve 240 görüntüde görülebilmektedir. Şekil 3.1.a’da sağlıklı elma görüntüsü Şekil 3.1.b’de ise çürük bulunan elma görüntüsü gösterilmektedir.




a) Sağlıklı Elma

b) Çürük Elma

Şekil 3.1. Sağlıklı ve çürük elma görüntüleri

### 3.1.1. Görüntü alma ve işleme sistemi

Literatürde elmalarda çürük tespiti üzerine yapılan çalışmalar incelendiğinde genellikle hiperspektral ve multispektral görüntüleme sistemlerinin kullanıldığı görülmektedir. Bu sistemler elma yüzeylerindeki çürüklerin daha iyi tespit edilmesini kolaylaştıracak spektral bölgenin belirlenmesini mümkün kılmaktadır. Ancak bu sistemler hem yüksek maliyetlidir hem de laboratuvar ortamlarının dışında kullanımı pek mümkün değildir. Bu yüzden, görüntü alma aşamasında, tasarlanan bir görüntü alma platformu kullanılmıştır. Platform, bir adet 6 mm objektif (Fujinon HF6HA-1B) lens ve 1984x1264 çözünürlüğe sahip bir NIR kamera (Teledyne DALSA G3-GM12-M1930) içermektedir. Platform, ortam ışığının elmaya ulaşmasını önleyecek şekilde tasarlanmıştır. Işık kaynağı olarak geniş bir dalga boyu aralığına sahip iki adet 100 W Tungsten-Halojen lamba kullanılmıştır. Şekil 3.2, görüntü alma ve işleme sistemini göstermektedir.



Şekil 3.2. Görüntü alma sisteminin genel yapısı

Elma görüntülerinin alınması ve işlenmesi için tasarlanan makine görme sistemi dört kısımda incelenebilir. Bunlar, görüntü yakalama cihazı, sahne platformu, aydınlatma ve bilgisayardan oluşmaktadır.

### Görüntü Yakalama Cihazı

Çalışmada, görüntü almak için Teledyne DALSA Genie Nano NIR kamera, Lens ve LWPF kullanılmıştır. Kamera, ethernet üzerinden doğrudan bilgisayara veri aktarabildiği için başka bir ara karta ihtiyaç duyulmamıştır. Kamera özellikleri Çizelge 3.1’de gösterilmektedir.

Çizelge 3.1. Teledyne DALSA Genie Nano NIR kamera özellikleri

<b>Model Tipi</b>	Mono/NIR
<b>Shutter</b>	Global
<b>Sensör Tipi</b>	CMOS
<b>Sensör Modeli</b>	On-Semi
<b>Aktif Çözünürlük</b>	1984 x 1264
<b>Mak çerçeve oranı</b>	50
<b>Görüntü Boyutu</b>	2.2 Megapiksel
<b>Sensör Formatı</b>	2/3”
<b>Piksel Boyutu</b>	4.8x4.8µm
<b>Veri Formatı</b>	8 or 10bit Mono
<b>Bağlantı Tipi</b>	Gigabit Ethernet
<b>Montaj Tipi</b>	C-mount
<b>Hairici Kontrol</b>	Programlanabilir

Tarama alanı ve nesne uzaklığı dikkate alınarak tespit edilen lens ‘Fujinon HF16HA-1B’dir. Lens özellikleri Çizelge 3.2’de gösterilmektedir.

Çizelge 3.2. Fujinon HF16HA-1B lens özellikleri

<b>Montaj Tipi</b>	C-mount
<b>Focus Boyutu</b>	2/3",1/2",
<b>Min. Focus Uzaklığı</b>	16mm
<b>Boyutlar</b>	29.5 x 29.5
<b>Iris</b>	Elle
<b>Iris aralığı</b>	F1.4~F16
<b>Odaklama</b>	Elle
<b>Mak. Görüş Açısı</b>	17°04' yatay
<b>Min. Nesne Mesafesi</b>	10cm

Çizelge 3.2'de görüldüğü gibi lensin özellikleri, görüntüsü alınacak olan nesnelerin kameraya olan mesafesi vb. parametreler göz önünde bulundurularak seçilmiştir.

### Aydınlatma

Sistemde aydınlatma elemanı olarak beyaz Işık Yayan Diyot (LED) ve Tungsten-Halojen lambalar bulunmaktadır. LED'lerin harcadığı güç diğer ışık kaynaklarından azdır, uygulaması kolaydır ve kullanım ömrü uzundur (Cubero ve ark., 2011). LED'ler dayanıklıdır ve sarsıntı gibi olumsuz kullanım koşullarından etkilenmez (Qin ve ark., 2013). Ancak LED ışığın dalga boyu aralığı diğer ışık kaynaklarına göre dardır. Bu yüzden görünür dalga boyları dışında görüntü almak gerektiğinde farklı ışık kaynakları kullanmak kaçınılmaz olmaktadır. Bunun için görüntülerin alınması esnasında dalga boyu aralığı geniş bir ışık kaynağı olan Tungsten-Halojen lambalar kullanılmıştır. Bunlar iki adet ve toplam 100W gücündedir. Çizelge 3.3'te çeşitli ışık kaynaklarının dalga boyu aralıkları gösterilmektedir.

Çizelge 3.3. Bazı ışık kaynaklarının dalga boyu aralıkları (Anonim, 2017b)

<b>Işık Kaynağı</b>	<b>Dalga Boyu Aralığı (nm)</b>
Nernst glower	400-20000 nm
Globar (SiC)	1200-40000 nm
Nikrom tel	750-20000 nm
Tungsten (W) filament lambalar	350-2200 nm
H2 ark lambalar	160-380 nm
Tungsten halogen lambalar	240-2500 nm
Civa ark lambalar	300-700 nm
Hollow katot lambalar (HCL)	400-20000 nm
Lazerler	1200-40000 nm

Çizelge 3.3'te görüldüğü gibi tungsten-halojen lambalar görünür ve yakın mor ötesi (UV) bölgede (240-2500 nm) sık kullanılan ışık kaynaklarından biridir. Lamba filament, halojen olmayan lambalardan daha yüksek sıcaklıklara (~ 3500 K) kadar yükseltilebilir. Halojen lambalarda az miktarda iyot veya brom gibi bir halojen bulunur. Çalışması sırasında meydana gelen uçucu tungsten ve halojen bileşiği, tungsten üzerinde birikerek yüksek sıcaklıkta tungstenin yanmasını engelleyen bir deposit oluşturur (Anonim, 2017b).

Platformda aydınlatma elemanı olarak kullanılan LED, yarıiletken bir ışık kaynağıdır. Gerilim uygulanarak elektronları harekete geçirilen LED, ışın yaymaya başlar. Bu etki "elektroluminans" ya da "elektroişınım" olarak adlandırılır. Elektroişınım olayı 1907 yılında İngiliz araştırmacı H.J. Round tarafından keşfedilmiştir. Günümüz LED'lerinin atası sayılan ilk LED ise 1962 de General Electric Firmasında çalışan Nick Holonyak tarafından yapılmıştır (Anonim, 2017a). LED'ler çeşitli inorganik yarıiletken malzemelerden yapılırlar. Çizelge 3.4'te piyasada bulunabilen renkler için dalga boyu aralık değerleri gösterilmektedir.

Çizelge 3.4. Bazı LED'lerin dalga boyu aralık değerleri (Anonim, 2012)

Renk	Dalga Boyu Aralığı (nm)
Kızılötesi	$\lambda > 760$
Kırmızı	$610 < \lambda < 760$
Sarı	$570 < \lambda < 590$
Yeşil	$500 < \lambda < 570$
Mavi	$450 < \lambda < 500$
Mor	Çoklu tipler
Mor ötesi	$\lambda < 400$
Beyaz	$400 < \lambda < 750$

Çizelge 3.4'te görüldüğü gibi projede kullanılan beyaz LED en geniş dalga boyu aralığına sahiptir. Yine de bu aralık NIR bölgede yapılacak çalışmalar için yetersiz olacağından daha geniş dalga boyu aralık değerine sahip olan Tungsten-Halojen lambalar da sisteme dahil edilerek kullanılmıştır.

#### Sahne Platformu

Platform, 40 x 50 x 25 cm boyutlarında 18 mm suntalam malzemeden imal edilmiştir. Ortam ışığının elmaya ulaşmasını önleyecek şekilde kapalı olarak tasarlanmıştır. Platformun alt yan kısımlarında aydınlatma kaynağından çıkan ışığın elmanın tüm yüzeyine eşit şekilde düşmesini sağlayan aynalar bulunmaktadır. Bu şekilde elma yüzeyinde oluşabilecek gölgelenmeler en aza indirilmiştir. Platformun tabanında homojen siyah renkli bir kaplama kullanılmış, böylece görüntü işleme sırasında arka planın elmadan daha kolay ayrılması sağlanmıştır. Şekil 3.3'te bu kısımlar gösterilmektedir.



Şekil 3.3. Platformun sahne kısmı

Platformun çıkarılabilir üst bölümünde aydınlatma elemanları ve kameranın monte edilebileceği kısımlar bulunmaktadır. Bunlar Şekil 3.4'te gösterilmektedir.



Şekil 3.4. Platformun üstten görünümü

Platformun ön kısmında 15 cm yüksekliğinde ve elmanın sahne içerisine yerleştirilmesi için açılabilir bir kapak bulunmaktadır. Bu kapak Şekil 3.5'te gösterilmektedir.





Şekil 3.5. Platformun önden görünümü

### Bilgisayar

Görüntülerin alınması, saklanması ve işlenmesi için yüksek işlem kapasitesine sahip bir bilgisayar kullanılmıştır. Bilgisayarın genel özellikleri Çizelge 3.5’te gösterilmektedir.

Çizelge 3.5. Bilgisayar teknik özellikleri

<b>İşlemci</b>	<b>Intel Core i7 6700HQ 2.6 GHz</b>
Grafik İşlemci	NVIDIA GeForce GTX 960M 4GB
Bellek	16GB DDR4
Sabit Disk	128GB SSD + 1TB HDD
Ekran	1920 x 1080 15.6” LED
İşletim Sistemi	Windows 10 Home

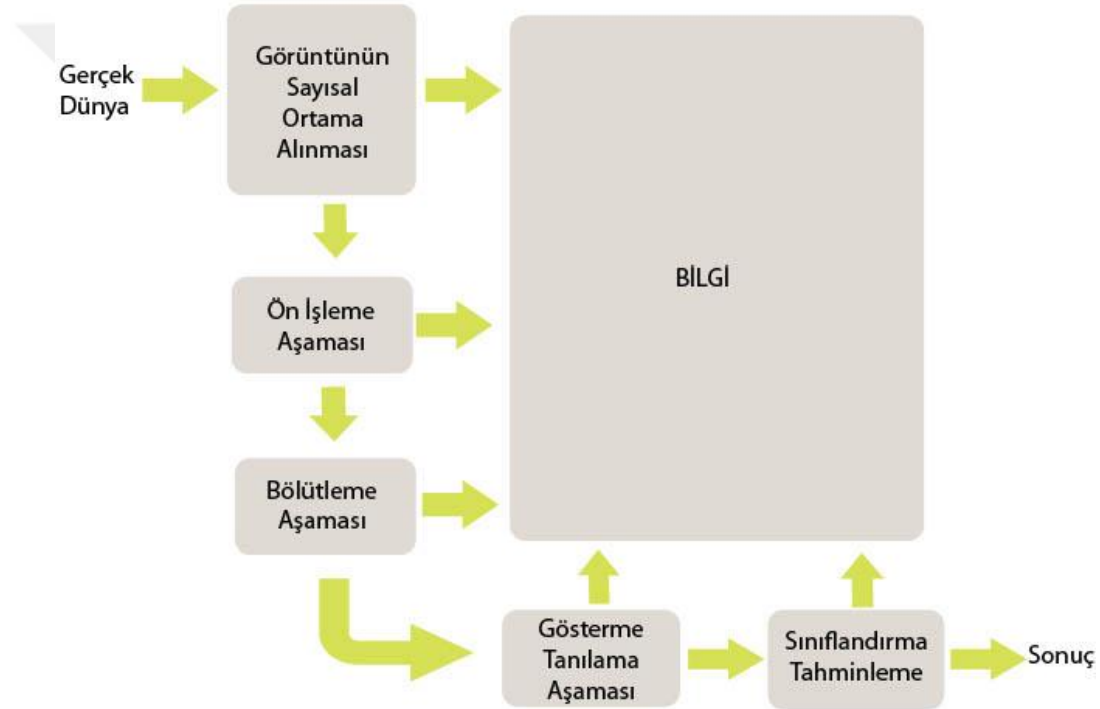
### **3.2. Sayısal Görüntü İşleme**

Kamera ve tarayıcı gibi aygıtlar ile sayısal ortama taşınmış ya da doğrudan bilgisayar ortamında hazırlanan görüntüler sayısal görüntüler olarak ifade edilmektedir. Sayısal

ortamda görüntüler 0 ve 1'lerden ibarettir. Her biri bir renk bilgisini gösteren piksellerin birleşmesi ile veya vektörel olarak belirlenen değerlerle görüntü verisi oluşturulmaktadır (Erbaş, 2011).

### 3.2.1. Sayısal görüntü işlemenin temel basamakları

Geleneksel bir görüntü işleme sisteminin çalışmasındaki temel işlem basamakları Şekil 3.6'da grafiksel olarak gösterilmektedir (Gonzalez ve Woods, 2002).



Şekil 3.6. Görüntü işlemenin temel basamakları

Şekil 3.6'da gösterildiği gibi, görüntü işlemenin her aşamasında bir bilgi elde edilebilmektedir. Burada ilk adım, gerçek dünyadaki görüntüyü bir kamera aygıtı yardımıyla alıp sayısal ortama aktarmaktır. Bu cihazlarda bir görüntü algılayıcısı ve algılanan resmi sayısal hale getiren dönüştürücü bir birim bulunmaktadır. İçerdikleri mikroişlemciler sayesinde birçok ayarı otomatik yapabilen bu cihazlar ile görüntüler sayısal ortamlara kolayca kaydedilebilmektedir.

Görüntü verisi elde edildikten sonra görüntü işlemenin ikinci işlem basamağı önileme aşamasıdır. Önileme aşaması, daha başarılı sonuçlar elde edebilmek için sayısal görüntülerin bazı ön işlemlerden geçirilmesini sağlar. Önileme için kontrastın ayarlanması, gürültülerin azaltılması ve görüntüdeki bölgelerin birbirinden ayrılması örnek olarak verilebilmektedir (Erbaş, 2011).

Önilemlerden sonra bölütleme aşaması, bir görüntüdeki nesne ve arka planın veya görüntü içerisindeki ilgilenilen değişik özelliklere sahip bölgelerin birbirinden ayrıştırılması işlemidir. Bölütleme görüntüyü, birbirine benzeyen ve yararlı bilgiler içeren parçalara ayırmayı amaçlamaktadır. Bu parçalardan elde edilen bilgiler de gösterme ve tanılama aşamalarında kullanılmaktadır (Erbaş, 2011).

Bölümün bu kısmından itibaren sayısal görüntü işlemede kullanılan tekniklere değinilmektedir.

### **3.2.2. Bölütleme**

Görüntü işlemede bölütleme, bir görüntüyü, özellikleri bakımından farklı ve anlamlı bilgiler içeren parçalara ayırma olarak tanımlanabilmektedir. Bu parçalar aynı kontrast veya aynı parlaklık değerlerine sahip piksellerden oluşabilmekte ve bu pikseller de görüntü içerisinde farklı nesnelere tanımlanabilmektedir. Burada önemli olan pikselden nesneye doğru uygun yapıyı kurmaktır. Bunun için görüntüye ait ölçek, renk, biçim, yumuşaklık ve bütünlük değişkenlerini kullanmak gerekebilmektedir. Bu değişkenlerin dâhil olduğu bir fonksiyon yardımıyla pikselden parçalara ve buradan da daha büyük parçalara doğru bir zincir yapısı kurulabilmektedir (Rego, 2003).

Bölütleme, bir görüntüdeki nesnenin sınırları, şekli veya o nesnenin alanı gibi ham bilgiler üretmektedir. Görüntü bölütleme ile ilgili şimdiye kadar birçok yöntem önerilmiştir. Bunlardan en fazla kullanılanları; sıkıştırma-tabanlı yöntemler, kümeleme yöntemleri, bölge-tabanlı yöntemler, böl ve birleştir yöntemi ve histogram-tabanlı yöntemlerdir. Bölütleme, görüntü işlemenin en zor aşamasıdır ve bu yüzden bölütleme yöntemlerinin sonuçlarında belli bir hata oranı da olabilmektedir. Aynı zamanda herhangi

bir görüntü üzerinde bölütleme yapabilecek belirli bir yöntem olduğu da söylenememektedir. Bir ya da daha fazla yöntem birlikte kullanılarak bölütleme yapılabilmektedir (Kızılkaya, 2008).

Gri tonlamalı görüntülerden siyah-beyaz görüntülerin elde edilmesi için yapılan bölütleme işlemlerinde görüntünün piksel değerleri üzerinde bazı temel özellikler kullanılmaktadır. Bunlar gri tonlamalı değerlerin benzerliği ve süreksizliğidir. Süreksizlik bilgisi kullanılarak görüntülerin kenar tespiti yapılabilmektedir. Bunun için gri tonlama değerlerindeki ani değişimler dikkate alınmaktadır. Benzerlik bilgisine dayanarak görüntüyü bölgelere ayırma işlemleri yapılabilmektedir (Wu, 2011).

Bu tez çalışmasında gri seviye görüntüler üzerinde arkaplanı bölütlemek amacıyla manuel eşikleme ve çürük alanların tespitinde ise yinelemeli eşikleme yöntemleri kullanılmıştır.

### Eşikleme

Görüntü bölütlemede en sık kullanılan teknik, histogram tabanlı bölütleme yöntemi olan eşiklemedir. Eşikleme tekniği, bölütleme işleminde birbirine benzeyen görüntü kümelerini oluşturmayı sağlamaktadır. Bu işlem sonucunda elde edilen görüntüde belirlenen eşik değerine bağlı olarak bir bilgi kaybı söz konusu olmaktadır (Kızılkaya, 2008).


Eşikleme işlemi genellikle gri tonlamalı görüntüler üzerinde yapılır. Ancak gerçek hayatta görüntüler RGB gibi üç boyutlu renk uzaylarında ifade edilmektedir. RGB renk uzayındaki bir görüntüyü gri tonlamalı görüntüye çevirmek için Eşitlik 3.1’de görüldüğü gibi RGB renk kanallarının ağırlıklı ortalaması kullanılmaktadır.

$$X = K_R * R + K_G * G + K_B * B \quad (3.1)$$

Eşitlik 3.1’de  $K_R$ ,  $K_G$  ve  $K_B$  değerleri R, G ve B renk kanallarına ait aydınlatma katsayılarıdır. Bu katsayılar 0 ile 1 arasında olup insan gözünün renklere olan duyarlılığına göre belirlenmektedir. İnsan gözünün yeşil renge daha duyarlı olmasından

dolayısıyla yeşilin aydınlatma katsayısı her zaman daha fazla alınmaktadır. Bu formül kullanılarak elde edilen ağırlıklı ortalama RGB'nin gri tonlamalı karşılığını vermektedir.

Gri tonlamalı görüntüler siyah, beyaz ve aradaki grinin bütün tonlarına dağıtılmış durumdadır. Bu seviyede her rengin değeri 0 ile 255 arasındadır. Eşikleme işlemi için 0 ile 255 arasında bir eşik değeri seçilmektedir. Şekil 3.7'de bir gri tonlamalı görüntü üzerinde eşikleme işleminin nasıl yapıldığı gösterilmektedir.



a) Orijinal görüntü

b) Eşiklenmiş görüntü


Şekil 3.7. Gri tonlamalı görüntü üzerinde eşikleme işlemi

Şekil 3.7.a'da verilen gri tonlamalı görüntü üzerinde eşik değeri 100 seçilmiş ve Eşitlik 3.2'den yararlanarak eşikleme yapılmış ve Şekil 3.7.b'de eşiklenmiş ikili görüntü elde edilmiştir.

$$P = \begin{cases} 1, & P > E \\ 0, & \text{Değilse} \end{cases} \quad (3.2)$$

Eşitlik 3.2'de  $E$  eşik değerini ve  $P$  piksel renk ton değerini göstermektedir. Eğer pikselin renk ton değeri bu eşik değerinden büyükse piksel renk ton değeri ikilik sayı sisteminde '1', değilse '0' yapılmaktadır.

RGB görüntü üzerinde eşikleme yapmak için RGB görüntünün kanallarını kullanmak gerekmektedir. Şekil 3.8'de RGB görüntünün R ve G kanalı üzerinden yapılan eşikleme işlemi gösterilmektedir.



a) Orijinal görüntü

b) Eşiklenmiş görüntü

Şekil 3.8. RGB görüntü üzerinde eşikleme işlemi

Şekil 3.8.a’da orijinal RGB görüntü ve Şekil 3.8.b’de R ve G kanalları üzerinden eşikleme işlemine tabi tutulmuş ikili görüntü gösterilmektedir. Eşikleme işlemi için şart olarak R kanalı değerlerinin G kanalı değerlerinden daha büyük olması sağlanmıştır. Böylece, Şekil 3.8’de verildiği gibi renk kanalları üzerinde yapılan eşikleme işlemi sonucunda elma nesnelere ve arka planın daha doğru bölütlenmesi sağlanmıştır.

Eşikleme için kullanılan eşik değeri elle belirlenebileceği gibi bazı algoritmalar yardımıyla otomatik olarak da belirlenebilmektedir. Otomatik belirlenen eşik değerine dinamik eşik değeri denmektedir (Kızılkaya, 2008). Eşik değeri görüntünün tamamına uygulamak için seçilen bir değer olabileceği gibi bölgesel olarak uygulanabilecek eşik değerleri de seçilebilmektedir (Wu, 2011).

#### Otsu İmge Eşikleme Algoritması

Gri seviyedeki bir imgeyi bilgi kaybı en az olacak şekilde ikili bir görüntüye çevirmek için optimum bir eşik değerine ihtiyaç vardır. Bu değer deneme yanılma yoluyla el ile bulunabileceği gibi yinelemeli bir algoritma ile de elde edilebilir. Otsu yöntemi, Nobuyuki Otsu tarafından geliştirilen bir yinelemeli eşikleme algoritmasıdır (Otsu, 1979). Yöntemin algoritmik şeması aşağıdaki gibidir.

*Adım 1:* Her bir yoğunluk seviyesinin histogramını ve olasılıklarını hesapla.

*Adım 2:*  $w_i(0)$  ve  $\mu_i(0)$  başlangıç değerlerine ayarla.

*Adım 3:* Bütün olası eşik değerlerini  $t = 1, \dots$  dene.

a.  $w_i$  ve  $\mu_i$  değerlerini güncelle.

b.  $\sigma_b^2(t)$  değerini hesapla.

*Adım 4:* İstenen eşik değeri maksimum  $\sigma_b^2(t)$  değerine karşılık gelen eşik değeridir.

Burada  $w_i$ , sınıf olasılıklarını,  $\mu_i$ , sınıf ortalamasını,  $t$ , eşik değerlerini ve  $\sigma_b^2(t)$ , sınıfiçi varyansı ifade etmektedir. Bu algorithmada ilk olarak bütün eşik değerleri ile elde edilen ikili görüntülerin iki bölümünün de (arka plan ve ön plan) histogram dizileri elde edilir. Bu dizilerden sınıf içi varyans değerleri hesaplanır. Bu değer en küçük olması optimum eşik değerinin elde edildiği anlamına gelir. Hesaplamaların daha az olması açısından sınıflar arası varyans değerine de bakılabilir. Bu değer de maksimum olması aranır.

Varyans, verilerin aritmetik ortalamadan sapmalarının karelerinin aritmetik ortalamasıdır ve Eşitlik 3.3'deki gibi hesaplanır:

$$\sigma^2 = \sum_{i=1}^N (x_i - \bar{x}_i)^2 P(x_i) \quad (3.3)$$

Eşitlik 3.3'de  $\bar{x}_i$ , ağırlıklı ortalama ve  $P(x_i)$ , renk değerlerinin olasılık fonksiyonudur. Bir görüntü üzerinde bir renk değerinin olasılığı bu renk değerinin görüntüdeki sayısının, görüntüdeki toplam piksel sayısına oranıdır.

Normalize edilmiş bir ağırlıklı ortalama değeri ağırlıklar toplamı 1 olmak koşuluyla (yani,  $w_0 + w_1 + \dots + w_n = 1$ ) Eşitlik 3.4 kullanılarak hesaplanır.

$$\bar{x} = w_0 x_0 + w_1 x_1 + \dots + w_n x_n \quad (3.4)$$

Sınıf içi varyans değeri, Eşitlik 3.5 ile hesaplanmaktadır.

$$\sigma_w^2 = w_0\sigma_0^2 + w_1\sigma_1^2 \quad (3.5)$$

Eşitlik 3.5'te  $w_0\sigma_0^2$ , ilk sınıfa ait ve  $w_1\sigma_1^2$ , ikinci sınıfa ait ağırlık ve varyans değerlerinin çarpımıdır.  $w_0$  ve  $\mu_0$ , ilk sınıfa,  $w_1$  ve  $\mu_1$ , ikinci sınıfa ait ağırlık ve ağırlıklı ortalama değerleri iken sınıflararası varyans değeri Eşitlik 3.6 ile hesaplanır:

$$\sigma_B^2 = w_0(\mu_0 - \mu_T)^2 + w_1(\mu_1 - \mu_T)^2 = w_0w_1(\mu_1 - \mu_0)^2 \quad (3.6)$$

Toplam varyans değeri Eşitlik 3.7, Eşitlik 3.8 ve Eşitlik 3.9 ile hesaplanır.

$$\sigma_T^2 = \sum_{i=1}^L (i - \mu_T)^2 P_i \quad (3.7)$$

$$\sigma_w^2 + \sigma_B^2 = \sigma_T^2 \quad (3.8)$$

$$\eta(k) = \sigma_B^2(k) / \sigma_T^2 \quad (3.9)$$

Her bir eşik değeri (0-255) için sınıfıçi veya sınıflararası varyans değeri hesaplandıktan sonra en küçük sınıfıçi varyans ya da en büyük sınıflararası varyans değerini veren eşik değeri en uygun değer olarak kabul edilir.  $\eta$  değerini en fazla yapan veya aynı şekilde Eşitlik 3.10'da arama yoluyla seçilen  $\sigma_B^2$  değerini en fazla yapan  $k^*$ , en iyi eşik değeri olarak kabul edilir.

$$\sigma_B^2(k^*) = \max_{1 \leq k < L} \sigma_B^2(k) \quad (3.10)$$

Otsu'nun yöntemini kullanarak geliştiren çok sayıda yöntem bulunmaktadır. Bunlardan birisi de Otsu çok seviyeli eşiklemedir (Raja ve ark., 2014).




## Çok Seviyeli Eşikleme


Bir görüntüdeki birden farklı aydınlık seviyesinde bölgeler bulunabilir. Bu durumda her bir aydınlık bölgesi için farklı bir eşik değeri belirlemek daha doğru bir sonuç verecektir. Literatürde, sürü optimizasyon yöntemleri gibi farklı teknikler kullanılarak çok seviyeli eşikleme yapılmıştır (Chao ve ark., 2016; He ve Huang, 2017; Raja ve ark., 2014; Vennila ve Thamizhmaran, 2017).

## Yerel Adaptif Eşikleme


Yerel Adaptif Eşikleme (LAT), düzensiz aydınlık değerlerine sahip görüntülerde nesne ile arka planı birbirinden ayırmak amacıyla kullanılan bir adaptif eşikleme algoritmasıdır. Adaptif eşikleme, eşik değerini dinamik olarak değiştirerek görüntü üzerinde, aydınlatma açısı ya da gölgelerden kaynaklanabilen değişen ışık koşullarına ayak uydurabilir. Adaptif eşikleme, görüntüdeki her bir piksel için bir eşik değeri hesaplar. Eğer piksel değeri hesaplanan eşik değerinin altındaysa arka plan olarak, aksi durumda ön plan olarak varsayılır. Burada eşik değerini hesaplamak için farklı yaklaşımlar bulunmaktadır. Bütün yöntemlerin arkasındaki ana varsayım, daha küçük görüntü bölgelerinin yaklaşık olarak eşit aydınlatmaya sahip olma olasılığının daha yüksek olmasıdır. Bu da eşikleme için daha uygundur (Fisher ve ark., 1996). Şekil 3.9'da LAT işlemi örnek üzerinde gösterilmektedir.



a) Orijinal Görüntü



b) Global Eşikleme (80)



c) Yerel Eşikleme (7x7)

Şekil 3.9. LAT yöntemi örneği

Chow ve Kaneko (1972), bir görüntüyü çakışan bir alt görüntü alt görüntü dizisine böler. Sonra onun histogramını inceleyerek her bir alt görüntü için optimum eşiği bulur. Her bir piksel için eşik, alt görüntülerin sonuçlarının enterpolasyonu ile bulunmuştur. Bu yöntemin dezavantajı, hesaplamanın uzun olması ve bu yüzden gerçek zamanlı uygulamalar için uygun olmamasıdır.

Yerel eşiğin bulunmasında alternatif bir yaklaşım ise her pikselin yerel komşuluğundaki yoğunluk değerlerini istatistiksel olarak incelemektir. Bunlar da çoğunlukla, ortalama, ağırlıklı ortalama, varyans, medyan, gaussian ağırlıklı ortalama ve hareketli ortalamadır. En uygun istatistik büyük ölçüde girdi imgesine bağlıdır. Basit ve hızlı fonksiyonlar, yerel yoğunluk dağılımının ortalamasını içerir. Komşuluk pencere büyüklüğü, ön plan ve arka plan piksellerini kapsayacak kadar büyük olmalıdır, aksi takdirde zayıf bir eşik değeri seçilir. Küçük pencere boyutu kullanmak daha fazla hesaplama zamanı gerektirirken, çok büyük bölgelerin seçilmesi, yaklaşık olarak eşit aydınlatma varsayımını ihlal edebilir (Wellner, 1993).

Sauvola ve Pietikäinen (2000), geliştirdikleri yöntemde her pikselin yerel ortalama ve yerel varyansını hesaplayarak bir eşik değeri bulmuştur. Pikselin değeri bu eşiğe göre ayarlamıştır.

Bradley ve Roth (2007) ise her pikselin parlaklığını, belli boyutta bir pencere içindeki komşu piksellerin ortalama parlaklığından yüzde T daha düşükse siyaha, aksi takdirde beyaza ayarlamıştır. Bu yöntem, neredeyse Sauvola ve Pietikäinen (2000)'in yöntemi kadar iyidir ve hesaplaması da iki kat daha hızlıdır. Çünkü Sauvola ve Pietikäinen (2000)'in yöntemi yerel ortalama ve yerel varyansı hesaplarken, Bradley ve Roth yöntemi ise sadece yerel ortalamayı hesaplamaktadır.

LAT yönteminin tıp alanında ve tarımsal ürünler üzerinde kullanıldığı bir çok çalışma yapılmıştır (ElMasry ve ark., 2008; Zhang ve ark., 2010; Hu ve ark., 2011; Phansalkart ve ark., 2011).

### 3.2.3. Şekilsel işlemler

Matematiksel şekilbilim, geometrik özelliklere sahip şekiller üzerinde yapılan konvolüsyon ve korelasyon gibi işlemler ve tekniklerdir. Bu işlemlerin temelinde küme teori ve topolojisi yatmaktadır. Bu yüzden kümeler üzerindeki bazı temel kavramları kullanmak gerekmektedir. Bunlar kesişim, birleşim, alt küme ve tümleyen gibi kavramlardır.  $P$  ve  $R$  görüntüleri temsil eden iki küme olmak üzere bu kümelerin elemanları koordinatları gösteren ikililerden oluşmaktadır. Örneğin  $P$  kümesinin bir elemanı  $p(px,py)$  şeklinde gösterilmektedir (Vernon, 1991).

$P$  kümesinin bir başka  $c(cx,cy)$  elemanı ile koordinat düzleminde ötelenmesi işlemi Eşitlik 3.11'deki gibi tanımlanmaktadır (Emiroğlu, 2011).

$$(P)_k = \{k \mid k = p + c, \forall p \in P\} \quad (3.11)$$

Görüntü işlemede şekilsel işleme uğrayacak pikseller bir küme olarak düşünülmektedir. Bunun için yapılandırma elemanı olarak bilinen bir filtre bu küme üzerinde gezdirilmektedir. Kare, dikdörtgen gibi simetrik şekillerde ve farklı büyüklüklerde olabilen bu filtrenin bir merkez noktası bulunmakta ve filtrenin her hareketinde bu merkez noktası kümenin bir elemanı üzerine gelmektedir. Daha sonra kümenin bu elemanı üzerinde gerekli şekilsel işlemler yapılmaktadır. Görüntüler üzerinde en sık uygulanan şekilsel işlemler aşındırma, genişletme, açma, kapama ve doldurma işlemleridir. Bu işlemler amaca göre sırasıyla uygulanabilmektedir (Kazan, 2011).

Şekilsel işlemler sırasında yapılandırma elemanı ( $R$ ) ile yapılandırma elemanının o anda üzerinde bulunduğu görüntü kümesinin elemanları ( $P$ ) üzerinde kesişim (mantıksal VE) veya birleşim (mantıksal VEYA) işlemleri yapılmaktadır. Böylece o anki durumun fit veya hit olup olmadığı anlaşılabilir. Eğer  $R$  ile  $P$ 'nin bütün elemanları örtüşüyorsa buna fit, en az bir elemanı örtüşüyorsa buna da hit olma durumu var denmektedir. Aşındırma işlemi için pikselin fit, genişletme işlemi içinse hit olarak tespit edilmesi gerekmektedir. Şekil 3.10 ve Şekil 3.11'de piksellerin fit ve hit olma durumları gösterilmektedir.

0	1	0
1	1	1
0	1	0

a) Görüntü kümesi ( $P$ )

0	1	0
1	1	1
0	1	0

b) Disk biçimli yapılandırma elemanı ( $R$ )

Şekil 3.10. Fit olma durumu

0	0	0
0	0	1
0	0	1

a) Görüntü kümesi ( $P$ )

0	1	0
1	1	1
0	1	0

b) Disk biçimli yapılandırma elemanı ( $R$ )

Şekil 3.11. Hit olma durumu

Şekil 3.10'da gösterilen fit olma durumunun tespit edilebilmesi için  $R$  ile  $P$  kümesinin elemanları arasında Eşitlik 3.12 ve Eşitlik 3.13'te verilen bağıntılar kullanılmaktadır.

$$\begin{aligned}
G = & P(x-1,y-1) \cap R(x-1,y-1) + P(x,y-1) \cap R(x,y-1) + \\
& P(x+1,y-1) \cap R(x+1,y-1) + P(x-1,y) \cap R(x-1,y) + \\
& P(x,y) \cap R(x,y) + P(x+1,y) \cap R(x+1,y) + \\
& P(x-1,y+1) \cap R(x-1,y+1) + P(x,y+1) \cap R(x,y+1) + \\
& P(x+1,y+1) \cap R(x+1,y+1)
\end{aligned} \tag{3.12}$$

$$P(x,y) = \begin{cases} 0, & G \geq 1 \\ 1, & \text{diğer} \end{cases} \tag{3.13}$$

Eşitlik 3.12'de verilen kesişim işlemlerinin toplamından elde edilen değer  $G$  geçici değişkenine atanmaktadır. Eşitlik 3.13'te  $G$ 'nin değerine göre fit olma durumunda görüntü kümesindeki  $P(x,y)$  elemanı aşındırmaya uğrayabilmektedir. Şekil 3.11'de gösterilen hit olma durumunun tespit edilebilmesi için  $R$  ile  $P$  kümesinin elemanları arasında Eşitlik 3.14 ve Eşitlik 3.15'de verilen bağıntılar kullanılmaktadır.

$$\begin{aligned}
G = & P(x-1,y-1) \cup R(x-1,y-1) + P(x,y-1) \cup R(x,y-1) + \\
& P(x+1,y-1) \cup R(x+1,y-1) + P(x-1,y) \cup R(x-1,y) + \\
& P(x,y) \cup R(x,y) + P(x+1,y) \cup R(x+1,y) + \\
& P(x-1,y+1) \cup R(x-1,y+1) + P(x,y+1) \cup R(x,y+1) + \\
& P(x+1,y+1) \cup R(x+1,y+1)
\end{aligned} \tag{3.14}$$

$$P(x, y) = \begin{cases} 1, & G \geq 1 \\ 0, & \text{diğer} \end{cases} \tag{3.15}$$



Eşitlik 3.14’te birleşim işlemlerinin toplamından elde edilen değer  $G$  geçici değişkenine atanmaktadır. Eşitlik 3.15’de  $G$ ’nin değerine göre hit olma durumunda görüntü kümesindeki  $P(x, y)$  elemanı genişletme işlemine uğrayabilmektedir (Abacı, 2012).

#### Aşındırma işlemi

Aşındırma ve genişletme işlemleri görüntü işlemede kullanılan önemli şekilsel işlemlerdir. Bu işlemin yapıldığı pikseller birer küme olarak düşünülür.  $P$  üzerinde işlem yapılan görüntünün parçası ve  $R$  yapılandırma elemanı diye iki küme olmak üzere aşındırma işleminin gösterimi Eşitlik 3.16’da verilmektedir.

$$P \ominus \check{R} = \{k \mid R_k \subset P\} \tag{3.16}$$

Buna göre  $P$  kümesinin  $R$  yapılandırma kümesinin yansıması ile aşındırmaya uğraması,  $k$  elemanı ile ötelenen  $R$  yapılandırma kümesinin  $P$  kümesinin öz alt kümesi olan, yani  $R$  kümesinin bütün elemanlarının  $P$  kümesinin içinde yer aldığı öteleme elemanları kümesi olarak ifade edilebilmektedir. Şekil 3.9’da aşındırmaya uğramış bir görüntü örneği verilmektedir.



a) Orijinal görüntü

b) Aşındırılmış görüntü

Şekil 3.12. Görüntü üzerinde aşındırma işlemi



Şekil 3.12.b’de görüldüğü gibi Şekil 3.12.a’da verilen görüntü üzerinde yapılan aşındırma işlemi ile görüntü daralmakta, çıkıntılar ve girintiler kısalmaktadır (Emiroğlu, 2011). Aşındırma işlemi Matlab dilinde “imerode” fonksiyonu ile gerçekleştirilmektedir.

### Genişletme işlemi

Genişletme işleminin gösterimi Eşitlik 3.17’de verilmektedir.

$$P \oplus \check{R} = [P^c \ominus \check{R}] \quad (3.17)$$

Buna göre  $P$  kümesinin  $R$  yapılandırma kümesinin yansıması ile genişletilmesi için  $P$ ’nin tümleyeni ile  $R$ ’nin yansımasının aşındırma işlemine tabi tutulması gerekmektedir. Şekil 3.13’te genişletmeye uğramış bir görüntü örneği verilmektedir.



a) Orijinal görüntü

b) Genişletilmiş görüntü

Şekil 3.13. Görüntü üzerinde genişletme işlemi



Şekil 3.13.b’de görüldüğü gibi Şekil 3.13.a üzerinde yapılan genişletme işlemi ile görüntü yayvanlaşmakta, çıkıntılar ve girintiler daha fazla ortaya çıkmaktadır. Aşındırma işlemi Matlab dilinde “imdilata” fonksiyonu ile gerçekleştirilmektedir.

#### Açma işlemi

Açma işlemi, görüntü üzerinde sırasıyla aşındırma ve genişletme işlemlerinin yapılması olarak tarif edilebilmektedir. Yani  $P$  kümesinin,  $R$  kümesinin yansıması ile önce aşındırma işlemine tabi tutulması, sonra elde edilen kümenin  $R$  kümesi ile genişletmeye tabi tutulması ile elde edilen sonuç kümesi olarak tarif edilmektedir. Bu işlem Eşitlik 3.18’de verilmektedir.

$$P_R = (P \ominus \check{R}) \oplus R \quad (3.18)$$

Eşitlik 3.18’de verilen denklemde  $\check{R}$  ifadesi  $R$  kümesinin yansımasını ifade etmektedir. Şekil 3.14’te açma işlemine tabi tutulmuş bir görüntü örneği verilmektedir.



a) Orijinal görüntü

b) Açılmış görüntü

Şekil 3.14. Görüntü üzerinde açma işlemi

Şekil 3.14.b’de görüldüğü gibi Şekil 3.14’te verilen görüntüde açma işlemine uğrayan nesnelere üzerindeki küçük çıkıntılar kaybedilebilmektedir. Nesneyi bir arada tutan küçük bağlar koparak nesne birden çok parçaya ayrılabilir ve bu işlemde yapılandırma elemanı küçük nesnelere de yok edilebilmektedir. Aşındırma işlemi Matlab dilinde “imopen” fonksiyonu ile gerçekleştirilmektedir.



### Kapama işlemi

Kapama işlemi, görüntü üzerinde sırasıyla genişletme ve aşındırma işlemlerinin yapılması olarak tarif edilebilmektedir. Yani  $P$  görüntü kümesinin  $R$  yapılandırma elemanının yansıması ile önce genişletmeye tabi tutulması, sonra elde edilen kümenin  $R$  yapılandırma kümesi ile aşındırmaya tabi tutulması ile elde edilen sonuç kümesi olarak tanımlanabilmektedir. Bu işlem Eşitlik 3.19’deki gibi ifade edilmektedir.

$$P^R = (P \oplus \check{R}) \ominus R \quad (3.19)$$

Şekil 3.15’de kapama işlemine tabi tutulmuş bir görüntü örneği verilmektedir.





a) Orijinal görüntü

b) Kapatılmış görüntü

Şekil 3.15. Görüntü üzerinde kapama işlemi


Şekil 3.15.b’de görüldüğü gibi Şekil 3.15.a’da verilen görüntü üzerinde yapılan kapama işlemi ile nesnelerin dış kısımlarında kalan detaylar kaybolabilmekte ve birbirine yakın nesneler birleşebilmektedir (Emiroğlu, 2011). Aşındırma işlemi Matlab dilinde “imclose” fonksiyonu ile gerçekleştirilmektedir.

#### Boşluk doldurma işlemi

Boşluk doldurma işlemi için şekilsel olarak yeniden yapılandırmaya dayalı bir algoritma kullanılmaktadır. Doldurma işlemi Eşitlik 3.20’deki gibi ifade edilmektedir.

$$P_k = (P_{k-1} \oplus R) \cap A^c \quad k = 1, 2, 3, \dots \quad (3.20)$$

Burada  $A$ , görüntüyü,  $A^c$ ,  $A$ ’nın tümleyenini ve  $R$ , yapılandırma elemanını ifade etmektedir.  $P$ ,  $A$  ile aynı boyutta, ilgilenilen alandaki tüm doldurulmuş delikleri ve sınırları içeren bir matristir. Algoritmanın her adımında yapılan genişletme işlemini sonlandırmak için  $P = P_k$  şartına bakılmaktadır. Doldurma işlemi, koşullu bir genişletme işlemine benzetilebilmektedir. Şekil 3.16’da doldurma işlemine uğramış görüntü örneği verilmektedir.



a) Orijinal görüntü

b) Doldurulmuş görüntü

Şekil 3.16. Görüntü üzerinde doldurma işlemi

Şekil 3.16.b’de görüldüğü gibi Şekil 3.16.a’da verilen görüntü üzerinde yapılan doldurma işleminden sonra görüntüdeki boşluklar kapanmıştır (Gonzalez ve Woods, 2002). Boşluk doldurma işlemi Matlab dilinde “imfill” fonksiyonu ile gerçekleştirilmektedir.

### 3.2.4. Görüntünün türevi ve kenar bulucular

Görüntünün birinci türevi kenar bölgelerinde en büyük değere yani yerel maksimuma sahip olmaktadır. İkinci türevi ise kenar bölgelerinde sıfır değerini üretmektedir. Bu şekilde görüntünün kenarları belirlenebilmektedir. Birinci türev gradyan tabanlı, ikinci türev ise Laplasyan tabanlı yöntemler olarak anılmaktadır (Kızılkaya, 2008).

İki boyutlu sayısal fonksiyonlarda türev işlemleri Eşitlik 3.21’deki gibi fark denklemleri ile ifade edilebilir.

$$\begin{aligned} \frac{df(x, y)}{dx} \cong & [f(n_1 + 1, n_2 + 1) - f(n_1 - 1, n_2 + 1)] \\ & + [f(n_1 + 1, n_2) - f(n_1 - 1, n_2)] \\ & + [f(n_1 + 1, n_2 - 1) - f(n_1 - 1, n_2 - 1)] \end{aligned} \quad (3.21)$$

Burada  $n_1$  ve  $n_2$ , ifade etmektedir. Tek boyutlu bir fonksiyon birinci derece türevi Eşitlik 3.22 ile ikinci derece türevi ise Eşitlik 3.23 ile hesaplanır:

$$\frac{df(x)}{dx} = f(x+1) - f(x) \quad (3.22)$$

$$\frac{d^2f(x)}{dx} = f(x+1) + f(x-1) - 2f(x) \quad (3.23)$$

Yukarıdaki denklemlerin matris olarak ifadesi aşağıda Çizelge 3.6'da gösterilmektedir. Burada  $n_1 = x$  ve  $n_2 = y$  dir.

Çizelge 3.6. Tek boyutlu bir fonksiyon ikinci derece türevi

$x - 1$	$x$	$x + 1$	
$n_1 - 1, n_2 + 1$	$n_1, n_2 + 1$	$n_1 + 1, n_2 + 1$	$y + 1$
$n_1 - 1, n_2$	$n_1, n_2$	$n_1 + 1, n_2$	$y$
$n_1 - 1, n_2 - 1$	$n_1, n_2 - 1$	$n_1 + 1, n_2 - 1$	$y - 1$

Şekil 3.17'de yönlü kenar bulucular için filtre tasarımları gösterilmektedir.

Düşey

Yatay

-1		1	-1		1	-1	-1	-1	-1	-2	-1
-1		1	-2		2						
-1		1	-1		1	1	1	1	1	2	1

45 derece açılı

	1	1	1	1	
-1		1	1		-1
-1	-1			-1	-1

Şekil 3.17. Yönlü kenar bulucular için filtre tasarımları

Yönsüz kenar bulucular Eşitlik 3.24 ile  $|df(x,y)|$  fonksiyonunun ayrık yaklaşımı ile geliştirilebilmektedir.

$$|df(x, y)| = \sqrt{\left(\frac{df(x, y)}{dx}\right)^2 + \left(\frac{df(x, y)}{dy}\right)^2} \quad (3.24)$$

Biçiminde elde edilir. Burada  $|df(x, y)|$ ,  $df(x, y)$  gradyan vektörünün genliğidir.

$$|df(x, y)| \cong \sqrt{(f_x(n_1, n_2))^2 + (f_y(n_1, n_2))^2} \quad (3.25)$$

Burada:

$$f_x(n_1, n_2) = f(n_1, n_2) \otimes h_x(n_1, n_2) \quad (3.26)$$



$$f_y(n_1, n_2) = f(n_1, n_2) \otimes h_y(n_1, n_2) \quad (3.27)$$

Biçiminde tanımlı olup,  $h_x(n_1, n_2)$  ve  $h_y(n_1, n_2)$  yönsüz kenar bulucuların x ve y doğrultusundaki maskeleridir. Buna göre, Sobel, Prewitt ve Canny kenar bulucuların  $h_x$  ve  $h_y$  maskeleri Şekil 3.18'de görüldüğü gibidir.

Sobel			Prewitt								
-1		1	1	2	1	-1		1	1	1	
-2		2				-1		1			
-1		1	-1	-2	-1	-1		1	-1	-1	
Dikey			Yatay			Dikey			Yatay		
Canny											
		1		1							
		-1								-1	

Şekil 3.18. Yönsüz kenar bulucular için filtre tasarımları

Şekil 3.19 ‘da yukarıdaki maske kullanılarak Prewitt kenar bulma yöntemi ile elde edilen ikili görüntü gösterilmektedir.



a) Orijinal görüntü

b) Kenarları elde edilmiş görüntü

Şekil 3.19. Prewitt kenar bulma örneği

Şekil 3.19.a’deki gri tonlamalı elma görüntüsü üzerinde Prewitt kenar bulma yöntemi uygulanarak Şekil 3.19.b’deki kenar bölgeleri ortaya çıkmış olan ikili görüntü elde edilmiştir.

### 3.2.5. Laplasyan (ikinci türev) tabanlı kenar bulucular

Birinci türevin en büyük veya en küçük olduğu noktada ikinci türevi sıfıra eşittir. Sıfır geçiş noktalarına bakarak görüntünün kenarlarına ulaşmak mümkündür (Kızılkaya, 2008).

$$d^2f(x, y) = d(df(x, y)) = \frac{d^2f(x, y)}{dx^2} + \frac{d^2f(x, y)}{dy^2} \quad (3.28)$$

İki boyutlu bir  $f(n_1, n_2)$  dizisi için ikinci dereceden kısmi türevler ikinci dereceden fark denklemleri ile ifade edilebilir. Bu denklemler Eşitlik 3.29 ve Eşitlik 3.30’da gösterilmektedir.

$$\begin{aligned}
d^2 f(x, y) &= d^2 f(n_1, n_2) = f_{xx}(n_1, n_2) + f_{yy}(n_1, n_2) \\
&= f(n_1 + 1, n_2) + f(n_1 - 1, n_2) + f(n_1, n_2 + 1) \\
&\quad + f(n_1, n_2 - 1) - 4f(n_1, n_2)
\end{aligned} \tag{3.29}$$

$$d^2 f(n_1, n_2) = f(n_1, n_2) \otimes h(n_1, n_2) \tag{3.30}$$

### 3.2.6. Genel histogram eşitleme

Histogram, görüntüde piksellerin gri değerlerine ilişkin bağıl sıklık ölçütüdür. Histogram eşitleme, karşıtlık zenginleştirme yöntemlerinden birisidir. Görüntünün histogramında renk değerleri bir bölgede yoğunluk göstermiş ise bu görüntünün karşıtlığı yüksektir. Görüntüde parlaklığın en çok toplandığı alana en büyük karşıtlık zenginleştirme uygulanır. Histogram eşitleme işleminin algoritmik adımları aşağıdaki gibidir (Gonzalez ve Woods, 2002).


*Adım 1:* Görüntüye ait histogramda her bir sütunda tekrarlanan piksel sayısının toplam piksel sayısına olan oranları hesaplanır.

*Adım 2:* Birikimli oranları hesaplanır ve oranlar toplanır.

*Adım 3:* Gri değer aralıklarına ait oranlar hesaplanır.

*Adım 4:* Birikimli oranları ile gri değer aralıklarına ait oranlar karşılaştırılır ve yeni histogram elde edilir.

Şekil 3.20’de histogram eşitlemenin uygulanmasına ait bir örnek gösterilmektedir.



a) Orijinal görüntü

b) Histogram eşitleme uygulanmış görüntü

Şekil 3.20. Histogram eşitleme örneği

Şekil 3.20.a’daki gri tonlamalı görüntü üzerinde histogram eşitleme uygulanarak Şekil 3.20.b’deki görüntü elde edilmiştir.

### 3.2.7. Adaptif histogram eşitleme

Adaptif histogram eşitleme, dar bir bölgede yoğun dağılıma sahip görüntülerde gürültü oluşması problemini çözmek için kullanılan yerel histogram eşitleme algoritmasıdır. Bu algoritmada temel görüntü dikdörtgensel alt bölgelere bölünür ve her bölgeye histogram eşitleme uygulandıktan sonra alt bölgeler birleştirilerek ana görüntü yeniden elde edilir (Teo, 2003). Adaptif histogram eşitleme işleminin algoritmik adımları aşağıdaki gibidir.



*Adım 1:* Görüntünün boyutuna göre bir çerçeve belirle.

*Adım 2:* Çerçeveyi görüntünün sol üst köşesine konumla.

*Adım 3:* Her çerçeve için genel histogram eşitleme algoritması uygula.

*Adım 4:* Alt bölgeleri birleştir.

Çalışmada kullanılan bir elma görüntüsüne adaptif histogram eşitleme algoritmasının uygulanması sonucu elde edilen görüntü ve histogram grafiği Şekil 3.21’de gösterilmektedir.



a) Orijinal görüntü

b) AHE uygulanmış görüntü

Şekil 3.21. AHE uygulaması

Şekil 3.21.a'daki gri tonlamalı görüntü üzerinde AHE uygulanarak Şekil 3.21.b'deki görüntü elde edilmiştir. AHE uygulanmış görüntüdeki detayların daha belirgin hale geldiği görülebilir.

### 3.3. Renkli Görüntü İşleme

Bu bölümde renk ve renkli görüntü işleme yöntemleri detaylı bir şekilde anlatılmıştır.

#### 3.3.1. Renk

Renk, ışık demetlerinin cisimlere çarpıp yansıyarak farklı dalga boylarında gözümüze ulaşması ve ardından beyindeki görme merkezi tarafından yorumlanması ile meydana gelen algılama olarak tarif edilebilmektedir. Gözümüzde rengi algılayan fotoreseptörler (koni hücreleri) bulunmaktadır. Sinirler aracılığıyla gözden beyne ulaşan renkler kırmızı, yeşil veya mavidir. Diğer renkler ise bu üç ana rengin farklı oranlarda beyinde yorumlanmasıyla elde edilmektedir. Gözümüz ancak 380 nm ile 740 nm dalga boyları arasındaki ışığı görebilmektedir. Göremediğimiz dalga boylarına sahip renkler ise mor ötesi ışınlar ya da kızılötesi ışınlar olarak adlandırılmaktadır (Bastı, 2005). Bunlar ise elektronik aygıtlar yardımıyla gözümüzle algılanabilir hale getirilebilmektedir. Şekil 3.22'de insan gözünün görebildiği renkler ve bunların dalga boyları gösterilmektedir.




Renk	Dalga Boyu
Mor	380-440 nm
Mavi	440-485 nm
Cam Göbeği	485-500 nm
Yeşil	500-565 nm
Sarı	565-590 nm
Turuncu	590-625 nm
Kırmızı	625-740 nm

Şekil 3.22. Görülebilen renklerin dalga boyları

Şekil 3.22'de görüldüğü gibi algılayabildiğimiz her rengin dalga boyları farklı aralıklarda bulunmaktadır.

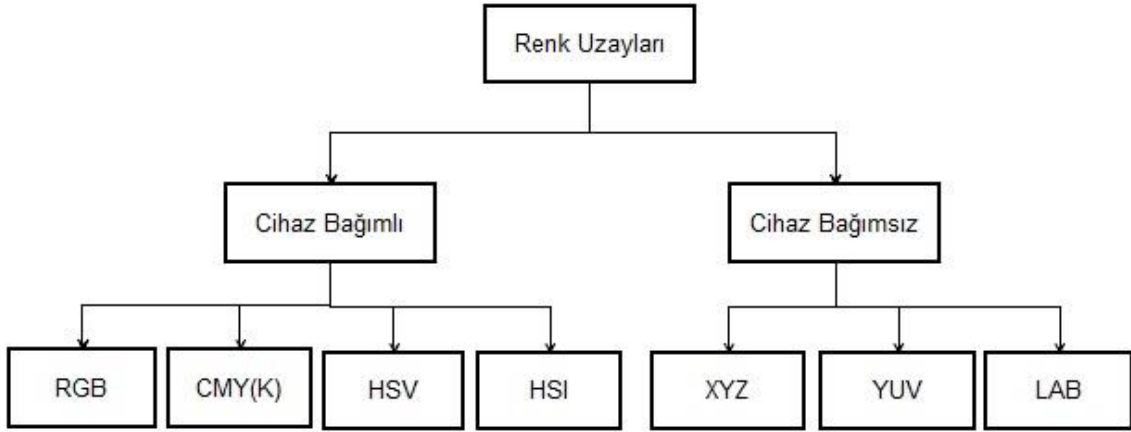
### 3.3.2. Renk uzayları

Renklerin makinelerce tanımlanabilmesi amacıyla üç veya dört boyutlu olarak oluşturulan soyut matematiksel modellerdir. Şekil 3.23'te insan gözünün görebildiği renk alanını gösteren ve gamut olarak bilinen yapı gösterilmektedir.



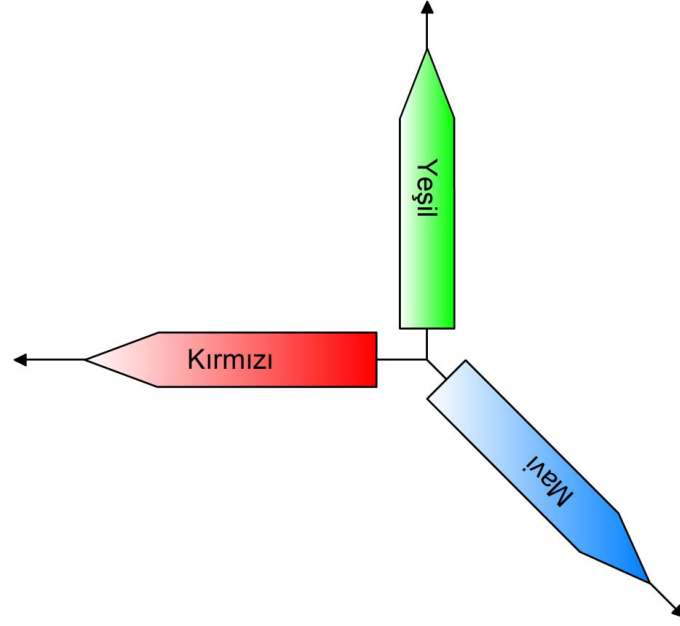
Şekil 3.23. Görülebilen renk alanları (Bastı, 2005)

Şekil 3.23'te A insan gözünün renk alanı, B renkli filmin renk alanı, C monitörün renk alanı ve D baskı renk alanını göstermektedir. Renk uzaylarını kullanan makineler genellikle baskılama ya da görüntüleme aygıtlarıdır. Eğer bir renk uzayı bir aygıtın tasarımına dayanarak oluşturulmuş ise buna cihaz bağımlı renk uzayı denmektedir. Uluslararası Aydınlatma Komisyonu (CIE) tarafından elde edilen cihaz bağımsız renk uzaylarında ise standart gözlemci ( $2^\circ$ ,  $10^\circ$ ) ve standart aydınlatıcı (A, B, C, D50, D65, E, F) olmak üzere iki sabit değer belirlenmektedir. Şekil 3.24'te renk uzaylarından bazıları gösterilmektedir (Gonzalez ve Woods, 2004).



Şekil 3.24. Renk uzayları

RGB renk uzayı adını kırmızı, yeşil ve mavi renklerin İngilizce baş harflerinden alan koordinat eksenleri bu üç rengin temsil ettiği bir uzaydır. Bir rengi ifade etmek için kullanılan bu koordinatların her biri 0 ile 255 arasında değişen değerler almaktadır. Bilgisayar monitörü gibi görüntüleme aygıtlarında ve tarayıcı cihazlarda kullanılmaktadır (Yılmaz, 2002). RGB renk uzayında oluşturulmuş bir görüntü sayısal ortamda  $M \times N \times 3$  boyutlarında bir matris şeklinde indekslenmektedir. Burada M ve N görüntünün piksel cinsinden boyutlarını, üçüncü boyut ise kırmızı, yeşil ve mavi rengin oranlarını ifade etmektedir (Gonzalez ve Woods, 2004). Şekil 3.25'te RGB renk uzayının renk kanalları gösterilmektedir.



Şekil 3.25. RGB renk uzayı

### 3.4. Harris Köşe Algılama Algoritması

Köşe bulma görüntü işlemenin en önemli konularından biridir. Bir görüntüdeki köşelerin tespiti nesnelerin hatları hakkında önemli bilgiler verebilmektedir. Köşe bulma konusunda birçok algoritma geliştirilmiştir. Bunlardan birisi de Harris ve Stephens (1988) tarafından geliştirilmiştir.

Görüntüdeki her noktada gradyan yani eğim hesaplanır. Gradyan: görüntüdeki parlaklık değişimidir. Gradyanın yönü  $\tan^{-1}(G_x/G_y)$  ile hesaplanır ve değişimin en fazla olduğu yöndür. Burada  $G_x$ ,  $x$  eksenine göre türev ve  $G_y$ ,  $y$  eksenine göre türevi ifade etmektedir. Harris Köşe Tespitinin algoritmik adımları aşağıdaki gibidir:

*Adım 1:* Her pikselde Gauss türevleri hesapla

*Adım 2:* Her piksel etrafında bir Gauss penceresinde ikinci momentleri hesaplayarak  $H$  matrisini oluştur.

*Adım 3:* Köşe cevap fonksiyonu olan  $R$  yi hesapla.

*Adım 4:*  $R$  'yi eşikle

*Adım 5:*  $R$ 'nin yerel en büyük noktalarını bul


### 3.5. Bresenham Çizgi Algoritması

Bresenham'ın çizgi algoritması, Amerikalı bilgisayar mühendisi Bresenham (1965) tarafından IBM için doğrunun bilgisayar ekranına çizimi için geliştirilen bir algoritmadır. Bresenham Algoritması Doğrudan Çizim Algoritması (DDA)'ya göre daha hızlıdır, çünkü DDA'nın aksine ondalıklı sayılarla (float) işlem yapılmaz. Bresenham algoritması tam sayılarla(int) toplama, çıkarma ve ikiyle çarpma işlemlerini içerir. İkiyle çarpma işlemi shift operasyonu ile assembler düzeyinde çok hızlı yapılabildiğinden, Bresenham algoritması oldukça verimli bir algoritmadır.

Algoritma, Pseudo kod ile şu şekilde ifade edilir (Bresenham, 1965).

```
function line(x0, y0, x1, y1)
  int deltax := abs(x1 - x0)
  int deltay := abs(y1 - y0)
  int error := 2 * deltay - deltax
  int xk := x0
  int yk := y0
  while xk < x1
    xk+1 := xk + 1
    if error > 0
      yk+1 := yk + 1
      error := error + 2 * deltay - 2 * deltax
    else
      yk+1 := yk
      error := error + 2 * deltay
    xk := xk+1
```

Bresenham algoritması verimliliğini, yavaş artan eksenin belirli bir kurala göre arttığını gözlemlemesine borçludur. Hızlı artan eksen her iterasyondan 1 piksel artarken, yavaş artan eksen bazen sabit kalır, bazen bir piksel artar. Şekil 3.26'da doğruyu oluşturan piksellerin tespiti gösterilmektedir.

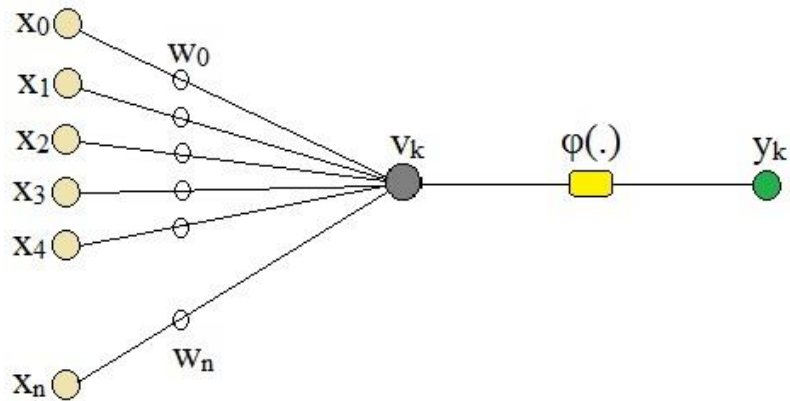


Şekil 3.26. Bresenham'ın çizgi algoritması kullanılıncaya ortaya çıkan bir çizgi (Anonim, 2019)

Şekil 3.26'da görüldüğü gibi bu algoritma sayesinde çapraz bir çizgiyi oluşturmak için hangi piksellerin kullanılması gerektiğine doğru bir şekilde karar verilebilmektedir.

### 3.6. Çok Katmanlı Algılayıcı Sinir Ağı

Çok Katmanlı Algılayıcı Sinir Ağı (MLPNN) için nöronların biyolojik modeline dayanan yapay nöronun (McCulloch ve Pits, 1943) tarafından önerilen gösterimi benimsenmiştir. Bu gösterim Şekil 3.27'de gösterilmektedir.



Şekil 3.27. Nöronun McCulloch-Pitts modeli

Şekil 3.27’de görüldüğü gibi ağda iki katman bulunmaktadır. Bunlar giriş katmanı ve çıkış katmanlarıdır. Ağın giriş katmanında birden fazla nöron varken çıkış katmanında tek nöron vardır. Giriş katmanındaki her bir nöron  $x_i$ , özellik vektöründeki değerleri almaktadır. Giriş katmanından çıkış katmanına olan bir ağırlık matrisi  $w_i$  bulunmaktadır. Eşitlik 3.31 ve Eşitlik 3.32 kullanılarak ağın çıkış değeri  $y_k$  hesaplanmaktadır.

$$v_k = \sum_{i=1}^n w_i x_i \quad (3.31)$$

$$y_k = \varphi(v_k) \quad (3.32)$$

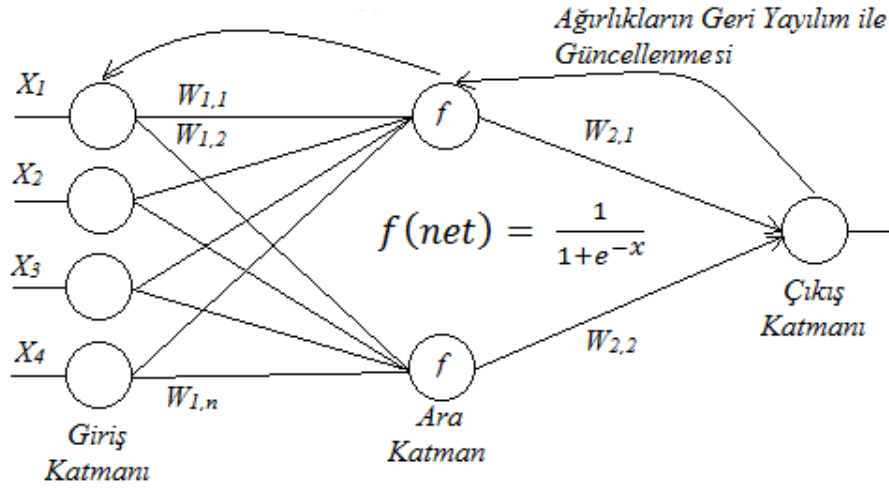
Eşitlik 3.31 kullanılarak her bir giriş ile ağırlık değeri çarpılarak toplanır. Sonra Eşitlik 3.32 kullanılarak bu değer aktivasyon fonksiyonuna girdi olarak verilmekte ve ağın çıkış değeri hesaplanmaktadır. En sık kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant ve adım basamaktır. Eşitlik 3.33’te sigmoid fonksiyonun denklemi verilmiştir.

$$\varphi(n) = 1/(1 + e^{-n}) \quad (3.33)$$

Eşitlik 3.33’te  $e$ , elde edilen çıkış değeri ile gerçek çıkış arasındaki farkı (hatayı) verir. Eğer hata belirlenen eşik değerinden fazla ise ağırlık değerleri güncellenir. Bunun için her bir ağırlığa Eşitlik 3.34’te hesaplanan değer ilave edilir.

$$\Delta w_i(t) = \eta e(t) X_i(t) \quad (3.34)$$

Eşitlik 3.34’te  $\eta$  öğrenme katsayısı,  $e$  hata değeri ve  $X_i$  giriş değeridir. Öğrenme katsayısı 0 ile 1 arasında özenle seçilen bir değerdir. Eğer bu değer küçük olursa ağın öğrenmesi yavaş olur, değer büyük olursa ağın öğrenmesi hızlı olur ama bu kez de hata yüksek olur. MLPNN’de ise giriş katmanı ile çıkış katmanı arasında farklı sayılarda nöron içerebilen gizli katmanlar ve her bir gizli katman için bir ağırlık matrisi bulunmaktadır. Şekil 3.28’de bir MLPNN’nin yapısı gösterilmektedir.



Şekil 3.28. Bir MLPNN'nin Yapısı

Ağdaki gizli katman sayısı ve gizli katmandaki nöron sayısı ağı karmaşıklığını artırır. Bu durum öğrenmeyi iyileştirebilir ancak öğrenme süresini artırabilir. Eğitim için geri yayılım algoritmaları kullanılır. Ağırlık değerleri eğitim azaltma yönteminin hata fonksiyonunu minimize etmesiyle hesaplanır. Hata değeri, geriye doğru giderken aktivasyon fonksiyonunun türevi ile çarpılır. Bu yüzden aktivasyon fonksiyonunun türevinin kolay alınabilmesi ağı öğrenmesini hızlandırır. Hesaplanan bu değer tüm ağırlıklara giriş değerleri oranında dağıtılır (Öztemel, 2003). Ağırlıkların güncellenmesi için Eşitlik 3.35 kullanılır.

$$E = \frac{1}{2} \sum_i e_j^2 = \frac{1}{2} \sum_i (d_j - y_j)^2 \quad (3.35)$$

Eşitlik 3.35'te ağı gerçek çıkış değerleri  $d_j$  ile hesaplanan çıkış değerleri  $y_j$  arasındaki farklar ( $e_j$ ) kullanılarak Ortalama Karesel Hata (MSE) hesaplanır.

$$\Delta W_{ij} = -\eta \frac{dE}{dW_{ij}} = -\eta [-e_j] \left[ \frac{dy_i}{dnet_i} \right] [X_{ij}] \quad (3.36)$$

Eşitlik 3.36'da, daha önceden hesaplanan  $E$  değerinin aktivasyon fonksiyonuna göre türevi alınmıştır. Burada  $\eta$  öğrenme katsayısı ve  $X_{ij}$  giriş değerleridir. Aktivasyon

fonksiyonu sigmoid olarak seçilirse ağırlıkların değişim değerleri  $\Delta W_{ij}$  aşağıda verilen Eşitlik 3.37 ile hesaplanır.

$$\Delta W_{ij} = -\eta e_j(1 - y_j)y_j X_{ij} \quad (3.37)$$

Eşitlik 3.37’de  $(1 - y_j)y_j$  ifadesi sigmoid fonksiyonunun türevidir. Eğitimin bir sonraki adımındaki  $\Delta W_{ij}$  değeri ise Eşitlik 3.38 ile hesaplanabilir.

$$\Delta W_{ij}(t + 1) = -\eta \frac{dE}{dW_{ij}} + \alpha \Delta W_{ij}(t) \quad (3.38)$$

Eşitlik 3.38’de  $\alpha$ , momentum değerini ifade etmektedir. Momentum, eğitimin önceki iterasyonlarındaki ağırlık değişim değerlerinin belli oranda katkısını sağlar. Böylece eğitim yerel minimum değerlerinden etkilenmez.

MLPNN’nin eğitiminin ne zaman durması gerektiğini belirleyecek bir kriter olmadığı takdirde aşırı eğitim meydana gelir. Bu durumda tüm örnekler makine tarafından ezberlenir ve bilinmeyen örneklere karşı tahmin yeteneği azalır. Çapraz geçerliliğe göre bölünen verinin bir alt kümesi olan eğitim kümesi bir daha ikiye bölünür. Bu parçalardan birisi eğitimde ağırlıkların güncellenmesi için kullanılır. Diğer parça olan geçerlik kümesi üzerinde eğitimin başarısı hesaplanır. Başarı grafiğinde keskin bir düşüş meydana geldiğinde eğitim durdurulur (Theodoridis ve Koutroumbas, 2010).


### 3.7. CNN Modeli

Derin öğrenme modelleri, pek çok araştırma alanında olduğu gibi tarım teknolojilerinde de yaygın olarak kullanılan güçlü bir araç haline gelmiştir (Kamilaris ve Prenafeta-Boldú, 2018). Otomatik kodlayıcılar, Kısıtlı Boltzman Makineleri ve CNN en çok kullanılan modellerdir. CNN, görüntüler üzerinde sıkça kullanılan özelleşmiş bir derin öğrenme mimarisidir (Özcan H., 2014). Geleneksel sinir ağlarından en önemli farkı görüntüden özellik çıkartımını kendisinin yapmasıdır. Geleneksel sinir ağlarına göre eğitim zamanı



çok uzun olmasına rağmen birçok görüntü işleme probleminde oldukça başarılı sonuçlar vermektedir. ImageNet2012’de Krizhevsky ve arkadaşlarının derin öğrenme tekniğiyle birinci olmasının ardından, derin öğrenmenin görüntü sınıflandırmadaki başarısı görülmüş ve ertesi yıl ImageNet2013’de, birçok katılımcı derin öğrenme tekniğini kullanmış ve aynı şekilde başarı elde etmişlerdir (Cengil ve Çınar, 2016).

Derin öğrenmenin görüntü işleme alanında en yaygın kullanılan modeli olan CNN mimarisi genel olarak eğitilebilen birçok katmandan oluşmaktadır. Şekil 3.29’da CNN mimarisinin genel yapısı gösterilmektedir.




Şekil 3.29. CNN mimarisinin genel yapısı

Şekil 3.29’da görüldüğü gibi, CNN mimarisi birbirini takip eden evrişim, alt-örnekleme katmanları ve son olarak da tam bağlantılı ve softmax ağından oluşmaktadır. Görüntü ilk olarak parçalara ayrılır ve her bir parça üzerinde filtre uygulanır. Filtre işleminden sonra görüntüde küçülme olur. Bu işlem sonucunda elde edilen pikseller anlamlandırılarak problem çözülmeye çalışılır (Bengio, 2009). Çalışmamızda CNN mimarisi üzerine kurulmuş bir yaklaşım olan ve en yaygın olarak kullanılan Faster R-CNN yöntemi kullanılmıştır.

### 3.8. Faster R-CNN

Faster R-CNN, Bölge Öneri Ağı (RPN) (Ren ve ark., 2017) ile Fast R-CNN ağının (Girshick, 2015) birleştirilmiş halidir. Şekil 3.30’da Faster R-CNN yapısını oluşturan RPN ve Fast R-CNN bölgeleri görülmektedir. RPN’in getirdiği yenilik, doğrudan

örnekleme katmanına bağlanılabilmektedir. Böylece Faster R-CNN, güçlü yapısı ile görüntülerde baştan sona nesne tespitini gerçekleştirmek için bir çalışma ortamı sunar (Ren ve ark., 2017). Şekil 3.30'da çalışmada kullanılan Faster R-CNN mimarisi gösterilmektedir.



Şekil 3.30. Çalışmada kullanılan Faster R-CNN mimarisi (Yang ve ark., 2017)

RPN tam olarak evrışimsel bir sinir ağıdır. Girdisi bir görüntü olan önerilen bölgeleri çıkartmak için kullanılır ve önerilen bölgelere aynı zamanda skorlar (tahmin etme doğruluğu) verilir. Önerilen bölgelerin sınıflama katmanı ve skor değerlerini tahmin katmanı aşamasında Fast R-CNN ağında birleştirilir. Fast R-CNN ağına da iki çıkış katmanı bulunmaktadır. Bunlardan ilki Softmax sınıflayıcı katmanı diğeri ise tespit edilen bölgenin tespit edilme doğruluğunu veren regresyon katmanıdır (Yang ve ark., 2017).

Faster R-CNN ile giriş görüntüsü sınıflandırma süreci boyunca sadece bir kez hesaplanır ve daha sonra tespit edilmesi gereken bölgelerin buldukları yeri belirleyen kutuların sınırlarını düzeltir. Daha da fazlası, evrışimsel katmanların paylaşılması sayesinde, nesne tespitinin performansını geliştirmek için derin bir evrışimsel ağ eğitilebilir.

### 3.9. Doğrusal Regresyon

Regresyon, eldeki veri seti üzerinde sınıflandırma ve tahmin yapmak (doğru uydurmak) için kullanılan en basit yöntemdir. Regresyon için doğrusal ve doğrusal olmayan diye iki yaklaşım vardır. Doğrusal Regresyon (LR) yaklaşımı, giriş değişkenlerinin ağırlıklı toplamı ile çıkış değişkeni arasında belirli bir hata olduğunu varsaymaktadır. Bu durumda giriş değişkenleri ile çıkış arasında doğrusal bir bağlantı vardır. Birden çok özelliğe sahip giriş verisi için kullanılan çoklu doğrusal bir regresyon denklemi Eşitlik 3.39'daki gibi gösterilmektedir.

$$Y = W_0 + \sum_{j=1}^N W_j X_j + E \quad (3.39)$$

Eşitlik 3.39'da yer alan  $W_j$  ağırlık değerlerini,  $X_j$  verinin özellik vektörlerini,  $N$  verideki toplam özellik sayısını,  $E$  hatayı ve  $Y$  ise hedef değişkeni temsil etmektedir. Burada önemli olan  $W_j$  değerlerini bulmaktır. Bunun için en çok kullanılan yöntem En Küçük Kareler Yöntemi (LSM)'dir (Chapra ve Canale, 2003). LSM, karesel hataların toplamını minimum yapan denklem katsayılarını bulmak üzerine kurulmuştur. Bu yönteminin ana prensibi aşağıda Eşitlik 3.40'ta ifade edilen MSE değerinin en küçük yapılmasına dayanmaktadır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (d_i - \bar{d}_i)^2 \quad (3.40)$$

Ortalama Karesel Hata Karekökü (RMSE) değeri ise Eşitlik 3.41'de ifade edilmektedir.

$$RMSE = \sqrt{MSE} \quad (3.41)$$

Eşitlik 3.40'ta ifade edilen  $d_i - \bar{d}_i$  her bir hedef değişken ile hesaplanan doğru denklemi arasındaki hatayı (uzaklığı) göstermektedir. Eşitlik 3.41'de ifade edilen RMSE, ölçülen değerler ile tahminler arasındaki hata oranını tespit etmek amacıyla kullanılmaktadır.

RMSE değerinin sıfıra yaklaşması sistemin tahmin kabiliyetinin artması anlamına gelmektedir (Singh ve ark., 2009).

### 3.10. ABC-Tabanlı Yinelemeli Eşikleme Yaklaşımı

Optimizasyon, bir problemde belirli koşullar altında mümkün olan alternatifler içinden en iyisini seçme işlemidir. Sürü zekâsı tabanlı optimizasyon algoritmaları kuş, balık, kedi ve arı gibi canlı sürülerinin hareketlerinin incelenmesiyle geliştirilmiştir. Ateşböceği Algoritması, Ateşböceği Sürü Optimizasyonu, Karınca Koloni Optimizasyonu, PSO, Yapay Balık Sürüsü Algoritması, Bakteriyel Besin Arama Optimizasyon Algoritması ve Kurt Koloni Algoritması örnek verilebilir (Akyol ve Alataş, 2012; Selva Bhuvaneshwari ve Geetha, 2016).

Bal arılarının akıllı yiyecek arama davranışlarından ilham alan ABC algoritması, sayısal problemleri optimize etmek amacıyla 2005 yılında Karaboğa tarafından geliştirilen global bir optimizasyon ve meta-sezgisel algoritmadır. Kullanıcı tarafından sadece, önceden belirlenmiş, popülasyon büyüklüğü, maksimum yineleme sayısı ve limit olan üç kontrol parametresi kullanır (Karaboğa, 2005). Bu yöntem farklı alanlarda optimizasyon için kullanılmıştır. (Makas ve Yumuşak, 2016; Güvenç ve ark., 2016; Karakuzu, 2017; Önen ve ark., 2019).

ABC-tabanlı yinelemeli eşikleme yaklaşımının adımları şöyle sıralanmaktadır:

*Adım 1:* Sap-çanak bölgeleri çıkarılmış 600x600 piksellik gri seviye elma görüntülerinde, bütün yiyecek kaynağı vektörleri ( $\overline{x_m}$ ) izci arılar tarafından başlangıç konumlarına getirilir. Her bir  $x_m$  elma görüntüsündeki bir pikseli ifade eder.

$$x_{mi} = l_i + rand(0,1) * (u_i - l_i) \quad (3.42)$$

burada,  $x_{mi}$  parametresi, maksimum ve minimum değerler olan  $l_i$  ve  $u_i$  arasında değerler alır.  $l_i$  ve  $u_i$  değerleri her bir elma görüntüsü için sırasıyla 1 ve 600 olarak belirlenmiştir.

*Adım 2:* İşçi arılar, komşuları içerisindeki daha iyi yiyecek kaynaklarına ( $v_m$ ) doğru hareket ederler. Onlar komşularındaki yiyecek kaynaklarını belirlemek için Eşitlik 3.43'ü kullanırlar:

$$v_{mi} = x_{mi} + \phi_{mi}(x_{mi} - x_{ki}) \quad (3.43)$$

Eşitlik 3.43'te  $i$ , değeri rastgele seçilmiş bir parametredir,  $x_k$  rastgele seçilmiş bir yiyecek kaynağı ve  $\phi_{mi}$   $[-a, a]$  aralığında rastgele bir değerdir. Bu şekilde yeni yiyecek kaynağı ( $v_m$ ) belirlenir ve onun uygunluk değeri hesaplanır. Daha sonra  $x_m$  ve  $v_m$  arasında açgözlü bir seçim yapılır. Görüntüdeki piksellerin uygunluk değerleri onların parlaklık değerleri olarak belirlenmiştir. Çürük bölgeler daha koyu olduğundan dolayı düşük parlaklık değerine sahip parçacıklar daha yüksek uygunluk değerine sahiptir.

Çözümün uygunluk değeri olan  $fit_m(\vec{x}_m)$ , minimizasyon problemleri için Eşitlik 3.44 ile hesaplanır:

$$fit_m(\vec{x}_m) = \begin{cases} \frac{1}{1 + f_m(\vec{x}_m)}, & f_m(\vec{x}_m) \geq 0 \\ 1 + abs(f_m(\vec{x}_m)), & f_m(\vec{x}_m) < 0 \end{cases} \quad (3.44)$$

burada,  $f_m(\vec{x}_m)$ ,  $x_m$  çözümünün objektif fonksiyon değeridir.

*Adım 3:* Bir gözcü arı, işçi arılar tarafından sağlanan uygunluk değerleri kullanılarak hesaplanan olasılık değerlerine dayanarak bir yiyecek kaynağı seçer. Burada  $\vec{x}_m$  bir işçi arı tarafından seçilir, olasılık değeri  $p_m$ , aşağıda verilen Eşitlik 3.45 kullanılarak hesaplanır.

$$p_m = \frac{fit_m(\vec{x}_m)}{\sum_{m=1}^{SN} fit_m(\vec{x}_m)} \quad (3.45)$$

Daha sonra seçilen yiyecek kaynağı  $x_m$  ile yeni bir komşu yiyecek kaynağı ( $v_m$ ) Eşitlik 3.44 ile hesaplanır. Adım 2 deki gibi,  $x_m$  ve  $v_m$  arasında tekrar bir seçim yapılır.

*Adım 4:* Bir çözüm geliştirmek için belli sayıda başarısız olan işçi arılar, rastgele yiyecek kaynakları seçen işsiz arılara yani izci arılara dönüşür. Başarısızlık limiti

kullanıcı tarafından belirlenir. Daha sonra bu izci arılar rastgele yeni çözümler aramaya başlar.

*Adım 5:* Şimdiye kadar ulaşılmış en iyi çözümü hafızaya kaydet ve azami yineleme sayısına ulaşılan dek Adım 2'ye git.

### 3.11. PSO-Tabanlı Yinelemeli Eşikleme Yaklaşımı

PSO, 1995'te Eberhart ve Kennedy tarafından önerilen, doğada yiyecek bulmak için sürüler halinde hareket eden kuşların ve balıkların hareketlerini simüle eden bir sürü tabanlı algoritmadır. PSO, bireyler arasındaki sosyal davranışlarla ilgili bilgileri paylaşmaya dayanmaktadır. Her bireye parçacık ve parçacık koleksiyonuna da küme adı verilmektedir. Her parçacık pozisyonu, önceki pozisyon deneyimlerinden yararlanılarak en iyi pozisyona ayarlanmaktadır. Bu işlem, örneğin bu çalışmada kullanılan maksimum yineleme sayısı gibi bir sonlandırma kriterine ulaşana kadar tekrarlanmaktadır (Eberhart ve Kennedy, 1995).

PSO-tabanlı yinelemeli eşikleme yaklaşımının adımları aşağıdaki gibidir:

*Adım 1:* Gri seviye elma görüntüsünde rastgele koordinatlarda oluşturulan parçacıkların başlangıç konumu ve hızıyla ilk sürüyü oluştur.

*Adım 2:* Sürüdeki tüm parçacıkların uygunluk değerlerini hesapla. Bu değer, parçacığın bulunduğu görüntüdeki pikselin renk değeridir.

*Adım 3:* Her bir parçacığın ( $i$ ) en iyi uygunluk değerini o parçacığın  $pbest$  değeri olarak Eşitlik 3.46'ya göre ayarlanır.

$$fitness_i < pbest_i, \quad pbest_i = fitness_i \quad (3.46)$$

*Adım 4:* Güncel en iyi  $pbest$  değerini Eşitlik 3.47'ye göre global en iyi ( $gbest$ ) olarak ayarlanır.

$$gbest = \min(pbest) \quad (3.47)$$

*Adım 5:* Eşitlik 3.48 ve Eşitlik 3.49'a göre her bir parçacığın konumunu ve hızını güncellenir.

$$v_i^{k+1} = v_i^k + c_1 rand_1(pbest_i - x_i^k) + c_2 rand_2(gbest - x_i^k) \quad (3.48)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1} \quad (3.49)$$

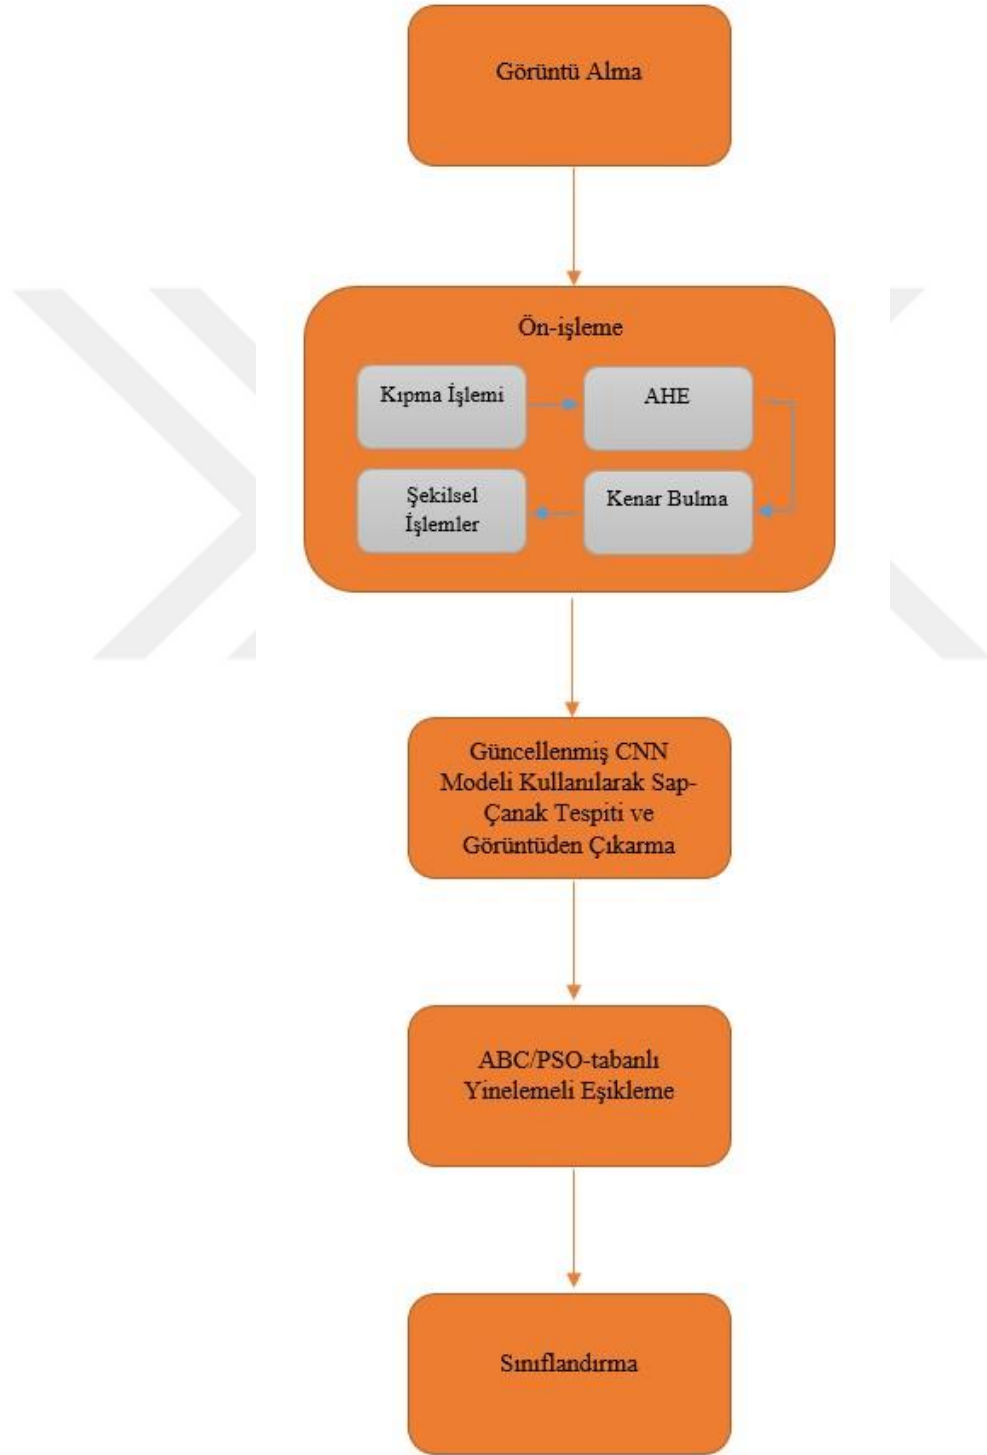
burada,  $x_i^k$  konum ve  $v_i^k$  hızdır,  $c_1$  ve  $c_2$ , her bir parçacığın  $pbest$  ve  $gbest$  konumlarına hareket etme hızını belirleyen sabitlerdir.  $c_1$  parçacığın kendi deneyimlerine göre hareket etmesine izin verirken,  $c_2$  ise parçacığın sürüdeki diğer parçacıkların deneyimlerine göre hareket etmesine izin verir.  $rand_1$  ve  $rand_2$ ,  $[0,1]$  aralığında düzgün dağılımlı rastgele sayılardır.

*Adım 6:* Azami yineleme sayısına ulaşılan dek Adım 2'ye git.

*Adım 7:* Eğer azami yineleme sayısına ulaşıldıysa, parçacıkların son buldukları konumlarına göre uygunluk (parlaklık) değerlerinin ortalamasını hesapla ve bu değeri iteratif eşik değeri olarak belirle (Adem, 2018).

#### 4. BULGULAR ve TARTIŞMA

Bu bölümde tezde yapılan deneyler ve sonuçları ayrıntılı olarak sunulmaktadır. Şekil 4.1’de tezde önerilen hibrit modelin genel adımları gösterilmektedir.



Şekil 4.1. Önerilen yöntemin genel adımları



## 4.1. Elmalarda Sap ve Çanak Tespiti


Bu çalışmada elmalar üzerinde çürük tespitine yönelik yapılan çalışmalar için bir ön işlem olarak elma görüntüsünde sap ve çanak kısımlarının tespiti amacıyla iki farklı yöntem önerilmiştir. Çalışmada Türkiye’de en fazla üretimi yapılan iki tür olan ‘Golden Delicious’ ve ‘Granny Smith’ cinsi elmalardan alınan görüntüler üzerinde çalışan bir görüntü işleme sistemi geliştirilmiştir.

### 4.1.1. Yöntem

Görüntü işleme aşamasında görüntüler üzerinde iki farklı algoritma çalıştırılmıştır. Bunlardan ilki yan pozisyonda alınan görüntülerden sap kısmını tespit etmek için geliştirilen Sap Tespiti Algoritması (STA)’dır. Diğeri ise düz pozisyonda alınan görüntülerden çanak kısmını tespit etmek için geliştirilen Çanak Tespiti Algoritması (ÇTA)’dır.

STA adımları:

- Adım 1:* Ortalama filtre uygulanır.
- Adım 2:* Otsu’nun yinelemeli eşikleme algoritması ile ikili görüntüye çevrilir.
- Adım 3:* Sırası ile aşındırma, kapama, doldurma ve açma işlemleri uygulanır.
- Adım 4:* Harris’in köşe algılama algoritması uygulanarak en güçlü 10 köşe noktası bulunur.
- Adım 5:* Bu noktalardan birbirine en yakın ve iç köşe olan iki tanesi tespit edilir.
- Adım 6:* Bresenham’ın çizgi algoritması kullanılarak bu noktaların arası kesilir. Böylece elmanın sapı ile kendisi birbirinden ayrılmış olur. Bu işlemlerin bir elma üzerinde gösterimi Şekil 4.2’de gösterilmektedir.



Şekil 4.2. STA ile sap tespiti

ÇTA adımları:

*Adım 1:* Ortalama filtre uygulanır.

*Adım 2:* Otsu'nun yinelemeli eşikleme algoritmasına dayalı olarak geliştirilen dört seviyeli eşikleme yapılır.

*Adım 3:* 4'üncü seviyedeki görüntü üzerinde sırası ile aşındırma, kapama ve doldurma işlemleri uygulanarak elmanın çanak kısmı elde edilir. Bu işlemlerin bir elma üzerinde gösterimi Şekil 4.3'te gösterilmektedir.



Şekil 4.3. ÇTA ile çanak tespiti

#### 4.1.2. Sonuç


Çalışmada uygulanan STA yöntemi ile elmaların sap kısımları %82 ve ÇTA yöntemi ile çanak kısımları ise %85 doğruluk ile tespit edilebilmiştir. Bu başarı oranlarının literatür ile karşılaştırıldığında düşük bir oran olduğu görülmüştür. Bu yüzden STA ve ÇTA yöntemlerinin tez çalışmasında sap-çanak tespitinde kullanılmamıştır.

#### 4.2. Faster R-CNN ile Elmalarda Çürük Tespiti

Elmalarda çürük tespitine yönelik çalışmalar incelendiğinde, genellikle hiperspektral veya multispektral görüntüleme sistemlerinin kullanıldığı görülmektedir (Mohana ve Prabhakar, 2015; Lu ve Lu, 2017; Zhang ve ark., 2017). Bu sistemler, elma yüzeylerinde çürüklerin daha iyi tespit edilmesini kolaylaştırmak için spektral bölgenin belirlenmesini mümkün kılmaktadır. Ancak, bu sistemlerin laboratuvar ortamı dışında kullanılması pahalı ve zordur. Bu yüzden çalışmamızda, görüntü elde etme aşamasında bir NIR kamera içeren bir görüntü alma platformu kullanılmıştır.


Bu çalışmada CNN mimarisi üzerine kurulmuş bir yaklaşım olan Faster R-CNN modeli kullanılarak elma görüntülerinde çürük bölgelerin tespiti üzerinde deneyler yapılmıştır (Cömert ve ark., 2019). Uygulama, Matlab yazılım ortamında Intel i7 6700HQ işlemci ve NVIDIA® GeForce® GTX 950M grafik kartı olan bir bilgisayar üzerinde koşturulmuştur.

Şekil 4.4'de uygulamanın işlem adımları gösterilmektedir.



Şekil 4.4. Çürük tespitinin adımları

Şekil 4.4’de görüldüğü gibi, görüntüler üzerinde bir önışlem uygulanmıştır. Bu aşamada önce görüntüde ilgilenilmeyen kısımlar kırpılmış, daha sonra elma ile arka plan bölütlenmiş ve elmanın arka planı tamamen beyaz (255) hale getirilmiştir. Yapılan deneylerde bu durumun çürük tespitinin başarısını artırdığı görülmüştür. Bu işlem Şekil 4.5’te gösterilmektedir.



Şekil 4.5. Önışlem adımları

Burada, Şekil 4.5.a, ön işleme teknikleri olmadan ham elma görüntüsü, Şekil 4.5.b, görüntüden atılan kırpılmış parçaları, Şekil 4.5.c, AHE, Prewitt kenar bulma ve şekilsel işlemler kullanarak elmanın arka planının bölütlenmesini ve arka planın tamamen beyaza dönüştürülmesini göstermektedir. Şekil 4.5.d, bu parçaların karışmasını önlemek için elma kenarlarındaki gölgeler nedeniyle oluşan koyu piksellerin giderilmesi için ikili görüntüye uygulanan erozyon işlemini göstermektedir. Daha sonra görüntülerde elmanın sadece çürük bölgeleri dikdörtgen bir şekilde etiketlenmiş, bu etiketlerden oluşan görüntü veri seti Faster R-CNN modeline giriş olarak verilmiştir.


#### 4.2.1. Deneyler

Faster R-CNN modelinde bulunan iki evriřim katmanının her birinde 3x3 boyutlarında 32 filtre, doldurma deęeri 1 ve adım sayısı 1, örnekleme katmanında ise 3x3 filtre boyutu ve adım sayısı 2 olarak belirlenmiřtir. Tam baęlantılı katmanda sınıflayıcı olarak softmax kullanılmıřtır. Görüntü veri kümesinin %70'i eğitim kalan %30'u ise test ařamasında kullanılmıřtır. Toplam 1 200 adet görüntünün 840 adeti eğitim ve 360 adeti test için kullanılmıřtır. Aęın eğitimi 420 etiketlenmiř çürük elma görüntüsü üzerinde 12 saat sürmüřtür. Çalışmada kullanılan modelin karıřıklık matrisi Çizelge 4.1'de verilmektedir.

Çizelge 4.1. Çalışmada kullanılan modelin karıřıklık matrisi

		Tahmin	
		Çürük	Saęlıklı
Gerçek	Çürük	155	25
	Saęlıklı	29	151

Çizelge 4.1'de görüldüęü gibi gerçekte çürük olan 180 elma görüntüsünün 155 tanesi çürük olarak tespit edilmiř, kalan 25 adet görüntü saęlıklı olarak yanlış sınıflandırılmıřtır. Aynı şekilde, gerçekte saęlıklı olan 180 elma görüntüsünün 151 tanesi saęlıklı olarak tespit edilmiř ve kalan 29 görüntü ise çürük olarak yanlış sınıflandırılmıřtır. Modelin doęru sınıflandırma oranı %84.95 olmuřtur. Şekil 4.6'da modelin test sonuçları görüntüler üzerinde etiketlenmiřtir.



Şekil 4.6. Etiketlenmiş test sonuçları

Şekil 4.6’da etiketler çürük olarak tespit edilmiş bölgeleri ifade etmektedir. Etiketler üzerindeki rakamlar ise etiketlenen bölgenin çürük olma ihtimalini yüzde olarak göstermektedir.


#### 4.2.2. Sonuç ve tartışma

Bu çalışmada bir CNN modeli olan Faster R-CNN kullanılarak elmalar üzerindeki çürük bölgelerin tespiti yapılmıştır. Görüntü verisi olarak 200 adet elmanın 6 farklı açısından alınan 1 200 adet görüntü kullanılmıştır. Deneysel çalışmalar sonucunda tek başına Faster R-CNN modeli kullanıldığında başarı oranının çok yüksek olmadığı (%74) tespit edilmiştir. Bunun en önemli sebebi elmaların anatomik bölgelerinden olan sap-çanak bölgelerinin çürük olarak sınıflandırılmasıdır. Bu yüzden bu bölgelerin görüntüde göz ardı edilmesi gerekmektedir. Ancak bu şekilde başarı oranları yükseltilebilir. Bir sonraki çalışmada planladığımız en önemli hedef, elmanın anatomik bölgelerinden olan sap-çanak kısımlarının görüntüden atılması yolu ile sınıflandırma başarısının artırılmasıdır. Bunun için ilk olarak, derin öğrenme kullanılarak elmanın sap-çanak kısımları tespit

edilecek ve görüntüden atılacaktır. Daha sonra görüntü işleme ile kalan çürük bölgelerin kolayca tespit edilip sınıflandırılması sağlanacak, böylece görüntü işleme ve derin öğrenmenin birlikte kullanıldığı hibrit bir yaklaşım önerilmiş olacaktır (Hekim ve ark., 2019).

#### 4.3. CNN Modeli ve ABC / PSO-Tabanlı Yinelemeli Eşiklemeyi Kullanarak Çürük Tespiti

Bu çalışmada, ilk olarak ön işleme aşamasında kırpma, AHE, kenar algılama ve şekilsel işlemler tüm elma görüntülerine geliştirme amacıyla uygulanmış ve daha sonra sap-çanak bölgelerinin tespiti için CNN modeli kullanılmıştır. Elma görüntülerinde çürük alanların tespitinde, ABC / PSO tabanlı yinelemeli eşikleme yaklaşımı kullanılmıştır (Hekim ve ark., 2019). Şekil 4.7, yaklaşımımızın usulüne ilişkin adımlarını göstermektedir.



Şekil 4.7. Önerilen yaklaşımın usulüne ilişkin adımları

##### 4.3.1. Ön işleme tekniklerini kullanarak görüntüyü geliştirme

Ön işleme aşamasında, çürük alanların tespitini kolaylaştırmak ve elmanın sınıflandırma başarısını arttırmak için, AHE, Prewitt kenar bulma ve şekilsel işlemleri ham elma görüntülerine uygulanmıştır. Şekil 4.5.d, ön işleme teknikleri kullanılarak elde edilen geliştirilmiş görüntüleri göstermektedir. Deneylerde, görüntü ön işleme tekniklerinin, çürük alanların tespit başarısını ve elmanın sınıflandırma başarısını arttırdığı görülmüştür.

#### 4.3.2. CNN modeli kullanılarak sap-çanak anatomik bölgelerinin tespiti

CNN modeli insan görüşü algısından esinlenmiştir. İlk katmanlarda düşük seviyeli nitelikler öğrenilirken, diğer katmanlarda nesnenin belirli kısımlarını oluşturan daha yüksek seviyeli nitelikler öğrenilir. Tipik bir CNN mimarisi, sabit boyutlu bir giriş katmanı, evrişim katmanları, havuzlama (alt örnekleme) katmanları ve tam bağlantılı katmanlardan oluşur. CNN mimarisinde her katman farklı bir rol oynar. Evrişim katmanı özellikleri çıkarırken, tam bağlantılı katman bu özelliklerde sınıflandırmanın yapılmasına izin verir. Havuzlama katmanında, özellik haritalarına bitişik değerlerin maksimum veya ortalaması alınır. Böylece işlemler hızlandırılmış ve bu şekilde boyut küçültülmüş olur. Havuzlama katmanı eğitim süresini kısaltsa da bilgi kaybına neden olabilir. Birden fazla evrişim ve havuzlama katmanları ile işlendikten sonra, elde edilen matrisler tam bağlantılı katmanlara yönlendirilir ve Softmax / RBF gibi fonksiyonlar tarafından parametreler ve ağırlıklar öğrenilir (Lecun ve ark., 1998). Çizelge 4.2, çalışmada kullanılan CNN modellerinin parametrelerini göstermektedir.

Çizelge 4.2. Çalışmada kullanılan CNN modelleri

	CNN modeli		Güncellenmiş CNN modeli	
<b>Giriş görüntüsü boyutu:</b>	32x32x3		600x600x3	
<b>Filtre sayısı:</b>	32		64	
<b>Filtre boyutu:</b>	3x3		3x3	
<b>Evrişim1:</b>	Kayma=1	Dolgu=1	Kayma =4	Dolgu =2
<b>Evrişim2:</b>	Kayma =1	Dolgu =1	Kayma =4	Dolgu =2
<b>Havuzlama:</b>	Havuz boyutu=3	Kayma =2	Havuz boyutu =3	Kayma =2
<b>Tam Bağlantılı:</b>	64		16	

Çizelge 4.2’de gösterildiği gibi, elma görüntülerinde anatomik yapıları belirlemek için güncellenmiş bir CNN modeli kullanılmıştır. Bu modelde kullanılan parametreler değerlendirildiğinde, 600x600 giriş görüntü boyutu ve 64 filtre, görüntüde ayırt edilmesi




gereken bölgelerin daha net tanınmasını sağlar. Görüntü boyutu büyüdükçe, eğitim süresi uzar, ancak artan boyutla başarı artar. Bu yüzden, uygulanan deneysel çalışmalara uygun olarak optimum görüntü boyutu 600x600 olarak belirlenmiştir. Özelliklerin çıkarılmasında kullanılan CNN modelinde ilk katman olan evrişim katmanı, girdilerini elma görüntülerinde etiketli sap-çanak bölgelerinden alır. Önerilen modelde, evrişim katmanları 4 kayma, 2 dolgu ve 3x3 filtre boyutunda bir evrişim çekirdeği kullanır. Evrişim çekirdeğinde kullanılan filtre boyutu çok küçük olduğunda, çıkarılan özelliklerin karmaşıklığı donanımı sınırlarına kadar zorlar, buna karşılık çok büyük olduğunda tespit edilecek alanlar iyi tanımlanamaz. Bu yüzden, CNN'in performansını artırmak için uygun parametreleri kullanmak önemlidir (Girshick, 2015; Adem, 2018). Alt örnekleme katmanı olan maksimum havuzlama katmanında, alt bölgelerin maksimum değeri, önceden belirlenmiş olan ölçek (havuz büyüklüğü) 3 değerine göre alınır. Bu değer, çalışmada 3 değerine ayarlanmıştır, çünkü daha yüksek bir değer, özellik boyutunun çok çabuk küçülmesine neden olarak görüntü kalitesinin azalmasına neden olabilir. CNN mimarisi, geri yayılım yöntemiyle her katmandaki filtreleri öğrenerek ağırlıkları optimize eder. Bu, giriş görüntüsünün ayırt edici özelliklerinin çıkarılmasını sağlar (Lecun ve ark., 2015). Ağırlıkların optimizasyonu sırasında, kütle boyutu 64, momentum 0.85 ve ağırlık azaltma 0.001 olarak alınmıştır.

#### **4.3.3. ABC/PSO-tabanlı yinelemeli eşikleme kullanarak çürük bölgelerin tespiti**

ABC tabanlı yinelemeli eşikleme yaklaşımı için maksimum yineleme sayısı, popülasyon büyüklüğü ve limiti parametreleri, uygulanan deneylerde en yüksek başarıya ulaştığından sırasıyla 25, 60 ve 600 olarak seçilmiştir.

PSO-tabanlı yinelemeli eşikleme yaklaşımı için sonlandırma kriteri olarak kullanılan azami yineleme sayısının ve popülasyon büyüklüğünün parametreleri, uygulanan deneylerde sırasıyla en yüksek başarıya ulaştığından 25 ve 60 olarak seçilmiştir. Hem PSO hem de ABC tabanlı yaklaşımlarda parçacıklar görüntüdeki pikseller üzerine rastgele olarak dağıtılmıştır. Şekil 4.8'de başlangıçta parçacıkların görüntüdeki pikseller üzerine dağılımı gösterilmektedir.



Şekil 4.8. Parçacıkların görüntüdeki pikseller üzerindeki başlangıç konumları


Şekil 4.8’de görüldüğü gibi, parçacıklar elma görüntüsü üzerinde rastgele bir şekilde dağılmıştır.

#### 4.3.4. Deneyler


Uygulama, Intel i7 6700HQ işlemcili ve NVIDIA® GeForce® GTX 950M grafik kartına sahip bir bilgisayarda Matlab yazılım ortamında gerçekleştirilmiştir. Deneysel çalışmalar sonucunda, CNN modelinin doğrudan çürük tespiti için kullanıldığında başarı oranının (%75) çok yüksek olmadığı tespit edilmiştir. Bunun en önemli nedeni, elmanın sap-çanak bölgelerinin çürük olarak sınıflandırılmasıdır. Bu durumun başarısızlığı Şekil 4.6’da gösterilmektedir. Elmalar üzerindeki çürük bölgelerin tespit edilememesinin ana nedeni, elmanın sap-çanak anatomik bölgelerinin çürük alanlarla benzerliğidir. Özellikle çanak bölgelerinin çürük olarak tespit edildiği görülmektedir. Bu yüzden çalışmamızda önce anatomik bölgeler tespit edilmiş ve görüntülerden atılmıştır. Sonra çürükler PSO/ABC-tabanlı yinelemeli eşikleme yöntemleriyle belirlenmiştir.

Anatomik bölgelerin tespiti için kullanılan CNN modelinin eğitimi için ilk olarak sap-çanak bölgeleri görünen görüntüler (960 adet) üzerinde etiketleme işlemi yapılmıştır

(Not: Görüntülerin yalnızca %80'inde sap-çanak etiket bulunmaktadır.). Daha sonra tüm görüntüler (1 200 adet) üzerinde DA işlemi yapılmıştır. Bu işlem genellikle derin öğrenme yöntemleri için tercih edilmekle birlikte sistemin başarı oranını artırması gibi önemli faydalar sağlanmaktadır (Fuentes ve ark., 2017; Wang ve Perez, 2017). Bu işlem, görüntülerin 30 derecelik açılarda döndürülerek yapılmış ve her bir görüntüden 12 adet olmak üzere toplam 14 440 adet görüntü elde edilmiştir. CNN modelinin eğitiminde görüntülerin rastgele %70'i eğitim, %15'i doğrulama ve %15'i test için kullanılmıştır. Eğitim süreci 300 000 yineleme için yaklaşık 102 saat sürmüştür. Eğitim sonucunda elde edilen CNN modelinin test görüntüleri üzerinde tespit ettiği sap-çanak bölgeleri tamamen beyaz (255) yapılarak görüntüden atılmıştır. Şekil 4.9, örnek elma görüntüleri üzerinde anatomik bölgelerin tespiti için geliştirilen CNN modelinin uygulamasından elde edilen görüntüleri göstermektedir.



Şekil 4.9. Elma görüntülerinde CNN modeli kullanılarak anatomik alanların tespiti



Şekil 4.9. (Devam) Elma görüntülerinde CNN modeli kullanılarak anatomik alanların tespiti


Şekil 4.9'da gösterildiği gibi, örnek elma görüntülerinde anatomik bölgelerin tespiti için geliştirilen CNN modeli, sap ve çanak bölgelerinin çürük alanlardan ayırt edilmesinde başarılı olmuştur. Örnek elma görüntülerini seçerken, görüntüleme sırasında karşılaşılan elmanın tüm yönleri (Çürük / Sağlıklı ve Sap / Çanak) dikkate alınmıştır. Görüntülerdeki

çürük alanlar, görüntüden atılacak anatomik bölgelerin tespiti ile daha kolay bir şekilde bölümlenebilir ve böylece artık anatomik bölgelere sahip olmayan görüntüler, çürümüş bölgelerin tespiti için PSO ve ABC-tabanlı yaklaşımların çalışmasını kolaylaştırır. Görüntüler üzerinde DA işlemi yapılmadan önce çürük alanlar uzman tarafından işaretlenerek her bir görüntünün çürük alanı piksel cinsinden kaydedilmiştir. Daha sonra, görüntüdeki çürük alanların görüntünün tamamına oranı %10'dan fazla ise görüntü çürük, değilse görüntü sağlıklı olarak etiketlenmiştir (Burada belirlenen %10'luk eşik değeri meyve suyu üretiminde kullanılabilir elmaların maksimum çürüklük oranıdır).


Sap-çanak bölgeleri atılmış görüntüler PSO-tabanlı yaklaşımda öğrenme katsayıları 2, maksimum hız 30 olarak alınmıştır. ABC-tabanlı yaklaşımda limit parametresi 600, hızlanma katsayısı ise 1 olarak alınmıştır. Yineleme sayısı algoritmalarda 25'e ayarlanmış ve parçacıkların sayısı 60 olarak ayarlanmıştır. PSO ve ABC-tabanlı yaklaşımlarda, parçacıklar algoritmanın adımlarına göre görüntüdeki rastgele pikseller üzerine dağıtılmıştır. Görüntüde dağıtılan piksellerin parlaklık değerleri, parçacıkların uygunluk değerleri olarak belirlenmiştir. Parçacıklar, parlaklık değerlerine göre karşılaştırıldıklarında, daha düşük parlaklığa sahip olan parçacıkların, daha yüksek uygunluk değerlerine sahip olduğu kabul edilmiştir. Tüm yinelemelerin sonuçlarının ortalamaları hesaplanmıştır. Sunulan yaklaşımlar her görüntü için 20 kez tekrar edilmiş ve sonuçların ortalama değeri o görüntü için eşik olarak belirlenmiştir. Eşikleme sonucu oluşan ikili görüntülerde çürük alanların piksel sayıları hesaplanmıştır. Hesaplanan değerlere göre çürük alanların görüntünün tamamına oranları hesaplanmış ve eğer bu oran %10'dan fazla ise görüntü çürük, değilse görüntü sağlıklı olarak etiketlenmiştir. Daha sonra, uzman tarafından kaydedilen sınıf etiketi ile PSO/ABC-tabanlı yinelemeli eşikleme sonucu tespit edilen sınıf etiketi karşılaştırılmıştır.

ABC ve PSO-tabanlı yinelemeli eşikleme yaklaşımlarına ek olarak, sap-çanak bölgeleri olmayan görüntülerdeki çürük alanların tespitinde Otsu çok-seviyeli eşikleme kullanılmıştır. Otsu eşik değeri 4 seviyede uygulanmıştır. Belirlenen eşik değerlerin yalnızca en küçüğü, ABC ve PSO kullanılarak belirlenen değerlere daha yakın olduğu görülmüştür. Otsu tarafından belirlenen diğer seviyeler ise çürük alanlar hakkında bilgi sağlayamamaktadır.

Şekil 4.10, örnek elma görüntüleri üzerinde Otsu, PSO ve ABC-tabanlı yinelemeli eşikleme yaklaşımları kullanılarak elde edilen görüntüleri göstermektedir.



Şekil 4.10. Elma görüntülerinde Otsu, PSO ve ABC-tabanlı yinelemeli eşikleme yaklaşımları kullanılarak elde edilen sonuçlar



Şekil 4.10. (Devam) Elma görüntülerinde Otsu, PSO ve ABC-tabanlı yinelemeli eşikleme yaklaşımları kullanılarak elde edilen sonuçlar

Şekil 4.10'da gösterildiği gibi, çürükler, elma görüntülerinde Otsu ve PSO-tabanlı yinelemeli eşikleme kullanılarak yeterince iyi sınıflandırılmamıştır. Bu yöntemin genellikle sağlıklı alanları çürük olarak sınıflandırdığı görülebilir. Çürük bölgelerin ABC-tabanlı yinelemeli eşikleme kullanılarak daha iyi tespit edildiği görülebilir.

Çalışmada, sınıflandırmanın performansını değerlendirmek için aşağıdaki istatistiksel ölçütleri kullanılmıştır:

- Özgüllük (Specificity): gerçek olumsuz kararların sayısı (TN) / gerçekten olumsuz durumların sayısı (TN + FP).
- Duyarlılık (Sensitivity): gerçek olumlu kararların sayısı (TP) / gerçekten olumlu durumların sayısı (TP + FN).
- Toplam doğru sınıflandırma (TCC): Doğru kararların sayısı (TN + TP) / durumların sayısı (TN + FN + TP + FP).
- Özgüllük, gerçek çürük elmalar arasında çürük nesnelere bulma kapasitesidir ve TN kararlarının gerçek olumsuz durumlara (TN + FP) oranıdır.
- Duyarlılık, gerçek sağlıklı elmalar arasında sağlıklı nesnelere bulma kapasitesidir ve TP kararlarının gerçek pozitif durumlara oranıdır (TP + FN).

- TCC, doğru sınıflandırılmış kararların (TP + TN) tüm durumlara (TP + FN + TN + FP) oranıdır.

Çizelge 4.3, PSO/ABC-tabanlı yinelemeli eşikleme yaklaşımı ile 2166 adet test görüntüsü üzerinde uygulanan sınıflandırmanın karışıklık matrisini göstermektedir.

Çizelge 4.3. ABC ve PSO-tabanlı yinelemeli eşikleme yaklaşımlarının karışıklık matrisi

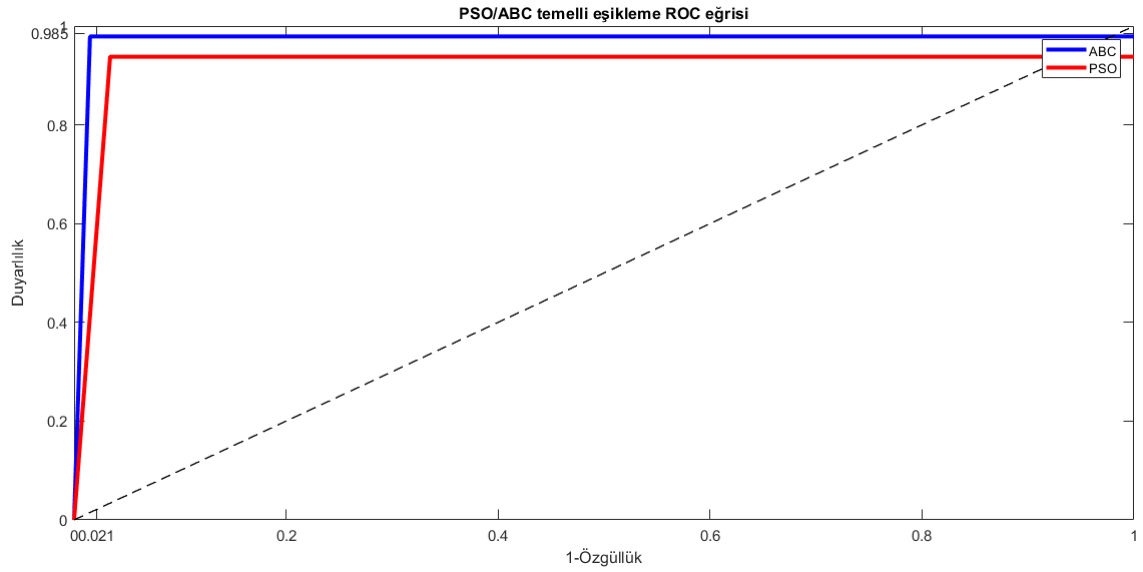
	PSO-tabanlı yinelemeli eşikleme		ABC-tabanlı yinelemeli eşikleme	
	Sağlıklı	Çürük	Sağlıklı	Çürük
Sağlıklı	1303	45	1338	20
Çürük	51	767	16	792

Çizelge 4.3'te gösterildiği gibi, PSO-tabanlı yinelemeli eşikleme yaklaşımı kullanıldığında, 1303 sağlıklı görüntü sağlıklı olarak sınıflandırılmış, 51 sağlıklı görüntü çürük olarak sınıflandırılmış, 45 çürük bölgeye sahip görüntü çürük olarak sınıflandırılmış, 767 çürük alanlara sahip görüntü çürük olarak sınıflandırılmıştır. Sınıflandırmanın performansını değerlendirmek için kullanılan istatistiksel ölçütlere göre, duyarlılık, özgüllük ve TCC oranları sırasıyla %93.82, %96.65 ve %95.58'dir. ABC-tabanlı yinelemeli eşikleme yaklaşımı kullanıldığında, 1338 sağlıklı görüntü sağlıklı olarak sınıflandırılmış, 16 sağlıklı görüntü çürük olarak sınıflandırılmış, çürük alanlara sahip 20 görüntü çürük olarak sınıflandırılmış, çürük alanlara sahip 792 görüntü çürük olarak sınıflandırılmıştır. Buna göre duyarlılık, özgüllük ve TCC oranları sırasıyla %97.99, %98.54 ve %98.33 olmuştur. Her iki modelin değerlendirme kriterleri ve ROC (Receiver Operator Characteristics Curve) eğrisi Çizelge 4.4 ve Şekil 4.11'de gösterilmektedir.



Çizelge 4.4. ABC ve PSO-tabanlı eşikleme yaklaşımlarının duyarlılık, özgüllük ve TCC oranları

Yöntem	Duyarlılık (%)	Özgüllük (%)	TCC (%)
PSO ile eşikleme	93.82	96.65	95.58
ABC ile eşikleme	97.99	98.54	98.33



Şekil 4.11. PSO ve ABC-tabanlı yinelemeli eşikleme yaklaşımlarının ROC eğrileri

Şekil 4.11’de görüldüğü gibi, kullanılan ABC-tabanlı yinelemeli eşikleme yaklaşımı diğerlerinden daha başarılı olmuştur. Ek olarak, her iki yöntem için de sağlıklı nesnelere tespitindeki TP oranı gerçekte çürük olan nesnelere göre daha yüksektir. Önerilen yöntemin özgüllüğü duyarlılık değerinden daha yüksektir. Son yıllarda önerilen yöntemlerin elmalarda çürük tespitine ilişkin başarı oranlarının karşılaştırılması ve önerilen yöntemlerin başarı oranları Çizelge 4.5’te gösterilmektedir.

Çizelge 4.5. Çürük elmanın tespitinde literatür çalışmaları ile sunulan yaklaşımların karşılaştırılması

Yazar	Yıl	Görüntü Sayısı	Hedef	Yöntem	TCC (%)
Xing ve Baerdemaeker	2005	160	Elmadaki çürüklerin tespiti	Yumuşatma, Eşikleme, Hiperspektral görüntüleme	86.4
Mohana ve Prabhakar	2015	600	Elmadaki sap-çanak kısımlarının tespiti	Multifractal, Fourier ve Radon dönüşümleri, SVM(Destek Vektör Makinesi), ANN, k-NN, LDC ve AdaBoost sınıflayıcıları	94
Dubey ve Jalal	2016	320	Elmadaki yaraların otomatik tanımlanması	$L^*a^*b^*$ ve HSV renk uzayları, K-means kümeleme, SVM	93
Lu ve Lu	2017	120	Elmadaki çürüklerin tespiti	Hiperspektral görüntüleme, Intermode, Ridler, Unimode ve Otsu eşikleme	90
Zhang ark.	2017	150	Elmaları çürüklük seviyesine göre sınıflandırma	SVM, Hiperspektral görüntüleme	92.5
<b>Faster R-CNN-model (Cömert ve ark., 2019)</b>	<b>2019</b>	<b>1200</b>	<b>Elmadaki çürüklerin tespiti</b>	<b>CNN (Evrişimsel Sinir Ağı)</b>	<b>84.95</b>
<b>Önerilen model-1 (Hekim ve ark., 2019)</b>	<b>2019</b>	<b>1200</b>	<b>Elmadaki çürüklerin tespiti</b>	<b>CNN+PSO-tabanlı yinelemeli eşikleme</b>	<b>95.58</b>
<b>Önerilen model-2 (Hekim ve ark., 2019)</b>	<b>2019</b>	<b>1200</b>	<b>Elmadaki çürüklerin tespiti</b>	<b>CNN+ABC-tabanlı yinelemeli eşikleme</b>	<b>98.33</b>

Çizelge 4.5’te, ABC ve PSO-tabanlı yinelemeli eşikleme yaklaşımlarının sınıflandırma performansları, makine öğrenme yöntemlerini ve görüntü işleme tekniklerini kullanan literatürde sunulan çalışmalarla karşılaştırılmıştır. Çalışmamızda önerilen yöntemlerin doğruluk oranları %95.58 ve %98.33 olmuştur. Anatomik bölgeleri CNN modeli ile tespit edildikten sonra göz ardı edilen görüntülerde, ABC-tabanlı yinelemeli eşikleme yaklaşımı için başarı oranı %98.33 olmuştur. Sonuç olarak, ABC-tabanlı yinelemeli eşikleme yaklaşımı, elma görüntülerinde çürük alanların tespitinde PSO-tabanlı yaklaşımdan daha iyi sonuçlar vermiştir.



## 5. SONUÇ

Bu çalışmada, çürük elmaların otomatik olarak tespit edilmesi amacıyla CNN modelinin ABC veya PSO-tabanlı yinelemeli eşikleme yaklaşımlarından biri ile birlikte kullanıldığı hibrit bir model önerilmiştir. Meyve görüntülerinde çürük alanların başarılı bir şekilde algılanmasını sağlamak için spektral bölgelerin algılanmasını sağlayan hiperspektral ve multispektral görüntüleme sistemlerinin kullanıldığı geleneksel sistemler, laboratuvar ortamları dışında kullanılmasının hem maliyetli hem de zor olması nedeniyle, bir NIR kamera barındıran görüntü toplama platformu tasarlanmıştır. Modelin eğitimi ve testinde kullanılmak üzere, bu görüntü toplama platformu kullanılarak 200 elmanın 6 farklı yönünden 1 200 görüntü alınmıştır. Bu görüntüler, yaygın olarak kullanılan görüntü ön işleme yöntemleri ile iyileştirilmiş, daha sonra DA yöntemi ile görüntü sayısı çoğaltılarak sınıflandırma başarıları artırılmıştır. İyileştirilmiş görüntülerin sap-çanak anatomik bölgelerinin göz ardı edilmesi için CNN modeli kullanılarak bu bölgeler tespit edilmiştir. ABC/PSO-tabanlı yinelemeli eşik yaklaşımı kullanılarak yinelemeli bir eşik değeri belirlenmiş, görüntülerdeki çürükler tespit edilmiş ve sonra elmalar sağlıklı ve çürük olarak sınıflandırılmıştır. CNN modeli tarafından desteklenen hem ABC hem de PSO-tabanlı yinelemeli eşikleme yaklaşımları tatmin edici sınıflandırma başarı oranlarına ulaşmıştır. Bununla birlikte, ABC-tabanlı yinelemeli eşikleme yaklaşımı, elma görüntülerinde çürük alanların tespit edilmesinde PSO-tabanlı yinelemeli eşikleme yaklaşımından daha yüksek sınıflandırma başarı oranı sağlamıştır. Sonuç olarak, bu tez çalışmasında önerilen modelin, üzerlerindeki çürük alanları tespit etmek suretiyle, meyve suyu endüstrisindeki meyveleri otomatik olarak ayırmak için kullanılabileceği düşünülmektedir. Gelecekteki çalışmalarda, eğitim verisetinin çeşitliliğini artırarak ve otomatik kodlayıcı gibi gelişmiş CNN modellerini kullanarak meyvelerde çürük tespitini geliştirmek mümkün olacak, böylece tüm meyve türleri için gerçek zamanlı çürük tespiti uygulanabilir olacaktır.

## 6. KAYNAKLAR

- Abacı, B., 2012. Morfolojik görüntü işleme. Bahri Abacı Kişisel Web Sitesi, [http://www.cescript.com/2012/08/morfolojik-goruntu-isleme.html-\(30.05.2013\)](http://www.cescript.com/2012/08/morfolojik-goruntu-isleme.html-(30.05.2013)).
- Adem, K., 2018. Exudate detection for diabetic retinopathy with circular Hough transformation and convolutional neural networks. *Expert Systems with Applications*, 114, 289-295.
- Adem, K., Hekim, M. ve Demir, S., 2019. Detection of hemorrhage in retinal images using linear classifiers and iterative thresholding approaches based on firefly and particle swarm optimization algorithms. *Turkish Journal of Electrical Engineering & Computer Sciences*, 27(1), 499-515.
- Akay, B., 2013. A study on particle swarm optimization and artificial bee colony algorithms for multilevel Thresholding. *Applied Soft Computing*, 13(6), 3066-3091.
- Akdağ, E., 2008. Dünya meyve suyu sektörüne bakış. [http://www.meyed.org.tr/userfiles/file/sector\\_istatistikleri/dunya\\_meyve\\_suyu\\_sektorune\\_bakis\\_akdag.pdf](http://www.meyed.org.tr/userfiles/file/sector_istatistikleri/dunya_meyve_suyu_sektorune_bakis_akdag.pdf) (08.04.2016).
- Akyol, S. ve Alataş, B., 2012. Güncel sürü zekası optimizasyon algoritmaları”. *Nevşehir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1).
- Anonim, 2012. All in 1 LED Lighting Solutions Guide. PhilipsLumileds, <https://web.archive.org/web/20130314111003/http://www.philipslumileds.com/uploads/221/PG01-pdf> (24.04.2017).
- Anonim, 2017a. Light-emitting Diode. [https://en.wikipedia.org/wiki/Light-emitting\\_diode#cite\\_note-56](https://en.wikipedia.org/wiki/Light-emitting_diode#cite_note-56) (24.04.2017).
- Anonim, 2017b. Halogen Lamp. [https://en.wikipedia.org/wiki/Halogen\\_lamp](https://en.wikipedia.org/wiki/Halogen_lamp) (24.04.2017).
- Anonim, 2019. [https://tr.wikipedia.org/wiki/Bresenham%27%C4%B1n\\_%C3%A7izgi\\_algoritmas%C4%B1](https://tr.wikipedia.org/wiki/Bresenham%27%C4%B1n_%C3%A7izgi_algoritmas%C4%B1) (20.11.2019).
- Apostolopoulos, T. ve Vlachos, A., 2010. Application of the firefly algorithm for solving the economic emissions load dispatch problem. *International journal of combinatorics*, 2011.
- Artık, N., 2017. Meyve ve sebze üretim teknolojisi, [http://acikders.ankara.edu.tr/pluginfile.php/8059/mod\\_resource/content/0/1.%20hafta.pdf](http://acikders.ankara.edu.tr/pluginfile.php/8059/mod_resource/content/0/1.%20hafta.pdf) (13.06.2017).
- Bastı, M., 2005. Renk kavramı ve renk modelleri. Mehmet Bastı Web Sayfası, <http://www.fatih.edu.tr/~mbasti/Ders/RENK.ppt> (05.04.2013).
- Bengio, Y., 2009. Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Bradley, D. ve Roth, G., 2007. Adaptive thresholding using the integral image. *Journal of graphics tools*, 12(2), 13-21.
- Bresenham, J. E., 1965. Algorithm for computer control of a digital plotter. *IBM Systems*, 4(1), 25-30.
- Cengil, E. ve Çınar, A., 2016. A new approach for image classification: convolutional neural network. *European Journal of Technique*, 6(2), 96-103.
- Chapra, S. C. ve Canale, R. P., 2003. Yazılım ve programlama uygulamalarıyla mühendisler için sayısal yöntemler. Literatür Yayıncılık, ISBN: 975-8431-83-8.

- Chao, Y., Dai, M., Chen, K., Chen, P. ve Zhang, Z., 2016. A novel gravitational search algorithm for multilevel image segmentation and its application on semiconductor packages vision inspection. *Optik*, 127(14), 5770-5782.
- Chen, K., Zhou, Y., Zhang, Z., Dai, M., Chao, Y. ve Shi, J., 2016. Multilevel image segmentation based on an improved firefly algorithm. *Mathematical Problems in Engineering*.
- Chow, C. ve Kaneko, T., 1972. Automatic boundary detection of the left ventricle from cineangiograms. *Computers and Biomedical Research*, 5(4), 388-410.
- Christiansen, P., Nielsen, L., Steen, K., Jørgensen, R. ve Karstoft, H., 2016. DeepAnomaly: Combining background subtraction and deep learning for detecting obstacles and anomalies in an agricultural field. *Sensors*, 16(11), 1904.
- Cömert, O., Hekim, M. ve Adem, K., 2016. Meyve görüntülerini kullanarak elmaların sınıflandırılması. 1. International Academic Research Congress, 1387-1393.
- Cömert, O., Hekim, M. ve Adem, K., 2019. Faster R-CNN Kullanarak Elmalarda Çürük Tespiti. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi (Umagd)*, 11(1), 335-341.
- Cubero, S., Aleixos, N., Moltó, E., Gómez-Sanchis, J. ve Blasco, J., 2008. Early detection of apple bruises on different background colors using hyperspectral imaging. *LWT-Food Science and Technology*, 41(2), 337-345.
- Cubero, S., Aleixos, N., Moltó, E., Gómez-Sanchis, J. ve Blasco, J., 2011. Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables. *Food and Bioprocess Technology*, 4(4), 487-504.
- Dubey, S. R. ve Jalal, A. S., 2016. Apple disease classification using color, texture and shape features from images. *Signal, Image and Video Processing*, 10(5), 819-826.
- Eberhart, R. ve Kennedy, J., 1995. Particle swarm optimization. *Proceedings of the IEEE international conference on neural networks*, Citeseer.
- ElMasry, G., Wang, N., Vigneault, C., Qiao, J., ve ElSayed, A., 2008. Early detection of apple bruises on different background colors using hyperspectral imaging. *LWT-Food Science and Technology*, 41(2), 337-345.
- ElMasry, G., Wang, N., ve Vigneault, C., 2009. Detecting chilling injury in Red Delicious apple using hyperspectral imaging and neural networks. *Postharvest biology and technology*, 52(1), 1-8.
- Emiroğlu, İ., 2011. Matematik mühendisliği bölümü görüntü işleme ders notları. İbrahim Emiroğlu Web sayfası, <http://www.yarbis.yildiz.edu.tr/web/userAnnouncementsFiles/dosya9838fbd1cd0c297d3bce14b5c08ddf11.pdf> (01.04.2013).
- Er, O., Cetişli, B., Sofu, M. M. ve Kayacan, M. C., 2013. Gerçek zamanlı otomatik elma tasnifleme. *Journal of Natural and Applied Science*, 17(2), 31-38.
- Erbaş S.K., 2011. Sayısal görüntü ve sayısal görüntü işlemenin tasarım eğitimine etkisi, 2nd International Conference on New Trends in Education and Their Implications, 231-237.
- Fisher, R., Perkins, S., Walker, A. ve Wolfart, E., 1996. *Hypermedia image processing reference*. England, John Wiley & Sons Ltd.
- Fuentes, A., Yoon, S., Kim, S. ve Park, D., 2017. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, 17(9), 2022.
- Girshick, R., 2015. Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*.

- Gonzalez R.C. ve Woods R.E., 2002. Digital Image Processing Second Edition, Prentice Hall.
- Gonzalez R.C. ve Woods R.E., 2004. Digital Image Processing Using Matlab, Prentice Hall.
- Goodfellow, I., Bengio, Y. ve Courville, A., 2016. Deep learning, MIT press.
- Güvenç, U., Işık, A.H., Yiğit, T. ve Akkaya, I., 2016. Performance analysis of biogeography-based optimization for automatic voltage regulator system. Turkish Journal of Electrical Engineering, Computer Sciences, 24 (3), 1150-1162. doi: 10.3906/elk-1311-111.
- Harris, C. G. ve Stephens, M., 1988. A combined corner and edge detector. In Alvey vision konferansı, 15(50), 10-5244.
- Hayıt, T., Erbay, H. ve Hayıt, F., 2018. Gıda sektöründe uygulanan görüntü işleme çalışmalarının ve tekniklerinin incelenmesi. Electronic Letters on Science and Engineering, 14 (1), 12-22.
- He, L. ve Huang, S., 2017. Modified firefly algorithm based multilevel thresholding for color image segmentation. Neurocomputing, 240, 152-174.
- Hekim, M., Cömert, O. ve Adem, K., 2019. A hybrid model based on the convolutional neural network model and artificial bee colony or particle swarm optimization-based iterative thresholding for the detection of bruised apples, Turkish Journal of Electrical Engineering & Computer Sciences. (Kabul Edildi: 26.10.2019).
- Hornig, M.H., 2011. Multilevel thresholding selection based on the artificial bee colony algorithm for image segmentation. Expert Systems with Applications, 38(11), 13785-13791.
- Hornig, M.H. ve Liou, R.J., 2011. Multilevel minimum cross entropy threshold selection based on the firefly algorithm. Expert Systems with Applications, 38(12), 14805-14811.
- Hu, K., Gao, X. ve Li, F., 2010. Detection of suspicious lesions by adaptive thresholding based on multiresolution analysis in mammograms. IEEE Transactions on Instrumentation and Measurement, 60(2), 462-472.
- Kamilaris, A. ve Prenafeta-Boldú, F.X., 2018. Deep learning in agriculture: A survey. Computers and Electronics in Agriculture, 147, 70-90.
- Karaboga, D., 2005. An idea based on honey bee swarm for numerical optimization Teknik Rapor-tr06, Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü. 200, 1-10.
- Karakuzu, C., 2017. On the performance of newsworthy meta-heuristic algorithms based on point of view fuzzy modelling. Turkish Journal of Electrical Engineering, Computer Sciences, 25 (6), 4706-4721. doi: 10.3906/elk-1705-337.
- Kazan, S., 2011. Bilgisayar Görmesi Ders Notu-7. Serap Kazan Web Sayfası, <https://dosya.sakarya.edu.tr> (31.03.2013).
- Kızılkaya, A., 2008. Görüntü bölütleme. Aydın Kızılkaya Web Sayfası, [http://akizilkaya.pamukkale.edu.tr/Bölüm4\\_goruntu\\_isleme.pdf](http://akizilkaya.pamukkale.edu.tr/Bölüm4_goruntu_isleme.pdf) (01.04.2013).
- Kondo, N., 2010. Automation on fruit and vegetable grading system and food traceability. Trends in Food Science & Technology, 21(3), 145-152.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015. Deep learning. Nature, 521(7553), 436.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998. Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.
- Lu, R. ve Ariana, D., 2002. A near-infrared sensing technique for measuring internal quality of apple fruit. Applied engineering in agriculture 18(5), 585.

- Lu, R., 2003. Detection of bruises on apples using near-infrared hyperspectral imaging. *Transactions of the ASAE*, 46(2), 523-530.
- Lu, Y. ve Lu, R., 2017. Histogram-based automatic thresholding for bruise detection of apples by structured-illumination reflectance imaging. *Biosystems Engineering* 160, 30-41.
- Maitra, M. ve Chatterjee, A., 2008. A hybrid cooperative-comprehensive learning based PSO algorithm for image segmentation using multilevel Thresholding. *Expert Systems with Applications*, 34(2), 1341-1350.
- Makas, H. ve Yumuşak, N., 2016, Balancing exploration and exploitation by using sequential execution cooperation between artificial bee colony and migrating birds optimization Algorithms. *Turkish Journal of Electrical Engineering, Computer Sciences*, 24 (6), 4935-4956. doi: 10.3906/elk-1404-45.
- Malathi, K. ve Nedunchelian, R., 2016. Detecting and classifying diabetic retinopathy in fundus retina images using artificial neural networks-based firefly clustering algorithm. *ARNP Journal of Engineering and Applied Sciences*, 11(5), 3419-3426.
- McCulloch, W. S. ve Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mehl, P. M., Chen, Y. R., Kim, M. S., ve Chan, D. E., 2004. Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations. *Journal of Food Engineering*, 61(1), 67-81.
- Mohana, S. ve Prabhakar, C., 2015. Stem-calyx recognition of an apple using shape descriptors. *Signal & Image Processing (SIPIJ)*, 5(6), 17-31.
- Otsu, N., 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62-66.
- Önen, U., Çakan A. ve İlhan, I., 2019. Performance comparison of optimization algorithms in LQR controller design for a nonlinear system. *Turkish Journal of Electrical Engineering, Computer Sciences*, 27 (3), 1938-1953. doi: 10.3906/elk-1808-51.
- Özcan, H., 2014. Çok düşük çözünürlüklü yüz imgelerinde derin öğrenme uygulamaları, Yüksek Lisans Tezi, Deniz Harp Okulu, Bilgisayar Mühendisliği Bölümü.
- Öztemel, E., 2003. Yapay sinir ağları. PapatyaYayincilik, İstanbul.
- Pandey, R., Naik, S. ve Marfatia, R., 2013. Image processing and machine learning for automated fruit grading system: A technical review. *International Journal of Computer Applications*, 81(16), 29-39.
- Wang, J. ve Perez, L., 2017. The effectiveness of data augmentation in image classification using deep learning. *Convolutional Neural Networks Vis. Recognit. Technical Report*.
- Phansalkar, N., More, S., Sabale, A. ve Joshi, M., 2011. Adaptive local thresholding for detection of nuclei in diversity stained cytology images. 2011 International Conference on Communications and Signal Processing, IEEE.
- Pourdarbani, R., Ghassemzadeh, H. R., Seyedarabi, H., Nahandi, F. Z. ve Vahed, M. M., 2015. Study on an automatic sorting system for Date fruits. *Journal of the Saudi Society of Agricultural Sciences*, 14(1), 83-90.
- Qin, J., Chao, K., Kim, M. S., Lu, R. ve Burks, T. F., 2013. Hyperspectral and multispectral imaging for evaluating food safety and quality. *Journal of Food Engineering*, 118(2), 157-171.



- Raja, N., Rajinikanth, V. ve Latha, K., 2014. Otsu based optimal multilevel image thresholding using firefly algorithm. *Modelling and Simulation in Engineering*, 2014, 37.
- Rego, FL., 2003. Automatic land-cover classification devired from high-resulation Ikonos satellite image in the Urban Atlantic Forest in Rio de Janerio, Brasil by means of object oriented approach. Doktora Tezi, Uzaktan Algılama ve Arazi Bilgi Sistemi Bölümü, Freiburg Üniversitesi, Almanya.
- Ren, S., Girshick, R. ve Sun, J., 2017. Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 39(6), 1137-1149.
- Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T. ve McCool, C., 2016. Deepfruits: A fruit detection system using deep neural networks. *Sensors*, 16(8), 1222.
- Sauvola, J. ve Pietikäinen, M., 2000. Adaptive document image binarization. *Pattern Recognition*, 33(2), 225-236.
- Selva Bhuvaneswari, K. ve Geetha, P., 2017. Segmentation and classification of brain images using firefly and hybrid kernel-based support vector machine. *Journal of Experimental & Theoretical Artificial Intelligence*, 29(3), 663-678.
- Singh, K.P., Basant, A., Malik, A. ve Jain, G., 2009. Artificial neural network modeling of the river water quality-A case study, *Ecological Modelling*, 220(6), 888-895.
- Sobral, José., 2018. Understanding human error in industry. 7th International Symposium on Industrial Engineering (SIE2018), 75-78.
- Sofu, M. M., Er, O., Kayacan, M. C. ve Cetişli, B., 2013. Elmaların görüntü işleme yöntemi ile sınıflandırılması ve leke tespiti. *Gıda Teknolojileri Elektronik Dergisi*, 8(1), 12-25.
- Teo, C. K., 2003. Digital enhancement of night vision and thermal images. Yüksek Lisans Tezi, Donanma Lisansüstü Okulu, Monterey, Kanada.
- Theodoridis, S., Piskrakis, A., Koutroumbas, K. ve Cavouras, D., 2010. Introduction to pattern recognition: a matlab approach, Academic Press.
- Tonguç, G. ve Yakut, A. K., 2009. Fruit grading using digital image processing techniques. *Tarım Makinaları Bilimi Dergisi*, 5(1), 93-101.
- Unay, D. ve Gosselin, B., 2004. A stem-end/calyx recognition system based on pattern recognition for 'jonagold' apples. *Teknik Rapor*, TCTS Lab., Mons Politeknik Üniversitesi, Wallonia, Belçika.
- Unay, D. ve Gosselin, B., 2005a. Artificial neural network-based segmentation and apple grading by machine vision. *IEEE International Conference on Image Processing 2005*, IEEE, 2, 630-633.
- Unay, D. ve Gosselin, B., 2005b. Thresholding-based segmentation and apple grading by machine vision. *2005 13th European Signal Processing Conference*, IEEE, 1-4.
- Vennila, K. ve Thamizhmaran, K., 2017. Implementation of multilevel thresholding on image using firefly algorithm. *International Journal of Advanced Research in Computer Science*, 8(3), 373-378.
- Vernon, D., 1991. *Machine Vision*, UK.
- Wellner, P. D., 1993. Adaptive thresholding for the DigitalDesk. Xerox, EPC1993-110, 1-19.
- Wu, X., 2011. [http://www.ece.mcmaster.ca/~xwu/lecture7\\_segmentation.pdf](http://www.ece.mcmaster.ca/~xwu/lecture7_segmentation.pdf) (11.04.2013).
- Xiaobo, Z., Jiewen, Z. ve Yanxiao, L., 2007. Apple color grading based on organization feature parameters. *Pattern Recognition Letters*, 28(15), 2046-2053.

- Xing, J. ve De Baerdemaeker, J., 2005. Bruise detection on 'Jonagold' apples using hyperspectral imaging. *Postharvest Biology and Technology*, 37(2), 152-162.
- Xing, J., Bravo, C., Jancsó, P. T., Ramon, H., ve De Baerdemaeker, J., 2005. Detecting bruises on 'Golden Delicious' apples using hyperspectral imaging with multiple wavebands. *Biosystems Engineering*, 90(1), 27-36.
- Xing, J., Bravo, C., Moshou, D., Ramon, H., ve De Baerdemaeker, J., 2006. Bruise detection on 'Golden Delicious' apples by vis/NIR spectroscopy. *Computers and electronics in agriculture*, 52(1-2), 11-20.
- Xing, J., Saeys, W., ve De Baerdemaeker, J., 2007. Combination of chemometric tools and image processing for bruise detection on apples. *Computers and electronics in agriculture*, 56(1), 1-13.
- Yang, S., Fang, B., Tang, W., Wu, X., Qian, J. ve Yang, W., 2017. Faster R-CNN based microscopic cell Detection. In 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC), IEEE, 345-350.
- Yılmaz İ., 2002. Renk sistemleri, renk uzayları ve dönüşümler, Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Sunulmuş Bildiri, 16-18.
- Zarifneshat, S., Rohani, A., Ghassemzadeh, H. R., Sadeghi, M., Ahmadi, E. ve Zarifneshat, M., 2012. Predictions of apple bruise volume using artificial neural network. *Computers and Electronics in Agriculture*, 82, 75-86.
- Zhang, J., Yan, C. H., Chui, C. K. ve Ong, S. H., 2010. Fast segmentation of bone in CT images using 3D adaptive Thresholding. *Computers in Biology and Medicine*, 40(2), 231-236.
- Zhang, S., Wu, X., Zhang, S., Cheng, Q. ve Tan, Z., 2017. An effective method to inspect and classify the bruising degree of apples based on the optical properties. *Postharvest Biology and Technology*, 127, 44-52.
- Zhihui, H., Weiyu, Y., Shanxiang, L. ve Jiuchao, F., 2013. Multi-level threshold image segmentation using artificial bee colony algorithm. In 2013 Fifth International Conference on Measuring Technology and Mechatronics Automation, IEEE, 707-711.

## 7. ÖZGEÇMİŞ

### Kişisel Bilgiler

---

Adı Soyadı : Onur CÖMERT  
Doğum Tarihi : 20.06.1982  
Doğum Yeri : Tokat  
Uyruğu : T.C.  
Medeni Hali : Evli  
E-Posta : onur.comert@gop.edu.tr

### Eğitim

---

2015 - 2019 Gaziosmanpaşa Üniversitesi Mekatronik Mühendisliği – Doktora (TOKAT)  
2010 - 2013 Gaziosmanpaşa Üniversitesi Mekatronik Mühendisliği – Yüksek Lisans (TOKAT)  
2005 - 2010 Fırat Üniversitesi Bilgisayar Mühendisliği – Lisans (ELAZIĞ)  
2003 - 2005 Gaziosmanpaşa Üniversitesi Bilgisayar Teknolojisi ve Programlama Bölümü – Önlisans (TOKAT)  
1996 - 1999 Tokat Endüstri Meslek Lisesi Bilgisayar Bölümü – Lise (TOKAT)

## Yabancı Dil

---

İngilizce (2014-YDS: 76.25)

## Deneyimler

---

2012 - ...	Gaziosmanpaşa Üniversitesi Tokat Teknik Bilimler Meslek Yüksekokulu – Öğretim Görevlisi (TOKAT)
2008	Forte Bilgi ve İletişim Teknolojileri San. ve Tic. A.Ş – Staj (ANKARA)
2007 - 2012	Gaziosmanpaşa Üniversitesi Bilgişlem Daire Başkanlığı – Ağ Yöneticisi (TOKAT)

## Eserler

---

### Uluslararası Hakemli Dergilerde Yayımlanan Makaleler:

Hekim, M., Cömert, O. ve Adem, K. (2019). A hybrid model based on the convolutional neural network model and artificial bee colony or particle swarm optimization-based iterative thresholding for the detection of bruised apples, Turkish Journal of Electrical Engineering & Computer Sciences. (Kabul Edildi: 26.10.2019)

Adem, K., Kılıçarslan, S. ve Cömert, O. (2019). Classification And Diagnosis Of Cervical Cancer with Stacked Autoencoder And Softmax Classification. Expert Systems With Applications, 115, 557-564., Doi: Doi.Org/10.1016/J.Eswa.2018.08.050

Adem, K., Cömert, O., Zengin, N. ve Hekim, M. (2017). Prediction Of Gold Prices Using Artificial Neural Networks. Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 9(3), 83-89., Doi: 10.29137/Umagd.350596.

Cömert, O., Hekim, M. ve Adem, K. (2017). Weight And Diameter Estimation Using Image Processing And Machine Learning Techniques On Apple Images. Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 9(3), 147-154., Doi: 10.29137/Umagd.350588.

Adem, K., Hekim, M., Cömert, O. ve Demir, S. (2016). A Novel Approach To Method For The Detection Of Optic Disc Location İnretinal Images Using Image Processing Techniques. Journal Of New Results In Science, 5(12), 41-47.

Cömert, O., Hekim, M. ve Adem, K. (2016). The Comparison Of New Web Communication Method Websocket With Traditional Methods. Journal Of New Results In Science, 5(12), 1-8.

#### **Ulusal Hakemli Dergilerde Yayımlanan Makaleler:**

Cömert, O., Hekim, M. ve Adem, K. (2019). Faster R-CNN kullanarak elmalarda çürük tespiti. Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi (Umagd), 11(1), 335-341., Doi: <https://dx.doi.org/10.29137/Umagd.469929>.

Kılıçarslan, S., Adem, K. ve Cömert, O. (2019). Parçacık sürü optimizasyonu kullanılarak boyutu azaltılmış mikrodizi verileri üzerinde makine öğrenmesi yöntemleri ile prostat kanseri teşhisi. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 7(1), 769-777., Doi: 10.29130/Dubited.464092.

Orhan Umut, Adem, K. ve Cömert, O. (2012). Least squares approach to locally weighted Naive Bayes method. Journal of New Results in Science, 1(1), 71-78.

**Uluslararası Bilimsel Toplantılarda Sunulan Ve Bildiri Kitaplarında (Proceedings)  
Basılan Bildiriler:**

Adem, K., Kılıçarslan, S. ve Cömert, O. (2018). Yapay sinir ağları kullanılarak rahim ağzı kanserinin teşhisi ve sınıflandırılması. Uluslararası Multidisipliner Çalışmaları Kongresi, 330-339.

Kılıçarslan, S., Adem, K. ve Cömert, O. (2018). Makine öğrenmesi yöntemleri kullanılarak orta gelirli ülkelerin borsa endeksleri ile bist100 endeksinin tahmin edilmesi. Uluslararası Avrupa Bilim, Sanat Ve Kültür Konferansı, 24-24.

Kılıçarslan, S., Adem, K. ve Cömert, O. (2018). Parçacık sürü ve ateş böceği optimizasyon algoritmalarıyla boyutu azaltılmış prostat kanseri verilerinin destek vektör makinesi ile sınıflandırılması. European Conference On Science, Art Culture (Ecsac'18).

Cömert, O., Adem, K., Hekim, M. ve Cömert, M. M. (2017). 1985-2015 verilerine bakarak kırsal kesimde yaşayan insan sayısı ile yetiştirilen hayvan sayılarının veri madenciliği kullanılarak gelecekteki durumunun analizi: Tokat örneği. I. International Scientific And Vocational Studies Congress, 438-438.

Cömert, O., Hekim, M., Adem, K. (2017). Elma görüntüleri üzerinde görüntü işleme ve makine öğrenmesi teknikleri kullanılarak ağırlık ve çap tahmini. I. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi (Bilmes 2017), 439-439.

Adem, K., Hekim, M., Cömert, O., Demir, S. (2017). Retina görüntüleri üzerinde ateşböceği algoritması temelli iteratif eşikleme ile eksuda tespiti. I. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi (Bilmes 2017), 321-321.

Adem, K., Cömert, O., Zengin, N. ve Hekim, M. (2017). Yapay sinir ağları yöntemi kullanılarak altın fiyatlarının tahmin edilmesi. I. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi (Bilmes 2017), 323-323.

Özkoçak, İ., Hekim, M., Göktürk, H., Adem, K. ve Cömert, O. (2017). Farklı ağartma ajanlarının renklenmiş dişler üzerindeki etkinliğinin görüntü işleme yöntemleri

kullanılarak deęerlendirilmesi. Türk Diřhekimleri Birlięi 23. Uluslararası Diřhekimlięi Kongresi.

Adem, K., Hekim, M. ve Cömert, O. (2016). Görüntü işleme yöntemleri kullanılarak retina görüntülerinde kan damarlarının bölütlenmesi. 1. International Academic Research Congress, 384-384.

Cömert, O., Hekim, M. ve Adem, K. (2016). İstenmeyen epostaların tespitine yönelik veri madencilięinin kullanımı. 1. International Academic Research Congress, 3793-3796.

Cömert, O. ve Adem, K. (2016). Market sektöründe ürünlerin yerleşimi üzerine genetik algoritma tabanlı bir optimizasyon uygulaması. 1. International Academic Research Congress, 252-252.

Adem, K., Hekim, M. ve Cömert, O. (2016). Retina görüntülerinin istatistiksel özelliklerini kullanarak diyabetik retinopati teşhisi. 1. International Academic Research Congress, 831-834.

Cömert, O., Hekim, M. ve Adem, K. (2016). Meyve görüntülerini kullanarak elmaların sınıflandırılması. 1. International Academic Research Congress, 1387-1393.

#### **Ulusal Bilimsel Toplantılarda Sunulan ve Bildiri Kitaplarında Basılan Bildiriler:**

Cömert, O. ve Hekim, M. (2016). Yeni Web iletişim yöntemi WebSocket protokolünün geleneksel yöntemlerle karşılaştırılması. Elektrik-Elektronik ve Bilgisayar Sempozyumu, 158-162.

Cömert, O., Umut, O. ve Hekim, M. (2013). Sayısal görüntüleme destekli meyve rekolte tahmini. 4. Ulusal Mekatronik Mühendislięi Öğrenci Kongresi (MEMÖK 2013), 4(1), 74-81.