

**T.C.  
KAYSERİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ  
ANABİLİM DALI**

**YAHYALI BÖLGESİNE AİT ELMA TÜRLERİNİN  
GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE  
OTOMATİK SINIFLANDIRILMASI**

**Hazırlayan  
Sevim ADİGE**

**Danışman  
Prof. Dr. Ercan KARAKÖSE**

**Yüksek Lisans Tezi**

**Haziran 2022, KAYSERİ**



**T.C.  
KAYSERİ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ  
ANABİLİM DALI**

**YAHYALI BÖLGESİNE AİT ELMA TÜRLERİNİN  
GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE  
OTOMATİK SINIFLANDIRILMASI**

**Hazırlayan  
Sevim ADİGE**

**Danışman  
Prof. Dr. Ercan KARAKÖSE**

**Bu çalışma; Kayseri Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından  
FYL-2022-1059 kodlu proje ile desteklenmiştir**

**Haziran 2022, KAYSERİ**

## BİLİMSEL ETİĞE UYGUNLUK

Bu tezin kendi çalışmam olduğunu, planlanmasından yazımına kadar hiçbir aşamasında etik dışı davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları kaynaklar listesine aldığımı, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını beyan ederim.

Sevim ADİGE

İmza

**T.C.**  
**KAYSERİ ÜNİVERSİTESİ**  
**Lisansüstü Eğitim Enstitüsü Müdürlüğü**

Anabilim Dalı : Elektrik Elektronik Mühendisliği ABD

Program Adı : Tezli Yüksek Lisans

Tez Başlığı : Yahyalı Bölgesine Ait Elma Türlerinin Görüntü İşleme Yöntemleriyle Otomatik Sınıflandırılması

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 42 sayfalık kısmına ilişkin 07/07/2022 tarihinde Turnitin intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı: % 9'dur.

Uygulanan filtrelemeler:

- 1- Giriş dahil
- 2- Ana Bölümler dahil
- 3- Sonuç dahil
- 4- Alıntılar dahil
- 5- Kapak hariç
- 6- Önsöz ve Teşekkür hariç
- 7- İçindekiler hariç
- 8- Kaynakça hariç
- 9- Özet hariç
- 10- Yedi (7) kelimedenden daha az örtüşme içeren metin kısımları hariç

Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Önerisi Hazırlama, Tez Yazma ve Teslim Yönergesini inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 07/07/2022

Danışman: Prof. Dr. Ercan KARAKÖSE

Öğrenci: Sevim ADİGE

İmza

İmza

## YÖNERGEYE UYGUNLUK

“Yahyalı Bölgesine Ait Elma Türlerinin Görüntü İşleme Yöntemleriyle Otomatik Sınıflandırılması” adlı Yüksek Lisans Tezi, Kayseri Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

**Hazırlayan**

Sevim ADİGE

İmza

**Danışman**

Prof. Dr. Ercan KARAKÖSE

İmza

**Elektrik Elektronik Mühendisliği ABD Başkanı**

Doç. Dr. Engin Cemal MENGÜÇ

İmza

## KABUL VE ONAY

**Prof. Dr. Ercan KARAKÖSE** danışmanlığında **Sevim ADİGE** tarafından hazırlanan “Yahyalı Bölgesine Ait Elma Türlerinin Görüntü İşleme Yöntemleriyle Otomatik Sınıflandırılması” adlı bu çalışma jürimiz tarafından Kayseri Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

28 /06 /2022

### JÜRİ:

Danışman : Prof. Dr. Ercan KARAKÖSE .....

Üye : Prof. Dr. Bahriye AKAY .....

Üye : Doç. Dr. Engin Cemal MENGÜÇ .....

### ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun ..... tarih ve .....sayılı kararı ile onaylanmıştır.

...../...../.....

Doç. Dr. Engin Cemal MENGÜÇ  
Enstitü Müdürü

## TEŐEKKÜR

Bana alıőmalarım süresince ilgi, alaka ve samimiyetiyle her türlü desteęi ve fedakarlıęı saęlayan, bilim insanı kiőilięinden ve insaniyetinden ok Őey öęrendięim deęerli danıőman hocalarım Prof. Dr. Ercan KARAKÖSE ve Dr. Öğr. Üyesi Rifat KURBAN'a en içten teşekkürlerimi sunarım.

Her zaman yanımda olduklarını hissettięim benim bugünlere gelmemdeki en büyük destekçilerim canım annem ve babama, tüm hayatım boyunca benim yanımda olan, aldıęım kararları her zaman destekleyen, beni cesaretlendiren hayatımın anlamı canım kardeőim Selenay ADİGE'ye sonsuz teşekkürlerimi sunarım.

Yüksek Lisans Tez Programı "Yahyalı Bölgesine Ait Elma Türlerinin Görüntü İşleme Yöntemleriyle Otomatik Sınıflandırılması" ve FYL-2022-1059 numarasıyla destekleyen Kayseri Üniversitesi Bilimsel Araőtırma Projeleri Koordinatörlüęüne teşekkür ederim.

Sevim ADİGE

KAYSERİ, Haziran 2022

# YAHYALI BÖLGESİNE AİT ELMA TÜRLERİNİN GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE OTOMATİK SINIFLANDIRILMASI

Sevim ADİGE

Kayseri Üniversitesi, Lisansüstü Eğitim Enstitüsü  
Yüksek Lisans Tezi, Haziran 2022  
Danışman: Prof. Dr. Ercan KARAKÖSE

## ÖZET

Yüksek miktarda elma üreten çiftçiler için en önemli sorunlardan biri el değmeden kısa sürede elmaların türlerine göre sınıflandırılmasıdır. Destek Vektör Makineleri (Support Vector Machine - SVM) ve Derin Artık Ağlar (Residual Neural Network - ResNet-50), genel sınıflandırma problemlerini çözmek için kullanılacak Makine Öğrenme yöntemleridir. Bu çalışmada, elma çeşitlerinin cins değişkenlerine göre sınıflandırılması SVM ve ResNet-50 mimarileri kullanılarak yapılmıştır. 6 türe ait 120 elma görüntüsü elde edilerek veri tabanı oluşturulmuştur. Görsel Kelimeler Çantası (Bag of Visual Words-BoVW), görüntü özelliklerini, kelime dağarcığı üzerinde seyrek bir oluşum vektörünü temsil eden kelimeler olarak ele alır. BoVW öznitelikleri, SVM'nin Lineer, Gauss ve Polinom kernel fonksiyonları kullanılarak sınıflandırılmıştır. ResNet-50, gömülü özellik çıkarma katmanlarına sahip 50 katmanlı bir derin evrişimli sinir ağıdır. Önceden eğitilmiş ResNet-50 mimarisi, elma sınıflandırması için yeniden eğitilmiştir. Deneyselerde, veri setimiz üç duruma bölünmüştür: Durum 1: %40 eğitim, %60 test, Durum 2: %60 eğitim, %40 test ve Durum 3: %80 eğitim, %20 test. Sonuç olarak, BoVW+SVM algoritmasında kullanılan lineer, gauss ve polinom kernel fonksiyonları, Durum 3'te sırasıyla %88, %92 ve %96 doğruluk elde etmiştir. ResNet-50 sınıflandırmasında, ortalama kare yayılımı (rmsprop), uyarlanabilir moment tahmini (adam) ve momentumlu stokastik gradyan inişi (sgdm) eğitim algoritmaları, Durum 3 setinde %86, %89 ve %90 doğruluk elde etmiştir.

**Anahtar Kelimeler:** Machine Learning, Support Vector Machine, Res-Net50, Bag of Visual Words

# AUTOMATIC CLASSIFICATION OF APPLE SPECIES BY IMAGE PROCESSING METHODS IN THE YAHALI REGION

Sevim ADİGE

Kayseri University, Institute of Graduate Education  
Master Thesis, July 2022  
Supervisor: Prof. Ercan KARAKÖSE

## ABSTRACT

One of the most important problems for farmers who produce high amounts of apples is the classification of apples according to their types in a short time without touching. Support Vector Machines (SVM) and Deep Residual Networks (ResNet-50) are machine learning methods that can be used to solve general classification problems. In this study, classification of apple varieties according to genus variables was made using SVM and ResNet architectures. A database was created by obtaining 120 apple images of 6 species. Bag of visual words (BoVW) treats image features as words that represent a sparse vector of occurrences on the vocabulary. BoVW features are classified using linear, gaussian and polynomial kernel functions of SVM. ResNet-50 is a 50-layer deep convolutional neural network with embedded feature extraction layers. The pre-trained ResNet-50 architecture has been retrained for apple classification. In experiments, our dataset is split into three states: Case 1: 40% train, 60% test, Case 2: 60% train, 40% test, and Case 3: 80% train, 20% test. As a result, linear, gaussian and polynomial kernel functions used in BoVW+SVM algorithm achieved 88%, 92% and 96% accuracy in Case 3, respectively. In the ResNet-50 classification, mean square propagation (rmsprop), adaptive moment estimation (adam), and stochastic gradient descent with momentum (sgdm) training algorithms achieved 86%, 89%, and 90% accuracy in the Case 3 set.

**Keywords:** Machine Learning, Support Vector Machine, Res-Net50, Bag of Visual Words

## İÇİNDEKİLER

### YAHYALI BÖLGESİNE AİT ELMA TÜRLERİNİN GÖRÜNTÜ İŞLEME YÖNTEMLERİYLE OTOMATİK SINIFLANDIRILMASI

|                                      |      |
|--------------------------------------|------|
| BİLİMSEL ETİĞE UYGUNLUK .....        | i    |
| TEZ İNTİHAL RAPORU TESLİM FORMU..... | ii   |
| YÖNERGEYE UYGUNLUK.....              | iii  |
| KABUL VE ONAY TUTANAĞI .....         | iv   |
| TEŞEKKÜR.....                        | v    |
| ÖZET.....                            | vi   |
| ABSTRACT.....                        | vii  |
| İÇİNDEKİLER .....                    | viii |
| KISALTMALAR .....                    | x    |
| TABLolar LİSTESİ.....                | xi   |
| ŞEKİLLER LİSTESİ .....               | xii  |
| GİRİŞ .....                          | 1    |

## BİRİNCİ BÖLÜM

### GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

|  |    |
|--|----|
| 1.1. Yahyalı Bölgesine Ait Elma Türlerinin Özellikleri ..... | 3  |
| 1.2. Görüntü İşleme .....                                    | 5  |
| 1.2.1. Görüntü İşleme Teknikleri .....                       | 6  |
| 1.3. Sınıflandırma Yöntemleri.....                           | 11 |

## İKİNCİ BÖLÜM

### ÇALIŞMADA KULLANILAN YÖNTEMLER

|   |    |
|---|----|
| 2.1. Elmalar Üzerinde Yapılan Çalışmalar ve Kullanılan Ekipmanlar ..... | 15 |
| 2.2. Makine Öğrenmesi.....  | 16 |
| 2.2.1. Makine Öğrenme ve Yapay Zeka .....                               | 17 |
| 2.2.2. Makine Öğrenmede Ağ Eğitimi .....                                | 18 |
| 2.2.2.1. Destek Vektör Makineleri BoVW .....                            | 18 |

|   |    |
|---|----|
| 2.3. Derin Öğrenme .....                            | 23 |
| 2.3.1 Derin Öğrenmede Ağ Eğitimi ve ResNet-50 ..... | 24 |

## ÜÇÜNCÜ BÖLÜM

### ÇALIŞMADA KULLANILAN YÖNTEMLERİN SONUÇLARI

|   |    |
|---|----|
| 3.1. Görüntü Veri Kümesi .....                                    | 31 |
| 3.2. BoVW + SVM Sınıflandırma Sonuçları .....                     | 32 |
| 3.3. ResNet-50 Sınıflandırma Sonuçları .....                      | 36 |
| 3.4. ResNet-50 ve BoVW + SVM Metodlarının Karşılaştırılması ..... | 40 |

## DÖRDÜNCÜ BÖLÜM

|   |    |
|---|----|
| SONUÇ VE ÖNERİLER .....                 | 42 |
| KAYNAKÇA .....                          | 43 |
| TEZ ÇALIŞMASINDA ÜRETİLEN ESERLER ..... | 48 |
| ÖZGEÇMİŞ .....                          | 49 |
| TEZ İNTİHAL RAPORU .....                | 50 |

## KISALTMALAR

RESNET: Residual Neural Network

SGDM: Stochastic Gradient Descent with Momentum

RMSPROP: Root Mean Square Propagation

ADAM: Adaptive Moment Estimation

CPU: Central Processing Unit

GP: Genetik Programlama

AI: Artificial Intelligence

SVM: Support Vector Machine

BOVW: Bag of Visual Words

SIFT: Scale Invariant Feature Transform

SURF: Speeded Up Robust Features

VGP: Vanishing Gradients Problem

RELU: Rectified Linear Unit

## TABLOLAR LİSTESİ

|  |    |
|--|----|
| Tablo 1.1. Türkiye’de üretilen meyve çeşitlerinin ton biriminde karşılıkları .....   | 4  |
| Tablo 1.2. Türkiye’de şehirlere göre elma miktarı .....  | 4  |
| Tablo 2.1. Çalışmada kullanılan kameranın teknik özellikleri .....   | 16 |
| Tablo 3.1 Durum 1: Veri kümesinin %40’ı eğitimde ve %60’ı test için kullanılarak BoVW+SVM kullanılarak elma sınıflandırmasının doğruluk ve CPU zamanının istatistiksel sonuçları .....         | 34 |
| Tablo 3.2. Durum 2: Veri kümesinin %60’ı eğitimde ve %40’ı test için kullanılarak BoVW+SVM kullanılarak elma sınıflandırmasının doğruluk ve CPU zamanının istatistiksel sonuçları .....        | 35 |
| Tablo 3.3. Durum 3: Veri kümesinin %80’i eğitimde ve %20’si test için kullanılarak BoVW+SVM kullanılarak elma sınıflandırmasının doğruluk ve CPU zamanının istatistiksel sonuçları .....       | 35 |
| Tablo 3.4. Durum 1: Veri kümesinin %40’ı eğitimde ve %60’ı test için kullanılarak ResNet-50 kullanılarak elma sınıflandırmasının doğruluk ve CPU zamanına ilişkin istatistiksel sonuçlar ..... | 39 |
| Tablo 3.5. Durum 2: Veri kümesinin %60’ı eğitimde ve %40’ı test için kullanılarak ResNet-50 kullanılarak elma sınıflandırmasının doğruluk ve CPU zamanına ilişkin istatistiksel sonuçlar ..... | 39 |
| Tablo 3.6. Durum 3: Veri kümesinin %80’i eğitimde ve %20’i test için kullanılarak ResNet-50 kullanılarak elma sınıflandırmasının doğruluk ve CPU zamanına ilişkin istatistiksel sonuçlar ..... | 40 |
| Tablo 3.7. BoVW+SVM ve ResNet-50 yöntemlerinin test veri setleri ile karşılaştırılması .....   | 41 |

## ŞEKİLLER LİSTESİ

|  |    |
|--|----|
| Şekil 1.1. Alçak ve yüksek geçiş fitre uygulaması.....   | 8  |
| Şekil 1.2. Histogram eşitleme .....  | 9  |
| Şekil 1.3. Görüntü onarımı.....  | 9  |
| Şekil 1.4. Kenar Belirleme .....   | 10 |
| Şekil 1.5. (a) 15,2 KB boyutundaki fotoğraf (b) 7,84 KB boyutundaki fotoğrafın görüntü sıkılaştırma yöntemi kullanılarak boyutunun azaltılması ..... | 11 |
| Şekil 2.1. Sınıflandırma probleminin çözümü için kullanılan Makine Öğrenmesi yöntemi .....   | 18 |
| Şekil 2.2. Görüntü veri kümesini tren ve test alt kümelerine bölme.....  | 19 |
| Şekil 2.3. Elma görüntüleri için Bag of Features oluşturulması. ....   | 20 |
| Şekil 2.4. SVM'nin genel yapısı .....  | 21 |
| Şekil 2.5. Görsel kelimelerle SVM sınıflandırıcı eğitimi. ....   | 23 |
| Şekil 2.6. Artık Öğrenme modeli blok diyagramı.....  | 26 |
| Şekil 2.7. ResNet-50 mimarisi .....  | 26 |
| Şekil 2.8. Görüntüleri sınıflandırmak için ResNet-50 Derin Öğrenme ağının eğitim süreci .....  | 29 |
| Şekil 3.1. Durum 1: BoVW+SVM için veri kümesinin %40'ı eğitim ve %60'ı test olarak kullanılan benzetim sonuçları .....                               | 32 |
| Şekil 3.2. Durum 2: BoVW+SVM için veri kümesinin %60'ı eğitim ve %40'ı test olarak kullanılan benzetim sonuçları .....                               | 33 |
| Şekil 3.3. Durum 3: BoVW+SVM için veri kümesinin %80'i eğitim ve %20'si test olarak kullanılan benzetim sonuçları .....                              | 34 |
| Şekil 3.4. Durum 1: ResNet-50 için veri kümesinin %40'ı eğitim ve %60'ı test olarak kullanılan benzetim sonuçları .....                              | 37 |
| Şekil 3.5. Durum 2: ResNet-50 için veri kümesinin %60'ı eğitim ve %40'ı test olarak kullanılan benzetim sonuçları .....                              | 37 |
| Şekil 3.6. Durum 3: ResNet-50 için veri kümesinin %80'i eğitim ve %20'si test olarak kullanılan benzetim sonuçları.....                              | 38 |

## GİRİŞ

Gelişen teknoloji ile birlikte son dönemlerde sıkça duymaya başladığımız “Yapay Zeka”, “Makine Öğrenimi” ve “Derin Öğrenme” kavramlarının pek çok uygulama alanları mevcuttur. İnsan zekâsını taklit eden bu yöntemler çevresinden aldığı veri setlerini tıpkı insanlar gibi deneyim yoluyla öğrenir.

Makine Öğrenimi, sistemlerin programlanmadan oluşturulan veri setlerinden öğrenme ve geliştirme işlemlerini sağlayan bir yapay zeka yöntemidir. Bu yöntem genellikle tahmin veya sınıflandırma yapmak için kullanılmaktadır.

Derin Öğrenme, oluşturulan veri setleri ile sonuçlar hakkında tahminde bulunan birden çok katmandan meydana gelen Makine Öğrenme yöntemidir. Makine ve Derin Öğrenme yöntemlerinin birbirinden farkı öğrenme şekilleridir. Derin Öğrenme yöntemi birden çok katmanda işlem yaparken Makine Öğrenimi tek katmanda işlem yapar. Her iki yöntem de görüntü işleme, tıp, endüstri, mühendislik, nesne tespiti, gelecek tahmini, yüz tanıma, görüntü sınıflandırma, ses tanıma, sürücüsüz araba kullanma, savunma sanayi, güvenlik sanayi, pazarlama, eğlence sektörü gibi pek çok alanda çözüm üretmektedir.

Görüntü işleme fotoğraf makinası, video kamera ve tarayıcı gibi cihazlardan elde edilerek sayısallaştırılan görüntülerin bilgisayar ortamında gerçekleşen yazılımlar yardımıyla işlenmesi veya analizi olarak tanımlanmaktadır.

Bu tez çalışmasında görüntü işleme tekniklerinden faydalanarak elma çeşitlerini türlerine göre sınıflandırmak için iki farklı yapay zeka yöntemi kullanılmıştır. Kayseri - Yahyalı yöresine ait 6 farklı türden elde edilen görüntüler eğitim ve test veri setlerine ayrılmıştır. BoVW+SVM yöntemiyle elde edilen sonuçlar, ResNet-50 Derin Öğrenme yöntemiyle elde edilen sonuçlarla karşılaştırılmıştır.

Tez çalışmasının ilk bölümünde, Yahyalı Bölgesine ait elma türlerinin özellikleri, görüntü işleme ve sınıflandırma yöntemleri ile ilgili genel bilgiler verilmiştir. Sınıflandırma işlemi için kullanılan tahmin yetenekleriyle ilgili detaylı literatür taraması ve özeti verilmiştir.

Çalışmanın ikinci bölümünde, tezde kullanılan tüm deneysel sistem ve benzetim işlemlerinde kullanılan yapay zeka yapıları detaylı bir şekilde literatür taramalarıyla birlikte verilmiştir.

Tez çalışmasının üçüncü bölümünde ise, Makine Öğrenme ve Derin Öğrenme yöntemleriyle gerçekleştirilen çalışmaların başarımları analizleri hem grafiksel hem de sayısal olarak karşılaştırılmıştır.

Bu tez çalışmasının son bölümünde, elde edilen başarımların yorumlanması ve mevcut literatürle karşılaştırılması yapılmış, gelecekte yapılacak çalışmalar hakkında bilgiler verilmiştir.

# BİRİNCİ BÖLÜM

## Genel Bilgiler ve Literatür Çalışması

### 1.1. Yahyalı Bölgesine Ait Elma Türlerinin Özellikleri

Tarım, insanlık tarihi için her dönemde önemli olmuştur. En temel üretim dallarından biri olan tarım sektörü ülke nüfusunun yaşamını sürdürebilmesi, milli gelire ve istihdama katkısı, diğer sektörlerle hammadde ve sermaye sağlaması, ihracata doğrudan ve dolaylı etkisi ve biyolojik çeşitlilik ile ekolojik dengeye olan katkısı nedeniyle tüm dünyada vazgeçilmez bir sektör niteliğindedir. Bu nedenle tarım sektörü, ekonomik, sosyal ve çevresel boyutlarıyla, toplumun bütün kesimlerini yakından ilgilendirmektedir [1]. Tarımsal alanın en önemli dallarından biri de meyve yetiştiriciliğidir. Meyve üretiminde dünyada ilk beş ülke Çin, Hindistan, Brezilya, ABD ve Türkiye'dir [2]. Ülkemizdeki bölgelerin ekolojik olarak birbirinden farklı olması, verimli ve geniş tarım alanlarına ev sahipliği yapması sayesinde en iyi koşullarda kaliteli meyve yetiştiriciliği yapılabilmektedir. Türkiye'de en çok üretilen meyve çeşitleri Tablo 1.1'de verilmiştir.

**Tablo 1.1.** Türkiye’de Üretilen Meyve Çeşitlerinin Ton Biriminde Karşılıkları.

|            | 2016    | 2017    | 2018    | 2019    | 2020    | 2021    |
|------------|---------|---------|---------|---------|---------|---------|
| Ürün Grubu | TON     | TON     | TON     | TON     | TON     | TON     |
| ELMA       | 2925828 | 3032164 | 3625960 | 3618752 | 4300486 | 4493264 |
| ÜZÜM       | 4000000 | 4200000 | 3933000 | 4100000 | 4208908 | 3670000 |
| MANDALİNA  | 1337037 | 1550469 | 1650000 | 1400000 | 1585629 | 1819000 |
| PORTAKAL   | 1850000 | 1950000 | 1900000 | 1700000 | 1333975 | 1742000 |
| ZEYTİN     | 1730000 | 2100000 | 1500467 | 1525000 | 1316626 | 1738680 |
| LİMON      | 850600  | 1007133 | 1100000 | 950000  | 1188517 | 1550000 |
| ÇAY        | 1350000 | 1300000 | 1480534 | 1407448 | 1450556 | 1450000 |
| KAYISI     | 730000  | 985000  | 750000  | 846606  | 833398  | 800000  |
| ŞEFTALİ    | 674136  | 771459  | 789457  | 830577  | 892048  | 891857  |
| FINDIK     | 420000  | 675000  | 515000  | 776046  | 665000  | 684000  |

Ülkemizde 2021 yılında Türkiye İstatistik Kurumunun (TÜİK) yayınladığı verilere göre 4.493.264 tonluk üretim ile en çok yetiştirilen meyve elmadır. Elmayı sırasıyla üzüm, mandalina, portakal gibi meyveler takip etmektedir [3]. Elmanın, ülkemizin birçok bölgesinde yetişmesi, soğuk hava depolarında uzun ömürlü olarak saklanabilmesi, ticaret açısından önemini artırmaktadır. Ülkemizde elma üretiminin en çok yapıldığı şehir Isparta’dır. Isparta’yı sırasıyla Karaman, Niğde, Antalya ve Kayseri takip etmektedir [4]. Ülkemizde üretilen elma miktarlarının şehirlere göre dağılımı Tablo 1.2’de verilmiştir.

**Tablo 1.2.** Türkiye’de Şehirlere Göre Elma Miktarı.

| İLLER         | 2016             |            | 2017             |            | 2018             |            | 2019             |            |
|---------------|------------------|------------|------------------|------------|------------------|------------|------------------|------------|
|               | Miktar           | %          | Miktar           | %          | Miktar           | %          | Miktar           | %          |
| Isparta       | 596.503          | 20,39      | 617.375          | 20,36      | 717.401          | 19,79      | 732.036          | 20,23      |
| Karaman       | 398.085          | 13,61      | 497.734          | 16,42      | 588.442          | 16,23      | 485.363          | 13,41      |
| Niğde         | 376.906          | 12,88      | 327.847          | 10,81      | 429.036          | 11,83      | 438.327          | 12,11      |
| Antalya       | 281.019          | 9,60       | 272.591          | 8,99       | 265.068          | 7,31       | 264.566          | 7,31       |
| Kayseri       | 108.959          | 3,72       | 126.829          | 4,18       | 127.847          | 3,53       | 243.066          | 6,72       |
| Konya         | 101.081          | 3,45       | 75.945           | 2,50       | 215.963          | 5,69       | 230.581          | 6,37       |
| Denizli       | 196.329          | 6,71       | 142.784          | 4,71       | 289.085          | 7,97       | 187.416          | 5,18       |
| Mersin        | 77.020           | 2,63       | 96.496           | 3,18       | 125.762          | 3,47       | 136.938          | 3,78       |
| Çanakkale     | 95.886           | 3,28       | 101.823          | 3,36       | 105.295          | 2,90       | 99.462           | 2,75       |
| K.Maraş       | 59.242           | 2,02       | 80.569           | 2,66       | 81.982           | 2,26       | 83.481           | 2,31       |
| Bursa         | 53.646           | 1,83       | 53.977           | 1,78       | 56.551           | 1,56       | 65.392           | 1,81       |
| İğdir         | 23.404           | 0,80       | 44.246           | 1,46       | 44.172           | 1,22       | 50.149           | 1,39       |
| Amasya        | 25.950           | 0,89       | 38.808           | 1,28       | 35.122           | 0,97       | 37.606           | 1,04       |
| Diğer iller   | 531.798          | 18,18      | 555.140          | 18,31      | 544.234          | 15,01      | 564.369          | 15,60      |
| <b>Toplam</b> | <b>2.925.828</b> | <b>100</b> | <b>3.032.164</b> | <b>100</b> | <b>3.625.960</b> | <b>100</b> | <b>3.618.752</b> | <b>100</b> |

Bu tez çalışmasında kullanılan elmalar Kayseri ilinde üretilmiştir. Ülkemiz elma üretiminde Kayseri'yi önemli kılan ilçelerden biri de Yahyalı ilçesidir. Yahyalı ilçesinde iklim ve toprak özellikleri bakımından elma yetiştirilmenin uygun olması alan başına yetiştirilen elmanın çokluğu, kalitesi ve doğallığını da olumlu yönde etkilemektedir. Ayrıca ilçenin 30.165 dekarlık alanını kapsayan meyveciliğin 29.450 dekarında elma tarımı yapılmaktadır [5]. Yahyalı ilçesinde son yıllarda elma tarımının bu denli önem kazanmasının sebebi gelişen bilim ile toprak analizi gibi yöntemlerin tarımda aktifliğinin artması, çiftçilerin bilinçlenmesi, tarım laboratuvarlarının imkânlarından faydalanılmasının etkileri büyüktür. Yahyalı ilçesinde modern tarıma geçiş hız kazanmıştır. Klasik elma ağacı tarımının yerini verimin daha çok alındığı bodur ve yarı bodur elma ağaçlarına bırakmıştır. Yahyalı elması görüntü ve tat açısından birçok çeşit barındırmaktadır.

Bunlar: Golden, Granny Smith, Joremini, Süper Chief, Buckeye Gala, Starking, Red Chief, Starkrimson, Scarlet Spur, Fuji, Galaval, Beraburn, Rainders Golden, Gold Chief, Pink Lady.

Gelişen teknolojiyle birlikte insan gücünün yerini makineleşmenin alması, bu elma çeşitleri arasında yapılan ayırımın daha ekonomik, hızlı ve sistemli hale gelmesini sağlamıştır. Hata payının az olduğu, teknoloji çağının aktif kullanıldığı, seri üretimin fazla olduğu bu çağda elmalar arası kalite ve cins ayırımının analizinin yapılabilmesi için çoğu alanda kullanılan otomasyon bu alanda da gerekliliğini göstermektedir. Tarımsal ürünlerin renk, uzunluk, kalınlık, genişlik, yüzey alanı ve iz düşüm alanı gibi fiziksel özelliklerinin bilinmesi mühendislik açısından oldukça önem taşımaktadır.

Bu tez çalışmasında Yahyalı Bölgesine ait elmalarla ilgili görüntü işleme analizleri gerçekleştirilmiştir.

## **1.2. Görüntü İşleme**

Görüntü işleme, bilgisayarlar aracılığıyla görüntülerdeki, videolardaki nesnelere, kişileri tanımlamaya ve anlamaya imkan tanıyan bir alandır. Yapay zekayı göz önünde bulundurduğumuzda görüntü işleme de insan yeteneklerini taklit eden görevleri gerçekleştirmeyi ve süreci otomatikleştirmeyi amaçlar. Bu durumda, görüntü işleme yöntemi insanların görme biçimini ve aynı zamanda gördüklerini anlamlandırma biçimini

taklit etmeye çalışır. Görüntü işleme teknolojisine yönelik pratik uygulamalar, onu birçok modern yeniliğin ve çözümün kilit taşı haline getirmektedir.

Görüntülerin analiz edilmesi için kullanılan tüm yazılım uygulamaları ve donanım gereçlerine görüntü işleme sistemi denilmektedir. Görüntü işleme sistemi, bir nesnenin veya durumun belirlenmesinde kullanılacak geometrik özelliklerini, konum özelliklerini ve optik özelliklerinin saptanmasını sağlamaktadır. Aynı zamanda sistemlerin analizlerinde kullanılabilir. Bu sayede, görüntü işleme sistemlerinin birçok alanda kullanımını artmaktadır. Elektromekanik otomasyon sistemlerinin de karar verme yapısında görüntü işleme teknolojisi yer almaktadır. Son yıllarda tarım alanında görüntü işleme sistemleri temelli sulama, ilaçlama ve hasat gibi faaliyetler için geliştirilen uygulamaların kullanımı oldukça artmış ve görüntü işleme temelli birçok uygulama gerçekleşmiştir [6].

Bu tez çalışmasında ise Yahyalı bölgesine ait elmaların cinsleri görüntü işleme yöntemi kullanılarak tespit edilmeye çalışılmıştır.

## **1.2. Görüntü İşleme Teknikleri**


Görüntü işleme alanının kendi içerisinde birden fazla uygulama tekniği bulunmaktadır. Bu teknikler aşağıda maddeler halinde verilmiştir.

Görüntü işleme teknikleri,

- Görüntü dönüşümleri
  - Fast Fourier dönüşümü
  - Hadamard dönüşümü
- Görüntü iyileştirme
  - Uzaysal alanda iyileştirme
  - Frekans alanında iyileştirme
- Görüntü onarma

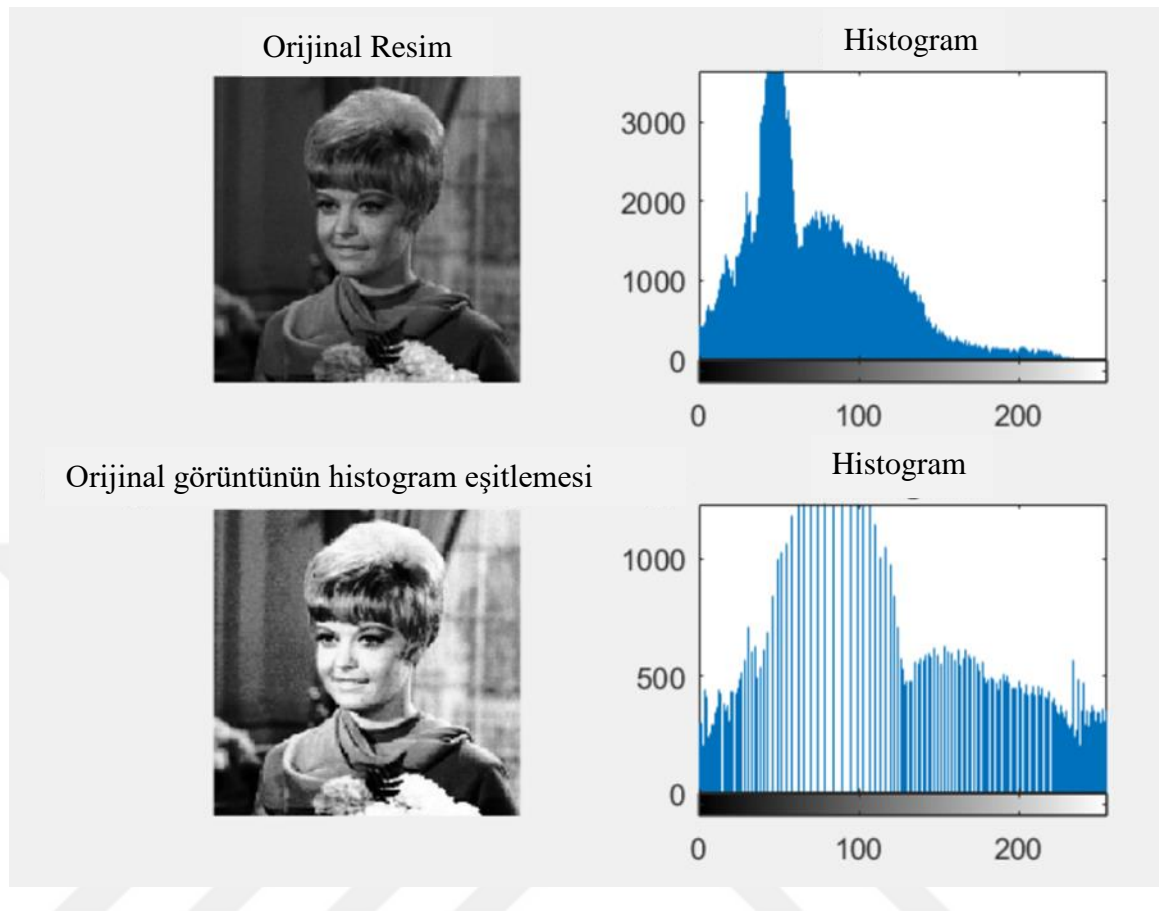
- Bozulma modelleri
- Block-Circulant matrisleri
- Ters filtreleme
- Görüntü Bölümleme
  - Süreksizlik yakalama
  - Eşik/Alan belirleme
- Görüntü sıkıştırma
  - Kayıplı sıkıştırma
  - Hata-Serbest sıkıştırma
- Görüntü sunma
  - Sınır tanımlama
  - Alan tanımlama
- Görüntü algılama
  - Karar-Teori metotları
  - Yapısal Metotları

olarak ele alınmaktadır. Farklı parametrelerle bir sinyalin anlatılması görüntü dönüşümlerini oluşturmaktadır. Çözülmesi oldukça zor olan uzaysal alandaki işlemleri, frekans alanında elde etmek amacıyla görüntü dönüşümleri kullanılmaktadır. Görüntüyü meydana getiren frekans bileşenlerini ayırt edebilmesi farklı derecelerden yüksek ve alçak filtreleme dönüşümleriyle sağlanmaktadır [7]. Belirtilen filtre uygulaması Şekil 1.1’de örneklendirilmiştir.




**Şekil 1.1.** Alçak Ve Yüksek Geçiş Fitre Uygulaması

Görüntü iyileştirme, bozulmuş görüntünün işlendiği bir yöntemdir. Aynı zamanda bu teknikle görüntünün görsel görünümünün de iyileştirilmesi gerçekleştirilmektedir. Görüntünün kontrastının artırıldığı öznel bir süreçtir [8]. Görüntü iyileştirme tekniği, görüntü üzerinde meydana gelen parlaklığın değiştirilmesinde, histogram eşitleme işleminde, kenar zenginleştirme gibi iyileştirme tekniklerinde kullanılır. Histogram eşitleme yöntemiyle ilgili örnek çalışma Şekil 1.2’de verilmiştir.



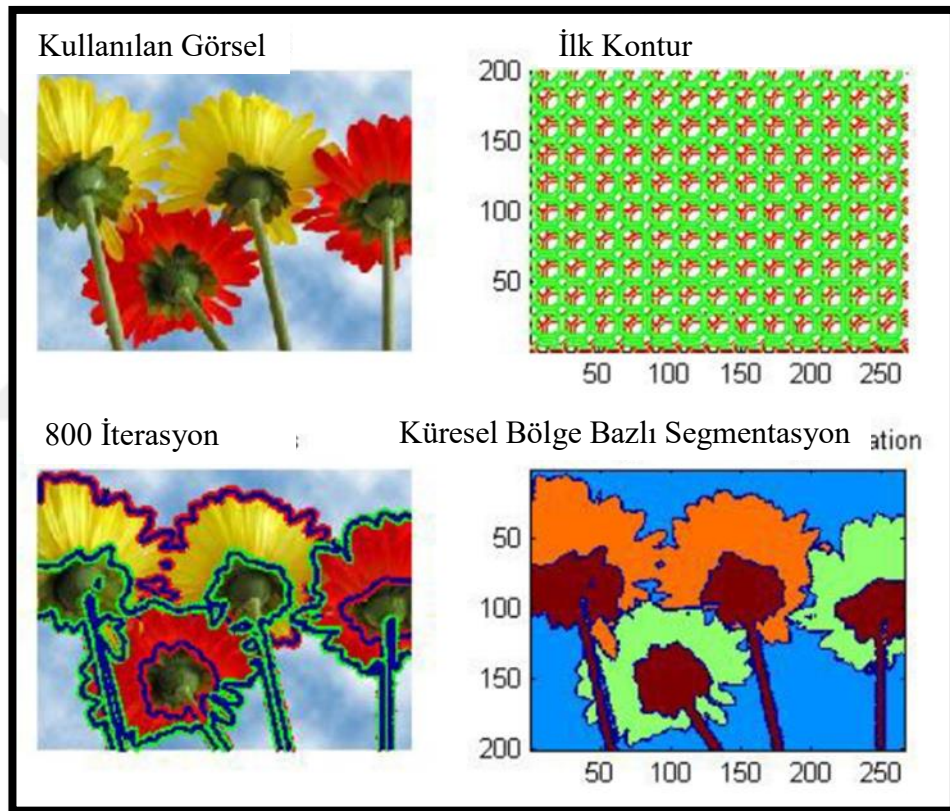
Şekil 1.2. Histogram Eşitleme

Bozuk olan görüntüyü orijinal haline geri getirmek için ise görüntü onarma işlemi kullanılmaktadır. Uydular ve kablosuz iletişim gibi iletişim araçlarıyla görüntü gönderilirken veya alınırken görüntüye gürültü eklenmektedir. Dürtü gürültüsü, Gauss gürültüsü gibi çeşitli gürültüler vardır. Görüntü onarımının asıl amacı, gürültü türünü tanımlamaktır. Ayrıca gürültü türünü tersine çevirmek için etkilerde bulunmaktadır [8]. Görüntü onarımı ile ilgili elektronik devre kartı üzerinde gerçekleştirilen bir çalışma Şekil 1.3'te verilmiştir.



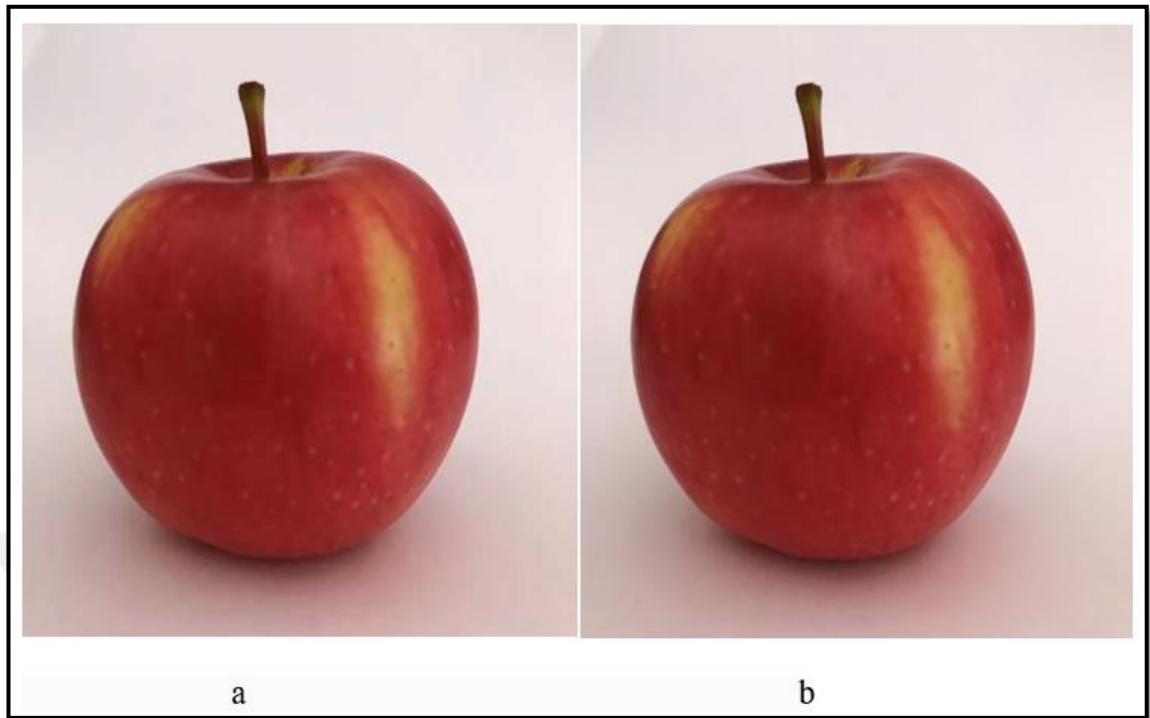
Şekil 1.3. Görüntü Onarımı

Bölümlenme yani segmentasyon, görüntü içerisinde yer alan farklı nesnelere birbirinden ayırma işlemini gerçekleştirerek, istenilen bölümleri belirgin hale getirir. Aynı zamanda bölümlenme istenmeyen bölgeleri ortadan kaldırmada da kullanılıyor. Bölümlenme işlemi, görüntü içindeki nesnenin kenarları, köşeleri, noktaları, çizgiler ve sınırları belirginleştirilerek nesnenin şekliyle ilgili bilgi edinilmesi sağlanır. Nesnenin alanı, yüzey kaplaması, renkleri gibi iç özellikleri ile ilgili ise bölgesel bölümlenme yapılarak nesne tespiti gerçekleştirilebilir. Görüntü bölümlenme ile ilgili bir uygulama Şekil 1.4'te verilmiştir.



**Şekil 1.4.** Kenar Belirleme

Görüntü işleme tekniklerinin bir başkası olan görüntü sıkılaştırma işlemi görüntü kalitesini bozmadan dosya boyutunu minimum seviyeye indirmek için uygulanan bir yöntemdir. Bu işlem görüntülerin rahatlıkla depolanabilmesi için yapılmaktadır. Bu tez çalışmasında kullanılan yöntemlerden de biri olan görüntü sıkılaştırma ile ilgili bir uygulama Şekil 1.5'te verilmiştir.



**Şekil 1.5.** (a) 15.2 Kb Boyutundaki Fotoğraf (b) 7.84 Kb Boyutundaki Fotoğrafın Görüntü Sıkılaştırma Yöntemi Kullanılarak Boyutunun Azaltılması

Diğer görüntü işleme tekniklerinden olan görüntü sunma tekniği görüntü içerisinde tespit edilecek nesnelere bulmada kullanılır [9]. Görüntü Algılama tekniği ise yer yüzeyinden yansıyan ve yayılan enerjinin algılanması, kaydedilmesi, elde edilen materyalin bilgi çıkarmak üzere işlenmesi ve analiz edilmesinde kullanılmaktadır.

Bu tez çalışmasında, Yahyalı'da yetiştirilen elma çeşitlerinin ayrıştırılmasında görüntü işleme teknikleri Matlab programı aracılığıyla kullanılmıştır.

### 1.3. Sınıflandırma Yöntemleri

Sınıflandırma kavramı, basit anlamıyla bir veri kümesi üzerinde tanımlanan çeşitli sınıflar arasında veriyi dağıtmaktır. Sınıflandırma algoritmaları, verilen eğitim kümesi aracılığıyla belirtilen dağılım şeklini öğrenirler. Daha sonra mevcut sınıfın belirli olmadığı test verileri sisteme verildiğinde doğru şekilde sınıflandırma işlemi gerçekleştirilir [10]. Denetimli ve denetimsiz olmak üzere iki tip Makine Öğrenmesi yöntemi vardır. Denetimli öğrenme yönteminde sınıf sayısı ve nesnelere hangi sınıfta olduğu bilinmektedir. Bu yöntemde algoritmalar öğrendikleri verileri kullanarak tahmin

işlemi gerçekleştirirler ve bunun için de yine öğrendikleri verilerden faydalanmaktadırlar. Sınıfların sayısı, nesne tipi ve nesnelerin sınıfı bilinmektedir. Denetimli öğrenme modelinde algoritmalar öğrendiklerini kullanarak tahmin yapmak amacıyla etiketli verileri kullanırlar. Eğitimde kullanılacak veriler dış dünyadan sisteme verilir. Bu veriler ile sistem öğrenmesi gerçekleştirildikten sonra yeni gelen veriler yorumlanır. Denetimli öğrenim kavramı literatürde örnekten öğrenme olarak da isimlendirilmektedir. Denetimli öğrenme modelinin amacı, verilen örnekleri kullanarak her bir sınıfa ilişkin özelliklerin bulunmasıdır. Aynı zamanda bu özelliklerin belirli kurallar çerçevesinde ifade edilmesidir. Bu amaç doğrultusunda tüm veri topluluğu bir öğrenme kümesine ayrılır ve model bu oluşturulan küme üzerinden kurulur. Ayrılan test kümesi doğrultusunda kümenin doğruluğu araştırılır. Eğer oluşturulan modelin doğruluğu yeterli ise yeni gelen örneklere bu model uygulanır.

Bir denetimli Makine Öğrenmesi yöntemi olan sınıflandırma tekniği, örneğin bir retinal tümörün kanserli mi yoksa zararsız mı olduğunu, bir mailin spam mı yoksa gerçek mi olduğunu öngörebilmektedir. Sınıflandırma modelleri girdi verilerini kategorilere ayırabilme özellikleriyle literatürde oldukça geniş çaplı çalışmalara konu olmuştur. Fan ve arkadaşları [11] yapmış oldukları çalışmada Genetik Programlamayı (GP), görüntü sınıflandırmasına başarıyla uygulamış ve umut verici sonuçlar elde etmiştir. Görüntülerden çeşitli cilt malignitelerini tespit etmek için bilgisayar destekli bir teşhis sistemi geliştirmek birçok araştırmacıyı cezbetmiştir. Bununla birlikte, bir sistemin gerçek zamanlı durumlarda etkinliğini belirlemek için yeni sistemler geliştirmek kadar algoritmaların davranışlarını analiz etmek de önemlidir; bu, dermatoloğa tanı koymada ne kadar yardımcı olabileceğini büyük ölçüde etkilemektedir. Ain ve arkadaşları çalışmasında [12], doku, renk ve dalgacık özellikleriyle cilt görüntüsü sınıflandırmasına yönelik son zamanlarda geliştirilen GP tabanlı yaklaşımları analiz etmeyi amaçlamış ve çalışmaları sonunda %86,77 doğruluk elde etmişlerdir. Görüntü sınıflandırma metodları biyolojide de önemli rol oynamaktadır. Maurya ve arkadaşları [13] mikroskobik hücrelerin Derin Öğrenme tabanlı görüntü sınıflandırmasını sgd, rmsprop, adam yöntemlerini kullanarak gerçekleştirmişlerdir. Çalışmalarında Karşılaştırma Çerçevesini (Framework For Comparison - FFC) ve Çok Seviyeli Topluluklar Topluluğu (Multi-Level Ensemble of Ensembles – M-EOE) yapılarını kıyaslamışlardır. Görüntü çözünürlük boyutlarının artmasıyla birlikte adam yöntemi için doğruluk oranının arttığı tespit edilmiş

ve bu oranın %99.61 olduğu ifade edilmiştir. Bu tez çalışmasında önceki başlıklarda da belirtildiği gibi elmaların cinslerinin tespitinde sınıflandırma yöntemleri kullanılmıştır. Literatürde çok fazla çalışma olmamakla birlikte bu tez çalışmasına benzer olarak Bird ve arkadaşları [14] tarafından meyveler üzerinde iyi mahsulü kötü mahsulden ayırt etmek için bilgisayarlı görme yöntemi kullanılarak küflü veya hasarlı olanlar gibi istenmeyen meyvelerden sağlıklı meyveleri seçme amaçlanmıştır. Çalışmalarında Evrişimli Sinir Ağı (Convolutional Neural Network - CNN) yapısı kullanılmıştır. Üç farklı türe göre gizli katman nöron sayıları belirlenmiş ve bu sayıların artmasıyla doğruluk oranlarının arttığı gözlemlenmiştir. 4096 nöronla yapılan çalışmada ortalama doğruluk oranı %81.99 olarak belirlenmiştir. Rocha ve arkadaşları [15] çalışmalarında yarı kontrollü bir ortamda çok sınıflı bir meyve ve sebze sınıflandırılmasını Küresel Renk Histogramı (Global Color Histogram - GCH) ve Renk Tutarlılığı Vektörleri (Color Coherence Vectors - CCV) ile gerçekleştirmişlerdir. Her iki yöntemde de SVM ile yapılan çalışmalarda %90'ın üzerinde doğruluk oranı tespit edilmiştir. Sınıflandırma yapmak için pek çok algoritma kullanılmaktadır. Bunlardan bazıları; destek vektör makinesi (SVM) , karar ağaçları, k-en yakın komşu, Naive Bayes, diskriminant analizi ve yapay sinir ağlarını içerir.

**Karar ağacı:** Veri madenciliğinde sınıflandırma algoritması olarak kullanılmaktadır. Daha önceden tanımlanmış hedef değişkene sahip oldukları bilinmektedir. Yapıları itibariyle en yukarıdan en aşağıya inen bir strateji sunabilmektedirler.

**K-en yakın komşu:** Bu algoritma, gruplama işlemi yapılması istenen bir veri topluluğunu daha önceki veri toplulukları ile olan yakınlık ilişkisi temelli sınıflandırabilen bir algoritmadır.

**Naive Bayes:** Bu sınıflandırıcının temeli Bayes teoremine dayanmaktadır. Algoritmanın çalışma şekli; Bir eleman için bütün durumların olasılığını hesaplamaktadır. Aynı zamanda olasılık değeri en yüksek olan sonuca göre sınıflandırma yapmaktadır. Düşük bir eğitim verisiyle oldukça başarılı sonuçlar elde edilmektedir.

**Diskriminant Analizi:** Bu analiz, çeşitli değişkenlere göre aynı anda iki ya da daha çok örnek gruplar arasındaki çeşitlilikler üzerinde çalışmasına olanak sağlayan istatistiksel bir tekniktir. Genellikle birimlerin sınıflandırılmasında matematiksel eşitliklerden faydalanılır.

**Yapay Sinir Ağları:** İnsan beyninin bilgi analiz etme tekniđi ele alınarak geliştirilmiş bir bilgi işlem teknolojisidir. Bu ağlar ile basit biyolojik sinir sisteminin çalışma yöntemi taklit edilmektedir. Yani biyolojik hücrelerin birbirleri ile arasında kurduđu sinaptik bađın sanal ortamda modellenmesidir.

Elma fotođraflarının sınıflandırılmasında Makine Öğrenmesi ve Derin Öğrenme başlıkları altında, dođruluđu en fazla olan SVM – BoVW ve ResNet-50 yöntemleri kullanılmıştır. Bir sonraki bölümde bu tez çalışmasında kullanılacak olan algoritmaların detayları işlenecektir.



## İKİNCİ BÖLÜM

### Çalışmada Kullanılan Yöntemler

Bu tez çalışmasında Yahyalı Bölgesine ait elma türlerinin görüntü işleme yöntemleriyle otomatik olarak sınıflandırılması gerçekleştirilmiştir. Görüntü işleme sistemleri, tarımsal ürünlerin sınıflandırılması, ürün kalite kontrolü ve otomasyon işlemlerinde büyük öneme sahiptir. Tarım, insan yaşamının sürdürülebilmesi açısından günümüzde oldukça önem kazanmıştır. Tarımda görüntü işleme sistemleri bitkiler üzerinde birçok analiz, sınıflandırılma, hastalık tespiti gibi tarımsal faaliyetlerde etkin olarak kullanılmaktadır [16].

Yüksek miktarda elma üreten çiftçiler için en önemli sorunlardan biri el değmeden kısa sürede elmaların türlerine göre sınıflandırılmasıdır. Derin Öğrenme ve Makine Öğrenme bu sorunu çözmek için en kullanışlı yöntemlerdir. Bu çalışmada, elma çeşitlerinin cins değişkenlerine göre sınıflandırılması Makine Öğrenme ve Derin Öğrenme algoritmaları kullanılarak yapılmıştır.

Elma fotoğraflarının sınıflandırılmasında en önemli yapay zeka algoritmalarından olan Destek Vektör Makineleri ve ResNet-50 yöntemleri kullanılmıştır.

### 2.1. Elmalar Üzerinde Yapılan Çalışmalar ve Kullanılan Ekipmanlar

Bu çalışmada Kayseri - Yahyalı ilçesinde yetişen elma çeşitlerinin cins değişkenlerine göre sınıflandırılması yapılmıştır. Elmaların hasat zamanı Eylül ayıdır. Bu çalışma hasat zamanında yapılmış olup 20 Golden, 20 Granny Smith, 20 Joremini, 20 Süper Chief, 20 Buckeye Gala ve 20 Galaval elma türünden toplamda 120 görüntü alınmıştır. Görüntüler sabit bir arka fon ile aynı açı ve aynı büyüklükte alınmıştır. Elmalara ait değerler görüntü işleme algoritmaları yardımıyla elde edilmiştir. Elmaların ayrıştırılmasında MATLAB'de bulunan SVM ve ResNet-50 algoritmalarından uygun olanları incelenip kullanılmıştır.

Elde edilen 120 elma fotoğrafının farklı öğrenme seti oranlarında (Durum - 1, Durum - 2 ve Durum - 3) öğrenme modelleri geliştirilmiştir. Öğrenme setinin haricinde kalan fotoğraflar ise test amacıyla kullanılmıştır. Bu tez çalışmasında kullanılan fotoğraflar Canon EOS 70D DSLR marka bir fotoğraf makinesi ile çekilmiştir. Bu fotoğraf makinesinde CMOS tipi bir sensör bulunmaktadır. Fotoğraf makinesinin detaylı özellikleri Tablo 2.1’de verilmiştir. Derin Öğrenme ve Makine Öğrenmenin gerçekleştirildiği bilgisayar, Intel i5 3.4 GHz işlemcili ve 16 GB RAM özelliklerine sahiptir. Bu özelliklerde bir bilgisayar kullanılarak modelleme işlemleri yapılmıştır. Modelleme işlemleri, çok paradigmatlı sayısal hesaplama yazılımı ve dördüncü nesil programlama dili olan MATLAB programının 2021b sürümünde gerçekleştirilmiştir.

**Tablo 2.1.** *Çalışmada Kullanılan Kameranın Teknik Özellikleri*

| CANON EOS 70D DSLR  | Teknik Özellikler |
|---------------------|-------------------|
| Sensör Tipi         | CMOS              |
| Kamera Tipi         | DSLR              |
| Maksimum Çözünürlük | 5472X3648         |
| Etkili Piksel       | 20 MP             |
| Görüntü İşlemcisi   | Digic 5+          |

## 2.2. Makine Öğrenmesi

Makine Öğrenimi, çevredeki ortamdan öğrenerek insan zekâsını taklit etmek için tasarlanmış, gelişen bir hesaplama algoritması dalıdır [17]. Makine Öğrenme, teknolojinin ilerlemesiyle birlikte büyüyen veri birimi alanının oldukça önemli bir bileşeni konumundadır. İstatistiksel yöntemler ele alınarak, algoritmalar; sınıflandırmalar ve/veya tahminler yapmak üzere eğitilirler. Aynı zamanda veri madenciliği projelerinde temel anlam, önem ve biçimini ortaya çıkarmaktadır. Bahsi geçen bu özellikler, sonrasında uygulamalar dahilinde karar verme sürecini aktif ederek, ideal ve ideale yakın anlamda önemli büyüme ölçütlerini etkilemektedir. Büyük veri genişleyip daha da büyümeye devam ederken, veri mühendislerine yönelik piyasa talebi günümüz gerekliliğince artacaktır. Bu alanda çevre sorunlarından tarıma, sanayiden uzay teknolojisine kadar pek çok alanda problemlere çözüm önerecektir.

Makine Öğrenme tekniği uyarlanabilirliği sayesinde verilerin, isteklerin veya görevlerin sürekli kaotik olarak değiştiği senaryolarda veya bir çözümün etkili bir şekilde kodlanmasının yine aşırı doğrusal olmayan olaylardan dolayı mümkün olmadığı durumlarda oldukça tercih edilebilir bir seçenektir. Makine Öğrenme algoritmaları iki gruba ayrılır: gözetimli öğrenme ve gözetimsiz öğrenme. Aralarındaki fark basit ama çok önemlidir. Gözetimli öğrenme yöntemi bir önceki bölümde detaylı bir şekilde açıklanmıştır. Gözetimsiz öğrenmede ise gözetimli öğrenme yönteminden farklı olarak herhangi bir şekilde kategorize edilmemiş ya da etiketlenmemiş eğitim verisi kullanılmaktadır. Önceden eğitilmemiş ve aynı zamanda bilinmeyen veriler arasında bağlantı kurarak birbirine yakın olan verilerin kümelendirilmesi mantığıyla çalışmaktadır.

Bu tez çalışmasında Makine Öğrenme algoritmalarından olan destek vektör makineleri ile sınıflandırma işlemi gerçekleştirilmiştir. İlerleyen bölümlerde bu algoritmanın detaylı açıklaması verilecektir.

### **2.2.1. Makine Öğrenme ve Yapay Zeka**

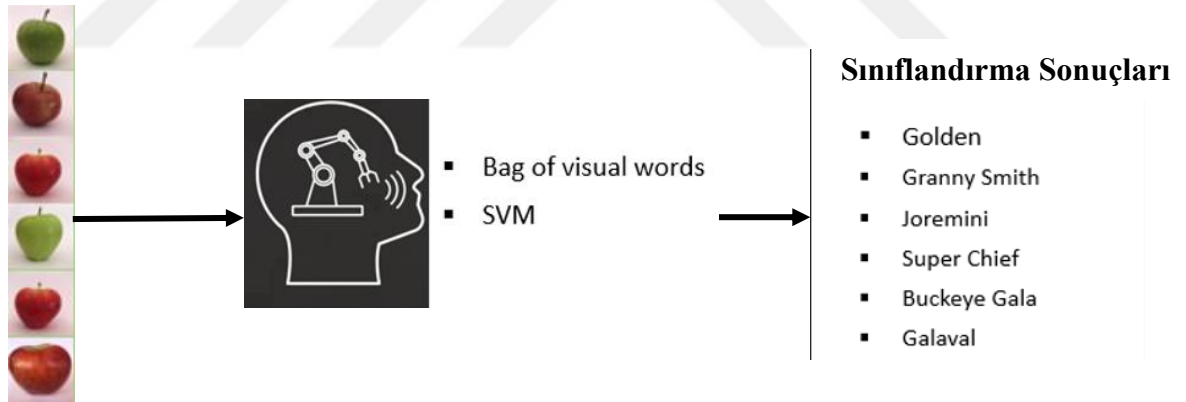
Sanayi devriminden bu yana teknoloji alanında büyük bir gelişme yaşanmıştır. İnsanlar tarafından yapılan birçok iş, makinalar tarafından yapılmaya başlanmıştır. Yapay Zeka (Artificial Intelligence - AI), çeşitli alanlarda insanlara yardımcı olmakla birlikte geleceğin teknolojisi de bu alanda şekillenmektedir. Yapay Zeka bir bilim dalı olmakla birlikte insan zekası gerektiren çeşitli görevleri yerine getirmek için akıllı makineler ve bilgisayar programları oluşturan teknolojidir [18]. Bir insanın yapabileceği çeşitli işlevleri taklit eden bir sistemdir [19]. Yapay zeka, verilen görevler için mükemmel performans elde etmek amacıyla büyük verileri kullanır. Yapay zeka, teknolojinin modern dünyadaki etkisini araştıran tartışmalarda sıklıkla görülen bir kavramdı ama artık gelişen teknoloji ile birlikte günlük hayatımızın bir parçası haline gelmiştir. Aynı zamanda pek çok teknik ve sanayi alanının, Endüstri 4.0 ile birlikte, temel işlevi haline de gelmiştir. Yapay Zekânın, üretim, iletişim, reklam, ulaşım, sağlık, tedarik zincirleri vb. sektörler üzerinde önemli bir etki yarattığı gözlemlenmiştir. Yapay zekanın insanın yapamayacağı şeyleri yapabilme yeteneği, birçok uygulamayı beraberinde getirir ve bu da şu sonuçlara yol açar: performans ve üretkenlikte iyileşme. Bu tez çalışmasında yapay

zekanın alt çalışma alanlarından olan Makine Öğrenme ve Derin Öğrenme yöntemleri kullanılarak, bir sınıflandırma gerçekleştirilmiştir.

Makine Öğrenme, yapay zekanın bir alt kümesi olarak değerlendirilmektedir. Akıllı bir bilgisayar, insan gibi düşünmekte ve görevleri kendi başına gerçekleştirebilmektedir. Bir bilgisayarı, insanların düşünce mekanizmasını taklit edecek şekilde eğitmenin bir yolu da, insan beyni esas alınarak modellenen bir grup algoritmadan oluşan bir sinir ağı kullanmaktır.

### 2.2.2. Makine Öğrenmede Ağ Eğitimi

Elmalar, göz aracılığıyla tespit ile kolayca ayırt edilemeyen benzer dokusal özelliklere sahiptir. Bu nedenle elmaları renk, şekil ve doku özelliklerine bağlı olmaksızın sınıflandırmak için bir çözüme ihtiyaç vardır. Bu çalışmada sınıflandırma problemlerini çözmek için kullanılan Makine Öğrenmesi yöntemleri Şekil 2.1’de gösterilmektedir.



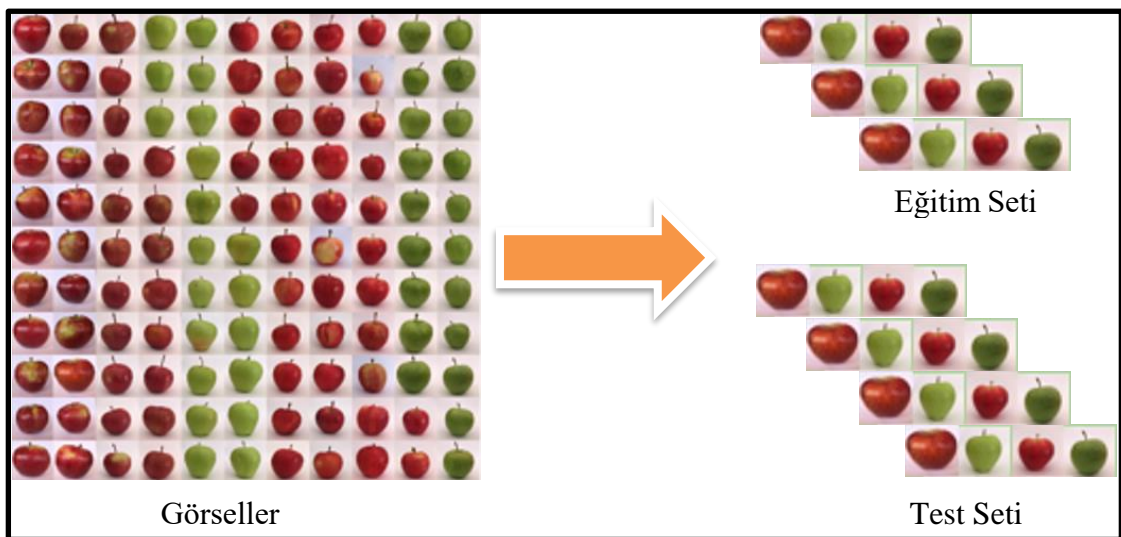
GİRİŞ

**Şekil 2.1.** Sınıflandırma Probleminin Çözümü İçin Kullanılan Makine Öğrenme Yöntemleri

#### 2.2.2.1. Destek Vektör Makinaları ve BoVW

Bag of Visual Words (BoVW), ilk olarak metin analizi alanında geliştirilmiş bir bilgi erişim tekniğidir [20]. Bu tür uygulamalarda bir kelimenin her tekrarı bir özellik olarak tanımlanır ve bir BoVW kelime dağarcığının düzensiz bir veri topluluğu olarak belirtilir [21]. BoVW modeli bütün verilerden bir terim öğrendiğinde, her bir veriyi sınıflandırmak için o kelimenin oluşum sayısı (sıklığı) kullanılabilir. Görüntü sınıflandırması aynı süreci

ve konsepti kullanır. Görüntüden alınan her görsel, bir kelime olarak kabul edilir ve tekrarına göre bir BoVW modeli oluşturulur. Scale Invariant Feature Transform (SIFT) [22] veya Speeded Up Robust Features (SURF) tarafından çıkarılan yerel tanımlayıcılar, sınıflandırma zorluklarını çözmek ve performans gereksinimlerini karşılamak için uygun yollar üretmektedirler [23]. SURF tanımlayıcıları, SIFT tanımlayıcılarından üç kat daha hızlıdır ve nesne algılama, resim kaydı, sınıflandırma veya 3B resmi yeniden oluşturma gibi uygulamalar için kullanılabilir. SIFT ve SURF, mükemmel gürültü direncine sahipken ışığa ve renge karşı duyarsızdır. BoVW'ler, bir görüntüyü karakterize eden görsel kelime görünümünün bir histogramını oluşturmak için kullanılır. Bu histogramlar kullanılarak bir görüntü kategorisi sınıflandırıcı eğitilir. Şekil 2.2 ve Şekil 2.3'te verilen adımlar, görüntülerin nasıl hazırlandığını, bir görsel terim torbasının üretildiğini ve bir görüntü kategorisi sınıflandırıcısının eğitilip uygulandığını göstermektedir. Görüntü veri kümeleri, Şekil 2.2'de gösterildiği gibi eğitim ve test alt kümelerine bölünmelidir. Eğitim seti, genelleştirilmiş bir model oluşturmak amacıyla Makine Öğrenme algoritmasını beslemek için kullanılır. Test seti, yapay modelin bilinmeyen verilere karşı başarısını değerlendirmek için kullanılır.




**Şekil 2.2.** *Görüntü Veri Kümesini Eğitim Ve Test Alt Kümelerine Bölme*

Her kategorinin temsili görüntülerinden özellik tanımlayıcıları çıkarılarak, özellikler çantası adı verilen görsel bir kelime dağarcığı oluşturulur. Eğitim setinden çıkarılan özellik tanımlayıcıları, görsel kelimeler elde etmek için K-araç kümelemesi ile gruplandırılır. Bu yöntem, tanımlayıcıları yinelemeli olarak belirli sayıda kümeye böler.

Benzer nitelikler, kümeler oluşturmak için birlikte gruplandırılır. Her kümenin merkezi, bir özelliği veya görsel kelimeyi belirtir.

Özellikler, bir özellik dedektörü veya önceden tanımlanmış bir ızgara kullanılarak çıkarılır. Izgara yöntemi genellikle elma görüntüleri gibi homojen sonuçlar için kullanılır. SURF dedektörü daha yüksek bir ölçek değişmezliğine sahiptir. Görsel kelimeler yöntemi, uzamsal bilgilere veya bir görüntüdeki belirli nesnelerin tanımlanmasına bağlı değildir. Bu yöntem, yerelleştirmeden çok algılamaya dayalıdır.



**Şekil 2.3.** Elma Görüntüleri İçin Bag Of Features Oluşturulması

SVM, yüksek boyutlu uzaylarda etkili olmasının yanı sıra sınıflandırma problemlerini, kare optimizasyon problemlerine dönüştürür ve çözer. Karar fonksiyonunda bazı eğitim noktalarının seçilmesi nedeniyle hafızayı verimli kullanır ve karar fonksiyonu için birçok farklı kernel fonksiyonunu tercih eder. Böylece öğrenme aşamasında işlem sayısı azaltılır ve diğer algoritmalara göre daha hızlı çözüme ulaşılır [24]. Ayrıca optimizasyon tabanlı bir algoritma olduğu için sınıflandırma performansı, hesaplama karmaşıklığı ve kullanılabilirlik açısından diğer algoritmalarından daha başarılıdır [25].

Lagrange fonksiyonu, Lagrange çarpanları kullanılarak ikinci dereceden bir programlama çözümü olarak tanımlanabilir. Doğrudan dönüştürülmüş öznitelik vektörleri  $h(x_i)$  için yapılabilir. Daha sonra, belirli  $h$  seçimleri için bu iç çarpımların düşük maliyette hesaplanabileceği görülebilir. Lagrange işlevi şu şekildedir:

$$L_D = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{i'=1}^N \alpha_i \alpha_{i'} y_i y_{i'} \langle h(x_i), h(x_{i'}) \rangle \quad (2.1)$$

Denklem (2.3) Denklem (2.2) kullanılarak elde edilebilir ve

$$\beta = \sum_{i=1}^N \alpha_i y_i x_i \quad (2.2)$$

$\beta$  değişkeniyle birlikte çözüm fonksiyonu  $f(x)$  yazılabilir.

$$\begin{aligned} f(x) &= h(x)^T \beta + \beta_0 \\ &= \sum_{i=1}^N \alpha_i y_i \langle h(x), h(x_i) \rangle + \beta_0 \end{aligned} \quad (2.3)$$

burada  $\beta$  bir birim vektördür ve  $h(x_i)$  dönüştürülmüş özellik girdi vektörleridir.  $a_i$  verildiğinde  $\beta_0$ ,  $0 < a_i < C$  olan herhangi bir  $x_i$  için  $(x)$ 'te  $y_i f(x_i) = 1$  çözülerek belirlenebilir. Burada  $C$  maliyet parametresidir. Bir Kernel fonksiyonunun SVM içerisinde en çok kullanılan üç türü vardır.


$$\text{Doğrusal: } K(x, x') = \langle h(x), h(x') \rangle \quad (2.4)$$

2.4 numaralı Denklemde dönüştürülmüş uzayda iç çarpımları hesaplanır.

$$\text{d. dereceden Polinom: } K(x, x') = (1 + \langle x, x' \rangle)^d \quad (2.5)$$

$$\text{Radyal Tabanlı: } K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (2.6)$$

burada  $d$  polinomun derecesidir,  $\gamma$  pozitif bir sabittir ve üstel fonksiyondur [26].




Şekil 2.4. SVM'nin Genel Yapısı

Bir destek vektör makinesinin iki katmanlı algılayıcı tipinde, gizli nöronların sayısı ve ağırlık vektörleri, sırasıyla destek vektörlerinin sayısı ve değerleri ile otomatik olarak belirlenir. Destek vektör makinelerinin genel yapısı Şekil 2.4'te verilmiştir. Çok katmanlı bir algılayıcının tasarımına yönelik geleneksel yaklaşımdan temel bir şekilde farklıdır. Geleneksel yaklaşımda, model karmaşıklığı, öznitelik sayısı küçük tutularak kontrol edilir. SVM, model karmaşıklığını boyuttan bağımsız olarak kontrol ederek öğrenme makinesinin tasarımına bir çözüm sunar:

**Kavramsal problem:** Gizli Katmanın boyutsallığı, hiperdüzlem şeklinde bir karar yüzeyinin inşasını sağlamak için bilerek çok büyük yapılıdır. İyi bir genelleme performansı için, model karmaşıklığı, ayırıcı hiperdüzlemin inşasına belirli kısıtlamalar getirilerek kontrol edilir, bu da eğitim verilerinin bir bölümünün destek vektörleri olarak çıkarılmasıyla sonuçlanır.

**Komutasyon sorunu:** Yüksek boyutlu bir uzayda sayısal optimizasyonun boyutluluk sorunu vardır. Bu hesaplama probleminde, bir Inner-product Kernel kavramı kullanılarak ve girdi katmanında formüle edilen kısıtlı optimizasyon probleminin ikili formunun çözülmesiyle önlenir.

Önerilen uygulamada, Şekil 2.5'te gösterildiği gibi, ikili SVM kullanan çok sınıflı bir sınıflandırıcı eğitilmiştir. Eğitim aşamasında görsel kelimelerin histogramı olarak kodlanan görüntüler kullanılır. Yaklaşık en yakın komşu algoritması kullanılarak veri setindeki her görüntü için bir özellik histogramı hesaplanır. Son olarak, özellik vektörleri, karşılık gelen özellik histogramları tarafından oluşturulur. Eğitim aşamasından sonra, Makine Öğrenme modelinin doğruluğunu ölçmek için test görüntü seti değerlendirilir. Karışıklık matrisi, her bir görüntü kategorisinin doğruluğunu gösteren sürecin son çıktısıdır. İdeal olarak, karışıklık matrisinin köşegeninin %100'lük bir ortalama doğruluğa sahip olması beklenir.



Şekil 2.5. Görsel Kelimelerle SVM Sınıflandırıcı Eğitimi

### 2.3. Derin Öğrenme

Derin Öğrenme, kaotik evrende doğrusal olmayan verilere dayalı olarak öğrenmeyi ve kararlar almayı amaçlamak üzere yapay sinir ağlarını kullanan bir Makine Öğrenme türüdür. Derin Öğrenme, yapay sinir ağlarına dayanmakta ve son on yılda kullanılmaya başlanmıştır [27]. Genellikle Makine Öğrenme, yapay zeka sistemlerini dış dünyadan alınan veriler ile deneyimleri inceleyerek öğrenip, doğrusal olmayan sistemlerdeki desenleri tanıyarak ve bu tanıma sonucunda öneriler sunarak aynı zamanda gerçek zamanlı uyum sağlayacak biçimde eğitir. Derin Öğrenme özellikle dijital sistemlerde, mevcut kural kümelerine yanıt vermek yerine, örneklerden faydalanarak bilgileri toplar ve ardından bu bilgileri kullanarak tıpkı insanlar gibi tepki verir, davranış sergiler ve performans gösterir.

Veri bilimcileri, programcılar ve geliştiriciler, büyük ve karmaşık veri kümelerini analiz etmek için Derin Öğrenme yöntemlerini kullanırlar. Aynı zamanda karmaşık ve aşırı doğrusal olmayan görevleri gerçekleştirmek için de bu yöntemler tercih edilmektedir. Metin, ses veya resimlere çoğu zaman beklenildiği gibi insanlardan daha hızlı ve daha doğru yanıt vermek için Derin Öğrenme yazılımları kullanır. Birçok pratik kullanım alanı olan bu özellikler ile birlikte Derin Öğrenme, pek çok modern teknolojik gelişmelere olanak tanımıştır. Örneğin Ayush ve arkadaşları çalışmalarında [28] ağa sağlanan görüntülerden bilgi alarak veya çıkararak göğüs kanseri, beyin tümörü, diyabetik retinopati gibi hastalıkları sınıflandırmak ve tespit etmek için Convolutional Neural

Network (CNN) Derin Öğrenme modeli oluşturmuşlardır. Liu ve arkadaşları [29] çalışmalarında çok adımlı akış tahmin problemini çözümlmek için yeni bir Derin Öğrenme çok boyutlu topluluk yöntemi önermişlerdir. Akış tahmin performansını önemli ölçüde artırabilen yöntem, farklı işlevsel boyutlara sahip iki topluluk tekniğini, yani anlık görüntü topluluğu ve dikkat topluluğu olarak birleştirmişlerdir. Light Gradient Boosting Machine (LightGBM), Gaussian Process Regression (GPR) ve Artificial Neural Network'e (ANN) kıyasla ortalama Root Mean Squared Error (RMSE) sırasıyla %1,12 ve %0,97 iyileştirme sağlayan iyi bir tahmin oranı elde etmiştir. Bu sonuç, topluluk teorisine sahip Makine Öğrenmesi modellerinin, topluluk olmayan Makine Öğrenmesi modellerinden daha iyi performans sağladığını göstermektedir. Wang ve arkadaşları [30] çalışmalarında farklı görüntü koşulları altında elma, badem, mango ve üzüm salkımlarını kapsayan meyve veri setinin Derin Öğrenme ile kapsamlı bir şekilde analizlerini gerçekleştirmişlerdir. Veri setlerinde nesne sayılarının artmasıyla birlikte ortalama hassasiyet oranlarının arttığı tespit edilmiştir. 1000 nesne ele alındığında %99'un üstünde bir hassasiyet oranı sunulmuştur.


Veri hacmi arttıkça ve bilgi işlem kapasitesi daha güçlü ve ekonomik hale geldikçe perakende, sağlık hizmetleri, taşıma, üretim, teknoloji ve diğer sektörlerdeki şirketlerin yenilikleri hızlandırmak, yeni fırsatlar elde etmek ve rakiplerinin gerisinde kalmamak için Derin Öğrenme uygulamaları literatürde oldukça geniş bir yer kaplamaktadır. Ve böylece Derin Öğrenmenin öneminin arttığı gözlemlenmektedir. Derin Öğrenme de birden çok katmanda sinir ağ mimarilerine, bulutta veya kümelerde dağıtılan grafik işleme birimlerine ve çok yüksek düzeyde girdi verisine sahip metin, konuşma ve görüntü tanıma doğruluğu elde etmek için büyük hacimlerdeki veri birimleri ile birlikte çalışmaktadır.

### **2.3.1. Derin Öğrenmede Ağ Eğitimi ve ResNet-50**

Derin Öğrenme yöntemi birçok alanda oldukça fazla çalışmada kullanılmıştır. Anton ve arkadaşları [31] çalışmalarında 2D ekokardiyografi ve kardiyak manyetik rezonans (CMR) verilerinden kardiyak resenkronizasyon tedavisi (CRT) yanıt tahmini için yeni bir multimodal derin öğrenme modeli sunmuşlardır. Bu çalışma sonucunda multimodal verilerin kombinasyonu, CRT yanıtının %77,38 doğrulukla (%83,33 duyarlılık ve %71,43 özgüllük) tahmin edilmesini sağlamıştır. Çağlar ve arkadaşları [32] çalışmalarında ise bir devre analogisi yoluyla birleştirilmiş 2B kesitlerin derin öğrenme


tabanlı geçirgenlik tahminlerinden 3B mikro yapıların geçirgenliğini tahmin etmek için etkili bir yaklaşım sunmuşlardır. 2B tahminlerin %90'ından fazlası, benzer şekilde 3B kesitlerin enine geçirgenlik tahminleri için akış simülasyonları yoluyla elde edilen muadillerinin  $\pm$  %30'u dahilindeyken, 3B kesit durumunda hesaplama süresi birkaç bin saniyeden 10 saniyenin altına düşürülmüştür. Sahoo ve Gubta [33] çalışmalarında chrome ortamında Makine Öğrenmesi ve Derin Öğrenme sınıflandırıcıları kullanan Facebook kullanıcıları için sahte haber algılama yaklaşımı önermişlerdir. Kullandıkları Derin Öğrenme algoritmaları, Makine Öğrenimi algoritmalarına kıyasla %99,4 doğrulukla oldukça iyi performans elde etmişlerdir. Alkouz ve arkadaşları [34] Grip ile ilgili tweetleri tespit etmek için sosyal medya gönderilerini kullanarak, grip salgınları hakkında erken bilgiler sağlayabilmek amacıyla grip raporlama tweetlerini doğru bir şekilde tanımlamak için bir Derin Öğrenme modeli olan İngilizce ve Arapça dillerini destekleyen Deepluena'yı sunmuşlardır. BERT tabanlı çok dilli modele dayanan Deepluena'nın %99 doğruluk oranına sahip olduğunu tespit etmişlerdir.

Residual Network (ResNet) mimarileri, derin sinir ağlarının eğitiminin zorluğunu azaltmak için Microsoft araştırma ekibi tarafından geliştirilmiştir. ResNet' in 18, 34, 50, 101 ve 152 ağırlık katmanından oluşan çeşitli varyantları vardır [35]. ResNet, bilgisayarla görme işlevselliği için ana omurga olarak kullanılan klasik bir sinir ağı olan Artık Ağlar anlamına gelir [36]. Çok derin sinir ağları, Vanishing Gradients Problem (VGP) nedeniyle eğitim sırasında zorluklarla karşılaşmaktadır. Atlama bağlantıları, eğimli yollar olarak hareket etmektedir ve dolayısıyla eğimin engellenmeden akmasını sağlamaktadır. ResNet modelini diğer modellere göre öne çıkaran unsur, karmaşık bir mimariye sahip olmasına rağmen performansının çok iyi olmasıdır. Ayrıca bu modelde bilgisayar üzerinde daha az performansla hesaplamalar yapılmakta ve bu yöntem yapay sinir ağlarını eğitmede oldukça güvenilirdir. ResNet modeli, toplu normalleştirme ve ReLU etkinleştirme işlevselliği kullanılarak, iki veya üç katmandaki mimariler arasındaki bağlantıları atlayarak uygulanır [37]. Bu modelin basit blok diyagramı Şekil 2.6'da verilmiştir.



**Şekil 2.6.** Artık Öğrenme modeli blok diyagramı

ResNet modeli kullanılarak literatürde oldukça fazla çalışma yapılmıştır. He ve arkadaşları [35] çalışmalarında ResNet modelinin resim sınıflandırmada VGG-16, GoogleNet, PReLU-net gibi modellerden daha iyi performans gösterdiği, görüntü özelliklerinin son derece etkili bir şekilde çıkarıldığını göstermişlerdir. ResNet50'nin mimarisi, Şekil 2.7'deki şemada gösterildiği gibi dört aşamaya sahiptir.



**Şekil 2.7.** ResNet-50 Mimarisi

Ağ yüksekliği, genişliği 32 ve 3'ün katları olan giriş görüntüsünü kanal genişliği olarak alabilir. Girdilerimiz bu tez çalışmasında kullanılan elma görselleri olarak alınmıştır. Her ResNet mimarisi, sırasıyla  $7 \times 7$  ve  $3 \times 3$  kernel boyutlarını kullanarak ilk evrişimli yapıyı ve maksimum havuzlamayı gerçekleştirir. Daha sonra ağın 1. aşaması başlar ve her biri 3 katman içeren 3 rezidüel bloğa sahiptir. Aşama 1'de bloğunun tüm 3 katmanında evrişim işlemini gerçekleştirmek için kullanılan çekirdeklerin boyutu sırasıyla 64, 64 ve 128'dir. Eğri oklar, kimlik bağlantılarını gerçekleştirir. Kesikli bağlantılı ok, rezidüel bloktaki evrişim işleminin 2. adımda gerçekleştirildiğini, dolayısıyla girdi boyutunun yükseklik ve genişlik olarak yarıya indirileceğini, ancak kanal genişliğinin iki katına çıkarılacağını gösterir. Bir aşamadan diğerine geçerken kanal genişliği iki katına çıkar ve girdinin boyutu yarıya iner. ResNet-50, ResNet-152 vb. gibi daha derin ağlar için özel bir tasarım kullanılır. Her artık fonksiyon  $F$  için 3 katman birbiri üzerine istiflenir. Bu üç

katman  $1 \times 1$ ,  $3 \times 3$ ,  $1 \times 1$  kıvrımlardır.  $1 \times 1$  evrişim katmanları, boyutların küçültülmesinden ve ardından geri yüklenmesinden sorumludur.  $3 \times 3$  katmanı, daha küçük girdi/çıkı boyutlarına sahip özel bir durum olarak bırakılır. Son olarak, ağda bir ortalama havuzlama katmanı ve ardından 1000 nörona sahip tam bağlantılı bir katman bulunur (ImageNet sınıfı çıktısı).

ResNet'te artık öğrenme, birden çok bölüm katmanı uygulanarak gerçekleştirilmektedir. ResNet'teki artık blok Denklem 2.7'deki gibi yazılır [38]:

$$\gamma = F(x, \{W_i\}) + x \quad (2.7)$$

burada  $F$ ,  $x$  ve  $y$  sırasıyla artık harita, girdi ve çıktı katmanlarını ifade etmektedir. Artık eşleme işlevi olan " $F(x, \{W_i\})$ " öğrenilmesi gerektirir. Eğer çıkış verilerinin ve giriş verilerinin boyutları aynıysa, ResNet'teki artık blok kullanılabilir durumda olacaktır. ResNet-18 ve ResNet-34 iki katmanlı ağlardır, ResNet-50 ve ResNet-101 ise üç katmanlı ağlardır. Bu tez çalışmasında ResNet-50 algoritma yapısı kullanılmıştır. Derin Öğrenmede tercih edilen algoritmalar olan sgd, rmsprop ve adam algoritmalarını aşağıdaki gibi kısaca açıklayabiliriz.

**Sgd**, tüm parametreler için tek bir öğrenme oranı kullanan bir algoritmadır. Diğer optimizasyon algoritmaları, parametreye göre farklılık gösteren ve optimize edilmiş kayıp fonksiyonuna otomatik olarak adapte olabilen öğrenme oranlarını kullanarak ağ eğitimi iyileştirmeyi amaçlar. Sgd algoritması, denkleme verilen momentum terimi ile parametre güncellemelerini gerçekleştirebilir:

$$\theta_{\ell+1} = \theta_{\ell} - \alpha \nabla E(\theta_{\ell}) + \gamma(\theta_{\ell} - \theta_{\ell-1}) \quad (2.8)$$

burada  $\gamma$ , önceki gradyan adımının mevcut yinelemeye katkısını belirler.  $\ell$  yineleme sayısıdır,  $\alpha > 0$  öğrenme oranıdır,  $\theta$  parametre vektörüdür ve  $E(\theta)$  kayıp fonksiyonudur. Standart gradient descent algorithm (sgd), kayıp fonksiyonunun gradyanı,  $\nabla E(\theta)$ , tüm eğitim seti kullanılarak değerlendirilir ve sgd algoritması, tüm veri setini bir kerede kullanır.

**Rmsprop**, Stokastik Gradyan İniş (SGD) algoritmasının uzantısı, momentum yöntemi ve adam algoritmasının temeli olması nedeniyle son yıllarda popülerlik kazanan uyarlamalı öğrenme yöntemleri arasında yer almaktadır. Root mean squared propagation (Rmsprop),

parametre gradyanlarının eleman karelerinin hareketli bir ortalamasını tutar. Rmsprop için Denklemler aşağıda verilmiştir:

$$v_\ell = \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_\ell)]^2 \quad (2.9)$$

$\beta_2$ , hareketli ortalamanın bozulma oranıdır. Azalma hızının ortak değerleri 0.9, 0.99 ve 0.999'dur. Kare gradyanların karşılık gelen ortalama uzunlukları  $1/(1-\beta_2)$ , yani sırasıyla 10, 100 ve 1000 parametre güncellemesine eşittir. Rmsprop algoritması, her parametre adına ayrı ayrı güncellemeleri normalleştirmek için (2.10) Denklemini kullanır.

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha \nabla E(\theta_\ell)}{\sqrt{v_\ell + \epsilon}} \quad (2.10)$$

burada bölme eleman bazında yapılır.  $\epsilon$  sıfıra bölmeyi önlemek için eklenen küçük bir sabittir.

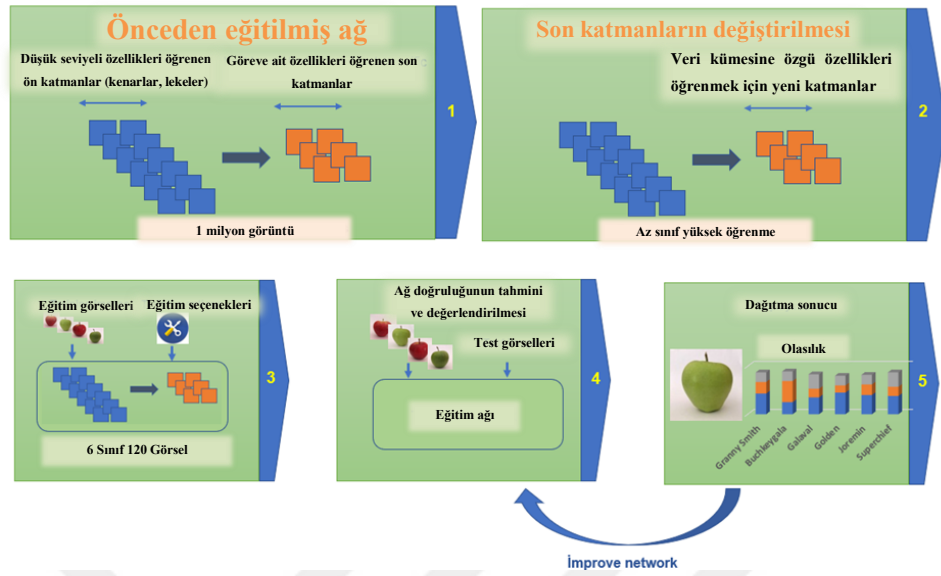
**Adam** algoritması, rmsprop'a benzer ek bir momentum terimi ile parametre güncellemesi gerçekleştirir. Hem parametre gradyanlarının hem de kare değerlerinin eleman bazında hareketli ortalamasının elde edilmesi, Denklem (2.11) ve Denklem (2.12) aracılığıyla verilir:

$$m_\ell = \beta_1 m_{\ell-1} + (1 - \beta_1) \nabla E(\theta_\ell) \quad (2.11)$$

$$v_\ell = \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_\ell)]^2 \quad (2.12)$$

Sırasıyla 'Gradient Decay Factor' ve 'Squared Gradient Decay Factor' ad-değer çifti bağımsız değişkenlerini kullanarak  $\beta_1$  ve  $\beta_2$  bozulma oranlarını belirleyebilir. Adam, ağ parametrelerini güncellemek için denklemde ( $h$ ) ile verilen hareketli ortalamaları kullanır [39].

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha m_\ell}{\sqrt{v_\ell + \epsilon}} \quad (2.13)$$



**Şekil 2.8.** Görüntüleri Sınıflandırmak İçin Resnet-50 Derin Öğrenme Ağının Eğitim Süreci

ResNet-50 önceden eğitilmiş bir transfer öğrenme ağıdır ve az sayıda eğitim görüntüsü kullanılarak hızlı ve kolay öğrenme gerçekleştirilebilir. Şekil 2.8, belirli özelliklere göre seçilen bir görüntü kümesini sınıflandırmak için bir evrişimli sinir ağının eğitim sürecini göstermektedir. Görüntü veri seti, kullanıcıların sınıflandırma problemlerini çözmek için bir milyondan fazla görüntü üzerinde eğitilmiştir. Görüntülerin kenar, nokta, renk gibi alt düzey özellikleri program tarafından öğrenilerek 1 milyon görüntü yaklaşık 1000 sınıfla sınırlandırılabilir. 1000 sınıfla sınırlandırılan özellikler, göreve özgü özellikleri öğrenen son katmanlara indirgenir (Şekil 2.8 1. blok). Elma görüntüleri, ResNet-50 mimarisinde bir görüntü veri deposu olarak beslenir. Veri seti, 120 görüntünün 96'sı eğitim, 24 test (%80 eğitim, %20 test - Durum 3), 72 eğitim, 48 test (%60 eğitim, %40 test - Durum 2), 48 eğitim ve 72 test (%40 eğitim, %60 test – Durum 1) olmak üzere 120 görüntü içerir. Şekil 2.8'de 2. blokta görüldüğü gibi elma türlerinin özelliklerini öğrenmek için veri setinde sınırlamalar yapılarak öğrenme süreci hızlandırılmaktadır. Şekil 2.8'de 3. blokta 120 elma fotoğrafı ile 6 farklı sınıf oluşturulacak eğitim seti oluşturulmakta ve sisteme eğitim seçenekleri girilmektedir. İsteğe bağlı olarak bu katmanlardaki öğrenme oranlarını sıfıra ayarlayarak ağdaki önceki katmanların etkileri dondurulabilir. Donmuş katmanların gradyanları hesaplanmadığından ağ eğitimi hızlandırılabilir. Ayrıca, ağ katmanlarının dondurulması, bu katmanların küçük kümelerdeki yeni veri kümesine gereğinden fazla uymasını önleyebilir. ResNet'te ilk 10 katman ağın ana gövdesini oluşturur. Grafiğin katmanları ve bağlantıları kaldırılarak ve hangi katmanların dondurulacağı seçilerek eğitim süreci tamamlanır. Program matrisi 224 x 224'lük 3 giriş görüntüsüne ihtiyaç

duyar. Eğitim görüntülerinin boyutu yetersiz olabilir, bu nedenle görüntülerin boyutu %10'a kadar artırılabilir. Eğitim yoluyla ince ayar yapılmış ağ kullanılarak, görüntüler ResNet-50 ile sınıflandırılır ve sınıflandırma doğruluğu hesaplanır. Test görüntüleri sistem içinde sürekli bir döngü içindedir ve döngü en doğru tahmini yapacak şekilde tasarlanmıştır.



## ÜÇÜNCÜ BÖLÜM

### Çalışmada Kullanılan Yöntemlerin Sonuçları

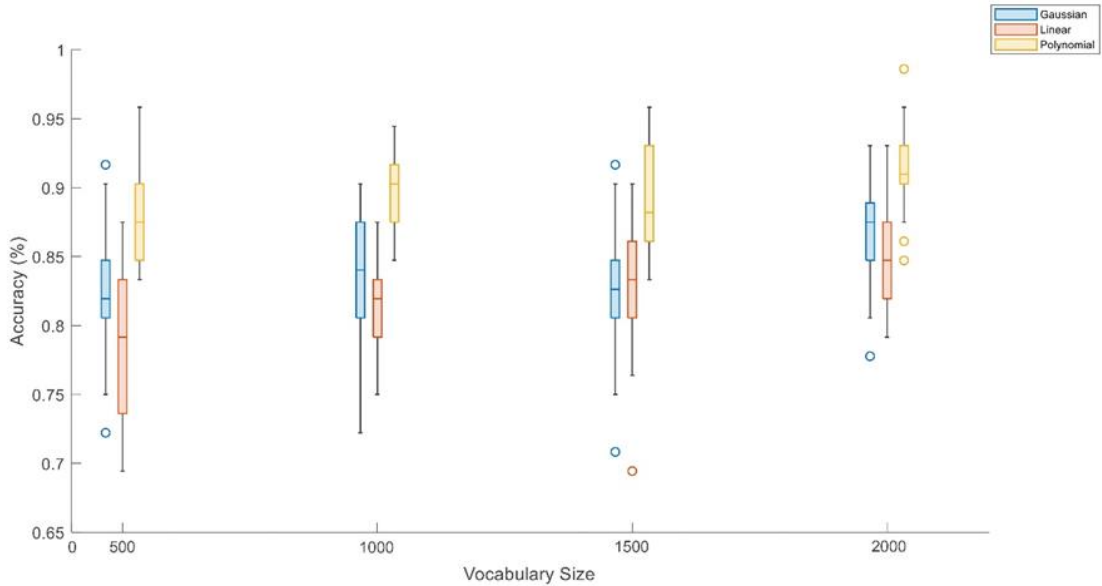
Bu tez çalışmasında, elma görüntülerini sınıflandırmak için BoVW+SVM ve ResNet-50 olmak üzere iki farklı Yapay Zeka yöntemleri kullanılmıştır. BoVW+SVM yönteminde lineer, gauss ve polinom kernel fonksiyonlarının sonuca etkisi değerlendirilirken, ResNet-50 Derin Öğrenme yönteminde adam, rmsprop ve sgd eğitim algoritmalarının sonuca etkileri karşılaştırılmıştır. Ayrıca BoVW+SVM için önemli bir parametre olan kelime büyüklüğü 500, 1000, 1500 ve 2000 için sonuçlar alınmış ve karşılaştırılmıştır. ResNet-50 yönteminde 3, 6, 8, 10 epoch sayıları ile deneyler yapılmıştır. Veri setleri her iki algoritmada da sırasıyla Durum - 1, Durum - 2 ve Durum - 3 olarak belirlenerek yöntemlerin performansları analiz edilmiştir. BoVW+SVM ve ResNet-50 yöntemlerinde daha adil bir karşılaştırma yapmak için 120 veri setinden rastgele eğitim ve test veri setleri oluşturulmuş ve tüm parametreler için 30 kez bu döngü tekrarlanmıştır.

#### 3.1. Görüntü Veri Kümesi

Bu çalışmada 6 farklı elma çeşidinin sınıflandırılması yapılmıştır. Sınıflandırma işleminin ilk adımı olan veri seti oluşturulurken hasat zamanında farklı ağaçlardan her türden 20 adet elma alınmıştır. Veri setinde 20 Golden, 20 Granny Smith, 20 Joremini, 20 Süper Chief, 20 Buckeye Gala ve 20 Galaval olmak üzere toplam 120 görüntü elde edilmiştir. Elma görüntüleri, sabit bir arka plana sahip 1080p HD kamera kullanılarak, aynı açıda ve aynı boyutta ayrı ayrı fotoğraflanmıştır. Görüntüler 3024x3024 piksel olarak alınmış ve verilerin optimum düzeyde işlenmesi için görüntüler 512x512 piksele indirgenmiştir. Görüntüler uygun veri boyutuna getirildikten sonra görüntü işleme aşamasına geçilmiştir. Görüntüleri işlemek için MATLAB programının R2021b versiyonu kullanılmıştır.

### 3.2. BoVW + SVM Sınıflandırma Sonuçları


Elma türlerinin kısa sürede hijyenik bir şekilde sınıflandırılması önemli bir problemdir. Bu çalışma kapsamında görüntü veri setinden öznelik çıkarıcı olarak BoVW ve görüntü özneliklerini elma türlerine göre sınıflandırmak için SVM algoritması kullanılmıştır. Şekil 3.1, eğitim verisi olarak veri setinin sadece %40'ı kullanılarak elde edilen test görüntülerinin doğruluk sonuçlarını göstermektedir. Simülasyonlarda üç farklı kernel fonksiyonu kullanılmaktadır: Gauss, Lineer ve Polinom. Şekil 3.1'de verilen sonuçlara göre Polinom kernel fonksiyonu diğer fonksiyonlara göre çok iyi bir sınıflandırma oranına sahiptir. En iyi sonuçlar kelime boyutu 2000 iken elde edilmektedir. Kelime dağarcığının artmasıyla doğruluk oranının arttığı gözlemlenmektedir.



**Şekil 3.1.** *Durum 1: BoVW+SVM İçin Veri Kümesinin %40'ı Eğitim Ve %60'ı Test Olarak Kullanılan Benzetim Sonuçları*

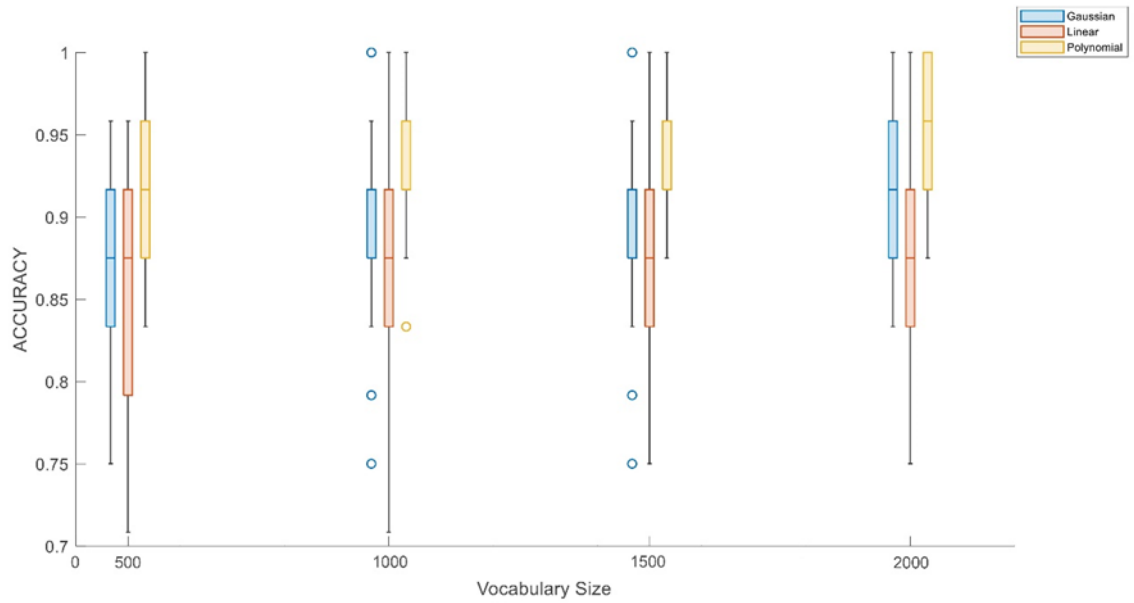
Şekil 3.2, eğitim verisi olarak görüntü veri setinin %60'ı ile elde edilen test veri setinin sınıflandırma doğruluğunu göstermektedir. Şekil 3.2'de verilen sonuçlara göre Polinom fonksiyonunun diğer fonksiyonlara göre çok iyi bir öğrenme oranına sahip olduğu belirlenmiştir. En iyi öğrenme oranı 1500 ve 2000 kelime büyüklüğü kullanılarak elde edilmiştir. Bu test koşullarında %95'in üzerinde bir öğrenme oranına ulaşıldığı gözlemlenmiştir. Ayrıca, Polinom fonksiyonunda kelime büyüklüğünün artmasıyla doğruluk oranının arttığı da gözlemlenmiştir. Bu özelliğin 2000 kelime boyutu dışında diğer koşullarda Lineer kernel fonksiyonu tarafından da sergilendiği tespit edilmiştir. Doğrusal

kernel fonksiyonunda en yüksek öğrenme oranı 1500 ve 2000 kelime büyüklüğü kullanılarak elde edilir. Bu ayarlarda yaklaşık %92 doğruluk oranı elde edilmiştir. Gauss kernel fonksiyonu, Lineer kernel fonksiyonuna göre en düşük ve en yüksek kelime boyutu değerlerine göre iyi bir performans analiz edilmiştir. Bu fonksiyon ile 2000 kelime büyüklüğünü kullanılarak yaklaşık %93 doğruluk oranı elde edilmiştir.



**Şekil 3.2.** *Durum 2: BoVW+SVM İçin Veri Kümesinin %60'ı Eğitim Ve %40'ı Test Olarak Kullanılan Benzetim Sonuçları*

Şekil 3.3, BoVW+SVM kullanılarak elmaların sınıflandırılmasında kullanılan %80 eğitim seti ile elde edilen sonuçları göstermektedir. Şekil 3.3'te Polinom fonksiyonunun diğer fonksiyonlara göre çok iyi bir öğrenme oranına sahip olduğu belirlenmiştir. En iyi öğrenme oranı 2000 kelime büyüklüğü kullanılarak gerçekleşir. Koşmalarda %99'un üzerinde bir öğrenme oranına ulaşıldığı gözlemlenmiştir. Polinom fonksiyonunda 500 – 1000 – 1500 - 2000 değerleri için kelime boyutunun %95 doğruluk oranına sahip olduğu gözlemlenmiştir. Bu özelliğin tüm kelime boyutu değerlerinde Lineer kerne fonksiyonu ile de sergilendiği tespit edilmiştir. Doğrusal kernel fonksiyonunda, tüm kelime boyutu ayarlarında öğrenme oranları eşit ve %90'ın üzerindedir. Gauss kernel fonksiyonu, Lineer kernel fonksiyonuna kıyasla 2000 kelime büyüklüğü değerine göre daha iyi bir performans göstermiştir. Bu fonksiyon ile 2000 kelime büyüklüğünü kullanmada yaklaşık %96 doğruluk oranı elde edilmektedir.



**Şekil 3.3.** Durum 3: BoVW+SVM İçin Veri Kümesinin %80'i Eğitim Ve %20'si Test Olarak Kullanılan Benzetim Sonuçları

**Tablo 3.1.** Durum 1: Veri Kümesinin %40'ı Eğitimde Ve %60'ı Test İçin Kullanılarak BoVW+SVM Kullanılarak Elma Sınıflandırmasının Doğruluk Ve CPU Zamanının İstatistiksel Sonuçları

| SVM Kernel | Kelime Boyutu | Ortalama Eğitim | Standart Eğitim | Ortalama Test | Standart Test | Ortalama Süre   |
|------------|---------------|-----------------|-----------------|---------------|---------------|-----------------|
| Gauss      | 500           | 0,9944          | 0,0094          | 0,8236        | 0,0470        | 107,0307        |
|            | 1000          | 0,9993          | 0,0038          | 0,8370        | 0,0463        | 120,1018        |
|            | 1500          | 0,9993          | 0,0038          | 0,8278        | 0,0436        | 130,7729        |
|            | 2000          | 0,9993          | 0,0038          | <b>0,8634</b> | 0,0354        | <b>137,0979</b> |
| Lineer     | 500           | 0,9819          | 0,0162          | 0,7847        | 0,0531        | 108,2179        |
|            | 1000          | 0,9938          | 0,0111          | 0,8148        | 0,0345        | 121,3457        |
|            | 1500          | 0,9958          | 0,0101          | 0,8259        | 0,0457        | 125,0050        |
|            | 2000          | 0,9979          | 0,0064          | <b>0,8491</b> | 0,0396        | <b>137,0353</b> |
| Polinom    | 500           | 1               | 0               | 0,8769        | 0,0311        | 103,7839        |
|            | 1000          | 1               | 0               | 0,8954        | 0,0267        | 116,5634        |
|            | 1500          | 1               | 0               | 0,8940        | 0,0364        | 132,0152        |
|            | 2000          | 1               | 0               | <b>0,9130</b> | 0,0322        | <b>138,8127</b> |

**Tablo 3.2.** Durum 2: Veri Kümesinin %60'ı Eğitimde Ve %40'ı Test İçin Kullanılarak BoVW+SVM Kullanılarak Elma Sınıflandırmasının Doğruluk Ve CPU Zamanının İstatistiksel Sonuçları

| SVM Kernel | Kelime Boyutu | Ortalama Eğitim | Standart Eğitim | Ortalama Test | Standart Test | Ortalama Süre   |
|------------|---------------|-----------------|-----------------|---------------|---------------|-----------------|
| Gauss      | 500           | 0,9833          | 0,0152          | 0,8493        | 0,0443        | <b>142,4233</b> |
|            | 1000          | 0,9912          | 0,0100          | 0,8708        | 0,0523        | 164,6093        |
|            | 1500          | 0,9963          | 0,0072          | 0,8875        | 0,0443        | 178,3062        |
|            | 2000          | <b>0,9999</b>   | 0,0025          | <b>0,8958</b> | 0,0409        | 191,0347        |
| Lineer     | 500           | 0,9755          | 0,0181          | 0,8313        | 0,0472        | <b>141,3958</b> |
|            | 1000          | 0,9866          | 0,0106          | 0,8528        | 0,0413        | 159,7241        |
|            | 1500          | 0,9880          | 0,0114          | 0,8840        | 0,0362        | 175,9674        |
|            | 2000          | <b>0,9926</b>   | 0,0087          | <b>0,8854</b> | 0,0419        | 184,5520        |
| Polinom    | 500           | 0,9995          | 0,0025          | 0,9069        | 0,0374        | <b>149,7379</b> |
|            | 1000          | 1               | 0               | 0,9306        | 0,0311        | 163,2641        |
|            | 1500          | 1               | 0               | 0,9250        | 0,0385        | 186,5572        |
|            | 2000          | 1               | 0               | <b>0,9396</b> | 0,0364        | 176,9773        |

**Tablo 3.3.** Durum 3: Veri Kümesinin %80'ı Eğitimde Ve %20'si Test İçin Kullanılarak BoVW+SVM Kullanılarak Elma Sınıflandırmasının Doğruluk Ve CPU Zamanının İstatistiksel Sonuçları

| SVM Kernel | Kelime Boyutu | Ortalama Eğitim | Standart Eğitim | Ortalama Test | Standart Test | Ortalama Süre   |
|------------|---------------|-----------------|-----------------|---------------|---------------|-----------------|
| Gauss      | 500           | 0,9729          | 0,0108          | 0,8764        | 0,0614        | <b>185,1388</b> |
|            | 1000          | 0,9858          | 0,0093          | 0,8972        | 0,0576        | 209,9681        |
|            | 1500          | <b>0,9944</b>   | 0,0066          | 0,8931        | 0,0555        | 214,8329        |
|            | 2000          | 0,9986          | 0,0036          | <b>0,9208</b> | 0,0442        | 232,8404        |
| Lineer     | 500           | 0,9587          | 0,0111          | 0,8583        | 0,0697        | <b>176,5363</b> |
|            | 1000          | 0,9753          | 0,0124          | 0,8681        | 0,0610        | 217,8336        |
|            | 1500          | 0,9806          | 0,0109          | <b>0,8806</b> | 0,0607        | 228,9741        |
|            | 2000          | <b>0,9837</b>   | 0,0094          | 0,8750        | 0,0547        | 264,8464        |
| Polinom    | 500           | 0,9997          | 0,0019          | 0,9181        | 0,0507        | <b>204,0340</b> |
|            | 1000          | 1               | 0               | 0,9375        | 0,0434        | 208,7469        |
|            | 1500          | 1               | 0               | 0,9458        | 0,0331        | 217,3534        |
|            | 2000          | 1               | 0               | <b>0,9597</b> | 0,0387        | 232,4238        |

Tablo 3.1-3.3, eğitim ve test veri kümesi girdilerinin farklı yüzdesine göre Gauss, Lineer ve Polinom SVM Kernel fonksiyonlarının "Kelime boyutu, Ortalama Eğitim, Standart Eğitim, Ortalama Testi, Standart Test ve Ortalama Zaman" değerlerini gösterir.


Tablo 3.1-3.3'te verilen değerlere göre kelime boyutunun artmasıyla ağın ortalama işlem süresinin arttığı görülmektedir.

Polinom kernel fonksiyonunun ortalama zamanlarda, zaman performansı açısından daha verimli olduğu gözlemlenmiştir. Şekil 3.1-3.3 ve Tablo 3.1-3.3'teki verilere göre en iyi öğrenme oranının polinom kernel fonksiyonuna ait olduğu tespit edilmiştir.


### 3.3. ResNet-50 Sınıflandırma Sonuçları

ResNet mimarisi, görüntünün artan ağ katmanları sayesinde gradyan sorunlarını (kaybolma ve patlama) çözer [40]. ResNet-50, diğer birçok mimariye kıyasla çok iyi bir tanımlama doğruluğuna ve gerçek zamanlı performansa sahiptir [35]. Çalışmanın bu bölümünde elma görüntülerinin ResNet-50 Derin Öğrenme yöntemi kullanılarak sınıflandırılması yapılmıştır. Deneylerde üç farklı eğitim fonksiyonu kullanılmıştır: adam, rmsprop ve sgd. Şekil 3.4, veri setinin Durum - 1 sonuçlarını göstermektedir. Şekil 3.4'te verilen sonuçlara göre en düşük iterasyon sayısında adam eğitim fonksiyonunun diğer eğitim fonksiyonlarına göre daha yüksek doğruluk oranı verdiği tespit edilmiştir. İterasyon sayısı 10'a çıkarıldığında sgd fonksiyonunun diğer fonksiyonlara göre daha iyi performans gösterdiği gözlemlenmiştir. Tüm işlevler için en iyi öğrenme oranı 10 iterasyonda gerçekleşmiştir. Tüm fonksiyonlar için dönem sayısının artmasıyla doğruluk oranı artmıştır. Sgd için 10 iterasyonda öğrenme oranı yaklaşık %91 iken, adam ve rmsprop fonksiyonları için bu oran %87 civarındadır.

Şekil 3.5'te ResNet-50 algoritmasında eğitim için Durum - 2 sonuçları verilmiştir. Simülasyon çalışmalarında %60 test setinde olduğu gibi üç farklı kernel fonksiyonu kullanılmıştır. Şekil 3.5'te verilen sonuçlara göre en düşük iterasyon sayısında adam eğitim fonksiyonunun diğer fonksiyonlara göre daha yüksek doğruluk oranı verdiği tespit edilmiştir. Test veri seti değerinin 6 ve 10 iterasyon olduğu durumlarda, rmsprop fonksiyonunun doğruluğu artmış olmakla birlikte, 8 iterasyonda azalmıştır. Öte yandan, sgd işlevinin öğrenme performansı 6, 8 ve 10 iterasyonda artmıştır. Sgd için en iyi öğrenme oranı 6 iterasyonda %93'tür. Genel olarak, iterasyon sayısı arttıkça adam ve rmsprop kernel fonksiyonlarının doğruluk oranlarının arttığı gözlemlenmiştir. Adam ve rmsprop eğitim fonksiyonları için en iyi değerler, 10 iterasyonda sırasıyla yaklaşık %90 ve %92'dir.




**Şekil 3.4.** Durum 1: ResNet-50 için veri kümesinin %40'ı eğitim ve %60'ı test olarak kullanılan benzetim sonuçları



**Şekil 3.5.** Durum 2: ResNet-50 İçin Veri Kümesinin %60'ı Eğitim Ve %40'ı Test Olarak Kullanılan Benzetim Sonuçları

Durum- 3'te elde edilen sonuçlar Şekil 3.6'da verilmiştir. Şekil 3.6'da verilen sonuçlara göre, eğitim fonksiyonlarının en düşük iterasyon sayısında eşit doğruluğa sahip olduğu belirlenmiştir. Kernel fonksiyonlarının doğruluk oranlarının genel olarak test veri setindeki artışla birlikte arttığı gözlemlenmiştir. Adam, sgd ve rmsprop kernel işlevleri için en iyi öğrenme oranı, 10 iterasyonda sırasıyla yaklaşık %95, %90 ve %91'dir.



**Şekil 3.6.** Durum 3: ResNet-50 İçin Veri Kümesinin %80'i Eğitim Ve %20'si Test Olarak Kullanılan Benzetim Sonuçları

Tablo 3.4-3.6, sgd, rmsprop ve adam kernel fonksiyonlarının eğitim sonuçları “Maksimum İterasyon, Ortalama Eğitim, Standart Eğitim, Ortalama Test, Standart Test ve Ortalama Süre” değerlerini göstermektedir. Tablolarda verilen değerlere göre iterasyon değerinin artmasıyla ağın ortalama işlem süresinin arttığı görülmektedir. Şekil 3.4 ve Tablo 3.4’te görüldüğü gibi en iyi öğrenme oranı sgd eğitim fonksiyonu ile elde edilmektedir.

**Tablo 3.4.** Durum 1: Veri Kümesinin %40’ı Eğitimde Ve %60’i Test İçin Kullanılarak ResNet-50 Kullanılarak Elma Sınıflandırmasının Doğruluk Ve CPU Zamanına İlişkin İstatistiksel Sonuçlar.

| Eğitim Algoritması | Maks. İterasyon | Ortalama Eğitim | Standart Eğitim | Ortalama Test | Standart Test | Ortalama Süre   |
|--------------------|-----------------|-----------------|-----------------|---------------|---------------|-----------------|
| sgd                | 3               | 0,8708          | 0,0436          | 0,7630        | 0,0488        | 143.1643        |
|                    | 6               | 0,9757          | 0,0219          | 0,8472        | 0,0379        | 225.4943        |
|                    | 8               | 0,9889          | 0,0142          | 0,8611        | 0,0370        | 304.4231        |
|                    | 10              | 0,9972          | 0,0072          | <b>0,8764</b> | 0,0378        | <b>344.4525</b> |
| rmsprop            | 3               | 0,7972          | 0,1157          | 0,7023        | 0,1209        | 141.4278        |
|                    | 6               | 0,9313          | 0,0629          | 0,8236        | 0,0634        | 232.6942        |
|                    | 8               | 0,9278          | 0,0863          | 0,8032        | 0,0950        | 292.7812        |
|                    | 10              | 0,9410          | 0,0582          | <b>0,8319</b> | 0,0795        | <b>365.9085</b> |
| adam               | 3               | 0,9271          | 0,0578          | 0,8042        | 0,0653        | 146.4620        |
|                    | 6               | 0,9549          | 0,0413          | 0,8370        | 0,0717        | 221.3938        |
|                    | 8               | 0,9562          | 0,0442          | 0,8347        | 0,0696        | 276.9126        |
|                    | 10              | 0,9549          | 0,0431          | <b>0,8551</b> | 0,0556        | <b>358.4349</b> |

Tablo 3.5'te verilen değerlere göre sgd m kernel fonksiyonunun zaman performansı açısından verimli olduğu tespit edilmiştir. Şekil 3.5 ve Tablo 3.5 hem görsel hem de sayısal karşılaştırma yapılabilmesi için verilmiştir. Bu değerlerden de anlaşılacağı üzere en iyi öğrenme değeri 10 iterasyonda %99 oranında rmsprop eğitim fonksiyonu ile elde edilmektedir.

**Tablo 3.5.** *Durum 2: Veri Kümesinin %60'ı Eğitimde Ve %40'ı Test İçin Kullanılarak ResNet-50 Kullanılarak Elma Sınıflandırmasının Doğruluk Ve CPU Zamanına İlişkin İstatistiksel Sonuçlar.*

| Eğitim Algoritması | Maks. İterasyon | Ortalama Eğitim | Standart Eğitim | Ortalama Test | Standart Test | Ortalama Süre   |
|--------------------|-----------------|-----------------|-----------------|---------------|---------------|-----------------|
| sgdm               | 3               | 0,9500          | 0,0229          | 0,8368        | 0,0474        | 165.8704        |
|                    | 6               | 0,9944          | 0,0086          | 0,8770        | 0,0372        | 280.3017        |
|                    | 8               | 0,9976          | 0,0064          | 0,8847        | 0,0272        | 370.7952        |
|                    | 10              | 0,9986          | 0,0042          | <b>0,8909</b> | 0,0287        | <b>468.0144</b> |
| rmsprop            | 3               | 0,8764          | 0,0927          | 0,7590        | 0,1022        | 158.0729        |
|                    | 6               | 0,9333          | 0,0647          | 0,8257        | 0,0777        | 277.6705        |
|                    | 8               | 0,9296          | 0,0688          | 0,8181        | 0,0915        | 367.4697        |
|                    | 10              | 0,9476          | 0,0551          | <b>0,8513</b> | 0,0731        | <b>450.5992</b> |
| adam               | 3               | 0,9403          | 0,0415          | 0,8243        | 0,0811        | 160.1268        |
|                    | 6               | 0,9639          | 0,0362          | 0,8292        | 0,0637        | 281.4267        |
|                    | 8               | 0,9639          | 0,0506          | <b>0,8562</b> | 0,0733        | 382.2819        |
|                    | 10              | 0,9634          | 0,0455          | 0,8389        | 0,1015        | <b>450.3780</b> |

Tablo 3.6 ve Şekil 3.6'da verilen değerlere göre minimum iterasyon değeri olan 3 için sgd m fonksiyonunun daha iyi bir performans sağladığı belirlenmiştir. En yüksek maksimum iterasyon değeri olan 10 için en iyi öğrenme değerine sgd m kernel fonksiyonunun sahip olduğu belirlenmiştir. Tablo 3.6 ve Şekil 3.6'da verilen değerlere göre 3 iterasyon değeri için tüm fonksiyonların yaklaşık olarak eşit doğruluğa sahip olduğu belirlenmiştir. En yüksek 10 iterasyon değeri için en iyi öğrenme değeri sgd m kernel fonksiyonunda olduğu tespit edilmiştir.

**Tablo 3.6.** Durum 3: Veri Kümesinin %80'i Eğitimde Ve %20'i Test İçin Kullanılarak ResNet-50 Kullanılarak Elma Sınıflandırmasının Doğruluk Ve CPU Zamanına İlişkin İstatistiksel Sonuçlar.

| Training Algorithm | Max Epochs | Mean Train | Std Train | Mean Test     | Std Test | Avg. Time       |
|--------------------|------------|------------|-----------|---------------|----------|-----------------|
| sgdm               | 3          | 0,9521     | 0,0260    | 0,8444        | 0,0557   | 180.0895        |
|                    | 6          | 0,9913     | 0,0099    | 0,8792        | 0,0442   | 335.5029        |
|                    | 8          | 0,9958     | 0,0070    | <b>0,9042</b> | 0,0248   | 401.4973        |
|                    | 10         | 0,9990     | 0,0032    | 0,9028        | 0,0228   | <b>487.4055</b> |
| rmsprop            | 3          | 0,8896     | 0,0754    | 0,8139        | 0,0907   | 180.07032       |
|                    | 6          | 0,9288     | 0,0590    | 0,8194        | 0,0993   | 329.8573        |
|                    | 8          | 0,9278     | 0,0774    | 0,8528        | 0,1031   | 423.9877        |
|                    | 10         | 0,9497     | 0,0641    | <b>0,8597</b> | 0,0822   | <b>482.9436</b> |
| adam               | 3          | 0,9170     | 0,0515    | 0,8278        | 0,0663   | 178.0338        |
|                    | 6          | 0,9406     | 0,0506    | 0,8542        | 0,0824   | 319.2763        |
|                    | 8          | 0,9646     | 0,0392    | <b>0,8889</b> | 0,0632   | 427.4709        |
|                    | 10         | 0,9778     | 0,0273    | 0,8736        | 0,0925   | <b>438.3448</b> |

### 3.4. ResNet-50 ve BoVW + SVM Metodlarının Karşılaştırılması

Durum-1'de polinom kernel fonksiyonu en yüksek doğruluk oranına ulaşırken, BoVW+SVM algoritması için doğruluk oranı %91,3'tür. ResNet-50 algoritması sgdm kernel fonksiyonunda en yüksek doğruluk oranına Durum-1'de %87,6 ile ulaşırken, BoVW+SVM algoritmasında en yüksek doğruluk oranının Durum-2'de %93,9'un üzerine çıktığı belirlenmiştir. Aynı çalışma koşulları altında ResNet-50 algoritmasının en iyi doğruluk oranının yaklaşık %89 olduğu sonucuna varılmıştır. Durum-3' te eğitimin %80'e yükseltilmesi ile BoVW+SVM algoritmasının %95'in üzerinde bir doğruluk oranına ulaştığı ancak ResNet-50 algoritmasında bu oranın %90'da kaldığı belirlenmiştir. Bu sonuçlar doğrultusunda BoVW+SVM algoritmasının ResNet-50 yapısına göre doğruluk açısından daha iyi performans gösterdiği elde edilmiştir. Tablolar incelendiğinde algoritmaların CPU zaman tüketimleri açısından performans analizi yapılabilmektedir. Bu analiz sonuçlarına göre ResNet-50 algoritmasının BoVW+SVM algoritmasına göre daha uzun sürede işlem gerçekleştirdiği tespit edilmiştir. BoVW+SVM algoritmasının polinom kernel fonksiyonunun aynı çalışma koşullarında diğer fonksiyonlardan daha iyi performans gösterdiği gözlemlenirken sözcük sayısı arttıkça BoVW+SVM algoritmasının performansında artış tespit edilmiştir. Tüm çalışma koşulları arasında en iyi sınıflandırma doğruluğu BoVW+SVM algoritmasının polinom

kernel fonksiyonunda gerçekleşmekte olup bu oran %95'in üzerindedir. Tablo 3.7'de BoVW +SVM ve ResNet-50 yapılarının test sonuçlarına göre karşılaştırılması verilmiştir.

**Tablo 3.7.** *BoVW+SVM Ve ResNet-50 Yöntemlerinin Test Veri Setleri İle karşılaştırılması.*

|           |                 | <b>Durum 1</b>  | <b>Durum 2</b>  | <b>Durum 3</b>  |
|-----------|-----------------|-----------------|-----------------|-----------------|
| BoVW+SVM  | Doğruluk (%)    | 0,9130 (0,0322) | 0,9396 (0,0364) | 0,9597 (0,0387) |
|           | Parametreler    | polinom, 2000   | polinom, 2000   | polinom, 2000   |
|           | CPU Süresi (sn) | 138             | 176             | 232             |
| ResNet-50 | Doğruluk (%)    | 0,8764 (0,0378) | 0,8909 (0,0287) | 0,9042 (0,0248) |
|           | Parametreler    | sgdm, 10        | sgdm, 10        | sgdm, 8         |
|           | CPU Süresi (sn) | 344             | 468             | 401             |

## DÖRDÜNCÜ BÖLÜM

### Sonuç ve Öneriler

Bu çalışmada elma görüntülerini sınıflandırmak için Makine Öğrenmesi yöntemlerinden BoVW+SVM ve ResNet-50 algoritmaları kullanılmıştır. Her iki yöntemde de en iyi sonuçlar Durum-3'te gözlenmiştir. BoVW+SVM yönteminde 2000 kelime boyutundaki polinom kernel fonksiyonunda öğrenme oranı %100 ve en iyi test oranı %95,9 olarak bulunmuştur. ResNet-50 yönteminde 8 epoch için sgd kernel fonksiyonlarında öğrenme oranının %99,5 ve en iyi test oranının %90,4 olduğu belirlenmiştir. Genel olarak eğitim oranlarının artması ile her iki algoritmanın da tahmin yeteneklerinin arttığı gözlemlenmiştir. BoVW+SVM yönteminde kelime sayısı arttıkça ortalama sürenin arttığı, ResNet-50 yönteminde ise iterasyon sayısı arttıkça ortalama sürenin arttığı görülmüştür. En iyi ortalama test sonuçlarında BoVW+SVM algoritmasının 30 tekrarında 232 dakikalık işlem süresine sahipken, ResNet-50 algoritmasının 30 tekrarında 401 dakikalık işlem süresine sahiptir. BoVW+SVM yönteminin hem test hızı hem de ortalama süre açısından ResNet-50 yöntemine göre daha başarılı olduğu tespit edilmiştir.

Bu tez çalışmasında kullanılan BoVW+SVM ve ResNet-50, yapay zeka metotlarında oldukça başarılı sonuçlar vermiştir. 6 farklı elma türünün de başarılı bir şekilde tahmin edilmesi, sistemin otomatikleştirilmesi açısından umut vericidir. İlerleyen çalışmalarda, tezde yer alan her iki yöntemin de kullanılarak sahada elma cinsi tespitinde kullanılması düşünülmektedir. Gerçek zamanlı tespitlerde kullanılması önerilen bu yöntemlerin doğruluk oranları ve tekrarlanabilirlik özellikleriyle sınıflandırma çalışmalarına oldukça fazla katkılar sunabileceği düşünülmektedir.

## KAYNAKÇA

- [1] W. N. Adger, S. Huq, K. Brown, D. Conway, and M. Hulme, "Adaptation to climate change in the developing world," *Progress in development studies*, vol. 3, no. 3, pp. 179-195, 2003.
- [2] O. F. Loss, "Food and agriculture," 2019. (<https://www.fao.org/3/ca6030en/ca6030en.pdf>), (Eriřim tarihi: Mayıs 2022).
- [3] TÜİK, "Meyveler, iecek ve baharat bitkilerin üretim miktarları (seilmiş ürünlerde)," 2021, (<https://data.tuik.gov.tr/Kategori/GetKategori?p=tarim-111>). (Eriřim tarihi: Mayıs 2022)
- [4] Tarımsal Ekonomik ve Politika Geliřtirme Enstitüsü, "Tarım ürünleri piyasası," 2020. (<https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20Tar%C4%B1m%20%C3%9Cr%C3%BCnleri%20Piyasalar%C4%B1/2020-Temmuz%20Tar%C4%B1m%20%C3%9Cr%C3%BCnleri%20Raporu/Elma,%20Temmuz-2020,%20Tar%C4%B1m%20%C3%9Cr%C3%BCnleri%20Piyasa%20Raporu.pdf>), (Eriřim tarihi: Mayıs 2022)
- [5] Yahyalı Belediyesi, "Elmacılık," 2022. (<https://yahyali.bel.tr/elmacilik>), (Eriřim tarihi: Mayıs 2022)
- [6] E. Bul, G. Gelen, H. Altun, "Görüntü işlemeye dayalı tarımsal ürün sınıflandırma," Researchgate,

([https://www.researchgate.net/publication/268257369\\_GORUNTU\\_DAYALI\\_TARIMSAL\\_URUN\\_SINIFLANDIRMA](https://www.researchgate.net/publication/268257369_GORUNTU_DAYALI_TARIMSAL_URUN_SINIFLANDIRMA)), (Eriřim Tarihi: Mayıs 2022)

- [7] K. Hanbay, M. TALU, O. Ozguven, “Real time fabric defect detection by using fourier transform,” *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 32, no. 1, pp. 151-158. 2017.
- [8] R. Kaur, E. N. Singh, “Image restoration-a survey.” *IOSR Journal of Computer Engineering*, vol. 16 no. 4, pp. 107-111, 2014.
- [9] M. Karakoç, “Görüntü İşleme Teknikleri ve Yapay Zeka Yöntemleri Kullanarak Görüntü İçinde Görüntü Arama,” Yüksek Lisans Tezi, Pamukkale Üniversitesi, Denizli, 2011.
- [10] Ş. E. ŞEKER, “Sınıflandırma,” 2013.  
(<https://bilgisayarkavramlari.com/2013/03/31/siniflandirma-classification/>), (Eriřim tarihi: Mayıs 2022).
- [11] Q. Fan, Y. Bi, B. Xue, M. Zhang, “Genetic programming for feature extraction and construction in image classification,” *Applied Soft Computing*, vol. 118, no. 108509, 2022.
- [12] Q. U. Ain, H. Al-Sahaf, B. Xue, M. Zhang, “Genetic programming for automatic skin cancer image classification,” *Expert Systems with Applications*, vol. 197 no. 116680, 2022.
- [13] R. Maurya, V. K. Pathak, M. K. Dutta, “Deep learning based microscopic cell images classification framework using multi-level ensemble.” *Computer Methods and Programs in Biomedicine*, vol. 211, no. 106445, 2021.
- [14] J. J. Bird, C. M. Barnes, L. J. Manso, A. Ekárt, D. R. Faria, “Fruit quality and defect image classification with conditional GAN data augmentation,” *Scientia Horticulturae*, vol. 293, no. 110684, 2022.
- [15] A. Rocha, D. C. Hauagge, J. Wainer, S. Goldenstein, “Automatic fruit and vegetable classification from images,” *Computers and Electronics in Agriculture*, vol. 70 no. 1, pp. 96-104, 2010.

- [16] A. M. M. Kaymak, M. N. N. Örnek, H. Kahramanlı, “Görüntü işleme teknolojilerinin elma bahçelerine yönelik kullanım örneği,” *Uluborlu Mesleki Bilimler Dergisi*, vol. 2, no. 1, pp. 17-26, 2019.
- [17] I. El Naqa, M. J. Murphy, “What is machine learning?,” *In Machine Learning in Radiation Oncology*, Springer, Cham., 2015.
- [18] B. G. Buchanan, “A (very) brief history of artificial intelligence,” *Ai Magazine*, pp. 53-53. 2005.
- [19] S. Bhbosale, V. Pujari, Z. Multani, “Advantages and disadvantages of artificial intellegence,” *Aayushi International Interdisciplinary Research Journal*, vol. 70, pp. 227-230, 2020.
- [20] A..Bosch, , X. Munoz, R. Marti, “Which is the best way to organize/classify images by content?,” *Image and Vision Computing*, vol. 25, no. 6, pp. 778-791, 2007.
- [21] G. Salton, M. J. McGill, “Information Retrieval: an Introduction,” Introduction to modern information retrieval, pp. 1-23, 1983.
- [22] G. Lowe, “Sift-the scale invariant feature transform,” *Int. J.*, vol. 60 no. 2, pp. 91-110. 2004.
- [23] H.Bay, A. Ess, T. Tuytelaars, L. Van Gool, “Speeded-up robustfeatures,” *Computer Vision and Image Understanding*, vol. 110, no. 3, pp. 346-359. 2008.
- [24] S. Osowski, K. Siwek, T. Markiewicz, “MLP and SVM networks-a comparative study,” *In Proceedings of the 6th Nordic Signal Processing Symposium*, June, vol. 37, no. 40, 2004.
- [25] I. Nitze, , U. Schulthess, H. Asche, “Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification,” 35-40.*Proceedings of the 4th GEOBIA, Rio de Janeiro, Brazil*, 79. 2012.

- [26] T. Hastie, R. Tibshirani, J. H. Friedman, J. H. Friedman, data mining, inference, and prediction, *The Elements of Statistical Learning*. New York, Springer, 2009, pp. 371-409.
- [27] Y. Bengio, A. Courville, P. Vincent, "Representation learning: a review and new perspectives," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35 no. 8, pp. 1798-1828, 2013.
- [28] A. Singhal, M. Phogat, D. Kumar, A. Kumar, M. Dahiya, V. K. Shrivastava, study of deep learning techniques for medical image analysis: *A review. Materials Today: Proceedings*, vol. 56, no. 1, pp. 209-214, 2022.
- [29] G. Liu, Z. Tang, H. Qin, S. Liu, Q. Shen, Y. Qu, J. Zhou, "Short-term runoff prediction using deep learning multi-dimensional ensemble method," *Journal of Hydrology*, vol. 609, no. 127762, 2022.
- [30] X. A. Wang, J. Tang, M. Whitty, "Data-centric analysis of on-tree fruit detection: experiments with deep learning," *Computers and Electronics in Agriculture*, vol. 194, no. 106748, 2022.
- [31] E. Puyol-Antón, B. S. Sidhu, J. Gould, B. Porter, M. K. Elliott, V. Mehta, A. P. King, "A multimodal deep learning model for cardiac resynchronisation therapy response prediction," *Medical Image Analysis*, vol. 79, no. 102465, 2022.
- [32] B. Caglar, G. Broggi, M. A. Ali, L. Orgéas, and V. Michaud, "Deep learning accelerated prediction of the permeability of fibrous microstructures," *Composites Part A: Applied Science and Manufacturing*, no. 106973, 2022.
- [33] S. R. Sahoo, B. B. Gupta, "Multiple features based approach for automatic fake news detection on social networks using deep learning," *Applied Soft Computing*, vol. 100, no. 106983, 2021.
- [34] B. Alkouz, Z. Al Aghbari, M. A. Al-Garadi, A. Sarker, "Deepluena: deep learning for influenza detection from Twitter," *Expert Systems with Applications*, vol. 198, no. 116845, 2022.

- [35] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition," In Proceedings of the IEEE conference on computer vision and pattern recognition, 27-30 June 2016, Las Vegas, NV, USA, IEEE. 2016, pp. 770-778.
- [36] X. Feng, Y. Jiang, X. Yang, M. Du, X. Li, "Computer vision algorithms and hardware implementations," *a survey. Integration*, vol. 69, pp. 309-320, 2019.
- [37] A. Sachan, "What is deep residual network?," (<https://cv-tricks.com/keras/understand-implement-resnets/>), (Erişim tarihi: Mayıs 2022).
- [38] Y. Cao, Z. Wu, C. Shen, "Estimating depth from monocular images as classification using deep fully convolutional residual networks," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 28 no. 11, pp. 3174-3182, 2017.
- [39] [https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html;jsessionid=c331b3b662f8c45102cf1f20e53c#bu80qkw-3\\_head](https://www.mathworks.com/help/deeplearning/ref/trainingoptions.html;jsessionid=c331b3b662f8c45102cf1f20e53c#bu80qkw-3_head) (Erişim tarihi: Mayıs 2022).
- [40] L. Geng, W. Xu, F. Zhang, Z. Xiao, Y. Liu, "Dried jujube classification based on a double branch deep fusion convolution neural network," *Food Science and Technology Research*, vol. 24, no. 6, pp.1007-1015, 2018.

## TEZ ÇALIŞMASINDAN ÜRETİLEN ESERLER

Bu tez çalışmasından 1 (bir) adet ulusal tebliğ (bildiri) ve 1 (bir) adet ulusal makale yayınlanmış olup diğer çalışmalar değerlendirme aşamasındadır. Yayımlanan bu çalışmalar aşağıda listelenmiştir.

Adige, S., Kurban R., Durmuş A., Karaköse E., “Görüntü İşleme Tekniklerinden Faydalanarak Elma Çeşitlerinin Türlerine Göre Sınıflandırılması”, **5th International Symposium on Innovative Approaches in Smart Technologies / 28-29 May 2022, Turkey. (online)**

Adige, S., Kurban, R., Durmuş, A. ve Karaköse, E., "Görüntü İşleme Tekniklerinden Faydalanarak Elma Çeşitlerinin Türlerine Göre Sınıflandırılması", **Avrupa Bilim ve Teknoloji Dergisi**, sayı. 37, ss. 131-138, Haz. 2022. (doi:10.31590/ejosat.1136913)

## ÖZGEÇMİŞ

### 1. İLETİŞİM BİLGİLERİ

**Adı Soyadı:** Sevim ADİGE  
**Uyruğu:** Türkiye (T.C)

### 2. ÖĞRENİM DURUMU

| Derece        | Kurum  | Mezuniyet Tarihi |
|---------------|--|------------------|
| Yüksek Lisans | Kayseri Üniversitesi, Elektrik Elektronik Mühendisliği ABD | -                |
| Lisans        | Cumhuriyet Üniversitesi, Elektrik Elektronik Mühendisliği  | 2018             |
| Lise          | Yahyagazi Lisesi, Kayseri                                  | 2012             |

### 3. YABANCI DİL

İngilizce

### 4. YAYINLAR

4.1. Adige, S., Kurban, R., Durmuş, A. ve Karaköse, E., “Classification of Apple Images by using Support Vector Machines and Deep Residual Networks” *Expert Systems with Applications. (Değerlendirilme aşamasındadır.)*

4.2. Adige, S., Kurban, R., Durmuş, A. ve Karaköse, E., “Görüntü İşleme Tekniklerinden Faydalanarak Elma Çeşitlerinin Türlerine Göre Sınıflandırılması”, *Avrupa Bilim ve Teknoloji Dergisi, sayı. 37, ss. 131-138, Haz. 2022, (doi:10.31590/ejosat.1136913)*

4.3. Adige, S., Kurban, R., Durmuş, A. ve Karaköse, E., “Görüntü İşleme Tekniklerinden Faydalanarak Elma Çeşitlerinin Türlerine Göre Sınıflandırılması”, *5th International Symposium on Innovative Approaches in Smart Technologies / 28-29 May 2022, Turkey (online)*

### 5. PROJELER

5.1. Yahyalı Bölgesine Ait Elma Türlerinin Görüntü İşleme Yöntemleriyle Sınıflandırılması. *Kayseri Üniversitesi Bilimsel Araştırma Projeleri Birimi, FYL-2022-1059. 2022.*