

T.C.  
KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME TEKNİKLERİ  
KULLANILARAK ELMA VE AYVADA ÇEŞİTLİ HASTALIKLARIN TESPİT  
EDİLMESİ

Aysun YILMAZ KIZILBOĞA

ŞUBAT 2021

**Bilgisayar Mühendisliği Anabilim Dalı'nda** Aysun YILMAZ KIZILBOĞA tarafından hazırlanan YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK ELMA VE AYVADA ÇEŞİTLİ HASTALIKLARIN TESPİT EDİLMESİ adlı Yüksek Lisans Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Doç. Dr. Atilla ERGÜZEN

Anabilim Dalı Başkanı

Bu tezi okuduğumu ve tezin **Yüksek Lisans Tezi** olarak bütün gereklilikleri yerine getirdiğini onaylarım.

Doç. Dr. Atilla ERGÜZEN

Danışman

Jüri Üyeleri

Başkan : Dr. Öğr. Üyesi Abdül Kadir GÖRÜR \_\_\_\_\_

Üye (Danışman) : Doç. Dr. Atilla ERGÜZEN \_\_\_\_\_

Üye :Dr. Öğr. Üyesi Erdal ERDAL \_\_\_\_\_

08/02/2021

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onaylamıştır.

Prof. Dr. Recep ÇALIN

Fen Bilimleri Enstitüsü Müdürü

## ÖZET

### YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK ELMA VE AYVADA ÇEŞİTLİ HASTALIKLARIN TESPİT EDİLMESİ

YILMAZ KIZILBOĞA, Aysun

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Doç. Dr. Atilla ERGÜZEN

Şubat 2021, 91 Sayfa

Bu çalışma kapsamında, üç farklı kişiden alınan 7 sınıf için 150 adet RGB görüntü kullanılarak bir veri seti elde edilmiştir. Veri kümelerine veri artırma yöntemleri uygulanmış, görüntü sayısı her bir sınıf için 900 adet olacak şekilde toplam 6300'den, 12600'e yükseltilmiştir. Hastalıkların sınıflandırılması için hem problemin çözümüne yönelik 10 katmanlı bir evrişimli derin ağ modeli oluşturulmuş hem de derin öğrenme yöntemlerinden biri olan aktarımlı öğrenme yöntemi kullanılarak hazır modellerden VGG16, Inception ve ResNet derin ağ mimarileri kullanılmıştır. Ayrıca derin öğrenmenin öznelik çıkarımı tekniğinden faydalanılarak elde edilen öznelik vektörü ile geleneksel makine öğrenme yöntemlerinden olan Destek Vektör Makineleri (Support Vector Machines, SVM) ve K- En Yakın Komşu(K- Nearest Neighbor, K-NN) yöntemleri ile sınıflandırılmıştır. Elde edilen sonuçlar zaman ve başarı oranlarına göre kıyaslanarak, en başarılı yöntem belirlenmiştir.

Bu çalışmada, görsel hasar bırakan elma ve ayva yüzeyinde iz bırakan hastalıkların, yapılan analizler sonucunda başarılı bulunan derin öğrenme yöntemlerinden biri olan aktarımlı öğrenme kullanılarak gerçek zamanlı yazılı dile çevrilmesi sağlanmış böylece hastalığın tespiti sağlanmıştır. Ayrıca, tasarlanan bu gerçek zamanlı sistem ile elma ve ayva hastalıklarına ait görüntüleri tanıma ve tahminini bilgisayar ekranına yazdırmasındaki başarısı değerlendirilmiştir.

**Anahtar Kelimeler:** Görüntü Örüntüsü Tanıma, Derin Öğrenme, Aktarımlı Öğrenme, Meyve Hastalıklarını Tanıma, Evrişimli Sinir Ağları



## **ABSTRACT**

### **DETECTION OF VARIOUS DISEASES IN APPLE AND QUINCE BY USING ARTIFICIAL NEURAL NETWORKS AND DEEP LEARNING TECHNIQUES**

**YILMAZ KIZILBOĞA, Aysun**

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, Master Thesis

Supervisor: Assoc. Prof. Dr. Atilla ERGÜZEN

February 2021, 91 Pages

Within the scope of this study, a data set was obtained using 150 RGB images for 7 classes taken from three different people. Data enhancement methods were applied to data sets, and the number of images was increased from 6300 to 12600, from 900 for each class. For the classification of the diseases, a 10-layer convolutional deep network model was created for the solution of the problem, and by using the transfer learning method, one of the deep learning methods, VGG16, Inception and ResNet deep network architectures were used. In addition, the feature vector obtained by using the feature extraction technique of deep learning and the traditional machine learning methods, Support Vector Machines (SVM) and K-Nearest Neighbor (K-NN) methods were classified. The most successful method was determined by comparing the obtained results according to time and performance rates. In this study, diseases that leave marks on the surface of apple and quince that cause visual damage were translated into real-time written language using transfer learning, which is one of the deep learning methods that was found successful as a result of the analyzes, thus the disease was detected. In addition, with this designed real-time system, its success in recognizing and predicting the signs of apple and quince diseases on the computer screen was evaluated.

**Keywords:** Image Pattern Recognition, Deep Learning, Transferred Learning, Fruit Disease Recognition, Convolutional Neural Networks



## TEŐEKKÖR

Tezimin hazırlanmasında bana destek olan, lisans ve yüksek lisans eğitimin boyunca bilgi ve tecrübeleri ile beni yönlendiren çok değerli danışman hocam Sayın Doç. Dr. Atilla ERGÜZEN'e teşekkürlerimi sunmayı kendime bir borç bilirim.

Hayatımın her aşamasında benden maddi ve manevi olarak desteklerini esirgemeyen babam İsmail YILMAZ'a, annem Münevver YILMAZ'a, abim Mustafa Onur YILMAZ'a, her an yanımda olup beni destekleyen eşim İlkay KIZILBOĞA ve oğlum Eymen Ayaz KIZILBOĞA'ya sevgilerimi sunar teşekkür ederim.

# İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
ÖZET .....	i
ABSTRACT.....	iii
TEŞEKKÜR.....	v
İÇİNDEKİLER DİZİNİ .....	vi
TABLolar DİZİNİ .....	ix
ŞEKİLLER DİZİNİ.....	x
SİMGE VE KISALTMALAR DİZİNİ .....	xii
1.GİRİŞ .....	1
1.1. Konunun Tanımı.....	1
1.2. Konunun Amacı.....	2
1.3. Konunun Önemi .....	3
1.4. Kaynak Araştırması .....	3
1.5. Yöntem ve Materyal .....	7
1.6. Görüntü İşleme Teknikleri Tanımı .....	9
2.ELMA VE AYVADA GÖRÜLEN MEYVE HASTALIKLARI .....	12
2.1. Elmada Görülen Hastalıklar .....	12
2.2. Ayvada Görülen Hastalıklar .....	16
3.MAKİNE ÖĞRENMESİ .....	20
3.1. Makine Öğrenmesinde Büyük Verinin Önemi.....	20
3.2. Makine Öğrenmesine Yaklaşımlar .....	21
3.1.1. Danışmanlı öğrenme .....	22
3.1.2. Danışmansız öğrenme.....	22
3.1.3. Yarı danışmanlı öğrenme.....	22
3.3. Yapay Zeka ve Makine Öğrenmesinin Tarihçesi .....	22



3.4. Yapay Sinir Ağları.....	23
4. DERİN ÖĞRENME ve EVRİŞİMLİ SİNİR AĞLARI (ESA).....	30
4.1. Derin Öğrenme ve Tarihçesi .....	30
4.1.1. Derin öğrenmenin gelişimi .....	31
4.2. Derin Öğrenmenin Güçlü Yönleri.....	31
4.3. Derin Öğrenmede Etkili Olan Kavramlar.....	33
4.3.1. Ağırlık.....	33
4.3.2. Sapma .....	34
4.3.3. Aktivasyon fonksiyonu.....	34
4.3.4. Öğrenme katsayısı ve eniyileme algoritması.....	36
4.3.5. Kayıp fonksiyonu.....	36
4.3.6. Geri yayılım .....	36
4.3.7. Yığın, epok ve tekrar sayısı .....	36
4.4. Derin Öğrenme Mimarileri.....	37
4.5. Evrişimsel Sinir Ağlar (ESA).....	38
4.6. 10 Katmanlı ESA Yapısı .....	40
4.7. Aktarımlı Öğrenme.....	41
4.7.1. VGG16.....	41
4.7.2. Inception .....	43
4.7.3. ResNet50.....	43
5. ELMA VE AYVA HASTALIKLARI TANILAMASI VERİ SETİ OLUŞTURULMASI .....	45
5.1. Kullanılan Yöntem ve Materyal .....	45
5.2. Veri Setinin Oluşturulması .....	46
5.3. Veri Setini Çeşitlendirme - 1 .....	48
5.4. Veri Setini Çeşitlendirme - 2.....	49
5.5. Veri Setinin Genel Özellikleri .....	50

6. ARAŞTIRMAYA İLİŞKİN BULGULAR .....	52
6.1. Araştırmaya İlişkin Bulgular .....	52
6.1.1. 10 Katmanlı ESA yapısını kullanarak başarımların değerlendirilmesi.....	52
6.1.2. Öğrenme aktarımı ile VGG16 kullanarak başarımların değerlendirilmesi.....	54
6.1.3. Öğrenme aktarımı ile Inceptionv3 kullanarak başarımların değerlendirilmesi ....	55
6.1.4. Öğrenme aktarımı ile ResNet50 kullanarak başarımların değerlendirilmesi.....	56
6.1.5. Öğrenme aktarımı kullanılarak öznelik çıkarımı ile birlikte destek vektör makineleri ve k- en yakın komşu sınıflandırması.....	58
6.1.6. Öznelik çıkarımı olmadan DVM ve K- En yakın komşu ile sınıflandırma .....	59
6.2. Tartışma.....	60
7.TANIMLANAN ELMA VE AYVA HASTALIKLARININ GERÇEK ZAMANLI TEST EDİLMESİ .....	63
7.1. Çalışma Prensipleri.....	63
7.2. Gerçek zamanlı programın özellikleri .....	65
7.3. Sistemin Farklı Kullanıcılar Üzerinde Test Edilmesi.....	67
8. SONUÇ VE ÖNERİLER .....	69
8.1. Sonuç .....	69
8.2. Öneriler.....	70
KAYNAKLAR .....	71

## TABLULAR DİZİNİ

	<b><u>Sayfa</u></b>
Tablo 5.1. Kullanılan WebCam' in genel özelliklerinin gösterilmesi .....	46
Tablo 5.2. Veri çeşitlendirme işlemleri.....	50
Tablo 5.3. Veri setinin genel özellikleri.....	50
Tablo 5.4. İki farklı veri setinin görüntü özellikleri.....	51
Tablo 6.1. 10 Katmanlı ESA (CNN) için farklı Epok sayılarında elde edilen sonuçlar .....	52
Tablo 6.2. VGG16' nın farklı epok sayılarında elde edilen sonuçları .....	54
Tablo 6.3. InceptionV3' ün farklı epok sayılarında elde edilen sonuçları .....	55
Tablo 6.4. ResNet50' ün farklı epok sayılarında elde edilen sonuçları .....	57
Tablo 6.5. Öznitelik çıkarımı yapılarak elde edilen DVM ve K en yakın komşu sonuçları.....	59
Tablo 6.6. DVM ve K en yakın komşu sınıflandırma sonuçları .....	59
Tablo 6.7. Modellerin zaman ve başarımlar oranları karşılaştıran tablo.....	61
Tablo 7.1. Sistemin farklı ortamlar ve hastalıklar üzerinde test sonuçlarını gösterir	67

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 1.1 Analog Görüntünün Dijital Görüntüye Çevrilmesi .....	10
Şekil 1.2 Veri setinde yer alan görüntüler.....	11
Şekil 3.1 Geleneksel makine öğrenmesini gösterimi (MathWorks introduces Release 2017).....	20
Şekil 3.2 Biyolojik Beyin Nöronu Yapısı .....	24
Şekil 3.3 Çok Katmanlı Yapay Sinir Ağı Nöronu Çalışma Fonksiyonu (F. Rosenblatt'ın 1958 Yılında Tanıttığı Model)( Hornik, Stinchcombe, White, 1989:362).....	25
Şekil 3.4 İleri Beslemeli Yapay Sinir Ağı Katmanları.....	26
Şekil 4.1 Derin sinir ağlarını genel yapısı (Mira,1995:11) .....	30
Şekil 4.2 Derin Öğrenme ve Geleneksel Makine Öğrenmesi Yaklaşımının Karşılaştırılması .....	32
Şekil 4.3 Katmanlar, kayıp fonksiyonu ve eniyileme algoritması arasındaki ilişki... 33	
Şekil 4.4 Evrişimli ağlarda bilgisayar mimarisi katmanları.....	39
Şekil 4.5 4x4 boyutunda bir görselde 2x2 boyutunda bir filtre ile görüntü işleme biçimi .....	39
Şekil 4.6 VGG16 mimari yapısı ve katmanları.....	42
Şekil 4.7 Inception mimarisine sahip iç içe ağların gösterimi .....	43
Şekil 4.8 Bir ResNet mimarisi için daha derin bir artık fonksiyon (56 × 56 özellik haritalarında) yapı taşı ve ResNet-50 için bir “darboğaz” yapı taşının gösterimi .....	44
Şekil 5.1 Veri kümesinde yer alan Elma Hastalıklarına ait 5 sınıf için renkli görüntüler.....	47
Şekil 5.2 Veri kümesinde yer alan Ayva Hastalıklarına ait 2 sınıf için binary görüntüler.....	47
Şekil 5.3 Elma alternaryası hastalığının gerçek ve gürültü eklenmiş görüntüleri.....	48
Şekil 5.4 Elma küllenmesi hastalığının gerçek ve karışıklık eklenmiş görüntüleri .....	48
Şekil 5.5 Elma kurtçuğu gelişimine elverişli noktaları gösterir larva izlerinin gerçek ve bulanıklık eklenmiş görüntüleri .....	49
Şekil 6.1 10 katmanlı ESA'nın başarıım grafiği .....	53

Şekil 6.2 10 katmanlı ESA'nın kayıp grafiği.....	53
Şekil 6.3 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen VGG16 mimarisinin başarıım grafiği.....	54
Şekil 6.4 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen VGG16 mimarisinin kayıp grafiği.....	55
Şekil 6.5 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen InceptionV3 mimarisinin başarıım grafiği.....	56
Şekil 6.6 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen InceptionV3 mimarisinin kayıp grafiği .....	56
Şekil 6.7 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen ResNet50 mimarisinin başarıım grafiği.....	57
Şekil 6.8 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen ResNet50 mimarisinin kayıp grafiği.....	57
Şekil 6.9 InceptionV3 karışıklık matrisi .....	62
Şekil 6.10 ResNet50 karışıklık matrisi.....	62
Şekil 7.1 Kahverengi ayva çürüğünün bilgisayar ekran görüntüsü.....	63
Şekil 7.2 Mavi ayva küfünün bilgisayar ekran görüntüsü.....	64
Şekil 7.3 Elma kurt larvası olasılığı bilgisayar tahminini gösteren ekran görüntüsü. 65	
Şekil 7.4 Kara elma lekesi hastalığının görüntüden yazıya çevrilmesini gösteren bilgisayar ekran görüntüsü.....	66
Şekil 7.5 Elmanın üstten görünümü ile eşleşen tüm kelimelerin yazımını gösteren bilgisayar ekran görüntüsü.....	66
Şekil 7.6 Çoklu elma görünümünde hastalık tanısının metin alanına yazdırılan ekran görüntüsü .....	68
Şekil 7.7 Taşduvar desenli arka planda elma hastalıklarının metin alanına yazılan ekran görüntü .....	68

## SİMGE VE KISALTMALAR DİZİNİ

$^{\circ}\text{C}$	Santigrat Derece
$^{\circ}\text{F}$	Fahrenhayt Derece
2B	İki Boyutlu
3B	Üç Boyutlu
CNN	Convolutional Neural Networks (Evrşimli Sinir Ağları)
CRT	Katot Işın Tüpü
DAE	Denosing Autoencoders (Derin Oto Kodlayıcılar)
DCT	Ayrık Kosinüs Dönüşümü
DVM	Destek Vektör Makinesi
EMG	Elektromiyografi
ESA	Evrşimli Sinir Ağı
ESAK	Evrşimli Katman
K –NN	K En Yakın Komşu Sınıflandırma Algoritması
LSTM	Long / Short Term Memory ( Uzun Kısa Dönemli Bellek)
MLP	Çok Katmanlı Algılayıcı
RBM	Restricted Boltzmann Machines (Kısıtlanmış Boltzmann Makineleri)
RDF	Rastgele Karar Ormanı
RGB	Kırmızı, Yeşil, Mavi ana renklerden oluşan renk uzayı
RNN	Recurrent Neural Networks (Tekrarlayan Sinir Ağı)
WEB	İnternet
XOR sorunu	Eşdeğerliğin Olumsuzlanması
YSA	Yapay Sinir Ağı

# 1. GİRİŞ

## 1.1. Konunun Tanımı

Bilgisayarlı görme sistemleri, gıda endüstrisinde kalite güvencesi amacıyla giderek daha fazla kullanılmaktadır. Esasen, bu tür sistemler çiğ ve hazırlanmış gıdaların çeşitli kalite niteliklerinin değerlendirilmesi için insan denetçilerinin yerini almaktadır. Geçtiğimiz birkaç yıl içinde, hem bilgisayar donanımı hem de yazılım alanında gözden kaçmayacak ölçüde yaşanan büyüme, bilgisayarla görme teknolojisinde birçok önemli ilerlemeye yol açmış durumdadır. Bilgisayarla görme uygulamaları, rutin incelemeden karmaşık görsel kılavuzlu robotik kontrollere kadar çeşitlilik gösteren bir alana sahiptir. Bilgisayarla görme teknolojisi, nispeten düşük maliyetle yüksek düzeyde doğruluktan ödün vermeden, tesis verimine izin verir. Günümüzde bilgisayarlı görme sistemleri, çevrimiçi, gerçek zamanlı kalite değerlendirmesi ve kalite kontrolü için gıda işleme tesislerinin ayrılmaz bir parçası olarak geliştirilmektedir. Görüntü işleme tekniklerine dayanarak gıda güvenliği kontrolünün sağlanmasına ilişkin kalite değerlendirme tekniklerinin iyileşmesi halinde nakliye masraflarının azaltılması hatta ağaç hastalıkları için bir ayırım yapıldığında hastalıklı ağaçların tedavisi sağlanabilecektir. Böylelikle bitkisel gıda üreticilerinin de zarara uğramasının önüne geçilebilecektir. Tüm bu işlemler daha güvenli gıdaya ulaşmayı kolaylaştıracak ve maliyetleri gıda zincirindeki kayıp masraflarını ve dolayısıyla nihai tüketiciye; daha kaliteli ve daha ekonomik olarak ulaşmasını sağlayacaktır. Görüntülerle bitki hastalıklarının tespitinde renk, gözle görünebilir bozunmalar gıda endüstrilerinde önemli bir kalite özelliğidir. Ürünün rengi, büyüme, olgunlaşma, hasat sonrası işleme ve işleme sırasında meydana gelen kimyasal, biyokimyasal, mikrobiyal ve fiziksel değişikliklerin görüntüyü etkilediği günümüzde bilinmektedir. Renk özelliklerini ölçmek için araçsal (objektif) ve görsel (sübjektif) ölçümlere odaklanarak ürünlerin olgunluğunu ve kalitesini karakterize etmek için kullanılan birincil ve türetilmiş objektif renk indeksleri yelpazesi ise görüntünün tanınmasını sağlayan bir fonksiyondur.

Gıda sektörünün önemli konularından biri olan meyveler de bu bitkisel üretim döngüsünün büyük bir parçasını oluşturmaktadır. Meyvelerdeki bozunmalar

nihai tüketim noktasında tüketicinin tercih etmediği ve karşılaştığında ise, ürünü nihai tüketiciye sunan esnafın, tüketici gözünde itibarının yok olmasına neden olan etkenlerden biri olarak karşımıza çıkmaktadır. Bu bozunmalar, bitkisel kökenli gıda ürünlerinde olduğu gibi, bir hastalığa işaret etmektedirler. Nihai tüketicinin tercih etmediği hasta ürünler, meyvenin üreticileri için de büyük bir ekonomik kaybı ifade etmektedir. Üretici, gerekli mücadele çalışmaları yapamadığında ürün kaybının artması nedeniyle, ekonomik açıdan zarar görmektedir. Tarımsal üretimde, ekonomik yönden oldukça büyük rakamlara ulaşan üreticisinden nakliyecisine, gıda toptancısından, perakende satıcısına dek ekonomik etkinliği olan gıda sektörünün kayıpların önlenmesi için tarım ürünlerindeki hastalıkların tespitinin önemini yansıtmaktadır. Tarım ürünlerin şekilsel bozukları çoğu kez ürünün bozuk olduğu noktasında nihai tüketicilerin temkinli yaklaşımına neden olmaktadır. Meyve hastalıkları da, diğer bitkisel ürünlerin çoğunluğunda olduğu üzere şekilsel bozuklukları beraberinde getirmektedir. Bu noktada, insan vücudunda yer alan organlarda meydana gelen şekil değişiklikleri, tümörlü hücre tespitleri gibi çeşitli hastalıkların tespitinde de kullanılan uzman sistemlerin, görüntü işleme teknikleriyle kullanılması, hastalığın başından itibaren yani henüz üretim aşamasında engellenebileceğinin mümkün olabileceğini düşündürmektedir. Akademik çalışmalar arttıkça, Tıp alanında bu gün bazı hastalık tespitlerini eksiksiz yapan uzman sistemler gibi çok iyi bir tanıma kabiliyetine sahip ve hatasız ayırım yaparak hastalığı tanıyan sistemlerin oluşturulması mümkündür. Bu bağlamda, yapay sinir ağları kullanılarak, spesifik iki meyve üzerinde çalışabilecek bir model oluşturularak, bu meyvelerdeki her hastalığı tespit edebilmek, ilerleyen zaman diliminde ise, tüm tarım ürünlerinde hastalıkların tespiti noktasında, geniş bir veri tabanının oluşmasına ve üreticilerin maliyetine etki etmeden, ürünlerindeki hastalıkların tespit edilmesine katkı sağlayacağı düşünülmüştür.

## **1.2. Konunun Amacı**

Bu çalışmada seçilen meyveler olan elma ve ayva üzerinde görülen bozunmalar literatüre dayanılarak hastalığın tespiti ve etiketlenmesini sağlayarak, yapay sinir ağları, görüntü işleme teknikleri ve derin öğrenme tekniklerinin kullanılması ile tanınmasını sağlamak üzere sonraki incelemeler için bir yol göstergesi sunmak amaç edinilmiştir.



### **1.3. Konunun Önemi**

Meyve hastalıklarının tanınması ve tespiti ile bitkisel kökenli gıda ürünlerinin erken dönemli teşhisini sağlayabilmekle gıda zincirinde meydana gelebilecek ekonomik kayıpların önlenmesi ve daha kaliteli ürünlerin nihai kullanıcı olan tüketiciye ulaşmasını sağlayabilmek önemli bir araştırma konusudur. Ancak çalışmanın uzun süreye ihtiyaç duyması her ağacın incelenmesi, meyvelerin üretimi sırasında araştırma sahasında geçirilecek süre ve maliyetli bir araştırma olması, konu hakkında yapılan çalışmaların parçalanmasını mantıklı kılmaktadır. Örneğin bu çalışma kapsamında, seçilen meyveler, üretim aşamasından ziyade dağıtımdan nihai üreticiye ulaşmasında toptan ve perakende satışların gerçekleştirildiği meyve hallerinden alınan görüntülere odaklanılarak bu iki meyvenin hastalıklarının literatüre dayandırılarak tespit edilmesiyle bahsi geçen geniş araştırma sahasına katkı sunması açısından önemli görülmektedir. Çalışmadaki saha araştırmasından elde edilen görüntülerin kullanılması ve sınıflandırmasıyla hastalığın tanınması ülkemizde yapılan kısıtlı sayıdaki çalışmaya literatür yönüyle de katkı sunması açısından önemli görülmektedir.

### **1.4. Kaynak Araştırması**

Yıldız, Özdemir & Uluişik, (2019). Çalışmalarında, tarımsal ürünlerin kalite değerlendirmesi için çeşitli yıkıcı ve tahribatsız yöntemlerin kullanılmasını savunmuşlar ultrasonik test ve otomatik makine görme teknikleriyle hacim tahmini ile eksiksiz bir tahribatsız kalite değerlendirme sistemi geliştirmeyi amaçlamışlardır. Araştırmacılar çalışmalarında, ultrasonik sistem, programlanabilir bir çift kutuplu uzak pulser ünitesinden oluşan bir verici ve bir alıcı kullanarak bir osiloskop ve bir bilgisayar olarak ultrasonik sinyal alımları için bir çift piezoelektrik çiftleri ile görüntü işleme tekniklerine dayalı bir makine görme sistemi kullanmışlardır. Bir meyvenin farklı açılardan beş farklı görüntüsü yüksek çözünürlüklü dijital kameralarla çekilmiş ve meyvenin hacmi, yakalanan meyve görüntülerinin yatay ve dikey mesafesinden sonra hesaplanmıştır. Bilgisayarlı görme sistemi tarafından hesaplanan hacim değerleri teorik değerlerle doğrulamasını sağlamışlardır. Tahribatsız ultrasonik tahmin ve görüntü işleme yöntemleriyle hacim tahmini ucuz,

hızlı ve pratik olmasına rağmen, deneylerimizde elde edilen sonuçlar, bu yöntemlerin literatürde iddia edildiği kadar güvenilir olmadığı sonucuna varmışlardır.

Zhang vd.(2014). Araştırmacılar çalışmalarında, meyve ve sebzeleri birlikte incelemişlerdir. Araştırmacılar meyve ve sebzelerin dış kalitesindeki renk, doku, boyut, şekil ve görsel kusurları dikkate alınarak değerlendirilmişler ve bilgisayarla görme sistemi, hiperspektral bilgisayar görme sistemi ve multispektral bilgisayarla görme sistemi dahil olmak üzere bilgisayarlı görme sistemlerini, meyve ve sebzelerin dış kalite denetiminde bilgisayarlı görme sistemlerinin karşılaştırmalı tanıtımlarını sağlamışlardır. Araştırmacılar çalışmaları sonucunda ana bileşenler, temel teoriler ve bunlara karşılık gelen işlemleri analitik yöntemlerle rapor etmişlerdir.

Brosnan,& Sun, (2004). Araştırmacılar çalışmalarında, yüksek kalite ve güvenlik standartlarına sahip gıda ürünlerine yönelik beklentilerin artması ile gıda ürünlerinde bu özelliklerin doğru, hızlı ve objektif kalite tespiti ihtiyacı büyümeye devam ettiğini belirtmişler, bilgisayarla görme tekniklerini kullanarak tahribatsız ve uygun maliyetli bir teknik için bir alternatif sağladığı vurgulamışlardır. Araştırmacılar, bir bilgisayarla görme sisteminin önemli unsurlarını sunmakta ve gıda endüstrisindeki en son gelişmelerin gözden geçirilmesiyle birlikte görüntü işleme tekniğinin önemli yönlerini vurgulamışlardır.

Günasekaran, (1996). Domates üretimi, domates mahsulü çeşitli mikroorganizmaların saldırılarına maruz kaldığı için göz korkutucu bir iştir. Saldırıların semptomları genellikle renk, bakteri lekeleri, özel tür benekler ve domatesin dış yüzeyinde farklı renklere sahip eş merkezli halkalı batık bölgelerde değişir. Bu makale, domates kalite denetimi için vizyon algılama tabanlı bir sistemi ele almaktadır. Domates meyvesinin tespiti ve hastalık tespiti için yeni bir yaklaşım geliştirilmiştir. Geliştirilen sistem, ARM-9 işlemci ile arayüzlü 12.0 megapiksel USB tabanlı kamera modülünden oluşmaktadır. Zigbee modülü, daha ileri işlemler için ana sistemden PC tabanlı sunucuya kablosuz iletim için geliştirilmiş sistemle arayüzlenmiştir. Algoritma geliştirme üç ana adımdan oluşur; gürültü reddi, segmentasyon ve ölçekleme gibi ön işleme adımları, sınıflandırma ve tanıma ve otomatik hastalık tespiti ve sınıflandırması sağladığını belirtmiştir. Yerel pazardan domates numuneleri toplanmış ve veri tabanı hazırlama ve çeşitli işleme aşamaları için veri toplama gerçekleştirilmiştir. Geliştirilen sistem domates örneklerinde çeşitli

hastalıkları tespit edebildiği gibi sınıflandırabilmektedir. Veri analizi için çeşitli örüntü tanıma ve yazılımsal hesaplama tekniklerinin yanı sıra domatesin raf ömrü, hastalık tespiti ve sınıflandırmasına dayalı kalite indeksi, tazelik tespiti, olgunluk indeksi tespiti ve tespit edilen hastalıklar için farklı öneriler gibi farklı parametrelerin öngörülmesi için uygulanmıştır. Sonuçlar, ticari Alpha Mos 3000 sistemi kullanılarak aroma algılama tekniği ile doğrulanmıştır. Doğruluk, yaklaşık% 92 olan çıkarılan sonuçlardan hesaplanmıştır.

Jolly,&Raman,(2017). Araştırmacılar çalışmalarında, bilgisayarla görüş kullanarak elmalardaki hastalıkların tespiti ve tanımlanması için farklı yaklaşımları açıklamışlardır. Araştırmacıların önerdikleri algoritmalar, görüntü özelliklerini kullanarak elmanın yüzey görünümünü kusurlar için analiz eder. ROI segmentasyonu için, K-ortalama kümeleme, yoğunluk değerlerine dayalı olarak görüntü pikselleri üzerinde gerçekleştirilir. Öznitelik vektörünün oluşturulması için Gabor Dalgacıklarının farklı öznitelik tanımlayıcılara sahip kombinasyonları araştırılmıştır. Gabor özellikleri üzerinden performanslarını gözlemlemek için Haralick özellikleri, Yerel İkili Modeller ve çekirdek PCA arasında karşılaştırmalı çalışma yapılmıştır. Sınıflandırma, Destek Vektör Makineleri ve K-En Yakın Komşular aracılığıyla gerçekleştirilir. Hastalık tespiti görevi için, kaydedilen doğruluk Gabor + LBP yaklaşımı için% 96,9'dan fazla ve% 89,8 ile 96 aralığındaydı. Gabor + Haralick yaklaşımı için% 25. Gabor + çekirdek PCA,% 90 ile en düşük doğruluğu kaydetti. Hastalık tanımlama için Gabor + LBP kombinasyonu, diğer kombinasyonlardan daha iyi performans gösterdi ve% 85.93 ile% 95.31 arasında değişen en yüksek doğruluğu kaydetmişlerdir.

Yang, (1994). Çalışmada, elma görüntülerinde yüzey özelliklerinin tespiti için yeni bir teknik sunar. Bu görüntüler için topografik temsil kavramının tanıtılmasıyla, yama benzeri özelliklerin tespiti, elma gri seviyeli manzaralarda havza tespitinden biri olarak ele alınır. Su toplama havzalarını, yani özellikleri tespit etmek için bir taşma algoritması benimsenir ve değiştirilir. Algoritmanın uygulanması ayrıntılı olarak anlatılmıştır. Su baskını sürecinden sonra havzalar, alan ve çevre gibi geometrik parametrelerin kolaylıkla çıkarılabildiği göller haline gelir. Golden Delicious ve Granny Smith elma türleri üzerinde önerilen tekniğin test sonuçları sunulmuştur. Yeni yaklaşımın avantajlarını göstermek için mevcut arka plan çıkarma

yöntemiyle bir karşılaştırma yapılmıştır. Daha genel bir şekilde, önerilen yöntem, nispeten tek tip ten rengine sahip olan diğer ürün türleri için özellik tespitine uygulanabilir olduğu sonucuna varılmıştır.

Wen, & Tao, (1997). Çalışmalarında taze pazar için OECD standartları, meyve kalitesinin boyut, renk ve yüzey kusurlarına göre derecelendirilerek tahmin edilmesini gerekli kıldığını vurgulamışlardır. Boyut ve renk derecelendirme artık otomatikleştirilirken, hasarlı meyvelerin sınıflandırılması hala manuel olarak yapılmaktadır. Golden Delicious elmalarındaki yüzey kusurlarının otomatik tespiti için bir sistem geliştirilmiş ve otomatik renk derecelendirme için kullanılan bir konveyör sistemi üzerinde hat üzerinde test edilmiştir. Meyveler yuvarlanırken, katı halli bir kamera dört fotoğraf çeker ve böylece yüzeyin çoğunu görebilir. İşlenecek veri miktarını azaltmak için bir donanım sistemi geliştirilmiştir. Bu, elmanın meyve boyutuna göre değişken çapta küresel olduğunu varsayan bir modele dayanmaktadır. Sistem, derecelendirme çizgisi başına saniyede beşten fazla meyveyi analiz edebilir. Hat üzerinde yapılan testler, meyvelerin% 69'unun doğru şekilde derecelendirildiğini, ancak% 26'sının doğru derecenin hemen üstünde veya altında sınıflandırıldığını gösterdi. Kullanılan kaba model, yalnızca pazarlanabilir meyvelerin (1. ve 2. sınıflar) pazarlanamayan meyvelerden (3. sınıflar ve atık) ayırt edilmesine ve 3. sınıfın atıktan ayırt edilmesine izin verdi. Dolayısıyla bu sistem, pazarlanamayan meyveleri taze meyve olarak sınıflandırmak için sadece toplama döneminde kullanılabilir. Bununla birlikte, ağırlığı  $\pm 5$  g ( $r = 0,985$ ) standart sapma ile verdiği için, depolamadan önce ön boyutlandırma işlemleri için de kullanılabilirliğini belirtmişlerdir.

Leemans, Magein, & Destain, (1999). Araştırmacılar çalışmalarında, kusurlu ve iyi elmaları ayırt etmek için meyve yüzeylerinin ışık yansımadaki farkı kullanan bir makine vizyonu ayıklama sistemi geliştirmişlerdir. Elma gibi eğimli yüzeye sahip meyvenin küresel yansıtma özelliklerine uyum sağlamak için, meyvede kusurlu segmentleri kaybetmeden orijinal görüntüyü degradersiz bir görüntüye dönüştüren küresel bir dönüştürme algoritmasını tanıtmışlardır. Yüksek kaliteli koyu renkli meyvelerin kusurlu sınıfa sınıflandırılmasını önlemek ve açık renkli meyveler için kusur tespit oranını artırmak için, maksimum yayılım kullanan bir yoğunluk telafisi yöntemi kullanılmıştır. Deneysel sonuçlar, elmalardaki kusurların çevrimiçi

tespiti için maksimum yayılma ve küresel dönüşüme dayanan yöntemin etkinliğini göstermiştir.

Nakano, (1997).Araştırmacılar çalışmalarında, bir sinir ağının yerine bir işçinin gözüyle deneysel derecelendirme duygusu 'koyma olasılığı', elmanın renk derecelendirmesine referansla tartışmışlardır. Eşitsiz ışık yoğunluğunun üstesinden gelmek için bu çalışmada tüm görüntü veri toplama sistemi geliştirilmiştir. Bu sistem bir döner tabla, bir kademe kontrolörü ve bir tek akslı sürücüden oluşur. Bu sistemde, bir elmanın tüm görüntüsü, perspektif projeksiyonlar gibi bilgisayar monitöründe tek bir sahne olarak açılır. İki aşamalı bir sinir ağı modeli kullanılan çalışmada, bir elmanın yüzeyinin herhangi bir kısmındaki bir pikseli 'normal kırmızı', 'yaralı renk kırmızı', 'zayıf renk kırmızı', 'asma' ve 'üst veya alt arka plan rengi' olarak sınıflandırmak için kullanılır. Bu koşullardan sınıflandırılan yargılama oranı% 95'in üzerindedir. Bir elmanın tüm yüzey rengini 'üstün', 'mükemmel', 'iyi', 'zayıf renk' ve 'yaralı' olarak derecelendirebilen başka bir sinir ağı geliştirildi. "Üstün", "zayıf renk" ve "yaralı" için derece değerlendirme oranları çok yüksektir, ancak "mükemmel" ve "iyi" için oranlar çok yüksek olmadığı sonucuna ulaşmışlardır.

Morrow vd. (2019). Araştırma, dijital görüntüler ve yapay zeka tekniklerini kullanan otomatik bir denetim sisteminin geliştirilmesiyle açıklanmaktadır. Elmalar, patatesler ve mantarların boyutu, şekli ve rengini değerlendirmek için prosedürler geliştirilmiştir. Yüzey kusurlarının tespiti için algoritmalar geliştirmeye şu anda vurgu yapılmaktadır. Meyve ve sebzelerin otomatik denetimi için genel bir "kalite" puanının geliştirilmesi için kullanılabilirliğini ve otomatik sonuçlar, geleneksel manuel inceleme yöntemleri kullanılarak elde edilenlerle karşılaştırılır. Algoritmalar ve teknikler birçok farklı meyve ve sebzeye uygulanabilse de, elma, patates ve mantarlar, denetlenen birincil ürünler olarak önermişlerdir.

## **1.5. Yöntem ve Materyal**

Çalışma sırasında seçilecek bir meyve için, birkaç kez saha çalışması yapılacak olup, hastalık habercisi olarak görünen lekelerin farklı hastalık sınıfları literatür taramasıyla ele alınacak olup, daha sonra hastalıklı meyve görüntülerinden bir veri seti oluşturulacaktır. Görüntüler çoğaltılacak ve veri seti böylelikle arttırılmış olacaktır. Seçilen meyve için tespit edilen her hastalık etiketlenerek sınıflandırılacak

ve bir CNN modeli python yazı dili kullanılarak eğitilecek, son olarak ise kontrol için ayrılmış olan veri setindeki görüntüler kameraya gösterildiğinde meyve yüzeyinde görülen farklılıklara göre meyvenin hasta olup olmadığı, hastalıklı ise hangi hastalığı gösterdiği yönünde ekran çıktısının alınması sağlanacaktır.

Bu amaçla, çalışmanın temelinde derin sinir ağları kullanılarak, meyve halinden alınan 2 boyutlu görüntü kümeleri kullanılarak, bir veri sistemi tanımlanmıştır. Veri sisteminde toplam 10.000 görüntüden elde edilmiş veri seti kullanılması planlanmıştır. Veri setindeki görüntülerde farklı teknikler kullanılarak (döndürme, blug,ters aç, ışık değerlerinin farklı kullanımı vs. yöntemlerle ) görüntüler çoğaltılarak hastalığın tanınması sağlanacaktır.

Oluşturulan sistemde görüntü işleme teknikleri kullanılarak makine öğrenmesi yöntemiyle görüntü sınıflandırmasında eğitilmiş bir modelin, Yapay Sinir Ağları (YSA) yöntemi kullanılarak sınıflandırılmadaki iyileşmenin sağlanması hedeflenmiş, sistem eğitimi tamamlandığında, JetBrains PyCharm Community Edition 2019 1.1 ortamında, diğer programlama dillerine nazaran program kodunu en az çaba ile ve hızlıca yazmaya imkân tanınması nedeni ile Python dili kullanılarak Intel ® Core ™ İ7 -8750h CPU @ 2.20 Ghz ve 16,00 GB RAM 'e sahip Nvidia GTX 1050 ti Ekran Kartı ve Microsoft Windows 10 Home x64 bit işletim sistemli bilgisayar tabanlı yazılım geliştirilmiştir. Çalışmada kullanılacak veri seti görüntüleri Samsung Galaxy J7 Pro kamerası ile kaydedilerek PC'ye ara kablo ile aktarılmaktadır.

Elde edilen sonuçlarla sınıflandırmadaki başarı oranının değerlendirilmesi planlanmıştır.

## 1.6. Görüntü İşleme Teknikleri Tanımı

Dijital görüntüler, uydu televizyonu, manyetik rezonans görüntüleme sistemleri, bilgisayarlı tomografi gibi günlük yaşam uygulamalarının yanı sıra coğrafi bilgi sistemleri ve astronomi gibi araştırma ve teknoloji alanlarında önemli bir rol oynamaktadır. Görüntü, üç boyutlu herhangi bir sahnenin ışığın göz ile görülebilen 2B temsilidir. Dijital görüntü temel olarak bir nesnenin sayısal temsilidir.

Dijital görüntü işleme terimi, bir görüntünün bir işlemci vasıtasıyla değiştirilmesini ifade eder. Bir görüntü işleme sisteminin farklı unsurları arasında görüntü elde etme, görüntü depolama, görüntü işleme ve görüntüleme sayılabilir(Krizhevsky vd,2012).

Nasıl ki beynimiz bir nesneye odaklandığında sahnenin tamamını görse de nesneyi sahneden ayırt etmek için etrafını bulanık olarak algılıyorsa, görüntü işleme modeli de buna bağımlı olarak çıkarılır. Görüntü işleme tekniklerinden birisi olan görüntü temizleme ( nesneyi diğer ortamdan ayırt etme) beynimizin bu özelliği kullanılarak tasarlanmaktadır. Görüntüdeki görüntü temizleme kısaca; Çalışma alanımız olan 2-B bir görüntüde sahnenin nesneden ayrılması işlemidir. Sahne görüntünün arka planı olarak tanımlanmaktadır(Bishop,2006).

Resim, görüntülenen alanın parlaklığı veya rengi gibi bazı karakteristiklerin bir ölçüsünü temsil eden iki boyutlu bir fonksiyondur. Resim, üç boyutlu (3B) görünen alanın iki boyutlu (2B) projeksiyon düzlemine yansıtılmasıdır. Resim, Projeksiyon düzlemindeki her noktasal  $(x, y)$  için, ışık yoğunluğunu belirten iki değişkenli  $(x, y)$  fonksiyonu olarak tanımlanmaktadır(Bishop,2006). Bir noktadan alınan ışık yoğunluğu, parlaklık ve renk gibi birkaç değişkenin fonksiyonu olarak da gösterilebilir. Görüntülerde düşünülebilen en basit yoğunluk siyah-beyaz (W/B) görüntüdür. Bu görüntü biçiminde iki renk arasındaki her alan gri alan olarak tanımlanır. İki değişkenli olan bu görüntü biçimi  $g(x, y)$  fonksiyonu olarak gösterilmektedir. Burada  $g(x, y)$  fonksiyonu, uzamsal koordinatta  $(x, y)$  noktasının görüntüdeki parlaklığı veya görüntüdeki gri alanların yoğunluğu şeklinde ifade edilmektedir(Qin, ve Lu,2008).

Elektromanyetik spektrum; Fizik kurallarının tanımladığı güneş radyasyonunun tamamını kapsayan, ışığın dalga boyuna göre dağılımıdır. Dalga boylarının çeşitli

vektörel kırınımları ise görünen alandaki renk yansımalarını bize sunar. Işığın çeşitli dalga boylarında vektörel kırınımları;  $[g_1(x, y), g_2(x, y), \dots, g_n(x, y)]$  ile temsil edilir. Elektromanyetik spektrum bandında siyah ile beyaz renk arasında renk görüntü kümesi yansıtma şiddeti yönünden kırmızı ( R ), yeşil ( G ) ve mavi ( B ) renge karşılık gelen üç ana dalga boyu ile tanımlanır. Bu durumda değişen görüntü fonksiyonu olarak ifade edilmektedir.

Görüntü, analog ve dijital görüntü olarak ikiye ayrılmaktadır;

- Analog Görüntü; Görüntünün noktasını, yoğunluğunu temsil eden bir sürekli değerler aralığı şeklinde tanımlanır. Analog görüntü, uzayda sürekli değişen fiziksel bir büyüklük ile karakterize edilir. Bir katot ışın tüpü (CRT) ekranında üretilen görüntü doğası gereği analogdur.
- Dijital Görüntü (Sayısal Görüntü) ; Görüntünün (resmin), en küçük birimi olan piksellerden oluşur. Pikseller belli bir noktadaki parlaklığın temsilcisidir.


Analog bir görüntünün dijital bir görüntüye dönüşmesi için, iki temel işlemden geçmesi gerekmektedir. Bu işlemler sırası ile örnekleme ve nicemleyici işlemleridir. Kısaca özetleyecek olursak,

Analog Görüntü → Örnekleme → Nicemleyici → Dijital Görüntü

### Şekil 1.1 Analog Görüntünün Dijital Görüntüye Çevrilmesi

Analog bir görüntüyü dijital görüntüye çevirmek, resim üzerinde bilgisayar ile çoğaltma yahut işlem yapma hususunda esneklik ve kolaylık sağlaması açısından önemlidir. Bir görüntünün bir bilgisayar aracılığıyla işlenmesi, genellikle görüntü işleme olarak adlandırılmaktadır.





Şekil 1.2 Veri setinde yer alan görüntüler



## 2. ELMA VE AYVADA GÖRÜLEN MEYVE HASTALIKLARI

### 2.1. Elmada Görülen Hastalıklar

Ağaçtan sofraya elmanın bozulması günümüz teknolojileriyle büyük ölçüde azaltılsa da yeni ve geliştirilmiş hasat hastalıkları savaşları için önerilen ve geçtiğimiz on yılda kullanılan yöntemler meyvelerde farklı hasarların meydana gelmesine yol açmaktadır. Yeni, etkili tarımsal ilaçlama malzemeleri düşük bir kalıntı bıraksa da tarım ilacı püskürtme kalıntısının çıkarılması ihtiyacı tarımsal işleme tekniklerinde yapılacak hasat sonrası işlem süresini uzatmaktadır. Bununla birlikte meyve bahçesi hasadı sonrası depolama sırasında, yaş ve gelişmiş soğutma ekipmanı hızlı bir soğutma sağlanması veya tekdüze sıcaklık ayarlarıyla kürlenme önleyici tedbirler mümkün kılarsa da uygun mevsimlerde yetiştirilip hasat edilen ve işlenen elmalar iyi bahçecilik uygulamalarıyla bir miktar kayıp azaltma sağlanabilse de depolamada veya pazarlama sırasında çürümesi sırasında oluşan kayıpların henüz önüne geçilememiştir(Morrow vd,2019). Aşırı olgunlaşmış elmalarda morarmaların meydana gelmesi ise neredeyse kaçınılmaz bir hastalık olarak karşımıza çıkmaktadır(Jolly ve Raman, 2017). Perakende mağazalarında toplu olarak sergilenen elmaların nakliyesi neredeyse her zaman traktiftir ve genellikle 40 ° F'de soğutlamalı bir sisteme sahip olan konteynırlarda taşınmasıyla nakliye sırasında elmanın hastalanmasının önüne geçilebilmektedir. Ancak bu toplu taşıma 32° F'de muhafaza edilen depolama sıcaklığının sezonunun ikinci yarısında, aşırı olgunluk nedeniyle yüzeyde morarmaların görülmesi yaygınlaşmaktadır. Bu hasatta olgunluk, uzun süreli depolama ve yetersiz soğutmaya bağlı hastalıkların yanı sıra (Elmalar 50 ° C'de 70 ° F'de iki kat, 50 ° C'de 40 ° C'de iki kat ve 40 ° C'de 32 ° C'de iki kat daha hızlı olgunlaşması söz konusudur), başka hastalıklarda görülebilmektedir.

Elma *Alternaria* da bunlardan birisidir ve *Alternaria* çürümesi, tüm üretim bölümlerinden elmalarda meydana gözlenebilen en yaygın hastalıktır. *Alternaria* çürümesi, hasat öncesi ölü veya zayıflamış bitki dokuları üzerinde büyüyen organizmanın ürettiği mantar sporlarından ileri gelmektedir ve neredeyse tüm meyve bahçesindeki meyveleri kirletmektedir. Bu durum elmaları da etkilemekte katı ve sert bir yüzeye sahip olan elmalarda yara parazitinden gelişen çürüme miktarı, yara sayısına ve meyvenin canlılığına bağlı olarak ilerlemektedir. *A. tenuis*'in depolamadaki bozulmamış meyvelerin çanak yapraklarında çürümeye neden

olmadan büyüdüğü ve spor ürettiği literatürde kayıtlı olarak bulunan bir bilgidir(Leemans, Magein, ve Destain, 1999).

Bu sinsi ve üretimin her aşamasını etkileyen sporların görünen semptomları, aşağı yukarı yuvarlak, kahverengiden siyaha kadar varabilen lezyonlardır, genellikle bir cilt kırığı (pl. 8, A) veya diğer zayıflamış dokular etrafında merkezlenmektedir. Kalikte ve gövde etrafındaki çukurda veya hasat sırasında sapın yırtıldığı yarada birkaç enfeksiyon meydana gelir. Soğuk hava deposunda çürüme çok yavaş ilerler. Sert olgun meyvelerde, alternaria çürüklüğü lekeleri genellikle kuru, sert ve sığdır. Daha olgun ve daha yaşlı meyvelerde, lezyonlar büyüdükçe lekelerin yüzeyi genellikle koyu kahverengiden siyaha dönüşür (pl. 8, B). Gelişmiş çürükler süngerimsi ve etkilenen ette genellikle siyah çizgi vardır(Zhang vd, 2015).

Elmalar soğuk hava deposundan çıkarıldığında, kısıtlanan veya tutuklanan çürükler daha büyük çürükler oluşturmak için aktif hale gelebilir. 50 ° F'nin üzerindeki nemli havada koyu küf gelişebilir. Diğer bazı çürükler alternaria çürüklüğü ile karıştırılabilir, ancak bunlar genellikle dikkatli inceleme ile ayırt edilebilir. Çapı 1 inçten daha küçük olan alternaria çürümesi lezyonlarının görsel tespitinde, görünen leke eğer kahverengiyse, yan çürümesinden bahsetmek mümkündür(Yue ve Tian, 2020).

Elma alternaria çürüklüğünü gösteren lezyonlarda hafif kürlenme, güneş yanığı gibi etkenlerle meydana gelmektedir ve sıklıkla baskı altında kolayca oluşan yan çürüme hastalığı ile karıştırılabilmektedir. Yan çürüme hastalığı alternaria hastalığına göre dokusal anlamda meyvenin içine doğru çökecek sulu ve yumuşak bir üst katman lekelenmesidir. Yalnız bu ayırım ne yazık ki gözle ayırt edilecek bir ayırımdan çok dokusal bir ayırım barındırmaktadır. Bu sebeple görüntü işlemede yan çürüklüğü tespiti kolayca ortaya konulacak bir tanıdan uzak durmayı gerekli kılmaktadır. Bu sebeple, bu çalışmada iki hastalık cinsinden elma alternaryası seçilerek elma yan çürüme rahatsızlığına yer verilmeyecek şekilde bir gruplandırma yapılması gerekmektedir(Barge vd.,2017:591).

Elmalarda görülen bir başka hastalık ise kara çürüklüğü veya kara leke hastalığıdır, bu hastalık alternaria çürüklüğünden çok daha sert bir yapıda olmasıyla bilinirken yan çürüme rahatsızlığı gibi görsel ayırımda alternariadan farklı bir

görünümüne sahiptir. Genel elma yüzeyinde siyah kılcal damarlar hastalığa görüntüsel olarak eşlik etmektedir. Değişen açık veya siyaha yakın koyu kahverengi bölgeleri siyah sivilce benzeri (pyrenia) meyve gövdeleri oluşturmaktadır. Kara leke hastalığı piyasada bulunan elmalarda sıklıkla karşılaşılan bir hastalıktır ve lekelenmeler kendilerini yüzeyde gömülü olmayan bir şekilde göstermektedirler. Lentiklerde görülen siyah noktaların artması gibi durumlarda siyah çürüklük genellikle kurumuş bir görünüm sergilemekte ve yüzey parlaklığında kayıp oluşturan bir lekeyi tanımlamaktadır(Du ve Sun, 2004:237).

Elma yüzeyinde görülen bir başka rahatsızlık ise acı çürük olarak karşımıza çıkmaktadır. Acı çürük çürümüş elma daha açık kahverengi rengiyle ve bazen de spor kütlelerinin varlığıyla alternaria çürüklüğünden ayırt edilebilmektedirler. Bu sporlar ilk çıktığında parlak pembe veya krem renginde bir görünüme sahiptirler ve aynı zamanda eşmerkezli halkalar halinde elma yüzeyinde görülebilmektedirler. Elma yüzey görünümünde belirtilen lezyonları sayılan acı çürük, mantar kaynaklı bir rahatsızlıktır. Bu mantar (*Alternaria tenuis*) yaralı veya zayıflamış elmalar olmadığı sürece çürümeye neden olamayan zayıf bir patojendir. Acı çürüklük, depoda uzun süre tutulan elmalardaki çürük, çekirdeklere dek uzanabilen mantar enfeksiyonlarını tanımlamaktadır(Morrow vd., 2019:714).

Acı elma çürüklüğünün kontrolü, enfeksiyona yol açan fizyolojik hastalıkları ve yaralanmaları önlemek için toplama, yıkama ve paketlenme sırasında dikkatli muameleye bağlıdır. Meyvelerin hızlı depolanması ve soğutulması ile önlenebileceği düşünülen rahatsızlıktır. Atmosfer değişimine bağlı sıcaklık değişimlerinin bu tip lezyonlara sebep verdikleri bilinmektedir. Elmaların depodan tüketiciye taşırken 32 ° ila 40 ° F sıcaklıklarda tutmak, bozulmanın önlenmesinde yardımcı olan bir rahatsızlıktır(Zhou vd.,2012:573).

Elma kurdu çürümesi, büyük elma yetiştirme bölümlerinde rastlanan bir başka elma hastalığı olarak karşımıza çıkmaktadır. Elma kurtçukları kötü tarımsal ilaçlamaların ticari bahçelerdeki yıkıcı etkisi olarak oluşmaktadır. Bu haşere en çok yaz ve sonbahar aylarındaki elmalarının ince kabuklu, tatlı ve asit altı çeşitleri en kolay istila edilebilir elma cinslerinden biri olan ve Türkiye pazarında bolca bulunan Golden Delicious, ağaçlarında yaralanmaya sebep olmaktadır(Morrow vd.,2019:713). Elma kurtçuğunun neden olduğu semptomlar, istilanın zamanına ve

şiddetine ve bir dereceye kadar elma türüne de bağlı görülmektedir. İstila erken ve ağırsa, yumurta birikintisi yaraları ve kurtçuklar tarafından elma etinde geniş çaplı bir tünel oluşturmaktadır, bu tünel elmaların ciddi şekilde deforme olmasına neden olur ve çok sayıda derin çöküntü yumrulu bir görünüm vermektedir(Leemans vd., 1998:121). Elma etinin içinden geçen çok sayıda dar, kahverengi tünel bulunmaktadır(Davenel vd., 1988:6). Daha az yumurta biriktirilmiş elmalar, herhangi bir şekil bozukluğu veya yumruluk göstermeyebilir, ancak elma etinde çeşitli tüneller görünmekte ve tünellerden bazıları derinin hemen altındadır ve oldukça uzun, biraz dolambaçlı yollardan geçen elma kurtları yeşil renkli elmalar üzerinde daha belirgin olarak görülmektedir(Wen ve Tao, 1997:475). Pek çok durumda, özellikle hızla büyüyen, sert etli çeşitlerde, kurtçuk elma etinin baskısıyla ezilir. Bu yumurta çatladıktan hemen sonra ortaya çıkabilir. Bu tip elma kurdu ayaksız beyaz veya krem rengi larvalar, genellikle 1/3 inç uzunluğundadır(Butler, 1930:674).

Yetişkin formu, karasinekten biraz daha küçük olan ve bölgeye bağlı olarak Haziran sonu, Temmuz veya Ağustos başında topraktan çıkan bir sinektir. Sinekler meyvelerin kabuğunda küçük delikler açarak yumurtalarını hemen altına yerleştirmektedirler. Yumurtaların kısa bir kuluçka dönemi vardır; sıcak havalarda 4 ila 6 gün içinde yumurtadan çıkarak elmanın içinden dışına doğru bir geçiş tüneli kazarlar. Yaşayamayan larvalar ise çekirdek çevresinde örümcek ağına benzer bir görüntüye sebep olarak burada kuruyabilirler. Bu durumda dışsal görünümde bir bozunma olmayıp elma kesildikten sonra içinde çekirdek çevresinde bir örümcek ağına benzer görüntü ile karşılaşılmasına neden olmaktadır(Burrell, 1937:201).

Elma pası elmada görülen bir başka elma hastalığını tanımlamaktadır. Bu elma hastalığı neredeyse tüm elma kesimlerinde görülmektedir. Bu tip hastalıklı meyveler piyasada nadiren karşımıza çıkmaktadır. Bu tip nadir görülen rahatsızlıklar pas renginde bir çürüme olarak, depolama ile sevkiyat arasında sağlıklı meyvelerden arındırılmaktadırlar. Genellikle gözle görülür şekilde elmanın yuvarlak formunu yitirmesine bir kısmının düzleşmesiyle elmanın biçimsiz hale gelmesine neden olmaktadır.

Kurum lekeli olarak bilinen bir başka elma hastalığında ise hemen tüm çekirdekli meyvelerde görülen bir rahatsızlığı tanımlamaktadır. Bu meyvelerin yüzeysel bir hastalığı en yaygın olarak görülen hastalıklardan biri olarak kabul

edilmektedir. Hastalık meyve bahçesinde ağırlıklı olarak yaz sonu ve kış çeşitlerinde görülmektedir, meyvelerde bulunan sinek ısırığı şeklindeki leke olarak görünür olmaktadır. Kurum lekesi, nakliye sırasında yahut depolama sırasında gelişmeyen yayılmayan bir hastalıktır piyasada çok az önem taşımaktadır ancak meyvenin piyasa değerini düşüren bir hastalıktır(Smith, 1954:15). Kurum lekesi, boyutları değişken bir ölçüde büyüklük gözlenebilmektedir. Başlangıçta yüzeyde görülen ince granüller başlangıçta , kazıyarak veya ovalayarak çıkarılmaya müsait olan bu lekeler hasat sonrası nem kaybına bağlı olarak, lekeler depolama sırasında meyvenin içine doğru göçük oluşturabilmektedir(Williams, 1963: 3586-3587). Düşük sıcaklık dönemleriyle birlikte yaz sonu yağmurları bu enfeksiyonların gelişmesine yardımcı olmaktadır. Uygun hava koşullarının ardından, isli leke genellikle başka bir yüzeysel hastalık olan sinek lekesi ile ilişkilendirilmektedir(Williams, 1963: 3586-3593).

## **2.2. Ayyada Görülen Hastalıklar**

Tüm dünyada olduğu gibi ayva, ülkemizde de geçtiğimiz on yıl içerisinde düşüş gösteren bir meyvedir. Yapısı gereği sert bir meyve olan ayva genellikle, ülkemizin kıyı şehirlerinde yetiştirilmektedir. Ayva üretiminde doğu meyve güvesinin (*Grapholitha molesta* Busck) olarak adlandırılan bir mantar zararlısının bu meyve ağaçlarına saldırdığı bilinmektedir. Bu güvenin neden olduğu kayıplar muhtemelen burada üretimi ortadan kaldırmaktadır. Bu çalışma süresi boyunca Ayvaların üzerinde doğuya özgü meyve güvesinin kontrolünün etkili olduğu ticari ayva bahçelerinin kuzeye bakan yönlerinde, genellikle saldırganların görüldüğü bilgisi hal nakliyecilerinden elde edilen şifai bir bilgidir. Literatür taramasıyla görülmüştür ki ayvalar, günümüzde ortaya çıkan birçok hastalığa tabidir. Burada genellikle ülkemiz ayva üretiminde karşımıza çıkan sıkça görülen ayva hastalıkları ele alınmaktadır.

Dünyada görülen mantar kökenli bir sporlanmaya neden olan doğu meyve güvesi kahverengi çürüklüğe neden olan bir ayva hastalığıdır. Hastalık genellikle ağaç üzerindeki meyvelere saldırmakta ancak küçük, gözden kaçan lezyonları, 32 ° F'nin üzerindeki sıcaklıklarda depolanmış meyvelerde yahut taşıma sırasında büyüme göstermektedir. Bu hastalık tipik olarak kahverengi dairesel çürüklükle

görünür olmakta ve orta derecede sert veya hafif süngerimsi olup, genellikle yüzeyde buruşuk kenar boşlukları olarak kendini göstermektedir(Mccolloch, Fisher, 1951:41).

Böcek yaralanmalarına uğrayan alanda konaklamaları daha kolay gerçekleşen sporların ayva üzerindeki görünümü kahverengi lekenin çapının büyümesine neden olmaktadır. Buna bağlı olarak kaliks (ön ayva başlangıç noktası çiçeğin büzüldüğü alanda) gövde ucunda çürümeleri meydana getirmektedir. Lezyon büyüdükçe merkezi veya yaşlı kısmın zamanla koyulaşması söz konusudur(Mccolloch, Fisher, 1951:53). Meyve sevkiyatçılarının kontrolü ile hastalıklı ürünlerin piyasaya çıkması bir nebze önlenmektedir. Ancak görünmeyen lezyonların olması sebebiyle, nihai tüketicinin alımından sonra, kısa zamanda bu lekelerin görülmesi de söz konusu olabilmektedir. Doğu meyve güvesi, meyve bahçesindeki ayva meyvelerine oldukça zarar verirken bu yönüyle nihai tüketiciye dek ulaşabilmektedir. Sporla enfeksiyonun taşınması söz konusu olabildiği gibi güve larvaları ayva etinin içinden geçerek ve genellikle meyveleri tünellerle petekli bir yapıya kavuşturma yetenekleri bulunmaktadır. Doğru ilaçlama teknikleri ve depolama sıcaklıkları ile azaltılabilecek bir meyve hastalığıdır(Mccolloch, Fisher, 1951:66).

Ayvalarda görülen bir diğer önemli hastalık çürütücü özelliği bulunan mavi küf çürüklüğüdür. Bu küfün gelişmesini ve yayılmasını etkileyen faktörler şu şekilde sınıflandırılabilir(Ryall, 1955:8).

- Meyveler üzerindeki spor yükünün derecesi,
- Meyvelerin durumu ve çevresel koşullar,
- Açık böcek yaralamaları ve morluklar dahil mekanik yaralanmaların varlığı, duyarlılığı arttırarak ayva üzerinde önemli bir biçimde görünür hale gelen mavi küf çürüklüğünü destekleyen koşullardır. Nem, havalandırma ve sıcaklık gibi çevresel koşullar, çürümenin gelişimini doğrudan etkilemektedir. Ayvaların buruşmasını önlemek için gerekli atmosferik nem mavi küf gelişimi için de yeterli koşulları sağlamaktadır.
- Havalandırma eksikliği, sıkı paketlenme ve istiflemeye hava boşluğu olmaması meyvelerin etrafındaki nemi arttırarak ve soğuma hızını yavaşlatarak bu küf çürüklüğünün gelişimi için uygun koşulların oluşmasını sağlamaktadır.

Mavi küf, ayvalar için, normal saklama sıcaklığından daha yüksek sıcaklıklarda daha hızlı gelişmektedir. Depolamaya girmesi geciken, depoda yavaşça soğutulan, sezon sonuna kadar depolanan veya depodan çıkarıldıktan sonra ılık sıcaklıklarda tutulan ayvalar özellikle enfeksiyona maruz kalmaktadır. Hastalık 30 ° ila 32 ° F'de önlenemez veya durdurulamaz bir yıkıma neden olmaktadır. Bu sıcaklıkların üstünde ise meyvede donma yaşanmakta olduğundan sıcaklığın düşürülmesi uygun görülmemektedir. Bu koşullarda çürük noktalar büyümeye devam ederek, yeni enfeksiyonların başlamasını kaçınılmaz kılmaktadır. Çürüme, ayvaların sert ve dirençli olduğu depolama mevsiminin erken döneminde yavaş ilerken, uzun bir saklama süresi gerekmesi halinde bu süre boyunca mavi küf gelişerek ve depolanan ayvalarda ciddi miktarda kayıplara neden olmaktadır. Bu küfe maruz kalan ayvalar 60 günün sonunda 34 ila 1 inç arasında çürük çapında büyüme göstermektedir(Schomer, 1957:46).

Mavi küf çürümesini kontrol etmenin en önemli yollarından bazıları dikkatli kullanım, paketleme tesisi temizliği ve soğuk depolama sıcaklıklarına kadar hızlı soğutma tekniklerinin kullanımıyla sağlanabilmektedir. Meyvelerin taşıdığı spor yükünün azaltılması büyük önem taşımaktadır. Bu sebeple başka meyvelerin enfekte olmasını önlemek için en iyi şekilde sert paketleme tesisi ile sağlanabileceği düşünülmektedir(Redit, Hamer, 1961:73).

Bir başka yöntem ise arındırmak için sanitasyon ve mantar öldürücü bir yıkama yapılmasıdır. Literatüre göre; bu mantar öldürücü sanitasyona sodyum ortofenilfenat (SOPP) ilavesi mantar öldürücü bir yıkama olarak kullanılmasıyla başarılı bir küf mücadelesi olarak kullanılmaktadır. Ancak bu tür işlemler mavi küf çürümesini azaltsa da, bunlar yalnızca dikkatli meyve işleme, paketleme tesisi temizliği, meyvelerin hızlı soğutulması ve önerilen aralıkta soğuk depolama sıcaklıklarının sürdürülmesi için tamamlayıcı niteliktedir(Redit, Hamer, 1961:76). Yavaş yükleme, arabaların geç buzlanması veya sıcak meyvelerin yüklenmesinden kaynaklanan soğutma sevkiyatlarındaki gecikme, çürümenin gelişmesine fırsat verir ve böylece kayıp olasılığını arttırmakta olduğu da göz ardı edilmemelidir. Sevkiyatta arabaları hareket ettirmedeki gecikme, mantarların araç gazını çözmek için kullanılan antifriz çözücüsündeki birleşiklerden güçlenmesi faktörü de bulunmaktadır ki çok dikkatli bir sevkiyatın gerçekleşmesine engel olan yöntemlerdir(Sommer, 1957:13).



Paketlemenin olmadığı kasalarla açık taşıma da bir başka etken sevkiyat sırasında spor üretimini arttıran bir faktör olarak görülmektedir. Bu nedenle bu hastalık bertarafı oldukça uzun süreli dikkatli üretim ve taşıma süreçlerinin bütünlük çalışmasını gerekli kılmaktadır.

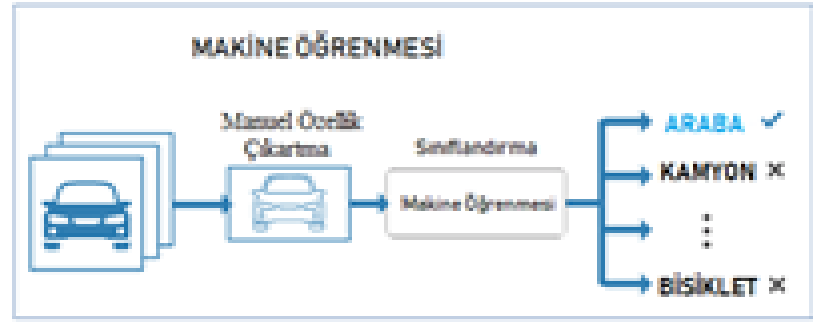
Bu hastalık görüntülerinin sınıflandırılması Şekil 1.1.'de yer alan veri kümesi kullanılarak sağlanacak olup hastalığın tespit edilmesi yöntemleri için makine öğrenmesi (Yapay Sinir Ağları (YSA)) ve Evrişimli Sinir Ağları (ESA) kullanılarak etikete göre hastalığın tespiti için eğitilmiştir. Bunun için kullanılan tekniklere ilişkin alt bilgilere 3. Bölümde yer verilmektedir.



### 3. MAKİNE ÖĞRENMESİ

Makine Öğrenmesi, belirli bir probleme yönelik model eğitimi yapılarak sorunun çözüme kavuşmasını hızlandıran, sistemi otomatik hale getiren yazılımsal kodlama argümanlarının ortak adıdır. Makine öğrenmesini, performansı artırmak veya doğru tahminlerde bulunmak için deneyimi kullanan hesaplama yöntemleri olarak en geniş çerçevede tanımlayabiliriz (Weeks ,1996:13),

Makine öğrenmesini, tanımlanan ve çözümü çıktı olarak vermesi amaç edinilen sorunu veri kümesindeki bilgilere göre tasarlanıp eğitilen model ile tarayarak çözüme yönelik bilgileri çıktı olarak sunan yapay zekanın bir alt birimi olarak tanımlayabiliriz. Makine öğrenmesi metodu, veri kümesindeki örüntüleri tespit ederek, akılcı karar verme için istatistik, mantık ve hesaplamayı birlikte kullanan yapay zekâ disiplinler bütününe bağıl olarak çözümü istenen konuda eğitilip modellenen algoritmaya göre çözümü çıktı olarak sunan yöntemdir.



Şekil 3.1 Geleneksel makine öğrenmesini gösterimi (MathWorks introduces Release 2017)

#### 3.1. Makine Öğrenmesinde Büyük Verinin Önemi

Büyük veri (big data) geleneksel veri işleme tekniği ile analizi tam ve sağlıklı bir şekilde yapılamayan doğrulamanın sınırlı olarak yapılabildiği durumlarda başvurulan genel kümelerdir. Görüntü kavramında ise büyük data resimlerin yer aldığı ve sınıflandırmaların doğru olarak yapıldığı kavram olarak tanımlanabilir. Oluşturulan veri setlerinde görüntülerin sınıflandırılması ve girdi ve çıktuların doğru olarak isimlendirilmesi yönü ile makine öğrenmesinde, yapay zekâ teknolojilerinde ve derin öğrenme metotlarının uygulanması sırasında yapay sinir ağlarının daha kapsamlı bir şekilde eğitilmesinde önemli rol oynamaktadır. Pratikte oluşturulan ve

bir amaca hizmet eden veri setlerinin bir araya getirilmesi aynı nesne yahut canlıya ait farklı açılardan alınan fotoğraflar, farklı tipte canlılar, farklı şekle sahip canlı yahut cansız varlıkların doğru bir şekilde sınıflandırılmasını ve anlamını bize sunar. Çeşitli kareler sürekli olarak üretilip etiketlenerek depolanmakta ve veri kütüphanelerini oluşturmaktadır. Etiketlenen her bilgi veri deposunda yerini aldığından tekrar tekrar model eğitime gerek kalmaksızın sınıflandırmanın yapılmasına imkân sağlamaktadır. İncelenen her biçime ilişkin verinin çokluğu, makine öğrenimi ve YSA eğitiminin daha doğru yapılabilmesine imkân ve olanak sağlar. Bu sebeple verinin doğru sınıflandırılarak depolanması, erişime açık büyük veri kaynaklarına aktarılarak verilere ilişkin görsel kütüphanelerin oluşturulması ile üzerine katılarak ilerlenmesi yapay zekâ araçlarının kullanımının artırılması ve doğru tanımların alınabilmesi konusu önem arz eder. Tıbbi incelemelerde hastalıkların teşhisi konusunda yapay zekâ kullanımı ile hastalık tanısı nasıl ki çok kısa sürede yapılabilirse, eğitim ve diğer alanlarda yaygınlaştırılması ile pek çok hizmetin çok daha az maliyet ile alınabilmesine katkı sunması açısından büyük veri setlerini barındıran kütüphanelerin oluşturulması bu sebeple önem arz etmektedir.

### **3.2. Makine Öğrenmesine Yaklaşımlar**

Günümüzde sıkça duyduğumuz ve büyük veri setlerini oluşturmayı amaç edinen veri madenciliği çeşitli kaynaklardan toplanan, bilginin elde edilip depolanmasını, bilginin doğru kullanımını için analiz ve yönetilmesini, sağlama amacını güden bir bilimsel disiplindir. Veri madenciliğinden elde edilmiş olan tüm bilgi sistemleri, istatistik bilgisinin yanında, bilimsel çalışmalar, fotoğraflar, videolar, sensörler, sosyal medya siteleri, arama motorları, ziyaret edilen blog ve siteler gibi tüm kaynakları kullanarak bilgiyi toplayabilir, depolayabilir, ihtiyaca yönelik hizmet sunmak için kullanılabilir olmak amacı ile bilgiyi elde eden ve yönetmeyi amaçlayan hızlı ve karmaşık, deneyimli makine öğrenmesi ve yapay zekâ algoritmalarını kullanır. Burada deneyim, genellikle elektronik veri ile harmanlanan ve analizler için kullanılabilir halde saklı bulunan bilgilerdir. Makine öğrenmesi denetimli öğrenme, denetimsiz öğrenme ve yarı denetimli öğrenme olmak üzere üç sınıfa ayrılır.

### **3.1.1. Danışmanlı öğrenme**

Bağlı yahut değişkenlerden oluşan bir veri setinde, yazılan her algoritmaya dair bir çıktının yer aldığı kısaca giriş yapılan bilgi ile sistem çıktısının belli olduğu öğrenme yöntemidir. Etiketlenmiş veri seti olarak adlandırılmış bu grup yüklenmiş algoritmalar ile sistem çıktısı arasında bir bağlantı kurmaya çalışarak karar verme yöntemini belirlemeyi amaçlayarak öğrenir. Karar ağaçları, destek vektör makineleri, yapay sinir ağları, topluluk öğrenme yöntemleri denetimli makine öğrenmesine birer örnek teşkil eder (Sammur , Webb, G., 2010:19).

### **3.1.2. Danışmansız öğrenme**

Veri setinde etiketlemesi bulunmayan dolayısı ile girdilere yönelik sistem çıktısının alınmasının daha zor olduğu öğrenme biçimidir. Kümeleme işlemi bu tarz öğrenme biçimine örnektir (Sağiroğlu, Beşdok, Erler, 2003:27).

### **3.1.3. Yarı danışmanlı öğrenme**

Makine öğrenmesi grupları içerisinde insanın öğrenme sürecine en yakın olan öğrenme biçimidir. Etiketlenmiş verilerin, etiketlenmemiş verilere nazaran daha az olduğu bu öğrenme biçiminde etiketlenmemiş verileri, etiketli olan verilerden hareket ile etiketlemeye çalışır. Günümüz WEB sayfalarının arama motorları bu tarz öğrenmeye örnek gösterilebilir (Sağiroğlu, Beşdok, Erler, 2003:32).

## **3.3. Yapay Zeka ve Makine Öğrenmesinin Tarihçesi**

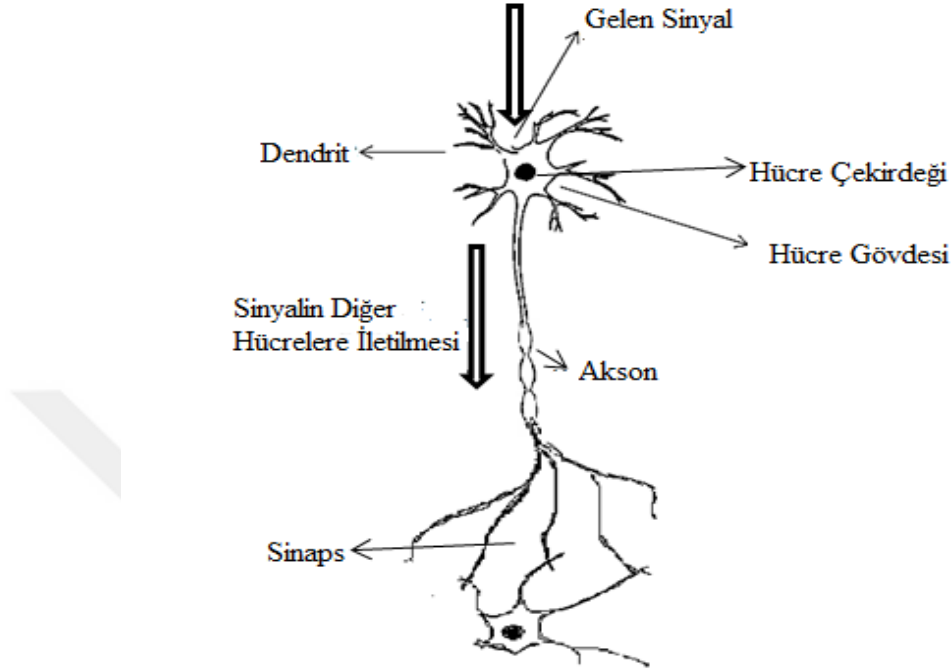
Cambridge Üniversitesi Profesörlerinden, Alfred North Whitehead ve Bertrand Russell tarafından 1925 yılında yazılan Principia Mathematica adlı üç ciltlik eser ile teorik mantığın temelleri atıldı. 1936 yılında ise Viyana Syntactic Structures'in yazarı Rudolf Canap mantıksal sözdizimi ile destek sundu. Yapay zekâ 1954 yılı soğuk savaş sırasında 1954'ten itibaren ABD ordusu Rus belgelerini ve akademik makalelerini otomatik olarak çevirmek için bir program istiyordu. Bunun için yapay zekâ önem kazandı ancak henüz istenilen düzeyde değildi. Sibernetiklerin kâşifi sayılan Walter Pitts ve Warren McCulloch 1947 yılında yapay zekâ ile kendini kontrol eden bir robot yapmışlardı ama 1951 yılında elektrik kontrolleri bilimi olan sibernetikler henüz ilgi uyandırmıştı. 1969 yılında Marvin Minsky ve Seymour Papert

tarafından yazılan An Introduction to Computational Geometry adlı kitaplarında XOR sorunu yani eşdeğerliğin olumsuzlanması sorunu nedeniyle yapay zeka teknolojilerine olan ilgi azaldı. XOR sorunu kısaca modern sinir ağlarındaki gibi işleyişin henüz olmadığı zamanlarda tüm grafiklerin doğrusal olarak verilmesi sorunudur. İki boyutlu bir algılayıcı sisteminde sonucun doğrusal olması ve grafiğin herhangi bir eğri içermemesi sorunudur. XOR problemi doğrusal olmayan ve türevi alınabilen Sigmoid fonksiyonunun kullanılması ile çözüme kavuşturulmuş ve XOR sorununun çözülmesi ile birlikte çok katmanlı bir algılayıcı fikri ortaya çıkmıştır (Vapnik, 1963:771). Destek vektör makinelerinin temeli (DVM) 1963 yılında Vladimir Vapnik ve Alexey Chervonenkis tarafından ortaya atılmış olup, istatistiksel öğrenmeyi esas alan, bir çeşit denetimli öğrenme algoritması olarak tanımlanabilir. Her ne kadar temelleri 60'lı yıllara dayansa da 1995 yılında Vladir Vapnik, Bernhard Boser ve Isabelle Guyon tarafından geliştirilmiştir. İlk olarak 1965' te Ivakhnenko ve Lapa tarafından geliştirilen ileri yayımlı perceptron çok ilgi görmemiştir. Yine aynı yıl Nilssons "Öğrenen Makineler" adlı bir kitap yayımlamıştır. Yayımlanan eserde tüm yapılan yapay zekâ ve makine öğrenmesi çalışmaları bir araya toplanmıştır (Vapnik, 1963:776). 1969 yılında ise XOR problemi nedeniyle ABD'de yapay zekâ araştırma çalışmalarını yürüten organizasyon olan DARPA yapay zeka ve makine öğrenmesi çalışmalarını desteklemeyeceğini açıkladı. Werbos tarafından 1974 yılında geliştirilen geriye yayılma tekniği ile çok katmanlı perseptron 1986 yılında Rumelhart'ın çalışmaları ile ünlenene dek yapay zekâ ve makine öğrenmesi çalışmaları için duraklama devri devam etmiş, ancak Rumelhart'ın çalışmaları tekrar hız kazanan yapay zekâ teknolojileri ve bu günkü derin sinir ağlarının temeli atılmıştır (Huang vd., 2017:43).

### **3.4. Yapay Sinir Ağları**

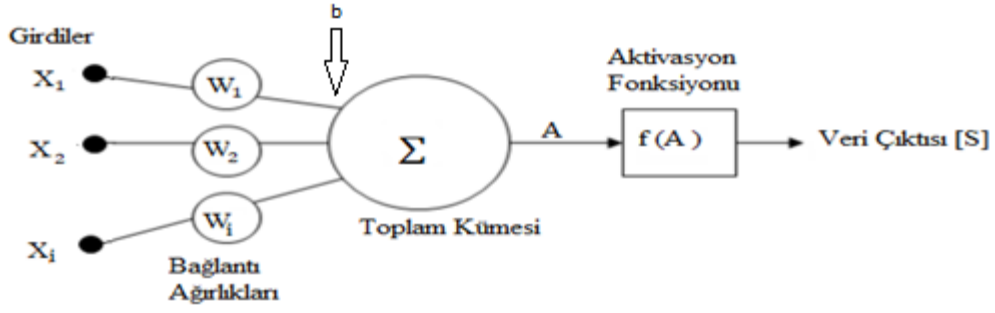
İnsan beyni ve öğrenme işlevi dikkate alınarak kurgulanan bir çeşit makine öğrenmesidir. Yapay sinir ağları, biyolojik insan beyni nöronlarını taklit eder. Şekil 3.2 de insan beynindeki biyolojik nöron yapısı verilmiştir. Biyolojik nöronda bulunan dendritlerin görevi, gelen uyarı sinyallerini sinir hücresinin gövdesine iletip, hücredeki kararlı halin bozulmasına sinir hücresinde bir dizi kimyasal sürecin başlamasına neden olmaktır. Sinir hücresinde vuku bulan bu kimyasal süreçte tüm girdiler bir sonraki sinir hücresine aksonlar aracılığı ile iletilir. Sinir hücresindeki

akson ucu ile kendisinden sonra gelen dendrit arasındaki boşluk sinaptik boşluk olarak tanımlanır. Sinaptik boşluk içerisine bilgiyi ileten her dal iletken madde olarak kabul edilir ve bu bilgi iletimi sırasında dolarak bilginin geçişini sağlar. Sinaptik boşluktaki değişkenlik öğrenme süreci olarak tanımlanır.



Şekil 3.2 Biyolojik Beyin Nöronu Yapısı

Yapısı gereği matematiksel algoritmalarla ibaret olan, yapay sinir ağları ise temelde üç ana bölümden oluşmaktadır. Giriş katmanı sisteme gelen verilerden oluşur. Veri seti bilgileri bu katmana işlenir. Özetle bu katman girdi vektörüdür. Orta katman olarak görülen gizli katman ise nöron görevini üstlenen algılayıcıların bulunduğu YSA'nın özüdür. Biyolojik nörondaki tüm görevleri burada gizli katmanda yer alan yapay sinir ağlarını çalıştıran algoritmalar yönetir. Gizli katman nöronları bir önceki katmandan alınan her veriyi bir dizi işlemde geçirerek bir sonraki katmana ileterek, anlamlı çıkışlar sunmaya çalışmaktadır. Giriş katmanındaki bilgiler bu katmanda işlenerek anlamlı çıktılarının alınmasını sağlar. Giriş katmanındaki YSA nöronları  $X_1, W_1; X_2, W_2; X_i, W_i$  gibi girdi verilerinin aktivasyon fonksiyonundan geçerek algoritmik kararı çıktı olarak sunar.  $X_1, X_2, \dots, X_i$  girdi kümesidir.  $W_1, W_2, \dots, W_i$  ise YSA nöronları ağırlık vektörü kümesinin elemanlarıdır. Algoritmik fonksiyon  $X_i W_i$  girdilerinin çarpımlarının toplam kümesinden aktivasyon fonksiyonuna geçirilerek çıktı olarak sunulur.



Şekil 3.3 Çok Katmanlı Yapay Sinir Ağı Nöronu Çalışma Fonksiyonu (F. Rosenblatt'ın 1958 Yılında Tanıttığı Model)( Hornik, Stinchcombe, White, 1989:362)

$$S = f(A) = f(X_1 \cdot W_1 + X_2 \cdot W_2 + \dots + X_i \cdot W_i) = f(\sum_{p=1}^i X_i W_i) \quad (3.1)$$

$$S = f(A) = f(X_1 \cdot W_1 + X_2 \cdot W_2 + \dots + X_i \cdot W_i) = f(\sum_{p=1}^i X_i W_i + b) \quad (3.2)$$

Burada

S= Verilerin Çıktısını,

A = Nöronun Aktivasyonunu,

f(A) = Aktivasyon Fonksiyonunu,

X<sub>1</sub>, X<sub>2</sub>,.....X<sub>i</sub> = Sisteme Yüklenen Girdileri,

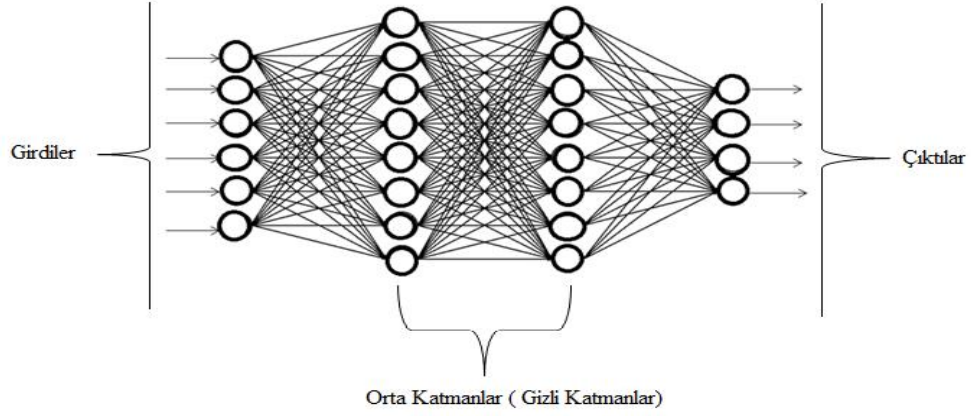
W<sub>1</sub>, W<sub>2</sub> .....W<sub>i</sub> = Bağlantının Vektörel Ağırlıklarını

X<sub>p</sub> = (p=1,....,i) Girdi Kümesi Olan X'in P Sırasında Bulunan Elemanını,

W<sub>p</sub> = (P=1,....,i) Ağırlık Vektörü W'nin P Sırasındaki Elemanını,

b = Bias önyargı değerini, ifade etmektedir.

1989 yılında K. Hornik vd. tarafından yazılan Neural Network adlı eserin 2. Cilt 5. Sayfasında ileri beslemeli yapay sinir ağını şekil 3.4'te gösterildiği gibi tanımlanmıştır. Şekilde insan beyni nöronlarına benzer şekilde görülen çizgiler (  $\ll$  ) ağırlık vektörleridir. Ağırlık vektörünün ataması düzgün şekilde atanmamış ise bilgi diğer katmana geçmez yahut eksik geçer(Hornik, K., Stinchcombe, M., White, H., 1989:365).



Şekil 3.4 İleri Beslemeli Yapay Sinir Ağı Katmanları

Burada veri girişi ile giriş katmanında yer alan her yapay sinir ağı nöronu, giriş vektöründeki değerleri ayrı ayrı üstlenerek bir değer elde eder. Giriş vektörü değerleri; RGB bandındaki JPEG formatında bir resme ait piksel değeri olabileceği gibi, ses aralığındaki titreşim değeri gibi sayısallaştırılmış herhangi bir değer de olabilir. Giriş katmanı nöronları, kendilerine atanmış ağırlık değeri vektörleri ile bağlı gizli katman nöronlarına bilgiyi taşır. Gizli katman nöronları  $S = f(A)$  başlangıcı ile (3.2) de bağlantısı verilen fonksiyonu tekrar tekrar işler ve her işleşte bias (b) adı verilen bir önyargı değeri ekler. Elde ettiği her değeri kendisinden sonra gelen diğer katmana taşır. Diğer gizli katmanlarda işlenen her değer bir sonraki katmana taşınır, değerlerin sürekli olarak sonraki katmana aktarılması şeklinde ilerlemesinden dolayı ileri beslemeli yapay sinir ağı adını alır. Sistemdeki her gizli katman aynı fonksiyonu işleyerek sonucunu sonraki katmana iletir. Son katman çıktı katmanıdır ki burada girdi katmanında yer alan veri sayısı ile farklılık göstermesi mümkündür. Bu giriş verilerinde değer kaybı yahut sayısallaştırmada sorun olması sebebi ile sınıflandırılmamış olması yahut aynı değer bir den fazla kez yüklenmiş olması sebebi ile birlikte öznelik ataması yapıldığı algısını çağırır.

K.Hornik v.d. ; a.g.e.'de, evrensel yaklaşımlarla, standart çok katmanlı ileri beslemeli sinir ağlarının verileri, yakınlık derecesi niteliği ile sınıflandırılabilirliğini, yahut derecesi fark etmeksizin bir fonksiyonun sonucunu kabul edilebilir bir sonuç ile tahmin edebileceğini ileri sürmektedir. Başarısız bir tahmin sonucunun oluşması halinde bu sorunun; girdi verilerinin eksik olmasında, gizli katmanların yetersiz




olması ile öğrenme eksikliğinin olmasında yahut girdi verileri ile hedeflenen çıktı verileri arasında yeterli derecede ilişki kurulamamasına bağlı olduğunu vurgulamaktadır (Hornik, Stinchcombe, White, 1989:368).

Yapay sinir ağlarına(YSA) yönelik bir tarih yazılacak olursa 1980 öncesi ve sonrası olarak ikiye ayırma konusunun hiçbir yazar tarafından göz ardı edilemeyecek kadar büyük bir ayırım barındırmaktadır. YSA kullanımının, yapay zeka tarihçesinde kısaca bahsetmiş olduğumuz gibi doğrusal olmayan Sigmoid fonksiyonunu kullanan çok katmanlı algılayıcı modelin tanınması ile birlikte hız kazandığı görülmektedir. Sigmoid fonksiyonu, temelde bulanık mantık kümesi olan  $[0,1]$  aralığındaki değerlerden oluşan kümeyi kullanır. Yapay sinir ağları oluşturulurken sıklıkla başvurulan aktivasyon fonksiyonu olarak bilinir. Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan ve sürekli artan bir fonksiyon olarak tanımlanmaktadır(Chih-Min vd.,2014:373).

$$y = f(x) = \sigma(x) = \frac{1}{1+e^{-x}} \quad , \quad 0 \leq f(x) \leq 1 \quad (4.1)$$

Sigmoid fonksiyonuna ilişkin grafik ise Şekil 3.5 'de yer aldığı gibidir:



Şekil 3.5. Sigmoid Fonksiyonu Grafiği

Sigmoid Fonksiyonu, nöral kompresyonda genellikle sadece ağırlıklandırılmış toplamların katmanlı ağları ve ardından harici programlamanın kısmen öğrenme ile sübvansede edildiği bir karar fonksiyonu olarak, 1980'lerde bağlantıcılığın güçlü bir canlanmasını sağlayan fonksiyon olarak kullanılması ile karşımıza çıkar. Bu vizyon, sonunda takip problemlerini ortaya koymaktadır (Srivastava, Lekha, 2010:163).

Sigmoid fonksiyonunu kullanan aktivasyon kodlarına ilişkin problemleri şu şekilde özetleyebiliriz (Mira, 1995:13)

- Gerçek nöronların bildiklerini açıklamak için, açıkça yetersiz olan hesaplama modüllerinin kullanımı, yapay nöronların biyolojik gerçeklikten geri dönüşü olmayan bir açıyla uzaklaşmasına yol açmaktadır.
- Sentez süreçlerinde metodoloji eksikliği ve aşırı ampirizm vardır.
- Kendini, yapay zekanın sembolik bakış açısıyla bütünleştirilemeyen bir alternatif olarak sunar.

Yapay Sinir Ağlarına ilişkin problem her ne kadar çözülmüşse de 2000'li yılların başlarına kadar hayatın içinde ve hemen her kademesinde var olduğunu söylememiz de gerçeği tam olarak yansıtmayacaktır (Ruder, 2016).

1980 yılında çalışmaları desteklenmeyen ve sıkıntılı sürece karşın çalışmalarına devam eden çok az bilim adamı çalışmalarının karşılığını almaya başlamışlardır (Lantz, 2015).

Yukarıda yer alan problemlere ilişkin yapay zekâ ve YSA'lar için farklı aktivasyon kodları kullanılmaya çalışılmıştır. En bilinen aktivasyon kodları: Hiperbolik Tanjant Fonksiyonu, ReLU, Softmax fonksiyonunu kullanan aktivasyon kodlarıdır. Bu aktivasyon kodlarına ilişkin bilgilere derin öğrenme konusunda değinilecektir. Rumelhard V.d. tarafından 1986 ve 1988 tarihlerinde yayımlanan, “*Parallel distributed processing*” ve “*Explorations in the microstructure of cognition*” adlı eserleri ile bugünkü yapay sinir ağlarının temelleri atılmıştır (Rumelhart V.d.,1986:43).

1988 yılında Broomhead ve Lowe tarafından “Radyal Tabanlı Fonksiyonlar” tanıtılmıştır. 1997 yılında Hochreiter ve Schmidhuber tarafından Tekrarlayan Sinir Ağları (TSA) çalışması tanımlanmış ve tanıtılmıştır (Pratt, 1994:12).

Ancak 2000 yılına dek YSA algoritmaları makine öğrenmesine göre çok daha fazla avantaj sunmasına rağmen maliyeti fazla görüldüğünden, model eğitim süresinin uzun olması sebepleri ile tercih edilmeyerek bunun yerine probleme özel tasarlanan destek vektör makineleri tercih edilmiştir. Yapay sinir ağlarının tercih edilebilirliği bilgisayar hız kapasitelerinin artması, grafik işlemcileri (GPU)'un hesaplamalarda kullanılabilir olması ile modellerin daha hızlı eğitilebilmesine imkân tanınması ile olmuştur (Bramer,2016:11).


2000 yılında YSA için “Derin Öğrenme” metodu Igor Aizenberg tarafından tanıtılmış ve bu doğru öğrenme metodu ilgi uyandırmıştır (Bramer, 2016:18).

## 4. DERİN ÖĞRENME ve EVRİŞİMLİ SİNİR AĞLARI (ESA)

### 4.1. Derin Öğrenme ve Tarihçesi

İlk kez 2006 yılında Hinton vd. tarafından çok katmanlı yapay sinir ağlarının daha verimli eğitebileceğinin öne sürülmesiyle ortaya çıkmış olsa da derin öğrenme terimi ilk olarak 1987 yılında Rina Dechter tarafından kullanılmış ve 2000 yılında Igor Aizenberg ve arkadaşları yaptıkları çalışmalarda bir yapay sinir ağı modeli olarak derin öğrenme kavramını ortaya koymuşlardır.

Burada ki derin kelimesi ağda ki katman sayısını ifade eder. Katman sayısı arttıkça ağ yapısı derinleşir. Yapay sinir ağları genelde bir iki katmandan oluşurken, derin ağlar yüzlerce katmanlardan oluşabilmektedir. Ancak derin öğrenme 1990 ile 2000'ler arası veri yetersizliği, ana darboğaz ve donanım yetersizliğinden dolayı ışıldayamamıştır. Çünkü sinir ağ modeli derinleştikçe işlem yükü artar ve donanımsal yetersizlikler ortaya çıkar. Ayrıca ağın geriye doğru eğitilmesi sırasında katman sayısı arttıkça geri bildirim sinyali yok olup gidebilir. Veri yetersizliği de derin öğrenmenin en büyük problemlerinden olan aşırı uydurmaya sebep olmaktadır.



Şekil 4.1 Derin sinir ağlarını genel yapısı (Mira,1995:11)

### 4.1.1. Derin öğrenmenin gelişimi

İnternetin yaygınlaşması ile makine öğrenmesinin ihtiyaç duyduğu büyük veri setlerinin toplanması ve dağıtımının mümkün kılınması derin öğrenme gelişiminin ilk basamağı oldu.

2009-2010 civarında basit ama önemli birkaç algoritmanın keşfi ile hata sinyalinin geriye daha iyi iletilmesi mümkün hale geldi. Bu algoritmalar:

- Katmanlar için daha uygun aktivasyon fonksiyonları (Relu, Softmax gibi),
- Daha uygun ilk ağırlık başlatma yöntemleri,
- Daha iyi eniyileme (optimizasyon) yöntemleri (RMSProp ve Adam gibi).

2014, 2015, 2016 yıllarında yığın normalizasyonu (batch normalization), artık bağlantılar (residual connections) ve derinlemesine evrişim (depthwise separable convolution) gibi hata sinyalinin geriye daha iyi yayılımını sağlayan bu yöntemler ile günümüzde, yüzlerce katmandan oluşan ağları sıfırdan eğitebilir duruma geldi.

Sonuç olarak derin öğrenme bugün sağlık, eğitim, iletişim gibi sektörlerde doğal dil işleme, örüntü tanıma, konuşma tanıma gibi birçok alanlarda yaygın bir biçimde kullanılmaktadır. Bu çalışmada da derin öğrenmeyi elma ve ayvadaki hastalıkların tespitini tanımada kullanılmıştır.

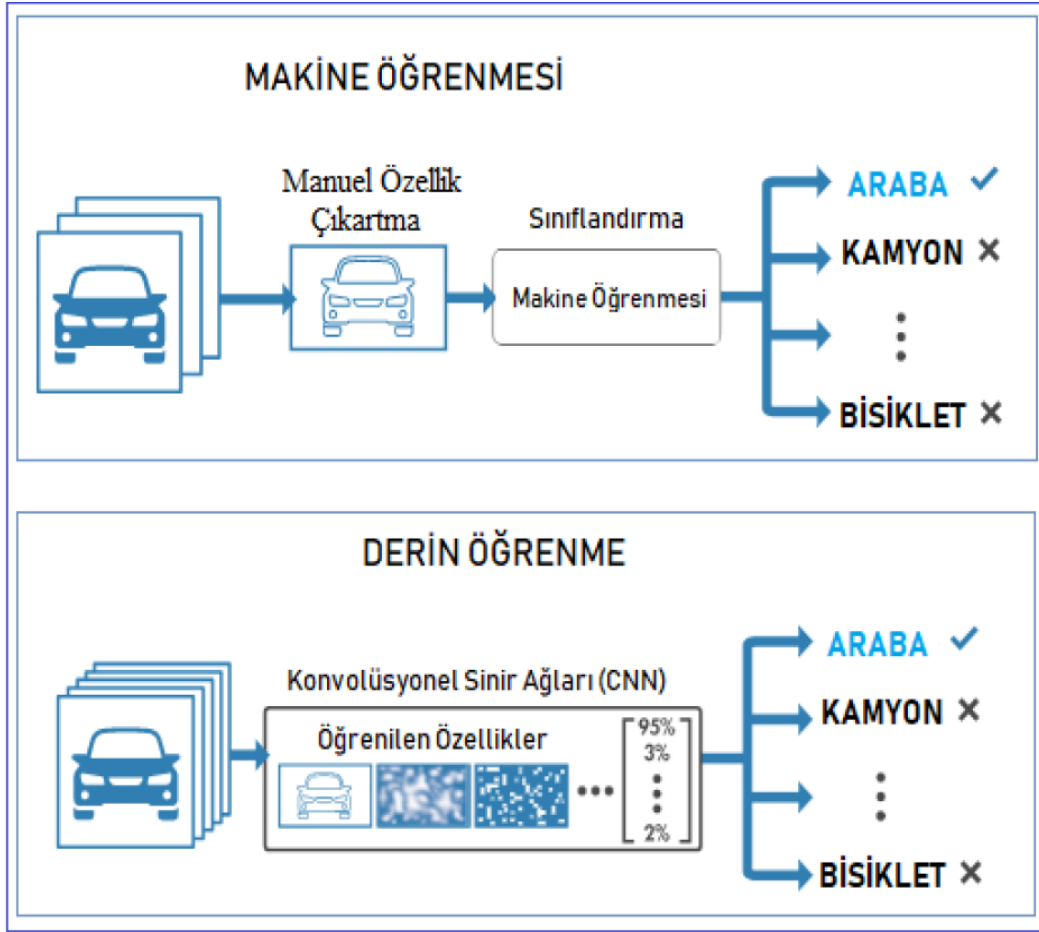
### 4.2. Derin Öğrenmenin Güçlü Yönleri

Derin öğrenme, tüm katmanlarının gösterimlerini sıralı olarak öğrenmek yerine bütünleşik olarak öğrenir. Her şey tek bir geri bildirim sinyali tarafından kontrol edilir ve modeldeki her değişim hedefe ulaşmaya hizmet eder. Böylece sığ modelleri üst üste sıralama yerine gösterimleri ara katmanlardan birbirinden soyut olarak öğrenebilmek mümkün olmaktadır.

Derin öğrenmeyi farklı kılan en önemli özelliklerinden biri; Klasik makine öğrenme tekniklerinde veriyi kullanmadan önce ön işlemden geçirerek veriyi model için anlamlı kılmak gerekmektedir. Bunun içinde problemin çözümünü kolaylaştırmak için girdilerin daha ayırt edici olmasını sağlayan öznelilikler çıkarılır.

Derin öğrenme, makine öğrenmesinin bu kritik adımını tamamen otomatikleştirmiş olarak kendi içinde yapması nedeniyle problemlerin çözümünü kolaylaştırmıştır. Şekil 4.2' de görüntüde bulunan girdilerin tahmin edilmesinde hem

klasik makine öğrenmesi hem de derin öğrenme modellerinin nasıl bir yol izlediği gösterilmiştir.



Şekil 4.2 Derin Öğrenme ve Geleneksel Makine Öğrenmesi Yaklaşımının Karşılaştırılması

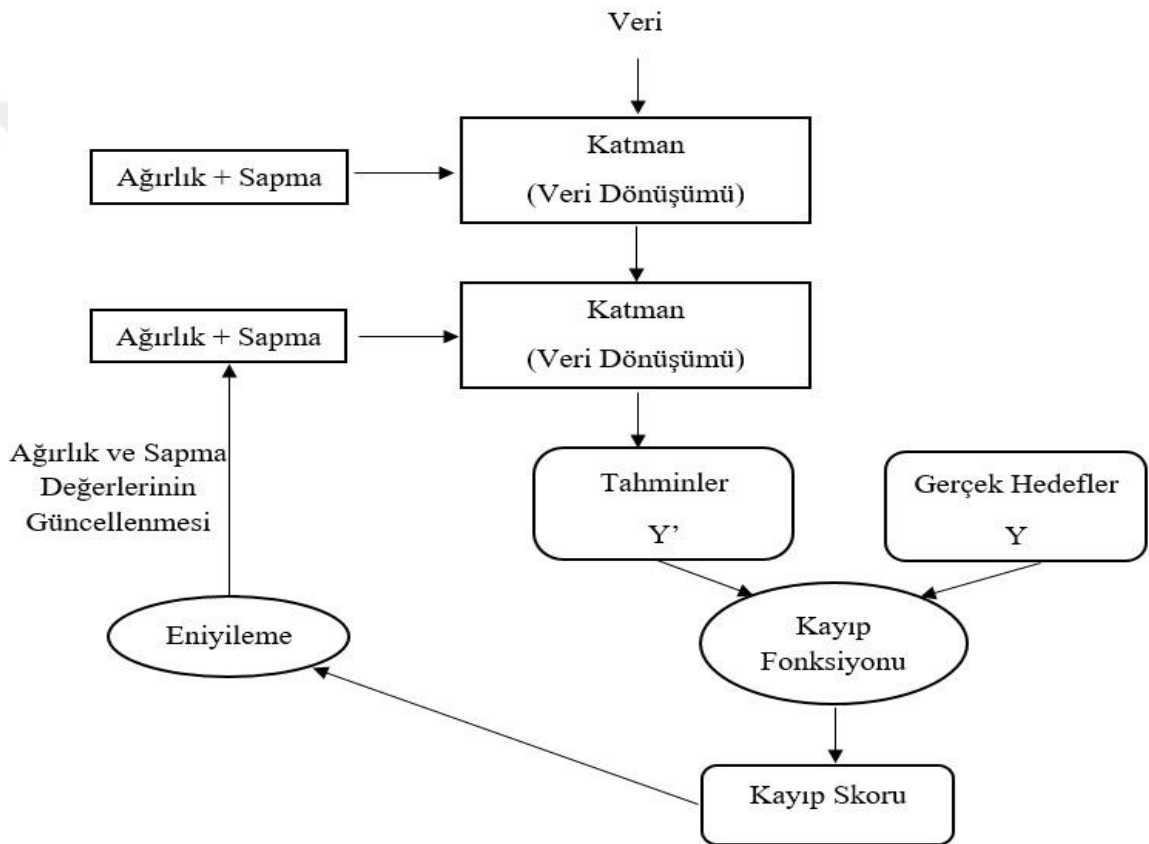
Geleneksel makine öğrenmesi tekniklerinde eğitim verilerinin artırılması her zaman başarıyı olumlu etkilemezken; derin öğrenmede eğitim verisi çeşitlenip artıkça başarı oranı da artmaktadır. Bu durumda derin öğrenme için çok miktarda eğitim verisine ihtiyaç vardır. Geleneksel makine öğrenmesinde başarılı bir sonuç için az miktarda eğitim verisi yeterli olabilmektedir.

Derin sinir ağlarıyla uygulama yapılırken genelde 3 farklı yöntem uygulanır. Birinci olarak problemin çözümüne uygun derin ağ modeli oluşturularak eğitimin gerçekleştirilmesi, ikinci olarak önceden eğitilmiş hazır bir ağ yapısının yeni verilerle eğitilmesi ve son olarak da derin sinir ağı yapısından öznelik çıkarımı yapılarak diğer makine öğrenme yöntemleri ile kullanılmasıdır. Gerçekleştirilen bu çalışmada

elma ve ayvadaki hastalıkların görüntü yoluyla tespiti için görüntünün tanınmasını sağlayabilmek için; her üç yöntemde uygulanmıştır.

### 4.3. Derin Öğrenmede Etkili Olan Kavramlar

Derin ağ yapısı, zincirleme eklenen katmanlardan oluşur ve girdi verisini tahminlere eşler. Sonrasında kayıp fonksiyonu vasıtasıyla tahminler ile hedefler arasındaki fark olan kayıp değeri bulunarak ağırlık tahminleri ile hedeflerin ne kadar eşleştiği ölçülür. Eniyileme algoritması kayıp değerini kullanarak ağırlık ve sapma değerleri güncellenmektedir.



Şekil 4.3 Katmanlar, kayıp fonksiyonu ve eniyileme algoritması arasındaki ilişki

#### 4.3.1. Ağırlık

Eğitilen parametrelerden bir tanesi İngilizce de weight anlamına geldiği için genellikle W harfi ile gösterilir. Sinir ağı tarafından eğitim esnasından daha önemli olduğu düşünülen girdilere daha yüksek ağırlık değeri verilmektedir.

### 4.3.2. Sapma

Eđitilen parametrelerden bir tanesi İngilizce de bias anlamına geldiđi için genellikle b harfi ile gösterilir. Ađırlıktan farklı ek olarak uygulanan dođrusal bileşene sapma denir. Bu deđer; ađırlıklı katsayılı girişin aralıđını temel olarak deđiřtirmek için eklenmektedir.

### 4.3.3. Aktivasyon fonksiyonu

Bu fonksiyonlar tensörlere etki eden dođrusal olmayan operasyonlardır. Amaç ađırlık ve sapma deđerlerinin ayarlanmasıdır. Bunu nöronların tetiklenmesi olarak düşünebiliriz. Yüksek bir deđer geldiđi zaman nöron daha yüksek bir sinyal verecektir.

Yapay zekâ ve YSA'da kullanılması ile neredeyse devrim yaratan Sigmoid Fonksiyonu hakkında yapılan çalıřma kapsamında ilgili bilgiler verildiđinden diđer en sık kullanılan fonksiyonlara iliřkin bilgilere deđinilecektir. Bunlar sırası ile ; Hiperbolik Tanjant Fonksiyonu, ReLU Fonksiyonu ve Softmax Fonksiyonlarıdır.

- Hiperbolik Tanjant Fonksiyonu (Tanh); Sigmoid Fonksiyonunun [-1 ve 1] aralıđını kapsayan fonksiyondur. Eřikleme 0,5 te deđil 0 da sađlanır. Bu sebeple 0 dan küçük olan sayılar 0 (sıfır) olarak kabul edilmeyerek -1 'e yaklařan deđerler alır ve fonksiyon denklemini řu řekilde formüle edilir:

$$, -1 \leq f(x) \leq 1 \quad (4.1.)$$

- ReLU Fonksiyonu; Düzeltilen dođrusal birim aktivasyon fonksiyonudur. Fonksiyon aynı Sigmoid fonksiyonunda yer alan sorunu yansıtır. Bu sorun 0'dan küçük deđerleri 0 deđerine gibi kabul etmektedir. Pozitif deđerler x deđerini alırken negatif deđerler 0 olarak kabul edilir ve řu řekilde formüle edilir:

$$y = f(x) = \max(0, x), \quad 0 \leq f(x) \quad (4.2.)$$

ReLU fonksiyonu, Sigmoid ve Hiperbolik Tanjant fonksiyonlarını kullanan aktivasyon kodlarına nazaran daha YSA eđitimi sırasında daha hızlı çalıřtıđının



tecrübe edilmiş olması nedeniyle, ağın öğrenmesi sürecinde sıkça kullanılan bir fonksiyon olmasına rağmen tıpkı Sigmoid Fonksiyonu aktivasyon kodunda olduğu gibi dezavantajlara sahiptir. Bu dezavantaj negatif değerlerin 0 olarak kabul edilmesidir. Bu durum 0'dan küçük ağırlık değerlerini alan perseptronların diğer deęişle nöronların yok olmasını ve bir daha eğitim sürecinde kullanılamaması sonucunu beraberinde getirmektedir. Bu dezavantajın önüne geçilmek için sızdırmalı (leaky) ReLU fonksiyonu ileri sürülmüştür. Bu fonksiyonun formülasyonu şu şekildedir:

$$y = f(x) = 1(x < 0)(ax) + 1(x \geq 0)(x), \quad (4.3.)$$

Fonksiyondaki  $\alpha$  sabiti genellikle küçük bir sayı olarak eklenir ve 0'a yakın bir deęer elde edilir (0,1) gibi ve bu deęer negatif ağırlık deęeri ile çarpılmaktadır.

➤ Softmax Fonksiyonu;

Çoklu sınıflandırma işlemleri için kullanımına en çok başvuru alan fonksiyon olmakla birlikte, girdiler için bir sınıflandırma olasılığı baęlı kayıp deęerleri üreten fonksiyondur. Sınıflandırıcı, girdilerin gerçek sınıfa ait daęılımı ile ait olma olasılığı bulunan kümenin daęılımını (en çok olabilirlik fonksiyonunu) normalize eder ve iki deęer arasındaki çarpaz entropi deęerinin en aza indirgenmesi mantığı ile hareket ederek çıktıları sunar.

Formülü ise şu şekildedir:

$$\sigma: \mathbb{R}^n \rightarrow \text{int}(\Delta^{n-1}), \quad (4.4.)$$

$$, \lambda > 0 \quad (4.5.)$$

softmax işlevi  $\sigma: \mathbb{R}^n \rightarrow$  ile verilir

$\Delta = 1$  olduğunda, (1) 'e standart softmax işlevinde ise  $\Delta \rightarrow 0$  olarak,  $\sigma$  çıkışı noktası merkezinde akıllıca, yani tekdüze bir olasılık daęılımı uygular. Öte yandan,  $\lambda \rightarrow \infty$  olarak,  $\sigma$  çıkışı noktasal olarak  $e, j \in \mathbb{R}^n$ 'ye yakınsar, burada  $j = \text{argmax}_{1 \leq i \leq n} e_i$ ,  $z$ , deęerleri ile ifade edilir. İki veya daha fazla bileşen arasındaki fark  $z$ 'nin çok küçük olmaması gerekmektedir.

Bu fonksiyonlara ek olarak farklı Derin Öğrenmede kullanılan farklı aktivasyon kodları da bulunmaktadır. Derin öğrenmede en sık başvuru alan aktivasyon fonksiyonlarına yer verilmiş olup, bu çalışma kapsamında, sınıflandırma için

önerilen ve kullanacağımız aktivasyon kodu ise softargmax, argmax ya da yanlış olmasına rağmen en bilinen adı ile softmax fonksiyonu olacaktır.

#### **4.3.4. Öğrenme katsayısı ve eniyileme algoritması**

Öğrenme katsayısı, başkaca bir söylem ile hata düzeltme katsayısıdır. YSA'da akson görevi gören taşıyıcı sinaptikleri eğim düşümü algoritmalarında kullanılan bir katsayıdır. Öğrenme katsayısı, eğim düşümüne göre tanımlanmış algoritmalarının yakınlaşmasını sağlamaktadır. Öğrenme katsayısı büyüdükçe sinaptiklerin bir sonraki katmana bilgiyi taşıyamamasına neden olur. Bu katsayı için çok küçük bir değer atandığında ise öğrenme sürecinin uzamasına etki eder.

Öğrenme katsayıları için çeşitli eniyileme algoritmalar kullanılır. Eniyileme algoritması, öğrenmenin nasıl gerçekleşeceğini belirlemektir. En sık kullanılan algoritmalar ise, eğimine göre, Adagrad, Adamax, Nadam, Adadelata, RMSprop ve Momentum algoritmalarıdır.

#### **4.3.5. Kayıp fonksiyonu**

Ağın doğruluk değeri, kayıp fonksiyonu kullanılarak hesaplanmaktadır. Bu fonksiyon, ağı, gerçek değerlerinin tahmininde hata oluşursa cezalandırmaya çalışmaktadır. Sınıflandırma problemlerinde genelde kategorik çapraz entropi fonksiyonu kullanılır. Bu tez çalışması bir sınıflandırma problemi olduğu için kullanılan derin öğrenme modellerinde bu fonksiyon kullanılmıştır.

#### **4.3.6. Geri yayılım**

Tek bir iterasyon ile elde edilen çıktı için ağın hatası hesaplanabilmektedir. Elde edilen hata değeri, maliyet fonksiyonun eğimi ile birlikte ağın ağırlıklarının, güncellenebilmesi için ağa geri beslenmektedir. Sonraki iterasyonlar da hatanın minimize edilmesi için bu ağırlıklar güncellenir. Kayıp fonksiyonun eğimi kullanılarak ağırlıkların güncellenmesi geri yayılım olarak ifade edilmektedir.

#### **4.3.7. Yığın, epok ve tekrar sayısı**

Yığın, model tarafından işlenmesi için bir defada alınan miktar. Tüm girdinin tek seferde gönderilmesi yerine girdiler rastgele seçilmiş eşit büyüklükte birbirinden

bağımsız yığınlara bölünerek ağda eğitilir. Her bir yığın kümesi işlendiğinde bir tekrar, tüm girdi yığınlarının bir defada işlenmesine de epok denir.

#### 4.4. Derin Öğrenme Mimarileri

Farklı derin öğrenme mimarileri vardır. En çok kullanılanlar;

➤ Tekrarlayan Sinir Ağı (Recurrent Neural Networks) (RNN):

Ara katman çıkışını hem bir sonraki katmana hem de tekrar aynı katmana giriş olarak vermesinden dolayı tekrarlayan sinir ağları denir. Sınıflandırma problemlerinde kullanılabilen bu yapı ses tanımda çalışmalarında başarılı olduğu görülmüştür.

➤ Kısıtlanmış Boltzmann Makineleri (Restricted Boltzmann Machines) (RBM):

Sınıflandırma, bağlanım ve özellik öğrenimi işlemlerinde kullanılan boltzman makinesi giriş veri seti üzerinde olasılık dağılımlarını öğrenebilen bir sinir ağıdır.

➤ Uzun Kısa Dönemli Bellek (Long / Short Term Memory) (LSTM):

RNN'lerin dezavantajı olarak bilinen bağlam boşluklarının tahmin edilmesi ihtiyacından dolayı Hochreiter ve Schmidhuber tarafından 1997 yılında LSTM'ler ortaya çıkmıştır.

Gizli durumları hesaplamak için LSTM ağlarında bir yapı kullanılır. LSTM içerisinde hafıza hücreleri yer alır. Bu hafıza hücreleri önceki durum ile girdi bilgisini tutan hücrelerdir. Ağ mimarisi içerisinde yer alan bu hücreler hangi verinin tutulacağına ya da hangi verinin sileceğine karar verirler. Sonraki aşamada ise önceki durumu mevcut bellek ile giriş verisini birleştirirler. Böyle bir yaklaşımla uzun vadeli bağımlılıkların ortadan kaldırılarak veri dizilerinin devam ettirilmesi mümkün kılınır.

➤ Derin Oto Kodlayıcılar (Denoising Autoencoders) (DAE):

Danışmansız öğrenme yaklaşımına sahip özel bir yapay sinir ağıdır. DAE, girdi katmanındaki değerleri çıktı katmanına kopyalayan bir sinir ağıdır. Yani, sinir ağına girdi olarak verilen veriyi, çıktı katmanında tekrar oluşturur. DAE, kısaca girdi verisinin sıkıştırılmış gösteriminden en iyi özelliklerin öğrenilmesini hedefleyen bir ileri beslemeli sinir ağıdır.

➤ Evrişimsel Sinir Ağları (Convolutional Neural Networks) (CNN):

Evrişimli sinir ağları oluşturulurken görsel korteksin nörobiyolojik modelinden esinlenilerek geliştirilmiştir. Bu anlamda bu ağ yapısı, görsel nesne tanımada daha etkindir. Çok sayıda evrişim ve havuzlama katmanına sahip ileri beslemeli bir sinir ağıdır.


Bu tezde görüntü tabanlı bir sınıflandırma işlemi yapıldığı için yukarda belirtilen modellerden görüntü sınıflandırmadaki başarısıyla diğerlerinden ayrılan evrişimsel sinir ağları tercih edilerek, elma ve ayva meyvelerindeki hastalıkların tanınması sistemi gerçekleştirilmiştir.

#### **4.5. Evrişimsel Sinir Ağlar (ESA)**

İsmi evrişim katmanında alan bu ağ yapısı ilk olarak el ile yazılmış rakamları tanımak için LeCun tarafından tanıtılarak literatüre kazandırılmıştır. ABD Posta Servisi tarafından zarflarının üzerinde yazan posta kodlarını okumak için kullanılmıştır(Sağiroğlu, Beşdok, Erler,2003: 35).

Evrişimsel katmanlar daha çok özelleştirilmiş doğrusal işlemleri barındırır. Doğrusal fonksiyonlardan seçilerek belirlenen fonksiyon kullanılır ve bir katmandan az olmayacak halde matris çarpımları yerine evrişimsel işlem uygulaması yapan sinir ağları olarak tanımlanabilir(Pratt,1994 chapter:19).

Evrişimsel sinir ağları, görüntü gibi 2 boyutlu veriler için kullanımının uygun olduğu genel kanısını taşımaktadır. Bu genel kaniya evrişimsel katmanda yer alan her bir gizli evrişim filtresinin, girdisini nöron aktivasyonlarının 3 boyutlu bir çıktısına dönüştürme becerisinden varılmaktadır. Evrişimli sinir ağları oluşturulurken görsel korteksin nörobiyolojik modelinden esinlenilerek geliştirilmiştir. Bu anlamda bu ağ yapısı, görsel nesne tanımada daha etkindir. Şekil 4.4 'de evrişimli ağlarının katmanları gösterilmiştir(Goodfellow, Bengio, Courville, 2016:9).



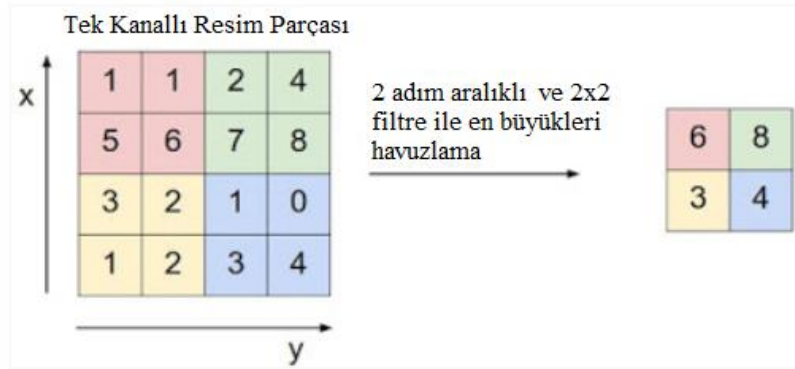
Şekil 4.4 Evrişimli ağlarda bilgisayar mimarisi katmanları

ESA mimarileri temelde beş katmandan oluşan modellemelerden ibarettir. Bu katmanlar sırası ile giriş, evrişimsel katman, havuzlama, tam bağlı katman ve çıktı katmanlarıdır(S. University,2020).

**Giriş Katmanı:** İsminden anlaşılacağı üzere ESA 'nın ilk katmanını oluşturulur. Girdi herhangi bir işlemde geçmeden ağa verilir.

**Evrişim Katmanı:** Izgara benzeri bir topolojide girdilerin evrişim adı verilen matematiksel işlemde geçirildiği katmandır. Doğrusal olan evrişim işlemi ile girdilerin bölgesel örüntüleri öğrenilir. Bu sayede bir resmin sol alt köşesinde öğrendiği bir örüntüyü farklı bir yerde konumlandığı zaman yeniden eğitilmeden tanıyabilir.

**Havuzlama Katmanı:** Bu katmanda kanal sayısı sabit tutulur. Belirlenen filtreler içerisindeki piksellerin maksimum değerleri veya ortalaması alınarak yükseklik ve genişlikte boyut küçülmesi yapılır. Bu işlem bilgi kaybına yol açar ancak az katsayıyla işlem yapmak hesaplama yükünü azaltır ve evrişim katmanlarını her seferinde daha büyük pencerelere bakması sağlanmış olur(Wang ve Raj, 2017).



Şekil 4.5 4x4 boyutunda bir görselde 2x2 boyutunda bir filtre ile görüntü işleme biçimi

**Tam Baęlı Katman:** Bu katmanda her giriş tüm nöronlara baęlı olduęu için tam baęlı katman denir. Genelde modelin sonlarına doęru konularak sınıf tahminlerini optimize etmek için kullanılır.

**Çıktı Katmanı:** Bu katman sınıflandırmanın olduęu katmandır. Genellikle sınıflandırmada başarılı olan softmax aktivasyon fonksiyonu tercih edilir. Kaç sınıf varsa o kadar çıkış deęeri vardır.

Evrışimsel sinir aęları için tasarlanabilecek birçok farklı modelden bahsetmek mümkündür. Model seçimi, problemin çözülmesinde önemli bir etken olarak kabul edilmektedir. 2 Boyutlu görüntülerin ayırt edilmesi amacı ile tasarlanmış ve başarısı kanıtlanan pek çok model bulunmaktadır. Temelde yer alan katmanların farklı kombinasyonlarla dizilimi, girdi ve çıktı katmanları hariç tutularak, farklı mimari modellerin tasarlanmasına imkan tanımaktadır. İnternet ortamında bulunan resimlerin toplanıp etiketlenmesiyle oluşan 1000 kategoride yaklaşık 1.4 milyon görüntüyü barındıran ImageNet veri seti üzerinde 2012 yılında düzenlenen Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC) birinci olan AlexNet, derin öğrenmeyi daha da yaygınlaştırmış aynı zaman ESA yapılarının görüntü tanımda ki başarısını kanıtlamıştır(Krizhevsky, Sutskever ve Hinton, 2012: 1099; Ganatra ve Patel, 2018).

Elma ve ayva hastalıklarının yüzeysel görünümlerinden tespiti amaçlı tanınmasında, derin öğrenmenin yaygın olan üç yöntemi de kullanılmıştır. Bu yöntemler sırasıyla problemin çözümüne yönelik bir modelin oluşturularak eğitilmesi, önceden eğitilmiş modelin aktarımlı öğrenme yolu ile yeni verilerle eğitilmesi ve derin öğrenme modelinin yalnızca öznelik çıkartılması sağlanarak geleneksel makine öğrenme yöntemleri ile sınıflandırılması yöntemleridir.

#### **4.6. 10 Katmanlı ESA Yapısı**

Oluşturulan ESA(CNN) yapısının giriş katmanına 50x50 piksel boyutunda rgb görüntüler verilmiştir. Birinci evrişim katmanında 2x2 boyutunda 16 adet filtre kullanılmıştır. İkinci evrişim katmanında 5x5 boyutunda 32 adet filtre kullanılmıştır. Üçüncü evrişim katmanında 5x5 boyutunda 64 adet filtre kullanılmış ve her evrişim katmanından sonra en büyükleri havuzlama katmanlarına koyulmuştur ve

düzleştirme işlemi yapıldıktan sonra iki tam bağlantılı katman eklenerek model oluşturmuştur. Son katmanda aktivasyon fonksiyonu olarak sınıflandırma için uygun olan softmax fonksiyonu seçilmiştir. Diğer katmanların aktivasyon fonksiyonları ReLu fonksiyonudur. Eniyileme algoritması olarak Stochastic gradient descent (SGD) kullanılmıştır. Aşırı uydurmayı önlemek için bırakma(dropout) tekniği uygulanmıştır. Bu teknikten kısaca değinirsek;

Bırakma, Sinir ağlarında ezberlemeyi engelleyen en etkin ve yaygın tekniktir. Eğitim esnasında o katmanın öğrendiği bilginin bir bölümü rastgele sıfır yapılıır. Amaç eğitim esnasında nöronlara bağımsızlık kazandırılarak ağırlıkların daha iyi eğitilmesini sağlamaktır.

#### **4.7. Aktarımlı Öğrenme**

İnsanlar bir alanda öğrendikleri tecrübeleri, benzer özelliklerdeki başka bir problemi çözümünde kullanırlar. Örneğin araba sürmeyi öğrenmiş bir birey tecrübelerinden faydalanarak kamyon sürmeyi daha kolay öğrenir. Bu kapsamda yapay sinir ağlarında bilgi ya da tecrübe eğitilen modelin ağırlık ve sapma değerlerinde saklanmaktadır. Belli bir alanda eğitilmiş bir modelin o alana benzer probleminde tamamen ya da kısmen yeniden eğitilmesine aktarımlı öğrenme (transfer learning) denir. Sonuçta daha önce eğitilmiş modelin, eğitilmemiş bir modele göre daha hızlı öğrenmesi ya da daha yüksek başarı elde etmesi beklenir. Bu sayede görüntü dünyası için anlamlı özellikler sunarak eğitilen sınıflardan tamamen farklı bir problem daha az veri ile çözülebilir. Bu çalışmada da bu yöntemden faydalanılarak, sınıfların çoğu hayvanlar ve günlük hayatta kullanılan nesnelere oluşan ImageNet veri setini sınıflandırmada başarılı olmuş ve birbirlerine göre farklı mimarilere sahip olan VGGNET, Inception ve ResNet ESA modelleri kullanılmıştır.

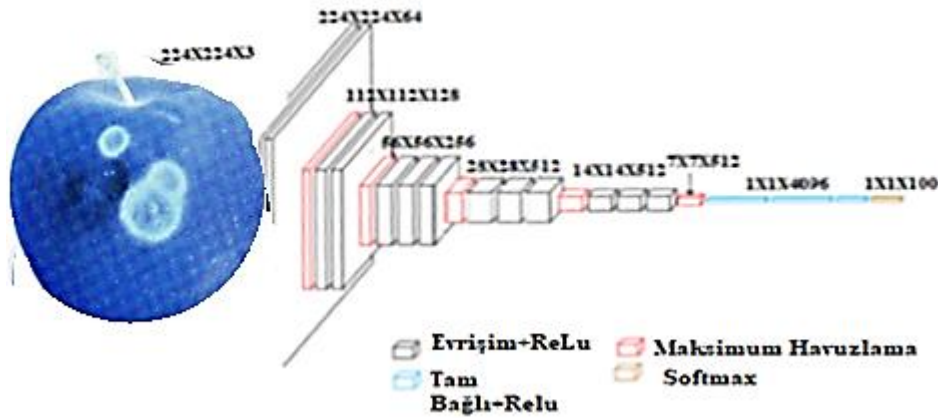
##### **4.7.1. VGG16**

VGG16, 2014 yılında ILSVR (Imagenet) yarışmasını kazanmak için kullanılan bir evrişimli sinir ağı (ESA) mimarisidir. 2014 yılındaki yarışmada başarılı olan VGGNet evrişimli sinir ağı yapısı Simonyan ve Zisserman tarafından geliştirilmiştir. 16 katmandan oluşan çok düzgün bir yapısı vardır. Mimari olarak AlexNet benzemektedir Bugüne kadar üretilmiş mimariler arasında mükemmel

vizyon modeli mimarisinden biri olarak kabul edilmektedir. Ağ yaklaşık olarak 138 milyon parametreden oluşmaktadır.

VGG16 ile ilgili en eşsiz şey, çok sayıda hiper parametreye sahip olmak yerine, tek adımda 3x3 filtrenin konveksiyon katmanlarına sahip olmaya odaklanmasıdır. Diğer taraftan VGG16 yapısında, evrişim ve maksimum havuz katmanları tüm mimari boyunca tutarlı bir şekilde 2x2 filtrelerde 2 adımlı olmak aynı dolgu ve en büyüklüğü havuzlama katmanının kullanılmış olmasıdır. Son katmanda ise tamamen bağlı katmanlar olan 2 tam bağlı katmanı ve ardından çıktı için bir Softmax kullanılmıştır. VGG16, ağırlıkları olan 16 katmanı olduğunu ifade eder. Bu ağ oldukça büyük bir ağıdır ve yaklaşık 138 milyon (yaklaşık) parametreye sahiptir.

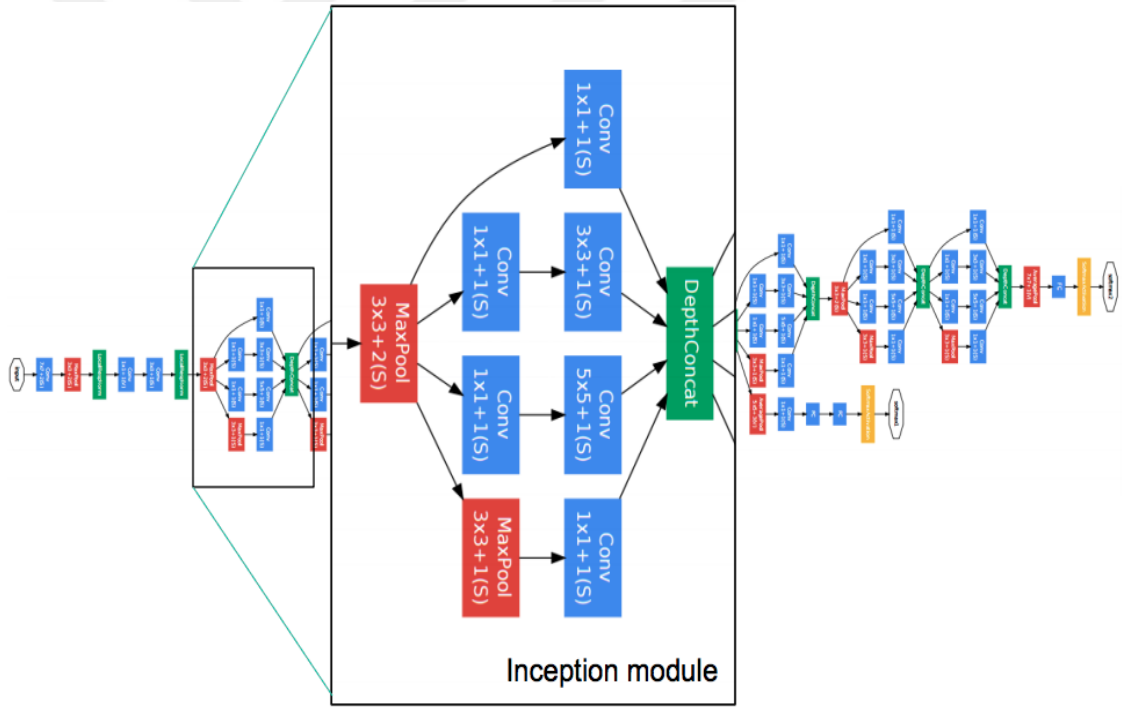
Şekil 4.6.'dan da anlaşılacağı üzere VGG16 mimarisinde 224x224 ebatlarında bir görüntü tanıma ve sınıflandırma öğrenimi pixel bölümlenme ile sağlanır ve ağ eğitimi yapılır. Böylelikle ağımız sınıflandırmayı öğrenmiş olur ve görüntü çözümlemesinde ağın öğrenmede doğruluk payı artmaktadır.





### 4.7.2. Inception

Google ekibinden Szegedy ve ekibi tarafından geliştirilen yapı 2014' de ki ImageNet yarışmasının kazananı olmuştur. Temelinde LeNet mimarisi olan ancak yapıya ağ içinde ağ mimarisini uygulayarak başlangıç(inception) adı verdikleri yeni modül oluşturmuşlardır. Inception filminden de hatırlanacağı üzere rüya içinde rüya gibi katmanlar arasında dibe inip yukarı çıkma işlemidir. Inception mimarisinde, paralel olarak birbirine bağlı katmanlar kullanılmıştır. Bu da parametre sayısını oldukça düşürmüştür (yaklaşık 4 milyon). Parametre sayısındaki düşüğe bağlı olarak, bellek kullanımı ve performans arttırmada avantaj sağlamıştır. Modelin yapısı Şekil 4.7'de gösterilmiştir.




Şekil 4.7 Inception mimarisine sahip iç içe ağların gösterimi

### 4.7.3. ResNet50

Microsoft ekibinden Kaiming He ve arkadaşları tarafından geliştirilen artık sinir ağ mimarisi 2015 yılındaki ImageNet yarışmasında hata oranını %3.57 ye düşürerek başarılı olmuştur. 152 katmandan oluşan yapı yaklaşık 23 milyon

parametreye sahiptir. ResNet50 görüntü tanıma ve sınıflandırmalarında sıkça kullanılan bir mimaridir. ResNet50 mimarisi de diğer öğrenme ağı mimarilerinde olduğu gibi derin ağ öğrenmelerindeki tıkanıklığı iyileştirme amacı gütmektedir. Bu bilgisayar mimarisi, yenilenen sinir ağlarına benzeyen yapısı ile, girişin “*artık*” bir değer olarak sonraki iki evrişimli katmanın çıkışına beslenmesi prensibi ile çalışmaktadır. Şekil. 4.8’te ResNET mimarisi için hizmet eden “artık” fonksiyon yapı taşı ve ResNET50 mimarisinde darboğaz oluşumu yer almaktadır. Artık değer fonksiyonunun kullanılması ile ImageNET yarışmasında başarısını kanıtlamıştır ( Targ, Almeida, Lyman, 2016).



Şekil 4.8 Bir ResNet mimarisi için daha derin bir artık fonksiyon ( $56 \times 56$  özellik haritalarında) yapı taşı ve ResNet-50 için bir “darboğaz” yapı taşının gösterimi

## 5. ELMA VE AYVA HASTALIKLARI TANILAMASI VERİ SETİ OLUŞTURULMASI

### 5.1. Kullanılan Yöntem ve Materyal

Gerçekleştirilen tez çalışması üç temel bölümden oluşmaktadır. Birinci kısımda bilgisayara bağlı webcam ile veri setinin oluşturulması ikinci olarak sistemin seçilen meyve hastalıklarını tanıyabilmesi için farklı modellerin geliştirilip eğitilmesi sınıflandırması ve başarısının değerlendirilmesidir. Son aşamada bunu bir program yazılarak kameraya gösterilen görüntünün ekrana gerçek zamanlı metin olarak yazdırılması amaçlanmaktadır. Bu kapsamda kullanılan materyal bilgileri şu şekildedir:

Oluşturulan sistemde görüntü işleme teknikleri kullanılarak makine öğrenmesi yöntemiyle görüntü sınıflandırmasında eğitilmiş bir modelin, Yapay Sinir Ağları (YSA) yöntemi kullanılarak sınıflandırılmadaki iyileşmenin sağlanması hedeflenmiş, sistem eğitimi tamamlandığında, JetBrains PyCharm Community Edition 2019 1.1 Intel® Core™ i7 -8750h CPU @ 2.20 Ghz ve 16,00 GB RAM'e sahip Nvidia GTX 1050 ti Ekran Kartı ve Microsoft Windows 10 Home x64 bit işletim sistemli bilgisayar üzerinde geliştirilmiştir.

Diğer programlama dillerine nazaran program kodunu en az çaba ile ve hızlıca yazmaya imkân tanınması nedeni ile Python dili seçilmiş ve JetBrains PyCharm Community Edition 2019 1.1 ortamında TensorFlow arkauç motorunu kullanarak çalışan keras kütüphanesi kullanılarak yazılım gerçekleştirilmiştir.

Bu çalışma bir kişisel dizüstü bilgisayarında yazılan kodlar ve dizüstüne tümleşik bağlı olan bir web kamerasından oluşmaktadır. Kameranın özellikleri Tablo 5.1.'de yer verilmiştir. Gerçekleştirilen çalışmada Galaxy J7 Pro kamerası ile halden alınan hasarlı elma ve ayvalardaki hastalıkların karşılığını doğru olarak tanıyıp; daha sonra PC kamerası aracılığıyla ekrana gösterilen meyvenin tanımlanan hastalık sınıflarından hangisine benzediği yönünde eşleştirme yaparak metin haline dönüştürmek için bir Python programı yazılmıştır.

Tablo 5.1. Kullanılan WebCam' in genel özelliklerinin gösterilmesi

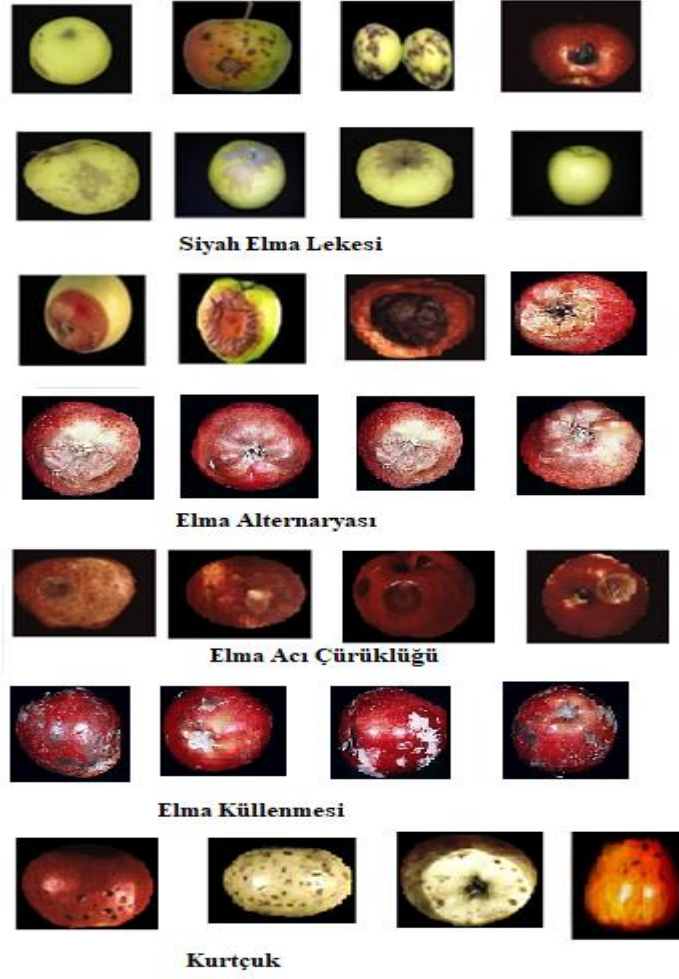
Kamera Model	Front- Facing 720p kamera
Ön kamera çözünürlüğü	1 MP
Ön kamera sinyal formatı	720p
Ön kamera HD türü	HD

## 5.2. Veri Setinin Oluşturulması

Elma ve ayva hastalıklarını içeren veri seti siyah arka planda alınan görüntülerle oluşturulmuştur. Veri setinde bulunan görüntüler, bilgisayara bağlanabilen Galaxy J7 Pro kamerası ile çekilmiş ve PC yazılımında tanınması için web kamerası yardımıyla iki farklı zamanda (gece-gündüz) elde edilen görüntülerin doğru sınıflandırması için kullanılmıştır. Çekim esansında, aynı ışığın kullanılmasına özen gösterilmiş ve çekimler için siyah arka fon için tüm çekim boyunca aynı siyah renk örtü kullanılmıştır.

Birinci aşamada üç farklı bireyden alınan her bir sınıf için yaklaşık 150 adet görüntü kullanılarak toplam 7 sınıftan oluşan 1050 resimden oluşan bir veri seti oluşturulmuştur. Bunlar 2 adet ayva ve 5 adet elma hastalığından oluşmaktadır.

Bu hastalıklardan elma üzerinde görülenleri; elma alternaryası, elma kara lekesi, elma küllenmesi, elma acı çürüklüğü, elma kurtçuğudur. Ayva üzerinde görülen hastalıklar ise; kahverengi ayva çürüklüğü ve mavi ayva küfü hastalıklarıdır.



Şekil 5.1 Veri kümesinde yer alan Elma Hastalıklarına ait 5 sınıf için renkli görüntüler



Şekil 5.2 Veri kümesinde yer alan Ayva Hastalıklarına ait 2 sınıf için binary görüntüler

### 5.3. Veri Setini Çeşitlendirme - 1

Aşırı uydurmayı önlemek için yapılan veri çeşitlendirme yönteminde amaç eldeki verilerden birtakım dönüşümler ile gerçeğe yakın daha fazla eğitim verisi oluşturmak böylece eğitim esnasında modelimiz aynı resmi ikinci kez görmemesini sağlamaktır. Bu da modelimizin daha çok örüntü aramasını ve daha iyi genelleştirmesini sağlar.


Çalışmada öncelikle her sınıf görüntü için 150 adet fotoğrafa gürültü(noise), karşıtlık(contrast) ve bulanıklık(blur) işlemleri yapılmış ve her sınıf için 150 adet olan görüntü sayısı 450'ye çıkarılmıştır. Çalışma sırasında bulanıklık (blur) işlemi için, dönme eksenini kullanılmıştır. Şekil 5.3' de elma alternaryası hastalığının gerçek gürültü eklenmiş ve Şekil 5.4' de ise elma küllenmesi hastalığının gerçek ve karşıtlık işlemi eklenmiş Şekil 5.5.'te ise elma kurtçuğu hastalığına bulanıklık işlemi yapılmıştır.



Şekil 5.3 Elma alternaryası hastalığının gerçek ve gürültü eklenmiş görüntüleri



Şekil 5.4 Elma küllenmesi hastalığının gerçek ve karşıtlık eklenmiş görüntüleri



Şekil 5.5 Elma kurtçuğu gelişimine elverişli noktaları gösterir larva izlerinin gerçek ve bulanıklık eklenmiş görüntüleri

#### 5.4. Veri Setini Çeşitlendirme - 2

İkinci aşamada sistemin örüntüyü farklı açılardan ve konumlardan çıkarabilmesi için keras kütüphanesinin sağladığı ImageDataGenerator sınıfını kullanarak rastgele dönüşüm parametreleri ile veriyi çeşitlendirdik. Her sınıf için 450 olan görüntü sayısını böylece 900'e çıkarmış olduk. Uygulanan işlemler Tablo 5.2' de yer verilmiştir.

**Tablo 5.2.** Veri çeşitlendirme işlemleri

<b>İşlem Adı</b>	<b>Değer</b>	<b>Açıklama</b>
Görüntü Döndürme Aralığı	15	Görüntüyü en fazla 15 olacak şekilde sağa sola döndürme işlemidir.
Görüntüyü uzay düzlemde X ekseninde Kaydırma Aralığı	0.1	Yatay ekseninde kaydırma
Görüntüyü uzay düzlemde Y ekseninde kaydırma aralığı	0.1	Dikey ekseninde kaydırma
Kesişme Noktası Aralığı	0.2	Burkma işlemi
Yakınlaştırma Aralığı	0.1	Yakınlaşma işlemi
Görüntünün Dikey Eksende Yatay Simetrisinin Alınması	True	Resmin dikey ekseninde simetriği

Yukarıdaki değerleri seçerken görüntünün tamamen bozulmaması için uygun değer seçilmeye çalışılmıştır. Örneğin döndürmede işlemde 15 dereceden fazlası görüntüyü farklı bir meyve hastalığı yorumlayabilir ya da yatay ekseninde simetrik alınması işlemi yapılsaydı farklı bir hastalık ortaya çıkarırdı.

### 5.5. Veri Setinin Genel Özellikleri

Veri çeşitlendirme işlemlerinden sonra her bir sınıf için 900 görüntü, toplamda da her biri 7 sınıftan oluşan veri setimizde  $7 \times 900 = 6300 \times 2 = 12600$  görüntü bulunmaktadır. Veri setinin 5/6 eğitim 1/12' si doğrulama ve 1/12' si de test için ayrılmıştır.

Veri setinin genel özellikleri Tablo 5.3' de belirtilmektedir.

**Tablo 5.3.** Veri setinin genel özellikleri

<b>Toplam Sınıf Sayısı</b>	<b>7</b>
Her Sınıf İçin Kaydedilen Görüntü Sayısı	900
Veri Setindeki Toplam Görüntü Sayısı	12600
Değişkenler	Gürültü, Işık, Yön, Uzaklık, Karşıtlık
Sınıfların Ortalama Dosya Büyüklüğü	16mb-22mb
Veri Seti Dosya Büyüklüğü	290 MB
Toplam Veri Seti Oluşturma Süresi	13-15 saat



Son olarak resimler yeniden boyutlandırılarak 50x50 formatta ayrı bir veri seti oluşturulmuştur. Tablo 5.4' te iki farklı görüntünün de özelliklerine yer verilmektedir.

**Tablo 5.4.** İki farklı veri setinin görüntü özellikleri

<b>Boyutlar</b>	<b>50 x 50</b>	<b>224 x 224</b>
Genişlik	50 piksel	224 piksel
Yükseklik	50 piksel	224 piksel
Yatay Çözünürlük	96dpi	96dpi
Dikey Çözünürlük	96dpi	96dpi
Bit Derinliği	24	24



## 6. ARAŞTIRMAYA İLİŞKİN BULGULAR

### 6.1. Araştırmaya İlişkin Bulgular


Modeller 16 Gb Ram, Intel I7 işlemci dizüstü bilgisayarda NVIDIA GeForce GTX 1050-Ti ekran kartı üzerinde test edilmiştir. Donanım kısıtlarına bağlı olarak yığın miktarında 200 den daha fazla üzerine çıkılmadığından tüm derin öğrenme modellerinde yığın miktarı (batch size) 150 seçilmiştir. Uygulanan derin öğrenme yöntemlerinde çok fazla sayıda parametre bulunmaktadır ve bu nedenle tüm parametreler için eniyileme yönteminin uygulanması çok zaman almaktadır. Literatür incelendiğinde ve birkaç elle deneme sonucunda epok sayısının başarıyı bir hayli etkilediği gözlenmiştir. Bundan dolayı bu tez çalışması kapsamında diğer parametreler sabit tutulduğunda en uygun epok sayısının tüm yöntemlerde belirlenmesi için bir analiz yapılmıştır. En uygun epok sayısı literatürde sıklıkla kullanılan 15, 30 ve 45 sayıları arasında aranmıştır.

#### 6.1.1. 10 Katmanlı ESA yapısını kullanarak başarımların değerlendirilmesi

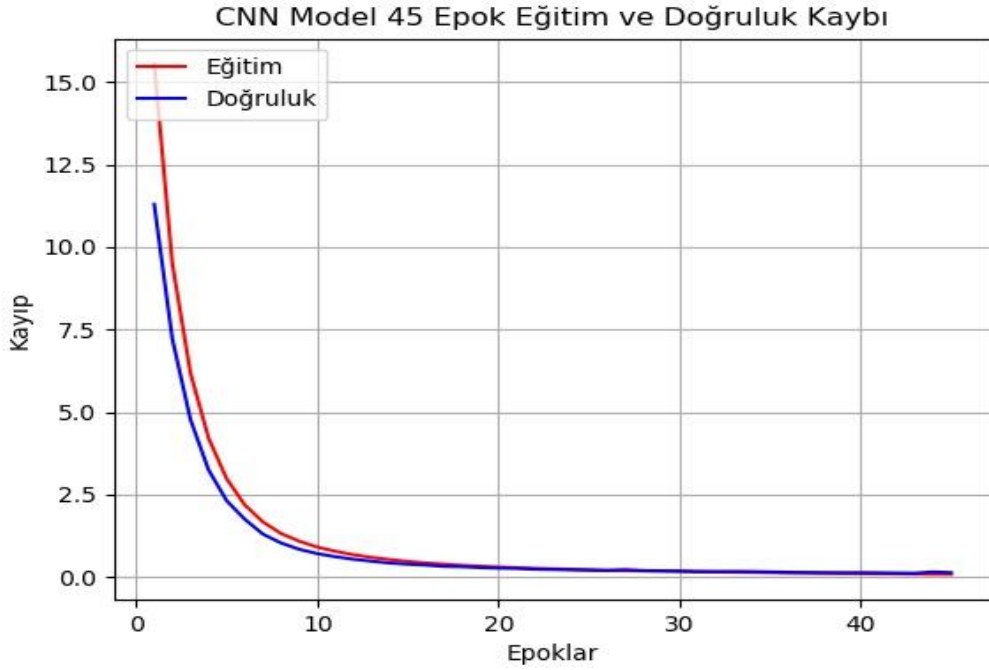
Bu tez çalışması kapsamında oluşturulan ESA mimarisinde epok sayısının değişimine göre kayıp ve başarımların değişimi incelenmiş ve uygun bir epok sayısı seçilmeye çalışılmıştır. Tablo 6.1. 'e göre en başarılı sonuç 45 epokta elde edilen %88' lik başarıdır. Epok sayısının 45 seçilmesi durumunda elde edilen kayıp ve başarımlar grafiği Şekil 6.1 ve Şekil 6.2'de verilmektedir.

**Tablo 6.1.** 10 Katmanlı ESA (CNN) için farklı Epok sayılarında elde edilen sonuçlar

Epok	Resim Boyutu	Yığın Boyutu	Zaman	Kayıp ve Başarımlar
15	50x50	150	0:00:43	Kayıp:0.3111-Başarımlar: 81.7500%
30	50x50	150	0:01:08	Kayıp:0.0773-Başarımlar: 87.8125%
45	50x50	150	0:01:41	Kayıp:0.0430-Başarımlar: 88.6250%



Şekil 6.1 10 katmanlı ESA'nın başarıım grafiği



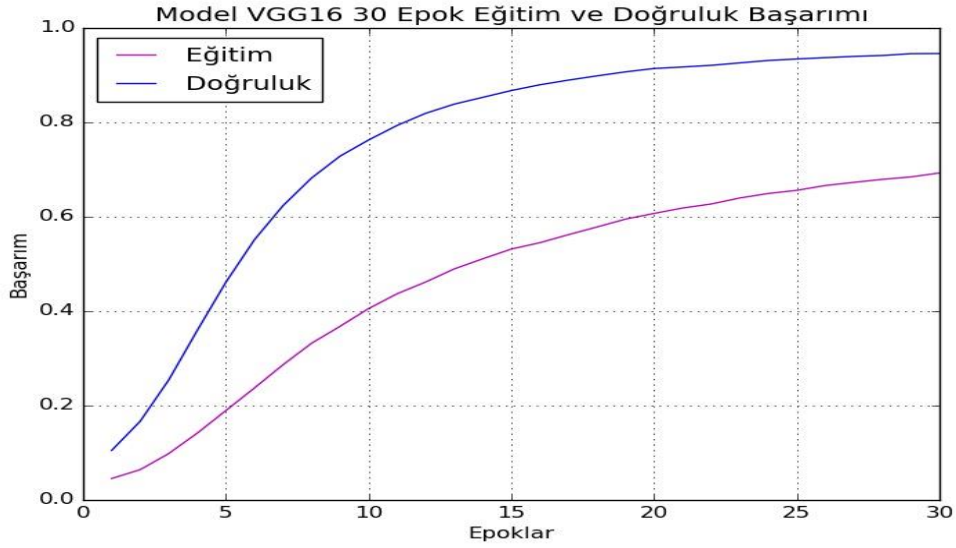
Şekil 6.2 10 katmanlı ESA'nın kayıp grafiği

### 6.1.2. Öğrenme aktarımı ile VGG16 kullanarak başarımların değerlendirilmesi

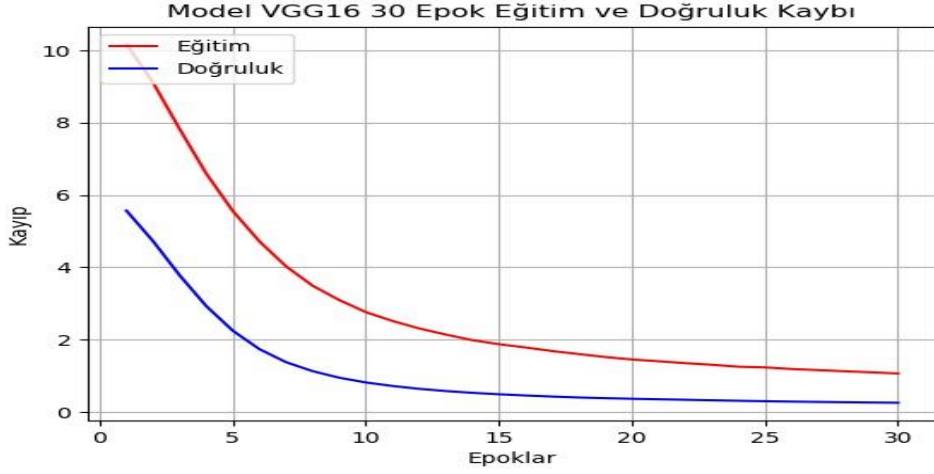
Öğrenme aktarımı ile katsayıları hazır alınmış VGG16 mimarisine sahip ESA'da en uygun epok sayısını bulmak için incelemeler yapılmıştır. Tablo 6.2'ye göre en yüksek başarımlar oranı 45 epokta elde edilen %86'lık oran olsa da 30 epokta elde edilen sonuca göre yaklaşık 45 dk. daha yavaş olduğundan ve iki sonuç arasından yaklaşık %2'lik az bir fark olduğundan en uygun epok sayısı 30 olarak kabul edilmiştir. Bu sonucun kayıp ve başarımlar grafiği Şekil 6.3 ve Şekil 6.4'de verilmiştir.

**Tablo 6.2.** VGG16'nın farklı epok sayılarında elde edilen sonuçları

Epok	Resim Boyutu	Zaman	Kayıp ve Başarımlar
15	224x224	0:46:37	Kayıp:0.4652-Başarımlar: 83.7500%
30	224x224	1:32:22	Kayıp:0.2502-Başarımlar: 84.6250%
45	224x224	2:17:34	Kayıp:0.1871-Başarımlar: 86.8125%



Şekil 6.3 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen VGG16 mimarisinin başarımlar grafiği



Şekil 6.4 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen VGG16 mimarisinin kayıp grafiği

### 6.1.3. Öğrenme aktarımı ile Inceptionv3 kullanarak başarımların değerlendirme

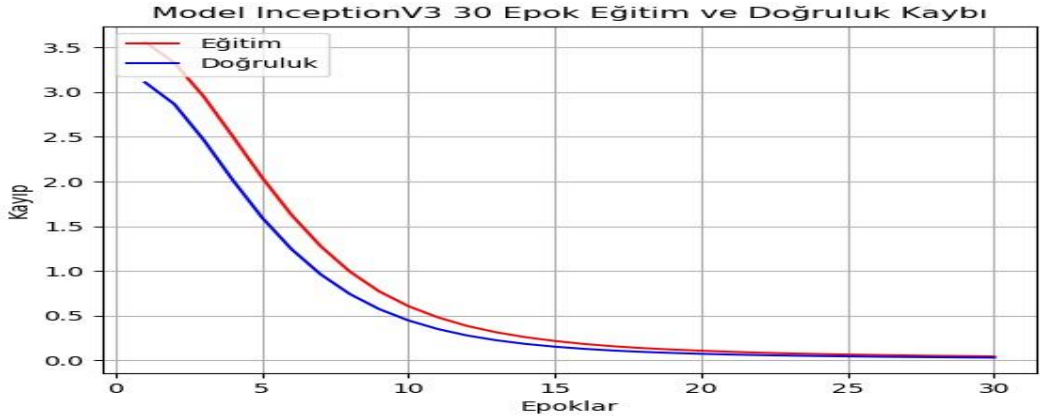
Öğrenme aktarımı ile ESA’da InceptionV3 mimarisi kullanıldığında en uygun epok sayısı için incelemeler yapılmıştır. Tablo 6.3’e göre başarımların oranları aynı olan 30 ve 45 epok sayılarına göre daha kısa süreye sahip olan 30 epokta elde edilen sonuç en başarılı kabul edilmiştir. Bu sonucun kayıp ve başarımların grafiği Şekil 6.5 ve Şekil 6.6’de verilmiştir.

**Tablo 6.3.** InceptionV3’ ün farklı epok sayılarında elde edilen sonuçları

Epok	Resim Size	Zaman	Kayıp ve Başarımlar
15	224x224	0:34:23	Kayıp:0.1240-Başarımlar: 82.4%
30	224x224	1:07:40	Kayıp:0.0294-Başarımlar: 89.7500%
45	224x224	1:37:58	Kayıp:0.0238-Başarımlar: 89.7500%



Şekil 6.5 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen InceptionV3 mimarisinin başarımları grafiği



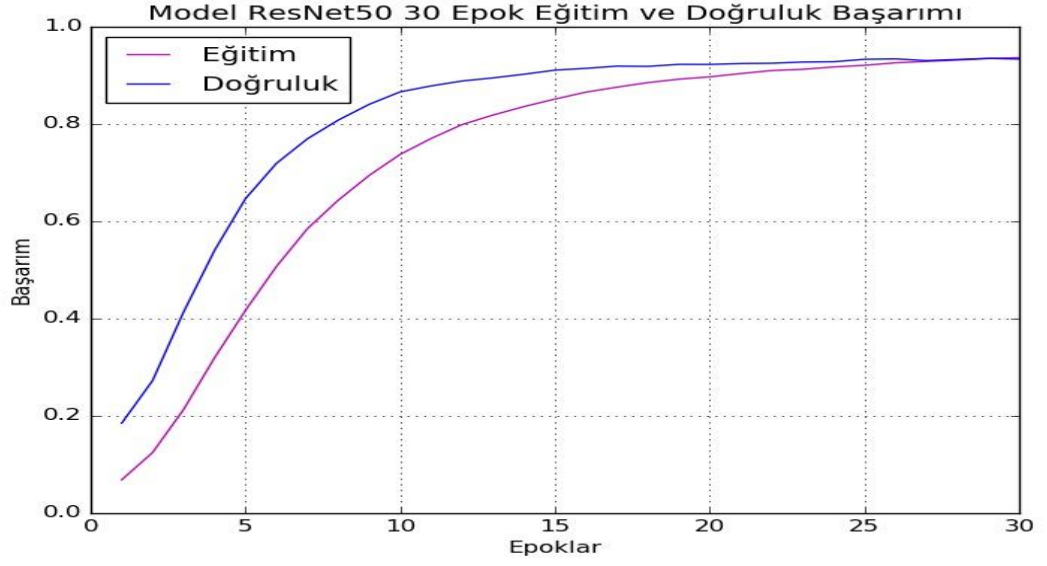
Şekil 6.6 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen InceptionV3 mimarisinin kayıp grafiği

#### 6.1.4. Öğrenme aktarımı ile ResNet50 kullanarak başarımları değerlendirme

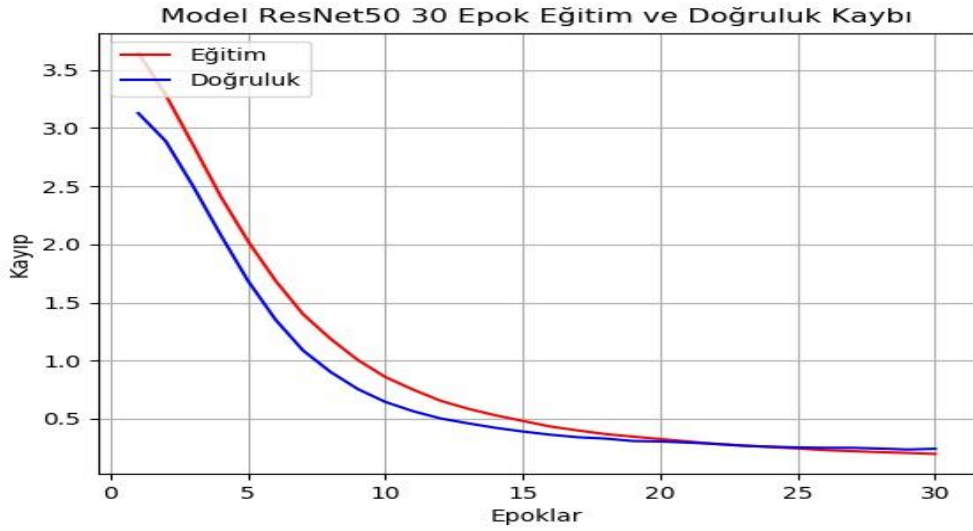
Tablo 6.4'e göre en yüksek başarımları oranı 45 epokta elde edilen %85,5'lik oran olsa da 30 epokta elde edilen sonuca göre yaklaşık 42 dk. daha yavaş olduğundan ve iki sonuç arasından yaklaşık %2 lik az bir fark önemsenmeyip en uygun epok sayısı 30 olarak belirlenmiştir. Bu sonucun kayıp ve başarımları grafikleri Şekil 6.7 ve 6.8 'de verilmektedir.

**Tablo 6.4.** ResNet50' nin farklı epok sayılarında elde edilen sonuçları

Epok	Resim Boyutu	Zaman	Kayıp ve Başarım
15	224x224	0:34:30	Kayıp:0.3658-Başarım: 80.8125%
30	224x224	1:24:16	Kayıp:0.2480-Başarım: 83.1875%
45	224x224	2:06:09	Kayıp:0.1725-Başarım:85.4375%



Şekil 6.7 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen ResNet50 mimarisinin başarımlar grafiği



Şekil 6.8 Öğrenme Aktarımı Yöntemi ile son katmanı eğitilen ResNet50 mimarisinin kayıp grafiği

### 6.1.5. Öğrenme aktarımı kullanılarak öznitelik çıkarımı ile birlikte destek vektör makineleri ve k- en yakın komşu sınıflandırması

Vapnik Destek Vektör Makinesi algoritmalarını 1963 yılında tanıtmıştır (Vapnik, 1963: 774–778). Destek vektör makineleri (DVM), denetimli öğrenme modellerinden biridir. DVM'lerde girdi olarak verilen örneklere göre çıktı olarak neyin beklendiği etiketlenir. DVM' nin amacı, bir veri setini iki sınıfa ayıran bir hiper düzlem veya bir karar yüzeyi bulmaktır (Akinsola, J.E.T. , 2017: 132).

Hiper düzlemi belirleyen veri noktalarına "destek vektörleri" denir (Huang ve diğerleri, 2017: 47). Veri noktalarını iki sınıfa ayıran birçok olası hiper düzlemin olması mümkündür. Yani, asıl amaç n-boyutlu bir alanda "azami verim" e sahip bir köprü bulmaktır. Verim, iki sınıf arasındaki mesafe için hiper düzlemin boyutuna bağlıdır, bu da giriş özelliklerinin sayısı ile ilişkilidir. DVM, doğrusal olmayan modellerde iki sınıf arasındaki mesafeyi hesaplamak için "çekirdek" adı verilen bir mekanizma kullanır. Çekirdek seçimi, yerleşik DVM modelinin performansını etkiler. Doğru çekirdeğe karar vermek için en iyi yol, veri üzerindeki çekirdek işlevlerinin ayarlanarak denetlenmesini sağlamaktır. Doğrusal destek vektör makinesi, karar düzlemi sınıfları mükemmel bir şekilde +1 ve -1 düzleminde ayırır (Srivastava ve Lekha, 2010: 24).

K-NN (*K-Nearest Neighbor*) algoritması en basit ve en sık kullanılan sınıflandırma algoritmasından biridir. K-NN eğitim aşaması olmayan bir yöntemdir. Yani tembel tabir edilen bir öğrenme algoritmasıdır. Eğitim verilerini öğrenmez, bunun yerine eğitim veri kümesini "ezberler" (Chih-Min, Wei-Shui ve Bor-Wen, 2014:172).

Bir tahmin yapmak istediğimizde, tüm veri setinde en yakın komşuları arar. Dezavantajı uzaklık hesaplanırken bütün uzaklıklar saklandığı için çok büyük veride yüksek bellek alanına ihtiyaç duyar. Algoritmanın çalışmasında bir *K* değeri belirlenir. Bu değer verilen noktaya en yakın komşu sayısıdır. Uzaklık fonksiyonları ile yeni noktanın mevcut noktalara göre tek tek uzaklığı hesaplanır en yakın k-komşuların özniteliklerine göre komşuların sınıfına yerleştirilir. Uzaklık hesaplama işleminde genelde Öklid fonksiyonu kullanılır. Ancak Öklid fonksiyonuna alternatif olarak Hamming, Manhattan ve Minkowski fonksiyonları da vardır (Özarı ve Eren, 2019: 1125-1126).



**Tablo 6.5.** Öznitelik çıkarımı yapılarak elde edilen DVM ve K en yakın komşu sonuçları

<b>Model</b>	<b>Resim Boyutu</b>	<b>Zaman</b>	<b>Kayıp ve Başarım</b>
InceptionV3-DVM	224x224	0:01:07	89.5%
InceptionV3-K En Yakın Komşu (K-NN)	224x224	0:00:34	87.5%

Derin öğrenme modellerinde en başarılı modelin en düşük kayıp ve en yüksek başarımlarına ait Inception mimarisine sahip model olduğu önceki sonuçlarda görülmüş olup bu nedenle bu model ile öznitelik çıkarımı yapılmıştır. Yaklaşık 15 dakikalık bir öznitelik çıkarımı yapıldıktan sonra değerler diske kayıt edilmiştir. SVM ile K-NN makine öğrenme algoritmalarıyla sınıflandırma yapılmıştır ve başarı oranı SVM’de % 89,5 ve K-NN’de ise % 87,5 elde edilmiştir. Buradan çıkarılacak sonuçlardan biri, InceptionV3 mimarisinin, uygulanan resimlerden ayırt edici öznitelikleri iyi tespit ettiği, bu sayede klasik makine öğrenme yöntemlerinden de başarılı sonuçlar alınmıştır.

#### **6.1.6. Öznitelik çıkarımı olmadan DVM ve K- En yakın komşu ile sınıflandırma**

Bu tez kapsamında derin öğrenme yöntemlerinin başarıyı ne kadar artırdığını anlamak için klasik makine öğrenmesi yöntemleri de kullanılmıştır. Öznitelik çıkarımı olmadan ham veri ile yapılan K-NN ve SVM sınıflandırmada sınıflandırma doğruluk oranlarının sırasıyla Tablo 6. 6 da gösterildiği gibi %86,5 ve %84,6 elde edilmiştir. Ancak bu yöntemlere yüksek boyutlu veri uygulanması durumunda donanım yetersizliği yaşandığı için veri boyutu 224x224 yerine 50x50 seçilmiştir.

**Tablo 6.6.** DVM ve K en yakın komşu sınıflandırma sonuçları

<b>Model</b>	<b>Resim Boyut</b>	<b>Zaman</b>	<b>Kayıp ve Başarım</b>
DVM	50x50	0:12:49	86.5%
K En Yakın Komşu (K-NN)	50x50	0:01:47	84.6%

## 6.2. Tartışma

Tablo 6.7’de tüm uygulanan yöntemler hızları, kayıp ve başarı oranları verilmektedir. Genel olarak tüm sonuçlar değerlendirildiğinde 50x50 boyuttaki verilerde klasik makine öğrenme yöntemlerine göre kendi oluşturduğumuz CNN modeli ile zaman ve başarımlar açısından daha iyi sonuçlar elde edilmiştir. Veri sayısı arttıkça ve gürültü arttıkça derin öğrenmenin SVM ve k-NN göre daha da başarılı olacağı öngörülmektedir. Ayrıca her problem için ona özgü derin ağ modelini oluşturmak daha hızlı ve başarılı sonuçlara ulaşılacağı bu tez kapsamında anlaşılmaktadır.

30 epok eğitim sonunda öğrenme aktarımı ile hassas ayar yapılan modeller içerisinde hem başarı oranı hem de zaman olarak InceptionV3 mimariye sahip ESA modelinin daha başarılı olduğu tespit edilmiştir. Çok küçük boyutta ve çok miktarda evrişim katmanı kullanıldığı için bu ağ, parametre sayısını büyük ölçüde azaltmayı başarmıştır. Alexnet 60 milyon parametre sayısı varken burada 4 milyona düşürülmüştür, Resnet50 23milyon ve VGG16 138 milyon parametreye sahiptir. Bu değerler göz önüne alındığında InceptionV3’ün diğer modellere göre daha hızlı olması normal kabul edilmiştir.


Bu tez kapsamında derin öğrenme yöntemleri ile klasik makine öğrenme yöntemleri hibrit şekilde birleştirilerek bu problem kapsamında analiz edilmiştir. Yine yüksek başarı gösteren InceptionV3 modeli öznelik çıkarmada kullanılmış ve klasik makine öğrenmesi yöntemlerinden seçilen SVM ve k-NN yöntemleri ile sınıflandırılması ile de yüksek başarı elde edilmiştir. Bunun nedeni olarak InceptionV3 mimarisinin bu problemin ayırt edici özneliklerini çıkarmada etkili olduğu görülmektedir. InceptionV3 mimarisinin doğrudan kullanmak yerine sınıflandırmayı klasik makine öğrenmesi yöntemleri ile yapmak işlemin hızını arttıracığı tespit edilmiştir.

Derin öğrenme modellerinde InceptionV3 ve 10 katmanlı bu problem kapsamında oluşturulan ESA modelinin zaman ve başarımlar açısından en başarılı gelen modellerdir. InceptionV3 modeli Imagenet yarışmasından daha fazla veri ile eğitilmiş olduğundan farklı arka planlarda başarılı olabileceği öngörülerek 30 epokta eğitilen InceptionV3 modelinin, gerçek zamanlı meyve hastalığını görüntüden tanıma sisteminde kullanılmasına karar verilmiştir.

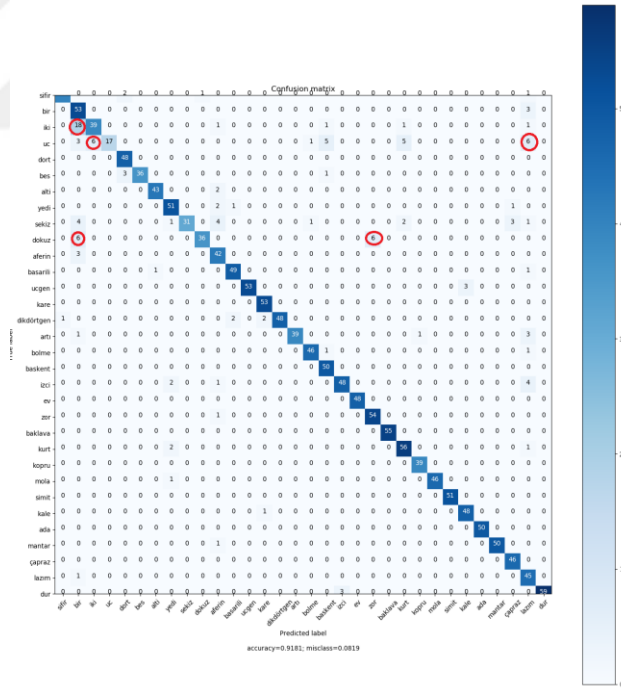
**Tablo 6.7.** Modellerin zaman ve başarımları karşılaştıran tablo

<b>Model</b>	<b>Resim Boyutu</b>	<b>Epok</b>	<b>Zaman</b>	<b>Başarımları Oranı</b>
DVM	50x50	-	0:12:49	86.5%
10-Katmanlı ESA(CNN)	50x50	45	0:01:41	88.6250%
K –NN	50x50	-	0:01:47	84.6%
InceptionV3 – K-NN	224x224	-	0:00:34	87.5%
InceptionV3 – DVM	224x224	-	0:01:07	89.5%
VGG16	224x224	30	1:32:22	84.6250%
InceptionV3	224x224	30	1:07:40	89.7500%
Resnet50	224x224	30	1:24:16	83.1875%

En yüksek ve en düşük başarımları oranına sahip Inception ve ResNet mimarilerinin, tahmin edilen değerler ile gerçek değerleri gösteren karışıklık matrisleri Şekil 6.9 ve 6.10’ da gösterilmiştir. Modelin hatalarını görmek ve incelemek için sıklıkla kullanılır. Inception yüzde yüze yakın bir oranla sadece yedi hastalık tanımlanan ayva ve elmalarda elma küllmesiyle, kara elma lekesini yanlış tahmin etmiştir. Resnet ise en çok on sekiz kez doğrusu elma küllmesi iken elma acı çürüğü olarak tahmin etmiştir. Ayrıca altı kez kara elma lekesini, elma acı çürüğü ve altı kez elma küllmesi olarak yanlış tahmin etmiştir. Karıştırılan hastalıklar birbirine yakın görünümlere sahiptir.



Şekil 6.9 InceptionV3 karışıklık matrisi



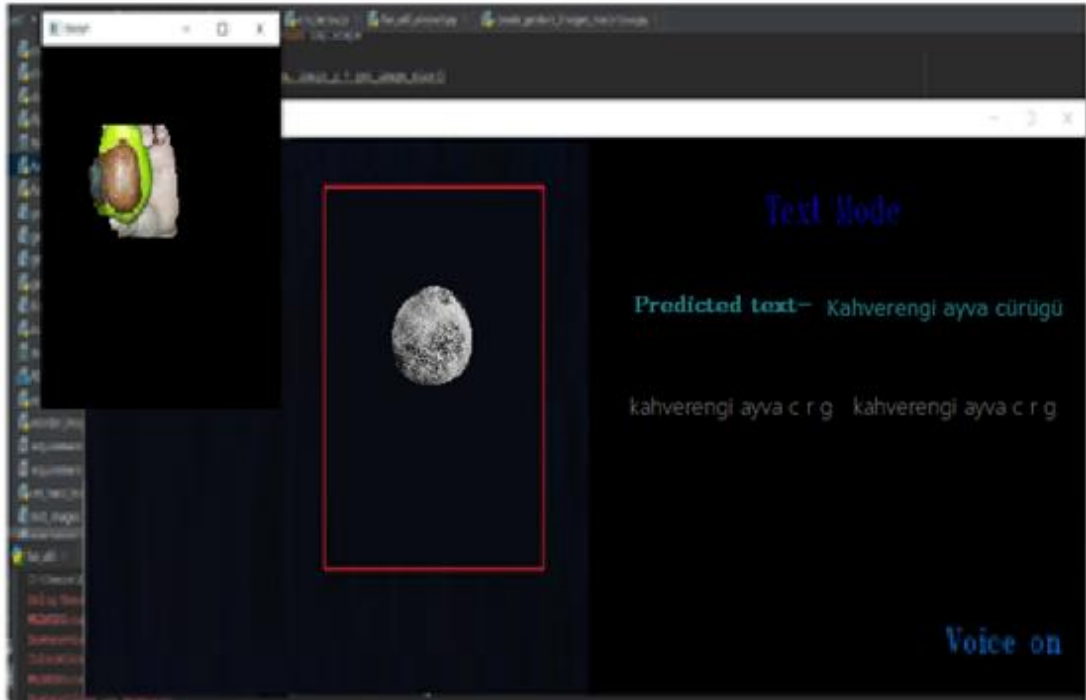
Şekil 6.10 ResNet50 karışıklık matrisi

## 7. TANIMLANAN ELMA VE AYVA HASTALIKLARININ GERÇEK ZAMANLI TEST EDİLMESİ

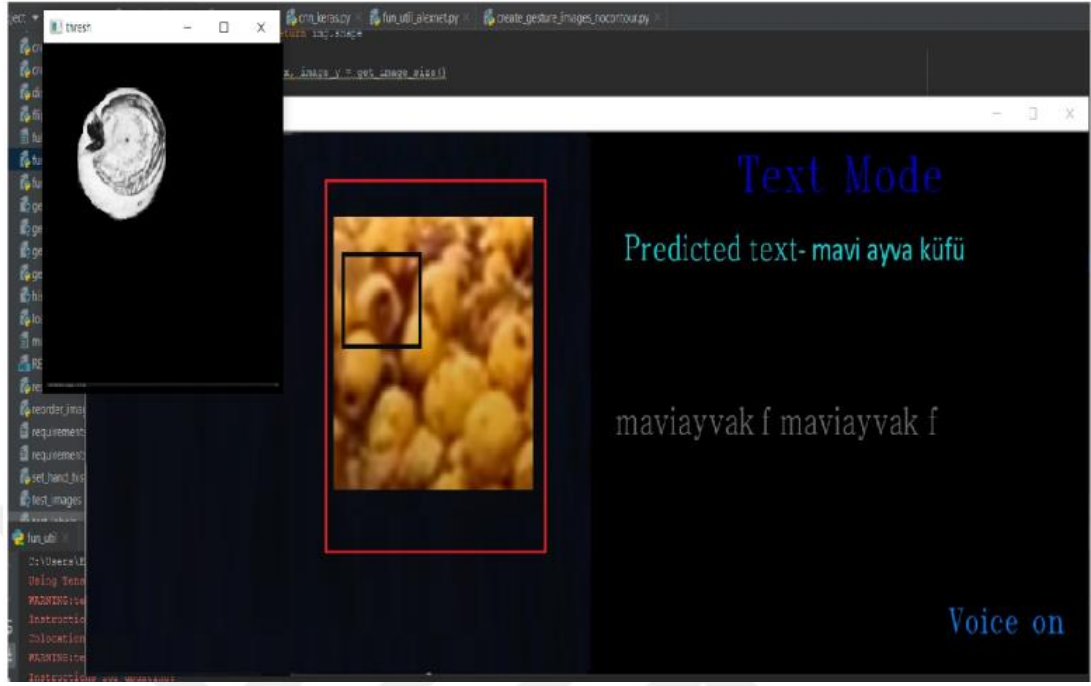
### 7.1. Çalışma Prensipleri

Şekil 7.1 , Şekil 7.2 ve Şekil 7.3' de gösterildiği gibi sistem daha önce eğitilmiş olan Inceptionv3 modelinden beslenerek tahmin yapmaktadır. Kamera önünde yeşil çerçevenin içerisinde yapılan örüntü daha önceden eğitilmiş model tarafından tahmin edilir ve güvenilirlik sınırı %70 ve üstü olarak belirtilmiştir. Tahmin kısmına tahmin edilen hastalık çeşidi yazılır. Eğer bu tahmin 20 çerçeve(frame) boyunca aynı ise tahmin edilen hastalık cinsini aşağıdaki metin alanına yazar. Burada karşılaşılan engel elma ve ayva hastalıklarının birbirine benzer şekildeki görselleridir. Elma ve ayva hastalıkları içerisinde yer alan ayva kahverengi çürük ile mavi küf çürümesi hemen hemen benzer görüntülerdir. Diğer taraftan elma alternaryası ile acı çürük yaklaşık olarak birbirine benzerdir.

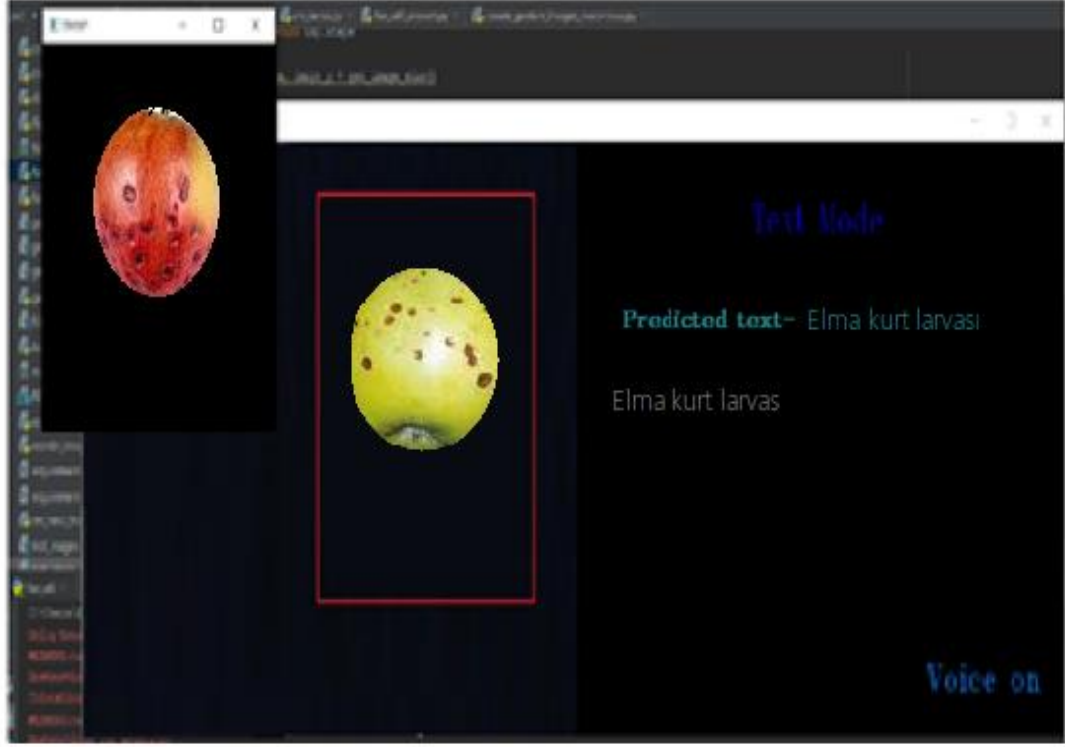
Bu benzer hastalıkların yanı sıra ayva üstten görünüm ile yeşil elma üstten görünüm de benzerlik göstermektedir. Bu benzerlik sebebiyle yeşil elmaların fazlaca kullanımı sağlanmamıştır.



Şekil 7.1 Kahverengi ayva çürüğünün bilgisayar ekran görüntüsü



Şekil 7.2 Mavi ayva küfünün bilgisayar ekran görüntüsü




Şekil 7.3 Elma kurt larvası olasılığı bilgisayar tahminini gösteren ekran görüntüsü

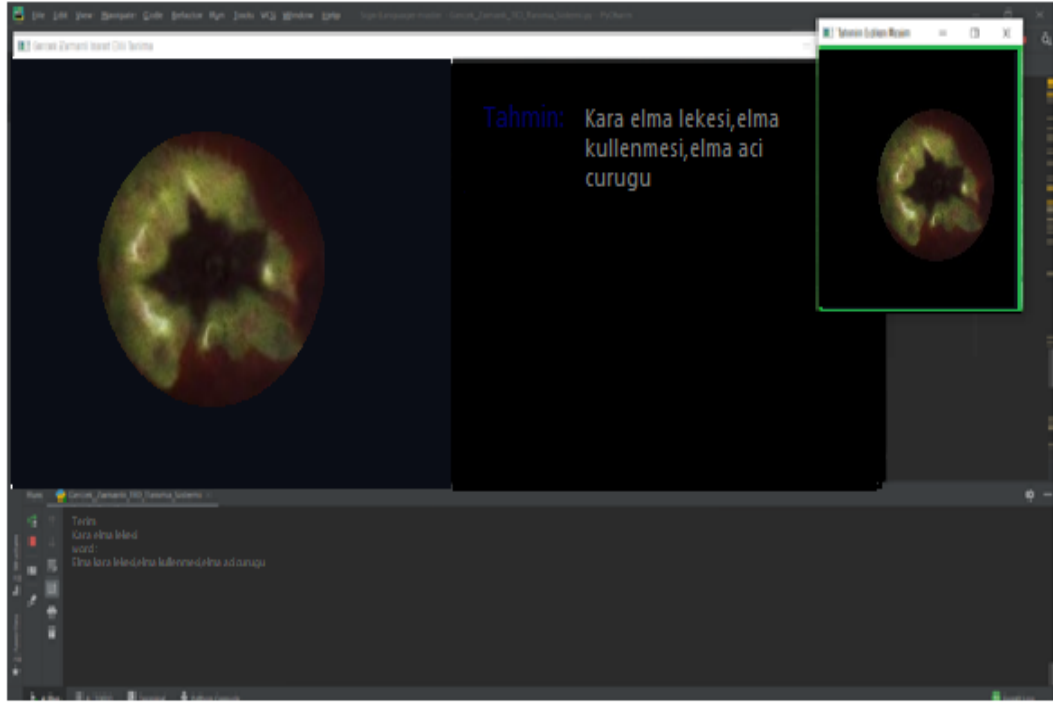
## 7.2. Gerçek zamanlı programın özellikleri

- Her kelime tahmininden sonra sistem otomatik olarak boşluk koyar, klavyeden virgül ve noktalama işaretleri koyula bilir.
- Klavyeden R tuşuna basıldığında bütün yazılanlar silinir.
- Backspace tuşu ile son yerleştirilen kelime silinir.
- Klavyeden C tuşuna basıldığında sistem kapanır.

Programın özellikleri kullanılarak Şekil 7.4'te ve Şekil 7.5'de programın özelliklerinden faydalanarak kullanılan benzer görüntüler ekranın metin kısmına yazılmıştır.



Şekil 7.4 Kara elma lekeli hastalığının görüntüden yazıya çevrilmesini gösteren bilgisayar ekran görüntüsü



Şekil 7.5 Elmanın üstten görünümü ile eşleşen tüm kelimelerin yazımını gösteren bilgisayar ekran görüntüsü



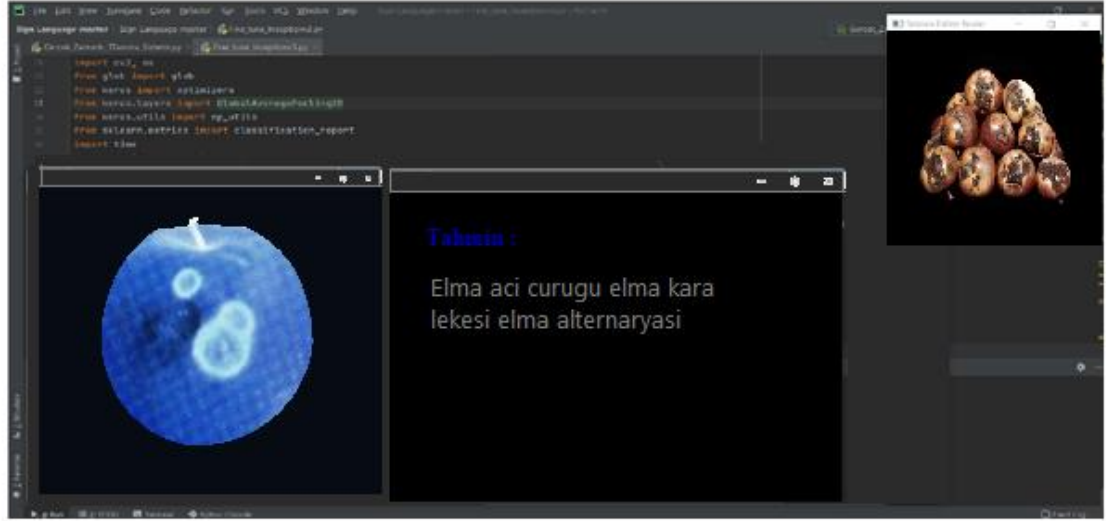
### 7.3. Sistemin Farklı Kullanıcılar Üzerinde Test Edilmesi

Eğitim veri setinde olmayan yedi farklı görüntü beş farklı arka fonda program test edilmiştir. Tablo 7.1’ de belirtilmiştir.


**Tablo 7.1.** Sistemin farklı ortamlar ve hastalıklar üzerinde test sonuçlarını gösterir

Görüntü/Ortam	Elma acı çürüğü	Elma kara lekesi	Elma Küllenmesi	Elma Alternaryası	Elma Kurtçuk Olasılığı
Ortam 1	X	✓	✓	✓	✓
Ortam 2	X	✓	✓	✓	✓
Ortam3	✓	X	✓	✓	✓
Ortam 4	✓	X	✓	✓	✓
Ortam 5	✓	✓	✓	✓	✓
Ayva Görüntüleri					
Görüntü/Ortam	Ayva mavi küfü	Ayva Kahverengi çürüğü			
Ortam 1	✓	✓			
Ortam 2	X	✓			
Ortam3	✓	✓			
Ortam 4	✓	✓			
Ortam 5	✓	✓			

Buradan elde edilen bulgu ise, sistemin elma acı çürüğü dekopajlı kümeyle ve elma kara lekesini ayırt etmekte zorlandığı tespit edilmiştir. 60 denemeden sonra 50 doğru sonuçla %83.7 oranında sistem başarısı elde edilmiştir. Farklı arka planlarda tekli ve çoklu görüntülerle yapılmış testlere ait ekran görüntülerine ise Şekil 7.6 ve Şekil 7.7’ de yer verilmiştir.



Şekil 7.6 Çoklu elma görünümünde hastalık tanısının metin alanına yazdırılan ekran görüntüsü



Şekil 7.7 Taşduvar desenli arka planda elma hastalıklarının metin alanına yazılan ekran görüntü

## 8. SONUÇ VE ÖNERİLER

### 8.1. Sonuç

Bu tez çalışmasında temel amaç elma ve ayva hastalıklarının görüntüleri kullanılarak hastalıkların sınıflandırılmasında başarılı bir şekilde tanınmasını sağlamak için derin öğrenme yöntemleri uygulanarak elma ve ayva hastalıklarının gerçek zamanlı tanınmasını gerçekleştirmektir. Bunu gerçekleştirmek için tanınacak hastalıkları sınıflandırmada derin öğrenme yöntemleri irdelenmiş ve tasarlanan sistem görüntü tanıma yaptığı için de bu alanda en başarılı sonuçları veren Evrişimsel Sinir Ağları incelenmiştir. Bu kapsamda ilk olarak bu probleme özgü tasarlanan Evrişimsel Sinir Ağıyla %88 başarı elde edilerek klasik makine öğrenme yöntemlerinden daha başarılı sonuç elde edildiği tespit edildi. Öğrenme aktarımı yoluyla farklı mimariye sahip Evrişimsel Sinir Ağları karşılaştırılmış ve bunların içinden InceptionV3 mimarisine sahip yapının yaklaşık %90 (89,75) ile en başarılı sonucu verdiği tespit edilmiştir. Bunların yanısıra yine derin ağlar ile öznetelik çıkartılarak Destek Vektör Makineleri ile sınıflandırdığında yaklaşık %90 (89,5) başarı elde edilmiştir. Tüm yöntemler zaman ve sınıflandırma başarı oranı açısından kıyasandığında, çalışma problemi olan meyve hastalıklarının elma ve ayva için en iyi yöntemin hibrit yöntem olan derin ağlarla öznetelik çıkardıktan sonra sınıflandırmak için klasik makine öğrenmesini kullanan yöntem olduğu tespit edilmiştir.

Ülkemizde meyve hastalıklarının tanınması sistemlerine ait çalışmaların az olması, ekstra bir cihaz kullanılmadığından maliyetsiz olması, ultrason gibi araçlar kullanılmadan tanıma işlemi gerçekleştirerek kullanıcı dostu olması, veri çeşitlendirme yöntemlerinden contrast, noise gibi işlemler yapılarak ve ayva hastalıklarında gray scale, elma hastalıklarında rgb görüntü kullanılarak ortamın aydınlatma şartlarından mümkün olduğunca bağımsız çalışabilmesini sağlamış olması, eğitim verilerinin doğrudan herhangi bir ön işlemde geçmeden yada bir öznetelik çıkarımı yöntemi uygulanmadan sınıflandırması bu çalışmayı özgün kılan özelliklerdir.

Sonuç olarak, bu tez çalışması kapsamında elde edilen kendi özgün verilerimiz ile oluşturulan meyve hastalıklarının tanınması ve gerçek zamanlı olarak yazılı metne dönüştürülmesinde başarılı sonuçlar alınmıştır.

## 8.2. Öneriler

1-Bu tez kapsamında yapılan webcamdan fotoğraf çeken kod sayesinde makine öğrenmesi modellerine uygun olacak şekilde yeni veriler eklenebilir. Farklı ortamlarda fotoğraf çekim gerçekleştirilebilir.

2-Mevcut çalışmada öğrenme transferi ile başka başarılı olmuş önceden eğitilmiş modellere hassas ayar yapılarak modellerin başarısı kıyaslanabilir.

3- Meyve hastalıklarının elma ve ayva haricindeki meyvelerin de eklenmesiyle daha da arttırılması ya da elma ve ayva özelinde diğer hastalıkların eklenmesi ile sınıf sayısı arttırılarak modellerin başarısı değerlendirilmeye devam ettirilebilir.

4-Meyve hastalıklarının tespitinde üretim bandı veya paketleme sistemi için kullanılan hareketli sistemler üzerinde tespit etmek için video bazlı bir tanıma sistemi yapılabilir.

5-Bu tez çalışmasında tasarlanan sistem geliştirilerek ürün henüz hasat edilmeden ve meyveler henüz tomurcuklanmadan yaprakları ile tespit edilebilir. Tüm tüketiciler için ise diğer meyve çeşitleri ile de çalışabilecek, büyük yığılda dokunmadan incelenebileceği kapsamlı bir çalışma yapılarak akıllı telefonlarda çalışabilen bir uygulama ile günlük hayatta da kullanılması sağlanabilir. Böyle bir çalışma meyve hastalıklarının engellenmesi ve üretimden nihai tüketiciye dek ekonomik zararın önlenmesinde önemli katkı sağlayacaktır.

## KAYNAKLAR

- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.
- Bishop, C., M. , (2006 ),*Pattern Recognition and Machine Learning*, Springer , ISBN: 978-0387310732. 2., Vol.: 2, pp:12-15,
- Qin, J. ve Lu, R. (2008). Uzamsal olarak çözümlenmiş hiperspektral difüz yansıtma görüntüleme tekniği kullanılarak meyve ve sebzelerin optik özelliklerinin ölçümü. *Hasat Sonrası Biyoloji ve Teknolojisi* , 49 (3), 355–365.
- Yıldız, F., Özdemir, AT, & Uluişik, S. (2019). Evaluation Performance of Ultrasonic Test in Determination of Fruit Quality. *Journal of Food Quality*, 2019. <https://doi.org/10.1155/2019/6810865>
- Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., & Liu, C. (2014). Computer vision principles, developments and applications for external quality control of fruits and vegetables: A review. *International Food Research*. Elsevier Ltd. <https://doi.org/10.1016/j.foodres.2014.03.012>
- Brosnan, T., & Sun, DW (2004). Improving the quality control of food products by computer vision - A review. *Journal of Food Engineering*. Elsevier Ltd. [https://doi.org/10.1016/S0260-8774\(03\)00183-3](https://doi.org/10.1016/S0260-8774(03)00183-3)
- Günasekaran, S. (1996). Computer vision technology for food quality assurance. *Trends in Food Science and Technology*. Elsevier Ltd. [https://doi.org/10.1016/0924-2244\(96\)10028-5](https://doi.org/10.1016/0924-2244(96)10028-5)
- Srivastava, S., Boyat, S., & Sadistap, S. (2014). A new vision detection system for tomato quality detection. *International Journal of Food Science*, 2014. <https://doi.org/10.1155/2014/184894>

- Jolly, P., & Raman, S. (2017). Analysis of Surface Defects in Apples Using Gabor Properties. In - Papers 12th International Conference on Signal Display Technology and Internet-based systems, SITIS 2016 (pp. 178-185). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/SITIS.2016.36>
- Du, CJ, and Sun, DW (2004). Recent developments in the application of image processing techniques for food quality assessment. *Trends in Food Science and Technology*, 15 (5), 230–249.
- Pathare, PB, Opara, UL, and Al-Said, FAJ (2013). Color Measurement and Analysis in Fresh and Processed Foods: A Review. *Food and Bioprocess Technology*. <https://doi.org/10.1007/s11947-012-0867-9>
- Leemans, V., Magein, H., & Destain, MF (1998). Segmentation errors in "Golden Delicious" apples using color machine vision. *Computers and Electronics in Agriculture*, 20 (2), 117–130.
- Yang, Q. (1994). An approach to apple surface feature detection with machine vision. *Computer and Electronics in Agriculture*, 11 (2–3), 249–264. [https://doi.org/10.1016/0168-1699\(94\)90012-4](https://doi.org/10.1016/0168-1699(94)90012-4)
- Wen, JZ, & Tao, Y. (1997). Density compensation for online detection of defects in fruit. In *Digital Image Processing XX Applications* (Vol. 3164, p. 474-481). SPIE. <https://doi.org/10.1117/12.292772>
- Leemans, V., Magein, H., & Destain, MF (1999). Defect segmentation in "Jonagold" apples using color vision and Bayesian classification method. *Computers and Electronics in Agriculture*, 23 (1), 43–53.
- Nakano, K. (1997). Application of neural networks to apple color grading. *Computer and Electronics in Agriculture*, 18 (2–3), 105–116.
- Zhang, Y., Wu, L., Wang, S., & Ji, G. (2015, April 1). "Principles, developments and applications of computer vision for external quality control of fruit and vegetables: A review (*Food Research International*; 2014, 62: 326-343)."

- Zhou, R., Damerow, L., Sun, Y., & Blanke, MM (2012). Using the color properties of CV. "Gala" apple fruits in an orchard in image processing to estimate yield. *Precision Agriculture*, 13 (5), 568–580.
- Morrow, C., Heinemann, P., Sommer, H., Crassweller, R., Cole, R., Tao, Y.,... Deck, S. (2019). Automatic Control of Fruits And Vegetables. *HortScience*, 26 (6), 712B - 712.
- Banot, Mrs S. and PM, Dr. M. (2016). A Fruit Detection and Grading System Based on Image Processing. *IJIREEICE*, 4 (1), 47-52.
- Burrell, A. B. 1937. Boron Treatment For A Physiogenic Apple Disease. *Amer. Soc. Hort. Sci. Proc.* 34 : 199-205.
- Butler, L. F. 1930. *Corticium Centrifugum* , A Heterothallic Pathogene Of Apples. *U. S. Dept. Agr. Jour. Agr. Res.* 41 : 269–294, illus.
- Redit, W. H. , And Hamer, A. A. 1961. Protection Of Rail Shipments Of Fruits And Vegetables. *U. S. Dept. Agr. Agr. Handb. No. 195* , 108 pp. , illus,
- Mccolloch, L. P. , Fisher, D. F. 1951. Market Diseases Of Fruits And Vegetables : Apples, Pears, Quinces. *U. S. Dept. Agr. Misc. Pub. 168*, 72 Pp. , Illus . (Re Vised. )
- Ryall, A. L. 1955. Ethylene Treatment Of Bartlett Pears Moving To Midwest Ern And Western Markets. *Blue Anchor* 32 ( 2 ) : 11 .
- Schomer, H. A. 1957. Polyethylene Film Bag Liners For Packaging Fresh Fruit . Eleventh National Conference on Handling Perishable Agr. Commod. , Purdue Univ. , Lafayette, Ind. Proc. pp. 45–48.
- Sommer, N. F. 1957. Quince And Pear Transit Simulated In Test. *Calif. Agr.* 11 : 3-4, 16, illus .
- Weeks ,A., R.,(1996), *Fundamentals of Electronic Image Processing*, Spie Press Book ISBN: 9780819491602 , Volume: PM32, pp: 37-40

MathWorks introduces Release 2017a (R2017a) with a range of new capabilities in MATLAB and Simulink.

Sammut , C.,Webb, G., I., (2010). Encyclopedia of Machine Learning,Volume:8. pp:11-25-29 ISBN:978-0-387-30768-8, Springer Science+Business Media, LLC

Sağiroğlu, Ş., Beşdok, E., Erler, M.,(2003), Mühendislikte yapay zeka uygulamaları-1 : yapay sinir ağları,Ufuk Yayınevi, ISBN: 9789759594855 , s: 24-47

Vapnik, V., (1963). Pattern Recognition Using Generalized Portrait Method, pp.774–780.

Huang, S., Cai, N., Pacheco, P.P., Narrantes, S., Wang, Y. and Xu, W. (2017). Applications of Support Vector Machine (SVM) Learning in Cancer Genomics, Cancer Genomics Proteomics, 15, 41 – 51.

Rumelhart, D. E., & the PDP Research Group, (1986), Parallel distributed processing: Explorations in the microstructure of cognition, Vol. 1. Psychological and biological models. Cambridge, Massachusetts: MIT Press.

Hornik, K., Stinchcombe, M., White, H., (1989), Multilayer feedforward networks are universal approximators, Neural networks, vol. 2, no. 5, pp. 359-366,

Chih-Min, M., Wei-Shui, Y. and Bor-Wen, C. (2014). How the Parameters of K-nearest Neighbor Algorithm Impact on the Best Classification Accuracy: In Case of Parkinson Dataset, Journal of Applied Sciences, 171–176.

K., D. and Srivastava, Lekha, B. (2010). Data Classification using Support Vector Machine, Journal of Theoretical and Applied Information Technology.

Mira, J. ,(1995) , Neural Computation Lecture Notes In Computer, International Workshop on Artificial Neural Networks Malaga- Torremolinos ,Spaine June 1995, Proceeding, IWANN '95. Sprenger ISBN 3 1741 102 204 973 pp. 4-15.



- S. Ruder,(2016), An overview of gradient descent optimization algorithms, ArXiv e-prints, vol. 1609, <http://adsabs.harvard.edu/abs/2016arXiv160904747R>  
Eriřim Tarihi:12.12.2020, Ankara.
- Lantz, B., (2015), Machine learning with R, Packt Publishing, Birmingham.
- Rumelhart, D. E., McClelland, J. L., & the PDP Research Group, (1986b), Parallel distributed processing Explorations in the microstructure of cognition, Vol. 2. Foundations, Cambridge, Massachusetts, and MIT Press.
- Pratt, L., Y., (1994), Experiments on the transfer of knowledge between neural networks. In S. Hanson, G. Drastal, and R. Rivest, editors, Computational Learning Theory and Natural Learning Systems, Constraints and Prospects, volume 1, chapter 19, pages MIT Press, franklinite.mines.colorado.edu:pub/prattpapers/pratt-clnlbook.ps.Z. Eriřim: 16.12. 2020, Ankara.
- Bramer, M., (2016), Principles of Data Mining, Springer, London.
- Rumelhart, D. E., McClelland, J. L., & the PDP Research Group, (1986b), Parallel distributed processing Explorations in the microstructure of cognition, Vol. 2. Foundations, Cambridge, Massachusetts, and MIT Press
- Keskenler,M.,F., Keskenler, E., F., (2017), Gemiřten Gnmze Yapay Sinir Ađları ve Tarihesi, Takvim-İ Vekayi Dergisi, ISSN: 2148-0087 , C.5, S.2, S.8-18.
- Roweis, S., Saul, L., and Hinton, G. , (2002). Global Coordination Of Local Linear Models , Advances in Neural Information Processing Systems 14, . MIT Press , Cambridge, MA. pp:491.
- S. University, CS231n: Convolutional Neural Networks for Visual Recognition, <http://cs231n.github.io/neural-networks-2> , Eriřim Tarihi :27.01.2020 , Ankara
- S. Ruder,(2016), An overview of gradient descent optimization algorithms, ArXiv e-prints, vol. 1609, <http://adsabs.harvard.edu/abs/2016arXiv160904747R>  
Eriřim Tarihi:29.01.2020 , Ankara.

- Goodfellow, I., Bengio, Y., Courville, A. (2016), Deep learning (Adaptive computation and machine learning). Cambridge, Massachusetts: The MIT Press, pp. 22.
- Wang, H., Raj, B., (2017). On the Origin of Deep Learning, Language Technologies Institute School of Computer Science Carnegie Mellon University.
- Ganatra, N., Patel, A. (2018). A Comprehensive Study of Deep Learning Architectures, Applications and Tools, International Journal of Computer Sciences and Engineering, Vol. 6, No:12, pp.701-705.
- Jaderberg, M., Simonyan, K., Zisserman, A., Kavukcuoglu, K. (2015). Spatial Transformer Networks, Neural Information Processing Systems (NIPS) Papers published at the Neural Information Processing Systems Conference.
- Szegedy, C., Vanhoucke, V., Loffe, S., Shlens, J. and Wojna, Z., Rethinking the inception architecture for computer vision. Arşiv Preprint Arşiv:1512.00567, 2015.
- Chollet, F. (2017), Deep Learning with Python, Manning Publications, ISBN-13: 978-1617294433.
- MathWorks introduces Release 2017 (R2017a) with a range of new capabilities in MATLAB and Simulink.
- Ure, N.K., Genc, U., (2019). CNN to RL how AI is changing the ADAS scene, Eaton Technologies.
- Lipton, Z.C., Berkowitz, J., Elkan, C. (2015). A Critical Review of Recurrent Neural Networks for Sequence Learning, arXiv:1506.00019v4 [cs.LG] 17 Oct 2015.
- He, K., Zhang, X., Ren, S., Sun, J., (2015). Deep Residual Learning for Image Recognition, Microsoft Research. arXiv:1512.03385v1 [cs.CV] 10 Dec 2015.

Targ, S. , Almeida, D., Lyman, K.(2016). Resnet in Resnet: Generalizing Residual Architectures, Workshop track - ICLR 2016.

