



T.C.

**BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**Derin Öğrenme Teknikleri Kullanılarak Meyve
ve Sebzelerde Çeşitli Hastalıkların Tespit
Edilmesi**

Sevil ÖZCAN

YÜKSEK LİSANS TEZİ

Elektrik- Elektronik Mühendisliği Anabilim Dalı

**Ağustos-2023
BATMAN
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Sevil ÖZCAN tarafından hazırlanan “Derin Öğrenme Teknikleri Kullanılarak Meyve ve Sebzelerde Çeşitli Hastalıkların Tespit Edilmesi” adlı tez çalışması 29/08/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Ömer TÜRK

.....

Danışman

Doç.Dr. Emrullah ACAR

.....

Üye

Dr. Öğr. Üyesi Erdoğan ALDEMİR

.....

Yukarıdaki sonucu onaylarım.

Prof.Dr. Osman PAKMA

Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Sevil ÖZCAN

Tarih:31.08.2023

ÖZET

YÜKSEK LİSANS TEZİ

Derin Öğrenme Teknikleri Kullanılarak Meyve ve Sebze de Çeşitli Hastalıkların Tespit Edilmesi

Sevil ÖZCAN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Emrullah ACAR

2023, 75 sayfa

Jüri

Doç.Dr. Emrullah ACAR

Dr. Öğr. Üyesi Ömer TÜRK

Dr. Öğr. Üyesi Erdoğan ALDEMİR

Meyve ve sebze hastalıklarının gıda güvenliği ve sürdürülebilir tarım pratikleri açısından kritik önemi bulunmaktadır. Dolayısıyla hastalıklar ürün verimini düşürmekte, kaliteyi azaltmakta ve böylece küresel gıda arzını tehdit etmektedir. Bu hastalıklar aynı zamanda biyoçeşitliliği de olumsuz etkilemekte, ekosistem dengesini bozmakta ve çiftçilerin geçim kaynaklarını zayıflatmaktadır. Bu çalışmada, derin öğrenme teknikleri kullanılarak meyve ve sebzelerde görülen hastalıkların tespiti yapılmıştır. Bu araştırma kapsamında 12 sınıfa ait 2907 adet RGB görüntüden çevrimiçi bir veri seti elde edilmiştir. Her sınıf için veri genişletme yöntemi ile veri seti 2907'den 17442'e kadar çıkarılmıştır. Meyve ve sebzelerdeki çeşitli hastalıkların tespiti için 10 katmanlı evrişimli derin ağ modeli oluşturulmuş ve ön eğitilmiş derin ağ mimarileri (InceptionV3 ve ResNet50) kullanılmıştır. Elde edilen sonuçlar, en başarılı yöntemleri belirlemek için zaman ve başarı oranı açısından karşılaştırılmıştır. Sağlanan analizlerin sonuçları ayrıca tasarlanan bu gerçek zamanlı sistem ile meyve ve sebzelerde hastalık görüntülerini tespit etme ve tahminlerini bilgisayar ekranına aktarmak için gerçekleştirilmiştir.

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

ABSTRACT

MS THESIS

Detection of Various Diseases in Fruit and Vegetables Using Deep Learning Techniques

Sevil ÖZCAN

Batman University Institute of Science

Department of Electrical Electronics Engineering

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2023, 75 pages

Jury

Assoc. Prof. Dr. Emrullah ACAR

Asst. Prof. Dr. Ömer TÜRK

Asst. Prof. Dr. Erdoğan ALDEMİR

Fruit and vegetable diseases have critical importance in terms of food safety and sustainable agricultural practices. Therefore, diseases reduce crop yields, reduce quality and thus threaten the global food supply. These diseases also negatively affect biodiversity, disrupt ecosystem balance and weaken farmers' livelihoods. In this study, the diseases seen in fruits and vegetables were determined by using deep learning techniques. Within the scope of this research, an online data set was obtained from 2907 RGB images belonging to 12 classes. The data set was increased from 2907 to 17442 with the data augmentation method for each class. For the detection of various diseases in fruits and vegetables, a 10-layer convolutional deep network model was created and pre education deep network architectures (InceptionV3 and ResNet50) were employed. The obtained results were compared in terms of time and success rate to determine the most successful methods. The results of the analyzes provided were also carried out with this designed real-time system to detect disease images in fruits and vegetables and transfer their predictions to the computer screen.

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

ÖNSÖZ

Yüksek Lisans Tez çalışmamda bana yol gösterici olan, ilgili ve olumlu tavırlarıyla beni cesaretlendiren, ve öğrencisi olmaktan onur duyduğum çok değerli sayın danışman hocam Doç. Dr. Emrullah ACAR'a sonsuz teşekkürlerimi sunarım.

Yüksek Lisans Tez çalışma sürecimde desteklerini benden esirgemeyen eşim Hakan ÖZCAN'a teşekkür ederim.

Tüm hayatım boyunca beni destekleyen, aldığım her kararda yanımda olan bana hem anne hem baba olan çok değerli annem Medine İLGİN'e sonsuz şükranlarımı sunar ve teşekkür ederim.

Sevil ÖZCAN

BATMAN

2023

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET.....	iv
ABSTRACT	v
ÖNSÖZ.....	vi
İÇİNDEKİLER DİZİNİ.....	vii
ŞEKİLLER DİZİNİ	ix
SİMGE VE KISALTMALAR DİZİNİ	x
1. GİRİŞ.....	1
1.1 Konunun Tanımı	1
1.2. Konunun amacı.....	3
1.3. Konunun Önemi	3
1.4. Görüntü İşleme Teknikleri Tanımı	4
1.5. Yaprak ve Yemiş Sınıflandırmalarıyla Domates, Fasulye Ve Çilekte Görülen Hastalıklar	6
1.5.1. Domateste Görülen Hastalıklar	6
1.5.2. Fasulyede Görülen Hastalıklar	9
1.5.3. Çileklerde Görülen Hastalıklar	13
1.6. Kaynak Araştırması	20
2. MATERYAL VE METOT.....	27
2.1. Veri Seti Oluşturma	27
2.2. Önerilen Sistem Mimarisi.....	32
2.3. Derin Öğrenmede Evrişimsel Sinir Ağları	33
2.3.1. Derin Öğrenmenin Tarihçesi.....	33
2.3.2. Derin Öğrenmenin Güçlü Yönleri.....	34
2.3.3. Temel Derin Öğrenme Kavramları	36
2.3.4. Derin Öğrenme Mimarileri.....	38
2.3.5. Evrişimsel Sinir Ağlar (ESA).....	38
2.3.6. Aktarımlı Öğrenme	40
2.3.6.1. InceptionV3	41
2.3.6.2. ResNet50	42
2.4. Performans Metrikleri	42
3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	44

3.1. Araştırmaya İlişkin Bulgular.....	44
3.1.1. 10 Katmanlı ESA yapısına ait eğitim sonuçları	45
3.1.2. 10 Katmanlı ESA yapısına ait test sonuçları	47
3.1.3. Inceptionv3 mimarisine ait eğitim sonuçları	47
3.1.4. Inceptionv3 mimarisine ait test sonuçları	49
3.1.5. ResNet50 derin öğrenme mimarisine ait eğitim sonuçları.....	49
3.1.6. ResNet50 derin öğrenme mimarisine ait test sonuçları	51
3.2. Tartışma	51
3.3. Gerçek Zamanlı Uygulama Örnekleri	53
4. SONUÇLAR VE ÖNERİLER	57
4.1. Sonuçlar	57
4.2. Öneriler	57
KAYNAKLAR	59
ÖZGEÇMİŞ	64

ŞEKİLLER DİZİNİ

Şekil 1.1. Analog Görüntünün Dijital Görüntüye Çevrilmesi (Erkuş, 2020).....	6
Şekil 1.2. Domates Yanıklığı Yaprakta Görülen Hastalık (Erken ve Geç Yanıklık)	7
Şekil.1.3. Domates Yaprak Küfü Hastalığı	8
Şekil.1.4. Domates Örümcek Akarları	8
Şekil 1.5. Fasulyelerde Köşeli Yaprak Lekesi Hastalığı Veri Kümesi (WEB 1)	10
Şekil 1.6. Fasulye Pası Hastalığı Yemiş Üzerindeki Görünümü.....	11
Şekil 1.7. Fasulye Yapraklarında Paslanma	12
Şekil 1.8. Çilek Külleme Hastalığı (Yaprak) (WEB 1)	14
Şekil 1.9. Çilek Yanıklığı/kürlenmesi veya çalışma kapsamında ele alındığı üzere Çilek küllemesi Hastalığı veri seti kümesi (WEB1)	15
Şekil 1.10. Çilek çiçek yanıklığı veri seti (WEB 1)	15
Şekil 1.11. Çilek Gri Kalıp/ Kurşuni Küf Hastalığı Görüntü Veri Kümesi (WEB1)	17
Şekil 1.12. Çilek Antraknoz Hastalığı Veri Seti Görüntü Kümesi (WEB1)	18
Şekil 1.13. Çilek Lekeli Yaprak Köşesi Hastalığı	19
Şekil 2.1. Sebze Veri seti kümesi (Sol Üst; Fasulye Pası, Sağ üst Fasulye Yaprak Köşe Benek ve Allta Domates Küllenmesi(Kürlenmesi) Hastalık Görüntüleri) WEB1	28
Şekil 2.2. Meyve Veri Seti Kümesi Çilek yaprak küllemesi(yahut Kürlenmesi Sol Üst), Çilek Meyve Küllemesi (veya kürlenmesi /sağ üst), Çilek Çiçeği Yanıklığı (Çiçek Çiçeği Kürlemesi/altta).....	29
Şekil 2.3. Veri setindeki Çilek Hastalıklarına ait renkli görüntüler	30
Şekil 2.4. Çilek küllenmesi hastalığının gerçek ve karşıtlık eklenmiş görüntüleri	30
Şekil 2.5. Önerilen Sistemin Akış Diyagramı	32
Şekil 2.6. Derin sinir ağlarını genel yapısı (Mira,1995)	33
Şekil 2.7. Geleneksel Makine Öğrenmesi ve Derin Öğrenme Yaklaşımının Karşılaştırılması(Erkuş, 2020).....	35
Şekil 2.8. Evrişimli sinir ağı katmanları(Ure, 2019).....	39
Şekil 2.9. 4x4 görsele 2x2 boyutunda filtre uygulama (Krizhevsky, ve ark. 2012).....	40
Şekil 2.10. Inception yapısı(Szegedy, 2015).....	41
Şekil 2.11. Bir ResNet yapısında daha derin bir artık fonksiyon yapı taşı ve ResNet- 50’de bir “darboğaz” yapı taşı(K.He vs. 2015 , S.Targ vs. 2016)	42

Şekil 3.1 10 katmanlı ESA mimarisi başarıml grafiğı	46
Şekil 3.2 10 katmanlı ESA mimarisi kayıp grafiğı.....	46
Şekil 3.3. InceptionV3 Mimarisinin Başarım Grafiğı.....	48
Şekil 3.4. InceptionV3 Mimarisinin Kayıp Grafiğı	48
Şekil 3.5. ResNet50 Mimarisinin Başarım Grafiğı.....	50
Şekil 3.6. ResNet50 Mimarisinin Kayıp Grafiğı	50
Şekil 3.7. Çilek Köşeli Yaprak Lekesi Hastalık Tespiti	54
Şekil 3.8. Fasulye Köşeli Yaprak Lekesi Hastalık Tespiti.....	54
Şekil 3.9. Çilek Yaprak Lekesi Hastalık Tespiti	55
Şekil 3.10. Çilek Çiçek Yanıklığı Hastalık Tespiti.....	55
Şekil 3.11. Domates Yaprak Küfü Hastalık Tespiti	56



SİMGE VE KISALTMALAR DİZİNİ

2B:	İki Boyutlu
3B:	Üç Boyutlu
CRT:	Katot Işın Tüpü
ESA:	Evrişimli Sinir Ağı
RGB:	Kırmızı, Yeşil, Mavi ana renklerinden oluşan renk uzayı
YSA:	Yapay Sinir Ağı
WEB:	İnternet
$^{\circ}\text{C}$:	Santigrat Derece
RNN:	Recurrent Neural Networks (Tekrarlayan Sinir Ağı)
RBM:	Restricted Boltzmann Machines (Kısıtlanmış Boltzmann Makineleri)
LSTM:	Long / Short Term Memory (Uzun Kısa Dönemli Bellek)
CNN:	Convolutional Neural Networks (Evrişimli Sinir Ağları)

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 (Kızılboga, 2021). 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 (Kızılboga, 2021).

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, derin öğrenme kullanılarak, spesifik bir meyve olan çilek ve iki sebze olarak seçilen fasulye ve domates üzerinde çalışabilecek bir model oluşturarak, 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, meyvelerden çilek ve sebzelerden domates ile fasulye üzerinde görülen hastalıkların literatüre dayanılarak tespiti için çeşitli derin öğrenme tekniklerinin kullanılması amaçlanmıştır.

1.3. Konunun Önemi

Meyve ve sebzelerdeki hastalıkların 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 ve sebze 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 (Wen ve Tao, 1997).

Bu çalışmada, meyve ve sebzeler için veri setinin verimli olmasına ve çok sayıda resim içermesine dikkat edilmiştir. Seçilen meyvelerden çilek için halka açık olan veri setinde tanımlı çilek köşeli yaprak lekesi, çilek antraknoz, çilek çiçek yanıklığı, çilek gri küf, çilek yaprak lekesi, çilek meyvesi küllenmesi, çilek yaprak küllenmesi olmak üzere WEB 1 verisinden alınarak sınıflandırılmıştır. Sebzelerden domates için domates yanıklığı, domates yaprak küfü ve domates örümcek akarları; fasulye için ise fasulye köşeli yaprak lekesi ve fasulye pası hastalıkları için de benzer bir biçimde sınıflandırma yapılmıştır. Daha sonra WEB 1’den indirilen görüntüler ile oluşturulan veri seti resimleri üzerinde görüntü çoğaltması sağlanarak, resimleri döndürme, bulanıklaştırma gibi görüntü işleme fonksiyonları kullanılarak ilgili sınıflar üzerine kayıt edilmiştir. Böylelikle veri seti üzerinde artış sağlanmıştır.

Seilen meyve iin tespit edilen her hastalık etiketlenerek sınıflandırılmış olup, bir CNN modeli python yazı dili kullanılarak eğitilmiştir. Son olarak ise kontrol iin ayrılmış olan veri setindeki görüntüler, siyah kartonlara basılmış ve bilgisayar kamerasına gösterilmiştir. Kontrol görüntüleri kameraya gösterildiğinde meyve ve sebze yaprakları, iekleri ve meyve/sebze yüzeyinde görülen farklılıklara göre meyvenin hasta olup olmadığı, hastalıklı ise hangi hastalığı gösterdiği yönünde ekran ıktısının alınması sağlanmıştır.

1.4. 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 deėiştirilmesini 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 iin etrafını bulanık olarak algılıyorsa, görüntü işleme modeli de buna baėımlı olarak ıkarılır. Görüntü işleme tekniklerinden birisi olan gürültü temizleme (nesneyi diėer ortamdan ayırt etme) beynimizin bu özelliėi kullanılarak tasarlanmaktadır. Görüntüdeki gürültü temizleme kısaca; alıřma alanımız olan 2-B bir görüntüde sahnenin nesneden ayrılması işlemidir. Sahne görüntünün arka planı olarak tanımlanmaktadır (Bishop,2006).

Resim, görüntülenen alanın parlaklıėı 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) iin, ışık yoğunluėunu belirten iki deėiřkenli (x, y) fonksiyonu olarak tanımlanmaktadır(Bishop,2006). Bir noktadan alınan ışık yoğunluėu, parlaklık ve renk gibi birkaç deėiřkenin fonksiyonu olarak da gösterilebilir. Görüntülerde düşünölebilen 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 kırınimleri ise görünen alandaki renk yansımalarını bize sunar. Işık çeşitli dalga boylarında vektörel kırınimleri; $[g_1(x, y), g_2(x, y), \dots g_n(x, y)]$ 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 (Şekil 1.1).
- 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 işlemlerdir. Şekil 1.1.'de analog bir görüntünün dijital görüntüye dönüştürülmesi şeması verilmiştir.



Şekil 11.1. Analog Görüntünün Dijital Görüntüye Çevrilmesi (Erkuş, 2020)

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.

1.5. Yaprak ve Yemiş Sınıflandırmalarıyla Domates, Fasulye Ve Çilekte Görülen Hastalıklar

1.5.1. Domateste Görülen Hastalıklar

1.5.1.1 Domates Yanıklığı

Ağaçtan sofraya domatesin 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. Yani, 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 küllenme veya domates yanıklığı önleyici tedbirler mümkün kılarsa da uygun mevsimlerde yetiştirilip hasat edilen ve işlenen meyve ve sebzeler iyi bahçecilik uygulamalarıyla bir miktar kayıp azaltma sağlanabilse de depolamada veya pazarlama sırasında çürümesi sırasında oluşan kayıpların henüz önüne geçilememiştir (Morrow ve ark. , 2019). Aşırı olgunlaşmış sebze ve meyvelerde erken ve geç yanıklık meydana gelmesi ise neredeyse kaçınılmaz bir hastalık olarak karşımıza çıkmaktadır (Jolly ve Raman, 2017). Perakende mağazalarında toplu olarak sergilenen meyve ve sebzelerin nakliyesi neredeyse her zaman sorun oluşturmakta ve genellikle 40 ° F'de soğutlamalı bir sisteme sahip olan konteynirlarda taşınmasıyla nakliye sırasında meyve ve sebzelerin 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 (Domates 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.

Domates yanıklığı da bunlardan birisidir ve genellikle domatesin üzerinde sert bir tabaka biçiminde kahverengi renk değişimi ile görülmektedir. Tüm üretim bölümleri arasında domateslerde meydana gelmiş ve yaprağındaki leke ile yemişin hastalıklı olacağı bildirimini başlangıçtan itibaren gözlenebilecek en yaygın hastalık olarak karşımıza çıkmaktadır. Domates yanıklığı ya da domates küllenmesi, erken yanıklık veya geç yanıklık olarak ikiye ayrılmaktadır. Şekil 1.2.'de domates yanıklığının erken ve geç dönemdeki şekil bozuklukları gösterilmiştir.



Şekil 1.2. Domates Yanıklığı Yaprakta Görülen Hastalık (Erken ve Geç Yanıklık)

Şekil 1.2'de görüldüğü üzere, domates yanıklığı erken dönemde yaprağın bir ucunda görülürken geç dönemde yaprakta şekil bozukluğu ve kayıplara yol açmaktadır. Bu da yemişteki şekil bozukluğuna (yamukluk ve kahverengi yanıklar) olarak görülebilir. Bu hastalık asıl olarak çekirdekli olan tüm meyve ve sebzelerde görülebilmektedir (Leemans ve ark. 1999). Bu çalışma kapsamında domates yanıklığı erken ve geç dönem yerine tek başlık olarak işlenecek olup, domates yaprağı yanıklığı (domates yaprağı kürlenmesi) olarak ele alınmıştır.

1.5.1.2 Domates Yaprak Küfü

Domates yaprak küfü, domates bitkilerinin büyümesini ve meyve verimini ciddi bir şekilde etkileyen yaygın bir hastalıktır. Domates yaprak küfü üzerine yapılan inceleme ve araştırmalar köklü bir geçmişe sahiptir (Zhao,2021). Şekil 1.3.' te domates yaprak küfü hastalığına ait görüntüler yer almaktadır.



Şekil.1.3. Domates Yaprak Küfü Hastalığı

1.5.1.3 Domates Örümcek Akarları

Domates örümcek akarları, aşağıdaki şekilde de görüleceği üzere domates yaprağı dokusu üzerinde klorotik lezyonlara neden olur (Merijn R. Kant, 2023). Şekil 1.4.' te domates örümcek akarları hastalığına ait görüntüler yer almaktadır.



Şekil.1.4. Domates Örümcek Akarları

1.5.2. Fasulyede Görülen Hastalıklar

1.5.2.1. Fasulye Köşeli Yaprak Nokta Hastalığı

Fasulyedeki hastalık, yapraklar, yaprak sapları, gövdeler ve fasulyeler dahil olmak üzere bitkinin tüm yeşil bileşenlerini etkileyerek çeşitli semptomlara neden olduğu görülmektedir (Zaumeyer ve Thomas, 1957).

Fasulye yapraklarındaki damarlar ve damarcıklar, yaprağın alt tarafında başlayan noktaları ayırarak kendini göstermektedir. Fasulye yaprağı üzerinde önce gri, sonra kahverengi olan lezyonlarda renkli sınırlar netlikle kendini göstermektedir. Bu hastalık, *Cercospora cruenta* ve diğer yaprak hastalıkları tarafından üretilen lekeden yaprakta renk olmaması ve beneklerin dikkate değer açısallığı ile ayrılmaktadır. Bu sebeple çalışma kapsamında hem hastalığı yaygınlığı hem de ayırt ediciliği açısından fasulyede köşeli yaprak nokta olarak görülmektedir (Zaumeyer ve Thomas, 1957).

Yapraklardaki ayırt edicilik, ana yapraklardaki lezyonlar, üç yapraklı yapraklardakilerden daha yuvarlak ve büyüktür ve eşmerkezli halkalar oluştururlar (Allen, 1983). Şiddetli enfeksiyonlar, lezyonların boyutunun büyümesine ve birleşmesine neden olarak kloroza veya yaprakların erken yaprak dökülmesine yol açmaktadır (Cardona ve Walker, 1956). Kabuklarda ve gövdelerde koyu, derin, ovalden dairesel çeşitli boyutlarda yamalar görülmektedir. Bu hastalığın dünya çapında fasulye üreten bölgelerde tohum kalitesi ve pazarlanabilirliği üzerinde bir etkisi bulunmaktadır (Pastor-Corrales ve diğerleri, 1998). Şekil 1.5'te Köşeli yaprak lekeli hastalığına ilişkin görüntü kümesi datasına yer verilmiştir.



Şekil 1.5. Fasulyelerde Köşeli Yaprak Lekesi Hastalığı Veri Kümesi (WEB 1)

Bölmelerdeki lekeler, neredeyse siyah kenar boşlukları ve kırmızımsı kahverengi merkezlerle ilk önce yüzeyselliği ile görülmektedir. Burada kenarlar ve merkezler, kısmen daha iyi sınırlar ile çizilmiştir. Hastalık, noktaların farklı boyutlarda olmasıyla kendini göstermektedir. Noktalar da sonra birleşerek bölmenin tüm genişliğini kaplayabilmekte ve fasulye yemişine sirayet edebilmektedir.

Nemli koşullar altında, daha yüksek lezyonlarla koyu griden siyaha doğru bir biçimde hastalık yemişin tohum olarak görülen kısımda sinnemata ve konidia lekesi olarak görülmesine yol açmaktadır (Zaumeyer ve Thomas, 1957).

Fasulyelerin üzerindeki lekelerin altında tohumun enfekte olması ise hastalığın nihai durumunu yansıtmaktadır. Hastalık buruşmuş ve rengi solmuş tohumlarda yerleşmekte ve bir yerden başka bir yere ve mevsimden mevsime taşınmasıyla yaygınlık oranını arttırmaktadır (Barros ve diğerleri, 1958).

Köşeli yaprak lekesi, Himachal Pradesh dağlık bölgelerinde ciddi bir sorundur ve yeşil fasulyelerin % 40 ila %70'ini pazarlama dışında bırakmaktadır (Singh ve Saini, 1980; Gupta ve diğerleri, 1998). Bu da dünya küresel krizlerinden yiyecek üretimini etkilemekte ve netice itibari ile açlık çeken insanların yiyeceğe kolay erişimini engelleyici bir durumu doğurmaktadır (Santos ve ark, 1978).

1.5.2.2. Fasulyelerde Paslanma Hastalığı


Fasulye bitkisi yaprağında paslanma hastalığının yönetimi için çeşitli stratejiler olmasına rağmen, dünyanın birçok fasulye üreticisi ülkesinde tarla koşullarında pas yönetimi (kontrol) hastalığa dayanıklı kùltivarlar ve fungusitler kullanılarak gerçekleştirilmektedir. Çünkü bu hastalık aynı zamanda sporlar ile taşınan ve yaygın bir mantar hastalığıdır. Fasulyenin dış kabuğunda Şekil 1.6'da yer aldığı biçimde paslı bir görünüm bırakmaktadır.



Şekil 1.6. Fasulye Pası Hastalığı Yemiş Üzerindeki Görünümü

Şekil 1.6'da fasulye pasının etkili yönetimi için çeşitli mantar ilaçları kullanılmakta olup, genel anlamda bitkinin üretim maliyetinin artmasına yol açmaktadır. Özellikle ilk üretim aşamasında, yani fasulye henüz olgunlaşmadan yahut kuru fasulye işlemleri uygulanmadan önce yapıldığında yani erken dönemde sağlandığında bu maliyetin azaldığı bilinmektedir. Fasulye pasıyla mücadele için fungusitler, salgının çok erken aşamalarında ve önleyici olarak kullanıldığında en etkilidir. Etkili fungusitler, klorothalonil ve ditiokarbamatlar gibi koruyucuları ve

triazoller gibi sistemik kimyasalları ve karboksinler olarak özetlenmiştir (Liebenberg & Pretorius, 2010). Fasulye pası patojeni tohumla bulaşmadığından, fasulye pası kontrolü için tohum tedavileri genellikle kullanılmamakta veya çok gerekli görülmemektedir (Kelly ve diğerleri, 1996). Bununla birlikte yaygın hastalık nedeniyle fasulye ticaretinin etkili bir düşüşe yol açtığı da bilinmektedir. Şekil 1.7’de Fasulye yapraklarında sararma biçimi ve delikler ile kendini göstermektedir.



Şekil 1.7. Fasulye Yapraklarında Paslanma

Fasulyeler için pas lekesi ürünün piyasaya çıkmasına ve özellikle ihraç edilmesinde etkili olmakta ve satış hacmini azaltmaktadır. Bununla birlikte ürünün kurutulması sırasında da eğer kabuktan doğru yöntem kullanarak ayrırma işlemi sağlanamadıysa fasulyenin taneli kısmına da bulaşmakta bu da kuru fasulyenin pas

lekesini almasına neden olabilmektedir. Bu da tek pazarlama alternatifini de ortadan kaldırmakta, dolayısıyla ürün olarak piyasaya sürülmesine engel oluşturabilmektedir. Asıl olarak pas lekesi varlığı henüz yaprak kısımlarında kendini gösterdiğinde, uygun arıtma yöntemleri kullanarak tarladaki diğer ürünlerin hastalanmasının engellenmesi yapılırsa, spor taşınması yapılmadan engellenebilmektedir.


1.5.3. Çileklerde Görülen Hastalıklar

1.5.3.1. Çilek Yaprakları, Çiçek ve Meyvesinde Külleme

Çilek çiçek yanıklığı ile karıştırılabilir, ancak bunlar genellikle dikkatli inceleme ile ayırt edilebilmektedir. Çapı 1 inçten daha küçük olan yanıklık çürümesi lezyonlarının görsel tespitinde, görünen leke eğer kahverengiyse, yanıklık çürümesinden bahsetmeyi mümkün kılmaktadır (Yue ve Tian, 2020).

Çilek yanıklık çürüklüğünü gösteren lezyonlarda küllenme, güneş yanığı gibi etkenlerle meydana gelmektedir ve sıklıkla baskı altında kolayca oluşan yan çürüme hastalığı ile karıştırılabilir. Yan çürüme hastalığı çilek yaprak küllemesi hastalığına göre dokunsal anlamda meyvenin içine doğru çökecek sulu ve yumuşak bir üst katman lekelenmesidir. Ancak bu durum görsel anlamda karışıklık yaratabilmektedir. Çünkü bu ayrım belirtildiği üzere gözle ayırt edilecek bir ayırmadan çok dokunsal bir ayrım barındırmaktadır. Bu sebeple görüntü işlemede yan çürüklüğü tespiti kolayca ortaya konulacak bir tanıdan uzak durmayı gerekli kılmaktadır. Bu sebeple, bu çalışmada iki hastalık cinsinden yalnızca çilek küllemesinin yaprak, çiçek ve meyvesi halinde işlemesi sağlanacak olup, çilek yan çürüme rahatsızlığına yer verilmeyecek şekilde bir gruplandırma yapılmasıyla benzerliğin önüne geçilmesi sağlanmıştır. Çünkü aksi halde görsel işlemede hata alınacağı bilinmektedir.

Çilek küllemesi hastalığına ilişkin yapraklar için işlenen veri data setine Şekil 1.8’de yer verilmiştir.



Şekil 1.8. Çilek Külleme Hastalığı (Yaprak) (WEB 1)

Çilek küllemesi olarak yapraktaki görünümü Şekil 1.6'daki gibiyken küremeye benzer biçimde çilek köşeli yaprak lekesi ile birbiri ile karıştırılacak görünüme sahip olup, gözle ayırt edilmeyen bir biçimde işlenmektedir. Bu kısma sonraki başlıklarda yeniden değinilmesi planlanmıştır. Yaprakın yanıklığı/küllemesi-kürlenmesi hastalık tipine ilişkin olarak meyvedeki küreme/küllenme görünümü ayrıca veri seti kümesinde yer almaktadır. Şekil 1.9'da meyvenin küllemesine ilişkin yapılan sınıflandırma kümesine (veri seti sınıflandırması kümesine) yer verilmektedir.



Şekil 1.9. Çilek Yanıklığı/kürlenmesi veya çalışma kapsamında ele alındığı üzere Çilek küllenmesi
Hastalığı veri seti kümesi (WEB1)

Çileğin yanıklığı ve içe doğru göçmesi ile tabakanın sert ve kalın görünümü sahip olduğu bu hastalık biçimi Şekil 1.10'da yer almaktadır. Çilek meyvesinde küllenme yukarıda yer alan Şekil 1.9'daki gibiyken çiçek yanıklığı da meyveye sirayet etmektedir. Şekil 1.10'da çilek çiçek yanıklığı veri kümesine yer verilmektedir.



Şekil 11.10. Çilek çiçek yanıklığı veri seti (WEB 1)

1.5.3.2. Gri Kalıp Hastalığı

Çilekte görülen gri kalıp hastalığı, ülkemizde de geçtiğimiz on yıl içerisinde düşüş gösteren bir meyve olarak bilinmektedir. Yapısı gereği yumuşak bir meyve olan çilek genellikle, ülkemizin kıyı şehirlerinde yetiştirilmektedir.

Çilek üretiminde meyve güvesi (*Grapholitha molesta* Busck) olarak adlandırılan bir mantar zararlısının bu meyve ağaçlarına saldırdığı bilinmektedir. Bu güvenin neden olduğu kayıplar muhtemel olarak tüm meyve üretimini ortadan kaldıran, bir bahçede tek meyve ağacında görüldüğünde, diğer ağaçlara sıçrama potansiyeli bulunmaktadır.

Dünyada görülen mantar kökenli bir sporlanmaya neden olan meyve güvesi griden kahverengiye dek meyve üzerinde görüntü bozunmalarına yol açmaktadır. Hastalık genellikle ağaç üzerindeyken meyvelere saldırmakta ancak küçük, gözden kaçan lezyonları, 32 ° F'nin üzerindeki sıcaklıklarda depolanmış meyvelerde yahut taşıma sırasında büyüme göstermektedir. Bu hastalık tipik olarak meyvenin uç kısmında dairesel grileşme ya da kurşuni küf ile görülmektedir (Mccolloch ve Fisher, 1951). Bununla birlikte hali hazırda yumuşak ve sulu bir meyve olan çilekte içe doğru büzüşme görülebilmektedir. Şekil 1.11.'de hastalığın görünmesine ilişkin çalışmada kullanılan veri kümesine yer verilmektedir.



 ekil 1.11.  ilek Gri Kalıp/ Kur uni K f Hastalığı G r nt  Veri K mesi (WEB1)

 ekil 1.11.'de K f hastalığı bulunmakta ve orta derecede sert veya hafif s ngerimsi olup, genellikle y zeyde buru uk kenar bo lukları olarak kendini g stermektedir.  ilek meyvesi gri kalıp hastalığı g r n m a ısından  ilek antraknoz meyve   r mesine benzemektedir.

1.5.3.3. Çilek Antraknoz Meyve Çürümesi

Çilekte antraknoz meyve çürüklüğü, hastalık ilk çiçek tomurcukları görüldüğünde görülür ve enfekte çiçekler çabuk kurur ve yaprak ölür. Meyve çürüklüğü, esas olarak toprak tüplerde yetiştirilen çileklerde görülmektedir. Olgunlaşma sırasında, enfekteli meyveler, kurduğunda mumyalaşan sert, yuvarlak, koyu kahverengi siyah noktalara hızla dönüşen açık kahverengi sulu lekelerin meyvenin üzerinde görülmesine yol açmaktadır. Bu şekil bozukluğu başlangıçta griye dönük olarak görülmektedir. Mumlama hali ise kurşuni küfle meyvenin üzerini kaplaması olarak bilinen gri kalıp hastalığına benzemektedir. Şekil 1.12’de Çilek antraknoz hastalığı veri kümesine yer verilmektedir.



Şekil 1.12. Çilek Antraknoz Hastalığı Veri Seti Görüntü Kümesi (WEB1)

1.5.3.4. Çilek Yaprak Köşeli Yaprak Lekesi Hastalığı

Çilek köşeli yaprak hastalığı, çilek yaprağının kenarında beyaz bir leke ile kendini göstermektedir. Şekil 1.13'te hastalığa dair görüntü veri kümesine yer verilmektedir.



Şekil 11.13. Çilek Lekeli Yaprak Köşesi Hastalığı

Bu hastalık görüntülerinin sınıflandırılması Şekil 1.11.'da 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.

1.6. Kaynak Araştırması

Literatürde bazı çalışmalar incelenmiş, bu incelemeler hakkında bilgiler verilmiştir;

Yang, (1994) yaptığı çalışmada, elma görüntülerinde yüzey özelliklerinin tespiti için yeni bir teknik sunmuştur. Bu görüntüler için topografik temsil kavramının tanıtılmasıyla, yama benzeri özelliklerin tespiti, elma gri seviyeli manzaralarda havza tespitinden biri olarak ele alınmıştır. Su toplama havzalarını, yani özellikleri tespit etmek için bir taşma algoritması benimsemiş ve değiştirilmiştir. Algoritmanın uygulanması ayrıntılı olarak anlatılmıştır. Su baskını sürecinden sonra havzalar, alan ve çevre gibi geometrik parametrelerin kolaylıkla çıkarılabildiği göller haline gelmiştir. 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.

Günasekaran (1996) tarafından ele alınan bu çalışma, mikroorganizmaların saldırılarına uğrayabilen domates mahsulünün kalite kontrolü için bir görüntü algılama sistemini anlatmaktadır. Sistem, USB tabanlı bir kamera modülü ve kablolu iletim sağlayabilen bir Zigbee modülü içerir. Bu sistemde kullanılan algoritma, ön işleme adımlarını, sınıflandırmayı ve otomatik hastalık tespitini kapsamaktadır. Yerel pazardan toplanan domates örnekleri üzerinde test edilmiş ve veri toplama aşaması için bir veritabanı oluşturulmuştur. Bu sistem, hem çeşitli hastalıkları tespit edebilme hem de sınıflandırma yeteneği sunmaktadır. Veri analizi, çeşitli örüntü tanıma ve yazılımsal hesaplama teknikleri ile gerçekleştirilmiştir. Sonuçlar, ticari bir aroma algılama tekniği olan Alpha Mos 3000 sistemi kullanılarak doğrulanmıştır ve yaklaşık% 92 doğruluk elde edilmiştir.

Wen ve 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 çoğu görülmüştür. 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 etmiştir. Hat üzerinde yapılan testler, meyvelerin% 69'unun doğru şekilde derecelendirildiğini, ancak% 26'sının doğru derecenin hemen üstünde veya altında sınıflandırıldığını göstermiştir. 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 vermiştir. Dolayısıyla bu sistem, pazarlanamayan meyveleri taze meyve olarak sınıflandırmak için sadece toplama döneminde kullanılmaktadır. Bununla birlikte, ağırlığı ± 5 g ($r = 0,985$) standart sapma ile verdiği için, depolamadan önce ön boyutlandırma işlemleri için de kullanılabileceğini belirtmişlerdir.

Nakano (1997) yaptığı 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 oluşmaktadır. Bu sistemde, bir elmanın tüm görüntüsü, perspektif projeksiyonlar gibi bilgisayar monitöründe tek bir sahne olarak açılmaktadır. 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 kullanılmaktadır. 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 geliştirilmiştir. "Üstün", "zayıf renk" ve "yaralı" için derece değerlendirme oranları

çok yüksektir, ancak "mükemmel" ve "iyi" için oranlar çok yüksek olmadığı sonucuna ulaşmışlardır.

Leemans ve ark. (1999) yaptıkları 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 degradesiz 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.

Brosnan ve Sun (2004) 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.

Zhang ve ark. (2014) 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 tanımlarını sağlamışlardır. Araştırmacılar çalışmaları sonucunda ana bileşenler, temel teoriler ve bunlara karşılık gelen işlemleri analitik yöntemlerle rapor etmişlerdir.

Jolly ve Raman (2017) yaptıkları çalışmalarında, bilgisayarla görü kullanarak elmalardaki hastalıkların tespiti ve tanımlanması için farklı yaklaşımları açıklamışlardır. Araştırmacıların önerdikleri algoritmalar, görüntü özelliklerini

kullanarak elmanın yüzey görünümünü kusurlar için analiz etmiştir. Renk ve doku ilgi Alanının (ROI) segmentasyonu için, K-ortalama kümeleme, yoğunluk değerlerine dayalı olarak görüntü pikselleri üzerinde gerçekleştirilmiştir. 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 gerçekleştirilmiştir. Hastalık tespiti için, kaydedilen doğruluk Gabor + LBP yaklaşımı için % 96,9'dan fazla ve % 89,8 ile 96 aralığında hesaplanmıştır. Gabor + Haralick yaklaşımı için Gabor + çekirdek PCA, % 90 ile en düşük doğruluğu kaydetmiştir. Hastalık tanımlama için Gabor + LBP kombinasyonu, diğer kombinasyonlardan daha iyi performans göstermiştir ve % 85.93 ile % 95.31 arasında değişen en yüksek doğruluğu kaydetmişlerdir.

Yıldız ve ark. (2019) çalışmalarında, tarımsal ürünlerin kalite değerlendirmesi için çeşitli yıkıcı ve tahribatsız yöntemlerin kullanılmasını savunmuşlar (a) ultrasonik test ve (b) 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.

Morrow ve ark. (2019), dijital görüntüler ve yapay zeka tekniklerini kullanan otomatik bir denetim sistemi yardımıyla elma, patates ve mantarların boyutu, şekli ve rengini değiştirmek için prosedürler geliştirmişlerdir. Yüzey

kusurlarının tespiti için algoritmalar geliştirmeye şu anda vurgu yapılmaktadır. Meyve ve sebzelerin otomatik denetimi için genel bir "kalite" puanının geliştirilmesi için kullanılabileceğini ve otomatik sonuçlar, geleneksel manuel inceleme yöntemleri kullanılarak elde edilenlerle karşılaştırılmıştır. Algoritmalar ve teknikler birçok farklı meyve ve sebzeye uygulanabilse de, elma, patates ve mantarlar, denetlenen birincil ürünler olarak önermişlerdir.

Aslan (2021), yaptığı "Derin Öğrenme ile Şeftali Hastalıklarının Tespiti" başlıklı çalışması, tarım ürünlerinin küresel beslenme ihtiyaçlarını karşılama konusundaki önemini vurgulamaktadır. Çalışma, dünya nüfusunun hızlı büyümesi ve tarım alanlarının sınırlılığı nedeniyle, bitki hastalıklarının etkin ve hızlı bir şekilde belirlenmesinin tarımsal verimlilik açısından zorunlu hale geldiğini belirtmektedir. Özellikle, meyve ağaçlarının yaşam süresinin genellikle kısa olması, hastalıkların doğru ve hızlı bir şekilde tespit edilmesini hayati hale getirmektedir. Derin öğrenme tekniklerinin görüntü işleme uygulamalarında yararlı olduğu, özellikle tarımsal operasyonlarda etkin çözümler sunduğu belirtiliyor. Aslan, bu çalışmada, evrişimli sinir ağlarını kullanarak şeftali ağaçlarındaki monilya ve koşnili hastalıklarının tespitini önermektedir. Bu metodoloji, önceden eğitilmiş bir AlexNet modeli kullanılarak uygulanmış ve TRB1 bölgesinden alınan gerçek hastalık görüntülerini içeren bir veri seti üzerinde test edilmiştir. Yapılan deneyler, hastalık tespitinde %99,30'luk bir doğruluk oranı sağlamıştır, bu da önceki çalışmalardan %1,44 daha yüksek bir doğruluk oranı anlamına gelmektedir.

Terzi ve ark. (2023) çalışması "Derin Öğrenme Teknikleri ile Bazı Üzüm Çeşitlerinin Tespiti" konu başlıklı olarak ele alınmıştır. Üzüm çeşitlerinin tanımlanmasındaki çeşitli yöntemleri incelemiştir. Araştırmada belirtildiği gibi, üzüm çeşitlerinin belirlenmesinde sürgün, yaprak, salkım ve meyve karakteristikleri kullanılmaktadır. Bu karakteristikler, "Uluslararası Bitki Genetik Kaynakları Kurulu", "Office International de la Vigne et du Vin-OIV" ve "Uluslararası Yeni Bitki Çeşitlerinin Korunması Birliği-UPOV" işbirliğiyle geliştirilmiş 'Üzüm Tanımlayıcıları' normuna dayanmaktadır. Her üzüm çeşidinin belirli ampelografik özellikleri bulunmaktadır ve bu özellikler, üzüm tanımlayıcı normuna göre belirlendikten sonra, sayısal veya sözel olarak ifade edilmektedir. Çalışma, Corint, Merlot, Tayfi, Michele palieri, Narince gibi üzüm çeşitlerinin derin öğrenme

teknikleri kullanılarak sınıflandırılmasına odaklanmıştır. Hedef, bu ampelografik özelliklerin derin öğrenme teknikleriyle hangi üzüm çeşidini belirlemek için kullanılabileceğini göstermektedir. Bu amaçla, 15 katmandan oluşan yeni bir CNN modeli geliştirilmiştir. Veri seti, beş üzüm çeşidinden elde edilen ve $227 \times 227 \times 3$ boyutlarındaki 1028 görüntüden oluşmaktadır. Görüntülerin %80'i eğitim, %20'si ise doğrulama için kullanılmıştır. MATLAB'ta geliştirilen yeni CNN modeli, %96.10'luk bir sınıflandırma başarı oranı elde etmiştir.

Sevli (2023), "Elma Bitkisi Hastalıklarının Derin Öğrenme ile Tespiti" tarımsal verimliliğin sürdürülebilirliği ve hastalıklarla mücadele konusunda derin öğrenme teknolojisinin önemini vurgulamaktadır. Bitkisel üretim, tarım faaliyetlerinin bel kemiği olmakla birlikte, çeşitli hastalıklar nedeniyle önemli kayıplara da maruz kalabilmektedir. Bu hastalıklar çeşitli çevresel etmenler ve farklı patojenler (bakteri, virüs, mantar) nedeniyle ortaya çıkmaktadır. Hastalıkların erken ve doğru teşhis edilmesi, ürün kayıplarını önlemek ve kaliteyi arttırmak için kritik olduğu görülmektedir. Ancak, tarım uzmanları, bazen bu durumları doğru bir şekilde teşhis etmede zorlanmakta, bu da verimde düşüşe veya yanlış kimyasal uygulamalarına neden olmaktadır. Bu durum, aynı zamanda çevre üzerinde olumsuz etkilere ve daha dirençli patojenlerin gelişimine yol açmaktadır. Dolayısıyla, bitki hastalıklarının tanısında teknolojik yardımın önemli olduğu görülmektedir. Yapay zeka teknolojileri, tarımda bitki hastalıklarının teşhisinde yeni ve etkili çözümler sunmaktadır. Derin öğrenme, karmaşık hiyerarşileri modelleyebilen bir yapay zeka teknolojisi türü olarak belirtilmektedir. Bu çalışmada, evrişimsel sinir ağları (ESA), bir tür derin öğrenme tekniği, elma bitkisinin yapraklarında görülebilen hastalıkların teşhisinde kullanılmıştır. Elma tarımı, dünya genelinde önemli bir tarım faaliyetidir ve elma bitkilerinin hastalıklarla mücadele etmek, sürdürülebilir tarım ve ekonomi açısından literatüre katkıda bulunmuştur. Çalışmada, sağlıklı elma yaprakları ile birlikte üç farklı hastalık türünden alınan veriler üzerinde ESA tabanlı bir sınıflandırma uygulanmıştır. Bu veri seti, toplamda 1821 örneği kapsamaktadır. Veri artırımı kullanılarak modelin başarısı artırılmış ve aşırı uyumun önüne geçilmiştir. Modelin test sonuçları, %98.76 doğruluk oranıyla son derece etkileyici olmuştur.

Bu alıřmada, farklı sebze ve meyvelerden domates, fasülye ve ilekte görölen hastalıkların derin öęrenme teknikleri kullanılarak otomatik tespit edilebilmesi ve sınıflandırma işleminin gerçekleştirilmesi amaçlanmaktadır.



2. MATERİYAL VE METOT

2.1. Veri Seti Oluşturma

Bu çalışmada, meyve ve sebze hastalıklarını içeren veri seti kaagle.com’da olduğu üzere çeşitli arka plan görüntüleriyle oluşturulmuştur. Eğitim veri seti ile modeller eğitilmiş, test veri seti ile de hastalık tahminlerinin doğrulaması yapılmıştır.

Birinci aşamada indirilen görüntüler hastalık isimleri ve yemiş isimleri kullanılarak sağlanmıştır. Hastalık ayrımlarının netlikle belirlenmesi için 2907 adet görüntüden veri çoklama ile (döndürme, kırpma gibi) 17442 adet görüntü elde edilmiş ve bu görüntüler ile bir veri seti oluşturulmuştur. Veri seti 7 adet çilek hastalığına, 2 adet fasulye hastalığına ve 3 adet de domates hastalığına ait görüntüler olmak üzere 12 sınıftan oluşmaktadır.

İki Boyutlu olarak işlenen görüntü veri seti kümesine Şekil 2.1 ve Şekil 2.2’de yer verilmektedir.



Şekil 2.1. Sebze Veri seti kümesi (Sol Üst; Fasulye Pası, Sağ üst Fasulye Yaprak Köşe Benek ve Allta Domates Küllenmesi(Kürlenmesi) Hastalık Görüntüleri) WEB1



Şekil 2.2. Meyve Veri Seti Kümesi Çilek yaprak küllemesi(yahut Kürlenmesi Sol Üst), Çilek Meyve Küllemesi (veya kürlenmesi /sağ üst), Çilek Çiçeği Yanıklığı (Çiçek Çiçeği Kürlemesi/alta)

Bu hastalıklardan çilek meyvesi üzerinde görülenleri; çilek köşeli yaprak lekesi, çilek antraknoz, çilek çiçek yanıklığı, çilek gri küf, çilek yaprak lekesi, çilek meyvesi küllenmesi, çilek yaprak küllenmesidir. Fasulye yaprağı üzerinde; fasulye köşeli yaprak lekesi ve fasulye pası olmak üzere iki adet ve son olarak domates için ise domates yanıklığı, domates yaprak küfü ve domates örümcek akarları olarak incelenmiştir. Şekil 2.3.'te çilek hastalıklarına ait görüntülere yer verilmiştir.



Şekil 02.3. Veri setindeki Çilek Hastalıklarına ait renkli görüntüler

Aşırı uydurmanın önüne geçmek adına yapılan veri çoklama yöntemindeki amaç mevcuttaki verilerden birtakım dönüşümler ile gerçeğe yakın daha çok sayıda veri oluşturmaktır. Bu sayede eğitim sırasında model, aynı görüntüyü tekrar tekrar görmeyecektir. Bu da tasarlanan modelin daha fazla sayıda örüntü aramasını ve daha iyi genelleştirmesini sağlamaktadır.

Çalışmada öncelikle her sınıftaki görüntüler için döndürme, kırpma, yakınlaştırma, ters çevirme ve karşıtlık(contrast) işlemleri yapılmış ve görüntü sayısı toplam 17442' ye çıkarılmıştır. Veri çoklama yöntemlerine örnek olarak Şekil 2.4' te çilek küllenmesi hastalığının gerçek ve karşıtlık işlemi eklenmiştir.



Şekil 2.4. Çilek küllenmesi hastalığının gerçek ve karşıtlık eklenmiş görüntüleri

İkinci olarak, ImageDataGenerator kullanılarak tasarlanan sistemin örüntüyü farklı konum ve açılardan tanıyabilmesi adına keras kütüphanesinin sağlamış olduğu rastgele dönüşüm parametreleri ile veri çeşitlendirilmiştir. Her sınıf için ort. 100-350

arasında olan görüntü sayısını böylece toplam yaklaşık 17442'ye çıkarılmıştır. Veri çoklama için kullanılan işlemlere Çizelge 2.1' de yer verilmiştir.

Çizelge 2.1. Veri Çeşitlendirme İşlemleri

İşlem Adı	Değer	Açıklama
Görüntü Döndürme Aralığı	40	Görüntüyü en fazla 40 olacak şekilde sağa sola döndürme işlemi yapılmıştır
Görüntüyü uzay düzlemde X ekseninde Kaydırma Aralığı	0,2	Yatay ekseninde kaydırma
Görüntüyü uzay düzlemde Y ekseninde kaydırma aralığı	0,2	Dikey ekseninde kaydırma
Görüntünün Dikey Eksende Yatay Simetriğinin Alınması	True	Resmin dikey ekseninde simetriği
Yakınlaştırma Aralığı	0,2	Yakınlaşma işlemi

Veri setinin 1/2'si eğitim 1/4' ü doğrulama ve 1/4' ü de test için ayrılmıştır.

Veri çoklamadan sonra oluşan son veri kümesinin özellikleri Çizelge 2.2'de verilmiştir.

Çizelge 2.2. Veri Setinin Genel Özellikleri

Toplam Sınıf Sayısı	12
Her Bir Sınıf İçin Kaydedilen Görüntü Sayısı	750-2200 aralığında
Veri Setindeki Toplam Görüntü Sayısı	17442
Değişkenler	Karşıtlık, Yön, Işık ve Uzaklık,
Sınıfların Ortalama Dosya Büyüklüğü	2.75mb-17mb
Veri Seti Dosya Büyüklüğü	642 mb
Toplam Veri Seti Oluşturma Süresi	17 dakika


Veri çoklama işleminin öncesindeki her bir sınıfta yer alan veri sayısı ve veri çoklama işleminin ardından oluşan yeni veri sayısının sınıflara göre dağılımı Çizelge 2.3' te olduğu gibidir.

Çizelge 2.3. Veri Çoklama İşleminin Öncesi ve Sonrası

Hastalık Sınıfları	Veri Çoklamadan Önceki Veri Sayısı	Veri Çoklamadan Sonraki Veri Sayısı	Toplam Veri Sayısı
Fasulye köşeli yaprak lekesi	287	1435	1722
Fasulye pası	327	1635	1962
Çilek köşeli yaprak lekesi	178	890	1068
Çilek antraknoz	111	555	666
Çilek çiçek yanıklığı	183	915	1098
Çilek gri küf	190	950	1140
Çilek yaprak lekesi	238	1190	1428
Çilek meyvesi küllenmesi	127	635	762
Çilek yaprak küllenmesi	211	1055	1266
Domates yanıklığı	349	1745	2094
Domates yaprak küfü	352	1760	2112
Domates örümcek akarları	354	1770	2124
Toplam	2907	14535	17442

2.2. Önerilen Sistem Mimarisi

Bu çalışmada, birbirinden farklı mimarilerdeki CNN, InceptionV3 ve ResNet50 modelleri kullanarak meyve ve sebzelerden oluşan veri setinin bu yöntemle başarılı bir şekilde sınıflandırılması önerilmektedir. Çalışmadaki önerilen sistem mimarisi Şekil 2.5.’teki gibidir;




Şekil 2.5. Önerilen Sistemin Akış Diyagramı

2.3. Derin Öğrenmede Evrimsel Sinir Ağları

2.3.1. Derin Öğrenmenin Tarihçesi

2006 yılında Hinton ve arkadaşları tarafından ilk olarak yayınlandı. 1987’de ilk olarak Rina Dechter tarafından Derin öğrenme ifadesi kullanıldı, ancak Igor Aizenberg ve diğerleri 2000 yılında derin öğrenme kavramını bir yapay sinir ağı modeli olarak tanıttı. Katmanların miktarı arttıkça ağın yapısı da derinleşir. Yapay sinir ağları tipik olarak bir veya iki katmandan oluşur. Ancak derin ağlar binlerce katmandan oluşabilir. Derin öğrenme, 2000’li yıllarda veri ve donanım eksikliği nedeniyle parlamadı. Bunun nedeni, sinir ağı modelinin derinliği arttıkça hesaplama yükünün artması ve donanım eksikliklerinin ortaya çıkmasıdır. Ayrıca, ağı ters eğitimi sırasında, katman sayısı arttıkça geri besleme sinyali kaybolabilir. Eksik veriler de fazla uydurmaya neden olur. Bu, derin öğrenmedeki en büyük sorunlardan biridir. Derin Sinir Ağları’ nın genel yapısı Şekil 2.6.’daki gibidir;



Şekil 2.6. Derin sinir ağlarının genel yapısı (Mira,1995)

2.3.1.1. Derin öğrenmenin gelişimi

Denetimsiz öğrenme, veri setini etiketlemeyen ve girdi için sistem çıktısını elde etmenin nispeten zor olduğu bir öğrenme stilidir. Kümeleme, bu tür öğrenmeye bir örnektir (Jaderberg ve ark. 2015).

- İnternetin her yerde bulunabilmesi, makine öğrenimi için gerekli olan büyük veri kümelerinin toplanmasını ve dağıtılmasını mümkün kılar.

- Bazı basit ama önemli algoritmaların keşfi, 2000 yılından sonra ortaya çıkmış olup, sinyallerin daha iyi geri gönderilmesini mümkün kıldı. Bu algoritmalar:

- Daha iyi katman aktivasyon fonksiyonları (Relu, Softmax, vb.),
- Daha iyi başlangıç ağırlık başlatma yöntemleri,
- Daha iyi optimizasyon yöntemleri (RMSProp, Adam, vb.).


Toplu normalleştirme, artık bağlantı, derinlemesine ayrılabilir evrişim, vb., hata sinyalinin geri yayılımını iyileştirir ve yüzlerce katmandan oluşan ağlara izin vermekte ve modelin sıfırdan eğitilmesini sağlamaktadır.

Sonuç olarak, tıp, eğitim ve haberleşme gibi alanlarda derin öğrenme popüler hale gelmiştir. Bu çalışmada çilek, domates ve fasulyedeki hastalıkları belirlemek için derin öğrenme kullanılmıştır.

2.3.2. Derin Öğrenmenin Güçlü Yönleri

Derin öğrenme, bütün katmanların temsillerini entegre bir şekilde öğrenir. Bütün sistem geri bildirim sinyali aracılığı ile kontrol altında tutulur. Böylece oluşturulan modeldeki her değişiklik hedefe ulaşılmasına yardımcı olur. Dolayısıyla üst üste düz modelleri yerleştirmek yerine ara katmanlardan soyut olarak birbirinden temsilleri öğrenmek mümkündür. (Erkuş, 2020)

Derin öğrenmeyi farklılaştıran temel özelliklerden biri. Geleneksel makine öğrenimi teknikleri, verileri kullanmadan önce model için anlamlı hale getirmek üzere ön işleme gerektirir. Sorunları çözmeye yardımcı olmak için girişi daha belirgin hale getiren özellikleri ayıklayın. Derin öğrenme, makine öğrenimi açısından kritik olan bu insanın, sorunları tamamen otomatikleştirerek kendi başlarına çözdüğü gibi çözmesini kolaylaştırdı. Şekil 2.7, klasik makine öğrenimi ve derin öğrenme modellerinin görüntülerdeki girdileri ne yöntemle tahmin ettiğini göstermektedir. (Erkuş, 2020)



Şekil 2.7. Geleneksel Makine Öğrenmesi ve Derin Öğrenme Yaklaşımının Karşılaştırılması(Erkuş, 2020)

Eğitim verilerini artırmak için klasik makine öğrenimi tekniklerini kullanmak, performans üzerinde her zaman olumlu bir etkiye sahip değildir. Derin öğrenme ile eğitim verileri çeşitlenip büyüdükçe başarımlar yüzdelere de bu oranda artar. Bu da, derin öğrenmenin çok sayıda eğitim verisi gerektirdiğini göstermektedir.

Derin sinir ağlarıyla çalışırken yaygın olarak üç farklı yöntem kullanılır. İlk olarak, sorunu çözmek için uygun bir derin ağ modeli oluşturulur ve eğitilir. Önceden eğitilmiş ağ yapısı daha sonra yeni verilerle eğitilir ve son olarak diğer makine öğrenimi yöntemlerinde kullanılmak üzere derin sinir ağından özellikler çıkarılır. Bu çalışma, görüntülerden meyve ve sebzelerdeki hastalıkları tespit etmek için görüntü tanıma sağlar. Her üç yöntem de bu çalışma kapsamında kullanılmıştır. (Erkuş, 2020)

2.3.3. Temel Derin Öğrenme Kavramları

Derin bir ağı yapısı, girdi verilerini tahminlere eşlemek için bağlantılı katmanlardan oluşur. Daha sonra, ağı tahminlerinin hedefle ne kadar iyi eşleştiğini ölçmek için kayıp değerini, tahmin ile hedef arasındaki farkı bulmak için bir kayıp fonksiyonu kullanılır. Ağırlık ve sapma değerleri, optimizasyon algoritmasının kayıp değeri ile güncellenir. (Erkuş, 2020)

2.3.3.1. Ağırlık

W harfi ile temsil edilen ve İngilizce'de ağırlık anlamına gelen bu kavram eğitilmiş parametrelerden biridir. (Erkuş, 2020)

2.3.3.2. Sapma

B harfi ile temsil edilen ve İngilizce'de yanlışlık anlamına gelen eğitilmiş parametrelerden biridir. Sapma, ağırlıklara uygulanan ek doğrusal bileşendir. Sapma, ağırlıklandırma faktörü girdilerinin aralığını temelden değiştirme amacıyla eklenmiştir. (Erkuş, 2020)

2.3.3.3. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, çok boyutlu veri kümelerine etkileyen ve doğrusal olmayan fonksiyonlardır. Aktivasyon fonksiyonunun kullanılmasının amacı, sapma ve ağırlık değerlerinin ayarlanmasıdır. (Erkuş, 2020)

Sık kullanılan aktivasyon fonksiyonlarına değinmek gerekirse; Hiperbolik Tanjant Fonksiyonu, ReLU Fonksiyonu ve Softmax Fonksiyonlarıdır.

➤ Hiperbolik Tanjant Fonksiyonu (Tanh); Sigmoid Fonksiyonunun $[-1$ ve $1]$ aralığındaki fonksiyondur. Eşikleme 0 değerinde sağlanmaktadır. Bu yüzden değeri 0 dan küçük sayılar 0 (sıfır) olarak kabul edilmeyip -1 'e yaklaşan değerler almaktadır. Hiperbolik Tanjant denklem (2.1) ile ifade edilir:

$$, -1 \leq f(x) \leq 1 \quad (2.1)$$

➤ ReLU Fonksiyonu; Doğrultulmuş lineer birim aktivasyon fonksiyonudur. ReLU Fonksiyonu da tıpkı Sigmoid fonksiyonu gibi 0'dan küçük değerleri 0 değeri olarak kabul etmek gibi bir soruna sahiptir. Bu fonksiyonda 0'dan büyük değerler x ; küçük değerler ise 0 olarak kabul edilmektedir. ReLU Fonksiyonunun formülü şu şekildedir:

$$y = f(x) = \max(0, x), \quad 0 \leq f(x) \quad (2.2)$$

➤ Softmax Fonksiyonu;

Verilen her bir girdinin bir sınıfa ait olma olasılığını gösteren ve $[0,1]$ arası çıktılar üreten aynı zamanda çoklu sınıflandırma sorunları için kullanılan bir fonksiyondur. Softmax Fonksiyonunun formülü şu şekildedir:

$$\sigma: \mathbb{R}^n \rightarrow \text{int}(\Delta^{n-1}), \quad \sum \sigma_i > 0 \quad (2.3)$$

2.3.3.4. Eniyileme ve Öğrenme katsayısı

Hata düzeltme katsayıları ya da öğrenme katsayıları, taşıyıcı sinapslar, YSA'da akson görevi görür ve gradyan iniş algoritmasında kullanılan katsayılardır. Öğrenme katsayısı, eğim inişi cinsinden tanımlanan algoritmanın yakınsamasını sağlar. Öğrenme katsayısı büyüdükçe, sinaps bilgiyi bir sonraki katmana iletemez. Bu katsayıya küçük bir değer verildiğinde öğrenme sürecinin uzamasına etki eder.

Öğrenme katsayılarını öğrenme amacıyla farklı optimizasyon algoritmaları kullanılmaktadır. Bir optimizasyon algoritmasının amacı, öğrenmenin nasıl ilerleyeceğini belirlemektir. Sık kullanılan eniyileme algoritmaları Momentum, Adagrad, Adamax, Nadam ve Adadelta algoritmalarıdır. (Erkuş, 2020)

2.3.3.5. Kayıp fonksiyonu

Bir hedefin gerçek değeri ve tahmin edilen değeri arasındaki mesafeyi ölçen fonksiyon, kayıp fonksiyonu olarak tanımlanmaktadır. (Erkuş, 2020)

2.3.3.6. Geri yayılım

Kayıp fonksiyonunun eğimini kullanarak ağırlıkların güncellenmesi olarak ifade edilir. Amaç, gerçek çıktının hedef çıktıya daha yakın olmasını sağlamaktır. (Erkuş, 2020)

2.3.3.7. Yığın, epok ve tekrar sayısı

Toplu iş, modelin tek seferde işlediği sayıdır. Tüm girdiyi bir kerede göndermek yerine, girdi rastgele seçilen eşit büyüklükte bağımsız yığınlara bölünür ve ağ eğitilir. Tüm girdi yığınlarının aynı anda işlenmesi epok olarak adlandırılır ve her bir blok yığını teker teker işlenir.

2.3.4. Derin Öğrenme Mimarileri

Sık kullanılan derin öğrenme mimarileri şunlardır; (Erkuş, 2020)

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

Genel olarak bir sonraki adımı tahminlemek için kullanılan bir derin öğrenme yapısıdır. Bu yapı, ses tanıma sistemlerinde sıklıkla kullanılmaktadır.

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

Visible ve hidden olmak üzere iki katman oluşan giriş veri seti üzerindeki olasılıksal dağılımları öğrenen bir derin öğrenme yapısıdır.

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

Uzun süreli bağımlılıkları öğrenebilen yinelemeli bir derin öğrenme yapısıdır.

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

Çok sayıda evrişim ve havuzlama katmanına sahip ileri beslemeli bir derin öğrenme yapısıdır. Genellikle görüntü ve video işleme ve öneri sistemleri gibi uygulamalarda bu mimari kullanılmaktadır.


Bu çalışmada meyve ve sebzelerdeki hastalıkların tespiti için evrişimsel sinir ağları tercih edilmiştir.

2.3.5. Evrişimsel Sinir Ağlar (ESA)

LeCun tarafından literatüre giren ve ismini evrişimli katmandan alan bu yapı, ilk defa el yazısı sayıları tanımış ve yayınlanmıştır. Amerika Birleşik Devletleri Posta Servisi zarfların üzerindeki posta kodlarını okumak için kullanmıştır (Sağıroğlu ve ark. 2003). Evrişimli katmanlar daha özel doğrusal işlemler içerir. Doğrusal fonksiyonlar arasından seçim yapılarak belirlenen bir fonksiyonun

kullanıldığı ve matris çarpımlarının bir veya daha fazla katmanının evrişim işlemleriyle değiştirildiği bir sinir ağı olarak tanımlanabilir (Pratt, 1999).

Evrişimli sinir ağlarının genellikle görüntüler gibi 2B verilerle kullanıma uygun olduğu varsayılmaktadır. Görsel korteksin nörobiyolojik bir modelinden ilham alınarak ve eş zamanlı olarak evrişimli bir sinir ağı oluşturulmuştur. Dolayısıyla evrişimli sinir ağı yapısı, diğer ağı yapılarına göre görsel nesne tanımada daha etkilidir. Şekil 2.8, evrişimsel bir ağı katmanlarını göstermektedir (Goodfellow ve ark. 2016).




Şekil 2.8. Evrişimli sinir ağı katmanları(Ure, 2019)

Evrişimli Sinir Ağ yapıları beş katmandan oluşur. Evrişimli Sinir Ağ mimarisindeki katmanlar; giriş katmanı, evrişimsel katman, havuzlama katmanı, tam bağlı katman ve çıktı katmanlarıdır (S. University,2020).

Giriş Katmanı: Evrişimsel Sinir Ağı'nın birinci katmanıdır. Giriş verisi bir işleme tabi tutulmadan bir sonraki ağı verilir.

Evrişim Katmanı: Verilerin evrişim denilen matematiksel işlere tabi tutulduğu ikinci Evrişimsel Sinir Ağı katmanıdır. Verilerin bölgesel örüntülerini doğrusal evrişim adı verilen işlem sayesinde öğrenmektedir.

Havuzlama Katmanı: Kanal sayısının sabit tutulduğu bu katmanda, bazı filtreler belirlenir. Bu filtreler içerisinde yer alan ilgili piksellerin genişlik ve yükseklik boyut küçülmesi yapılmaktadır. Yapılan bu işlem, bilgi kaybına neden olsa da hesaplama yükünü azaltır (Wang ve Raj, 2017). Şekil 2.9.'da 4x4 görsele 2x2 boyutunda filtre uygulanmış görüntü yer almaktadır;



Şekil 2.9. 4x4 görsele 2x2 boyutunda filtre uygulama (Krizhevsky, ve ark. 2012)

Tam Bağlı Katman: Her bir girişin bütün nöronlara bağlı olduğu Evrişimsel Sinir Ağı katmanıdır.

Çıktı Katmanı: Sınıflandırmanın olduğu Evrişimli Sinir Ağı katmanıdır. Bu katmanda, sınıflandırma için genellikle en başarılı olan softmax fonksiyonu kullanılmaktadır. Çıkış değeri sayısı, sınıf sayısı kadardır.

Birçok farklı modeli Evrişimli Sinir Ağı ile tasarlanabilmektedir. Ancak kullanılacak modelin belirlenmesi, sorunun çözümünde önemli bir faktördür. Modellerin temelde bulunan katmanların farklı şekilde sıralanması, girdi ve çıktı katmanları hariç tutularak, farklı birçok modellerin tasarımına olanak sağlamaktadır. 2012 yılında düzenlenen Büyük Ölçekli Görsel Tanıma Yarışması'nda birinci olan AlexNet modeli, Evrişimli Sinir Ağ yapılarının görüntü tanımadaki başarısını göstermektedir. Bu sayede derin öğrenmenin kullanımı yaygınlaşmıştır (Krizhevskyve ark. 2012 ; Ganatra ve Patel, 2018).


2.3.6. Aktarımlı Öğrenme

Bir konudaki tecrübelerimizi benzeyen özelliklere sahip farklı bir sorunu çözmek için de kullanırız. Örneğin, bisiklet sürmeyi öğrenen biri, bu deneyimi araba kullanmayı daha kolay öğrenmek için kullanabilir. Bilgi veya deneyim, eğitilen modelin ağırlık ve sapma değerlerinde yapay sinir ağlarında depolanır. Transfer öğrenme, belirli bir konuda eğitilen bir modelin, o konuya benzer problemler için tamamen veya kısmen yeniden eğitilmesidir. Sonuç olarak, önceden eğitilmiş modellerin eğitimsiz modellere göre daha hızlı öğrenmesi veya daha başarılı olması beklenir. Bu, görsel dünyaya anlamlı özellikler sağlama konusunda eğitilen sınıflardan daha az veriyle çok farklı bir sorunu çözer. Bu çalışmada birbirinden

farklı mimarilere sahip ESA, ResNet ve InceptionV3 modellerini kullanarak meyve ve sebzelerden oluşan bir ImageNet veri setini bu şekilde başarılı bir şekilde sınıflandırılmasını sağlamaktadırlar. (Erkuş, 2020)

2.3.6.1. InceptionV3


LeNet mimarisine dayalı yeni bir modül olan InceptionV3, iç içe katmanlardan oluşmaktadır. InceptionV3, bir tür konvolüsyonel sinir ağ modelidir. Modelin mimarisi aşağıdaki gibidir; (AI. Aggarwal, 2018). Şekil 2.10.'da InceptionV3 mimarisi yer almaktadır;



Şekil 2.10. Inception yapısı(Szegedy, 2015)

2.3.6.2. ResNet50

23 milyon parametreye sahip yaklaşık 152 katmandan oluşan bir yapıdır. ResNet50, sınıflandırma ve görüntü algılamada sıklıkla kullanılan bir mimaridir. ResNet50 mimarisi, öğrenimindeki tıkanıklığı iyileştirmeyi hedefler. Aşağıda, ResNET ve ResNET50 yapıları için darboğazlar sağlayan "artık" bloklar vardır. (Targ, Almeida, Lyman, 2016). Şekil 2.11.'de Bir ResNet yapısının yapı taşı ve ResNet50 darboğaz yapı taşı görüntüsü yer almaktadır;



Şekil 2.11. Bir ResNet yapısında daha derin bir artık fonksiyon yapı taşı ve ResNet-50’de bir “darboğaz” yapı taşı(K.He vs. 2015 , S.Targ vs. 2016)

2.4.Performans Metrikleri

Bu çalışma kapsamında kullanılan metrikler precision, recall, accuary ve F1- score değerleridir. Bu metriklerin tanımı ve formülleri aşağıda olduğu gibidir. (Acar ve ark. 2022):

Precision: Türkçe karşılığı “kesinlik” anlamına gelen bu terim, veri sonucunun uygunluğunun ölçüsüdür. “P” ile ifade edilen bu metrik, gerçek pozitiflerin sayısı olarak tanımlanır. TP (doğru pozitif) ve FP (yanlış pozitif) olmak üzere;

$$Precision = \frac{TP}{TP+FP} \quad (2.4)$$

Recall: Türkçe karşılığı “geri çağırmak/hatırlamak” anlamına gelen bu terim, kaç adet gerçekten alakalı sonucun döndürüldüğünün ölçütüdür. “R” ile ifade edilen bu metrik, gerçek pozitiflerin sayısı olarak tanımlanır. TP (doğru pozitif) ve FN (yanlış negatif) olmak üzere;

$$Recall = \frac{TP}{TP+FN} \quad (2.5)$$

Accuary: Türkçe karşılığı “doğruluk” anlamına gelen bu terim, başarı oranının bir ölçütüdür.

$$Accuary (\%) = \frac{TP+TN}{TP+TN+FP+FN} \times 100 \quad (2.6)$$

F-1 Score: Türkçe karşılığı “F-1 Değeri” anlamına gelen bu terim, kesinlik ve hatırlama değerlerinin harmonik ortalamasıdır.

$$F2 = 2 \frac{P \times R}{P+R} \quad (2.7)$$

3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Gerçekleştirilen tez çalışması iki temel bölümden oluşmaktadır. İlk kısım, çalışma kapsamında WEB1 olarak anılan kaagle.com ile ulaşılan resimlerin indirilerek bilgisayara depo edilmesi, veri setinin oluşturulması, ikinci olarak, sistemin seçilen meyve hastalıklarını tespit edebilmesi için birbirinden farklı modellerin geliştirilip eğitilmesi sınıflandırması ve eğitim başarısının değerlendirilmesidir. Son olarak bu işlemi bir programlama kodu yazılarak, seçilen resimlerin bilgisayara bağlı webcam vasıtasıyla kameraya gösterilen görüntünün ekrana gerçek zamanlı metin olarak yazdırılmasına hazır hale getirmeyi amaçlanmaktadır. Bu kapsamda kullanılan materyal bilgileri şöyledir:

Oluşturulan modeller, Microsoft Visual Studio 1.81 İntel Xeon E7-8893 v4 CPU 3.20 Ghz 'e sahip Microsoft Windows Server 2019 x64 bit işletim özellikteki bilgisayar aracılığıyla geliştirilmiştir. Mevcuttaki başka programlama dillerine nispeten program kodunu en hızlı yazmaya olanak sağlayan Python dili kullanılmıştır. Microsoft Visual Studio 1.81 ortamında TensorFlow arkauç motoru ve keras kütüphanesi kullanılarak yazılım geliştirilmiştir.

Bu çalışma bir bilgisayarda yazılan kodlar ve veri setinden oluşmaktadır. Gerçekleştirilen çalışmada, eğitim için kullanılan veri setinde modeller oluşturulmuştur. Son olarak test veri setinde bulunan görüntüler kullanılarak çilek, domates ve fasulyedeki hastalıklar tespit edilmiştir. Çalışmadaki amaç sebze ve meyvelerdeki hastalıkların karşılığını doğru olarak tanınmasıdır.

3.1. Araştırmaya İlişkin Bulgular

Modeller, Microsoft Visual Studio 1.81 İntel Xeon E7-8893 v4 CPU 3.20 Ghz 'e sahip Microsoft Windows Server 2019 x64 bit işletim özellikteki bilgisayar üzerinde test edilmiştir. Ekran kartı yetersizliğine bağlı olarak çalışmanın epok sayısı sınırlı tutulmuştur. Verilere uyarlanan derin öğrenme yöntemlerinde çok sayıda parametre bulunduğu için uygulama çok zaman almaktadır. Dolayısıyla bu tez kapsamında en uygun epok sayısının tüm yöntemlerde belirlenmiştir. En uygun epok

sayısı genellikle 5 ve 15 sayıları arasındadır. Son olarak, veri setinin 1/2'si eğitim, 1/4'ü validasyon ve 1/4'ü test için kullanılmıştır.

3.1.1. 10 Katmanlı ESA yapısına ait eğitim sonuçları


CNN mimarisi ile en uygun epok sayısı için incelemeler yapılmıştır. Çizelge 3.1'de 5, 10 ve 15 epoklardaki eğitim veri setinin başarımları ve kayıp değerleri bulunmaktadır. Başarımları en yüksek olan 15 epoktaki %68.83'lük başarımları ve 0.83'lük kayıp eğrisi Şekil 3.1 ve Şekil.3.2' de yer almaktadır.

Çizelge 3.1. 10 Katmanlı ESA(CNN) yapısına ait eğitim sonuçları

Epok	Zaman	Resim Boyutu	Kayıp ve Başarımları
5	11:27:01	416x416	Kayıp:1.1069-Başarımları: 56.80%
10	22:32:05	416x416	Kayıp:0.9551-Başarımları: 64.82%
15	28:24:02	416x416	Kayıp:0.83-Başarımları: 68.83%



Şekil 3.1 10 katmanlı ESA mimarisi başarımlar grafiği



Şekil 3.2 10 katmanlı ESA mimarisi kayıp grafiği

3.1.2. 10 Katmanlı ESA yapısına ait test sonuçları

CNN mimarisi ile eğitilen veri setinin test sonuçları, precision, recall, accuary ve F1 score değerleri ile birlikte aşağıda yer alan Çizelge 3.2 'de yer aldığı gibidir.

Çizelge 3.2 10 Katmanlı ESA(CNN) yapısına ait test sonuçları

Test Accuary	Precision	Recall	F-1 Score
%69.51	0.7482	0.6465	0.6936

3.1.3. Inceptionv3 mimarisine ait eğitim sonuçları

InceptionV3 mimarisi ile en uygun epok sayısı için incelemeler yapılmıştır. Çizelge 3.3.'te 5, 10 ve 15 epoklardaki başarımlar ve kayıp değerleri bulunmaktadır. Başarımlar oranı en yüksek olan 15 epoktaki %79.18'lik başarımlar ve 0.5749'luk kayıp eğrisi Şekil 3.3. ve Şekil.3.4.' te yer almaktadır.

Çizelge 3.3. InceptionV3 mimarisine ait eğitim sonuçları

Epok	Zaman	Resim Boyutu	Kayıp ve Başarımlar
5	6:42:30	416x416	Kayıp:1.127-Başarımlar: 56.45%
10	13:17:25	416x416	Kayıp:0.7669-Başarımlar: 71.46%
15	19:11:38	416x416	Kayıp:0.5749-Başarımlar: 79.18%



Şekil 3.3. InceptionV3 Mimarisinin Başarım Grafiği



Şekil 3.4. InceptionV3 Mimarisinin Kayıp Grafiği

3.1.4. Inceptionv3 mimarisine ait test sonuçları

Inceptionv3 mimarisi ile eğitilen veri setinin test sonuçları, precision, recall, accuary ve F1 score değerleri ile birlikte aşağıda yer alan Çizelge 3.4'te yer aldığı gibidir.

Çizelge 3.4. Inceptionv3 mimarisine ait test sonuçları


Test Accuary	Precision	Recall	F-1 Score
%55.06	0.5942	0.5137	0.551

3.1.5. ResNet50 derin öğrenme mimarisine ait eğitim sonuçları


ResNet50 mimarisi ile en uygun epok sayısı için incelemeler yapılmıştır. Çizelge 3.5.'te 5,10 ve 15 epoklardaki başarımlar ve kayıp değerleri bulunmaktadır. Başarımlar oranı en yüksek olan 15 epoktaki %78.63'lük başarımlar ve 0.9889'luk kayıp eğrisi Şekil 3.5. ve Şekil.3.6.' da yer almaktadır.

Çizelge 3.5. ResNet50 mimarisine ait eğitim sonuçları

Epok	Zaman	Resim Boyutu	Kayıp ve Başarımlar
5	7:58:22	416x416	Kayıp:1.3869- Başarımlar: 74.66%
10	15:05:01	416x416	Kayıp:1.5020- Başarımlar: 73.74%
15	22:14:27	416x416	Kayıp:0.9889- Başarımlar:78.63%



Şekil 3.5. ResNet50 Mimarisinin Başarım Grafiği



Şekil 3.6. ResNet50 Mimarisinin Kayıp Grafiği

3.1.6. ResNet50 derin öğrenme mimarisine ait test sonuçları

ResNet50 mimarisi ile eğitilen veri setinin test sonuçları, precision, recall, accuary ve F1 score değerleri ile birlikte aşağıda yer alan Çizelge 3.6’da yer aldığı gibidir.

Çizelge 3.6. ResNet50 mimarisine ait test sonuçları

Test Accuary	Precision	Recall	F-1 Score
%60.98	0.6192	0.5815	0.5998

3.2. Tartışma

Bu çalışmada kullanılan bütün yöntemlerin eğitim veri setindeki başarımlar oranları Çizelge 3.7’de yer alırken; test veri setindeki başarımlar oranları Çizelge 3.8’de yer almaktadır. Genel olarak oluşturulan modellerden CNN modelinin test aşamasında daha iyi performans gösterdiği görülmektedir.

15 epok eğitimin sonunda yapılan testlerde %69.51’lik bir başarımlar oranı gösteren 10 katmanlı ESA(CNN) mimarisi, en yüksek başarımlar oranı elde edilen mimari olarak tespit edilmiştir.

Bu tez çalışmasında çeşitli derin öğrenme yöntemleri kullanılarak meyve ve sebzelerde hastalıklar tespit edilmiştir. Daha iyi ve yeterli donanıma sahip olunabilseydi, daha yüksek epoklarda çalışılabilir ve daha iyi başarımlar oranları elde edilebilirdi.

Derin öğrenme modellerindeki CNN, zaman ve performans açısından en başarılı modeldir.

Çizelge 3.7. Modellerin eğitim verisi üzerindeki zaman ve başarımlar oranları karşılaştıran tablo

Model	Resim Boyutu	Epok	Zaman	Başarımlar Oranı
10-Katmanlı ESA(CNN)	416x416	15	28:24:02	%68.83
ResNet50	416x416	15	22:14:27	%78.63
InceptionV3	416x416	15	19:11:38	%79.18

Çizelge 3.8. Modellerin test verisi üzerindeki zaman ve başarımların karşılaştırma tablosu

Model	Resim Boyutu	Başarımlar
10-Katmanlı ESA(CNN)	416x416	%69.51
ResNet50	416x416	%60.98
InceptionV3	416x416	%55.06

Bu çalışma kapsamında yapılan her üç modeldeki test verilerine ait metrikler, Çizelge 3.9'daki gibidir;

Çizelge 3.9. Modellerin test metrikleri

Model	Accuracy	Precision	Recall	F-1 Score
10-Katmanlı ESA(CNN)	%69.51	0.7482	0.6465	0.6936
ResNet50	%60.98	0.6192	0.5815	0.5998
InceptionV3	%55.06	0.5942	0.5137	0.551

Literatürde, bu çalışmadaki veri setinde herhangi bir çalışma olmadığı için kıyas diğer çalışma sonuçları ile yapılamamıştır. Ancak benzer veri setlerine sahip çalışmaların başarımların ile yapılan karşılaştırma tablosu Çizelge 3.10'daki gibidir;

Çizelge 3.10. Modellerin diğer çalışmalar ile karşılaştırılması

Çalışma	Metot	Veri Tipi	Başarımlar
Günasekaran (1996)	CNN	Domates	%92
Jolly&Raman (2017)	SVM+K-NN	Elma	%85.93
Aslan (2021)	CNN+AlexNet	Şeftali	%99.30
Terzi, Özgüven ve Yağcı (2023)	CNN	Üzüm	%96.10
Sevli (2023)	CNN	Elma	%98.76
Hazırlanan Çalışma	CNN	Domates+Çilek+Fasulye	%69.51

Yapılan bu çalışmaya ait başarımların düşük olmasının sebepleri, veri setindeki sınıflara ait verilerin dengesiz dağılımı (unbalance), ekran kartı yetersizliği, sunucu yetersizliğinden kaynaklı epok sayılarının sınırlı ve düşük seviyede tutulması ve veri setindeki sınıf sayısının çokluğu ve bu sınıfların birbirine benzemesidir.

Veri setinde yer alan görüntülerde her bir görüntüye ait arka plan izole olmadığından ve her bir sınıfa ait görüntüler birbirine benzer olduğundan dolayı veri setinin zor ve ayırt ediciliğinin de zor olduğu söylenebilir. Bu yüzden sistem eğitim aşamasını iyi sağlayamamıştır. İlerleyen zamanlarda segmentasyon teknikleri kullanarak bu sonuçların iyileştirilmesi düşünülmektedir.

3.3. Gerçek Zamanlı Uygulama Örnekleri

Bu aşamada, veri setinde bulunan görüntülere öncelikle veri çoklama işlemi yapılmış olup, veri setindeki görüntü sayısı arttırılmıştır. Oluşan görüntüler, CNN, InceptionV3 ve ResNet50 modellerinde eğitilmiştir. Eğitimde kullanılmayan test klasöründeki fotoğraflar rastgele seçilerek hastalık tahmin edilmiştir. Bu tahmin sonucundaki tespit edilen hastalık, ekran çıktısı olarak gösterilmiştir. Model dosyası kaydedilip kamera aracılığı ile canlı uygulamaya hazır hale getirilmiştir. Test veri seti ile yapılan çalışmadaki hastalık tahminlerin CNN modelinden beslenerek örnek çıktılar Şekil 3.7, Şekil 3.8, Şekil 3.9, Şekil 3.10 ve Şekil 3.11’de de gösterildiği gibi sistem tarafından sağlanmıştır.



Şekil 3.7. Çilek Köşeli Yaprak Lekesi Hastalık Tespiti



Şekil 3.8. Fasulye Köşeli Yaprak Lekesi Hastalık Tespiti



Şekil 3.9. Çilek Yaprak Lekesi Hastalık Tespiti



Şekil 3.10. Çilek Çiçek Yanıklığı Hastalık Tespiti



Şekil 3.11. Domates Yaprak Küfü Hastalık Tespiti

4. SONUÇLAR VE ÖNERİLER

4.1. Sonuçlar

Temel amacı sebze ve meyve hastalık görüntülerinden hastalık sınıflandırmasını güvenilir bir şekilde tespit etmek olan bu çalışma, derin öğrenme yöntemleri uygulayarak sebze ve meyve hastalıklarının tespitini sağlamaktadır. Bu bağlamda, bu problem için özel olarak tasarlanmış bir evrişimli sinir ağı kullanmanın iyi sonuçlar verdiği görülmüştür. Bunu başarmak için, çeşitli derin öğrenme teknikleri araştırılmıştır. Evrişimli sinir ağlarını öğrenme aktarımı ile farklı mimarilerle karşılaştırdığımızda, CNN mimarisinin yapısının yaklaşık %69.51 ile en başarılı olduğu görülmektedir. Tüm yöntemleri zaman ve sınıflandırma başarı oranı açısından karşılaştırdığımızda, öğrenme problemleri meyve ve sebze meyve hastalıkları için en iyi yöntem, 10 katmanlı ESA (CNN) mimarisini kullanmaktır.

Bu çalışmamızda kullandığımız veri setinde arka plan izole değildi. Veri seti, birbirine çok benzeyen ve farklı açılardan çekilen görüntülerden oluşmaktaydı. Dolayısıyla sistem eğitim aşamasını iyi sağlamamıştır. İlerleyen zamanlarda transfer learning ve segmentasyon(UNET ve SEGNET) teknikleri kullanarak sonuçları iyileştirmek hedeflenmiştir.

Ülkemizde meyve hastalığı tespit sistemi ile ilgili az sayıda çalışma vardır. Bu sistem ek ekipman kullanılmadığı için ucuzdur, veri çeşitliliği iyi olduğu için kullanıcı dostudur. Sonuç olarak, bu çalışma çerçevesinde elde edilen orijinal veriler gerçek zamanlı olarak uygulamaya hazır hale getirilerek meyve hastalıklarının başarılı bir şekilde tespiti sağlanmıştır.

4.2. Öneriler

Mevcut çalışmada, modelin başarısı, öğrenme transferinde ince ayar yapılarak önceden eğitilmiş diğer başarılı modellerle karşılaştırılabilir. Ancak meyve hastalıklarına çilek dışındaki meyve ve sebzeler, sebze hastalıklarına fasulye ve domates yaprağı dışındaki sebzeler eklenerek sınıf sayısı artırılabilir. Üretim hatlarında veya paketlemede kullanılan hareketli sistemlerde sebze ve meyve

hastalıklarının tespiti için video tabanlı tespit sistemi oluşturulabileceği öngörülmektedir. Ayrıca bu çalışmada tasarlanan sistem geliştirilerek ürünün hasat öncesi ve henüz çimlenmemiş meyve yapraklarında tanınması mümkündür. Tüm tüketicilerin günlük hayatta kullanabileceği, meyve ve sebzelerle ilgili bir uygulamanın kapsamlı bir şekilde inceleneceği ve bu uygulamanın akıllı telefonlarda çalışıp çalışmadığı, ayrıca dokunma gerektirmeden kullanılıp kullanılamayacağı belirlenecektir. Bu tür araştırmalar, meyve hastalıklarının önlenmesine ve üretimden son tüketiciye ekonomik zararın önlenmesine önemli katkı sağlayacaktır.



KAYNAKLAR

Allen, D,j, The pathology of tropical food legums: disease resistance in crop improvement 1983 pp.428 ISBN: 0471102326

Al. Aggarwal, The Resurgence of Artificial Intelligence During 1983–2010. March 22, Datafloq, 2018

ASLAN, M. (2021). Derin Öğrenme ile Şeftali Hastalıklarının Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (23), 540-546.

Barros. N, Skiles, R.L., O., Cardona Alvarez, *Report 3rd Reun Interamer Fitogen Fitopat Ent Edafol 1955 1958* pp.224-5 pp. , Protective effect of seed treatment of beans with fungicides against root rots.

Bishop, C., M. , (2006),Pattern Recognition and Machine Learning, Springer , ISBN: 978-0387310732. 2., Vol.: 2, pp:12-15,

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)

Cardona. Alvarez, Walker, J. C, *Phytopathology* 1956 vol.46 no.11 pp. 610-615 pp.

Differential Timing of Spider Mite-Induced Direct and Indirect Defenses in Tomato Plants. Merijn R. Kant, Kai Ament, Maurice W. Sabelis, Michel A. Haring, and Robert C. Schuurink. <https://academic.oup.com/plphys/article/135/1/483/6111989>

Erkuş, M. (2020). Türk İşaret Dilinde Kelime Tabanlı Derin Öğrenme Uygulaması, *Başkent Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı*, Yayımlanmış Yüksek Lisans Tezi.

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.

Goodfellow,I., Bengio, Y. , Courville, A.. (2016), Deep learning (Adaptive computation and machine learning). *Cambridge, Massachusetts: The MIT Press*, pp. 22.

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)

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.

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*.

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>

Kelly, J.D., L. Afanador., M.Meletto, Development of a SCAR marker linked to the I gene in common bean, Genome December 1996, *Candian Science Publishing* <https://doi.org/10.1139/g96-155>.

Kızılboğa, A. Y. (2021). Yapay sinir ağları ve derin öğrenme teknikleri kullanılarak meyve ve sebzede çeşitli hastalıkların tespit edilmesi (*Master's thesis, Fen Bilimleri Enstitüsü/Bilgisayar Mühendisliği Ana Bilim Dalı*)

Krizhevsky, A., Sutskever, I. ve Hinton, G. E., (2012), Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 1097-1105.

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.

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.

Liebenberg M. Merion, Pretorius A. 2010, *Common Bean Rust: Pathology and Control, South Africa*

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. , İllus . (Re Vised.)

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

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.

Nakano, K. (1997). Application of neural networks to apple color grading. *Computer and Electronics in Agriculture*, 18 (2–3), 105–116.

O. Turk, D. Ozhan, E. Acar, T.C. Akinci, and M. Yilmaz. "Automatic detection of brain tumors with the aid of ensemble deep learning architectures and class activation map indicators by employing magnetic resonance images." *Zeitschrift für Medizinische Physik* (2022). <https://doi.org/10.1016/j.zemedi.2022.11.010>

Pastor. M, Corrales, Carlos Jara, Shree P. Singh, *Eupytica* 103, 161-171 (1998), Pathogenic variation in, sources of, and breeding for resistance to *Phaeoisariopsis griseola* causing angular leaf spot in common bean

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.

Qin, J. ve Lu, R. (2008). Uzamsal olarak çözümlenmiř hiperspektral difüz yansıtma görüntüleme teknięi kullanılarak meyve ve sebzelerin optik özelliklerinin ölçümü. *Hasat Sonrası Biyoloji ve Teknolojisi* , 49 (3), 355–365.

Santos, Gil, Martins da Silva, Raimundo Jacinto; Pereira, João; Dutra, Leôncio Gonçalves, Moraes, Ednan Araújo; vs.. Pesquisa Agropecuária Tropical; Goiânia Vol. 8, Iss. 1, (Jan/Dec 1978): 93. *PRELIMINARY ESSAY OF NPK FERTILIZATION IN COMMON BEAN (Phaseolus vulgaris L.) FOR SOME SOILS OF GOIÁS STATE, BRAZIL*

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

S. University, CS231n: Convolutional Neural Networks for Visual Recognition, <http://cs231n.github.io/neural-networks-2> , Eriřim Tarihi :27.01.2020 , Ankara

Saęıroęlu, ř., Beřdok, E., Erler, M.,(2003), Mühendislikte yapay zeka uygulamaları-1 : yapay sinir aęları,Ufuk Yayınevi, ISBN: 9789759594855 , s: 24-47-

SEVLİ, Ö. Ü. O. ELMA BİTKİSİ HASTALIKLARININ DERİN ÖĞRENME İLE TESPİTİ,

Szegedy,C., Vanhoucke,V., Loffe, S., Shlens, J. and Wojna, Z., *Rethinking the inception architecture for computer vision*. Arřiv Preprint Arřiv:1512.00567, 2015.

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

Terzi, İ., Özgüven, M. M., & Yaęcı, A. (2023). Derin Öğrenme Teknikleri ile Bazı Üzüm Çeřitlerinin Tespiti. *Turkish Journal of Agriculture-Food Science and Technology*, 11(1), 125-130.

Tingting Zhao, Tong Pei, Jingbin Jiang, Huanhuan Yang, He Zhang, Jingfu Li, and Xiangyang Xu* *Key Laboratory of Biology and Genetic Improvement of Horticultural Crops (Northeast Region), Ministry of Agriculture and Rural Affairs, College of Horticulture and Landscape Architecture, Northeast Agricultural University, Harbin 150030, China*

Ure, N.K.,Genc, U., (2019). CNN to RL how AI is changing the ADAS scene, *Eatron Technologies*.

Wang, H., Raj, B. , (2017). On the Origin of Deep Learning, *Language Technologies Institute School of Computer Science Carnegie Mellon University*.

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>

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)

Yıldız, F., Özdemir, AT, & Uluiřık, S. (2019). Evaluation Performance of Ultrasonic Test in Determination of Fruit Quality. *Journal of Food Quality*, 2019. <https://doi.org/10.1155/2019/6810865>

Yue. Xing, Peng Chen , Yu-zhu Wang , Qi-zhi Liu , Yun-tao Zhang , He-qin Li , Wei-hua Li, Phase changes of continuous cropping obstacles in strawberry (*Fragaria × ananassa* Duch.) production, Volume 155, November 2020, 103626, *Elsevier*, <https://doi.org/10.1016/j.apsoil.2020.103626>

Zaumeyer. J.W. , Thomas. Rex. H. A monographic Study of Beans and Methods for Their Control, U.S. Department of Agriculture, Revised February, 1957

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>

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)." *International Food Research. Elsevier Ltd.* <https://doi.org/10.1016/j.foodres.2015.01.034>

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Sevil ÖZCAN
Uyruğu : T.C.

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Üniversite	: Dicle Üniversitesi Merkez/ Diyarbakır	2014
Yüksek Lisans	: Batman Üniversitesi Merkez/ Batman	2023

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2019	Dicle Elektrik Dağıtım A.Ş. Mardin İl Müd.	Kesme- Açma ve Abonelik Süreçleri Mühendisi
2021-devam ediyor	Dicle Elektrik Dağıtım A.Ş. Genel Müd.	Müşteri Teknik Hizmetleri Mühendisi

UZMANLIK ALANI: Elektrik Tesisat Projeleri

YABANCI DİLLER: İngilizce

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR*