



T.C.  
KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ

BUĞDAYDA SARI PAS (*Puccinia striiformis*) HASTALIĞININ  
DEĞERLENDİRİLMESİ İÇİN GÖRÜNTÜ İŞLEME TEKNİKLERİ  
KULLANILARAK BİR KARAR DESTEK SİSTEMİNİN  
GELİŞTİRİLMESİ

TOLGA HAYIT  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

DANIŞMAN  
Prof. Dr. Hasan ERBAY

KIRIKKALE-2021



T.C.  
KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLER ENSTİTÜSÜ

BUĞDAYDA SARI PAS (*Puccinia striiformis*) HASTALIĞININ  
DEĞERLENDİRİLMESİ İÇİN GÖRÜNTÜ İŞLEME TEKNİKLERİ  
KULLANILARAK BİR KARAR DESTEK SİSTEMİNİN  
GELİŞTİRİLMESİ

TOLGA HAYIT  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

DANIŞMAN  
Prof. Dr. Hasan ERBAY

KIRIKKALE-2021

Tolga HAYIT tarafından hazırlanan “BUĞDAYDA SARI PAS (*Puccinia striiformis*) HASTALIĞININ DEĞERLENDİRİLMESİ İÇİN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BİR KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİ” adlı tez çalışması, aşağıdaki jüri tarafından OY BİRLİĞİ / ÖY ÇOKLUĞU ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Başkan, Danışman: Prof. Dr. Hasan ERBAY

İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Türk Hava Kurumu Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.

Üye : Doç. Dr. Bülent Gürsel EMİROĞLU

İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.

Üye : Dr. Öğr. Üyesi Fahrettin HORASAN

İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.

Üye : Dr. Öğr. Üyesi Hakan KÖR

İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Hitit Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.

Üye : Dr. Öğr. Üyesi Ahmet Haşim YURTTAKAL

İmza.....

Bilgisayar Mühendisliği Anabilim Dalı, Afyon Kocatepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.

Tez Savunma Tarihi: 15/09/2021

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Recep ÇALIN

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Müdürü



*Biricik eşime ve Mustafa Kemal'ime...*

## ETİK BEYANI

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

(İmza)

Tolga HAYIT

15.09.2021

## ÖZET

### BUĞDAYDA SARI PAS (*Puccinia striiformis*) HASTALIĞININ DEĞERLENDİRİLMESİ İÇİN GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BİR KARAR DESTEK SİSTEMİNİN GELİŞTİRİLMESİ

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Doktora Tezi

Danışman: Prof. Dr. Hasan ERBAY

Eylül 2021, 119 sayfa

Buğdayda sarı pas hastalığı (*Puccinia striiformis*) son derece tahribat özelliğinden dolayı, dünya çapında buğday üretiminde önemli ekonomik kayıplara neden olmaktadır. Esasında, buğday yetiştiriciliği alanlarında hastalıkların görülme şiddetine göre farklı düzeylerde verim ve kalite kayıpları oluşabilmekte ve buna bağlı olarak da ekonomik zararlar meydana gelmektedir. Başta Orta Anadolu olmak üzere üretim alanlarında görülen, verim artışını engelleyen ve kalitenin düşmesine neden olan bazı önemli fungal hastalık etmenleri bilinmektedir. Bunların başında Sarı pas hastalığı gelmektedir. Bu hastalık buğdayın verim ve kalitesini sınırlayan önemli faktörler arasındadır. Bu yüzden tarla koşullarında sarı pas hastalığının tespit ve teşhis çalışmalarının sağlıklı bir şekilde sürdürülebilmesi önem arz etmektedir. Sarı pas, buğday yapraklarında çeşitli enfeksiyon türleri ile kendini göstermektedir. Hastalığın enfeksiyon derecesi, kullanılan buğdayın türü, üretim alanlarındaki iklim ve hava koşulları, bitkiyi korumak için kullanılan kimyasallar gibi çeşitli faktörlere bağlıdır. Bu kriterler, araştırmacılara ve üreticilere hastalığa karşı olası eylemleri gerçekleştirebilmeleri ve sonraki dönem için yeterli önlemleri alabilmeleri bakımından gerekli bilgiyi sağlamaktadır. Bununla birlikte, tarla koşullarında hastalığın şiddetinin sınıflandırılması işlemi, alanında uzmanlar tarafından görsel inceleme ile belirli standartlara göre gerçekleştirilir. Hastalığın şiddetinin doğru bir şekilde belirlenememesi üretimde ileriki aşamalarda sorun yaratabilmektedir.

Bu tez çalışması, sarı pas hastalığının incelenmesi için özel olarak ayrılmış tarla ortamından alınan buğday yaprak görüntülerinin 6 çeşit enfeksiyon türü kategorisinde sınıflandırılabilmesi için doku analizi yöntemleri, özellik çıkarımında derin ve yapısal yöntemlerin kombinasyonunu içeren yeni hibrit bir yöntem ve tamamen derin öğrenmeye dayalı yaklaşımları tartışmaktadır. Hibrit öznitelikler geleneksel metotlardan ve derin öğrenme tabanlı modellerden elde edilen özniteliklerin bir araya getirilmesiyle elde edilmiş ve sınıflandırmada doku analizinde başarıları kanıtlanmış metotlar işe koşulmuştur. Derin öznitelikler için önceden eğitilmiş DenseNet-201 ağı kullanılmıştır. Farklı renk uzaylarının renk verilerinden de faydalanılmıştır. Hibrit özelliklere dayalı sınıflandırmada %91,7 doğruluk başarıları elde edilmiştir.

Diđer yandan aynı veri seti kullanılarak tamamen derin öğrenmeye dayalı sınıflandırmada literatürde yer alan önceden eğitilmiş farklı ağlar test edilmiştir ve doğruluk oranları belirlenmiştir. Üç farklı ağ üzerinden gerçekleştirilen denemelerde %91 ortalama doğrulukla en iyi performans Xception modeli ile elde edilmiştir. Çalışmada önerilen yöntemler benzer veri setleri ile yapılabilecek sınıflandırma çalışmaları için temel oluşturmakla birlikte sektörde hastalığın erken teşhisi ve önlenmesi doğrultusunda umut vericidir.

Anahtar kelimeler: Derin öğrenme, evrişimsel sinir ağları, doku analizi, *Puccinia striiformis*



## ABSTRACT

### DEVELOPMENT OF A DECISION SUPPORT SYSTEM BY USING IMAGE PROCESSING TECHNIQUES FOR ESTIMATION OF YELLOW RUST (*Puccinia striiformis*) DISEASE

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, Ph. D. Thesis

Supervisor: Prof. Hasan ERBAY

October 2021, 119 pages

Yellow rust disease (*Puccinia striiformis*) in wheat causes significant economic losses in wheat production worldwide due to its highly destructive property. Essentially, different levels of yield and quality losses may occur in wheat growing areas, depending on the severity of the diseases, and accordingly, economic losses occur. Some important fungal disease are known, which are seen in production areas, especially in Central Anatolia, preventing the increase in yield and causing a decrease in quality. Yellow rust disease is one of them. This disease is among the important factors limiting the yield and quality of wheat. For this reason, it is important that the detection and diagnosis of yellow rust disease in field conditions can be carried out in a healthy way. Yellow rust shows various types of infections on wheat leaves. The level of infection of the disease depends on various factors such as the type of wheat used, the climate and weather conditions in the production areas, and the chemicals used to protect the plant. These criteria provide and producers with the necessary information to take possible actions against the disease and to take adequate measures for the next period. However, the classification of the severity of the disease in field conditions is carried out by experts in the field according to certain standards by visual inspection. Failure to accurately determine the severity of the disease may cause problems in the later stages of production.

This thesis discusses textural analysis methods, a novel hybrid method that includes a combination of deep and textural methods for feature extraction, and deep learning approaches to classify wheat leaf images taken from a specially reserved field environment for the study of yellow rust disease into 6 categories of infections. Hybrid features were obtained by combining the features obtained from traditional methods and deep learning-based models, and methods with proven success in texture analysis were used in classification. Pre-trained DenseNet-201 network is used for deep features. Color data of different color spaces are also used. An accuracy of 91.7% was achieved in classification based on hybrid features.

On the other hand, using the same data set, different pre-trained networks in the literature were tested and their accuracy rates were determined in the classification



based on deep learning. The best performance was obtained with the Xception model with an average accuracy of 91% in the trials performed over three different networks. Although the methods proposed in the study form the basis for classification studies that can be done with similar data sets, they are promising in terms of early diagnosis and prevention of the disease in the sector.

**Key Words:** Deep learning, convolutional neural networks, textural analysis, *Puccinia striiformis*



## TEŐEKKÜR

Tezimin hazırlanması esnasında hiçbir yardımı esirgemeyen ve genç arařtırmacılara her zaman destek olan, her zaman önümüzü açan, tez yöneticisi hocam, Sayın Prof. Dr. Hasan ERBAY'a; arařtırmam sırasındaki akademik desteklerinden dolayı Sayın Dr. Fatih VARÇIN ve Yozgat Bozok Üniversitesi UZEM Müdürü Sayın Dr. Öğr. Üyesi Can MEŐE'ye; çalışmalarında desteklerini esirgemeyen Yozgat Bozok Üniversitesi Boğazlıyan Meslek Yüksekokulu Müdürü Sayın Dr. Öğr. Üyesi Mustafa KOCAKAYA'ya; tez çalışmamın konusu için bana fikir veren ve yönlendiren Sayın Dr. Nilüfer AKCİ'ye teşekkür ederim. Ayrıca tezimde kullanılan veri setini oluřturma aşamasında çalışma arazilerini kullanmama izin veren T.C. Tarım ve Orman Bakanlığı Tarla Bitkileri Merkez Arařtırma Enstitüsü Müdürlüğü'ne teşekkür ederim.

Bu çalışma Türkiye Bilimsel ve Teknolojik Arařtırma Kurumu (TÜBİTAK) 1002-Hızlı Destek Programı 1200960 numaralı proje kapsamında desteklenmiştir.

# İÇİNDEKİLER DİZİNİ

Sayfa

<b>ÖZET</b> .....	<b>IV</b>
<b>ABSTRACT</b> .....	<b>VI</b>
<b>TEŞEKKÜR</b> .....	<b>VIII</b>
<b>İÇİNDEKİLER DİZİNİ</b> .....	<b>IX</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>XIV</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>XVI</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>XIX</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>1.1. Arka Plan</b> .....	<b>1</b>
<b>1.2. Motivasyon</b> .....	<b>4</b>
<b>1.3. Buğday ve Buğday Pası Hastalıkları</b> .....	<b>5</b>
1.3.1. Türkiye’de Buğday.....	5
1.3.2. Buğday Pası Hastalıkları .....	6
1.3.2.1. Yaprak Pası (Kahverengi Pas) .....	6
1.3.2.2. Sap Pası (Kara Pas) .....	7
1.3.2.3. Sarı Pas (Çizgi Pası).....	7
1.3.2.4. Sarı Pasla Mücadele .....	8
<b>1.4. Problem Tanımı</b> .....	<b>9</b>
<b>1.5. Araştırma Soruları</b> .....	<b>9</b>
<b>1.6. Amaçlar</b> .....	<b>10</b>
<b>1.7. Çalışmanın Organizasyonu</b> .....	<b>10</b>
<b>2. SAYISAL GÖRÜNTÜ İŞLEME</b> .....	<b>12</b>
<b>2.1. Başlıca Görüntü İşleme Teknikleri</b> .....	<b>13</b>
2.1.1. Parlaklık Dönüşümleri / Parlaklık Düzeltmeleri .....	13

2.1.1.1. Gama Düzeltme.....	13
2.1.1.2. Histogram Eşitleme.....	14
2.1.2. Geometrik Dönüşümler.....	14
2.1.3. Görüntü Filtreleme.....	15
2.1.4. Görüntü Bölütleme (Segmentasyon).....	15
2.1.5. Fourier Dönüşümü ve Görüntü Restorasyonu.....	15
<b>2.2. Görüntü Doku Analizi .....</b>	<b>16</b>
2.2.1. Doku Bölütleme .....	16
2.2.2. Doku Sınıflandırma.....	17
2.2.3. Gri Seviye Eş-Oluşum Matrisi (GLCM).....	17
2.2.3.1. Kontrast (Haralick vd., 1973; Soh ve Tsatsoulis, 1999).....	18
2.2.3.2. Korelasyon (Haralick vd., 1973; Soh ve Tsatsoulis, 1999) .....	18
2.2.3.3. Entropi (Soh ve Tsatsoulis, 1999).....	19
2.2.3.4. Homojenlik (Soh ve Tsatsoulis, 1999).....	19
2.2.3.5. Enerji (Haralick vd., 1973; Soh ve Tsatsoulis, 1999).....	19
2.2.3.6. Karelerin Toplamı (Varyans) (Haralick vd., 1973).....	19
2.2.3.7. Toplam Varyans (Haralick vd., 1973).....	20
2.2.3.8. Toplam Ortalama (Haralick vd., 1973).....	20
2.2.3.9. Toplam Entropi (Haralick vd., 1973).....	20
2.2.3.10. Varyans Farkı (Haralick vd., 1973).....	20
2.2.3.11. Entropi Farkı (Haralick vd., 1973).....	21
2.2.3.12. Korelasyonun Bilgilendirici Ölçüsü-1 (KBÖ1) (Haralick vd., 1973) .....	21
2.2.3.13. Korelasyonun Bilgilendirici Ölçüsü-2 (KBÖ2) (Haralick vd., 1973) .....	21
2.2.3.14. Maksimum Korelasyon Katsayısı (Haralick vd., 1973).....	21
2.2.3.15. Farklılık (Soh ve Tsatsoulis, 1999).....	22
2.2.3.16. Küme Gölgesi (Soh ve Tsatsoulis, 1999).....	22
2.2.3.17. Küme Belirginliği (Soh ve Tsatsoulis, 1999).....	22
2.2.3.18. Maksimum Olasılık (Soh ve Tsatsoulis, 1999).....	23
2.2.3.19. Ters Fark Momenti (Clausi, 2002).....	23
2.2.3.20. Normalleştirilmiş Ters Fark (NTF) (Clausi, 2002).....	23
2.2.3.21. Normalleştirilmiş Ters Fark Momenti (NTFM) (Clausi, 2002).....	23

2.2.3.22. Otokorelasyon (Soh ve Tsatsoulis, 1999) .....	24
<b>3. MAKİNE ÖĞRENMESİ.....</b>	<b>25</b>
<b>3.1. Terminoloji .....</b>	<b>26</b>
<b>3.2. Makine Öğreniminde Öğrenme/Eğitim Yaklaşımları .....</b>	<b>27</b>
3.2.1. Denetimli Makine Öğrenme Yaklaşımı .....	27
3.2.2. Denetimsiz Makine Öğrenme Yaklaşımı .....	28
3.2.3. Yarı Denetimli Makine Öğrenme Yaklaşımı .....	28
3.2.4. Takviyeli (Pekiştirmeli) Makine Öğrenme Yaklaşımı .....	28
<b>3.3. Sınıflandırma .....</b>	<b>29</b>
<b>3.4. Başlıca Sınıflandırma Algoritmaları .....</b>	<b>29</b>
3.4.1. Destek Vektör Makineleri .....	29
3.4.1.1. Maksimum Marj Sınıflandırıcısı .....	30
3.4.1.2. Destek Vektör Sınıflandırıcısı .....	30
3.4.1.3. Destek Vektör Makinesi .....	31
3.4.2. Karar Ağaçları .....	32
3.4.3. Rastgele Orman .....	34
3.4.4. K-En Yakın Komşu .....	35
3.4.5. Yapay Sinir Ağları .....	37
3.4.5.1. Yapay Sinir Ağlarının Yapısı .....	39
3.4.5.2. Tek Katmanlı Algılayıcılar .....	40
3.4.5.3. Çok Katmanlı Algılayıcılar .....	41
3.4.5.4. İleri Beslemeli Yapay Sinir Ağları .....	41
3.4.5.5. Geri Beslemeli Yapay Sinir Ağları .....	42
<b>4. DERİN ÖĞRENME.....</b>	<b>43</b>
<b>4.1. Derin Öğrenmenin ve Nöronların Çalışma Şekli .....</b>	<b>44</b>
<b>4.2. Derin Öğrenme ve Makine Öğrenimi Arasındaki Fark Nedir? .....</b>	<b>45</b>
<b>4.3. Evrimsel Sinir Ağları (CNN) .....</b>	<b>46</b>
4.3.1. Evrişim Katmanı .....	48
4.3.2. Havuzlama Katmanı .....	49
4.3.3. Tam Bağlantılı Katman .....	50
<b>4.4. Aktivasyon .....</b>	<b>50</b>

<b>4.5. Aşırı Uyum (Overfitting) ve Yetersiz Uyum (Underfitting)</b> .....	<b>50</b>
<b>4.6. Bırakma (Dropout)</b> .....	<b>51</b>
<b>4.7. Toplu Normalizasyon (batch normalization)</b> .....	<b>52</b>
<b>4.8. Başlıca CNN Sınıflandırıcıları</b> .....	<b>52</b>
4.8.1. AlexNet .....	53
4.8.2. VGGNet .....	54
4.8.3. Inception (GoogLeNet) .....	55
4.8.4. ResNet .....	56
4.8.5. MobileNet .....	57
4.8.6. Xception .....	58
<b>5. İLGİLİ ÇALIŞMALAR</b> .....	<b>60</b>
<b>5.1. Yapısal ve Hibrit Özelliklere Dayalı Çalışmalar</b> .....	<b>60</b>
<b>5.2. Derin Öğrenmeye Dayalı Çalışmalar</b> .....	<b>64</b>
<b>6. MATERYAL VE METOT</b> .....	<b>67</b>
<b>6.1. Kullanılan Araçlar ve Yazılımlar</b> .....	<b>67</b>
<b>6.2. Veri Setinin Oluşturulması</b> .....	<b>68</b>
6.2.1. Ekim Çalışmaları.....	68
6.2.2. İnokulasyon ve İnkubasyon .....	70
6.2.3. Görsel Materyalin Elde Edilmesi .....	70
6.2.4. Görüntü Ön İşleme Çalışmaları .....	71
6.2.4.1. Eşikleme .....	72
6.2.4.2. Morfolojik Operatörler (Genişletme ve Kapatma).....	74
6.2.4.3. Maskeleye .....	76
6.2.4.4. Son Görüntünün Kaydedilmesi .....	77
6.2.5. Etiketleme Çalışmaları .....	77
6.2.6. Veri Artırımı.....	79
<b>6.3. Birleştirilmiş (Hibrit) Özelliklere Dayalı Sınıflandırma</b> .....	<b>81</b>
6.3.1. Derin Özelik Çıkarımı.....	81
6.3.1.1. DenseNet ve Transfer Öğrenimi .....	81
6.3.2. Renk-Gri Seviye Eş-Oluşum Matrisi (CGLCM) Özelik Çıkarımı .....	83
<b>6.4. CGLCM ve Derin Özelliklerin Birleşimine Dayalı Özelik Çıkarımı</b> .....	<b>85</b>

<b>6.5. Geleneksel Yapısal Özellik Sınıflandırıcısı .....</b>	<b>86</b>
6.5.1. Destek Vektör Makineleri .....	86
<b>6.6. Derin Öğrenmeye Dayalı Sınıflandırma .....</b>	<b>87</b>
6.6.1. CNN .....	87
6.6.2. Xception .....	88
6.6.3. Önerilen Derin Öğrenme Modeli .....	88
<b>6.7. Değerlendirme Ölçütleri.....</b>	<b>91</b>
6.7.1. Doğruluk (Accuracy) .....	91
6.7.2. Kesinlik (Precision).....	91
6.7.3. Hassasiyet (Recall-Sensitivitiy) .....	92
6.7.4. F1 Skor (F1-Score).....	92
6.7.5. Karışıklık Matrisi (Confusion Matrix).....	92
<b>7. ARAŞTIRMA BULGULARI.....</b>	<b>94</b>
7.1. Yapısal Özelliklere Dayalı Sınıflandırma Bulguları .....	94
7.2. Derin Öğrenmeye Dayalı Sınıflandırma Bulguları .....	98
<b>8. SONUÇ VE TARTIŞMA.....</b>	<b>101</b>
<b>KAYNAKLAR .....</b>	<b>105</b>
<b>ÖZGEÇMİŞ.....</b>	<b>118</b>

## ÇİZELGELER DİZİNİ

Sayfa

<b>Çizelge 1.1</b> 2019-2020 Üretim dönemi bitkisel üretim verileri (Anonim, 2021b) .....	6
<b>Çizelge 3.1</b> Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları (Öztürk ve Şahin, 2018) .....	38
<b>Çizelge 6.1</b> Sarı pas değerlendirmesinde kullanılan enfeksiyon türleri ve açıklamaları (Roelfs vd., 1992).....	78
<b>Çizelge 6.2</b> Görüntü ön işleme ve etiketleme çalışmalarından sonra yaprak sayıları	79
<b>Çizelge 6.3</b> Yellow-Rust-19 veri seti istatistikleri.....	80
<b>Çizelge 6.4</b> Şekil 6.16 yaprak görüntüleri için örnek CGLCM öznelikleri.....	86
<b>Çizelge 6.5</b> Şekil 6.16 yaprak görüntüleri için örnek CNN öznelikleri.....	86
<b>Çizelge 6.6</b> SVM sınıflandırıcı parametreleri.....	87
<b>Çizelge 6.7</b> Yellow-Rust-19 veri setinin eğitim (öğrenme süreci sırasında kullanılan veri kümesi) ve doğrulama (modelde değerlendirmesi için kullanılan veri kümesi) grupları. ....	87
<b>Çizelge 6.8</b> Yellow-Rust-19 veri setinin eğitim (öğrenme süreci sırasında kullanılan örnek veri kümesi) ve doğrulama (modelde ince ayar yapmak için kullanılan örnek veri kümesi) ve test (eğitim ve doğrulama veri kümelerinden bağımsız veri kümesi) grupları. ....	89
<b>Çizelge 6.9</b> Önerilen Yellow-Rust-Xception modelinin hiperparametreleri .....	90
<b>Çizelge 7.1</b> Ortalama doğruluk oranları (%).....	96
<b>Çizelge 7.2</b> CGLCM_RGB'ye karşılık hibrit özelliklerin performans sonuçları .....	97
<b>Çizelge 7.3</b> Önerilen model Yellow-Rust-Xception ve diğer modellerin sınıflandırma doğruluk oranları.....	98
<b>Çizelge 7.4</b> Yellow-Rust-Xception performans sonuçları.....	100



**Çizelge 8.1** Hibrit özniteliklere (HÖ) karşı standart doku özniteliklerin (SDÖ) performans karşılaştırması ..... 102



## ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
<b>Şekil 1.1</b> Sağlıklı buğday yaprakları (a), kahverengi pas bulaşmış buğday yaprağı (b), kara pas bulaşmış buğday sapı (c), sarı pas bulaşmış buğday yaprağı (d).....	8
<b>Şekil 2.1</b> Örnek histogram eşitleme uygulaması.....	14
<b>Şekil 3.1</b> Geleneksel programlama ve makine öğrenmesi.....	26
<b>Şekil 3.2</b> SVM ile iki değişkenin sınıflandırılması (Widodo ve Yang, 2007).....	29
<b>Şekil 3.3</b> Destek vektör sınıflandırıcısının uygulanması (Misra vd., 2020) .....	31
<b>Şekil 3.4</b> Ayrılamayan bir durum için sınırın oluşturulması. SVM'ler, verileri optimum ayırma hiper düzleminin arandığı daha yüksek boyutlu bir alana yansıtır. Destek vektörleri karelerle gösterilmiştir (Xu, Zomer ve Brereton, 2006).....	32
<b>Şekil 3.5</b> Dört boyutlu özellik uzayına sahip üç sınıftan oluşan bir karar ağacı örneği (Kavzoğlu ve Çölkesen, 2010).....	33
<b>Şekil 3.6</b> Rastgele ormanın şematik gösterimi (Gedeck, Kramer ve Ertl, 2010).....	35
<b>Şekil 3.7</b> KNN sınıflandırma örneği (Özsakabaşı, 2008) .....	36
<b>Şekil 3.8</b> Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, Honorio ve da Silva, 2013; Öztürk ve Şahin, 2018) .....	38
<b>Şekil 3.9</b> Basitçe ANN yapısı (Ayvaz, 2012) .....	39
<b>Şekil 3.10</b> Yapay nöron (Öztürk ve Şahin, 2018).....	39
<b>Şekil 3.11</b> Yapay sinir ağlarında kullanılan başlıca aktivasyon fonksiyonları .....	40
<b>Şekil 3.12</b> Tek katmanlı sinir ağı modeli (Öztemel, 2006).....	41
<b>Şekil 3.13</b> Çok katmanlı algılayıcı modeli (Öztürk ve Şahin, 2018).....	41
<b>Şekil 3.14</b> İleri beslemeli sinir ağlarının çalışma şekli (Öztemel, 2006).....	42
<b>Şekil 3.15</b> Geri beslemeli yapay sinir ağı yapısı (Öztürk ve Şahin, 2018).....	42
<b>Şekil 4.1</b> DL, ML ve AI arasındaki ilişki .....	44
<b>Şekil 4.2</b> Genel CNN mimarisi (Nisha ve Meeral, 2021).....	48

<b>Şekil 4.3</b> Bir sinir ağında bırakma işleminin uygulanması. X işaretli nöronlar bırakılarak dışlanmış (Ha, Tran, Van ve Than, 2019).....	52
<b>Şekil 4.4</b> Çeşitli CNN sınıflandırıcılarının karşılaştırması (Anonim, 2021c).....	53
<b>Şekil 4.5</b> AlexNet mimarisi (Llamas, Leronés, Medina, Zalama ve Gómez-García-Bermejo, 2017).....	54
<b>Şekil 4.6</b> VGG-16 model mimarisi (Shi vd., 2018).....	55
<b>Şekil 4.7</b> GoogLeNet Inception mimarisi (Ebrahim, Alsmirat ve Ayyoub, 2018) .....	56
<b>Şekil 4.8</b> ResNet mimarisinin şematik görünümü (Rousseau, Drumetz ve Fablet, 2020) .....	57
<b>Şekil 4.9</b> MobileNet mimarisi (Pujara, 2020).....	58
<b>Şekil 4.10</b> Xception mimarisinin şematik gösterimi (Mahdianpari, Salehi, Rezaee, Mohammadimanesh ve Zhang, 2018).....	59
<b>Şekil 6.1</b> Ekili alandan görüntüler .....	69
<b>Şekil 6.2</b> Çalışma bölgesinin haritada gösterimi.....	69
<b>Şekil 6.3</b> Fotoğraflama mekanizması: dijital fotoğraf makinesi, yatay tripod ve çekim kabini (a), dörderli ve beşerli gruplar halinde çekilen ham yaprak görüntüleri (b) ...	71
<b>Şekil 6.4</b> Manuel işlemden sonra elde edilen örnek bir yaprak görüntüsü .....	72
<b>Şekil 6.5</b> Basit bir eşikleme işlemi örneği (Anonim, 2020b).....	73
<b>Şekil 6.6</b> L, a ve b kanallarının histogram grafiği.....	74
<b>Şekil 6.7</b> İkili görüntüye genişletme uygulaması (Anonim, 2020c) .....	75
<b>Şekil 6.8</b> Genişletme işlemi: orijinal görüntü (a), genişletilmiş görüntü (b) (Anonim, 2020c).....	75
<b>Şekil 6.9</b> Kapatma işlemi: orijinal görüntü (a), kapatılmış görüntü (b) (Anonim, 2020d) .....	76
<b>Şekil 6.10</b> Otomatik görüntü ön işleme adımları: orijinal resim (a), $L*a*b^*$ renk uzayına dönüştürme (b), eşikleme (c), genişletme (d), kapatma (e), maskeleyme (f), kırpma (g), alfa kanallı son görüntünün elde edilmesi (h).....	77

<b>Şekil 6.11</b> Her bir sınıf için örnek yaprak görüntüleri.....	79
<b>Şekil 6.12</b> Veri artırımı uygulanmış örnek bir yaprak görüntüsü .....	80
<b>Şekil 6.13</b> Transfer öğrenim yönteminin çalışma şekli .....	82
<b>Şekil 6.14</b> DenseNet-201 mimarisi (Wang ve Zhang, 2020) (GAP katmanı özellikleri sağlamaktadır).....	83
<b>Şekil 6.15</b> CGLCM_RGB işleyişinin basitçe gösterimi .....	85
<b>Şekil 6.16</b> MR (a) ve S (b) sınıflarından örnek yaprak görüntüleri.....	86
<b>Şekil 6.17</b> Önerilen derin öğrenme modeli iş akışı. Görüntüler, özellikleri otomatik olarak öğrenen ve nesnelere sınıflandıran CNN'ye iletilmektedir .....	88
<b>Şekil 6.18</b> Önerilen Yellow-Rust-Xception modeli.....	90
<b>Şekil 6.19</b> Örnek bir karışıklık matrisi.....	93
<b>Şekil 7.1</b> Giriş görüntüsü (a), ilk evrişim katmanında öğrenilen 64 filtrenin görselleştirimi (b), ilk evrişim katmanından örnek görüntüler (c), toplu normalleştirme katmanından öğrenilen 64 filtrenin görselleştirimi (d), toplu normalleştirme katmanından örnek görüntüler (e).....	95
<b>Şekil 7.2</b> Karışıklık matrisleri: CGLCM_RGB (a), CNN-CGLCM_RGB (b), CNN-CGLCM_HSV (c), CNN-CGLCM_Lab (d) .....	97
<b>Şekil 7.3</b> Yellow-Rust-Xception eğitim ve doğrulama sonuç grafiği.....	98
<b>Şekil 7.4</b> Yellow-Rust-Xception eğitim ve doğrulama kayıp grafiği .....	99
<b>Şekil 7.5</b> Test işlemi karışıklık matrisi .....	100

## SİMGELER VE KISALTMALAR

### Simgeler

$\Sigma$	Toplam
$\delta$	Delta
$\sigma$	Standart Sapma
$\sigma_x$	$p_x$ 'in standart sapması
$\sigma_y$	$p_y$ 'in standart sapması
$\mu_x$	$p_x$ 'in ortalama gri seviye yoğunluğu
$\mu_y$	$p_y$ 'in ortalama gri seviye yoğunluğu

### Kısaltmalar

AI	Yapay Zekâ
AID	Otomatik Etkileşim Algılama
ANN	Yapay Sinir Ağları
CART	Sınıflandırma ve Regresyon Ağacı
CGLCM	Renk-Gri Seviye Eş-Oluşum Matrisi
CHAID	Ki-Kare Otomatik Etkileşim Dedektörü
CLBP	Renk Tabanlı Yerel İkili Desenler
CLGW	Renk Tabanlı Yerel Gabor Dalgacıkları
CNN	Evrişimsel Sinir Ağları
DL	Derin Öğrenme
FNR	Yanlış Negatif Oranları
GAP	Küresel Ortalama Havuzlama
GLCM	Gri Seviye Eş-Oluşum Matrisi
HÖ	Hibrit Öznitelikler
ID3	Yinelemeli Dikotomizer 3
ILSVRC	ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
KBÖ1	Korelasyonun Bilgilendirici Ölçüsü-1
KBÖ2	Korelasyonun Bilgilendirici Ölçüsü-2
KNN	K-En Yakın Komşu
LBP	Yerel İkili Desenler
LR	Lojistik Regresyon
ML	Makine Öğrenmesi
MR	Orta Derecede Dayanıkl
MRMS	Orta Derecede Dayanıkl Orta Derecede Hassas
MS	Orta Derecede Hassas
NTF	Normalleştirilmiş Ters Fark
NTFM	Normalleştirilmiş Ters Fark Momenti
R	Dayanıkl
RF	Rastgele Orman
S	Hassas
SDÖ	Standart Doku Öznitelikleri
SFTA	Bölütlenmiş Fraktal Doku Analizi
SVM	Destek Vektör Makineleri

TKA  
TPR  
USDA

Tek Katmanlı Algılayıcı  
Gerçek Pozitif Oranları  
Amerika Birleşik Devletleri Tarım Bakanlığı



# 1. GİRİŞ

## 1.1. Arka Plan

Gıda ihtiyacı, evrensel anlamda herkes için en temel ihtiyaçlardan biridir. Günümüzde kullanılan teknolojilerle, dünya çapında milyarlarca insana yetecek kadar yiyecek üretebilmek mümkündür. Ancak bu teknolojilerle insanlığın gıda ihtiyacını karşılamaya yönelik her ne kadar çok ürün üretilse de gıda güvenliği kapsamında insan sağlığını tehdit edebilecek birçok unsur bulunmaktadır. Bu tehditler iklim değişiklikleri, tozlayıcılar ve bitki hastalıkları gibi doğal etmenlerden kaynaklanabilmektedir. Bu etmenler arasında bitki hastalıkları, iklim ve coğrafi özellikleri nedeniyle başta ülkemiz olmak üzere tüm dünyada küresel gıda güvenliğine yönelik bir tehdit oluşturmaktadır.

Buğday, ülkemiz başta olmak üzere tüm dünyada insan beslenmesi için en temel besinlerin (unlu mamuller, bulgur, makarna vb.) ana maddesi olmasından dolayı diğer tarım ürünlerine göre daha önemli bir konumda yer almaktadır (Polat, 2021). Uygun beslenme değeri, muhafaza ve işleme kolaylığı gibi avantajlarla birçok ülkede temel besin durumundadır (Özcan, Bayramoğlu ve Aydın, 2017). Son zamanlarda, Covid-19 salgını nedeniyle makarna gibi dayanıklı ürünlerde talebin artması doğal olarak buğdaya olan talebi de artırmıştır (Polat, 2021). Bu sonuçlar buğdayda zararlılarla, hastalıklarla ve yabancı otlarla mücadele çalışmalarının ne derece önemli olduğunu kanıtlamaktadır.

*Pucciniales* takımı içerisinde yer alan *Puccinia* spp.'nin sebep olduğu pas hastalıkları tüm dünyada buğday üretimini ve bununla birlikte ülkemiz gibi beslenmesi buğdaya dayalı olan ülkelerin gıda güvenliğini tehdit etmektedir (Çat, Tekin, Çatal, Akan ve Akar, 2017). Tarihte yer alan ilk kayıtlar, pas hastalıklarının varlığının MÖ 384 yıllarına dayandığını göstermektedir (Roelfs, Singh ve Saari, 1992). Buğdayda pas hastalıkları içerisinde yer alan sarı pas ya da çizgi pası (*Puccinia striiformis* Westend. f. sp. *tritici*) olarak adlandırılan pas hastalığı buğday üretiminde ciddi hasarlara ve verim kayıplarına yol açan bir hastalıktır (Wellings, 2011). Geniş bir adaptasyon yeteneği ile ülkemizde ekiliş alanlarının yanı sıra üretim miktarı bakımından ilk sırada bulunan buğdayın (Akci, 2018) gıda güvenliği kapsamında korunması ve ekonomik kayıpların en aza indirgenmesi için diğer pas hastalıkları gibi sarı pas hastalığının da

kontrol edilmesi, hastalığın takibinin yapılması ve hastalığı önleme çalışmalarının sürdürülmesi önem arz etmektedir.

Sarı pas hastalığı, buğday yapraklarında çeşitli enfeksiyon türleri ile kendini göstermektedir (Roelfs vd., 1992). Hastalığın ve ciddiyet düzeyinin belirlenmesinde kullanılan kriterler, kullanılan buğdayın türü, üretim alanlarındaki iklim ve hava koşulları, bitkiyi korumak için kullanılan kimyasallar gibi çeşitli kriterlere bağlıdır (Roelfs vd., 1992). Bu kriterler araştırmacılara ve üreticilere, sarı pasa karşı alınması gereken olası önlemler bakımından yeterli bilgiyi sağlamaktadır. Ancak özellikle sarı pasın şiddet seviyesinin belirlenmesi, saha koşullarında uzmanlar tarafından gözlem yoluyla belirli standartlara göre gerçekleştirilmektedir. Sarı pasın şiddet düzeyinin değerlendirilmesinin doğru yapılamaması buğday üretiminin ileri aşamalarında sorun yaratabilmektedir. Bu nedenle, bu çalışmada buğday bitkisinde sarı pas hastalığının olup olmadığının yanı sıra; sarı pas hastalığının hangi aşamada bulunduğunu tespit eden derin öğrenme tabanlı bir sistem önerilmiştir. Çalışma, devlet ya da özel tarım arazilerinde sarı pasın şiddet seviyesinin belirlenmesinde ölçüm için kullanılacak, gelecekte bu alanda yapılacak olan çalışmalar için önerilen modeller sunmaktadır.

Bilgi teknolojilerindeki gelişmeler, nesne görüntülerinin sadece piksel değerleri kullanılarak nesnelereki olası yapısal bozuklukların tanınması için bilgisayar tabanlı yöntemler geliştirmek gibi farklı amaçlar doğrultusunda büyük verileri depolamamıza ve işlememize olanak tanıyan uygulamalar sunmaktadır. Sarı pas hastalığı, buğday yapraklarında yaprak rengi, yaprak dokusu ve yaprak morfolojisi üzerinde bazı fiziksel deformasyonlara neden olmaktadır (Lu, Zhou, Gao ve Jiang, 2018). Yani yapısal özellikler sarı pas hakkında bilgiler vermektedir. İki boyutlu görüntüler üzerinde doku analizi kullanılarak özellik çıkarımı en çok kullanılan yöntemlerden biridir (Aksoy ve Haralick, 2000). Yüzeylerin yapısal özellikleri, incelenmesi gereken özellikler ve bunların birbirleriyle olan ilişkileri hakkında bilgileri içermektedir (Haralick, 1979).

Doku öznitelik çıkarma yöntemleri, nesne algılama ve görüntü sınıflandırma dahil olmak üzere çeşitli bilgisayarlı görme uygulamalarında yaklaşık yarım yüzyıldır (Haralick, Shanmugam ve Dinstein, 1973) kullanılmaktadır. Zamanla, çalışmalarda yer alan çeşitli görevlere daha iyi uyum sağlamak için özelliklerin sayısı artmıştır. Yöntemler, her biri farklı hesaplamalara dayanan Gri Seviye Eş-Oluşum Matrisi (GLCM: Gray Level Co-occurrence Matrix), Yerel İkili Desenler (LBP: Local Binary Patterns), Gabor Filtre, Bölütlenmiş Fraktal Doku Analizi (SFTA: Segmented Fraktal



Texture Analysis) gibi çeşitli tekniklerden oluşmaktadır. GLCM, doku analizi ve makine öğrenmesi alanlarında farklı görüntü dokuları ve formları üzerinde istatistiksel hesaplamalar yapmak için tasarlanmış diğer doku öznitelik çıkarma yöntemleri arasında popüler bir ölçüm yöntemidir (Haralick, 1979). GLCM, bir görüntü için farklı yoğunluk değerlerinin kombinasyonlarının istatistiksel dağılımlarını kullanarak hesaplamalar yapmamızı sağlar (Vardhan ve Rao, 2014). Bununla birlikte, doku analizi için popüler bir istatistiksel yöntem olmasına rağmen, yalnızca gri tonlamalı görüntülerden bilgi yakalayabilmesi GLCM'yi sınırlamaktadır (Hossain ve Parekh, 2010). Bu nedenle doku analizinde başlangıçta genellikle siyah beyaz görüntüler kullanılırken, sonralarda renkli görüntülerin, farklı renk uzaylarının piksel değerlerinde gizlenmiş renk verilerini içermesi özelliğinden dolayı GLCM'nin renkli görüntüler üzerinde kullanılması araştırmacıların ilgisini çekmiştir (Choi, Ro ve Plataniotis, 2011).

Diğer yandan, yapay zekâ alanındaki son gelişmeler, dijital görüntüler kullanılarak nesnelere yapısal kusurların tespitini sağlayan modern yöntemler sunmaktadır. Evrimsel Sinir Ağları (CNN: Convolutional Neural Network), hem otomatik öznitelik çıkarımı hem de sınıflandırma yapabilme avantajlarından dolayı bu yöntemler arasında lider bir konuma sahiptir (LeCun, Bengio ve Hinton, 2015). CNN, sınıflandırma için gereken bilgileri görüntülerden, videolardan, metinlerden veya seslerden doğrudan öğrenebilen (LeCun ve Bengio, 1995) popüler bir derin öğrenme yöntemidir. CNN'nin en güçlü yönlerinden biri, veri setinden veriye bağlı uygun özellikleri otomatik olarak çıkarabilmesidir. Kısacası, CNN, özellik çıkarımı ile sınıflandırma yöntemlerini birleştirmesi yeteneğiyle, yapay sinir ağları gibi geleneksel makine öğrenmesi algoritmalarına göre farklı bir konuma sahip olmaktadır. Literatürde tıp (Üreten, Erbay ve Maraş, 2019; Yurttakal, Erbay, İkizceli ve Karaçavuş, 2019) ve tarım (Ayan, Erbay ve Varçın, 2020; Hayit, Erbay, Varçın, Hayit ve Akci, 2021) gibi çeşitli alanlarda CNN'ye dayalı çalışmalar bulunmaktadır. Tarımda özellikle yaprak görüntülerini sınıflandırma gibi görevler için CNN, en popüler derin öğrenme yaklaşımıdır (Krizhevsky, Sutskever ve Hinton, 2017) ve CNN ile yaprak sınıflandırma üzerine birçok çalışma gerçekleştirilmiştir.

Bu çalışma, sarı pasın şiddet seviyesinin belirlenmesinde buğday yaprakları kullanılarak, geleneksel doku analizi yöntemleri ile birlikte derin öğrenme gibi modern yöntemlerden oluşan bir dizi uygulamayı tartışmaktadır. Çalışmanın hikayesi

kapsamında görüntü işleme, doku özellik çıkarımı, birleştirilmiş doku özellik çıkarımı ve derin öğrenmeye dayalı görüntü sınıflama çalışmalarından bahsedilmiştir.

## 1.2. Motivasyon

Buğday, Türkiye'nin tarım sektöründe başlıca geçim kaynaklarından biridir. Amerika Birleşik Devletleri Tarım Bakanlığı'nın (USDA) verilerine göre toplam 2,7 milyar ton olan dünya tahıl üretiminin %28'ini buğday üretimi oluşturmaktadır (Polat, 2021). Türkiye, dünyada buğday ihracatında önemli ülkeler arasında olup; USDA verilerine göre 2019-2020 üretim sezonunda 6,1 milyon tonluk buğday ihracatı ile dünya sıralamasında dokuzuncu sırada yerini almıştır (Polat, 2021). İklim koşullarının önceki senelere göre daha uygun geçmesi ve verimdeki artış ile birlikte 2020-2021 yılları arası buğday üretimi 20,5 milyon tona yükselmiştir (Anonim, 2021a). Türkiye'de 2019-2020 üretim sezonunda bitkisel üretim verileri içerisinde %47'lik üstünlükle buğday üretimi ilk sırada yer almaktadır (Anonim, 2021b). Bu veriler ülke ekonomisinde buğdayın önemini ortaya koymaktadır.

Sarı pas hastalığı, yüksek tahribat özelliği nedeniyle dünya çapında buğday üretiminde önemli ekonomik kayıplara neden olmaktadır (Wellings, 2011). Hastalığın şiddetine bağlı olarak verim kayıpları ve kalite bozulma düzeyleri değişebilmekte, buna bağlı olarak da ekonomik kayıplar yaşanmaktadır. Buğday pası hastalıkları, kontrol edilmediği ve önlenmediği takdirde mahsulün %50 ila %100'ünü etkileme potansiyeline sahiptir (Chen 2005). Buğday pas hastalıklarından kaynaklanan tahmini küresel yıllık kaybın 5,5 milyar USD'ye kadar çıktığı bildirilmiştir (Beddow vd., 2015). Sarı pas hastalığı, diğer buğday pası hastalıklarına göre en yüksek tahribat oranına sahip hastalık olmakla birlikte dünya çapında 60'tan fazla ülkede görülmektedir (Wellings, 2011). Türkiye buğday üretimi de sarı pas hastalığından nasibini almıştır. Türkiye'de, epidemi şartlarını sağlayan farklı yıllarda birçok buğday üretim alanında hastalığın varlığı bildirilmiştir (Düşünceli, Cetin, Albustan ve Beniwal, 1996). Türkiye'de sarı pas hastalığı ile ilgili ilk kaydın 1886 yılında oluşturulduğu belirtilmiştir (Akan, 2019). Braun ve Saari (1992) tarafından 1975, 1976, 1977, 1984 ve 1991 yıllarında hastalığın etkisinin yerel düzeyde kaldığı; 1995 yılında Güneydoğu Anadolu Bölgesinde de görüldüğü bildirilmiştir (Akan, 2019). 1996-1997 yıllarında geniş alanlarda tespit edilen sarı pas hastalığına ait enfeksiyonun; 1998 yıllarında incelenen üretim alanlarının %98'inde görüldüğü belirtilmiştir

(Düşünceli, Cetin, Albustan ve Ekiz, 2000). 2009 yılında Orta Anadolu ve Güneydoğu Anadolu Bölgesinde sarı pas hastalığı nedeniyle önemli ürün kayıpları yaşanmıştır (Akan, 2019). 2014 ve 2015 yıllarında Trakya Bölgesi üretim alanlarında etkili olan hastalık epidemisi bildirilmiştir (Akan, 2019). Bu veriler doğrultusunda, buğday üretiminde verimi ve kaliteyi etkileyerek ülke ekonomisine ciddi zarar verme potansiyeli bulunan sarı pas hastalığının kontrol edilmesi, hastalığın tespiti ve hastalığı önleme çalışmaları önem arz etmektedir.

Diğer yandan, üretim alanlarında görülen hastalıklarla Zirai Mücadele Teknik Talimatında (Anonim, 2020a) belirtilen şekilde mücadele edilmektedir. Zirai Mücadele Teknik Talimatında hastalıkların tanımı, süreci, belirtileri, ekonomik önemi ile yayılışı, konukçuları, kültürel ve kimyasal mücadele yöntemleri açık ve detaylı bir şekilde sunulmuştur. Uzmanlar arazi ortamında bu talimatlara göre sarı pas hastalığını araştırmaktadırlar. Değerlendirmelerin doğru yapılamaması üretimde ileri aşamalarda sorun yaratabilmektedir. Bu bağlamda hastalığı, insan faktörünü en aza indirgeyerek nesnel olarak etkili ve verimli bir şekilde değerlendirebilen; hastalık, ekine tam olarak zarar vermeden önce anında ölçüm yapmaya yardımcı bir model oluşturularak literatüre ve ülke üretimine katkı sağlanması hedeflenmiştir.

### **1.3. Buğday ve Buğday Pası Hastalıkları**

#### **1.3.1. Türkiye’de Buğday**

Buğday, dünyanın en çok tüketilen tahıl ürünlerinden biri olmakla birlikte dünyada ekiliş ve üretim bakımından ilk sırada yer almaktadır (Özcan vd., 2017). Buğday, Türkiye’de tarım sektöründe başlıca geçim kaynaklarından biridir. USDA verilerine göre 6,1 milyon tonluk buğday ihracatı ile Türkiye, dünya sıralamasında dokuzuncu sırada yer almaktadır (Polat, 2021). 2019-2020 üretim sezonu verilerine bakıldığında (Çizelge 1.1) buğday üretimi, diğer bitkisel üretim verilerine göre %47’lik üstünlükle ilk sırada bulunmaktadır (Anonim, 2021b). Türkiye’de buğdayın önemine rağmen değişen iklim şartları, coğrafi koşullar, bilinçsiz üretim gibi nedenlerin de etkisiyle sarı pas başta olmak üzere buğdayda pas hastalıkları üretimi ciddi olarak etkilemektedir.

**Çizelge 1.1** 2019-2020 Üretim dönemi bitkisel üretim verileri (Anonim, 2021b)

Ürün	Üretim (Ton)
Buğday	19.000
Mısır	6.000
Patates	4.980
Kuru Soğan	2.200
Ayçiçeği	2.100
Pamuk (Çiğit)	1.320

### 1.3.2. Buğday Pası Hastalıkları

*Pucciniales* takımı içerisinde yer alan *Puccinia* spp.'nin sebep olduğu pas hastalıkları ülkemiz dahil olmak üzere tüm dünyada buğday üretimini tehdit etmektedir (Çat vd., 2017). Türkiye gibi tarım sektöründe başlıca geçim kaynağı buğday olan ülkeler için buğdaya zarar verebilecek en küçük bir tehdidin dikkate alınmaması sonraki süreçte yıkıcı ekonomik zararlara yol açabilmektedir. Pas hastalıklarına karşı mücadelede her ne kadar mantar ilaçları çare olabilse de bu ilaçların yanlış yerde ve zamanda uygulanması mahsulü risk altında bırakabilecek, aynı zamanda ilaçlama için harcanan maliyetin de boşa gitmesine neden olabilecektir.

Sarı pas hastalığı, ülkemizde ve dünyada buğday üretimini sınırlandıran en önemli pas hastalığıdır (Çat vd., 2017). Sarı pasla birlikte, mahsulün %50 ila %100'ünü etkileme potansiyeline sahip olan (Chen 2005) en yaygın üç buğday pası bulunmaktadır. Bunlar sarı pas (çizgi pası), yaprak pası (kahverengi pas) ve sap pasıdır (kara pas). Sarı pas ve yaprak pası buğday bitkisinde yaprak üzerinde belirgin olmaktadır. Her pas çeşidinin kendine ait belirgin yapısal deformasyonları bulunmaktadır. Bu deformasyonlar araştırmacılara özellikle doku sınıflandırma kapsamında çeşitli bilgiler sunmaktadır.

#### 1.3.2.1. Yaprak Pası (Kahverengi Pas)

*Puccinia recondita* Rob. ex Desm. f.sp. *tritici* (Roelfs vd., 1992) patojeninin neden olduğu kahverengi pas olarak da bilinen yaprak pası, buğday başta olmak üzere arpa, çavdar gibi diğer tahıl ürünlerinin yetiştirildiği her alanda görülebilmektedir. Adından da anlaşılacağı gibi kahverengimsi bir toz şeklinde belirtileri tespit edilmektedir (Şekil 1.1(b)). Yaprak pasının da sarı pas gibi ciddi verim kayıplarına sebep olabildiği belirtilmiştir (Roelfs vd., 1992).

### 1.3.2.2. Sap Pası (Kara Pas)

*Puccinia graminis Pers. f. sp. tritici* (Roelfs vd., 1992) patojeninin neden olduđu kara pas olarak da bilinen sap pası diđer önemli buđday pası hastalıklarındandır (Akci, 2018). Hasat zamanından üç hafta önceye kadar sağlıklı görünen bir mahsulü hasat zamanına kadar kısa bir sürede kullanılamaz hale getirebildiđi bildirilmiştir (Roelfs vd., 1992). Buđdayda kara pas hastalıđı buđdayın sap kısmında görülebileceđi gibi diđer yeşil kısımlarda da görülebilmektedir (Şekil 1.1(c)) (Akci, 2018).

### 1.3.2.3. Sarı Pas (Çizgi Pası)

*Puccinia striiformis f. sp. tritici* (Roelfs vd., 1992) patojeninin neden olduđu, çizgi pası olarak da adlandırılan sarı pas hastalıđı, buđdayda diđer pas hastalıklarına göre dünyada en fazla zarara yol açan ve dünya genelinde 60'tan fazla ülkede görülen bitki hastalıđıdır (Wellings, 2011). Buđdayda sarı pas ilk defa 1777 yılında tanımlanmıştır (Roelfs vd., 1992). Hastalıđa etmen olan patojenin adı Hylander vd. (1953) tarafından belirlenmiştir (Roelfs vd., 1992). Cođrafi uzaklık fark etmeksizin hastalıđın birçok ülkede görüldüđu ve hastalık etmeninin kolayca taşındıđı bildirilmiştir (Wellings, 2011; Çat vd., 2017). Dünya buđday üretiminin %88'inin hassas olduđu sarı pas hastalıđı (Çat vd., 2017), Türkiye'de Orta Anadolu başta olmak üzere milyonlarca ABD doları tutarında hasara neden olmuştur (Chen, 2020). Sarı pas, adından da anlaşılacağı gibi yaprak üzerinde sarımsı bir toz şeklinde çizgiler halinde görülebilmektedir (Şekil 1.1(d)).



(a)



(b)



(c)



(d)

**Şekil 1.1** Sağlıklı buğday yaprakları (a), kahverengi pas bulaşmış buğday yaprağı (b), kara pas bulaşmış buğday sapı (c), sarı pas bulaşmış buğday yaprağı (d)

#### 1.3.2.4. Sarı Pasla Mücadele

Türkiye’de sarı pas hastalığının tespiti ve takibi geleneksel yöntemlerle araştırmacı uzmanlar tarafından yürütülmektedir. Bu durum çok fazla maliyete ve zaman kaybına neden olmaktadır. Hastalığın tespit edilip gereken önlemin alınmasına kadar geçen zaman içerisinde mahsul risk altında bırakılmaktadır.

Diğer pas hastalıklarında olduğu gibi sarı pas için de önleyici mantar ilaçları ve kimyasallar piyasada bulunmaktadır. Bu ilaçların bilinçsizce kullanılması mahsulü risk altında bırakmakla kalmayıp aynı zamanda gereksiz bir maliyete de yol açmaktadır.

Türkiye’de pas hastalıklarının takibi T.C. Tarım ve Orman Bakanlığı Araştırma Enstitüleri ve İl Tarım ve Orman Müdürlükleri tarafından yürütülmektedir. Araştırmacılar saha şartlarında değerlendirmeleri Zirai Mücadele Teknik Talimatında (Anonim, 2020) belirtilen standartlara göre görsel yolla yapmaktadırlar. Hastalığa karşı dayanıklı türlerin yetiştirilmesi, bu türlerin araştırılarak adaptasyonunu sağlamak

ve piyasada hastalıklara karşı dayanıklı ürünlerin yetiştirilmesini teşvik etmek bu alanda yapılan en etkili mücadele olarak değerlendirilebilir.

#### **1.4. Problem Tanımı**

Buğday üretimi ülkemiz ekonomisi ve gıda tedariki bakımından önemli bir konumdur. Verilere göre ülkemiz buğday ihracatında önemli ülkeler arasındadır (Polat, 2021). Bununla birlikte bitkisel üretim verilerine göre buğday üretimi %47'lik bir üstünlükle ilk sırada bulunmaktadır (Anonim, 2021b). Bu bağlamda ülkemiz ekonomisini ve gıda güvenliğini tehdit eden sarı pas hastalığının arazi koşullarında takibinin ve kontrolünün sağlıklı bir şekilde sürdürülmesi önem arz etmektedir.

Arazi koşullarında hastalığın takibi ve önleme çalışmaları devletin görevlendirdiği araştırmacı uzmanlar tarafından belirli kriterlere göre gerçekleştirilmektedir. İnsan faktörü dikkate alındığında hastalığın her zaman ve her yerde manuel değerlendirilmesinin objektif olarak yapılabilmesi durumu tartışmaya açıktır.

Diğer yandan, sarı pas gibi pas hastalıklarının önlenmesi için kullanılan zirai ilaçlar maliyetli olmakla birlikte bilinçsiz kullanımlarda bitkiyi risk altında bırakabilmektedir. Tüm bu koşullar dikkate alındığında, hastalığı maliyet gerektirmeden, nesnel ve otomatik olarak değerlendirebilen bir sisteme ihtiyaç duyulmaktadır.

#### **1.5. Araştırma Soruları**

Soru1: Buğday yaprakları arka plan görselden arındırılarak nasıl ön plana çıkarılabilir?

Soru2: Geleneksel yöntemler kullanılarak sarı pas bulaşmış buğday yapraklarının özellikleri nasıl çıkarılabilir?

Soru3: Geleneksel yöntemlere göre özellik çıkarımında alternatif bir yöntem bulunabilir mi?

Soru4: Modern yöntemler dikkate alındığında insan beyni formuna en yakın şekilde sınıflama yapılarak yüksek hız ve doğrulukla sarı pas hastalığının etki derecesi tespit edilebilir mi?

## 1.6. Amaçlar

Bu tez çalışmasında tarım ekonomisi ve verimliliği açısından kritik öneme sahip olan sarı pas hastalığının enfeksiyon derecesinin güvenli ve otomatik yollarla sınıflandırılması amaçlanmaktadır. Literatürde, geleneksel olarak yapısal özelliklerin kullanılması ile gerçekleştirilen yaprak sınıflama çalışmalarının varlığı bilinmektedir. Bu çalışmalarda kullanılan teknikler çeşitlilik gösterse de özellik çıkarıcının yeteneği doğrultusunda başarı sağlayabilmektedir. Bu çalışmada benzersiz bir veri seti oluşturularak, bu veri seti ile sarı pas hastalığının ayırıcı özelliklerini kendi başına öğrenip hastalık derecesini sınıflandırabilen, yüksek başarı oranına sahip bir sistemin üretilmesi hedeflenmektedir.

## 1.7. Çalışmanın Organizasyonu

Bu tez çalışması şu şekilde organize edilmiştir:

- Birinci bölümde genel olarak çalışmanın ana motivasyonunun bağlı olduğu hususlara yer verilmiştir. Buğdayın, dünya ve ülkemiz için önemi belirtilerek sarı pas hastalığı başta olmak üzere buğdayda pas hastalıkları hakkında bilgilendirme yapılmıştır. Kuramsal kısma geçmeden önce çalışmanın problem tanımı, araştırma soruları ve amaçları hakkında bilgilendirme yapılmıştır.
- İkinci bölümde, çalışmada kullanılan metotlar arasında yer alan sayısal görüntü işleme hakkında bilgi verilerek başlıca görüntü işleme tekniklerine yer verilmiştir.
- Üçüncü bölümde makine öğrenmesi ve geleneksel makine öğrenimi sınıflandırıcılarına yer verilerek araştırma sürecinde kullanılan bazı önemli araştırma teknikleri ve metodolojileri detaylandırılmıştır.
- Dördüncü bölümde, Derin Öğrenme ve Evrimsel Sinir Ağları hakkında genel bilgiler verilmektedir. Bir derin öğrenme yaklaşımı olan CNN'lerin çalışma şekli detaylandırılmıştır.
- Beşinci bölümde, çalışmada kullanılan metotları da ilgilendiren farklı literatür incelemelerine ve ayrıca diğer araştırmacılar tarafından önceden yapılan ilgili çalışmalara yer verilmiştir.
- Altıncı bölümde, araştırma sürecinde kullanılan bazı önemli araştırma metodolojileri ve teknikleri detaylandırılmıştır. Çalışmada önerilen modelleri



tasarlamak ve uygulamak için kullanılan veri ön işleme ve bölütleme teknikleri tartışılmaktadır. Ayrıca geleneksel doku analiz yaklaşımları ve önerilen derin öğrenme yaklaşımı detaylandırılmıştır.

- Yedinci bölümde araştırmanın bulguları, çizelge ve grafikler şeklinde detaylandırılarak sunulmuştur.



## 2. SAYISAL GÖRÜNTÜ İŞLEME

Makine öğreniminde verinin kullanılmadan önce işlenmesi veya temizlenmesi önemli bir aşamadır (Chicco, 2017). Araştırmacılar modeli oluşturmadan önce veri işleme aşamasında oldukça zaman harcamaktadırlar. Veri işleme çalışmaları örnek olarak eksik verilerin tamamlanması, aykırı değer tespiti, gürültünün düzeltilmesi, verilerdeki tutarsızlıkların giderilmesi gibi işlemleri kapsamaktadır.

Sayısal bir görüntü, sayısal bir cihaz ile sayısal ortama aktarılan; her biri belirli bir konuma ve değere sahip, sonlu sayıda piksel adı verilen öğelerden oluşmaktadır. Sayısal (dijital) görüntü işleme ise görüntülerin bilgisayar ortamında belirli algoritmalar kullanılarak işlenmesi anlamına gelmektedir. Görüntüden anlamlı bilgiler çıkarmak için uygulanan yöntemlerin tamamı görüntü işleme teknikleri kapsamındadır. Görüntü işlemenin amacı, istenmeyen bozulmaları önleyerek, sonraki aşamalar için görüntüyü hazırlamak, görüntü özelliklerini geliştirerek verinin iyileştirilmesini sağlamaktır. Literatürde sınıflandırma, özellik çıkarımı, sinyal işleme, görüntü tanıma gibi farklı görevler için kullanılmaktadır.

Görüntü işleme alanı, bilgisayar mühendisliği başta olmak üzere, elektrik-elektronik mühendisliği, matematik ve fizik gibi farklı bilim kollarının katkılarıyla disiplinler arası çalışmalarla geliştirilmektedir. Makine öğrenmesi, bilgisayarla görme, görüntü tanıma gibi yapay zekâ alanlarıyla yakından ilişkilidir. Görüntü işleme, manuel veya otomatik olarak gerçekleştirilebilmektedir. Araştırmacılar manuel olarak bilgisayar ortamında özel yazılımlar (Photoshop, CoreIDRAW, Gimp vb.) kullanarak daha iyi sonuçlar elde edebilmektedirler. Bununla birlikte manuel görüntü işleme, çok sayıda verinin kullanılması durumunda oldukça zaman gerektireceği için tamamen otomatik olarak çalışan sistemlerin tasarlanması önem arz etmektedir.

Genel olarak görüntü işlemenin ilk adımı sayısal görüntünün elde edilmesidir. Görüntü işlemede sonraki aşamaların sağlıklı olarak ilerlemesi bakımından bu ilk adım çok önemlidir. Tasarlanan modele uygun olacak şekilde veri setinin oluşturulması gerekmektedir. Bu görüntüler amaca göre yüksek kaliteli görüntülerden oluşabileceği gibi çok fazla görüntünün gerektirdiği modeller için hazır veri tabanlarından ya da internet üzerinden temin edilen görüntülerden de oluşabilmektedir.

Sayısal görüntünün elde edilmesi adımından sonra sayısal görüntü işleme gerçekleştirilir. Sayısal görüntü işleme süreci iki ardışık süreçten meydana gelmektedir: görüntü ön işleme ve özellik çıkarma. Görüntü ön işleme süreci genellikle işlenecek verinin iyileştirilmesi çalışmalarını kapsamaktadır. Bu adımda eşikleme, genişletme, aşındırma, açma, kapama, sınır çıkarma vb. morfolojik operatörler gibi uygulamalarla ham görüntü üzerinde birçok sorun giderilmeye çalışılır. Sonuç olarak sonraki süreçte özellik çıkarımı için işlenmeye hazır, yenilenmiş bir çıktı üretilmektedir.

Özellik çıkarma sürecinde, ön işlenmiş ya da ham veri setinden elde edilmesi gereken karakteristik özelliklerin çıkarılmasına odaklanılmaktadır. Bu aşamada, sonraki süreç için kullanıma hazır, görüntünün içeriği hakkında karakteristik bilgiler veren çıktılar üretilmektedir.

## **2.1. Başlıca Görüntü İşleme Teknikleri**

### **2.1.1. Parlaklık Dönüşümleri / Parlaklık Düzeltmeleri**

Parlaklık dönüşümü ile pikselin parlaklığı değiştirilmektedir. Ortaya çıkan değişim pikselin özelliklerine bağlıdır. Parlaklık ve kontrast ayarlamalarının yanı sıra renk düzeltme ve renk dönüşümleri için de kullanılabilir.

Kontrast geliştirme hem insan hem de bilgisayarlı görme için önemli bir görüntü işleme alanıdır. Tıbbi görüntü işleme, konuşma tanıma, doku analizi gibi birçok uygulamada önemli bir ön işleme adımı olarak kullanılmaktadır. Parlaklık dönüşüm işlemleri gama düzeltme ve histogram eşitleme gibi işlevleri içermektedir.

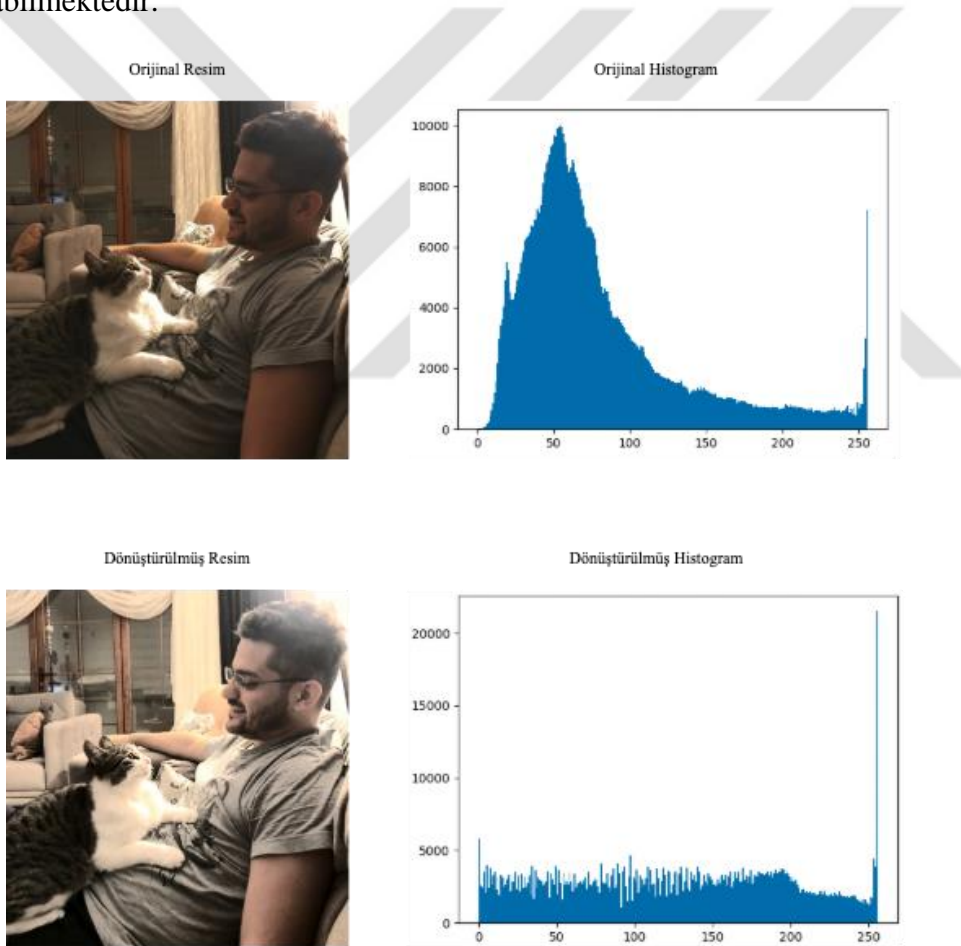
#### **2.1.1.1. Gama Düzeltme**

Gama düzeltme işlemi, piksel değerlerine doğrusal olmadan bireysel olarak uygulanan bir ayarlamadır. Gama düzeltme, görüntüde tek tek pikseller üzerinde doğrusal işlemler gerçekleştirilirken, kaynak pikseller üzerinde doğrusal olmayan bir işlem gerçekleştirir ve görüntünün doygunluğunun değişmesine neden olur. İnsan gözü parlak renklere nazaran koyu renklere daha duyarlıdır (Choudhury, 2014). Bu nedenle insan gözünün hassasiyeti ile kamera sensörleri arasındaki farkın dengelenmesi için gama düzeltmesi uygulanabilmektedir.

### 2.1.1.2. Histogram Eşitleme

Basitçe histogram, sayısal bir görüntü içerisinde her renk değerinden kaç adet olduğunu gösteren bir grafiği tanımlamaktadır. Bu grafik araştırmacılara görüntünün parlaklık durumu ya da tonları hakkında bilgi vermektedir. Kontrast değeri kötü olan bir görüntünün histogramı geniş bir alana yaydırılarak görüntünün iyileştirilmesi sağlanabilir. Histogram eşitleme tekniği ile bu işlem gerçekleştirilebilmektedir.

Histogram eşitleme, hemen her görüntü için kullanılabilen, performansı nedeniyle de iyi bilinen ve tercih edilen bir kontrast geliştirme tekniğidir. Kontrast gerdirme gibi tekniklerin aksine, histogram modelleme operatörleri, girdi ve çıktı görüntülerindeki piksel yoğunluk değerleri arasında eşitleme yapmak için doğrusal olmayan yöntemleri kullanabilmektedir.



Şekil 2.1 Örnek histogram eşitleme uygulaması

### 2.1.2. Geometrik Dönüşümler

Önceki bölümde bahsedilen yöntemler renk, parlaklık ve kontrast ile ilgili yöntemlerden oluşmaktadır. Geometrik dönüşümlerde, görüntüdeki piksellerin

renklerinde oynama yapılmadan konumları değiştirilmektedir. Geometrik dönüşüm kullanılarak, yakalama esnasında görüntüde meydana gelen geometrik bozulma giderilmeye çalışılır. Geometrik dönüştürme işlemleri, öteleme, döndürme, ölçeklendirme, eğme ve yansıma gibi tekniklerden oluşmaktadır.

### **2.1.3. Görüntü Filtreleme**

Görüntü işlemede filtrelerin kullanılmasının amacı, kenarlar, köşeler, lekeler gibi görüntü özelliklerini değiştirmek/geliştirmek ya da görüntüden değerli bilgileri çıkarmaktır. Bir filtre, bir görüntü içerisindeki her piksele ve onun komşu piksellerine uygulanan bir çekirdek (kernel) ile tanımlanmaktadır. Temel filtreleme tekniklerinden bazıları, yumuşatma, kenar algılama, yönlü filtreleme gibi uygulamaları içermektedir.

### **2.1.4. Görüntü Bölütleme (Segmentasyon)**

Görüntü bölütleme, genellikle bir görüntüyü piksellerin özelliklerine dayalı olarak birden çok parçaya veya bölgeye bölmek için kullanılan yaygın kullanılan bir tekniktir. Çıkarılan bölgeler genellikle değerli görülen bilgilere ait parçaları içerebilir. Nesne tanımlamada ön planın arka plandan ayrılması ya da renk veya şekillerdeki benzerliklere dayalı piksel bölgelerinin kümelenmesi gibi uygulamalar için kullanılmaktadır. Görüntü bölütleme, yüz tanıma, tıbbi görüntüleme, bilgisayarla görme gibi farklı alanlar için tercih edilen bir tekniktir.

Görüntü bölütleme yöntemleri, bağlamsal olmayan bölütleme ve bağlamsal bölütleme olmak üzere iki sınıfa ayrılmaktadır. Bağlamsal olmayan bölütleme en basit bölütleme tekniklerini kapsamaktadır. Bağlamsal olmayan bölütlemelerde, görüntüdeki bölgesel özellikleri ve piksellerin birbirleriyle olan ilişkileri göz ardı edilmektedir. Piksellerin gri seviye değerleri gibi yüzeysel özellikler dikkate alınır. Bağlamsal bölütlemelerde ise piksel ilişkileri dikkate alınarak bölütleme yapılmaktadır. Bağlamsal bölütleme, tek bir nesneye ait olan piksellerin yakınlığı hesaba katıldığından dolayı nesnelere ayırmakta daha başarılı olmaktadır.

### **2.1.5. Fourier Dönüşümü ve Görüntü Restorasyonu**

Fourier Dönüşümü, bir görüntüyü sinüs ve kosinüs bileşenlerine ayrıştırmak için kullanılan bir görüntü işleme aracıdır. Giriş görüntüsü uzaysal alanı, dönüşümün çıktısı da Fourier veya frekans alanındaki görüntüyü temsil etmektedir. Fourier alan görüntüsünde, her nokta, uzaysal alan görüntüsünde bulunan belirli bir frekansın

temsilidir. Fourier Dönüşümü, görüntü analizi, görüntü filtreleme, görüntüyü yeniden yapılandırma ve görüntü sıkıştırma gibi çeşitli uygulamalarda kullanılmaktadır.

## **2.2. Görüntü Doku Analizi**

Sayısal görüntü dokusu, bir görüntünün algılanan dokusunu ölçmek, görüntüleri istenen alanlarına bölmek ve bu bölgeleri sınıflandırmak gibi işlevler için dikkate alınan bir özelliktir. Görüntü dokusu bize bir görüntünün bütününe ya da görüntünün seçilen bir bölgesine ait renkler veya yoğunluklar hakkında bilgi sunmaktadır (Shapiro ve Stockman, 2001). Görüntü dokuları istenen özelliğe göre yapay olarak oluşturulabileceği gibi bir görüntüden alınan gerçek bir sahneyi de içerebilir. Dokular, görüntülerin sınıflandırılmasına veya bölütlenmesine yardımcı olarak görüntü işleme alanında kullanılabilir.

Doku analizi, bir görüntüdeki bölgelerin doku içeriğine göre temsilini ifade etmektedir. Piksel yoğunluklarındaki uzamsal varyasyonun bir işlevi olarak, kaba, pürüzsüz, ipeksi veya engebeli gibi kavramlarla tanımlanan duyuşal nitelikleri ölçmeye çalışmak için kullanılmaktadır. Doku analizi, uzaktan algılama, tıbbi görüntü işleme uygulamaları dahil olmak üzere çeşitli uygulamalarda kullanılmaktadır. Bir görüntüdeki nesnelere, yoğunluk değerlerinden ziyade doku özellikleriyle temsil edildiği durumlarda doku analiz teknikleri geleneksel görüntü işleme tekniklerine göre daha başarılı olabilmektedir.

Sayısal görüntülerde bir görüntü dokusunu analiz etmek için iki temel yaklaşım bulunmaktadır: doku bölütleme ve doku sınıflandırma.

### **2.2.1. Doku Bölütleme**

Doku bölütleme, bir görüntüyü benzer piksel gruplarını içeren çeşitli dokulara sahip bölgelere ayırma işlemidir (Madasu, V. K. ve Yarlagadda, P., 2007). Görüntü işleme alanında uzun zamandır çalışmalarda kullanılan geleneksel bir yöntemdir. Temel olarak, bir görüntüyü benzer desenlere sahip bölgelere ayırmayı amaçlamaktadır. Etkili ve verimli bir doku bölütleme farklı birçok uygulamada kullanılmaktadır.

Doku bölütlemenin sağlıklı çalışabilmesi için, diğer bölütleme uygulamalarında olduğu gibi görüntüden iyi ayırt edici özelliklere sahip özelliklerin doğru seçilmesi gerekmektedir (Chaudhuri, B. B. ve Sarkar, N., 1995).

### **2.2.2. Doku Sınıflandırma**

Sınıflandırma, fiziksel bir nesnenin ya da olgunun önceden tanımlanmış bir sınıfa atanması anlamına gelmektedir. Doku sınıflandırma, tıbbi görüntü analizi, uzaktan algılama, nesne tanıma gibi birçok uygulamada önemli bir rol üstlenen, bilgisayarlı görme ve görüntü işleme alanlarında temel olarak kullanılan bir kavramdır. Basitçe, örüntü tanımada klasik bir problem olan dokular arasında ayırım yapma işlevidir. Haralick vd. (1973) görüntü sınıflandırma için doku özelliklerini kullanma fikrini ilk olarak ortaya atan araştırmacılarıdır. Doku sınıflandırmasında amaç, bilinmeyen bir doku görüntüsünü bilinen doku sınıflarından birine aktarmaktır. Doku sınıflandırma işlemini gerçekleştiren birçok karmaşık sınıflandırıcı mevcuttur. Doku sınıflandırmadaki temel zorluk, belirli bir doku görüntüsünden çıkarılması gereken etkili özelliklerin geliştirilmesidir. Doku sınıflandırmada her sınıf kendine has benzersiz doku özelliklerine sahiptir.

Doku sınıflandırma süreci iki aşamadan oluşmaktadır: öğrenme ve tanıma aşaması. Öğrenme aşamasında amaç, eğitim verisi olarak kullanılan ve genellikle bilinen sınıf etiketlerine sahip görüntülerden oluşan her sınıfın doku içeriğinin etkili bir şekilde modellenmesidir. Eğitim görüntülerinde bulunan her görüntü, ilgili sınıfların özelliklerine göre belirlenen doku analiz yöntemiyle yakalanır ve ait olduğu sınıfa atanır. Yakalanan her doku görüntüsü belirli yapısal özellikleri de temsil eder. Tanıma aşamasında, bilinmeyen örneğin doku içeriği tanımlanır; doku analiz yöntemiyle örneğin yapısal özellikleri eğitim verileriyle karşılaştırılır ve örnek doku görüntüsü en iyi eşleşen sınıfa atanır.

Doku analizinde istatistiksel yöntemler (GLCM, Kontrast, Korelasyon, Entropi, Homojenlik vb.) daha yaygın olarak kullanılmaktadır.

### **2.2.3. Gri Seviye Eş-Oluşum Matrisi (GLCM)**

Gri Seviye Eş-Oluşum Matrisi (GLCM) basitçe, pikseller arasındaki özel ilişkililere dayalı doku hesaplamalarında kullanılan bir görüntü analizi tekniğidir (Yogeshwari ve Thailambal, 2021). GLCM, ilk kez Haralick (1979) tarafından önerilmiştir. Görüntü sınıflandırmada, istatistiksel doku analizi için ikinci dereceden özelliklerin hesaplanmasına dayalı kullanılmaktadır (Manjunath ve Ma, 1996; Soh ve Tsatsoulis, 1999; Nikoo, Talebi ve Mirzaei, 2011; Pantic, Dimitrijevic, Nesic ve Petrovic, 2016).

GLCM'leri belirli bir örnek üzerinden anlatmak daha kolay anlaşılmasını sağlayacaktır (Haralick vd., 1973; Soh ve Tsatsoulis, 1999). Analiz edilecek sayısal görüntünün  $N_x$  adet sütun ve  $N_y$  adet satırlara sahip dikdörtgen şeklinde olduğunu ve her piksele ait gri seviyenin  $N_g$  olarak hesaplandığını varsayalım.  $L_x = \{1, 2, 3, \dots, N_x\}$  sütunlar için,  $L_y = \{1, 2, 3, \dots, N_y\}$  satırlar için ve  $G_x = \{1, 2, 3, \dots, N_g - 1\}$  de  $N_g$  olarak hesaplanan gri seviyeler kümesi olsun.  $L_x \times L_y$  kümesi, görüntünün satır-sütun gösterimine göre sıralanmış piksel kümesidir. Buna göre  $I$  görüntüsü,  $L_x \times L_y$  kümesindeki her piksele veya koordinat çiftine  $G$ 'de bir miktar gri seviye atayan bir fonksiyonla temsil edilebilmektedir ( $L_x \times L_y \rightarrow G$ ). Doku-bağlam bilgisi, biri gri seviye  $i$  ve diğeri gri seviye  $j$  olmak üzere görüntü üzerinde oluşan  $d$  mesafesi ile ayrılmış iki komşu piksel ile bağlı frekanslar ( $P_{ij}$ ) hesaplanarak belirlenmektedir. Gri seviyeli eş-oluşum frekanslarının bu tür matrisleri, komşu pikseller arasındaki açısal ilişkinin ve mesafenin bir fonksiyonudur.

Haralick (1979) makalesinde yedi yapısal özellik (entropi, enerji, maksimum olasılık, ters fark momenti, kontrast, korelasyon ve Gri ton için  $n$  uzunluğunda bir çalışma olasılığı) üzerinde çalışmıştır. Ancak sonraları bu özellikler daha da genişletilerek daha farklı metotlarla çalışmalar gerçekleştirilmiştir. Bu bölümde, tez çalışmasında doku özellik çıkarımı için kullanılan özelliklerin açıklamalarına ve denklemlerine yer verilmiştir.

### 2.2.3.1. Kontrast (Haralick vd., 1973; Soh ve Tsatsoulis, 1999)

Kontrast (contrast), yerel yoğunluk değişiminin bir ölçüsüdür. Formülü, görüntüde bir piksel ile komşusu arasındaki yoğunluk farkının bir ölçüsünü döndürmektedir.

$$\text{Kontrast} = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) |i - j| = n \right\} \quad (2.1)$$

### 2.2.3.2. Korelasyon (Haralick vd., 1973; Soh ve Tsatsoulis, 1999)

Korelasyon (correlation), gri seviye değerlerinin GLCM'deki ilgili piksellere doğrusal bağlılığını gösteren 0-1 aralığında bir değerdir.



$$\text{Korelasyon} = \sum_{i,j=1}^N \frac{(i - \mu_x)(i - \mu_y) p(i, j)}{N_x N_y} \quad (2.2)$$

### 2.2.3.3. Entropi (Soh ve Tsatsoulis, 1999)

Entropi (Entropy), görüntüdeki düzensizliği, belirsizliği veya rastgelelik durumuyla ilişkilendirilen ölçülebilir bir fiziksel özelliktir.

$$\text{Entropi} = - \sum_i \sum_j p(i, j) \log (p(i, j)) \quad (2.3)$$

### 2.2.3.4. Homojenlik (Soh ve Tsatsoulis, 1999)

Homojenlik (homogeneity), bir görüntüdeki piksel özelliklerinin diğer piksellerin özellikleriyle benzerliği ya da uygunluğu ile ilgilidir. Veri kümesinin özellikleri tanımlandıkça ortaya çıkar.

$$\text{Homojenlik} = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2} \quad (2.4)$$

### 2.2.3.5. Enerji (Haralick vd., 1973; Soh ve Tsatsoulis, 1999)

Enerji, görüntüdeki gri seviye dağılımının tekdüzeliğini temsil etmektedir. (0) ile (+1) arasında değer alır.

$$\text{Enerji} = \sum_{i=1}^N \sum_{j=1}^N \{p(i, j)\}^2 \quad (2.5)$$

### 2.2.3.6. Karelerin Toplamı (Varyans) (Haralick vd., 1973)

Doku analizinde kullanılan karelerin toplamı, bir diğer adıyla varyans (variance), istatistikteki genel kullanımı ile aynı görevi gerçekleştirir. GLCM'de, piksel değerlerinin ortalaması ile pikselin etrafındaki piksellerin ortalama dağılımına dayanmaktadır. Bu nedenle orijinal görüntüdeki piksellerin gri seviyelerinin basit varyansı ile aynı değildir.

$$\text{Karelerin toplamı (Varyans)} = \sum_{i=1}^N \sum_{j=1}^N (i - \mu)^2 p(i, j) \quad (2.6)$$

### 2.2.3.7. Toplam Varyans (Haralick vd., 1973)

Toplam Varyans (Sum Variance), görüntünün piksel değerlerinin toplam varyans dağılımını ölçer.

$$\text{Toplam varyans} = \sum_{i=2}^{2N_g} (i - SA)^2 P_{x+y}(i) \quad (2.7)$$

### 2.2.3.8. Toplam Ortalama (Haralick vd., 1973)

Toplam Ortalama (Sum Average), görüntünün piksel değerlerinin toplam dağılımının ortalamasını ölçer.

$$\text{Toplam ortalama} = \sum_{i=2}^{2N_g} [i P_{x+y}(i)] \quad (2.8)$$

### 2.2.3.9. Toplam Entropi (Haralick vd., 1973)

Toplam Entropi (Sum Entropy), görüntünün piksel değerlerinin toplam dağılımlarıyla ilgili bozukluğu ölçer.

$$\text{Toplam entropi} = - \sum_{i=2}^{2N_g} P_{x+y}(i) \log_2 [P_{x+y}(i)] \quad (2.9)$$

### 2.2.3.10. Varyans Farkı (Haralick vd., 1973)

Varyans Farkı (Difference Variance), görüntünün piksel değer farkı dağılımlarıyla ilgilidir.

$$\text{Varyans farkı} = \sum_{i=0}^{N_g-1} i^2 P_{x-y}(i) \quad (2.10)$$

#### 2.2.3.11. Entropi Farkı (Haralick vd., 1973)

Entropi Farkı (Difference Entropy), görüntünün piksel değer farkı dağılımı ile ilgili bozukluğu ölçer.

$$\text{Entropi farkı} = \sum_{i=0}^{N_g-1} P_{x-y}(i) \log_2[P_{x-y}(i)] \quad (2.11)$$

#### 2.2.3.12. Korelasyonun Bilgilendirici Ölçüsü-1 (KBÖ1) (Haralick vd., 1973)

Korelasyonun Bilgilendirici Ölçüsü-1 (Informational Measure of Correlation-1), piksellerin karşılıklı bilgilerinden yararlanarak olasılık dağılımları arasındaki korelasyonu, dokunun karmaşıklığını ölçerek değerlendirir.

$$\text{KBÖ1} = \frac{H_{XY} - H_{XY1}}{\max\{H_X, H_Y\}} \quad (2.12)$$

#### 2.2.3.13. Korelasyonun Bilgilendirici Ölçüsü-2 (KBÖ2) (Haralick vd., 1973)

Korelasyonun Bilgilendirici Ölçüsü-2 (Informational Measure of Correlation-2), piksellerin olasılık dağılımları arasındaki korelasyonu, görüntünün karmaşıklığını ölçerek değerlendirir.

$$\text{KBÖ2} = \sqrt{(1 - \exp[-2.0(H_{XY}^2 - H_{XY1})])} \quad (2.13)$$

#### 2.2.3.14. Maksimum Korelasyon Katsayısı (Haralick vd., 1973)

Korelasyon katsayısı (Correlation Coefficient), bağımsız değişkenler arasındaki ilişki ile ilgilenir. İlişkinin yönü ve büyüklüğünü belirtmekle birlikte bu katsayı (-1) ile (+1) arasında bir değer alır. Maksimum korelasyon katsayısı, korelasyon katsayısının maksimum değerine işaret eder.

$$\text{Maksimum korelasyon katsayısı} = \sqrt{\sum_k \frac{p(i,k)p(j,k)}{p_x(i)p_y(k)}} \quad (2.14)$$

### 2.2.3.15. Farklılık (Soh ve Tsatsoulis, 1999)

Farklılık (Dissimilarity), görüntüdeki piksellerin farklılık dereceleriyle ilgilenir: Örnek pikseller aynı seviyeye sahipse en küçük; örnekler aynı bağlamdaki iki görüntünün öğeleriye küçük; örnekler birbirinden farklı bağlamdaki iki görüntünün öğeleriye en büyük değeri. Bu durum, GLCM'in iki farklı bağlamı ayırt etmek için ya da iki benzer bağlamı tanımak ve aynı sınıfa atamak için kullanılabileceğini göstermektedir.

$$\text{Farklılık} = \sum_i \sum_j [i - j] \mathbf{p}(i, j) \quad (2.15)$$

### 2.2.3.16. Küme Gölgesi (Soh ve Tsatsoulis, 1999)

Küme Gölgesi (Cluster Shade), görüntünün çarpıklığının bir ölçüsüdür. 0'dan 2'ye kadar bir dizi tamsayı yoğunluğuna sahip yeni bir " $i + j$ " görüntüsü oluşturulur.  $\mu_x + j$  değeri görüntünün ilk komşuluğu için hesaplanır ve saklanır. Daha sonra komşuluk bir piksel taşındıkça güncellenir. Küme gölgesi yüksek olduğunda görüntü asimetriktir (Yang vd., 2012).

$$\text{Küme gölgesi} = \sum_{i=1} \sum_{j=1} [i + j - \mu_x - \mu_y]^2 \mathbf{p}(i, j) \quad (2.16)$$

### 2.2.3.17. Küme Belirginliği (Soh ve Tsatsoulis, 1999)

Küme Belirginliği (Cluster Prominence) de küme gölgesi gibi bir asimetri ölçüsüdür. Küme belirginliği değeri yüksek olduğunda, görüntü daha az simetriktir. Ayrıca, küme belirginlik değeri düşük olduğunda, GLCM matrisinde ortalama değerler etrafında bir tepe oluşur. Bir görüntü için, düşük bir küme belirginlik değeri, gri tonlamada küçük bir değişimi gösterir (Yang vd., 2012).

$$\text{Küme belirginliđi} = \sum_{i=1} \sum_{j=1} [i + j - \mu_x - \mu_y]^4 \mathbf{p}(i, j) \quad (2.17)$$

### 2.2.3.18. Maksimum Olasılık (Soh ve Tsatsoulis, 1999)

Maksimum Olasılık (Maximum Probability), en baskın komşu yoğunluk değerleri çiftinin oluşumudur.

$$\text{Maksimum olasılık} = \max\{p(i, j)\} \quad (2.18)$$

### 2.2.3.19. Ters Fark Momenti (Clausi, 2002)

Ters Fark Momenti (Inverse Difference Moment), bir görüntünün yerel homojenliğinin bir ölçüsüdür. Ters fark momenti ağırlıkları, kontrast ağırlıklarının tersidir.

$$\text{Ters fark momenti} = \sum_{k=0}^{N_g-1} \frac{p_{x-y}(k)}{1 + k^2} \quad (2.19)$$

### 2.2.3.20. Normalleştirilmiş Ters Fark (NTF) (Clausi, 2002)

Normalleştirilmiş Ters Fark (Inverse Difference Normalized), bir görüntünün yerel homojenliğinin başka bir ölçüsüdür. Homojenlikten farklı olarak, toplam ayırık yoğunluk değerlerine bölünerek komşu yoğunluk değerleri arasındaki farkı hesaplayarak normalleştirir.

$$\text{NTF} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i, j)}{1 + \left(\frac{|i - j|^2}{N^2}\right)} \quad (2.20)$$

### 2.2.3.21. Normalleştirilmiş Ters Fark Momenti (NTFM) (Clausi, 2002)

Normalleştirilmiş Ters Fark Momenti (Inverse Difference Moment Normalized), normalleştirilmiş ters fark gibi bir görüntünün yerel homojenliğinin başka bir

ölçüsüdür. Normalleştirilmiş ters fark momenti ağırlıkları, kontrast ağırlıklarının tersidir.

$$\text{NTFM} = \sum_{i=1}^N \sum_{j=1}^N \frac{P(i,j)}{1 + \left(\frac{(i-j)^2}{N^2}\right)} \quad (2.21)$$

#### 2.2.3.22. Otokorelasyon (Soh ve Tsatsoulis, 1999)

Otokorelasyon (Autocorrelation), doku inceliğinin ve kalınlığının büyüklüğünün bir ölçüsüdür.

$$\text{Otokorelasyon} = \sum_i \sum_j (ij) \mathbf{p}(i,j) \quad (2.22)$$

### 3. MAKİNE ÖĞRENMESİ

Günümüz teknolojilerle, açıkça talimat verilmeden görevleri akıllıca yerine getirebilen, akılcı ve insancıl düşünme becerisine sahip sistemlerin üretilmesi mümkündür. Bu sistemlerin oluşturulması Yapay Zekâ (AI: Artificial Intelligence) çalışma alanına girmektedir. Yapay zekâ, günümüzde günlük sosyal yaşamı, tıbbi çalışmaları ve ekonomik faaliyetleri destekleyen önemli bir teknolojidir.

Samuel (1959), “Makine Öğrenmesi” (ML: Machine Learning) kavramını ilk kez ortaya attığında yapay zekâ kavramı henüz bilgisayar oyunlarında öncü bir konumdaydı. Samuel (1959), Makine öğrenmesini makalesinde “Bilgisayarlara açık bir şekilde programlama yapmadan öğrenme yeteneğini kazandıran çalışma alanı” olarak tanımlamıştır.

Makine Öğrenimi, Yapay Zekanın bir alt kümesidir. Basit bir ifadeyle, bir yazılımın deneyimlerden öğrenmesini ve açıkça programlanmadan belirli bir görevde kendini geliştirmesini sağlama çalışmasıdır. ML, makinelere minimum insan müdahalesi ile açık bir şekilde programlanmadan öğrenme yeteneği vererek; makinelerin davranışlarında ve karar verme yetilerinde daha fazla insana benzemelerini sağlamak gibi amaçlar çerçevesinde yürütülür.

Makine öğreniminde, belirli bir görev için oluşturulan yazılımlar deneyimlerini ve öğrendiklerini verilerden karşılamaktadır. Veriler, makine öğreniminin yakıtı olarak da adlandırılmaktadır ve makinelerin veriler üzerinde eğitilebilmesi amacıyla ML modelleri oluşturmak için farklı algoritmalar kullanılmaktadır. ML’de kullanılacak algoritmanın seçimi eldeki veriye ve öğrenilmesi gereken göreve bağlıdır. Makine öğrenimine dayalı teknikler, örüntü tanıma, bilgisayarla görme, finans, eğlence dünyası ve tıbbi uygulamalardan tarım uygulamalarına kadar çeşitli alanlarda başarıyla uygulanmaktadır (El Naqa ve Murphy, 2015).

Geleneksel programlama yöntemlerinde ürünün oluşturulması için verilerle birlikte iyi yazılmış ve test edilmiş bir programın da sisteme girdi olarak verilmesi gerekmektedir. Günümüzde makine öğrenmesi ile öğrenme aşamasında elde edilen çıktılar verilerle birlikte sisteme girdi olarak sunulmaktadır. Elde edilen ürün makinenin belirli bir görevi yerine getirmesi için oluşturduğu yazılımdır. ML’nin geleneksel programlama yöntemlerine göre mimarisi Şekil 3.1 üzerinde gösterilmiştir.



**Şekil 3.1** Geleneksel programlama ve makine öğrenmesi

Makine öğrenimi genellikle yedi adımdan oluşmaktadır:

1. Verilerin elde edilmesi
2. Veri setinin hazırlanması
3. Model seçimi
4. Eğitim
5. Değerlendirme
6. Hiper parametre ayarlama
7. Tahmin

### 3.1. Terminoloji

Makine öğrenimi ile çalışmaya başlamadan önce bazı terimlerin bilinmesi gerekmektedir. Bu bölümde ML için bazı terimler sunulmuştur.

**Model:** Gerçekleştirilmesi beklenen gerçek dünyadaki bir görevin sayısal olarak temsilidir. Bir makine öğrenmesi modeli, eğitim verileriyle birlikte algoritmadan oluşmaktadır.

**Özellik (Feature):** Model için kullanılacak veri kümesinin ölçülebilir bir özelliğini ya da parametresini temsil eder.

**Özellik Vektörü (Feature Vector):** Çoklu sayısal özelliklerin kümesini temsil eder. Özellik vektörü, eğitim ya da tahmin amacıyla ML modeline girdi olarak verilmektedir.

**Eğitim (Training):** Bir öğrenme algoritması, yerine getirmesi gereken görev için eğitim verilerini girdi olarak alır. Girdi verilerindeki işe yarar özellikleri bularak modeli istenen sonuçlar (hedef) için eğitir. Eğitim sürecinin çıktısı ML öğrenme modelidir.



**Hedef (Etiket):** ML modelinin tahmin etmesi gereken değere hedef ya da diğer adıyla etiket adı verilmektedir.

**Tahmin (Prediction):** Eğitim modeli hazır olduğunda, girdi verileriyle beslenerek beklenen çıktıyı üretmek için tahmin eder.

**Aşırı uyum (Overfitting):** Bir eğitim modeli, büyük miktarda veri eğitirken, gürültü, yanlış veri girişi vb. gibi durumlardan dolayı yanlış öğrenme eğilimi gösterebilir. Burada model, verileri doğru bir şekilde karakterize etmede başarısız olmaktadır.

**Yetersiz uyum (Underfitting):** Modelin, girdi verilerindeki istenen özelliklere ulaşamaması durumudur. Basit bir ifadeyle, modelin veya algoritmanın verilere yeterince uymaması gibi durumlarda ortaya çıkmaktadır.

## 3.2. Makine Öğreniminde Öğrenme/Eğitim Yaklaşımları

Makine öğreniminde, denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve takviyeli öğrenme olmak üzere dört ana yaklaşım bulunmaktadır. Bu yaklaşımlar, makine öğrenme modeli için veri setinin nasıl gözlemleneceğine ve ulaşılması istenen hedefe göre çalışmaktadır. Bu tez çalışmasında denetimli makine öğrenme yaklaşımının bir alt türü olan sınıflandırma modelleri kullanıldığı için bahsi geçen yaklaşımların açıklamalarından sonra başlıca sınıflandırma algoritmaları hakkında detaylı bilgi verilecektir.

### 3.2.1. Denetimli Makine Öğrenme Yaklaşımı

Denetimli makine öğrenme modelinde bir dizi giriş değişkeni ( $x$ ) ve bir çıktı değişkeni ( $y$ ) bulunur. Modelde kullanılan algoritma, bu değişkenler arasındaki eşleme (tahmin) işlevini temsil eder (ilişki:  $y = f(x)$ ). Çıktı, öğrenme süreci boyunca takip edilir veya denetlenir. Sonuçların optimizasyonu için algoritma her adımda düzeltilir. Algoritma, veri seti üzerinde eğitilerek kabul edilebilir bir seviyeye gelene kadar değiştirilir. Denetimli öğrenme yaklaşımı regresyon ve sınıflandırma görevleri için kullanılmaktadır.

Regresyon, gelecekteki değerlerin tahmin edilmesinde kullanılmaktadır. Model geçmiş istatistikî verilerle eğitilir. Sınıflandırmada ise çeşitli sınıflar (etiketler) altındaki öğeler bağlı oldukları etiketlere göre eğitilir. Yeni gelen bir verinin doğru sınıfa atanması sistemin başarılı çalıştığının göstergesidir. Çalışmalarda genellikle

kullanılan bazı denetimli öğrenme algoritmaları, Lojistik Regresyon, Destek Vektör Makineleri, Karar Ağaçları, Rastgele Orman, K-En Yakın Komşu Algoritması, Naive Bayes ve Yapay Sinir Ağları olarak gösterilebilir.

### **3.2.2. Denetimsiz Makine Öğrenme Yaklaşımı**

Denetimsiz makine öğrenme yaklaşımı, çıktının bilinmediği ve elimizde sadece girdi değişkeninin bulunduğu durumlarda kullanılabilen bir yaklaşımdır. Burada algoritmanın kendi kendine öğrenmesi söz konusudur ve algoritma verilerden öğrendikçe faydalanılacak özelliği kendi kendine keşfeder. Amaç, veri seti hakkında daha fazla bilgi sahibi olmak için verilerdeki dağılımı ortaya çıkarmaktır. Denetimsiz öğrenme kümeleme ve ilişkilendirme görevleri için kullanılmaktadır.

Kümeleme, veri setindeki aynı özelliklere sahip girdilerin bir araya toplanılması anlamına gelir. İlişkilendirmede ise veri seti içerisinde anlamlı ilişkileri yöneten kurallar ortaya çıkarılır. Denetimsiz öğrenme algoritmalarına örnek olarak temel bileşen analizi ve K-Ortalama kümeleme analizi gösterilebilir.

### **3.2.3. Yarı Denetimli Makine Öğrenme Yaklaşımı**

Yarı denetimli öğrenme yaklaşımında, model az miktarda etiketlenmiş veri ile büyük miktarda etiketlenmemiş veri kullanılarak eğitilir. Bu özelliğiyle hem denetimli hem denetimsiz olma yeteneğine sahiptir. Yarı denetimli öğrenmede genellikle ilk adım denetimsiz bir ML algoritması yardımıyla benzer verileri kümelemektir. Sonraki adım, mevcut az miktarda etiketli verilerin özelliklerini kullanarak etiketli olmayan verileri etiketlemektir. Tüm veriler etiketlendikten sonra son aşamada görevi yerine getirmek için denetimli öğrenme yaklaşımı uygulanabilir.

### **3.2.4. Takviyeli (Pekiştirmeli) Makine Öğrenme Yaklaşımı**

Takviyeli öğrenme yaklaşımında, makine öğrenme modeli, davranışları için aldıkları pekiştirme araçlarına ya da geri bildirimlere dayalı kararlar dizisi oluşturmak için eğitilir. Makine, karmaşık ve belirsiz durumlarda bir sonuca ulaşmayı öğrenir ve bu süreç boyunca hedefe her ulaştığında pekiştirilir.

Takviyeli öğrenmede çıktı olmamasından dolayı denetimli öğrenmeden farklıdır. Takviyeli öğrenme yaklaşımında, pekiştirme aracı bir görevi gerçekleştirme

adımlarının belirlenmesinde karar mekanizmasını temsil eder. Makine, eğitim verileri olmadığında kendi öğrendiği deneyimlerine göre hareket eder.

### 3.3. Sınıflandırma

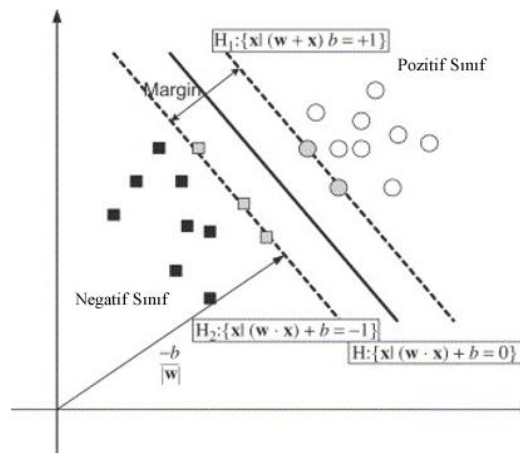
Görüntü sınıflandırma basit bir ifadeyle, bir görüntünün hangi sınıfa ait olduğuyula ilgilenmektedir. Makine öğreniminde birçok farklı sınıflandırma görev türü ile her bir görev için kullanılabilir modellemeye yönelik özel yaklaşımlar bulunmaktadır.

### 3.4. Başlıca Sınıflandırma Algoritmaları

#### 3.4.1. Destek Vektör Makineleri

Destek Vektör Makineleri (SVM: Support Vector Machines) ya da destek vektör ağları, günümüzde hala büyük veri sınıflandırma problemlerini çözmeye yardımcı olan klasik öğrenme tekniklerinden biridir (Suthaharan, 2016). Vapnik ve meslektaşları tarafından geliştirilmiştir (Boser, Guyon ve Vapnik, 1992; Guyon, Boser ve Vapnik, 1993; Vapnik, Golowich ve Smola, 1997). SVM, özellikle büyük veriler için yardımcı olmaktadır.

Destek vektör ağı, yüksek boyutlu bir özellik alanına yansıtılan veri noktalarını bir hiper düzlem ile ayıran denetimli makine öğrenme algoritmasıdır (Cortes ve Vapnik, 1995). Destek vektör makineleleri algoritmasının basitçe çalışma prensibi Şekil 3.2'de sunulmuştur.



Şekil 3.2 SVM ile iki değişkenin sınıflandırılması (Widodo ve Yang, 2007)

SVM temelde üç çalışma prensibine dayanmaktadır: maksimum marj sınıflandırıcısı, destek vektör sınıflandırıcıları ve destek vektör makineleri.

### 3.4.1.1. Maksimum Marj Sınıflandırıcısı

Maksimum marj sınıflandırıcısı bir diğer adıyla sert kenar sınıflandırıcısı, basit parametrelere sahiptir. Esasında, SVM'nin pratikte nasıl çalıştığını en basit şekilde açıklayan varsayımsal bir sınıflandırıcıdır.

Hiper düzlem, girdi değişken alını bölen bir çizgidir. Çalışma prensibinde, girdi değişkenlerinin yer aldığı uzayı, değişkenleri sınıflara en iyi ayıracak şekilde bir hiper düzlem seçilir. Tüm değişkenler tamamen bu çizgi ile ayrılmaktadır. Hiper düzlem oluşturulduktan sonra aşağıdaki denklem takip edilir.

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 = 0 \quad (3.1)$$

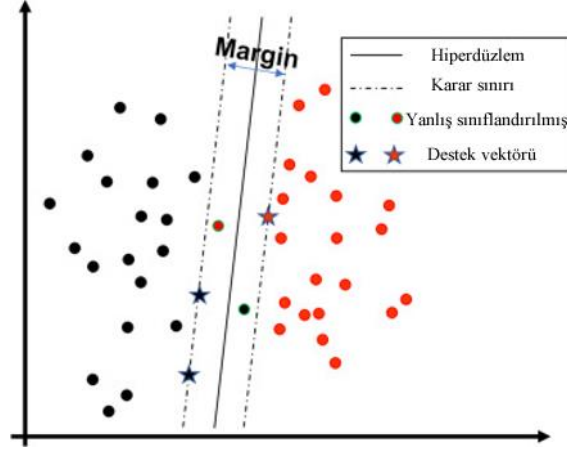
Hangi verinin hiper düzlemin altında ya da üstünde kalıp kalmayacağını takibi de aşağıdaki denklemlere göre gerçekleştirilir.

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 > 0 \quad (3.2)$$

$$\beta_0 + \beta_1 X_1 + \beta_2 X_2 < 0 \quad (3.3)$$

### 3.4.1.2. Destek Vektör Sınıflandırıcısı

Bazı karmaşık durumlarda maksimum marj sınıflandırıcıları verileri ayırmada yetersiz kalabilmektedir. Destek vektör sınıflandırıcısı bir diğer adıyla yumuşak kenar sınıflandırıcısı, maksimum marj sınıflandırıcılarının genişletilmiş bir versiyonu olarak da değerlendirilebilir. Kolayca ayrılamayan bir veri kümesi için, karar sınırları çerçevesinde sınıflandırma hatalarına daha az ağırlık vererek fazla uyumu önlemek için destek vektör sınıflandırıcıları kullanılmaktadır (Misra, Li ve He, 2020).

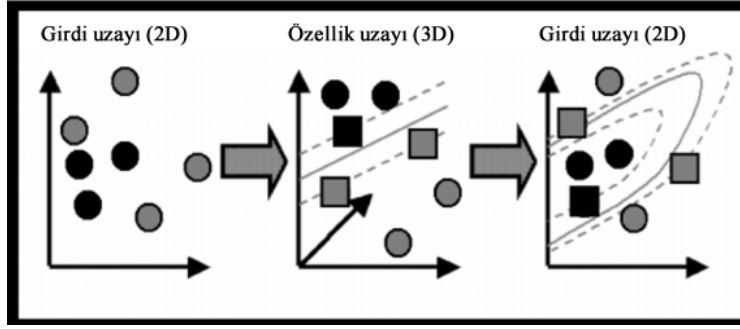


**Şekil 3.3** Destek vektör sınıflandırıcısının uygulanması (Misra vd., 2020)

Veri seti içerisinde tek bir aykırı değer bile marjların tanımlanma şekillerini değiştirebilmektedir. Esasında temel amaç, gözlemin daha sağlıklı yapılabilmesi için verilere göre maksimum marjın tanımlanması ve bu şekilde modelin daha iyi geliştirilmesini sağlamaktır.

#### 3.4.1.3. Destek Vektör Makinesi

Destek vektör makinesi prensibi, destek vektör sınıflandırıcısının sınıflandıramadığı doğrusal olmayan görevler için kullanılmaktadır. Doğrusal olmayan sınıfları ayırmak neredeyse imkânsız olduğunda çekirdek (kernel) adı verilen bir fonksiyon kullanılır. Çekirdek fonksiyonu, bir SVM için ayar parametresi olarak kabul edilebilir. Daha yüksek boyutlu vektör uzayını elde etmek için maliyeti düşürmeyi ve doğrusal olmayan sınıflandırılabilir verilerle uğraşmak için kullanılmaktadır. SVM'nin performansı büyük ölçüde çekirdeğe bağlıdır (Amari ve Wu, 1999). Polinom çekirdeği ve Gauss radyal temel işlev çekirdeği olmak üzere yaygın olarak kullanılan iki çekirdek bulunmaktadır. Polinom çekirdeği, doğrusal olarak sınıflandırılmayan bir problemin çözümü için uzayı, iki boyuttan üç veya daha fazla boyuta taşır. Üç veya daha yüksek boyutlarda sınıflandırma yaparken doğru yerine düzlem kullanılır. Daha önce bahsi geçen hiper düzlem terimi bunu ifade etmektedir. Polinom çekirdeğinde  $c$  parametresi ile ince ayarlamalar yapılabilir.



**Şekil 3.4** Ayrılmayan bir durum için sınırın oluşturulması. SVM'ler, verileri optimum ayırma hiper düzleminin arandığı daha yüksek boyutlu bir alana yansıtır. Destek vektörleri karelerle gösterilmiştir (Xu, Zomer ve Breerton, 2006).

Radyal temel işlev çekirdeği, bir diğer adıyla Gauss işlev çekirdeği, doğrusal olmayan verileri ayırmak için sonsuz sayıda boyut üretebilir. Verileri normalleştirirken ölçeklendirilmesi gereken bir “ $\gamma$ ” (gama) hiper parametresine bağlıdır. Gamma değeri ne kadar küçükse varyans o kadar yüksek; ne kadar büyükse varyans o kadar küçük olur.


Destek vektör makinesinin bazı avantajları bulunmaktadır:

- Yapılandırılmış, yapılandırılmamış ya da yarı yapılandırılmış veriler için esnek bir özelliğe sahiptir.
- Çekirdek işlevi, neredeyse her veri türünde karmaşıklığı kolaylaştırır.
- Aşırı uyum sorunu diğer modellere göre daha az görülmektedir.

Ancak bu avantajlara rağmen büyük veri kümeleri için daha fazla hesaplama süresi gerektirebilir.

### 3.4.2. Karar Ağaçları

Karar ağaçları önemli bir veri madenciliği metodudur. Yukarıdan aşağıya özyinelemeli bir yaklaşımı temel alan bir algoritmadır. Genel olarak bir karar ağacı adından da anlaşılacağı üzere bir kök düğümden, alt düğümlerden ve yaprak düğümlerden meydana gelmektedir. Her yaprak düğüm bir karara karşılık gelmektedir. Yaprak olmayan her düğüm veri örneklerinin bir alt kümesini içerir. Kök düğüm, tüm veri setini kapsamaktadır. Temel olarak bir karar ağacı, özellik alanını bölme stratejisini temsil etmektedir. Özellik alanını bölme işlemi her basamakta uygulanır ve en iyi bölen özneliğin seçiminde farklı yöntemler kullanılır. Özellik bölmenin amacı, yaprak olmayan her düğümün saflığını en üst düzeye çıkarmaktır. Basit bir karar ağacı örneği Şekil 3.5 üzerinde gösterilmiştir.



**Şekil 3.5** Dört boyutlu özellik uzayına sahip üç sınıftan oluşan bir karar ağacı örneği (Kavzoğlu ve Çölkesen, 2010)

Zamanla performans artışı ve farklı veri işleme çalışmaları ile çeşitli karar ağacı algoritmaları geliştirilmiştir. Bunlar arasında AID, CHAID, CART, ID3, C4.5, C5.0 gibi popüler algoritmalar yer almaktadır.

Morgan ve Sonquist (1963a, 1963b) tarafından ilk kez ortaya atılan Otomatik Etkileşim Algılama (AID: Automatic Interaction Detection) algoritması (Kass, 1975), karar ağacı algoritmalarının bilinen en eski algoritmasıdır. Karar ağacı algoritmasının daha önce bahsedilen temel özelliklerini içermektedir. Her adımda AID, değişken ve değerlere göre ikiye bölünür. Süreç, bölünmeler sonlanıncaya kadar sürmektedir.

Ki-Kare Otomatik Etkileşim Dedektörü (CHAID: CHi-squared Automatic Interaction Detector), temel bir karar ağacı öğrenme algoritmasıdır. Kass (1980) tarafından geliştirilmiştir. Yorumlanması ve kullanım kolaylığı ile tercih edilmektedir. Değişkenler arası ilişkinin saptanmasından sonra, seçilen özneliliğin homojen değerlerinin bir alt sınıfı olarak oluşturulan alt düğümü bölmek için en iyi özneliliği seçer. Yöntem, herhangi bir budama olmadan eksik değerleri işleyebilmektedir.

Breiman, Friedman, Olshen ve Stone (1984) tarafından önerilen Sınıflandırma ve Regresyon Ağacı (CART: Classification and Regression Tree), her adımda kendinden daha homojen iki alt grup oluşturur. CART, bağımlı değişkenin kategorik veya sayısal olmasına bağlı olarak sınıflandırma veya regresyon ağaçları üreten bir karar ağacı öğrenme tekniğidir.

Quinlan (1986), karar ağacı algoritmaları arasında iyi bilinen Yinelemeli Dikotomizer 3 (ID3: Iterative Dichotomiser 3) algoritmasını ortaya koymuştur. ID3, tüm veri setini kök düğüm olarak kabul eden bir ağaç oluşturur. Daha sonra her özneliliği yeniler ve

bu özneliğin entropisini hesaplamak için verileri alt kümeler olarak bilinen parçalara ayırır. Bölme işleminden sonra algoritma, daha önce dikkate alınmamış öznelikleri yinelenen öznelikler içerisinde alarak sonraki adımlara ilerler. Ancak bu algoritmanın aşırı uyum gibi daha az doğruluğa yol açan dezavantajları bulunduğundan, sonraları iyileştirilmiş ID3 (Jin, De-Lin ve Fen-Xiang, 2009), optimize edilmiş ID3, C4.5 ve C5.0 (Thakur, Markandaiah ve Raj, 2010) gibi versiyonlar ortaya atılmıştır (Brijain, Patel, Kushik ve Rana, 2014).

C4.5, Ross Quinlan tarafından geliştirilen bir karar ağacı algoritmasıdır. Yine Quinlan (1986) tarafından geliştirilen önceki ID3 algoritmasının geliştirilmiş halidir. C4.5, her basamakta sınıflandırılmış örnekleri dikkate aldığı için ID3'e göre ileri düzeydedir. C4.5'te normalleştirilmiş bilgi kazancına göre bölme işlemi yapılır ve en yüksek bilgi kazancına sahip öznelik dikkate alınır. ID3'ten farklı olarak hem sürekli hem ayrık özellikleri çok verimli bir şekilde işleyebilir. Bir karar ağacı kurduktan sonra düşük öneme sahip tüm dallar budanarak kaldırılır.


### **3.4.3. Rastgele Orman**

Rastgele Orman (RF: Random Forest), temelde sınıflandırma yapmak için bir dizi karar ağacı içeren bir algoritma olmasına karşın bir regresyon algoritması tekniğine de sahip olduğundan dolayı burada ayrıca ele alınmıştır. Breiman (2001), sınıflandırmada ağaç kullanımına ilişkin iyi bilinen iki yönteme dayalı olarak RF'yi önermiştir: Bagging (Breiman, 1996) ve Boosting (Bartlett, Freund, Lee ve Schapire, 1996). Bagging yönteminde, ek olarak rastgelelik katmanını eklemiştir (Xia, 2020).

Terim içerisinde geçen "Orman" kelimesi algoritmanın çok sayıda ağaç içerdiğini anlatmaktadır. RF, yüksek varyans özellikleriyle oldukça kararsız sonuçlar verebilen bir karar ağacı modelinin yetersiz kaldığı durumlarda kurtarıcı bir model olarak ortaya çıkmaktadır.

Rastgele orman, adından da anlaşılacağı üzere oluşturacağı karar ağaçlarını rastgele seçer ve elde ettiği sonuçların ortalamasını alarak sınıflandırır. Bu yönüyle karar ağaçlarından ayrılmaktadır. Küçük eğitim verilerinin kullanıldığı önyükleme verileri kullanılarak bağımsız olarak eğitilen ağaçlar ile RF oluşturulur. Bu sayede doğruluk ve istikrarın artması ile birlikte aşırı uyum önlenir ve varyans azaltılır. Buna karşın çok sayıda ağaç oluşumu modelin yavaş çalışmasına yol açarak zaman kaybına neden olabilir. RF'nin şematik gösterimi Şekil 3.6 üzerinde sunulmuştur.





**Şekil 3.6** Rastgele ormanın şematik gösterimi (Gedeck, Kramer ve Ertl, 2010)

Rastgele orman algoritması her özellik için rastgele alt kümeler oluşturur ve bunlarla küçük ağaçları meydana getirir. Bu özelliği ile tüm modele ait en önemli özelliği ortaya çıkarmak yerine rastgele oluşturulan bu alt kümeler arasından en iyi özelliği ortaya çıkarmayı hedefler. RF, basit bir karar ağacı algoritmasına göre birçok avantaja sahiptir:

- Karar ağaçlarında fazla takılmayı azaltır ve doğruluğun artırılmasına yardımcı olur,
- Hem sınıflandırma hem de regresyon problemlerine karşı esnek bir yapıdadır,
- Hem kategorik hem de sürekli verilerle iyi çalışır,
- Kural tabanlı bir yaklaşım kullanıldığından verilerin normalleştirilmesine gerek yoktur.

Bununla birlikte RF'nin bazı dezavantajları da bulunmaktadır:


- Çıktıları birleştirmek için çok sayıda ağaç oluşturulduğundan dolayı fazla hesaplama gücü gerektirebilir,
- Sınıfı belirlemek için çok sayıda karar ağacı birleştirildiğinden dolayı çok zaman gerektirebilir.

#### **3.4.4. K-En Yakın Komşu**

K-En Yakın Komşu (KNN: K-Nearest Neighbors) algoritması, Amerika Birleşik Devletleri Savunma Bakanlığı için yapılan bir araştırma üzerine 1951 yılında ilk olarak Evelyn Fix ve Joseph Hodges tarafından ortaya atılmış (Fix ve Hodges, 1989); daha

sonra Thomas Cover tarafından geliştirilmiş (Cover ve Hart, 1967; Altman, 1992) parametrik olmayan bir sınıflandırma yöntemidir. KNN, makine öğrenme algoritmaları içerisinde basit mantıkla çalışan algoritmalarından biridir. Temel olarak sınıflandırılacak özniteliğin sınıf etiketi kendisine en yakın “ $k$ ” komşularına göre belirlenir (Hellman, 1970). Bu “ $k$ ” değeri girilen öznitelige en yakın komşu noktaların sayısını temsil etmektedir. Veri noktası, komşularının çoğunluk oyu ile sınıflandırılır ve bir uzaklık fonksiyonu ile ölçülen “ $k$ ” en yakın komşusu arasında en yaygın olan sınıfa atanır.

K-En Yakın Komşu hem regresyon hem de sınıflandırma problemlerinde kullanılabilir. KNN, tahmin gücü, hesaplama süresi, hedef çıktıyı yorumlama kolaylığı gibi avantajları nedeniyle kullanılmaktadır. KNN, basitliği nedeniyle genellikle SVM ve Yapay Sinir Ağları gibi daha karmaşık sınıflandırıcılar için bir kıyaslama noktası olarak kullanılabilir (Mukid, Widiharah, Rusgiyono ve Prahutama, 2018). Basitliğine rağmen KNN, daha güçlü sınıflandırıcılardan daha iyi sonuçlar üretebilmektedir. Veri sıkıştırma, genetik, finans, video tanıma, el yazısı algılama ve konuşma tanıma gibi alanlarda kullanılmaktadır. Amazon veya Netflix gibi dev şirketler, satın alınacak kitapları veya izlenecek filmleri önerirken KNN'yi kullanmaktadır (Liu, Wang ve Chen, 2020).



Şekil 3.7 KNN sınıflandırma örneği (Özsakabaşı, 2008)

K-En yakın komşu sınıflandırmasının bir örneği Şekil 3.7’de sunulmuştur. Burada toplamda iki sınıf bulunmaktadır. İç çemberin  $k=3$ ’ü; dış çemberin ise  $k=5$  örneklemini referans aldığı bilinmektedir. Gösterilen yeşil dairenin bu iki sınıftan birine atanacağını varsayarsak;  $k=3$  alındığında yeşil daire kırmızı üçgen sınıfına

atanır çünkü iç çember içerisinde bir mavi kareye karşın iki kırmızı üçgen bulunmaktadır. Buna karşın  $k=5$  alındığında ise yeşil daire mavi kare olarak atanacaktır çünkü kesik çemberin içerisinde iki kırmızı üçgene karşılık üç mavi kare bulunmaktadır (Özsakabaşı, 2008).

K-En yakın komşu algoritması sınıflandırmasında “ $k$ ” değerinin sınıflandırma performansı üzerine ciddi etkileri olabilmektedir. Doğru “ $k$ ”yi elde edebilmek için, KNN algoritması farklı “ $k$ ” değerleri ile birkaç kez çalıştırılmalı ve en az hataya sahip olanı seçilmelidir. Doğru “ $k$ ”, daha önce görmediği verileri doğru bir şekilde tahmin edebilmelidir. Sınıflandırmada eşitlik sorununu çözmek için “ $k$ ” değeri tek sayı olarak belirlenmelidir.

K-En yakın komşu algoritmasının avantajları:

- Hızlı hesaplama süresine sahiptir,
- Basit bir algoritma yapısına sahiptir,
- Hem regresyon hem de sınıflandırma için kullanışlıdır,
- Daha kısa sürede yüksek doğrulukla çalışabilmektedir.

Bunların yanında KNN'nin bazı dezavantajları:


- Doğruluğun yüksek olması verilerin kalitesine bağlıdır,
- Büyük verilerde yavaşlamaya neden olabilir,
- Veride alakasız özellikleri hesaba katabilir,
- Yüksek bir bellek donanımı gerektirebilir,
- Tüm eğitim verilerini saklamaya dayalı bir sisteme sahip olduğundan hesaplama maliyetli olabilmektedir.

### 3.4.5. Yapay Sinir Ağları

Yapay zekâ uygulamalarından biri olan Yapay Sinir Ağları (ANN: Artificial Neural Networks) basit bir ifadeyle, insan beyninin çalışma yapısını taklit eden (Egrioglu, Aladag, Yolcu, Uslu ve Basaran, 2009), mevcut verileri analiz ederek bu verilerden farklı öğrenme algoritmaları ile yeni bilgiler oluşturan bir bilgi işleme teknolojisidir.

Doğal bir sinir sistemi, milyarlarca sinir hücresinden (nöronlardan) oluşmaktadır. Bu nöronlar birbirlerine karmaşık bir yapıyla bağlanmaktadır. İnsan beyni de bu doğal sinir sisteminin bir parçasıdır. İnsan beyninin öğrenme ve çıkarım yeteneğinden esinlenerek tasarlanan ANN modelleri, veri tahmininden yeni bir bilgi oluşturmaya

yani kendiliğinden öğrenmeye kadar birçok yeteneğe sahiptir. Biyolojik sinir hücresi ve yapay sinir ağı modelinin benzetim ilişkisi Şekil 3.8 üzerinde gösterilmiştir (Öztürk ve Şahin, 2018). Biyolojik Sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları ise Tablo 1’de verilmiştir (Öztürk ve Şahin, 2018).




Şekil 3.8 Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, Honorio ve da Silva, 2013; Öztürk ve Şahin, 2018)

Çizelge 3.1 Biyolojik sinir sistemi elemanları ve yapay sinir sisteminde karşılıkları (Öztürk ve Şahin, 2018)


Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı (Yapay Nöron)
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay sinir ağları, farklı mimarilere göre birleştirilen yapay nöron adı verilen temel hesaplama birimlerinden oluşmaktadır (McCulloch ve Pitts, 1943). ANN, yapı olarak bir adet girdi katmanı, en az bir adet gizli katman ve bir adet çıktı katmanından oluşmaktadır (Şekil 3.9).



Şekil 3.9 Basitçe ANN yapısı (Ayvaz, 2012)

Şekil 3.10 üzerinde yapay sinir ağı hücresinin yapısı basitçe gösterilmiştir. Görüldüğü üzere bir yapay nörona  $n$  adet veri girişi gerçekleştirilmiştir. Girilen veriler ağırlıklarla çarpılarak toplanır ve tahmin (ön yargı) eklenir. Bunun sonucunda net girdi elde edilir. Daha sonra net girdi aktivasyon fonksiyonundan geçirilerek bir veri çıktısı elde edilmiş olur (Öztürk ve Şahin, 2018).



Şekil 3.10 Yapay nöron (Öztürk ve Şahin, 2018)

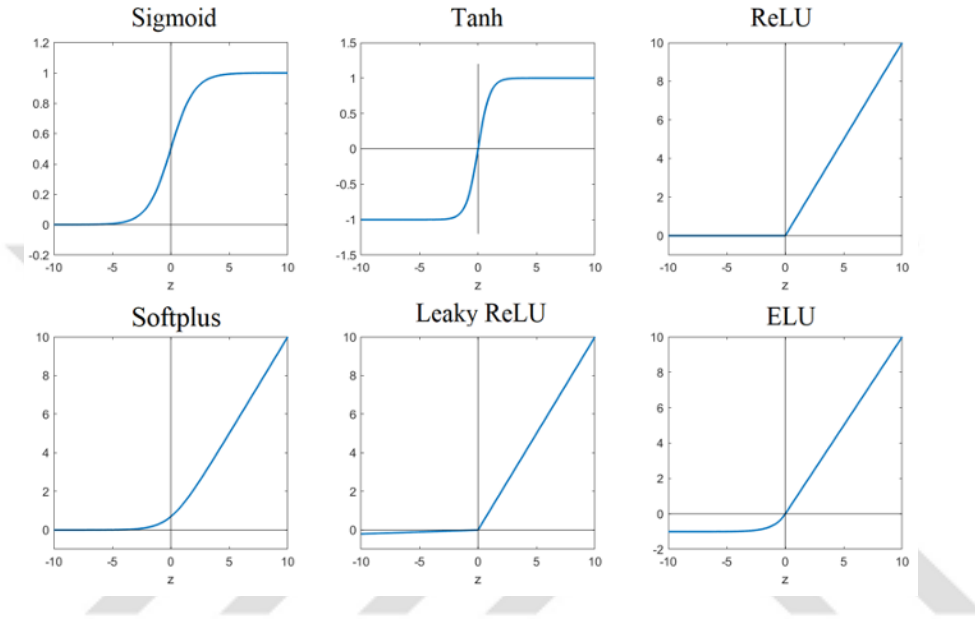
### 3.4.5.1. Yapay Sinir Ağlarının Yapısı

**Girdiler:** Yapay sinir hücresine bir başka hücreden veya katmandan gönderilen bilgiyi ifade eder.

**Ağırlıklar:** Her bir verinin önemine ve etkisine göre atanan değerdir. Ağırlıklar eşik değere göre hesaplanır. Eşik değerinin altındakilerin ağırlıkları daha düşük; üstündeki değerlerin ağırlıkları daha yüksek kabul edilir. Girdi olarak alınan veriler ağırlıklarla çarpılarak toplanır, ön yargı eklenerek bir sonraki nörona iletilir.

**Birleştirme fonksiyonu:** Bir yapay nörona birden fazla girdi ulaştığında bunların tek bir değer olarak alınmasını sağlar.

**Aktivasyon fonksiyonları:** Basit bir ifadeyle, hücreye gelen net girdiyi işleyerek hücrenin üreteceği çıktının belirlenmesini sağlar. Aktivasyon fonksiyonları doğrusal, adım, sigmoid, tanjant hiperbolik, eşik değer ve sinüs aktivasyon fonksiyonları gibi farklı fonksiyonları içermektedir (Şekil 3.11).



**Şekil 3.11** Yapay sinir ağlarında kullanılan başlıca aktivasyon fonksiyonları


**Katman sayısı:** ANN'ler katman sayısına göre tek katmanlı ve çok katmanlı olmak üzere iki grupta incelenmektedir. Tek katmanlı modellerde genellikle doğrusal bir yapı bulunurken, çok katmanlı modellerde veri çeşidi ve probleme göre farklı yapılar kullanılabilir.

Yapay sinir ağlarının, günümüz teknolojilerinde en fazla kullanıldığı problemler sınıflandırma, tahmin, veri yorumlama ve ilişkilendirme ve veri filtrelemedir (Ağyar, 2015; Öztürk ve Şahin, 2018). ANN modelleri, tek katmanlı algılayıcılar, çok katmanlı algılayıcılar, ileri beslemeli ANN ve geri beslemeli ANN olmak üzere dört başlıkta sınıflandırılmaktadır.

### 3.4.5.2. Tek Katmanlı Algılayıcılar

Tek katmanlı sinir ağları sadece girdi ve çıktı katmanlarından oluşmaktadır. Her ağın bir veya birden fazla girdisi ve çıktısı bulunabilir. Her bağlantının bir ağırlığı bulunmaktadır. Tek katmanlı algılayıcılarda ağın çıktısının sıfır olmasını önleyen bir

eşik değeri bulunmaktadır. Eşik değerinin girdisi 1'dir (Öztemel, 2006). Şekil 3.12 üzerinde basit bir tek katmanlı ağ gösterilmiştir.




Şekil 3.12 Tek katmanlı sinir ağı modeli (Öztemel, 2006)

### 3.4.5.3. Çok Katmanlı Algılayıcılar

Öğrenilmesi gereken bilgilerin girdi ve çıktıları arasında doğrusal olmayan bir ilişki bulunması durumunda diğer metotlar yetersiz kalmaktadır. Bu sorunun üstesinden gelmek için çok katmanlı yapay sinir ağları modeli geliştirilmiştir.

Çok katmanlı sinir ağlarının yapısı Şekil 3.13 üzerinde gösterilmiştir. Şekilde de görüldüğü üzere çok katmanlı bir sinir ağı girdi, ara katmanlar ve çıktı katmanı olmak üzere üç katmandan oluşan bir yapıdadır. Çok katmanlı ağdaki bilgiler girdi katmanından ağa sunulur ve ara katmanlardan geçerek çıktı katmanına iletilir (Öztemel, 2006).




Şekil 3.13 Çok katmanlı algılayıcı modeli (Öztürk ve Şahin, 2018)

### 3.4.5.4. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında, adından da anlaşıldığı üzere bilgi aktarımı sadece ileri yönlüdür. Giriş katmanından çıkış katmanına doğru bir hareket söz konusudur. Bir katmandaki nöronların kendi aralarında bağı bulunmaz; nöronlar sadece kendinden



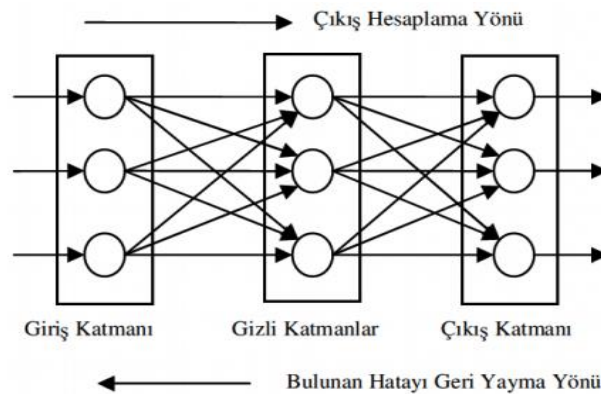
sonraki katmana bilgi verir. Giriş katmanına gelen bilgiler hiçbir değişime uğramadan sonraki katmana aktarılır. Sonrasında bilgi, orta ve çıkış katmanında hesaplamalarla belirli bir ağırlığa sahip olarak çıkış katmanına yönlendirilir. Burada işlenerek dış ortama aktarılır. İleri beslemeli sinir ağlarının çalışma şekli Şekil 3.14 üzerinde gösterilmiştir.



Şekil 3.14 İleri beslemeli sinir ağlarının çalışma şekli (Öztemel, 2006)

### 3.4.5.5. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağı modelinde bir nöron sadece kendinden sonraki katmanla bağlantı kurmaz; kendinden önceki ya da kendi katmanında bulunan herhangi bir nöronla da bağlantı kurabilir. Geri beslemeli ANN'lerin dinamik bir yapısı bulunmaktadır, doğrusal ilişkiden söz edilemez. Geri beslemeli ANN'lerde modelin mimarisi kullanılan veri setine göre farklılık gösterebilmektedir. Geri beslemeli bir ANN yapısı Şekil 3.15 üzerine gösterilmektedir.



Şekil 3.15 Geri beslemeli yapay sinir ağı yapısı (Öztürk ve Şahin, 2018)




## 4. DERİN ÖĞRENME

Günümüz teknolojilerine bakıldığında kendi kendini sürebilen arabalar, doğal dil işleme ya da robotlar gibi temeli makine öğrenmesine dayanan daha pek çok uygulamanın artık sıradan hale geldiğini görebilmek mümkündür. Hayatımızın çoğu alanına girmiş olan makine öğreniminin geçmişi, esasında yaklaşık 80 yıl öncesine kadar ulaşabilmektedir. Makine öğrenimi hakkında her şey 1943'te nörofizyoloji uzmanı Warren McCulloch ve matematikçi Walter Pitts'in nöronlar ve nöronların nasıl çalıştıkları hakkında bir makale yazmaları ve yapay sinir ağının ilk modelini oluşturmalarıyla başlamıştır (McCulloch ve Pitts, 1943). Yirminci yüzyılın ortalarında Alan Turing tarafından makine öğrenmesi hakkında ileri sürülen fikirler hız kazanarak devam etmiştir. 1952'de Arthur Samuel kendi kendine öğrenebilen bir bilgisayar oyunu programını yazmıştır (Samuel, 1959). 1957'de (Rosenblatt, 1957) Frank Rosenblatt tarafından insan beyninin simülasyonu olarak ilk sinir ağı tasarlanmıştır. Daha sonra 1967'de KNN algoritması yazılmıştır (Cover ve Hart, 1967).

Esasında asıl değişimin 90'lı yıllarda gerçekleştiği söylenebilir. 90'lı yıllara geçişle birlikte makine öğrenimi bilgi odaklı bir yaklaşımdan veri odaklı bir yaklaşıma geçmiştir. Büyük miktarda veriyi analiz etmek, veriden sonuçlar çıkarmak ya da çıkarılan sonuçlardan öğrenimin gerçekleşmesi için bilgisayar yazılımları oluşturulmaya başlanmıştır.

1997'de IBM firması tarafından o dönemki dünya satranç şampiyonunu yenen ilk bilgisayar yazılımı geliştirilmiştir (Hsu, 1999). “Derin ağ” kavramına olan ilgi, Kanada İleri Araştırma Enstitüsü tarafından bir araya getirilen bir grup araştırmacı tarafından 2000'li yıllarda canlandırılmıştır (Hinton, 2005; Hinton, Osindero ve Teh, 2006; Bengio, Lamblin, Popovici ve Larochelle, 2006; Ranzato, Poultney, Chopra ve LeCun, 2006; LeCun vd., 2015). 2006 yılında Geoffrey Hinton, bilgisayarların resim ve videolardaki nesnelere ve metinleri tanıyabilmesine yardımcı olabilecek yeni algoritmalar için “Derin Öğrenme” kavramını ortaya atmıştır.

Derin Öğrenme (DL: Deep Learning), bilgisayarlara ve elektronik cihazlara mantıksal işleyişi öğreten, yapay zekanın (AI) bir alt sınıfı olan makine öğrenmesinin (ML) bir alt kümesidir. DL, ML ve AI arasındaki ilişki Şekil 4.1 üzerinde basitçe gösterilmiştir.



**Şekil 4.1** DL, ML ve AI arasındaki ilişki

Bu tez çalışmasının bir bölümünü ilgilendiren derin öğrenme yaklaşımının detaylı anlaşılabilmesi için makine öğreniminin iyi anlaşılması gerekmektedir. Makine öğrenimine ilişkin detaylı anlatıma önceki bölümde yer verilmiştir.

Derin öğrenme yöntemleri, ham veriden başlayarak, her biri bir sınıfa ait temsil verileri, daha yüksek, biraz daha soyut bir düzeyde temsile dönüştüren, basit ancak doğrusal olmayan öğrenme yöntemlerini kapsamaktadır (LeCun vd., 2015). DL, insan zekasını taklit edebilmek için çeşitli karmaşık algoritmalara dayanmaktadır. Bu özel metot, makineler verileri farklı kategorilerde sınıflandırabilmeleri için tanımayı öğretir. DL sayesinde makineler, herhangi bir görevi insan benzeri şekilde tanımlamak ve gerçekleştirmek için görüntüleri, videoları, metinleri veya ses dosyalarını kullanabilir. Günümüz teknolojisinde yer alan sürücüsüz araçlar, kişiselleştirilmiş öneri sistemleri ve kullanılan sesli asistanlar DL'nin günlük hayatımızdaki uygulamalarının birer örneğidir. DL'ye göre uygun şekilde ve doğru verilerle eğitilmiş bilgisayarlar insan başarısını başarılı bir şekilde taklit edebilir. Burada DL, bilgisayarları büyük veri setlerine maruz bırakan yinelemeli öğrenme yöntemlerine odaklanmaktadır. Bu şekilde, bilgisayarların tanımlayıcı özellikleri öğrenmesine ve değişime uyum sağlamasına yardımcı olur. Bilgisayarların verilere tekrar tekrar maruz bırakılması, farklılıkların, mantıkların anlaşılmasını ve güvenilir bir sonuca ulaşılmasını sağlar. DL, son zamanlarda farklı ve karmaşık problemlerde daha güvenilir bir yapıda geliştirilmiştir. Bu yönüyle farklı disiplinlerde birçok araştırmacının ilgi odağı olmaya devam etmektedir.

#### **4.1. Derin Öğrenmenin ve Nöronların Çalışma Şekli**

Basit bir ifadeyle DL, makineler insan zekasını taklit etmeyi öğretmek için yinelemeli ve doğrusal olmayan yöntemlere dayanmaktadır. DL'de bir yapay sinir ağı, bu

yinelemeli yöntemi birkaç hiyerarşik düzeyde gerçekleştirmektedir. İlk aşamalarda, makineler nesnenin (görüntü, ses, metin vb.) basit bilgilerini öğrenir ve aşamalar arttıkça bilgileri karmaşıklaşır ve artmaya devam eder. Her aşamada makineler daha fazla bilgiyi öğrenir ve tüm öğrendiklerini son aşamada birleştirir. Sürecin son aşamasında sistem, birleşik girdi olan son bilgiyi toplar. Bu bilgi birkaç hiyerarşiden geçer ve bu süreç insan zekâsındaki mantıksal düşünmeye benzetilir.

Bir DL sisteminde, giriş düğümlerine bilgi sağlandığında, her düğüme sayısal bir değer atanır. Sayısı yüksek olan düğümler daha fazla aktivasyon değerine sahiptir. Transfer fonksiyonuna ve bağlantı gücüne bağlı olarak düğümler aktivasyon değerini aktarmaktadır. Düğümler, aktivasyon değerini aldığı anda, tüm miktar hesabına ve transfer fonksiyonuna göre aktivasyon değerini değiştirir. Süreçteki sonraki adım, nöronun bir sinyalin iletilip ileilmeyeceğine karar vermesine yardımcı olan aktivasyon fonksiyonunun uygulanmasıdır. Aktivasyon işleminden sonra yapay sinir ağını tasarlamak için sinapslara ağırlıklar atanmaktadır. DL’de yapay sinir ağı eğitilirken aktivasyon ağırlıkları sıklıkla değiştirilir. Aktivasyon işleminin ardından ağ çıkış katmanına ulaşır. Bu katman kullanıcı ve model arasında bir arayüz görevi gören bir adımdır. Çıkış düğümü kullanıcının anlaması için gerekli bilgileri yorumlar.

Geri yayılım ya da geriye doğru yayılma ile her defasında yanlış ağırlıklar ortadan kaldırılır. Bu işlem istenen hedefe ulaşılmasına yardımcı olur. İleri yayılmada ise; giriş katmanları bilgiyi işler ve ağ üzerinden ileriye doğru yayar. Beklenen sonuçlar sonuç değerleriyle karşılaştırılır, hatalar hesaplanır ve bilgileri geriye doğru yayılır. Optimal seviyeye ulaşıldığında ağ nihai sonuç için test edilebilir.

## **4.2. Derin Öğrenme ve Makine Öğrenimi Arasındaki Fark Nedir?**

Derin öğrenme ve makine öğrenmesi sıklıkla iç içe kullanılsa da iki kavram yapay zekanın bir parçasıdır ve bazı noktalarda farklılıklar yer almaktadır. ML, öğrenme modellerini tanımlamak ve oluşturmak için verileri kullanan daha geniş kapsamlı bir alandır. ML, istatistiksel modeller kullanarak verilerin yapısını anlamaya çalışır. Veri setlerinden gereken bilgileri manuel olarak çıkarmak için veri madenciliği ile başlar; daha sonra makineleri verilerden öğrenmeye ve tahminlerde bulunmaya yönlendirmek için algoritmalar kullanır. ML’nin kullanımı çok eskiye dayanmaktadır. DL, yalnızca öğrenmek ve hedefe yönelik işlev görmek için yapay sinir ağlarına odaklanan yeni bir

alandır. Daha önce de belirtildiği üzere yapay sinir ağı, verilerden otomatik olarak bilgi toplamak ve bu bilgileri öğrenmek için insan sinirlerini taklit eden bir mekanizmadır. DL, işlenmemiş verilerle beslenen sistemde uçtan uca öğrenmeyi içerdiğinden, sistem ne kadar çok veri ile beslenirse sonuçlar o kadar kesin ve doğru olmaktadır. DL, daha büyük hacimli verilerle çalışıp daha derinlemesine çalışırken, ML modelleri daha yüzeysel bir öğrenme ile sınırlıdır. Belirli bir aşamadan sonra daha fazla yeni veri eklenmesi ML için pek bir fark oluşturmaz.

Derin öğrenme ve makine öğrenimi arasındaki temel farklar şunlardır:

- Derin öğrenme küçük veri setleriyle nispeten daha iyi performans göstermez. ML algoritmaları ise performansından ödün vermeden daha küçük veri setlerini işleyebilmektedir. DL’de modelin doğruluğu daha fazla veriyle artabilir; buna rağmen geleneksel ML’de belirli bir görev için daha az veri kullanmak doğru olabilmektedir.
- Geleneksel ML’de uzman, modelde uygulanacak özellikleri tanımlar, veri türünü ve işlevlerini manuel olarak kodlar. DL’de ise veri seti üzerinden modelin öğrenimi için bir uzmana gerek olmayabilir.
- Derin öğrenmede hesaplamaların ağır yükünü taşımak için gelişmiş üst düzey donanım gereklidir. ML için ise düşük kaliteli makinelerde de sağlıklı bir şekilde çalışmam mümkün olabilir. DL algoritmaları, karmaşık hesaplamalarda verimli sonuçlar alabilmek için Grafik İşlemci Birimine ihtiyaç duyulabilir.
- Derin öğrenme, büyük veri seti ve sinir ağının karmaşıklığı nedeniyle eğitim için daha fazla zaman gerektirmektedir. Bir ML algoritmasının eğitilmesi saniyelerden saatlere kadar sürebilir ancak bir DL görevi ile kıyaslanırsa bu haftalarla açıklanabilir. Bunun yanında bir defa eğitildikten sonra DL algoritmasının çalışma süresi, ML’den önemli ölçüde azdır.

### **4.3. Evrişimsel Sinir Ağları (CNN)**

Evrişimsel Sinir Ağları, görüntü tanıma için yaygın olarak kullanılan (Nisha ve Meeral, 2021) bir DL algoritmasıdır. Bir evrişimsel sinir ağı, insan beyninin korteks bölgesinin çalışmasından ilham alınarak oluşturulmuştur. Bilgisayarla görme kapsamında birçok probleme uygulanmaktadır (Krizhevsky vd., 2017). CNN, temelde

yapay sinir ağlarına benzerdir ancak ağ yapısı olarak evrişim adı verilen matrisleri kullanır. “Tensör” adı verilen üç boyutlu yapılar birden fazla iki boyutlu matris kanallarından oluşmaktadır. CNN, Tensör olarak verilen bir grafik girdisine evrişim filtreleri kullanarak karmaşık işlemleri gerçekleştirebilen bir mimaridir (Litjens vd., 2017).

Esasında tipik bir CNN mimarisi, evrişimli filtreler ve havuzlama katmanları uygulayan ileri beslemeli bir katmanlar dizisidir. Son havuzlama katmanından sonra önceki katmanların harita özelliklerini sınıflandırmada kullanmak amacıyla vektörel hale getirmek için tam bağlantılı katmanı kullanır. CNN mimarisi, uygulamadan önce bir özellik çıkarım işlemi gerektirmez. Ancak buna rağmen CNN’yi sıfırdan eğitmek zor ve zaman alıcıdır.

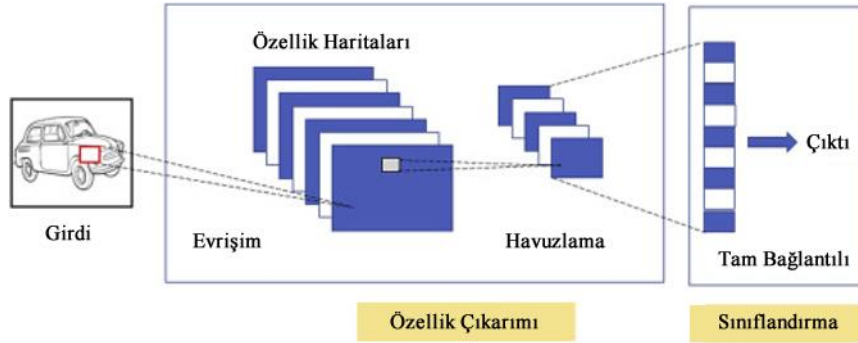
Çalışmalarda kullanılacak model, sınıflandırma için hazır olmadan önce eğitim için çok büyük bir veri setine ihtiyaç duyar. Ayrıca, büyük boyutlu görüntülerin kullanılması durumunda çok sayıda filtreyi işleyebilmesi için çok yüksek donanım ve altyapıya da ihtiyaç duyulmaktadır.

Bir evrişimsel sinir ağı, birçok evrişimli matristeki değerleri öğrenmek için kullanılabilir. Öğrenme süreci, belirli görsel özellikler veya yapılarla karşılaştırıldığında etkinleşen görüntü filtreleri ile sonuçlanır. Çekirdek boyutu veya komşuluk olarak da adlandırılan her bir filtre matrisinin boyutu, filtrenin alıcı alanını belirtmektedir (Thoma, 2017).

Evrişimsel sinir ağı algoritması, giriş olarak sunulan görüntünün her bir bölümünü çıkarır. Çıkarılan bölümlerin özelliklerine dayalı olarak her nöron için ağırlık atar. Böylece nöronların önemi birbirinden ayırt edilir (Nisha ve Meeral, 2021). CNN’de her katman bir önceki katmandan bilgi alır (Albawi, Mohammed ve Al-Zawi, 2017) ve bunu bir sonraki katmana aktarır. Bir CNN’nin çıktısı çeşitli sınıflara ait bir örneğin istatistiksel olasılıkları olabileceği gibi herhangi bir sınıflandırıcı ile kullanılabilen özellikler de olabilmektedir (Mosisa, 2019).

Şekil 4.2, bir sayısal görüntünün, CNN’nin ilk katmanı olan “Evrişim Katmanı”na girdi olarak verildiği ve bir sonraki “Havuzlama Katmanı” ile işlenerek sonunda “Tam Bağlantılı Katman” ile sınıflandırıldığı genel CNN mimarisini temsil etmektedir. Evrişim ve havuzlama katmanlarında özellik çıkarımı gerçekleştirilirken; son katman olan tam bağlantılı katmanda sınıflandırma işlemi gerçekleştirilmektedir. Esasında bu

katmanlar arasında kesin bir sınır olmamakla birlikte sınıflandırma işlemi bir veya daha fazla tam bağlantılı katmandan oluşabilmektedir.



Şekil 4.2 Genel CNN mimarisi (Nisha ve Meeral, 2021)

Tam bağlantılı katman, mimarinin son elemanı olarak tasarlanan, sınıflardan birine ait girdi verisinin veya görüntüsünün sonuç olasılığını hesaplayan çıktı katmanıdır. Sistemden tam bağlantılı katmanların kaldırılması, CNN mimarisinin sınıflandırma yeteneğini ortadan kaldırarak mimarinin sadece özellik çıkarıcıya dönüştürülmesi anlamına gelmektedir. Sonraki başlıklarda CNN katmanları daha detaylı açıklanmıştır.

#### 4.3.1. Evrişim Katmanı

Bilgisayarlar, sayısal görüntüleri piksel olarak okur ve bu da *yükseklik x genişlik x derinlik* matrisi olarak temsil edilir. Renkli görüntüler farklı renk kanalları üzerinden hesaplanır (Örneğin RGB), buradaki derinlik terimi bunu ifade etmektedir (Udofia, 2021).

Evrişim katmanı, bir dizi öğrenilebilir filtreden yararlanır. Modele girdi olarak verilen görüntüde belirli özelliklerin varlığının tespit edilmesi için bir filtre kullanılır. Genellikle orijinal görüntüye göre daha küçük boyutlu ancak aynı derinliğe sahip bir matris ( $M \times M \times 3$ ) elde edilir. Evrişim işleminin matematiksel olarak ifadesi denklem 4.1 üzerinde gösterilmiştir (Mosisa, 2019). Denklemde  $m$  ve  $n$ , örnek bir girdi görüntüsünün boyutlarını;  $K$  çekirdeği ve  $S$ ,  $i$  ve  $j$  konumlarından elde edilen çıktıyı temsil etmektedir.

$$S[i, j] = \sum m \sum n . K[u - m, j - n] \quad (4.1)$$

Evrişim işlemi temel olarak üç fikre dayanmaktadır: seyrek etkileşimler ya da seyrek ağırlıklar, parametre paylaşımı ve eşdeğer temsiller (Kang, 2021). Seyrek etkileşimler

terimi, giriş ve çıkış değerleri arasında daha az bağlantı olduğu anlamına gelmektedir. Bu nedenle, bellek gereksinimlerini azaltan, istatistiksel verimliliği artıran daha az parametreye ihtiyaç bulunmaktadır. Giriş görüntüsünden daha küçük çekirdek boyutları uygulanarak daha az işlemle çıktı üretilmektedir. Buna karşılık evrişim tekniği kullanılmayan geleneksel sinir ağlarında, her bir girdi değeri ile her bir çıktı değeri arasındaki ilişkilerin tanımlanması için matris çarpımı kullanılmaktadır. Dolayısıyla, tüm çıkışların tüm girişlere bağlı olma durumu ortaya çıkmaktadır.

Evrişimsel katman, öğrenebilen filtreleri kullanarak belirli sayıdaki özellik haritasını girdi olarak alıp  $n$  adet özellik haritasını çıktı olarak verir. Burada  $n$  değeri katmandaki özellik haritalarına uygulanan filtre sayısıdır. Bu değer genellikle 32, 64, 128 gibi değerler alır. Filtre sayısı, filtre boyutu ve adım sayısı evrişimsel katmanın hiper parametreleridir. Filtre derinliği girdi derinliği ile aynıdır. Filtrenin eni ve boyu genellikle eşittir.

Evrişim katmanının bir diğer önemli işlevi parametre paylaşımıdır. Parametre paylaşımı, belirli bir özellik haritasında tüm nöronlar tarafından filtre ağırlıklarının paylaşılmasını ifade eder. Bu işlevi sayesinde parametre sayısının azaltılmasının yanında daha basit karar sınırları öğrenebildiğinden daha doğru tahminler için daha az eğitim verisine ihtiyaç duyulmaktadır. Bu durum, aynı veri seti için uygun mimariye sahip bir CNN'nin, ANN'ye göre daha iyi sonuçlar elde edebildiğini açıklar niteliktedir.

#### **4.3.2. Havuzlama Katmanı**

Havuzlama katmanı, temel olarak ağız uzamsal boyutunu kademeli olarak azaltarak aşırı uydurmayı kontrol etmek için kullanılan, evrişim katmanları arasındaki bağlantıların sayısını azaltarak hesaplama yükünü azaltan CNN'nin önemli bir bileşenidir. Evrişim katmanının aksine havuzlama, ağız derinliğini değiştirmez, derinlik boyutu sabit kalır. Küresel ortalama havuzlama (GAP: Global Average Pooling), stokastik havuzlama ve maksimum havuzlama (max pooling) gibi havuzlama yöntemleri bulunmaktadır. Maksimum havuzlama, evrişimsel sinir ağında en yaygın kullanılan havuzlama yöntemidir.

Bir modelde havuzlama katmanı kullanılmasının temelde üç amacı bulunmaktadır: yerel öteleme değişmezliği elde etmek, küçük yerel değişikliklerden etkilenmemek ve

parametre sayısını azaltmak. Bu sayede hesaplama maliyeti azalırken aynı zamanda aşırı uyum ihtimali de azaltılmaktadır.

### **4.3.3. Tam Bağlantılı Katman**

Bir CNN ağında son katmanlar tamamen bağlantılı şekildedir. Önceki katmanların her bir nöronu sonraki katmanlardaki her bir nörona bağlıdır. Bu durum basit bir ifadeyle, girdiden çıktıya kadar tüm olası yolların dikkate alındığı üst düzey akıl yürütme becerisinin taklit edilmesidir. Tam bağlantılı katman bir CNN ağının son aşamasıdır.

## **4.4. Aktivasyon**

Aktivasyon işlevi, bazı kaynaklarda aktivasyon katmanı olarak da geçmektedir. Aktivasyon işlevi, sinyalin bir katmandan diğerine nasıl aktarıldığını kontrol eder. Temel olarak insan beyinde nöronların ateşlenmesinin simülasyonudur. Öğrenilen bilgilerle güçlü bir şekilde ilişkilendirilen çıkış sinyalleri, daha fazla nöronu aktive ederek, sonraki süreçte sinyallerin tanımlama için daha verimli bir şekilde yayılmasını sağlar. CNN’de sinyal yayılımının modellenmesi için çok çeşitli aktivasyon işlevleri kullanılmaktadır. Bunların arasında en yaygın olanı ReLU işlevidir (Sharma, 2017).

## **4.5. Aşırı Uyum (Overfitting) ve Yetersiz Uyum (Underfitting)**

Aşırı uyum ve yetersiz uyum yapay sinir ağları modellerinde kritik olan iki problemdir. Bu problemler farklı nedenlerden dolayı meydana gelmektedir.

Aşırı uyum, bir modelin etkili bir şekilde eğitilmesine rağmen zayıf bir doğrulama gerçekleştirmediği durumda ortaya çıkmaktadır. Aşırı uyum gerçekleştiğinde, tasarlanan model görünmeyen verilere karşı doğru bir performans gösteremez ve amacından sapar. Bu durum, oluşturulan bir ML modelinin yeni verilere genelleştirilerek yeniden kullanılabilmesi açısından önemli bir problemdir.

Bir ML algoritması kullanılarak modeli eğitmek için örnek bir veri setinden yararlanılır. Bununla birlikte, modelin örnek veriler üzerinde çok uzun süre eğitilmesi ya da modelin çok karmaşık bir şekilde kurgulanması, modelin “gürültüyü” ya da alakasız bilgileri öğrenmesine yol açabilir. Model gürültüyü ezberlediğinde ve eğitim kümesine çok yaklaştığında model “aşırı uyum” sağlamış olur ve yeni gelen verilere genelleme yapamaz. Bir ML modeli yeni verilere genellemiyorsa, hedeflenen




sınıflandırma veya tahmin görevlerini yerine getiremez. Düşük hata oranları ve yüksek varyans, aşırı uyumun en iyi göstergeleridir. Bu tür davranışları önlemek amacıyla eğitim veri setinin bir kısmı aşırı uyumun kontrolü için “test veri seti” olarak ayrılır. Eğitim verilerinin hata oranı düşük; ancak test verilerinin hata oranı yüksek olması durumunda büyük olasılıkla aşırı uyum gerçekleşmiş demektir. Doğrusal bir model kullanımı aşırı uyumdan kaçınmaya yardımcı olmakla birlikte karşılaşılan gerçek dünya problemleri genellikle doğrusal olmayan problemlerden oluşmaktadır. Bu bağlamda aşırı uyumu engellemek için bazı tekniklere başvurulması gerekmektedir. Bu teknikler arasında erken durdurma (bırakma), daha çok veri ile eğitim, veri artırma, özellik sayısının azaltılması gibi yöntemler yer almaktadır.

Yetersiz uyum, model yeterli süre boyunca eğitilmediğinde veya modelin girdi ve çıktı değişkenleri arasında anlamlı bir ilişki yakalayamaması durumunda ortaya çıkan bir problemdir. Yetersiz uyumda yüksek bir hata oranı elde edilir. Yetersiz uyum, modelin çok basit kurgulanmasından kaynaklı olabilir. Yetersiz uyumun en iyi göstergeleri yüksek önyargı ve düşük varyanstır. Bu durum veri seti eğitilirken tespit edilebilmektedir.

Model eğitilirken yetersiz uyumun erken tespit edilmesi, başlangıçta girdi ve çıktı değişkenleri arasındaki ilişkiyi iyi anlamlandırmaya yardımcı olmaktadır. Modeli çok sade tasarlamadan yeterli düzeyde karmaşıklığı koruyarak yetersiz uyumun önüne geçilebilir ve daha doğru sınıflandırma gerçekleştirilebilir. Yetersiz uyumun önüne geçebilmek için model için kullanılacak verideki gürültü ve aykırı değerleri azaltma, eğitim süresini artırma, doğru öznitelik seçimi gibi yöntemler yer almaktadır.

#### **4.6. Bırakma (Dropout)**

Bırakma, yapay sinir ağlarının aşırı uyum sorunlarını önlemenin basit bir yoludur (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014). Bırakma, gizli nöronların çıktılarını önceden ayarlanmış bir olasılıkla sıfıra indirgeyerek çalışmaktadır. Sıfıra ayarlanmış nöronların ileri geçişe ya da geri yayılıma bir katkısı bulunmaz yani “dışlanırlar”. Bırakılan nöronlar nedeniyle sinir ağı mimarisi her seferinde güncellenir. Bu durum modeli daha sağlam örnekleri öğrenmeye zorlar. Şekil 4.3 üzerinde bırakma işleminin temsili gösterilmiştir.




**Şekil 4.3** Bir sinir ağındaki bırakma işleminin uygulanması. X işaretli nöronlar bırakılarak dışlanmıştır (Ha, Tran, Van ve Than, 2019)

#### 4.7. Toplu Normalizasyon (batch normalization)

Bir sinir ağındaki, eğitilebilir her katmanın girdilerinin özellikleri arasında karşılaştırma yapılabilmesi için bir normalleştirme işlemi gerçekleştirilir. Burada sıfır ortalama normalizasyon (zero-mean) ve birim varyans (unit variance) gibi normalleştirme teknikleri kullanılır. Bunu işlemle ağı yüksek bir öğrenme oranıyla eğitilmesi sağlanır. Buna ek olarak normalizasyon işlemiyle sigmoid gibi aktivasyon fonksiyonlarının doygunluk modunda takılıp kalmaması da sağlanmaktadır.

#### 4.8. Başlıca CNN Sınıflandırıcıları

Probleme uygun bir sınıflandırıcı seçiminde önemli olan bazı kriterler bulunmaktadır. Bu kriterlerin başında sınıflandırıcının doğrulama başarısı, hızı ve model ağının boyutu gelmektedir. Bir ağ seçiminde bu özelliklerin optimum belirlenmesi gerekmektedir. ImageNet kullanılarak yapılan sınıflamadan elde edilen doğruluk, doğrulama başarıları için gereken süre ve model boyutu açısından çeşitli CNN sınıflandırıcıları arasındaki karşılaştırılma Şekil 4.4 üzerinde gösterilmiştir.



**Şekil 4.4** Çeşitli CNN sınıflandırıcılarının karşılaştırması (Anonim, 2021c)


ImageNet projesi tarafından her yıl farklı CNN sınıflandırıcılarının performanslarının sergilendiği ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC: ImageNet Large Scale Visual Recognition Competition) düzenlenmektedir. ILSVRC, ImageNet (Deng vd., 2009) olarak adlandırılan 20000 kategoride 15 milyon görüntü içeren açık erişimli veri kümesinin 1,2 milyon görüntü ve 1000 kategori içeren bir alt kümesi kullanılarak yapılan bir bilgisayarlı görü yarışmasıdır. Burada test edilen modellerin performansları “top-5” hata oranına göre değerlendirilmektedir. Top-5 hata oranı hesaplanırken yöntemin bir test görüntüsü için en olası 5 sınıf tahmini gerçekleştirilir. Bu sınıflardan biri test görüntüsünün gerçek sınıfına ait ise metodun tahmini doğru olarak kabul edilir. Aksi durumda yapılan tahmin yanlış sayılır. Geleneksel ML yöntemlerinde top-5 hata oranı %26 seviyelerine ulaşırken son dönemlerde grafik işlemci birimlerinin gelişmesi ve farklı CNN modellerinin ortaya çıkması ile bu hata oranı giderek düşürülmüştür.

Bu bölümde ILSVRC’de top-5 hata oranlarına göre birbirlerine rakip olabilen başlıca CNN sınıflandırıcıları detaylıca açıklanmıştır.

#### 4.8.1. AlexNet

Krizhevsky vd. (2017) tarafından 2012 yılında sunulan AlexNet, ILSVRC-2012 yarışmasında %15,3’lük bir top-5 hata oranı seviyesiyle başarılı bir sonuç ortaya koymuştur. Yarışmada ikinci modele %10,9’luk bir fark atarak bilgisayarlı görü


dünyasının ilgisini toplamayı başarmıştır. 8 katmandan oluşan AlexNet; LeCun, Bottou, Bengio ve Haffner (1998) tarafından oluşturulan LeNet mimarisine benzer olmasının yanında daha fazla filtreye sahiptir ve daha derindir. AlexNet mimarisinde nesnelere tanımak için evrişim katmanında  $11 \times 11$ ,  $5 \times 5$  ve  $3 \times 3$  filtreler kullanılmıştır. Son evrişim katmanından sonra 4096 çıkış içeren tam bağlantılı iki katman bulunur. Aktivasyon fonksiyonu olarak ReLU kullanılmış ve maksimum havuzlama yönteminden yararlanılmıştır. AlexNet mimarisinin temsili Şekil 4.5 üzerinde gösterilmiştir.



Şekil 4.5 AlexNet mimarisi (Llamas, Lerones, Medina, Zalama ve Gómez-García-Bermejo, 2017)

#### 4.8.2. VGGNet

Simonyan ve Zisserman (2014) tarafından tasarlanan VGGNet 2014 yılındaki ILSVRC yarışmasında top-5 hata oranında %7,3 ile derece elde etmiştir. Tasarlanan ilk modeli temel alınarak sonradan farklı katmanlarla farklı VGGNet modelleri oluşturulmuştur. Bunlardan en sık kullanılanları VGG-16 ve VGG-19'dur. Modellerin sonunda yer alan sayılar modelde yer alan katman sayısını belirtmektedir. VGG-16 mimarisi, 13 evrişim katmanı ve 3 adet tam bağlantılı katmandan oluşmaktadır. VGG-16 modelinin temsili Şekil 4.6 üzerinde gösterilmiştir.

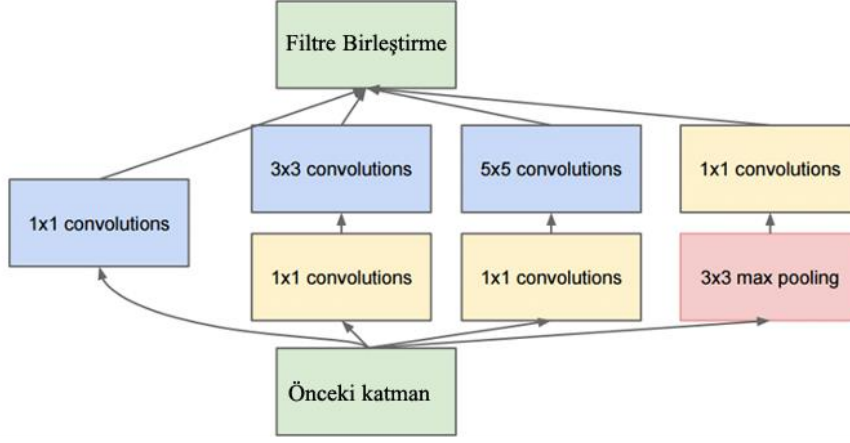


**Şekil 4.6** VGG-16 model mimarisi (Shi vd., 2018)

VGG ağında  $11 \times 11$  ve  $7 \times 7$  gibi büyük filtreler kullanmak yerine  $3 \times 3$ 'lük küçük filtreler ve birer adımlık ilerlemeler kullanılmıştır. Tüm evrişim katmanlarından sonra ReLU aktivasyon fonksiyonu kullanılmış ve ardından  $2 \times 2$  maksimum havuzlama eklenmiştir. Küçük filtre kullanımı sayesinde evrişimsel katman sayısını artırarak daha ayrımcı bir karar sistemi oluşturulmuştur.

#### 4.8.3. Inception (GoogLeNet)

Google firmasından Szegedy vd. (2015) tarafından oluşturulan Inception bir diğer adıyla GoogLeNet modeli, ILSVRC-2014 %6,67'lik top-5 hata oranıyla VGGNet'in önüne geçmiştir. Sonralarda farklı sürümlerin modellenmesiyle Inception-V1 olarak adlandırılan model toplamda 22 katmandan oluşmaktadır. Inception-V1'in VGGNet ve AlexNet'e nazaran farklı bir yapısı bulunmaktadır. Ağın ortasında  $1 \times 1$  filtreye sahip evrişim katmanı bulunmaktadır. Bununla birlikte ağın sonunda tam bağlantılı katmanlar yerine GAP katmanı bulunmaktadır. Bu uygulamalar sayesinde derinliğin artmasına rağmen parametre sayısı azaltılmış ve aşırı uyum sorunu engellenmiştir. Bu iki farklı tekniğin başka bir modelden alınmasına rağmen (Lin, Chen ve Yan, 2013), evrişim katmanlarında farklı boyutlarda filtrelerin girdi olarak kullanılması ve evrişim katmanları ve havuzlama katmanından elde edilen çıktılarının birleştirilmesi Inception olarak yeni bir modelin yaratılmasını sağlamıştır. Şekil 4.7 üzerinde Inception-V1'in temel mimarisi gösterilmiştir.

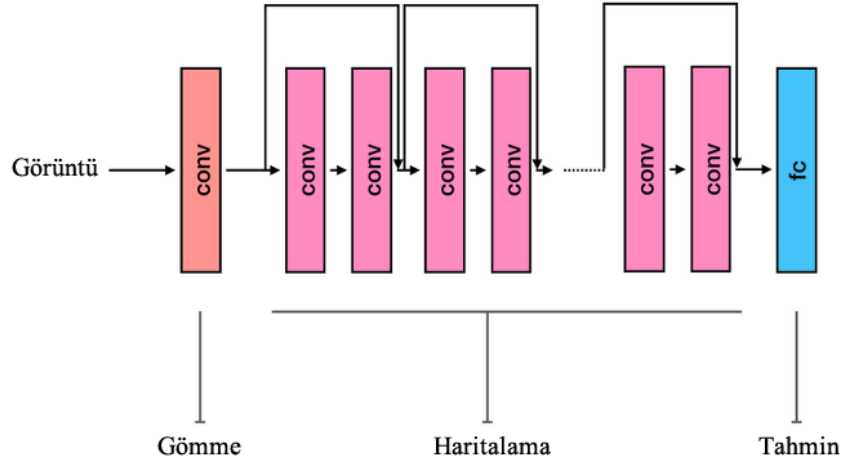


**Şekil 4.7** GoogLeNet Inception mimarisi (Ebrahim, Alsmirat ve Al-Ayyoub, 2018)

Inception mimarisinden esinlenilerek oluşturulmuş Inception-V3 modeli (Szegedy, Vanhoucke, Ioffe, Shlens ve Wojna, 2016), Inception-V1'in tekrar düzenlenerek parametre sayısı ve hesaplama verimliliği açısından daha da geliştirilmiş bir versiyonudur. 42 katmandan oluşan Inception-V3, ILSVRC-2015 yarışmasında sınıflandırma kategorisinde derece elde etmiştir. Çarpanlara ayrılmış evrişimler, ara çıktılarda yapılan düzenlemeler ve boyut indirgeme teknikleri Inception-V3'ün getirdiği yenilikler arasındadır. Özellikle çarpanlara ayrılmış evrişimler sayesinde ağır verimliliği düşmeden parametre sayısında azalma meydana gelmiştir. Bu sayede daha az parametre ile daha derin bir model yaratılmıştır. Önerilen boyut indirgeme yöntemiyle hesaplamada verimlilik artırılmıştır.

#### 4.8.4. ResNet

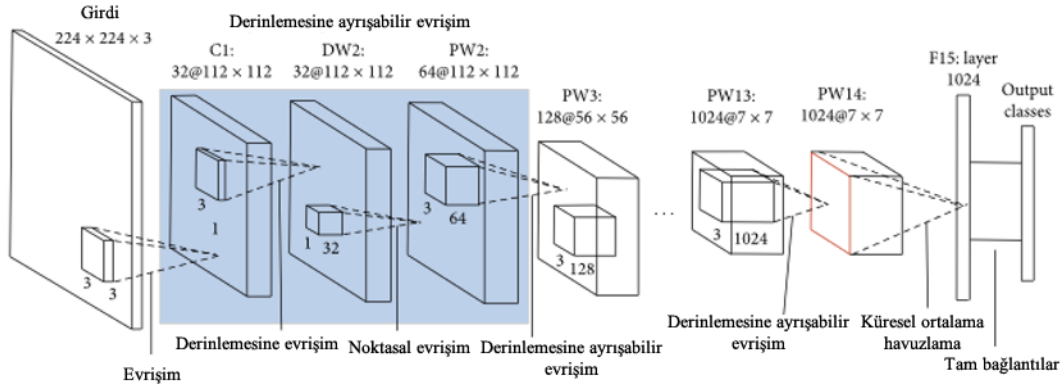
He, Zhang, Ren ve Sun (2016) tarafından geliştirilen ResNet mimarisi, ILSVRC-2015 yarışmasında %3,57'lik top-5 hata oranı ile birinci dereceyi elde etmiştir. Bu başarısıyla derin öğrenme alanında dikkatleri toplamayı başarmıştır. Temelde ResNet, yüzlerce hatta binlerce katmanın eğitilmesini performans kaybı yaşamadan mümkün kılabilir. ResNet, derin öğrenme alanında karşılaşılan başlıca iki probleme (kayıp gradyan ve parametre iyileştirme) çözüm getirmiştir. ResNet artan derinliğe rağmen artık bağlantılar kullanarak bu iki problemi aşmış yüksek bir sınıflandırma performansı elde etmiştir. ResNet mimarisinin şematik bir görünümü Şekil 4.8 üzerinde gösterilmiştir.



**Şekil 4.8** ResNet mimarisinin şematik görünümü (Rousseau, Drumetz ve Fablet, 2020)

#### 4.8.5. MobileNet

Howard vd. (2017) tarafından geliştirilen MobileNet mimarisi, derinlemesine ayrışabilir evrişim (depthwise separable convolution) işleviyle ön plana çıkmaktadır. Derinlemesine ayrışabilir evrişim işlemi filtreleme için ayrı bir katman, birleştirmek için ayrı bir katman olmak üzere iki aşamadan oluşmaktadır. İlk aşamada her bir girdi kanalına özel tek bir filtre uygulanır. İkinci aşamada elde edilen sonuçlara  $1 \times 1$ 'lik noktasal evrişim işlemi uygulanarak sonuçlar bir araya getirilir. Bu yöntem ile derinlik sağlanmasının yanı sıra hesaplama maliyeti azalmaktadır. MobileNet derinlemesine ve noktasal evrişim katmanları dahil olmak üzere 28 katmandan oluşmaktadır. Her bir derinlemesine ayrılabilir evrişim katmanından sonra yığın normalleştirme ve ReLU kullanılmaktadır. MobileNet mimarisinin bir temsili Şekil 4.9 üzerinde gösterilmiştir.




Şekil 4.9 MobileNet mimarisi (Pujara, 2020)

#### 4.8.6. Xception

Chollet (2017) tarafından modellenen Xception mimarisi, Inception mimarisinden ilham alınarak oluşturulan derinlemesine evrişim katmanlarından meydana gelmektedir. Orijinal derinlemesine evrişim yönteminde noktasal evrişim katmanı derinlemesine evrişim katmanından sonra gelirken; Xception modelinde ise noktasal evrişim katmanı derinlemesine evrişim katmanından önce kullanılmaktadır. Bu yeniliği ile Xception mimarisi, Inception-V3'ten daha iyi bir başarı ortaya koymuştur. Xception'ın Inception-V3 ile aynı parametrelere sahip olması da Xception'ın parametreleri daha verimli kullandığını göstermektedir.

Xception toplamda 36 evrişim katmanı ile 14 modülden oluşmaktadır. Modüller arasında doğrusal artık bağlantılara yer verilmiştir. Evrişim katmanlarının sonunda küresel ortalama havuz katmanı kullanılmıştır. Şekil 4.10 üzerinde Xception mimarisinin şematik gösterimi sunulmuştur.





**Şekil 4.10** Xception mimarisinin şematik gösterimi (Mahdianpari, Salehi, Rezaee, Mohammadimanesh ve Zhang, 2018)



## 5. İLGİLİ ÇALIŞMALAR

Buğdayda *Puccinia striiformis f. sp. Tritici* patojeninin neden olduğu sarı pas hastalığı, yüksek tahribat özelliği nedeniyle dünya çapında buğday üretiminde önemli kayıplara neden olmaktadır (Wellings, 2011; Pardey vd., 2013). Hastalık dünya çapında 60'tan fazla ülkede etkisini göstermiştir (Wellings, 201). Türkiye de buğday üretiminde sarı pas hastalığından mustarıptir (Düşünceli vd., 1996; Chen, 2020). Özellikle Orta Anadolu'da meydana gelen salgın, 2010 yılında tahminen 10 milyon ABD doları değerinde mahsul zararına neden olmuştur (Chen, 2020). Hastalık sadece verimi değil aynı zamanda buğdayın kalitesini de sınırlamaktadır. Bu nedenle buğdayda sarı pas hastalığının gelişiminin tarla koşullarında güvenilir yöntemlerle izlenmesi ve kontrol altında tutulması; ek olarak bu alanda yapılan çalışmaların artırılması ve teşvik edilmesi, ekonomik kayıpların en aza indirilmesi bakımından kritik bir öneme sahiptir.

Bu tez çalışması, buğdayda sarı pas hastalığının izlenmesi ve kontrol altında tutulması için tasarlanabilecek uzaktan algılama ve tanımlama sistemleri için çeşitli ML yaklaşımlarını ve DL yaklaşımlarını tartışmaktadır. Çalışmada kullanılan yöntemler çerçevesinde ilgili metotlara ilişkin literatür çalışmaları bu bölümde sunulmuştur. Tez çalışması kapsamında tarım sektöründe sarı pas gibi yaprak hastalıkları başta olmak üzere benzer alanda yapılmış; geleneksel ML yaklaşımlarından yapısal ve hibrit öznitelik çıkarımı; bununla birlikte DL yaklaşımlarının uygulandığı çalışmalar incelenmiştir.

### 5.1. Yapısal ve Hibrit Özelliklere Dayalı Çalışmalar

Sarı pas hastalığı buğday yapraklarında farklı enfeksiyon türleri ile kendini gösterir. Hastalık buğday yaprak dokusunda deformasyona neden olur ve bu deformasyon hastalığın enfeksiyon derecesini ortaya çıkarır (Roelfs vd., 1992). Normal şartlarda pas şiddetinin belirlenmesi, saha koşullarında uzmanlar tarafından gözle incelemeler yoluyla belirli standartlara göre gerçekleştirilir. Bu işlem yoğun emek ve zaman gerektiren bir süreçtir. Saha koşullarında hastalığa ilişkin şiddet seviyesinin doğru tespit edilememesi, buğday üretiminde sonraki süreçler için sorun oluşturabilmektedir. Buğday yapraklarında sarı pasın neden olduğu fiziksel deformasyonlar yaprak rengi, dokusu ve morfolojisidir (Lu vd., 2018). Yani buğday yapraklarının yapısal özellikleri sarı pas hastalığı hakkında gerekli bilgiyi verebilmektedir.

İki boyutlu görüntüler üzerinde doku analizi yapılarak özellik çıkarımı en çok başvurulan yöntemlerden birisidir (Aksoy ve Haralick, 2000). Yüzeylerin doku özellikleri, yapısal durum ve özelliklerin birbirleriyle olan ilişkileri hakkında bilgiler içerir (Haralick, 1979).

Gri Seviye Eş-Oluşum Matrisi (GLCM), doku analizi ve makine öğrenimi alanlarında farklı görüntü dokuları ve formları üzerinde istatistiksel hesaplamalar yapmak için tasarlanmış popüler bir hesaplama yöntemidir (Haralick, 1979). GLCM, bir görüntü için farklı yoğunluk değerlerinin kombinasyonlarının istatistiksel dağılımlarını kullanarak hesaplamalar yapar (Vardhan, 2014). GLCM, doku analizi için popüler bir istatistiksel yöntem olmasına rağmen temel versiyonu yalnızca gri tonlamalı görüntülerden bilgi yakalayabilir (Hossain ve Parekh, 2010). Bu nedenle başlangıçta doku analizi alanında genellikle sadece gri tonlamalı görüntüler kullanılırken; daha sonraları piksel değerlerinde gizli renk verileriyle ve farklı renk uzaylarıyla renkli görüntüler araştırmacıların ilgisini çekmiştir (Choi, 2011). Bu tez çalışmasında yaprak görüntülerinin doku analizi, renk özellikleri kullanılarak gerçekleştirilmiştir. Kullanılan özellik çıkarım yöntemi GLCM, görüntülerin renk özellik verileri hesaba katılarak kullanılmıştır. Literatürde renkli görüntüler kullanılarak yapılan doku analizi çalışmalarında, geleneksel yöntemlerin renk özellikleri ile birlikte kullanılması başarılı sonuçlar alınmasını sağlamıştır.

Bu çalışmalar arasında Mei ve Androustos (2008) tarafından yapılan çalışmada, renkli görüntüler kullanılarak Dalgacık Dönüşümüne (Wavelet Transform) dayalı bir doku analizi metodu önerilmiştir. Deneysel sonuçlar, kullanılan yöntemin renk uzaylarını dikkate almayan geleneksel yöntemlerden daha başarılı olduğunu göstermiştir. Hossain ve Parekh (2010) tarafından doku analizini geliştirmek için sisteme renkli doku görüntülerinin renk bilgisinin dahil edilip edilmemesinin gerekliliği incelenmiştir. Sonuçlar renk bilgileri dahil edilerek kullanılan GLCM yönteminin standart GLCM'ye göre daha iyi doğruluk sağladığını göstermiştir.

Choi vd. (2011), yüz tanıma için Renk Tabanlı Yerel Gabor Dalgacıkları (CLGW: Color-based Local Gabor Wavelet) ve Renk Tabanlı Yerel İkili Desenler (CLBP: Color-based Local Binary Patterns) modellerini önermişlerdir. Deneysel sonuçlar, renk tabanlı yerel doku özelliklerini kullanan yaklaşımların, standart ve sadece renk özelliklerini kullanan yaklaşımlara göre daha başarılı olduğunu göstermiştir. Başka bir çalışmada Gui vd. (2013), Renkli Eş-Oluşum Matrisine dayalı doku öznelik çıkarma

yönteminin geleneksel GLCM yöntemine göre daha başarılı olduğunu göstermişlerdir. Renkli doku özellik çıkarımı için HSI ve RGB renk uzayları kullanılmıştır. Benco vd. (2014), renk ve geleneksel doku analizinin birleşimi olan tanımlayıcı bir sistem oluşturmayı amaçlamışlardır. Deneylerinde RGB ve HSV renk uzayları için GLCM (CLCM-rgb ve CLCM-hsv) ve Gabor Filtre (GF-rgb ve GF-hsv) yöntemlerini uygulamışlardır. Elde ettikleri sonuçlar, CLCM-rgb ve CLCM-hsv yöntemlerinin doku sınıflandırması için başarılı yöntemler olduğunu göstermiştir. Fekriershad ve Tajeripour (2017), renk verilerini ve doku özelliklerini bir araya getiren bir doku sınıflandırma yaklaşımı önermişlerdir. Önerilen yöntem Hibrit Renk Tabanlı Yerel İkili Desenler adı verdikleri çalışma, yöntemin renk ve doku özelliklerini birlikte çıkarmak için kullanılabileceğini göstermiştir.

Yapılan çalışmalar yapısal öznitelik sınıflandırma görevi için renk özellikleri dikkate alındığında ortaya çıkan sonuçların daha başarılı olduğunu göstermektedir. Renk özelliklerinin veya doku özelliklerinin tek başına yeterli olmadığı; bir arada dikkate alındığında daha iyi doğruluk elde edileceği görülmüştür.

Diğer yandan, Evrimsel Sinir Ağları (CNN), öznitelik çıkarımı ile sınıflandırma işlevlerini bir araya getiren popüler bir Derin Öğrenme (DL) yaklaşımıdır (Krizhevsky vd., 2017) ve bu açıdan RF ve ANN gibi geleneksel ML algoritmalarından farklı bir konumda yer almaktadır. CNN, güçlü bir öznitelik çıkarıcı ve sınıflandırıcıdır, ancak bazı görevler için yalnızca öznitelik çıkarıcı özelliğinin kullanılması daha iyi sonuç verebilmektedir.

Son yıllarda farklı sınıflandırma görevleri için doku ve derin özelliklerin birleşimine dayalı hibrit özelliklerin standart yöntemlere göre daha başarılı olduğunu ortaya koyan araştırmalar bulunmaktadır. Örneğin, Jia ve Meng (2017), kablosuz kapsül endoskopi kanama tespiti için yapısal ve CNN özellikleri bir araya getiren bir yaklaşım önermişlerdir. Çalışmada, önerilen yöntemin eğitim verileri sınırlı olsa bile oldukça verimli olduğu ve modern yaklaşımlara göre benzer veya daha iyi sonuçlar ortaya koyduğu vurgulanmıştır. Zhang, Xia, Xie, Fulham ve Feng (2017), önceden eğitilmiş ve ince ayarlanmış üç derin CNN ve iki yapısal tanımlayıcı tarafından öğrenilen özellikleri bir araya getirerek kullanan hibrit bir yaklaşım önermişlerdir. Deneysel sonuçlar, hibrit yöntemin belirli tıbbi görüntü sınıflandırma problemleri için doğruluğu iyileştirdiğini göstermiştir. Wei vd. (2019), derin ve el yapımı öznitelikleri birleştirerek hibrit bir öznitelik tanımlayıcı önermişlerdir. Çalışmada verilerin

eđitilmesi için SVM tabanlı bir sınıflandırma modeli kullanılmıştır. Elde edilen sonuçlar, önerilen yöntemin en gelişmiş tahmin edicilerden bile daha iyi performans sergilediđini ortaya koymaktadır. Aynı yılda gerekleşen bir diđer alıřmada Ali, Hardie, De Silva ve Kedebe (2019), cilt lezyonu analizi için yapısal ve derin özelliklerden gelen bilgileri birleřtiren bir yöntem kullanmışlardır. Elde edilen birleřtirilmiş özellikler, ok sınıflı bir SVM tabanlı sınıflandırıcı modeline girdi olarak kullanılmıştır. evrimii veri tabanları kullanılarak dođrulama yapılan yöntemin hesaplama aısından verimli olduđu bildirilmiştir. Hasan, Jalab, Meziane, Kahtan ve Al-Ahmad (2019), doku ve derin özellikleri kullanan bir sistem önermişlerdir. alıřmada kullanılan doku özellikleri modifiyeli GLCM kullanılarak elde edilmiştir. Deneysel sonuçlar, önerilen hibrit yaklaşımın standart metotlara göre dođruluđu artırdıđını göstermiştir. Nanni, De Luca, Facin ve Maguolo (2020), önceden eđitilmiş derin sinir ađı ve yapısal özellikleri bir arada kullanarak virüs görüntülerinin sınıflandırılması için bir model sunmuşlardır. alıřmada hibrit özelliklerin eđitimi için SVM kullanılmıştır. Yapısal özelliklerin elde edilmesi için tek bir modele bađlı kalınmadan eřitli doku analizi yöntemleri kullanılmıştır. Performans testleri, birleřtirilmiş özelliklere dayalı yöntemin standart yöntemlere göre dođruluđu artırdıđını göstermiştir. Luz, Oliveira, Araujo ve Magalhães (2021), hibrit özellikleri kentsel ses sınıflandırma görevi için kullanmışlardır. alıřmada derin özellik ıkarımı için CNN kullanılmıştır. İki ayrı veri setinin yanı sıra; özelliklerin sınıflandırılması için iki ayrı sınıflandırıcı (RF ve SVM) kullanılmıştır. Sonuçta her iki sınıflandırıcı için hibrit yöntem, yapısal özelliklere dayalı yöntemlere göre daha iyi performans elde etmiştir. Diđer yandan Zhang, Pogorelsky, Loveland ve Wolf (2021), yaygın görülen bir zatürre ve Covid-19 hastalarını sınıflandırmak için X-Ray görüntülerini kullanarak yapısal ve derin CNN özelliklerin birleřimine dayalı bir yöntem önermişlerdir. Önerilen yaklaşımın performansı, standart bir CNN ve doku özellikleri ile ayrı ayrı eđitilmiş sistemlerin performansı ile karřılařtırılmıştır. Buna göre, hibrit özelliklerin sınıflandırma dođruluđunu iyileřtirdiđi bildirilmiştir. Son dönemde yapılan bir diđer alıřmada Naz vd. (2021), kablosuz kapsül endoskopi görüntülerini kullanarak gastrointestinal hastalıkların otomatik tespit edilebilmesi için doku ve derin özelliklere dayalı hibrit bir yöntem önermişlerdir. alıřmada SFTA ve LBP kullanılarak doku öznitelikleri ıkarılmıştır. Bununla birlikte önceden eđitilmiş VGG-16 ve Inception-V3 CNN modelleri kullanılarak derin özellikler elde edilmiştir. ıkarılan özelliklerin

birleşimine dayalı tasarlanan hibrit yaklaşımın sonuçlarının umut verici olduğu belirtilmiştir.

Bu çalışmalar yapısal ve derin özellikleri bir araya getiren başarılı sınıflandırma çalışmalarından oluşmaktadır. Çalışmalarda gerçekleştirilen performans testleri, birleştirilmiş yöntemlerin doğrulama başarısını artırdığını kanıtlamaktadır. Bu nedenle bu tez çalışmasının yapısal analiz tarafında, sarı pas hastalığının enfeksiyon derecesini sınıflandırmak için yapısal ve derin özelliklerin birleşimine dayalı sınıflandırma modellerinin etkisi araştırılmaktadır.

## 5.2. Derin Öğrenmeye Dayalı Çalışmalar

Yapay zekâ alanındaki son gelişmeler, sayısal görüntüleri kullanarak nesnelere yapısal kusurların tespitine olanak sağlayan teknikler sunmaktadır. CNN, görüntülerden hem otomatik öznitelik çıkarımı yapabilmeye hem de görüntüleri sınıflandırabilme yeteneğinden dolayı bu yöntemler arasında lider bir konumdadır. CNN, özellikle görüntüleri, metinleri, sesleri ve videoları sınıflandırmada popüler (Krizhevsky vd., 2017) bir DL yöntemidir. CNN'nin en güçlü yönlerinden biri, veri kümesindeki görüntülerden veriye bağlı uygun özellikleri otomatik olarak çıkarabilmesidir. Literatürde tıp, finans, ekonomi gibi alanların yanı sıra tarım sektöründe de (Hayit vd., 2021) CNN'ye dayalı çalışmalar yer almaktadır. Bu çalışmaların çoğu, bir insan gibi, verilerden ayırt edici özellikleri otomatik olarak öğrenebilen, karmaşık ilişkileri çıkarabilen ve karar verebilen CNN'lere dayanmaktadır. Bu çalışmalardan bazıları bu bölümde sunulmuştur.

Hussain, Ahmad ve Mughal (2018), üç adet buğday hastalığı ile sağlıklı buğday yapraklarını sınıflandırmak için CNN tabanlı bir model önermişlerdir. Model olarak AlexNet tercih edilen çalışmada %84,54'lük bir doğruluk elde edilmiştir. Lin vd. (2019), yedi adet buğday hastalığı ile sağlıklı buğday yapraklarının bulunduğu sekiz sınıflı bir veri seti kullanarak sınıflandırma yapabilen bir CNN modeli önermişlerdir. Çalışmada önerilen matris tabanlı evrimsel sinir ağı modeli %96,5'lik bir ortalama doğruluk ve %90,1'lik bir test doğruluğu elde etmiştir. Buğday hastalıkları üzerine yapılan bir başka çalışmada Mosisa (2019), buğdayda sarı pas, kara pas ve yaprak pası hastalıklarının sınıflandırılması için kendi tasarımı olan CNN tabanlı MosNet'i önermiştir. Çalışmada önerilen model %86,62'lik bir başarı elde etmiştir. Son

dönemlerde yapılan çalışmalar incelendiğinde Genaev, Ekaterina ve Afonnikov (2020) tarafından yapılan çalışmada sağlıklı buğday yaprakları, yaprak pası ve kara pas görüntüleri olmak üzere üç sınıf içeren toplam 876 görüntünün yer aldığı veri seti kullanılarak bir CNN modeli geliştirilmiştir. Çalışmada tasarlanan modelin başarılı bir sınıflandırma gerçekleştirildiği belirtilmiştir. Dong, Mu, Shi, Mu ve Sun (2020), Lin vd. (2019) tarafından yapılan çalışmada da kullanılan sekiz sınıflı veri setini kullanarak CNN tabanlı bir model geliştirmişlerdir. Çalışmada CNN ve SVM birleşik modeli ile %95,32'lik bir başarı elde edilirken; SVM yerine softmax kullanıldığında başarının %96,09'a ulaştığı belirtilmiştir. Sood ve Singh (2020) tarafından yapılan çalışmada sağlıklı buğday yaprakları, yaprak pası ve kara pas görüntüleri olmak üzere üç sınıf içeren bir CNN sınıflandırma modeli önerilmiştir. ResNet-50 ve VGG-16 mimarilerinin kullanıldığı çalışmada %99,07 doğruluk oranı ile VGG-16 modeli başarılı bir sonuç elde etmiştir.

Literatürde buğday dışında farklı mahsuller için yapılan çalışmalar da yer almaktadır. Örneğin, Grinblat, Uzal, Larese ve Granitto (2016), daha önce yaptıkları klasik sınıflandırma çalışmasından (Larese vd., 2014) farklı olarak, soya, kırmızı ve beyaz fasulye olmak üzere üç farklı fasulye türünü CNN ile sınıflandırarak önceki çalışmalarına göre %96,9 bir doğrulukla daha iyi sonuç elde etmişlerdir. Tavakoli, Alirezazadeh, Hedayatipour, Nasib ve Landwehr (2021), farklı fasülye çeşitlerinin yaprak görüntülerini sınıflandırmak için CNN tabanlı bir model önermişlerdir. Yaprakların hem ön hem arka görüntülerini içeren veri setinin kullanıldığı çalışma; türlerin sınıflandırılması, çeşitlerin tür içinde sınıflandırılması ve çeşitlerin farklı türler içerisinde sınıflandırılması olmak üzere üç aşamada gerçekleştirilmiştir. Çalışmada elde edilen ortalama doğruluk oranları sırasıyla, %95,86, %91,37 ve %86,87 olarak hesaplanmıştır. Mısır yapraklarında görülen bir hastalığın tanınması ve sınıflandırılması üzerine yapılan bir çalışmada, Zhang, Qiao, Meng, Fan ve Zhang (2018) GoogLeNet ve Cifar10 modellerini önermişlerdir. 8 çeşit mısır hastalığının sınıflandırılması denemelerinde GoogLeNet modeli %98,9, Cifar10 modeli ise %98,8 doğruluk oranı göstermiştir. Mısır yaprağı hastalığının teşhisine yönelik başka bir çalışmada Waheed vd. (2020) %98.06 doğrulukla DenseNet tabanlı bir CNN yaklaşımı önermişlerdir. Shrivastava, Pradhan, Minz ve Thakur (2019), dört farklı pirinç yaprağı hastalığını sınıflandırmak için CNN ve SVM modellerinin kombinasyonunu içeren bir model önermişlerdir. Özellik çıkarımı için AlexNet tabanlı

CNN modelinin kullanıldığı çalışmada %91,37'lik bir doğruluk elde edilmiştir. Barman, Choudhury, Sahu ve Barman (2020) tarafından yapılan çalışmada bir narenciye türüne ait yaprak hastalığını sınıflandırmak için iki farklı CNN modeli (MobileNet ve Öz-Yapılandırılmış) kullanılmıştır. Çalışmada %99 sınıflandırma başarısı ile Öz-Yapılandırılmış model önerilmiştir. Tang, Yang, Li ve Qi (2020), üzüm yaprağının sınıflandırılması için %99,14 doğrulukla AlexNet tabanlı bir CNN modeli önermişlerdir. Bunların dışında Agarwal, Singh, Arjaria, Sinha ve Gupta (2020) tarafından yapılan çalışmada domates hastalıklarının sınıflandırılması için VGG16, Inception V3 ve MobileNet ağları kullanılarak geliştirilen karma bir CNN modeli önerilmiştir. Önerilen modelin 9 hastalıklı ve 1 sağlıklı sınıf için ortalama doğruluğu %91,2 olarak bildirilmiştir.

Bu çalışmaların haricinde çeşitli bitki türleri kullanılarak yaprak hastalıklarını teşhis etmek ve tanımak için yapılan çalışmalar da mevcuttur. Örneğin bir çalışmada (Ferentinos, 2018), 25 farklı bitki türü üzerindeki hastalıkları teşhis etmek için bir CNN modeli önerilmiştir. Toplamda 87.848 adet yaprak görüntüsünün kullanıldığı çalışmada önerilen model %99,53 ortalama doğruluk elde etmiştir. Deeba ve Amutha (2020), beş önemli sebze türü (patates, domates, mısır, patlıcan ve biber) için CNN'ye dayalı bir hastalık tahmin ve sınıflandırma sistemi önermişlerdir. Veri seti ile farklı ağların (LeNet, AlexNet, VGG16, VGG19 ve ResNet) test edildiği çalışmada genel performansın %98 doğrulukla hesaplandığı bildirilmiştir.

Yapılan çalışmalar buğday başta olmak üzere fasulye, mısır, üzüm gibi farklı bitki türlerinin yer aldığı veri setleri ile geliştirilen çeşitli CNN modellerinin sınıflandırmada elde ettiği başarıları ortaya koymaktadır. Bu sonuçlar, tez çalışmasında ulaşılmak istenen hedef için CNN metodunun neden tercih edildiğini göstermektedir.



## 6. MATERYAL VE METOT

Buğdayda sarı pas hastalığının doğru bir şekilde değerlendirmesi amacıyla oluşturulmak istenen karar destek sistemi için, kullanılan materyallerin ve uygulanan metotların sunumundan önce çalışmanın tarladan makineye nasıl evrildiğinin hikayesini kısaca özetleyerek anlatmak uygun olacaktır.

Sonuçlarıyla gerçekte ülkemiz için fayda sağlaması beklenen böyle bir sistem için kullanılacak veri setinin özel koşullarda üretilmiş olmayıp doğal şartlarında üretilmiş olması dikkate alınmıştır. Bu bakımdan Türkiye’de bu alanda yapılan çalışmalarda başı çeken kurumlarla iş birliği halinde çalışılmış ve danışıklı bir şekilde profesyonel olarak hareket edilmiştir.

Çalışmada elde edilen veri seti için, yaprak çalışmalarında başarısı kanıtlanmış geleneksel doku analiz yöntemlerinin araştırılmasının yanı sıra insan beyninin çalışma şekline ilham alan modern metotların uygulanabilirliği de araştırılmıştır. Doku analiz yöntemlerinde öne çıkan özellik çıkarımı için hem geleneksel yöntemler denenmiş hem de modern özellik çıkarım yöntemleri ile geleneksel yöntemlerin harmanlandığı yeni teknikler tartışılmıştır. Özellikle görüntüler üzerinde özellik çıkarımı ve sınıflama yeteneği ile lider bir konumda bulunan CNN modeli, farklı ağlar test edilerek uygulanmış ve sonuçta yüksek bir başarı ile Yellow-Rust-Xception modeli oluşturulmuştur. Elde edilen modeller arazi koşullarında uygun altyapı ve donanım desteği sağlanarak kullanılabilir bir yapıda tasarlanmıştır.

Materyal ve Metot bölümünde tez çalışmasında kullanılan ham ve Yellow-Rust-19 veri setinin oluşturulması, görüntü ön işleme çalışmaları, önerilen hibrit doku analiz yöntemi ile önerilen derin öğrenme modeli detaylı bir şekilde anlatılmıştır.

### 6.1. Kullanılan Araçlar ve Yazılımlar

Tez çalışmasında görüntü işleme çalışmaları, veri artırımı tekniği ve önerilen derin öğrenme modeli python programlama dili kullanılarak kodlanmıştır. CNN modelinin oluşturulmasında Tensorflow kütüphanesini içeren Keras DL kütüphanesi kullanılmıştır. Diğer yandan çalışmada gerçekleştirilen tüm doku analizleri MATLAB yazılımı kullanılarak gerçekleştirilmiştir. Tüm kodlamalar Windows 10 işletim sistemi bulunan istasyon üzerinde gerçekleştirilmiştir.

CNN modellerindeki derin sinir ağlarının eğitilmesinde güçlü altyapıya sahip bilgisayarların kullanılması, hesaplama zamanı açısından avantaj sağlamaktadır. DL modelleri için özellikle işlemci dışında ekstra bir ekran kartının kullanılması, haftalar alabilecek bir işlemi saatlerle sınırlayabilmektedir. Bu bağlamda önerilen modelin oluşturulmasındaki tüm süreçler Xenon işlemcili, 32GB RAM, 512 GB SDD ve Nvidia GTX 1080 Ti ekran kartına sahip bir iş istasyonu kullanılarak tamamlanmıştır.

## **6.2. Veri Setinin Oluşturulması**

Buğdayda sarı pas hastalığının tarla koşullarında ciddiyet seviyesinin doğru bir şekilde belirlenebilmesi için, tasarlanması planlanan modele girdi olarak sunulan veri setinin uygun bir şekilde oluşturulması çok önemlidir. Başka bir deyişle, yeterince büyük bir veri setine sahip olmak yeterli değildir; aynı zamanda veri seti çeşitlilik açısından zengin olmalı ve yüksek kaliteli görüntüler içermelidir. Çalışmada eşsiz olarak oluşturulan ve “Yellow-Rust-19” olarak adlandırılan veri seti, ekim çalışmaları, inokulasyon ve inkubasyon, görsel materyalin elde edilmesi, görüntü işleme çalışmaları, etiketleme ve veri artırımı gibi bir dizi ardışık işlemler kullanılarak sıfırdan oluşturulmuştur.

### **6.2.1. Ekim Çalışmaları**

Tez çalışmasında kullanılan veri seti için çalışılan ekili alan, T.C. Tarım ve Orman Bakanlığı Tarla Bitkileri Merkez Araştırma Enstitüsü’ne ait olup; buğdayda sarı pas başta olmak üzere tahıllarda görülen bazı önemli fungal hastalıklar için özellikle ayrılmıştır. Kullanılan ekili alana ait görüntüler Şekil 6.1 üzerinde gösterilmiştir.



**Şekil 6.1** Ekili alandan görüntüler

Bölge Türkiye’de Ankara/Haymana/İkizce yakınlığında yer almaktadır (Şekil 6.2).



**Şekil 6.2** Çalışma bölgesinin haritada gösterimi

Tez çalışmasında kullanılan buğdayların ekim çalışmaları arazi koşullarında Ekim-Kasım 2018 tarihleri arasında tamamlanmıştır. Buğdaylar 20 ila 30 cm aralıklarla ve 1-2 m uzunluğunda şeritler halinde ekilmiştir. Her on sıra buğday ekiminden sonra tek sıra sarı pas hastalığına karşı hassas “Little Club” çeşidi ekilmiştir. Ekili alan çalışma

boyunca nem ve sıcaklık bakımından takip edilerek sulama uygulanmış ve sıklıkla yabancı otlardan temizlenmiştir.


### **6.2.2. İnokulasyon ve İnkubasyon**

Belirli bir büyüme aşamasına gelen buğday bitkilerine doğru zamanda ve doğru iklim koşullarında sarı pas hastalığının inokule edilmesi gerekmektedir. Bu nedenle sera koşullarında sarı pas hastalığının spor üretiminin yapılması ile denemeler başlatılmıştır. Arazide sonradan tek sıraya dikilecek olan Little Club çeşidi 7×7×9 cm boyutlarındaki saksılara 7-9 adet tohum olacak şekilde ekilmiştir. Tohumlar sarı pasın inokulasyon sürecine kadar 15-20 °C'de serada büyütülmüştür. İlk yaprak tamamen ortaya çıktıktan ve ikinci yaprak koleoptil evresinden geçtikten sonra (Zadoks GS11 büyüme aşaması (Zadoks, Chang ve Konzak, 1974)) bitkiler inokule edilmiştir. Bitkileri inokule etmek için taze sarı pas ürediosporları kullanılmıştır. Urediospor süspansiyonu (yaklaşık 250.000 ml-1 yoğunlukta) Soltrol 170 uçucu mineral yağı ile hazırlanmış ve bitkilere inokule edilmiştir. Bitkiler, inokulasyondan sonra enfeksiyonun oluşması için 24 saat boyunca 9-12 °C sıcaklık ve %100 bağıl nem koşullarında inkubasyona bırakılmıştır. Daha sonra inokule edilen bitkiler 15-20 °C sıcaklıkta koşullandırılmış seraya aktarılmış ve 18 saat gün ışığında, 6 saat karanlıkta bekletilmiştir (Hovmoller, 2007). Hastalık inokule edilen bitkiler, belirli aralıklarla sulanmıştır. İnokulasyondan yaklaşık 14-16 gün sonra gelişen taze sporlar tarla koşullarında spreyleme yöntemi kullanılarak bitkilere püskürtülmüş ve sulama işlemi ile hastalık gelişimi teşvik edilmiştir. Tarlada inokulasyon işlemi buğdayın sapa kalkma döneminde başlatılmış olup birkaç kez uygulanmıştır (Micron ULVA+ Pulverisateur kullanılarak bitkileri ıslatacak yeterlikte).

### **6.2.3. Görsel Materyalin Elde Edilmesi**

Görsel materyalin elde edilmesi çalışmaları hastalığın en yoğun görüldüğü buğdayın süt olum döneminde (Murray, Ellison ve Watson, 1995), Haziran 2019 ayında yaklaşık 10 günlük bir süre çerçevesinde tamamlanmıştır.

Hastalıklı ve sağlıklı buğday yaprak yaprakları, Şekil 6.3(a)'da görüldüğü üzere dijital bir fotoğraf makinesi, yatay bir tripod ve çekim kabini içeren özel olarak tasarlanmış bir mekanizma kullanılarak tarla koşullarında fotoğraflanmıştır.



**Şekil 6.3** Fotoğraflama mekanizması: dijital fotoğraf makinesi, yatay tripod ve çekim kabini (a), dörderli ve beşerli gruplar halinde çekilen ham yaprak görüntüleri (b)

Yapraklar belirli aralıklarla ve dörderli ve beşerli gruplar halinde, bitkilerden koparılarak nem muhafazası için özel zarflara koyulmuştur. Çok vakit kaybetmeden (iklim şartları nedeniyle nem kaybı çok hızlıydı ve nem kaybı yaprağın deformasyonuna neden oluyordu) bu yapraklar metal plakalar ile siyah bir zemine sabitlenmiştir. Daha sonra dijital bir fotoğraf makinesi kullanılarak her grup fotoğraflanmıştır. Fotoğraflanmış örnek bir görüntü Şekil 6.3(b) üzerinde gösterilmiştir. Bu işlem 10 gün boyunca yaklaşık 1250 kere tekrar edilmiştir. Fotoğraflama sırasında hava, ışık ve sıcaklık gibi çevresel koşullar dikkate alınmıştır.

#### **6.2.4. Görüntü Ön İşleme Çalışmaları**

Görüntü ön işleme, sayısal bir görüntüdeki istenmeyen bozulmaları gidermek ve daha sonraki işlemler için gerekli olan görüntü özneteliklerini geliştirmek ve ortaya çıkarmak için ham görüntüler üzerinde yapılan bir dizi işlemi açıklamaktadır (Vinoth vd., 2018; Kumar, 2020). Bu çalışmada elde edilen ham yaprak görüntüleri sağlam bir model oluşturmak için görüntü ön işleme adımlarından geçirilmiştir. Kullanılan ön işleme adımları manuel ve otomatik olmak üzere iki aşamalıdır. Manuel aşamada dörderli ve beşerli gruplar halinde fotoğraflanan yaprak görüntüleri Adobe Fireworks yazılımı kullanılarak kırılmış ve jpg formatında kaydedilerek tekil yaprak formları elde edilmiştir. Manuel işlemden sonra toplamda 5421 adet tekil buğday yaprak görüntüsü elde edilmiştir. Örnek bir yaprak görüntüsü Şekil 6.4 üzerinde gösterilmiştir.





**Şekil 6.4** Manuel işlemden sonra elde edilen örnek bir yaprak görüntüsü

Sonraki aşamada elde edilen yaprak görüntülerinin her birine bazı görüntü ön işleme adımları otomatik olarak uygulanmıştır. Bu adımlar sırayla, Eşikleme, Morfolojik Operatörler, Maskeleye ve nihai görüntünün alfa kanallı olarak kaydedilmesidir.

#### **6.2.4.1. Eşikleme**

Otomatik ön işleme çalışmalarının temel amacı arka plan piksellerden kurtulup yaprak formunun ön plana çıkarılması yani bölütleme (segmentasyon) işlemidir. Burada karşılaşılan problemlerden biri arka plan formunun sabit bir renk olmamasıdır. Güneş ışığının pozisyonu, yaprağın altında kalan gölge ve fotoğraflama işlemi boyunca zeminde oluşan deformasyon, arka plan görselinin bölütlenmesi için dezavantaj oluşturmuştur. Bu bağlamda arka plan piksellerinden kurtulmak için geniş bir literatür taraması yapılarak farklı yöntemler denenmiştir.

Eşikleme işlemi en basit bölütleme tekniklerinden biridir. Temelde ayrıştırılmak istenen nesnenin pikselleri ile kalan diğer pikseller arasındaki yoğunluk değişimine dayanmaktadır. İstenilen pikselleri diğerlerinden ayırt etmek için her pikselin yoğunluk değerinin belirli bir eşik değerine göre karşılaştırılması yapılır. Uygun eşik değeri kullanıldığında istenilen nesne ayrılmış olur (Anonim, 2020b). Başlangıçta siyah beyaz resimler kullanılarak (renkli resimler siyah beyaz forma dönüştürülerek analiz edilir) bunların gri seviye dağılımlarını gösteren histogram bilgisinden faydalanılırken sonralarda renk özelliklerinden faydalanılarak oluşturulan eşikleme teknikleri de popüler yöntemler arasına girmiştir. Basit bir eşikleme uygulaması Şekil 6.5 üzerinde gösterilmiştir.




**Şekil 6.5** Basit bir eşikleme işlemi örneği (Anonim, 2020b)

Tez çalışmasında bütünsel (global) eşikleme, çift eşikleme gibi temel eşikleme yöntemleri denenmiş ancak başarılı bir sonuç elde edilememiştir. Bölütleme işleminde yaklaşık 5000 kadar yaprak görüntüsünün tümüne genelleme yapılacak olması önemli bir problem olarak karşımıza çıkmaktadır. Bu noktada, farklı renk uzaylarını kullanarak renk kanallarının piksel değerleri aralığına dayalı eşikleme tekniği devreye girmektedir. Teknik basit bir ifadeyle, görüntünün RGB, HSV,  $L^*a^*b^*$  gibi farklı renk kanalları kullanılarak nesneyi ayırt edici renk piksel değer aralığının tespit edilmesi ve bu sayede istenen piksellerin ayırt edilmesini sağlamaktır.

Çalışmada yaprak görüntüleri kullanılarak RGB, HSV ve  $L^*a^*b^*$  olmak üzere farklı renk uzayları üzerinde denemeler gerçekleştirilmiş olup; arka plan formunu en iyi ayıran renk uzayının  $L^*a^*b^*$  olduğu tespit edilmiştir. Uygun renk uzayının tespit işlemi ve bu uzaydaki her bir renk kanalının sınır eşik değerleri, Adobe Photoshop yazılımı kullanılarak uzun bir çalışma ile, farklı sınıflarda birçok görüntünün farklı piksellerinin incelenmesi neticesinde gerçekleştirilmiştir.

Bölütleme işlemi için uygun renk uzayı belirlendikten sonra RGB formda olan her bir yaprak görüntüsü sırayla  $L^*a^*b^*$  formuna dönüştürülmüştür (Şekil 6.10(b)). Python programlama dili kullanılarak yapılan çalışmada  $L^*a^*b^*$  formdaki yaprak görüntüleri L, a ve b olmak üzere farklı kanallara ayrıştırılmıştır. Burada amaç daha önce belirlenen sınır eşik değerlerine göre işlem gerçekleştirmektir. Bu amaçla her görüntü, uygun L (1-255), a (126-255) ve b (1-133) sınır eşik değerleri doğrultusunda ikili görüntüye dönüştürülmüştür (Şekil 6.10(c)). Şekil 6.6 örnek bir yaprak görüntüsünün L, a, b kanallarının histogram değerlerini göstermektedir. Şekil incelendiğinde L değerinin geniş bir yayılım sergilediği; tüm değerlerin yaklaşık 125-135 sınırları arasında kesiştiği görülmektedir. Alınan sınır değerleri de bu grafiği doğrulamaktadır.



**Şekil 6.6** L, a ve b kanallarının histogram grafiği


Renk kanallarına göre eşikleme işlemi Python programlama dili ile OpenCV kütüphanesinin `inRange` (Anonim, 2020b) fonksiyonu kullanılarak gerçekleştirilmiştir.

#### 6.2.4.2. Morfolojik Operatörler (Genişletme ve Kapatma)

Morfolojik operatörler ya da işlemler, sayısal görüntüleri “çekirdek (kernel)” olarak adlandırılan önceden tanımlanmış yapılandırma öğesine dayalı olarak işleyen bir dizi görüntü işleme tekniğidir. Temelde çıkış görüntüsündeki her pikselin değerinin, giriş görüntüsündeki karşılık gelen pikselin komşularıyla karşılaştırılmasına dayanmaktadır.

Morfolojik işlemler normalde ikili görüntüler üzerinde gerçekleştirilir. Uygulama için iki girdiye ihtiyaç duyulmaktadır: giriş görüntüsü ve işlemin doğasına karar veren yapılandırma elemanı yani çekirdek. Çekirdeğin boyutu ve şekli belirlenerek, girdi görüntüsü ile ilgili belirli amaçlara göre morfolojik işlem gerçekleştirilir. Çekirdek herhangi bir şekilde ve boyutta yapılandırılabilen, yalnızca 0 ve 1’lerden oluşan bir matristir. Tipik olarak işlenmekte olan görüntüden çok daha küçüktür. Çekirdeğin “Orijin” olarak adlandırılan merkez pikseli, ilgilenilen yani işlenmekte olan pikselleri tanımlar (Anonim, 2020c). Örnek bir morfolojik işlemi ve çekirdeğin çalışma şekli Şekil 6.7 üzerinde basitçe gösterilmiştir. Görüldüğü üzere herhangi bir morfolojik işlemde kullanılan çekirdek elemanı, giriş görüntüsünün incelenmesi için dikkat edilmesi gereken en önemli yapıyı oluşturmaktadır.

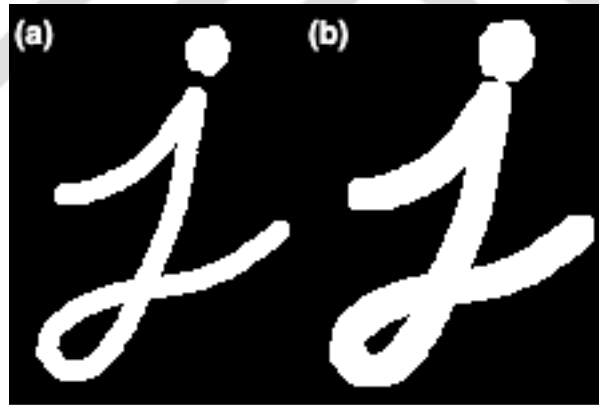




**Şekil 6.7** İkili görüntüye genişletme uygulaması (Anonim, 2020c)


İki temel morfolojik operatör, Aşındırma (Erozyon) ve Genişletmedir (Dilation). Bu işlemlerden sonra Açma, Kapama, Gradyan vb. gibi operatörler kullanılmaktadır.

Genişletme, bir görüntüdeki nesnenin sınırlarına pikseller eklerken, aşındırma işlemi tam tersini yapar. Eklenen veya çıkarılan piksel miktarı, görüntüyü işlemek için kullanılan yapılandırma elemanının boyutuna ve şekline bağlıdır. Her iki işlem de gri tonlamalı ya da ikili görüntülere uygulanabilmektedir (Anonim, 2020c). Şekil 6.8(b) üzerinde ikili bir görüntüye uygulanan genişletme işlemi gösterilmiştir.



**Şekil 6.8** Genişletme işlemi: orijinal görüntü (a), genişletilmiş görüntü (b) (Anonim, 2020c)

Kapatma (Closing) işlemi, basitçe Açma (Opening) işleminin tam tersi olup; aşındırma ya da genişletme aşamalarından sonra kullanılır. Adından da anlaşılacağı gibi, nesnelerin içerisindeki delikleri kapatmak ve pikselleri birbirine bağlamak için kapatma kullanılır. Bir nesne içinde bulunan dahili gürültüyü azaltmaya yardımcı olur (Anonim, 2020d). Bu uygulamalar sayesinde bir sonraki aşama olan maskeleyme işlemi daha sağlıklı bir şekilde gerçekleştirilmektedir. Şekil 6.9(b) üzerinde ikili bir görüntüye uygulanan kapatma işlemi gösterilmiştir.



**Şekil 6.9** Kapatma işlemi: orijinal görüntü (a), kapatılmış görüntü (b) (Anonim, 2020d)

Tez çalışmasında yaprak görüntüleri eşikleme işleminden hemen sonra sınır bölgelerinin temizliği, olası çıkıntılı ve yaprak formundaki gürültülerin engellenmesi için sırasıyla genişletme ve kapatma aşamalarından geçirilmiştir. Bu aşamalarda 3x3 kare şeklinde bir çekirdek kullanılmıştır. Farklı sınıflardan alınan örnek yaprak görüntüleri üzerinde gerçekleştirilen genişletme (d) ve kapatma (e) işlemleri Şekil 6.10 üzerinde gösterilmiştir. İşlemler Python programlama dili ile OpenCV kütüphanesinin morphologyEx (Anonim, 2020c; Anonim, 2020d) fonksiyonu kullanılarak gerçekleştirilmiştir.


#### **6.2.4.3. Maskeleye**

Maskeleye, görüntünün yalnızca amaca yönelik kısımlarına odaklanılmasını sağlamaktadır (Anonim, 2020e). Dhaygude ve Kumbhar'a göre (2013) maskeleye, bir görüntüdeki bazı piksel değerlerinin sıfıra veya başka bir arka plan değerine ayarlanmasını içerir. Maskeleye işleminde temel fikir, görüntüdeki her piksel değerinin bir maske matrisine göre yeniden hesaplanmasıdır. Bahsi geçen maske, orijinal görüntüdeki komşu piksellerin yeni değerinin ne olacağını belirleyecek bir değeri içermektedir.

Maskeleye işlemi tez çalışmasında otomatik bölütleme aşamalarının son adımıdır. Maskeleye işleminde maske matrisi olarak morfolojik işlemlerin son adımı olan kapatma aşamasının çıktısı kullanılmıştır. Bu sayede yaprak formu net bir şekilde çıkarılmıştır. Maskeleye işlemi, Python programlama dili ile OpenCV kütüphanesinin bitwise\_not (Anonim, 2020e) fonksiyonu kullanılarak gerçekleştirilmiştir. Farklı sınıflardan alınan örnek yaprak görüntüleri üzerinde gerçekleştirilen maskeleye işlemi Şekil 6.10(f) üzerinde gösterilmiştir.

#### 6.2.4.4. Son Görüntünün Kaydedilmesi

Maskeleme aşamasından sonra yaprak görüntüleri, yaprak formu dışında kalan kısmı en aza indirmek için yaprak sınırlarına kırılmıştır (Şekil 6.10(g)). Daha sonra kırılan yaprak görüntüleri RGBA (Kırmızı, Yeşil, Mavi ve Alfa kanalı) forma dönüştürülerek kaydedilmiştir. Farklı sınıflardan alınan örnek yaprak görüntüleri üzerinde gerçekleştirilen tüm otomatik ön işleme adımları Şekil 6.10 üzerinde sırasıyla gösterilmiştir.



**Şekil 6.10** Otomatik görüntü ön işleme adımları: orijinal resim (a), L\*a\*b\* renk uzayına dönüştürme (b), eşikleme (c), genişletme (d), kapatma (e), maskeleme (f), kırpma (g), alfa kanallı son görüntünün elde edilmesi (h)

#### 6.2.5. Etiketleme Çalışmaları

Makine öğreniminde veri etiketleme resim, metin dosyaları, videolar gibi ham verileri tanımlamak ya da sınıflandırmak için kurgulanan modelin ilişkilendirerek öğrenebilmesini sağlamak amacıyla bir veya daha fazla sınıfa tanımlayıcı sınıf ismi verme sürecini ifade etmektedir. Örneğin etiketler, bir görüntüdeki nesnenin kedi ya da köpek olup olmadığının bilgisini verebilir. Bilgisayarla görme alanı başta olmak

üzere doğal dil işleme ve konuşma tanıma gibi çeşitli alanlarda model geliştirebilmek için veri etiketleme gereklidir.

Günümüzde çoğu popüler ML modeli, bir girdiyi bir çıktıya eşleştirmek için denetimli öğrenmeyi kullanmaktadır. Denetimli öğrenmenin sağlıklı çalışabilmesi için, modele doğru kararlar verdirebilecek etiketlenmiş bir veri setine ihtiyaç duyulmaktadır. Veri etiketleme, tipik olarak uzmanlardan, etiketlenmemiş belirli bir veri parçası hakkında yargıda bulunmalarını isteyerek başlar. Etiketleme işlemi basit bir evet/hayır şeklinde olabileceği gibi nesnelere ayırt etmek için farklı sınıflar içerecek kadar ayrıntılı da olabilir. ML’de tasarlanan model, eğitim sürecinde uzman tarafından sağlanan etiketleri kullanır. Bu sayede yeni karşılaştığı bir veriyi uygun olan çıktıya eşleyebilir.

Makine öğreniminde, bir modeli eğitmek için kullanılacak veri setinin etiketlenmesi adı üzerinde “uzmanlar” tarafından yapılmalıdır. Veriyi etiketlendirecek kişi ilgili alanda uzman ve yeterli bir insan olmalıdır. Eğitilmiş bir modelin doğruluğu buna bağlıdır. Yüksek düzeyde doğru veri etiketleme işlemi zaman ve maliyet gerektiren bir süreç olabilir.


Çalışmada görüntü ön işleme süreci sonunda oluşturulan veri seti, alanında uzman üç araştırmacı (iki ziraat mühendisi ve bir gıda mühendisi) tarafından etiketlenmiştir. Etiketleme işlemi literatürde belirtilen standartlara göre gerçekleştirilmiştir (Roelfs vd., 1992; Anonim, 2020a).

Sarı pas hastalığı, buğday yaprak dokusu üzerinde farklı enfeksiyon türleriyle kendini göstermektedir (Roelfs vd., 1992). Yaprığın deformasyon derecesi hastalığın enfeksiyon türü hakkında bilgi verir. Literatürde belirtildiği üzere sarı pas hastalığının toplam 5 ana enfeksiyon türü bulunmaktadır. Bunlar, Bağışık (0), Dayanıklı (R: Resistant), Orta Derecede Dayanıklı (MR: Moderately Resistant), Orta Derecede Hassas (MS: Moderately Susceptible) ve Hassas (S: Susceptible) şeklindedir (Roelfs vd., 1992). Enfeksiyon türlerinin açıklamaları Çizelge 6.1 üzerinde verilmiştir.

**Çizelge 6.1** Sarı pas değerlendirilmesinde kullanılan enfeksiyon türleri ve açıklamaları (Roelfs vd., 1992)

Enfeksiyon Türü	Açıklaması
0: Bağışık	Hiç belirti görülmez
R: Dayanıklı	Küçük belirtiler içerir
MR: Orta Derecede Dayanıklı	Küçük ve orta düzeyde belirtiler içerir
MS: Orta Derecede Hassas	Orta düzeyde belirtiler içerir
S: Hassas	Büyük çapta belirtiler içerir

Çalışmada kullanılan veri setine MR ve MS sınıfları arasında değerlendirilen ayrıca bir sınıf daha (MRMS) eklenmiştir. Şekil 6.11, kullanılan veri setinden her bir sınıf için örnek yaprak görüntüleri sunmaktadır.



**Şekil 6.11** Her bir sınıf için örnek yaprak görüntüleri

Görüntü ön işleme ve etiketleme çalışmalarından sonra her sınıf için belirlenen yaprak sayıları Çizelge 6.2 üzerinde sunulmuştur.

**Çizelge 6.2** Görüntü ön işleme ve etiketleme çalışmalarından sonra yaprak sayıları

0	R	MR	MRMS	MS	S	TOPLAM
205	361	564	1135	1795	1361	5421


### 6.2.6. Veri Artırımı

Görüntü ön işleme ile elde edilen veri setinde bulunan görüntü sayısı, aşırı uyum gibi sorunların önlenmesi bakımından yetersizdir. Bu problemin üstesinden gelebilmek için veri seti veri artırımı (data augmentation) olarak bilinen teknik kullanılarak artırılmıştır.

Veri artırımı tekniği, araştırmacılara orijinal veri setini etkilemeden veri çeşitliliğinin ve miktarının önemli ölçüde artırılmasını sağlayan bir avantaj sunmaktadır (Ho, Liang, Chen, Stoica ve Abbeel, 2019). Veri artırımı, büyük sinir ağlarını eğitmek için kırma, döndürme, yakınlaştırma/uzaklaştırma vb. teknikler kullanılarak gerçekleştirilir. Yapılan araştırmalar, veri geliştirme yönteminin modelin eğitilmesinde olumlu

sonular ortaya koyduėunu gstermektedir (Moreno-Barea, Jerez ve Franco, 2020; Tian, Ding, Chen, Luo ve Wang, 2021; Oyelade ve Ezugwu, 2021).

Grnt n iŐleme ile elde edilen veri setinin boyutu dndrme, yatay ve dikey evirme, parlaklık ve kontrast ayarı gibi iyi bilinen veri bytme teknikleri kullanılarak artırılmıŐtır. Veri artırımını ile verilerde eŐitlilik saėlamakla birlikte sınıflarda bulunan grnt sayıları eŐitlenerek sınıflar arası dengesiz veri sorunu da engellenmiŐtir. rnek bir yaprak grntsnn artırılmıŐ versiyonları Őekil 6.12 zerinde gsterilmiŐtir.



**Őekil 6.12** Veri artırımını uygulanmıŐ rnek bir yaprak grnts

Veri artırım iŐlemi sonucunda elde edilen Yellow-Rust-19 veri seti istatistikleri izelge 6.3 zerinde verilmiŐtir.

**izelge 6.3** Yellow-Rust-19 veri seti istatistikleri

0	R	MR	MRMS	MS	S	TOPLAM
2500	2500	2500	2500	2500	2500	15000

## 6.3. Birleştirilmiş (Hibrit) Özelliklere Dayalı Sınıflandırma

### 6.3.1. Derin Özelik Çıkarımı

Evrişimsel Sinir Ağları (CNN), insan beyninden ilham alan ve ayırt edici özellikleri verilerden otomatik olarak öğrenebilen, birbirine bağlı katmanlardan oluşan bir DL metodudur. CNN'ler, bir insan gibi verilerden ayırt edici özellikleri öğrenir ve performansları, göreve özgü problemlerde karmaşık ve doğrusal olmayan ilişkileri sınıflandırmada insanlara benzerdir ve hatta onları geride bırakabilir. CNN, sınıflandırma ve tahmin için kullanılmasının yanında ML sınıflandırıcıları için özellik çıkarıcı olarak da kullanılabilir. Özellik çıkarımında geleneksel yöntemlerin yetersiz olduğu, düşük maliyet ve zaman gerektiren sınıflama problemlerinde CNN özellik çıkarımı için değerlendirilmektedir. Bunların yanında geleneksel sınıflandırıcılara has görevler için eğitim aşamasında daha çok veri gerektiği durumlarda da CNN'den faydalanılabilmektedir.

Evrişimsel Sinir Ağlarının doku analizinde kullanılmasının arkasında yatan motive edici fikir, derin sinir ağlarının doku görüntülerini ayırmak için gereken yüksek seviyeli anahtar özellikleri yakalayabilme yeteneğidir. Derin CNN, ilk evrişim katmanlarından düşük seviye detay özellikleri yakalayabilir ve katmanlar, son katmanlarda yüksek seviyeli özellikleri oluşturmak için yayılım gösterir. Farklı filtreler kullanılarak uygulanan ayırt edici CNN özellikleri, havuzlama işlemiyle üretilir. Buna ek olarak modele önceden eğitilmiş modeller kullanılıyorsa, CNN bu modellerden zengin bir dizi özellik haritası oluşturur. Göreve has yapısal özelliklerin seçimi geleneksel ML yaklaşımları için her zaman zorlu bir süreç olmuştur. Bundan dolayı doku analizinde özellik çıkarımında ince ve hassas yüksek boyutlu özniteliklerin elde edilmesi için CNN kullanmak faydalı olmaktadır.

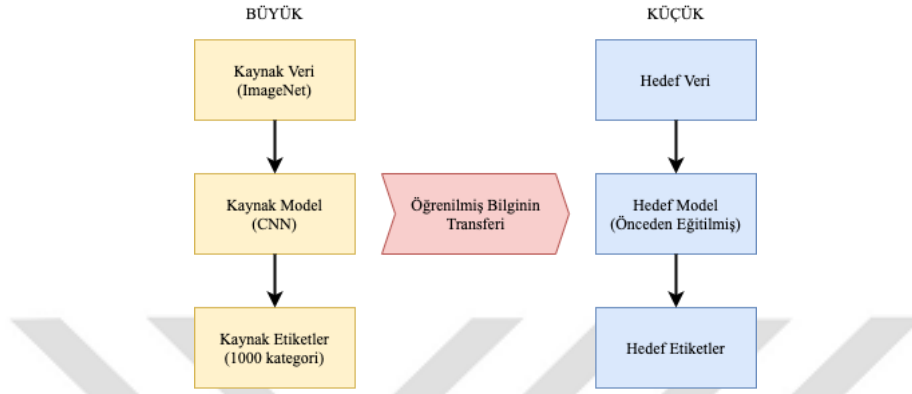
Bir CNN, sıfırdan modellenebilir ve eğitilebilir ancak, bu zorlu bir süreçtir ve sağlam, büyük ölçekli bir veri seti gerektirmektedir. İşte tam bu noktada transfer öğrenme tekniği imdada yetişmektedir.

#### 6.3.1.1. DenseNet ve Transfer Öğrenimi

Bir DL tekniği olarak transfer öğrenimi, belirli bir alandaki bir görev için büyük ölçekli bir veri kümesi üzerinde önceden eğitilmiş mevcut bir modelin, nispeten daha az etiketlenmiş veri setine sahip benzer bir alandaki başka bir görev için başlangıç



aşaması olarak kullanılması durumudur. Sıfırdan eğitilen modellerle karşılaştırıldığında, transfer öğrenme tabanlı modeller daha az eğitim süresine ve daha az veriye ihtiyaç duyar ayrıca daha az maliyet gerektirir (Mohanty, Hughes ve Salathe, 2016). Transfer öğrenme yönteminin çalışma şekli şematik olarak Şekil 6.13 üzerinde gösterilmiştir.



**Şekil 6.13** Transfer öğrenim yönteminin çalışma şekli

Literatürde Resnet (He vd., 2016), MobileNet (Howard vd., 2017) ve Xception (Chollet 2017) gibi önceden eğitilmiş çok sayıda model vardır ve bu modellerin her biri sarı pas hastalığını tanımak ve hastalığın enfeksiyon derecesini belirlemek için kullanışlıdır.

Tez çalışmasının bu aşamasında derin özellik çıkarımı için bir CNN yöntemi olan DenseNet (Dense Convolutional Network) (Huang, Liu, Van Der Maaten ve Weinberger, 2017) kullanılmıştır. DenseNet görsel nesne tanıma problemleri için yeni DL teknolojilerinden biridir. Mimarisi temel olarak ResNet'e benzer ancak bazı farklılıklar bulunmaktadır. ResNet yapısal olarak önceki katmanı gelecek katmanla birleştiren bir toplama yöntemi kullanırken; DenseNet önceki katmanın çıktısını gelecek katmanla birleştirir.


DenseNet'in ILSVRC test sonuçları, yoğun (dense) mimarisinin daha az parametre ile ResNet ile benzer düzeyde performans sergilediğini göstermektedir (Valev, Schumann, Sommer ve Beyerer, 2018). DenseNet'in DenseNet-121, DenseNet-160 ve DenseNet-201 olmak üzere üç farklı versiyonu bulunmaktadır. Versiyonlarda belirtilen sayılar modellerin ağında bulunan katman sayısını ifade etmektedir. DenseNet-160 ve DenseNet-201, 1x1 ve 3x3 katman sayıları dışında DenseNet-121 ile benzerdir. DenseNet-201, sırasıyla Dense Block 3 ve 4'te 48 ve 32 alt blok içerir (Wang ve Zhang, 2020).



Wang ve Zhang (2020) tarafından, önceden eğitilmiş popüler CNN modellerin karşılaştırma sonuçlarına dayanarak DenseNet'in diğer modellere göre daha başarılı olduğu bildirilmiştir. Bununla birlikte aynı çalışmada, sınıflandırma görevi için DenseNet-201 modelinin diğer DenseNet modellerinden daha başarılı olduğunu kanıtlamışlardır. Bu nedenle bu tez çalışmasında önerilen hibrit model için derin öznetelik çıkarma noktasında DenseNet-201 tercih edilmiştir.

DenseNet-201, 201 katman derinliğine sahip ve bir milyondan fazla görüntü içeren ImageNet (Peng, Zhang, Li ve Liu, 2020) veri tabanı kullanılarak önceden eğitilmiş bir CNN modelidir. Görüntüleri 1000 kategoride (örneğin birçok hayvan ve nesne) sınıflandırabilmektedir. DenseNet-201, 224x224x3 görüntü giriş boyutuna sahiptir. İlk 224 değeri genişliği, sonraki 224 değeri yüksekliği ve 3 değeri derinliği (renk kanalları sayısını) ifade eder.

Evrişimsel Sinir Ağlarında ağ, giriş görüntülerinin hiyerarşik bir temsilini oluşturur. Daha derin katmanlar, önceki katmanların alt düzey özellikleri kullanılarak oluşturulan üst düzey özellikleri içermektedir. Çalışmada veri setinin özellik temsilini elde etmek için ağın sonunda bulunan tam bağlantılı katmandan önce gelen küresel ortalama havuzlama katmanı "Global Average Pooling" (GAP) üzerindeki aktivasyonlar kullanılmıştır. GAP, toplamda 1920 özellik sağlamıştır. DenseNet-201'in genel mimarisi Şekil 6.14 üzerinde gösterilmiştir.



**Şekil 6.14** DenseNet-201 mimarisi (Wang ve Zhang, 2020) (GAP katmanı özellikleri sağlamaktadır)

### 6.3.2. Renk-Gri Seviye Eş-Oluşum Matrisi (CGLCM) Özellik Çıkarımı

Haralick 1979 yılında GLCM yöntemini önermiştir (Haralick, 1979). GLCM, istatistiksel doku analizi için güçlü bir yöntemdir (Manjunath ve Ma, 1996; Soh ve Tsatsoulis, 1999; Nikoo vd., 2011) ve ikinci dereceden özelliklerin istatistiksel ölçümleri kullanılarak görüntü sınıflandırması için kullanılmıştır (Pantic vd., 2016).

GLCM öznitelikleri, bir görüntüde belirli bir mesafe ile ayrılmış iki piksel arasındaki özel ilişki kullanılarak hesaplanır (Yogeshwari ve Thailambal, 2021).

Gri Seviye Eş-Oluşum Matrisi yönteminin etkili bir doku tanımlayıcı olduğu belirtilmiş ve diğer doku analiz yöntemlerine göre daha iyi doğruluk değerine ve hesaplama süresine sahip olduğu belirtilmiştir (De Siqueira, Schwartz ve Pedrini, 2013). Ayrıca GLCM'nin farklı renk uzaylarına uygulanabilecek şekilde geliştirilebileceği de belirtilmiştir (Tou, Tay ve Lau, 2009; Selvarajah ve Kodituwakku, 2011; Metre ve Ghorpade, 2013).

Bu çalışmada, her renkli yaprak görüntüsünün farklı renk kanallarına ve gri tonlamalı formuna doku öznelik çıkarımının uygulanması için GLCM yöntemi esas alınmıştır. Uygulanan yöntem "Renk-Gri Seviye Eş-Oluşum Matrisi" (CGLCM: Color-Gray Level Co-occurrence Matrix) adı verilmiştir. Özellik çıkarımında CGLCM için 22 özellik denklemleri (Haralick vd., 1973; Soh ve Tsatsoulis, 1999) kullanılmış olup; bu denklemlere ilişkin açıklamalar Görüntü Doku Analizi başlığı altında daha önce detaylandırılmıştır.


CGLCM ile doku özellik çıkarımı renkli yaprak görüntülerinin üç farklı renk uzayı için ayrı ayrı gerçekleştirilmiştir. Her bir görüntü için uygulanan CGLCM ile doku özellik çıkarımının aşamaları şu şekildedir:

- Öncelikle her bir yaprak görüntüsü farklı boyutlara sahip olduğundan yeniden boyutlandırılmıştır. Bir DenseNet ağı, 224x224 boyutunda giriş görüntülerine ihtiyaç duymaktadır. Yapısal doku analizi aşamasında önerilen özellik çıkarımı CNN ve CGLCM özelliklerinin bir kombinasyonunu içereceğinden dolayı CGLCM için görüntülerin boyutları 224x224 olacak şekilde ayarlanmıştır. Bu şekilde sonuçlar üzerinde adil bir kıyaslanmanın yapılması da sağlanmıştır.
- Her yaprak için renk dönüşümleri (RGB formdan HSV,  $L^*a^*b^*$ , ve gri tonlamalı forma dönüştürme) gerçekleştirilmiştir.
- Yaprak görüntüleri her renk uzayı için farklı kanallara ayrılmıştır (örneğin RGB için Kırmızı, Yeşil, Mavi renk kanallarına ayrıştırılmıştır). Bu sayede 3D görüntüler 2D'ye indirgenmiştir. Gri tonlamalı görüntüler zaten 2D olduğundan onlar için bir ayrıştırma yapılmamıştır.
- Yaprak görüntüsünün tüm renk kanalları için CGLCM'ler hesaplanmıştır (CGLCM\_RGB, CGLCM\_HSV ve CGLCM\_Lab). Bu aşamada daha önce

bahsedilen 22 özelliği sağlayan MATLAB fonksiyonu (Uppuluri, 2021) kullanılmıştır. Böylece her bir renk kanalı ve gri düzeyi (3+1) için toplamda 88 öznelik elde edilmiştir.

- Son olarak sınıflandırma süresini azaltmak için her bir veri min-max normalizasyon yöntemi kullanılarak normalize edilmiştir.

CGLCM\_RGB işleyişi basitçe Şekil 6.15’da gösterilmiştir.



Şekil 6.15 CGLCM\_RGB işleyişinin basitçe gösterimi


Tüm bu işlemler sonucunda tüm yaprak görüntüleri için 15.000 satır ve 88 sütundan oluşan bir matris elde edilmiştir.

#### 6.4. CGLCM ve Derin Özelliklerin Birleşimine Dayalı Özellik Çıkarımı

Çalışmanın doku analizi bölümünde, modern derin öznelik çıkarımı ve geleneksel doku öznelik çıkarımı yöntemlerinin bir arada kullanıldığı bir hibrit model önerilmiştir. Bu kapsamda;

- Daha önce de belirtildiği üzere verilerden derin öznitelik çıkarımında DenseNet-201 ağı kullanılarak GAP ile toplam 1920 öznitelik elde edilmiştir.
- Doku öznitelik çıkarımında CGLCM kullanılarak her bir renk uzayı için ayrı ayrı uygulamalarla, doku ve renk özelliklerini içeren 88 öznitelik elde edilmiştir.
- Sonuç olarak 15000 görsel için toplam 2008 öznitelik girişi ve bir adet hedef çıktı elde edilmiştir.

Veri setinden iki farklı sınıf için örnek yaprak görüntüleri Şekil 6.16’da sunulmuş olup; bu yaprak görüntüleri için elde edilen örnek CGLCM ve CNN öznitelikleri sırasıyla Çizelge 6.4 ve 6.5’te verilmiştir.



Şekil 6.16 MR (a) ve S (b) sınıflarından örnek yaprak görüntüleri

Çizelge 6.4 Şekil 6.16 yaprak görüntüleri için örnek CGLCM öznitelikleri

	Otokorelasyon	Kontrast	Korelasyon	Farklılık	Enerji	Entropi	Homojenlik	Maks. Olasılık
(a)	21,25	0,13	0,96	0,13	0,31	1,76	0,94	0,53
(b)	26,50	0,36	0,95	0,32	0,09	2,69	0,84	0,19

Çizelge 6.5 Şekil 6.16 yaprak görüntüleri için örnek CNN öznitelikleri

	Otokorelasyon	Kontrast	Korelasyon	Farklılık	Enerji	Entropi	Homojenlik	Maks. Olasılık
(a)	0,66	0,95	1,43	0,85	1,23	0,95	0,72	0,74
(b)	0,41	0,56	1,17	0,24	0,88	0,91	0,51	1,35

## 6.5. Geleneksel Yapısal Özellik Sınıflandırıcısı

Çalışmada, elde edilen birleştirilmiş yapısal özniteliklerin performans testi ve karşılaştırması için popüler doku sınıflandırma yöntemleri arasında yer alan (Metre ve Ghorpade, 2013) Destek Vektör Makineleri (SVM) ML yöntemi tercih edilmiştir. SVM kullanılarak çok sınıflı bir denetimli ML metodu önerilmektedir.

### 6.5.1. Destek Vektör Makineleri

Destek Vektör makineleri, birçok doku sınıflandırma problemi için yaygın olarak kullanılan bir ML metodudur (Kim, Jung, Park ve Kim, 2002; Vapnik, 2013; Wang vd., 2019; Chakraborty, Paul ve Rahat-uz-Zaman, 2021). Çok sınıflı sınıflandırma problemleri için yararlıdır (Metre ve Ghorpade, 2013; Chakraborty vd., 2021).

Kim vd. (2002) çalışmalarında, çok sınıflı doku sınıflandırma problemlerinde çözüm için sınıflandırıcı olarak doğrusal SVM kullanmanın faydalarını bildirmişlerdir. SVM, yüksek verilerle karşılaşıldığında genelleme yapabilmekte ve doku özellik uzayında optimal bir hiper düzlem oluşturabilmektedir. Bu tez çalışmasında, SVM kullanılarak CGLCM ve derin özelliklerin birleşimine dayalı özelliklerle eğitilen bir model önerilmiştir. Çalışmada kullanılan SVM parametreleri Çizelge 6.6 üzerinde gösterilmiştir.

**Çizelge 6.6 SVM sınıflandırıcı parametreleri**

Parametre Adı	Değeri
Kernel	Cubic polynomial
Max. Iteration	30
Optimizer	Bayesian
Multiclass Method	One vs One

Önerilen modelde sınıflandırıcı için kullanılan veri seti, model geliştirme için (training) %90 (n=13500) ve model değerlendirmesi için %10 doğrulama (validation) örneğine (n=1500) rastgele olacak şekilde bölünmüştür (Çizelge 6.7).

**Çizelge 6.7 Yellow-Rust-19 veri setinin eğitim (öğrenme süreci sırasında kullanılan veri kümesi) ve doğrulama (modelde değerlendirmesi için kullanılan veri kümesi) grupları.**


	0	R	MR	MRMS	MS	S	TOPLAM
Eğitim	2250	2250	2250	2250	2250	2250	<b>13500</b>
Doğrulama	250	250	250	250	250	250	<b>1500</b>

## 6.6. Derin Öğrenmeye Dayalı Sınıflandırma

### 6.6.1. CNN

Evrışimsel Sinir Ağları, verilerden ayırt edici özellikleri kendi kendine öğrenebilen, sınıflama becerisine sahip, insan beyninden ilham alınarak tasarlanmış bir derin öğrenme modelidir.

Tez çalışmasının bu bölümünde önerilen DL modelinin iş akışını özetleyen görsel Şekil 6.17 üzerinde gösterilmiştir.



**Şekil 6.17** Önerilen derin öğrenme modeli iş akışı. Görüntüler, özellikleri otomatik olarak öğrenen ve nesnelere sınıflandıran CNN'ye iletilmektedir

### 6.6.2. Xception

Xception derin öğrenme modeli Chollet (2017) tarafından sunulmuştur. Mimari olarak, ILSVRC-2015'te sınıflandırma kategorisinde ikinciliği kazanan Inception-V3'ü (Szegedy vd., 2016) temel alır. Mimari yapısı nedeniyle sınıflandırmada VGG-16 (Simonyan ve Zisserman, 2014), ResNet152 (He vd., 2016) ve Inception-V3'ü geride bırakmıştır.

Tez çalışmasında derin öğrenmeye dayalı sınıflandırma için Xception modeli ile ResNet ve MobileNet modelleri kullanılmıştır.

### 6.6.3. Önerilen Derin Öğrenme Modeli

Bu çalışma, Xception modeli üzerine kurulu Yellow-Rust-Xception adlı bir transfer öğrenme modeli önermektedir.

Buğdayda sarı pasın enfeksiyon düzeyini belirleme görevi için Xception, ResNet ve MobileNet modelleri, ImageNet kullanılarak önceden eğitilmiş şekliyle modele entegre edilmiş olup; her bir model için sınıflama başarısı belirlenmiştir. Modellerin yeniden eğitilmesi, doğrulanması ve test edilmesi gibi tüm işlemler Python programlama dili kullanılarak gerçekleştirilmiştir.


Çalışmada önceden belirtilen veri artırımı tekniği ile artırılan veri seti eğitim, doğrulama ve test olmak üzere üç gruba ayrılmıştır. Burada doku analiz çalışmasında

oluşturulan eğitim ve doğrulama veri kümelerine ek olarak bir “test” veri kümesinin oluşturulduğu ayrıca belirtilmelidir. Modelde aşırı uyum gibi sorunların önüne geçilebilmesi açısından model, eğitim süreci boyunca hiç karşılaşmadığı küçük bir test veri kümesi ile test edilmiş ve doğruluk derecesi ile test derecesi karşılaştırılmıştır. Derin öğrenmeye dayalı sınıflandırma için ayarlanan veri sayıları Çizelge 6.8’de verilmiştir.

**Çizelge 6.8** Yellow-Rust-19 veri setinin eğitim (öğrenme süreci sırasında kullanılan örnek veri kümesi) ve doğrulama (modelde ince ayar yapmak için kullanılan örnek veri kümesi) ve test (eğitim ve doğrulama veri kümelerinden bağımsız veri kümesi) grupları.

	<b>0</b>	<b>R</b>	<b>MR</b>	<b>MRMS</b>	<b>MS</b>	<b>S</b>	<b>TOPLAM</b>
Eğitim	1750	1750	1750	1750	1750	1750	<b>10500</b>
Doğrulama	250	250	250	250	250	250	<b>1500</b>
Test	500	500	500	500	500	500	<b>3000</b>

Önceden eğitilmiş Xception modeli mimari olarak yeniden tasarlanmıştır. Daha sonra model, 10500 görüntü ile eğitilmiştir. Eğitim sırasında 1500 görüntü ile doğrulama işlemi gerçekleştirilmiştir. Eğitim süreci sonunda Yellow-Rust-Xception adı verilen model elde edilmiştir. Yellow-Rust-Xception modelinin oluşturulma aşamalarını özetleyen görsel Şekil 6.18 üzerinde gösterilmiştir.



**Şekil 6.18** Önerilen Yellow-Rust-Xception modeli

Şekil 6.18 üzerinde görüldüğü gibi, Xception mimarisinin son aşaması olan Lojistik Regresyon katmanı, iki tam bağlantılı katman ve özelleştirilmiş bir Softmax katmanı ile değiştirilmiştir. Bunlara ek olarak, tam bağlantılı her katmandan hemen sonra toplu normalleştirme ve bırakma işlemleri uygulanmıştır. Hiper parametrelerden öğrenme oranı 0.001 olarak ayarlanmış olup; optimize edici olarak Adam kullanılmıştır (Çizelge 6.9). İlk 12 evrişim katmanı ve ayrılabilir evrişim katmanları eğitim sırasında dondurularak bırakma işlemi uygulanmış; ancak daha yüksek katmanlarda ince ayar yapılmıştır.

**Çizelge 6.9** Önerilen Yellow-Rust-Xception modelinin hiperparametreleri

Parametre Adı	Değeri
Optimizer	Adam
Loss function	Categorical cross entropy
Momentum	0.9
Learning rate	1.0000e-03
Early stopping patience	10
Maximum epoch	50
Mini batch size	32
Shuffle	Every epoch



## 6.7. Değerlendirme Ölçütleri

Çalışmada tasarlanan modellerin sarı pasın enfeksiyon derecesini belirleme yeteneğinin performans analizinin yapılabilmesi için literatürde de belirtilen belirli ölçütlere ihtiyaç duyulmaktadır. Temelde çok sınıflı bir sınıflandırma problemi ele alındığından dolayı başlıca değerlendirme ölçütlerinin kullanılması yeterlidir. Literatürde bahsedilen yaprak hastalıkları sınıflandırma çalışmalarının büyük bir çoğunluğu sadece doğruluk ölçütünü kullanmaktadır. Ancak son çalışmalarda özellikle sınıflandırma problemlerinin performansının belirlenmesinde doğruluk kriterinin tek başına yeterli olmadığı, farklı ölçütlerle başarının desteklenmesinin gereği belirtilmiştir. Bu nedenle çalışma kapsamında daha ayrıntılı ve sağlıklı bir değerlendirmenin yapılabilmesi için başka ölçütlerden de yararlanılmıştır. Kullanılan değerlendirme ölçütleri aşağıda detaylandırılmıştır.

### 6.7.1. Doğruluk (Accuracy)

Doğruluk, sınıflandırma problemleri için yaygın olarak kullanılan bir değerlendirme ölçütüdür. Doğru tahmin edilen örnek sayısının toplam örnek sayısına bölünmesi ile elde edilir. Verideki sınıflara ait örnek sayısı dengeli ise daha anlamlı bir değerlendirme sunar.

$$\text{Accuracy} = \frac{\sum_{i=1}^6 C(i,i)}{\sum_{i=1}^6 \sum_{j=1}^6 C(i,j)}. \quad (6.1)$$

### 6.7.2. Kesinlik (Precision)

Kesinlik, sistemin bir  $k$  sınıfı için doğru tahmin ettiği örneklerin sayısının, sınıfını  $k$  olarak tahmin ettiği tüm örneklerin sayısına oranıdır.

$$\text{Precision}(k) = \frac{C(k,k)}{\sum_{i=1}^6 C(k,i)}, \quad k = 1, 2, \dots, 6 \quad (6.2)$$

### 6.7.3. Hassasiyet (Recall-Sensitivity)

Hassasiyet, sistemin bir  $k$  sınıfı için doğru tahmin ettiği örneklerin sayısının, gerçek sınıfı  $k$  olan örneklerin sayısına oranıdır.

$$\text{Recall}(k) = \frac{C(k,k)}{\sum_{i=1}^6 C(i,k)}, \quad k = 1, 2, \dots, 6 \quad (6.3)$$

### 6.7.4. F1 Skor (F1-Score)

Kesinlik ve hassasiyet ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli olmayabilir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. Bunun için F1 skor tanımlanmıştır. F1 skor, kesinlik ve hassasiyetin harmonik ortalamasıdır.

$$\text{F1-Score}(k) = 2 \times \frac{\text{Precision}(k) \times \text{Recall}(k)}{\text{Precision}(k) + \text{Recall}(k)}, \quad k = 1, 2, \dots, 6 \quad (6.4)$$

### 6.7.5. Karışıklık Matrisi (Confusion Matrix)

Bahsedilen ölçütleri hesaplamak için bazı ara parametreler ve formüller kullanılmaktadır. Ölçütleri hesaplamak için kullanılan bu parametreler Doğru Pozitif, Yanlış Negatif, Yanlış Pozitif, Doğru Negatiftir. ML’de hata matrisi olarak da adlandırılan karışıklık matrisleri, tipik olarak bir denetimli öğrenme algoritmasının performansının görselleştirilmesinde kullanılan bir tablodur. Matrisin her satırı gerçek bir sınıftaki örneklerin temsilini oluştururken; her sütun tahmin edilen bir sınıftaki örneklerin temsilini oluşturmaktadır. Bir sınıflandırma problemi için karışıklık matrisi, doğru ve yanlış tahminlerin sayısını (ya da yüzdesini) özetler. Adında bulunan “Karışıklık” terimi, karışıklık matrisinin sistemin sınıfları karıştırıp karıştırmadığını ortaya çıkarmasından dolayı kullanılmıştır. Örnek bir karışıklık matrisi Şekil 6.19 üzerinde gösterilmiştir. Örnekte gösterilen karışıklık matrisinde mavi olarak gösterilen çapraz hücrelerin, ilgili sınıflarda kaç adet doğru sınıflandırma yapıldığını gösterdiği anlaşılmaktadır. Örnekteki karışıklık matrisi, *versicolor* sınıfındaki üç ölçümün yanlış sınıflandırıldığını göstermektedir. *Setosa* ve *virginica* sınıflarına ait tüm veriler doğru

bir şekilde sınıflandırılmıştır. Tez çalışmasında önerilen modellerin sınıflandırma başarıları karışıklık matrisleri kullanılarak görselleştirilmiştir.

setosa	20		
versicolor	1	30	2
virginica			22
	setosa	versicolor	virginica
	Predicted Class		

Şekil 6.19 Örnek bir karışıklık matrisi

## 7. ARAŞTIRMA BULGULARI

Bu başlık altında doku analizi kapsamında elde edilen bulgularla derin öğrenmeye dayalı elde edilen bulgular ayrı başlıklar altında sunulmuştur.

### 7.1. Yapısal Özelliklere Dayalı Sınıflandırma Bulguları


Tez çalışmasının doku analizi tarafında sarı pas hastalıklı buğday yaprak görüntülerinin öznitelik çıkarımı, Renk-Gri Seviye Eş-Oluşum Matrisi (CGLCM) ile derin öğrenme öznitelik çıkarma yöntemi birleştirilerek gerçekleştirilmiştir. Başlangıçta sarı pas çalışmaları için özellikle ayrılan bir tarla ortamında 5421 adet ham yaprak görüntüsü elde edilmiştir. Daha sonra görüntülerden arka plan piksellerini çıkarmak amacıyla bazı ön işleme adımları manuel ve otomatik olarak uygulanmıştır. Ön işleme adımlarından geçirilen yaprak görüntüleri alan uzmanları tarafından etiketlenilerek toplam 6 sınıf oluşturulmuştur. Son olarak veri artırma teknikleri kullanılarak toplamda 15000 görüntü içeren nihai Yellow-Rust-19 veri seti oluşturulmuştur.

Veri seti kullanılarak aşağıda açıklanan ve sonraki bölümlerde kullanılacak kısaltmaları verilen öznitelik çıkarımları gerçekleştirilmiştir:

- RGB renk uzayı için CGLCM ile öznitelik çıkarımı (CGLCM\_RGB)
- HSV renk uzayı için CGLCM ile öznitelik çıkarımı (CGLCM\_HSV)
- L\*a\*b\* renk uzayı için CGLCM ile öznitelik çıkarımı (CGLCM\_Lab)
- DenseNet-201 ve CGLCM\_RGB özniteliklerinin birleşimi (CNN-CGLCM\_RGB)
- DenseNet-201 ve CGLCM\_HSV özniteliklerinin birleşimi (CNN-CGLCM\_HSV)
- DenseNet-201 ve CGLCM\_Lab özniteliklerinin birleşimi (CNN-CGLCM\_Lab)

Son olarak her bir yöntem için elde edilen öznitelikler SVM sınıflandırıcısı ile test edilmiştir. Çalışmada yaprak görsellerinin farklı renk uzayları kullanılmasının nedeni, farklı renk uzayları bakımından doğruluk karşılaştırmasının yapılarak en iyi sonuç veren renk uzayının belirlenmesidir.

Derin öznitelik çıkarımı tarafında, GAP katmanı, tam bağlantılı katmandan önce toplam 1920 öznitelik sağlamıştır. Şekil 7.1 üzerinde örnek bir yaprak görüntüsünün, DenseNet-201 mimarisi birinci evrişim katmanı (2. katman) ve toplu normalleştirme katmanı (3. katman) sonrası görselleştirimi sunulmaktadır. Birinci katman olan giriş katmanında  $224 \times 224 \times 3$  boyutuna dönüştürülen yaprak görüntüsü, ilk evrişim katmanına girdi olarak verilir ve 64 filtre uygulanır. Ardından, ilk evrişim katmanından üretilen her çıktı sonraki toplu normalleştirme katmanında normalleştirilir.



**Şekil 7.1** Giriş görüntüsü (a), ilk evrişim katmanında öğrenilen 64 filtrenin görselleştirimi (b), ilk evrişim katmanından örnek görüntüler (c), toplu normalleştirme katmanından öğrenilen 64 filtrenin görselleştirimi (d), toplu normalleştirme katmanından örnek görüntüler (e)

Her bir yöntemden elde edilen özniteliklerin sınıflandırılmasına ait ortalama doğruluk oranları Çizelge 7.1 üzerinde gösterilmiştir. Hesaplanan doğruluk oranları tüm renk uzayları için gösterilmiştir. Burada, hibrit ve hibrit olmayan özellikler arasındaki farklar dikkate alındığında derin özelliklerin deneysel sonuçlara katkısını belirtmek önemlidir.

**Çizelge 7.1** Ortalama doğruluk oranları (%)


<b>Metot</b>	<b>Doğruluk</b>
CGLCM_RGB	75,4
CGLCM_HSV	73,9
CGLCM_Lab	71,3
CNN-CGLCM_RGB	90,3
<b>CNN-CGLCM_HSV</b>	<b>91,7</b>
CNN-CGLCM_Lab	89,3

Kullanılan SVM sınıflandırıcısının parametreleri tüm öznelikler için aynı şekilde uygulanmıştır. Birleştirilmiş özellikler tüm renk uzayları için doğruluğu artırmayı başarmıştır. Böylece derin özelliklerin genel doğruluğu artırdığı kanıtlanmıştır.

CGLCM sonuçlarına göre, %75,4 ortalama doğrulukla en iyi performans CGLCM\_RGB ile elde edilmiştir. Birleştirilmiş özellikler için en iyi performans %91,7 ortalama doğrulukla CNN-CGLCM\_HSV ile elde edilmiştir. CGLCM sonuçlarında en iyi performansı RGB renk uzayının sergilemesine karşın birleştirilmiş özelliklerde en iyi performansı HSV uzayının sergilediği görülmektedir.

Diğer yandan, sınıflandırıcının her sınıfta nasıl performans gösterdiğini anlamak için karışıklık matrisi kullanılmıştır (Şekil 7.2). Karışıklık matrisleri, sınıflandırıcının güçlü ve zayıf performans gösterdiği sınıfları belirlemiştir. Satırlar gerçek sınıfları, sütunlar ise tahmin edilen sınıfları göstermektedir. Çapraz hücreler ise her sınıfın ne kadar doğru sınıflandırıldığını göstermektedir. Mavi renkle gösterilen çapraz hücreler, sınıfların ne kadar doğrulukla sınıflandırıldığını belirtmektedir.

En iyi sınıflandırıcıların Gerçek Pozitif Oranları (TPR: True Positive Rates)- Yanlış Negatif Oranları (FNR: False Negative Rates) karışıklık matrisleri, sınıflandırıcıların sınıf başına nasıl performans gösterdiğini anlayabilmek için gösterilmiştir. TPR değerleri, gerçek sınıf başına doğru sınıflandırılmış gözlemlerin oranını, FNR değerleri ise yanlış sınıflandırılmış gözlemlerin oranını göstermektedir. Karışıklık matrislerinde sağda kalan son iki sütun, TPR ve FNR'nin özetlerini belirtmektedir. Satır ve sütun adlarında yer alan rakamlardan 0 "Bağışıklığı", 1 "R"yi, 2 "MR"yi, 3 "MRMS"yi, 4 "MS"yi ve 5 "S"yi temsil etmektedir.



**Şekil 7.2** Karışıklık matrisleri: CGLCM\_RGB (a), CNN-CGLCM\_RGB (b), CNN-CGLCM\_HSV (c), CNN-CGLCM\_Lab (d)

Karışıklık matrislerinde CGLCM yöntemleri arasında en iyi yöntem olan CGLCM\_RGB'nin performansı hibrit yöntemlere karşı gösterilmiştir (Şekil 7.2(a)). Buna göre, CNN özniteliklerinin sisteme dahil edilmesi her sınıf için fark edilir bir performans sağlamıştır.

Bunlara ek olarak CGLCM\_RGB ve hibrit yöntemlerin karışıklık matrisleri aracılığıyla kesinlik, hassasiyet ve F1 skor ölçütleri hesaplanmıştır. Her yöntemin performansı Çizelge 7.2'de verilmiştir.

**Çizelge 7.2** CGLCM\_RGB'ye karşılık hibrit özelliklerin performans sonuçları

	Kesinlik	Hassasiyet	F1 Skor
CGLCM_RGB	0,756	0,753	0,756
CNN-CGLCM_RGB	0,898	0,896	0,895
CNN -CGLCM_HSV	<b>0,918</b>	<b>0,915</b>	<b>0,916</b>
CNN -CGLCM_Lab	0,893	0,891	0,891

Genel olarak, birleştirilmiş öznitelik çıkarma yöntemleri, diğer öznitelik çıkarma yöntemlerine göre daha başarılı sonuçlar vermiştir. Derin özniteliklerin sınıflandırmada hassasiyet yaratabileceği kanıtlanmıştır.


## 7.2. Derin Öğrenmeye Dayalı Sınıflandırma Bulguları

Tez çalışmasının bu bölümünde deneyler MobileNet, ResNet ve Xception gibi önceden eğitilmiş farklı DL modelleri kullanılarak gerçekleştirilmiştir. Deneysel sonuçlar Xception tabanlı modelin en yüksek doğruluk derecesine sahip olduğunu göstermiştir. Ortaya çıkan Xception tabanlı modele Yellow-Rust-Xception adı verilmiştir. Çizelge 7.3, tüm modellerin sınıflandırma doğruluk oranlarını göstermektedir.

**Çizelge 7.3** Önerilen model Yellow-Rust-Xception ve diğer modellerin sınıflandırma doğruluk oranları

Model	Doğruluk (%)
Yellow-Rust-Xception	91,17
MobileNet	87,57
ResNet	87,10


Hem eğitim hem de doğrulama sonuçlarının grafikleri Yellow-Rust-Xception modeli için gösterilmiştir (Şekil 7.3). Yellow-Rust-Xception modeli, 50 dönem (epoch) ile eğitilmiş ve her dönemden sonra eğitim-doğrulama sonuçları sunulmuştur. Eğitim sırasında hem eğitim hem de doğrulama sonuçlarının artışı görülmektedir.



**Şekil 7.3** Yellow-Rust-Xception eğitim ve doğrulama sonuç grafiği

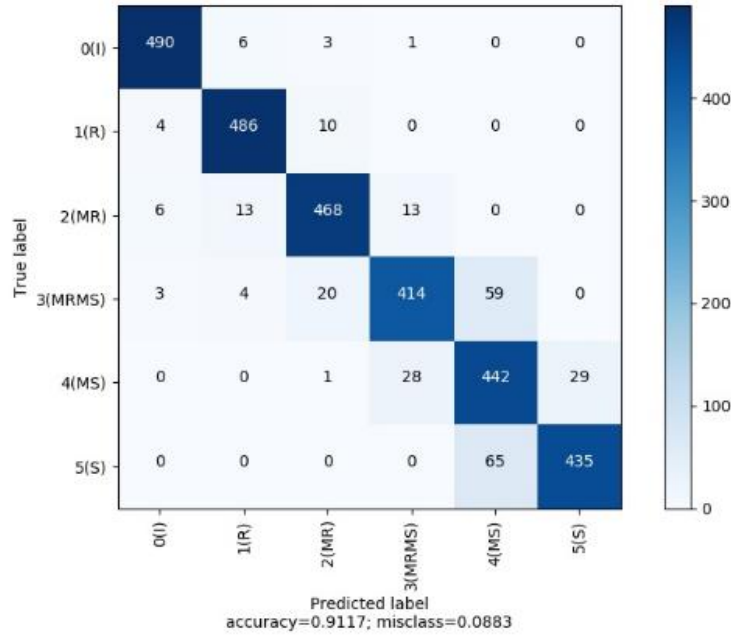
Ayrıca modelin eğitim ve doğrulama kayıp grafiği de çizilmiştir (Şekil 7.4). Kayıp verilerinin dönem boyunca azalmakta olduğu hem eğitim hem de doğrulama için gözlemlenmektedir.





**Şekil 7.4** Yellow-Rust-Xception eğitim ve doğrulama kayıp grafiği

Daha sonra Yellow-Rust-Xception, modelin eğitim sırasında karşılaşmadığı 3000 görüntü ile (Çizelge 6.8) test edilmiştir. Test işlemi için karışıklık matrisi Şekil 7.5 üzerinde gösterilmiştir. Hem eğitim hem de test sonuçları, önerilen modelin iyi bir şekilde genelleştirildiğini göstermektedir. Test işlemi sonucunda elde edilen doğruluk oranı 0,9117 olarak ölçülmüştür. Bu oran doğrulama sonucu ile hemen hemen aynı değerde hesaplanmıştır. Dolayısıyla önerilen modelin aşırı uyum ve yetersiz uyum gibi sorunlardan da etkilenmediğini söylemek doğru olacaktır.



**Şekil 7.5** Test işlemi karışıklık matrisi

Diğer yandan, doğruluk oranının yanı sıra kesinlik, hassasiyet ve F1 skor gibi performans ölçütleri de karışıklık matrisi aracılığıyla hesaplanmıştır. Bu ölçütler yukarıda belirtilen iddiaları destekler niteliktedir. Yellow-Rust-Xception modelinin her sınıf için performansı Çizelge 7.4 üzerinde detaylandırılmıştır.

**Çizelge 7.4** Yellow-Rust-Xception performans sonuçları

Ölçüt	0	R	MR	MRMS	MS	S	Ortalama
Kesinlik	0,9742	0,9548	0,9323	0,9079	0,7809	0,9375	0,9146
Hassasiyet	0,9800	0,9720	0,9360	0,8280	0,8840	0,8700	0,9117
F1 Skor	0,9771	0,9633	0,9341	0,8661	0,8293	0,9025	0,9121

## 8. SONUÇ VE TARTIŞMA

Sarı pas hastalığı ülkemiz başta olmak üzere dünyada buğday üretimini etkileyen önemli hastalıklardan biridir (Wellings 2011). Hastalığın enfeksiyon derecesinin bilinmesi, araştırmacılara ve üreticilere hastalığa karşı alınabilecek önlemleri için önemli bilgiler sağlamaktadır. Normal koşullarda sarı pas hastalığının epidemi durumu, uzmanlar tarafından buğday yapraklarındaki yapısal değişikliklerin görsel olarak incelenmesiyle belirlenmektedir. Ancak bu süreç zaman alıcı, zahmetli ve konu ile ilgili derin bir bilgi ve deneyim gerektirmektedir. Bu nedenle sağlam ve kullanışlı tasarlanan bilgisayar destekli sistemler bu sorunu çözmek için araştırmacılara ve üreticilere faydalı olabilir.

Bu tez çalışmasında problemin çözümü için buğdayda sarı pas hastalığı hem doku analiz yöntemleri çerçevesinde hem de son yıllarda popüler olan derin öğrenmeye dayalı analiz yöntemleri çerçevesinde araştırılmış ve uygun model bulunmaya çalışılmıştır.

Araştırmanın ilk aşamasında doku analiz yöntemleri bağlamında geleneksel öznitelik çıkarım metotları arasında popüler olan Gri Seviye Eş-Oluşum Matrisi (GLCM) ve alanda kendini kanıtlamış geleneksel doku sınıflandırıcısı olarak Destek Vektör Makineleri (SVM) kullanılmıştır. Yapısal öznitelik çıkarımında sadece geleneksel yöntemlerle yetinmeyip modern öznitelik çıkarıcı bir yöntem olan CNN tabanlı bir model (DenseNet) kullanılarak geleneksel doku analiz yöntemleri ile modern yöntemlerin birleşimi olan yeni bir yöntem önerilmiştir.

İlk aşama için deney sonuçlarından, sınıflandırmada birleşik özniteliklerin, tek başına geleneksel doku analiz yöntemleriyle elde edilen özniteliklerden daha iyi doğruluk oranına sahip olduğu gözlemlenmiştir. Tüm deneysel süreçlerde sağlıklı ve farklı enfeksiyon türlerine sahip buğday yapraklarını içeren veri seti “Yellow-Rust-19” kullanılmıştır. Hibrit özniteliklerin performans testleri karşılaştırıldığında en iyi performans HSV renk uzayı için %91,7 ortalama doğrulukla elde edilmiştir. Sınıflandırıcı olarak kullanılan SVM için belirlenen parametreler tüm deneyler için sabit tutulmuş ve bu şekilde adil bir karşılaştırma yapılması sağlanmıştır.

Ek olarak, çalışmada elde edilen performans sonuçları, İlgili Çalışmalar bölümünde bahsedilen benzer metodolojilere sahip diğer çalışmalarla da karşılaştırılmıştır. Derin

özniteliklerin sınıflandırma performansına katkısı diğer çalışmalarda da görülmektedir. Karşılaştırma sonuçları Çizelge 8.1’de sunulmuştur.

**Çizelge 8.1** Hibrit özniteliklere (HÖ) karşı standart doku özniteliklerin (SDÖ) performans karşılaştırması

Çalışma	Ö	TA Metodu	DL Metodu	Sınıflandırıcı	SDÖ	HÖ
Önerilen Çalışma	A	Renk tabanlı GLCM	Önceden eğitilmiş DenseNet-201	SVM	75.4	91.7
Zhang vd. [21]	A	LBP	VGG-19, VGG-f, Caffe-ref	Ensemble sınıflandırıcı	71.29	85.47
Wei vd. [22]	A	NPPS	Derin İnanç Ağı	LR	76.70	79.23
Ali vd. [23]	R	GMM	Standart/Modifiyeli CNN	SVM	-	0.841
Hasan vd. [24]	A	GLCM	Standart/Modifiyeli CNN	SVM	96.10	99.30
Jia vd. [25]	R	Kümeleme	Standart/Modifiyeli CNN	Softmax	0.82	0.91
Nanni vd. [26]	A	Çeşitli metotlar	Önceden eğitilmiş DenseNet-201	SVM	86.13	89.47
Luz vd. [27]	A	Çeşitli metotlar	LeNet	SVM	71.2	85
Zhang vd. [21]	A	Çeşitli metotlar	VGG-16	SVM	96.3	98.8
Naz vd. [29]	A	LBP ve SFTA	Inception-V3 ve VGG-16	SVM	59.2	99.3

Not: Bahsedilen çalışmaların en iyi sonuçları gösterilmektedir. Verilen kısaltmalar için Ö, ölçütü; TA, kullanılan doku analiz yöntemini; DL, kullanılan derin öğrenme yöntemini; A, doğruluğu; R, hassasiyeti; LR, lojistik regresyon modelini; NPPS, nükleotid çift pozisyon özgüllüğünü; GMM, Gauss karışım modelini temsil etmektedir

Doku analiz alanında popüler doku öznitelik çıkarma teknikleri literatürde belirtilmiştir (Metre ve Ghorpade, 2013). Önceden de bahsedildiği gibi GLCM yöntemi etkili bir doku tanımlayıcısıdır ve GLCM’nin diğer doku analiz yöntemlerinden daha iyi doğruluk değerine ve daha kısa hesaplama süresine sahip olduğu kanıtlanmıştır (De Siqueira vd., 2013). Bu nedenle çalışmada geleneksel doku öznitelik çıkarımı için GLCM tercih edilmiştir. Bununla birlikte GLCM’nin farklı renk uzaylarına uygulanabilecek şekilde geliştirilebileceği de kanıtlanmıştır (Tou vd., 2009; Selvarajah ve Kodituwakku, 2011; Metre ve Ghorpade, 2013). Bu tez çalışması da bu durumu desteklemektedir.

Birleştirilmiş yöntemlerde tüm renk uzaylarında performans artışı olmasına rağmen; karışıklık matrisleri her sınıf için elde edilen performanslarda farklılıklar olduğunu göstermiştir. Bu durum tüm renk uzayları için geçerli olduğundan dikkate alınmalıdır. Ayrıca her sınıf için elde edilen ham görüntü sayıları arasındaki tutarsızlığı da dikkate almak önemlidir. Ancak derin öznitelikler, standart özniteliklerin performansını artırmak ve daha kararlı bir sistem oluşturmak için yardımcı olabilir.

Yapısal analiz çalışmaları için sonuç olarak, Yellow-Rust-19 veri seti için 6 sınıflı bir sınıflandırmada derin öznitelik çıkarımı ve doku öznitelik çıkarımı metotlarının birleşimine yönelik hibrit bir yöntem önerilmiştir. Derin öznitelik analizi önceden

eđitilmiş DenseNet-201 ađına dayanmaktadır. Birleřtirilmiř yöntemlere ait izelge 7.2’de verilen kesinlik, hassasiyet ve F1 skor gibi performans ölçütlerinin yanı sıra yöntemlerin ortalama dođruluk derecesi, önerilen hibrit yöntemin umut verici olduđunu göstermektedir. Geleneksel doku öznelikleri tek başına yeterli olmamakla birlikte derin öznelikle birleřtirildiđinde hassasiyeti ve başarıyı artırdıđı kanıtlanmıřtır. Birleřtirilmiř doku analizi için ileride yapılacak alıřmalarda DenseNet-201 dıřında farklı ađlar test edilerek sonuçları karřılařtırılabilir. Buna ek olarak bu alıřmada yapısal analiz alıřmalarında kullanılan GLCM dıřında diđer doku analiz yöntemleri de test edilerek başarıya katkıları tartıřılabilir.

Yapısal analiz alıřmalarında, deneysel sonuçlara göre derin öznelikle geleneksel yöntemlerin performansını artırmak ve daha kararlı bir sistem oluřturmak için yardımcı olabilir. Performans testleri, birleřtirilmiř yöntemlerin başarısını kanıtlaya da modelleri gerek saha kořullarında kullanabilmek için daha iyi öznelikle ıkarıcı ve sınıflandırıcı yöntemlere ihtiya vardır. Tam bu noktada alıřmanın diđer ařaması olan tamamen derin öğrenmeye dayalı olan sınıflandırma alıřması önerilmektedir.

Hem bilgisayar bilimi hem de bilgisayar donanım teknolojisindeki son geliřmeler, yüksek çözünürlüklü görüntülerin elde edilmesini, bu görüntülerin depolanmasını ve iřlenmesini kolaylařtırmıřtır. İnsan beyninden ilham alan son teknoloji derin öğrenme algoritmaları, uzman düzeyinde, hatta bazı durumlarda uzmandan daha iyi performanslar sergilemiřtir. Bu geliřmeler yapay zekâ alanında devrim yaratmıřtır. Bundan dolayı tıpta meme kanseri tespiti (Yurttakal vd., 2019), tarımda bitki hastalıđı sınıflandırması (Hayit vd., 2021) gibi farklı alanlarda ok başarılı alıřmalar gerekleřtirilmiřtir. Bu alıřmaların birođu bir insan gibi verilerden ayırt edici özellikleri otomatik olarak öğrenebilen ve verideki karmařık iliřkileri ıkarabilen CNN’lere dayanmaktadır.

Sarı pas için doku analizi ve derin öğrenme aısından literatürde bu tez alıřmasında kullanılan veri setine benzer bir veri setine rastlanmaması; özellikle buđday pas hastalıkları için sınıflandırma alıřmalarında yine tez alıřmasındaki sınıflandırma görevi ile aynı görevi ieren bir arařtırmanın bulunmaması, alıřmanın bařka alıřmalarla kıyaslamasını sınırlamıřtır. řöyle ki; literatürde farklı bitki türlerinin yaprak hastalıkları ile ilgili alıřmalar mevcuttur (Dhaygude ve Kumbhar, 2013; Lu vd., 2018; Zhang vd., 2018; Shrivastava vd., 2019; Waheed vd., 2020; Barman vd., 2020; Deeba ve Amutha, 2020; Tavakoli vd., 2021; Yogeshwari ve Thailambal, 2021).

Bu çalışmalar genellikle ya belirli bir hastalığın türleri arasında sınıflandırma görevini içermekte ya da farklı bitki türleri arasında farklı yaprak hastalıklarını sınıflandırma görevini içermektedir. Ancak bu tez çalışması, belirli bir bitki türü için belirli bir hastalığın epidemi seviyesini belirlemek için oluşturulabilecek yöntemleri tartışmaktadır. Basit bir örnek üzerinden anlatmak gerekirse bu çalışma, elmayla armudun sınıflandırılması değil elmanın alt türleri arasında bir sınıflandırma görevini üstlenmektedir. Birbirine çok yakın enfeksiyon dereceleri dikkate alındığında, mevcut çalışmadaki problemin zorluğu daha net anlaşılabilir. Bu noktada diğer çalışmalarla adil bir karşılaştırma yapılabilmesi mümkün değildir.

Ek olarak nihai hedefin, çiftçilerin kullanabileceği, gerçek ortamdaki görüntüleri alabilen, alınan görüntülerin ayırt edici özneliklerini çıkarıp sınıflandırabilen, tamamen taşınabilir bir sistemin geliştirilmesini desteklemek olduğunu belirtmek önemlidir. Bu çalışmada önerilen model, taşınabilir bir sistem için yazılımın başlangıç aşamasına hizmet etmektedir.

Tamamen derin öğrenmeye dayalı çalışmalar, buğdaydaki sarı pas hastalığının enfeksiyon seviyesini altı farklı seviye üzerinden belirlemeyi amaçlamıştır. Altı yönlü sınıflandırma için CNN tabanlı Yellow-Rust-Xception modeli önerilmiştir. Deneysel çalışmalara göre önerilen modelin doğruluk derecesi %91 olarak hesaplanmıştır. Doğruluk derecesine ek olarak kesinlik, hassasiyet ve F1 skor gibi diğer performans ölçütleri modelin istatistiksel olarak umut verici olduğunu göstermektedir. Doğruluk grafikleri ile kayıp grafikleri karşılaştırıldığında Yellow-Rust-Xception modelinin sarı pas hastalığını tespit etmek ve hastalığın enfeksiyon derecesini ayırt etmek için iyi bir aday olduğu öne sürülmüştür.

Sonuç olarak çalışmada önerilen hibrit model performans açısından tamamen derin öğrenmeye dayalı modellerle yaklaşık bir sonuç sergilemiştir. Buna rağmen tamamen derin öğrenme modelinde sağlıklı bir kıyaslama yapılabilmesi için DenseNet-201 modeli de işe koşularak sonuçların değerlendirilmesi önerilmektedir. Her iki metodun sonuçları da önerilen yöntemlerin gerçek arazi koşullarında tasarlanabilecek bir sistem için kullanılabilir yöntemler olabileceğini göstermektedir.

## KAYNAKLAR

Agarwal, M., Singh, A., Arjaria, S., Sinha, A. and Gupta, S. (2020). ToLeD: Tomato leaf disease detection using convolution neural network. *Procedia Computer Science*, 167, 293-301.

Ağyar, Z. (2015). Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine*, 56(662), 22-23.

Akan, K. (2019). Sarı Pas (*Puccinia striiformis* f. sp. *tritici*) Hastalığına Dayanıklı Makarnalık Buğday Hatlarının Geliştirilmesi. *Türk Tarım ve Doğa Bilimleri Dergisi*, 6(4), 661-670.

Akci, N. (2018). Kastamonu İlinde Buğday Alanlarında Görülen Kara Pas (*Puccinia Graminis* F. Sp. *Tritici*) Irklarının Belirlenmesi ve Berberis Türlerinin Kara Pas Etmeninde Patojenik Varyasyona Olan Etkileri. Doktora Tezi. *Ankara Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.

Aksoy, S. ve Haralick, R. M. (2000). Using texture in image similarity and retrieval. In *Texture analysis in machine vision*, 129-149.

Albawi, S., Mohammed, T. A. ve Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In *2017 International Conference on Engineering and Technology (ICET)*. Antalya, Turkey, 21-23 August.

Ali, R., Hardie, R. C., De Silva, M. S. ve Kebede, T. M. (2019). Skin lesion segmentation and classification for ISIC 2018 by combining deep CNN and handcrafted features. arXiv preprint arXiv:1908.05730.

Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.

Amari, S. I. ve Wu, S. (1999). Improving support vector machine classifiers by modifying kernel functions. *Neural Networks*, 12(6), 783-789.

Anonim (2020a). Bitki Zararlıları Zirai Mücadele Teknik Talimatları. <https://www.tarimorman.gov.tr/TAGEM/Belgeler/yayin/Bitki%20Zararlı%20C4%B1lar%20Zirai%20M%20C3%BCcadele%20Teknik%20Talimatlar%20C4%B1.pdf> İndirilme tarihi: 06 Mayıs 2021.

Anonim (2020b). Thresholding Operations using inRange. [https://docs.opencv.org/3.4/da/d97/tutorial\\_threshold\\_inRange.html](https://docs.opencv.org/3.4/da/d97/tutorial_threshold_inRange.html) İndirilme tarihi 02.03.2020

Anonim (2020c). Extract horizontal and vertical lines by using morphological operations. [https://docs.opencv.org/4.5.2/dd/dd7/tutorial\\_morph\\_lines\\_detection.html](https://docs.opencv.org/4.5.2/dd/dd7/tutorial_morph_lines_detection.html) İndirilme tarihi 03.03.2020

Anonim (2020d). More Morphology Transformations. [https://docs.opencv.org/3.4/d3/db6/tutorial\\_opening\\_closing\\_hats.html](https://docs.opencv.org/3.4/d3/db6/tutorial_opening_closing_hats.html) İndirilme tarihi 03.03.2020

Anonim (2020e). Arithmetic Operations on Images. [https://docs.opencv.org/4.5.2/d0/d86/tutorial\\_py\\_image\\_arithmetics.html](https://docs.opencv.org/4.5.2/d0/d86/tutorial_py_image_arithmetics.html) İndirilme tarihi 03.03.2020

Anonim (2021a). <https://www.tarimorman.gov.tr/sgb/Belgeler/SagMenuVeriler/TMO.pdf> İndirilme Tarihi: 21.05.2021.

Anonim (2021b). Tarımsal Veriler. Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü. [https://arastirma.tarimorman.gov.tr/tepge/Belgeler/Tar%C4%B1msal%20Veriler/TARIMSAL%20VER%C4%B0LER%20May%C4%B1s\\_2021%20internet.pdf](https://arastirma.tarimorman.gov.tr/tepge/Belgeler/Tar%C4%B1msal%20Veriler/TARIMSAL%20VER%C4%B0LER%20May%C4%B1s_2021%20internet.pdf) İndirilme Tarihi: 21.05.2021.

Anonim (2021c). Pretrained Deep Neural Networks. <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html> İndirilme Tarihi: 18.03.2021.

Ayan, E., Erbay, H. ve Varçın, F. (2020). Crop pest classification with a genetic algorithm-based weighted ensemble of deep convolutional neural networks. *Computers and Electronics in Agriculture*, 179, 105809.

Ayvaz, E. (2012). Yapay Sinir Ağları ve Paralel Akışlı Isı Eşanjörlerinde Uygulanması. Yüksek Lisans Tezi, *Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Trabzon.

Barman, U., Choudhury, R. D., Sahu, D. ve Barman, G. G. (2020). Comparison of convolution neural networks for smartphone image based real time classification of citrus leaf disease. *Computers and Electronics in Agriculture*, 177, 105661.

Bartlett, P., Freund, Y., Lee, W. S. ve Schapire, R. E. (1998). Boosting the margin: A new explanation for the effectiveness of voting methods. *The annals of statistics*, 26(5), 1651-1686.

Beddow, J. M., Pardey, P. G., Chai, Y., Hurley, T. M., Kriticos, D. J., Braun, H. J., ... ve Yonow, T. (2015). Research investment implications of shifts in the global geography of wheat stripe rust. *Nature Plants*, 1(10), 1-5.

Bengio, Y., Lamblin, P., Popovici, D. ve Larochelle, H. (2006). Greedy layer-wise training of deep networks. *In Proc. Advances in Neural Information Processing Systems 19*. Vancouver, British Columbia, Canada, 4-7 December.

Boser, B. E., Guyon, I. M. ve Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. *In Proceedings of the fifth annual workshop on Computational learning theory*. Pittsburgh Pennsylvania USA, 27-29 July.



- Braun, H.J. ve Saari, E.E. 1992. An assessment of the potential of *Puccinia striiformis* f. sp. tritici to cause yield losses in wheat on the Anatolian plateau of Turkey. *Vortr. Planzenzuchtg*, (24): 121-123.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2), 123-140.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Breiman, L., Friedman, J. H., Olshen R. A. ve Stone C. J. (1984). Classification and Regression Trees. Wadsworth International Group, Belmont, California.
- Brijain, M., Patel, R., Kushik, M. R. ve Rana, K. (2014). A survey on decision tree algorithm for classification. *International Journal of Engineering Development And Research*, 2(1).
- Chakraborty, S., Paul, S. ve Rahat-uz-Zaman, M. (2021, January). Prediction of Apple Leaf Diseases Using Multiclass Support Vector Machine. In *2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*. Dhaka, Bangladesh, 5-7 January.
- Chaudhuri, B. B. ve Sarkar, N. (1995). Texture segmentation using fractal dimension. *IEEE Transactions on pattern analysis and machine intelligence*, 17(1), 72-77.
- Chen, X. (2020). Pathogens which threaten food security: *Puccinia striiformis*, the wheat stripe rust pathogen. *Food Security*, 12(2), 239-251.
- Chen, X. M. (2005). Epidemiology and control of stripe rust [*Puccinia striiformis* f. sp. tritici] on wheat. *Canadian journal of plant pathology*, 27(3), 314-337.
- Chicco, D. (2017). Ten quick tips for machine learning in computational biology. *BioData mining*, 10(1), 1-17.
- Choi, J. Y., Ro, Y. M. ve Plataniotis, K. N. (2011). Color local texture features for color face recognition. *IEEE transactions on image processing*, 21(3), 1366-1380.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. Honolulu, HI, USA, 21-26 July.
- Choudhury, A. K. R. (2014). Unusual visual phenomena and colour blindness. İçinde Choudhury, A. K. R. (Edt.), *Principles of Colour and Appearance Measurement* (ss. 185-220). UK, Woodhead Publishing.
- Clausi, D. A. (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Canadian Journal of remote sensing*, 28(1), 45-62.
- Cortes, C. ve Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3):273–297.

Cover, T. ve Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.

Çat, A., Tekin, M., Çatal, M., Akan, K. ve Akar, T. (2017). Buğdayda sarı pas hastalığı ve dayanıklılık ıslahı çalışmaları. *Mediterranean Agricultural Sciences*, 30(2), 97-105.

De Siqueira, F. R., Schwartz, W. R. ve Pedrini, H. (2013). Multi-scale gray level co-occurrence matrices for texture description. *Neurocomputing*, 120, 336-345.

Deeba, K. ve Amutha, B. (2020). ResNet-deep neural network architecture for leaf disease classification. *Microprocessors and Microsystems*, 103364.

Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. ve Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. *2009 IEEE conference on computer vision and pattern recognition*. Miami, Florida, USA, 20 -21 June.

Dhaygude, S. B. ve Kumbhar, N. P. (2013). Agricultural plant leaf disease detection using image processing. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2(1), 599-602.

Dong, M., Mu, S., Shi, A., Mu, W. ve Sun, W. (2020). Novel method for identifying wheat leaf disease images based on differential amplification convolutional neural network. *International Journal of Agricultural and Biological Engineering*, 13(4), 205-210.

Düşünceli, F., Cetin, L., Albustan, S. ve Beniwal, S. P. S. (1996). Occurrence and impact of wheat stripe rust (*Puccinia striiformis*) in Turkey in 1994/95 crop season. *In Proceedings 9th European and Mediterranean Cereal Rusts and Powdery Mildews Conference*. Lunteren, the Netherlands, 2–6 September.

Düşünceli, F., Cetin, L., Albustan, S., Ekiz, H. (2000). Orta Anadolu buğday ekilişlerinde pas hastalıklarının (*Puccinia spp.*) yaygınlığı, önemi ve alınması gereken tedbirler. *Orta Anadolu'da Hububat Tarımının Sorunlar ve Çözüm Yollar Sempozyumu*. Konya, Türkiye, 8-11 Haziran.

Ebrahim, M., Alsmirat, M. ve Al-Ayyoub, M. (2018). Performance study of augmentation techniques for hep2 cnn classification. *In 9th International Conference on Information and Communication Systems (ICICS)*. Irbid, Jordan, 3-5 April.

Egrioglu, E., Aladag, C. H., Yolcu, U., Uslu, V. R. ve Basaran, M. A. (2009). A new approach based on artificial neural networks for high order multivariate fuzzy time series. *Expert Systems with Applications*, 36(7), 10589-10594.

El Naqa, I. ve Murphy, M. J. (2015). What is machine learning?. İçinde El Naqa, I., Li, R. ve Murphy, M. J. (Edt.), *In machine learning in radiation oncology* (ss. 3-11). Switzerland, Springer, Cham.

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318.

Fix, E. ve Hodges, J. L. (1989). Discriminatory analysis. Nonparametric discrimination: Consistency properties. *International Statistical Review/Revue Internationale de Statistique*, 57(3), 238-247.

Gedeck, P., Kramer, C. ve Ertl, P. (2010). Computational analysis of structure–activity relationships. *Progress in medicinal chemistry*, 49, 113-160.

Genaev, M., Ekaterina, S. ve Afonnikov, D. (2020, July). Application of neural networks to image recognition of wheat rust diseases. In *2020 Cognitive Sciences, Genomics and Bioinformatics (CSGB)*. Novosibirsk, Russia, 06-10 July.

Grinblat, G. L., Uzal, L. C., Larese, M. G. ve Granitto, P. M. (2016). Deep learning for plant identification using vein morphological patterns. *Computers and Electronics in Agriculture*, 127, 418-424.

Guyon, I., Boser, B. ve Vapnik, V. (1993). Automatic capacity tuning of very large VC-dimension classifiers. In *Advances in neural information processing systems*, 147-155.

Ha, C., Tran, V. D., Van, L. N. ve Than, K. (2019). Eliminating overfitting of probabilistic topic models on short and noisy text: The role of dropout. *International Journal of Approximate Reasoning*, 112, 85-104.

Haralick, R. M. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5), 786-804.

Haralick, R. M., Shanmugam, K. ve Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.

Hasan, A. M., Jalab, H. A., Meziane, F., Kahtan, H. ve Al-Ahmad, A. S. (2019). Combining deep and handcrafted image features for MRI brain scan classification. *IEEE Access*, 7, 79959-79967.

Hayit, T., Erbay, H., Varçın, F., Hayit, F. ve Akci, N. (2021). Determination of the severity level of yellow rust disease in wheat by using convolutional neural networks. *Journal of Plant Pathology*, 1-12.

He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. Las Vegas, NV, USA, 27-30 June.

Hellman, M. E. (1970). The nearest neighbor classification rule with a reject option. *IEEE Transactions on Systems Science and Cybernetics*, 6(3), 179-185.

Hinton, G. E. (2005). What kind of graphical model is the brain? In *Proc. 19th International Joint Conference on Artificial intelligence*. Edinburgh, Scotland, 30 July-5 August.

Hinton, G. E., Osindero, S. ve Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural Comp.*, 18, 1527–1554.

Ho, D., Liang, E., Chen, X., Stoica, I. ve Abbeel, P. (2019). Population based augmentation: Efficient learning of augmentation policy schedules. *In International Conference on Machine Learning*. Long Beach, CA, USA, 9-15 June.

Hossain, K. ve Parekh, R. (2010). Extending GLCM to include color information for texture recognition. *AIP Conference Proceedings*, 1298(1), 583-588.

Hovmøller, M. S. (2007). Sources of seedling and adult plant resistance to *Puccinia striiformis* f. sp. *tritici* in European wheats. *Plant Breeding*, 126(3), 225-233.

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... ve Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.

Hsu, F. H. (1999). IBM's deep blue chess grandmaster chips. *IEEE micro*, 19(2), 70-81.

Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q. (2017). Densely connected convolutional networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition*. Honolulu, HI, USA, 21-26 July.

Hussain, A., Ahmad, M. ve Mughal, I. A. (2018). Automatic Disease Detection in Wheat Crop using Convolution Neural Network. *In The 4th International Conference on Next Generation Computing*. Dehradun, India, 21-22 November.

Hylander, N. (1953). Enumeratio uredinearum scandinavicarum. *Opera Bot.*, 1, 1-102.

Jia, X. ve Meng, M. Q. H. (2017). Gastrointestinal bleeding detection in wireless capsule endoscopy images using handcrafted and CNN features. *In 2017 39th annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Jeju Island, South Korea, 11-15 July.

Jin, C., De-Lin, L. ve Fen-Xiang, M. (2009). An improved ID3 decision tree algorithm. *In 2009 4th International Conference on Computer Science & Education*. Nanning, China, 25-28 July.

Kang, U. (2021). Large Scale Data Analysis Using Deep Learning. <https://ocw.snu.ac.kr/sites/default/files/NOTE/L11-Convolutional%20Neural%20Network.pdf> İndirilme Tarihi 12.03.2021.

Kass, G. (1975). Significance Testing in Automatic Interaction Detection (A.I.D.). *Journal of the Royal Statistical Society*, 24(2), 178-189.

Kass, G. V. (1980). An exploratory technique for investigating large quantities of categorical data. *Journal of the Royal Statistical Society*, 29(2), 119-127.

Kavzoğlu, T. ve Çölkesen, İ. (2010). Karar Ağaçları İle Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği. *Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.

- Kim, K. I., Jung, K., Park, S. H. ve Kim, H. J. (2002). Support vector machines for texture classification. *IEEE transactions on pattern analysis and machine intelligence*, 24(11), 1542-1550.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kumar, D. (2020). Feature extraction and selection of kidney ultrasound images using GLCM and PCA. *Procedia Computer Science*, 167, 1722-1731.
- Larese, M. G., Namías, R., Craviotto, R. M., Arango, M. R., Gallo, C. ve Granitto, P. M. (2014). Automatic classification of legumes using leaf vein image features. *Pattern Recognition*, 47(1), 158-168.
- LeCun, Y. ve Bengio, Y. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, 3361(10).
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Lin, M., Chen, Q. ve Yan, S. (2013). Network in network. *arXiv preprint arXiv:1312.4400*.
- Lin, Z., Mu, S., Huang, F., Mateen, K. A., Wang, M., Gao, W. ve Jia, J. (2019). A unified matrix-based convolutional neural network for fine-grained image classification of wheat leaf diseases. *IEEE Access*, 7, 11570-11590.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M. vd. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- Liu, Z., Wang, L. ve Chen, K. (2020). Secure Efficient Federated KNN for Recommendation Systems. In *The International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery*, Xi'an, China, 1-3 August.
- Llamas, J., M Leronés, P., Medina, R., Zalama, E. ve Gómez-García-Bermejo, J. (2017). Classification of architectural heritage images using deep learning techniques. *Applied Sciences*, 7(10), 992.
- Lu, J., Zhou, M., Gao, Y. ve Jiang, H. (2018). Using hyperspectral imaging to discriminate yellow leaf curl disease in tomato leaves. *Precision agriculture*, 19(3), 379-394.
- Luz, J. S., Oliveira, M. C., Araujo, F. H. ve Magalhães, D. M. (2021). Ensemble of handcrafted and deep features for urban sound classification. *Applied Acoustics*, 175, 107819.

- Madasu, V. K. ve Yarlagadda, P. (2007). An in depth comparison of four texture segmentation methods. *In 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications*. Glenelg, SA, Australia, 3-5 December.
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F. ve Zhang, Y. (2018). Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery. *Remote Sensing*, 10(7), 1119.
- Maltarollo, V. G., Honório, K. M. ve da Silva, A. B. F. (2013). Applications of artificial neural networks in chemical problems. *Artificial neural networks-architectures and applications*, 203-223.
- Manjunath, B. S. ve Ma, W. Y. (1996). Texture features for browsing and retrieval of image data. *IEEE Transactions on pattern analysis and machine intelligence*, 18(8), 837-842.
- McCulloch W. S. ve Pitts W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of mathematical biophysics*, 5, pp. 115–133.
- Metre, V. ve Ghorpade, J. (2013). An overview of the research on texture based plant leaf classification. *arXiv preprint arXiv:1306.4345*.
- Misra, S., Li, H. ve He, J. (2020). Noninvasive fracture characterization based on the classification of sonic wave travel times. İçinde Misra, S., Li, H. ve He, J. (Edt.), *In Machine Learning for Subsurface Characterization* (ss. 243-287). USA, Gulf Professional Publishing.
- Mohanty, S. P., Hughes, D. P. ve Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in plant science*, 7, 1419.
- Moreno-Barea, F. J., Jerez, J. M. ve Franco, L. (2020). Improving classification accuracy using data augmentation on small data sets. *Expert Systems with Applications*, 161, 113696.
- Morgan, J. A. ve Sonquist, J. N. (1963a). Problems in the analysis of survey data: and a proposal. *J. Amer. Statist. Ass.*, 58, 415-434.
- Morgan, J. A. ve Sonquist, J. N. (1963b). Some results from a non-symmetrical branching process that looks for interaction effects. *Proc. of the Soc. States. Sec.*, 40-53.
- Mosisa, D. (2019). Applying a deep learning approach for wheat rust disease detection. Yüksek Lisans Tezi, *Adama Science and Technology University*, Ethiopia.
- Mukid, M. A., Widiharah, T., Rusgiyono, A. ve Prahutama, A. (2018). Credit scoring analysis using weighted k nearest neighbor. *Journal of Physics*, 1025(1), 012114.
- Murray, G. M., Ellison, P. J. ve Watson, A. (1995). Effects of stripe rust on the wheat plant. *Australasian Plant Pathology*, 24(4), 261-270.

Nanni, L., De Luca, E., Facin, M. L. ve Maguolo, G. (2020). Deep Learning and Handcrafted Features for Virus Image Classification. *Journal of Imaging*, 6(12), 143.

Naz, J., Sharif, M., Raza, M., Shah, J. H., Yasmin, M., Kadry, S. ve Vimal, S. (2021). Recognizing Gastrointestinal Malignancies on WCE and CCE Images by an Ensemble of Deep and Handcrafted Features with Entropy and PCA Based Features Optimization. *Neural Processing Letters*, 1-26.

Nikoo, H., Talebi, H. ve Mirzaei, A. (2011). A supervised method for determining displacement of gray level co-occurrence matrix. *7th Iranian conference on machine vision and image processing*, Iran, 16-17 Novemver.

Nisha, S. S. ve Meeral, M. N. (2021). Applications of deep learning in biomedical engineering. In *Handbook of Deep Learning in Biomedical Engineering* (pp. 245-270). Academic Press.

Oyelade, O. N. ve Ezugwu, A. E. (2021). A deep learning model using data augmentation for detection of architectural distortion in whole and patches of images. *Biomedical Signal Processing and Control*, 65, 102366.

Özcan, H., Bayramoğlu, H. O. ve Aydın, N. (2017). Buğday Tarımı. T.C. Tarım ve Orman Bakanlığı. <https://arastirma.tarimorman.gov.tr/ktae/Belgeler/brosurler/Bu%20C4%9Fday%20Tar%20C4%B1m%20C4%B1.pdf> İndirilme Tarihi: 01.04.2021.

Özsakabaşı, F. (2008). Classification of forest areas by k nearest neighbor method. Yüksek Lisans Tezi. *Ortadoğu Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.

Öztemel, E. (2006). *Yapay sinir ağları*. İstanbul, Papatya Yayıncılık.

Öztürk, K. ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.

Pantic, I., Dimitrijevic, D., Nesic, D. ve Petrovic, D. (2016). Gray level co-occurrence matrix algorithm as pattern recognition biosensor for oxidopamine-induced changes in lymphocyte chromatin architecture. *Journal of theoretical biology*, 406, 124-128.

Pardey, P. G., Beddow, J. M., Kriticos, D. J., Hurley, T. M., Park, R. F., Duveiller, E., ... ve Hodson, D. (2013). Right-sizing stem-rust research. *Science*, 340(6129), 147-148.

Peng, X., Zhang, X., Li, Y. ve Liu, B. (2020). Research on image feature extraction and retrieval algorithms based on convolutional neural network. *Journal of Visual Communication and Image Representation*, 69, 102705.

Polat, K. (2021). Tarım Ürünleri Piyasaları. Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü. <https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20Tar%20C4%B1m%20C3%9Cr%20C3%BCnleri%20Piyasalar%20C4%B1/2021-Ocak%20Tar%20C4%B1m%20C3%9Cr%20C3%BCnleri%20Raporu/Bu%20C4%9Fday,%20Ocak%202021,%20Tar%20C4%B1m%20C3%9Cr%20C3%BCnleri%20Piyasa%20Raporu.pdf> İndirilme Tarihi: 01.04.2021.

Pujara, A. (2020). Image Classification With MobileNet. <https://medium.com/analyt-ics-vidhya/image-classification-with-mobilenet-cc6fbb2cd470> İndirilme Tarihi 22.05.2021.

Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1(1), 81-106.

Ranzato, M., Poultney, C., Chopra, S. ve LeCun, Y. (2006). Efficient learning of sparse representations with an energy-based model. *In Proc. Advances in Neural Information Processing Systems 19*. Vancouver, British Columbia, Canada, 4-7 December.

Roelfs, A. P., Singh, R. P. ve Saari, E. E. (1992). *Rust diseases of wheat: concepts and methods of disease management*. Mexico, D.F.: CIMMYT.

Rosenblatt, F. (1957). The perceptron, a perceiving and recognizing automaton Project Para. *Cornell Aeronautical Laboratory*.

Rousseau, F., Drumetz, L. ve Fablet, R. (2020). Residual networks as flows of diffeomorphisms. *Journal of Mathematical Imaging and Vision*, 62(3), 365-375.

Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), 210-229.

Schlüter, N. (2019). Don't Overfit!-How to prevent Overfitting in your Deep Learning Models. <https://towardsdatascience.com/dont-overfit-how-to-prevent-overfitting-in-your-deep-learning-models-63274e552323> İndirilme Tarihi 25.05.2021.

Selvarajah, S. ve Kodituwakku, S. R. (2011). Analysis and comparison of texture features for content based image retrieval. *Energy*, 1(1).

Shapiro, L. G. ve Stockman G. C. (2001). *Computer vision*. New Jersey, ABD: Prentice Hall Inc.

Sharma, S. (2017). Activation Functions in Neural Networks. <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6> İndirilme Tarihi 25.05.2021.

Shi, B., Hou, R., Mazurowski, M. A., Grimm, L. J., Ren, Y., Marks, J. R., ... ve Lo, J. Y. (2018, February). Learning better deep features for the prediction of occult invasive disease in ductal carcinoma in situ through transfer learning. *In Medical Imaging 2018: Computer-Aided Diagnosis*. Houston, Texas, USA, 27 February.

Shrivastava, V. K., Pradhan, M. K., Minz, S. ve Thakur, M. P. (2019). Rice plant disease classification using transfer learning of deep convolution neural network. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*.

Simonyan, K. ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.



Soh, L. K. ve Tsatsoulis, C. (1999). Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices. *IEEE Transactions on geoscience and remote sensing*, 37(2), 780-795.

Sood, S. ve Singh, H. (2020). An implementation and analysis of deep learning models for the detection of wheat rust disease. In *2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)*. Coimbatore, Tamilnadu, India, 3-5 December.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.

Suthaharan, S. (2016). Support vector machine. İçinde Voß, S. ve Sharda, R. (Edt.), *In Machine learning models and algorithms for big data classification* (ss. 207-235). USA, Boston, Springer, MA.

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... ve Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. Las Vegas, NV, USA, 27-30 June.

Tang, Z., Yang, J., Li, Z. ve Qi, F. (2020). Grape disease image classification based on lightweight convolution neural networks and channelwise attention. *Computers and Electronics in Agriculture*, 178, 105735.

Tavakoli, H., Alirezazadeh, P., Hedayatipour, A., Nasib, A. B. ve Landwehr, N. (2021). Leaf image-based classification of some common bean cultivars using discriminative convolutional neural networks. *Computers and Electronics in Agriculture*, 181, 105935.

Thakur, D., Markandaiah, N. ve Raj, D. S. (2010). Re optimization of ID3 and C4. 5 decision tree. In *2010 International conference on computer and communication technology (ICCCCT)*. Allahabad, Uttar Pradesh, India, 17-19 September.

Thoma, M. (2017). Analysis and optimization of convolutional neural network architectures. *arXiv preprint arXiv:1707.09725*.

Tian, X., Ding, C. H., Chen, S., Luo, B. ve Wang, X. (2021). Regularization graph convolutional networks with data augmentation. *Neurocomputing*, 436, 92-102.

Tou, J. Y., Tay, Y. H. ve Lau, P. Y. (2009, December). Recent trends in texture classification: a review. In *Symposium on Progress in Information & Communication Technology*, 3(2), 56-59.

Udofia, U. (2021). Basic Overview of Convolutional Neural Network (CNN). <https://medium.com/dataseries/basic-overview-of-convolutional-neural-network-cnn-4fcc7dbb4f17> İndirilme Tarihi 02.03.2021.

Uppuluri, A. (2021). GLCM texture features, <https://www.mathworks.com/matlabcentral/fileexchange/22187-glcm-texture-features> İndirilme Tarihi 02.03.2021.

Üreten, K., Erbay, H. ve Maraş, H. H. (2020). Detection of rheumatoid arthritis from hand radiographs using a convolutional neural network. *Clinical rheumatology*, 39(4), 969-974.

Valev, K., Schumann, A., Sommer, L. ve Beyerer, J. (2018). A systematic evaluation of recent deep learning architectures for fine-grained vehicle classification. *International Society for Optics and Photonics*, 10649, 1064902.

Vapnik, V. (2013). *The nature of statistical learning theory*. Springer science & business media.

Vapnik, V., Golowich, S. E. ve Smola, A. (1997). Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, 281-287.

Vardhan, M. H. ve Rao, S. V. (2014). GLCM architecture for image extraction. *Int. J. Adv. Res. Electron. Commun. Eng*, 3, 75-82.

Vinoth, R., Anusha, C. H., SaiPriya, D., Sridhar, B. S., ManiKantaPavan, C. H. ve Aditya, G. (2018). A novel approach on ultrasound kidney images classification by using micro deep neural network algorithm. *International Journal of pure and applied Mathematics*, 119(12), 15047-15058.

Waheed, A., Goyal, M., Gupta, D., Khanna, A., Hassanien, A. E. ve Pandey, H. M. (2020). An optimized dense convolutional neural network model for disease recognition and classification in corn leaf. *Computers and Electronics in Agriculture*, 175, 105456.

Wang, S. H. ve Zhang, Y. D. (2020). DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 16(2s), 1-19.

Wang, Z., Li, M., Wang, H., Jiang, H., Yao, Y., Zhang, H. ve Xin, J. (2019). Breast cancer detection using extreme learning machine based on feature fusion with CNN deep features. *IEEE Access*, 7, 105146-105158.

Wei, L., Su, R., Wang, B., Li, X., Zou, Q. ve Gao, X. (2019). Integration of deep feature representations and handcrafted features to improve the prediction of N6-methyladenosine sites. *Neurocomputing*, 324, 3-9.

Wellings, C. R. (2011). Global status of stripe rust: a review of historical and current threats. *Euphytica*, 179, 129-141.

Widodo, A. ve Yang, B. S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574.

Xia, Y. (2020). Correlation and association analyses in microbiome study integrating multiomics in health and disease. *Progress in Molecular Biology and Translational Science*, 171, 309-491.

Xu, Y., Zomer, S. ve Brereton, R. G. (2006). Support vector machines: a recent method for classification in chemometrics. *Critical Reviews in Analytical Chemistry*, 36(3-4), 177-188.

Yang, X., Tridandapani, S., Beitler, J. J., Yu, D. S., Yoshida, E. J., Curran, W. J. ve Liu, T. (2012). Ultrasound GLCM texture analysis of radiation- induced parotid-gland injury in head- and- neck cancer radiotherapy: An in vivo study of late toxicity. *Medical physics*, 39(9), 5732-5739.

Yogeshwari, M. ve Thailambal, G. (2021). Automatic feature extraction and detection of plant leaf disease using GLCM features and convolutional neural networks. *Materials Today: Proceedings*.

Yurttakal, A. H., Erbay, H., İkizceli, T. ve Karaçavuş, S. (2019). Detection of breast cancer via deep convolution neural networks using MRI images. *Multimedia Tools and Applications*, 1-19.

Zadoks, J. C., Chang, T. T. ve Konzak, C. F. (1974). A decimal code for the growth stages of cereals. *Weed research*, 14(6), 415-421.

Zhang, J., Xia, Y., Xie, Y., Fulham, M. ve Feng, D. D. (2017). Classification of medical images in the biomedical literature by jointly using deep and handcrafted visual features. *IEEE journal of biomedical and health informatics*, 22(5), 1521-1530.

Zhang, W., Pogorelsky, B., Loveland, M. ve Wolf, T. (2021). Classification of COVID-19 X-ray images using a combination of deep and handcrafted features. *arXiv preprint arXiv:2101.07866*.

Zhang, X., Qiao, Y., Meng, F., Fan, C. ve Zhang, M. (2018). Identification of maize leaf diseases using improved deep convolutional neural networks. *IEEE Access*, 6, 30370-30377.

## ÖZGEÇMİŞ

Adı Soyadı : Tolga HAYIT

Doğum Tarihi :

Yabancı Dil : İngilizce

**Eğitim Durumu** :

Lisans : Ege Üniversitesi, 2010

Yüksek Lisans : Afyon Kocatepe Üniversitesi, 2016

**Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar** :

Yozgat Bozok Üniversitesi, 2013 – Devam ediyor

**Yayımları (SCI)** :

Hayit, T., Erbay, H., Varçın, F., Hayit, F. and Akci, N. (2021). Determination of the severity level of yellow rust disease in wheat by using convolutional neural networks. *Journal of Plant Pathology*, 1-12.

**Yayımları (Diğer)** :

Hayit, T. ve Ergün, U. (2016). Analysing Of Mobile Applications Developed Within The Health Sector And Sample For Patient Tracking Application For Mobile Devices. *AJIT-e*, 7(23), 97.

Hayit, T., Erbay, H. ve Hayit, F. Gıda Sektöründe Uygulanan Görüntü İşleme Çalışmalarının ve Tekniklerinin İncelenmesi. *Electronic Letters on Science and Engineering*, 14(1), 12-22.

Hayit, T. ve Özkan, A. Öğrencinin Hazırbulunuşluk Seviyesinin Belirlenmesi: Bir Mobil Uygulama Çalışması. *Uluslararası Eğitim Bilim ve Teknoloji Dergisi*, 3(3), 160-165.

Hayit, T. ve Ergün, U. (2018). Transferring Data from Glucometer to Mobile Device Via Bluetooth with Arduino Technology. *Electronic Letters on Science and Engineering*, 14(1), 1-11.

Hayıt, T. ve Dönmez, O. (2016). Üniversite Öğrencilerinin Siber Aylaklık Profilleriyle Bilişsel Kapılma Düzeyleri Arasındaki İlişkinin İncelenmesi. *Jret*, 5, 146-150.

**Araştırma Alanları**

:

Derin öğrenme, nesne sınıflama, bilgisayarla görme, görüntü işleme

