

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



İki BOYUTLU SAĞLIK, TARIM VE İŞ GÜVENLİĞİ
İMGELERİ ÜZERİNDE SINIFLANDIRMA VE NESNE TESPİTİ

Emine CENGİL

Doktora Tezi

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ARALIK 2021

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

İKİ BOYUTLU SAĞLIK, TARIM VE İŞ GÜVENLİĞİ İMGELERİ ÜZERİNDE SINIFLANDIRMA VE NESNE TESPİTİ

Tez Yazarı
Emine CENGİL

Danışman
Doç. Dr. Ahmet ÇINAR

ARALIK 2021
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı:	İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti
Yazarı:	Emine CENGİL
İlk Teslim	30.11.2021
Savunma	31.12.2021

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Ahmet ÇINAR Fırat Üniversitesi, Mühendislik Fakültesi	<i>İmza</i> Onayladım
Başkan:	Prof. Dr. Ali KARCI İnönü Üniversitesi Mühendislik Fakültesi	Onayladım
Üye:	Prof. Dr. Mehmet KAYA Fırat Üniversitesi Mühendislik Fakültesi	Onayladım
Üye:	Prof. Dr. Bilal ALATAŞ Fırat Üniversitesi Mühendislik Fakültesi	Onayladım
Üye:	Dr. Öğr. Üyesi Selman YAKUT Turgut Özal Üniversitesi Mühendislik Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Kürşat Esat ALYAMAÇ
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

31.12.2021

Emine CENGİL



ÖNSÖZ

Yapay zekâ insanlar için görme algısının doğal bir sonucu olarak ortaya çıkan basit ve sezgisel olan bazı durumları makinelerle kazaandırmayı amaç edinir. İnsanlar için doğal olan görüntüleri tanımak ve ayırt etmek gibi durumlar makineler için zorlu becerilerdir. Bu becerilerin makinelerle kazandırılması için yüksek doğruluk ve hız gereksinimlerini sağlayan yöntemlere ihtiyaç vardır. Derin öğrenme tabanlı yöntemler birçok temel makine öğrenmesi probleminde olduğu gibi görüntü sınıflandırma ve nesne bulma problemlerinin çözümünde de son teknoloji başarı gösterir. Bu tez çalışmasında, insan yaşamında dijitalleşmenin fayda sağlayacağını düşündüğümüz üç farklı alandan seçilen veri kümeleri kullanılarak derin öğrenme tabanlı sınıflandırma ve nesne bulma yaklaşımı önerilmiştir.

Yüksek lisans ve Doktora çalışmalarım süresince bilgi birikimi ve tecrübeleri ile bana yol gösteren, hoşgörüsünü esirgemeyerek yardımcı olan değerli danışman hocam Doç. Dr. Ahmet ÇINAR'a, üzerimde emeği olan tüm hocalarıma ve dostlarıma, sadece tez sürecinde değil her zaman yanımda olan kıymetli aileme sonsuz teşekkürlerimi sunarım.

Emine CENGİL
ELAZIĞ, 2021

İÇİNDEKİLER

Sayfa

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLOLAR LİSTESİ	xi
SİMGELER	xii
KISALTMALAR	xiii
1. GİRİŞ	1
1.1. Tezin Amacı ve Kapsamı	1
1.2. Tezin Organizasyonu	3
2. GÖRÜNTÜ SINIFLANDIRMA.....	4
2.1. Evrişimsel Sinir Ağı (CNN) Mimarileri	5
2.1.1. AlexNet Mimarisi.....	5
2.1.2. VGG16 Mimarisi.....	6
2.1.3. ResNet50 Mimarisi	7
2.1.4. Xception Mimarisi.....	8
2.1.5. NASNet Mimarisi	9
2.1.6. EfficientNet Mimarisi	10
2.1.7. DarkNet53 Mimarisi	11
2.1.8. ShuffleNetv2 Mimarisi.....	11
2.1.9. MobileNetv3 Mimarisi	13
2.2. Geleneksel Makine Öğrenmesi Sınıflandırıcıları.....	13
2.2.1. Destek Vektör Makinaları	14
2.2.2. K-En Yakın Komşu.....	15
2.2.3. Karar Ağaçları	15
2.2.4. Naive Bayes	16
2.2.5. Doğrusal Diskriminant Analizi	17
2.3. Aktivasyon Fonksiyonları.....	17
2.4. Başarım Ölçümünde Kullanılan Metrikler	19
2.5. Sonuç	20
3. NESNE BULMA.....	21
3.1. Derin Öğrenme Tabanlı Nesne Bulucular	21
3.1.1. İki Aşamalı Nesne Buluculardan RCNN Ailesi	22
3.1.2. Tek Aşamalı Nesne Buluculardan YOLO Ailesi	24
3.2. Başarım Ölçümünde Kullanılan Metrikler	29
3.3. Sonuç	31
4. DOMATES YAPRAĞI GÖRÜNTÜLERİNİN CNN TABANLI HİBRİT SINIFLANDIRMASI..	32
4.1. Problem Tanımı	32
4.2. İlgili Çalışmalar	33
4.3. Materyal ve Metot	34
4.3.1. Veri Kümeleri.....	35

4.3.2. Özellik Seçimi	36
4.3.3. Özellik Birleştirme	36
4.3.4. Metot	37
4.4. Deneysel Sonuçlar	38
4.5. Sonuçlar ve Tartışma	42
5. COVID-19 HASTALIK TESPİTİ ÜZERİNE BİR YAKLAŞIM.....	44
5.1. Problem Tanımı	44
5.2. İlgili Çalışmalar	45
5.3. Veri Kümeleri	46
5.4. Metot	47
5.5. Deneysel Sonuçlar	49
5.6. Sonuçlar ve Tartışma	53
6. İŞ GÜVENLİĞİNİN SAĞLANMASI İÇİN BARET TAKMA DURUMUNUN TESPİTİ.....	56
6.1. Problem Tanımı	56
6.2. İlgili Çalışmalar	56
6.3. Veri Kümesi	57
6.4. Metot	58
6.5. Deneysel Sonuçlar	59
6.6. Sonuçlar ve Tartışma	63
7. SONUÇLAR.....	65
7.1. Toplumsal/Kültürel Etkisi	66
7.2. Akademik Etkisi	66
KAYNAKLAR	67
ÖZGEÇMİŞ	

ÖZET

İki Boyutlu Sağlık, Tarım ve İş Güvenliği İmgeleri Üzerinde Sınıflandırma ve Nesne Tespiti

Emine CENGİL

Doktora Tezi

FIRAT ÜNİVERSİTESİ

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Aralık 2021, Sayfa: xiii + 76

Derin öğrenme teknolojileri, özellikle evrimsel sinir ağları görüntüler üzerinde sınıflandırma ve nesne tespiti problemlerinde yüksek doğruluk sağlar. Makine öğrenimi ve derin öğrenmeyi kapsayan yapay zekâ biliminin ilerlemesi ile beraber birçok sektörde dijitalleşme başlamıştır. Bunun yanında büyük veri kaynaklarının ulaşılabilir olması, yapay zekâ biliminin ilerlemesine ve akıllı sistemlerin kullanımının yaygınlaşmasına zemin hazırlamıştır. Bu tez çalışması, insan yaşamında birçok sektörde yapay zekânın kullanımının artışına odaklanmaktadır. Bu kapsamda üç farklı sektörde kullanılmak üzere yöntemler önerilmiştir. İlk çalışmada, domates yapraklarından hastalık tespitini gerçekleştirmek amacıyla derin öğrenme tabanlı bir yaklaşım sunulmaktadır. İkinci çalışmada, X-ray görüntüleri kullanılarak ilgili görüntünün Covid-19, normal veya zatürre olarak sınıflandırılması sağlanmaktadır. Sınıflandırmayı gerçekleştirmek için CNN tabanlı hibrit bir yöntem önerilmektedir. Son çalışmada ise başta inşaat alanları olmak üzere, iş güvenliğinin sağlanması adına baret takma durumunun tespit edilmesi için bir nesne bulma yaklaşımı ele alınmaktadır. Bu yaklaşım, bilinen tek adımlı nesne bulma algoritması Yolov5 esas alınarak önerilmektedir. Tez kapsamında gerçekleştirilen uygulamaların her biri, bir veya daha fazla açık erişimli veri kümesi ile doğrulanmıştır.

Önerilen yöntemlerde evrimsel sinir ağları esas alınmış ve başarılı sonuçlar elde edilmiştir. Yöntemlerin iyileştirilmesi konusunda spesifik verilerle yapılan uygulamalar ile literatüre katkıda bulunulmuştur. Önerilen yöntemleri gerçekleştirmek için matlab ve python gibi yazılım araçlarından yararlanılmıştır. Kullanılan metrikler ile sınıflandırma ve nesne bulma başarımları değerlendirilmiştir. Ayrıca önerilen yöntemler literatürdeki benzer çalışmalar ile kıyaslanmıştır.

Anahtar Kelimeler: Derin öğrenme, Görüntü Sınıflandırma, Nesne Bulma.

ABSTRACT

Classification and Object Detection on Two Dimensional Health, Agriculture, and Occupational Safety Images

Emine CENGİL

Ph.D. Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

December 2021, Pages: xiii + 76

Deep learning technologies, especially convolutional neural networks, provide high accuracy in classification and object detection on images. Digitalization has begun in many areas with the progress of artificial intelligence, which includes machine learning and deep learning. In addition, the availability of big data sources has paved the way for the improvement of artificial intelligence and the widespread use of smart systems. This dissertation study focuses on the increase in the use of artificial intelligence in many sectors of human life. In this context, methods are proposed to be used in three different sections. In the first study section, a deep learning-based approach is presented to perform disease detection from tomato leaves. In the second study section, X-ray images are used to classify the relevant image as Covid-19, normal, or pneumonia. A CNN-based hybrid method is proposed to perform the classification. In the last study section, an object-detection approach is discussed in order to determine the helmet-wearing situation to ensure occupational safety, especially in construction areas. This approach is proposed based on the known one-step object detection algorithm YOLOv5. Each of the implemented applications within the scope of the dissertation is validated with one or more open-access datasets.

The proposed methods are based on convolutional neural networks and successful results have been obtained. This study made a contribution to the literature with applications made with specific data on the improvement of methods. Software tools Matlab, and python was used to implement the proposed methods. Classification and object detection performances were evaluated via used the metrics. Moreover, the proposed methods were compared with similar studies in the literature.

Keywords: Deep learning, Image classification, Object detection.

ŞEKİLLER LİSTESİ

Sayfa

Şekil 2.1.	Geleneksel makine öğrenmesi ve derin öğrenme ile görüntü sınıflandırma probleminin çözümü	4
Şekil 2.2.	CNN mimarilerinin genel yapısı	5
Şekil 2.3.	AlexNet mimarisi [12]	6
Şekil 2.4.	VGG16 mimarisi [13]	7
Şekil 2.5.	Artık blok.....	7
Şekil 2.6.	ResNet 34 katmanlı ağ mimarisi [15]	8
Şekil 2.7.	Xception mimarisi [18]	9
Şekil 2.8.	NASNetLarge mimarisi [19].....	10
Şekil 2.9.	EfficientNet mimarisi [21].....	10
Şekil 2.10.	DarkNet53 mimarisi [23].....	11
Şekil 2.11.	ShuffleNetv2 blok diyagramı.....	12
Şekil 2.12.	MobileNetv3 mimarisi [31]	13
Şekil 2.13.	Üç sınıflı sınıflandırma için SVM.....	14
Şekil 2.14.	Bir karar ağacı görünümü [41].....	16
Şekil 2.15.	Karmaşıklık matrisi ve performans metrikleri	20
Şekil 3.1.	Tek ve iki adımlı nesne bulucuların gösterimi [61]	21
Şekil 3.2.	RCNN mimarisi [63]	22
Şekil 3.3.	Fast RCNN mimarisi [64].....	23
Şekil 3.4.	Faster RCNN mimarisi [65].....	24
Şekil 3.5.	4x4 grid hücrendeki bir sınırlayıcı kutu için parametreler	25
Şekil 3.6.	Bir YOLO modelinde etiket vektörü y, 4 sınıf için nesne tahmini	26
Şekil 3.7.	YOLOv1 mimarisi [76]	27
Şekil 3.8.	YOLOv5 mimarisi [81]	29
Şekil 4.1.	Geç yanıklık hastalığına yakalanmış olan domates bitkisinin (a) Meyve ve (b) Yaprak görüntüsü [87].....	32
Şekil 4.2.	Tomato leaf disease detection veri kümesinden alınmış örnek görüntüler [105].....	35
Şekil 4.3.	Taiwan tomato leaves veri kümesinden alınmış örnek görüntüler ve görüntü sayıları [106] ..	36
Şekil 4.4.	Önerilen yöntemin grafiksel özeti.....	37
Şekil 4.5.	(a) ResNet50-1000 &LDA (Tomato leaf disease detection veri kümesi) ve (b) AlexNet-1000&k-NN (Taiwan tomato leaves veri kümesi) modellerin karmaşıklık matrisleri	39

Şekil 4.6.	AlexNet+ResNet50+VGG16, mRMR ve QSVM modelinin karmaşıklık matrisi (Tomato leaf disease detection veri kümesi)	40
Şekil 4.7.	AlexNet+ResNet50+VGG16, mRMR ve k-NN modelinin karmaşıklık matrisi (Taiwan tomato leaves veri kümesi)	41
Şekil 4.8.	AlexNet+Resnet50+VGG16 ve LDA modelinin karmaşıklık matrisi (Tomato leaf disease detection veri kümesi).....	42
Şekil 5.1.	Kullanılan veri kümelerinden örnek görüntüler	47
Şekil 5.2.	Önerilen yaklaşımın basit blok diyagramı	48
Şekil 5.3.	Önerilen yöntemin grafiksel özeti.....	48
Şekil 5.4.	EfficientNet-B0 + LDA ile COVID-19 Image veri kümesi için karmaşıklık matrisi ve başarımların metrik değerleri.....	50
Şekil 5.5.	EfficientNet- B0 + LDA ile COVID-19 Pneumonia Normal Chest X-ray (PA) veri kümesi için karmaşıklık matrisi ve başarımların metrik değerleri.....	50
Şekil 5.6.	EfficientNet- B0 + LDA ile COVID-19 Radiography veri kümesi için karmaşıklık matrisi ve başarımların metrik değerleri	50
Şekil 5.7.	(a) COVID-19 image, (b) COVID-19 Pneumonia Normal Chest X-ray (PA) ve (c) COVID-19 Radiography veri kümelerinde en iyi sonuçları sağlayan modellerin karmaşıklık matrisleri ..	52
Şekil 6.1.	Hard Hat Workers veri kümesinden alınmış örnek görüntüler [160].....	58
Şekil 6.2.	Önerilen boru hattının kaba şekli	58
Şekil 6.3.	Uygulanan yöntemin grafiksel özeti	59
Şekil 6.4.	Modelin kesinlik eğrisi ve hatırlama eğrisi	60
Şekil 6.5.	MobileNetv3 ağının omurga olarak dahil edildiği yöntemin kesinlik eğrisi ve hatırlama eğrisi	60
Şekil 6.6.	Omurga ağı olarak a) ShuffleNetv2 ve b) MobileNetv3 mimarisinin kullanıldığı modellere ait Kesinlik-Hatırlama eğrileri	61
Şekil 6.7.	a) ShuffleNetv2 ve b) MobileNetv3 mimarisinin kullanıldığı modellere ait bazı doğru bulunmuş görüntü örnekleri	61
Şekil 6.8.	a) ShuffleNetv2 ve b) MobileNetv3 mimarisinin kullanıldığı modellerin uygulandığı bazı test görüntülerinin kıyaslanması.....	62

TABLolar LİSTESİ

	Sayfa
Tablo 2.1. Dört farklı karmaşıklık düzeyi için genel ShuffleNetv2 mimarisi [24]	12
Tablo 2.2. Sıklıkla kullanılan bazı aktivasyon fonksiyonları	18
Tablo 4.1. Temel mimarilerin sınıflandırma doğrulukları (%).....	38
Tablo 4.2. Tomato leaf disease detection veri kümesi için mRMR uygulanmış modellerin sınıflandırma doğrulukları (%).....	39
Tablo 4.3. Taiwan veri kümesi için mRMR uygulanmış modellerin sınıflandırma doğrulukları (%)	39
Tablo 4.4. AlexNet+ResNet50+VGG16 özellikleri ve farklı sınıflandırıcılar ile oluşturulan modellere ait başarımlar değerleri (Tomato leaf disease detection veri kümesi)	41
Tablo 4.5. AlexNet+ResNet50+VGG16 ve LDA modelinin sınıflandırma sonuçları (Tomato leaf disease detection veri kümesi) (%).....	42
Tablo 4.6. Konuyla ilgili yapılmış çalışmalar ile önerilen yöntemin karşılaştırılması.....	43
Tablo 5.1. Eğitim ve doğrulama süreçlerinde kullanılan veri kümelerinin içerdiği sınıflar ve görüntü sayıları	47
Tablo 5.2. Modellerin uygulandıkları veri kümelerine göre sınıflandırma doğruluğu (%)	49
Tablo 5.3. İki mimariden alınan özelliklerin birleştirilmesiyle oluşturulan özellik kümelerinin deneysel sonuçları (COVID-19 Image veri kümesi).....	51
Tablo 5.4. Üç mimariden alınan özelliklerin birleştirilmesiyle oluşturulan özellik kümelerinin deneysel sonuçları (COVID-19 Image veri kümesi).....	52
Tablo 5.5. Dört mimariden alınan özelliklerin birleştirilmesiyle oluşturulan özellik kümelerinin deneysel sonuçları	53
Tablo 5.6. Önerilen yaklaşımın diğer yaklaşımlar ile kıyaslanması.....	54
Tablo 6.1. Baret tespiti ile ilgili yapılmış bazı çalışmalar ile önerilen yöntemin kıyaslanması	63

SİMGELER

a	: Giriş değeri
β	: Doğrusal model katsayısı
b	: Sapma
B	: Sınırlayıcı kutu
BB_t	: Tahmin edilen sınırlayıcı kutu
BB_{yg}	: Yer gerçeği sınırlayıcı kutu
C	: Sınıf
$C1, C2$	: Kovaryans matrisler
$f(a)$	: Çıkış değeri
h	: Yükseklik
K	: Havuzlanmış kovaryans matrisi
S	: Seçilen özellik kümesi
$ S $	: Özellik kümesinin boyutu
x	: Girdi vektörü
w	: Genişlik
W	: Ağırlık vektörü
μ_1, μ_2	: Ortalama vektörler

KISALTMALAR

ACC	: Accuracy (Doğruluk)
AUC	: Area Under Curve (Eğrinin Altındaki Yüksek Bir Alan)
AP	: Average Precision (Ortalama Kesinlik)
BN	: Batch Normalization (Yığın Normalleştirme)
BT	: Bilgisayarlı Tomografi
CONV	: Convolution (Evrişim)
Covid-19	: SARS-CoV-2
CSP	: Cross Stage Partial (Çapraz Aşamalı Kısmi Ağı)
SVM	: Support Vector Machine (Destek Vektör Makinası)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağları)
F1	: F1 Score (F1 Puanı)
FCD	: F-test Correlation Difference (F-test Korelasyon Farkı)
FCQ	: F-test Correlation Quotient (F-test Korelasyon Katsayısı)
FLOPs	: Saniyede Kayan Nokta İşlemleri
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Doğru Negatif)
FPN	: Feature Pyramid Network (Özellik Piramit Ağı)
GPU	: Graphics Processing Unit (Grafik İşlemci Birimi)
IoU	: Intersection Over Union (Birleşim Üzerinde Kesişim)
K-NN	: K- Nearest Neighbor (k- En Yakın Komşu)
LDA	: Linear Discriminant Analysis (Doğrusal Diskriminant Analizi)
LReLU	: Leaky Rectified Linear Unit(Sızıntı Doğrultulmuş Doğrusal Birim)
LSTM	: Long-Short Term Memory (Uzun-Kısa Vadeli Hafıza Ağları)
MAP	: Mean Average Precision (Ortalama Kesinlik Değerlerinin Ortalaması)
MID	: Mutual Information Difference (Karşılıklı Bilgi Farkı)
MIQ	: Mutual Information Quotient (Karşılıklı Bilgi Bölümü)
mRMR	: Minimum Redundancy Maximum Relevance (Minimum Artıklık Maksimum Uygunluk)
NB	: Naive Bayes
NMS	: Non-Max Suppression (Maksimum-Olmayan Bastırma)
PAN	: Path Aggregation Network (Yol Toplama Ağı)
PREC	: Precision (Kesinlik)
RCNN	: Region-Based Convolutional Neural Network (Bölge-Tabanlı Evrişimsel Sinir Ağları)
ReLU	: Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RPN	: Region Propose Network (Bölge Öneri Ağı)
SN	: Sensitivity (Hatırlama)
SP	: Specifity (Özgüllük)
SPP	: Spatial Pyramid Pooling (Uzamsal Piramit Havuzlama)
SSD	: Single Shot Multibox Detector(Tek Atış Çoklu Kutu Algılama)
TanH	: Hiperbolik Tanjant
TN	: True Negative (Doğru Negatif)
TP	: True Positive (Doğru Pozitif)
YOLO	: You Only Look Once(Sadece Bir Kez Bak)
X-ray	: Röntgen

1. GİRİŞ

Yapay zekâ, insan ayrıcalığı olarak kabul edilen durumları yaratıcı bir şekilde çözebilen akıllı programlar ve makineler oluşturma yollarını araştıran bir bilimdir. Tanıma ve ayırt etme gibi durumlar, insanlar için görme algısının bir sonucu olarak sağlanan basit ve sezgisel durumlardır. Makineler için ise tanımak ve ayırt etmek zorlu becerilerdir. Yapay zekâ makinelere bu gibi problemlerin çözümü için insansı özellikler kazandırmayı amaç edinmektedir [1].

Makine öğrenimi, bilgisayarların, açıkça programlanmadan bir görevi gerçekleştirmek için algoritmalar kullanarak verilerden öğrenmesi anlamına gelir ve yapay zekânın bir alt kümesidir. Makine öğrenmesinde, sorunları çözmeye yardımcı olan farklı algoritmalar vardır. Derin öğrenme insan sinir sistemine benzer bir yapı ile farklı faktörleri analiz etmek için sinir ağlarını kullanan bir makine öğrenimi alt kümesidir [2]. Genel olarak derin öğrenme olarak adlandırılmış çok katmanlı birden fazla yapı bulunmaktadır. Bunlardan en çok kullanılanlarından birisi olan evrimsel sinir ağları, birçok makine öğrenmesi probleminde başarılı çözümler üretmektedir. Görüntü sınıflandırma ve nesne bulma yaygın olarak çözülmeye çalışılan problemlerden ikisidir.

Evrimsel ağlar, problemin çözümü için gerekli olan özelliklerin çıkartılması işlemini otomatik olarak yapmaktadır. Bu, evrimsel ağların en önemli özelliklerindendir. Geleneksel makine öğrenmesi yöntemlerinde özelliklerin çıkartılması işlemi otomatik olarak yapılmaz. Bu yöntemlerde uzman bilgisi gereklidir. Evrimsel sinir ağı mimarileri, büyük veri kümeleri ile eğitilebilir ve GPU desteği sağlanabilir [3]. Bu gibi avantajlar sayesinde Evrimsel sinir ağları yöntemlerinin her geçen gün iyileştirilmesi ile birlikte yapay zekâ da gelişmektedir. Bununla birlikte insan yaşamındaki hemen hemen her alanda yapay zekâ teknolojileri ile dijitalleşme görülmektedir. Bu alanlara, sağlık, güvenlik, eğitim, ulaşım, tarım ve hayvancılık örnek olarak gösterilebilir.

1.1. Tezin Amacı ve Kapsamı

Bu tez çalışması, yapay zekânın geldiği noktada derin öğrenme teknolojilerinin etkisine odaklanmaktadır. Bu amaçla makine öğrenmesinin temel problemleri olan görüntü sınıflandırma ve nesne bulma konuları incelenmiştir. Her iki konu ilgilendikleri alanlar bakımından oldukça kapsamlı konulardır. Sağlık, inşaat ve tarım sektörleri bu alanlara örnek olarak gösterilebilir [4].

Bu tez çalışmasında derin öğrenme teknikleri temel alınarak üç uygulama gerçekleştirilmiştir. Bu kapsamda gerçekleştirilen ilk çalışma, domates bitkisinin yapraklarından belirli hastalıkların sınıflandırılmasıdır. Domates, yetiştirilme sürecinin her safhasında çevresel ve iklimsel faktörlere bağlı olarak birçok hastalığa yakalanabilir [5]. Bu hastalıkların erken safhalarda fark edilmesi, ürünün tedavi edilerek kalitesinin artırılması açısından önemlidir. Domatesin

yaprakları, hastalıkla alakalı belirtiler gösterir. Bu yüzden hastalığın tespiti için yapraklardaki benek ve nokta gibi belirtilerden yararlanılabilir. Özellikle büyük tarım alanlarında domates yetiştiricilerinin bu hastalıkları belirlemek için sıklıkla yaprakları izlemeleri zordur. Dolayısıyla hastalıkların tespiti için otomatik sistemlerin kullanımı faydalı olmaktadır. Önerilen yöntemde Evrişimsel Sinir Ağları (CNN) mimarileri, özellik çıkartma algoritması, özellik birleştirme yöntemi ve sınıflandırma algoritmaları ile yeni mimariler sunulmuştur. İki farklı kamuya açık veri kümesi ile eğitim ve doğrulama işlemleri gerçekleştirilmiştir. Performans ölçüm kriterleri ile değerlendirilen yöntem, ilgili veri kümelerinde literatürdeki benzer çalışmalara kıyasla yüksek doğruluk sağlamıştır.

Tez kapsamında gerçekleştirilen diğer bir çalışma ise 2019 yılının sonlarında ortaya çıkan Covid-19 hastalığının sınıflandırılmasıdır. Bu amaçla X-ray görüntüleri kullanılmıştır. Covid-19 hastalığı diğer akciğer enfeksiyonlarına benzemektedir [6]. Bu durum, teşhisi zorlaştırmaktadır. Ayrıca virüsün hızla yayılması, vakaların bir an önce tespit edilmesini zorunlu kılmaktadır. Gereksinimleri sağlamak için bilgisayar destekli derin öğrenme modellerinin kullanımı yararlıdır. Önerilen yöntemde, farklı ön-eğitilmiş CNN mimarileri özellik aktarım yöntemi ile kullanılmıştır. Ayrıca, özellik birleştirme yöntemi ve geleneksel makine öğrenimi tekniklerinin kullanıldığı hibrit model üç farklı veri kümesi ile analiz edilmiştir. Önerilen yöntemin Covid-19 hastalığını sınıflandırmada kullanımının faydalı olacağı görülmüştür.

Tez kapsamında gerçekleştirilen ilk iki yaklaşım, sınıflandırma probleminin çözümüne odaklanmaktadır. Son çalışmada ise iş güvenliği alanında kullanılabilecek bir nesne bulma probleminin çözümü gerçekleştirilmiştir. İnşaatlar, iş kazalarının çok olduğu alanlardandır. Buna bağlı olarak yaralanma ve ölümler olmaktadır. Bu durumun önlenmesi ya da en aza indirilebilmesi için güvenli bir iş ortamının sağlanması gereklidir. Çalışanların karşı karşıya kaldığı ciddi ölüm ve yaralanmaları, genelde kafaya alınan hasarlardan kaynaklanır [7]. Böyle durumlarda, kişilerin güvenliği baret takmaları ile sağlanabilir. Çalışmada, kişilerin baret takma durumlarının tespit edilmesi için derin öğrenme tabanlı bir nesne bulma yaklaşımı önerilir. Hız ve doğruluk kriterlerinin önemli olduğu yaklaşımda hafif ve doğruluğu yüksek bir model sunulmuştur. Eğitim, doğrulama ve test işlemleri için açık erişimli bir veri kümesi kullanılmıştır. Model, literatürdeki benzer çalışmalar ile kıyaslanmıştır. Ayrıca, nesne bulma yaklaşımlarının başarımlarında kullanılan metrikler ile değerlendirilen model, yüksek başarımlar sağlamıştır. Elde edilen sonuçlar, önerilen yaklaşımın, şantiyelerde baret takılıp takılmadığını kontrol etmek için kullanımının uygun olduğunu göstermiştir.

1.2. Tezin Organizasyonu

Bu tez çalışması, yedi bölümden oluşmaktadır. Tezin organizasyonu şu şekildedir. Birinci bölüm giriş bölümü olup; tezin amacı, kapsamı ve katkıları özetlenmiştir.

İkinci bölümde, makine öğrenmesinin temel problemlerinden olan görüntü sınıflandırma konusu incelenmiştir. Sıklıkla kullanılan evrimsel sinir ağı modelleri, geleneksel makine öğrenmesi sınıflandırıcıları, aktivasyon fonksiyonları ve sınıflandırma problemlerinde kullanılan başarı ölçüm metrikleri anlatılmıştır.

Üçüncü bölümde, nesne bulma problemi anlatılmıştır. Genelde tek ve iki adımlı olarak sınıflandırılan derin öğrenme tabanlı nesne buluculara yer verilmiştir. Ayrıca, nesne bulma problemlerinin çözümünde kullanılan yöntemlerin başarı ölçütünde esas alınan metrikler sunulmuştur.

Dördüncü bölümde, domates yapraklarından hastalık tespitinin yapıldığı sınıflandırma çalışmasına yer verilmiştir. Altı ve on sınıflı iki farklı açık erişimli veri kümesi ile modeller eğitim ve test işlemlerine tabi tutulmuştur. Elde edilen sonuçlar raporlanmıştır. Ayrıca literatürdeki benzer çalışmalar geliştirilen yöntem ile karşılaştırılmıştır.

Beşinci bölüm, X-ray görüntülerinden Covid-19 hastalığının ayırt edildiği sınıflandırma çalışmasını kapsar. Sınıflandırma, her biri üç sınıftan oluşan üç farklı veri kümesi ile gerçekleştirilmiştir. Veri kümeleri ile elde edilen sonuçlar analiz edilmiştir. Önerilen yöntem, literatürdeki benzer çalışmalar ile ayrıntılı olarak kıyaslanmış ve tartışılmıştır.


Altıncı bölümde, iş güvenliğinin sağlanması için baret takma durumunun tespit edildiği nesne bulma yaklaşımı sunulmuştur. Bu bölümde yöntemin eğitim, test ve doğrulama işlemleri için üç sınıflı açık erişime sahip bir veri kümesi kullanılmıştır. Tavsiye edilen model ile yine hafif bir ağ yapısına sahip olan başka bir modele ait analiz sonuçları verilmiştir. Elde edilen sonuçlar değerlendirilmiştir.

Yedinci bölüm, tezin son bölümüdür. Tezin sonuçlarına bu bölümde yer verilmiştir. Yöntem önerilerinin olduğu dördüncü, beşinci ve altıncı bölümde yöntemlere ait sonuçlar verilmiştir. Dolayısıyla bu bölümde ayrıca detaylı olarak yöntem sonuçları verilmemiştir. Bu bölümde tezin genel bir değerlendirmesi yapılmıştır.

2. GÖRÜNTÜ SINIFLANDIRMA

Görüntülerin sınıflandırılması bilgisayar görmesi alanında bilinen temel görsel tanıma problemlerindendir. Görüntü veya video üzerinden ilgili nesne veya nesnelerin sadece sınıfının belirlenmesi, sınıflandırma işlemi olarak adlandırılır. Başka bir deyişle herhangi bir sınıfa ait olmayan görüntülerin sınıflarına dâhil edilmesini sağlama sürecidir. Görüntü sınıflandırma oldukça kapsamlı bir görüntü işleme konusudur. Birçok insanın yaşamının her alanında kullandığı bir teknolojidir [8].

Son yıllarda, sınıflandırma problemlerinin çözümünde geleneksel makine öğrenme algoritmalarının yerini derin öğrenme yaklaşımları almıştır. Görüntü sınıflandırma uygulamalarında kullanışlı özneteliklerin sağlanması önemlidir. Evrişimsel sinir ağları, eğitim sırasında çıkarılan özellikleri otomatik olarak öğrenen yapılardır [9]. Şekil 2.1, sınıflandırma problemlerinin geleneksel makine öğrenmesi ve derin öğrenme yöntemleri ile çözümünün genel bir çizimini göstermektedir.




Şekil 2.1. Geleneksel makine öğrenmesi ve derin öğrenme ile görüntü sınıflandırma probleminin çözümü

Tezin bu bölümünde, önerilen yöntemlerde kullanılmış olan bilinen evrişimsel sinir ağı mimarileri, geleneksel makine öğrenmesi sınıflandırıcıları, aktivasyon fonksiyonları ve sınıflandırma problemlerinin başarı analizinde kullanılan başarı ölçütlerine yer verilmiştir.

2.1. Evrişimsel Sinir Ağı (CNN) Mimarileri

Genel olarak derin öğrenme diye isimlendirilmiş mimarilerden olan evrişimsel sinir ağları, ortaya çıktığı günden bugüne çeşitli problemlerin çözümünde çokça tercih edilmektedir. Temelde evrişim, havuzlama, aktivasyon ve tam bağlı katmandan oluşan bu ağlar çeşitli yollarla iyileştirilerek yeni modeller geliştirilmiştir [10]. Şekil 2.2, evrişimsel sinir ağı mimarilerinin basit bir grafiksel temsilini vermektedir.



Şekil 2.2. CNN mimarilerinin genel yapısı

Evrişim katmanının birincil amacı, girdi görüntüsünden öznitelikleri çıkarmaktır. Evrişim, girdi verisinin küçük karelerini kullanarak görüntü özelliklerini öğrenir. Böylece pikseller arasındaki mekânsal ilişkiyi korur. Evrişimsel ağlar mimarisinde, birbiri ardına evrişim katmanları arasında periyodik olarak bir havuzlama katmanı eklemek sık görülür. Bu kısımda havuzlama katmanının yerini alt-örnekleme katmanının aldığı modeller de bulunmaktadır. Havuzlama katmanının işlevi, ağdaki parametrelerin ve hesaplamaların miktarını azaltmak ve dolayısıyla aşırı uygunluğu kontrol etmek için temsilin uzamsal boyutunu aşamalı olarak azaltmaktır.

Evrişim ve havuzlama katmanlarının sonucunda oluşan çıkış, giriş görüntüsünün üst düzey özelliklerini temsil eder. Tam bağlı katman, neredeyse tüm sinir ağlarında bulunur. Genellikle çıktı katmanının boyutunu ve şeklini kontrol etmek için kullanılır [11].

Problem çözümünde daha iyiye gitmek adına geliştirilen modeller standartlaşmış açık erişimli veri kümeleri ile test edilerek başarımlarını doğrulamışlardır. Tez çalışmasında bu modellerden bazıları kullanılmıştır.


2.1.1. AlexNet Mimarisi

Evrişimsel sinir ağlarının dikkat çekmesi ve çok çalışılan bir konu haline gelmesi AlexNet ağının tanıtıldığı görüntü sınıflandırma yarışması olan ImageNet Large-Scale Visual Recognition Challenge (ILSVRC) 2012'ye dayanmaktadır. Alex Krishevsky ve arkadaşları tarafından sunulan mimari 1000 sınıftan oluşan yaklaşık 1,2 milyon görüntüyü diğer katılımcılara göre en doğru olarak

sınıflandırılmıştır [12]. Bu sayede dikkatler CNN mimarilerine çevrilmiştir. Her yıl düzenlenen görüntü sınıflandırma yarışmasına CNN mimarileri ile katılım artarak devam etmiştir. Ayrıca sınıflandırmadaki başarısı gözler önüne serilen ağlar başka alanlarda da sınıflandırma problemlerinin çözümünde sıklıkla kullanılmaya başlanmıştır ve hala kullanılmaktadır.

Krishevsky'nin AlexNet'i, onbir katmandan meydana gelmektedir. İlk iki katmanı evrişim+maksimum havuzlama+normalizasyon, üç ve dördüncü katmanlar evrişim, beşinci katman evrişim+maksimum havuzlama, altı ve yedinci katmanlar tam bağlantılı katman ve son katman sınıflandırma işlemi yapan softmax'dir.

Evrişim işlemi yapılırken ilk katmanda 11x11 boyutlu 96 filtre kullanılmaktadır. Adım sayısı 4 olarak belirlenen ağda evrişim işlemi sonucu görüntü boyutu 55x55 olmaktadır. Modeldeki ilk havuzlama katmanında 3x3 boyutlu filtreler kullanılmaktadır. İşlem sonrası görüntü boyutu 27x27 olmaktadır. Bundan sonraki devam eden katmanlarda aynı işlemler tekrarlanır. Tam bağlı katmandaki her nöron bir sınıfı temsil etmektedir. Yöntemde 1000 görüntü için sınıflandırma yapıldığından son katmanda 1000 tane nöron bulunmaktadır. Şekil 2.3'de AlexNet mimarisi gösterilmektedir.




Şekil 2.3. AlexNet mimarisi [12]

2.1.2. VGG16 Mimarisi

AlexNet'in başarısı sonrasında ağa benzer birçok mimari önerilmiştir. AlexNet'in önceki türevlerinin aksine VGG, derinlik yönünü esas almıştır. ILSVRC-2014'de sunulan ünlü modellerden birisidir [13]. Model, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan bir veri kümesi olan ImageNet'te %92,7 oran ile ilk 5 test doğruluğuna ulaşmıştır. Veri artırma yöntemlerinden birinin kullanıldığı yapıda her evrişim katmanından sonra aktivasyon fonksiyonu olarak Doğrultulmuş Doğrusal Birim (ReLU) kullanılmaktadır.

VGG, 11x11 ve 5x5 filtreleri, 3x3 filtre katmanından oluşan bir yığınla değiştirmiştir. Küçük boyutlu filtrelerin kullanılması, parametre sayısını azaltarak düşük bir hesaplama karmaşıklığı sağlar. Ağda toplam beş blok vardır. İlk iki blok iki evrişim katmanına sahiptir. Her birinin ardından


ReLU aktivasyonu ve Maksimum havuzlama katmanı; son üçünde üç evrişim katmanı ve ardından her biri için ReLU aktivasyonu ve Maksimum havuzlama katmanı bulunur. Şekil 2.4, VGG16 mimarisinin şekilsel gösterimini sunmaktadır.



Şekil 2.4. VGG16 mimarisi [13]


2.1.3. ResNet50 Mimarisi

ResNet, He Kaiming ve diğerleri tarafından 2015 yılında önerilmiştir [14]. ILSVRC yarışmasının 2015 yılındaki kazananıdır. CNN’de artık öğrenme kavramını tanıtarak CNN mimari yarışında devrim yapmıştır ve derin ağların eğitimi için etkili bir yöntem tasarlamıştır. Derinlik arttıkça eğitim doğruluğunun artması beklenirken azaldığı yani aşırı uyumun olduğu görülmüştür. Aşırı uyum, eğitim doğruluğunun yüksek test doğruluğunun ise düşük olması durumudur [15]. Derinlik arttıkça ağı en iyi hale getirilmesi zorlaşmaktadır. Bu sorunun üstesinden gelmek amacıyla önerilen artık sinir ağı, bir ağ oluşturmak için artık blokları üst üste istifleyen bir tür yapay sinir ağıdır. Şekil 2.5 artık bloğun bir temsili göstermektedir. Burada a girişi, çıkışa doğrudan eklenir. Kısa yol veya atlama bağlantısı olarak bilinen bu durum $f(a)+a$ olarak verilmiştir.



Şekil 2.5. Artık blok


Derinliğine rağmen ResNet daha önce önerilen ağlardan daha az hesaplama karmaşıklığı göstermiştir. Bunun yanında hata oranı azaltılmıştır. ResNet'in aynı kavram üzerinde çalışan ancak farklı sayıda katmana sahip birçok çeşidi vardır. ResNet50, ResNet mimarisinin elli sinir ağı katmanı ile çalışabilen varyantı belirtir. Şekil 2.6, ResNet'in 34 katmanlı ağ yapısını verir. Burada ağdaki her iki katman bloğunu üç katmanlı darboğaz katmanı ile değiştirilmesi ile oluşan ResNet ağının yapısı gösterilmektedir.



Şekil 2.6. ResNet 34 katmanlı ağ mimarisi [15]

2.1.4. Xception Mimarisi


Xception [16] modeli, 2017'de Francois Chollet tarafından önerilmiştir. Model, derinlemesine ayrılabilir evrişim katmanlarına dayanmaktadır. Inception [17] mimarisindeki "inception" modülleri ile derinlemesine ayrılabilir (deeptwise seperable) evrişimlerin değiştirilmiş bir uzantısıdır. Tamamen evrişimsel bir sinir ağı mimarisidir. Kanallar arası korelasyonların ve uzaysal korelasyonların, evrişimsel sinir ağlarının özellik haritalarında haritalanması, tamamen ayrıştırılabilir hipotezi gerçekleştirilmiştir. Bu hipotez, Inception mimarisinin altında yatan hipotezin daha güçlü bir versiyonu olduğu için, "Extreme Inception" anlamına gelen mimariye Xception adı verilmiştir. Mimarinin grafiksel gösterimi Şekil 2.7'de verildiği gibidir.



Şekil 2.7. Xception mimarisi [18]

2.1.5. NASNet Mimarisi

NASNet (Neural Search Architecture Network) [19], Google Brain tarafından önerilmiştir. NASNet'in temel ilkeleri AlexNet gibi standart mimarilerden farklı bir mimariye sahiptir. NAS'ın genel kuruluşu arama alanı, arama stratejisi ve performans tahmini bileşenlerini içermektedir. Yazarlar, küçük bir veri kümesinde bir mimari yapı bloğu aramayı ve ardından bloğu daha büyük bir veri kümesine aktarmayı önermektedir. Özellikle, önce CIFAR-10 veri kümesinde, en iyi evrimsel katmanı veya hücreyi ararlar. CIFAR-10'da, sınıf başına 6000 görüntü olmak üzere 10 sınıfta toplam 50000 eğitim görüntüsü ve 10000 test görüntüsü vardır. Veri kümesi, her biri 10000 görüntü içeren beş eğitim grubuna ve bir test grubuna bölünmüştür. Test grubu, her sınıftan tam olarak rastgele seçilmiş 1000 görüntü içerir. Eğitim grupları rastgele sırada kalan görüntüleri içerir, ancak bazı eğitim gruplarındaki bir sınıfta diğerinden daha fazla görüntü bulunabilir. Bunların arasında, eğitim grupları her sınıftan tam olarak 5000 görüntü içerir [20]. Daha sonra bu hücreyi, bu hücrenin daha fazla kopyasını bir araya getirerek ImageNet'e uyguladılar. NASNet modeli, daha küçük model boyutu ve daha düşük karmaşıklık ile son teknoloji sonuçlara ulaşır. Şekil 2.8, NASNet large modelinin mimarisini göstermektedir.




Şekil 2.8. NASNetLarge mimarisi [19]

2.1.6. EfficientNet Mimarisi

EfficientNet [21] Tan ve Le tarafından önerilmiştir. Daha iyi bir performans elde etmek için birleşik ölçeklendirme yöntemi benimsenmiştir. EfficientNet önerilmeden önce araştırmacılar tarafından ağın genişliği, derinliği ve görüntünün çözünürlüğü ağ performansını arttırmak için ölçeklendirmeye çalışılmıştır. Fakat tüm bu boyutların nasıl dengeleneceği tanımlanmamıştır. Bu gözleme dayanarak, bir bileşik katsayısı kullanarak tüm derinlik / genişlik / çözünürlük boyutlarını eşit şekilde ölçekleyen yeni bir ölçeklendirme yöntemi önerilmiştir.


EfficientNet ağında mobil ters çevrilmiş darboğaz evrişimi (MBconv) blokları kullanılmıştır. Bu bloklar, kanalları ilk olarak genişleterek ardından sıkıştıran bir katmandan meydana gelmektedir. Bu sayede daha az kanala sahip katmanlar atlanarak bağlanır. Tüm EfficientNet modelleri, farklı bileşik katsayıları kullanılarak temel EfficientNet-B0'dan ölçeklenir [21]. Şekil 2.9, EfficientNet modelinin mimarisini vermektedir.



Şekil 2.9. EfficientNet mimarisi [21]

2.1.7. DarkNet53 Mimarisi

Darknet, C ve CUDA ile yazılmış açık kaynaklı bir sinir ağı çerçevesidir. Darknet53, YOLO (You Only Look Once, Sadece Bir Kez Bak) hedef tespit ağının üçüncü sürümü olan YOLOv3’de kullanılmış temel özellik çıkarma ağıdır [22]. Bu ağ modeli, ardışık 1×1 ve 3×3 evrişim katmanları ve artıkları kullanarak ResNet ve YOLOv2 temel özellik çıkarma ağı Darknet-19’u birleştirmektedir. Evrişim katmanı, Yığın Normalleştirme (BN) katmanı ve Sızıntı ReLU (Leaky ReLU) katmanı birlikte en küçük bileşenini oluşturur. Model, 53 tanesi evrişim olmak üzere 75 katmandan oluşmaktadır. Şekil 2.10, Darknet53 mimarisini vermektedir.




Şekil 2.10. DarkNet53 mimarisi[23]

2.1.8. ShuffleNetv2 Mimarisi

ShuffleNetv2 [24], çok sınırlı hesaplama gücüne sahip mobil cihazlar için özel olarak tasarlanmış hesaplama açısından verimli bir evrişim mimarisidir. ShuffleNet modeli, artık bir yapıdır ve darboğaz yapısını içermektedir. Diğer çoğu CNN mimarilerine kıyasla daha düşük karmaşıklığa ve daha az parametreye sahiptir.

Şekil 2.11’de ShuffleNetv2 mimarisinde kullanılan bir görüntü modeli bloğu gösterilmektedir. Kanal bölme olarak bilinen basit bir operatörden yararlanır. Saniyede kayan nokta işlemleri (FLOPs) gibi dolaylı metrikler yerine hız optimize edilmiş ölçüdür. Her ünitenin başında, özellik kanallarının girişi iki kola ayrılmıştır. Şekilde gösterildiği gibi evrişimden sonra iki dal birleştirilir. Böylece kanal sayısı aynı kalır. ShuffleNet’teki [25] ile aynı “kanal karıştırma” işlemi daha sonra iki dal arasında bilgi iletişimini etkinleştirmek için kullanılır.



Şekil 2.11. ShuffleNetv2 blok diyagramı

ShuffleNetv2, yüksek hızda yüksek doğruluk sağlayan pratik yönergelerle önerilmiştir. Çalışmada yapılan deneyler sonrasında verimli bir ağ mimarisinin, dengeli/evrişimler (eşit kanal genişliği) kullanması, grup konvolüsyon kullanmanın maliyetinin farkında olması, parçalanma derecesini azaltmak ve eleman bazında işlemleri azaltmak gerektiği raporlanmıştır. Bu istenen özellikler, teorik FLOP'ların ötesindeki platform özelliklerine (bellek güdümlenme ve kod optimizasyonu gibi) bağlıdır. Pratik ağ tasarımı için dikkate alınmaları gerekir [24]. Tablo 2.1 ShuffleNetv2'nin dört farklı karmaşıklık düzeyi için genel mimarisini gösterir.


Tablo 2.1. Dört farklı karmaşıklık düzeyi için genel ShuffleNetv2 mimarisi [24]

Katman	Çıktı boyutu	Çekirdek boyutu	Adım	Tekrar	Çıkış kanalları			
					0,5 X	1X	1,5X	2X
Görüntü	224X224				3	3	3	3
Evrişim1	112X112	3X3	2		24	24	24	24
Maks.Havuzlama	56X56	3X3	2	1				
Düzyey2	28X28		2	1	48	116	176	244
	28X28		1	3				
Düzyey3	14X14		2	1	96	232	352	488
	14X14		1	7				
Düzyey4	7X7		2	1	192	464	704	976
	7X7		1	3				
Evrişim5	7X7	1X1	1	1	1024	1024	1024	2048
Global havuz	1X1	7X7						
Tam Bağlı					1000	1000	1000	1000
FLOPs					41M	146M	299M	591M
# ağırlıkları					1,4M	2,3M	3,5M	7,4 M

2.1.9. MobileNetv3 Mimarisi

MobileNetv1 [26], geleneksel evrişim katmanları için etkili bir ikame olarak derinlemesine ayrılabilir evrişimleri tanıtmıştır. Derinlemesine ayrılabilir evrişimler, uzamsal filtrelemeyi özellik oluşturma mekanizmasından ayırarak geleneksel evrişimi etkili bir şekilde çarpanlara ayırır. MobileNetv2 [27], daha verimli katman yapıları oluşturmak için doğrusal darboğaz ve tersine çevrilmiş kalıntı yapıyı tanıtmıştır. MnasNet [28], darboğaz yapısına sıkıştırmaya ve uyarıya dayalı hafif dikkat modülleri sunarak MobileNetv2 yapısı üzerine inşa edilmiştir.

MobileNetv3 [29], en etkili modelleri oluşturmak için bu katmanların bir birleşimini yapı taşları olarak kullanmaktadır. Katmanlar ayrıca değiştirilmiş swish doğrusal olmayanlarla da yükseltilir. Sıkıştırma (squeeze), uyarma (excitation) ve swish doğrusal olmama özelliği, hesaplamak için verimsiz olabilen ve sabit nokta aritmetiğinde doğruluğu sürdürmek için zor olan sigmoid, sert sigmoid ile değiştirilmiştir. Sıkıştırma ve uyarma modülü, en büyük gösterime dikkat edilmesi için genişletmede derinlemesine filtrelerden sonra yerleştirilir. [30]'daki yaklaşımın aksine burada sıkıştırma ve uyarma, artık katmana uygulanmıştır. MobileNetv3, small (küçük) ve large (geniş) olmak üzere tanımlanmıştır. Şekil 2.12, MobilNetv3 mimarisinin genel yapısını vermektedir.



Şekil 2.12. MobileNetv3 mimarisi [31]


2.2. Geleneksel Makine Öğrenmesi Sınıflandırıcıları

Geleneksel makine öğrenme sınıflandırıcıları birçok problemin çözümünde kullanılabilir. Tek başına veriye uygulandıkları gibi başka yöntemler ile birlikte kullanılarak

elde edilen mimarilerde de kullanım durumlarına göre başarıyı artırıcı etki yapabilmektedirler [32, 33]. Literatürde birçok makine öğrenme algoritması bulunmaktadır. Destek vektör makinaları (SVM), k-En yakın komşu (k-NN), Naïve Bayes (NB), Doğrusal diskriminant analizi (LDA), ve Karar ağacı (DT) çok kullanılan bazı yöntemlerdendir [34].

2.2.1. Destek Vektör Makinaları

İlk olarak 1992 yılında Vapnik ve diğerleri tarafından tanıtılan SVM, sınıflandırma ve regresyon için kullanılan denetimli bir öğrenme yöntemidir [35]. SVM, verilere aşırı uymayı otomatik olarak önler. Tekniğin temel amacı, farklı çekirdek fonksiyonlarını kullanarak doğrusal olmayan ayrılabilir örnekleri başka bir yüksek boyutlu uzaya yansıtmaktır. Çekirdek işlevleri, SVM’de doğrusallıktan doğrusal olmayışa geçişte önemli bir rol oynar. Popüler çekirdek fonksiyonları; Doğrusal, Polinom, Radyal Temel Fonksiyonlar ve Sigmoid olarak verilebilir [36]. İkinci dereceden (quadratic) çekirdekler ise polinom çekirdeklerin yaygın bir formudur. Doğrusal çekirdek genellikle geniş öznitelik kümeleri için kullanılır.



Şekil 2.13. Üç sınıflı sınıflandırma için SVM

SVM, makine öğrenmesinde güçlü bir sınıflandırıcıdır. Algoritma, her veri kümesini veya veri ögesini m boyutlu uzayda bir nokta olarak çizerek çalışır. Burada m , belirli bir koordinatın değeri olan özelliklerin sayısıdır. Daha sonra sınıfları ayırmak için kullanılan hiper düzlem bularak sınıflandırma yapılır [37]. Şekil 2.13'de SVM ile çoklu sınıflandırma verilmiştir. Burada, her bir sınıf çiftindeki bir sınıftan diğer sınıfın örneklerini ayırmak için eğitim işlemi yapılır. Şekil 2.13'de üç sınıf sırasıyla mavi, turuncu ve yeşil noktalarla temsil edilmektedir. Bunları sınıflandırmak için, sırasıyla mavi ve turuncu sınıflar, turuncu ve yeşil sınıflar ve mavi ve yeşil sınıflar arasında oluşturulan hiper düzlemler ve bunlara karşılık gelen destek vektörleriyle üç ikili sınıflandırıcı

oluşturulur. Üç ikili sınıflandırıcının tümü tarafından sınıflandırıldıktan sonra, test verisi örneği, maksimum oylama sürecini kazanan sınıfa dahil edilir [38].

2.2.2. K-En Yakın Komşu


K-NN, etiketlenmemiş nesneleri en benzer etiketli örneklerin sınıfına atayarak sınıflandırmaktadır. Gözlemlerin özellikleri hem eğitim hem de test veri kümesi için toplanır. 1970 yılında önerilmiş olan k-NN o günden beri birçok uygulamada kullanılmaktadır. K-NN algoritmasında eğitim noktasından örnek noktasına kadar olan mesafe değerlendirilir ve en düşük mesafeli noktaya en yakın komşu adı verilir. Temelde iki adımdan oluşur. İlk adımda, bilinmeyen örneğe en yakın olan k eğitim örneklerini bulunur. Sonraki adımda, bu k örnekleri için en sık görülen sınıf seçilir. En yakın komşu sınıflandırması esas olarak tüm öznitelikler devamlı olduğunda kullanılır [39].

K-NN, eğitim verilerini öğrenmez, bunun yerine eğitim veri kümesini ezberler. Tahmin yapmak istediğimizde tüm veri kümesinde en yakın komşuları arar. Mesafe hesaplama işleminde genellikle Öklid fonksiyonu kullanılır. Ayrıca Manhattan, Minkowski ve Hamming fonksiyonları da kullanılabilir [40].

2.2.3. Karar Ağaçları

Karar Ağacı, tümevarımlı öğrenmenin bir şeklidir. Belirli bir veri kümesi için amaç, verilere yol açan mekanizma için bir model oluşturmaktır. Eğitim, hedef adı verilen bir sonuç değişkeni tarafından denetlenir. Karar Ağaçları, yinelemeli ikili bölümlenme olarak bilinen bir yöntemle büyütülür. Düğümler, bir ağaçta öznitelik üzerinde bir testin yapıldığı noktalardır; dallar, başka bir düğüme götüren testin sonuçlarıdır.

Ağaçta kök düğüm, iç düğüm ve yaprak düğüm olmak üzere üç tür düğüm vardır. Kök düğüm en üst düğümdür, iç düğümler arada ve yaprak düğüm ile uç düğümler arasındadır. Testin tamamlanmasına her düğümün saflığına göre karar verilir. Bir düğüm önceden tanımlanmış belirli bir sınıf saflığı düzeyine ulaşırsa düğüm sonlandırılır. Yeni bir örneği sınıflandırmak için öznitelik değerleri karar ağacına göre test edilir. Kök düğümden o örnek için sınıf tahminini tutan yaprak düğüme giden bir yol izlenir. Karar ağacının şematik bir görünümü Şekil 2.14'de gösterilmektedir. Bir DT oluşturmanın temel görevi, bir düğüm üzerinde test edilecek bir özniteliği tekrar tekrar bulmak ve ardından başka bir düğüme dallanmaktır [41].



Şekil 2.14. Bir karar ağacı görünümü [41]

2.2.4. Naive Bayes

Naive Bayes, Bayes'in kuralını ve sınıfa göre özneliliklerin koşullu olarak bağımsız olduğuna dair bir varsayımla birlikte kullanan bir öğrenme algoritmasıdır [42]. Olasılık teorisinde Bayes teoremi, iki rastgele olayın koşullu ve uç olasılıklarını ilişkilendirir ve genellikle gözlemler verilen gerideki olasılıkları hesaplamak için kullanılır. Naive Bayes çoğu kez rekabetçi sınıflandırma doğruluğu sağlar. Hesaplama verimliliği ve diğer birçok istenilen özelliği sebebiyle sıklıkla uygulamalarda tercih edilmektedir. Bayes kuralı Denklem 2.1'de verilmektedir.

$$P(b|a) = P(b)P(a|b)/P(a) \quad (2.1)$$

Burada $P(b|a)$, a olayı gerçekleştiğinde b olayının olma olasılığıdır. $P(a|b)$, b olayı meydana geldiğinde a olayının olma ihtimalidir. $P(a)$ ve $P(b)$ ise sırasıyla a ve b olaylarının olma ihtimalleridir. Naive Bayes, özneliliklerin sınıfa göre koşullu olarak bağımsız olduğu varsayımıyla birlikte Bayes kuralına dayanan bir Bayes ağ sınıflandırıcısı biçimidir. Aşağıdaki denklemlerde, a_i , a 'daki i . özelliştir. Burada m , özellik sayısı, n , sınıf sayısı ve c_i , i . sınıftır [43].

$$P(a|b) = \prod_{i=1}^m P(a_i|b) \quad (2.2)$$

$$P(a) = \prod_{i=1}^n P(c_i)P(a|c_i) \quad (2.3)$$

2.2.5. Doğrusal Diskriminant Analizi

Doğrusal diskriminant analizi, R. Fisher tarafından önerilen temel bir veri analizi yöntemidir [44]. Sınıflandırma, boyut küçültme ve veri görselleştirme için doğrusal diskriminant analizi sıklıkla kullanılır. Genel olarak, LDA sağlam, tek tip ve yorumlanabilir sınıflandırma sonuçları üreten sade bir yapıya sahiptir. Algoritma, her sınıfın bir gauss dağılımı ile modellenebileceği ve tüm sınıfların aynı kovaryans matrisini paylaştığı varsayımına dayanmaktadır. Varsayımlar, LDA'yı doğrusal bir sınıflandırma yöntemi yapar. Çok sınıflı etiketlerde en iyi ayrımı sağlamak için değişkenleri doğrusal bir kombinasyonda aramaya dayanır.

Verilerin gerçek dağılımı için tutulurlarsa, veri sayısı sonsuza doğru eğilim gösterdiğinde LDA, Bayes sınıflandırıcısına yakınsama açısından optimaldir. Yansıma, yüksek boyutlu uzaydan daha düşük boyutlu uzaya doğrudur ve önerilen dönüşüm, sınıf içi dağılımın sınıflar arası dağılıma oranını maksimize etmeye yarar [45].

LDA, iki sınıfı en iyi şekilde ayıran değişkenlerin doğrusal bir kombinasyonunu arama kavramına dayanmaktadır. Ayrılabilirlik kavramını yakalamak için yazar tarafından Denklem 2.6'daki puan fonksiyonu tanımlanmıştır [46].

$$X = \beta_1 a_1 + \beta_2 a_2 + \dots + \beta_n a_n \quad (2.4)$$

$$P(\beta) = \frac{\overline{X_1} - \overline{X_2}}{\text{Gruplar içindeki } X \text{ varyansı}} \quad (2.5)$$

$$P(\beta) = \frac{\beta^T \mu_1 - \beta^T \mu_2}{\beta^T K \beta} \quad (2.6)$$

Puan fonksiyonu verildiğinde problem, Denklem 2.7 ve Denklem 2.8'deki denklemlerle çözülebilecek puanı maksimize eden doğrusal katsayıları tahmin etmektir.

$$\beta = K^{-1}(\mu_1 - \mu_2) \quad (2.7)$$








$$K = \frac{1}{m_1 + m_2} (m_1 K_1 + m_2 K_2) \quad (2.8)$$

2.3. Aktivasyon Fonksiyonları

Derin öğrenme, genelde doğrusal olmayan problemlerin çözümünde kullanılmaktadır. Bunun sebebi, derin öğrenmenin var olan diğer yöntemlere nazaran doğrusal olmayan problemlerde daha başarılı olmasıdır. Evrişim katmanındaki matris çarpımı sonrasında elde edilen değerler doğrusaldır. Değerlerin doğrusal olmayan hale dönüştürülmesi için aktivasyon fonksiyonları kullanılmaktadır [47].

Aktivasyon fonksiyonları, bir sinir ağı tasarımının kritik bir parçasıdır. Çıktı katmanındaki aktivasyon fonksiyonunun seçimi, modelin yapabileceği tahminlerin türünü tanımlar. Dolayısıyla bu katmanlarda kullanılacak olan fonksiyon, tahmin probleminin tipine bağlı olarak seçilir [48].

Tablo 2.2. Sıklıkla kullanılan bazı aktivasyon fonksiyonları

İsim	Eşitlik	Grafik
Doğrusal	$f(a) = xa$	
Sigmoid	$f(a) = \frac{1}{1 + e^{-a}}$	
Softmax	$f(a)_j = \frac{e^{a_j}}{\sum_{i=1}^I e^{a_i}} \quad i = 1, \dots, I.$	
TanH	$\text{TanH}(a) = 2\text{sigmoid}(2a) - 1$	
ReLU	$f(a) = \max(0, a)$	
LReLU	$f(a) = \begin{cases} xa, & a < 0 \\ a, & a \geq 0 \end{cases}$	
Mish	$f(a) = a * \text{TanH}(\ln(1 + e^x))$	

En basit aktivasyon fonksiyonu, hiçbir dönüşümün uygulanmadığı doğrusal aktivasyon olarak adlandırılır. Yalnızca doğrusal aktivasyon fonksiyonlarından oluşan bir ağı eğitilmesi çok kolaydır. Sinir ağı eğitiminde geri yayılım olarak adlandırılmış olan bir algoritma kullanılır. Algoritma türev alan bir sistemden oluşur. Bu yüzden kullanılan fonksiyonun türevi alınabilen bir doğrusal olmayan fonksiyon olması eğitimi olumlu yönde etkiler. Doğrusal aktivasyon fonksiyonunda türevin sabit olması durumu öğrenmeyi engeller. Bu yüzden gizli katmanlarda kullanım için genellikle tercih edilmez.

Lojistik fonksiyon olarak da adlandırılan sigmoid aktivasyon fonksiyonu, geleneksel sinir ağları için çok popülerdir. Fonksiyonun girdisi 0 ile 1 arasında bir değere dönüştürülür. 1’den daha büyük olan girdiler 1 değerine dönüştürülür, benzer şekilde 0’dan daha küçük değerler 0’a dönüştürülür. Tüm olası girişler için fonksiyonun şekli, bir S şeklindedir. Softmax, çoklu Sigmoid olarak da bilinmektedir. Fonksiyon, her sınıf için bir olasılık verir. Çıktı, sınıf sayısı kadar değer üretir. Aynı veri kümesi için, tüm vektörlerin olasılık toplamı 1’e eşittir [49,50]. AlexNet, ResNet gibi bilinen mimarilerin çoğu son katmanında Softmax aktivasyon fonksiyonunu tercih etmiştir.

Gizli katmandaki aktivasyon fonksiyonunun seçimi, ağ modelinin eğitim veri kümesini ne kadar iyi öğrendiğini kontrol eder. Önceki standart CNN mimarileri gizli katmanlar için hiperbolik tanjant (TanH) ve sigmoid aktivasyon fonksiyonunu kullanmışlardır. Modern varsayılan aktivasyon fonksiyonu, ReLU’dur. Hiperbolik tanjant fonksiyonu, Sigmoid fonksiyonuna benzemektedir. Ancak aldığı değerlerin aralığı -1 ile 1’dir. Tablo 2.2’deki ilgili grafiğe bakıldığında uç kısımlarda türevin sıfıra yakınsandığı görülmektedir. Bu durum eğitimi kötü etkiler. Dolayısıyla ilk çıkan CNN modellerinde tercih edilmiş olsa da günümüz CNN mimarilerinde kullanımı yaygın değildir. ReLU fonksiyonu, negatif değerleri 0 olarak alır. Amaç ağı daha hızlı bir şekilde çalışmasını sağlamaktır. Fakat bu bölgede türevin sıfır olması öğrenmeyi engellemektedir. ReLU’nun bu dezavantajını ortadan kaldırmak için birkaç aktivasyon fonksiyonu önerilmiştir. Bunlardan birisi olan LReLU, negatif olan değerleri 0 yapmak yerine 0’a yakın bir değere eşitleyerek negatif eksenindeki değerlerin de eğitime katılmasını sağlamıştır [51, 52]. Son olarak Mish aktivasyon fonksiyonu, 2020 yılında yayınlanan bir makale ile “kendi kendini yenileyen monoton olmayan aktivasyon fonksiyonu” olarak tanıtılmıştır [53]. Anlatılan aktivasyon fonksiyonlarına ait denklem ve grafikler Tablo 2.2’de verildiği gibidir. Denklemlerde a giriş değeri ve $f(a)$ çıkış değerini temsil eder.

2.4. Başarım Ölçümünde Kullanılan Metrikler

Sınıflandırmanın başarımını analiz etmek amacıyla çeşitli başarım ölçütleri kullanılmaktadır. Doğruluk (ACC) metriği, genellikle sınıflandırma problemlerinin performansını değerlendirmek için kullanılır. Ancak doğruluk tek başına güvenilir bir ölçüm sağlamaz. Daha güvenilir bir başarım analizi yapmak için başka metriklerin kullanılması gerekmektedir [54].

Deneylerde doğruluk metriğinin yanı sıra özgüllük (SP), kesinlik (PREC), hatırlama (SN) ve F1-puanı (F1) metrikleri kullanılmıştır. Karmaşıklık matrisi kullanılarak bu değerler hesaplanabilmektedir. Doğru Pozitif (TP), Doğru Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) değerleri, sınıflandırma sonucunun karmaşıklık matrisine dâhil edilir. Karmaşıklık matrisi ve metriklerin hesaplanmasında kullanılan formüller Şekil 2.15’de görülmektedir [55].

		Tahmin edilen sınıf		Performans kriteri
		Positif(1)	Negatif(0)	
Gerçek Sınıf	Positif (1)	TP	FN	Kesinlik $\frac{TP}{(TP+FP)}$
	Negatif (0)	FP	TN	F1-puanı $2 * ((PREC.SN) / (PREC+SN))$
Performans kriteri		Hatırlama $\frac{TP}{(TP+FN)}$	Özgüllük $\frac{TN}{(TN+FP)}$	Doğruluk $\frac{(TP+TN)}{(TP+TN+FP+FN)}$

Şekil 2.15. Karmaşıklık matrisi ve performans metrikleri

2.5. Sonuç

Bu bölümde, görüntü sınıflandırma konusu incelenmiştir. Görüntü sınıflandırma problemlerinin çözümünde sıklıkla kullanılan Evrimsel sinir ağları mimarilerinin genel yapısı ve tez kapsamında kullanılmış olan öneğitimli mimarilerin yapısı kısaca anlatılmıştır. Sınıflandırma problemlerinde CNN mimarilerinin son katmanında Softmax algoritmasını kullanmak yaygındır. Bunun yanında, son zamanlarda mimarinin son katmanda gerçekleştirilen sınıflandırma işlemi için geleneksel makine öğrenmesi algoritmaları kullanılarak hibrit mimariler oluşturulmaktadır. Bu şekilde kullanmış olduğumuz sınıflandırma algoritmalarına bu bölümde yer verilmiştir. CNN mimarilerinde kullanılan aktivasyon fonksiyonları oluşturulan mimarinin başarımını etkileyen faktörlerden birisi olmaktadır. Genellikle kullanılan aktivasyon fonksiyonları tezin bu bölümünde sunulmuştur. Son olarak sınıflandırma problemlerinin başarı ölçümünde kullanılan metrikler anlatılmıştır.

3. NESNE BULMA

Nesne bulma, birçok nesne sınıfı içerisinde bir kısım nesnelerin tanımlanmasına odaklanmaktadır. Sınıflandırma işlemi, sadece görüntünün hangi kategoride olduğunu tahminini esas alırken, nesne bulmada görüntünün konumunun da bulunması gerekmektedir. Nesne bulma, sınıflandırma ve yerleştirme işlemlerini içeren bir problemdir. Bu açıdan nesne bulma, makine öğrenmesinde zorlu bir görev olmaktadır [56].

Nesne bulma, birçok bilgisayar görmesi probleminin ilk ve temel adımıdır. Nesne bulma kullanılarak birçok uygulama gerçekleştirilmektedir. Optik karakter tanıma, sürücüsüz arabalar, nesneleri izleme, yüz bulma ve tanıma, kimlik doğrulama, görüntüden nesne çıkartma, duygu tespiti, hareket tanıma, yaya bulma, tıbbi görüntüleme, imalat endüstrisi, robotik ve nesne sayma bazı uygulamalardandır [57].

Nesne bulma problemlerinin çözümünde derin öğrenme yaklaşımlarından sıklıkla yararlanılmaktadır. Tezin bu bölümünde, derin öğrenme tabanlı nesne bulucularına yer verilmiştir. Ayrıca nesne bulma problemlerinin başarımlarının analizinde kullanılan başarı ölçütleri anlatılmıştır.

3.1. Derin Öğrenme Tabanlı Nesne Bulucular

Nesne algılama, iyi bilinen bir makine öğrenmesi sorunudur. Başlangıçtan günümüze nesne algılama probleminin çözümü için birçok algoritma önerilmiştir. Geleneksel nesne algılama algoritmaları, kayan pencereye dayalı bir bölge seçim stratejisi kullanır [58]. Ayrıca geleneksel öznetelik çıkarıcılar hedefleri ayırt etmede etkili değildir. Bilgisayar teknolojisindeki gelişmeler sayesinde artık derin öğrenme modelleri bilgisayarlı görüde kullanılabilir. CNN tabanlı nesne bulucuları, görüntü özelliklerini otomatik olarak çıkarmanın avantajlarından yararlanır [59]. Genellikle, CNN tabanlı nesne bulucuları tek aşamalı ve iki aşamalı olarak iki gruba ayrılmaktadır [60]. Şekil 3.1, iki farklı yaklaşımın bir özetini vermektedir.



Şekil 3.1. Tek ve iki adımli nesne bulucuların gösterimi [61]

3.1.1. İki Aşamalı Nesne Buluculardan RCNN Ailesi


İki aşamalı nesne bulma algoritması, önemli bölgelerin tespit edildiği ve daha sonra bu alanlarda bir nesnenin tespit edilip edilmediğini görmek için sınıflandırıldığı bir ön aşama kullanır. Esas olarak iki aşamayı içerir. İlk adımda, bir nesne içerebilecek görüntünün bölge önermeleri veya alt kümeleri belirlenir. İkinci aşamada, algoritma bir önceki aşamada oluşturulan ilgili bölgeler üzerinde bölgesel sınıflandırma ve konum iyileştirmesi gerçekleştirir [62].

RCNN [63], bölge önerisi yaklaşımını kullanan en temel modeldir. RCNN, Fast RCNN[64], Faster RCNN[65], mask RCNN [66] ve RFCN [67] iki aşamalı buluculara örnek olarak verilebilir. En yaygın kullanılan algoritma ise RCNN ailesinin en iyi sürümlerinden birisi olan Faster RCNN olmaktadır [68].

RCNN

Bölge tabanlı evrimsel sinir ağı, önceki geleneksel makine öğrenimi yöntemlerinden nesne algılama prosedüründe bir gelişmedir. RCNN, seçici bir arama algoritması yardımıyla bölge önerileri yapmaktadır. Seçici arama ilgili görüntüdeki bulunması gereken bölgeleri tanımak için kullanılan bir algoritmadır [69]. Algoritmada öncelikle küçük bölgeler belirlenir. Birbirine benzeyen bölgeler birleştirilerek daha büyük bölgeler elde edilir. İşlemin tekrar etmesi ile nesneler kümelendirilir. Aday bölgeler bu şekilde belirlenir. Sonrasında belirlenen bölgeler ayrı ayrı CNN modeline beslenir. Çıkarılan öznelikler ile sınıf ve sınırlayıcı kutu tahmini gerçekleştirilir.


Elde edilen 2000 tane aday bölgenin tamamı kullanılmaz. Doğru sınırlayıcı kutuların seçimi Maksimum-olmayan bastırma (NMS) ile yapılır. Bu algoritma sadece birleşim üzerinde kesişim (IoU) değeri 0,5'ten büyük olanları alır. Bir nesne için birden fazla 0,5'ten büyük skoru olan sınırlayıcı kutular içerisinde en yüksek skoru olanı alır [63]. Şekil 3.2 RCNN mimarisini göstermektedir.



Şekil 3.2. RCNN mimarisi [63]

Fast RCNN

RCNN yaklaşımını öneren yazarlardan birisi olan Ross Girshick tarafından geliştirilen Fast RCNN, nesne algılamayı hızlandırmak için farklı teknikleri birleştirmiştir. Bölge önerileri yapmak yerine, tüm görüntü Fast RCNN algoritması üzerinde CNN'ye yerleştirilir. Sonuç olarak, yüksek kararlı evrişimsel özellik haritası elde edilir. Seçici arama yoluyla evrişimsel özellik haritasında yaklaşık 2000 ilgi alanı tanımlanır. Önerilen bölgeler, havuzlama katmanı aracılığıyla sabit boyutta sarılır ve ardından tam bağlantılı katmana bağlanır. Softmax, her bir ilgili bölge için nesneye ait sınıfı bulmak için kullanılır. Sınırlayıcı kutu regresyon ile sınırlama kutusu bulunur [64]. Şekil 3.3 Fast RCNN mimarisini vermektedir.




Şekil 3.3. Fast RCNN mimarisi [64]

Fast RCNN avantajı, evrişimsel özellik haritası kullanmaktır, ancak seçici arama, süreç için hala darboğaza sebep olmaktadır.

Faster RCNN

Bölge önermek için seçici arama algoritmasını kullanmak yerine bölge öneri ağı (RPN) kullanır. Bu sayede işlem yükü azaltılmıştır. Önceki RCNN sürümlerine göre daha hızlıdır. RPN evrişimsel bir sinir ağıdır. Bölge önerirken herhangi bir boyuttaki aldığı girdiyi nesne puanına göre ait olabileceği nesneler ile dikdörtgen bir teklif oluşturur. Öneri, evrişim katmanınca oluşturulan özellik haritası üzerindeki küçük bir ağın kaydırılması ile olur. Sonrasında üretilen hesaplamalar Fast RCNN mimarisine verilir. Burada nesnenin sınıfı ve sınırlayıcı kutular ile de yeri tahmin edilir [65]. Faster RCNN mimarisi, Şekil 3.4'te gösterildiği gibidir.



Şekil 3.4. Faster RCNN mimarisi [65]

3.1.2. Tek Aşamalı Nesne Buluculardan YOLO Ailesi


Tek aşamalı bir model, bir ön adıma ihtiyaç duymadan nesneleri algılama yeteneğine sahiptir. Tek aşamalı bulucunun avantajı, gerçek zamanlı kullanıma izin vererek hızlı bir şekilde tahminler yapabilmesidir. Tek aşamalı nesne bulucuları, kayan bir pencere kullanarak çeşitli kategorilerdeki nesneleri bulur. Giriş görüntüleri ızgaralıdır ve bağlantı kutuları (anchor) uzamsal olarak yerleştirilmiş bölgeleri temsil eder. Bu bölgelerin CNN çıkışları, nesneleri arka plandan ayırmak için kullanılır. Bu bulucular, tasarım ve eğitimde basit ve etkili olmakla birlikte, önemli dengesiz sınıflandırma problemlerinden muzdariptir [70].

Tek aşamalı algoritmanın bir bölge önerisi oluşturması gerekmediğinden, algoritma akışı daha kısa ve nettir. Sıklıkla kullanılan tek aşamalı nesne bulucularına örnek olarak SSD [71], YOLO [72] ve CornerNet [73] verilebilir.

YOLOv1 Modeli

2015 yılında Redmon ve arkadaşları tarafından tanıtılmıştır. Yazarların amacı önceki Fast RCNN, Faster RCNN gibi ağların yaptığı işin aksine sinir ağındaki tüm aşamaları içeren birleşik bir model oluşturmak olmuştur. Bu sayede işlem yükü azalmış ve hız kistası açısından performans iyileştirilmiştir. Nesneleri içeren girdi, çoklu evrişim ağların tek bir sinir ağından geçtikten sonra; sistem, görüntüde görünen her bir nesneye karşılık gelen tahmin vektörlerini üretir [72].

YOLO'nun ana fikri görüntüyü ilk olarak $S \times S$ (7×7 varsayılan) gride bölmektir. Nesneleri içeren girdi ağıdan geçtikten sonra Şekil 3.5'deki gibi bir görüntü elde edilir [74, 75].



Şekil 3.5. 4x4 grid hücresindeki bir sınırlayıcı kutu için parametreler

416x416 boyutundaki görüntü 4x4 gride bölünmüştür. 16 gridin her biri nesne bulmakla görevlidir. Eğer bir nesnenin merkezi bir ızgara hücresine düşerse, o nesnenin bulunmasından sorumludur. Şekilde ilgili nesnenin merkezi grid 6'ya düşmüştür. Dolayısıyla bu nesnenin bulunmasından grid 6 sorumludur. Diğer hücreler nesneyi göz ardı eder.

Güven puanı ile birleştiğinde, her bir sınırlayıcı kutu, 5 parametreden oluşur. Güven puanı o kutuda nesne olup olmadığını söyler. Sınırlayıcı kutu parametreleri Denklem 3.1 ile Denklem 3.5 arasında verilen eşitliklere göre hesaplanmaktadır. Şekil 3.5'de verilen değerler bu denklemler kullanılarak hesaplanmıştır.

$$x = (Merkez_{Grid_x} - Başlangıç_x) / Başlangıç_x \quad (3.1)$$

$$y = (Merkez_{Grid_y} - Başlangıç_y) / Başlangıç_y \quad (3.2)$$

$$w = Nesne\ genişliği / Görüntü\ genişliği \quad (3.3)$$


$$h = Nesne\ yüksekliği / Görüntü\ Yüksekliği \quad (3.4)$$

$$Güven\ puanı = IoU_{tahmin}^{gerçek} \times P(Nesne) \times P(Sınıf_i | Nesne) \quad (3.5)$$

Bir grid hücresindeki her sınıf için tahmin edilen bir nesnenin olasılığı $P(Sınıf_i | Nesne)$ ile gösterilir. C sınıfı için olasılık değerleri, her grid hücresi için C çıktı üretecektir. Aynı grid hücresinin sınırlayıcı kutusu, nesnenin sınıfı hakkında ortak bir tahmin kümesini paylaşır; bu, aynı


grid hücresindeki tüm sınırlayıcı kutuların aynı sınıfa sahip olduğu anlamına gelir. Mesela merkez hücrede 2 tahmin kutusu varsa bunların farklı parametreleri vardır (x , y , w , h , güven puanı). Ancak, aynı sayıda tahmin sınıfına sahiptirler.

Böylece model, bir görüntü için $S \times S$ ızgara hücrelerine sahiptir. Her hücre, 5 parametreden oluşan ve C sınıfının tahmin olasılıklarını paylaşan B sınırlayıcı kutuları tahmin eder. Model parametrelerinin toplam YOLO çıktısı $S \times S \times (5 \times B + C)$ olacaktır [74]. Örneğin, YOLO modelini 4×4 gride sahip 4 sınıf içeren ve her bir hücreyi 2 sınırlayıcı kutu öngören bir veri kümesinde değerlendirdiğimizde, toplam çıktı parametreleri $4 \times 4 \times (5 \times 2 + 4)$ olur. Şekil 3.6 her grid için eğitim etiketleri vermektedir. Burada etiket vektörü y 'dir. Vektör parametreleri şekilde gösterildiği gibidir.



Şekil 3.6. Bir YOLO modelinde etiket vektörü y , 4 sınıf için nesne tahmini

YOLO son olarak RCNN algoritması gibi maksimum olmayan bastırma uygulayarak herhangi bir nesne içermeyen veya diğer sınırlayıcı kutularla aynı nesneyi içeren tüm sınırlayıcı kutuları temizler. YOLOv1 mimarisi 24 evrişim katmanı ve 2 tam bağlı katmandan oluşmaktadır. Şekil 3.7. YOLOv1 mimarisini göstermektedir. Yazarlar $S=7$ ve $B=2$ almıştır. Eğitimin gerçekleştirildiği veri kümesinin sınıf sayısı ise 20'dir. Dolayısıyla çıkış vektörü $7 \times 7 \times (2 \times 5 + 20)$ olmaktadır [76].



Şekil 3.7. YOLOv1 mimarisi [76]

YOLOv1 mimarisi her ne kadar hızlı olsa da doğru tahmin yapmak konusunda Faster RCNN'e kıyasla daha çok yerelleştirme hatası yapmıştır. Mimari ve temel prensipleri ele alınarak YOLO mimarisinin yeni sürümleri geliştirilmiştir. Şu anda ilk sürümü dâhil olmak üzere beş sürüm geliştirilmiştir.

YOLOv2 Modeli

YOLO'da her grid hücresi sadece bir nesne tahmini yapabiliyordu. Oysa bir grid birden fazla nesnenin merkezi olabilir. Bu kısıt RCNN'de de kullanılmış olan bağlantı kutusu kullanımı ile giderilmiştir. Diğer bir yenilik YOLOv2 [77] mimarisindeki her evrişim katmanının ardından yığın normalleştirme eklenmesidir. Yığın normalleştirme, derin öğrenme modelinde en popüler normalleştirme yöntemlerinden biridir. Eğitim sırasında girdi katmanlarının dağılımını sabitleştirerek derin sinir ağlarının daha hızlı ve daha kararlı eğitimini sağlar. Bu yaklaşımın amacı, özellikleri standart sapması 1 olan sıfır ortalamalı bir duruma normalleştirmektir [78]. Bu teknik ile eğitim süresi azaltılmış ve ağırların genelleştirilmesi artırılmıştır. Ayrıca ağırların aşırı uyumu engellemek için ek bırakma (dropout) kullanmasına gerek yoktur.

Orijinal YOLO'da, 224x224 giriş görüntüsü ile özellik çıkarıcıyı eğitmek için ilk 20 evrişim katmanı kullanılmıştır. Daha sonra kalan 4 evrişim katmanı ve 2 tam bağlı katman eklenmiş, giriş görüntüsünün çözünürlüğü nesne bulucusu olarak kullanılmak üzere eş zamanlı olarak 448x448'e yükseltilmiştir. YOLOv2'de ise, 224x224 giriş görüntüsü ile özellik çıkarıcının eğitim aşamasını tamamladıktan sonra model, nesne bulucu eğitimi için mimariyi kullanmadan önce özellik çıkarıcıyı 448x448 girdi görüntüsü ile 10 tekrardan fazla eğitmeye devam etmiştir. Böylece, özellik çıkarıcı eğitim aşaması, nesne algılayıcı eğitim aşamasına geçtiğinde görüntü boyutunu aniden artırmak yerine modelin 448x448 gibi büyük bir çözünürlüğe "uyarlanmasına" yardımcı olunmuştur. Yüksek çözünürlüklü sınıflandırma ağı, yaklaşık %4 mAP (Ortalama kesinlik değerlerinin ortalaması) artışı sağlamıştır [79].

YOLOv3 Modeli

2018 yılında önceki sürümlerin daha geliştirilmiş olan YOLOv3 tanıtılmıştır [22]. Model, orijinal olarak eğitim özelliği çıkarıcı için 53 katmanlı ağı sahip Darknet53 (Şekil 2.10) mimarisini kullanır. Bundan sonra, nesne bulucu eğitiminde algılama kafası için 53 katman daha istiflenmiş ve YOLOv3 toplam 106 katman tamamen evrimsel temel mimari haline getirilmiştir. YOLOv3 önceki sürümler gibi son katmanda tahmin yapmak yerine tahmin katmanlarını ağı bir kenarına ekler. Son 3 artık bloğun özellikleri 3 farklı ölçekli bulucu için kullanılır. Böylece 3 farklı ölçekte tespitler yapmaktadır. Her farklı bulucu için toplam YOLOv3'ün çıkış parametreleri $S \times S \times (B \times (5+C))$ olmaktadır.

Nesne bulucular omurga, boyun ve kafa kısımlarından oluşmaktadır. Omurga kısmında etkili özellikler çıkartılır. Boyun daha fazla bilgi elde etmek için ara katman olarak kullanılır. Burada ara katman olarak Özellik Piramit Ağı (FPN) kullanılmıştır. Kafa kısmı ise tahminin yapıldığı kısımdır.

YOLOv4 Modeli

YOLOv4 [61], omurga ağı olarak özellik çıkarma görevi için CSPDarkNet53 (Cross Stage Partial DarkNet53) mimarisini kullanmıştır. Boyundaki özellik toplama mimarisine iletilmeden önce, CSPDarknet53 omurgasının çıkış özellik haritaları, alıcı alanı artırmak ve en önemli özellikleri ayırmak için Uzamsal Piramit Havuzlama (SPP) adı verilen ek bir bloğa gönderilmektedir. SPP, girdi boyutundan bağımsız olarak sabit boyutlu bir çıktı üretmeyi amaçlar. Ayrıca, kendisinin çok ölçekli sürümlerini bir havuzda toplayarak önemli özelliklerin çıkarılmasına da yardımcı olur [80]. YOLO'nun bu sürümünde Yol Toplama Ağı (PAN) da kullanılmıştır. Son olarak tahmin işleminin yapıldığı baş kısmında YOLOv3 tercih edilmiştir.

Yazarlar, algoritma performansını ve doğruluğunu daha da geliştirmek amacıyla YOLOv4 mimarisine bir dizi sıra dışı eniyileme yöntemini uygulamıştır. İyileştirmeler, yazarlar tarafından "Bag of Frebies" ve "Bag of Specials" terimleriyle anılır.

YOLOv5 Modeli

YOLOv4'ün piyasaya sürülmesinden 1 ay gibi kısa bir süre sonra YOLOv5 [76] tanıtılmıştır. YOLOv4 ve YOLOv5 farklı çerçeve ve farklı dil ile yazılmışlardır. Bu yüzden aralarındaki performansın karşılaştırılması zordur. Ancak YOLOv5 tanıtıldıktan bir süre sonra, belirli koşullar altında YOLOv4'ten daha yüksek performans göstermiş ve YOLOv4'ün yanı sıra bilgisayarlı görme topluluğunda kısmen güven kazanmıştır [79].

YOLOv5 mimarisi, YOLOv4 mimarisi birbirine çok yakın zamanda tanıtılmış olmalarının etkisiyle benzer en son yenilikleri entegre etmiştir. Bu nedenle teoride çok farklılık yoktur. YOLOv5 modeli çapraz aşamalı kısmi ağı (CSPNet) Darknet'e dahil ederek CSPDarknet'i omurgası olarak oluşturmuştur. CSPNet, büyük ölçekli omurgalarda tekrarlanan gradyan bilgisi

IoU: Bir yer gerçeği sınırlayıcı kutu BB_{yg} ile temsil edilen tespit edilecek bir hedef nesneyi ve tahmin edilen bir sınırlayıcı kutu BB_t ile temsil olunan tespit edilen alan olsun. Bir güven seviyesi hesaba katılmadan, tahmin edilen ve kesin referans kutularının alanı ve konumu aynı olduğunda mükemmel bir eşleşme kabul edilir. Bu iki koşul, iki veri kümesi için bir benzerlik katsayısı olan Jaccard İndeksine dayanan bir ölçüm olan birleşim üzerinden kesişim ile değerlendirilir. Nesne algılama kapsamında, IoU, tahmin edilen sınırlayıcı kutu BB_t ile yer gerçeği sınırlayıcı kutu BB_{yg} arasındaki kesişim alanının birleşim alanına bölünmesiyle elde edilen alana eşittir. Denklem 3.6'daki gibi hesaplanmaktadır.

$$IoU = \frac{alan(BB_{yg} \cap BB_t)}{alan(BB_{yg} \cup BB_t)} \quad (3.6)$$

Bir IoU eşiği belirlemek, algılamaların doğru veya yanlış olarak değerlendirilmesi konusunda kısıtlayıcı olabilir. IoU değerleri genellikle yüzde olarak ifade edilir ve en çok kullanılan eşik değerleri % 50 ve % 75'tir [83].

Kesinlik ve Hatırlama: Kesinlik, bir modelin yalnızca ilgili nesneleri tanımlama yeteneğidir. Doğru pozitif tahminlerin yüzdesidir. Hatırlama, bir modelin tüm ilgili durumları bulma yeteneğidir. Verilen tüm temel gerçekler arasındaki doğru pozitif tahminlerin yüzdesidir [54]. Kesinlik ve hatırlama matematiksel formülleri Şekil 2.15'de verilmiştir.

Ortalama Kesinlik: 0 ile 1 arasındaki hatırlama değeri için ortalama kesinlik değerini hesaplar. Bir nesne bulucu, hatırlama arttıkça hassasiyeti yüksek kalırsa iyi kabul edilebilir. Yani, güven eşiği değiştiğinde de, kesinlik ve hatırlama yüksek olacaktır. Bu nedenle, eğrinin altındaki yüksek bir alan (AUC) hem yüksek kesinliği hem de yüksek hatırlamayı gösterme eğilimindedir. Pratik durumlarda, kesinlik $\times$ hatırlama grafiği genellikle zikzak benzeri bir eğridir ve AUC'nin doğru bir şekilde ölçülmesi zorlaşır. Bunu engellemek için, AUC tahmininden önce hassasiyet $\times$ hatırlama eğrisi işlenir. 11 noktalı enterpolasyon yaklaşımı, bu amaçla kullanılır. Hassasiyet $\times$ hatırlama eğrisinin şekli, 11 eşit aralıklı geri çağırma kümesindeki maksimum hassasiyet değerlerinin ortalaması alınarak özetlenir [84, 85].

Her hatırlama seviyesindeki kesinlik, karşılık gelen hatırlamanın SN'yi aştığı bir yöntem için ölçülen maksimum kesinlik alınarak enterpolasyon yapılır.

Ortalama Kesinlik Değerlerinin Ortalaması: MAP, birden çok IoU eşiği üzerindeki ortalama AP'dir. Tüm sınıflar üzerindeki ortalama AP'dir [86].

3.3. Sonuç

Bu bölümde, makine öğrenmesi temel problemlerinden birisi olan nesne bulma incelenmiştir. Nesne bulma probleminin çözümü için geleneksel yöntemler ve derin öğrenme tabanlı yöntemler kullanılmaktadır. Son zamanlarda derin öğrenme tabanlı nesne bulma yöntemleri çokça kullanılır. Dolayısıyla sadece derin öğrenme tabanlı nesne buluculardan sıklıkla kullanılan iki temel yaklaşım anlatılmıştır. Bunlardan ilki RCNN olarak adlandırılmış, iki adımlı bölge öneri tabanlı yaklaşımdır. Diğeri ise tek adımlı olan YOLO algoritmasıdır. Tezin bu bölümünde ayrıca nesne bulma yaklaşımlarının değerlendirilmelerinde kullanılan başarı ölçütlerine yer verilmiştir.



4. DOMATES YAPRAĞI GÖRÜNTÜLERİNİN CNN TABANLI HİBRİT SINIFLANDIRMASI

Bu çalışma, domates yaprağı görüntülerinden hastalıkların tespit edilmesi ve verimli bir üretim süreci için tedavinin sağlanmasına odaklanmaktadır. Bu amaçla, hastalık tespitinin yüksek sınıflandırma başarımı CNN tabanlı bir yöntem ile sağlanmaktadır.

4.1. Problem Tanımı

Domatesler, çevre ve iklim koşullarına bağlı olarak, yetiştirme sürecinin herhangi bir aşamasında çeşitli hastalıklara yakalanabilir. Bu hastalıkların erken evrelerde fark edilmesi ve tedavi edilerek ürün kalitesinin artırılması önemlidir. Domates bitkisinin hastalığına neden olabilecek birkaç patojen vardır. Bazı domates hastalıkları patojenleri mantar organizmaları iken diğerleri bakteriyel veya viraldir. Domates bitkisi hastalıklarını önlemek ve sağlıklı tutmak için yapılabilecek birkaç tedavi vardır [87]. Ancak tüm bu önleme çabalarına rağmen zaman zaman hastalıklar başka şekillerde de ortaya çıkabilmektedir. En yaygın domates bitkisi hastalıklarından bazıları bakteriyel leke, siyah küf, geç yanıklık, külleme, gri nokta, erken yanıklık, mozaik virüsü ve sarı yaprak kıvrılma virüsüdür. Geç yanıklık hastalığına yakalanmış bir domates bitkisinin meyve ve yaprak görüntüsü Şekil 4.1'deki gibidir.



Şekil 4.1. Geç yanıklık hastalığına yakalanmış olan domates bitkisinin (a) Meyve ve (b) Yaprak görüntüsü [82]

Domates yaprakları, hastalıklarla ilgili belirtiler gösterebilir. Yapraklarda leke ve benek gibi belirtiler hastalıkları tespit etmek için kullanılabilir. Ancak bu yetiştiriciler için özellikle büyük tarım alanlarında büyük çaba ve zaman gerektirir. Bu nedenle algılama sistemleri geliştirilmiştir.

Çalışmanın motivasyonu viral, bakteriyel ve mantar kaynaklı hastalıkların erken teşhisi ve tedavisi için hastalıklı yaprakların sınıflandırılmasıdır. Yapraklardaki hastalıkları görmek ve ortaya çıkarmak zordur. Bu sorunu çözmek için otomatik algılama sistemlerinin kullanılması faydalı olacaktır. Bu amaçla CNN mimarileri kullanılmaktadır. Biri 10 sınıflı Tomato leaf disease detection veri kümesi ve diğeri altı sınıflı Taiwan tomato leaves veri kümesi olmak üzere iki veri kümesi kullanılmıştır [88, 89]. Hibrit yapılar AlexNet, ResNet50 ve VGG16 mimarilerine dayalı olarak önerilmiştir. Bu mimarileri görüntü sınıflandırmadaki başarılarından dolayı tercih edilmiştir. Hibrit bir yapıda, elde edilen özneteliklerin indirgenmesi için minimum artıklık maksimum uygunluk (mRMR) öznetelik seçim algoritması incelenir. Öznetelik seçim algoritması, ilgili öznetelikleri ayırt etmedeki başarılarına göre sıralar. Daha sonra bilinen makine öğrenmesi sınıflandırma yöntemleri birbiriyle karşılaştırılır. Çalışmada hem Taiwan tomato leaves hem de Tomato leaf disease detection veri kümeleri sınıflandırma sonuçları elde edilmiştir.

4.2. İlgili Çalışmalar

Domates bitkisinin yapraklarından çeşitli hastalıkları tespit etmek için yapılan bazı çalışmalar vardır. Agarwal ve arkadaşları [90], çalışmalarında bir CNN mimarisi kullanmıştır. Önerdikleri yöntem, 10 sınıflı bir veri kümesinde %91,2 ortalama doğruluk elde etmiştir. Granik ve Mesyura [91], PlantVillage veri kümesinden aldıkları yedi sınıftan oluşan domates yapraklarının görüntülerini AlexNet ve VGG16 mimarilerine girdi olarak vermiştir. Görüntü sayısı, mini parti boyutu (mini batch size) ve önyargı (bias) gibi parametrelerin sınıflandırma doğruluğu üzerindeki etkisi gözlemlenmiştir. En iyi koşullar altında AlexNet ve VGG16 mimarileri sırasıyla %97,29 ve %97,49 doğruluğa ulaşmıştır.

Agarwal ve arkadaşları [92] önerdikleri evrimsel ağ yapısının performansını artırmak için görüntüye ön işleme uygulamıştır. Sekiz gizli katmandan oluşan mimari, ilgili veri kümesinde %98,4 başarı elde etmiştir. Wspanialy ve Moussa [93], PlantVillage domates veri kümesinin çeşitli sürümlerini kullanarak farklı yaprak özelliklerinin hastalık tespiti üzerindeki etkisini araştırmıştır.

Hasan ve arkadaşları [94] az sayıda domates yaprağı görüntüsünü (2600), baskın bir kıvrımlı ağ kullanarak üç pestisit yoğunlaşması sınıfına sınıflandırmıştır. Geetharamani ve Pandian [95], bitki yaprağı hastalıklarının tanımlanması için önerilen CNN'e dayalı yeni bir dokuz katmanlı model önermiştir. Modelin eğitimi için kullanılan veri kümesine veri büyütme yöntemleri uygulanmıştır. Bu sürecin bir performans iyileştirme etkisi olmuştur.

Karthik ve arkadaşları [96], iki farklı derin mimari kullanarak domates yapraklarındaki enfeksiyon tipini sınıflandırmıştır. Dört sınıflı PlantVillage veri kümesi kullanılarak yapılan çalışmada önerilen yöntem %98 başarı sağlamıştır. Chen ve arkadaşları [97], domates yapraklarını sınıflandırmak için yeni bir çerçeve önermiştir. Görüntüler retinex, ikili dalgacık dönüşümü gürültüsü ve kenar noktaları ile kaldırılmıştır. Yapay arı kolonisi ile optimize edilmiş KSW

kullanılarak yapraklar arka plandan ayrılmıştır. Daha sonra iki kanallı artık dikkat ağı görüntülerini tanımlamak için kullanılmış, 8616 görüntünün kullanıldığı uygulamada %89 doğruluk elde edilmiştir.

Durmuş ve arkadaşları [98], hastalıkları tespit etmek için derin öğrenme yöntemlerini kullanmışlardır. AlexNet ve SqueezeNet mimarilerinin test edildiği çalışmada, eğitim için PlantVillage veri kümesindeki görüntüler kullanılmıştır. Foysal ve arkadaşları [99], domates hastalıklarını sınıflandırmak için 15 katmanlı bir CNN önermiştir. Sonuçlar, altı sınıf için toplam 3000 görüntünün eğitilmesi ve doğrulanmasıyla gösterilmiştir.

Batool ve arkadaşları [100], domates yaprağı hastalığını saptayan ve sınıflandıran bir sınıflandırma modeli önermiştir. 450 görüntüden oluşan bir eğitim veri kümesi kullanılarak yapılan çalışmada, çeşitli modeller kullanılarak görüntü öznitelikleri çıkarılmıştır. Sınıflandırma için k-NN uygulanmıştır. En yüksek doğruluk %76,1 olarak AlexNet modeli ile elde edilmiştir.

Nasir ve arkadaşları [101], meyveleri ve hastalıklarını sınıflandırmak için birleşik bir derin sinir ağı ve kontur özelliği tabanlı bir yaklaşım kullanmıştır. VGG19, yönlendirilmiş gradyan piramit histogramı (PHOG), füzyon tekniği, optimizasyon tekniği ve farklı sınıflandırıcıların kullanıldığı hibrit yöntem ile ilgili veri kümesinde %99,6 başarı sağlanmıştır. Wang ve arkadaşları [102], domates hastalıklarının tespiti için internetten toplanan hastalıklı domates görüntülerinden oluşan bir veri kümesi kullanmışlardır. Yazarlar, Faster R-CNN ve mask RCNN nesne algılama modellerini kullanarak, kullandıkları veri kümesinde yüksek doğruluk elde etmişlerdir.

Gonzalez-Huitron ve arkadaşları [103], domates yapraklarındaki hastalıkları sınıflandırmak için dört yeni CNN modeli denemiştir. PlantVillage veri kümesinin bir alt kümesi, aktarım öğrenimi için 10 sınıfa ayrılmıştır. Raspberry Pi4 mikrobilgisayar üzerinde grafiksel kullanıcı ara yüzüne sahip bir uygulama geliştirilerek gerçek zamanlı olarak sınıflandırma sağlanmıştır. Fuentes ve arkadaşları [104], bitki hastalıklarının tanınması için derin öğrenmeye dayalı bir teknik sunmuştur. Yöntem, bitki hastalıklarını ve görüntüdeki yerini tanımak için derin bir meta-mimariye ve bir özellik çıkarıcıya dayalı bir çözüm sunar. Filtre Bankası adı verilen bir iyileştirme fonksiyonu getirilerek, uygulandıkları veri kümesinde model performansı 0,9625 mAP olarak elde edilmiştir.

4.3. Materyal ve Metot


Bu bölümde, gerçekleştirilen deneylerde kullanılan veri kümeleri, özellik seçim yöntemi ve özellik birleştirme yöntemi hakkında bilgi verilmiştir. Ayrıca bu bölümde, geliştirilen yöntemin genel yapısı hakkında bilgiler yer almaktadır.

4.3.1. Veri Kümeleri

Bu çalışma iki farklı veri kümesi ile eğitim ve doğrulama işlemlerine tabi tutulmuştur. Tezin bu kısmında ilgili veri kümeleri anlatılmaktadır.

Tomato Leaf Disease Detection Veri Kümesi

Kullanılan ilk veri kümesi 10 sınıf içeren Tomato leaf disease detection veri kümesidir [105]. Eğitim ve doğrulama süreçlerindeki veri kümesi 10 sınıfa sahiptir. Sınıflardan dokuzu; bakteriyel leke (bacterial spot), erken yanıklık (early blight), geç yanıklık (late blight), yaprak küfü (leaf mold), mozaik virüsü (mosaic virus), septorial yaprak lekesi (septorial leaf spot), örümcek akarları iki benekli örümcek akarı, (spider mites two spotted spider mite), hedef nokta (target spot) ve sarı yaprak kıvrılması (yellow leaf curl virus) hastalık/zararlı sınıflarıdır. Diğer bir sınıf ise sağlıklı (healthy)'dır. Her sınıfta 1000 görüntü bulunur. Toplamda, veri kümesi 10.000 görüntü içermektedir. Şekil 4.2, veri kümesinden alınmış görüntü örneklerini vermektedir.



Şekil 4.2. Tomato leaf disease detection veri kümesinden alınmış örnek görüntüler [105]

Taiwan Tomato Leaves Veri Kümesi

Taiwan tomato leaves veri kümesi, beş hastalık/zararlı kategorisi ve bir sağlıklı olmak üzere altı kategoriden oluşmaktadır. Sınıflar şu şekildedir: bakteriyel leke, black leaf spot (kara yaprak küfü), gray leaf spot (gri yaprak lekesi), geç yanıklık, powdery mildew (külleme) ve sağlıklı'dır. Görüntüler tek bir yaprak, birden çok yaprak, tek bir arka plan ve karmaşık bir arka plandan oluşur. Bu veri kümesinde 4976 görüntü bulunmaktadır. Şekil 4.3, veri kümesinin içerdiği bazı örnek görüntüleri vermektedir.

Kategori	Bakteriyel leke	Kara yaprak kütü	Gri yaprak lekesi	Sağlıklı	Geç yamalık	Küleme
Görüntü sayısı	880	536	672	848	848	1256
Örnek görüntü						

Şekil 4.3. Taiwan tomato leaves veri kümesinden alınmış örnek görüntüler ve görüntü sayıları [106]

4.3.2. Özellik Seçimi

Özellik seçimi, ilgili veri kümesindeki en kullanışlı özellikleri bulma ve seçme işlemidir. Bu süreç, model performansını büyük ölçüde etkiler. Gereksiz özellikler modelin eğitim sürecini uzatabilir. Ayrıca modeldeki hata oranını da artırırlar. Model tasarımında verilerin temizlenmesi ve özelliklerin seçilmesi performansı artırabilir [107].

Özellik seçim yöntemleri, filtre tabanlı yöntemler, gömülü yöntemler ve sarmalayıcı tabanlı yöntemler olarak gruplandırılabilir [108,109]. Filtre tabanlı yöntemler, öğrenme sürecinden bağımsız olarak özellik seçimini gerçekleştirirken; sarmalayıcı tabanlı ve gömülü yöntemler, en uygun öznetelik alt kümesini seçmek için öznetelik seçimini öğrenme süreciyle birleştirir [110].

MRMR algoritması, sınıfla yüksek korelasyona ve aralarında düşük korelasyona sahip özellikleri seçme eğiliminde olan filtre tabanlı bir özellik seçim yaklaşımıdır. Karşılıklı bilgilere dayalı olarak mRMR kriterlerine göre özellikleri sıralayarak işlemleri gerçekleştirir [111].

MRMR algoritması, karşılıklı bilgi farkı (MID), karşılıklı bilgi bölümü (MIQ), F-test korelasyon farkı (FCD) ve F-test korelasyon katsayısı (FCQ) olarak bilinen dört seçim kriterine sahiptir. Çalışmada kullanılan MID kriterinin temel formülü Denklem (3.1)'deki gibidir.

$$I(C, A_j) - \frac{1}{|S|} \sum_{A_s \in S} I(A_s, A_j) \quad (3.1)$$

Bu denklemde C karşılık gelen sınıf etiketidir, A_j verilen özellik kümesidir, S seçilen özellik kümesidir ve $|S|$ özellik kümesinin boyutunu ifade eder [112].

4.3.3. Özellik Birleştirme

Özellik birleştirme, sınıflandırma sürecini geliştirmek için farklı özellikleri bir araya getirmenin etkili bir yoludur [113]. Bu çalışmada özellik birleştirme iki şekilde uygulanmıştır. İlkinde, belirlenen üç ön-eğitilmiş modelin çıkartılan özellikleri herhangi bir işlem yapılmaksızın uygulanmıştır. Böylece son özellik tanımlayıcısı Denklem 3.2'deki gibi oluşturulmuştur.

$$\text{Özellik_Tanımlayıcı} = \text{Ö}^{\text{AlexNet}} \cup \text{Ö}^{\text{ResNet50}} \cup \text{Ö}^{\text{VGG16}} \quad (3.2)$$


İkincisinde, mimarilere ayrı ayrı özellik seçim algoritması uygulanarak en etkili özelliklerin seçilmesi amaçlanmıştır. Seçilen özelliklere birleştirme işlemi uygulanmıştır. Son özellik kümesi bu özelliklerin, özellik birleştirme yöntemi kullanılarak aşağıdaki şekilde birleştirilmesi ile elde edilmiştir:

$$\text{Özellik_Tanımlayıcı} = \text{Ö}^{S(\text{AlexNet})} \cup \text{Ö}^{S(\text{ResNet50})} \cup \text{Ö}^{S(\text{VGG16})} \quad (3.3)$$

Burada Özellik=Ö ve Özellik Seçimi=S olarak tanımlanmıştır.

4.3.4. Metot

Domatesler birçok farklı hastalıkla tehdit edilmektedir. Hastalıkların belirtileri genellikle bitkinin yapraklarında görülür. Bu belirtiler birbirine benzediği için hastalıkları ayırt etmek kolay değildir. Bu ana zorluktur. Bu çalışmada, hastalıkların tespiti için CNN tabanlı hibrit model önerilmektedir. Üç adımdan oluşan önerilen yöntemin grafiksel özeti Şekil 4.4'te gösterilmiştir.



Şekil 4.4. Önerilen yöntemin grafiksel özeti

Önerilen yöntemin adımları aşağıdaki gibidir:

Adım 1: Özellik transfer yöntemi ile önceden eğitilmiş CNN mimarilerinden özelliklerin çıkarılması

Modeller sıfırdan veya aktarım öğrenme yöntemi ile eğitilebilir [114]. Özellikle çok fazla verinin olmadığı problemlerin çözümünde aktarım öğrenme yönteminin kullanılması performans açısından fayda sağlamaktadır. Özellik aktarım yöntemi, bir aktarım öğrenme şeklidir. Yöntemimizde görüntü sınıflandırma problemlerinin çözümünde etkin mimariler olan AlexNet, ResNet50 ve VGG16 mimarileri kullanılmıştır. Bu mimarilerin son tam bağlantılı katmanlarından 1000 öznitelik alınmıştır. CNN'de, ilk katmanlar renk ve kenar gibi daha az ayırt edici özellikler üretirken, sonraki katmanlar ayırma sağlayan daha spesifik özellikler üretir. Bu nedenle, mimarilerin son tam bağlantılı katmanlarındaki özellikler alınmıştır.

Adım 2: Özelliklerin seçilmesi ve birleştirilmesi

Öznitelik aktarımı ile çıkarılan öznitelik kümeleri iki farklı şekilde işlendikten sonra sınıflandırma aşamasına geçilir. İlk olarak, seçilen mimarilere veri kümesinin uygulanması ile alınan özelliklerin birleştirilmesiyle 3000 öznitelik içeren küme elde edilmiştir. Ardından, mRMR öznitelik seçim algoritması, üç mimarideki özniteliklere ayrı ayrı uygulanmıştır. mRMR algoritması, özellikleri karşılıklı bilgilere dayalı olarak minimum artıklık ve maksimum uygunluk ölçütlerine göre sıralayarak gerçekleştirir. Yöntemde en etkili öznitelikler mRMR algoritması kullanılarak listelenir. Her bir mimariden en iyi 100 özellik alınmıştır. Son olarak bu adımda özellik kümeleri bir araya getirilerek 300 özellik elde edilmiştir.

Adım 3: Sınıflandırma

Son adım sınıflandırmadır. İlk iki adımda elde edilen farklı sayı ve yapıdaki öznitelik kümeleri sınıflandırıcılara girdi olarak verilir. Kullandığımız algoritmalar, doğrusal SVM (LSVM), ikinci dereceden SVM (QSVM), k-NN, NB, LDA ve DT'dir.


4.4. Deneysel Sonuçlar

Çalışmada öncelikle AlexNet, ResNet50 ve VGG16 mimarilerinden alınan özellik kümeleri geleneksel makine öğrenme sınıflandırıcılarına ayrı ayrı verilerek domates yaprak hastalıkları sınıflandırılmıştır. Verilerin %70'i eğitim ve %30'u doğrulama için ayrılmıştır. Özellikler, üç mimarinin tümü için son tam bağlı katmanlardan alınır. Sağlanan sınıflandırma doğruluk değerleri Tablo 4.1'de verildiği gibidir.

Tablo 4.1. Temel mimarilerin sınıflandırma doğrulukları (%)

	QSVM	LSVM	LDA	k-NN	NB	DT
ResNet50-1000(Tomato leaf disease)	96,1	94,0	96,3	84,8	71,4	55,4
VGG16-1000 (Tomato leaf disease)	87,7	84,2	89,5	68,7	60,5	49,9
AlexNet-1000 (Tomato leaf disease)	90,3	86,6	90,1	73,5	63,4	50,1
ResNet50-1000 (Taiwan tomato leaves)	89,0	75,2	85,8	94,5	49,6	54,3
VGG16-1000 (Taiwan tomato leaves)	88,9	73,3	86,2	95,2	52,3	55,7
AlexNet-1000 (Taiwan tomato leaves)	89,9	74,8	85,1	96,5	56,5	58,7

Tomato leaf disease detection veri kümesi için en yüksek doğruluğa ResNet50 modelinden elde edilen özelliklerin LDA ile sınıflandırıldığı yöntem ile ulaşılmıştır. Taiwan tomato leaves veri kümesi için en yüksek doğruluk AlexNet tarafından alınan özelliklerin k-NN ile sınıflandırılması ile sağlanmıştır. İki veri kümesine ait karmaşıklık matrisleri Şekil 4.5'de verilmiştir.



Şekil 4.5. (a) ResNet50-1000 &LDA (Tomato leaf diseases detection veri kümesi) ve (b) AlexNet-1000&k-NN (Taiwan tomato leaves veri kümesi) modellerin karmaşıklık matrisleri

Deneylerin ikinci kısmında alınan öznetelik kümelerine öznetelik seçme yöntemi mRMR uygulanarak öznetelik sayısı her model için 100'e düşürülmüştür. Daha sonra bu öznetelikler birleştirilerek 300 öznetelik elde edilmiştir. Sonuçlar, altı farklı makine öğrenme yöntemine özellikler atanarak gözlemlenmiştir. Bu şekilde elde edilen doğruluk değerleri Tablo 4.2 ve Tablo 4.3'deki gibidir.

Tablo 4.2. Tomato leaf disease detection veri kümesi için mRMR uygulanmış modellerin sınıflandırma doğrulukları (%)

Özellik Seçimi				
Sınıflandırıcı	AlexNet	VGG16	ResNet50	AlexNet, ResNet50, VGG16 ve mRMR
QSVM	85,3	92,4	91,3	96,3
LSVM	80,3	89,3	87,9	95,7
LDA	79,8	86,5	85,1	96,3
k-NN	67,6	79,8	78,7	80,9
NB	59,0	66,9	65,3	79,9
DT	43,3	49,2	49,7	48,9

Tablo 4.3. Taiwan tomato leaves veri kümesi için mRMR uygulanmış modellerin sınıflandırma doğrulukları (%)

Özellik Seçimi				
Sınıflandırıcı	AlexNet	VGG16	ResNet50	AlexNet, ResNet50, VGG16 ve mRMR
QSVM	87,2	86,0	92,4	92,7
LSVM	68,5	76,5	76,8	85,3
LDA	69,8	70,0	72,8	86,7
k-NN	93,1	93,7	96,6	96,3
NB	55,6	53,1	54,9	63,4
DT	55,4	51,8	59,3	57,2

Tomato leaf diseases veri kümesi üzerinde yapılan deneylerde, özellik kümeleri ile çalıştırılan mRMR algoritmasından sonra tüm kümeler sadece 100 özneliğe indirgenmiştir. VGG16'dan alınan özelliklerin QSVM tarafından sınıflandırıldığı model ile en yüksek performans elde edilmiştir. Yalnızca 100 özneliğin kullanıldığı yöntemlerden ResNet50 ve AlexNet mimarileri Tablo 4.1'de gösterilen değerlerden daha düşük doğruluk elde etmiştir. Öte yandan VGG16, seçilen öznelikler ile daha iyi performans sağlamıştır. Üç mimarinin her birinden 100 özelliğin birleştirilmesiyle oluşturulan model, diğer tüm modellerden daha yüksek başarımla elde etmiştir. QSVM ve LDA sınıflandırıcıları %96,3 doğruluğa ulaşmıştır. Diğer modellerin performansının da arttığı gözlenmiştir. Kullanılan yöntem hastalık belirtisi olan domates yapraklarının sınıflandırılma başarısını artırmada etkilidir. Üç mimariden alınan özneliklere uygulanan öznelik seçimi ve birleştirme sonrası QSVM sınıflandırıcısına verilen yöntemin karmaşıklık matrisi Şekil 4.6'da verilmiştir.

Gerçek Sınıf \ Tahmin Sınıf	1	2	3	4	5	6	7	8	9	10
1	294	2	3		1					
2	3	283	4	2		1	7			
3		11	284	3		2				
4	2	4	4	282	3	4				1
5	3	3	1	1	285		7			
6		2				284	14			
7		2	1			5	292			
8		2				4		293		1
9							6		294	
10				1		1				298

Şekil 4.6. AlexNet+ResNet50+VGG16, mRMR ve QSVM modelinin karmaşıklık matrisi (Tomato leaf disease detection veri kümesi)

Taiwan tomato leaves veri kümesi üzerinde aynı yöntemler uygulanmıştır. Yapılan deneylerde genellikle domates yaprak hastalıkları veri kümesi ile kıyaslandığında daha düşük doğruluklar elde edildiği raporlanmıştır. Taiwan tomato leaves veri kümesi, tomato leaf diseases veri kümesinden daha az kategoriden oluşur. Fakat içerdiği görseller açısından daha zorlayıcıdır. Tablo 4.3 mRMR özellik seçimi kullanılarak 100'e düşürülen özellik kümeleri ile gerçekleştirilen deneylerin doğruluk değerlerini vermektedir. Üç mimarinin her birinden 100 özelliğin birleştirilmesiyle oluşturulan model, diğer tüm modellerden daha yüksek başarımla elde etmiştir. K-NN sınıflandırıcı %96,3 doğruluk elde etmiştir. Diğer modellerin başarımlarının da arttığı gözlemlenmiştir. Üç mimariden alınan özneliklere uygulanan öznelik seçimi ve birleştirme sonrası k-NN sınıflandırıcısına verilen yöntemin karmaşıklık matrisi Şekil 4.7'dedir.

1	200	7	1	1		2
2	4	119	1	4		1
3	3	1	150		2	5
4	3	2	5	170	1	7
5					203	
6	2	1	9		4	285
	1	2	3	4	5	6

Tahmin Sınıfı


Şekil 4.7. AlexNet+ResNet50+VGG16,mRMR ve k-NN modelinin karmaşıklık matrisi (Taiwan tomato leaves veri kümesi)

Son olarak AlexNet, ResNet50 ve VGG16'dan alınan özellikler birleştirilmiştir. Toplam 3000 özellikten oluşan özellik kümesi, diğer deneylerde olduğu gibi QSVM, LSVM, LDA, k-NN, NB ve DT algoritmalarına beslenmiştir. LDA'nın sınıflandırıcı olarak kullanıldığı yöntem %99,0 ile en yüksek doğruluğa ulaşmıştır. Bu yöntemi sırasıyla QSVM, LSVM, NB, k-NN ve DT izlemiştir. Tablo 4.4, yöntemlerin doğruluk, yanlış sınıflandırma maliyeti, eğitim zamanı değerlerini vermektedir. LDA'nın kullanıldığı yöntem, eğitim süresi açısından en hızlı olanıdır.

Tablo 4.4. AlexNet+ResNet50+VGG16 özellikleri ve farklı sınıflandırıcılar ile oluşturulan modellere ait başarımlar (Tomato leaf disease detection veri kümesi)

	QSVM	LSVM	LDA	k-NN	NB	DT
Doğruluk (%)	98,3	97,7	99,0	81,4	89,3	58,1
Toplam yanlış sınıflandırma	51	69	31	558	322	1258
Eğitim zamanı (s)	150,45	96,195	74,715	139,39	79,625	64,274

Şekil 4.8 en yüksek doğruluğu göstermiş olan mimarinin karmaşıklık matrisini vermektedir. Tablo 4.5 aynı mimarinin sınıflandırma sonuçlarına bakarak her bir sınıf için başarımlar ölçütlerini göstermektedir.



Şekil 4.8. AlexNet+ResNet50+VGG16 ve LDA modelinin karmaşıklık matrisi (Tomato leaf disease detection veri kümesi)

Tablo 4.5. AlexNet+ResNet50+VGG16 ve LDA modelinin sınıflandırma sonuçları (%) (Tomato leaf disease detection veri kümesi)

Metrik	Bakteriyel leke	Erken yanıklık	Sağlıklı	Geç yanıklık	Yaprak küf	Mozaik virüs	Septoriyal yaprak küf	Örümcek akarı	Hedef nokta	Sarı yaprak kıvrılması
ACC	99,9	99,2	99,6	99,9	99,8	99,7	99,6	99,9	100	100
SP	99,9	99,6	99,8	99,9	99,9	99,8	99,5	100	100	100
PREC	99,3	93,7	98,9	99,6	99,3	98,9	98,9	96,4	100	100
SN	99,6	95,6	97,3	100	99,0	98,6	99,6	99,6	100	100
F1	99,4	94,6	98,0	99,7	99,1	98,7	99,2	97,9	100	100

4.5. Sonuçlar ve Tartışma

Domates, tüm dünyada yaygın olarak üretilen ve tüketilen bir tarım ürünüdür. Yetiştirme işlemi sırasında çeşitli nedenlerle birçok hastalıkla karşılaşabilir. Bu durum domates verimini düşürür. Domatesin sağlık durumu yapraklara bakılarak anlaşılabilir. Hastalığın tespiti ve tedavisinin sağlanması ürünün sağlıklı hale gelmesini sağlar.

Bu uygulamada, iki veri kümesi kullanılmıştır. Bunlardan biri 10 sınıflı Tomato leaf disease veri kümesi, diğeri ise altı sınıflı Taiwan tomato leaves veri kümesidir. İlk olarak, önceden eğitilmiş AlexNet, ResNet50 ve VGG16 mimarilerinden öznitelikleri çıkarmak için bir aktarım öğrenme biçimi olan öznitelik aktarım yöntemi kullanılmıştır. Daha sonra etkin öznitelikler elde etmek için öznitelik seçimi ve öznitelik birleştirme gibi işlemler yapılmıştır.

Bu şekilde elde edilen farklı öznitelik kümeleri altı farklı makine öğrenmesi yönteminden faydalanılarak sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntemde, omurga olarak tek bir mimarinin kullanıldığı yapılara göre özellik seçimi yöntemi eğitim süresi ve doğruluk kıstasları

açısından olumlu etki yapmıştır. Ayrıca üç ortak CNN mimarisinin tam bağlantılı son katmanlarından alınan özneliklerin birleştirilmesiyle elde edilen özellik kümesi en yüksek başarıyı göstermiştir. LDA algoritması ile sınıflandırılan tomato leaf disease veri kümesi % 99,0 sınıflandırma doğruluğu elde etmiştir.

Tablo 4.6. Konuyla ilgili yapılmış çalışmalar ile önerilen yöntemin karşılaştırılması

Çalışma/Yıl	Veri kümesi/Sınıf sayısı	Yöntem	Doğruluk
[115]/2017	7040/10	VGGNet	%89,0
[91]/2018	PlantVillage/7	VGG16	%97,49
[91]/2018	PlantVillage/7	AlexNet	%97,29
[116]/2018	5550 görüntü/ 9	ResNet	%97,28
[117]/ 2019	7176 görüntü/10	Mobilenet	%90,3
[90]/2020	PlantVillage/10	CNN	%91,2
[100]/2020	450 görüntü/10	k-NN	%76,1
[90]/2020	PlantVillage/10	Önişleme &CNN	%98,7
[96]/2020	Plant Village/4	Dikkate dayalı artık CNN	%98,0
[97]/2020	PlantVillage/5	ABCK-BWTR & B-ARNET	%89,0
[99]/2020	3000 görüntü/6	15 katmanlı CNN	%76,0
[93]/2020	PlantVillage/10	Geliştirilmiş UNET& ResNet	%97,0
[103]/2021	PlantVillage/10	MobileNetV3	%98,0
[104]/2020	Tomato Plant Diseases and Pest/10	CNN & Filtre bankası	96,25 mAP
Önerilen	Taiwan tomato leaves/6	CNN&mRMR&k-NN	%96,3
Önerilen	Taiwan tomato leaves/6	CNN&k-NN	%96,5
Önerilen	Tomato leaf diseases/10	CNN&mRMR& QSVM	%98,3
Önerilen	Tomato leaf diseases/10	CNN&LDA	%99,0

Hastalıkların tespiti, çiftçilerin ekim alanlarını düzenli aralıklarla izlemelerini gerektirir. Bu işlem özellikle geniş ekim alanlarında oldukça zahmetlidir. Bu nedenle hastalıkları tespit etmek için otomatik sistemler faydalıdır. Deneysel sonuçlar, yöntemimizin etkili olduğunu göstermektedir.

Konuyla ilgili yapılan çalışmalar ile önerilen yöntemin karşılaştırılması Tablo 4.6'da verilmiştir. Bu tabloya göre yöntemimiz hastalıkların sınıflandırılmasını diğer yöntemlere göre daha doğru bir şekilde öngörmektedir. Yöntemin eğitimi için kullanılan veri kümeleri farklı arka plan bilgileri içermektedir. Görüntülerde yalnızca bir yaprak veya birden çok yaprak bulunur. Hastalığın tespiti için tarlada yaprağın çıkarılması gerekli değildir. Bitkinin hastalık bilgisi bitkiyi sökmeden elde edilir. Bu nedenle yöntem gerçek zamanlı olarak tarım alanlarında kullanılabilir. Önerilen yöntemin tarım alanlarında kullanılmasının hastalıkların tespiti ve tedavi önlemlerinin alınması açısından faydalı olacağı kanaatindeyiz.

5. COVID-19 HASTALIK TESPİTİ ÜZERİNE BİR YAKLAŞIM

Bu çalışma, X-ray görüntülerinden Covid-19, normal ve zatürre ayrımının sağlanmasına odaklanmaktadır. Hastalığın erken tespit ve tedavisinin sağlanması amacıyla, CNN mimarilerinden çıkartılan özelliklerin birleştirilmesinin esas alındığı bir yöntem önerilmektedir.

5.1. Problem Tanımı

2019 yılının sonunda SARS-CoV-2 (Covid-19) adlı yeni bir virüs ortaya çıkmıştır [118]. Son on yılda, yeni korona virüsleri insan sağlığı için ciddi bir tehdit oluşturmıştır. Daha önce tüm dünyada halk sağlığı tehditleri olarak karşımıza çıkan (SARS)-CoV ve (MERS)-CoV olarak adlandırılan virüsler, korona virüsünün önceki salgınları olarak da bilinmektedir [119]. Virüs, 30 Ocak 2020 tarihinde Dünya Sağlık Örgütü tarafından uluslararası öneme sahip acil bir halk sağlığı sorunu olarak ilan edilmiştir [120].

Virüsün bulaştığı hastalarda farklı belirtiler görülüyor. En sık görülen belirtiler kuru öksürük, yüksek ateş ve titremedir. Daha az yaygın belirtiler baş ağrısı, koku kaybı, deri döküntüsü ve boğaz ağrısıdır [121, 122]. Zayıf bağışıklığı ve kronik hastalığı olan kişiler için virüs ölümcüldür. Virüsün yayılma hızı ve ciddi etkileri göz önüne alındığında, virüs bulaşmış bireylerin erken tespit edilmesi hayati önem taşımaktadır. Temas ve damlacıklar yoluyla bulaşan virüsü kontrol altına almanın en etkili yöntemi, erken teşhis ile enfekte hastaların ayrıklaştırılmasını ve tedavisini sağlamaktır [122].

Enfeksiyondan şüphelenilen hastaların teşhisi birçok laboratuvar testi ile doğrulanabilir. Bronkoalveolar lavaj sıvısı üzerinde tam genom dizilimi ve filogenetik analiz, Covid-19 bulaşını doğrulayabilir. Şüpheli hastalardan bazı örnekler (burun salgıları, kan, balgam ve bronkoalveolar lavaj) alınarak Covid-19'a özgü serolojik ve moleküler testlere tabi tutulur. Serolojik testlerde, belirli Covid-19 proteinlerini tanımlayan enzime bağlı immünosorbent testi (ELISA) veya batı lekesi testleri kullanılır. Moleküler tanıda gerçek zamanlı transkriptaz polimeraz zincir reaksiyonu (RT-PCR) veya kuzey lekesi hibridizasyonu kullanılmaktadır. Ayrıca, klinik örneklerde bulunan viral antijenler, doğrudan immün floresan testi (IFA) kullanılarak tespit edilir. Tanı için kullanılan altın standart PCR testidir. Nükleik asit testlerinin sadece %30-50 doğruluğa ulaştığı ileri sürülmektedir [123]. Enfekte bölgedeki laboratuvar testlerinin sınırlamaları ve kalitesi, alternatif teşhis yöntemleri gerektirir.

Son zamanlarda yapılan araştırmalar, bilgisayarlı tomografi (BT) ve X-ray (röntgen) gibi araçların Covid-19 virüsü hakkında önemli bilgiler içerdiğini ve başka bir tanı yöntemi olarak kullanılabileceğini göstermiştir [124]. Göğüs röntgeni, daha hızlı görüntüleme süresi, düşük maliyeti ve taşınabilirliği nedeniyle öne çıkmaktadır. Araştırmacılar tarafından hastalığın teşhisi için kullanılan en yaygın ve etkili yöntemlerden biri göğüs röntgeni görüntüleridir [125, 126].

Ancak görüntüleri incelemek için radyoloji uzmanı ve zaman gereklidir. Bu durum salgın koşullarında zorlayıcıdır. Bu nedenle alternatif olarak, yapay zekâya dayalı otomatik, hızlı tarama yöntemleri erken teşhis ve sahadaki sağlık personelinin iş yükünün hafifletilmesi için faydalıdır.

5.2. İlgili Çalışmalar

Derin öğrenme, tıp alanında yaygın olarak kullanılmaktadır. Covid-19 tanımlama araştırmalarında sınıflandırma, segmentasyon ve tespit yöntemleri dâhil olmak üzere çeşitli metodolojiler önerilmiştir.

Varma ve arkadaşları [127], Uzun Kısa Süreli Bellek (LSTM) kullanarak Covid-19 pozitif vakayı doğrulamak için tahmin analizi gerçekleştirmiştir. Nayak ve arkadaşları [128], Covid-19'un erken tespiti için X-ray görüntülerini kullanan derin öğrenme destekli otomatik bir teknik önermiştir. Sekiz önceden eğitilmiş CNN mimarisi değerlendirilmiştir. En iyi performans ResNet34 ile %98,33 doğrulukla elde edilmiştir. Xu ve arkadaşları [129], derin öğrenme yöntemlerini kullanarak pulmoner BT görüntüleri aracılığıyla Covid-19, IAVP ve sağlıklı bireyleri ayırt etmeyi amaçlamıştır. Çalışma %86,7 doğruluk sağlamıştır. Hemdan ve arkadaşları [130], Covid-19'u X-ray görüntülerinden ayırt etmek için 25 pozitif vakanın görüntülerini kullanmıştır. Çalışma, CovidxNet, ResNet, GoogleNet gibi 7 farklı eğitim çerçevesi içermektedir. En yüksek doğruluk %90 olarak VGG19 ile elde edilmiştir. Wang ve arkadaşları [131], eğitim için 217 görüntü kullanmıştır. Algoritmayı oluşturmak için başlangıç geçiş-öğrenme modelinden yararlanmışlardır. Yöntem % 82,9 doğruluk elde etmiştir.

Song ve arkadaşları [132], Çin'deki iki ildeki hastanelerden, Covid-19 teşhisi konan, bakteriyel zatürre ile enfekte olan ve sağlıklı kişilerden göğüs BT taramaları toplamıştır. Toplanan veri kümesine dayanarak, Covid-19 hastalarını belirlemek için derin öğrenmeye dayalı bir teşhis sistemi uygulanmıştır. Model, 0,95 AUC değeriyle Covid-19 ile enfekte olan hastaları ayırt edebilmiştir. Çalışmada buzlu cam görüntü lokalizasyonu da akciğerde yapılmıştır. BT görüntülerinden Covid-19 hastalığını tespit etmek ve sınıflandırmak için zayıf denetimli bir derin öğrenme tekniği [133]'de önerilmiştir. He ve arkadaşları [134], Covid-19 için pozitif BT taramasını içeren halka açık bir veri kümesi oluşturmuştur. Aşırı uyum riskini azaltmak için, kontrastlı kendi kendine geçiş öğrenmeyi aktarım öğrenme ile bütünleştiren bir kendinden geçiş yaklaşımı önerilmiştir. Önerilen kendinden geçiş yaklaşımı, Covid-19 tanısında 0,85 F1 puanına ve 0,94 AUC'ye ulaşmıştır. Wang ve arkadaşları [135], BT ile Covid-19 teşhisi için tam otomatik bir derin öğrenme yöntemi önermiştir. Dört harici doğrulama kümesinde derin öğrenme sistemi, Covid-19'u diğer zatürre ve viral zatürreden ayırmada iyi performans göstermiştir.

[136]'da, kapsül ağları ve göğüs röntgeni görüntüleri kullanılarak Covid-19 enfeksiyonunun sınıflandırılması için Evrişimsel CapsNet önerilmiştir. Önerilen strateji, ikili ve çok sınıflı Covid-19 hastalıkları için teşhis sağlamayı amaçlamıştır. İkili ve çok sınıflı sınıflandırmalar için önerilen

yöntemin doğruluğu sırasıyla, %97,24 ve %84,22 olmuştur. Öztürk ve arkadaşları [137], değiştirilmiş DarkNet mimarisini kullanarak X-ray görüntülerinden covid sınıflandırması yapmıştır. Yazarlar %87,02 doğruluk elde etmiştir. Chaudhary ve arkadaşları [138], görüntü ayrıştırma için Fourier-Bessel serisi genişletme tabanlı ikili ayrıştırma (FBD) yaklaşımını tanıtmıştır. Yöntemde FBD ile elde edilen alt bant görüntüleri önceden eğitilmiş Resnet50 ağına verilmektedir. Prosedürler kullanılarak, her bir CNN'den gelen derin özellikler birleştirilir. Softmax sınıflandırıcısı daha sonra topluluk CNN özelliklerine beslenir. Modelin genel doğruluğu %98,6'dır.

Hussain ve arkadaşları [139], önerdikleri 22 katmanlı CNN yapısını X-ray görüntülerinin 2, 3 ve 4 sınıf sınıflandırması için kullanmıştır. Sırasıyla %99,1, %94,2 ve %91,2 doğruluk elde etmişlerdir. Verma ve arkadaşları [140], aşırı uydu sorunu ortadan kaldırmak için farklı öğrenme oranları denemiştir. Çalışmada Covid-19 görüntülerini tanımlamak için aktarım öğrenme yönteminin ve 2 katmanlı CNN topluluğunun kullanılması önerilmiştir. Yöntem ile %90,45 doğruluk sağlamışlardır. Yıldırım ve arkadaşları [141], ResNet50 yapısının katman sayısını artırarak oluşturdukları yöntemle X-ray görüntülerinden bir Covid-19 sınıflandırması yapmıştır. Teknik, %96,30'luk bir doğruluk göstermiştir.

Literatürde bildirilen çalışmaların çoğu, Covid-19 teşhisi için ikili sınıflandırmada yüksek doğruluk elde etmiştir. Ancak çoklu sınıflandırmalarda başarı oranı, ilgili veri kümelerinde ikili sınıflandırmadaki kadar yüksek doğruluk değerine ulaşamamıştır. Covid-19 hastalığını diğer akciğer hastalıklarından ayırt etmek için daha doğru çoklu sınıflandırmalar yapmak önemlidir. Çalışma bu konuya odaklanmakta ve üç sınıflı veri kümeleri ile çalışmaktadır. Önerilen yöntem, üç sınıflı sınıflandırma için yüksek doğruluk oranları elde etmiştir. Ayrıca önerilen yöntem hesaplama süresi açısından da verimlidir.


5.3. Veri Kümeleri

Çalışma, röntgen görüntülerini içeren veri kümelerini kullanarak Covid-19 teşhisinin geliştirilmesine katkıda bulunmaktadır. Bu amaçla üç farklı veri kümesi ile çalışılmıştır. Bunlardan ilki, Montreal Üniversitesi tarafından yayınlanan Covid-19 Image veri kümesidir [142]. İkincisi, Katar Üniversitesi, Doha, Katar ve Dakka Üniversitesi, Bangladeş'ten bir araştırma ekibi ile Pakistan ve Malezya'daki işbirlikçilerle işbirliği içinde oluşturulan Covid-19 Radiography veri kümesidir [143, 144]. Bir diğeri Covid-19 Pneumonia Normal Chest X-ray (PA) veri kümesidir [145]. Kullandığımız veri kümelerinin ortak özelliği X-ray görüntüleri içermeleri ve üç sınıftan oluşmalarıdır. İçerdikleri görüntülerin sayısı birbirinden farklıdır. Eğitim ve doğrulama süreçlerinde kullanılan veri kümelerinde yer alan sınıflar ve görüntü sayıları Tablo 5.1'de verilmektedir.

Tablo 5.1. Eğitim ve doğrulama süreçlerinde kullanılan veri kümelerinin içerdiği sınıflar ve görüntü sayıları

Veri Kümesi	Sınıf	Görüntü Sayısı
Covid-19 Image	Covid	111
	Normal	70
	Viral Zatürre	70
Covid-19 Pneumonia Normal Chest X-ray(PA)	Covid	1525
	Normal	1525
	Zatürre	1525
Covid-19 Radiography Database	Covid	3616
	Normal	10192
	Viral Zatürre	1345


Şekil 5.1, veri kümelerindeki bazı örnek görüntüleri göstermektedir. Çalışmada kullanılan Covid-19 Image veri kümesi en az sayıda görüntüyü içermektedir. Covid-19 Pneumonia Normal Chest X-ray (PA) veri kümesi, her sınıf için eşit sayıda görüntü içermesi açısından dengelidir. Tercih ettiğimiz diğer bir veri kümesi ise büyük bir veri kümesi olup 15153 görüntüden oluşmaktadır.



Şekil 5.1. Kullanılan veri kümelerinden örnek görüntüler


5.4. Metot

Çalışmanın amacı, göğüs röntgeni görüntülerini kullanarak Covid-19 hastalığının otomatik tespiti için hibrit bir yöntem tasarlamak ve değerlendirmektir. Çalışmamızda üç adet Covid-19 X-ray görüntü veri kümesi incelenmiştir. Çalışmada önerilen yöntemle çok sınıflı (Covid, Normal ve Zatürre) sınıflandırma gerçekleştirilmiştir. Önerilen boru hattının basit blok diyagramı Şekil 5.2'deki gibidir.



Şekil 5.2. Önerilen yaklaşımın basit blok diyagramı

Bu çalışmada transfer öğrenme yöntemi olan özellik aktarım yaklaşımı kullanılmıştır. Önerilen yöntemde, Covid-19 görüntülerini sınıflandırmak için, evrimsel sinir ağı mimarileri olan AlexNet, Xception, NASNETLarge ve Efficientnet- B0 omurga ağı olarak kullanılır. Çalışmada, özellik aktarım yöntemi kullanılarak modellerin son tam bağlı katmanlarından 1000 tane olmak üzere özellikler çıkartılır. Ardından çıkartılan özellikler, birleştirilerek yeni bir özellik kümesi (4000) oluşturulur. Önerilen yöntemin son adımında ise, özellik kümeleri geleneksel makine öğrenme algoritmaları kullanılarak sınıflandırılır. En yüksek sınıflandırma doğruluğuna ulaşan sınıflandırıcı seçilir. Şekil 5.3, Önerilen yöntemin grafiksel özetini vermektedir.



Şekil 5.3. Önerilen yöntemin grafiksel özeti

5.5. Deneysel Sonuçlar

Modeller derlenirken GPU desteği sağlanır. Görüntüler CNN'lere girdi olarak uygulanmadan önce ağların girdi boyutuna göre yeniden boyutlandırılır. Simülasyon ortamı 64 bit Windows 10, NVIDIA GeForce 950M grafik kartı, Intel © i7 – 7500U @ 2.7 GHz işlemci ve 16 GB RAM'dir. X-ray görüntülerini içeren üç veri kümesi kullanılarak yapılan deneyler Matlab (2020a) ortamında gerçekleştirilmiştir. Üç sınıftan oluşan veriler 5-çapraz doğrulama ile çalıştırılmıştır.

Tablo 5.2. Modellerin uygulandıkları veri kümelerine göre sınıflandırma doğruluğu (%)

Veri kümesi	Özellikler	LDA	SVM	k-NN	DT	NB
Covid-19 image	AlexNet	90,8	89,6	86,1	80,9	89,2
	EfficientNet-B0	94,4	94,4	92,0	80,9	89,2
	NASNetLarge	89,2	93,2	87,3	78,9	83,7
	Xception	80,5	89,2	87,6	80,5	85,3
Covid-19 Pneumonia Normal Chest X-ray (PA)	AlexNet	93,4	93,2	89,8	84,2	84,9
	EfficientNet-B0	94,7	93,9	91,8	84,1	87,1
	NASNetLarge	93,0	92,3	87,3	82,8	77,9
	Xception	93,4	93,2	89,8	83,0	85,9
Covid-19 Radiography	AlexNet	95,4	92,7	90,5	83,5	71,2
	EfficientNet-B0	96,7	95,7	94,5	85,6	77,9
	NASNetLarge	93,2	92,5	86,8	82,0	72,1
	Xception	93,9	92,6	88,8	81,7	70,3

Deneylerin ilk adımında veri kümeleri, ön eğitilmiş CNN mimarilerinden alınan özelliklerin, makine öğrenmesi algoritmalarına verilmesi ile uygulanmıştır. Modellere ait doğruluk değerleri Tablo 5.2'deki gibidir. Her üç veri kümesinde de en yüksek başarıyı, EfficientNet-B0 ile sağlanan özellikler ve LDA sınıflandırıcısının kullanıldığı model göstermiştir. Covid-19 Image, Covid-19 Pneumonia Normal Chest X-ray (PA) ve Covid-19 Radiography veri kümeleri için sırasıyla %94,4, %94,7 ve %96,7 doğruluk sağlanmıştır.

Şekil 5.4, eğitim ve doğrulamada Covid-19 Image veri kümesinin kullanıldığı modele ait karmaşıklık matrisini ve başarımlar ölçüm değerlerini vermektedir. Şekle göre veri kümesinde, önerilen model sadece 14 yanlış sınıflandırma yapmıştır.

Sınıflara ait SN, SP, PREC ve F1 değerleri de sınıflandırmanın yüksek oranda doğru yapıldığını göstermektedir. Aynı şekilde diğer iki veri kümesine göre alınan sonuçlar sırasıyla, Şekil 5.5 ve Şekil 5.6'daki gibidir.

			SN	SP	PREC	F1	
			Covid (1)	93,6	98,5	98,1	95,7
			Normal (2)	95,7	96,6	91,7	93,6
			Viral Zatürre (3)	94,2	96,6	91,6	92,8
Genel doğruluk = % 94,4							

Gerçek Sınıf					
	1	2	3		
	104	3	4		
	1	67	2		
2	1	67	2		
3	1	3	66		
		Tahmin Sınıfı	1	2	3

Şekil 5.4. EfficientNet- B0 + LDA ile Covid-19 Image veri kümesi için karmaşıklık matrisi ve başarımlar

			SN	SP	PREC	F1	
			Covid (1)	97,2	99,0	98,0	97,5
			Normal (2)	97,6	93,7	88,6	92,8
			Viral Zatürre (3)	89,1	99,2	98,2	93,4
Genel doğruluk = % 94,7							

Gerçek Sınıf			
	1	2	3
	1483	35	7
	19	1489	17
3	10	156	1359
		Tahmin Sınıfı	

Şekil 5.5. EfficientNet- B0 + LDA ile Covid-19 Pneumonia Normal Chest X-ray (PA) veri kümesi için karmaşıklık matrisi ve başarımlar

			SN	SP	PREC	F1	
			Covid (1)	92,0	99,0	96,7	94,2
			Normal (2)	98,7	92,8	96,5	97,5
Viral Zatürre (3)	94,2	99,7	97,6	95,8			
Genel doğruluk = % 96,7							

Gerçek Sınıf					
	1	2	3		
	3328	287	1		
	103	10060	29		
8	70	1267			
			Tahmin Sınıfı		
			1	2	3

Şekil 5.6. EfficientNet- B0 + LDA ile Covid-19 Radiography veri kümesi için karmaşıklık matrisi ve başarımlar

Çalışmanın ikinci aşamasında, modeller ikili ve üçlü olarak bir araya getirilerek yeni özellik kümeleri elde edilmiştir. Daha sonra bu özellik kümeleri sınıflandırma algoritmalarına verilmiştir. Tablo 5.3, kullanılan dört modelden sadece ikisinden gelen özelliklerin birleştirilmesiyle elde edilen sonuçları göstermektedir. Modeller, Covid-19 Image veri kümesine uygulanmıştır. AlexNet ve EfficientNet-B0 ağlarından çıkarılan özneteliklerin birleştirilmesiyle elde edilen öznetelik kümesinin LDA sınıflandırıcısına verildiği model %98,0 ile en yüksek doğruluğu elde etmiştir.

Tablo 5.3. İki mimariden alınan özelliklerin birleştirilmesiyle oluşturulan özellik kümesinin deneysel sonuçları (COVID-19 Image veri kümesi)


Özellik Çıkartıcı	Sınıflandırıcı	ACC (%)	SN (%)	SP(%)	PREC (%)	Süre (s)
AlexNet + EfficientNet-B0	LDA	98,0	99,0	100	100	4,651
	SVM	97,2	98,0	99,2	99,0	4,589
	k-NN	94,0	91,8	100	100	3,864
	DT	81,3	88,2	90,0	87,5	4,958
	NB	94,0	98,1	97,1	96,4	10,757
AlexNet + NASNetLarge	LDA	94,0	94,5	98,5	98,1	4,003
	SVM	96,0	98,1	98,5	98,1	3,791
	k-NN	90,4	94,5	97,1	96,3	3,542
	DT	80,5	90,0	90,7	88,4	3,661
	NB	93,2	96,3	96,4	95,5	10,538
AlexNet + Xception	LDA	92,8	94,5	100	100	4,053
	SVM	96,8	98,1	100	100	3,997
	k-NN	92,0	92,7	100	100	3,883
	DT	83,9	90,9	95,7	94,3	3,854
	NB	95,6	97,2	100	100	11,171
EfficientNet-B0+ NASNetLarge	LDA	97,2	98,1	99,2	99,0	4,052
	SVM	97,2	97,2	99,2	99,0	4,321
	k-NN	91,6	92,7	98,5	98,0	4,038
	DT	76,5	84,6	87,8	84,6	3,956
	NB	93,6	97,2	97,8	97,2	11,139
EfficientNet-B0 + Xception	LDA	96,0	97,2	100	100	4,217
	SVM	97,2	97,2	100	100	4,153
	k-NN	96,4	95,4	100	100	4,019
	DT	80,1	87,3	93,3	90,6	4,010
	NB	93,6	95,4	100	100	11,475
NASNetLarge + Xception	LDA	94,8	95,4	97,8	97,2	4,760
	SVM	97,6	99,0	99,2	99,0	4,485
	k-NN	90,8	91,8	97,1	96,2	3,862
	DT	80,1	90,9	90,0	87,8	3,942
	NB	94,8	97,2	98,5	97,2	12,314

Tablo 5.4, dört modelden sadece üçünün özelliklerinin birleştirilmesiyle elde edilen sonuçları ortaya koymaktadır. Sonuçlar doğrultusunda AlexNet, EfficientNet-B0 ve Xception mimarilerinin sağladığı özellikler ile en yüksek doğruluk elde edilmektedir. LDA ve SVM, sınıflandırıcılar olarak ilgili özellik kümesi için aynı doğruluğa (%98,4) ulaşmıştır. Tablo 5.2 ve 5.3 ayrıca elde edilen SN, SP, PREC değerleri ile eğitim süresini (Covid sınıfı için) göstermektedir.

Tablo 5.4. Üç mimariden alınan özelliklerin birleştirilmesiyle oluşturulan özellik kümesinin deneysel sonuçları (Covid-19 Image veri kümesi)

Özellik Çıkartıcı	Sınıflandırıcı	ACC(%)	SN (%)	SP(%)	PREC (%)	Süre (s)
AlexNet + EfficientNet-B0+ NASNetLarge	LDA	98,0	99,0	100	100	8,044
	SVM	98,0	99,0	99,2	99,0	7,576
	k-NN	94,4	95,4	100	100	7,180
	DT	84,1	91,8	90,0	87,9	7,027
	NB	95,2	97,2	97,1	96,4	20,428
AlexNet + EfficientNet-B0+ Xception	LDA	98,4	99,0	100	100	8,673
	SVM	98,4	99,0	100	100	7,886
	k-NN	96,4	97,2	100	100	7,301
	DT	83,7	86,4	95,7	94,1	7,719
	NB	97,2	97,2	100	100	20,97
EfficientNet-B0+ NASNetLarge + Xception	LDA	97,6	99,0	100	100	8,830
	SVM	98,0	99,0	99,2	99,0	8,057
	k-NN	94,8	95,4	100	100	8,360
	DT	80,5	86,4	92,8	90,5	7,560
	NB	96,0	98,1	98,5	98,1	22,17

Çalışmanın üçüncü adımında, dört mimariden gelen özellikler birleştirilmiştir. Daha sonra elde edilen özellik kümeleri ilk deneylerde olduğu gibi çeşitli geleneksel makine öğrenmesi sınıflandırıcılarına verilmiştir. Elde edilen sonuçlar Tablo 5.5’de verilmiştir. Tabloya göre Covid-19 Image veri kümesi ile gerçekleştirilen deneyde LDA sınıflandırıcısı kullanılarak %98,8 doğrulukla sınıflandırma sağlanmıştır. Covid-19 Pneumonia Normal Chest X-ray (PA) veri kümesi ile çıkartılan özelliklerin kullanıldığı deneyde, SVM sınıflandırıcısı %95,9 doğruluk elde etmiştir. Son olarak Covid-19 Radiography veri kümesi ile oluşturulan derin öznitelik kümesine uygulanan algoritmalar arasında en yüksek performans LDA algoritması tarafından %99,6 doğruluk olarak elde edilmiştir.



Şekil 5.7. (a) Covid-19 Image, (b) Covid-19 Pneumonia Normal Chest X-ray (PA) ve (c) Covid-19 Radiography veri kümelerinde en iyi sonuçları sağlayan modellerin karmaşıklık matrisleri

Tablo 5.5. Dört mimariden alınan özelliklerin birleştirilmesiyle oluşturulan özellik kümelerinin deneysel sonuçları

Veri kümesi	Özellik çıkartıcı	Sınıflandırıcı	ACC (%)	SN (%)	SP (%)	PREC (%)	Süre (s)
Covid-19 image	AlexNet+	LDA	98,8	99,0	99,2	99,0	10,827
	EfficientNet-B0+	SVM	98,8	98,1	100	100	11,1
	NASNetLarge+	k-NN	97,2	97,2	99,2	99,0	9,8717
	Xception	DT	84,5	93,6	92,8	91,2	10,779
		NB	98,0	97,2	100	100	28,869
Covid-19 Pneumonia Normal Chest X-ray (PA)	AlexNet +	LDA	72,6	83,5	90,5	81,5	192,42
	EfficientNet-B0+	SVM	95,9	98,6	99,9	99,8	55,071
	NASNetLarge+	k-NN	92,0	91,4	99,9	99,7	223,39
	Xception	DT	84,8	86,5	93,9	87,6	82,697
		NB	93,2	93,2	99,0	93,2	43,496
Covid-19 Radiography	AlexNet +	LDA	99,6	98,7	99,9	99,8	418,93
	EfficientNet-B0+	SVM	99,3	97,8	99,8	99,5	227,02
	NASNetLarge+	k-NN	93,2	76,3	99,1	96,5	2195,9
	Xception	DT	88,4	74,3	95,5	84,0	201,49
		NB	91,1	92,5	94,8	84,9	102,12

En yüksek doğruluğa ulaşan modellerin karmaşıklık matrisleri Şekil 5.7’de verilmiştir. Covid Image veri kümesi için; ilk deneylerde en yüksek başarıyı sağlayan modelde 14 yanlış sınıflandırma yapılmış iken iyileştirilen yöntem ile yanlış sınıflandırılan görüntü sayısı 3’e indirgenmiştir. Her bir sınıfında 1525 görüntü bulunan Covid-19 Pneumonia Normal Chest X-ray (PA) veri kümesinin doğruluğu %95,9 olarak iyileştirilmiştir. Son olarak kullandığımız en büyük veri kümesi olan 15153 görüntü içeren Covid-19 Radiograph veri kümesi sonuçlarına bakıldığında, yanlış sınıflandırılan görüntü sayısı azalmış ve doğruluk oranı % 96,7 den %99,6’ya yükseltilmiştir. Öz nitelikleri birleştirmeden uyguladığımız modellerle elde edilen sonuçlarla karşılaştırıldığında, her üç veri kümesinde de doğruluk değerlerinin arttığı görülmektedir.

5.6. Sonuçlar ve Tartışma

Covid-19 kısa sürede dünya çapında bir etkiye sahip olmuştur. Temas ve damlacık yoluyla bulaşması virüsün kontrol edilmesini zorlaştırmaktadır. Virüsü kontrol etmenin yolu, enfekte olmuş kişilerin hızlı bir şekilde tespittir. Bu şekilde insanlar izole edilebilir ve tedavi sağlanabilir. Vakaların tespiti için altın standart olan RT-PCR testi tek başına yeterli olmamaktadır. Ayrıca, özellikle vakalar arttığında testin elde edilmesi zordur. Vakaları tespit etmek için başka testler ve yöntemler vardır. Ancak salgın koşullarında yeterli sağlık personeli ve cihazları mümkün olmayabilir. Bu gibi nedenlerle hızlı ve doğru sonuçlar üretebilen bilgisayar destekli sistemlere ihtiyaç doğmuştur. Özellikle derin öğrenme tabanlı yöntemler geliştirilmiştir. Bu yöntemlerden bazıları Tablo 5.6’daki gibidir.

Tablo 5.6. Önerilen yaklaşımın diğer yaklaşımlar ile kıyaslanması

Kaynak/Yıl	Görüntüler	Yöntem	Veri kümesi kaynağı	Başarım	Sınıf Sayısı
[134]/2020	BT	Self-Trans	COVID-CT [134]	%85 F1 %94 AUC	2
[135]/2020	BT	DenseNet121-FPN	Çin'deki altı şehirden hastaneler	%86 AUC	6
[136]/2020	X-ray	CapsNet	COVID-Chestxray	%84,22 ACC (3) %97,24 ACC (2)	3
[131]/2020	BT	Inception ile aktarım öğrenme	Çin'deki üç hastane	%93 AUC %88 SP %87 SN	2
[137]/2020	X-ray	DarkNet	COVID-Chestxray Chest X-ray	%85,53 SN %87,02 ACC	3
[138]/2020	X-ray	FBD+ResNet50+Softmax	750 Images	%98,6 ACC % 94 SP %96 SN	3
[132]/2020	BT	ARENET(ResNet50& FPN)	Çin'deki iki şehirden hastaneler	%93 PREC %93 SN %93 ACC	3
[128]/2021	X-ray	ResNet34	İki ayrı kaynaktan	%98,33ACC	2
[139]/2021	X-ray	22 katmanlı CNN	COVID-R [135]	% 99,1 ACC (2) % 94,2 ACC (3) %91,2 ACC (4)	4
[140]/2021	X-ray	CNN ile özellik aktarımı	COVIDGR 1.0 [136]	%90,45 ACC	2
[146]/2021	X-ray	InstacovNet-19	3150 görüntü	%99,53 ACC (2) %99,08 ACC (3)	3
[147]/2020	X-ray	COVID-Net	COVIDx Dataset	%93,3 ACC	3
[148]/2020	X-ray	VGG19 ile özellik aktarımı	1424 görüntü	%98,75 ACC (2) %93,48 ACC (3)	3
Önerilen	X-ray	AlexNet+EfficientNet-B0 +NASNetLarge+Xception& LDA	Covid-19 Image	%98,4 ACC	3
Önerilen	X-ray	AlexNet+EfficientNet-B0 +NASNetLarge+Xception& SVM	Covid-19 Pneumonia Normal Chest Xray (PA)	%95,7 ACC	3
Önerilen	X-ray	AlexNet+EfficientNet-B0 +NASNetLarge+Xception& LDA	Covid-19 Radiography	%99,6 ACC	3

Tablo 5.6'ya göre önerilen yöntemin sınıflandırma doğruluk oranının literatürdeki birçok çalışmaya göre daha yüksek olduğu görülmektedir. Göğüs X-ray görüntülerini kullanarak Covid-19 tespiti yapmak için CapsNet kullanan Toraman ve arkadaşları [132], ikili sınıflandırma için % 97,24 doğruluğa ulaşmıştır. Fakat bu oran üçlü sınıflandırma için % 84,2 olarak raporlanmıştır. Poonam ve arkadaşları [140], aktarım öğrenme yaklaşımı kullanarak uyguladıkları yöntem ile Covid, Covid-değil sınıflandırması yapmıştır. Elde edilen sınıflandırma doğruluğu ilgili veri kümesinde % 90,45 olmuştur. Wang ve arkadaşları [148], üçlü sınıflandırma yaptıkları çalışmada Covid-Net olarak

adlandırdıkları evrişimsel sinir ağı tabanlı bir model önermiştir. Bu model ile COVIDx veri kümesi kullanan yazarlar, % 93,3 sınıflandırma doğruluğuna ulaşmıştır.

Kupta ve arkadaşları, ön-eğitilmiş CNN mimarileri olan VGG19, MobileNetv2, Inception, Xception ve InceptionResnetv2 ağlarını aktarım öğrenme yöntemi ile yeniden eğitmiştir. Bu mimarilerden en iyi sonuç VGG19 ile sağlanmıştır. İki sınıf için %98,75 olarak sağlanan sınıflandırma doğruluğu, 3 sınıf için %93,48'e ulaşabilmiştir. Bir diğer çalışma olan [146]'da kısıtlı sayıda veri ile çalışılmıştır. Eğitim için her sınıfta 270 görüntü bulunur. İlgili veri kümesinde üç sınıf için % 99,08 doğruluk raporlanmıştır. Çalışmalar incelendiğinde, vakaların hızlı ve doğru tespiti için yöntemlerin geliştirilmesi gerekir. Bu amaçla yaptığımız çalışmada normal, covid-19 ve zatürre sınıflarından X-ray görüntüleri içeren üç ayrı veri kümesi giriş olarak kullanılmıştır. Önerilen yöntemin ilk adımında, AlexNet, EfficientNet-B0, NASNetLarge ve Xception mimarilerinin son katmanlarından alınan özelliklerin birleştirilmesi ile özellik kümesi oluşturulmuştur. Evrişimsel sinir ağlarında ilk katmanlar sınıflandırmaya çok katkısı olmayan genel bilgiler vermektedir. Son katmanlar ise daha ayırıcı bilgiler vermesi ile sınıflandırmaya katkı sağlarlar. Dolayısıyla özellikler alınırken son katman tercih edilmiştir. Yöntemin ikinci adımında, geleneksel makine öğrenme algoritmaları ile sınıflandırma işlemi gerçekleştirilmiştir. Bu algoritmalarından LDA, Covid-19 Image ve Covid-19 Radiography veri kümeleri için en yüksek başarıyı sağlamıştır. Diğer yandan Covid-19 Pneumonia Normal Chest X-ray (PA) veri kümesi için en yüksek başarıyı SVM sınıflandırıcısı ile sağlanmıştır. Sonuçlara göre, özellik aktarımı yöntemi ile CNN mimarilerinden özelliklerin çıkartılarak birleştirilmesinin Covid-19 sınıflandırılması için etkili olduğu görülmüştür.

6. İŞ GÜVENLİĞİNİN SAĞLANMASI İÇİN BARET TAKMA DURUMUNUN TESPİTİ

İnşaatlar ve maden ocakları gibi iş güvenliği için baret takılmasının gerekli olduğu iş sahalarında, baret takılıp takılmadığının kontrolünün yapılması önemlidir. Tezin bu bölümünde, yapay zekânın bir diğer kullanım alanı olan güvenlik sektörü için nesne bulma yaklaşımı önerilmiştir.

6.1. Problem Tanımı

İnşaat sektörü, ekonomiye sağladığı katma değer ve istihdam olanakları açısından önemli bir yere sahiptir. Dünya çapında, inşaat sektöründe yaşanan iş kazaları büyük sorun teşkil etmektedir [149]. Sosyal Güvenlik Kurumu (SGK) istatistiklerine göre inşaat sektörü Türkiye’de yaşanan iş kazalarının sayıca fazla olduğu ilk üç sektör arasında bulunmaktadır. Ayrıca, can kayıpları açısından tüm sektörler içerisinde ilk sırada yer almaktadır. 2016 yılı SGK verilerine göre Türkiye’de bulunan 1 milyon 749 bin 240 iş yerinin 195 bin 990’ı inşaat sektörünü kapsamaktadır. Tüm sektörlerde çalışanların %13,7’si inşaat sektöründe istihdam edilmektedir. İş kazalarının %15,6’sı inşaat sektöründe yaşanmış olup, ölümlü iş kazaları bakımından sektör %35,3’lük oranla tüm faaliyet alanları içerisinde ilk sırada yer almaktadır [150].

İnşaat ölümleri farklı faktörlerin birleşiminden kaynaklanır. Kazaların çoğu, güvensiz davranışlar ve koşullar nedeniyle meydana gelmektedir. Türkiye’de inşaat sektöründe en çok meydana gelen kaza tiplerinden malzeme düşmesi ve malzeme sıçraması ikinci ve üçüncü sırada gelmektedir [151]. İş kazalarının sebep olduğu yaralanma ve ölümler nedeniyle şantiye güvenliğini artırmaya yönelik saha içi güvenlik politikaları ve prosedürleri için kritik bir talep vardır. Baret gibi kişisel koruyucu donanımların kullanımı etkili bir risk yönetimi sağlar. Fakat işçiler daha önceden eğitim almış olsalar bile şantiye güvenlik kurallarına tam olarak uymamaktadır [149]. İnşaat sektörü, dünya çapında en az dijitalleştirilmiş endüstrilerdendir. Sonuç olarak, mevcut emniyet teftiş uygulamaları büyük ölçüde müfettişlerin manuel izleme ve raporlamasına dayanmaktadır. Emniyet teftişinin daha güvenli ve kolay olması için otomatik sistemler fayda sağlar.

6.2. İlgili Çalışmalar

Şantiye güvenliğini artırmak için, özellikle derin öğrenme tekniklerini kullanarak yapılmış olan birçok çalışma bulunmaktadır.

Wu ve arkadaşları [152], inşaat personelinin baret takıp takmadığını otomatik olarak izlemek ve karşılık gelen renkleri belirlemek için SSD’ye dayalı bir yöntem önermektedir. Sistem, 512x512 girdi boyutuyla % 83,89 mAP elde edebileceğini göstermektedir. Fang ve arkadaşları [153], baret

takmayan personelin tespiti için Faster RCNN tabanlı bir sistem önermektedir. Wang ve arkadaşları [154], baret ve yelek varlığını kontrol eden dört sınıflı bir tespit problemini YOLOv3 ile geliştirmiştir. Kim ve arkadaşları [155], Faster RCNN tekniğine dayalı olarak inşaat işçilerinin baret takıp takmadıklarını öğrenen bir model kullanmıştır.

Saudi ve arkadaşları [156], Faster RCNN algoritmasını kullanarak çalışanların güvenlik koşulları hakkında bir görüntü algılama modeli sunmuştur. Deneylerde baret, yelek ve botları içeren üç sınıflı bir eğitim veri kümesi olarak MIT Places veri kümesi kullanılmıştır. Sonuçlar, ortalama % 70 doğruluk oranını göstermiştir.

Filatov ve arkadaşları [157], SqueezeDet ve MobileNet sinir ağlarından oluşan birleşik bir sistem önermiştir. Yöntem, 0,75 F1 puanı elde etmiştir. Casuat ve arkadaşları [158], baret takan kişileri tespit etmek için YOLOv3 kullanmıştır. Modelin test edilen veri kümesinde %79,2 ortalama doğruluk elde ettiği raporlanmıştır.

Wang ve arkadaşları [159], işçilerin kask takıp takmadığını tespit etmek için uçtan uca evrişimsel bir sinir ağı sunmuştur. Önerilen yöntem, bir kişinin kafasının yerini belirlemeye ve kask takıp takmadığına karar vermeye odaklanmıştır. MobileNet modeli, bulucunun gerçek zamanlı çalışmasına izin veren omurga ağı olarak kullanılmıştır. Özellik çıkarma sürecini geliştirmek için yukarıdan aşağıya bir modülden yararlanılır. Son olarak, artık blok tabanlı bir tahmin modülü kullanılarak çok ölçekli özelliklerde algılanır. Kullanılan veri kümesindeki deneysel sonuçlar, önerilen yöntemin kafasına baret takılı / takılı olmayan insanları tespit etmek için saniyede 62 karede % 87,4 / % 89,4 ortalama hassasiyet üretebileceğini göstermiştir.

6.3. Veri Kümesi


Çalışmada halka açık bir veri kümesi olan Hard Hat Workers veri kümesi kullanılmıştır [160]. Veri kümesi, baret gerektiren çalışma alanlarında çalışanların nesne algılama veri kümesidir. Ek açıklamalar, bir kişinin baret olmadan bulunabileceği “kişi” ve “kafa” örneklerini de içerir. Kişi (Person), baret (helmet) ve kafa (head) olmak üzere toplam üç sınıfın yer aldığı veri kümesi 7041 görüntüden oluşmaktadır. Bu görüntülerin %75’i eğitim, %20’si doğrulama ve %5’i test için kullanılmıştır. Veri kümesine ait bazı görüntüler Şekil 6.1’deki gibidir.



Şekil 6.1. Hard Hat Workers veri kümesinden alınmış örnek görüntüler [160]

6.4. Metot


İnşaat alanlarına yerleştirilen kameralardan alınan görüntüler, ölçek değişiklikleri ve perspektif bozulması gibi zorluklar ortaya çıkarabilir. Baret takma durumunun hem doğru hem de hızlı tespit edilmesi güvenlik açısından önemlidir. Çalışmada hafif ve doğruluğu kabul edilebilir bir model ile baret takma durumunun tespiti amaçlanmıştır. Bu amaçla, YOLOv5 çerçevesine dayalı bir yöntem önerilmiştir. YOLO, son teknoloji ürünü, gerçek zamanlı bir nesne dedektörüdür ve YOLOv5, YOLOv1-YOLOv4'ü temel alır. Model önerisinde YOLOv5'i temel almanın nedeni uygulandığı problemlerde hem hızlı hem de doğru sonuçlar üretmesidir [161, 162]. Önerilen yöntemin basit diyagramı Şekil 6.2'deki gibidir.



Şekil 6.2. Önerilen boru hattının kaba şekli


Önerilen model diğer derin öğrenme tabanlı nesne bulucularda olduğu gibi üç aşamadan oluşmaktadır. İlk olarak özellik çıkartma adımında omurga ağı olarak ShuffleNetv2 kullanılmıştır. ShuffleNetv2 [24], sınırlı miktarda bilgi işlem gücüne sahip mobil cihazlar için özel olarak tasarlanmış, hesaplama açısından verimli bir evrişim mimarisidir. Model artık bir yapıdır ve darboğaz yapısını içerir. Diğer CNN mimarilerine kıyasla daha düşük karmaşıklığa ve daha az

hatırlama arttıkça kesinlik yüksek kalırsa iyi olarak kabul edilebilir. Önerilen modelin kesinlik eğrisi ve hatırlama eğrisi Şekil 6.4’de gösterilmiştir. Kesinlik ve hatırlama değerleri sırasıyla 0,942 ve 0,91 olarak verilmiştir.




Şekil 6.4. Modelin kesinlik eğrisi ve hatırlama eğrisi

MobileNetv3 [29], önerilen boru hattında boyut ve karmaşıklık özelliklerinden dolayı hafif bir mimari oluşturmak için özellik çıkartma ağı olarak kullanılabilecek bir diğer mimaridir. MobileNetv3 omurga olarak dâhil edilerek aynı şartlar altında test edilmiştir. Modele ait kesinlik ve hatırlama eğrileri Şekil 6.5’de gösterilmektedir. Eğitim ve doğrulama için ilgili veri kümesindeki görüntülerin kullanıldığı model, 0,925 kesinlik ve 0,91 hatırlama değerleri sağlamıştır. Buna göre, değiştirilmiş iki model aynı hatırlama değerlerini sağlarken, ShuffleNetv2 biraz daha iyi kesinlik sağlar.



Şekil 6.5. MobileNetv3 ağının omurga olarak dahil edildiği yöntemin kesinlik eğrisi ve hatırlama eğrisi

Yöntemlere ait Kesinlik-Hatırlama eğrileri Şekil 6.6’da verilmiştir. Veri kümesi kafa, baret ve kişi olarak üç sınıflıdır. Önerilen yöntem kafa sınıfı için 0,891 AP ve baret için 0,903 AP sağlamıştır.



Şekil 6.6. Omurga ağı olarak a) ShuffleNetv2 ve b) MobileNetv3 mimarisinin kullanıldığı modellere ait Kesinlik-Hatırlama eğrileri

Modeller ilgili veri kümesinden alınan görüntülerle test edilmiştir. Test için 351 görüntü kullanılmıştır. Şekil 6.7, aynı test verilerinin uygulandığı modeller için bazı doğru algılama sonuçlarını göstermektedir. Genel olarak, modeller görüntülerin çoğunda benzer algılama sonuçları göstermiştir.



Şekil 6.7. a) ShuffleNetv2 ve b) MobileNetv3 mimarisinin kullanıldığı modellere ait bazı doğru bulunmuş görüntü örnekleri

Bazı görüntülerde, bir model resimdeki ilgili tüm baş ve baret nesnelerini bulurken, diğer model tüm nesneleri bulamamış veya yanlış bulmuştur. Bahsedilen bazı görüntüler Şekil 6.8’de örneklendirilmiştir. Şekilde ilk sütun a) ShuffleNetv2 ağının sonuçlarını, ikinci sütun b) MobileNetv3’ün omurga olarak kullandığı modelin sonuçlarını göstermektedir. Şekilde, ilk satırdaki a) görüntüde baret olarak baret olmayan bir nesne bulunmuştur. Aynı görüntüdeki nesneler diğer yöntemle doğru bulunmuştur. İkinci satırdaki görüntü, bir baret, ShuffleNetv2 kullanan model tarafından bulunamamış, ancak diğer model tarafından bulunmuştur. Aynı şekilde 3. satırdaki görüntülerde ShuffleNetv2’nin kullanıldığı model, görüntüdeki ilgili nesneleri doğru tanımlarken, diğer model baret nesnesi bulamamıştır. Bulunamayan ve yanlış bulunan kısımlar sarı ok ile gösterilmiştir. Sonuç olarak, ilgili veri kümesinde kullanılan modeller, doğru tespit etmede yakın performans göstermiştir. Hız açısından değerlendirdiğimizde ShuffleNetv2’nin omurga olarak kullanıldığı model 32,101 saniyede test sürecini tamamlamıştır. Diğer yandan MobileNetv3, aynı koşullar altında 30,908 saniyede test sürecini tamamlamıştır. Modeller düşük boyut ve karmaşıklığa sahiptir. Bu nedenle eğitim ve test süreçleri hızlı olmuştur.



Şekil 6.8. a) ShuffleNetv2 ve b) MobileNetv3 mimarisinin kullanıldığı modellerin uygulandığı bazı test görüntülerinin kıyaslanması

6.6. Sonuçlar ve Tartışma

Güvenli çalışma koşullarını sağlamak için yıllar boyunca yapılan çeşitli güvenlik denetimlerine rağmen, inşaat, toplam işçi ölümlerinin büyük bir kısmından sorumlu olan en tehlikeli endüstriler arasında yer almaktadır. Şantiye yaralanmalarının yaygın nedenleri arasında düşmeler, kaymalar ve takılmalar bulunur. İşçi yaralanmaları ve ölümleri büyük ölçüde kişisel koruyucu donanım kullanılmamasından kaynaklanmaktadır. Bu, güvenlik görevlileri ve müfettişler tarafından kontrol edilse de, geniş iş alanlarının ve çok sayıda işçinin olduğu durumlarda kişilerin kontrolü yetersiz kalmaktadır. Bu nedenle kaskın takılı olup olmadığı sürekli kontrol edilmelidir.

Çalışmamız, derin öğrenme çerçevelerine dayanan diğer araştırmalara benzemektedir. Nesne bulma görevlerinde, tek aşamalı nesne dedektörleri, çok aşamalıya göre daha az doğru sonuçlar verir [163]. Öte yandan, tek aşamalı dedektörler, iki aşamalı nesne dedektörlerinden daha hızlı sonuçlar üretir. Yolo ailesinden olan Yolov5, tek aşamalı olmasının getirdiği avantaj ile hızlıdır. Aynı zamanda, önceki sürümlere yapılan iyileştirmeler sayesinde daha doğru sonuçlar elde eder. Dolayısıyla güvenli bir inşaat ortamı sağlamak adına baret giyilip giyilmediğini kontrol etmek için çalışmada Yolov5 modeli esas alınmıştır. Yöntem, eğitim, doğrulama ve test süreçlerine tabi tutulmuş ve sonuçlar raporlanmıştır. Çalışmamız Hardhat workers veri kümesinde yüksek doğruluklar elde etmiştir.

Tablo 6.1. Baret tespiti ile ilgili yapılmış bazı çalışmalar ile önerilen yöntemin kıyaslanması

Çalışma/ Yıl	Veri kümesi/Sınıf	Yöntem	Başarım değerleri
[152]/2019	GDUT-HWD/5	SSD	83,89 mAP
[155]/2020	287 görüntü/2	Faster RCNN	0,82 AP
[156]/2020	MIT Place /4	Faster RCNN	%70 ACC
[157]/2020	Hardhat Wearing/2	SqueezeDet+MobileNet	0,75 F1
[158]/2020	Kamuya açık veri kümelerinden toplanmış görüntüler/1	Yolov3	%79,2 mAP
[159]/2020	Hardhat Wearing /2	Uçtan uca CNN	87,4 AP (baretli) 89,4 AP (baretsiz)
[164]/2020	Pictor-v3/ 3	YOLO ve CNN	63,1 mAP
[165]/2021	Hardhat Wearing Detection/5	Darknet53 & geliştirilmiş BiFPN	87,04 mAP
[166]/2021	İnternette toplanmış 6000 görüntü /2	Geliştirilmiş YOLOv5	92,24 PREC 96,27 SN
[161]/2021	İnternette toplanmış 6045 görüntü /2	YOLOv5s, YOLOv5m YOLOv5l, YOLOv5x	93,6 mAP, 94,3 mAP 94,4 mAP, 94,7 mAP
Önerilen	Hard Hat Workers/3	ShuffleNetv2+PANet+ YOLO	%94,2 PREC %91,0 SN

Konuyla ilgili tek ve iki aşamalı nesne dedektörlerine dayalı çalışmaların bazılarının değerlendirmeleri Tablo 6.1'deki gibidir. Çalışmalarda farklı veri kümeleri ve performans ölçütleri kullanılmıştır. Sınıf sayıları ve görüntünün zorluk derecesi gibi parametreler farklılık gösterir. Dolayısıyla kesin bir karşılaştırma yapmak mümkün değildir. Fakat çalışmamız kabul görmüş

nesne bulma deęerlendirme kriterleri ile test edilmiřtir. Elde edilen sonular yksek doęruluktur. Bu nedenlerle inřaat alanlarında ve gvenlik iin baret takmanın gerekli olduęu dięer yerlerde yntemin kullanımının faydalı olacaęı kanaatindeyiz.



7. SONUÇLAR

İnsan yaşamındaki birçok alanda, yapay zekâ kullanılarak geliştirilen akıllı sistemleri görmekteyiz. Akıllı sistemlerin her alanda kullanılıyor olması, yapay zekâ biliminin geliştirilmesi ve problemlerin daha yüksek doğrulukta sağlanmasını zorunlu kılmaktadır. Akıllı sistemler geliştirilirken, genellikle görüntü sınıflandırma ve nesne bulma konuları ile ilgilenilmektedir. Görüntü sınıflandırma ve nesne bulma konuları oldukça kapsamlıdır. Uygulama alanlarına yüz tanıma, kişi sayma, duygu tespiti, insansız araç üretimi ve hava tahmini örnek olarak gösterilebilir. Günümüzde, akıllı sistemlerin insan hayatına bu kadar dâhil olmasında CNN mimarilerinin büyük katkısı bulunmaktadır. Çalışmada, ilgili üç farklı alanda derin öğrenme yaklaşımları kullanılarak görüntülerin sınıflandırılması ve nesnelerin tespiti sağlanmıştır.

Görüntü sınıflandırma uygulamalarında kullanışlı özellikler elde etmek önemlidir. Evrimsel sinir ağları, eğitim sırasında çıkarılan özellikleri otomatik olarak öğrenir. Elde edilen özellikler ile sınıflandırma işlemi gerçekleştirilir. Bu nedenle, başarılı özellikler elde etmek, yüksek sınıflandırma başarısı sağlamak için kritik bir öneme sahiptir. Bu tez çalışmasında etkili özelliklerin kullanılmasına odaklanılan iki ayrı sınıflandırma çalışması gerçekleştirilmiştir. Bölüm 4’de verilen ilk çalışmada CNN tabanlı öneğitilmiş mimariler kullanılmıştır. İki ayrı kamuya açık domates yaprağı görüntülerinden oluşan veri kümesi kullanılarak özellikler çıkartılmıştır. Ardından özellik seçim algoritması ile etkili özelliklerin çıkartılması amaçlanmıştır. Son aşamada ise özellik kümesi, geleneksel makine öğrenimi sınıflandırıcısı ile sınıflandırılmıştır.

Bölüm 5’deki bir diğer sınıflandırma çalışmasında, Covid-19 olarak bilinen hastalığın normal ve zatürre olan kişilerden ayırt edilmesi ve önlemin alınması adına sağlık çalışanlarına yardımcı olunabilmesi için bir yöntem önerilmiştir. Burada, en etkili sınıflandırma yapan özellik kümesinin seçilmesi için dört öneğitilmiş CNN mimarisinin özellikleri farklı şekillerde birleştirilmiştir. Özellik kümeleri, farklı sınıflandırıcılar ile test edilmiştir. Bu şekilde yapılan karşılaştırmalar sonrasında en yüksek doğruluğu sağlayan özellik kümesi ve sınıflandırıcının kullanıldığı hibrit mimari elde edilmiştir.

Tez çalışmasında yapılan son çalışma ise Bölüm 6’yı kapsayan iş güvenliğinin sağlanması amacıyla yapılmış olan baret takma durumunun tespiti. Bu amaçla son zamanların popüler nesne bulma algoritması Yolov5 esas alınmıştır. Model, Yolov5 mimarisinin omurga ağı değiştirilerek oluşturulmuştur. Omurga ağı karmaşık olmayan basit bir ağ yapısıdır. Bu sayede nesne bulma işlemi hızlıdır. Model, açık erişime sahip bir veri kümesi ile test edilmiştir. Elde edilen sonuçlar modelin yüksek doğruluk sağladığını göstermiştir. Her üç çalışma ayrıca literatürdeki benzer çalışmalar ile karşılaştırılmıştır. Sonuçlar, üç yaklaşımın da yüksek başarımlar sağladığını ve ilgili alanlarda kullanımının faydalı olacağını göstermiştir. Tezin toplumsal/kültürel etkisi ve akademik etkisi alt bölümde verilmiştir.

7.1. Toplumsal/Kültürel Etkisi

Beslenme, barınma ve sağlık insan hayatı için elzem ihtiyaçlardır. Çalışmalarda seçilen veri kümeleri, insan temel ihtiyaçlarını içermesi dolayısıyla doğrudan toplumsal etki sağlar. Akıllı sistemlerin kullanımı hayatımızı kolaylaştırmaktadır. Bu anlamda, tez çalışmasının fayda sağlayacağı düşünülmektedir.

7.2. Akademik Etkisi

Bu tez çalışması, gerçekleştirilme sürecinde üç adet Bilim Alıntı Endeksli-Genişletilmiş (SCI-E) dergi yayını, üç adet ulusal TR dizin kapsamlı dergi yayını, bir adet uluslararası hakemli dergi yayını ve yedi adet uluslararası konferans yayını ile tamamlanmıştır. Yayımlanmış çalışmalar ile literatüre katkıda bulunulmuştur.

KAYNAKLAR

- [1] Anantrasirichai, N. ve Bull, D. (2021). Artificial intelligence in the creative industries: a review. *Artificial Intelligence Review*, 1-68
- [2] Mathew, A., Amudha, P., Sivakumari, S. (2020, Şubat). Deep Learning Techniques: An Overview. In *International Conference on Advanced Machine Learning Technologies and Applications* (pp. 599-608). Springer, Singapore
- [3] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8(1), 1-74.
- [4] Zhou, J. Y., ve Zhao, Y. M. (2017). Application of convolution neural network in image classification and object detection. *Computer Engineering and Applications*, 53(13), 34-41
- [5] Shamshiri, R. R., Jones, J. W., Thorp, K. R., Ahmad, D., Che Man, H., Taheri, S. (2018). Review of optimum temperature, humidity, and vapour pressure deficit for microclimate evaluation and control in greenhouse cultivation of tomato: a review. *International agrophysics*, 32(2)
- [6] Aveyard, P., Gao, M., Lindson, N., Hartmann-Boyce, J., Watkinson, P., Young, D., ... Hippisley-Cox, J. (2021). Association between pre-existing respiratory disease and its treatment, and severe COVID-19: a population cohort study. *The lancet Respiratory medicine*
- [7] Uzdil, O. ve GÜLLÜOĞLU, A. N. (2020). Türkiye İnşaat Sektöründe 2016 ve 2017 Yıllarında Meydana Gelen İş Kazalarının İstatistiksel Olarak Karşılaştırılması. *International Journal of Advances in Engineering and Pure Sciences*, 32(2), 137-144
- [8] Tripathi, M. (2021). Analysis of Convolutional Neural Network based Image Classification Techniques. *Journal of Innovative Image Processing (JIIP)*, 3(02), 100-117.
- [9] Lu, Z., Whalen, I., Dhebar, Y., Deb, K., Goodman, E. D., Banzhaf, W., Boddeti, V. N. (2020). Multiobjective Evolutionary Design of Deep Convolutional Neural Networks for Image Classification. *IEEE Transactions on Evolutionary Computation*, 25(2), 277-291.
- [10] LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324
- [11] Yamashita, R., Nishio, M., Do, R. K. G., Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9(4), 611-629
- [12] Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105
- [13] Simonyan, K. ve Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*
- [14] He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778)
- [15] Ying, X. (2019). An overview of overfitting and its solutions. In *Journal of Physics: Conference Series* (Vol. 1168, No. 2, p. 022022). IOP Publishing
- [16] Chollet, F. (2017). Xception: deep learning with depthwise separable convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*
- [17] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).

- [18] Srinivasan, K., Garg, L., Datta, D., Alaboudi, A. A., Jhanjhi, N. Z., Agarwal, R., Thomas, A. G. (2021). Performance Comparison of Deep CNN Models for Detecting Driver's Distraction. *CMC-Computers, Materials & Continua*, 68(3), 4109-4124
- [19] Zoph B, Vasudevan V, Shlens J, Le Q. (2018). Learning transferable architectures for scalable image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*
- [20] The CIFAR-10 dataset. <https://www.cs.toronto.edu/~kriz/cifar.html>. Erişim tarihi:2 Ekim 2021.
- [21] Tan, M. ve Le Q. (2019). Efficientnet: Rethinking Model Scaling for Convolutional Neural Networks. In *International Conference on Machine Learning*, PMLR.
- [22] Redmon, J. ve Farhadi, A. (2018). Yolov3: An incremental improvement. *arXiv preprint arXiv:1804.02767*
- [23] Wang, H., Zhang, F., Wang, L. (2020). Fruit classification model based on improved Darknet53 convolutional neural network. In *2020 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)* (pp. 881-884). IEEE
- [24] Ma, N., Zhang, X., Zheng, H. T., Sun, J. (2018). Shufflenet v2: Practical guidelines for efficient cnn architecture design. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 116-131).
- [25] Zhang, X., Zhou, X., Lin, M., Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 6848-6856)
- [26] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [27] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4510-4520).
- [28] Tan, M., Chen, B., Pang, R., Vasudevan, V., Sandler, M., Howard, A., Le, Q. V. (2019). Mnasnet: Platform-aware neural architecture search for mobile. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 2820-2828).
- [29] Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... Adam, H. (2019). Searching for mobilenetv3. In *Proceedings of the IEEE/CVF International Conference on Computer Vision* (pp. 1314-1324).
- [30] Hu, J., Shen, L., Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7132-7141).
- [31] Qian, S., Ning, C., & Hu, Y. (2021). MobileNetV3 for Image Classification. In *2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)* (pp. 490-497). IEEE.
- [32] Srinivas, B. ve Rao, G. S. (2019). A Hybrid CNN-KNN model for MRI brain tumor Classification. *Int J Recent Technol Eng (IJRTE)*, 8(2)
- [33] Khagi, B., Kwon, G. R., Lama, R. (2019). Comparative analysis of Alzheimer's disease classification by CDR level using CNN, feature selection, and machine-learning techniques. *International Journal of Imaging Systems and Technology*, 29(3), 297-310
- [34] Saleh, M.A. Evaluation of Supervised Machine Learning Classifiers for Detecting Ransomware based on Naïve Bayes, SVM, KNN, C 4.5, and Random Forest Algorithms

- [35] Jakkula, V. (2006). Tutorial on support vector machine (svm). School of EECS, Washington State University, 37.
- [36] Hong, H., Pradhan, B., Bui, D. T., Xu, C., Youssef, A. M., Chen, W. (2017). Comparison of four kernel functions used in support vector machines for landslide susceptibility mapping: a case study at Suichuan area (China). *Geomatics, Natural Hazards and Risk*, 8(2), 544-569
- [37] Koranga, M., Pandey, R., Joshi, M., Kumar, M. (2021). Analysis of white wine using machine learning algorithms. *Materials Today: Proceedings*
- [38] Wu, H., Wang, L., Zhao, Z., Shu, C., Lu, C. (2018). Support vector machine based differential pulse-width pair Brillouin optical time domain analyzer. *IEEE Photonics Journal*, 10(4), 1-11.
- [39] Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883
- [40] Abu Alfeilat, H. A., Hassanat, A. B., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., Eyal Salman, H. S., Prasath, V. S. (2019). Effects of distance measure choice on k-nearest neighbor classifier performance: a review. *Big data*, 7(4), 221-248
- [41] Vanfretti, L., ve Arava, V. N. (2020). Decision tree-based classification of multiple operating conditions for power system voltage stability assessment. *International Journal of Electrical Power & Energy Systems*, 123, 106251
- [42] Webb, G. I., Keogh, E., & Miikkulainen, R. (2010). Naïve Bayes. *Encyclopedia of machine learning*, 15, 713-714.
- [43] Sammut, C., ve Webb, G. I. (Eds.). (2011). *Encyclopedia of machine learning*. Springer Science & Business Media
- [44] Xanthopoulos, Petros, Panos M. Pardalos, ve Theodore B. Trafalis. (2013). *Linear discriminant analysis. Robust data mining*. Springer, New York, NY. 27-33
- [45] Tharwat, A., Gaber, T., Ibrahim, A., Hassanien, A. E. (2017). Linear discriminant analysis: A detailed tutorial. *AI communications*, 30(2), 169-190
- [46] Linear Discriminant Analysis. <https://www.saedsayad.com/lda.htm>. Erişim tarihi:10 Eylül 2021.
- [47] Nwankpa, C., Ijomah, W., Gachagan, A., Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*
- [48] Sharma, S., Sharma, S., Athaiya, A. (2017). Activation functions in neural networks. *towards data science*, 6(12), 310-316.
- [49] Yeo, I., Gi, S. G., Lee, B. G., Chu, M. (2016). Stochastic implementation of the activation function for artificial neural networks. In *2016 IEEE Biomedical Circuits and Systems Conference (BioCAS)* (pp. 440-443). IEEE
- [50] Kanai, S., Fujiwara, Y., Yamanaka, Y., Adachi, S. (2018). Sigsoftmax: Reanalysis of the softmax bottleneck. *arXiv preprint arXiv:1805.10829*
- [51] Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*
- [52] Xu, B., Wang, N., Chen, T., Li, M. (2015). Empirical evaluation of rectified activations in convolutional network. *arXiv preprint arXiv:1505.00853*
- [53] Misra, D. (2019). Mish: A self regularized non-monotonic neural activation function. *arXiv preprint arXiv:1908.08681*, 4, 2
- [54] Liu, Y., Zhou, Y., Wen, S., Tang, C. (2014). A strategy on selecting performance metrics for classifier evaluation. *International Journal of Mobile Computing and Multimedia Communications (IJMCMC)*, 6(4), 20-35.

- [55] Hossin, M., ve Sulaiman, M. N. (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1.
- [56] Sun, P., Jiang, Y., Xie, E., Shao, W., Yuan, Z., Wang, C., Luo, P. (2021, Temmuz). What Makes for End-to-End Object Detection?. In *International Conference on Machine Learning* (pp. 9934-9944). PMLR.
- [57] Sharma, V., ve Mir, R. N. (2020). A comprehensive and systematic look up into deep learning based object detection techniques: A review. *Computer Science Review*, 38, 100301.
- [58] Gupta, A., Anpalagan, A., Guan, L., Khwaja, A. S. (2021). Deep Learning for Object Detection and Scene Perception in Self-Driving Cars: Survey, Challenges, and Open Issues. *Array*, 100057.
- [59] Valueva, M. V., Nagornov, N. N., Lyakhov, P. A., Valuev, G. V., Chervyakov, N. I. (2020). Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. *Mathematics and Computers in Simulation*, 177, 232-243.
- [60] Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., Pietikäinen, M. (2020). Deep learning for generic object detection: A survey. *International journal of computer vision*, 128(2), 261-318.
- [61] Bochkovskiy, A., Wang, C. Y., Liao, H. Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*.
- [62] Du, L., Zhang, R., Wang, X. (2020). Overview of two-stage object detection algorithms. In *Journal of Physics: Conference Series* (Vol. 1544, No. 1, p. 012033). IOP Publishing.
- [63] Girshick, R., Donahue, J., Darrell, T., Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- [64] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- [65] Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28, 91-99.
- [66] He, K., Gkioxari, G., Dollár, P., Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).
- [67] Dai, J., Li, Y., He, K., Sun, J. (2016). R-fcn: Object detection via region-based fully convolutional networks. In *Advances in neural information processing systems* (pp. 379-387).
- [68] Zeren, M. T., Aytulun, S. K., KIRELLİ, Y. (2020). Comparison of SSD and faster R-CNN algorithms to detect the airports with data set which obtained from unmanned aerial vehicles and satellite images. *Avrupa Bilim ve Teknoloji Dergisi*, (19), 643-658.
- [69] Uijlings, J. R., Van De Sande, K. E., Gevers, T., Smeulders, A. W. (2013). Selective search for object recognition. *International journal of computer vision*, 104(2), 154-171.
- [70] Zhao, Z. Q., Zheng, P., Xu, S. T., Wu, X. (2019). Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30(11), 3212-3232.
- [71] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., Berg, A. C. (2016). Ssd: Single shot multibox detector. In *European conference on computer vision* (pp. 21-37). Springer, Cham.
- [72] Redmon, J., Divvala, S., Girshick, R., Farhadi, A. (2015). You only look once: Unified, real-time object detection. *arXiv 2015. arXiv preprint arXiv:1506.02640*.
- [73] Law, H., ve Deng, J. (2018). Cornernet: Detecting objects as paired keypoints. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 734-750).

- [74] Menegaz, M. (2018). Understanding YOLO. hackernoon. <https://hackernoon.com/understanding-yolo-f5a74bbc7967> Erişim tarihi: 9 Kasım 2021.
- [75] Bryan, H. (2015). Pre-Bloom Disease Management Review. <https://psuwineandgrapes.wordpress.com/2015/04/03/2015-pre-bloom-disease-managementreview/>. Erişim tarihi: 10 Kasım 2021
- [76] Koubâa, A., Ammar, A., Benjdira, B., Al-Hadid, A., Kawaf, B., Al-Yahri, S. A., ... Ras, M. B. (2020). Activity monitoring of islamic prayer (salat) postures using deep learning. In 2020 6th Conference on Data Science and Machine Learning Applications (CDMA) (pp. 106-111). IEEE.
- [77] Redmon, J., ve Farhadi, A. (2017). YOLO9000: better, faster, stronger. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 7263-7271).
- [78] Santurkar, S., Tsipras, D., Ilyas, A., Mađry, A. (2018). How does batch normalization help optimization?. In Proceedings of the 32nd international conference on neural information processing systems (pp. 2488-2498).
- [79] Thuan, D. (2021). Evolution of yolo algorithm and yolov5: the state-of-the-art object detection algorithm.
- [80] He, K., Zhang, X., Ren, S., Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. IEEE transactions on pattern analysis and machine intelligence, 37(9), 1904-1916.
- [81] Jocher, G., Nishimura, K., Mineeva, T., Vilariño, R.: YOLOv5 (2020). <https://github.com/ultralytics/yolov5>. Erişim tarihi: 7 Kasım 2021
- [82] Zhao, Z. Q., Zheng, P., Xu, S. T., Wu, X. (2019). Object detection with deep learning: A review. IEEE transactions on neural networks and learning systems, 30(11), 3212-3232
- [83] Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., da Silva, E. A. B. (2021). A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. Electronics 2021, 10, 279.
- [84] Powers, D. M. (2020). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. arXiv preprint arXiv:2010.16061.
- [85] Padilla, R., Netto, S. L., da Silva, E. A. (2020). A survey on performance metrics for object-detection algorithms. In 2020 International Conference on Systems, Signals and Image Processing (IWSSIP) (pp. 237-242). IEEE.
- [86] Li, Y., ve Velipasalar, S. (2020). Weighted Average Precision: Adversarial Example Detection in the Visual Perception of Autonomous Vehicles. arXiv preprint arXiv:2002.03751.
- [87] How to identify and control tomato plant disease. <https://savvygardening.com/tomato-plant-disease/>
- [88] Zhang S, Li X, Zong M, Zhu X, Wang R. (2017). Efficient kNN classification with different numbers of nearest neighbors. IEEE Trans Neural Netw Learn Syst. 29(5):1774-1785.
- [89] Granik M. ve Mesyura V. (2017). Fake news detection using naive Bayes classifier. Proceedings of the 2017 IEEE 1st Ukraine Conference on Electrical and Computer Engineering (UKRCON). IEEE;900-903.
- [90] Agarwal M, Singh A, Arjaria S, Sinha A, Gupta S. (2020). ToLeD: tomato leaf disease detection using convolution neural network. Proc Comput Sci. 167:293-301.
- [91] Rangarajan AK, Purushothaman R, Ramesh A. (2018). Tomato crop disease classification using pre-trained deep learning algorithm. Proc Comput Sci. 133, 1040-1047.
- [92] Agarwal, M., Gupta, S. K., Biswas, K. K. (2020). Development of Efficient CNN model for Tomato crop disease identification. Sustainable Computing: Informatics and Systems, 28, 100407.

- [93] Wspanialy P. ve Moussa M. (2020). A detection and severity estimation system for generic diseases of tomato greenhouse plants. *Comput Electron Agric.* 178, 105701.
- [94] Hasan M, Tanawala B, Patel KJ. (2019). Deep learning precision farming: tomato leaf disease detection by transfer learning. *Proceedings of 2nd International Conference on Advanced Computing and Software Engineering (ICACSE)*.
- [95] Geetharamani G. ve Pandian A. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Comput Electr Eng.* 76, 323-338.
- [96] Karthik R, Hariharan M, Anand S, Mathikshara P, Johnson A, Menaka R. (2020). Attention embedded residual CNN for disease detection in tomato leaves. *Appl Soft Comput.* 86, 105933.
- [97] Chen X, Zhou G, Chen A, Yi J, Zhang W, Hu Y. (2020). Identification of tomato leaf diseases based on combination of ABCK-BWTR and B-ARNet. *Comput Electron Agric.* 178, 105730.
- [98] Durmuş H, Güneş EO, Kırıcı M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. *Proceedings of the 2017 6th International Conference on Agro-Geoinformatics. IEEE*, 1-5.
- [99] Foysal MFA, Islam MS, Abujar S, Hossain SA. (2020). A novel approach for tomato diseases classification based on deep convolutional neural networks. *Proceedings of International Joint Conference on Computational Intelligence. Springer.* 583-591.
- [100] Batool A, Hyder SB, Rahim A, Waheed N, Asghar MA. (2020). Classification and identification of tomato leaf disease using deep neural network. *Proceedings of the 2020 International Conference on Engineering and Emerging Technologies (ICEET). IEEE.*
- [101] Nasir, I. M., Bibi, A., Shah, J. H., Khan, M. A., Sharif, M., Iqbal, K., ... ve Kadry, S. (2021). Deep learning-based classification of fruit diseases: An application for precision agriculture.
- [102] Wang Q, Qi F, Sun M, Qu J, Xue J. (2019). Identification of tomato disease types and detection of infected areas based on deep convolutional neural networks and object detection techniques. *Comput Intell Neurosci.* 9142753.
- [103] Gonzalez-Huitron V, León-Borges JA, Rodríguez-Mata AE, Amabilis-Sosa LE, Ramírez-Pereda B, Rodríguez H. (2021). Disease detection in tomato leaves via CNN with lightweight architectures implemented in raspberry Pi 4. *Comput Electron Agric.* 181, 105951.
- [104] Fuentes A, Yoon S, Park DS. (2020). Deep learning-based techniques for plant diseases recognition in real-field scenarios. *Proceedings of the International Conference on Advanced Concepts for Intelligent Vision Systems. Springer.*
- [105] Tomato leaf disease detection. <https://www.kaggle.com/kaustubhb999/tomatoleaf>
- [106] Huang ML; Chang, Ya-Han (2020), Dataset of Tomato Leaves, Mendeley Data, V1, <https://doi.org/10.17632/ngdgg79rzb.1>
- [107] Yu L ve Liu H. (2003). Feature selection for high-dimensional data: a fast correlation-based filter solution. *Proceedings of the 20th International Conference on Machine Learning (ICML-03). IEEE.* 856-863.
- [108] Guyon, I., Gunn, S., Nikravesh, M., ve Zadeh, L. A. (Eds.). (2008). *Feature extraction: foundations and applications* (Vol. 207). Springer.
- [109] Kohavi R. ve John GH. (1997). Wrappers for feature subset selection. *Artif Intell.* 97(1-2), 273-324.
- [110] Radovic M, Ghalwash M, Filipovic N, Obradovic Z. (2017). Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. *BMC Bioinform.* 18(1), 1-14.

- [111] Mehmood R, Shahzad W, Ahmed E. (2017). Maximum relevancy minimum redundancy based feature subset selection using ant colony optimization. *J Appl Environ Biol Sci.* 7(4), 118-130.
- [112] Gulgezen G, Cataltepe Z, Yu L. (2009). Stable feature selection using MRMR algorithm. *Proceedings of the 2009 IEEE 17th Signal Processing and Communications Applications Conference.* IEEE. 596-599.
- [113] Saad, W., Shalaby, W. A., Shokair, M., Abd El-Samie, F., Dessouky, M., ve Abdellatef, E. (2021). COVID-19 classification using deep feature concatenation technique. *Journal of Ambient Intelligence and Humanized Computing*, 1-19.
- [114] Vapnik V. (1995). *The Nature of Statistical Learning Theory.* Springer.
- [115] Shijie J, Peiyi J, Siping H. (2017). Automatic detection of tomato diseases and pests based on leaf images. *Proceedings of the 2017 Chinese Automation Congress.* IEEE.
- [116] Zhang K, Wu Q, Liu A, Meng X. (2018). Can deep learning identify tomato leaf disease? *AdvMultimed.* 6710865.
- [117] Elhassouny A. ve Smarandache F. (2019). Smartmobile application to recognize tomato leaf diseases using convolutional neural networks. *Proceedings of the 2019 International Conference of Computer Science and Renewable Energies.* IEEE.
- [118] Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., ... ve Cao, B. (2020). Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. *The lancet*, 395(10223), 497-506.
- [119] WHO. Middle East respiratory syndrome coronavirus (MERS-CoV). <http://www.who.int/emergencies/merscov/en/>. Kasım, 2019. Erişim tarihi: 13 Şubat 2021.
- [120] World Health Organization. Novel Coronavirus (2019-nCoV). https://www.who.int/docs/defaultsource/coronaviruse/situationreports/20200130-sitrep-10-ncov.pdf?sfvrsn=d0b2e480_2. Erişim tarihi: 13 Şubat 2020.
- [121] Koyama T, Platt D, Parida L. (2020). Variant analysis of SARS-CoV-2 genomes. *Bull World Health Organ.* 98(7), 495-504.
- [122] Sağlık Bakanlığı TC. COVID-19 (SARS-CoV2 enfeksiyonu) rehberi. https://covid19bilgi.saglik.gov.tr/depo/rehberler/COVID-19_Rehberi.pdf. Erişim tarihi: 16 temmuz, 2020.
- [123] Kutlu R. (2020). What we have learned about the new coronavirus pandemic, current diagnostic and therapeutic approaches and the situation in Turkey. *TJFMPC.* 14(2), 329-344.
- [124] Qi X, Brown LG, Foran DJ, Noshier J, Hacıhaliloglu I. (2021). Chest Xray image phase features for improved diagnosis of COVID-19 using convolutional neural network. *Int J Comput Assist Radiol Surg.* 16(2), 197-206.
- [125] Khan, M. A., Kadry, S., Zhang, Y. D., Akram, T., Sharif, M., Rehman, A., Saba, T. (2021). Prediction of COVID-19-pneumonia based on selected deep features and one class kernel extreme learning machine. *Computers & Electrical Engineering*, 90, 106960.
- [126] Rauf, H. T., Lali, M. I. U., Khan, M. A., Kadry, S., Alolaiyan, H., Razaq, A., Irfan, R. (2021). Time series forecasting of COVID-19 transmission in Asia Pacific countries using deep neural networks. *Personal and Ubiquitous Computing*, 1-18.
- [127] Verma P, Negi CS, Panth M, Saxena, A. A. (2021) Deep_Saliency: A Deep Learning based Saliency Approach to detect Covid-19 through x-ray images. *Research Square.* <https://doi.org/10.21203/rs.3.rs-65967/v2>

- [128] Nayak SR, Nayak DR, Sinha U, Arora V, Pachori RB. (2021). Application of deep learning techniques for detection of COVID-19 cases using chest X-ray images: a comprehensive study. *Biomed Signal Process Control*. 64, 102365.
- [129] Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., ... Li, L. (2020). A deep learning system to screen novel coronavirus disease 2019 pneumonia. *Engineering*, 6(10), 1122-1129.
- [130] Hemdan EED, Shouman MA, Karar ME. (2020). Covidx-net: a framework of deep learning classifiers to diagnose covid-19 in x-ray images Hemdan, arXiv preprint arXiv:2003.11055.
- [131] Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., ... Xu, B. (2021). A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19). *European radiology*, 1-9.
- [132] Song Y, Zheng S, Li L. (2021). Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*.
- [133] Hu, S., Gao, Y., Niu, Z., Jiang, Y., Li, L., Xiao, X., ... Yang, G. (2020). Weakly supervised deep learning for covid-19 infection detection and classification from ct images. *IEEE Access*, 8, 118869-118883.
- [134] He, X., Yang, X., Zhang, S., Zhao, J., Zhang, Y., Xing, E., Xie, P. (2020). Sample-efficient deep learning for COVID-19 diagnosis based on CT scans. *medrxiv*.
- [135] Wang, S., Zha, Y., Li, W., Wu, Q., Li, X., Niu, M., ... Tian, J. (2020). A fully automatic deep learning system for COVID-19 diagnostic and prognostic analysis. *European Respiratory Journal*, 56(2).
- [136] Toraman S, Alakus TB, Turkoglu I. (2020). Convolutional capsnet: a novel artificial neural network approach to detect COVID-19 disease from X-ray images using capsule networks. *Chaos Soliton Fract*. 2020;140:110122.
- [137] Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Acharya UR. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Comput Biol Med*. 121, 103792.
- [138] Chaudhary PK, Pachori RB. (2020). Automatic diagnosis of COVID-19 and pneumonia using FBD method. In 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM); 2257–2263.
- [139] Hussain E, Hasan M, Rahman MA, Lee I, Tamanna T, Parvez MZ. (2021). CoroDet: a deep learning based classification for COVID-19 detection using chest X-ray images. *Chaos Soliton Fract*. 142,110495.
- [140] Verma P, Tripathi V, Pant B. (2021). Comparison of different optimizers implemented on the deep learning architectures for COVID-19 classification. *Mater Today Proc*. 46, 11098-11102.
- [141] Yildirim M ve Cinar A. (2020). A deep learning based hybrid approach for COVID-19 disease detections. *Trait du Signal*.37(3):461-468.
- [142] Covid-19 Image Dataset. <https://www.kaggle.com/pranavraikokte/covid19-image-dataset>. Erişim tarihi: 8 Nisan 2021.
- [143] Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., ... Islam, M. T. (2020). Can AI help in screening viral and COVID-19 pneumonia?. *IEEE Access*, 8, 132665-132676.
- [144] Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S. B. A., ... Chowdhury, M. E. (2021). Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in biology and medicine*, 132, 104319.

- [145] COVID19_Pneumonia_Normal_Chest_Xray(PA)_Dataset. <https://www.kaggle.com/amanullahasraf/covid19-pneumonia-normal-chest-xraypa-dataset>. Erişim tarihi: 8 Nisan 2021.
- [146] Gupta A, Gupta S, Katarya R. (2021). InstaCovNet-19: a deep learning classification model for the detection of COVID-19 patients using chest X-ray. *Appl Soft Comput.*99, 106859.
- [147] Wang L, Lin ZQ, Wong A. (2020). Covid-net: a tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Sci Rep.* 10(1), 1-12.
- [148] Apostolopoulos ID, Mpesiana TA. Covid-19 (2020). Automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Phys Eng Sci Med.*43(2),635-640.
- [149] Uzdil, O. ve GÜLLÜOĞLU, A. N. (2020). Türkiye İnşaat Sektöründe 2016 ve 2017 Yıllarında Meydana Gelen İş Kazalarının İstatistiksel Olarak Karşılaştırılması. *International Journal of Advances in Engineering and Pure Sciences*, 32(2), 137-144.
- [150] T.C. Aile, Çalışma ve Sosyal Hizmetler Bakanlığı. (2019). İnşaat Sektöründe İş Sağlığı ve Güvenliği: <http://www.guvenliinfaat.gov.tr/genelbilgi.html>
- [151] Müngen, U. (2011). İnşaat Sektörümüzdeki Başlıca İş Kazası Tipleri. TMH, İnşaat Mühendisleri Odası, 496(5), 32-39
- [152] Wu, J., Cai, N., Chen, W., Wang, H., Wang, G. (2019). Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset. *Automation in Construction*, 106, 102894.
- [153] Fang, Q., Li, H., Luo, X., Ding, L., Luo, H., Rose, T. M., An, W. (2018). Detecting non-hardhat-use by a deep learning method from far-field surveillance videos. *Automation in Construction*, 85, 1-9.
- [154] Wang, X., Niu, D., Luo, P., Zhu, C., Ding, L., Huang, K. (2020). A Safety Helmet and Protective Clothing Detection Method based on Improved-Yolo V 3. In *2020 Chinese Automation Congress (CAC)* (pp. 5437-5441). IEEE.
- [155] Kim, D., Kong, J., Lim, J., Sho, B. (2020). A Study on Data Collection and Object Detection using Faster R-CNN for Application to Construction Site Safety. *Journal of the Korean Society of Hazard Mitigation*, 20(1), 119-126.
- [156] Saudi, M., Hakim, A., Ahmad, A., Saudi, M., Shakir, A. (2020). Image Detection Model for Construction Worker Safety Conditions using Faster R-CNN. *International Journal of Advanced Computer Science and Applications*.
- [157] Filatov, N., Maltseva, N., Bakhshiev, A. (2020). Development of Hard Hat Wearing Monitoring System Using Deep Neural Networks with High Inference Speed. In *2020 International Russian Automation Conference (RusAutoCon)* (pp. 459-463). IEEE.
- [158] Casuat, C. D., Merencilla, N. E., Reyes, R. C., Sevilla, R. V., Pascion, C. G. (2020). Deep-Hart: An Inference Deep Learning Approach of Hard Hat Detection for Work Safety and Surveillance.
- [159] Wang, L., Xie, L., Yang, P., Deng, Q., Du, S., Xu, L. (2020). Hardhat-Wearing Detection Based on a Lightweight Convolutional Neural Network with Multi-Scale Features and a Top-Down Module. *Sensors*, 20(7), 1868.
- [160] "Hard Hat Workers Dataset", Erişim tarihi: 10 mayıs 2021: <https://public.roboflow.com/object-detection/hard-hat-workers>
- [161] Zhou, F., Zhao, H., Nie, Z. (2021). Safety Helmet Detection Based on YOLOv5. In *2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA)* (pp. 6-11). IEEE.

- [162] Hu, G. X., Hu, B. L., Yang, Z., Huang, L., Li, P. (2021). Pavement Crack Detection Method Based on Deep Learning Models. *Wireless Communications and Mobile Computing*.
- [163] Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z., Qu, R. (2019). A survey of deep learning-based object detection. *IEEE Access*, 7, 128837-128868.
- [164] Nath, N. D., Behzadan, A. H., Paal, S. G. (2020). Deep learning for site safety: Real-time detection of personal protective equipment. *Automation in Construction*, 112, 103085
- [165] Zhang, C., Tian, Z., Song, J., Zheng, Y., Xu, B. (2021). Construction worker hardhat-wearing detection based on an improved BiFPN. In 2020 25th International Conference on Pattern Recognition (ICPR) (pp. 8600-8607). IEEE.
- [166] Tan, S., Lu, G., Jiang, Z., Huang, L. (2021). Improved YOLOv5 Network Model and Application in Safety Helmet Detection. In 2021 IEEE International Conference on Intelligence and Safety for Robotics (ISR) (pp. 330-333). IEEE.



ÖZGEÇMİŞ

Emine CENGİL

KİŞİSEL BİLGİLER

[Redacted Personal Information]

ARAŞTIRMACI BİLGİLERİ

[Redacted Researcher Information]

EĞİTİM BİLGİLERİ

[Redacted Education Information]

ARAŞTIRMA DENEYİMİ

✓ C-C++, Matlab, Java, Phyton

İŞ DENEYİMİ

2016 – ... : Fırat Üniversitesi, Bilgisayar Mühendisliği Bölümü, Araştırma Görevlisi
2016 : Bitlis Eren Üniversitesi, Bilgisayar Mühendisliği Bölümü, Araştırma görevlisi (2 ay)

AKADEMİK FAALİYETLER

Makaleler:

1. Cengil, E., ve Çınar, A. (2021). The effect of deep feature concatenation in the classification problem: An approach on COVID-19 disease detection. *International Journal of Imaging Systems and Technology*.
2. Cengil, E., ve Çınar, A. (2021). Hybrid convolutional neural network based classification of bacterial, viral, and fungal diseases on tomato leaf images. *Concurrency and Computation: Practice and Experience*, e6617.
3. Cengil, E., Çınar, A. ve Yıldırım M.(2021). A Hybrid Approach for Efficient Multi-Classification of White Blood Cells Based on Transfer Learning Techniques and Traditional Machine Learning Methods. *Concurrency and Computation: Practice and Experience*, e6756.
4. Cengil, E., Çınar, A., ve Yıldırım, M. (2021). Hybrid Convolutional Neural Network Architectures for Skin Cancer Classification. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 694-701.

5. Cengil, E., ve Çınar, A. (2021). Poisonous Mushroom Detection using YOLOV5. *Turkish Journal of Science and Technology*, 16(1), 119-127.
6. Cengil, E., ve Çınar, A. (2020). Göğüs Verileri Metrikleri Üzerinden Kanser Sınıflandırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(2), 513-519.
7. Yıldırım, M., Çınar, A., & Cengil, E. Investigation of Cloud Computing Based Big Data on Machine Learning Algorithms. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 10(2), 670-682.

Bildiriler:

1. Cengil, E., Çınar, A., ve Yildirim, M. (2021). A Case Study: Cat-Dog Face Detector Based on YOLOv5. In *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)* (pp. 149-153). IEEE.
2. Yildirim, M., Çınar, A., ve Cengil, E. (2021, Eylül). Classification of flower species using CNN models, Subspace Discriminant, and NCA. In *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)* (pp. 334-339). IEEE.
3. Cengil, E., ve Cinar, A. (2019, Eylül). Classification of Human Driving Behaviour Images Using Convolutional Neural Network Architecture. In *International Conference on Hybrid Artificial Intelligence Systems* (pp. 264-274). Springer, Cham.
4. Cengil, E., ve Cinar, A. (2019). Image Classification With Convolutional Neural Network Using Difference Of Gaussians. 4th International Engineering and Natural Sciences Conference(IENSC 2019).(pp. 396-403)
5. Cengil, E., ve Cinar, A. (2019). Generating Of Convolutional Neural Network Model For Image Classification. 4th International Engineering and Natural Sciences Conference(IENSC 2019).(pp. 367-374)
6. Cengil, E., ve Çınar, A. (2019). Multiple classification of flower images using transfer learning. In *2019 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-6). IEEE.
7. Cengil, E., ve Cinar, A. (2018). A deep learning based approach to lung cancer identification. In *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)* (pp. 1-5). IEEE.