

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İNSANSIZ HAVA ARAÇINDAN ALINAN
GÖRÜNTÜLERDEN DERİN ÖĞRENME YÖNTEMİ İLE
YANGIN TESPİTİ**

**Hazırlayan
MUSA CESUR**

**Danışman
Dr. Öğr. Üyesi Tayyip ÖZCAN**

Yüksek Lisans Tezi

**Nisan 2024
KAYSERİ**

T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

İNSANSIZ HAVA ARACINDAN ALINAN
GÖRÜNTÜLERDEN DERİN ÖĞRENME YÖNTEMİ İLE
YANGIN TESPİTİ
(Yüksek Lisans Tezi)

Hazırlayan
MUSA CESUR

Danışman
Dr. Öğr. Üyesi Tayyip ÖZCAN

Bu çalışma Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi
tarafından FYL-2023-13036 numaralı proje ile desteklenmiştir

Nisan 2024
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

MUSA CESUR



“İnsansız Hava Aracından Alınan Görüntülerden Derin Öğrenme Yöntemi İle Yangın Tespiti” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Hazırlayan
MUSA CESUR

Danışman
Dr. Öğr. Üyesi Tayyip ÖZCAN



Bilgisayar Mühendisliği ABD Başkanı
Prof. Dr. Veysel ASLANTAŞ

TEŐEKKÜR

Tez çalışmasında bilgi ve deneyimlerini hiç esirgmeden bana göstermiş olduđu destek için Dr. Öğr. Üyesi Tayyip ÖZCAN'a minnettarım. Çalışma sürecinin başarılı olması adına bana göstermiş olduđu samimiyet ve alakası için çok teşekkür ederim. Aynı zamanda, babam Yılmaz CESUR ve annem Fatma CESUR'a, babamın hastalığının tekrar nüksetmesine rağmen sürekli motivasyonumu yüksek tutmaları ve arkamda durmaları için sonsuz teşekkürlerimi iletiyorum. Ailemin destekleri, bu zorlu süreçte benim için güç kaynağı oldu, minnettarım. Benim için önem arz eden arkadaşlarım, Kamil ALTINAY ve Merve SAFALI' ya bana olan destekleri ve güvenleri için en içten teşekkürlerimi sunarım. İşyeri yöneticilerime, çalışmamın gerçekleşmesi adına katılmak durumunda olduğum faaliyet süreçlerini anlayışla karşılamaları ve destekleri için kendilerine teşekkür ederim. Saygılarımla,

Musa CESUR

NİSAN 2024, KAYSERİ

İNSANSIZ HAVA ARACINDAN ALINAN GÖRÜNTÜLERDEN DERİN ÖĞRENME YÖNTEMİ İLE YANGIN TESPİTİ

MUSA CESUR

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Nisan 2024

Danışman : Dr. Öğr. Üyesi Tayyip ÖZCAN

ÖZET

İklim değişiklikleri ve kontrol edilemeyen yangınlar kalıcı hasarlara neden olan büyük doğal afetlerdir. Büyük kayıpların yaşanmaması için orman yangınlarına en kısa sürede müdahale edilmesi ve kontrol altına alınması önemlidir. Gelişen teknolojilerle birlikte İnsansız Hava Araçlarının (İHA) önemi artmış olup farklı işlevler için kullanılmaktadır. Orman yangınlarının tespitinde araştırmacılar tarafından derin öğrenme yöntemleri kullanılmaktadır. Bu tezde literatürde en sık kullanılan YOLOv8, ResNet50, VGG19 ve optimize edilmiş YOLOv8 (GA-YOLOv8) modelleri tercih edilmiştir. Tez çalışması kapsamında özgün bir veri seti (ERUFORESTFIRE) oluşturulmuş ve mevcut açık erişimli FIRE dataset üzerinde deneysel çalışmalar gerçekleştirilmiştir. Önerilen yöntemler simüle edilmiş sunulmuştur. FIRE Veri Seti üzerinde yapılan deneysel çalışmalarda, test verilerinde ResNet50 kullanılarak %98.49, VGG19 kullanılarak %100, YOLOv8 kullanılarak %100 ve GA-YOLOv8 kullanılarak %100 doğruluk oranı elde edilmiştir. GA-YOLOv8 tabanlı sınıflandırma sisteminin doğruluk oranı, mevcut en iyi çalışmanın bildirdiği %98'lik sınıflandırma performansını geride bırakmaktadır. Öte yandan, ERUFORESTFIRE Veri Seti üzerinde yapılan deneysel çalışmalarda, test verilerinde ResNet50 kullanılarak %99.83, VGG19 kullanılarak %99.83, YOLOv8 kullanılarak %99.83 ve GA-YOLOv8 kullanılarak %100 doğruluk oranı elde edilmiştir. Bu çalışmanın ikinci aşamasında, derin öğrenme destekli orman yangın tespitini gerçek zamanlı gerçekleştirecek tasarım ve yazılım geliştirilmiştir. İlk aşamada her iki veri setinde de %100 başarı ile çalışan GA-YOLOv8, gerçek zamanlı sınıflandırma sisteminde derin öğrenme tabanlı yöntem olarak tercih edilmiştir. Bu sistemin testinde, orman yangını olan ve olmayan videolar kullanılmış ve sistemin %100 başarı oranı ile çalıştığı belirlenmiştir. İHA ile yapay zeka entegrasyonu sağlanmış ve veri aktarım istasyonu ile kontrol merkezi üzerinden canlı izleme yapılarak orman yangını tespit işlemi gerçekleştirilmiştir.

Anahtar Kelimeler: Orman yangını sınıflandırması, optimize edilmiş YOLO, derin öğrenme, YOLO, genetik algoritma, GA-YOLOv8, ERUFORESTFIRE.

FIRE DETECTION WITH DEEP LEARNING METHOD FROM IMAGES TAKEN FROM UNMANNED AERIAL VEHICLES

MUSA CESUR

Erciyes University, Graduate School of Natural and Applied Sciences

Master Thesis, April 2024

Supervisor: Asst. Prof. Tayyip ÖZCAN

ABSTRACT

Climate changes and uncontrollable fires are major natural disasters that cause permanent damage. To prevent significant losses, it is important to intervene in forest fires as quickly as possible and bring them under control. With developing technologies, the importance of Unmanned Aerial Vehicles (UAVs) has increased and they are used for different functions. Researchers have been using deep learning methods to detect forest fires. In this thesis, YOLOv8, ResNet50, VGG19, and optimized YOLOv8 (GA-YOLOv8) models, which are most frequently used in the literature, were preferred. An original dataset, ERUFORESTFIRE, was created for the thesis work, and experimental studies were conducted on the existing open-access FIRE dataset. The proposed methods have been simulated and presented. In the experimental studies on the FIRE Dataset, accuracies of %98.49 with ResNet50, %100 with VGG19, %100 with YOLOv8, and %100 with GA-YOLOv8 were achieved on test data. The accuracy rate of the GA-YOLOv8-based classification system surpasses the %98 classification performance reported by the current best study. On the other hand, in the experimental studies on the ERUFORESTFIRE Dataset, accuracies of %99.83 with ResNet50, %99.83 with VGG19, %99.83 with YOLOv8, and %100 with GA-YOLOv8 were achieved on test data. In the second phase of this study, a design and software that will perform deep learning-supported forest fire detection in real time was developed. GA-YOLOv8, which worked with %100 success on both datasets in the first phase, was chosen as the deep learning-based method in the real-time classification system. In the tests of this system, videos with and without forest fires were used, and the system was determined to work with a %100 success rate. Integration of artificial intelligence with UAVs has been achieved, and forest fire detection has been performed through live monitoring from a data transmission station and control center.

Keywords: Forest fire classification, optimized YOLO, deep learning, YOLO, genetic algorithm, GA-YOLOv8, ERUFORESTFIRE.

İÇİNDEKİLER

İNSANSIZ HAVA ARACINDAN ALINAN GÖRÜNTÜLERDEN DERİN ÖĞRENME YÖNTEMİ İLE YANGIN TESPİTİ

BİLİMSEL ETİĞE UYGUNLUK SAYFASI	ii
YÖNERGEYE UYGUNLUK SAYFASI	iii
KABUL VE ONAY	iv
TEŞEKKÜR	v
ÖZET	vi
ABSTRACT	vii
İÇİNDEKİLER	viii
KISALTMALAR	xi
TABLolar LİSTESİ	xii
ŞEKİLLER LİSTESİ	xiii
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR TARAMASI

1.1. Orman Yangını Tespit için Yapılan Çalışmalar	3
1.2. İHA'dan Alınmış Görüntüler ile Orman Yangını Tespiti	7
1.3. Tez Çalışmasında Kullanılan Açık Erişimli Veri Seti ile Yapılan Çalışmalar	10

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Veri Seti	13
2.1.1. FIRE Dataset: Açık Erişimli Yangın Veri Seti	13
2.1.2. ERUFORESTFIRE: Orman Yangını Tespiti İçin Yeni Bir Veri Seti	14
2.2. Problem Çözümünde kullanılacak Derin Öğrenme Algoritmaları	15
2.2.1. Yapay Zekâ	15
2.2.2. Makine Öğrenmesi	16
2.2.3. Derin Öğrenme	17

2.2.4. Yapay Sinir Ağları	17
2.2.5. CNN Ağının Eğitilmesi	20
2.2.6. Ön Eğitilmiş Önerilen Derin Öğrenme Modelleri	23
2.2.6.1. Önerilen Metot:1 VGG19 Tabanlı Yöntem	23
2.2.6.2. Önerilen Metot:2 ResNet50 Tabanlı Yöntem	24
2.2.6.3. Önerilen Metot:3 YOLOv8 Tabanlı Yöntem	25
2.2.6.4. Önerilen Metot:4 Hiperparametre Optimizasyonu Destekli YOLOv8(GA-YOLOv8) Tabanlı Yöntem	27
2.3. Deneysel Kurulum	29
2.3.1. Donanım Altyapısı	29
2.3.2. Yazılım Altyapısı	31
2.4. Gerçek Zamanlı Orman Yangını Tespit Sisteminin Oluşturulması	31
2.5. Değerlendirme Metriği: Confusion Matrix ve Doğruluk Oranı	34

3. BÖLÜM DENEYSEL SONUÇLAR

3.1. Fire Dataset Üzerinde Önerilen Yöntemler ile Elde Edilen Sonuçlar	36
3.1.1. Önerilen Metot:1 ile Elde Edilen Sonuçlar	37
3.1.2. Önerilen Metot:2 ile Elde Edilen Sonuçlar	39
3.1.3. Önerilen Metot:3 ile Elde Edilen Sonuçlar	40
3.1.4. Önerilen Metot:4 ile Elde Edilen Sonuçlar	42
3.2. ERUFORESTFIRE Dataset Üzerinde Önerilen Yöntemler ile Elde Edilen Sonuçlar	43
3.2.1. Önerilen Metot:1 ile Elde Edilen Sonuçlar	44
3.2.2. Önerilen Metot:2 ile Elde Edilen Sonuçlar	46
3.2.3. Önerilen Metot:3 ile Elde Edilen Sonuçlar	48
3.2.4. Önerilen Metot:4 ile Elde Edilen Sonuçlar	50
3.3. Önerilen Modellerle Yapılan Gerçek Zamanlı Testler	52

4. BÖLÜM TARTIŞMA-SONUÇ ve ÖNERİLER

4.1. Tartışma-Sonuç ve Öneriler	58
---	----

KAYNAKÇA	59
ÖZGEÇMİŞ	65



KISALTMALAR

İHA	: İnsansız Hava Aracı
GA	: Genetik Algoritma (Genetic Algorithm)
YSA	: Yapay Sinir Ağları
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
VGG19	: Visual Geometry Group 19
YOLOv8	: You Only Look Once version 8
ERUFORESTFIRE	: Erciyes Üniversitesi Orman Yangını Veri Seti
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
GPU	: Grafik İşlem Birimi (Graphics Processing Unit)
RAM	: Rastgele Erişimli Bellek (Random Access Memory)
LR	: Öğrenme Oranı (Learning Rate)
GUI	: Grafiksel Kullanıcı Arayüzü (Graphical User Interface)
PyQt5	: Qt çatısı için Python bağlantıları (Python bindings for Qt framework)

TABLULAR LİSTESİ

Tablo 2.1.	İkili sınıflandırma confusion matrix	34
Tablo 2.2.	Örnek yangın tahmin tablosu	35
Tablo 3.1.	GA tarafından seçilen hiperparametreler ve değerler.	44
Tablo 3.2.	GA tarafından seçilen hiperparametreler ve değerler.	52
Tablo 3.3.	Orman yangını sınıflandırma modellerinin performansı.	56
Tablo 3.4.	FİRE veri seti ve doğruluk oranlarına ilişkin karşılaştırma.	56

ŞEKİLLER LİSTESİ

Şekil G.1.	İHA ile çekilen orman yangını görüntüsü.	2
Şekil 2.1.	Fire Dataset veri setine ait görüntüler.	14
Şekil 2.2.	ERUFORESTFIRE veri setine ait görüntüler.	15
Şekil 2.3.	Makine öğrenmesi karşılaştırma.	16
Şekil 2.4.	YZ yöntemlerin kapsamaları.	17
Şekil 2.5.	İnsan sinir hücresi biyolojik gösterimi.	18
Şekil 2.6.	Bir sinir hücresinin matematiksel modeli.	19
Şekil 2.7.	Yapay sinir ağı katmanları.	19
Şekil 2.8.	Evrişimli katman görüntüden özellik çıkarımı.	20
Şekil 2.9.	Evrişim işlemi.	21
Şekil 2.10.	Aktivasyon fonksiyonları.	22
Şekil 2.11.	Dropout katmanı.	23
Şekil 2.12.	VGG19 ağ mimarisi.	24
Şekil 2.13.	ResNet50 mimarisi.	25
Şekil 2.14.	YOLOv8 ağ mimarisi.	26
Şekil 2.15.	Hiperparametre ayarlama.	27
Şekil 2.16.	EvoII pro v3.	29
Şekil 2.17.	Veri aktarım istasyonu.	30
Şekil 2.18.	Önerilen orman yangını canlı sistem modeli.	33
Şekil 3.1.	VGG19 eğitim ve doğrulamanın kayıp ve doğruluk değerleri.	37
Şekil 3.2.	FIRE dataset için VGG19 tabanlı modelin karışıklık matrisi.	38
Şekil 3.3.	ResNet50 eğitim ve doğrulamanın kayıp ve doğruluk değerleri.	39

Şekil 3.4.	FIRE dataset için ResNet50 tabanlı modelin karışıklık matrisi.	40
Şekil 3.5.	FIRE Dataset için YOLOv8 tabanlı modelin karışıklık matrisi.	41
Şekil 3.6.	FIRE Dataset için GA-YOLOv8 tabanlı modelin karışıklık matrisi.	43
Şekil 3.7.	Performans görselleştirme.	43
Şekil 3.8.	VGG19 eğitim ve doğrulamanın kayıp ve doğruluk değerleri.	45
Şekil 3.9.	ERUFORESTFIRE dataset için VGG19 tabanlı modelin karışıklık matrisi.	46
Şekil 3.10.	ResNet50 eğitim ve doğrulamanın kayıp ve doğruluk değerleri.	47
Şekil 3.11.	ERUFORESTFIRE dataset için ResNet50 tabanlı modelin karışıklık matrisi.	48
Şekil 3.12.	ERUFORESTFIRE dataset için YOLOv8 tabanlı modelin karışıklık matrisi.	49
Şekil 3.13.	ERUFORESTFIRE dataset için GA-YOLOv8 tabanlı modelin karışıklık matrisi.	51
Şekil 3.14.	Performans görselleştirme.	52
Şekil 3.15.	Yerel video ile model testleri yapılan arayüz görünümü.	54
Şekil 3.16.	VGG19	54
Şekil 3.17.	ResNet50	55
Şekil 3.18.	YOLOv8	55
Şekil 3.19.	GA-YOLOv8	55
Şekil 3.20.	GA-YOLOv8 modelinin gerçek zamanlı test görüntüsü.	57

GİRİŞ

Ormanlar, geniş alanlarda kendilerine özgü mikroiklimleri barındıran, yosunlar, mantar türleri, ağaçlar, çalılar ve çeşitli bitki türlerinin yanı sıra toprak altı ve üstündeki mikroorganizmalar, böcekler ve hayvanların bir araya gelerek oluşturduğu ekosistemlerdir [1]. Ormanlar, canlı topluluklar için yaşam alanları sağlamanın yanı sıra oksijen üretimi açısından da kritik öneme sahiptirler. Ayrıca, erozyonu ve sel oluşumunu engelleme, güneşin zararlı etkilerinden koruma gibi ekolojik rollerin yanı sıra, insanlar için dinlenme ve sosyal etkileşim alanları sunma işlevleri de bulunmaktadır [2]. AFAD (Afet ve Acil Durum Yönetimi Başkanlığı), orman yangınlarını dünyada biyolojik afetler kategorisine dahil ederek, ülkemizde en sık karşılaşılan doğal afetlerden biri olarak tanımlamaktadır. [3]. Orman yangınlarının, yıldırım düşmesi, elektrik hatlarının arızalanması, yanardağ patlaması gibi doğal olaylarla birlikte, insan kaynaklı bilinçli ve bilinçsiz davranışların da neden olduğu bilinmektedir. Türkiye'nin toplam alanının %29,4'ü ormanlarla kaplı olup, bu da ülkenin toplam orman alanının 22,9 milyon hektar olduğunu göstermektedir. [1]. Ülkemizde, yıllık ortalama olarak 8-10 bin hektar ormanlık alan yangınlar tarafından etkilenmektedir. Dünya genelinde ve Avrupa'da ise, orman yangınlarından etkilenen toplam alanın yıllık ortalaması 400 milyon hektar civarındadır [4]. Doğal afetlerin sıklığı ve şiddeti günümüzde iklim değişikliğinin etkilerine bağlı olarak artmaktadır. Afetler arasında özellikle orman yangınları, canlı yaşamına ve ekosistemlere ciddi zararlar oluşturan olaylardır. Bu kapsamda, erken tespit ve hızlı müdahale oldukça önemli faktördür. Oluşacak zararları önlemede ve güvenlik hizmetinin sağlanabilmesi anlamında hayati öneme sahiptir. İnsansız Hava Araçları (İHA'lar) ve derin öğrenme teknikleri doğal afetlere müdahalede teknolojiye ve inovasyondan faydalanarak, daha etkili ve daha sürdürülebilir sonuçlar elde etmektedir. İHA'lar ormandaki alanları geniş yelpaze ile tarayarak topladığı veriler ve elde ettiği yüksek çözünürlükteki görsellere ulaşabilme kapasitesine sahiptirler. İnsansız hava araçları yangın tespiti ve kontrol amaçlı izleme gerçekleştirilmede çok kıymetli araçlardır. Bununla

birlikte, derin öğrenme algoritmaları büyük miktarda verileri, karmaşık desenlerden anlamlı bilgiler elde etme yeteneğine sahiptir. Sınıflandırma ve görüntü işleme görevlerinde gelişmiş sinir ağları önemli ve belirgin sonuçlar elde etmiştir. İHA tarafından toplanan görüntüler yangın tespiti için hassas ve etkili modellerin geliştirilmesinde potansiyel bir önem arz etmektedir. İHA kullanımındaki avantajlar derin öğrenme yöntemlerinin yangın tespiti konusundaki potansiyelini incelemek bu iki teknolojiyi birleştirerek daha güçlü bir yangın izleme sistemini ortaya koymak bu çalışmanın odak noktasıdır. G.1 ile bir orman yangınına ait görsel sunulmuştur [5].



Şekil G.1. İHA ile çekilen orman yangını görüntüsü.

Yapılacak olan bu çalışma, İHA'lar tarafından elde edilen görüntülerin derin öğrenme yöntemleriyle analiz edilerek yangın tespiti için yeni ve etkili modellerin geliştirilmesini ve canlı izleme sistemi oluşturulması hedeflenmektedir. Bu tez çalışmasının 1. Bölümünde Orman yangını tespiti ile ilgili genel bilgi ve literatür çalışmalarından bahsedilmiştir. 2. Bölümde Orman yangını tespiti için kullanılacak olan İHA'dan alınan görüntüler ile oluşturulmuş olan ERUFORESTFIRE veriseti ve açık erişimli FIREDATASET veri seti anlatılmıştır. Problemin çözümünde kullanılacak olan algoritmalar hakkında bilgi verilmiştir. Gerçek zamanlı yangın izleme sistemi oluşturulması ve deneysel kurulumlardan bahsedilmiştir. 3. Bölümde ERUFORESTFIRE veriseti ve açık erişimli FIREDATASET ile yapılan test çalışmalarının sonuçları incelenmiştir. Önerilen modelle yapılan deneysel çalışma sonuçları hakkında bilgi verilmiştir. 4. Bölümde ise çalışmalar kapsamında elde edilen sonuçların yorumlanması tartışma ve öneriler sunulmaktadır.

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR TARAMASI

Orman yangınları, doğal ekosistemlerin ve biyoçeşitliliğin ciddi bir tehdidi oluşturan, hızlı yayılabilen ve yıkıcı sonuçlar doğurabilen felaketler arasında yer almaktadır. Bu bağlamda, orman yangınları ile ilgili yapılan çalışmalar, yangınların erken tespiti, etkili izleme ve doğru müdahale stratejilerinin geliştirilmesi amacıyla büyük bir öneme sahiptir. Literatürde orman yangınlarına dair yapılan çeşitli çalışmalar, yangınların oluşum nedenlerinden, yayılma modellerine, yangınların erken tespiti, etkilediği ekosistemlere ve yangın sonrası rehabilitasyon stratejilerine kadar geniş bir konu yelpazesini kapsamaktadır. Literatür çalışması, orman yangınlarının erken tespit edilmesine dair bir perspektifle ele alınarak, farklı alanlardaki çalışmaların yerini incelemeyi amaçlamaktadır.

1.1. Orman Yangını Tespit için Yapılan Çalışmalar

Sivrikaya ve ark. [6], yangın risk haritalarının oluşturulması ve bu haritaların kullanılması, orman yangınlarının olumsuz etkilerini azaltmak amacıyla alınması gereken koruyucu tedbirlerin belirlenmesine katkı sağlamaktadır. Bu çalışma, Normalleştirilmiş Yanma Oranı (NBR) indeksi, Normalleştirilmiş Yanma Oranı Termal (NBRT) indeksi, Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI) ve Normalleştirilmiş Fark Su İndeksi (NDWI) gibi dört bitki örtüsü indeksine dayalı yangın riski haritalarının üretilmesine ve karşılaştırılmasına odaklanmıştır. Bu çalışmada, Muğla Orman Bölge Müdürlüğü'nün bulunduğu Akdeniz iklim kuşağında gerçekleşen mega yangınların yaşandığı bir örnek çalışma alanı seçilmiştir. Landsat 8 OLI uydu görüntülerinden dört bitki örtüsü indeksi kullanılarak yangın risk haritaları oluşturulmuştur. Haritaların doğruluğunu değerlendirmek için 2021 yılında meydana gelen yangın verileri kullanılmıştır. NBR,

NDWI ve NDVI'ye göre oluşturulan haritaların çoğu (%90'dan fazla), yangın riski bakımından yüksek ve aşırı yüksek riskli bölgeleri doğru bir şekilde belirlemiştir. Yangınların büyük bir kısmının yüksek riskli bölgelerde meydana gelmesi, çalışma alanının yangına karşı hassas olduğunu ve kullanılan bitki örtüsü indekslerinin yangınların meydana gelebileceği yerleri doğru bir şekilde tahmin etmede yüksek doğrulukta olduğunu göstermektedir. Doğruluk sonuçları, NBR için 0,842, NDWI için 0,835, NBRT için 0,812 ve NDVI için 0,810 olarak belirlenmiştir.

Miao, Xinyu ve ark. [7], orman büyüme tahminlerinin doğruluğunu artırmayı hedefleyen genişletilmiş pencere tabanlı Transformer zaman serisi tahmin modelini sunmaktadır. Chongli bölgesinde 2020'den 2021'e kadar olan zaman serisi verilerinden elde edilen bilgilerle, uzaktan algılama uydusu ve GIS teknolojileri kullanılarak bir dizi orman parçalanma faktörü tespit edilmiş ve bu faktörler arasındaki çoklu kesitlilik analizi gerçekleştirilmiştir. Gerçekleşen orman patlaması tahmin görevinin karmaşık yapısını dikkate alarak, 13 etkili faktöre dayanan bir ikili zaman serisi stratejisi ile tamamlanan yeni bir pencere tabanlı Transformer yapısı tanıtılmıştır. Daha sonra, Chongli bölgesinde orman yangını risk tahmini oluşturmak için bu zaman serisi veri modeli entegre edilmiştir. Modelin etkinliği, doğruluk (ACC), ortalama karekök hata (RMSE) ve ortalama mutlak hata (MAE) gibi çeşitli ölçümler kullanılarak değerlendirilmiş ve geleneksel derin öğrenme yöntemleriyle karşılaştırılmıştır. Model, orman dosyalarının depolanmasıyla mekansal arka plan bilgilerini verimli şekilde kullanılmıştır. Elde edilen sonuçlar ACC = %91,56, RMSE = 0,37, MAE = 0,05 şeklindedir.

Zhou ve ark. [8], Himawari-8 verilerini kullanarak eşik tabanlı bir algoritma ile rastgele orman (RF) modelini birleştiren bir orman yangını izleme yöntemi önerilmektedir. Eşik tabanlı algoritma, potansiyel yangın noktalarını belirlemek amacıyla güneş tepe açısını kullanarak olası yangın noktalarını çıkarmak için adaptasyon yeteneğine sahip bir karar eşiği belirlemektedir. Spektral özellikler ve uzay-zamansal bilgilerle oluşturulan RF modeli daha sonra eşik tabanlı algoritmanın sonuçlarından sahte yangın noktalarını filtrelemek için kullanılmaktadır. Orman dışı alanlardaki yangın noktalarını elemek için arazi örtüsü verileri kullanılarak son işlemler gerçekleştirilir. Tanımlama doğruluğunu doğrulamak amacıyla beş yangın oluşma anı seçilmiştir. Sonuçlar, genel doğruluk ve genel kapsamlı değerlendirme değerlerinin sırasıyla %97,36 ve 91,30 sonuçları elde

edilmiştir.

Anuar ve ark. [9], gerçek zamanlı bir orman yangını tespit, izleme ve uyarı sistemini geliştirmeyi amaçlamaktadır. Sistem, sıcaklık ve nem sensörleri, duman sensörü, Arduino mikrodenetleyici ve kablosuz bağlantı modülünün bir araya getirilmesiyle başlanmıştır. Ardından, Blynk kullanılarak bir yangın izleme ve uyarı sistemi geliştirilmiştir. Alev sensörü analizi ile sistemin alev varlığını 60 cm'ye kadar algılayabildiği tespit edilmiştir. Sensör aynı zamanda öğle saatlerinde yüksek sıcaklık (45 °C) ve düşük nem (%53,4) tespit edilmiştir. Sabah saatlerinde ise düşük sıcaklık (29 °C) ve yüksek nem (%88,4) tespit edilmiştir. Ayrıca, yangından çıkan duman algılandığında en yüksek karbon dioksit (CO₂) konsantrasyonu 1,800 ppm olarak kaydedilmiştir. Küresel konumlandırma sistemi modülü, sistemin Blynk uygulamasında doğru bir şekilde gerçek zamanlı konumunu göstermektedir. Sonuç olarak, bu sistem gerçek zamanlı olarak orman yangınlarını erken tespit edebilmektedir.

Bharti ve ark. [10], yangının hızını ve şiddetini tespit etmek amacıyla alev, duman, sıcaklık, LDR ve MQ2 sensörlerini kullanan yeni bir yangın algılama ve kontrol sistemi önerilmektedir. Bu önerilen IoT tabanlı yangın izleme ve kontrol sistemi, sadece mevcut durumsal bilgileri iletmekle kalmayıp aynı zamanda gerekli iyileştirici eylemleri de gerçekleştirmektedir. NodeMCU kartı, yangın alarm sisteminin temelini oluşturur ve bilgileri yangın kontrol merkezlerine iletir, yangının ciddiyetine göre alarmları etkinleştirir. Eğer bir alev yayılma şansı bulamadan fark edilirse, sistem alarm verecek ve Blynk bulutu aracılığıyla yangın kontrol merkezini bilgilendirecektir.

Satheeshkumar ve ark. [11], IoT tabanlı bir yangın algılama ve uyarı sistemi önermektedir. Belirli bir ortamın 7/24 izlenmesi ve herhangi bir ölümcül durumda kullanıcıya uyarı verilmesi sağlanmaktadır. Bu sistem, yangınla ilgili bir kaza sırasında ortaya çıkabilecek farklı fiziksel parametreleri tespit etmek için bir NodeMCU ve bir dizi sensör kullanmaktadır. Sistemde sürekli olarak sıcaklık ve duman varlığı olmak üzere iki parametre izlenmektedir. Sıcaklığın algılanması için LM35 sıcaklık sensörü kullanılmaktadır. Dumanın varlığını tespit etmek için ise MQ6 adı verilen bir gaz sensörü kullanılmaktadır, bu sensör CO₂ üreten her türlü karbon bazlı gaz dumanını algılayabilir ve ölçebilir, bu da MQ6 kullanılarak dumanın algılanmasını sağlamaktadır.

Ayrıca, herhangi bir insanın varlığını tespit etmek için PIR sensörü kullanılmaktadır. Gaz ve sıcaklık sensörleri analog olduğundan dolayı, bir ADC'ye (analogdan dijitale dönüştürücü) giriş olan bir analog pime bağlanmaktadır. Nodemcu'da iki analog sensör olduğundan tek kanallı bir ADC kullanılmaktadır ve bu sorun, MCP3008 adı verilen bir ADC modülü eklenerek çözülmüştür. MCP3008, sekiz kanallı bir ADC'ye sahip bir IC'dir. Ayrıca, ormanlık alanlar kamera aracılığıyla izlenebilmekte ve görüntü işleme kullanılarak yangın tespiti yapılabilmektedir. Bu amaçla, bir PC'den çalıştırılan bir Python programı ve OpenCV kütüphanesi kullanılarak yangın tespiti gerçekleştirilebilir. Sensörlerin arızalanması durumunda bu sistem acil durum durumunda kullanılarak yangın tespiti ve önleme işlemlerini gerçekleştirebilir. Yangın tespit edildiğinde su fıskiyesi devreye girecek ve ilgili kişiye daha fazla önlem alınması için uyarı gönderilecektir.

Kang ve ark. [12], sabit konumdaki uydu sensörlerinin büyük zamansal çözünürlüğü sayesinde orman yangınlarının anında tespit edilebileceğini ortaya koymaktadır. Çalışmada, 91 orman yangını vakasından yararlanılmış; bunlardan yedisi büyük zararlar meydana getiren büyük orman yangınlarına sebep olmuştur. Model, döndürme ve çevirme işlemleriyle temel veri artırma yöntemleri kullanılarak eğitilmiştir. Giriş verileri, N giriş karakteristiğine sahip 9×9 pencere görüntüsünden oluşmaktadır ve sonuç, pencerenin merkez pikselinin bir orman yangını olayını temsil edip etmediğini gösteren ikili bir sınıftır. Simülasyon sonuçları, sırasıyla 0,91 hassasiyet, 0,74 F1 puanı, 0,98 doğruluk ve 0,63 geri çağırma değerlerine varılmıştır.

Jiang ve ark. [13], yangın olaylarını tespit etmek için genetik algoritmayı (GA) kullanarak CNN modelinin hiperparametrelerini ayarlamışlardır. Yazarlar, yöntemlerini geri yayılma (BP) sinir ağı, destek vektör makinesi (SVM) ve CNN yaklaşımlarıyla karşılaştırmışlardır. Test ve eğitim veri setleri, 1900 görüntüden oluşan geliştirme veri setini oluşturmuşlardır. Optimize edilmiş GA-CNN yönteminin doğruluk değeri %95'tir. Bu, optimize edilmemiş CNN algoritmasının (%85), BP sinir ağı algoritmasının (%73) ve SVM algoritmasının (%90) doğruluk değerlerini elde etmişlerdir.

Gayathri ve arkadaşları [14], CNN'yi normal LSTM ile birleştirmek yerine çift yönlü bir algoritmanın hibrit ortamında LSTM ve CNN'yi kullanmışlardır. Bu yaklaşım, mobil veya IoT cihazlarına bildirimler yoluyla bağlanabilen Google'ın Firebase'ini

içermektedir. Önerilen model, eğitim veri seti için %96, test veri seti için ise %92 doğruluk elde etmişlerdir.

Khan ve ark. [15], MobileNetV2'nin orijinal ağırlıklarını dondurarak ve özellik çıkarma katmanlarına tamamen bağlı katmanları uygulayarak bir model geliştirmişlerdir. 950 yangın sınıfına ve 950 yangın olmayan sınıfa eşit olarak bölümlenmiş görüntülerden oluşan bir veri seti kullanmışlardır. Ayrıca, eğitim veri setine büyütme teknikleri uygulamış ve görüntü çeşitliliğini daha iyi temsil edebilmek için giriş görüntülerinin boyutu 224×224 piksele düşürmüşlerdir. FireNet, %1,58 hata oranı, %99,47 geri çağırma ve %97,42 hassasiyetle %98,42 doğruluk elde etmişlerdir.

1.2. İHA'dan Alınmış Görüntüler ile Orman Yangını Tespiti

Mashrafi ve arkadaşları [16], DIFFDC-MDL adlı değiştirilmiş bir DL modelini kullanarak orman yangınlarını tespit etmek ve sınıflandırmak için drone görüntüleri kullanmaktadır. DIFFDC-MDL, temel MobileNet-v2 mimarisini kullanarak, en uygun özellik vektörlerini üretmek için hibrit bir LSTM-RNN katmanını entegre etmişlerdir. Yazarlar, 6000 örneğin bulunduğu Ateş Parlaklığı Havadan Tabanlı Makine Öğrenimi Değerlendirmesi (FLAME) veri kümesini, yangın görüntüleri (3000) ve ateşsiz görüntüler (3000) olmak üzere iki dengeli gruba ayırmışlardır. DIFFDC-MDL, %99,38'lük yüksek bir doğruluk performansı sergileyerek, optimize edilmiş bir hiperparametre setinin DL modelinin etkinliğini potansiyel olarak artırabileceğini sonuca varmışlardır.

Jandhyala ve ark. [17], belirli bir hava görüntüsündeki yangın veya duman varlığına göre sınıflandırma yapmak amacıyla Evrişimli Sinir Ağı (CNN) temelli Inception-V3 modeli ve görüntüdeki yangın veya duman bölgelerini tespit etmek için Tek Atış Dedektör modeli kullanmıştır. Bu modeller, hava görüntüleri üzerinde transfer öğrenimi kullanılarak eğitilmiş olup, sınıflandırma için %88, tespit için ise %91 genel doğruluk oranlarına ulaşmıştır. Bu modeller, hava araçlarıyla kaydedilen canlı görüntülerdeki yangınları tespit etmek için kullanılabilir ve afet yönetimi birimlerine anında tepki verme ve müdahalede bulunma konusunda yardımcı olmaktadır.

Namburu ve ark. [18], orman yangınlarını %97,26 doğruluk ile sınıflandırmak ve eyalet orman birimleri ile işbirliği yaparak orman yangınlarını zamanında tespit edip GPS

konumunu paylaşmak için daha ekonomik bir İnsansız Hava Aracı (İHA) önermektedir. Genişletilmiş MobileNet derin öğrenme yeteneklerine sahip olan bu İHA, orman yangınlarının etkili bir şekilde tanımlanmasını ve hızlı müdahaleyi sağlamak amacı üzerine çalışmışlardır.

Deng ve ark. [19], İnsansız Hava Araçları (İHA) görüntülerini kullanarak orman yangınlarını tespit etmek amacıyla MobileNetV2 ve dikkat mekanizmasını temel alan hafif derin öğrenme (DL) algoritmaları önermektedir. Yapılan çeşitli deneyler sonucunda, önerilen model orman yangını algılama ve sınıflandırmada diğer ilgili yöntemlere göre daha yüksek bir performans sergileyerek %86,14'lük bir doğruluk oranı ve 87,19'luk bir F1 puanı elde edilmiştir.

Mohammed ve ark. [20], transfer öğrenme tekniğine odaklanarak ImageNet veri kümesinden duman ve orman yangınlarının özelliklerini çıkarmayı amaçlamaktadır. Derlenmiş veri seti, her yangın ve duman sınıfı için 1102 görüntü içermektedir. Bu görüntüler, önceden eğitilmiş bir Inception-ResNet-V2 ağına girdi olarak kullanılmıştır. Çalışmada, Inception-ResNet-V2 ağının kullanılmasıyla veri kümesinden en uygun özelliklerin çıkarılması hedeflenmiştir. Yazarlar, Adam optimizasyonunu belirli bir konfigürasyonla kullanmışlardır. Önerilen model, orman yangını sınıflandırma görevi için yüksek performans sergileyerek %99,09 doğruluk, %100 kesinlik, %98,08 geri çağırma, %98,09 F1 puanı ve %98,30 özgüllük elde edilmiştir.

Aral ve ark. [21], İnsansız Hava Araçları (İHA'lar) tarafından kaydedilen görüntülerden elde edilen İHA görüş verilerini kullanarak orman yangını algılama görevlerini gerçekleştirmek için dikkat odaklı bir yaklaşım sunmaktadır. Ayrıca, transfer öğrenimi, derin CNN'ler ve hafif CNN'ler gibi farklı yaklaşımlara dair kapsamlı bir araştırma sunulmaktadır. Deneylenen modeller arasında, dikkat odaklı EfficientNetB0 omurga modeli, orman yangını tespitinde en başarılı mimari olarak belirlenmiştir. Test doğruluğu %92,02, F1 puanı %92,08, hatırlama oranı %92,02 ve kesinlik %92,66 ile EfficientNetB0 tabanlı model, orman yangını tespitinde yüksek bir etkinlik sergilemiştir.

Aral ve ark. [22], orman yangınlarını tespit etmek amacıyla geliştirilen bir Derin Öğrenme yaklaşımını CNN tabanlı olarak çalışılmıştır. Optimal sonuçlara ulaşmak için belirlenen mimari içerisinde, sinir ağlarını özellik çıkarıcı olarak uygulanmaktadır. Deneylerde,

İnsansız Hava Aracı (İHA) ile elde edilen kızılötesi orman yangını görüntüleri kullanılmıştır. Elde edilen sonuçlar, en üst düzeyde değerlendirme metriklerine sahip olan ResNet101 tabanlı mimari, %99,20 test doğruluk elde edilmiştir.

Nallakaruppan ve ark. [23], uydu görüntüleme kullanılarak orman yangınlarının erken aşamalarda tespit edilmesine yönelik bilgiler sunmakta ve aynı verilerin en yakın izleme istasyonlarına iletilmektedir. İzleme istasyonlarında, orman yangını olup olmadığını belirlemek için InceptionV3, VGG-16, ResNet-50 ve DenseNet-201 gibi derin görüntü sinir ağı modellerini ikili sınıflandırma yöntemi uygulanmaktadır. Elde edilen sonuçlar, DenseNet 201'in tüm bu modeller arasında en derin evrişim katmanına sahip olduğunu performans göstererek %98,46 doğruluk elde edilmiştir.

Duangsuwan ve ark. [24], drone tabanlı gerçek zamanlı açık yanma görüntü algılama için YOLOv5 dedektörü ve hafif bir versiyonunu kullanarak derin öğrenme temelli bir nesne algılama yöntemini önermektedir. Bu çalışma, uzun kısa süreli bellek (LSTM) sınıflandırıcısını içermektedir ve Dr-TOBID (Drone-based Real-time Open Burning Image Detection) çerçevesi olarak isimlendirilmektedir. Dr-TOBID çerçevesi, OpenCV, YOLOv5, TensorFlow, LebelImg ve Pycharm kullanılarak tasarlanmış ve canlı yayın aracılığıyla kablosuz olarak OBS üzerine bağlanmıştır. Veri kümeleri eğitim için %80, test için %20 oranında ayrılmıştır. Gündüz ve gece koşulları, drone'nun irtifaları, menzilleri ve RGB modunun koşulları değerlendirme sürecinde dikkate alınmıştır. Doğruluk, kesinlik, geri çağırma ve F1 Puanı olmak üzere değerlendirme metrikleri kullanılmıştır. Elde edilen sonuçlar, Dr-TOBID'in açık yanma izleme, duman ve yanma özelliklerini başarıyla tespit ettiğini göstermektedir; ortalama F1 puanı gündüz duman tespiti için %80,6, gündüz yanma tespiti için %82,5 ve gece duman algılama ile gece yanma algılama için %81,9 olarak elde edilmiştir.

Saydirasulovich ve ark. [25], İnsansız Hava Aracı (İHA) görüntülerine özel olarak uyarlanmış ve daha yüksek algılama doğruluğu elde etmek amacıyla geliştirilmiş bir YOLOv8 modelini önermektedir. İlk olarak, araştırma Wise-IoU (WIoU) v3'ü sınırlayıcı kutular için bir regresyon kaybı olarak içermekte ve makul bir gradyan tahsis stratejisi ile desteklenmektedir, böylece modelin hassasiyet kapasitesi artırılmaktadır. İkinci olarak, ara katmanındaki geleneksel evrişim süreci, Ghost Shuffle Evrişim mekanizması

ile değiştirilmiştir. Bu değişiklik, model parametrelerini azaltır ve yakınsama oranını hızlandırmaktadır. Üçüncü olarak, karmaşık ormanlık ortamlarda orman yangını dumanının göze çarpan özelliklerinin yetersiz şekilde yakalanmasının zorluğunu kabul eden bu çalışma, BiFormer dikkat mekanizmasını göstermektedir. Bu mekanizma, modelin dikkatini orman yangını dumanının karmaşık özelliklerine yönlendirmektedir. Elde edilen deneysel bulgular, geliştirilmiş YOLOv8 modelinin duman algılamada etkinliğini vurgulayarak %79,4'lük bir ortalama hassasiyet (AP) elde ettiğini gösteriyor ve bu, taban çizgisine göre %3,3'lük dikkat çekmektedir. Performans metriğine göre model ile elde edilen değerler sırası ile %71,3 ve %92,6'dır.

1.3. Tez Çalışmasında Kullanılan Açık Erişimli Veri Seti ile Yapılan Çalışmalar

Aksoy ve ark. [26], yangınların erken tespiti üzerine odaklanılmış ve bu amaçla bir İHA tasarlanmıştır. Görüntü işleme ve yapay zeka yöntemleri kullanılarak, ateşin görüntülerde tespiti yapılmakta ve yangın tespit edilen konum belirlenmektedir. Çalışma sonuçlarına göre, kullanılan mimari değerlendirilmiş ve %96 doğruluk, %98 duyarlılık, %89 özgülük ve %96 kesinlik gibi performans değerleri elde edilmiştir.

Wang ve ark. [27], ResNet-50 ve RGB iki modelin birleşimi, birbirlerini tamamlayarak daha etkili bir yangın tespiti ve sınıflandırma sistemini ortaya koymayı amaçlamışlardır. Bu çalışmada kullanılan veri seti içerisinde, açık erişimli Firedataset'ten de faydalanmışlardır. ResNet-50 modeli %96,2 doğruluk elde etmişlerdir.

Ghosh ve ark. [28], özellikleri çıkarmak için RNN ve CNN ağlarını birleştirerek tek bir model kullanmak yerine, bu özellikler daha sonra tamamen bağlı iki katmana aktarılmıştır. Mivia veri seti, toplamda 22.500 görüntü içermekte olup, bunlardan 12.000'i yangın veya duman sekansları içerirken, geri kalan 10.000'i ne ateş ne de duman içermektedir. Kaggle veri seti ise toplamda 1000 görüntüden oluşmaktadır; bunlardan 755'i yangın sınıfında iken, diğer 245'i normal sınıfa aittir. Ghosh ve Kumar, Mivia laboratuvarı ve Kaggle yangın veri kümeleri için sırasıyla %99,62 ve %99,10 doğruluk sonuçlarını elde etmişlerdir.

Batog ve ark. [29], görüntülerdeki yangınları tanımlamak için optimal renk uzayını belirlemeyi amaçlamışlardır. Bu amaçla, görüntüler Kaggle platformundan alınan iki veri

tabanından seçilmiş ve görüntüler altı renk uzayında işlenmiştir: RGB, YCbCr, HSV, HLS, Lab ve Luv. Ardından, modeller altı veri kümesinde eğitilmiş, her renk uzayı için bir veri kümesi, ve CNN'lerin derlenmesinden sonra bir tahmin modeli için bir test seti önermişlerdir. Modelin sonuçları doğruluk ve kayıp fonksiyonuna göre analiz etmişlerdir. Yangının görselleştirilmesi ve lokalizasyonu için Grad-CAM yöntemini, görüntü sınıflandırması için ise EfficientNetB0 CNN'yi kullanmışlardır. Yangın Algılama Veri Seti ve DeepQuestAI görüntü veri setleri için %95,40'lık bir test doğruluğu elde edilmiştir.

Wang ve ark. [30], BCFS-Net adını verdikleri, yangın görüntüsü sınıflandırması için çift yönlü karakteristiklere ve özellik seçimine dayalı entegre bir algoritma önermektedirler. Algoritma, çift yönlü karakteristikler modülü ve özellik seçimi modülü olmak üzere iki ana modülden oluşmaktadır. Çift yönlü dikkat mekanizması ve Öklid uzaklığı kullanılarak, Inception V3 modülündeki evrişimler tarafından oluşturulan özellik haritaları arasında daha yüksek korelasyona sahip özellik noktaları seçmektedir. Özellik noktalarını birden fazla boyuttan gelen daha zengin anlamsal bilgilerle kapsamlı bir şekilde değerlendirip entegre etmektedirler. Önerilen algoritmanın fizibilitesini, açık erişimli FireDataset yangın veri setinde %96,96 oranında başarı oranı elde etmişlerdir.

Musaev ve ark. [31], KeepNMax adlı bir görüntü kanalları ve dönemler topluluğu geliştirilmiştir. KeepNMax, en üstteki N maksimum tahmin olasılığını kullanarak topluluk hatasını azaltmayı ve veri bilgisi miktarını artırmayı amaçlamaktadır. Dokuz farklı veri seti üzerinde eğitilen KeepNMax, görüntüleri farklı kanallara bölen ve aynı model mimarisi kullanılarak eğiten bir yaklaşım benimsemiştir. %98,9 şeklinde sonuç elde etmişlerdir.

Jagatheesaperumal ve ark. [32], yangın tespiti için CNN'in katman parametreleri özel bir öğrenme ağı oluşturacak şekilde değiştirerek, yangınları daha doğru bir şekilde tespit etmeyi amaçlamışlardır. İnsan tespiti için ise AlexNet mimarisi, yangın kazası bölgesindeki insanların varlığını belirlemek amacıyla kullanmışlardır. İçerisinde açık erişimli olan FireDataset kümesini de ekleyerek yangın veri kümesi oluşturmuşlar, farklı optimize ediciler, aktivasyon fonksiyonları ve öğrenme oranları kullanarak oluşturulan modeli test ve analiz etmişlerdir. Eğitimin onüçüncü aşamasında %90 doğruluk sonucu

elde etmişlerdir.

Hindarto ve ark. [33], temel amacı iki modelin orman yangını tespiti senaryolarındaki avantajlarını ve dezavantajlarını anlamak, değerlendirmek ve karşılaştırmaktır. Bu çalışmada, CNN ve VGG16 modellerini eğitmek için FireDataset veri seti kullanılmıştır. Test sonuçları, CNN modelinin %96 oranında orman yangını algılama doğruluğuna ulaştığını, VGG16 modelinin ise %98 doğruluk elde edilmiştir.

Literatürde yapılan çalışmalar, çeşitli yöntemlerin ve teknolojilerin kullanılarak orman yangınlarının tespit edilmesi ve izlenmesi üzerine odaklanmaktadır. İlk olarak geleneksel tekniklerden başlayıp yapay zeka tekniklerinin kullanıldığı İHA gibi teknolojiler kullanılarak orman yangınlarının tespiti ve sınıflandırması gerçekleştirildiği çalışmalar, açık erişimli veri setinin kullanıldığı diğer çalışmalar incelenmiştir. Bu çalışmalarda, farklı makine öğrenmesi ve derin öğrenme modelleri denenerek, orman yangınlarının tespiti ve sınıflandırması üzerine çeşitli yöntemler geliştirilmiştir. Tüm bu çalışmalar, orman yangınlarının erken tespiti ve izlenmesi için çeşitli yöntemlerin ve teknolojilerin kullanılabilceğini göstermektedir.

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Veri Seti


Bir veri seti, araştırma veya analiz için derlenmiş verilerin bir koleksiyonudur. Makine öğrenimi, istatistiksel analiz ve veri görselleştirme gibi çeşitli alanlarda kullanılmak üzere bir araya getirilen bu veri kümesi, tez çalışmasında kullanılacaktır. Tez çalışmasında kullanılacak olan açık erişimli bir veri seti ve oluşturulan yeni bir veri seti kullanılacaktır.

2.1.1. FIRE Dataset: Açık Erişimli Yangın Veri Seti

FIRE Dataset isimli veri seti [34] yangın tespiti yapılabilmesi adına yangın olan ve olmayan görsellerden oluşmaktadır. Bu veri seti 2018 yılında NASA Uzay Uygulamaları Yarışması sırasında oluşturulmuştur. Bu çalışmada, yangın içeren görüntüler ile normal doğa görüntüleri arasında ayırım yapacak bir modeli eğitmek için görüntüler toplanmıştır. Ancak, veri seti çarpık bir dağılıma sahiptir; yangın içeren görüntülerin sayısı 755 iken, doğa görüntülerinin sayısı 244'tür. Klasörler arasındaki eşitsizlik, sınıf başına eşit sayıda örneğe sahip olmayan bir doğrulama kümesi elde etmeyi zorlaştırmaktadır. Bu yaklaşım, modelin eğitim sırasında dengeli bir performans sergilemesini ve yanlışlık olasılığını azaltmasını amaçlamaktadır. Şekil 2.1 a) ve b) ile FIRE Dataset veri setine ait örnekler sunulmuştur. [34].



a) Yangın olan örnek görüntü.



b) Yangın olmayan örnek görüntü.

Şekil 2.1. Fire Dataset veri setine ait görüntüler.

2.1.2. ERUFORESTFIRE: Orman Yangın Tespiti İçin Yeni Bir Veri Seti

Bu çalışma kapsamında, orman yangınlarını tespit etmek amacıyla derin öğrenme modellerinin etkin bir şekilde kullanılabilmesi için gerekli olan ERUFORESTFIRE Veri Seti oluşturulmuştur. Bu veri seti, EVO II Pro V3 drone tarafından çekilen orman videolarından çıkarılan görüntüleri ve Roboflow, internet gezinti aracılığıyla elde edilen yangın görüntülerini içermektedir. Drone ile çekilen orman videoları Python ve OpenCV kütüphanesi kullanılarak geliştirilen yazılım ile belirli aralıklarla alınan kareler, yangınsız orman görüntülerini temsil eden fotoğraflara dönüştürülmüştür. Toplamda 45 orman videosundan elde edilen 3.000 adet yangın içermeyen görüntü ile aynı sayıda Roboflow ve internet görseller gezinti aracılığıyla 3.000 adet orman yangını görüntüsü oluşturulmuştur. Oluşturulan ERUFORESTFIRE Veri Seti, mevsimsel çeşitliliği ve farklı ağaç özelliklerini içererek derin öğrenme modellerinin gerçek dünya koşullarında daha etkili bir şekilde genellemesini hedeflemektedir.



a) Yangın olan örnek görüntü



b) Yangın olmayan örnek görüntü

Şekil 2.2. ERUFORESTFIRE veri setine ait görüntüler.

2.2. Problem Çözümünde kullanılacak Derin Öğrenme Algoritmaları

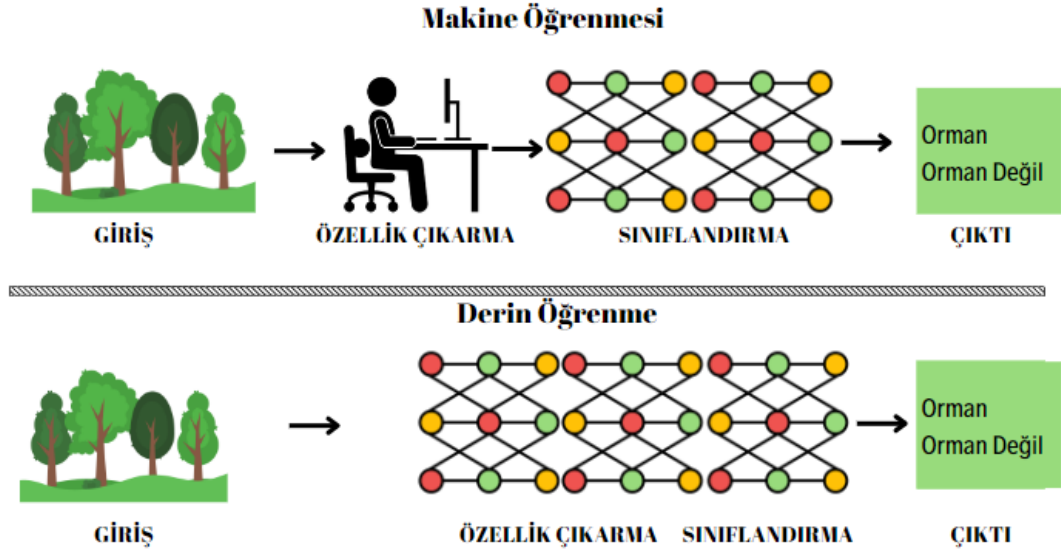
Günümüzde, derin öğrenme modelleri, birçok bilgisayarlı görü, doğal dil işleme ve diğer yapay zeka alanlarında önemli başarılar elde etmiştir. Özellikle, ön eğitilmiş derin öğrenme modelleri, sınırlı veriye sahip olduğumuz karmaşık problemleri çözmek için güçlü bir araç haline gelmiştir. Bu modeller, genellikle büyük veri kümeleri üzerinde önceden eğitilmiş ve ardından belirli bir görev için özelleştirilmiştir, böylece belirli bir görevde yüksek performans göstermektedir. Bu başlık altında, ön eğitilmiş derin öğrenme modellerinin genel özellikleri hakkında bilgi verilmiştir.

2.2.1. Yapay Zekâ

Yapay Zekâ (YZ) oldukça köklü bir geçmişi bulunmaktadır. 1950'li yıllardan günümüze gelişerek gelmiştir [35]. İnsan benzeri zekâ yeteneklerini bilgisayara kazandırmayı amaçlayan bir disiplindir. Verileri analiz etmek, düşünmek, öğrenmek ve karmaşık görevleri yerine getirebilmeyi amaçlamaktadır. Böylece problem çözme, desen tanıma, öğrenme ve adaptasyon gibi insan benzeri yetenekleri sergilemek üzere tasarlanmıştır. Gelişen bu teknoloji sağlık ve endüstri olmak üzere birçok alanda yaygın şekilde kullanılmakta ve gelişmekte gelişmelere de yol açmaktadır.

2.2.2. Makine Öğrenmesi

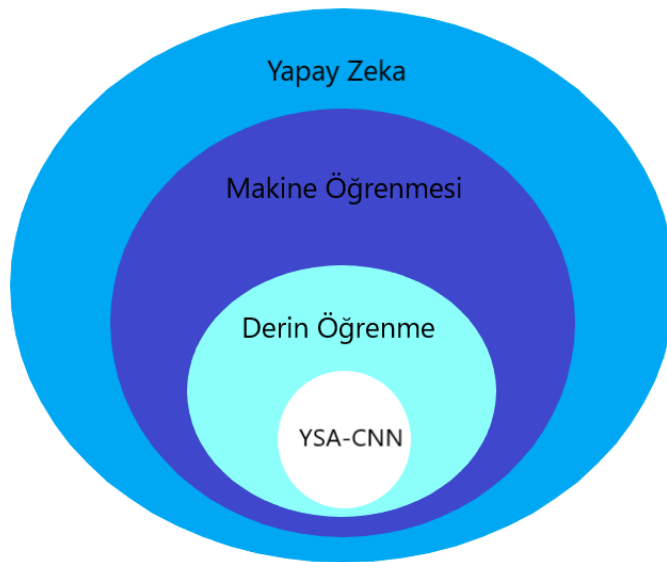
Makine öğrenmesi (ML) normal programlamadan farklı olarak kurallardan oluşmaktadır. Normal programlamada bilgisayara girdiler yazılmış olan algoritmanın sırasına uygun şekilde çıktılar vermektedir. Fakat makine öğrenmesinde belirli ölçütler ve performanslara bağlı olarak farklı sonuçlar üretebilen yapay zekânın alt dalıdır. Algoritmalar veri üzerinden öğrenim gerçekleştirir ve böylece verilen görevleri uygulamaktadırlar. Makine öğrenimi genel olarak denetimli ve denetimsiz öğrenme olarak sınıflandırılabilir. Tanım gereği denetlenen terimi, "makinenin" (sistemin) bir şeyin (tipik olarak etiketlenmiş bir eğitim verisi) yardımıyla öğrendiği anlamına gelmektedir [36].



Şekil 2.3. Makine öğrenmesi karşılaştırma.

2.2.3. Derin Öğrenme

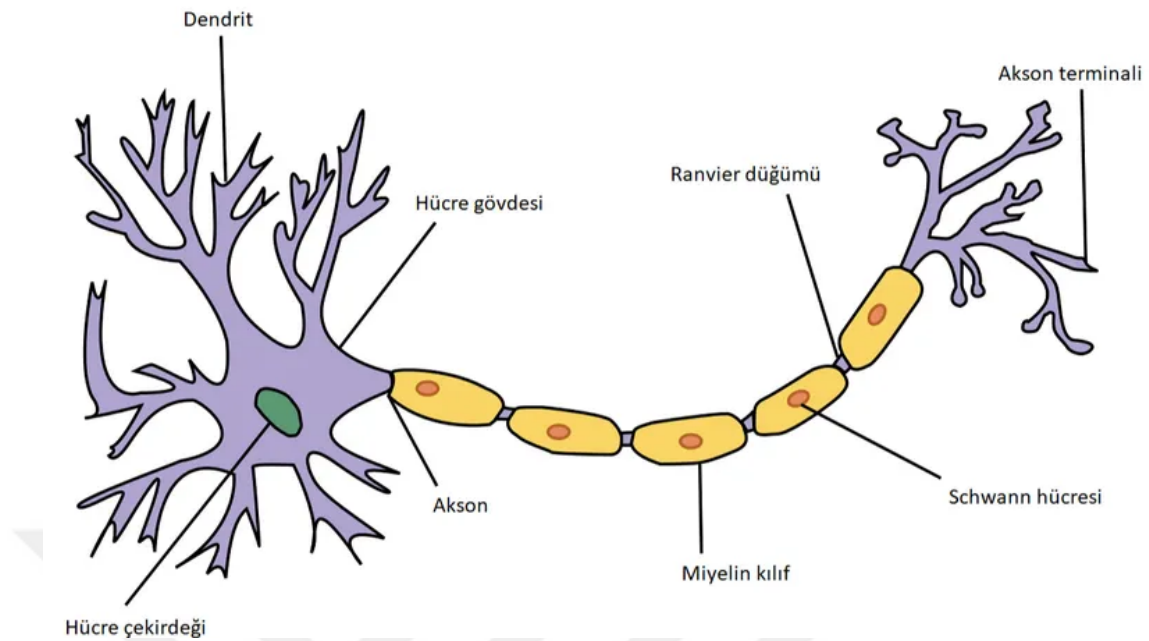
Derin öğrenme (DL), Çok katmanlı yapay sinir ağları kullanılan makine öğrenmesinin bir alt dalıdır. Derin öğrenme modeli makine öğrenmesine göre daha karmaşık özellikleri öğrenme odak noktasıdır. Makine öğrenmesinden farklı olarak verileri elle hazırlamaktan kurtarmaktadır. Özellik çıkarım yapması sebebiyle kullanımı oldukça fazladır. Evrişimli Sinir Ağı (CNN) derin sinir ağları en popüleridir. Yapay sinir ağlarının parametrelerine genellikle ağırlık olarak isimlendirilmektedir [37]. Yapay zekânın bir alt dalı olan makine öğrenmesinin sınıfı olarak kabul edilebilmektedir.



Şekil 2.4. YZ yöntemlerin kapsamaları.

2.2.4. Yapay Sinir Ağları

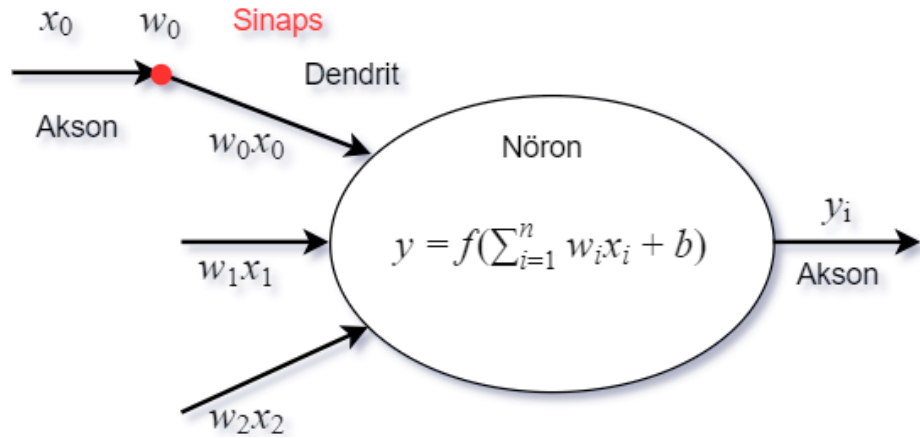
Günümüzün yapay zeka sistemlerinde, sinir hücrelerinin matematiksel modellemesi oldukça önemlidir. Bu modeller, biyolojik sinir sistemlerinden ilham alınarak oluşturulmuştur. Bir sinir hücresinin temel yapı taşları olan dentritler, sinapslar ve aksonlar, bilgisayar bilimlerinde yapay sinir ağları olarak bilinen derin öğrenme modellerinin temelini oluşturmaktadır.



Şekil 2.5. İnsan sinir hücresi biyolojik gösterimi.


Dentritler, diğer sinir hücrelerinden gelen sinyalleri alarak sinir hücresine ileten yapısal bileşenlerdir. Sinapslar, bu sinyallerin bir sinir hücresinden diğerine iletilmesini sağlayan bağlantı noktalarıdır. Aksonlar ise sinir hücresinin çıkışıdır ve çıkış darbelerinin iletilmesini sağlamaktadır.

Bir sinir hücresinin matematiksel modellenmesi sırasında, dentritler boyunca bulunan ağırlıklar ve giriş değerleri göz önüne alınmaktadır. Dentrite giren bir giriş değeri, o dentritin ağırlığıyla çarpılarak sinir hücresine iletmektedir. Sinir hücresinde, tüm dentritlerden gelen ağırlık-giriş çarpımları toplanır ve bir bias değeri eklenmektedir. Ardından, bu toplam değer bir aktivasyon fonksiyonuna geçirilerek nihai çıkış elde edilmektedir.



Şekil 2.6. Bir sinir hücresinin matematiksel modeli.

Yapay sinir ağları (YSA) insan beynindeki işleyişi sinir ağlarını taklit etme üzerine matematiksel bir makine öğrenme modelidir. Sinir hücreleri nöron adı verilen birimlerin birbirine bağlantıları aracılığıyla bilgi işleme yeteneğini edinmektedir. Şekil 2.7 ile yapay sinir ağı katmanları ait bir görsel sunulmuştur [38].




Şekil 2.7. Yapay sinir ağı katmanları.

Yapay sinir ağlarında (YSA), bu matematiksel modelleme süreci önemli bir yer tutmaktadır. Her sinir hücresi için en uygun ağırlık ve bias değerlerinin hesaplanması, ağın doğru çalışması için kritiktir. Yapay sinir ağları, giriş, gizli ve çıkış katmanlarından oluşmaktadır. Giriş katmanı, ağa gelen verileri alırken, gizli katmanlar özellik haritalarını çıkarır ve çıkış katmanı anlamlı sonuçlar üretmektedir. Bu yapısal bileşenler ve matematiksel modelleme süreci, yapay sinir ağlarının temelini oluşturur ve çeşitli uygulama alanlarında kullanılan derin öğrenme modellerinin çalışma prensiplerini belirlemektedir.


2.2.5. CNN Ağının Eğitilmesi

CNN (Convolutional Neural Network), görüntü işleme alanında bir devrim yaratan yapay sinir ağı türüdür. Eğitim sürecinde, ağ, giriş verileri üzerinden bir tür "dokunma" işlemi uygulayarak, görüntülerin özelliklerini tespit etmektedir. Bu sayede, CNN, yüz tanıma, nesne algılama ve görüntü sınıflandırma gibi uygulamalarda geleneksel görüntü işleme yöntemlerine göre daha hassas ve doğru sonuçlar üretebilmektedir. Giriş katmanı, gizli katmanlar ve çıkış katmanı şeklinde düzenlenen bu katmanlar, verideki kalıpları ve ilişkileri keşfederek, öğrenme sürecini yönetmektedir. Temelde dört ana katmandan oluşur: Evrişim Katmanı, Aktivasyon Katmanı, Pooling Katmanı ve Fully Connected Flattening Katmanı. Bunlar, bir görüntüyü analiz etmek ve sınıflandırmak için birlikte çalışmaktadır. Ancak, modelin hızını ve performansını artırmak için Batch Normalization ve Dropout gibi katmanlar da opsiyonel olarak eklenmektedir. Şekil 2.8 ile evrişimli katman görüntüden özellik çıkarımına ait bir görsel sunulmuştur [39].



Şekil 2.8. Evrişimli katman görüntüden özellik çıkarımı.

Evrişim Katmanı (Convolutional Layer): Evrişim katmanı, girdi görüntüsü üzerinde özelliklerin belirlenmesi için kullanılmaktadır. Bu katmanda, belirli boyutta bir pencere (filtre) kullanılarak girdi görüntü üzerinde evrişim işlemi uygulanmaktadır. Evrişim işlemi, filtrenin girdi görüntü üzerinde hareket ettirilerek çarpım işlemleri yapılması ve sonuçların toplanmasıyla gerçekleştirilmektedir. Bu sayede, farklı özelliklerin (kenarlar, köşeler, desenler vb.) tespit edilmesi sağlanmaktadır. Görülen giriş matrisi 5×5




Şekil 2.9. Evrişim işlemi.

boyutunda ve kernel matrisi 3×3 boyutundadır. Beklenen çıktı matrisi (evrişim özelliği) ise 3×3 boyutundadır. Bu, 3×3 filtre ile 5×5 matrisin maksimum kesişim pozisyonlarının 3×3 boyutunda olmasından kaynaklanmaktadır. CNN, özellikleri otomatik olarak çıkarma yeteneğiyle tanınmaktadır. [40].


Aktivasyon katmanı, evrişim katmanından çıkan çıktıya bir aktivasyon fonksiyonu uygulamaktadır. Bu fonksiyon, çıktıların doğrusallığını kırarak ve non-lineer hale getirerek modelin daha karmaşık ilişkileri öğrenmesine olanak bilinmektedir. Örneğin, popüler aktivasyon fonksiyonları arasında ReLU (Rectified Linear Activation), sigmoid ve tanh fonksiyonları bulunmaktadır. Şekil 2.10 ile aktivasyon fonksiyonlarına ait bir görsel sunulmuştur [41].

Sigmoid


$$\sigma(x) = \frac{1}{1+e^{-x}}$$

**Leaky ReLU**

$$\max(0.1x, x)$$

**tanh**


$$\tanh(x)$$

**Maxout**


$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

ReLU

$$\max(0, x)$$

**ELU**

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$



Şekil 2.10. Aktivasyon fonksiyonları.

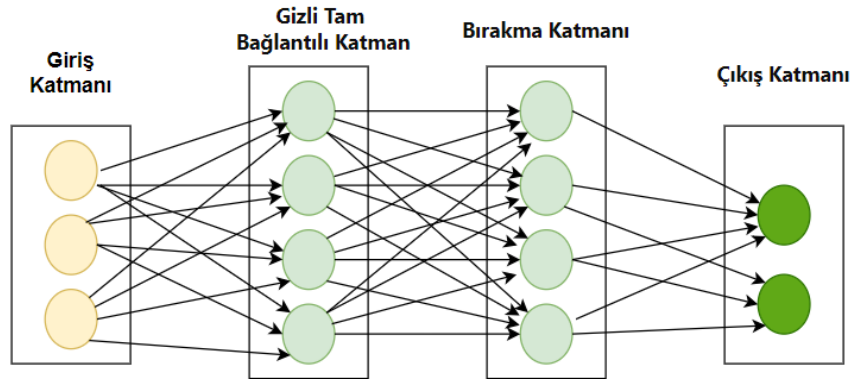
Pooling katmanı, boyut azaltma işlemi yaparak modelin hesaplama maliyetini azaltır ve öğrenme sürecini hızlandırmaktadır. Bu katmanda, girdi görüntüsü üzerinde bir pencere (örneğin, 2×2) gezdirilir ve her bölgenin maksimum değeri (Maksimum Ortaklama) veya ortalaması (Ortalama Ortaklama) alınarak yeni bir görüntü elde edilmektedir.

Tam bağlantı katmanı, önceki katmandan gelen özellikleri düzleştirerek (flattening) bir vektör haline getirir ve bu vektörü bir yapay sinir ağına (fully connected layer) bağlamaktadır. Bu katman, modelin çeşitli özellikler arasında ilişki kurmasını sağlar ve genellikle sınıflandırma veya regresyon gibi görevler için kullanılmaktadır.

Flattening katmanı, evrişim ve havuzlama katmanlarından gelen çok boyutlu verileri düzleştirerek tek boyutlu bir vektör haline getirmektedir. Bu işlem, verilerin bir yapay sinir ağına girebilmesi için gerekmektedir. Batch Normalization katmanı, eğitim sürecini hızlandırmak ve daha istikrarlı sonuçlar elde etmek için kullanılmaktadır. Bu katmanda, her mini-batch için girdi verileri normalleştirilir ve daha sonra bir ölçek ve kayma parametresiyle dönüştürülmektedir.

Dropout katmanı, modelin overfitting'i engellemek için kullanılmaktadır. Bu katmanda, eğitim sırasında rastgele birimler (nöronlar) belirli bir olasılıkla devre dışı bırakılır, bu da modelin farklı özellikler arasında daha iyi genelleme yapmasını sağlamaktadır.

Son olarak, çıkış katmanı, modelin çıktısını oluşturur ve sınıflandırma sonuçlarını sağlamaktadır.



Şekil 2.11. Dropout katmanı.

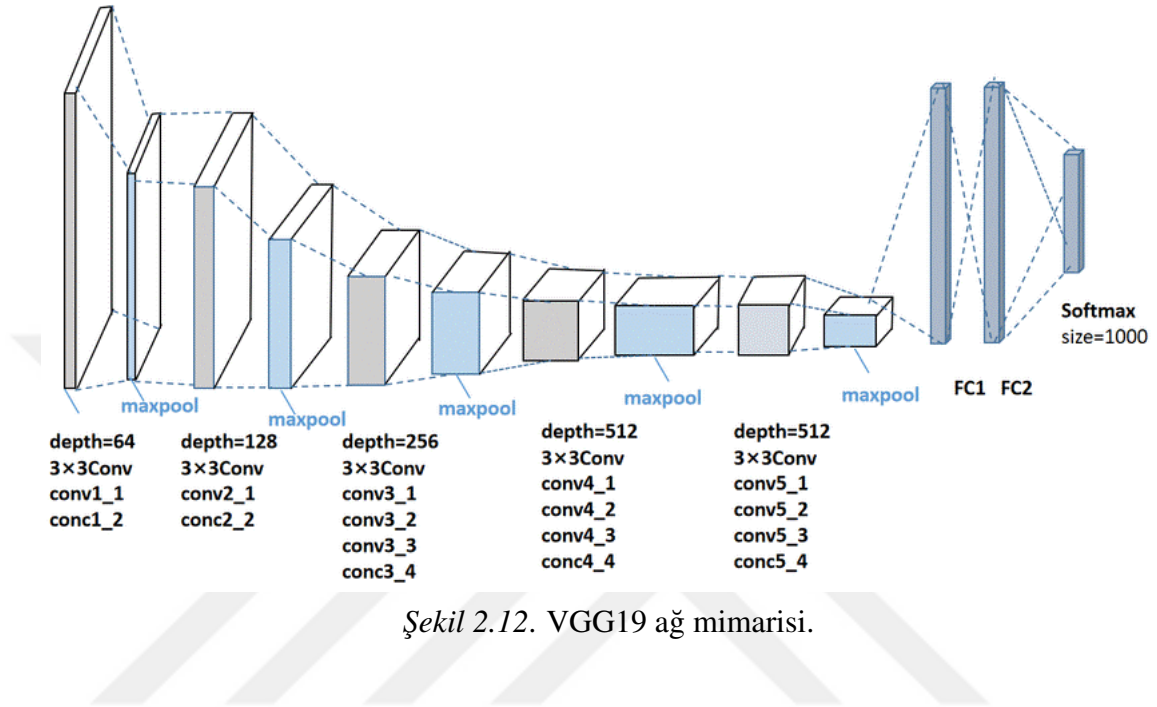
2.2.6. Ön Eğitilmiş Önerilen Derin Öğrenme Modelleri

Derin Öğrenme alanında bu çalışmada kullanılacak olan modeller incelenmektedir.

2.2.6.1. Önerilen Metot:1 VGG19 Tabanlı Yöntem

VGG19 (Visual Geometry Group Network), derin öğrenme alanında belirgin bir konumda bulunan ve özellikle görüntü sınıflandırma görevlerinde kullanılan bir modeldir. 19 katmanlı evrişimli sinir ağı, görsel veri setlerindeki karmaşıklığı ele alabilme yeteneğiyle öne çıkmaktadır. Küçük çekirdek boyutları ve derinlikleriyle tasarlanmış mimarisi, geniş bir ölçekte bilgi temsil etme yeteneği sunmakta ve çeşitli görsel veri setlerinde yüksek doğruluk oranları elde etme yeteneğini artırmaktadır. Özellikle öznetelik çıkarma konusunda etkileyici sonuçlar veren VGG19, önceden eğitilmiş ağı kullanarak görsel hiyerarşiyi öğrenmekte ve bu özellikleri transfer öğrenme uygulamalarında başka görevlere de kolaylıkla uyum sağlamaktadır. VGG19, görüntü özelliklerini çıkarmak için 3×3 evrişim çekirdeği serisi ve özellik kanallarının sayısını genişletir [42]. Bu, özellikle sınırlı veri setleriyle çalışan görevlerde modelin güvenilirliğini artırmaktadır. Görüntü sınıflandırma yetenekleri açısından, VGG19'un katmanlarının derinliği, nesnelere doğru bir şekilde tanıma ve sınıflandırmada üstün bir doğruluk elde etme yeteneğini birlikte getirmektedir. Bu özellikleri, modelin çeşitli uygulama alanlarında başarıyla kullanılmasını destekler, özellikle karmaşık görsel veri setleriyle karşılaşılan zorlukları aşma potansiyeline sahiptir.

Bu nedenle, VGG19, öznetelik çıkarma, transfer öğrenme ve görüntü sınıflandırma alanlarında iyi sonuçlar elde edilebilen önemli bir derin öğrenme modelidir. Şekil 2.12 ile Vgg19 ağ mimarisine ait bir görsel sunulmuştur [43].




Şekil 2.12. VGG19 ağ mimarisini.

2.2.6.2. Önerilen Metot:2 ResNet50 Tabanlı Yöntem

ResNet-50, derin öğrenme alanında önemli bir konumda bulunan ve özellikle görüntü sınıflandırma görevlerinde başarı elde eden bir modeldir. ResNet-50'nin öne çıkan özelliği, aşırı derin sinir ağlarının eğitiminde ortaya çıkan "degradasyon" sorununu çözen yenilikçi bir bağlantı yapısına sahip olmasıdır. Ağ, her bir katmandan geçen bilgilerin doğrudan önceki katmanlara bağlanmasını sağlayan "residual block" yapısını içermektedir [44]. Bu özellik, ağın daha derin ve öğrenmeye uygun olmasını sağlamaktadır. ResNet-50'nin mimarisi, 50 katmandan oluşan ve derin öğrenme modellerinin karmaşıklığına başarılı bir şekilde karşı koyabilen bir yapıya sahiptir. Küçük çekirdek boyutları ve artan derinlik, çeşitli ölçeklerde bilgi temsil etme yeteneğini artırmaktadır. Bu özellik, farklı boyuttaki nesnelere tanıma ve sınıflandırmada etkili olmayı sağlamaktadır. Özellikle öznetelik çıkarma ve transfer öğrenme uygulamalarında ResNet-50'nin etkili olduğu gözlemlenmiştir. Önceden eğitilmiş ağın öğrendiği özelliklerin başka görevlere transfer edilmesi, modelin genel kullanılabilirliğini artırmaktadır.


Model, sınırlı veri setleriyle çalışan görevlerde modelin performansını iyileştirmeye yol açmaktadır. ResNet-50, görüntü sınıflandırma, öznetelik çıkarma ve transfer öğrenme alanlarında üstün performans sergileyen önemli bir derin öğrenme modelidir. Bağlantı yapısındaki inovasyonlar, ağına daha derin ve daha etkili öğrenmeye olanak tanıyan bir yapıya sahip olmasını sağlamakta, bu da çeşitli görevlerde güvenilir bir performans elde etmesini sağlamaktadır. Şekil 2.13 ile ResNet50 mimarisine ait bir görsel sunulmuştur [45].



Şekil 2.13. ResNet50 mimarisi.

2.2.6.3. Önerilen Metot:3 YOLOv8 Tabanlı Yöntem


YOLOv8, derin öğrenme alanında öne çıkan bir nesne tespiti modelidir ve özellikle gerçek zamanlı uygulamalarda etkili performans gösterme kapasitesi ile bilinmektedir. Bu model, "You Only Look Once" (YOLO) ailesinin bir üyesidir ve nesne tespiti başarılarıyla dikkat çekmektedir. Görüntü analizi alanında, 2D görüntüleri frekans alanına dönüştürmek için iki boyutlu (2D) Fourier analizi kullanılır [46]. YOLOv8'in temel özelliği, tek bir geçişte tüm görüntüyü analiz ederek nesne tespiti gerçekleştirmesidir. Bu özelliği, hızlı çalışma yeteneğiyle gerçek zamanlı uygulamalarda kullanılabilirliğini artırmaktadır. Ayrıca, model değişken boyutlu girişlere uyum sağlamakta, bu da farklı çözünürlükteki görüntülerle başa çıkmasını sağlamaktadır. YOLOv8, yüksek doğruluk oranları elde etme yeteneği ile geniş ve çeşitli veri setlerinde üstün performans göstermektedir. Derin evrişimli sinir ağı (CNN) tabanlı mimarisi, karmaşık nesnelere ve senaryoları başarılı bir şekilde tanımlayabilmektedir. Model, modüler bir mimariye sahiptir, Şekil 2.14 ile YOLOv8 ağı mimarisini anlatan görsel verilmiştir [47].



Şekil 2.14. YOLOv8 ağ mimarisi.

2.2.6.4. Önerilen Metot:4 Hiperparametre Optimizasyonu Destekli YOLOv8(GA-YOLOv8) Tabanlı Yöntem

Hiperparametre ayarı makine öğrenimi modelinin performansını optimize etmek amacıyla gerçekleştirilen bir süreçtir [48]. Ultralytics YOLO kapsamında, bu hiperparametreler öğrenme hızı, kullanılan katman sayısı, aktivasyon fonksiyonu türleri gibi mimari detaylardan doğruluk, kesinlik ve geri çağırma gibi performans ölçümlerini etkileyen çeşitli faktörlere kadar geniş bir yelpazede değiştirilmektedir. Modelin genel performansını artırmak ve belirli bir görevde en etkili hale getirmek için hiperparametre değerlerini ayarlamayı içermektedir. Learning Rate (Öğrenme Oranı), Batch Size (Görüntü Büyüklüğü), Number of Epochs (İterasyon), Architecture Specifics (Mimari Özellikleri) gibi bazı hiperparametreler yapısal ayarlardır. Şekil 2.15 ile örnek bir hiperparametre ayarlama görseli sunulmuştur [49].



Şekil 2.15. Hiperparametre ayarlama.

Hiperparametreleri optimize etmek için genetik algoritma kullanılmaktadır. Genetik algoritmalar, evrimsel prensipleri kullanarak popülasyon içindeki bireylerin genetik materyallerini çeşitlendirme, çaprazlama ve mutasyon gibi genetik operatörlerle yeni çözümler üretmeyi amaçlamaktadır. Biyolojik evrim süreçlerini taklit ederek, çeşitlilik ve uygunluk ilkesini algoritmik bir bağlamda uygulayarak, hiperparametre optimizasyonunda etkili sonuçlar elde etmeyi hedeflemektedir. Ultralytics YOLO kapsamında mutasyon, küçük rastgele değişiklikler uygulanarak hiperparametre uzayının aranmasını sağlamaktadır.

Çaprazlama algoritma tekniđi en çok kullanılan tekniklerden birisi olmasına rağmen Yolo da kullanılmamaktadır. Hiperparametreleri oluşturmak için mutasyon asıl olarak kabul edilmektedir. Hiperparametre ayarlarına başlamadan önce modelin performans değerlerini belirlemek f1 skoru oranı gibi değerler ayarlanmalıdır. Modelin fonksiyon yöntemi ile YOLOv8'nin hiperparametrelerini ayarlamak için kullanılan bir Tuner sınıfını tanımlamak üzere optimize edici olarak AdamW'yi kullanmaktadır. Bu süreç, COCO8 veri kümesi üzerinde 30 epok boyunca gerçekleştirilmektedir. Bu ayarlamalar, YOLOv8 modelinin COCO8 veri kümesi üzerinde daha iyi bir performans elde edilmesi için tasarlanmıştır. İlgili adımlardan bahsetmek gerekirse; varsayılan ayarlardan farklı olarak öncelikle hiperparametre kümesi üretilir. Eğitim değiştirilmiş hiperparemetre ayarları ile gerçekleştirilir. Modelin performansı AP50, F1-skoru gibi metrikler ile değerlendirilir. Belirlenen iterasyondaki en iyi performans değerine ulaşılanaya kadar tekrarlanır. İşlemler sonucunda birkaç dosya dizini elde edilmektedir. Oluşan bu dosyalardan YAML dosyası değerleri ayarlama en iyi performans gösteren hiperparametre değerlerini göstermektedir. En iyi uygunluk görseli ise genetik algoritmanın iterasyon süresinde ne kadar iyi performans gösterdiğinin sonucudur. İterasyonun ayrıntılı sonucunu içeren ve hiperparametreleri de içeren yineleme başına kullanılan sonuç .csv formatında kaydedilir. Dağılım grafikleri görsel çıktısı ise hiperparametreler ve performans metrikleri arasında ilişkileri göstermektedir. Sonuç olarak en iyi elde edilen sonuç kaydedilmektedir. Böylece hiperparametre ayarlama süresince mutasyona odaklanan genetik taban Ultralytics YOLO adresindeki hiperparametre ayarlama süreci, mutasyona odaklanan genetik algoritma tabanlı yaklaşımı sayesinde basitleştirilmiş ancak güçlüdür.

2.3. Deneysel Kurulum

2.3.1. Donanım Altyapısı

İHA'lar, orman yangını tespitinde kritik bir rol oynamaktadır. Hızlı ve etkili gözetim kabiliyetleri, zorlu koşullarda çalışma adaptasyonu, sürekli izleme olanağı ve yüksek çözünürlükte görüntüleme kapasitesi, bu teknolojinin orman yangınlarıyla mücadeledeki etkinliğini artırmaktadır. İHA'larla elde edilen verilerin gerçek zamanlı iletilmesi, hızlı müdahale imkanı sağlamaktadır. Yüksek çözünürlük, mobilite ve esneklik, çeşitli sensörlerle entegrasyon ve maliyet etkinliği gibi avantajlar, bu teknolojinin orman yangınlarına karşı kullanımına yönlendirmektedir. Orman yangını tespit sistemi için veri toplamada ve orman yangını tespiti canlı izleme sistemi için kullanılan Drone Modeli Autel Robotics Evo II Pro V3 dür. Şekil 2.16 ile drone modeline ait bir görsel sunulmuştur [50].



Şekil 2.16. EvoII pro v3.

Autel Robotics Evo II Pro V3 kamerası, 1 inç CMOS görüntü sensörüyle donatılmış olup geniş dinamik aralığı, etkili gürültü bastırma ve 6K çözünürlükte video kaydı yapma yeteneği sunmaktadır. Değişken diyafram ayarları (f/2.8-f/11) ve yüksek maksimum ISO değeri sağlamaktadır. EVO II Pro V3, Moonlight Algorithm 2.0 ile gece fotoğrafçılığında üst düzey performans sergilemektedir. 4K HDR video kaydı, netlik, renk ve detayları mükemmel bir şekilde birleştirmektedir. Ayrıca, 12-Bit DNG ile fotoğrafları çekme avantajı sunmaktadır.

Hiper Atlamalı fotoğrafçılık özelliği sayesinde 6K video kaydı hızlı bir şekilde dışa aktarılabilir ve kullanıcılara daha fazla esneklik sunmaktadır. SkyLink 2.0 Video İletimi teknolojisi, 9 mil mesafeye kadar HD video aktarımı yapabilme yeteneği ile kullanılabilirliği öne çıkmaktadır. QHD ekran çözünürlüğü ve üç bantlı iletişim desteği, 360° Engelden Kaçınma özelliği, 12 görsel sensör, ana kamera, ultrason, IMU'lar ve diğer sensörlerin entegrasyonu ile birlikte gerçek zamanlı üç boyutlu haritaların ve yol planlamasının oluşturulmasını sağlamaktadır. Bu sayede drone, çevresindeki engelleri güvenli bir şekilde algılamaktadır. Şekil 2.17 ile veri aktarım cihazına ait bir görsel sunulmuştur [50].



Şekil 2.17. Veri aktarım istasyonu.

Veri aktarım istasyonu olarak tercih edilen LiveDeck2, Autel Robotics EVO II drone serisiyle uyumlu bir canlı yayın ünitesidir. Bu özellikli aparat, EVO II dronunun görüntüsünü HDMI, ethernet veya USB aracılığıyla istenilen kaynağa aktarabilme kabiliyetine sahiptir. LiveDeck, 1080P 60FPS çözünürlüğünde Full HD video aktarımı yapabilir ve 4 saatlik uzun pil ömrü ile uzun süreli kullanım imkanı sunmaktadır. Güçlü iletim gücü ve genişletilmiş anten bağlantısı, 7 km'ye kadar uzaklıkta güvenilir video iletimini desteklemektedir. EVO drone modelleri ile entegre edilebilen LiveDeck, 2,4 GHz iletim gücüyle 7 km'ye kadar video iletimi sağlamaktadır. Uzaktan kumandayla eşzamanlı çalışabilir ve HDMI aracılığıyla Full HD video çıkışı ile büyük ekranlarda, televizyonlarda ve izleme cihazlarında yüksek kaliteli görüntüleme deneyimi sunmaktadır. Ayrıca, 60 Hz'de 1080p görüntü girişi ve çıkışını desteklemektedir.

2.3.2. Yazılım Altyapısı

Derin öğrenme eğitimleri aşağıdaki donanım özelliklerine sahip bir bilgisayar üzerinde gerçekleştirilmiştir.

- CPU (Intel Xeon 2.20GHz)
- 16 GB RAM
- "cu121" CUDA Toolkit sürüm 12.1'

Eğitimler gerçekleştirildikten sonra ise model yüklenip visual studio üzerinde bir form aracılığıyla video formatında gerçek sisteme yakın denemeler yapılmıştır. Bu denemelerin gerçekleştirildiği sistem aşağıdaki özellikler bulunan bilgisayarda gerçekleştirilmiştir.

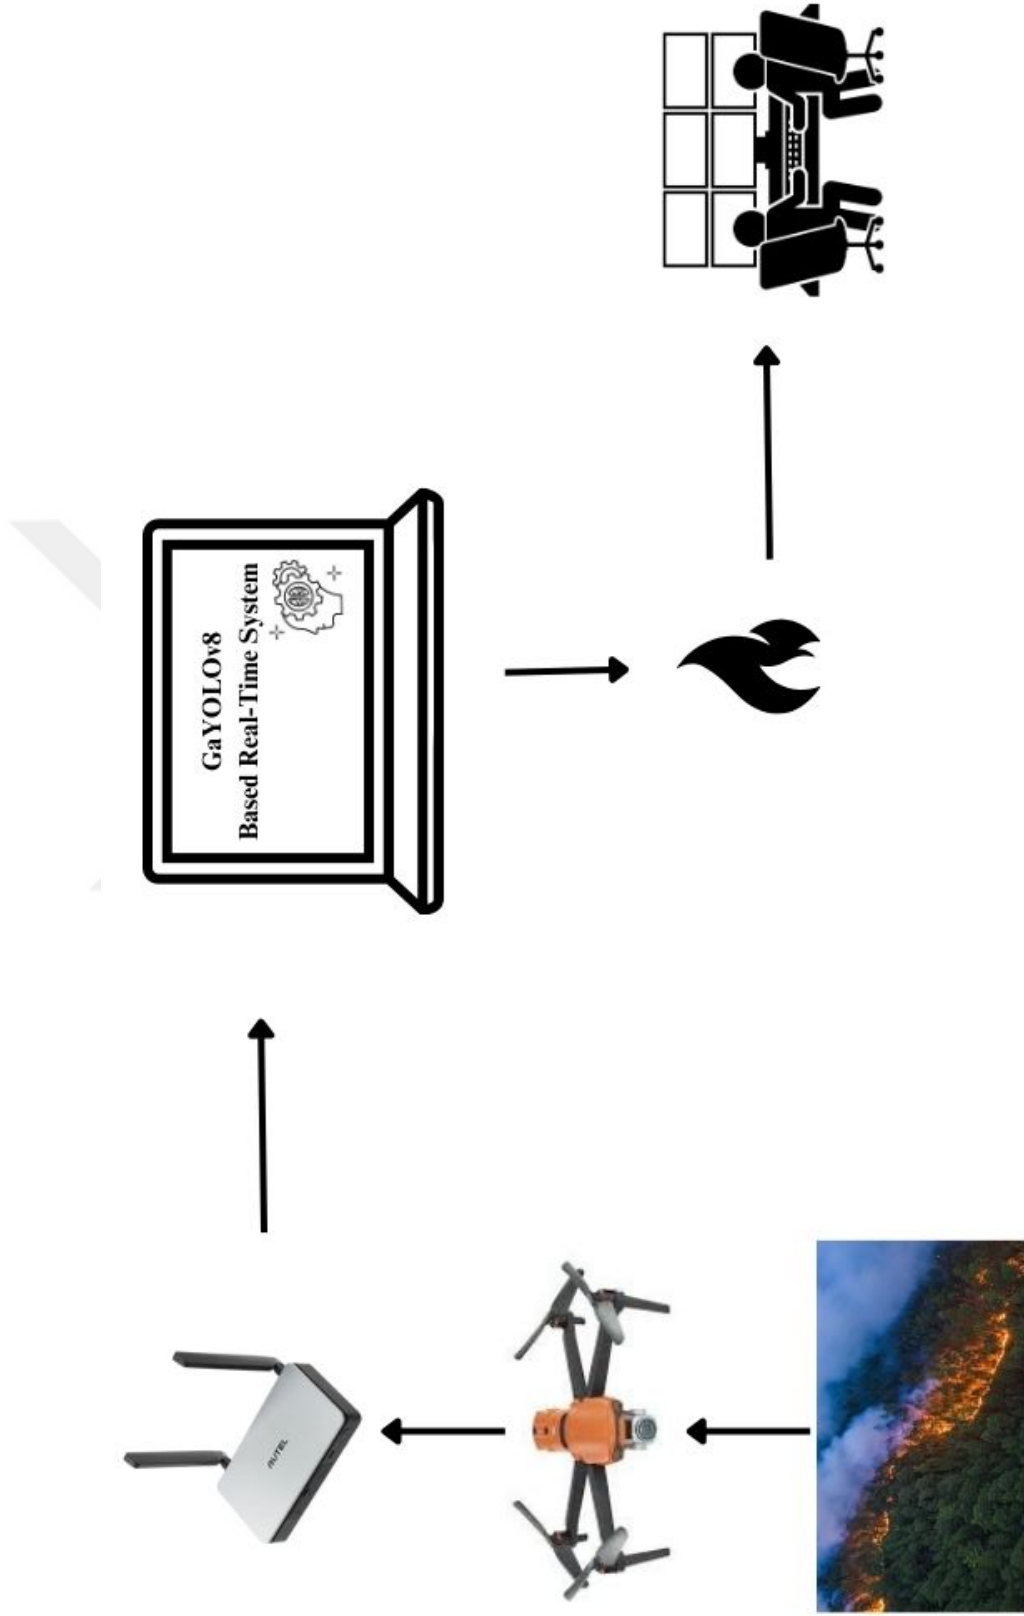
- Intel(R) Core(TM) i5-3210m @ 2.50GHz (4 CPU's), 2.4GHz
- 8 GB RAM
- GeForce GT 635M 6GB

2.4. Gerçek Zamanlı Orman Yangını Tespit Sisteminin Oluşturulması

Bu çalışmada, EVO II Pro V3 drone modelinin entegre kamerasını kullanarak elde edilen İHA görüntüleri üzerinde derin öğrenme yöntemlerini kullanılarak gerçek zamanlı yangın tespiti sistemini geliştirme hedeflenmektedir. İHA tarafından toplanan verileri analiz ederek yangın tespiti konusunda etkili bir çözüm sunmayı amaçlamaktadır. Bu bağlamda, derin öğrenme algoritmaları kullanılarak elde edilen görüntü verileri, önceden belirlenmiş yangın özellikleri ve desenleri açısından incelenecek ve tez konusu olan gerçek zamanlı yangın tespiti sistemi oluşturulacaktır. Geliştirilen sistem, İHA teknolojisinin yangın tespiti alanında nasıl etkili bir şekilde kullanılabileceğini göstererek, acil durumlarda hızlı ve doğru müdahalelerin gerçekleştirilmesine katkı sağlamayı amaçlamaktadır.

EVO II Pro V3 otonom uçarak kamera entegresinden alınan görüntüleri LiveDeck2 canlı yayın ünitesi üzerinden anasunucuya aktarılmaktadır. Anasunucu da kurulu olan öğrenilmiş model ile arayüzde tespit edilebilir canlı izleme sistemi oluşturulacaktır. Bu yapıdaki sistem şematiği aşağıdaki gibi verilmiştir.





Şekil 2.18. Önerilen orman yangını canlı sistem modeli.

2.5. Değerlendirme Metriği: Confusion Matrix ve Doğruluk Oranı

Makine öğrenmesi modellerinin performansını değerlendirmek için confusion matrix (karışıklık matrisi) sıklıkla kullanılmaktadır. Bu matris, modelin gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi görselleştirir ve performansı değerlendirmek için TP (true positive), FP (false positive), TN (true negative) ve FN (false negative) gibi değerleri içermektedir. Makine öğrenmesi ve istatistiksel sınıflandırma problemlerinde, bir sınıflandırıcının performansını görselleştirmek için geliştirilen bir tablo düzenidir [51,52].

True Positive (TP): Gerçek pozitif örneklerin sayısı, yani modelin doğru şekilde pozitif olarak tahmin ettiği örneklerdir. Orman yangını tespitinde, bu modelin yangın olduğunu doğru bir şekilde tespit ettiği örnekler olmaktadır.

False Positive (FP): Gerçekte negatif olan ancak modelin pozitif olarak yanlış şekilde tahmin ettiği örneklerdir. Yangın olmayan ancak modelin yanlışlıkla yangın olduğunu tahmin ettiği örnekler bu kategoriye girmektedir.

True Negative (TN): Gerçek negatif örneklerin sayısı, yani modelin doğru şekilde negatif olarak tahmin ettiği örneklerdir. Yangın olmayan ve modelin doğru bir şekilde yangın olmadığını tespit ettiği örnekler bu kategoriye girmektedir.

False Negative (FN): Gerçekte pozitif olan ancak modelin negatif olarak yanlış şekilde tahmin ettiği örneklerdir. Yangın olan ancak modelin yanlışlıkla yangın olmadığını tahmin ettiği örnekler bu kategoriye girmektedir.

Tablo 2.1. İkili sınıflandırma confusion matrix

	Gerçek Pozitif (Yangın)	Gerçek Negatif (Yangın Değil)
Tahmin Pozitif (Yangın)	TP	FP
Tahmin Negatif (Yangın Değil)	FN	TN

Doğruluk oranı, doğru tahmin edilen örneklerin toplam örnek sayısına oranıdır. Formülü şu şekildedir:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Örneğin, orman yangını tespiti için bir modelin confusion matrix'i tablo 2.2 gibi olabilir:

Tablo 2.2. Örnek yangın tahmin tablosu

	Gerçek Yangın	Gerçek Yangın Değil
Tahmin Yangın	100	20
Tahmin Yangın Değil	10	1000

Bu matriste, modelin 100 yangını doğru şekilde tahmin ettiği, 1000 yangın olmayan örneği doğru şekilde tahmin ettiği, 10 yangını yanlış şekilde tahmin ettiği ve 20 yangın olmayan örneği yanlış şekilde tahmin ettiği görülmektedir. Bu durumda, modelin doğruluk oranı şu şekilde hesaplanır:

$$\text{Accuracy} = \frac{100 + 1000}{100 + 1000 + 10 + 20} = 0.97 \quad (2)$$

Bu şekilde, confusion matrix ve doğruluk oranı kullanılarak modelin performansı objektif bir şekilde değerlendirilebilmektedir.

Kesinlik, pozitif olarak doğru tahmin edilen bir durumun başarısını göstermektedir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3)$$

Duyarlılık, pozitif durumların ne kadar başarılı bir şekilde tahmin edildiğini göstermektedir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4)$$

F1 Skoru, doğruluk gibi bir değerlendirme ölçütü olarak kullanılabilir. Kesinlik ve duyarlılık değerlerinin harmonik ortalaması alınarak bulunmaktadır.

$$F1 = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

3. BÖLÜM

DENEYSEL SONUÇLAR


Tez çalışmasında orman yangını görüntülerinden tespit yapılması amacıyla CNN modellerinde ResNet50, VGG19, YOLOv8 ve genetik algoritma ile optimize edilmiş YOLOv8 modelleri kullanılmıştır. Bu çalışmada, orman yangınlarını tespit etmek amacıyla sınıflandırma (classification) tekniğini kullanmıştır. Bu teknik, görüntü verilerini analiz ederek orman yangını içeren görüntüleri ve yangın içermeyen görüntüleri ayrı kategorilere sınıflandırmak üzere uygulanmıştır. Modellerin test aşamasında orman yangını tespiti için yeni bir veri seti ERUFORESTFIRE ve açık erişimli olan FIRE Dataset üzerinde de deneysel çalışmalar yapılarak kıyaslama işlemi yapılmıştır.

3.1. Fire Dataset Üzerinde Önerilen Yöntemler ile Elde Edilen Sonuçlar

İkinci bölümde, Fire dataset hakkında detaylı bilgi sunulmuştur. Veri kümesi, yangın içeren görüntülerin yanı sıra doğa görüntülerini içermektedir. Toplamda, 755 yangın içeren görüntü ve 244 doğa görüntüsü bulunmaktadır. Bu veri seti üzerinde yürütülen çalışmada, önerilen yöntemlerin performansı detaylı bir şekilde incelenmiştir.

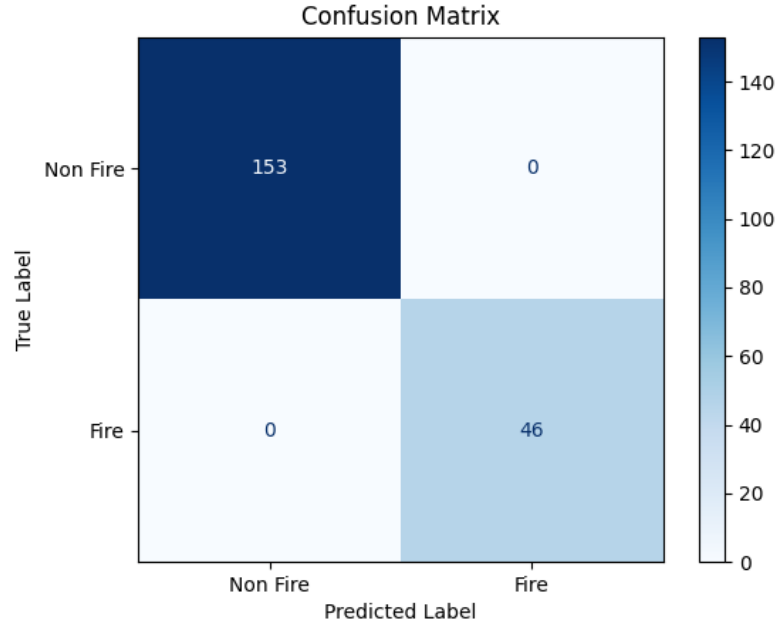
3.1.1. Önerilen Metot:1 ile Elde Edilen Sonuçlar

İlk adımda, Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri iki ayrı kategoriye sınıflandırılmıştır. Ardından, sınıflandırma modeli eğitimi için TensorFlow ve Keras kütüphanelerini VGG19 mimarisi üzerine inşa edilmiştir. Veri setinin bulunduğu dizin yolu path değişkenine atanmıştır. Eğitim sırasında kullanılacak mini-batch boyutu belirlenmiştir. 32 örneklilik mini-batch'ler kullanılmıştır. Veri setindeki görüntülerin boyutları, 224×224 piksel olarak kullanılmıştır. Veri setinin %20'si test seti için kullanılmıştır. Veri kümesi üzerinde 20 epoch (iterasyon) boyunca eğitilmiştir. Ayrıca, ModelCheckpoint ve EarlyStopping geri çağrılarını, eğitim sırasında modelin durumunu kontrol etmek ve en iyi performans gösteren modeli kaydetmek için kullanılmıştır. VGG19 mimarisini önceden eğitilmiş ağırlıkları transfer öğrenme için kullanarak, üzerine eklenen katmanlarla özelleştirilmiş bir sınıflandırma modeli oluşturulmuştur. Elde edilen test kaybı (loss) ve doğruluk (accuracy) değerleri, modelin genel başarısını ölçen önemli metriklerdir. Eğitim (Train) ve doğrulama (validation) doğruluğu metrik değerleri Şekil 3.1 sunulmuştur.



Şekil 3.1. VGG19 eğitim ve doğrulamanın kayıp ve doğruluk değerleri.

Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin değerlendirme metriği olan gerçek ve tahmin etiketleri Şekil 3.2 ile sunulmuştur.




Şekil 3.2. FIRE dataset için VGG19 tabanlı modelin karışıklık matrisi.

Orman yangını olan 46 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 153 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan ve orman yangını olan görsellerde yanlış tahmin yapmadığı görülmüştür. Değerlendirmelerde doğruluk, kesinlik, duyarlılık ve F1 skoru olarak %100'lük bir başarı elde edilmiştir.

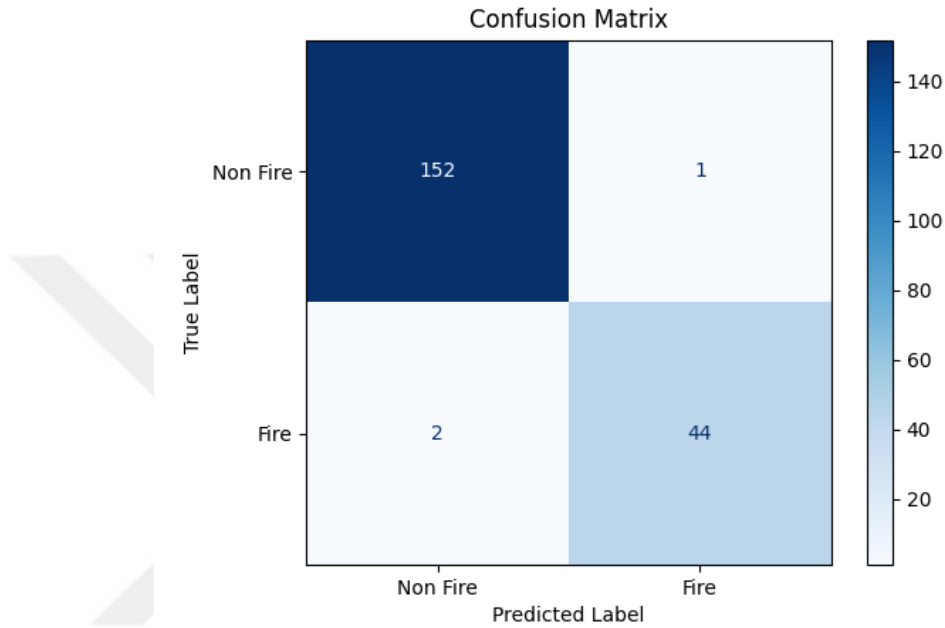
3.1.2. Önerilen Metot:2 ile Elde Edilen Sonuçlar

Veri seti, Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri iki ayrı kategoriye sınıflandırmak için başlangıç adımı olarak atılmıştır. Bu sınıflandırma modeli eğitimi için TensorFlow ve Keras kütüphaneleri kullanılmıştır. Veri setinden TensorFlow'un "image dataset from directory" fonksiyonunu kullanarak eğitim (train) ve doğrulama (validation) veri setlerini oluşturan bir dizi işlem gerçekleştirilmiştir. Bu işlemde, veri setinin bulunduğu dizini belirten "path" değişkeni kullanılarak eğitim ve doğrulama veri setlerini oluşturacak olan dizin yolu tanımlanmıştır. Her bir eğitim ve doğrulama veri setindeki mini grup (batch) boyutunu belirten "batch size" değişkeni 32 olarak ayarlanmıştır. Bu değişken, bir seferde işlenen görüntü sayısını ifade etmektedir. Görüntülerin hedef boyutunu belirten "target size" değişkeni (224, 224) olarak ayarlanmıştır. Bu boyut, ResNet50 modelinin eğitimi sırasında kullanılan uygun boyuttur. Veri setinin ne kadarının doğrulama seti olarak kullanılacağını belirten "validation split" değişkeni, veri setinin %20'sini test seti olarak ayrılacak şekilde ayarlanmıştır. Toplam eğitim epoch sayısı "epochs=20" parametresi ile belirlenmiştir. Modelin eğitimi sırasında en iyi performans gösteren ağırlıkları kaydederek, aşırı öğrenmeyi önleyen ve eğitimi belirli bir durumda durduran dizin işlemi gerçekleştirilmiştir. Elde edilen test kaybı (loss) ve doğruluk (accuracy) değerleri, modelin genel başarısını ölçen önemli metriklerdir. Eğitim (Train) ve doğrulama (validation) doğruluğu metrik değerleri Şekil 3.3 ile sunulmuştur.



Şekil 3.3. ResNet50 eğitim ve doğrulamanın kayıp ve doğruluk değerleri.

Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin değerlendirme metriği olan gerçek ve tahmin etiketleri Şekil 3.4 ile sunulmuştur.



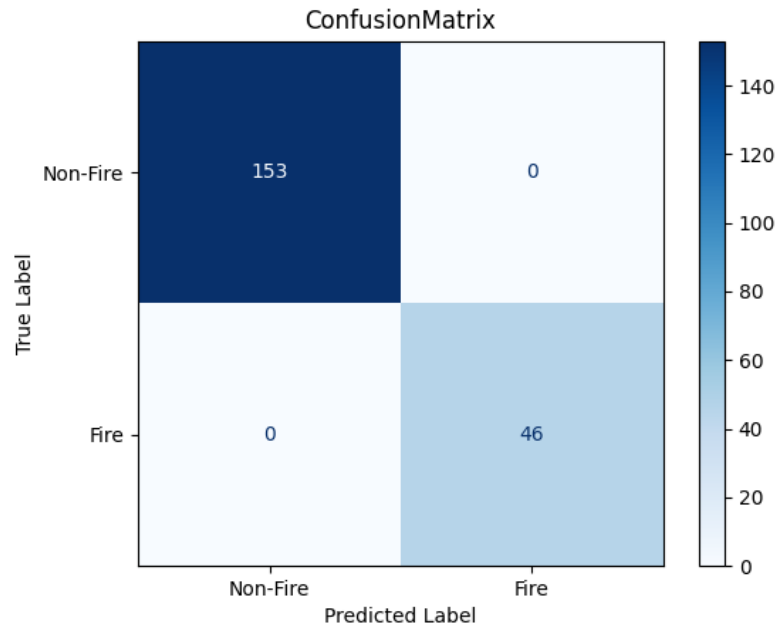
Şekil 3.4. FIRE dataset için ResNet50 tabanlı modelin karışıklık matrisi.

Orman yangını olan 44 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 152 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan bir görüntü, model tarafından yanlış bir şekilde orman yangını olarak tahmin edilmiştir. Orman yangını olan iki görüntü, model tarafından yanlış bir şekilde orman yangını olmayan olarak tahmin edilmiştir. Doğruluk oranında %98.49, kesinlikte %97.78, duyarlılıkta %95.65 ve F1 skorunda yaklaşık %96.70 şeklinde elde edilmiştir.

3.1.3. Önerilen Metot:3 ile Elde Edilen Sonuçlar

Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri sınıflandırmak için YOLOv8 modeli kullanılmıştır. TensorFlow ve Keras kütüphaneleri kullanılarak gerçekleştirilen bu uyarlamada, Ultralytics kütüphanesi aracılığıyla TensorFlow ve PyTorch tanımlaması ile eğitilmiş ve kullanılmıştır.

Veri seti eğitim için %72, doğrulama için %8 ve test için %20 oranında bir bölünme kullanılmıştır. YOLOv8 modeli, 5 epoch süresince eğitilmiştir. Öğrenme hızı (lr0), momentum ve ağırlık azalma oranı (weight decay) gibi hiperparametreler default olarak belirlenmiş, atanmıştır. Eğitim sırasında oluşan en iyi model yüklenmiştir. Resimler karıştırılmış, tek tek test edilmiştir. Modelin tahminlerini gerçek etiketle karşılaştırarak bir çözüm dataframe oluşturulmuştur. Oluşturulan çözümü bir CSV dosyasına kaydedilmiştir. Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin değerlendirme metriği olan gerçek ve tahmin etiketleri Şekil 3.5 ile sunulmuştur.



Şekil 3.5. FIRE Dataset için YOLOv8 tabanlı modelin karışıklık matrisi.


Orman yangını olan 46 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 153 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan ve orman yangını olan görsellerde yanlış tahmin yapmadığı görülmüştür. Değerlendirmelerde doğruluk, kesinlik, duyarlılık ve F1 skoru olarak %100'lük bir başarı elde edilmiştir.

3.1.4. Önerilen Metot:4 ile Elde Edilen Sonuçlar


Veri seti Google Drive'da bulunan veri seti kullanılarak, orman yangını içeren ve içermeyen görüntüleri sınıflandırmak amacıyla YOLOv8 modeli kullanılmıştır. Bu ayarlama, TensorFlow ve Keras kütüphaneleri kullanılarak gerçekleştirilmiş olup, Ultralytics kütüphanesi aracılığıyla TensorFlow ve PyTorch tanımlaması ile eğitilmiş ve kullanılmıştır. Ön eğitimli model yüklenmiştir. Modelin parametrelerinin ayarlanmasında hiperparametreleri optimize etmek için genetik algoritma kullanılmıştır. Veri seti, eğitim için %72, doğrulama için %8 ve test için %20 oranlarında bölünmüştür. YOLOv8 modeli, COCO8 veri kümesi üzerinde hiperparametre ayarlaması için 30 epoch boyunca toplamda 10 iterasyon olacak şekilde, tüm işlemlere sıfırdan başlanarak 5 kez eğitilmiştir. Eğitim sırasında elde edilen en iyi model seçilerek kullanılmıştır. Ardından, resimler tek tek test edilmiş ve modelin tahminleri gerçek etiketlerle karşılaştırılarak bir çözüm dataframe'i oluşturulmuştur. Son olarak, oluşturulan çözüm bir CSV dosyasına kaydedilmiştir. Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin değerlendirme metriği olan gerçek ve tahmin etiketleri Şekil 3.6 ile sunulmuştur.

Orman yangını olan 46 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 153 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan ve orman yangını olan görsellerde yanlış tahmin yapmadığı görülmüştür. Değerlendirmelerde doğruluk, kesinlik, duyarlılık ve F1 skoru olarak %100'lük bir başarı elde edilmiştir. Öğrenme modelinin epok veya iterasyon boyunca modelin en iyi performansını ölçen çizim Şekil 3.7 ile sunulmuştur.

Hiperparametrelerin konfigürasyon edilmesi ve modelin eğitim süresince performansını etkileyen değerler Tablo 3.1 ile sunulmuştur.



Şekil 3.6. FIRE Dataset için GA-YOLOv8 tabanlı modelin karışıklık matrisi.



Şekil 3.7. Performans görselleştirme.

3.2. ERUFORESTFIRE Dataset Üzerinde Önerilen Yöntemler ile Elde Edilen Sonuçlar

İkinci bölümde, bu veri kümesi hakkında kapsamlı bilgi sunulmuştur. Veri kümesi, yangın içeren görüntülerin yanı sıra orman görüntülerini içermektedir. Toplamda, 3.000 yangın içeren görüntü ve 3.000 orman görüntüsü bulunmaktadır.

Tablo 3.1. GA tarafından seçilen hiperparametreler ve değerler.


Hiperparametre	Değerler
lr0	0.01
lrf	0.01
momentum	0.937
weight_decay	0.0005
warmup_epochs	3.0
warmup_momentum	0.8
box	7.5
cls	0.5
df1	1.5
hsv_h	0.015
hsv_s	0.7
hsv_v	0.4
degrees	0.0
translate	0.1
scale	0.5
shear	0.0
perspective	0.0
flipud	0.0
fliplr	0.5
mosaic	1.0
mixup	0.0

Bu sayısal dağılım, önerilen yöntemlerin test edilmesi ve sonuçların değerlendirilmesi için uygun bir zemin oluşturmuştur. Yangın içeren ve içermeyen görüntülerin eşit sayıda olması, yöntemlerin dengeli bir şekilde değerlendirilmesine imkan tanımıştır. ERUFORESTFIRE veri kümesi üzerinde yürütülen çalışmada, önerilen yöntemlerin performansı detaylı bir şekilde incelenmiştir.

3.2.1. Önerilen Metot:1 ile Elde Edilen Sonuçlar


İlk adımda, Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri iki ayrı kategoriye sınıflandırılmıştır. Ardından, sınıflandırma modeli eğitimi için TensorFlow ve Keras kütüphanelerini VGG19 mimarisi üzerine inşa edilmiştir. Veri setinin bulunduğu dizin yolu path değişkenine atanmıştır. Eğitim sırasında kullanılacak mini-batch boyutu belirlenmiştir. 32 örneklilik mini-batch'ler kullanılmıştır. Veri setindeki görüntülerin boyutları, 224×224 piksel olarak kullanılmıştır. Veri setinin %20'si test seti için kullanılmıştır. Veri kümesi üzerinde 20 epoch (iterasyon) boyunca

eđitilmiřtir. Ayrıca, ModelCheckpoint ve EarlyStopping geri çağrılarını, eğitim sırasında modelin durumunu kontrol etmek ve en iyi performans gösteren modeli kaydetmek için kullanılmıřtır. VGG19 mimarisini önceden eğitimliř ađrılıkları transfer öğrenme için kullanarak, üzerine eklenen katmanlarla özelleřtirilmiř bir sınıflandırma modeli oluřturulmuřtur. Elde edilen test kaybı (loss) ve dođruluk (accuracy) deđerleri, modelin genel başarısını ölçen önemli metriklerdir. Eğitim (Train) ve dođrulama (validation) dođruluđu metrik deđerleri řekil 3.8 ile sunulmuřtur.



řekil 3.8. VGG19 eğitim ve dođrulamanın kayıp ve dođruluk deđerleri.

Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar dođru veya yanlış tahmin ettiđini anlamak için kullanılmıřtır. Sonuçlarını göstermek adına Karıřıklık Matrisi (Confusion Matrix) üzerinde bu matrisin deđerlendirme metriđi olan gerçek ve tahmin etiketleri řekil 3.9 ile sunulmuřtur.




Şekil 3.9. ERUFORESTFIRE dataset için VGG19 tabanlı modelin karışıklık matrisi.

Model tarafından orman yangını içeren 600 görüntü doğru bir şekilde tespit edildi. Model tarafından orman yangını olmayan 598 görüntü doğru bir şekilde tespit edildi. Orman yangını olmayan iki görüntü orman yangını olarak sınıflandırılmış ve iki hatalı tahmin vermiştir. Doğruluk oranında %99.83, kesinlikte %99.67, duyarlılıkta %100 ve F1 skorunda yaklaşık %99.83 olarak şeklinde elde edilmiştir.

3.2.2. Önerilen Metot:2 ile Elde Edilen Sonuçlar

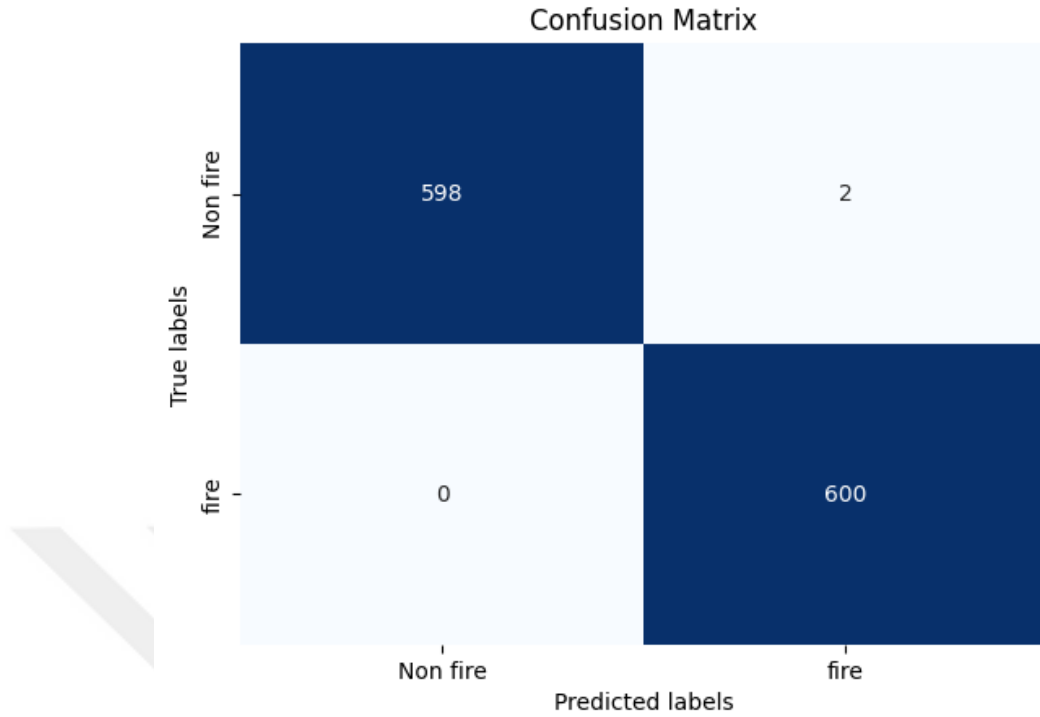
Veri seti, Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri iki ayrı kategoriye sınıflandırmak için başlangıç adımı olarak atılmıştır. Bu sınıflandırma modeli eğitimi için TensorFlow ve Keras kütüphaneleri kullanılmıştır. Veri setinden TensorFlow'un "image dataset from directory" fonksiyonunu kullanarak eğitim (train) ve doğrulama (validation) veri setlerini oluşturan bir dizi işlem gerçekleştirilmiştir. Bu işlemde, veri setinin bulunduğu dizini belirten "path" değişkeni kullanılarak eğitim ve doğrulama veri setlerini oluşturacak olan dizin yolu tanımlanmıştır. Her bir eğitim ve doğrulama veri setindeki mini grup (batch) boyutunu belirten "batch size" değişkeni 32 olarak ayarlanmıştır.

Bu deęişken, bir seferde işlenen görüntü sayısını ifade etmektedir. Görüntülerin hedef boyutunu belirten "target size" deęişkeni (224, 224) olarak ayarlanmıştır. Bu boyut, ResNet50 modelinin eğitimi sırasında kullanılan uygun boyuttur. Veri setinin ne kadarının doğrulama seti olarak kullanılacağını belirten "validation split" deęişkeni, veri setinin %20'sini test seti olarak ayrılacak şekilde ayarlanmıştır. Toplam eğitim epoch sayısı "epochs=20" parametresi ile belirlenmiştir. Modelin eğitimi sırasında en iyi performans gösteren ağırlıkları kaydederek, aşırı öğrenmeyi önleyen ve eğitimi belirli bir durumda durduran dizin işlemi gerçekleştirilmiştir. Elde edilen test kaybı (loss) ve doğruluk (accuracy) deęerleri, modelin genel başarısını ölçen önemli metriklerdir. Eğitim (Train) ve doğrulama (validation) doğruluęu metrik deęerleri Şekil 3.10 ile sunulmuştur.



Şekil 3.10. ResNet50 eğitim ve doğrulamanın kayıp ve doğruluk deęerleri.

Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin deęerlendirme metrięi olan gerçek ve tahmin etiketleri Şekil 3.11 ile sunulmuştur.




Şekil 3.11. ERUFORESTFIRE dataset için ResNet50 tabanlı modelin karışıklık matrisi.

Orman yangını olan 600 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 598 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan iki görüntü, model tarafından yanlış bir şekilde orman yangını olarak tahmin edilmiştir. Orman yangını olan hiçbir görüntüde hata yapmamış 0 olarak tahmin edilmiştir. Doğruluk oranında %99.83, kesinlikte %99.67, duyarlılıkta %100 ve F1 skorunda yaklaşık %99.83 olarak şekilde elde edilmiştir.

3.2.3. Önerilen Metot:3 ile Elde Edilen Sonuçlar

Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri sınıflandırmak için YOLOv8 modeli kullanılmıştır. TensorFlow ve Keras kütüphaneleri kullanılarak gerçekleştirilen bu uyarlamada, Ultralytics kütüphanesi aracılığıyla TensorFlow ve PyTorch tanımlaması ile eğitilmiş ve kullanılmıştır. Veri seti eğitim için %72, doğrulama için %8 ve test için %20 oranında bir bölünme kullanılmıştır. YOLOv8 modeli, 5 epoch süresince eğitilmiştir. Öğrenme hızı (lr0), momentum ve ağırlık azalma oranı (weight decay) gibi hiperparametreler default olarak belirlenmiş, atanmıştır. Eğitim sırasında oluşan en iyi model yüklenmiştir.

Resimler karıştırılmış, tek tek test edilmiştir. Modelin tahminlerini gerçek etiketle karşılaştırarak bir çözüm dataframe oluşturulmuştur. Oluşturulan çözümü bir CSV dosyasına kaydedilmiştir. Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin değerlendirme metriği olan gerçek ve tahmin etiketleri Şekil 3.12 ile sunulmuştur.

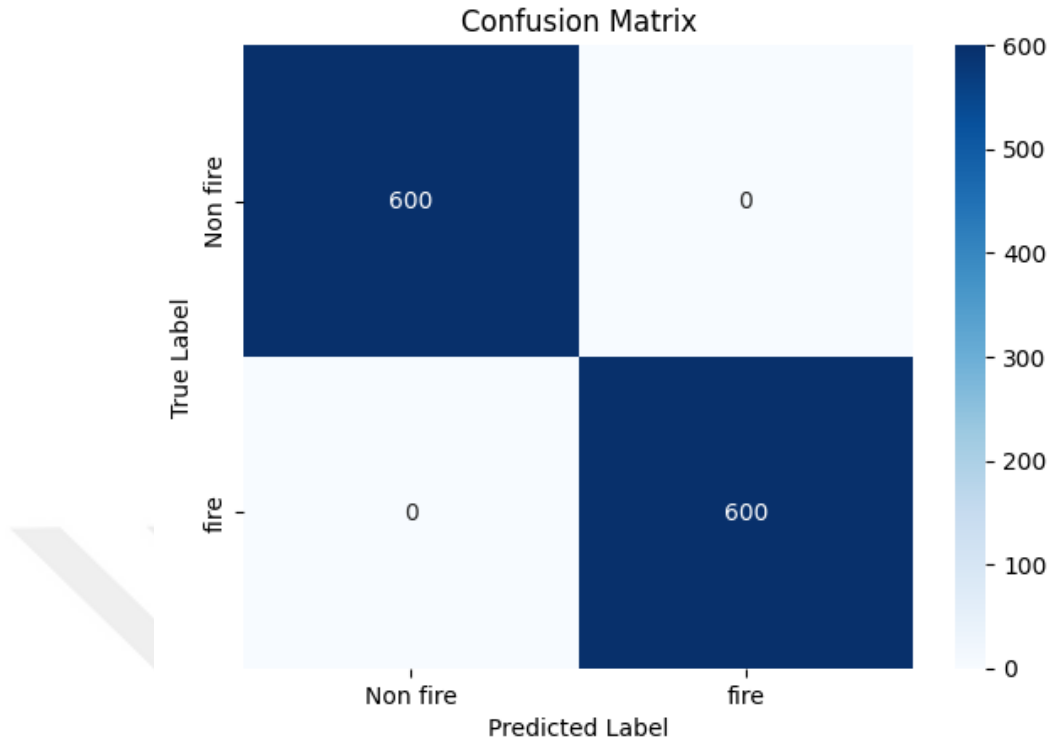


Şekil 3.12. ERUFORESTFIRE dataset için YOLOv8 tabanlı modelin karışıklık matrisi.

Orman yangını olan 599 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 599 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan ve orman yangını olan görsellerde yanlış tahmin yapmadığı görülmüştür. Orman yangını olmayan bir görüntü, model tarafından yanlış bir şekilde orman yangını olarak tahmin edilmiştir. Orman yangını bir görüntü, model tarafından yanlış bir şekilde orman yangını olmayan olarak tahmin edilmiştir. Doğruluk oranında %99.83, kesinlikte %99.83, duyarlılıkta %99.83 ve F1 skorunda yaklaşık %99.83 olarak elde edilmiştir.

3.2.4. Önerilen Metot:4 ile Elde Edilen Sonuçlar


Google Drive üzerindeki veri setini kullanarak orman yangını içeren ve içermeyen görüntüleri sınıflandırmak için YOLOv8 modeli kullanılmıştır. TensorFlow ve Keras kütüphaneleri kullanılarak gerçekleştirilen bu uyarlamada, Ultralytics kütüphanesi aracılığıyla TensorFlow ve PyTorch tanımlaması ile eğitilmiş ve kullanılmıştır. Ön eğitimli model yüklenmiştir. Modelin parametrelerinin ayarlanmasında hiperparametreleri optimize etmek için genetik algoritma kullanılmıştır. Detaylı anlatımı Bölüm2 de gerçekleştirilmiştir. Veri seti eğitim için %72, doğrulama için %8 ve test için %20 oranında bir bölünme kullanılmıştır. YOLOv8 modeli, COCO8 veri kümesi üzerinde hiperparametre ayarlaması için 30 epoch boyunca toplamda 10 iterasyon olacak şekilde, tüm işlemlere sıfırdan başlanarak 5 kez eğitilmiştir. Bu süreç sonunda elde edilen sonuçlar incelenmiştir. Eğitim sırasında oluşan en iyi model yüklenmiştir. Resimler karıştırılmış, tek tek test edilmiştir. Modelin tahminlerini gerçek etiketle karşılaştırarak bir çözüm dataframe oluşturulmuştur. Oluşturulan çözümü bir CSV dosyasına kaydedilmiştir. Test verilerini model üzerinde sonuçlarını görmek için hangi sınıfları ne kadar doğru veya yanlış tahmin ettiğini anlamak için kullanılmıştır. Sonuçlarını göstermek adına Karışıklık Matrisi (Confusion Matrix) üzerinde bu matrisin değerlendirme metriği olan gerçek ve tahmin etiketleri Şekil 3.13 ile sunulmuştur.



Şekil 3.13. ERUFORESTFIRE dataset için GA-YOLOv8 tabanlı modelin karışıklık matrisi.

Orman yangını olan 600 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan 600 görüntü, model tarafından doğru bir şekilde tespit edilmiştir. Orman yangını olmayan ve orman yangını olan görsellerde yanlış tahmin yapmadığı görülmüştür. Değerlendirmelerde doğruluk, kesinlik, duyarlılık ve F1 skoru olarak %100'lük bir başarı elde edilmiştir. Öğrenme modelinin epok veya iterasyon boyunca modelin en iyi performansını ölçen çizim Şekil 3.14 ile sunulmuştur.

En iyi modele ulaşan Hiperparametre sonuç değerleri aşağıdaki 3.2. tabloda sunulmuştur.



Şekil 3.14. Performans görselleştirme.

Tablo 3.2. GA tarafından seçilen hiperparametreler ve değerler.

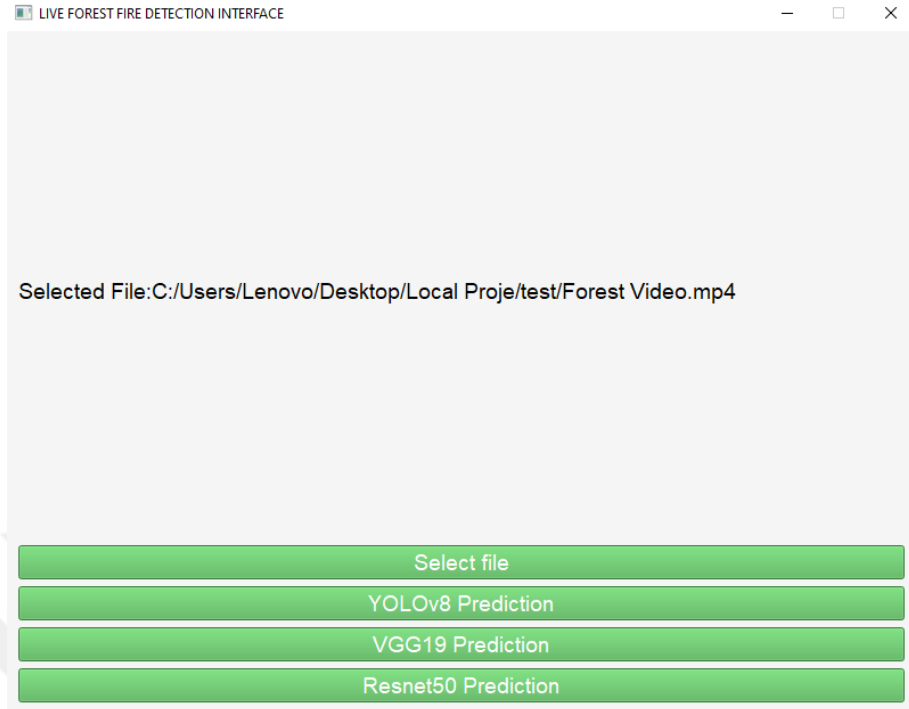
Hiperparametre	Değerler
lr0	0.01
lrf	0.01
momentum	0.87
weight_decay	0.0006
warmup_epochs	3.0
warmup_momentum	0.8
box	6.7
cls	0.6
df1	2.1
hsv_h	0.012
hsv_s	0.8
hsv_v	0.4
degrees	0.0
translate	0.7
scale	0.5
shear	0.0
perspective	0.0
flipud	0.0
fliplr	0.5
mosaic	1.0
mixup	0.0

3.3. Önerilen Modelle Yapılan Gerçek Zamanlı Testler

Bu tez çalışmasında orman yangını tespiti için derin öğrenme tabanlı yöntemler

önerilmiştir. Gerçek zamanlı bir yazılım oluşturulması hedeflenmiştir. Gerçek zamanlı bir yazılımın tepki süresi, uygulamanın türüne ve gereksinimlerine bağlı olarak değişebilmektedir. Ancak, genel olarak bir yazılımın "gerçek zamanlı" olarak kabul edilmesi için, işlemleri kullanıcıya hissedilir bir gecikme olmadan hızlı bir şekilde gerçekleştirmesi beklenmektedir. Orman yangınları için yapay zeka tabanlı tespit sistemlerinde ideal tepki süresi genellikle saniyeler içinde olmalıdır. Bu süre, yangının erken evrelerde tespit edilmesini ve hızlı bir şekilde müdahale edilmesini sağlamaktadır. Orman yangını tespitinin gerçek zamanlı yapılabilmesi için bu tez çalışmasının 2. aşamasında geliştirilen yazılım eşliğinde tepki süreleri videolar ile test edilmiş şekillerde sunulmuştur. Bu yazılım sistemi PyQt5 kütüphanesi kullanılarak oluşturulmuş GUI (Grafiksel Kullanıcı Arayüzü) uygulamasıdır. Program, resim veya video seçilmesine ve seçilen dosya üzerinde dört farklı derin öğrenme modeli ile tahmin yapmasını sağlamaktadır. Bu tahminler görsel olarak ekrana yansıtılmaktadır. Arayüzde bir ana pencere ve tahmin yapma modellerin seçilmesi işlemleri için butonlar oluşturulmuştur. Bu butonlar sayesinde seçilen videoyu seçenekler arasında olan VGG19, ResNet50, YOLOv8 ve GA-YOLOv8 modellerinde kontrol sağlanabilmektedir. Modellerin ağırlıklarından en iyi doğruluk oranı sonucu verdiği ağırlık dosyası üzerinden tespit işlemlerinin gerçekleşeceği şekilde kodlar yazılmıştır. Böylece modellerin performansını karşılaştırması sağlanmış ve canlı sistemde kullanılacak en uygun model belirlenmiştir. Çalışmanın sonuçları aşağıdaki şekiller ile sunulmuştur.


VGG19 modelinin test edilmesi için aynı videolar yüklenmiştir, ortalama tahmin süresi 110 milisaniyedir. Şekil 3.16 ile sunulmuştur.



Şekil 3.15. Yerel video ile model testleri yapılan arayüz görünümü.



a) Yangın tahmin modeli.



b) Yangın olmayan tahmin modeli.

Şekil 3.16. VGG19


ResNet50 modellenin test edilmesi için yüklenen videoda ortalama tahmin süresi 33 milisaniyedir. Şekil 3.17 ile sunulmuştur.

YOLOv8 modelinin test edilmesi için de aynı videolar yüklenmiştir, ortalama tahmin süresi 5 milisaniyedir. Şekil 3.18 ile sunulmuştur.

GA-YOLOv8, genetik algoritma ile optimize edilmiş ve diğer modeller ile aynı test işlemine tabi tutulmuştur. Ortalama tahmin süresi değişmemiştir. Şekil 3.19 ile sunulmuştur.




a) Yangın tahmin modeli.




b) Yangın olmayan tahmin modeli.

Şekil 3.17. ResNet50




a) Yangın tahmin modeli.



b) Yangın olmayan tahmin modeli.

Şekil 3.18. YOLOv8



a) Yangın tahmin modeli.



b) Yangın olmayan tahmin modeli.

Şekil 3.19. GA-YOLOv8

Tablo 3.3. Orman yangını sınıflandırma modellerinin performansı.

Dataset	ResNet50	VGG19	YOLOv8	GA-YOLOv8
FireDataset	98.49	100	100	100
ERUFORESTFIRE	99.83	99.83	99.83	100

Tablo 3.4 incelendiğinde, literatürdeki en bilinen çalışmayı geride bırakarak önerdiğimiz GA-YOLOv8 tabanlı yöntemle %100'e en iyi doğruluk oranı veren çalışmadır.

Tablo 3.4. FIRE veri seti ve doğruluk oranlarına ilişkin karşılaştırma.

Makale Yazarları	Kullanılan Yöntemler	Doğruluk oranı(%)
Aksoy et al. [26]	SqueezeNet	96,0
Hindarto et al. [33]	CNN	96,0
Hindarto et al. [33]	VGG16	98,0
Önerilen Yöntem	GA-YOLOv8	100,0

Yukarıdaki 3.3 tabloda elde edilmiş sonuçlara istinaden YOLOv8' in genetik algoritma destekli hiperparametre optimizasyonlu modeli gerçek sisteme entegre edilmek üzere karar verilmiştir. Canlı izleme sistemi en hızlı ve doğruluk oranı en iyi sonuç veren model kontrol merkezi bilgisayarına kurulmuştur. Drone üzerindeki görüntülerin aktarım modülü ile doğrudan gelip kontrol merkezi ekranında görüntülendiği ve sonuçlarının ekrana yazdırıldığı test işlemi gerçekleştirilmiştir. Bu test işlemi ait görsel Şekil 3.20 ile sunulmuştur.



Şekil 3.20. GA-YOLOv8 modelinin gerçek zamanlı test görüntüsü.

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

4.1. Tartışma-Sonuç ve Öneriler

Bu tez çalışmasında orman yangınlarının erken tespiti ve hızlı müdahale sağlanabilmesi için yapay zeka tekniklerinin etkinliği değerlendirilmiştir. Öncelikle literatürde yapılan geleneksel çalışmalar daha sonra İHA ile yapılan çalışmalar ve son olarak çalışmada karşılaştırma sağlanması için kullanılan açık erişimli veri setinin kullanıldığı çalışmalar incelenmiştir. İkinci faz olarak yeni bir veri seti mevsimsel değişiklikler ve ağaç tipleri farklı olması kaydı ile oluşturulmuştur. Üçüncü fazda ise orman yangını tespitinde kullanılacak önerilen derin öğrenme temelli modeller sınıflandırma metodu ile geliştirilmiş testlere tabi tutulmuştur, bulgular açıkça gösterilmiştir. Önerilen modeller üzerinde doğruluk oranı ve tahmin süresi dikkate alınarak en iyi model kullanılmak üzere seçilmiştir. Model seçiminden sonra hiperparametreleri optimize etmek için genetik algoritma kullanılmıştır. Genetik algoritmalar, evrimsel prensipleri kullanarak çaprazlama ve mutasyon gibi genetik operatörle iyileştirme sağlanmıştır. Oluşturulan model eğitim sonucunda iki farklı verisetinde de %100 doğruluk sonucu elde edilerek başarılı bir sonuç elde edilmiştir. Son fazda, donanımsal ve yazılımsal bileşenlerin bir araya getirilmesi ile gerçek zamanlı orman yangını tespit sistemi oluşturulmuştur. İlerleyen süreçte yapılacak çalışmalarda veri setinin genişletilmesi, daha hassas ve güvenilir bir sistem oluşturulması adına kritik bir öneme sahiptir. Bununla birlikte, otonom drone devriye filosu kullanımıyla birlikte birden fazla orman alanının etkin bir şekilde kontrol edilmesi ve yine ana bir kontrol merkezinden izlenmesi mümkün olacaktır. Bu da orman yangınlarıyla mücadelede daha etkili ve hızlı bir yanıt sağlayarak doğal yaşamın ve insanların güvenliğini artıracaktır.

KAYNAKÇA

1. , 2024. Orman Genel Müdürlüğü Faaliyet Raporu. <https://www.ogm.gov.tr/tr/faaliyet-raporu>.
2. Šiljković, Ž., Mamut, M., 2016. Forest fires in Dalmatia. **Bulletin of Geography. Socio-economic Series**, (32):117–130.
3. Kobak, K., Soğukdere, Ş., 2021. Sosyal medyadaki dezenformasyon: 2021 Türkiye orman yangınları örneği. **Uluslararası Medya ve İletişim Araştırmaları Hakemli Dergisi**, 4(2):167–189.
4. ATMIŞ, E., TOLUNAY, D., ERDÖNMEZ, C. BÖLÜM I-II ORMAN YANGINLARININ SAYISAL ANALİZİ. **ORMAN Y.**
5. Alberts, E.C., 2020. Photos show scale of massive fires tearing through Siberian forests. <https://news.mongabay.com/2020/07/>.
6. Sivrikaya, F., Günlü, A., Küçük, Ö., Ürker, O., 2024. Forest fire risk mapping with Landsat 8 OLI images: Evaluation of the potential use of vegetation indices. **Ecological Informatics**, 102461.
7. Miao, X., Li, J., Mu, Y., He, C., Ma, Y., Chen, J., Wei, W., Gao, D., 2023. Time Series Forest Fire Prediction Based on Improved Transformer. **Forests**, 14(8):1596.
8. Zhou, W., Tang, B.H., He, Z.W., Huang, L., Chen, J., 2024. Identification of forest fire points under clear sky conditions with Himawari-8 satellite data. **International Journal of Remote Sensing**, 45(1):214–234.
9. Anuar, A.I.M., Mohamad, R., Markom, A.M., II, R.C., 2024. Real-time forest fire detection, monitoring, and alert system using Arduino. **Indonesian Journal of Electrical Engineering and Computer Science**, 33(2):942–950.
10. Bharti, T., Saini, M.L., Kumar, A., Tiwari, R., 2024. Design and implementation of industrial fire detection and control system using internet of things, Artificial Intelligence, Blockchain, Computing and Security Volume 1, 310–315, CRC Press.

11. Satheeshkumar, S., Praveenkumar, V., Ragul, P., Naveenkumar, R. FOREST FIRE DETECTION AND PREDICTION USING IOT. .
12. Kang, Y., Jang, E., Im, J., Kwon, C., 2022. A deep learning model using geostationary satellite data for forest fire detection with reduced detection latency. **GIScience & Remote Sensing**, **59**(1):2019–2035.
13. Jiang, Y., Wei, R., Chen, J., Wang, G., 2021. Deep learning of qinling forest fire anomaly detection based on genetic algorithm optimization. **UPB Scientif. Bull., Ser. C: Electr. Eng. Comp. Sci.**, **83**(4):75–84.
14. Gayathri, S., Karthi, P.A., Sunil, S., 2022. Prediction and Detection of Forest Fires based on Deep Learning Approach. **Journal of Pharmaceutical Negative Results**, 429–433.
15. Khan, S., Khan, A., 2022. Ffirenet: Deep learning based forest fire classification and detection in smart cities. **Symmetry**, **14**(10):2155.
16. Mashraqi, A.M., Asiri, Y., Algarni, A.D., Abu-Zinadah, H., 2022. Drone imagery forest fire detection and classification using modified deep learning model. **Thermal Science**, **26**(Spec. issue 1):411–423.
17. Jandhyala, S.S., Jalleada, R.R., Ravuri, D.M., 2023. Forest Fire Classification and Detection in Aerial Images using Inception-V3 and SSD Models, 320–325. *2023 International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, IEEE.
18. Namburu, A., Selvaraj, P., Mohan, S., Ragavanantham, S., Eldin, E.T., 2023. Forest Fire Identification in UAV Imagery Using X-MobileNet. **Electronics**, **12**(3):733.
19. Deng, X., Khan, B., Lim, C.P., Liao, M.Y., 2023. A MobileNetV2-CBAM-based Model for Forest Fire Classification Using UAV Imagery, 141–146. *2023 IEEE 4th International Conference on Pattern Recognition and Machine Learning (PRML)*, IEEE.

20. K Mohammed, R., 2022. A real-time forest fire and smoke detection system using deep learning. **International Journal of Nonlinear Analysis and Applications**, **13**(1):2053–2063.
21. Aral, R.A., Zalluhoglu, C., Akcapinar Sezer, E., 2023. Lightweight and attention-based CNN architecture for wildfire detection using UAV vision data. **International Journal of Remote Sensing**, **44**(18):5768–5787.
22. Aral, R.A., Zalluhoglu, C., Sezer, E.A., 2023. Wildfire Classification Using Infrared Unmanned Aerial Vehicle Data with Convolutional Neural Networks, 1–6. *2023 International Conference on Smart Applications, Communications and Networking (SmartNets)*, IEEE.
23. Nallakaruppan, M., Pillai, S., Bharadwaj, G., Balusamy, B., 2023. Early Detection of Forest Fire using Deep Image Neural Networks, 1–5. *2023 IEEE IAS Global Conference on Emerging Technologies (GlobConET)*, IEEE.
24. Duangsuwan, S., Klubsuwan, K., 2023. Accuracy Assessment of Drone Real-Time Open Burning Imagery Detection for Early Wildfire Surveillance. **Forests**, **14**(9):1852.
25. Saydirasulovich, S.N., Mukhiddinov, M., Djuraev, O., Abdusalomov, A., Cho, Y.I., 2023. An improved wildfire smoke detection based on YOLOv8 and UAV images. **Sensors**, **23**(20):8374.
26. Aksoy, B., Korucu, K., Çalışkan, Ö., Osmanbey, Ş., Halis, H.D., 2021. İnsansız Hava Aracı ile Görüntü İşleme ve Yapay Zekâ Teknikleri Kullanılarak Yangın Tespiti: Örnek Bir Uygulama. **Düzce Üniversitesi Bilim ve Teknoloji Dergisi**, **9**(6):112–122.
27. Wang, Y., 2022. A Novel Fire Detection Method Based on Deep Neural Network and Image Processing, 66–73. *2022 2nd International Conference on Networking Systems of AI (INSAI)*, IEEE.
28. Ghosh, R., Kumar, A., 2022. A hybrid deep learning model by combining convolutional neural network and recurrent neural network to detect forest fire. **Multimedia Tools and Applications**, **81**(27):38643–38660.

29. Batog, F., Moldovanu, S., 2023. The monitoring of burning buildings with convolutional neural network. **SYSTEM THEORY, CONTROL AND COMPUTING JOURNAL**, 3(2):1–8.
30. Wang, Z., Zhao, X., Tao, Y., 2023. Integrated Algorithm Based on Bidirectional Characteristics and Feature Selection for Fire Image Classification. **Electronics**, 12(22):4566.
31. Musaev, J., Anorboev, A., Nguyen, N.T., Hwang, D., 2023. KeepNMax: keep N maximum of epoch-channel ensemble method for deep learning models. **IEEE Access**, 11:9339–9350.
32. Jagatheesaperumal, S.K., Muhammad, K., Saudagar, A.K.J., Rodrigues, J.J., 2023. Automated fire extinguishing system using a deep learning based framework. **Mathematics**, 11(3):608.
33. Hindarto, D., 2024. Comparison Accuracy of CNN and VGG16 in Forest Fire Identification: A Case Study. **Journal of Computer Networks, Architecture and High Performance Computing**, 6(1):137–148.
34. SAIED, A., 2020. FIRE Dataset. <https://www.kaggle.com/datasets/phylake1337>.
35. Roser, M., 2022. The brief history of artificial intelligence: the world has changed fast — what might be next?. **Our World in Data**, <https://ourworldindata.org/brief-history-of-ai>.
36. Ayyadevara, V.K., 2018. Pro machine learning algorithms. **Apress: Berkeley, CA, USA**, 283–297.
37. Oliynyk, D., Mayer, R., Rauber, A., 2023. I know what you trained last summer: A survey on stealing machine learning models and defences. **ACM Computing Surveys**, 55(14s):1–41.
38. ÖLÜÇ, S., 2021. Yapay Sinir Ağı. <https://seda-oluc.medium.com>.
39. Cengil, E., Çınar, A., 2016. A new approach for image classification: convolutional neural network. **European Journal of Technique (EJT)**, 6(2):96–103.

40. Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., Ghayvat, H., 2021. CNN variants for computer vision: History, architecture, application, challenges and future scope. **Electronics**, **10**(20):2470.
41. KOGLAK, 2024. MAKİNE ÖĞRENMESİNDE TEMEL KAVRAMLAR. .
42. Han, B., Du, J., Jia, Y., Zhu, H., 2021. Zero-watermarking algorithm for medical image based on VGG19 deep convolution neural network. **Journal of Healthcare Engineering**, **2021**.
43. Li, H., 2021. Network structure of VGG-19. <https://www.researchgate.net>.
44. Koonce, B., Koonce, B., 2021. ResNet 50. **Convolutional neural networks with swift for tensorflow: image recognition and dataset categorization**, 63–72.
45. Mukherjee, S., 2022. The Annotated ResNet-50. <https://towardsdatascience.com>.
46. Wang, S., Zhu, J., Li, Z., Sun, X., Wang, G., 2024. GDPs-YOLO: an improved YOLOv8s for coal gangue detection. **International Journal of Coal Preparation and Utilization**, 1–14.
47. Terven, J., Córdova-Esparza, D.M., Romero-González, J.A., 2023. A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas. **Machine Learning and Knowledge Extraction**, **5**(4):1680–1716.
48. Karna, N., Putra, M.A.P., Rachmawati, S.M., Abisado, M., Sampedro, G.A., 2023. Towards Accurate Fused Deposition Modeling 3D Printer Fault Detection using Improved YOLOv8 with Hyperparameter Optimization. **IEEE Access**.
49. Jocher, G., Chaurasia, A., Qiu, J., 2023. Ultralytics YOLO Hyperparameter Tuning Guide. .
50. Autel, 2024. Model Autel Robotics Evo II Pro V3. .
51. Han, J., Kamber, M., Pei, J., 2012. Data Mining: Concepts and. **Techniques, Waltham: Morgan Kaufmann Publishers**.
52. Japkowicz, N., Shah, M., 2011. Evaluating learning algorithms: a classification perspective. .

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Musa CESUR

Uyruğu: Türkiye (T.C.)

Doğum Tarihi ve Yeri:

Medeni Durum:

E-posta:

Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Beykent Üniversitesi, Bilgisayar Mühendisliği	2021
Lise	Selçuklu Anadolu Lisesi	2015

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2020 - Halen	Ulaşım A.Ş., Kayseri	Yazılım Mühendisi
2019 - 2020	Fnf Teknoloji San.Tic.A.Ş., Kayseri	Gömülü Yazılım Mühendisi

YABANCI DİL

İngilizce