



**DERİN ÖĞRENME VE MAKİNE ÖĞRENME
ALGORİTMALARI KULLANILARAK
ORMAN YANGINI RİSK TAHMİNİ**

DOKTORA TEZİ

Mustafa Mutlu UYSAL

Danışman

Prof. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

ARALIK 2024

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

DERİN ÖĞRENME VE MAKİNE ÖĞRENME
ALGORİTMALARI KULLANILARAK
ORMAN YANGINI RİSK TAHMİNİ

Mustafa Mutlu UYSAL

Danışman
Prof. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Aralık 2024

TEZ ONAY SAYFASI

Mustafa Mutlu UYSAL tarafından hazırlanan “Derin Öğrenme ve Makine Öğrenme Algoritmaları Kullanılarak Orman Yangını Risk Tahmini” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 05 / 12 / 2024 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Harita Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Murat UYSAL

Başkan : Prof. Dr. Hüseyin Oğuz ÇOBAN
Isparta Uygulamalı Bilimler Üniversitesi,
Orman Fakültesi

..... İmza

Üye : Doç. Dr. Uğur FİDAN
Afyon Kocatepe Üniversitesi,
Mühendislik Fakültesi

..... İmza

Üye : Doç. Dr. Nizar POLAT
Harran Üniversitesi, Mühendislik Fakültesi

..... İmza

Üye : Dr. Öğr. Üyesi Abdullah VARLIK
Necmettin Erbakan Üniversitesi,
Mühendislik Fakültesi

..... İmza

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

05 / 12 / 2024

İmza

Mustafa Mutlu UYSAL

ÖZET

Doktora Tezi

DERİN ÖĞRENME VE MAKİNE ÖĞRENME ALGORİTMALARI KULLANILARAK ORMAN YANGINI RİSK TAHMİNİ

Mustafa Mutlu UYSAL

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Murat UYSAL

Ormanlar, karasal ekosistemlerde canlılar için hayati önem taşıyan unsurlar olup toprak, su ve iklim gibi doğal faktörlerin bütünlüğünü ve sürdürülebilirliğini sağlamaktadır. Orman yangınları, sosyal ve ekonomik etkilerinin yanı sıra ekosistemin bozulmasına da neden olan afetlerdendir. Bu araştırmada orman yangınlarını etkileyen faktörler uzaktan algılama ve coğrafi bilgi sistemleri teknikleriyle antropojenik, meteorolojik, topoğrafik ve vejetasyon üst başlıklarında 21 adet bağımsız değişken olarak belirlenmiştir. Bağımlı değişken olan geçmiş orman yangınları ve bağımsız değişkenler 2017-2023 yılları arasında 7 yıl boyunca Mayıs-Eylül ayları arasında aylık zamansal çözünürlükte sınıflandırılmış ve haritalandırılmıştır. Üretilen haritalardan değer çıkarımı yapılarak 670x22 satır/sütundan oluşan I. veri seti ile 2100x22 satır/sütundan oluşan II. veri seti model eğitimleri için oluşturulup risk tahmini için de 689419x21 satır/sütundan oluşan çalışma alanı coğrafi veri seti haline getirilmiştir. Veri setleri Google Colab ara yüzünde Python yazılım dili kullanılarak keşifsel veri analizi teknikleriyle görselleştirilmiş ve korelasyon analizleri gerçekleştirilmiştir. Model eğitimleri tamamlandıktan sonra tahmin aşamasına geçilmiş ve 7 adet makine öğrenimi algoritmalarından en iyi doğruluk metriklerine ulaşılan Rastgele Orman (0,94) ve Aşırı Gradyan Artırma (0,95) algoritmaları ile orman yangını risk haritaları üretilmiştir. Derin Öğrenme modeli olan Sıralı (sequential) model ile de II. veri seti kullanılarak 0,95 test doğruluğu ile eğitilmiş modelden orman yangını risk tahmin haritası üretilmiştir. Bu çalışmanın sonucunda, orman yangını risk tahmini için kullanılan veri seti boyutlarının, orman yangınları ile ilişkilendirilebilen bağımsız değişkenler ile artırılarak daha doğru ve anlamlı sonuçlara ulaşılabileceği bununla birlikte rastgele orman ve Aşırı Gradyan Artırma gibi topluluk

modellerine dayalı algoritmalar ve daha büyük veri setleri için derin öğrenme tekinlerine dayalı algoritmaların orman yangını risk tahminlerinde daha başarılı olduğu ortaya konmuştur.

2024, xiii + 106 sayfa

Anahtar Kelimeler: Uzaktan Algılama, Yapay Zekâ, Orman Yangını, Makine Öğrenimi, Derin Öğrenme, Risk Haritası.



ABSTRACT

Ph.D. Thesis

FOREST FIRE RISK PREDICTION USING DEEP LEARNING AND MACHINE LEARNING ALGORITHMS

Mustafa Mutlu UYSAL

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Danışman: Prof. Dr. Murat UYSAL

Forests are vital elements for living things in terrestrial ecosystems and ensure the integrity and sustainability of natural factors such as soil, water and climate. Forest fires are one of the disasters that cause ecosystem degradation as well as social and economic impacts. In this study, the factors affecting forest fires were determined as 21 independent variables under the headings of anthropogenic, meteorological, topographical and vegetation using RF and GIS techniques. The dependent variable, past forest fires, and the independent variables were classified and mapped at monthly temporal resolution from May to September for 7 years between 2017 and 2023. By extracting values from the produced maps, the first data set consisting of 670*22 rows*columns and the second data set consisting of 2100*22 rows*columns were created for model training and the study area geospatial data set consisting of 689419*21 rows*columns was created for risk estimation. The data sets were visualized with Exploratory Data Analysis techniques using Python language in the Google Colab interface, and correlation analyses were performed. After the model training was completed, the prediction phase was executed and risk maps were produced with Random Forest (0.94) and XGBoost (0.95) algorithms, which achieved the best accuracy metrics among 7 machine learning algorithms. With the sequential model, which is a Deep Learning model, a risk prediction map was produced from the trained model with a test accuracy of 0.95 using Dataset II. As a result of this study, it was revealed that more accurate and meaningful results can be obtained

by increasing the size of the data set used for forest fire risk prediction with independent variables that can be associated with forest fires, and that algorithms based on ensemble models such as Random Forest and Extreme Gradient Boosting are more successful in forest fire risk prediction.

2024, xiii + 106 pages

Keywords: Remote Sensing, Artificial Intelligence, Forest Fire, Machine Learning, Deep Learning, Risk Mapping.



TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Prof. Dr. Murat UYSAL'a, araştırma ve yazım süresince yardımlarını esirgemeyen Sayın Prof. Dr. Hüseyin Oğuz ÇOBAN'a ve Sayın Doç. Dr. Uğur FİDAN'a her konuda öneri ve eleştirileriyle yardımlarını gördüğüm Sayın Doç. Dr. Nizar POLAT'a ve Sayın Dr. Öğretim Üyesi Abdullah VARLIK'a bu süreçte desteğini esirgemeyen tüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Tez çalışmama katkılarından dolayı Orman Genel Müdürlüğü ve Balıkesir Orman Bölge Müdürlüğü'ne teşekkür ederim

Bu araştırma boyunca sonsuz destekleri ile devamlı yanımda olan ve her anımı kolaylaştırmaya çalışan değerli eşim Dr. Nuriye DEĞİRMENCİ UYSAL'a, varlığıyla hayat veren, motive kaynağım oğlum Uzay Yılmaz UYSAL'a, araştırma süresince fikirleri ve destekleriyle katkı sağlayan ağabeyim Dr. Cihan UYSAL'a ve son olarak sonsuz minnet ve özlemle andığım varlıklarında olduğu gibi hala üzerimde maddi ve manevi desteklerini hissettiğim annem Şehriban UYSAL ve babam Yılmaz UYSAL'a teşekkür ederim.

Mustafa Mutlu UYSAL

Afyonkarahisar, 2024

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ.....	xiii
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	3
2.1 Dünyada ve Ülkemizde Orman Varlığı Durumu.....	3
2.2 Orman Yangınları	4
2.3 Orman Yangınları Risk Tahmini için UA ve CBS	9
2.4 Orman Yangınları Risk Tahmini için Makine Öğrenimi.....	12
2.5 Orman Yangını Risk Tahmini için Derin öğrenme	15
3. MATERYAL ve METOT	18
3.1 Makine Öğrenimi.....	19
3.2 Derin Öğrenme	22
3.3 Çalışma Alanı	25
3.4 I. Veri Seti.....	27
3.4.1 Topoğrafik Veriler	29
3.4.2 Antropjenik Veriler	34
3.4.3 Vejetasyon Verileri	37
3.4.4 Meteorolojik Veriler.....	41
3.4.5 Veri Seti Analizi.....	47
3.5 Makine Öğrenimi ile Risk Tahmini	58
3.5.1 Model Seçimi	58
3.6 II. Veri Seti	65
3.6.1 II. Veri Seti Analizi	68
3.7 Derin Öğrenme ile Risk Tahmini.....	74
3.7.1 Keras Kütüphanesi Sıralı Model Katmanı	75
4. BULGULAR	80

4.1 Risk Tahmini Haritaları	80
4.1.1 Rastgele Orman Algoritması ile Orman Yangını Risk Tahmini.....	80
4.1.2 Aşırı Gradyan Artırma Algoritması ile Orman Yangını Risk Tahmini	82
4.1.3 Sıralı Model Katmanı ile Orman Yangını Risk Tahmini.....	84
4.1.4 Orman Yangın Gözetleme Kulelerinin Risk Modelleri için Görünürlük Analizi	86
4.2 Bağımsız Değişkenlerin Analizi	88
5. TARTIŞMA ve SONUÇ	94
6. KAYNAKLAR.....	98
ÖZGEÇMİŞ.....	105



KISALTMALAR DİZİNİ

Kısaltmalar

AFAD	Afet ve Acil Durum Yönetimi Başkanlığı
AK/AÖ	Arazi kullanımı/arazi örtüsü
ASTER	Uzaydan gelen termal emisyon ve yansıma radyometresi
CBS	Coğrafi bilgi sistemleri
CORINE	Çevre bilgilerinin koordinasyonu
CART	Sınıflandırma ve regresyon karar ağaçları
CNN	Evrişimli sinir ağları
DEM	Dijital yükseklik modeli
DSM	Dijital yüzey modeli
Deep-NC	Derin üretken ağ tamamlama
DL	Derin öğrenme
ETM	Gelişmiş tematik haritalayıcı
EVI	Geliştirilmiş bitki örtüsü indeksi
ENH	Enerji nakil hattı
FAO	Birleşmiş milletler gıda ve tarım örgütü
FRA	Küresel orman kaynakları değerlendirmeleri
FRZI	Yangın risk bölgesi indeksi
GBDT	Gradient boosting karar ağacı
GIS	Coğrafi bilgi sistemleri
GEMI	Küresel çevre izleme indeksi
GPU	Grafik işlemci ünitesi
GDEM	Küresel dijital yükseklik modeli
GEE	Google earth engine
LST	Arazi yüzeyi sıcaklığı
LSTM	Uzun-kısa vadeli bellek
LU/LC	Arazi kullanımı/arazi örtüsü
MGM	Meteoroloji Genel Müdürlüğü
MODIS	Orta çözünürlüklü görüntüleme spektro radyometresi
MSAVI	Modifiye edilmiş toprak düzeltilmiş bitki örtüsü indeksi
MLP	Çok katmanlı algılayıcı
ML	Makine öğrenimi
METI	Japonya ekonomi, ticaret ve sanayi bakanlığı
NDVI	Normalize edilmiş fark bitki örtüsü indeksi
NBR	Normalleştirilmiş yangın oranı
NDMI	Normalize edilmiş fark nem indeksi
NDWI	Normalleştirilmiş fark su indeksi
NASA	Ulusal havacılık ve uzay dairesi
OGM	Orman Genel Müdürlüğü
OSM	Open Street map
OLI	Operasyonel arazi görüntüleyici
ROC	Alıcı işletim karakteristiği
RF	Rastgele orman algoritması
RELU	Doğrultucu aktivasyon fonksiyonu
SAVI	Toprakla düzeltilmiş bitki örtüsü indeksi
SVM	Destek vektör makineleri
SGD	Stokastik gradyan iniş

TM	Tematik haritalayıcı
TA	Termal anemoli
TUREF	Türkiye ulusal referans ağı
UA	Uzaktan algılama
UNDRR	Birleşmiş Milletler Afet Riskini Azaltma Ofisi
YSA	Yapay sinir ağları
XGBoost	Aşırı gradyan artırma



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1 Dünyadaki orman varlığının ülkelere göre durumu	3
Şekil 2.2 Türkiye orman varlığının yıllara göre değişimi	4
Şekil 2.3 Yangın üçgeni	5
Şekil 2.4 Türkiye geneli meteorolojik afet dağılımı.....	8
Şekil 3.1 Geleneksel programlama ve makine öğrenimi.....	19
Şekil 3.2 Makine öğrenimi işlem adımları	19
Şekil 3.3 XGBoost algoritmasının karar ağaçlarından evrimi	22
Şekil 3.4 Biyolojik nöron ve biyolojik nöronun matematiksel modeli	23
Şekil 3.5 Yapay sinir ağı ve derin sinir ağı	24
Şekil 3.6 Çalışma alanı lokasyon haritası.....	26
Şekil 3.7 Orman yangını istatistikleri.....	26
Şekil 3.8 Orman yangını ateşlenme noktaları	28
Şekil 3.9 Orman yangını ateşlenme noktası ve yanan orman alanı.....	29
Şekil 3.10 Sayısal yükseklik modeli.....	30
Şekil 3.11 Bakı haritası	31
Şekil 3.12 Eğim haritası	31
Şekil 3.13 Eğrisellik haritası	32
Şekil 3.14 Yüzey pürüzlülüğü haritası	33
Şekil 3.15 Yola uzaklık haritası	34
Şekil 3.16 Yerleşime uzaklık haritası.....	35
Şekil 3.17 Enerji nakil hatlarına uzaklık haritası	36
Şekil 3.18 Nüfus yoğunluğu haritası	36
Şekil 3.19 Yangın yoğunluğu haritası	37
Şekil 3.20 Arazi kullanımı/Arazi örtüsü haritası.....	38
Şekil 3.21 Orman kapallığı haritası.....	39
Şekil 3.22 Meşcere tipi haritası	40
Şekil 3.23 NDVI bitki indeksi haritası	40
Şekil 3.24 Minimum sıcaklık haritası	42
Şekil 3.25 Maksimum sıcaklık haritası	42
Şekil 3.26 Toprak nemi haritası	43
Şekil 3.27 Rüzgar hızı haritası	44
Şekil 3.28 Yağış haritası.....	45

Şekil 3.29 Evapotranspirasyon haritası	45
Şekil 3.30 Potansiyel güneş radyasyonu haritası	46
Şekil 3.31 Veri seti histogramları.....	49
Şekil 3.32 Çeyreklikler-aykırı değer analizi.....	50
Şekil 3.33 Veri seti çeyreklikleri I.....	51
Şekil 3.34 Veri seti çeyreklikleri II	52
Şekil 3.35 Veri seti çeyreklikleri III.....	53
Şekil 3.36 Veri seti korelasyon matrisi	54
Şekil 3.37 Veri seti korelasyon ısı haritası	55
Şekil 3.38 Verilerin modele etkisi (KA)	59
Şekil 3.39 Verilerin modele etkisi (SRA)	60
Şekil 3.40 Verilerin modele etkisi (AGA)	62
Şekil 3.41 Verilerin modele etkisi (RO).....	63
Şekil 3.42 Orman yangını sıçraması.....	66
Şekil 3.43 Orman yangını noktaları	66
Şekil 3.44 II. Veri seti histogramları-I	68
Şekil 3.45 II. Veri seti histogramları-II	69
Şekil 3.46 II. Veri seti korelasyon ısı haritası	72
Şekil 3.47 II. Veri seti bağımsız değişkenlerin korelasyon matrisi.....	72
Şekil 3.48 Algoritmaların veri miktarına göre performansı	74
Şekil 3.49 Aktivasyon fonksiyonları.....	76
Şekil 3.50 Epok ve doğruluk	77
Şekil 3.51 Model işlem özeti.....	78
Şekil 3.52 Modelin yapay sinir ağı şeklinde gösterimi	78
Şekil 4.1 Rastgele orman algoritması ile oluşturulmuş orman yangını risk tahmini (%20lik olasılık dilimlerine göre)	80
Şekil 4.2 Rastgele orman algoritması ile oluşturulmuş orman yangını risk tahmini	81
Şekil 4.3 Rastgele orman algoritması ile oluşturulmuş orman yangını risk tahmini ve 2023 ile 2024 yılı orman yangınları	81
Şekil 4.4 Aşırı gradyan artırma algoritması ile oluşturulmuş orman yangını risk tahmini.....	82
Şekil 4.5 Aşırı gradyan artırma algoritması ile oluşturulmuş orman yangını risk tahmini (%20lik olasılık dilimlerine göre)	83

Şekil 4.6 Aşırı gradyan artırma algoritması ile oluşturulmuş orman yangını risk tahmini ve 2023 ile 2024 yılı orman yangınları	83
Şekil 4.7 Sıralı model ile risk haritası	84
Şekil 4.8 Sıralı model doğruluk ve kayıpları.....	85
Şekil 4.9 Sıralı model ile oluşturulmuş orman yangını risk tahmini ve 2024 yılı orman yangınları.....	86
Şekil 4.10 Aşırı gradyan artırma algoritması ile oluşturulan riskli alanların kule görünürlük analizi	87
Şekil 4.11 Rastgele orman algoritması ile oluşturulan riskli alanların kule görünürlük analizi.....	87
Şekil 4.12 Sıralı model katmanı ile oluşturulan riskli alanların kule görünürlük analizi.....	88

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1 Yıllara ve çıkış nedenlerine göre Türkiye geneli orman yangınları.....	7
Çizelge 3.1 Orman yangını bağımsız değişkenleri (Veri seti I).....	27
Çizelge 3.2 I. Topoğrafik değişkenlerin özellikleri.....	29
Çizelge 3.3 I. Antropojenik değişkenlerin özellikleri	34
Çizelge 3.4 I. Vejetasyon değişkenlerin özellikleri.....	38
Çizelge 3.5 I. Meteorolojik değişkenlerin özellikleri.....	41
Çizelge 3.6 I. Veri seti örneği.....	48
Çizelge 3.7 Bağımsız değişkenlerin orman yangınları ile korelasyonları.....	57
Çizelge 3.8 Karar ağaçları doğruluk metrikleri.....	58
Çizelge 3.9 CART (Classification & Regression Tree).....	59
Çizelge 3.10 Destek Vektör Makineleri (Support Vector Machine).....	60
Çizelge 3.11 Naive Bayes Sınıflandırıcısı.....	61
Çizelge 3.12 Çok Katmanlı Algılayıcılar (Multi Layer Perceptron (MLP)).....	61
Çizelge 3.13 Aşırı Gradyan Artırma (Extreme Gradient Boosting).....	62
Çizelge 3.14 Rastgele orman (Random forest).....	63
Çizelge 3.15 Sınıflandırma modeli için karışıklık matrisi.....	64
Çizelge 3.16 Doğrulama ölçütleri.....	64
Çizelge 3.17 Orman yangını bağımsız değişkenleri.....	65
Çizelge 3.18 II. Veri seti örneği.....	67
Çizelge 3.19 Bağımsız değişkenlerin orman yangınları ile korelasyonu.....	70
Çizelge 4.1 I. ve II. Veri seti yangın korelasyonları.....	90

1. GİRİŞ

Ormanlar karasal ekosistemde canlıların yaşamsal unsurlarındandır. Toprak, su ve iklim gibi doğal faktörlerin bütünlüğünü ve yaşamsal sürdürülebilirliğini sağlarlar. Ekosistemdeki doğal kaynaklar yaşam standartlarının gelişimine ve küresel ekonominin büyümesine olanak sağlamıştır. Ancak dünya nüfusunun artışı, değişen tüketim alışkanlıkları, plansız şehirleşmeler ve ekonomik büyüme faaliyetleri doğal kaynaklar üzerinde yoğun baskıya sebep olmaktadır. Tüketicinin artması ve üretimdeki artış için yeni teknolojilerin gelişmesi doğal kaynakların hızla azalmasına sebep olmaktadır. Artan nüfusa ve tüketim isteklerine cevap verebilmek için gelişen teknolojilerin karşısında doğal kaynakların sürdürülebilirliğini korumak hayati öneme sahip bir konu haline gelmiştir. Doğal kaynakların yönetimindeki dengenin korunamaması, iklim değişikliği, hava kirliliği, çölleşme, ormansızlaşma ve kuraklık gibi küresel çevre sorunlarına ve bu sorunların artışına sebep olmaktadır. Doğal kaynaklar üzerindeki baskıyı azaltmak ancak planlı ve sürdürülebilirliği sağlayacak doğal kaynak yönetimi ile gerçekleştirilebilir (OGM 2019).

Doğal kaynaklar içerisindeki orman ekosistemi Birleşmiş Milletler Gıda ve Tarım Örgütü verilerine göre dünya kara alanının yaklaşık % 31' ini oluşturmaktadır (FAO 2020). Doğal kaynaklar üzerindeki tüketim baskısı ormanlarında yok olmasına sebep olmaktadır. Ormanların bütünlüğünün korunmayarak daha küçük parçalara bölünmesi, ormancılık faaliyetleri dışındaki izinler, orman dışına çıkarma ve yangınlar ormansızlaşmaya sebep olmaktadır (TOD 2022).

Orman yangınları sosyal ve ekonomik etkilerin yanı sıra ekosistemin bozulmasına sebep olan afetlerdendir. Dünyada iklim değişimi etkileri artmakta olup iklim krizinin orman yangınlarında da artışa sebep olacağı öngörülmektedir (Legg 2021). Hükümetler arası İklim Değişikliği Paneli 6. Raporunun Sentez Raporunda mevcut durum hakkında 21. yüzyılın ilk yirmi yılında (2001-2020) küresel yüzey sıcaklığının 1850-1900 yıllarına göre 0,99 C° [0,84 C°- 1,10 C°] daha yüksek olduğu belirtilmiştir (İnt.Kyn.1).

Yüksek hava sıcaklıkları, düşük nem ile kuru ve şiddetli rüzgarların bulunduğu dönemlerde oluşan yangınlar şiddetli olmaktadır. Genellikle sıcaklığın çok yüksek, bağıl nemin ise %10'un altında olduğu durumlarda yangın riski çok yüksek olarak

değerlendirilir. Akdeniz iklim kuşağında bulunan ülkemizin de Ege ve Akdeniz bölgeleri orman yangınları riski en yüksek alanlar olup iklim değişikliği etkileriyle afet risklerinde de artış beklenmektedir (Küçük ve Sağlam 2004, Kavzoğlu 2021).

Orman yangınlarını tamamen önlemek pek mümkün olmasa bile yangın öncesi tedbirlerle, yangınların sayısını, şiddetini ve oluşacak zararları azaltmak mümkün olabilir. Afet yönetiminin en önemli aşamasını afet öncesi çalışmalar oluşturmaktadır. Afet öncesi çalışmalar ile afete sebep olan değişkenleri belirlemek, oluşabilecek riskleri ortaya koymak, afet anında doğru müdahaleyi yapabilmemizi ve afet sonrası olumsuz sonuçları en aza indirmemizi sağlar.

Orman yangınlarını önlemek ve zararlarını azaltmak için görevli kurum ve kuruluşların yaptığı çalışmaların yanı sıra birçok bilimsel yöntem ve çalışma bulunmaktadır. Ormanlar gibi çok büyük alanlarda yapılan çalışmalar için uydu görüntüleri ve uzaktan algılama teknikleri önemli bir kaynak haline gelmiştir. Geleneksel ölçüm ve gözlem teknikleri orman yangınları için faydalı ve zemin doğrulaması gibi işlemler için gerekli olsa da maliyetli ve zaman alıcıdır. Uzaktan algılama (UA) ve coğrafi bilgi sistemleri (CBS), orman yangını riskini yerel ve büyük ölçekte yüksek doğrulukla ve zaman açısından verimli bir şekilde tahmin etme, haritalandırma ve değerlendirme fırsatı vermektedir. Yangın yönetiminde her aşamada risk tahmini, tespit ve analiz için yine uzaktan algılama teknolojilerinden yararlanılmaktadır (Çolak ve Sunar 2020).


Özellikle son yıllarda gelişen bilgi teknolojileri ile nesnelerin interneti gibi veri üreticilerinin artması bu verilerin depolanması gibi gelişmeler ile büyük veriler oluşmuştur. Uzaktan algılama ve yapay zekâ teknikleri entegreli büyük verilerden anlamlı bilgiler üreterek afet öncesi çalışmalara yön vermek daha hızlı ve kolay hale gelmiştir.

Bu tez çalışmasının ilk aşaması çalışma alanı içerisinde gerçekleşmiş orman yangınlarına ait koordinatlar ile UA & CBS veri ve teknikleriyle hazırlanmış 21 adet bağımsız değişkenden oluşan veri setleri hazırlamaktır. İkinci aşamada ise oluşturulan veri setlerinin analizi ile yapay zekâ yöntemleri olan makine öğrenimi ve derin öğrenme teknikleri kullanılarak orman yangını risk haritaları oluşturmaktır. Uygulama sonrasında bağımsız değişkenler, algoritma seçimi ve çalışma alanı için riskli alanlara dair değerlendirmeler yapılmıştır.

2. LİTERATÜR BİLGİLERİ

2.1 Dünyada ve Ülkemizde Orman Varlığı Durumu

Doğal kaynaklar içerisindeki ormanlar Birleşmiş Milletler Gıda ve Tarım Örgütü 2020 yılı küresel orman kaynakları değerlendirmesine göre dünya kara alanının % 31.1 ini oluşturmaktadır ve dünyadaki toplam orman alanı 4 milyar hektarın üzerindedir. Bu haliyle dünyamızın yaklaşık 1/3 ü ormanlarla kaplıdır ve kişi başına düşen orman alanı 5,2 dekadır. Ayrıca dünyamızdaki ormanların yarısından fazlası sadece 5 ülkede (Rusya Federasyonu, Brezilya, Kanada, Amerika Birleşik Devletleri ve Çin) bulunmaktadır (Şekil 2.1) (FAO 2020).




Şekil 2.1 Dünyadaki orman varlığının ülkelere göre durumu (FAO 2020).

Dünyamız orman ekosisteminden 1990 yılından 2020 yılına kadar 177,5 milyon hektar ormanlık alanı kaybetmiştir. Ormansızlaşma dünya genelinde hala devam etmesine rağmen ulusal ve uluslararası çalışmalar ile orman kaybı hızı düşmektedir (FAO 2020).

Ülkemiz 78 milyon hektarlık yüzölçümü ile orman ekosistemi zengin bir çeşitliliğe sahiptir. 2022 yılı itibarıyla yapılan tespitlere göre ülkemizdeki ormanlık alanlar 23.2 milyon hektar yer kaplamaktadır (Şekil 2.2).

Türkiye, Küresel Orman Kaynaklar Değerlendirmesi 2020 Raporuna göre 22 milyon hektarın üzerindeki orman varlığı ile 252 ülkenin listelendiği raporda 27. Sırada yer almaktadır (FAO 2020).



Şekil 2.2 Türkiye orman varlığının yıllara göre değişimi (OGM 2022).


Ülkemizde ormanların idaresi ve yönetimi 6831 sayılı Orman Kanunu kapsamında Orman Genel Müdürlüğü tarafından yapılmaktadır. Mezkûr Kanun kapsamında ormanlar mülkiyeti bakımından, Devlet Ormanları, Hükmi şahsiyeti haiz amme müesseselerine ait ormanlar ve Hususi Ormanlar olmak üzere üçe ayrılmıştır. Ancak Amme müesseselerine ait ormanlar ve hususi ormanlar çok az olup ülkemiz ormanlarının neredeyse tamamına yakını Devlet ormanı olarak sınıflandırılarak orman vasfı ile tapuda Maliye Hazinesi adına tescillidir.

Ülkemizin ormanlık alanının %32'sini geniş yapraklı ormanlar (meşe, kayın, kızılğaç, kestane, gürgen gibi ağaç türleri), % 48'ini iğne yapraklı (ibrelî) ormanlar (kızılçam, karaçam, sarıçam, göknar, ladin, sedir gibi ağaç türleri), %20'sini ise ibrelî ve geniş yapraklı karışık ormanlar oluşturmaktadır. Ormanlarda en fazla meşe (6,7 milyon ha) yayılış göstermekte, ondan sonra alan büyüklüğü sırasına göre kızılçam, karaçam, kayın, ardıç, sarıçam, göknar, sedir, ladin, fıstıkçamı, kızılğaç, kestane, gürgen, sahil çamı, kavak, fındık, defne ve dişbudak gelmektedir (OGM 2020).

2.2 Orman Yangınları

Bir yangın oluşumu için üç farklı parametreye ihtiyaç vardır. Bunlar; ısı, yakıt ve oksijendir (Şekil 2.3). Bu değişkenlerden herhangi biri yangın üçgeninde yer almadığı

takdirde yangın olayı başlamaz. Orman yangınlarının başlaması için ise belli bazı parametrelerin olması gerekir. Yangının tutuşması ve yayılması, yakıt nemi, hava koşulları, yakıtın türü ile topoğrafya gibi parametrelere bağlıdır (Sabuncu ve Özener 2019).



Şekil 2.3 Yangın üçgeni

Orman yangınları kontrol altına alınamadığında hızlı bir şekilde afet boyutlarına ulaşabilmektedir. Nitekim 2021 yılı Manavgat yangını Türkiye tarihinin en büyük orman yangını afeti olarak kayıtlara geçmiştir.

Birleşmiş Milletler Afet Riskini Azaltma Ofisi (UNDRR), afet tanımını, "*toplumların kapasitesini aşan ve önemli kayıplara neden olan olaylar*" olarak tanımlamaktadır. Bu tanım kapsamında orman yangınları, canlıların yaşamını tehdit etmesi, ekonomik kayıplara sebep olması, doğal çevrenin tahribatı ve karbon emisyonu ile iklim değişikliğine etkisi gibi afet boyutunda sonuçlar doğurabilir.

Dünyanın farklı yerlerinde olduğu gibi içinde yer aldığımız Akdeniz havzasında, son yıllarda görülmeye başlanan iklim değişiminden kaynaklanan olağan dışı hava halleri ile yangınların artışı beklenmektedir. Yangın yönetimindeki başarı yangın aşamasında olduğu kadar, yangınlar çıkmadan önce alınacak önlemlere de bağlıdır. Bu yüzden yangınlarla mücadeleye verilen önem kadar, yangın öncesi çalışma ve planlamalara da önem verilmelidir. Bu kapsamda orman alanlarının potansiyel yangın risklerini dinamik modellerle ortaya koyulmalıdır (Bilgili vd. 2021).

Afet ve Acil Durum Yönetimi Başkanlığı (AFAD)'ın Afet Yönetimi terimler Sözlüğünde afet: *‘‘Toplumun tamamı veya belli kesimleri için fiziksel, ekonomik ve sosyal kayıplar doğuran, normal hayatı ve insan faaliyetlerini durduran veya kesintiye uğratan, etkilenen toplumun baş etme kapasitesinin yeterli olmadığı doğa, teknoloji veya insan kaynaklı olay. Afet bir olayın kendisi değil, doğurduğu sonuçtur.’’* şeklinde tanımlanmaktadır (AFAD 2023). Afet, olayın doğurduğu sonuç olduğuna göre en az afetlere müdahale kadar afet öncesi çalışmalarla da afetlerin önüne geçebiliriz. Ayrıca afet öncesi önlemlerin maliyeti, afet sonrası iyileştirme çalışmalarının maliyetini her zaman azaltacaktır.

Afet yönetimi; afetlere hazırlık, afetlere müdahale etme ve iyileştirme gibi çalışmalarda yapılması gereken müdahalelerin, toplumun tüm kesimlerini ve gerekli bütün kurumları kapsayacak şekilde planlanması, yönlendirilmesi, desteklenmesi, koordine edilmesi ve tüm adımlarda denetlenmesi şeklinde ifade edilebilmektedir (Parlak 2023).

Kapsamlı afet yönetiminin aşamaları, bir afet olayını izleyen ve bir sonraki afete kadar birbirini takip eden aşamaların tümünü ifade eder. Bu evreler; risk belirleme ve modelleme, risk öngörülerini doğrultusunda hazırlık, müdahale, iyileştirme olarak tanımlanmaktadır (Koçkan 2015).

Ülkelerde farklı orman ve orman yangını tanımlamalarından dolayı yangın istatistikleri değişiklik göstermektedir. 2000’li yıllardan günümüze ormanların da içinde bulunduğu 7 milyar hektarın üzerinde arazinin yandığı, bunun 4,8 milyar hektarının Afrika’da, 0,6 milyar hektarının ise Güney Amerika’da olduğu tespit edilmiştir. Yanan orman alanları, yıllara göre farklılık göstermekle birlikte FAO verilerine göre 2015 yılında 98 milyon hektara yakın orman alanının yangınlarda zarar gördüğü açıklanmıştır (FAO 2020, Kavgacı ve Başaran 2023).

Ülkemizde orman yangınları sebeplerine göre kasıt, ihmal, doğal ve sebebi bilinmeyen üst başlıklarında sınıflandırılmıştır. Orman Genel Müdürlüğü resmi istatistik verilerine göre 1988 yılından günümüze orman yangınları çıkış sebeplerine göre Çizelge 2.1’de gösterilmiştir. Kayıtlara göre 1997 yılından itibaren çıkış sebeplerine göre sınıflandırma yapılmış ve 3755 yangın sayısı ile en çok orman yangını 2013 yılında gerçekleşmiş olup

en çok yanan alan ise 139503 hektar ile 2021 yılında gerçekleşmiştir. 1988 yılından 2022 yılına kadar 74520 adet yangın çıkmış olup bu yangınlarla 498104 hektar orman alanı zarar görmüştür (OGM 2022).

Çizelge 2.1 Yıllara ve çıkış nedenlerine göre Türkiye geneli orman yangınları (OGM 2022)


Yıl	Yanan Alan Hektar	Yangın Sayısı Adet	YANGIN ÇIKIŞ NEDENLERİ							
			Kasıt		İhmal-Kaza		Doğal		Sebebi Bilinmeyen	
			Adet	Hektar	Adet	Hektar	Adet	Hektar	Adet	Hektar
1988	18 210	1372								
1989	13 099	1633								
1990	13 742	1 750								
1991	8 081	1481								
1992	12 232	2117								
1993	15 393	2 545								
1994	30 828	3 239								
1995	7676	1 770								
1996	14 922	1 645								
1997	6 317	1339	193	923	696	3 389	78	37	372	1 968
1998	6 764	1932	249	1655	1163	3 713	53	20	467	1 376
1999	5804	2 075	279	1926	1 151	2 808	203	126	442	944
2000	26 353	2 353	410	4 417	1384	19 017	132	167	427	2 752
2001	7 394	2 631	251	651	1 629	4 247	188	735	563	1 761
2002	8 514	1471	218	509	809	7 287	181	261	263	457
2003	6644	2 177	258	665	1 317	4 520	120	694	482	765
2004	4876	1 762	242	748	1 033	3 093	128	233	359	802
2005	2 821	1 530	272	402	867	2 084	140	48	251	288
2006	7 762	2 227	166	206	1 315	5873	330	543	416	1139
2007	11664	2 829	292	1 705	1642	7 994	407	243	488	1 722
2008	29 749	2 135	377	797	1 018	26 283	330	699	410	1 970
2009	4 679	1 793	231	792	884	3 082	333	105	345	700
2010	3 317	1 861	146	526	861	1 851	281	69	573	871
2011	3 612	1954	153	283	1 067	2 368	130	39	604	922
2012	10 454	2 450	197	1615	936	5 780	373	334	944	2 725
2013	11 456	3 755	260	1478	1 419	4 051	258	138	1818	5 789
2014	3 117	2 149	127	85	801	1682	328	77	893	1 273
2015	3 219	2 150	138	167	794	1 198	257	95	961	1 759
2016	9 156	3 188	157	240	990	5 222	310	170	1 731	3 524
2017	11993	2 411	151	619	721	7 146	259	84	1280	4 144
2018	5644	2 167	92	148	693	2 216	413	141	969	3139
2019	11 332	2 688	124	686	883	6 529	372	373	1309	3 744
2020	20 971	3 399	72	718	1156	8 285	312	197	1859	11 771
2021	139 503	2 793	110	46 147	1 001	46 879	353	208	1 329	46 269
2022	12 799	2 160	86	4 722	830	5 428	358	517	886	2 132

Ülkemizde Ege ve Akdeniz kıyılarında bulunan Çanakkale, Balıkesir, İzmir, Aydın, Muğla, Antalya, Mersin, Adana ve Hatay illeri Akdeniz iklimi özelliği taşıyan bölgeleriyle orman yangınları açısından en riskli yerler olduğu bilinmektedir. Yaz aylarında sıcaklıkların artışı, yanıcı madde ve bağıl neminin düşmesiyle birlikte tutuşma

kolaylığı artan bitki örtüsü, yangın oluşumunu kolaylaştırmaktadır. Geçmiş yangınlara bakıldığında yangınların en çok yaşandığı ay Ağustos olmakla birlikte günümüzde iklim değişikliğine bağlı ani hava değişimleri ve sıcaklık artışlarıyla yaz aylarının tamamı hatta sonbahar başlangıcı olan Eylül ayı da orman yangınları için büyük risk taşımaktadır (OGM 2022).

Akdeniz iklimi özelliklerinden biri de geç ilkbahar ile erken sonbahar arasında kısa süreli kurutucu rüzgar ve sıcak hava dalgalarıdır. Kısa zamanlı kurutucu ve sıcak hava dalgaları ile bağıl nemin çok düşmesine sebep olan ve kuzeydeki yüksek basınç ve güneydeki alçak basınç etkisiyle ortaya çıkan poyraz adı verilen rüzgarlar orman yangını oluşumlarına olanak sağlarlar (Küçük ve Sağlam 2004).

Meteoroloji Genel Müdürlüğü verilerine göre Türkiye'de 2000'li yıllar ile artmaya başlayan ve günümüze doğru sürekli artış gösteren aşırı hava olayları, iklim değişikliği ile ilgilidir (Şekil 2.4). Bu durumda afet risk azaltma kavramı her geçen gün daha çok önem kazanacaktır (Tolunay 2021).



Şekil 2.4 Türkiye geneli meteorolojik afet dağılımı (MGM 2022)

2.3 Orman Yangınları Risk Tahmini için UA ve CBS

Uzaktan algılama teknikleri ile orman yangınları için yangın öncesi, yangın anında ve yangın sonrası olmak üzere yapılan çalışmalar 1990'lı yıllar ile başlamış olup gelişen uzaktan algılama teknolojileri ve uluslararası programlar ile ivme kazanarak devam etmektedir (Aspragathos vd. 2019, Bakış vd. 2021).

Yeryüzünde geniş alanları kapsayan ormanların izlenmesi ve yönetilmesi için özellikle uydu tabanlı uzaktan algılama teknikleri hızlı ve faydalı analizler yapılmasını sağlamaktadır. Orman yangınları için de yangın öncesi risk alanlarının belirlenmesi için en çok kullanılan yöntemlerin başında uzaktan algılama teknikleri gelmektedir. Ayrıca uzaktan algılama ve coğrafi bilgi sistemi teknikleri birbirini tamamlayan teknikler olup risk analizi çalışmalarında büyük öneme sahiptir. Coğrafi Bilgi Sistemi, konumsal verilerin toplanması, depolanması, ilişkilendirilmesi, sınıflandırılması, sorgulanması ve verilerin analiz edilmesiyle oluşan bir karar destek sistemi olarak geliştirilmiştir (Erten vd. 2004).

Jain vd. (1996)'i orman yangını riski taşıyan alanların önceliklendirilmesi için bütünleşmiş bir uzaktan algılama ve Coğrafi Bilgi Sistemi (CBS) yaklaşımı sunulmuştur. Orman yangını ve yayılmasını kolaylaştıran önemli faktörler olan ormandaki yakıt içeriği, yollara, yerleşime uzaklık ve topografya, çalışma alanının yangın riski bölgesi haritasını elde etmek için entegre edilmiştir Çalışma alanının neredeyse yarısının ve çoğunlukla parkın kenarlarında yoğunlaşan çok yüksek ve yüksek riskli bölgeler altında olacağı tahmin edilmiştir.

Erten vd. (2004)'i Gelibolu Yarımadası için uzaktan algılama ve CBS verilerinin kombinasyonuna dayanan bir yangın yayılma risk modeli oluşturmuşlardır. Landsat uydu görüntüleri 25 Temmuz 1994 tarihinde meydana gelen yangının etkilerini araştırmak için hem yangın öncesi hem de yangın sonrası için kullanılmıştır. Topografya ve bitki örtüsü gibi yangını etkileyen parametreler ile nüfus, yerleşim yerleri, orman yangın kuleleri, yangın istasyonları, müdahale yerleri, müdahale edecek personelin özellikleri ve ulaşım gibi diğer arazi kullanım bilgileri CBS içerisinde entegre edilmiştir. Yapılan analizlerle en kısa müdahale yolu, boşaltılması gereken alanlar, yangın müdahalesi için öncelikli alanlar gibi sonuçlar

ortaya konarak karar vericilerin orman yangınlarının risk ve etkilerini en aza indirebilmesi için ülke genelinde uygulamanın yapılması önerilmiştir.

Pradhan vd. (2007)'i orman yangınına duyarlılığı değerlendirmek için uzaktan algılama ve coğrafi bilgi sistemlerini kullanılmışlardır. Çalışma alanı için orman yangını haritalamasının belirlenmesinde frekans oranı modeli uygulanmıştır. Chuvieco vd. (2012)'i orman yangınları risk değerlendirmeleri için coğrafi bilginin entegrasyonunu açıklamaktadırlar. Pettinari vd. (2014)'i Güney Amerika'da yangın potansiyelini ve bölgedeki yakıt özelliklerini haritalamak için metot önermektedir.

Adab vd. (2013)'i İran'ın kuzeydoğusundaki yangın riskini belirlemek için Yapısal Yangın Endeksi, Yangın Riski Endeksi ve Hibrit Yangın Endeksi adı verilen yeni bir endeks kullanmışlardır. Yangınları etkileyen faktörler için bitki örtüsü nemi, eğim, bakı, yükseklik, yollara ve yerleşim yerlerine uzaklık değişkenlerini belirlemişler. Bu indeksler, katmanların sınıflarına yangına duyarlılık oranlarına göre subjektif ağırlık değerleri atanarak oluşturulmuştur. Doğrulama için MODIS uydu sensöründen elde edilen noktalar kullanılmış ve İndekslerin ROC eğrileri ile değerlendirilmesi, HFI'nın %76,7 doğruluğunun diğer iki indeksten daha iyi performans gösterdiğini ortaya koymuşlardır.

Boyatan M. (2019) Orman yangınları için karar destek sistemi geliştirme çalışmasında meşcere, yol, dere, yerleşim alanı gibi arazi kullanım durumlarını değerlendirerek CBS teknikleri ile dinamik bir model oluşturmuştur. Model kapsamında Dört Yol Orman işletme Müdürlüğü sorumluluk sahasında kalan ormanlık alanların yangın tehlikesi beş sınıfa ayrılıp derecelendirilmiştir.

Gülçin ve Deniz (2020) MODIS'e dayalı yangın kayıtları ile ASTER Global DEM, CORINE ve OSM gibi uydu ve açık kaynaklı veriler kullanarak tematik haritalar oluşturmuşlardır. Orman yangını risk derecelendirmesi için Yangın Risk Bölgesi İndeksi (FRZI) kullanılmış olup 2001-2018 yılları arasındaki yangınların değerlendirmesinde ise geçmiş yangınların yaklaşık %65'inin yüksek ve çok yüksek risk bölgelerinde kaldığını tespit etmişlerdir. UA ve CBS tekniklerine dayalı olarak hazırlanan metodolojinin yangın risk bölgelerinin belirlenmesinde etkin olarak kullanılabilirliği önerilmiştir.

Kavlak vd. (2020)'nin 'Coğrafi Bilgi Sistemleri ile Orman Yangını Risk Haritası Oluşturulması: Ören Örneği' adlı çalışmalarında Çalışma alanına ait CBS teknikleriyle yangın risk haritası oluşturulmuştur. Ayrıca bölgede yer alan yangın kulelerinin, çalışma alanının ne kadarına hakim olduğu da görünürlük analizi ile incelenmiştir. Görünürlük analizi ve yangın risk haritaları sonuçlarına göre risklerin önlenmesine yönelik önerilerde bulunulmuştur.

Parajuli vd. (2020)'i Nepal'in iki büyük bölgesinde, orman yangını risk modellerini geliştirmek için UA, CBS teknolojisi ve istatistiksel araçlar kullanmışlardır. Orman yangını risk haritasını bitki örtüsü, topoğrafik faktörler, arazi yüzey sıcaklığı, yola ve yerleşim yerlerine yakınlık gibi risk değişkenleriyle birlikte çok parametrelili ağırlıklı indeks modeli benimsenmiştir. 2001'den 2018'e kadar MODIS sıcak nokta verileri de değerlendirildiğinde yangın noktalarının yanık alanıyla güçlü bir ilişkiye ($R^2 = 0,82$) sahip olduğunu tespit etmişlerdir.

Dilekçi vd. (2021)'nin çalışmasında Landsat 8 uydu verisi ile yangına konu olan sınıfları her bir için Analitik Hiyerarşi Süreci yöntemiyle uygunluk puanları belirlemiştir. Bu sonuçlara göre coğrafi bilgi sistemleri teknikleriyle orman yangını risk haritası oluşturulmuştur. Sınıflandırılan haritanın doğruluğu için diskriminant analizi yapılmıştır.

Alkayış vd. (2021)'i Muğla ili Menteşe bölgesinin yangın risk haritası için yola ve yerleşime olan uzaklık, bakı, eğim ve vejetasyon temel parametreler olarak belirlemişlerdir. Çalışma ile coğrafi bilgi sistemleri (CBS) tabanlı orman yangını risk haritası hazırlanmış ve %11,86'sı yüksek riskli, %18,32'si riskli, %25,23'ü orta riskli, %20,40'ı düşük riskli, %24,19'u ise risksiz olduğu sonucuna ulaşılmıştır.

Gövdetaşan M. (2022) 2000-2020 yılları arasında Biga ve Gelibolu Yarımadalarında gerçekleşen 24 orman yangını uydu bazlı uzaktan algılama teknikleri ile incelenmiştir. Uydu verisi olarak Landsat 5 (TM), Landsat 7 (ETM+) ve Landsat 8 (OLI) multispektral uydu görüntüleri ile NDVI, NBR, NBR2, EVI, SAVI, MSAVI, NDMI ve GEMI endeksleri oluşturup Orman Genel Müdürlüğü'nden (OGM) temin edilen yangın verileri ile arasındaki ilişkileri incelenmiştir. 15 metre mekânsal çözünürlükteki uydu görüntüleri ile 30 metre mekânsal çözünürlükteki uydu görüntüleri karşılaştırıldığında 15 metre de EVI, MSAVI, NBR ve NDMI en yüksek korelasyonu sağlarken, 30 metre de NDVI, SAVI, NBR2 ve GEMI en iyi ilişkiyi sağlamıştır.

Sivrikaya vd. (2024)'i Orman yollarının orman yangınlarına etkisini Coğrafi Bilgi Sistemleri teknikleri kullanarak araştırmışlardır. Orman yolları için 250, 500, 1000 ve 5000 metrelik zonlar oluşturularak yangınlar analiz edilmiş ve en çok yangının 0-250 m zonda meydana geldiği tespit edilmiştir.

2.4 Orman Yangınları Risk Tahmini için Makine Öğrenimi

Günümüzde teknolojik gelişmeler ile daha yüksek çözünürlüklü veriler üretilmeye başlanmış ve bu verilerin değerlendirilmesi, işlenmesi ve analizinde eksiklikler olmuştur. Bu verilerin değerlendirilmesi için farklı yöntemlere ve donanımlara duyulan ihtiyaç her geçen gün artmaktadır. Son zamanlarda popülerliği gittikçe artan yapay zekâ ve makine öğrenimi tekniği olan derin öğrenme yapıları yaygın bir şekilde kullanılmaktadır (Döş ve Uysal 2019).

Satır vd. (2016)'i Akdeniz iklimi özelliği taşıyan Yukarı Seyhan Havzasındaki orman yangını risk değerlendirmesi için geri yayılım algoritmasına dayalı çok katmanlı algılayıcı (MLP) tekniği ile yapay sinir ağlarını kullanmışlardır. Çoklu veri değerlendirmesine dayanan yöntemde yangın oluşumunu etkileyen faktörler; Fiziksel, Antropojenik, İklim ve Yangın oluşum verileri başlıkları altında uzaktan algılama ve CBS teknikleriyle yangın parametreleri haritalandırılarak veri seti oluşturulmuştur. Orman yangını risk durumunu belirlemede çok katmanlı algılayıcı (MLP)'nin başarılı olduğu, antropojenik etkilerin tek başına yangın tehlikesinde önemli olmadığı fakat yangın oluşumu için ağaç örtü tipi, sayısal yükseklik modeli ve ortalama sıcaklık değişkenleri için gerekli değerlere ulaştığında antropojenik faktörlerin belirleyiciliği ortaya çıktığı sonucuna varılmıştır.

Guo vd. (2016)'nin Çin'in Kuzey ormanlarındaki orman yangınları olasılığını etkileyen antropojenik parametreleri incelemek için yaptığı çalışmada lojistik regresyon ve rastgele orman yöntemleri uygulanıp karşılaştırılmıştır. Yangın oluşumunu etkileyen faktörler olarak İklim (Günlük Yağış, Günlük Sıcaklık, günlük Bağıl Nem), Topoğrafya (Eğim, Bakı), ve Bitki Örtüsü (Orman Tipi)'den oluşan biyofiziksel katmanlar ile altyapısal ve sosyoekonomik birçok veri kullanılmıştır. Rastgele orman yönteminin lojistik regresyonla karşılaştırılmasında rastgele orman yönteminin antropojenik etkileri

belirlemede daha yetenekli olduğu görülmüştür. Antropojenik yangınların demiryolları, yollar ve yerleşim yerleri gibi altyapıların yakınında meydana gelme olasılığının daha yüksek olduğunu ve ayrıca orman türlerinden önemli ölçüde etkilendiği tespit edilmiştir. İşsizlik ve nüfus yoğunluğu ve kişi başı gelir gibi sosyoekonomik faktörlerin ise antropojenik yangınlar için itici bir faktör olarak görülmemiştir ve bunun daha yavaş ekonomik kalkınma ve nüfus artışından kaynaklandığı görüşüne varılmıştır.

Thach vd. (2018)'i makine Öğrenimi yöntemleri olan, Destek vektör Makinesi sınıflandırıcısı, Rastgele Ormanlar ve Çok katmanlı Algılayıcı sinir ağı kullanarak orman yangını tehlikesini mekânsal olarak analiz etmiş ve yöntemleri karşılaştırmışlardır. 564 adet tarihsel yangın noktası ile 10 adet yangın oluşumunu etkileyici değişken belirlenmiş ve değişkenlerin orman yangını ile ilişkisini değerlendirmek için Pearson korelasyon yöntemi kullanılmıştır. Bu çalışma ile oluşturulan üç adet orman yangını tehlike modeli, SVMC, RF ve MLP-Net karşılaştırıldığında MLP-Net, yüksek tahmin doğruluğu ile öne çıkmıştır.

Sayad vd. (2019)'i orman yangınlarının oluşumunu tahmin etmek için uzaktan algılama, büyük veri ve veri madenciliği algoritmalarını birleştirmeyi önermektedir. NDVI bitki indeksi, meteorolojik koşullar ve yangın göstergesi Termal anomaliler ile ilgili uzaktan algılamaya dayalı veri seti hazırlanmış ve kaynak olarak MODIS uydu verileri kullanılmıştır. Büyük veri platformu “Databricks” kullanılarak yapılan deneysel sonuçlarda yüksek tahmin doğruluğuna ulaşılmıştır. (%98.32). Ayrıca bazı erken uyarı sistemleriyle de karşılaştırılmıştır.

Ghorbanzadeh vd. (2019)'nin Kuzey İran da orman yangını duyarlılık endeksi ve bir sosyal/altyapısal güvenlik açığı tahmini için makine öğrenimi yöntemi ve bir coğrafi bilgi sistemi çok kriterli karar verme kullanmışlardır. 2012-2017 yılları için orta çözünürlüklü görüntüleme spektro radyometresi, termal anomaliler ürününden bir orman yangını envanter veri tabanı ve 16 çevresel değişken ve k-kat çapraz doğrulama (CV) yaklaşımı kullanılarak bir orman yangını duyarlılık haritası oluşturulmuştur. Daha sonra, orman yangını duyarlılığı ve sosyal/altyapısal kırılganlık haritaları dikkate alınarak risk alanlarını değerlendirmek için CBS-MCDM kullanılmıştır. Yangına duyarlılığın yüksek olduğu alanların çoğu, küçük düzeyde sosyal/altyapısal güvenlik açığı sergilediği sonucuna varılmıştır.

Bešli ve Tenekeci (2020)'nin 'Uydu verilerinden karar ağaçları kullanarak orman yangını tahmini' adlı çalışmalarında uydu verilerinden hazırlanan Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NVDI), Arazi Yüzeyi Sıcaklığı (LST) ve Termal anomali (TA) verileri kullanılarak tahmin için karar ağaçları kullanılmıştır. Karar ağaçlarının eğitiminde kullanılmak için veri setindeki verilerin %70'i kullanılmış olup geriye kalan %30 veri ile de modelin testi gerçekleştirilmiştir. Tüm denemelerde yapılan tahminler için ortalama %93,11 doğruluk ile gerçek durum belirlenmiştir. Ayrıca yazarlar, tahmin başarısını arttırmak için farklı uygulamalarda kullanılan meteorolojik veriler ve eski orman yangını kayıtları da kullanılmasıyla daha fazla parametre ile daha yüksek başarı oranına ulaşılabileceği ve uygulanan yöntem farklı veri madenciliği yöntemleri ile birlikte hibrid bir şekilde kullanılarak ta daha başarılı tahminler gerçekleştirilebileceğini önermektedir.

Pourghasemi vd. (2020)'i çoklu tehlike değerlendirmesi yaptıkları çalışmada orman yangını için 10, sel için 12 ve heyelan için 10 etken faktör kullanmışlardır. Her bir faktörün meydana gelmesi durumu için boruta algoritması kullanılmış olup tüm afetler için rastgele orman yöntemi ile duyarlılık haritaları hazırlanmıştır.

Sevinç vd. (2020)'i olası orman yangını sebeplerinin tahmini ve bu sebepler arası ilişkilerin analizi için Bayes ağ modelini kullanmışlardır. Sıcaklık, bağıl nem, ağaç türü, yoldan uzaklık, rüzgar hızı, tarım arazisinden uzaklık, yanan alan miktarı, ay ve yerleşime uzaklık orman yangınları oluşumuna etken faktörler olarak belirlenmiştir. Orman yangını tutuşması ise insan kaynaklı (kundaklama, sigara içme, avlanma, piknik yangını, çoban yangını, anız yakma) ve doğal nedenli (yıldırım çarpması, elektrik hatları) olarak nitelendirilmiştir. Çalışmanın girdilerine göre orman yangınının da en önemli faktör ay ve sıcaklık sonucuna varılmıştır.

Bjānes vd. (2021)'nin çalışması orman yangını duyarlılığı için iki derin öğrenme ağına dayanan yeni bir Ensemble modeli önermektedir. 2013'ten 2019'a kadar Şili'deki iki bölgeye ait yangın verileri ile 15 adet yangın etkileyici faktör ile oluşturulan veri seti oluşturulup eğitilmiştir. Ayrıca model Aşırı Gradyan Artırma ve SVM gibi diğer makine öğrenimi yöntemleri ile karşılaştırılmıştır. Sonuç olarak önerilen model en yüksek doğruluk değerlerini almıştır.

He vd. (2021)'nin çalışması heyelan ve orman yangını duyarlılığının kesişimini incelemekte ve RF (Random Forest), GBDT (Gradient Boosting Karar Ağacı), AdaBoost (Adaptive Boosting) olmak üzere üç farklı makine öğrenimi algoritması kullanmaktadır. RF'nin diğer modellere göre üstünlüğü, heyelan ve orman yangını duyarlılık haritalaması için potansiyel olarak verimli bir model olduğu sonucuna varılmıştır.

Bilücan vd. (2022)'i CatBoost, LightGBM ve Rastgele Orman olmak üzere üç makine öğrenme algoritması ile Hatay ili için orman yangını risk tahmini yapmışlardır. Yangın verisi olarak NASA kaynaklı MODIS verileri ve 11 bağımsız değişken kullanılmıştır. Sonuçlara göre, LightGBM algoritması %88.31, CatBoost algoritması %87.21 ve Rastgele Orman algoritması ile %85.90 doğrulukta risk modelleri üretilmiştir. McNemar's testi ile doğruluklar arasındaki fark incelenmiştir. Bağımsız değişkenlerden en etkili faktörlerin yükseklik, yağış, bitki örtüsü ve rüzgar hızı olduğu tespit edilmiştir.

Yıldırım vd. (2023)'i Orman yangını tahmini için NASA kaynaklı veri setini çeşitli ön işlemeye tabi tutarak sınıflandırma modeline uygun hale getirmişlerdir. Makine öğrenimi algoritması olarak Destek Vektör Makinesi, Karar Ağacı, Rasgele Orman, Gradyan Artırma, K-En Yakın Komşu ve Naive Bayes sınıflandırma algoritmaları model oluşturulmuş ve en yüksek doğruluğa Rasgele Orman (%97) ve Naive Bayes (%96) algoritmaları ulaşmıştır.

2.5 Orman Yangını Risk Tahmini için Derin öğrenme

Najafabadi vd. (2015)'i derin öğrenmeyi, insan beynini son derece karmaşık problemler için gözlem, analiz, öğrenme ve karar verme yeteneğini taklit etmeyi amaçlayan ve denetimsiz veri kullanan bir makine öğrenimi olarak tanımlamışlardır.

Makine öğrenimi tekniklerinden farklı olarak derin öğrenme çok sayıda katman kullanarak her katmanı eğitilmiş bir model olarak işlev görür. Derin öğrenme algoritmaları, katmanlı yaklaşım ile karmaşık örüntüleri tanıyabilir ve geleneksel makine öğrenimi tekniklerine kıyasla verilerden daha derin anlamlar çıkarabilir. CNN'ler yangın algılama sistemlerinde, alevleri tespit etmek için yaygın olarak kullanılmaktadır (Aldossary vd. 2024)

Zhang vd. (2019)'i 2002'den 2010'a kadar Çin'in Yunnan Eyaletindeki orman yangını noktalarını ve orman yangını etkileyen 14 adet faktörü haritalandırmışlardır. Orman yangını duyarlılığı tahmini için bir derin öğrenme yöntemi olan evrişimli sinir ağı mimarisi tasarlamışlardır. Orman yangını duyarlılığının mekânsal tahmin haritasını oluşturmak ve eğitim/doğrulama örnek kitaplıklarını oluşturmak için orantılı örnekleme kullanılarak veri seti eğitilmiştir. Önerilen modelin tahmin performansı, Wilcoxon işaretli sıra testi, alıcı işletim karakteristik eğrisi ve eğrinin altındaki alan (AUC) gibi istatistiksel ölçüler kullanılarak değerlendirilmesi sonucunda CNN modelinin (AUC 0.86) rastgele orman, destek vektör makinesi, çok katmanlı algılayıcı sinir ağı ve çekirdek lojistik regresyona kıyaslama sınıflandırıcılarından daha yüksek doğruluğunu verdiği tespit edilmiştir.

Van Le vd. (2021)'i çalışma alanını orman yangını duyarlılığı açısından karakterize etmek için eğim, bakı, yükseklik, eğrilik, arazi kullanımı, NVDI, NDWI, NDMI, sıcaklık, rüzgâr hızı, bağıl nem ve yağış gibi on iki ateşleme faktörü kullanılmıştır. Çalışma tropikal bir iklim bölgesinde orman yangınlarının mekânsal tahmini için yeni bir derin sinirsel hesaplama yaklaşımı önermektedir. Modelin ağırlıklandırmak ve optimize etmek için Stokastik Gradyan İniş (SGD), Ortalama Kare Yayılım (RMSProp), Uyarlamalı Moment Tahmini (Adam) ve Adadelat optimize edicileri kullanılmışlardır. Sonuçta en yüksek doğruluk Adam optimize edilmiş Deep-NC modelinden elde edilmiştir.

Naderpour vd. (2021)'nin çalışmasında Sidney'in Kuzey Plajları bölgesindeki orman yangını riskini ölçmek için orman yangını riskine katkıda bulunan otuz altı önemli gösterge belirlenmiş ve modellerine girdi olarak hazırlanan topografya, morfoloji, iklim, insan kaynaklı, sosyal ve fiziksel perspektifler mekânsal olarak haritalanmıştır. Çok katmanlı algılayıcının kapasitesini en üst düzeye çıkarmak için optimize edilmiş derin sinir ağları geliştirmiştir. Sonuçlar, ROC = %95,1, PRC = %93,8 ve k katsayısı = %94,3 doğruluk değerlendirme metrikleri modelin yüksek doğruluğunu göstermektedir. Ayrıca yazarlar gelecekteki çalışmalar için orman yangını tehlike değerlendirmesine katkılarını incelemek için orman biyo çeşitliliği, toprak nemi, ağaç özellikleri ve koşullar gibi daha derinlemesine morfolojik parametreleri dikkate almayı, ek olarak, gradyan artırma, evrişimli sinir ağları veya topluluk yaklaşımları gibi diğer son teknoloji ML modellerini incelemek ve karşılaştırmak faydalı olacağını önermektedir.

Zhang vd. (2021)'i orman yangınlarına duyarlılık için bir evrişimli sinir ağı ile çok katmanlı algılayıcı sinir ağını karşılaştırmış ve evrişimli sinir ağlarının büyük bir potansiyele sahip olduğu belirtilmiştir. Ayrıca çalışmada küresel ölekte orman yangını duyarlılık haritası üretilmiştir.

Fidanboy vd. (2022)'i orman yangınlarıyla mücadelede kapsamında, bitki örtüsü, iklim değişiklikleri, antropojenik etmenler ve geçmiş yangın verileri ile Orman Yangını Analiz Tahmin (OYAT) modeli oluşturmuşlardır. Coğrafi bilgi sistemleri ile uyumlu çalışan model değişkenleri derin öğrenme teknikleriyle işlenerek bölgesel risk tahminleri üretebilmektedir. 2013 yılından itibaren 7 yıllık orman yangını verileri OYAT modelinin değerlendirilmesinde kullanılmış olup model ile %98 doğruluk oranına ulaşılmıştır.




3. MATERYAL ve METOT

Balıkesir ili sınırları içerisinde meydana gelen orman yangınlarına ait koordinatlar OGM'den temin edilerek bağımlı değişken olarak belirlenmiştir. Çalışma alanına ait 21 adet bağımsız değişkenin 5'i antropojenik, 4'ü vejetasyon, 5'i topoğrafik ve 7'si ise meteorolojik veriler olmak üzere belirlenmiş olup uzaktan algılama ve açık kaynaklı platformlardan temin edilen ham veriler Arcmap yazılımı aracılığıyla haritalandırılmıştır. Bağımlı ve Bağımsız değişkenler 2017-2022 yılları arasında 6 yıl ve 2017-2023 yılları arasında 7 yıl boyunca mayıs-eylül ayları arasında aylık zamansal çözünürlükte sınıflandırılmış ve her bir nokta geçmiş uydu görüntülerinden kontrol edilerek hatalı veya doğruluğu teyit edilemeyen noktalar elenmiştir. Kesinleşen noktalardaki yanan alanlar için her piksele bir yangın varlığı değeri atanmıştır. Rastgele nokta üretimi ve eşit dağılım kontrolü ile yangın olmayan noktalar üretilmiştir. Uzaktan algılama verileri ve teknikleri ile oluşturulan 21 bağımsız değişkenden değerler çıkarılarak 670*22 satır*sütundan oluşan I. eğitim veri seti ile 2100*22 satır*sütundan oluşan II. eğitim veri seti model eğitimleri için oluşturulup risk tahmini için de çalışma alanında ki tüm orman alanlarının piksellerini kapsayan 689419*21 satır*sütundan oluşan tahmin veri seti hazırlanmıştır. Eğitim veri setleri Google Colab arayüzünde Python dili kullanılarak keşifsel veri analizi ile görselleştirilmiş ve korelasyon analizi gerçekleştirilmiştir. Eğitim aşamasında kategorik veriler olan Bakı, Arazi Örtüsü/Arazi Kullanımı ve Orman Kapalılık değişkenleri için (dummy encoder) kukla kodlayıcılar kullanılmış, böylece değişkenlerin makine öğrenimi algoritmalarında kullanılabilmesi sağlanmıştır. Veri setindeki değişkenlere ait verilerin normal dağılmaması bazı algoritmaların çalışmasını etkileyen bir faktördür. Verilerin sağa çarpık veya sola çarpık olması durumunda model performansı etkilenebilir. Bu durumda değerleri normalleştirmek ve baskınlığı azaltmak için bir özellik ölçekleme yöntemi olan standardizasyon kullanılmıştır. Makine Öğrenimi ve Derin öğrenme için model eğitimleri tamamlandıktan sonra tahmin aşamasına geçilmiş ve makine öğrenimi algoritmalarında en iyi doğruluk metriklerine ulaşılan Rastgele Orman ve Aşırı Gradyan Artırma algoritmaları ile eğitim ve tahminler yapılarak haritalandırılmıştır. Derin Öğrenme modeli olan Sıralı model ile de II. Veri seti kullanılarak yüksek doğruluk metrikleri ile eğitim ve test yapılarak risk tahmini haritası üretilmiştir.


3.1 Makine Öğrenimi

Makine öğrenimi, programlama yapılmadan bilgisayarların karmaşık görevleri otomatik öğrenmelerini sağlar ve Sunulan verilerdeki örüntüleri keşfederek bu örüntüleri yeni durumlara uygulama yeteneği kazandırır. Geleneksel programlama ile daha gelişmiş ve karmaşık görevlerde gerekli algoritmaları oluşturmak zor olabilir ya da mümkün olmayabilir (Şekil 3.1). Programcıların her adımı belirlemesi yerine, makinenin kendi algoritmasını geliştirmesine yardımcı olmak daha etkili olabilir (Alpaydın 2020).



Şekil 3.1 Geleneksel programlama ve makine öğrenimi

Makine öğrenimi yöntemleri denetimli, denetimsiz ve yarı denetimli olmak üzere üç ana kategoriye ayrılır. Bunlar verinin etiketlenmesi, sınıflandırılması gibi ön işlemlere tabi olup olmamasına bağlıdır (Deperlioğlu ve Köse 2024). Makine öğrenimi problemin çözülmesi için farklı algoritmalarda farklı sonuçlar ile karşılaşılrsa da her algoritmada benzer işlem adımlarını içerir (Şekil 3.2).



Şekil 3.2 Makine öğrenimi işlem adımları

Yaygın kullanıma sahip bazı makine öğrenimi algoritmaları: Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Trees, CART), Karar Ağaçları (Decision Tree), Destek Vektör Makineleri (Support Vector Machine), Naive Bayes Classifier, Çok Katmanlı Algılayıcılar (Multi Layer Perceptron, MLP), Aşırı Gradyan Artırma (Extreme Gradient Boosting) ve Rastgele Orman (Random Forest) bu tez kapsamında uygulanarak ve sonuçları değerlendirilerek yüksek doğruluk metriklerine sahip model seçimi yapılmıştır.

Karar ağaçları (Decision Tree) algoritması, denetimli öğrenmede ağaç bazlı öğrenme algoritması olup hem sınıflandırma hem de regresyon için kullanılabilir. Karar ağaçları Rastgele Orman (Random Forest) algoritmasının da temelini oluşturur. Ağaç yapısında ilk bölünmenin başladığı yere, kök, dalların uzaması ile gelişen kısımlara düğümler ve en son kararın verildiği alt uçlarına ise yapraklar olarak tanımlanır. Büyük ve karmaşık veri kümelerini bir dizi karar kuralları uygulayarak daha küçük kümelere bölerek kullanan yapısı ile basit ve hızlı karar verme ve tahminde bulunma olanağı sağlar. (Jo, 2024)

Sınıflandırma ve Regresyon Ağaçları (CART) karar ağacı tabanlı model olup bu algoritma, tahmine dayalı modellemeler de güçlü bir algoritmadır (Brownlee, 2016) CART veri seti içerisindeki karmaşık yapıları, bir dizi ikili seçim yaparak basit karar yapılarına dönüştürür (Deperlioğlu ve Köse 2024). CART, karar ağaçlarının bir alt kümesi olarak düşünülebilir ve genellikle daha belirgin ve tutarlı bir metodolojiye sahiptir.

Destek Vektör Makineleri (Support Vector Machine) genellikle sınıflandırma problemlerinde kullanılan denetimli öğrenme yöntemlerinden biridir. Düzlem üzerindeki noktaları doğru ile ayırmaya çalışır. Bu doğru, iki sınıfının noktaları için de maksimum uzaklıkta olmasını hedefler. Küçük ve orta ölçekteki veri setleri için uygundur (Brownlee, 2016).

SVM, doğrusal olarak ayrılabilir olmayan verilerle başa çıkmak için çekirdek fonksiyonları kullanır. Çekirdek fonksiyonları, verileri daha yüksek boyutlu bir uzaya dönüştürerek, bu uzayda doğrusal olarak ayrılabilir hale getirmeye çalışır.

Naive Bayes sınıflandırıcısının temeli, rastgele olayların koşullu ve marjinal olasılıklarını ilişkilendiren Bayes Teoremi'dir. Teorem şu şekilde ifade edilir (4.1).

$$P\left(\frac{C}{X}\right) \cdot P(X) = \left(P\left(\frac{X}{C}\right) \cdot P(C)\right) \quad (3.1)$$

Burada:

- $P(C/X)$: Özellik vektörü X verildiğinde, sınıf C 'nin posterior olasılığıdır.
- $P(X/C)$: Sınıf C verildiğinde, özellik vektörü X 'in likelihood olasılığıdır.
- $P(C)$: Sınıf C 'nin prior olasılığıdır.
- $P(X)$: Özellik vektörü X 'in marjinal olasılığıdır.


Algoritmanın çalışma şekli bir özellik için her durumun olasılığını hesaplar ve olasılık değeri en yüksek olana göre sınıflandırır (Deperlioğlu ve Köse 2024). Karmaşık ve küçük veri kümelerinde de çalışabilir.

Çok Katmanlı Algılayıcı (MLP), yapay sinir ağlarının en temel formlarından biridir. Bu yapı, insan beyninin bilgi işleme şeklini taklit etmeye çalışan matematiksel bir modeldir. MLP, birbirine bağlı nöronlardan (yapay sinir hücrelerinden) oluşan birden fazla katmana sahiptir (Goodfellow, 2016).

Rastgele orman, Leo Breiman ve Adele Cutler tarafından oluşturulan, sonuca ulaşmak için birden fazla karar ağacının çıktısını birleştiren, kullanımı yaygın bir makine öğrenme algoritmasıdır. Hem sınıflandırma hem de regresyon problemlerini ele aldığından ve kolaylığı ve esnekliği ile öne çıkan topluluk algoritmalarındandır (Deperlioğlu ve Köse 2024). Bu algoritma, bootstrap örnekleme ve rastgele özellik seçimleri kullanarak modelin çeşitliliğini artırır ve aşırı öğrenmeyi (overfitting) azaltır.

Makine öğreniminde, denetimli öğrenme algoritmalarının bir alt kümesi olan 'ensemble' yöntemler, genellikle tahmin etme ve sınıflandırma problemlerinde yüksek performans gösterir. 'ensemble' yöntemlerden biri olan Aşırı Gradyan Artırma, karar ağaçları üzerinde çalışan bir gradient boosting algoritmasıdır ve yüksek performansa sahiptir (Deperlioğlu ve Köse 2024). Tianqi Chen ve Carlos Guestrin'in 2016 yılında yayınladıkları "Aşırı Gradyan Artırma: A Scalable Tree Boosting System" adlı makale ile hayatımıza dahil olmuştur.

Aşırı Gradyan Artırma algoritmasında model, basit bir başlangıç tahmini ile başlar, model oluşturulur, modelin hatası hesaplanır ve gradient descent yöntemi kullanılarak hata azaltma hedeflenir. Sonrasında hataları düzelten yeni ağaç eklenir ve model güncellenir. Bu süreç bu adımlar, modelin performansını iyileştirmek için belirli bir durma kriterine ulaşılan kadar devam eder (Şekil 3.3).



Şekil 3.3 Aşırı gradyan artırma algoritmasının karar ağaçlarından evrimi (Morde ve Setty 2019).

Özellikle son yıllarda gelişen bilgi teknolojileri ile nesnelerin interneti gibi veri üreticilerinin artması bu verilerin depolanması gibi gelişmeler ile büyük veriler oluşmuştur. Uzaktan algılama ve yapay zeka teknikleri entegre edilerek büyük verilerden orman yangınları için risk analizi araştırmaları yapılmaktadır.


3.2 Derin Öğrenme

Yapay zekâ fikrinin ortaya çıkması her ne kadar eski olsa da gelişimi son yıllardaki teknolojik gelişmeler sayesinde hızlanmıştır. Büyük veriler ve artmaya devam eden veri miktarı ile insan beynini taklit eden, karmaşık problemlerde daha başarılı sistemlerin oluşturabilmesi için derin öğrenme son zamanlarda sıkça üzerine çalışılan bir konu haline gelmiştir.

Najafabadi vd. (2015)'i derin öğrenmeyi, insan beynini son derece karmaşık problemler için gözlem, analiz, öğrenme ve karar verme yeteneğini taklit etmeyi amaçlayan ve denetimsiz veri kullanan bir makine öğrenimi olarak tanımlamışlardır.


Endüstri ve akademik çevrelerdeki kullanıcılar tarafından görüntü sınıflandırmadan, video analizi, konuşma tanıma ve doğal dil öğrenme süreci gibi farklı alanlarda çığır açan gelişmeler elde etmek üzere makineyle öğrenmede GPU'ları (Grafik İşlemci Ünitesi) kullanılmaktadır. Büyük miktarlarda eğitim verilerinden özellik çıkarımı yapabilen sistemler oluşturmak için, çok seviyeli derin sinir ağlarının kullanılması olan derin öğrenme, önemli derecede yatırım ve araştırmanın yapıldığı bir alandır. Gelişen bilgi teknolojileri, hızlı veri toplama ve depolama büyük verilerin oluşumunu sağlamıştır. Büyük verilerden anlamlı bilgiler çıkarmak için yapay zeka yöntemleri her geçen gün gelişmektedir.

Yapay sinir ağları tıpkı insan beyni gibi nöronlardan oluşur. Tüm nöronlar birbirine bağlıdır ve çıktıyı etkilemektedir (Şekil 3.4).



Şekil 3.4 Biyolojik nöron ve biyolojik nöronun matematiksel modeli (İnt.Kyn.2)

Nöronlar giriş, gizli ve çıkış katmanı olarak üç katmana ayrılır. Giriş katmanı giriş verilerini ilk gizli katmana gönderir. Gizli katmanlar girdilerimizde matematiksel hesaplamalar yapar. Yapay sinir ağları oluşturmadaki zorluklardan biri, her bir katman için nöronların sayısının yanı sıra gizli katmanların sayısına da karar vermektir. Çıktı katmanı ise çıktı verilerini fonksiyonlarla döndürerek sonuca ulaşmamızı sağlarlar (Şekil 3.5) (İnt.Kyn.2). Derin Öğrenme, birden fazla gizli katmana sahip yapay sinir ağları olarak ta tanımlanabilir.



Şekil 3.5 Yapay sinir ağı ve derin sinir ağı (Santos vd 2021)

Sinir ağları girdi katmanından bilgi alır, gizli katmanlarda işler ve çıktı katmanında istenen bilgiyi verir. Bununla birlikte, farklı katman türleri vardır. Farklı katmanlar girdilerinde farklı dönüşümler gerçekleştirir ve bazı katmanlar bazı görevler için diğerlerinden daha uygundur.

Havuzlama Katmanı (Pooling Layer), *Maksimum Havuzlama (Max Pooling)*, *Ortalama Havuzlama (Average Pooling)*, Yoğun Katman (Dense Layer), Uzun-Kısa Vadeli Bellek (LSTM), Evrişim Katmanı (Convolutional Layer), Düzleştirme Katmanı (Flatten Layer), Aktivasyon Katmanı (Activation Layer) ve Normalleştirme Katmanı (Normalization Layer) en çok kullanılan katmanlardır.

Keras, derin öğrenme modelleri oluşturmak ve eğitmek için kullanılan yüksek seviyeli bir sinir ağı API'sidir. Keras, özellikle kullanım kolaylığı ve esnekliği ile bilinir ve TensorFlow gibi derin öğrenme kütüphaneleri üzerinde çalışabilir. Keras, bir model tanımlamanın iki yolunu sunar: Sıralı , en sık kullanılan model olup tam bağlantılı yığınlar oluştururken Functional API, çoklu çıktılı modeller, paylaşılan katmanlar gibi karmaşık model mimarileri tasarlamak için kullanılır. Keras'ta model oluşturma en yaygın yollarından biri, sıralı model kullanmaktır. Sıralı model, katmanları bir sırayla ekleyerek basit sinir ağı modelleri oluşturmak için kullanılır. (İnt.Kyn.3).

Eker vd (2023)'i Ormancılık faaliyetleri için yapay zeka ve makine öğrenimi kullanımına yönelik yaptıkları derleme çalışmasında 2017 yılından günümüze bu alanda yapılan çalışmaların hızla arttığını tespit etmişlerdir. Yapılan değerlendirmede ise erişilen

literatüre göre ormancılık alanında otomatik makine öğreniminin (AutoML) henüz yeteri kadar çalışılmadığı sonucuna varmışlardır.

Yapay zeka yöntemleri, artan veri kümeleri ile her geçen gün gelişmekte ve bu alanda yapılan çalışmalar birçok disipline yön vermektedir. Ormanlar gibi çok büyük alanların yönetiminde de uzaktan algılama ve coğrafi bilgi sistemleri ile büyük veri yığınları oluşmaktadır. Bu verilerden anlamlı bilgiler çıkarılabilmesi için yapay zeka teknikleri olan makine öğrenimi ile derin öğrenme algoritma ve modelleri başarılı sonuçlar vermektedir.


Bu çalışmanın materyalleri uzaktan algılama ve coğrafi bilgi sistemlerine dayanmakta olup metot olarak makine öğrenimi algoritmalarının yanı sıra bir derin öğrenme modeli ile de risk tahmini değerlendirilmesi yapılmıştır.

3.3 Çalışma Alanı


Çalışma alanı olarak Balıkesir Orman Bölge Müdürlüğü sorumluluk sahası olan yaklaşık Balıkesir il sınırlarında bulunan alan adalar hariç tutularak belirlenmiştir (Şekil 3.6). Yüzölçümü 14.30 km² olan Balıkesir ili sınırları 39,20° - 40,30° Kuzey paralelleri ve 26,30° - 28,30° Doğu meridyenleri arasında yer alır. Hem Marmara hem de Ege denizine kıyısı bulunan Balıkesir'in Ege kıyılarında Akdeniz iklimi hakimken doğusunda karasal kuzeyinde ise Karadeniz iklimi özellikleri görülmektedir (İnt.Kyn.4).

Balıkesir ili Ayavlık, Edremit, Burhaniye, Gömeç, Havran, İvrindi, Balya, Savaştepe, Bigadiç, Sındırgı, Dursunbey, Kepsut, Susurluk, Manyas, Gönen, Bandırma, Erdek, Marmara ve merkez ilçeleri olan Altıeylül ile Karesi ilçelerinden oluşmakta olup, Çalışma alanı için Marmara ilçesi hariç tutulmuştur.

Çalışma alanı olarak belirlenen ve Balıkesir Orman Bölge Müdürlüğü sorumluluk sahasında kalan alanda 2017 ve 2024 yılları arasında 616 adet yangın gerçekleşmiş olup yıllara göre yangın sayısı ve yanan alan miktarı Şekil 3.7' te gösterilmiştir. Yanan alan miktarı her ne kadar yıllara göre değişse de yangın sayısı geçmişten günümüze artış göstermektedir.



Şekil 3.6 Çalışma alanı lokasyon haritası



Şekil 3.7 Orman yangını istatistikleri (Balıkesir OBM, 2024)

3.4 Veri Seti – I


Eğitim veri seti, bağımsız değişkenleri Topoğrafik, Antropojenik, Vejetasyon ve Meteorolojik üst başlıklarında sınıflandırılmıştır. Tüm veriler açık kaynaklardan temin edildikten sonra Arcmap yazılımında ön işleme adımları uygulanarak haritalandırılmıştır.

Topoğrafik veriler, bakı, eğim, eğrisellik, pürüzlülük ve yükseklik değişkenlerinden oluşmaktadır. Antropojenik veriler, yerleşime uzaklık, yola uzaklık, enerji nakil hatlarına (ENH) uzaklık, nüfus ve yangın yoğunluğu değişkenlerinden oluşmaktadır. Vejetasyon verileri, arazi kullanımı, orman kapalılığı, meşcere türleri ve NDVI bitki indeksinden oluşmaktadır. Meteorolojik veriler, yağış, nem, maksimum sıcaklık, minimum sıcaklık, rüzgâr hızı, potansiyel güneş radyasyonu ve evapotranspirasyondan oluşmaktadır (Çizelge 3.1).

Çizelge 3.1 Orman yangını bağımsız değişkenleri

TOPOĞRAFİK	ANTROPOJENİK	VEJETASYON	METEOROLOJİK
Yükseklik	Yola Uzaklık	Arazi Kullanımı	Min. Sıcaklık
Bakı	Yerleşime Uzaklık	NDVI Bitki İndeksi	Maks. Sıcaklık
Eğim	ENH Uzaklık	Meşcere Tipi	Toprak Nemi
Pürüzlülük	Nüfus Yoğunluğu	Orman Kapalılığı	Rüzgar Hızı
Eğrisellik	Yangın Yoğunluğu		Yağış
			Evapotranspirasyon
			P. Güneş Radyasyonu

Bağımlı değişken olan orman yangınları 2017 ila 2022 yılları arasında mayıstan başlayıp eylül sonuna kadar olan yangınlardan oluşturulmuştur. Çalışma alanı içerisinde bulunan 323 adet yangın var noktasına 348 adet yangın yok noktası eklenerek 670*22 satır*sütundan oluşan eğitim seti oluşturulmuştur (Şekil 3.8).



Şekil 3.8 Orman yangını ateşlenme noktaları (Yıl: 2017-2022; Datum: ITRF, Projeksiyon:UTM 3°)

Orman Genel Müdürlüğünden temin edilen orman yangını koordinatları bu çalışmada kullanılan ateşlenme noktalarını ifade etmektedir. I. Veri setinde sadece ateşlenme noktalarının içinde kaldığı pikseller yangın var olarak ele alınmıştır. (Şekil 3.9).

2017-2022 yılları yangın kayıtları her ne kadar 323'ten fazla olsa da orman yangını ile ilişkilendirilemeyen veya koordinatları hatalı kayıtlar çalışmaya dahil edilmemiştir. Çalışmada kullanılan tüm yangın ateşlenme noktaları geçmiş uydu görüntüleri ve kayıt detayları incelenerek kontrol edilmiştir.

Çalışma alanı içinde gerçekleşmiş yangınlar, yangın sebepleri ve yangın büyüklüklerine bakılmaksızın ateşlenme noktası olarak değerlendirilmiş olup yangın noktasının koordinatlarının içinde bulunduğu piksel yangın var değeri atanmıştır. Yangın koordinatları Orman Genel Müdürlüğü'nden coğrafi koordinat olarak alınmış, UTM projeksiyon koordinatlarına dönüştürülmüştür.




Şekil 3.9 Orman yangını ateşlenme noktası (15 no’lu nokta) ve yanan orman alanı

3.4.1 Topoğrafik Veriler

Literatürde en çok kullanılan topoğrafik veriler, yükseklik, eğim ve bakı olup yüzey pürüzlülüğü ve eğrisellik verileri nadiren kullanılmıştır. Topoğrafik verilerin kaynağı, birimleri ve veri tipleri Çizelge 3.2’de gösterilmiştir.

Çizelge 3.2 Topoğrafik değişkenlerin özellikleri

Topoğrafik Değişkenler	Kaynak	Birim	Veri Tipi
Yükseklik	ASTER-GDEM	Metre	Nümerik
Bakı	ASTER-GDEM	-	Kategorik
Eğim	ASTER-GDEM	Oran	Nümerik
Pürüzlülük	ASTER-GDEM	Oran	Nümerik
Eğrisellik	ASTER-GDEM	Oran	Nümerik/Kategorik




Şekil 3.10 Sayısal yükseklik modeli


Japonya Ekonomi, Ticaret ve Sanayi Bakanlığı (METI) ve Amerika Birleşik Devletleri Ulusal Havacılık ve Uzay Dairesi (NASA), Gelişmiş Uzaydan Gelen Termal Emisyon ve Yansıma Radyometresi (ASTER) Küresel Dijital Yükseklik Modeli (GDEM) kaynak olarak kullanılmıştır. Çalışma alanı sınırları göre kesilerek Arcmap yazılımında görselleştirilmiştir. Aynı yazılım ile TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.10).

Sayısal yükseklik modeli, orman yangınları ile ilgili çalışmalarda en çok kullanılan topoğrafik parametre haline gelmiş olup, birçok araştırmada yangın riski için parametre olarak kullanılmıştır (Satır vd. 2016, Thach vd. 2018, Mohajane vd. 2021, Arif vd. 2021, Tavakkoli vd. 2022).

Bakı Haritası için ASTER-GDEM verisi kaynak olarak kullanılmıştır. Çalışma alanı sınırları göre kesilerek 9 sınıfta Bakı haritası görselleştirilmiştir. Bu haritadan elde edilen piksel değerleri kategorik veri olup nominal yapıdadır. Bakı haritası TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.11).




Şekil 3.11 Bakı haritası



Şekil 3.12 Eğim haritası

ASTER-GDEM kaynak olarak kullanılmıştır. Çalışma alanı sınırları göre kesilerek 5 sınıfta Eğim haritası görselleştirilmiştir. Ancak veri kullanımında yüzdelik eğim verisi kullanılmış olup nümerik veri olarak kullanılmıştır. Eğim haritası TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.12).


Eğim ve bakı değişkenleri sayısal yükseklik modeliyle birlikte orman yangını risk analizlerinde topoğrafik parametre haline gelmiş olup tahminlerde etki değeri en yüksek topoğrafya özellikleridir (Guo vd. 2016, Thach vd. 2018, Zhang vd. 2019, Ghorbanzadeh vd. 2019, Novo vd. 2020, Bjånes vd. 2021, Naderpour vd. 2021, He vd. 2021, Van Le vd.2021, Mohajane vd. 2021, Chen vd. 2021).



Şekil 3.13 Eğrisellik haritası

ASTER-GDEM kaynak olarak kullanılmıştır. Çalışma alanı sınırları göre kesilerek 3 sınıfta eğrisellik haritası görselleştirilmiştir. Ancak veri kullanımında eğrisellik oran değeri olarak kullanılmış olup nümerik veri olarak kullanılmıştır. Eğrisellik haritası TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.13).

Eğrisellik haritası 3 sınıfta gösterimi yapılmış olup bunlar iç bükey, dış bükey ve düz eğimli alanlar olarak adlandırılmıştır. Çalışma alanının yaklaşık %12'sini iç bükey, %10'unu dış bükey ve %78'ini düz eğimli alanların oluşturduğu tespit edilmiştir. Eğrisellik haritaları SYM, Eğim ve Bakı kadar kullanılmamış olsa da risk bazı tahmin çalışmalarında topoğrafik değişken olarak kullanılmıştır (Thach vd. 2018, Ghorbanzadeh vd. 2019, Van Le vd.2021).



Şekil 3.14 Yüzey pürüzlülüğü haritası


ASTER-GDEM kaynak olarak kullanılmıştır. Çalışma alanı sınırları göre kesilerek 5 sınıfta Pürüzlülük haritası görselleştirilmiştir. Ancak veri kullanımında pürüzlülük oran değeri verisi kullanılmış olup nümerik veri olarak kullanılmıştır. Pürüzlülük haritası TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.14). Yüzey pürüzlülüğü diğer topoğrafik değişkenler kadar olmasa da bazı risk tahmini amaçlı çalışmalarda kullanılmıştır(Zhang vd. 2019, Bjånes vd. 2021).

3.4.2 Antropojenik veriler

Literatürde orman yangınları risk tahmini için hazırlanan tarihsel veri setlerinde en çok kullanılan antropojenik değişkenlerin başında yol ve yerleşim alanlarına uzaklık gelmekte, sonrasında da nüfus dağılımı, yangın yoğunluğu ve ENH'ye uzaklık gibi antropojenik değişkenler kullanılmaktadır. Antropojenik değişkenlerin özellikleri Çizelge 3.3'de gösterilmiştir.


Çizelge 3.3 Antropojenik değişkenlerin özellikleri

Antropojenik Değişkenler	Kaynak	Birim	Veri Tipi
Yola Uzaklık	Open Street Map- Vektör veri	Metre	Numerik
Yerleşime Uzaklık	Open Street Map- Vektör veri	Metre	Numerik
ENH'na Uzaklık	Open Street Map- Vektör veri	Metre	Numerik
Nüfus Yoğunluğu	GEE Katalog-World-pop	Oran	Numerik
Yangın Yoğunluğu	OGM	Oran	Numerik



Şekil 3.15 Yola uzaklık haritası


Yola uzaklık haritası için Open Street Map kaynağından il, ilçe ve mahalle yolları temin edilerek 6 sınıfta görselleştirilmiştir. Bu harita verileri aralıklı numerik verilerdir. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.15).




Şekil 3.16 Yerleşime uzaklık haritası

Yerleşime uzaklık haritası için Open Street Map kaynağından il, ilçe ve mahalle yerleşim alanları temin edilerek 7 sınıfta görselleştirilmiştir. Bu harita verileri aralıklı numerik verilerdir. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.16).

Yerleşime uzaklık haritası için Open Street Map kaynağından enerji nakil hatları ve enerji iletim hatları temin edilerek mesafe olarak görselleştirilmiştir. Bu harita verileri sürekli numerik verilerdir. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.17).




Şekil 3.17 Enerji nakil hatlarına uzaklık haritası



Şekil 3.18 Nüfus yoğunluğu haritası

Nüfus yoğunluğu haritası için Google Earth Engine aracılığıyla WorldPop Küresel Proje Nüfus verileri temin edilerek piksel başına düşen nüfus olarak görselleştirilmiştir. Bu harita verileri sürekli numerik verilerdir. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örnekleme tekniği ile 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir (Şekil 3.18).

Yangın yoğunluğu haritası Orman Genel Müdürlüğünden temin edilen 2017-2022 yılları arasında gerçekleşmiş orman yangınlarına ait koordinat değerlerinden Arcmap yazılımında yoğunluk haritası olarak 5 sınıfta görselleştirilmiştir. Veri kullanımında sürekli nümerik veri olarak kullanılıp Arcmap yazılımı ile TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde 30m*30m mekânsal çözünürlük ile 1 adet üretilmiştir (Şekil 3.19).



Şekil 3.19 Yangın yoğunluğu haritası


3.4.3 Vejetasyon verileri

Literatürde en çok kullanılan vejetasyon değişkenleri sırasıyla, NDVI ve Arazi Kullanımı/Örtüsü sonrasında ise orman kapalılığı ve meşcere tipi değişkenleri gelmektedir (Çizelge 3.4)

Çizelge 3.4 Vegetasyon değişkenlerinin özellikleri

Vejetasyon Değişkenleri	Kaynak	Birim	Veri Tipi
Arazi Kullanımı	CORINE	-	Kategorik
Orman Kapalılığı	OGM	-	Kategorik-Ordinal
Meşcere Tipi	OGM	-	Kategorik
NDVI	SENTINEL	Oran	Nümerik


CORINE (Coordination of Information on the Environment) Çevresel Bilginin Koordinasyonu, Avrupa Çevre Ajansı tarafından belirlenen Arazi Örtüsü/Kullanımı Sınıflandırmasına göre uydu görüntüleri üzerinden bilgisayar destekli görsel yorumlama metodu ile üretilen arazi örtüsü/kullanımını verisi kaynak olarak kullanılmış olup 5 sınıfta görselleştirilmiştir. Veri GEE aracılığıyla temin edilmiş olup kategorik ve nominal yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örneklem tekniği kullanılarak 30m*30m mekânsal çözünürlük ile 1 adet üretilmiştir (Şekil 3.20).



Şekil 3.20 Arazi kullanımı/Arazi örtüsü haritası


Orman yangını risk tahmini çalışmalarında en çok kullanılan vejetasyon değişkenleri AK/AÖ ve NDVI olduğu literatürde görülmektedir.

Orman kapalılığı haritası Orman Genel Müdürlüğünün güncel amenajman planlarına göre hazırlanmış meşcere haritalarından temin edilerek 4 sınıfta görselleştirilmiştir. Veri kategorik ve ordinal yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlük ile 1 adet üretilmiştir (Şekil 3.21).




Şekil 3.21 Orman kapalılığı haritası

Meşcere tipi haritası OGM' nün güncel amenajman planlarına göre hazırlanmış meşcere haritalarından temin edilerek Arcmap yazılımında 4 sınıfta görselleştirilmiştir. Veri kategorik ve nominal yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlük ile 1 adet üretilmiştir (Şekil 3.22).



Şekil 3.22 Meşcere tipi haritası



Şekil 3.23 NDVI bitki indeksi haritası

NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi) bitki indeksi GEE map aracılığıyla SENTINEL uydu görüntüsünden temin edilmiş olup harita piksel değerleri nümerik ve sürekli yapıdadır. Arcmap yazılımı ile TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örneklem tekniği kullanılarak 30m*30m mekânsal çözünürlük ile mayıs ve haziran ayı ortalaması için bir, temmuz, ağustos ve eylül aylarının ortalaması için de 1 olmak üzere toplam 2 adet üretilmiştir. (Şekil 3.23).

3.4.4 Meteorolojik veriler


Literatürde orman yangınları için risk tahmini çalışmalarında meteorolojik değişkenlerde gece ve gündüz sıcaklıkları, rüzgar hızı, yağış oranları, hava ve toprak nemi gibi değişkenler sıklıkla kullanılmaktadır. Bu çalışmada gerçek evapotranspirasyon ve potansiyel güneş radyasyonu değişkenleri de analiz edilmiştir (Çizelge 3.5).

Çizelge 3.5 Meteorolojik değişkenlerinin özellikleri


Meteorolojik Değişkenleri	Kaynak	Birim	Veri Tipi
Minimum Sıcaklık	Terra Climate	C°	Nümerik
Maksimum Sıcaklık	Terra Climate	C°	Nümerik
Toprak Nemi	Terra Climate	mm	Nümerik
Rüzgar Hızı	Terra Climate	m/s	Nümerik
Yağış	Terra Climate	mm	Nümerik
Evapotranspirasyon	Terra Climate	mm	Nümerik
P. Güneş Radyasyonu	ASTER-GDEM	W/ m ²	Nümerik

Minimum sıcaklık haritası GEE aracılığıyla Terra Climate Küresel Karasal Yüzeyler için Aylık İklim ve İklimsel Su Dengesi, verilerinden mayıstan eylüle kadar her ay için aylık ortalama olmak üzere 2017-2023 arasında toplam 35 adet veri temin edilerek Arcmap yazılım ile ön işleme yapılarak görselleştirilmiştir. Veri nümerik ve sürekli yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örneklem tekniği kullanılarak 30m*30m mekânsal çözünürlük ile 35 adet üretilmiştir.


Makine Öğrenimi ile risk tahmininde 2017-2022 yılları arası veriler, Derin öğrenme risk tahmini için ise 2017-2023 yılları arası verilerin tamamı kullanılmıştır (Şekil 3.24).



Şekil 3.24 Minimum sıcaklık haritası




Şekil 3.25 Maksimum sıcaklık haritası




Şekil 3.27 Rüzgar hızı haritası

Rüzgar hızı haritası GEE aracılığıyla TerraClimate: Küresel Karasal Yüzeyler için Aylık İklim ve İklimsel Su Dengesi, verilerinden mayıstan eylüle kadar her ay için aylık ortalama olmak üzere 2017-2023 arasında toplam 35 adet veri temin edilerek görselleştirilmiştir. Veri nümerik ve sürekli yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örneklem tekniği kullanılarak 30m*30m mekânsal çözünürlük ile 35 adet üretilmiştir. Makine Öğrenimi ile risk tahmininde 2017-2022 yılları arası veriler, Derin öğrenme risk tahmini için ise 2017-2023 yılları arası verilerin tamamı kullanılmıştır (Şekil 3.27).

Yağış haritası GEE aracılığıyla TerraClimate: Küresel Karasal Yüzeyler için Aylık İklim ve İklimsel Su Dengesi, verilerinden mayıstan eylüle kadar her ay için aylık ortalama olmak üzere 2017-2023 arasında toplam 35 adet veri temin edilerek görselleştirilmiştir. Veri nümerik ve sürekli yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örneklem tekniği kullanılarak 30m*30m mekânsal çözünürlük ile 35 adet üretilmiştir. Makine Öğrenimi ile risk tahmininde 2017-2022 yılları arası veriler, Derin öğrenme risk tahmini için ise 2017-2023 yılları arası verilerin tamamı kullanılmıştır (Şekil 3.28).




Şekil 3.28 Yağış haritası



Şekil 3.29 Evapotranspirasyon haritası

Evapotranspirasyon haritası GEE aracılığıyla TerraClimate: Küresel Karasal Yüzeyler için Aylık İklim ve İklimsel Su Dengesi, verilerinden mayıstan eylüle kadar her ay için aylık ortalama olmak üzere 2017-2023 arasında toplam 35 adet veri temin edilerek görselleştirilmiştir. Veri nümerik ve sürekli yapıdadır. Harita TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde ve yeniden örneklem tekniği kullanılarak 30m*30m mekânsal çözünürlük ile 35 adet üretilmiştir. Makine Öğrenimi ile risk tahmininde 2017-2022 yılları arası veriler, Derin öğrenme risk tahmini için ise 2017-2023 yılları arası verilerin tamamı kullanılmıştır (Şekil 3.29).



Şekil 3.30 Potansiyel güneş radyasyonu haritası

Potansiyel Güneş Radyasyonu Haritası, ASTER-GDEM verisi kullanılarak hazırlanmıştır. Veri nümerik ve kesikli yapıdadır. Çalışma alanı sınırları göre kesilerek Arcmap yazılımında görselleştirilmiştir. Aynı yazılım ile TUREF(DATUM: ITRF PROJEKSİYON: UTM 3°) koordinat sisteminde ve 30m*30m mekânsal çözünürlüklü 1 adet üretilmiştir. (Şekil 3.30).

3.4.5 Veri Seti Analizi

Veri seti Topoğrafik, Antropojenik, Vejetasyon ve Meteorolojik üst başlıklarında olmak üzere toplam 21 adet bağımsız değişkenden ve yangın var/yok noktaları olan 1 adet bağımlı değişkenden oluşmaktadır (Çizelge 3.6).

Veri seti için veri toplama ve ön işleme adımları Arcmap yazılımında tamamlandıktan sonra aynı koordinat sisteminde aynı mekânsal çözünürlükte hazırlanmış bağımsız değişkenler ait haritalar üzerine çakıştırılan yangın var/yok noktaları ile 670 pikselden değer çıkarımı yapılarak veri seti 670*22 satır sütun olarak hazır hale getirilmiştir.

Veri setindeki değişkenlere ait verilerin normal dağılımlı olmaması bazı algoritmaların çalışmasını etkileyen bir faktör olup Veriler sağa yatık, ya da sola yatıksa, model performansı bu durumdan etkilenebilir (Şekil 3.31). Bu durumda değerleri normal hale getirmek ve baskınlığı azaltmak için Özellik Ölçekleme (Feature Scaling) yöntemi olan standardizasyon kullanılmıştır.

```
standard_scaler = StandardScaler()
```

```
X_standardized = standard_scaler.fit_transform(X)
```

Makine öğreniminde modelin çalışabilmesi için kategorik verilerin sayısal anlamda dönüştürülmesi gerekmektedir. Encoding (karakter kodlaması) değişkenlerin temsil şekilleri ile ilgili değişiklikler yapmaktır. Bu çalışmada da dummy encoder kullanılarak kategorik değişkenlerin temsili değiştirilmiştir.


```
cat_cols = ["Baki", "Arazi_Kullanım", "Kapalılık"]
```

```
X = pd.get_dummies(X, columns=cat_cols, drop_first=True)
```

Çizelge 3.6 Veri seti-I örneği (670*22)

VAR/YOK	1	1	1	1	1	1	0	1	0	0	0	0	0	0
P_Gunes_Rad	1230765	1092007	1210125	1210862	1199037	936179	1268250	1419847	1023393	1186355	1268250	1186355	1016714	
Minumum_S	20.08	20.15	19.32	18.97	19.23	19.13	18.86	18.06	20.36	20.45	18.22	20.5	20.24	
Maksmim_S	33.05	33	32.98	32.9	32.84	32.8	32.74	32.53	32.46	32.4	32.27	32.27	32.26	
Yagis	2.9928	14.253	7.2158	7.9066	5.1096	8.7025	51.502	3	43.049	3.7102	4.5678	63.463	4.0385	
Nem	83.8151	69.3231	53.4153	45.2808	57.787	48.9567	33.228	26.7614	55.0269	52.103	43.3025	53.0356	53.9716	
Ruzgar_hizi	3.979	4.0823	3.1202	3.2033	3.2	3.1	2.6	2.5	3.3334	4.9918	3.4352	3.4479	4.9963	
G_Evapotrans	55.7861	41.3054	29.2651	24.2213	31.345	27.2922	56.3011	9.1291	54.7057	16.0604	18.7202	73.4496	17.3193	
Nufus	1.05681	0.47937	0.06127	0.05021	0.59039	0.16018	0.03713	0.04721	0.07757	0.11272	0.03713	0.11272	0.06144	
ENH_uzaklik	1510.76	5469.63	1770	920.272	6714.17	3751.08	150	318.904	4686.53	4920.37	150	4920.37	7334.98	
Yangin_yog	0.059	0.0458	0.028	0.0101	0.0279	0.0272	0.0138	0.0251	0.0273	0.0123	0.0138	0.0123	0.017	
Yol_uzaklik	150	931.93	969.33	800.5	711.2	295.47	1827.1	212.13	848.53	169.71	1827.1	169.71	982.7	
Yerlesim_uza	169.706	872.067	1348.33	2382.12	617.738	2101.07	2586.45	1733.26	1124.5	2142.01	2586.45	2142.01	2838.77	
Mescere	3	4	1	3	1	1	3	3	1	4	3	4	1	
Kapalılık	0	0	3	0	1	2	0	0	3	0	0	0	2	
NDVI	0.48	0.63	0.67	0.35	0.51	0.65	0.17	0.23	0.79	0.25	0.17	0.25	0.74	
Arazi_Kullani	3	2	3	3	3	3	3	3	3	3	3	3	3	
Baki	5	2	2	3	1	2	4	6	2	3	4	3	3	
Egrisellik	0.5556	-0.111	0	1.8889	-0.667	-0.667	0.3333	1.3333	-0.778	1.4444	0.3333	1.4444	1.5556	
Yukseklık	296	186	258	531	263	175	283	657	349	169	283	169	304	
Egim	27.048	12.756	4.3154	11.945	7.8962	21.761	5.571	13.783	5.259	7.454	5.571	7.454	21.518	
Puruzluluk	0.414	0.432	0.5	0.57	0.325	0.484	0.578	0.456	0.284	0.648	0.578	0.648	0.452	


Veri seti analizi için veri görselleştirme yöntemleri olan histogramlar, kartiller, korelasyon matrisi ve korelasyon ısı haritası oluşturularak verilerin dağılımı, aykırı değerleri tespit edilerek veri seti kullanılabilir hale getirilmiştir (Şekil 3.31, 32, 33, 34, 35, 36, 37). Veri görselleştirmesi Google colab ara yüzü ve python yazılım dili kullanılarak yapılmıştır.



Şekil 3.31 Veri seti histogramları


Histogramlar veri setinde bulunan gözlem değer aralığını kutu (bins) adı verilen eşit parçalara bölüp, eşit genişliklere sahip sütunlar olarak görselleştirir ve kutunun yüksekliği, kutu içerisindeki gözlem sayısına bağlıdır (Şekil 3.31).

Veri görselleştirmede kullanılan başka bir yöntem olan kutu grafiği aykırı değerleri analiz etmek için kullanılır. Veri setindeki değer aralığını ardışık olarak sıralayıp 4 adet çeyreklik dilimlere böler. Şekil 3.32’da gösterildiği gibi sol kenar 1. çeyrekliği sağ kenar ise 3. çeyreklik sınırını gösterir. 3 ve 1. çeyreklikler arasındaki fark çeyrekler açıklığını gösterir. Bu açıklık değerinin 1.5 katı ise aykırı değer sınırlarını belirlememizi sağlar.




Şekil 3.32 Kartiller-Aykırı Değer Analizi


Veri seti analizi için veri görselleştirme teknikleri kullanımında, veri setindeki aykırı değerleri ve veri ortalama değerlerini çeyreklikler yardımıyla ortaya konulmakta ve veri seti düzenlenmesi yapılmaktadır (Şekil 3.32).



Şekil 3.33 Veri seti çeyreklikleri-I




Şekil 3.34 Veri seti çeyreklikleri-II



Şekil 3.35 Veri seti çeyreklikleri-III

Korelasyon matrisi, veri kümelerinde ki ilişkileri gösteren bir veri görselleştirme tekniği olup her bir değişken çifti arasındaki korelasyonları gösteren bir matristir. Korelasyon matrisi, iki veya daha fazla değişkenin birbiriyle nasıl ilişkili olduğunun hakkında bilgi veren gösterimdir (Şekil 3.36).

Korelasyon ısı haritası da bir başka veri görselleştirme tekniği olup her iki değişken çifti arasındaki ilişkinin kuvveti ve yönü hakkında bilgiler verir. Bu yöntem renklendirilme sayesinde çok değişkenli çapraz verileri incelemek için kullanışlıdır. Isı haritaları, birden fazla değişkenin gösterilmesi, örüntünün ortaya çıkması veya değişkenlerin birbirleriyle benzerliğinin gösterilmesini sağlarlar (Şekil 3.37).



Şekil 3.37 Veri seti korelasyon ısı haritası

Korelasyon ısı haritası incelendiğinde birbirine benzerliği en yüksek değişkenlerin yola uzaklık-yerleşime uzaklık, maksimum sıcaklık-minimum sıcaklık, Yağış- Evapotranspirasyon değişkenleri arasında olduğu görülmektedir.

Topoğrafik veriler ile orman yangınları arasındaki ilişkiler incelendiğinde en yüksek korelasyon yükseklik değişkeni ile sağlandığı ve negatif yönlü olduğu görülmektedir. Diğer topoğrafik değişkenler korelasyon kuvvetine göre sırasıyla eğim ile negatif yönlü, bakı, eğrisellik ile negatif yönlü ve pürüzlülük ile pozitif yönlü olarak tespit edilmiştir. Eğrisellik ve Pürüzlülük değişkenlerinin korelasyon kuvveti çok düşük olup risk tespitlerinden öte yangın sırasındaki yangın davranışlarında daha etkili olacağı düşünülmektedir.

Vejetasyon verilerine bakıldığında yangınlar ile en yüksek korelasyonu arazi kullanımı sonrasında kuvvet sırasıyla kapalılık, NDVI ve meşcere tipi şeklinde sıralandığı görülmekte olup en düşük korelasyon meşcere tipi değişkeninde olduğu görülmüştür.

Antropojenik verilerin içinde en yüksek korelasyon yola uzaklık ve yangın yoğunluğu değişkenleri olup sonrasında kuvvet sırasıyla yerleşime uzaklık, nüfus yoğunluğu ve ENH uzaklık değişkenleri olarak tespit edilmiştir.

Meteorolojik veriler kendi arasında incelendiğinde ise maksimum-minimum sıcaklıklar, yağış ve nem en yüksek korelasyona sahiptir. Diğer meteorolojik değişkenlerin korelasyon kuvvetleri ise sırasıyla potansiyel güneş radyasyonu, rüzgar hızı ve evapotranspirasyon değişkenleri olduğu tespit edilmiştir.

Genel olarak bakıldığında en yüksek korelasyona sahip ilk üç değişken antropojenik değişkenler olup Yangın yoğunluğu pozitif yönde, Yola uzaklık negatif yönde ve Yerleşime uzaklık negatif yönde olmak üzere sıralanmıştır. Sonrasında göze çarpan korelasyonlar Arazi kullanımı, Kapalılık ve NDVI değişkenleri olup bunlarda vejetasyon kategorisindeki değişkenlerdir. Kategorik olarak bakıldığında veri setindeki yangınların korelasyonları öncelikle antropojenik değişkenlerle sonrasında ise vejetasyon, meteorolojik ve son olarak topoğrafik değişkenlerle ilişkili olduğu ortaya çıkmıştır (Çizelge 3.7).

Çizelge 3.7 Bağımsız değişkenlerin orman yangınları ile korelasyonları (I.verİ seti)

DEĞİŞKENLER	KORELASYONLAR
	Orman Yangın Noktaları (Var/Yok)
Pürüzlülük	-0.004076
Eğim	-0.157820
Yükseklik	-0.214795
Eğrisellik	-0.019051
Bakı	0.122806
Arazi Kullanımı	-0.373902
NDVI	-0.312829
Orman Kapallığı	-0.357855
Meşcere Tipi	0.067613
Yerleşim Uzaklık	-0.401605
Yol Uzaklık	-0.426693
Yangın Yoğunluğu	0.430101
ENH Uzaklık	-0.136794
Nüfus yoğunluğu	0.187644
Gerçek Evapotranspirasyon	-0.115613
Rüzgar Hızı	0.118309
Toprak Nemi	-0.270663
Yağış	-0.343116
Maksimum Sıcaklık	0.467118
Minimum Sıcaklık	0.281652
Potansiyel Güneş Radyasyonu	0.139177
Orman Yangın Noktaları (Var/Yok)	1.000000

3.5 Makine Öğrenimi ile Risk Tahmini

Uzaktan algılama teknikleri kullanılarak hazırlanan veri seti python yazılım dili ile bulut tabanlı Google Colab ara yüzünde analizleri yapıldıktan sonra veri seti bölünerek %80 eğitim aşamasında %20 de test aşamasında kullanılmak üzere bölünerek Makine Öğrenimi modelleri için eğitim ve testler yapılmıştır.


Makine öğrenimi ile risk tahmini için hazırlanan veri seti analizleri yapıldıktan sonra literatürde de sınıflandırma çalışmalarında sıklıkla kullanılan Decision Tree (Karar Ağaçları), CART (Classification & Regression Tree), Destek Vektör Makineleri (Support Vector Machine), Naive Bayes Classifier, Çok Katmanlı Algılayıcılar (Multi Layer Perceptron (MLP), Aşırı Gradyan Artırma (Extreme Gradient Boosting) ve Rastgele Orman algoritmaları ile eğitimler yapılmış ve eğitim doğruluk metrikleri hesaplanmıştır.

3.5.1 Model Seçimi

Karar Ağaçları algoritması ile yapılan eğitim sonrası test doğruluğu 0,89 da kalmış olup diğer modellerden daha düşük performans göstermiştir. Ayrıca veri setindeki bağımsız değişkenlerin etki dağılımının az olduğu için model seçiminde bu algoritma elenmiştir (Şekil 3.38).

Çizelge 3.8 Karar ağaçları doğruluk metrikleri

Decision Tree Metrics	
Accuracy	0.89
Precision	0.93
Recall (Sensitivity)	0.87
Specificity	0.92
F1 Score	0.90
K-Index	1.02




Şekil 3.38 Verilerin modele etkisi (Karar ağaçları)

Sınıflandırma ve Regresyon ağaçları algoritması ile yapılan eğitim sonrası test doğruluğu 0,89 da kalmış olup diğer modellerden daha düşük performans göstermiştir. Ayrıca veri setindeki bağımsız değişkenlerin etki dağılımının az olduğu için model seçiminde bu algoritma elenmiştir (Şekil 3.39).

Çizelge 3.9 CART (Classification & Regression Tree)

Classification & Regression Tree Metrics	
Accuracy	0.89
Precision	0.94
Recall (Sensitivity)	0.85
Specificity	0.93
F1 Score	0.90
K-Index	1.01



Şekil 3.39 Verilerin modele etkisi (Sınıflandırma ve regresyon ağaçları)

Destek Vektör Makineleri 0,84, Naive Bayes sınıflandırıcı 0,65 ve Çok Katmanlı Algılayıcı algoritması 0,83 test doğrulukları ile model seçimi aşamasında elenmiştir. Model seçimi kısmında ilk 5 algoritma olan Karar Ağaçları, Sınıflandırma ve Regresyon ağaçları, Destek Vektör Makineleri, Naive Bayes sınıflandırıcı ve Çok Katmanlı Algılayıcı algoritmaları diğer algoritmalarda daha düşük test doğruluğunda olması ve bağımsız değişkenlerin etki öneminin kısıtlı kalması sebebiyle model olarak kullanılmamasına karar verilen makine öğrenimi algoritmaları olmuşlardır.

Çizelge 3.10 Destek vektör makineleri (Support Vector Machine)

Support Vector Machine Metrics	
Accuracy	0.84
Precision	0.90
Recall (Sensitivity)	0.80
Specificity	0.88
F1 Score	0.85
K-Index	1.00

Çizelge 3.11 Naive bayes sınıflandırıcısı

Naive Bayes Classifier Metrics	
Accuracy	0.65
Precision	0.94
Recall (Sensitivity)	0.40
Specificity	0.97
F1 Score	0.56
K-Index	0.92


Çizelge 3.12 Çok katmanlı algılayıcılar (Multi layer perceptron (MLP))

Multi Layer Perceptron Metrics	
Accuracy	0.83
Precision	0.88
Recall (Sensitivity)	0.80
Specificity	0.87
F1 Score	0.84
K-Index	1.02

Aşırı Gradyan Artırma Algoritması 0.95 test doğruluğu ile en yüksek test doğruluğuna sahip algoritma olup risk tahmini için model olarak kullanılacak makine öğrenimi algoritmasıdır. Bağımsız değişkenlerin etki sıralaması ise Yola uzaklık, Arazi kullanımı 2-3, minimum sıcaklık, yağış, Kapalılık-1, Yangın yoğunluğu, Evapotranspirasyon, Yükseklik, Bakı-6, NDVI, Maksimum sıcaklık, Nem, Kapalılık 3, Yerleşime uzaklık, Rüzgar hızı, kapalılık-2, bakı-8, nüfus, Bakı-4, Potansiyel güneş radyasyonu, ENH uzaklık, Meşcere 3, Eğim, Bakı 3,5, Eğrisellik ve pürüzlülük şeklinde olup duyarlılık değeri 0.93 olarak tespit edilmiştir (Şekil 3.40).

Çizelge 3.13 Aşırı gradyan artırma (Extreme Gradient Boosting)

Extreme Gradient Boosting Metrics	
Accuracy	0.95
Precision	0.97
Recall (Sensitivity)	0.93
Specificity	0.97
F1 Score	0.95
K-Index	1.01




Şekil 3.40 Verilerin modele etkisi (Aşırı gradyan artırma)

Rastgele Orman algoritması ile eğitilen veri seti için test doğruluğu 0.94 olarak belirlenmiş ve Aşırı Gradyan Artırma algoritmasından sonra ikinci yüksek doğruluğa sahip model olmuştur. Bağımsız değişkenlerin etki dağılımı ise tüm algoritmalara göre daha geniş olduğu görülmektedir. Bağımsız değişkenlerin etki sıralaması Yola uzaklık, Yangın yoğunluğu, yağış, yerleşime uzaklık, minimum sıcaklık, nüfus, NDVI, Maksimum sıcaklık, Evapotranspirasyon, Toprak nemi, Rüzgar hızı, Arazi kullanımı 3-2, Yükseklik, Potansiyel güneş radyasyonu, ENH uzaklık, Eğim, Pürüzlülük, Meşcere 2, Kapalılık 3, Eğrisellik, Kapalılık 1 şeklinde olup duyarlılık değeri 0.92 olarak tespit edilmiştir (Şekil 3.41).

Çizelge 3.14 Rastgele orman (Random forest)

Random Forest Metrics	
Accuracy	0.94
Precision	0.97
Recall (Sensitivity)	0.92
Specificity	0.97
F1 Score	0.95
K-Index	1.01



Şekil 3.41 Verilerin modele etkisi

Doğrulama Ölçütleri: Bu çalışmada makine öğrenimi algoritmalarının tahminleri için, doğruluk oranı, kesinlik, duyarlılık, özgüllük ve F1 skoru performans ölçütleri kullanılmıştır. Tüm algoritmalar bu ölçütlerle değerlendirilmiş olup bu ölçütlerle beraber kullanılan k-indeksi de eklenmiştir. Sınıflandırma model tahminlerinde değerlendirme ölçütleri, Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri üzerinden hesaplanmaktadır (Çizelge 3.15)(Deperlioğlu ve Köse 2024).

Çizelge 3.15 Sınıflandırma modeli için karışıklık matrisi

		Tahmin	
		Orman Yangını Var	Orman Yangını Yok
Gerçek Değer	Orman Yangını Var	DP	YP
	Orman Yangını Yok	YN	DN

$$\text{Doğruluk : } Doğruluk = (DP + DN) / (DP + YP + YN + DN) \quad (3.2)$$

$$\text{Kesinlik : } Kesinlik = DP / (DP + YP) \quad (3.3)$$

$$\text{Duyarlılık: } Duyarlılık = DP / (DP + YN) \quad (3.4)$$

$$\text{Özgüllük : } Özgüllük = DN / (YP + DN) \quad (3.5)$$

$$\text{F1 Puanı : } F1 \text{ skoru} = 2 * (Kesinlik * Duyarlılık) / (Kesinlik + duyarlılık) \quad (3.6)$$

Yukarıda formülleri gösterilmiş değerlendirme ölçütleri her algoritma için hesaplanmış olup Çizelge 3.16’da ulaşılan metrikler verilmiştir.

Çizelge 3.16 Doğrulama ölçütleri

	Doğruluk (Accuracy)	Kesinlik (Precision)	Duyarlılık (Sensitivity)	Özgüllük (Specificity)	F1 Skoru (F1 Score)
KA (DT)	0.89	0.93	0.87	0.92	0.90
SRA (CART)	0.89	0.94	0.85	0.93	0.90
DVM (SVM)	0.84	0.90	0.80	0.88	0.85
Naive Bayes	0.65	0.94	0.40	0.97	0.56
ÇKA (MLP)	0.83	0.88	0.80	0.87	0.84
AGA (XGBoost)	0.95	0.97	0.93	0.97	0.95
RO (RF)	0.94	0.97	0.92	0.97	0.95

3.6 Veri Seti -II

II Veri seti bağımsız değişkenleri I. Veri setinde de kullanılan Topoğrafik, Antropojenik, Vejetasyon ve Meteorolojik üst başlıklarından oluşmaktadır. Topoğrafik veriler, Bakı, Eğim, Eğrisellik, Pürüzlülük ve Yükseklik değişkenlerinden, Antropojenik veriler, yerleşime uzaklık, yola uzaklık, ENH uzaklık, nüfus ve yangın yoğunluğu değişkenlerinden, Vejetasyon verileri, arazi kullanımı, orman kapalılığı, meşcere türleri ve NDVI bitki indeksinden, Meteorolojik veriler, yağış, nem, maksimum sıcaklık, minimum sıcaklık, rüzgar hızı, potansiyel güneş radyasyonu ve evapotranspirasyondan oluşmaktadır (Çizelge 3.17).

Çizelge 3.17 Orman yangını bağımsız değişkenleri

TOPOĞRAFİK	ANTROPOJENİK	VEJETASYON	METEOROLOJİK
Yükseklik	Yola Uzaklık	Arazi Kullanımı	Min. Sıcaklık
Bakı	Yerleşime Uzaklık	NDVI Bitki İndeksi	Maks. Sıcaklık
Eğim	ENH Uzaklık	Meşcere Tipi	Toprak Nemi
Pürüzlülük	Nüfus Yoğunluğu	Orman Kapalılığı	Rüzgar Hızı
Eğrisellik	Yangın Yoğunluğu		Yağış
			Evapotranspirasyon
			P.Güneş Radyasyonu


II. Veri seti oluşturmanın ilk amacı I. Veri seti Derin öğrenme algoritması ile kullanıldığında Rastgele Orman ve Aşırı Gradyan Artırma algoritmalarının test doğruluk değerine ulaşamadığından daha çok veriye ihtiyaç duyulması, ikinci amacı ise Şekil 3.42 de görüldüğü gibi tek bir ateşlenme noktasından başlayan fakat sonrasında bağımsız değişken etkileriyle farklı konumlara taşınan yangınlarında veri setine dahil edilmesi olmuştur. Bu sebepler ile I. Veri setinde kullanılan yangın ateşlenme noktalarına, 2023 yılı yangınlarının eklenmesinin yanı sıra, Şekil 3.43'deki gibi parçalı ve büyük yangın alanlarında, yanmış alanda kalan her piksele yangın var değeri atayarak 2100*22 satır sütuna sahip II. Veri seti oluşturulmuştur (Şekil 3.42).

Bağımlı değişken olan orman yangınları 2017 ila 2023 yılları arasında mayıstan başlayıp eylül sonuna kadar olan yangınlardan oluşturulmuştur. Çalışma alanı içerisinde bulunan

1098 adet yangın var noktasına 1002 adet yangın yok noktası eklenerek 2100*22 satır*sütundan oluşan eğitim seti oluşturulmuştur (Çizelge 3.18). Orman Genel Müdürlüğünden temin edilen orman yangını koordinatları ve bu koordinatlardaki birden fazla pikselde kalan tüm yanmış alanlar II. Veri setini oluşturmuştur.



Şekil 3.42 Orman yangını sıçraması




Şekil 3.43 Orman Yangını noktaları

3.6.1 Veri Seti Analizi

II. Veri seti Topoğrafik, Antropojenik, Vejetasyon ve Meteorolojik üst başlıklarında olmak üzere toplam 21 adet bağımsız değişkenden ve yangın var/yok noktaları olan 1 adet bağımlı değişkenden oluşmaktadır.

Veri Setindeki değişkenlere ait verilerin normal dağılımlı olmaması bazı algoritmaların çalışmasını etkileyen bir faktör olup veriler sağa yatık, ya da sola yatık, model performansı bu durumdan etkilenebilir (Şekil 3.44). Bu durumda değerleri normal hale getirmek ve baskınlığı azaltmak için Özellik Ölçekleme (Feature Scaling) yöntemi olan standardizasyon kullanılmıştır. Bu veri seti Derin Öğrenme algoritmasında kullanılacağından dolayı kategorik verilerde karakter kodlaması yapılmamıştır.


Veri seti analizi için veri görselleştirme yöntemleri olan histogramlar, korelasyon matrisi ve korelasyon ısı haritası oluşturularak verilerin dağılımı, aykırı değerleri tespit edilerek veri seti kullanılabilir hale getirilmiştir (Şekil 3.44, 45, 46 ,47). Veri görselleştirmesi Google colab ara yüzü ve python yazılım dili kullanılarak yapılmıştır.



Şekil 3.44 Veri seti histogramları-I

Genel olarak bakıldığında en yüksek korelasyona sahip değişkenler yağış, gerçek evapotranspirasyon, yola uzaklık, yerleşime uzaklık, yangın yoğunluğu, orman kapallılığı ve NDVI olarak ortaya çıkmıştır (Çizelge 3.19). II. veri setinde yangın ateşlenme noktası yerine

yanan alanlar kullanıldığı için korelasyon kuvvetlerindeki değişim göze çarpmaktadır. Bu durum bazı değişkenlerde pozitif yönde etki ederken bazı değişkenlerde ise korelasyon kuvvetinin azlamasına sebep olmuştur.



Şekil 3.45 Veri seti histogramları-II

Çizelge 3.19 Bağımsız değişkenlerin orman yangınları ile korelasyonu

DEĞİŞKENLER	KORELASYONLAR
	Orman Yangın Noktaları (Var/Yok)
Pürüzlülük	-0.076463
Eğim	-0.158434
Yükseklik	-0.336395
Eğrisellik	-0.009311
Bakı	0.177351
Arazi Kullanımı	-0.241905
NDVI	-0.429743
Orman Kapalılığı	-0.407809
Meşcere Tipi	0.021685
Yerleşim Uzaklık	-0.541430
Yol Uzaklık	-0.604938
Yangın Yoğunluğu	0.577469
ENH Uzaklık	-0.304359
Nüfus yoğunluğu	0.288150
Gerçek Evapotranspirasyon	-0.563584
Rüzgar Hızı	0.205452
Toprak Nemi	-0.095125
Yağış	-0.668111
Maksimum Sıcaklık	0.294737
Minimum Sıcaklık	0.239056
Potansiyel Güneş Radyasyonu	0.129745
Orman Yangın Noktaları (Var/Yok)	1.000000

Korelasyon ısı haritası incelendiğinde birbirine benzerliği en yüksek değişkenlerin yola uzaklık-yerleşime uzaklık, maksimum sıcaklık-minimum sıcaklık, Yağış-Evapotranspirasyon, Maksimum sıcaklık-Minimum sıcaklık değişkenleri arasında olduğu görülmektedir.

Topoğrafik veriler ile orman yangınları arasındaki ilişkiler incelendiğinde en yüksek korelasyon yükseklik değişkeni ile sağlandığı ve negatif yönlü olduğu görülmektedir. Diğer topoğrafik değişkenler korelasyon kuvvetine göre sırasıyla bakı, eğim ile negatif yönlü, pürüzlülük ile negatif yönlü ve eğrisellik ile de negatif yönlü olarak tespit edilmiştir. Eğrisellik ve pürüzlülük değişkenlerinin korelasyon kuvveti çok düşük olup risk tespitlerinden öte yangın sırasındaki yangın davranışlarında daha etkili olacağı düşünülmektedir.

Vejetasyon verilerine bakıldığında yangınlar ile en yüksek korelasyonu NDVI sonrasında kuvvet sırasıyla kapalılık, arazi kullanımı ve meşcere tipi şeklinde sıralandığı görülmekte olup en düşük korelasyon Mescere tipi değişkeninde olduğu görülmüştür.

Antropojenik verilerin içinde en yüksek korelasyon yola uzaklık ve yangın yoğunluğu değişkenleri olup sonrasında kuvvet sırasıyla yerleşime uzaklık, ENH uzaklık ve nüfus yoğunluğu değişkenleri olarak tespit edilmiştir.

Meteorolojik veriler kendi arasında incelendiğinde ise yağış ve evapotranspirasyon değişkenleri en yüksek korelasyona sahiptir. Diğer meteorolojik değişkenlerin korelasyon kuvvetleri ise sırasıyla Maksimum ve Minimum sıcaklık, Rüzgar hızı, potansiyel güneş radyasyonu ve toprak nemi değişkenleri olduğu tespit edilmiştir.

Genel olarak bakıldığında en yüksek korelasyona sahip Antropojenik değişkenler, yangın yoğunluğu, yola uzaklık ve yerleşime uzaklık, vejetasyon kategorisindeki değişkenler NDVI ve kapalılık, Meteorolojik verilerde yağış ve evapotranspirasyon ve son olarak Topoğrafik kategoride yükseklik değişkenidir. Kategorik olarak bakıldığında veri setindeki yangınların korelasyonları öncelikle Antropojenik değişkenlerle sonrasında ise Vejetasyon, Meteorolojik ve son olarak Topoğrafik değişkenlerle ilişkili olduğu ortaya çıkmıştır (Şekil 3.46).

Pozisyonluk	Eğim	Yükseklik	Eğrisellik	Baki	Arazi_Kullanım	NDVI	Kapalılık	Mescere	Yerleşim_uzaklık	Yol_uzaklık	Yangın_yog	ENH_uzaklık	Nüfus	G_Evapotranspirasyon	Rüzgar_hızı	Nem	Yağış	Maksimum_S	Minimum_S	P_Güneş_Rad	VARIYOK
Pozisyonluk	1.00000	-0.005091	0.033094	0.436777	0.012289	0.060802	0.028951	0.025017	0.035517	0.067416	0.074813	0.020047	-0.065776	0.026582	0.006252	0.016463	0.031528	-0.040744	-0.037626	0.062468	-0.076463
Eğim	-0.005091	1.00000	0.231430	-0.014155	-0.065342	0.105752	0.164509	0.078746	0.106824	0.208184	0.243946	0.079954	-0.122682	0.105706	-0.004424	0.024613	0.090886	-0.044208	-0.074543	-0.287680	-0.158434
Yükseklik	0.033094	0.231430	1.00000	0.042422	-0.021597	0.084865	0.179789	0.215379	-0.224536	0.481063	0.480256	0.151465	-0.404231	0.069618	-0.293476	-0.143063	0.151141	-0.184491	-0.377827	0.327504	-0.336395
Eğrisellik	0.436777	-0.014155	0.042422	1.00000	-0.014666	0.014159	-0.033080	-0.003460	0.041907	0.013194	0.019177	0.009482	0.047787	-0.030759	0.002282	0.015566	-0.035689	-0.000464	-0.019683	0.053953	-0.008311
Baki	0.012289	-0.065342	-0.021597	-0.014666	1.00000	-0.089936	-0.168022	-0.173311	0.084746	-0.081362	-0.138525	-0.072512	0.070890	-0.129642	0.117359	-0.072477	-0.118164	0.077938	0.082556	0.541304	0.177351
Arazi_Kullanım	0.060802	0.105752	0.084865	0.014159	-0.089936	1.00000	0.208093	0.270902	-0.268872	0.187385	0.188951	0.170675	-0.066072	0.043227	0.059931	0.019731	0.059065	0.008288	0.001594	-0.077294	-0.241905
NDVI	0.028951	0.164509	0.179789	-0.033080	-0.168022	0.208093	1.00000	0.581772	-0.318779	0.325367	0.347523	0.209420	-0.216336	0.257778	-0.053951	0.019431	0.352041	-0.119767	-0.087282	-0.211726	-0.428743
Kapalılık	0.025017	0.078746	0.215379	-0.003460	-0.173311	0.270902	0.581772	1.00000	-0.650144	0.336538	0.362597	0.173565	-0.146225	0.190191	-0.027628	-0.027203	0.319382	-0.079964	-0.051905	-0.158726	-0.407809
Mescere	0.035517	0.067416	0.074813	0.020047	0.035517	-0.268872	-0.318779	-0.650144	1.00000	-0.174437	-0.144589	-0.100148	0.090446	0.133033	0.011852	0.113763	0.040757	-0.047931	0.031341	-0.020051	0.021685
Yerleşim_uzaklık	0.067416	0.208184	0.481063	0.013194	-0.081362	0.187385	0.325367	0.336538	-0.174437	1.00000	0.823917	0.311292	-0.298175	0.305759	0.015339	0.055208	0.406076	-0.193768	-0.175961	0.031425	-0.541430
Yol_uzaklık	0.074813	0.243946	0.480256	0.019177	-0.138525	0.189051	0.347523	0.362597	0.823917	0.823917	1.00000	0.280744	-0.438240	0.308963	0.014028	0.120286	0.467517	-0.223196	-0.195636	-0.025687	-0.604938
Yangın_yog	-0.047960	-0.172127	-0.173636	0.009482	0.161124	-0.122014	-0.256979	-0.280312	-0.100148	-0.360769	-0.438240	1.00000	-0.290111	-0.422102	0.047558	-0.115320	0.443727	0.243030	0.163491	0.164437	0.577469
ENH_uzaklık	0.020047	0.079954	0.151465	0.047787	-0.072512	0.170675	0.209420	0.173565	-0.115588	0.311292	0.280744	-0.290111	1.00000	0.102682	0.088493	0.052044	0.144248	-0.093405	-0.064046	-0.068025	-0.304359
Nüfus	-0.065776	-0.122682	-0.404231	-0.010262	0.078090	-0.066072	-0.216336	-0.146225	0.090446	-0.298175	-0.249916	0.102682	0.015385	0.100000	0.382145	-0.027852	-0.271955	0.102254	0.238896	-0.099419	0.288150
G_Evapotranspirasyon	0.026582	0.05706	0.069618	-0.030759	-0.129642	0.043227	0.257278	0.190191	0.133033	0.305759	0.398963	0.122255	-0.223906	1.00000	-0.270221	0.527163	0.804763	0.027429	-0.181824	-0.170294	-0.563584
Rüzgar_hızı	0.006252	-0.004424	-0.293476	0.002282	0.117359	0.059931	-0.058951	-0.027628	0.010852	0.015339	0.014028	0.047558	0.382145	-0.270221	1.00000	0.027429	-0.283955	0.284485	0.418220	-0.042853	0.205452
Nem	0.016463	0.024613	-0.43063	0.013566	-0.072477	0.019731	0.019431	-0.027203	0.113763	0.055208	0.120298	-0.115320	0.052044	0.527163	0.027429	1.00000	0.075968	-0.450087	-0.432889	-0.148271	-0.095125
Yağış	0.031528	0.090886	0.151141	-0.035689	-0.118164	0.059065	0.352041	0.313982	0.040757	0.406076	0.467517	0.144248	-0.271955	0.804763	-0.282955	0.075968	1.00000	-0.185283	-0.059314	-0.105101	-0.688111
Maksimum_S	-0.040744	-0.044208	-0.184491	-0.000464	0.077938	0.008288	-0.119767	-0.079964	-0.047931	-0.193768	-0.223196	-0.093405	0.102254	-0.274817	0.284485	-0.450087	-0.185283	1.00000	0.911151	0.016605	0.294737
Minimum_S	-0.037626	-0.074543	-0.377827	-0.019683	0.082556	0.001594	-0.087282	-0.051905	0.031341	-0.175961	-0.195636	0.163491	-0.064046	-0.181824	0.418220	-0.432889	-0.059314	0.911151	1.00000	-0.063842	0.239056
P_Güneş_Rad	0.062468	-0.287680	0.327504	0.053953	0.541304	-0.077294	-0.211726	-0.158726	-0.020051	0.031425	-0.026687	0.164437	-0.068025	-0.099419	-0.042853	-0.148271	-0.105101	0.016605	-0.063842	1.00000	0.129745
VARIYOK	-0.076463	-0.158434	-0.336395	-0.009311	0.177351	-0.241905	-0.428743	-0.407809	0.021685	-0.541430	-0.604938	-0.304359	0.288150	-0.563584	0.205452	-0.095125	-0.688111	0.294737	0.239056	0.129745	1.00000


Şekil 3.46 Veri seti II Korelasyon ısı haritası



Şekil 3.47 Bağımsız değişkenlerin korelasyon matrisi

3.7 Derin Öğrenme ile Risk Tahmini

Derin öğrenme, makine öğreniminin alt dalı olup bir makine öğrenimi algoritması olan ve insan beynini taklit etme prensibine dayanan yapay sinir ağları temellidir. Yapay sinir ağlarında, bir gizli katman bulunurken derin sinir ağlarında birden fazla gizli katman bulunur. Büyük verileri analiz etmek için klasik makine öğrenimi algoritmaları yetersiz kalması, yapılandırılmamış verileri makine öğrenimi teknikleri ile analizinin zorluğu derin öğrenme algoritmaları gelişimini sağlamıştır (Géron, 2022).



Şekil 3.48 Algoritmaların veri miktarına göre performansı (Heaton, 2020)

Derin öğrenme modeli ile I. Veri seti üzerinde çalışılmış olup test doğruluğu makine öğrenimi algoritmalarının test doğruluğuna ulaşamadığı görülmüş olup bunun için II. Veri seti hazırlanarak veri boyutu artırılmıştır (Şekil 3.48).

Uzaktan algılama teknikleri kullanılarak hazırlanan II. Veri seti python yazılım dili ile bulut tabanlı Google Colab ara yüzünde analizleri yapıldıktan sonra veri seti bölünerek %80 eğitim aşamasında %20’de test aşamasında kullanılmak üzere bölünmüştür. Risk tahmini için Derin Öğrenme modeli olarak Sıralı Model seçilmiştir.

3.6.1 Keras Kütüphanesi Sıralı Model Dense Katmanı

Keras'taki Sıralı model, derin öğrenme modellerini oluşturmak için model türlerinden biridir. Bu model, katmanların sırayla eklenmesini ve yapılandırılmasını sağlar. Sıralı model kullanarak, her katmanı birer birer ekleyebilir ve böylece karmaşık yapılar oluşturulabilmektedir. Sıralı model kullanılarak yapılan model tanımlama aşağıdaki gibidir.

```
model = Sequential([  
    Dense(22, activation='relu', input_shape=(Xpred.shape[1],)),  
    Dropout(.5),  
    Dense(11, activation='relu'),  
    Dropout(.5),  
    Dense(1, activation='sigmoid')  
])
```

Sıralı model ile yapay sinir ağı modeli tanımlanır. Bu model katmanları sırayla eklemeyi sağlamaktadır. Dense katmanlar tam bağlantılı (fully connected) katmanlardır. İlk katman 22 nörona sahip ve relu aktivasyon fonksiyonunu kullanılmaktadır. input_shape parametresi ile giriş verisinin boyutu belirlenmektedir. Dropout katmanı, belirtilen oran kadar nöronu rastgele sıfırlayarak (kapatır) aşırı öğrenmeyi (overfitting) önler. İkinci Dense katmanı 11 nöron içeriyor ve yine relu aktivasyon fonksiyonunu kullanılmaktadır. Sonrasında İkinci bir Dropout katmanı ekleniyor. Son katman ise 1 nörona sahip ve ikili sınıflandırma için uygun olan sigmoid aktivasyon fonksiyonu kullanılarak model tanımlanmıştır.


Dense Katmanı, tam bağlantılı (fully connected) katmandır. Her nöron, bir önceki katmandaki tüm nöronlara bağlanır.

Dense(22, activation='relu') ifadesi, 22 nöronlu ve ReLU aktivasyon fonksiyonuna sahip bir katman ekler.

Dropout Katmanı, overfitting'i önlemek için belirli bir oranda nöronları rastgele kapatır.

Dropout(0.5) ifadesi, %50 oranında nöronları kapatır.

Aktivasyon fonksiyonu, her nöronun çıktısını dönüştürmek için kullanılır. Yaygın aktivasyon fonksiyonları arasında relu, sigmoid, softmax vb. bulunur.



Şekil 3.49 Aktivasyon fonksiyonları

Rectified Linear Unit, derin öğrenme modellerinde yaygın olarak kullanılan bir aktivasyon fonksiyonudur. Matematiksel olarak, ReLU fonksiyonu negatif girişler için sıfır, pozitif girişler için ise aynı değeri döndürür (Şekil 3.49).

ReLU fonksiyonunun formülü (3.7).

$$f(x)=\max\{0,x\} \quad f(x)=\max(0,x) \quad (3.7)$$

ReLU, doğrusal olmayan bir aktivasyon fonksiyonudur. Bu, sinir ağının daha karmaşık yapılar ve örüntüler öğrenmesini sağlar.

Sigmoid aktivasyon fonksiyonu, yapay sinir ağlarında yaygın olarak kullanılan bir aktivasyon fonksiyonudur (Şekil 3.48). Özellikle ikili sınıflandırma problemlerinde (örneğin, 0 veya 1 gibi iki sınıfa ayırma) çıkış katmanında sıklıkla tercih edilir.

Sigmoid fonksiyonunun matematiksel formülü şu şekildedir (3.8)

$$S(x) = \frac{1}{1+e^{-ax}} \quad (3.8)$$

Model Derleme, `model.compile(optimizer='adam', loss='binary_crossentropy', metrics = ['accuracy'])`

Bu kısımda model derleniyor, adam optimizasyon algoritması kullanılıyor, bu yaygın ve genellikle iyi sonuçlar veren bir optimizasyon yöntemidir. Loss parametresi olarak binary crossentropy kullanılıyor, bu ikili sınıflandırma problemlerinde kullanılır.

Derleme :Model derlenirken optimizasyon algoritması, kayıp fonksiyonu ve metrikler belirlenir:

Optimizer: Modelin ağırlıklarını güncellemek için kullanılan algoritma. Örneğin, adam, SGD gibi.

Loss: Kayıp fonksiyonu, modelin tahminleri ile gerçek değerler arasındaki farkı ölçer.

İkili sınıflandırma için binary_crossentropy, çok sınıflı sınıflandırma için categorical_crossentropy vb. kullanılır.

Metrics: Modelin performansını değerlendirmek için kullanılan metrikler. Örneğin, accuracy, precision, recall vb.

Eğitim aşamasında işlemler aşağıda açıklanmıştır.

- history = model.fit(X_train_scale, y_train, epochs=250, batch_size=10, validation_split=0.2)
- X_train ve y_train: Eğitim verisi ve etiketleri.
- epochs: Eğitim boyunca verisetinin kaç kez işleneceği.
- batch_size: Her adımda işlenecek örnek sayısı.
- validation_split: Eğitim verisinin belirli bir yüzdesi doğrulama için kullanılır

Python yazılım dili ile Google Colab arayüzünde model eğitilmiş ve test aşamasında 0.94 doğruluk metriğine ulaşılmıştır (Şekil 3.50).

Şekil 3.50 Epok ve doğruluk

```
143/143 [=====] - 1s 4ms/step - loss: 0.1264 - accuracy: 0.9510 - val_loss: 0.1060 - val_accuracy: 0.9580
Epoch 245/250
143/143 [=====] - 0s 3ms/step - loss: 0.1082 - accuracy: 0.9587 - val_loss: 0.1043 - val_accuracy: 0.9580
Epoch 246/250
143/143 [=====] - 0s 3ms/step - loss: 0.1051 - accuracy: 0.9524 - val_loss: 0.1042 - val_accuracy: 0.9608
Epoch 247/250
143/143 [=====] - 1s 4ms/step - loss: 0.1044 - accuracy: 0.9594 - val_loss: 0.1051 - val_accuracy: 0.9636
Epoch 248/250
143/143 [=====] - 0s 2ms/step - loss: 0.1096 - accuracy: 0.9622 - val_loss: 0.1046 - val_accuracy: 0.9608
Epoch 249/250
143/143 [=====] - 0s 2ms/step - loss: 0.1012 - accuracy: 0.9545 - val_loss: 0.1050 - val_accuracy: 0.9664
Epoch 250/250
143/143 [=====] - 0s 2ms/step - loss: 0.1056 - accuracy: 0.9538 - val_loss: 0.1046 - val_accuracy: 0.9664
10/10 [=====] - 0s 2ms/step - loss: 0.1885 - accuracy: 0.9460
Test Loss: 0.18853852152824402
Test Accuracy: 0.9460317492485046
```

Model eğitimi 250 epok sonrasında ulaştığı doğruluk metriği (0,95), modelin işlem özeti ve modelin sinir ağı şeklinde gösterimi Şekil. 3.50 , 3.51 ve 3.52’de gösterilmiştir.


```
model.summary()
```

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 22)	462
dropout (Dropout)	(None, 22)	0
dense_1 (Dense)	(None, 11)	253
dropout_1 (Dropout)	(None, 11)	0
dense_2 (Dense)	(None, 1)	12

=====
Total params: 727 (2.84 KB)
Trainable params: 727 (2.84 KB)
Non-trainable params: 0 (0.00 Byte)
=====

Şekil 3.51 Model işlem özeti



Şekil 3.52 Modelin yapay sinir ağı şeklinde gösterimi

Uzaktan algılama ve Coğrafi Bilgi Sistemleri teknikleri ile üretilmiş değişkenler ile oluşturulan II. Veri seti (2100*22) kullanılarak, Derin Öğrenme modeli olan Sıralı Model ile eğitilip 0.95 test doğruluğu değeri ile sonuçlanan risk tahmini Arcmap yazılımı ile 100*100 mekansal çözünürlük ile 5 sınıfta haritalandırılmıştır.




4. BULGULAR

4.1 Risk Tahmini Haritaları


Tüm algoritmalar için risk tahminleri yapılmış olup 100*100 konumsal çözünürlükte orman yangınlarına karşı risk durumları 5 sınıfta görselleştirilmiştir. Her piksel için üretilen tahmin olasılıkları 0-100 değer aralığında ölçeklendirilmiştir. Harita üretimi aşamasında makine öğrenimi algoritmaları için sınıflandırma ilk olarak %20lik dilimlere ayrılarak görselleştirilmiş, ikinci olarakda % 0-40 çok az, %40-55 az, %55-70 orta, %70-85 yüksek, %85-100 çok yüksek dilimleri ile haritalandırılmıştır. Buradaki amaç olasılıklardaki geçişleri görselleştirebilmektir. Ayrıca kullanılan veri seti yangın korelasyonları ve haritalar birlikte sunulmuştur.

4.1.1 Rastgele Orman Algoritması ile Orman Yangını Risk Tahmini


Uzaktan algılama ve CBS teknikleri ile oluşturulan I. Veri seti Rastgele Orman algoritması ile eğitilmiş ve 0,94 test doğruluğu ile tahminler yapılmıştır. Tahmin için çalışma alanında orman varlığı bulunan alanlar 100*100 konumsal çözünürlükte her piksel için değer çıkarımı yapılarak 689419*21 satır*sütundan oluşan tahmin veri seti oluşturulmuştur. Tahmin olasılıkları ölçeklendirilip Arcmap yazılımı yardımıyla iki farklı olasılık dilimlerinde haritalandırılmıştır (Şekil 4.1, 2).



Şekil 4.1 Rastgele orman algoritması ile oluşturulmuş orman yangını risk tahmini (%20'lik olasılık dilimlerine göre haritalandırılmıştır.)



Şekil 4.2 Rastgele orman algoritması ile oluşturulmuş orman yangını risk tahmini (% 0-40 çok az, %40-55 az, %55-70 orta, %70-85 yüksek, %85-100 çok yüksek olasılık dilimlerine göre haritalandırılmıştır.)




Şekil 4.3 Rastgele orman algoritması ile oluşturulmuş orman yangını risk tahmini ve 2023 ile 2024 yılı orman yangınları


2017 ve 2022 yılları arasında 6 yıllık yangın döneminden elde edilmiş I. Veri seti ile eğitilmiş model ile oluşturulan risk haritaları 2023 ve 2024 yıllarında oluşan yangınlara ait koordinatlar ile karşılaştırıldığında mezkur yangınların %50 üzerinde yüksek ve Çok yüksek riskli alanlarda kaldığı tespit edilmiştir (Şekil 4.3). Düşük risk alanında kalan yangınlar incelendiğinde ise bunların belirlenen sebepleri kısmında, diğer ateşlenme (çoban-avcı), elektrik hatları, sıcak kül ve nedeni bilinmeyen olarak kayıtlı olduğu görülmektedir.

4.1.2 Aşırı Gradyan Artırma Algoritması İle Orman Yangını Risk Tahmini


Uzaktan algılama ve CBS teknikleri ile oluşturulan I. Veri seti Aşırı Gradyan Artırma algoritması ile eğitilmiş ve 0,95 test doğruluğu ile tahminler yapılmıştır. Tahmin için çalışma alanında orman varlığı bulunan alanlar 100*100 konumsal çözünürlükte her piksel için değer çıkarımı yapılarak 689419*21 satır*sütundan oluşan tahmin veri seti oluşturulmuştur. Tahmin olasılıkları ölçeklendirilip Arcmap yazılımı yardımıyla iki farklı olasılık dilimlerinde haritalandırılmıştır (Şekil 4.4, 5).



Şekil 4.4 Aşırı gradyan artırma algoritması ile oluşturulmuş orman yangını risk tahmini (% 0-40 çok az, %40-55 az, %55-70 orta, %70-85 yüksek, %85-100 çok yüksek olasılık dilimlerine göre haritalandırılmıştır.)



Şekil 4.5 Aşırı gradyan artırma algoritması ile oluşturulmuş orman yangını risk tahmini (%20'lik olasılık dilimlerine göre haritalandırılmıştır.)




Şekil 4.6 Aşırı gradyan artırma algoritması ile oluşturulmuş orman yangını risk tahmini ve 2023 ile 2024 yılı orman yangınları


2017 ve 2022 yılları arasında 6 yıllık yangın döneminden elde edilmiş I. Veri seti ile eğitilmiş model ile oluşturulan risk haritaları 2023 ve 2024 yıllarında oluşan yangınlara ait koordinatlar ile karşılaştırıldığında mezkur yangınların %50 üzerinde yüksek ve Çok yüksek riskli alanlarda kaldığı tespit edilmiştir. %30 a yakın yangın da Orman dışı alanlarda olduğu görülmüştür (Şekil 4.6). Düşük risk alanında kalan yangınlar incelendiğinde ise bunların belirlenen sebepleri kısmında, diğer ateşlenme (çoban-avcı), elektrik hatları, sıcak kül ve nedeni bilinmeyen olarak kayıtlı olduğu görülmektedir.

4.1.3 Sıralı Model Katmanı ile Orman Yangını Risk Tahmini

Bağımlı değişken olan orman yangınları 2017 ila 2023 yılları arasında mayıstan başlayıp eylül sonuna kadar olan yangınlardan 1098 adet yangın var noktasına 1002 adet yangın yok noktası eklenerek 2100*22 satır*sütundan oluşan eğitim seti oluşturulmuştur. OGM'den temin edilen orman yangını koordinatları ve bu koordinatlardaki birden fazla pikselde kalan tüm yanmış alanlar II. Veri setini oluşturmuştur. Bu veri setinde korelasyon kuvveti yüksek 7 değişkenden 3ünün Antropojenik, 2sinin Vejetasyon ve diğer ikisinin ise meteorolojik olduğu görülmektedir. Model seçimi olarak ta derin öğrenme modeli olan Sıralı model belirlemiştir (Şekil 4.7, 8)




Şekil 4.7 Sıralı model ile oluşturulmuş orman yangını risk tahmini



Şekil 4.8 Sıralı model doğruluk ve kayıpları

Uzaktan algılama ve CBS teknikleri ile oluşturulan II. Veri seti Derin Öğrenme modeli olan Sıralı modeli ile eğitilmiş ve 0,94 test doğruluğu ile tahminler yapılmıştır. Tahmin için çalışma alanında orman varlığı bulunan alanlar 100*100 konumsal çözünürlükte her piksel için değer çıkarımı yapılarak 689419*21 satır*sütundan oluşan tahmin veri seti oluşturulmuştur. Tahmin olasılıkları ölçeklendirilip Arcmap yazılımı yardımıyla haritalandırılmıştır.

2017 ve 2023 yılları arasında 7 yıllık yangın döneminden elde edilmiş II. Veri seti ile eğitilmiş model ile oluşturulan risk haritası 2024 yıllarında oluşan yangınlara ait koordinatlar ile karşılaştırıldığında mezkur yangınların %50 üzerinde yüksek ve çok yüksek riskli alanlarda kaldığı tespit edilmiştir. Yangınların %35 nin ise Orman dışı alanlarda olduğu görülmüştür (Şekil 4.9). Düşük risk alanında kalan yangınlar incelendiğinde ise bunların belirlenen sebepleri kısmında, diğer ateşlenme (çoban-avcı), elektrik hatları, sıcak kül ve nedeni bilinmeyen olarak kayıtlı olduğu görülmektedir.




Şekil 4.9 Sıralı model ile oluşturulmuş orman yangını risk tahmini ve 2024 yılı orman yangınları


4.1.4 Orman Yangın Gözetleme kulelerinin Risk Modelleri için Görünürlük Analizi

Aşırı Gradyan Artırma Algoritması ile riskli alan olarak tespit edilen yaklaşık 140 bin hektar alanın, 2024 yılı itibariyle 30 adet aktif orman yangını gözetleme kuleleri ile görünürlük analizi yapılmış olup riskli alanın %47'sinin görülebilir olduğu tespit edilmiştir. Analizde kule yüksekliği 20m, duman yüksekliği 10 m, 360 derece yatay açı ve +/-90 derece dikey açı metrikleri kullanılmıştır (Şekil 4.10).


Rastgele Orman Algoritması ile riskli alan olarak tespit edilen yaklaşık 120 bin hektar alanın, 2024 yılı itibariyle 30 adet aktif orman yangını gözetleme kuleleri ile görünürlük analizi yapılmış olup riskli alanın %45'inin görülebilir olduğu tespit edilmiştir. Analizde kule yüksekliği 20m, duman yüksekliği 10 m, 360 derece yatay açı ve +/-90 derece dikey açı metrikleri kullanılmıştır (Şekil 4.11).



Şekil 4.10 Aşırı gradyan artırma algoritması ile oluşturulan riskli alanların kule görünürlük analizi



Şekil 4.11 Rastgele orman algoritması ile oluşturulan riskli alanların kule görünürlük analizi



Şekil 4.12 Sıralı model katmanı ile oluşturulan riskli alanların kule görünürlük analizi

Derin Öğrenme tekniği olan Sıralı Katman modeli ile riskli alan olarak tespit edilen yaklaşık 170 bin hektar alanın, 2024 yılı itibariyle 30 adet aktif orman yangını gözetleme kuleleri ile görünürlük analizi yapılmış olup riskli alanın %41'inin görülebilir olduğu tespit edilmiştir. Analizde kule yüksekliği 20m, duman yüksekliği 10 m, 360 derece yatay açı ve +-90 derece dikey açı metrikleri kullanılmıştır (Şekil 4.12).

Yangın gözetleme kulelerinin kamera sistemleri ile güçlendirildiği, duman algılayıcı sistemlere ilave olarak insansız hava araçlarıyla yangın gözetimleri yapıldığı bilinmektedir. Bu ve buna benzer çalışmalar ile riskli alanlar için konuşlandırılacak acil müdahale ekipleri ve yeni tesis edilecek gözetleme sistemlerinin riskli alanlarda yoğunlaştırılması açısından karar vericilere faydalı olacağı öngörülmektedir.

4.2 Bağımsız Değişkenlerin Analizi

Veri setlerine ait korelasyon değerleri çizelge 4.1'de özetlenmiştir. Bağımsız değişkenlere ait korelasyonların yönleri her iki veri setinde de aynı olup korelasyon kuvvetleri farklılık göstermektedir.

Çizelge 4.1 I ve II. Veri seti korelasyonları

BAĞIMSIZ DEĞİŞKENLER	BAĞIMLI DEĞİŞKEN İLE KORELASYONLAR	
	I. VERİ SETİ	II. VERİ SETİ
Pürüzlülük	-0.004076	-0.076463
Eğim	-0.157820	-0.158434
Yükseklik	-0.214795	-0.336395
Eğrisellik	-0.019051	-0.009311
Bakı	0.122806	0.177351
Arazi Kullanımı	-0.373902	-0.241905
NDVI	-0.312829	-0.429743
Orman Kapallığı	-0.357855	-0.407809
Meşcere Tipi	0.067613	0.021685
Yerleşim Uzaklık	-0.401605	-0.541430
Yol Uzaklık	-0.426693	-0.604938
Yangın Yoğunluğu	0.430101	0.577469
ENH Uzaklık	-0.136794	-0.304359
Nüfus yoğunluğu	0.187644	0.288150
Gerçek Evapotranspirasyon	-0.115613	-0.563584
Rüzgar Hızı	0.118309	0.205452
Toprak Nemi	-0.270663	-0.095125
Yağış	-0.343116	-0.668111
Maksimum Sıcaklık	0.467118	0.294737
Minimum Sıcaklık	0.281652	0.239056
Potansiyel Güneş Radyasyonu	0.139177	0.129745
Orman Yangın Noktaları	1.000000	1.000000

Topoğrafik değişkenlerin korelasyon ve modele etki değerlendirmesi aşağıda yapılmıştır.

Pürüzlülük değişkeni, her iki veri setinde de negatif yönde olup orman yangınları ile korelasyon kuvveti çok düşük değerdedir. Yangın öncesi çalışmalarda sonuca etkisi çok zayıf olup yangın anındaki çalışmalarda etkili olabileceği öngörülmektedir.

Eğim değişkeni, her iki veri setinde de negatif yönlü olup korelasyon kuvveti (-0,15) zayıf olsa bile orman yangınları risk tahmini çalışmalarında kullanılması gereken değişkenlerden olup

bölgesel çalışmalarda farklı kuvvette etkileri olacaktır. Harita okumalarından da anlaşılmaktadır ki eğim arttıkça yangın riski azalmaktadır.

Yükseklik değişkeni, her iki veri setinde de negatif yönlü olup I. Veri setinde 0,21 kuvvetinde II. Veri setinde ise 0,33 kuvvetinde korelasyon göstermiştir. Risk tahmini çalışmalarında en çok kullanılan topoğrafik parametredir. Harita okumaları ile de yükseklik arttıkça yangın riski azalmaktadır.

Eğrisellik değişkeni, her iki veri setinde negatif yönlü olup korelasyon kuvvetleri çok düşük olarak belirlenmiştir. Modele etkisi de çok zayıf olması sebebiyle yangın riski tahmin çalışmalarında kullanılmasına veri analizleri sonrasında karar verilmelidir.

Bakı değişkeni, I. Veri setinde 0,12 ikinci veri setinde 0,17 korelasyon kuvvetine sahip olup kategorik değişken olduğu için korelasyon yönünün bir önemi yoktur. Risk tahmini çalışmalarında zayıf korelasyon gösterse de kullanılması önerilmektedir. Bu çalışma sırasında bakı-6 rumuzlu güneybatı bakısı yangınlarla en çok ilişkili yön olarak ortaya çıkmaktadır.

Topoğrafik değişkenlerden Yükseklik, Eğim ve Bakı yangın risk tahmini çalışmalarında mutlaka kullanılması gerektiği, bunun yanı sıra Pürüzlülük ve Eğrisellik değişkenlerinin ise veri analizi ile etkilerinin incelenerek kullanılması gerektiği sonucuna varılmıştır.

Vejetasyon değişkenlerinin korelasyon ve modele etki değerlendirmesi aşağıda yapılmıştır.

Arazi Kullanım/Arazi örtüsü değişkeni, arazi kullanım değişkeni de kategorik veri olup korelasyon yönünün önemi yoktur. I. Veri setinde 0,37 II. Veri setinde 0,24 korelasyon kuvvetine sahip olup orman yangını risk tahmini çalışmalarında kullanılması gerekmektedir.

NDVI, bitki indeksi her iki veri setinde de negatif yönlü olup I. veri setinde -0,31, II. veri setinde -0,42 korelasyon kuvvetine sahip olup orta ve yüksek korelasyon kuvvetlerinin bu tür çalışmalarda mutlaka kullanılması gereken değişkendir.

Orman Kapalılığı, kategorik veri olmasına rağmen ordinal yapıda olması nedeniyle korelasyon yönü önemlidir. Her iki veri setinde de negatif yönlü olup I. Veri setinde -0,35, II. Veri setinde -0,40 korelasyon kuvveti ile orman yangını risk tahminlerinde mutlaka kullanılması gereken değişkendir.

Harita okumalarında da görülmektedir ki orman kapalılığı arttıkça yangın riski azalmaktadır.

Meşcere tipi, kategorik ve nominal yapıda olup kuvvet yönünün önemi yoktur. Her iki veri setinde de çok zayıf korelasyona sahip olup yangın riski tahmin çalışmalarında kullanılmasına veri analizleri sonrasında karar verilmelidir.

Vejetasyon değişkenlerinden arazi kullanımı/ arazi örtüsü, NDVI bitki indeksi ve orman kapallılığı değişkenlerinin, orman yangını risk tahmin çalışmalarında mutlaka kullanılması gereken değişkenlerdir. Meşcere tipinin ise veri analizi ile etkilerinin incelenerek kullanılması gerektiği sonucuna varılmıştır. Ayrıca Orman içi açıklıklar ve çalışma alanı içerisindeki tarımsal faaliyetlerin sınıflandırılarak değişken olarak irdelenmesinin başarı oranının artıracakı öngörülmektedir. Yanıcı madde ve tutuşturucu madde hesaplamaları ile ilgili çalışmalarında risk çalışmalarına entegre edilmesi risk tahmin başarısının aratacağı düşünülmektedir.

Antropojenik değişkenlerin korelasyon ve modele etki değerlendirmesi aşağıda yapılmıştır.

Yerleşime uzaklık, her iki veri setinde de negatif yönlü olup I. Veri setinde -0,40, II. Veri setinde -0,54 korelasyon kuvveti ile orman yangını risk tahmini çalışmalarında kesinlikle kullanılması gereken değişkendir. Risk haritaları okumalarında da görüldüğü üzere yerleşim yerlerinden uzaklaştıkça orman yangını riski azalmaktadır.

Yola uzaklık, her iki veri setinde de negatif yönlü olup I. Veri setinde -0,42, II. Veri setinde -0,60 korelasyon kuvveti ile orman yangını risk tahmini çalışmalarında kesinlikle kullanılması gereken değişkenlerdendir. Risk haritaları okumalarında da görüldüğü üzere yollardan uzaklaştıkça orman yangını riski azalmaktadır.

Yangın Yoğunluğu, geçmiş yıllardaki yangınların yoğunluk gösterdiği alanların veri setinde kullanılması tahmin çalışmalarında kullanılmakta ve kalibrasyon özelliği taşımaktadır.

ENH'dan uzaklık, her iki veri setinde de negatif yönlü olup I. Veri setinde -0,13 II. Veri setinde -0,30 korelasyon kuvvetlerine sahip olup orman yangını risk tahmini çalışmalarında kullanılması gereken değişkenlerdendir.

Nüfus dağılımı, çalışma alanı içerisinde ki piksel başına düşen insan sayısını ifade etmekte olup her iki veri setinde de pozitif yönlü olup nüfus arttıkça orman yangını riski artmaktadır.

I. Veri setinde 0,18 II. veri setinde 0,28 korelasyon kuvvetine sahip olup orman yangını risk tahmini çalışmalarında kullanılmalıdır.

Bu çalışmada kullanılan tüm Antropojenik değişkenler korelasyon yön ve kuvvetleri ile modele etki etmiş olup harita okumalarından da fark edilebilmektedir. Orman yangını risk tahmin çalışmalarında antropojenik değişkenler olan Yerleşim, yol VE ENH'na uzaklık değişkenleri ile birlikte yangın yoğunluğu ve nüfus dağılımı değişkenlerinin kullanılması önerilmektedir.

Orman yangınlarının en büyük sebebi antropojenik etkiler olduğu bilinmektedir. Bu kapsamda yangın kontrolü amaçlı yapılan yangın şeritleri ve yollarının da ulaşım olarak kullanılmasının olumsuz etkilerinin incelenmesi gerekmektedir. Bu çalışmada ENH olarak yüksek gerilim hatları kullanılmış olup orta ve düşük gerilim hatlarının da çalışmalara dahil edilmesinin başarı oranının artıracağı öngörülmektedir. Bunların yanı sıra avcılık ve çoban ateşi de bilinen yangın sebepleri arasında olup bunlar ile ilgili verilerin de değişken olarak kullanılmasında yarar olacağı görüşüne varılmıştır.

Meteorolojik değişkenlerin korelasyon ve modele etki değerlendirmesi aşağıda yapılmıştır.

Evapotranspirasyon, terleme ve buharlaşma olarak ta tanımlanan bu değişken literatürde kullanılmamış olup I. Veri setinde -0,11 negatif yönlü ve II. veri setinde -0,56 negatif yönlü olmak üzere modeller üzerinde etkisi olduğu görülmekte olup evapotranspirasyon değeri arttıkça yangın riski azaldığı tespit edilmiştir.

Rüzgar hızı, Veri setlerinde farklı yönlerde etki gösterdiği görülen bu değişken yangın ateşlenmesinden daha çok yangının seyrini, yönünü ve büyüklüğünü etkileyen bir değişken olup yangın anı ve yangın davranışları analizlerinde çok önemlidir. I. Veri setinde 0,11 pozitif yönlü ve II. veri setinde 0,20 pozitif yönlü olmak üzere modeller üzerinde etkisi olduğu görülmekte olup rüzgar hızı değeri arttıkça yangın riski arttığı tespit edilmiştir.

Yağış, çalışma alanı içerisinde yağış farklılığı oluşan bölgelerde yüksek korelasyon ve etkiye sahip yağış değişkeni her iki veri setinde de negatif yönlü olup I. veri setinde -0,34 II. veri setinde -0,66 korelasyona sahiptir.

Toprak nemi, korelasyonu I. Veri setinde -0,27 olup negatif yönlüdür. II. veri setinde ise çok zayıf korelasyon göstermektedir. Bunun sebebinin II. veri setinde yanan alanlarında dahil edilmesi olduğu düşünülmektedir. Yangın öncesi çalışmalarda Toprak nemi ve havadaki bağıl nem miktarları önemli olup bu değişkende benzer çalışmalarda kullanılmalıdır.

Maksimum ve Minimum sıcaklıklar, bazı çalışmalarda sadece maksimum sıcaklık kullanılırken bu çalışmada gece ve gündüz sıcaklıkları ayrı değişken olarak kullanılmıştır. Her iki veri setinde de sıcaklıklar pozitif korelasyon göstermiştir. I. Veri setinde 0,46, 0,28 korelasyon kuvvetleri II. veri seti 0,29, 0,23 korelasyon kuvvetleriyle sıcaklıklar arttıkça yangınların artacağı sonucu ortaya çıkmaktadır.

Potansiyel Güneş radyasyonu, Literatürde nadir kullanılan bu değişken her iki veri setinde de pozitif yönde ve zayıf korelasyon göstermiştir. Bu değişkeninde benzer çalışmalarda kullanılması önerilmektedir.

Bu çalışmada kullanılan meteorolojik değişkenlerin tamamının orman yangını risk tahmini çalışmalarında kullanılması önerilmektedir. Ancak Meteoroloji uydularının düşük mekânsal çözünürlüğü, meteoroloji istasyonlarının sıklığının daha çok yerleşim alanlarında bulunması ve her istasyonda tüm değişkenlerin ölçülmemesi gibi nedenlerle meteorolojik değişkenler de daha iyi sonuçlar alabilmek için mekânsal çözünürlüğün artırılması konusuna dikkat edilmesi gerektiği sonucuna varılmıştır. Bunlar ile birlikte literatürde nadir kullanılmış olan evapotranspirasyon ve potansiyel güneş enerjisi değişkenlerinin de çalışmalara dahil edilmesinin faydalı olacağı görüşüne varılmıştır.

5. TARTIŞMA ve SONUÇ

Bu tez çalışmasının ilk aşamasında orman yangınları problem olarak belirlenmiş olup uzaktan algılama verilerinin yapay zeka teknikleri ile incelenerek risk tahminleri oluşturmak hedeflenmiştir. Bu kapsamda literatür taraması yapılarak yapılan çalışmalarda kullanılan değişkenler tespit edilmiş ve kullanılan yöntem ve metotlar incelenmiştir. OGM'den alınan tarihsel yangın kayıtları incelenerek 2017 yılından günümüze kullanılabilir noktalar tespit edilmiştir. Literatür ışığında belirlenen değişkenler için veri toplama aşamasında Open Street Map, Google Earth Engine, USGS, gibi platformlardan veri toplanmıştır. Uzaktan Algılama ve Coğrafi bilgi sistemleri teknikleri ile uydu görüntüleri, kamu kurumlarından temin edilen vektör veriler ve Open Street Map gibi açık kaynaklı ham veriler işlenerek TUREF(Datum: ITRF Projeksiyon: UTM 3°) koordinat sisteminde aynı konumsal çözünürlükte (30m*30m) 21 bağımsız ve 1 bağımlı olmak üzere 22 değişken ön işleme adımları ile işlenerek haritalandırılmıştır. Haritalardan piksel değer çıkarımı yapılarak değişkenlerin yangınlarla ve kendi aralarındaki ilişkileri Google Colab ara yüzünde python dilinde veri görselleştirme ve keşifsel veri analizi teknikleri ile incelenerek özellik seçimi yapılmış ve I. Veri seti oluşturulmuştur. Model seçimi aşamasında makine öğrenimi için 7 adet algoritma ile eğitim ve testler yapılmış olup en yüksek doğruluk metriklerine ulaşan Rastgele Orman ve Aşırı Gradyan Artırma algoritmaları model olarak seçilerek risk tahminleri yapılmış ve haritalandırılmıştır. Aynı veri seti ile derin öğrenme modeli olan Sıralı model eğitimi yapılmış fakat test aşamasında yeterli doğruluğa ulaşamamıştır. Bu sebep başta olmak üzere çalışma alanı içerisindeki büyük yangınlardaki yanan alanlarında veri setine dahil edilmesi amacıyla tüm pikseller ve 2023 yangın verilerinin de eklenmesiyle veri seti boyutu artırılarak II. Veri seti oluşturulmuştur. II. Veri seti ile Sıralı model kullanılarak model tanımlama, model derleme, eğitim ve test aşamaları tamamlanarak derin öğrenme modeli ile de risk tahmini yapılmıştır.

Uzaktan algılama ve CBS teknikleri ile iki adet veri seti oluşturulmuştur. Bu veriler kullanılarak Makine öğrenimi algoritması olan Rastgele Orman ve Aşırı Gradyan Artırma algoritmaları ile birlikte derin Öğrenme modeli olan Sıralı model ile de risk tahmini yapıp haritalandırılmıştır.

Öncelikle her iki veri setinde de bulunan 21 adet bağımsız değişkenin orman yangınları ile ilişkilerini ve risk tahmini uygulamalarında kullanılabilirliğini korelasyonlar, özellik etkileri ve harita okumalarıyla değerlendirecek olursak;

I. Veri setinde (670*22) özellikle meteorolojik değişkenlerin tahmini kısmında bazı değişkenlerde yetersiz kaldığı, değişkenlerin zayıf ve yön belirleyememesine sebep olduğu görülmüştür. II. veri setinin (2100*22) boyutu birinciye göre nispeten daha büyük olup değişkenlerin literatüre benzer yön ve kuvvetle modele etki ettiği görülmüştür. II. veri setindeki dezavantaj ise büyük yangınlardaki alanların yangın var pikseline dahil edilmesi ile veri boyutu artırıldığı için toprak nemi gibi bazı değişkenlerin korelasyon kuvvetinin düşmesine sebep olurken evapotranspirasyon ve yağış gibi değişkenlerinde korelasyonlarının belirgin şekilde artmasına sebep olmuştur. Çalışma alanı ile veri boyutu arasında pozitif bir korelasyon olması gerektiği, özellikle bağımlı değişken sayısının yapay zeka tekniklerinde kullanılan eğitim ve test aşamaları sayesinde öğrenmeyi artıracak görüşüne varılmıştır. Topoğrafik değişkenlerden olan yüzey pürüzlülüğü ve eğrisellik değişkenlerinin orman yangını risk tahmini çalışmalarında modele etkisinin olmadığı, daha çok yangın anında yangın davranışlarında etkili olacağı öngörülmektedir. Bu iki değişken haricindeki tüm değişkenlerin bu tür çalışmalarda kullanılması önerilmektedir. Orman yangınları için risk tahminlerinde, orman yangınları ile ilişkilendirilen etkenlerin belirlenerek, parametre sayısının artırılması daha anlamlı ve yüksek doğruluklu sonuçlara ulaşılmasını sağlayacaktır.

Literatürde genellikle az sayıda değişken ile yüksek test doğruluklarına ulaşıldığı görülmektedir. Orman yangınlarının en büyük sebebinin antropojenik değişkenler olduğu ve çok fazla bağımsız değişkenden etkilenebilen bir olay olduğunu göz önünde bulundurduğumuzda modele etki edebilen çok sayıda değişken ile yüksek test doğrulukları yakalamak daha doğru olacaktır. Ayrıca gelişen bilgi teknolojileri, veri madenciliği ve veri depolamak gelişmeler ile her geçen büyük veriler oluşmakta ve depolanmaktadır. Bu da yeni algoritmaların oluşmasına ve daha büyük verilerin işlenmesine olanak sağlayacaktır.

Bu çalışmada makine öğrenimi ile risk tahmini için Karar Ağaçları, Sınıflandırma ve Regresyon ağaçları, Destek Vektör Makineleri, Naive Bayes Sınıflandırıcı, Çok Katmanlı Algılayıcılar, Aşırı Gradyan Artırma ve Rastgele Orman algoritmaları kullanılmış olup en yüksek doğruluğa Rastgele Orman ve Aşırı Gradyan Artırma algoritmaları ile ulaşılmıştır.

Literatürde farklı makine öğrenimi algoritmaları ile farklı test doğruluklarına ulaşıldığı görülmektedir. Satır vd. (2016)'i 10 adet bağımsız değişken kullanarak geri yayılım algoritmasına dayalı Çok Katmanlı Algılayıcı (MLP) tekniği ile 0,83 test doğruluğuna, Thach vd. (2018)'i 10 adet bağımsız değişken ile Çok Katmanlı Algılayıcı sinir ağı kullanarak 0,89 test doğruluğuna, Bešli ve Tenekeci (2020)'Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NVDI), Arazi Yüzeyi Sıcaklığı (LST) ve Termal anomali (TA) verileri kullanılarak Karar Ağaçları ile 0,93 test doğruluğuna, Yıldırım vd. (2023)'i 35 öznitelik PCA ile 15 ve ANOVA ile 11 öznitelige indirgeyerek Naive Bayes sınıflandırıcısı ile 0,96 test doğruluğuna ulaşmışlardır. Bu çalışmada ise 21 adet bağımsız değişken ile en yüksek doğruluğa ulaşan Rastgele Orman(0,95) ve Aşırı Gradyan Artırma(0,95) algoritmalarından sonra, Karar Ağaçları 0,89, Destek Vektör Makinesi 0,84, Çok Katmanlı Algılayıcı 0,83, ve Naive Bayes sınıflandırıcısı 0,65 test doğruluğuna ulaşabilmişlerdir. Bu durumun en önemli sebebinin kullanılan veri setlerinin boyutları ve bölgesel olup olmadığıyla ilişkili olduğu öngörülmektedir.

Orman yangınları risk tahmini için bölgeye özgü veri setleri hazırlanması, bu veri setleri ile eğitim ve tahminlerin daha başarılı olacağı öngörülmektedir. Ayrıca üretilen risk tahminlerinin sadece test doğruluğu metrikleriyle bırakılmayıp tahmin ve yaşanmış kıyası ile modelin eksiklikleri ve hassasiyeti üzerine de önemli fikirler edinilebileceği görülmüştür. Bu çalışmada kullanılan algoritmalar çerçevesinde Rastgele Orman ve Aşırı Gradyan Artırma algoritmaları önerilmekte olup özellikle Rastgele Orman algoritması literatüre paralellik göstermektedir (Guo vd. 2016, He vd. 2021, Bilücan vd. 2022, Yıldırım vd. 2023).

Bu algoritmalarla üretilen risk tahminleri sonraki yıl orman yangınları ile kıyaslanmış ve önemli sonuçlar ortaya çıkmıştır. %95 seviyesinde test doğruluklarına rağmen modeller yaşanmış orman yangınları ile kıyasta % 50'leri ancak geçebilmişlerdir. Bunun sebepleri incelendiğinde yangınların yaklaşık %30'luk kısmının orman dışı alanlarda başladığı, kalan %20'lik kısımda da bazı değişkenlerin veri setinde yeterince yer almadığı tespit edilmiştir. Bunların başında orman sınırında bulunan tarım amaçlı kullanılan araziler, orman yolları, enerji nakil hatları, yıldırımlar ve çoban ateşi gibi sebepler olduğu tespit edilmiştir. Bu sebeple ileride yapılacak çalışmalarda, sınıflandırılmış tarım alanları, yol tipleri, enerji nakil hatları ve hayvancılık faaliyetleri gibi verilerinde toplanarak, risk tahmin modellerinde kullanılması önerilmektedir.

Bu çalışmada makine öğrenimi algoritmalarının yanısıra derin öğrenme modeli olan Sıralı Model ile de risk tahmini üretilmiştir. Makine öğrenimi algoritmalarına kıyasla daha çok veri ile başarılı sonuçlara ulaşılabileceği, veri setleri büyüdükçe daha çok kullanılacağı öngörülmektedir. Keras kütüphanesine ait Sıralı Katman (Sequential-Dense) modeli ile de yüksek test doğruluklu sonuca ulaşılmıştır. Kullanılan algoritma ve modellerden Rastgele Orman algoritması, Aşırı Gradyan Artırma ve büyük veri setleri için de Sıralı Katman Modeli risk analizi çalışmalarında kullanılması önerilmektedir. Derin öğrenme model ve algoritmalarının makine öğrenimi algoritmalarına kıyasla daha çok veri ile başarılı sonuçlara ulaşılabileceği ve her geçen gün büyüyen veri setleri ile derin öğrenme ağlarına dayalı tekniklerin daha çok kullanılacağı görülmektedir (Van Le vd. 2021, Naderpour vd. 2021, Zhang vd. 2021, Bjanes vd. 2021, Fidanboy vd. 2022).

Çalışma sonunda üç farklı algoritma ile risk tahmin haritaları oluşturulmuş olup haritalar genel yorumlamada yangına riskli alanları ortak olarak işaret etmektedirler. Çalışma alanının güneyinde kalan akdeniz iklimi ve karasal iklim görülen, ilçe merkezlerine ve nüfus yoğunluğuna yakın, orman bütünlüğü olmayan orman içi açıklıkların fazla olduğu ve antropojenik etkilerin yüksek olduğu alanların orman yangını riski yüksektir. Haritalar büyük ölçeğe analiz edildiğinde ise risk alanlarındaki değişkenlikler de göze çarpmaktadır. Bununda ilk sebebi iki farklı veri setinin kullanılmasıdır. Ancak aynı veri setinde çalışılan makine öğrenimi algoritmalarında farklı olasılık dilimlerinde de gösterimler yapılmış olup olasılık dilimleri ölçeklendiğinde risk önceliği geçişleri ile benzerlikler ortaya konmuştur.

Bu çalışmanın orman yangınları ile mücadele kapsamında yangın öncesi riskli alanların tespiti ve alınabilecek önlemlerin belirlenmesinde yol gösterici olacağı ve yangın zararlarını azaltmada katkı sunacağı düşünülmektedir.

Uzaktan algılama ve coğrafi bilgi sistemleri ile geçmiş orman yangınlarına ait koordinatlar kullanılarak çok değişkenli veri setleri hazırlamak mümkündür. Bununla birlikte bu veri setlerinden yapay zekâ yöntem ve teknikleri olan makine öğrenimi ve derin öğrenme modelleri ile risk tahminlerinde bulunmak ve bu tahmin olasılıklarını haritalandırmak afet öncesi çalışmalar için yol gösterici olup afet risklerini azaltmak için oldukça önemlidir.

6. KAYNAKLAR

- Adab H, Kanniah K D, Solaimani K, 2013, Modeling forest fire risk in the northeast of Iran using remote sensing and GIS techniques. *Natural hazards*, 65, 1723-1743.
- AFAD, 2020, Açıklamalı afet yönetimi terimleri sözlüğü. TC İçişleri Bakanlığı, Afet ve Acil Durum Yönetimi Başkanlığı, Ankara.
- Aldossary S M A, Sanober S, Aldosari H, Lalitha, Preethi P, 2024, An extensive investigation about the developments of learning algorithms for forest fire prediction and tracking. *Annals of Forest Research*, 67(1), 472-492.
- Alkayış M H, Karşlıoğlu A, Onur M İ, Muğla ili Menteşe yöresi orman yangını risk potansiyeli haritasının coğrafi bilgi sistemleri ile belirlenmesi. *Geomatik*, 7(1), 10-16.
- Alpaydin E, 2020, Introduction to machine learning. MIT press.
- Arif M, Alghamdi K K, Sahel S A, Alosaimi S O, Alsahft M E, Alharthi M A, Arif M., 2021, Role of machine learning algorithms in forest fire management: A literature review. *J. Robot. Autom*, 5, 212-226.
- Aspragathos N, Dogkas E, Konstantinidis P, Koutmos P, Lamprinou N, Moulitanitis V C, Xofis P, 2019, From pillars to AI technology-based forest fire protection systems. In *Intelligent system and computing*, IntechOpen.
- Beşli N, Tenekeci E, 2020 Uydu verilerinden karar ağaçları kullanarak orman yangını tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(3), 899-906.
- Bilgili E, Küçük Ö, Sağlam B, Coşkun A, 2021, Mega forest fires: causes, organization and management.
- Bilücan F, Teke A, Kavzoğlu T, 2022 Topluluk Tabanlı Makine Öğrenmesi Algoritmaları İle Orman Yangını Duyarlılık Haritalaması: Hatay Örneği.
- Brownlee J, 2016, Machine learning algorithms from scratch with Python. *Machine Learning Mastery*.
- Bjånes A, De La Fuente R, Mena P, 2021, A deep learning ensemble model for wildfire susceptibility mapping. *Ecological Informatics*, 65, 101397.

- Bjånes A, De La Fuente R, Mena, P, 2021, A deep learning ensemble model for wildfire susceptibility mapping. *Ecological Informatics*, 65, 101397.
- Boyatan M, 2019, Yangın risk ve tehlike haritalarının oluşturulmasında kullanılacak karar destek sistemlerinin geliştirilmesi, Artvin Çoruh Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Artvin.
- Campbell J B, Wynne R H, 2011, Introduction to remote sensing. Guilford press.
- Chuvieco E, Aguado I, Jurdao S, Pettinari M L, Yebra M, Salas J, Martínez-Vega F J, 2012, Integrating geospatial information into fire risk assessment. *International journal of wildland fire*, 23(5), 606-619.
- Çolak E, Sunar F, 2020, Evaluation of forest fire risk in the Mediterranean Turkish forests: A case study of Menderes region, Izmir. *International journal of disaster risk reduction*, 45, 101479.
- Deperlioğlu Ö ve Köse U, 2024, Python ile Makine Öğrenmesi Temel Kavramlar – Sınıflandırma – Regresyon – Kümeleme, Seçkin Yayıncılık, 2024
- Dilekçi S, Marangoz A M, Ateşoğlu A, 2021, Zonguldak ve Ereğli Orman İşletme Müdürlükleri Orman Yangını Risk Alanlarının Belirlenmesi. *Geomatik*, 6(1), 44-53.
- Döş M, Uysal M, 2019, Uzaktan algılama verilerinin derin öğrenme algoritmaları ile sınıflandırılması. *Türkiye Uzaktan Algılama Dergisi* , 1 (1) , 28-34 .
- Eker R, Alkiş K C, Uçar Z, Aydın A, 2023, Ormancılıkta makine öğrenmesi kullanımı. *Turkish Journal of Forestry*, 24(2), 150-177.
- Erten C, Harding P J, Kobourov, S G, Wampler K, Yee G, 2004, GraphAEL: Graph animations with evolving layouts. In *Graph Drawing: 11th International Symposium, GD 2003 Perugia, Italy, September 21-24, 2003 Revised Papers* 11 (pp. 98-110). Springer Berlin Heidelberg.
- Erten E, Kurgun V, Musaoglu N, 2004, Forest fire risk zone mapping from satellite imagery and GIS: a case study. In *XXth Congress of the International Society for Photogrammetry and Remote Sensing, Istanbul, Turkey* (pp. 222-230).
- FAO. 2020. Global Forest Resources Assessment 2020: Main report. Rome. <https://doi.org/10.4060/ca9825en> (Erişim: 20.10.2022)

- Fidanboy M, Adar N, Okyay S, 2022, Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması. *Ormancılık Araştırma Dergisi*, 9(2), 206-218.
- Géron A, 2022, Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. "O'Reilly Media, Inc."
- Ghorbanzadeh O, Blaschke T, Gholamnia K, Aryal J, 2019, Forest fire susceptibility and risk mapping using social/infrastructural vulnerability and environmental variables. *Fire*, 2(3), 50.
- Goodfellow, I. (2016). Deep learning.
- Gövdetaşan M, 2022, Orman yangınlarının uzaktan algılama teknikleri ile analizi: Biga ve Gelibolu Yarımadası örneği, Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, Çanakkale.
- Guo F, Zhang L, Jin S, Tigabu M, Su Z, Wang W, 2016, Modeling anthropogenic fire occurrence in the boreal forest of China using logistic regression and random forests. *Forests*, 7(11), 250.
- Gülçin D, Deniz B, 2020, Remote sensing and GIS-based forest fire risk zone mapping: The case of Manisa, Turkey. *Turkish Journal of Forestry*, 21(1), 15-24.
- He Q, Jiang Z, Wang M, Liu K, 2021, Landslide and wildfire susceptibility assessment in southeast asia using ensemble machine learning methods. *Remote Sensing*, 13(8), 1572.
- Heaton, J. (2020). Applications of deep neural networks. arXiv preprint arXiv:2009.05673.
- Jain A, Ravan S A, Singh R K, Das K K, Roy P S, 1996, Forest fire risk modelling using remote sensing and geographic information system. *Current Science*, 928-933.
- Jo T, 2021, Makine öğreniminin temelleri. *Makine Öğreniminin Temelleri*. Springer Nature Switzerland AG, 2021 <https://doi.org/10.1007/978-3-030-65900-4>
- Kavgacı A (Ed.), Başaran M A (Ed.), 2023, Orman yangınları. Türkiye Ormancılar Derneği Yayını, 422 s. Ankara.
- Kavlak, M Ö, Kurtipek A, Çabuk S N, 2020, Coğrafi Bilgi Sistemleri ile orman yangını risk haritası oluşturulması: Ören örneği. *Resilience*, 4(1), 33-54.

- Kavzoğlu T (Ed.), 2021, Orman yangınları: sebepleri, etkileri, izlenmesi, alınması gereken önlemler ve rehabilitasyon faaliyetleri, Türkiye Bilimler Akademisi.
- Koçkan Ç, 2015, Doğal Afet Risk Yönetimi, 3. Türkiye Deprem Mühendisliği ve Sismoloji Konferansı, 14-16.
- Küçük Ö, Sağlam B, 2004, Orman yangınları ve hava halleri, Kastamonu Üniversitesi Orman Fakültesi Dergisi, 4(2), 220-231.
- Legg, S. (2021). IPCC, 2021: Climate change 2021-the physical science basis. Interaction, 49(4), 44-45.
- MGM, 2022, 2022 Yılı Meteorolojik Afetler Değerlendirmesi, T.C. Çevre, Şehircilik Ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü, Ankara
- Mohajane M, Costache R, Karimi F, Pham Q B, Essahlaoui A, Nguyen H, Oudija F, 2021 Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. Ecological Indicators, 129, 107869.
- Morde V, Setty V A, 2019. Xgboost algorithm: Long may she reign. Towards Data Science, 8.
- Naderpour M, Rizeei H M, Ramezani F, 2021, Forest fire risk prediction: a spatial deep neural network-based framework. Remote Sensing, 13(13), 2513.
- Najafabadi M M, Villanustre, F, Khoshgoftaar T M, Seliya N, Wald R, Muharemagic E, 2015, Deep learning applications and challenges in big data analytics. Journal of Big Data, 2(1), 1–21.
- Novo A, Fariñas-Álvarez, N., Martínez-Sánchez, J., González-Jorge, H., Fernández-Alonso, J. M., & Lorenzo, H. (2020). Mapping forest fire risk—a case study in Galicia (Spain). Remote Sensing, 12(22), 3705.
- OGM, 2019, Sürdürülebilir Orman Yönetimi Kriter Ve Göstergeleri Türkiye Raporu 2019, Orman Genel Müdürlüğü (OGM), Ankara.
- OGM, 2022, Orman Genel Müdürlüğü 2021 Yılı Resmi İstatistikleri.
- Parajuli A, Gautam A P, Sharma S P, Bhujel K B, Sharma G, Thapa P B, Poudel, S, 2020, Forest fire risk mapping using GIS and remote sensing in two major landscapes of Nepal. Geomat Nat Haz Risk 11 (1): 2569–2586.

- Parlak B, 2023, Bütünleşik Afet Yönetiřimi: Hibrid Model Önerisi. TESAM Strateji Dergisi, 3, 21-24.
- Pettinari M L, Ottmar R D, Prichard S J, Andreu A G, Chuvieco E, 2013, Development and mapping of fuel characteristics and associated fire potentials for South America. International journal of wildland fire, 23(5), 643-654.
- Pourghasemi H R, Kariminejad N, Amiri M, Edalat M, Zarafshar M, Blaschke T, Cerda A, 2020, Assessing and mapping multi-hazard risk susceptibility using a machine learning technique. Scientific reports, 10(1), 1-11.
- Pradhan B, Dini Hairi Bin Suliman M, Arshad Bin Awang M, 2007, Forest fire susceptibility and risk mapping using remote sensing and geographical information systems (GIS). Disaster Prevention and Management: An International Journal, 16(3), 344-352.
- Sabuncu A, Özener H, 2019, Uzaktan algılama teknikleri ile yanmış alanların tespiti: İzmir Seferihisar orman yangını örneđi.
- Santos, I., Castro, L., Rodriguez-Fernandez, N., Torrente-Patino, A., & Carballal, A. (2021). Artificial neural networks and deep learning in the visual arts: A review. Neural Computing and Applications, 33, 121-157.
- Satir O, Berberoglu S, Donmez C, 2016, Mapping regional forest fire probability using artificial neural network model in a Mediterranean forest ecosystem. Geomatics, Natural Hazards and Risk, 7(5), 1645-1658.
- Sayad Y O, Mousannif H, Al Moatassime H, 2019, Predictive modeling of wildfires: A new dataset and machine learning approach. Fire safety journal, 104, 130-146.
- Sevinc V, Kucuk O, Goltas M, 2020, A Bayesian network model for prediction and analysis of possible forest fire causes. Forest Ecology and Management, 457, 117723.
- Sivrikaya, F., Enez, K., & Özcan, G. (2024). Orman yol ağının orman yangınlarına etkisinin coğrafi bilgi sistemleri ile araştırılması. Anadolu Orman Arařtırmaları Dergisi, 10(1), 72-77.
- Sunar F, Özkan C, Osmanoglu B, 2013, Uzaktan Algılama Kitabı, Anadolu Üniversitesi Yayını, (2320), 9-15.

- Şatır O, Berberoğlu S, 2021, Geçmişten Günümüze Orman Yangınlarının Önlenmesinde Kullanılan Risk Haritalama, Kavzoğlu T (Ed.), 2021, Orman yangınları: sebepleri, etkileri, izlenmesi, alınması gereken önlemler ve rehabilitasyon faaliyetleri, Türkiye Bilimler Akademisi.
- Tavakkoli Piralilou S, Einali G, Ghorbanzadeh O, Nachappa T G, Gholamnia K, Blaschke, T, Ghamisi P, 2022, A Google Earth Engine approach for wildfire susceptibility prediction fusion with remote sensing data of different spatial resolutions. Remote sensing, 14(3), 672.
- Thach N N, Ngo D B T, Xuan-Canh P, Hong-Thi N, Thi B H, Nhat-Duc, H, Dieu T B, 2018, Spatial pattern assessment of tropical forest fire danger at Thuan Chau area (Vietnam) using GIS-based advanced machine learning algorithms: A comparative study. Ecological informatics, 46, 74-85.
- TOD, 2022. Türkiye Ormancılığı 2022, Türkiye’de Ormansızlaşma ve Orman Bozulması. Editör: Erdoğan Atmış. Türkiye Ormancılar Derneği Yayını. 200 S. Ankara
- Tolunay D, 2021, İklim değişikliğiyle yükselen yangın riskine karşı alınabilecek önlemler. 2. Orman Yangınları Çalıştayı, Muğla, Türkiye, 28, 74-83.
- Van Le H, Hoang D A, Tran C T, Nguyen P Q, Hoang N D, Amiri M, Bui D T, 2021, A new approach of deep neural computing for spatial prediction of wildfire danger at tropical climate areas. Ecological Informatics, 63, 101300.
- Yıldırım O, Gunay F B, Yağanoğlu M, 2023, Makine Öğrenmesi Yöntemleriyle Orman Yangını Tahmini. Journal of the Institute of Science and Technology, 13(3), 1468-1481.
- Zhang G, Wang M, Liu K, 2019, Forest fire susceptibility modeling using a convolutional neural network for Yunnan province of China. International Journal of Disaster Risk Science, 10(3), 386-403.
- Zhang G, Wang M, Liu K, 2021, Deep neural networks for global wildfire susceptibility modelling. Ecological Indicators, 127, 107735.

İnternet Kaynakları

- 1- <https://www.ipcc.ch/report/ar6/syr/summary-for-policymakers/>, 01.02.2024
- 2- <https://cs.stanford.edu/people/karpathy/>, 10.05.2021
- 3- https://keras.io/guides/sequential_model/, 10.08.2023
- 4- [https://tr.wikipedia.org/wiki/Bal%C4%B1kesir_\(il\)](https://tr.wikipedia.org/wiki/Bal%C4%B1kesir_(il)), 01.03.2023



Uysal, M. M., Uysal, M., & Uysal, C. (2016). Sleuth Modeli ile Kentsel Gelişimin İzlenmesi, 6. UZAL-CBS Sempozyumu, 5-7.

Uysal, C., Uysal, M., & Uysal, M. (2020). CBS Temelli Hücresel Özişleme Yaklaşımı ile Kentsel Büyüme Simülasyonu: Afyonkarahisar Örneği. Türkiye Coğrafi Bilgi Sistemleri Dergisi, 2(1), 26-36.

