



**T. C.
SIVAS CUMHURİYET ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ANTALYA MANAVGAT BÖLGESİNDE CBS VE MAKİNE
ÖĞRENMESİ DESTEKLİ ORMAN YANGINI RİSK BİLGİ
SİSTEMİ OLUŞTURULMASI**

YÜKSEK LİSANS TEZİ

**İzzet ERSOY
(20209249009)**

**Geomatik Mühendisliği Ana Bilim Dalı
Tez Danışmanı: Doç. Dr. Önder GÜRSOY
2. Danışman: Dr. Öğr. Üyesi Emre ÜNSAL**

**SIVAS
HAZİRAN 2024**

İzzet ERSOY' un hazırladığı ve “**ANTALYA MANAVGAT BÖLGESİNDE CBS VE MAKİNE ÖĞRENMESİ DESTEKLİ ORMAN YANGINI RİSK BİLGİ SİSTEMİ OLUŞTURULMASI**” adlı bu çalışma aşağıdaki jüri tarafından **GEOMATİK MÜHENDİSLİĞİ ANA BİLİM DALI**’ nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Doç. Dr. Önder GÜRSOY

Sivas Cumhuriyet Üniversitesi

.....

Jüri Üyesi

Doç. Dr. Adalet DERVİŞOĞLU

İstanbul Teknik Üniversitesi

.....

Jüri Üyesi

Dr. Öğr. Üyesi Nuray BAŞ

Sivas Cumhuriyet Üniversitesi

.....

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Nevcihan GÜRSOY

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu'nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırlanmıştır.



Bütün hakları saklıdır.

Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

© İzzet ERSOY, 2024

Aileme...



ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada;

- ✓ 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 ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Bütün bilgilerin doğru ve tam olduğunu, kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ✓ Tezin herhangi bir bölümünü, Sivas Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

25.06.2024

İzzet ERSOY

KATKI BELİRTME VE TEŞEKKÜR

Lisans ve yüksek lisans eğitimim boyunca bilgi ve deneyimlerinden sürekli yararlandığım, tezin her aşamasında beni yönlendiren çok değerli danışman hocam Doç. Dr. Önder GÜRSOY' a;

Tez çalışması süresince yardımlarını esirgemeyen Cumhuriyet Üniversitesi Yazılım Mühendisliği Bölümü'nden kıymetli hocam Dr. Öğr. Üyesi Emre ÜNSAL' a;

Eğitimim ve bütün hayatım boyunca maddi manevi her yönden beni destekleyen, bana inanan ve güvenen çok değerli aileme sonsuz teşekkür ederim.

ÖZET

ANTALYA MANAVGAT BÖLGESİNDE CBS VE MAKİNE ÖĞRENMESİ DESTEKLİ ORMAN YANGINI RİSK BİLGİ SİSTEMİ OLUŞTURULMASI

İzzet ERSOY

Yüksek Lisans Tezi

Geomatik Mühendisliği Anabilim Dalı

Danışmanlar: Doç. Dr. Önder GÜRSOY, Dr. Öğr. Üyesi Emre ÜNSAL

2024, 142+xix sayfa

Orman yangınları çevresel ve ekonomik etkileri bakımından büyük afetlerdir. Yangınlar, flora ve fauna kayıplarına, habitat tahribatına ve biyolojik çeşitliliğin azalmasına neden olmaktadır. Hava kirliliği, toprak erozyonu ve su kaynaklarının kirlenmesi gibi olumsuz etkileri vardır. Dünyada her yıl yaklaşık 120 milyon hektar ormanlık alan yanarak yok olmaktadır. Bu da yaklaşık 168 milyon 67 bin adet futbol sahasının büyüklüğüne veya Güney Afrika'nın yüzölçümüne eşittir. Orman yangınları; doğal sebepler, ihmal, kaza, kasıt ve sebebi bilinmeyen yangınlar olarak birçok sebepten çıkmaktadır. Bu yangınları önleyebilmek için, yangın öncesinde riski öngörmek amacıyla Coğrafi Bilgi Sistemleri ve Makine Öğrenmesi disiplinlerinden yardım alınarak bir bilgi sistemi oluşturulmuştur. Oluşturulan bu sistemde, çalışma bölgesine ait; orman meşcere haritaları, meteorolojik veriler, orman yangın envanteri ve arazi kullanım haritası edinilerek, toplam 13 adet kriter belirlenmiş ve bilgi sistemine entegre edilmiştir. Hem Analitik Hiyerarşi Prosesi hem de literatür taraması sonucunda geçmiş çalışmalarda kullanılan verilerden elde edilen bilgiler toplanarak girdi verilerine ağırlıklar belirlenmiştir. Ağırlıklı çakıştırma sonucunda çalışma bölgesine ait 5 adet risk sınıfı oluşturulmuştur. Geçmişte çıkan yangınların konumları ile çıktı verileri kıyaslandığında, risk sınıflarının alansal dağılımında yüzdesi literatür taraması sonucunda elde edilen harita için; çok yüksek risk %27, yüksek risk %37, normal risk %22, düşük risk %14 ve çok düşük risk %0 olarak; AHP için ise çok yüksek risk %41, yüksek risk %23, normal risk %20, düşük risk %12 ve çok düşük risk %4 olarak hesaplanmıştır. Sonrasında belirlenen sınıfların doğruluğu Makine

Öğrenmesi kullanarak doğrulanmış ve %85'in üzerinde doğruluk elde edilmiştir. Ayrıca bu makine öğrenmesi modeli yalnızca mevcut verilerden değil, farklı durumlarda farklı verilerden de sonuç sağlayacak ve bilgi sistemi; geliştirilen kullanıcı ara yüzü ve esnek yapısı ile farklı topoğrafyaya, farklı orman yapısına ve farklı iklimlere ait ormanlık alanlarda da çalıştırılıp kullanılabilir. Böylelikle yalnızca çalışma alanı için değil, tüm orman alanlarının korunmasına yönelik bir bilgi sistemi ve model olmuştur.

Anahtar kelimeler: Orman yangını, risk haritası, yangın risk bilgi sistemi, CBS, makine öğrenmesi, analitik hiyerarşi prosesi.



ABSTRACT

CREATING A FOREST FIRE RISK INFORMATION SYSTEM SUPPORTED BY GIS AND MACHINE LEARNING IN ANTALYA MANAVGAT

İzzet ERSOY

Master of Science Thesis

Department of Geomatics Engineering

Supervisors: Assoc. Prof. Önder GÜRSOY, Asst. Prof. Emre ÜNSAL

2024, 142+xix pages

Forest fires significantly impact the environment and economy, leading to flora and fauna loss, habitat destruction, and decreased biodiversity. They also contribute to air pollution, soil erosion, and water resource contamination. Approximately 120 million hectares of forested areas are destroyed by burning every year in the world. This is approximately equal to the size of 168 million 67 thousand football fields or the area of South Africa. Causes of forest fires include natural factors, negligence, accidents, intentional acts, and unknown origins. To mitigate these fires, an information system leveraging Geographic Information Systems (GIS) and Machine Learning (ML) has been developed to predict fire risk. This system incorporates forest stand maps, meteorological data, forest fire inventory, and land use maps, integrating 13 criteria. Weights for input data were derived using the Analytical Hierarchy Process and literature review, resulting in five risk classes: very high risk, high risk, normal risk, low risk, and very low risk. Comparison with historical fire locations revealed the areal distribution for the literature review map as 27% very high risk, 37% high risk, 22% normal risk, 14% low risk, and 0% very low risk. For the AHP map, the distribution was 41% very high risk, 23% high risk, 20% normal risk, 12% low risk, and 4% very low risk. The accuracy of these classifications was verified using ML, achieving over 85% accuracy. This ML model is adaptable, providing results from both existing and new data under varying conditions. The developed information system, with its user-friendly interface and flexible structure, is applicable across diverse topographies, forest structures, and climates. Consequently, it serves as a robust model for

safeguarding forest areas beyond the initial study region, contributing to comprehensive forest protection.

Key Words: Forest fire, risk map, fire risk information system, GIS, machine learning, AHP.



İÇİNDEKİLER

ÖZET.....	viii
ABSTRACT	x
İÇİNDEKİLER	xii
ŞEKİLLER DİZİNİ	xv
TABLolar DİZİNİ	xvi
DENKLEMLER DİZİNİ.....	xviii
KISALTMALAR DİZİNİ	xix
1. GİRİŞ.....	1
1.1. Ormanların Önemi.....	1
1.2. Dünyada ve Türkiye’de Orman Varlığı.....	2
1.3. Orman Yangını Nedir	5
1.4. Yangın Duyarlılık Haritaları.....	8
1.5. Orman Yangınlarının Zararları ve Etkileri "Genel"	11
1.6. Orman Yangınlarının Zararları ve Etkileri "Türkiye"	15
1.7. Yangınları Önlemek/Mücadele Etmek İçin Neler Yapılabilir.....	17
1.8. Orman Yangınlarında CBS ve Makine Öğrenmesi Yönteminin Önemi ve Kullanımı.....	19
1.9. Literatür Taraması	22
1.10. Çalışmanın Amacı, Önemi ve Kapsamı.....	31
2. KAVRAMSAL ÇERÇEVE.....	33
2.1. Yangın	33
2.2. Orman Yangını Türleri.....	34
2.3. Yangın Çıkış Nedenleri	34
2.4. Yangına Sebebiyet Veren Etkenler	36
2.4.1. Topoğrafik veriler:	36
2.4.2. Biyolojik veriler:	37
2.4.3. Meteorolojik veriler:	38
2.4.4. İnsan faktörlü veriler:.....	39
2.5. Makine Öğrenmesi	40
2.5.1. Yapay sinir ağları (NN):.....	42
2.5.2. Destek vektör makineleri (SVM):.....	45
2.5.3. Naive bayes (NB):.....	46
2.5.4. Doğrusal diskriminant analizi (LDA):	47
2.5.5. K-En yakın komşu (KNN):	48
2.5.6. Karar ağaçları (DT):.....	49

2.6.	CBS	52
2.6.1.	Veri:	52
2.6.2.	Yazılım:.....	54
2.6.3.	Donanım:.....	54
2.6.4.	İnsan:	55
2.6.5.	Yöntem:.....	55
2.7.	AHP	56
2.7.1.	Problemin tanımlanması veya hiyerarşik yapının oluşturulması:	57
2.7.2.	İkili karşılaştırılmaların oluşturulması:	58
2.7.3.	Kriterlerin ağırlıklarının hesaplanması:	59
2.7.4.	Duyarlılık analizi veya tutarlılıkların belirlenmesi:	60
3.	MATERYAL VE METOT.....	62
3.1.	Çalışma Sahasına Ait Bilgiler	62
3.2.	Materyal.....	64
3.2.1.	Veri seti:	64
3.2.2.	Tarihsel yangın verileri:	67
3.3.	Metot	68
3.3.1.	Parametreler:	68
3.3.2.	Literatür:.....	69
3.3.3.	Analitik hiyerarşi prosesi:	72
3.3.4.	Coğrafi bilgi sistemleri:	74
3.3.5.	Makine öğrenmesi:.....	78
4.	SONUÇLAR.....	81
4.1.	Sınıflandırma Sonuçları.....	83
4.1.1.	Yükseklik:	83
4.1.2.	Bakı:	84
4.1.3.	Eğim:	86
4.1.4.	Arazi örtüsü:.....	87
4.1.5.	Meşcere kapalılığı:	89
4.1.6.	Gelişme çağları:	90
4.1.7.	Sıcaklık:	92
4.1.8.	Nem:.....	93
4.1.9.	Rüzgâr şiddeti:	95
4.1.10.	Yağış:.....	96
4.1.11.	Yollara uzaklık:	97

4.1.12.	Yerleşime uzaklık:.....	99
4.1.13.	Tarıma uzaklık:.....	100
4.2.	Literatür Ağırlıklarıyla Elde Edilen Sonuçlar	102
4.3.	Analitik Hiyerarşi Prosesi Sonuçları	105
4.4.	Literatür ve AHP Sonuçlarının Karşılaştırılması	107
4.5.	Makine Öğrenmesi Sonuçları	109
5.	TARTIŞMA VE ÖNERİLER.....	114
5.1.	Tartışma.....	114
5.2.	Öneriler.....	117
KAYNAKÇA		120
EKLER.....		135
EK-1:	İş akış şeması	135
EK-2:	CBS ortamında kurulan modelin arka planı	136
EK-3:	Genel ağırlıklar tablosu.....	137
ÖZGEÇMİŞ.....		142

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1 1990-2020 arası Dünya ormanlarının yıllık net değişimi	7
Şekil 2 Yangın Üçgeni	33
Şekil 3 Yapay sinir hücresi	42
Şekil 4 Yapay sinir ağlarının yapısı	44
Şekil 5 SVM sınıflandırması	46
Şekil 6 LDA sınıflandırması	47
Şekil 7 KNN sınıflandırması	49
Şekil 8 DT sınıflandırması	50
Şekil 9 Raster ve vektör veri türleri	53
Şekil 10 AHP'nin yapısı	57
Şekil 11 Çalışma bölgesi	62
Şekil 12 Tarihsel yangın verileri	67
Şekil 13 İş akış şeması	68
Şekil 14 CBS ortamında kurulan modelin arka planı	75
Şekil 15 Model içerisindeki semboller	75
Şekil 16 Model arayüzü	77
Şekil 17 Yangın öncesi NDVI sınıflandırması	82
Şekil 18 Yangın sonrası NDVI sınıflandırması	82
Şekil 19 Yükseklik sınıflarının risk haritası	84
Şekil 20 Bakı sınıflarının risk haritası	85
Şekil 21 Eğim sınıflarının risk haritası	87
Şekil 22 Arazi örtüsü sınıflarının risk haritası	89
Şekil 23 Meşcere kapalılığı sınıflarının risk haritası	90
Şekil 24 Gelişme çağları sınıflarının risk haritası	91
Şekil 25 Sıcaklık sınıflarının risk haritası	93
Şekil 26 Nem sınıflarının risk haritası	94
Şekil 27 Rüzgâr şiddeti sınıflarının risk haritası	96
Şekil 28 Yağış sınıflarının risk haritası	97
Şekil 29 Yollara uzaklık sınıflarının risk haritası	98
Şekil 30 Yerleşime uzaklık sınıflarının risk haritası	100
Şekil 31 Tarıma uzaklık sınıflarının risk haritası	101
Şekil 32 Literatür sonuçlarına göre oluşturulan orman yangını risk haritası	103
Şekil 33 Literatür sonuçlarına göre oluşturulan risk haritasının tarihsel yangın konumları ile doğrulanması	104
Şekil 34 AHP sonuçlarına göre oluşturulan orman yangını risk haritası	105
Şekil 35 AHP sonuçlarına göre oluşturulan risk haritasının tarihsel yangın konumları ile doğrulanması	106
Şekil 36 Literatür ve AHP sonuçlarının fark haritası	108
Şekil 37 Eğitim veri setinin ROC eğrisi	112
Şekil 38 Test veri setinin ROC eğrisi	112

TABLolar DİZİNİ

	<u>Sayfa</u>
Tablo 1 Dünyadaki ormanlık alan dağılımı.....	2
Tablo 2 2010-2020 arası ormanlarında yıllık ortalama net kazanç açısından ilk 10 ülke.....	3
Tablo 3 1973-2022 arası Türkiye ormanlarının alansal değişimi.....	3
Tablo 4 Türkiye ormanlarının il düzeyinde dağılımı, ilk 5	4
Tablo 5 1990 – 2020 arası Dünyadaki ormanlık alan sayısı	6
Tablo 6 2010-2020 arası ormanlık alanında yıllık ortalama net kayıp açısından ilk 10 ülke.....	7
Tablo 7 1937-2022 yılları arasında Türkiye’de çıkan orman yangını sayıları ve yanan alan miktarı.....	16
Tablo 8 Orman yangınlarının çıkış sebeplerine göre sayısal ve alansal dağılımı	35
Tablo 9 Saaty önem ölçeği tablosu.....	58
Tablo 10 İkili karşılaştırma matrisinin oluşturulması	59
Tablo 11 Rassallık indeksi değerleri tablosu.....	60
Tablo 12 Parametrelerin, sınıflarının ve risk derecelerinin seçiminde kullanılan literatür çalışmaları.....	64
Tablo 13 Veri seti	66
Tablo 14 Literatürdeki çalışmaların parametrelere verdikleri ağırlık değerleri	70
Tablo 15 Literatür araştırması sonucu elde edilen nihai ağırlıklar.....	71
Tablo 16 Ana kriterlerin ikili karşılaştırma matrisi	72
Tablo 17 Biyolojik kriterlerin ikili karşılaştırma matrisi	72
Tablo 18 İnsan kriterlerinin ikili karşılaştırma matrisi.....	73
Tablo 19 Meteorolojik kriterlerin ikili karşılaştırma matrisi.....	73
Tablo 20 Topoğrafik kriterlerin ikili karşılaştırma matrisi.....	73
Tablo 21 AHP sonucu elde edilen nihai ağırlıklar	74
Tablo 22 Genel ağırlıklar tablosu	76
Tablo 23 Makine öğrenmesi için hazırlanan veri setinden alınan rastgele 10 örneklem.....	79
Tablo 24 2021 yangını sonrasında çalışma sahasındaki değişim	81
Tablo 25 Yükseklik kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	83
Tablo 26 Bakı kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları.....	85
Tablo 27 Eğim kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları....	86
Tablo 28 Arazi örtüsü kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	87
Tablo 29 Meşcere kapallılığı kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	89
Tablo 30 Gelişme çağı kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	91
Tablo 31 Sıcaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları.....	92
Tablo 32 Nem kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları.....	94
Tablo 33 Rüzgâr şiddeti kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	95
Tablo 34 Yağış kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları ...	96
Tablo 35 Yollara uzaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	98

Tablo 36 Yerleşime uzaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	99
Tablo 37 Tarıma uzaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları	100
Tablo 38 Orman yangını örnek risk senaryosu	101
Tablo 39 Literatür sonuçları	105
Tablo 40 AHP sonuçları	107
Tablo 41 Literatür ve AHP sonuçlarının fark tablosu	108
Tablo 42 Eğitim sonrası performans değerlendirmesi.....	110
Tablo 43 Test sonrası performans değerlendirmesi.....	110
Tablo 44 Karışıklık matrisi.....	111
Tablo 45 Sınıflandırma performansının ölçülmesi için kullanılan metrikler	111



DENKLEMLER DİZİNİ

	<u>Sayfa</u>
Denklem [2. 1]	46
Denklem [2. 2]	51
Denklem [2. 3]	51
Denklem [2. 4]	51
Denklem [2. 5]	51
Denklem [2. 6]	51
Denklem [2. 7]	59
Denklem [2. 8]	59
Denklem [2. 9]	60
Denklem [2. 10]	60
Denklem [2. 11]	60
Denklem [3. 1]	71
Denklem [3. 2]	74

KISALTMALAR DİZİNİ

AHP	: Analitik Hiyerarşi Prosesi
ASTER	: Advanced Spaceborne Thermal Emission and Reflection Radiometer
AUC	: Eğrinin Altında Kalan Alan
CR	: Tutarlılık Oranı
DT	: Karar Ağaçları
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
IDW	: Inverse Distance Weighted
KNN	: K-En Yakın Komşu
LDA	: Doğrusal Diskriminant Analizi
MGM	: Meteoroloji Genel Müdürlüğü
NASA	: National Aeronautics and Space Administration
NB	: Naïve Bayes
NDVI	: Normalize Edilmiş Fark Bitki İndeksi
NN	: Yapay Sinir Ağı
OİM	: Orman İşletme Müdürlüğü
Rİ	: Rassallık İndeksi
ROC	: Alıcı İşletim Karakteristiği
SVM	: Destek Vektör Makineleri
SYM	: Sayısal Yükseklik Modeli
Tİ	: Tutarlılık İndeksi
TN	: Gerçek Negatif
TO	: Tutarlılık Oranı
TP	: Gerçek Pozitif

1. GİRİŞ

1.1. Ormanların Önemi

Dünyanın akciğerleri ormanlar, ekolojik dengeyi koruyarak sürdürülebilir kılan ve bu sebeple özenle korunması gereken en kıymetli doğal kaynaklarımızdan biridir (Atmaca vd., 2022; Zainalabden, 2022).

Orman ekosistemi; içerisinde yaşayan birçok organizmaya ev sahipliği yaparak, canlıların kendilerini korudukları, barındıkları ve devamlılıklarını sürdürdükleri yaşam alanlarıdır. Tüm bunlarla beraber insanlar için de yeri doldurulamaz değerli kaynaklardır. Öyle ki dünyadaki kara yüzeylerinin %30'unu oluşturan ormanlar yakıt, ilaç ve gıda gibi temel ihtiyaçları bir milyardan fazla insan için temin etmektedir. Ayrıca odun, insan yaşamının her alanında var olan önemli bir hammadDEDİR. Hem ormancılık ve orman ürünlerin yönetim ve üretimi yönüyle hem de turistik yönüyle ekonomiye de katkı sağlamaktadır (Karadeniz, 2020).

İnsanlar ve diğer canlıların yanı sıra çevresel faydaları da göz ardı edilemeyecek kadar değerli olan ormanlar; su ve çevre yönetiminin düzenlenmesinde, iklimsel bozulmasının engellenmesinde, toprakların sağlığı ve korunmasında, biyoçeşitliliğin muhafazasında, hava kirliliğinin önlenmesinde ve hatta rekreasyon faaliyetleri ile insanların ruhsal sağlığı açısından oldukça büyük bir öneme sahiptir (Muhammad vd., 2021; Yıldırım, 2023).

Sonuç olarak, ormanların faydaları yalnızca insanlarla sınırlı kalmaz, aynı zamanda tüm dünyada ekosistemlerin sağlıklı bir şekilde devamı ve doğal dengenin korunması için kritik bir rol oynar.

Bu nedenle ormanların ve ormanlık alanların artırılması, korunması ve sürdürülebilir bir şekilde yönetilmesi büyük bir öneme sahiptir. Bununla birlikte, yok edilmesi halinde yeniden yerine getirilmesi oldukça masraflı ve son derece zaman alıcı bir süreçtir (Asri vd., 2015).

1.2. Dünyada ve Türkiye’de Orman Varlığı

Ormanlık alanlar, toplamda 4,06 milyar hektar ile Dünya kara yüzeyinin yaklaşık %31’ini oluşturmaktadır. Avrupa’nın tamamı ormanların yaklaşık %25’ine sahip iken bu oran Güney ve Kuzey Amerika toplamında %39, Afrika’da %16, Asya’da %15 ve Antarktika’da %5 tir (Tablo 1). 815 milyon hektar ormanlık alana sahip olan Rusya Federasyonu ise dünyanın en büyük ormanlık alanına sahip ülkesidir (FAO, 2020).

Tablo 1 Dünyadaki ormanlık alan dağılımı

Bölge	Orman Alanı	
	(×1.000 ha)	Yüzde
Avrupa	1.017.461	25%
Amerika	1.596.896	39%
Afrika	636.639	16%
Asya	622.687	15%
Antarktika	185.248	5%
Dünya	4.058.931	100%

2010-2020 dönemleri arasındaki 10 yıllık süreçte Dünyadaki ormanlık alan değişimleri açısından Türkiye, ormanlık alanlarını yıllık ortalama 114 bin hektar (ülke ormanlarının yaklaşık %0,53’ü) artırmıştır ve ormanlık alan kazancı açısından Dünya sıralamasında 6. sırada yer almaktadır. Birinci sırada ise ormanlık alanlarını yıllık ortalama 1 milyon 937 bin hektar artıran Çin vardır (Tablo 2) (FAO, 2020).

Tablo 2 2010-2020 arası ormanlarında yıllık ortalama net kazanç açısından ilk 10 ülke

Sıra	Ülke	Yıllık net değişim	
		×1.000 ha/yıl	Yüzde
1	Çin	1.973	0,93%
2	Avustralya	446	0,34%
3	Hindistan	266	0,38%
4	Şili	149	0,85%
5	Vietnam	126	0,90%
6	Türkiye	114	0,53%
7	Abd	108	0,03%
8	Fransa	83	0,50%
9	İtalya	54	0,58%
10	Romanya	41	0,62%

Türkiye özelinde bakıldığında 1973 yılından 2022 ye kadar geçen 49 yıllık süreçte ülkemiz, orman alanlarını yaklaşık olarak toplamda 3 milyon 45 bin hektar artırarak toplam orman varlığını 2022 yılı itibariyle 23 milyon 245 bin hektara çıkarmayı başarmıştır (Tablo 3) (OGM, 2022).

Tablo 3 1973-2022 arası Türkiye ormanlarının alansal değişimi

Yıllar	Orman Alanı (×1.000 ha)
1973	20.199
1999	20.763
2005	21.188
2012	21.678
2015	22.342

Tablo 3 1973-2022 arası Türkiye ormanlarının alansal değişimi (devam)

2018	22.621
2020	22.933
2022	23.245

Bu da ülkenin yaklaşık %30'unun ormanlarla kaplı olduğu anlamına gelir.

Bu ormanların yaklaşık 1,2 milyon hektarı Antalya ilindedir ve Antalya en büyük orman alanına sahip ilimizdir (Tablo 4) (OGM, 2022).

Tablo 4 Türkiye ormanlarının il düzeyinde dağılımı, ilk 5

Sıra	İller	Orman Alanı (×1.000 ha)	Türkiye geneli yüzdesi
1	Antalya	1.177	5,1%
2	Kastamonu	876	3,8%
3	Mersin	835	3,6%
4	Muğla	833	3,6%
5	Kütahya	646	2,8%

Türkiye ormanlarının %29,42'si en fazla alana sahip Meşe ile, %22,74'ü ise yangına karşı en hassas tür olan Kızılçam ile kaplıdır (OGM, 2021).

Türkiye, jeopolitik konumu dolayısıyla Akdeniz ekosistemindedir ve bu ekosistemde yangın duyarlılığı oldukça yüksektir. Mevsimsel bazda yaz aylarının sıcak ve kurak geçtiği iklim koşulları hüküm sürer. Aynı zamanda biyolojik çeşitlilik bakımından oldukça zengin olan Türkiye, bu ekosistem içerisinde 3649 adet endemik bitki türüne de ev sahipliği yapmaktadır (Karadeniz, 2020).

Akdeniz'in doğusundan başlayarak batıya doğru Akdeniz kıyıları ile Ege kıyıları ve kuzeyde de Marmara kıyıları dahil olmak üzere bu hat boyunca yaklaşık 5,5 milyon hektar ormanlık alan yangına karşı en duyarlı alanlar olarak belirlenmiştir (Akay & Erdoğan, 2017).

Bu, bu bölgelerin yangın tehdidine karşı özellikle dikkatli olunması gerektiği anlamına gelir ve yangınların önlenmesi ve kontrol altına alınması için ciddi çaba gerektirir.

1.3. Orman Yangını Nedir

İnsanlar binlerce yıl boyunca ateşi birçok farklı amaç doğrultusunda yöneterek kendilerine yardımcı bir araç olarak kullanmışlardır. Bu kullanıma örnek olarak; ısınma ve aydınlatma, avcılık ve beslenme, savunma ve iletişim, tarım ve yerleşme için toprak örtüsünü temizleme, yol açma ve güvenlik gibi birçok sebep sayılabilir (FAO, 2020).

Ateş, insanlığın hayatta kalma ve uygarlık oluşturma sürecinde kritik bir rol oynamıştır. Ayrıca ateşin kontrolü, insanların teknolojik ve kültürel gelişiminde önemli bir dönüm noktası olmuştur.

Ormanlar üzerindeki eylemlerimiz ise, insanların birbirine ve doğal dünyaya olan tutumlarının bir yansımasını oluşturur. Son yıllarda insani tutumlarımız, ormanlarımızı tehlikelerle karşı karşıya bırakarak sürdürülebilirliklerini riske atmaktadır. Ormanlar çevreden gelebilecek baskı ve tesirlere karşı hassastırlar. Bundan dolayı, farklı nedenlerle meydana gelen yangınlar ormanlara büyük zararlar verebilir (Maser, 1989; Avcı & Korkmaz, 2020; Dilekçi, 2019).

Esasında orman yangınları, birçok ekosistem için meteorolojik faaliyetler kadar kritik bir doğal ekolojik unsur olarak kabul edilmektedir. Yangınlar, birçok farklı çevresel değişkenin etkisi altında, ekosistemlerin yapısını ve fonksiyonunu belirlemede önemli bir rol oynar. En yüksek bağıl nem değerine sahip yaş ortamlar ile sıcaklık veya soğukluk değerinin aşırı olduğu koşullar hariç, yangınlar, Dünya'nın neredeyse tüm bölgelerinde tarih boyunca etkili olmuştur.

Yangınların tesirleri, bir dizi faktöre bağlı olarak büyük ölçüde değişkenlik gösterir. Bu faktörler arasında yangının ne zaman meydana geldiği, yakıt miktarı ve yapısı, yangın öncesinde ve anında meteorolojik koşulların durumu, arazinin topoğrafik yapısı, meşcere ve toprak türleri bulunur. Bu nedenle, yangınlar doğal ekosistemler için karmaşık bir rol oynar ve yangınlarla ilgili yapılan genellemelerin yerine, her

yangın olayı, yerel koşullar ve çevresel etkiler göz önüne alınarak özel olarak değerlendirilmelidir (Teketay, 2000).

Gerek insan gerekse doğal nedenlerden dolayı çıkan orman yangınları, beşerî faktörleri işin içerisinden çıkaracak olursak, bilhassa Akdeniz ekosisteminin doğal döngüsü haline gelmiştir (Baltacı & Yıldırım, 2021).


Ancak insan etkisi de işin içerisine katıldığında, doğal süreçlerden bağımsız hale gelerek geniş çaplı yangınların çıkmasına sebebiyet vermektedir (Baltacı, 2021).

Dünya çapında çıkan yangınlarla her yıl ortalama 400 milyon hektar arazi, ağaçlarla kaplı ormanların bulunduğu alanların ise her yıl ortalama 120 milyon hektarı yanarak yok olmaktadır. 1990 yılından itibaren Dünya net (ağaç kazancı – ağaç kaybı) 178 milyon hektarlık ormanlık alanı kaybetmiştir (Tablo 5). Bu alan Türkiye'nin yüzölçümünün 2 katından daha fazladır.

Tablo 5 1990 – 2020 arası Dünyadaki ormanlık alan sayısı

Bölge / Yıl	Orman alanı (×1.000 ha)			
	1990	2000	2010	2020
Avrupa	994.319	1.002.268	1.013.982	1.017.461
Amerika	1.728.945	1.674.994	1.624.344	1.596.896
Afrika	742.801	710.049	676.015	636.639
Asya	585.393	587.410	610.960	622.687
Antarktika	184.974	183.328	181.015	185.248
Dünya	4.236.432	4.158.049	4.106.316	4.058.931

Net orman kaybı oranı ise 1990 – 2000 arasındaki on yıllık süreçte toplam 7,8 milyon, 2010'a kadar 5,2 milyon ve 2020 ye kadar olan on yıllık süreçte ise 4,7 milyon hektara gerilemiştir (Şekil 1). Bu da demek oluyor ki ormanlık alanlar son yıllarda daha fazla genişlemekte ve orman kaybı oranını nispeten düşürmektedir.



Şekil 1 1990-2020 arası Dünya ormanlarının yıllık net değişimi

(FAO, 2020) “düzenlenmiştir”

Tablo 6’da ise 2010-2020 yılları arası ormanlık alanında yıllık ortalama net kayıp açısından ilk 10 ülkeyi göstermektedir.

Tablo 6 2010-2020 arası ormanlık alanında yıllık ortalama net kayıp açısından ilk 10 ülke

Sıra	Ülke	Yıllık net değişim	
		×1.000 ha/yıl	Yüzde
1	Brezilya	-1.496	-0,30%
2	Demokratik Kongo	-1.101	-0,83%
3	Endonezya	-753	-0,78%
4	Angola	-555	-0,80%
5	Tanzanya	-421	-0,88%
6	Paraguay	-347	-1,93%
7	Myanmar	-290	-0,96%
8	Kamboçya	-252	-2,68%
9	Bolivya	-225	-0,43%
10	Mozambik	-223	-0,59%

Orman yangınlarının yaklaşık olarak %90'ı kolaylıkla kontrol altına alınmaktadır ve bu yangınlarda yanan alanlar, toplam alanların %10'unu oluşturmaktadır. Yanan alanların %90'ı ise çıkan yangınların %10'luk kısmı ile yanmaktadır. Yani çıkan yangınların yalnızca %10'u büyüyerek çok büyük alanlar yakmaktadır (FAO, 2020).

Teknoloji ve bilimin orman yangınlarıyla mücadelede kullanılması, yangın kontrolü ve söndürülmesinde büyük faydalar sağlamaktadır. Ancak, orman yangınlarının hala ciddi bir tehdit olarak kabul edilmesinin ardında bir dizi faktör bulunmaktadır. Başlangıçta, iklim değişikliğinin yarattığı artan sıcaklık ve kuraklık gibi aşırı hava koşulları, orman yangınlarının daha yaygın hale gelmesine neden olmaktadır. Bu tür koşullar, yangınların hızla yayılmasını ve kontrol altına alınmasını zorlaştırmaktadır. İkinci olarak, dünya nüfusunun hızla artması, orman yangınlarının kontrol edilmesi ve söndürülmesi için daha fazla kaynağa ihtiyaç duyulmasına yol açmaktadır. Buna ek olarak, insanların orman bölgelerine yönelik artan yerleşimleri, yangın riskini artırmaktadır. Ve ormanlık alanlara yoğun bir şekilde yerleşim, yangınların daha fazla insanı etkileme potansiyelini de artırmaktadır (Ertuğrul, 2005).

Orman yangınlarının yol açtığı kayıpların tekrar yerine getirilmesi, restore edilmesi ve bu alanlarda ormanın işlevselliğini yeniden kazanabilmesi için ciddi finansal kaynak, uzun süreçler ve iş gücü gerekmektedir. Bu sebeple, yangınların çıkmadan öngörülerek önlem alınması ve bir yangın meydana geldiğinde erken müdahale stratejileri ile hızla kontrol altına alınması için titiz çalışmalar yürütülmesi stratejik önem taşımaktadır (Sepetçi, 2014).

1.4. Yangın Duyarlılık Haritaları

Ülkemiz, yangın riskinin en yüksek olduğu bölgelerden birisi olan Akdeniz Ekosisteminde yer almaktadır. Bu riski göz önünde bulundurarak yangının öncesi, yangın esnası ve yangın sonrası safhalarını doğru bir şekilde izleyerek yangın planlaması yapılmalıdır (Sepetçi, 2014).

Orman yangınlarıyla mücadelede yangının nerede ve nasıl çıkacağını bilmek neredeyse imkansızdır çünkü değişken birçok faktör bulunur (Erten vd., 2005).

Bunlar insan kaynaklı (kasıt, ihmal ve dikkatsizlik vs.) ya da doğal (yıldırım vs.) faktörlerdir. Her ne kadar insan kaynaklı yangınlar engellense dahi doğanın bu yangın döngüsünü engellemek olanaksızdır. Yine de hem engellenemeyen insan faktörünün hem doğal döngünün verdiği hasarları azaltabilir ya da bitirebiliriz (Özenen Kavlak vd., 2020).

Yangın riski, bir yangının başlama olasılığının ne kadar yüksek veya düşük olduğunu gösteren bir kavramdır. Bu risk, bir dizi faktörün bir araya gelmesi sonucunda ortaya çıkar ve bu faktörlerin bir araya geldiğinde yangın çıkarma olasılığının ne kadar arttığına bağlıdır. Örneğin insan faaliyetlerinin yoğun olduğu yerlerde -piknik ve mesire alanları gibi- yangın riski yüksektir (Sepetçi, 2014).

Aynı zamanda iklimsel koşulların değiştiği son yıllarda kuraklıkların artması, yağışların azalması ve sıcakların daha yüksek seviyelere ulaşmasıyla beraber yangın riski de artırmıştır (H. R. Pourghasemi vd., 2020).

Bu riski azaltmak ve etkili bir şekilde yönetmek için doğru planlama gereklidir. Bu planlama, özetle 4 aşamadan oluşmaktadır.

İlk aşama, yangın riskinin olduğu yerler ve o yerlerin hassasiyetini belirlemekle ilgilidir. Yani, yangın tehlikesi nerelerde ve ne kadar büyük bir riskte sorusunun yanıtlarını bulmayı içerir. İkinci aşama yangınların olası başlama noktalarını belirlemektir. Bu noktalar, yangın riskini daha iyi analiz etmemize yardımcı olacaktır. Üçüncü aşamada yangınların izlenmesi, yangınların gelişimini ve hareketini takip etmek vardır. Son aşama ise yangın bittikten sonra, yangının etkilerinin ve hasarının değerlendirilmesidir. Sonuç olarak, yangın riskini azaltmak ve orman yangınlarını yönetmek için bu dört adımı takip etmek önemlidir (Çolak & Sunar, 2020).

Risk haritalaması bu aşamaların ilk ikisini oluşturur ve bunlar dışında yöneticilere, karar vericilere ve itfaiyecilere kolaylıklar sağlayarak gerekli önlemlerin alınması konusunda yardımcı olur (Sivrikaya vd., 2014).

Yangına riskli bölgelerin belirlenmesi ve haritalanması ile yangın yönetim planları yapılırken bu haritalara uyularak yapılması hayati önem taşımaktadır. Yangınların çıkış nedenlerinin araştırılması ve aynı türden yangınların çıkabilme olasılığı olan bölgelerin belirlenmesine ve önlemler alınmasına yardımcı olmaktadır. Yangın

yönetimi genellikle sadece yangının nasıl yayılacağına odaklanır. Ancak, farklı bölgeler arasındaki öncelikleri ayırt etmek, kaynakların daha iyi kullanılmasına yardımcı olabilir (De Vasconcelos vd., 2001).

Ayrıca yangınlarla mücadelede bütçe ve kaynaklar sınırlıdır. Bu nedenle, bu sınırlı kaynakları en iyi şekilde kullanmanın yolu, nokta atışı kararlar alabilmek ve işleri verimli bir şekilde yönetebilmektir. İşte bu noktada karar destek sistemleri veya daha yalın bir ifade ile yangın risk haritaları devreye girmektedir (Baltacı & Yıldırım, 2021).

Bu sistemler en genel kavramıyla risk ve tehlike tahmin sistemleridir (Baltacı, 2021).

Yangınların can, mal ve orman kaynakları üzerindeki olası etki ve zararlarını en aza indirmek için yangın riski olan bölgelerin belirlenmesi, haritalanması ve bu alanlarda gerekli önlemlerin alınması elzemdir (Akay & Erdoğan, 2017).

Risk haritaları ya da karar destek sistemleri, orman yangınlarını daha etkili bir şekilde yönetmek için verileri analiz etmeye, riskleri değerlendirmeye ve stratejiler geliştirmeye yardımcı olur. Bu sistemler, yangınların yayılma olasılığını tahmin edebilir, olası etkilerini değerlendirebilir ve hangi bölgelerin öncelikli müdahale gerektirdiğini belirleyebilir.

Orman yangını risk haritalarının yangınlardan önce oluşturularak, meydana gelecek yangınlar için erken tahmin ve tespitin yapılması; acil durum ekiplerinin müdahalesi, yangının söndürülmesi, zararlarının azaltılması, can ve mal güvenliğinin sağlanması, arazi kullanım planlaması, ekolojik risklerin azaltılması hususunda planların geliştirilmesi ve yangına müdahale için harcanan maddi ve insan gücü kaynaklarının doğru, hızlı ve planlı bir şekilde uygulanması için son derece önemlidir (Abid, 2021; Mohajane vd., 2021; Muhammad vd., 2021).

Bu sayede sınırlı kaynaklar daha etkili bir şekilde kullanılabilir ve yangınların kontrol altına alınması, ormanları koruması ve yangınların zararlarının minimize edilmesi için daha iyi bir planlama yapılabilmesi sağlanabilir.

1.5. Orman Yangınlarının Zararları ve Etkileri "Genel"

İnsanlık var olduğu sürece ormanlar üzerindeki baskısı devam edecektir. Dünya nüfusu her geçen gün hızla artmaktadır ve bu artış aynı zamanda insanların yerleşim yerlerine, tarımsal arazilere, sanayi alanlarına ve hammaddeye olan gereksinimlerinin artması anlamına gelmektedir. Bu da ormanlık araziler ve kaynakları üzerindeki insan baskısını artırmaktadır (Karadeniz, 2020).

Yangınların oluşmasının doğal boyutu dışında bir de insan faktörü vardır ve bu faktörü düşünecek olursak insan baskısı, orman yangınlarını hem doğrudan hem dolaylı olarak etkilemekte ya da tetiklemektedir.

İnsan faktörünün yangınlar üzerindeki coğrafi etkisini anlamak, yangın riski ile başa çıkmak ve riski azaltmak için son derece önemlidir. Yangının kontrol altına alınabilmesi için büyümeden müdahale edilmesi önemlidir. Bu sebeple yangın risk haritalarından yararlanarak en doğru planlamayı yapmak ve mücadele için gerekli olan kaynakları, yangınların en sık görüldüğü veya riskin en yüksek olduğu alanlara konumlandırmak gerekir (Romero-Calcerrada vd., 2008).

Ülkemizin içinde bulunduğu ekosistemde orman yangınları kaçınılmaz bir gerçektir ve yangınları tamamen bitirmek olanaksızdır ancak zararlarını ve sayılarını büyük ölçüde azaltmak mümkündür (Dilekçi, 2019).

Son yıllarda orman yangınları, küresel ısınmanın sebep olduğu etkiler, toprakların verim kaybı, sosyo-ekonomik değişiklikler ve ormanların uygunsuz planlanması gibi faktörlerin etkisiyle daha sık ve daha büyük çaplarda meydana gelmektedir (Vieira vd., 2011).

Her yıl milyonlarca hektarlık orman alanı yanarak kül olmaktadır. Orman yangınları ekosistemlerin bir parçası olsa dahi küresel ve bölgesel düzeyde ekonomik, ekolojik ve sosyal kültüre olumsuz etkileri olan büyük bir afettir (Muhammad vd., 2021) ve geri dönüşü mümkün olmayan hasarlar bırakmaktadır (Özenen Kavlak vd., 2020).

Orman yangınları sadece ağaçları yakıp onlara zarar vermekle kalmaz. Aynı zamanda ekolojik dengeyi bozarak bütün ekosistemi tehdit etmektedir (Çepel, 1975).

Canlı yaşamlarının yok olmasına sebep olur. Canlıların barınma ve beslenmesini devam ettirdikleri yaşam alanlarını ve biyotayı yok edebilir. Ağaçlardan elde edilen

kereste gibi hammadde kaynaklarını yok eder, toprak örtüsünü yakarak biyoçeşitliliğe zarar verir (Dilekçi, 2019; Nikhil vd., 2021).

Yangınların topraklar üzerindeki en büyük zararlarından biri organik madde kaybıdır. Topraktaki yararlı organizmalar yanar ve organik madde ortadan kalkar. Toprak örtüsü yanarak toprağın yapısını ve gözenekliliğini kaybetmesine yol açar. Arazi bozunumuna ve erozyonuna yol açar. Çölleşmeyi tetikler. Sera gazı miktarı artar, emisyonu azalır. Solunum rahatsızlıklarına neden olan parçacık madde yayılımı artar (Nikhil vd., 2021; Teketay, 2000).

Yangın esnasında atmosfere büyük miktarda karbondioksit salınımı olur. Ortaya çıkan duman ve zehirli gazlar hava kalitesini etkiler, kirliliğe neden olur ve canlıların sağlığı üzerinde doğrudan ya da dolaylı yollarda olumsuz etkiler yaratır (Yıldırım, 2023).

Bu çoğu zaman canlılara ısının doğrudan etkisinden daha fazla zarar vermektedir (Teketay, 2000).

Bölgesel iklimi ve yer altı ve yer yüzeyi hidrolojisine zarar vererek su kaynaklarını kirletir. Ormanlardan elde edilen kereste ve bunun yanın sıra turizm gibi ekonomik yönden hem bölgeler için hem ülkeler için ciddi maddi kayıplara yol açmakta ve insanların geçimini de olumsuz yönde etkilemektedir (Muhammad vd., 2021; Thomas Ambadan vd., 2020).

Yangınların bu gibi zararlı etkilerini minimize etmek için ormanlık alanların çoğaltılması ve mevcut alanların korunması gereklidir (Yıldırım, 2023).

Sonuç olarak orman yangınları; canlılara, ekosistemlere, ekonomiye ve iklim değişimine dolayısıyla tüm dünyaya zarar verebilen en önemli afetlerden birisidir. Ormanlarımız, korunması gereken hassas ve önemli bir değerdir.

Dünyada orman yangınları deyince akla ABD, Kanada, Avustralya ve Akdeniz ekosistemindeki ülkeler gelir (Ertuğrul, 2005).

Dünyadaki en büyük orman alanlarına sahip ve en çok orman yangınlarına maruz kalan bu ülkelerde, geçmişten günümüze kadar çıkmış en büyük ve en ölümcül yangınlardan bazıları şöyledir.

Amerika:

Amerika’da 2002’den bu yana 10 yılda çıkan toplam 1.436.799 adet yangında 61.367.584 hektar alan yanmıştır (Wildfires and Acres, 2022).

Bu yangınların sadece %1 veya 2’si büyük yangınlarına dönüşmesine rağmen yanan alanların %95’inden fazlası bu yangınlarda yanmaktadır (Leite vd., 2015).

1825 Miramichi Fire: ABD tarihinin en büyük orman yangıdır. Bu yangında tahminen 1.2 milyon hektardan fazla alan yanarak en az 160 insanın hayatını kaybetmesine yol açmıştır.

The Great Fire Of 1910: Bu yangın sadece 2 gün sürmüş, yangında yaklaşık 1.2 milyon hektar alan yanmış ve 87 kişi hayatını kaybetmiştir.

2020 California Wildfire Season: Yangın sezonu boyunca 10bin’e yakın yangın olmuş ve toplamda 1.7 milyon hektarlık orman alanı yanmış, 33 kişi de hayatını kaybetmiştir.

Peshtigo Fire 1871, Great Michigan Fire 1871, Chicago Fire 1871: Bu 3 yangında aynı anda farklı yerlerde meydana gelmiş ve her üçü de oldukça büyük hasarlara yol açmıştır. Peshtigo yangınında 1.500’den fazla insan hayatını kaybederken 400bin hektardan fazla alan yanmıştır. Michigan yangınında 1 milyon hektar alan yanarken can kaybı yaklaşık 250 kişidir (Leite vd., 2015; WFCA, 2022).

Chicago yangını 900 hektar alan yakmıştır ancak yaklaşık 300 kişinin ölümünden, 17binden fazla yapının yıkımından ve 100bin’den fazla insanın evsiz kalmasından sorumludur (Rayfield, 1997).

Kanada:

Kanada’da ABD ile benzer olarak, çıkan yangınların sadece %3’ünde 200 hektardan fazla bir alan yanmış ancak bu %3 ise yanan alanların %97’sini oluşturmuştur (Wildfires and Acres, 2022).

Kanada’da ise 2001-2021 arası 10 senelik sezonda toplam 138.824 adet yangın çıkmış ve 5.0422.567 hektar alan yanmıştır (Forest area burned and number of forest fires, 2023).

Mart 2023 yılında başlayan ve 6 Ekim 2023 itibari son bulan yangınlar, tarihinin en büyük orman yangını felaketidir. Çıkan toplam 6.551 adet yangında 18,5 milyon hektar alan yanmıştır. Kanada tarihinde şimdiye kadar çıkmış en büyük yangın olan

1989 yılı yangınlarında 1.147 adet yangın meydana gelmiş ve 7,6 milyon hektar alan yanmıştır. 2023 yangınları tarihin en büyük yangınının 2 katından daha fazladır (CIIFFC, 2023).

Avustralya:

Tarih boyunca birçok orman yangına maruz kalan Avustralya hala Dünya'daki orman varlığı açısından önemli bir yere sahiptir ve yangına çok hassas bölgelerden birisidir. Geçmişte de oldukça yıkıcı ve büyük yangınlarla mücadele etmek zorunda kalmıştır.

Black Friday 1939: 71 cana ve 2 milyon hektardan fazla alanın yanmasına sebep olan yangın, binlerce hayvanı öldürmüş, 5 eyaleti tamamen yok etmiştir. 700'den fazla ev, 69 kereste fabrikası ve birçok çiftlik olmak üzere toplam 1.300 bina yıkılmıştır.

Black Saturday 2009: 450 bin hektardan fazla ormanlık arazi yanmış, 173 kişi hayatını kaybetmiş ve 414 kişi de yangından etkilenmiştir. Yaklaşık 1 milyon hayvan ölürken, çoğunluğu ev olmak üzere 3.500 bina yıkılmıştır.

2019-2020 Bushfires: 90 gün süren yangında 1,5 milyon hektardan fazla alan yanarak, 5 kişinin hayatını kaybetmesine sebep olmuştur. 6.800 besi hayvanı ve 400'den fazla ev de yanarak yok olmuştur (HISTORY & MAJOR FIRES, 2023; Leite vd., 2015).

Ash Wednesday 1983: 76 kişinin hayatını kaybettiği yangında 1.100 kişi yaralanmış ve 520bin hektardan fazla alan yanmıştır. 340bin'den fazla koyun ve 18bin sığır telef olurken 3.700'den fazla bina yıkılmıştır (ISDR, 2000).

Akdeniz:

Akdeniz ekosisteminde de orman yangınları sıklıkla görülmeye başlamıştır. 1900 yılından 2016'ya kadar yıllık sıcaklık ortalaması 1,1 °C artmıştır. Bu yüzyılın sonlarında ise 4,5 °C daha artacağı tahmin edilmektedir ki bu ciddi bir sıcaklık artışıdır (Zeke, 2019).

Akdeniz ormanları dünya ormanlarının yalnızca %1,5'ini oluşturur ve her sene ortalama 500bin hektar alan yanar. Ancak Akdeniz ormanlarının kendine özgü karakteristik ve endemik özellikleri sayesinde, zengin flora ve faunasıyla Dünya ormanlarında yeri oldukça değerlidir. Bu zenginlikleri bakımından Akdeniz ormanlarından keresteden çok, toprağın korunumu ve aşınımı ile mikroklima bakımından faydalanılmaktadır (Ertuğrul, 2005).

1.6. Orman Yangınlarının Zararları ve Etkileri "Türkiye"

Türkiye ormanlarının sürekliliğini etkileyen en büyük sebep orman yangınlarıdır (Küçükosmanoğlu, 1990).

Akdeniz ekosisteminde bulunan ülkemizde de orman yangınları, orman varlığını tehdit eden ve son zamanlarda sıkça görülmeye başlanan doğal afetlerden birisidir (Hacısalıhoğlu, 2018).

Ülkemizde yangına elverişli ormanlarının bulunduğu coğrafyalara iklimsel çerçeveden bakıldığında, yazlar sıcak ve kurak, kışlar ılıman ve yağışlı geçmektedir (Küçükosmanoğlu, 1993).

Ülkemiz ormanlarının yaklaşık %37'si birinci, %25'i ikinci, %27'si üçüncü, %6'sı dördü ve %5'i de beşinci dereceden yangın duyarlılığı olan alanlardadır. Başka bir deyişle ormanlarımızın 14 milyon hektardan fazlası yani %62'si bir ve ikinci dereceden duyarlı bölgelerde bulunmaktadır. Yangına duyarlı bu bölgeler sıklıkla Ege ve Akdeniz kıyılarıdır (Baltacı, 2021).

Yine bu kıyılarda en sık görülen ağaç türü olan kızılçam ve karaçam ise yangına en hassas ve yangından en çok etkilenen, tepe çatısı yandığı takdirde canlılığını tamamen kaybeden meşcere türüdür (Bilgili vd., 2010; Küçükosmanoğlu, 1990).

İğne yapraklılar olarak bilinen bu türün diğer yapraklılardan daha çok etkilenmesi ve yangına karşı daha hassas olmasının sebebi gövde ve iğne yapraklarında reçine bulundurmasıdır. İğne yapraklılar içinde ise çam ağaçları, diğerlerine göre daha bol miktarda reçine içerdiğinden ve kurak yerlerde yetiştirme eğilimlerinden dolayı daha fazla tahribata uğramaktadırlar (Küçükosmanoğlu, 1990).

Kızılçam ve karaçam meşcereleri toplamda yaklaşık 9,4 milyon hektar alanıyla ülke ormanlarının %42'sini oluşturlar (OGM, 2021).

Türkiye'de orman yangını verileri 1937 yılından beri tutulmaktadır. 2022'ye kadar geçen 85 yılda toplam, 119.896 yangın çıkarak yaklaşık 1,9 milyon hektar alanı

yakarak yok etmiştir. Yıllara göre çıkan yangın sayıları ve yanan alanalar Tablo 7’de gösterilmektedir. (Küçükosmanoğlu, 1994; OGM, 2022).

Tablo 7 1937-2022 yılları arasında Türkiye’de çıkan orman yangını sayıları ve yanan alan miktarı

Yıllar	Yangın adedi	Yanan alan (hektar)	Yıllar	Yangın adedi	Yanan alan (hektar)	Yıllar	Yangın adedi	Yanan alan (hektar)
1937	544	13.564	1966	433	6.664	1995	1.770	7.676
1938	398	14.416	1967	473	8.441	1996	1.645	14.922
1939	510	12.304	1968	387	7.540	1997	1.339	6.317
1940	419	18.732	1969	714	16.354	1998	1.932	6.764
1941	850	33.415	1970	790	15.019	1999	2.075	5.804
1942	740	73.210	1971	651	7.532	2000	2.353	26.353
1943	779	46.723	1972	440	6.913	2001	2.631	7.394
1944	536	39.315	1973	1.208	17.002	2002	1.471	8.514
1945	1.169	165.307	1974	769	14.743	2003	2.177	6.644
1946	1.023	125.115	1975	811	17.515	2004	1.762	4.876
1947	868	59.999	1976	702	5.171	2005	1.530	2.821
1948	630	32.463	1977	1.615	43.076	2006	2.227	7.762
1949	738	36.502	1978	1.122	13.235	2007	2.829	11.664
1950	987	69.068	1979	1.300	34.132	2008	2.135	29.749
1951	828	18.884	1980	1.092	10.248	2009	1.793	4.679
1952	1.282	62.271	1981	982	5.470	2010	1.861	3.317
1953	654	17.596	1982	950	4.018	2011	1.954	3.612
1954	1.126	35.580	1983	968	3.556	2012	2.450	10.454
1955	878	27.773	1984	1.433	7.358	2013	3.755	11.456
1956	1.118	38.983	1985	1.793	26.006	2014	2.149	3.117
1957	779	28.634	1986	1.526	11.037	2015	2.150	3.219
1958	725	26.862	1987	1.310	10.746	2016	3.188	9.156

Tablo 7 1937-2022 yılları arasında Türkiye’de çıkan orman yangını sayıları ve yanan alan miktarı (devam)

1959	436	8.070	1988	1.372	18.210	2017	2.411	11.993
1960	504	8.559	1989	1.633	13.099	2018	2.167	5.644
1961	620	9.127	1990	1.750	13.742	2019	2.688	11.332
1962	717	10.059	1991	1.481	8.081	2020	3.399	20.971
1963	455	5.178	1992	2.117	12.232	2021	2.793	139.503
1964	768	13.348	1993	2.545	15.393	2022	2.160	12.799
1965	415	3.945	1994	3.239	30.828	Toplam:	119.896	1.856.875

2021 yılında çıkan yangınlar hem ülke için hem Manavgat ilçesi için tarihin en büyük orman yangını felaketi olarak kayıtlara geçmiştir. Çalışma bölgesinde, Manavgat’ta, ortaya çıkan bu yangın 10 gün süren zorlu mücadeleler sonucunda ancak kontrol altına alınabilmıştır. 60 bin hektar orman alanı ile 1.500 hektar ziraat alanı yanarak yok olmuştur. Yangında 7 kişi hayatını kaybederken, 263’ü büyükbaş olmak üzere toplam 3.046 besi hayvanı, 20 bini bıldırcın türünden olmak üzere 27.407 kuş, 1.441’i arılı olmak üzere toplam 2.447 kovan yanmıştır. Toplamda 33 bine yakın hayvan hayatını kaybetmiştir. Yangından sadece canlılar etkilenmemiş; aynı zamanda birçok ev, ahır, depo ve iş yerleri de zarar görmüştür. Bu yangının neden olduğu maddi kayıp, aynı yıl en az 1 milyar TL olarak hesaplanmıştır (Yangının Acı Bilançosu, 2021).

1.7. Yangınları Önlemek/Mücadele Etmek İçin Neler Yapılabilir

Yangınlarla mücadele hususunda ne kadar önlem alınırsa alınsın orman yangınlarını tamamen önlemek kasıtlı çıkarılan yangınlar dolayısıyla mümkün değildir. Yine de olası çözümlerle yangınları azaltmak ve yangınlardan en az zararla kurtulmak mümkündür (Teketay, 2000).

Ormanları korumak ve yangınların verdiği tahribatı en aza indirgeyerek ekosistemin sürdürülebilirliğini sağlamak yangın önleme faaliyetlerinin birincil amacıdır. Yangınlarla mücadele edilirken yangın öncesinde ve sonrasında yapılması gerekenler

iyi bilinip analiz edilirse, yangın çıkma ihtimali düşürülecek ve olası bir yangında da tahribatın boyutları azaltılmış olacaktır (Çolak & Sunar, 2020; Sepetçi, 2014).

Bazı ülkeler orman yangınlarıyla mücadele çerçevesinde, bu mücadeleyi daha etkili ve verimli hale getirebilmek için daha önceden çıkmış yangınların kayıtlarını tutarak, bu kayıtlı verilerden bir takım analiz ve bilgi sistemleri geliştirmişlerdir. Geçmiş yangınların arşivlenmesinin sebebi, bu verilerden faydalanarak yangınların özelliklerini daha iyi anlamak ve yeni çıkacak olan yangınların tahmin edilebilir hale getirmektir. Örneğin Avrupa Birliği ülkelerinin yangın verileri European Forest Fire Information System 'de (Avrupa Orman Yangını Bilgi Sistemi) tutulmakta ve her sene güncellenmektedir (Yıldırım, 2023).

Yangın öncesi olduğu kadar yangın sırasında da anlık olarak oluşturulacak yangın risk haritaları hem stratejik hem lojistik anlamda fayda sağlayarak doğru ve hızlı kararların anlık olarak verilmesinde ve yangınların en kısa zamanda söndürülmesinde önemli rol oynayacaktır (Asri vd., 2015).

Bu mücadele için eğitilmiş ve donanımlı itfaiye erleri yetiştirmek ve onları maddi açıdan desteklemek önemlidir. Sıcaklığın yüksek olduğu kurak mevsimlerde olası yangınlara karşı tetikte olunmalıdır. Yine bu mevsimlerde insanları ormanlık alanlardan mümkün olduğunca uzak tutmak yangın riskini azaltacaktır. Ayrıca yangınlar konusunda bilinçli bir toplumda yangınlar çok daha az görülür (Teketay, 2000).

Yangınların erken tespiti ve yerinin belirlenip, yönünün ve hızının kestirilmesi ile yangınla mücadele ekiplerine hızla haber verilmesi önemlidir. Hızlı bir iletişim ve iyi bir organizasyon, yangın söndürmenin temelidir (Küçükosmanoğlu, 1993; Teketay, 2000).

Coğrafi Bilgi Sistemleri ile desteklenen bilgisayar tabanlı sistemler; veri toplama, karmaşık verileri yönetme ve depolama avantajı, doğruluğu kontrol edilebilen hassas veriler üretmesi, güncellenebilir ve anında erişilebilir olması, istatistiksel ve görsel olarak analiz edilebilir olması gibi sebeplerle risk analizlerinde kullanılmaktadır.

1.8. Orman Yangınlarında CBS ve Makine Öğrenmesi Yönteminin Önemi ve Kullanımı

Yangınlarla mücadelede risk yönetimi, ormanlar gibi büyük sahalarda bulunan kaynakların yönetimi ve sürdürülebilirliği bakımından son derece önemli bir yere sahiptir. Bu bağlamda yangınların verdiği zararlar ile birlikte, can ve mal kayıplarının minimuma düşürülmesini hedefler (Asri vd., 2015;Yavuz & Sağlam, 2012).

Yangın yönetiminin etkili olabilmesi için geçmişte çıkan yangın verileri ile desteklenen risk haritaları ve yangın bilgi sistemleri oluşturulmalı, bu sistemler sürekli güncellenmeli ve dinamik yapıda olmalıdır. Yangın yönetiminin etkinliği ve yangın riskinin azaltılması amacıyla yapılması gerekenler arasında bu gibi birçok çeşitli verinin de toplanması en önemli adımlardandır (Özmen, 2010).

Yangın risk haritaları, yangınların olma olasılığını ve bu yangınların olası etkilerini gösteren haritalardır. Bu haritalar, yangınların riskli olduğu bölgeleri derecelendirerek ve vurgulayarak yangın riskini değerlendirip yüksek riskli alanların belirlenmesine yardımcı olur. Yangın öncesi ve yangın esnasında ne yapıp nasıl davranacağımızı, nelere dikkat edip öncelik vereceğimizi anlamamız konusunda yol gösterir. Bu da yangınla mücadele kaynaklarının en iyi şekilde kullanılmasını sağlar. Ayrıca yangınlarla ilgili veri toplanması ve analiz yapılmasına da olanak tanır. Risk haritaları yangınların etkilerini azaltmak ve yangınla mücadele stratejilerini geliştirmek için önemli bir araçtır (Hacısalıhoğlu, 2018)(Özelkan, 2008; Zainalabden, 2022).

Eksiksiz bir yangın bilgi sistemi, hem yangının nasıl yayılacağını tahmin etmek için çevresel faktörleri incelemeli hem de yangının ne zaman ve nerede başlama olasılığını belirlemelidir. Yani, bu sistem, olası yangınları öngörmek için hem doğal faktörleri hem de insan etkilerini dikkate almalıdır (De Vasconcelos vd., 2001).

Orman yangınları birçok farklı sebepten, birçok farklı senaryoyla çıkabilir. Bu sebepleri incelerken coğrafya (eğim, bakı vb.), insan (yerleşim yerleri vb.), doğal etkenler (sıcaklık, nem vb.) gibi farklı etkenlerin etkisi altında kaldığı görülmektedir (Özenen Kavlak vd., 2020).

Son yıllarda yangınların yönetiminde çeşitli araç ve metotlar kullanılmaya başlanmıştır. Bu metotlardan biriside CBS'dir (Zainalabden, 2022).

Orman yangını risk haritalarının oluşturulması, birçok farklı veri kaynağından gelen verilerin işlenmesi, bir araya getirilmesi ve analiz edilmesi açısından zorlu bir görevdir. Bu zorlu görevi üstlenen Coğrafi Bilgi Sistemleri (CBS) karmaşık haritaların oluşturulmasını kolaylaştırır. Ayrıca CBS, bu tarz değişkenlerin daha iyi anlaşılmasına ve karar verme süreçlerinde kullanılmasına katkı sağlar. Tüm bu değişkenlerin bir arada değerlendirilmesi ve her etkenin kendine özgü ağırlıklandırılıp karşılaştırılmasıyla risk haritaları oluşturulur (Karabulut vd., 2013; Mohajane vd., 2021; Özenen Kavlak vd., 2020).

CBS, orman yangını risk haritaları gibi coğrafi verilerin işlenmesi ve haritaların oluşturulması için sıklıkla tercih edilen bir araç olarak karşımıza çıkmaktadır (Hacısalıhoğlu, 2018).

Bu tercih edilişin birkaç nedeni vardır:

- CBS, farklı kaynaklardan gelen coğrafi verileri depolar, sınıflandırır ve kullanmak için düzenli bir hale getirir. Orman yangınları için gereken farklı veri türlerini barındırabilir, bu da analiz etmeyi ve haritalamayı kolaylaştırır.
- Büyük miktarda coğrafi veriyi hızlı ve etkili bir şekilde analiz etme ve sorgulama yeteneği sunar. Bu, orman yangını duyarlılık haritaları gibi karmaşık haritaların oluşturulmasını sağlar. CBS, verileri farklı katmanlar halinde bir araya getirerek, yangın riskini ve duyarlılık alanlarını anlamamıza yardımcı olur.
- Verileri haritalar, grafikler ve görsel araçlarla temsil etme yeteneği sunar. Bu, yangın yöneticilerinin ve karar vericilerin verileri daha iyi anlamalarını ve kararlarını daha iyi desteklemelerini sağlar.
- Gerçek zamanlı veri akışlarını işleme yeteneği sunar. Bu da yangın yöneticilerine yangın sırasında anlık bilgi sağlayarak, yangına daha hızlı tepki verme olanağı tanır.

Bu da CBS'yi orman yangını yönetimlerinde tercih edilen en avantajlı sistem yapmaktadır (Karadeniz, 2020).

Kısacası Coğrafi Bilgi Sistemi, mekânsal verileri toplama, işleme, analiz etme ve karar verme süreçlerinde kullanılan bir bilgi yönetim sistemidir. CBS'nin yapısal ve işlevsel bileşenleri, coğrafi verilerin etkili bir şekilde yönetilmesini ve kullanılmasını sağlamaktadır (Çoban & Erdin, 2020).

Yangınlarla mücadele başarısı, yalnızca önlemlerin alınmasıyla veya kaynakların etkili kullanılmasıyla değil, aynı zamanda bu teknolojilerin yangın sırası ve sonrasında da kullanılmasıyla anlam kazanır (Küçük & Bilgili, 2006).

Yersel yöntemlerle yapılan ölçmeler riskin değerlendirilmesi ve doğrulanması bakımından önemlidir ancak bu ölçümler hem maddi hem işgücü hem zamansal yönde oldukça maliyetlidir. Ayrıca büyük alanlarda da uygulanabilirliği ve doğruluğu düşük olduğundan tatmin edici sonuçlar vermez. CBS teknoloji çok daha etkin, verimli, ucuz, hızlı ve hassaslığı nedeniyle yaygın bir şekilde kullanılmakta ve tercih edilmektedir (Alkayış vd., 2022; Çolak & Sunar, 2020; Yavuz & Sağlam, 2012).

Bu sebeplerle; yangın öncesinde, risk tahmini ve haritalaması çalışmalarında, yangın sırasında, yangın oluşumunun gözlenmesi ve söndürme çalışmalarının organize edilmesinde, yangın sonrasında ise oluşan hasarın tespiti, etkilenen alanların haritalaması ve rehabilitasyon çalışmalarında kullanılmaktadır (Atmaca vd., 2022; Dilekçi, 2019; Hacısalıhoğlu, 2018).

Bu teknoloji ormanların yalnızca yangın yönetiminde değil, bununla birlikte orman yönetimi, orman işletmeciliği, orman taşımacılığı gibi farklı alanlarda da kullanılmaktadır (Akay vd., 2006; Sivrikaya vd., 2007; Yüksel vd., 2008).

İnsanların geçmiş deneyimlerinden öğrenip, geleceği tahmin etme yeteneğinden esinlenerek geliştirilmiş makine öğrenmesi, yapay zekanın bir alt dalıdır. İstatistik ve matematik temelli yöntemler kullanarak veri analizi yapar ve tahminlerde bulunur. Girdi ve çıktı verilerinden, daha önce öğrenilmemiş olan girdi verilerinin çıktılarından neler olacağını tahmin eder (Yıldırım, 2023).

Makine öğrenimi, bilgisayar teknolojilerine bağlı hesaplama gücünün büyük ilerlemeler kaydetmesiyle birlikte günümüzün en önemli ve sık çalışma alanlarından birisi olmuştur. Bu alan, büyük veri işleme ve veriden anlamlı bilgi çıkarmada önemli rol oynamaktadır (Eker vd., 2023).

Makine öğrenmesi; tıp, robotik, sosyal medya, tarım, finans, ulaştırma, sanal kişisel yardım gibi birçok farklı alanda kullanılmaktadır (Kumar vd., 2020; Sarker, 2021).

Son yıllarda olası orman yangınlarını erken tahmin etmede kullanılan yöntemlerden biri olarak karşımıza çıkmaktadır (Yıldırım, 2023).

Son on yılda yangınların modellenmesinde ve risk haritalarının oluşturulmasında, artan veri hacmi ile birlikte makine öğrenimi yaklaşımları da Coğrafi bilgi sistemleri kadar yaygın kullanılmaya başlanmıştır (Jain vd., 2020).

Yangın analizlerinde birden çok değişken olduğu ve bu değişkenlerin çalışma sahasına göre veri boyutlarının büyük miktarlarda olabileceği için bu noktada makine öğrenimi büyük veri setlerinin analizi ve özelliklerin seçilmesinde diğer yöntemlerden avantajlı olabilmektedir. Dahası, makine öğreniminin çıkarım kabiliyeti, orman yangınlarının hangi alanlarda daha yaygın olarak görüleceğini tahmin etmek konusunda, yani tıpkı CBS gibi yangın öncesi risk analizlerinin yapılması ve riskli bölgelerin belirlenmesinde de faydalıdır.

Olası yangınların konumlarını tahmin etmek ve yangın riskini belirlemek için makine öğrenimi kullanılarak çeşitli algoritmalar geliştirilmiştir (Muhammad vd., 2021; Tien Bui vd., 2018).

Yapay Sinir Ağları (Kantarcıoglu vd., 2023), Lojistik Regresyon (De Vasconcelos vd., 2001), Naïve Bayes (Pham vd., 2020), Destek Vektör Makineleri (Tehrany vd., 2019), Rastgele Orman (Ma vd., 2020), Karar Ağaçları (Shao vd., 2022), orman yangını yönetiminde kullanılan bazı makine öğrenimi algoritmalarıdır.

Bunlar arasında Yapay Sinir Ağları (YSA) karmaşık verileri öğrenme, tanıma, yorumlama, büyük ölçekli ve çok değişkenli veri setlerini yöneterek çeşitli karmaşık sorunları çözme gibi yeteneklere sahip olması nedeniyle ön plana çıkmaktadır (Ojha vd., 2017; Tien Bui vd., 2018).

Makine öğrenmesi ve Coğrafi bilgi sistemleri gibi güncel teknolojilerin kullanımı, orman yangınlarını önlemek ve yönetmek için daha etkin önlemler alınmasına yardımcı olmaktadır.

1.9. Literatür Taraması

Sivrikaya vd. (2014) tarafından Kahramanmaraş'ın Yeşilova orman işletmesinde yapılan çalışmada, orman yangını risk faktörleri değerlendirilmiş ve yangın riskini belirlemek için CBS kullanılmıştır. Bu çalışmada üretilen risk haritasının amacı,

yangın riskinin deęerlendirmesi ile birlikte aynı zamanda orman yöneticileri, karar vericiler ve itfaiyecilere yardımcı olmasıdır. Çalışmada Ağaç tipleri, Gelişme çağları, Taç kapallılığı, Eğim, Bakı, Yerleşim yerlerine uzaklık, Tarım alanlarına uzaklık ve Yollara uzaklık verileri kullanılmıştır. Her verinin alt kriterine 1 den 5 e kadar deęerler verilmiş ve bu deęerlerden yangın riski endeksi (fire risk index - FRI) elde edilmiştir. Bu endeks şu formülle hesaplanmıştır;

$$FRI = 10SC_i + 10CC_j + 10DS_k + 5S_l + 3IS_m + 2SA_n + 2R_o$$

SC ağaç tipleri, CC taç kapallılığı, DS gelişme çağları, S eğim, IS bakı, SA yerleşim ve tarım arazilerine uzaklık ve R yollara uzaklıktır. Sessizler (i, j, k, l, m, n, o) yangın riski ile tanımlanan alt sınıfları göstermektedir.

Üretilen risk haritası sonucunda, toplam ormanlık alanın yarısından fazlasının %65.7 ile düşük sınıfta olduğu, orta sınıfın %16.1, riskli sınıfın %6.6 ve çok riskli sınıfın %11.6 olduğu bulunmuştur (Sivrikaya vd., 2014).

Karabulut vd. (2013) tarafından yapılan çalışma için Başkonuş Dağı seçilmiştir. CBS, birden fazla deęişkene sahip modelleri ve farklı deęişkenler arasındaki karmaşık bağlantıları araştırmak ve çözümlemek için kullanılır. Bu teknikler, ekolojik sorunların niteliklerini anlama ve bu sorunların yönetilmesinde büyük faydalar sunar. Bu çalışmada da orman yangınları üzerinde etkili olan coğrafi faktörler, CBS yardımıyla oluşturulan modeller kullanılarak deęerlendirilmiştir. Bu bağlamda kullanılacak olan Eğim, Bakı, Yollar ve Yerleşim yerleri verileri topoğrafya ve arazi kullanım paftalarından sayısallaştırma ile Bitki örtüsü verisi ise meşcere haritalarından elde edilmiştir. Yangına etki eden bu deęişkenlerin hepsine 1’den 5’e kadar ağırlıklar atanmıştır. 1 yangın çıkarma ihtimali en az, 5 yangın çıkarma ihtimali çok yüksek olarak belirlenmiştir. Yangın riski haritası oluşturmak için ise şu şekilde formülize edilmiştir.

$$RS = (7 \times F_T) + (5 \times (S + A)) + (3 \times (D_R + D_S))$$

RS yangın risk seviyesi, F_T bitki örtüsünün nem durumuna göre yanabilme potansiyeli, S eğim, A bakı, D_R yollara olan mesafe ve D_S yerleşime olan mesafedir. Tüm veriler ağırlıklarına göre çakıştırılarak sonuç haritası üretilmiştir.

Çalışma sahasının; bitki örtüsü bakımından %75'i yüksek ve çok yüksek riskli sınıf olan kızılçam ve karaçam türleri ile bakı açısından %26'sı çok yüksek riskli sınıf olan güney bölgeleri ile eğim bakımından %61'i yüksek ve çok yüksek riskli sınıf olan 20° ve üzeri eğimler ile yollara yakınlık bakımından %39'u yüksek ve çok yüksek riskli sınıf olan 200 metreden az olan yerler ile ve yerleşim yerlerine yakınlık bakımından %80'i yüksek ve çok yüksek riskli sınıf olan 1000 metreden az olan yerler ile kaplıdır.

Sonuçlar incelendiğinde özellikle 1000 ila 1500 metrelerde riskin yüksek olarak yoğunlaştığı görülmüştür. Ayrıca güney ve batı yamaçlar ile yerleşim yerlerinin ve yollarının birbirine yakın olduğu bölgeler de yine riskin yoğun olarak yüksek olduğu bölgeler olduğu sonucuna varılmıştır. (Karabulut vd., 2013)

Kantarcıoğlu vd. (2023) tarafından İstanbul, Kırklareli, Tekirdağ ve Edirne illerini kapsayan çalışmada bir makine öğrenmesi algoritması olan Yapay Sinir Ağları kullanılmıştır. Çalışmanın amacı YSA'nın yangın duyarlılığı performansını değerlendirmek, bölgenin risk haritasını çıkarmak ve hangi kriterin yangına en çok etki ettiğini bulmaktır. Bu çalışmada; yükseklik, bakı, eğim, ağaç türleri, gelişme çağları, ağaç kapallılığı, orman türleri, NDVI, suya yakınlık, MNDWI, yerleşim yoğunluğu, yerleşime yakınlık, yola yakınlık, enerji hatlarına yakınlık, orman yollarına yakınlık ve arazi örtüsü olmak üzere 16 adet veri türünü kullanılmıştır. Bu veriler çeşitli kaynaklardan elde edilmiştir. Bunlar dışında modelleme aşamasında kullanılmak üzere geçmiş yangın konumları da edinilmiştir. Girdi verileri %80 eğitim ve %20 test verisi olarak ayrılmış ve yangın envanteri verisi de kullanılarak model eğitilmiştir. Eğitilen model daha sonrasında görselleştirilerek orman yangını duyarlılık haritası oluşturulmuştur. Doğruluğun değerlendirilmesi için AUC (area under the curve) değeri, F-1 skoru ve OA (overall accuracy) kullanılmış ve elde edilen doğruluk değerlerinin performansları sırasıyla (0,94), (0,80), (0,88) olduğu sonucuna ulaşılmıştır. Bunlardan yola çıkarak YSA, yüksek tahmin performansı gösterdiği ifade edilmiştir. Bu performans ve haritalar incelendiğinde, çözünürlük, güvenilirlik ve tutarlık gibi veri kalitesini etkileyen faktörler açısından yersel verilerin önemi vurgulanmıştır. Özellik önemine ilişkin olarak ise orman yollarına yakınlık, veri kümesindeki en etkili faktör olmuştur. (Kantarcioğlu vd., 2023)

Pham vd. (2020) tarafından orman yangını duyarlılığını tahmin etmek ve haritalamak için çeşitli makine öğrenimi yöntemleri (Bayes Ağı - BN, Naïve Bayes - NB, Karar Ağaçları - DT ve Çok Değişkenli Lojistik Regresyon - MLR) kullanılmıştır. En iyi tahmin doğruluğuna sahip olan algoritmayı seçmek amacıyla yapılan bu çalışma Vietnam'ın kuzeyinde bulunan Pu Mat Milli Parkında gerçekleştirilmiştir. Yangına etki eden kriterler; Eğim, Bakı, Yükseklik, Arazi örtüsü, Ortalama yıllık sıcaklık, Kuraklık indeksi, Nehir yoğunluğu, Yollara uzaklık ve Yerleşim alanlarına uzaklık olmak üzere seçilmiş ve bunlarla birlikte 57 adet geçmiş yangın konumu verisi için veri seti oluşturulmuştur. Geçmiş yangınların 40 tanesi (yani %70'i) model eğitimi için, 17 tanesi (yani %30'u) ise test veri seti olmak üzere ikiye ayrılmıştır. Yangın olmayan yerler ise 80 adet eğitim ve 34 adet test veri seti için işaretlenmiştir. Öncelikle Relief özellik seçimi yöntemi kullanılarak veri setine ön işleme uygulanmış, daha sonra eğitim veri seti kullanılarak çalışma için seçilen her 4 makine öğrenimi yöntemi de eğitilmiş ve test veri setleriyle doğrulanmıştır. Oluşturulan bu modellerin doğruluğunu test etmek ve hem eğitim hem test performansları bakımından birbirleriyle kıyaslamak için çeşitli istatistiksel yöntemler ve ROC eğrisi altında kalan alan (AUC) parametresi kullanılmıştır. Yapılan performans ölçümlerinin sonuçları incelendiğinde her 4 algoritmanın da yüksek doğruluk verdiği, her algoritmanın farklı metrikler için farklı performanslar sergilediği ancak BN algoritmasının özellikle test veri seti ile birlikte doğrulandığında diğerlerine kıyasla daha iyi bir performans sergilendiği görülmektedir. Ayrıca lojistik regresyon modellerinin yangın tahmini açısından diğer modellere göre sıklıkla daha iyi performans gösterdiğini ortaya koymuştur. Elde edilen sonuçlarla birlikte, insan faaliyetlerinin yoğun olduğu ve özellikle artan yol inşaatları ile orman-insan etkileşimlerinin artmasından kaynaklanan nedenlerle, yangın oluşumu konusunda orta ila yüksek hassasiyet aralığında bulunan çalışma alanının yaklaşık %19'unu etkilediğini göstermiştir. (Pham vd., 2020)

Nikhil vd. (2021) orman yangınlarında riskli bölgelerin haritalanması ve her bir faktörün yangın çıkarmadaki etkisini değerlendirmek amacıyla Hindistan'ın Kerala eyaletinde bir çalışma gerçekleştirmişlerdir. Çalışmada; Arazi örtüsü (LCT), Eğim, Bakı, Topoğrafik ıslaklık indeksi (TWI), Yerleşim yerlerinden uzaklık (DS), Yoldan uzaklık (DR), Turistik noktalardan uzaklık (DTS) ve Kaçak avlanma karşıtı kamp barakalarından uzaklık (DAPCS) olmak üzere 8 adet veri türü kullanılmıştır. Bu

faktörlerin ağırlık değerleri analitik hiyerarşi prosesi (AHP) yardımıyla belirlenmiştir. Belirlenen nihai ağırlıklar şu formülle çakıştırılmış ve yangın risk haritasının oluşturulması için CBS ortamına aktarılmıştır.

$$FRZ = (0,33 \times LCT) + (0,23 \times E\tilde{g}im) + (0,16 \times Bakı) + (0,11 \times TWI) + (0,07 \times DS) + (0,05 \times DR) + (0,03 \times DTS) + (0,02 \times DAPCS)$$

Oluşturulan yangın risk haritası; çok düşük, düşük, orta, yüksek ve çok yüksek riskli bölgeler olarak 5 sınıfa ayrılmış, geçmiş yangın konumları verileriyle de çakıştırılarak teyit edilmiştir. Geçmiş yangın verilerinin %71'i yüksek ve çok yüksek riskli alanlarda kalmıştır. Çalışma alanının ise %61,92'si yüksek ve çok riskli bölgelerden oluşmaktadır. Ayrıca ROC eğrisinin altında kalan alan olan AUC analizi ile de doğruluğu araştırılmıştır. Çalışmanın AUC değeri 0,795 olarak bulunmuştur. Son olarak araştırma sonuçları, topografik ıslaklık indeksi ile orman yangınlarının oluşumu arasında güçlü bir ilişki bulunduğunu göstermektedir. Bu ilişki, yolların ve yerleşim yerlerinin de orman yangınlarıyla ilintili olduğunu ortaya koymaktadır (Nikhil vd., 2021).

Eskandari (2017) İran'ın Hyrcanian ormanlarında yaptığı çalışmada bir risk haritası oluşturmak amacıyla CBS ve Bulanık AHP yöntemlerini kullanmıştır. İlk olarak yangına etki eden toplam 4 adet ana kriter (Topoğrafik, Biyolojik, Meteorolojik, İnsan) ile 17 adet alt kriter belirlenmiştir ve uzman görüşlerine dayanarak bunlara ağırlıklar atanmıştır. Ana kriterlerin bulanık ağırlıkları; topoğrafik 0,2080, meteorolojik 0,2315, biyolojik 0,2595 ve insan 0,3010 iken alt kriterler ise şu şekildedir:

Eğim 0,2517, bakı 0,3056, yükseklik 0,2177, nehirden uzaklık 0,2250, yıllık sıcaklık 0,2652, yıllık yağış 0,2257, yıllık bağıl nem 0,2381, yıllık rüzgar hızı 0,2710, bitki örtüsü türü 0,1839, bitki örtüsü yoğunluğu 0,1762, ölü örtü derinliği 0,1839, ölü örtü nemi 0,1839, toprak dokusu 0,1306, toprak nemi 0,1415, yoldan uzaklık 0,3736, yerleşime uzaklık 0,3227 ve tarım arazisine uzaklık 0,3037 olarak belirtilmiştir.

Ana kriterler arasında yangın çıkarmada en fazla etkisi olan kriter %30'luk bir puan ile insan kriteridir ve alt kriterleri arasında ise yaklaşık %37'lik dilimle yoldan uzaklık kriterinin yer aldığı görülmektedir. Ana kriterlere atanan bu bulanık ağırlıkları referans olarak yangın riski modeli oluşturulmuştur. Yangın risk haritasının oluşturulabilmesi için ise her alt kriter CBS ortamında bir raster formata dönüştürülmüş ve ağırlıkları

girilerek akıştırılmıştır. Oluşturulan bu harita ok düşük, düşük, orta, yüksek ve ok yüksek olmak üzere 5 risk sınıfına ayrılmıştır. alıřma alanının yaklaşık %39'u yüksek ve ok yüksek riskli sınıfta kalmıştır. Risk haritasını doęrulamak amacıyla gemiřte ıkmiř yangın yerleri haritası ile üst üste bindirilmiş ve kontrol saęlanmıştır. Görölmektedir ki gemiř yangınlarda yanan alanların %80'i oluşturulan bu risk haritasında yüksek ve ok yüksek riskin yer aldığı alanlara denk gelmektedir. %17'si ise orta sınıfta yer almaktadır. Bu sonular da yangın risk haritasının görece iyi alıřtığını göstermektedir. (Eskandari, 2017)

Dimuccio vd. (2011) CBS ile Yapay Sinir Aęı (YSA) modellerini bir arada kullanarak Portekiz'in orta bölgelerinde bir yangın duyarlılık haritası üretmeyi ve her iki aracı entegre edecek en iyi yöntemleri bulmayı amaçlamışlardır. alıřmada kullanılan veriler; Eęim, Bakı, Yol yoğunluęu, Yangın gözetleme kulelerinin gördüęü alanlar, Arazi kullanımı, Bitki örtüsü indeksi (NDVI), Yaęıř ve nüfus yoğunluęudur. Bunların yanında 1990'dan 2007'ye kadar ıkan yangınlarda yanan alanların verisi de kullanılmış ve aęırlıkların belirlenmesinde bu veriden yararlanılmıştır. Her kriterin bir alt kriteri vardır. Örneęin eęim kriteri 0-2, 2-10, 10-25, 25-45, >45 olmak üzere sınıflara ayrılmıştır. Her sınıfın arazide karşılık geldięi yanmış (a) veya yanmamış alanlar (b) belirlenmiş ve yüzdelerle temsil edilmiştir. Yanmış alanların, yanmamış alanlarına oranı bulunmuş (a / b) ve ortalaması alınmıştır $((a / b) / n)$. Standart sapmaları hesaplandıktan sonra deęerler, birbirine bölünerek elde edilen orandan, bunların ortalaması ıkarılıp standart sapmasına bölünmesiyle normalize edilmiştir $((a / b - n) / \text{standart sapma})$. Daha sonra normalize edilen deęerlere göre her sınıfın final aęırlıkları belirlenmiştir. YSA modeline gemeden önce alıřma alanındaki verilerin %50'si eęitim, %25'i test ve geri kalan %25'i de doęrulama için seilmiştir. YSA için geri yayılım algoritması kullanılmıştır. Sinir aęlarını eęitirken ortaya ıkan, yangına etki eden faktörlerin aęırlıkları hesaplanmış ve normalize edilmiştir. Böylece hem gemiř yanan alanların verileri hem de YSA kullanılarak her bir kritere bir aęırlık deęeri atanmıştır. Bir sonraki aşama ise CBS kullanarak bu aęırlıkların birleřtirilmesi ve yangın duyarlılık haritasının oluşturulmasıdır. Harita oluşturulduktan sonra řu sonulara ulařılmıştır; Otsu ve alılık örtünün %100'ü, reineli ormanlarının %47'si, ok kuru örtünün %42'si, 45 derecenin üzerindeki eęimlerin %67'si, güney sınıfındaki bakıların %43'ü, yaęıřın 1600 mm'den fazla olduęu daęlık alanların %82'si, düşük

nüfus yoğunluğuna sahip alanların %54'ü, düşük yol yoğunluğuna sahip alanları %56'sı ve yangın gözetleme kulesinin görmediği alanların %52'si yangına karşı duyarlılığı yüksek ve çok yüksek riskli alanlarda kalmaktadır. Doğrulamak için eğrinin altında kalan alan algoritması kullanılmış ve %78 doğruluk elde edilmiştir. (Dimuccio vd., 2011)

Atmaca vd. (2022) Muğla'nın Milas ilçesinde yangın risk haritalaması amacıyla bir denetimli makine öğrenmesi algoritması olan Lojistik Regresyon (LR) ve CBS tekniklerini birleştirmiştir. Atmaca, yangın çıkarmada etkili olan kriterleri literatürde sıklıkla tercih edilen kriterler olan; Meşcere tipi, Meşcere kapalılığı, Gelişme çağı, Yollara uzaklık, Yerleşim yerlerine uzaklık, Tarım alanlarına uzaklık, Eğim, Bakı ve Yükseklik olarak seçmiştir. Model kurulurken geçmiş yangın konumları verilerinden faydalanılmış ve yangın olan yerler için 1, olmayan yerler için 0 ataması yapılmıştır. Yangın olmayan konumlar araziden rastgele ve yangın çıkan konumların yaklaşık 1.5 katı olacak sayıda işaretlenmiştir. Yangın verilerinin %50'si eğitim, %50'si ise test için ayrılmıştır. Lojistik regresyon testi sonuçlarında P değerinin 0,05'den daha küçük olduğu bulunmuştur ki bu model verilerinin uyumlu olduğunu gösterir. Tahmin edilen ile gerçekte olan yangınların arasındaki ilişkiye bakılarak performans değerlendirmesi yapılmıştır. Geçmiş yangın konumlarıyla yapılan doğrulamada eğitim verileri %89 doğrulukta, test verileri ise %86 doğrulukta elde edilmiştir. ROC eğrisi altında kalan alan (AUC) değerlendirmesinde ise 0,902 sonucuna ulaşılmıştır. Bu sonuca göre model performansının çok iyi düzeyde olduğu söylenmektedir. Haritanın oluşturulması amacıyla kriterler CBS ortamına katman olarak yüklenmiş ve aşağıdaki formülle risk faktörü hesaplanmıştır:

$$y = 0,036153 + (0,386409 \times \text{gelişme çağı}) + (-0,56716 \times \text{meşcere kapalılığı}) + (-0,04826 \times \text{eğim}) + (0,958323 \times \text{bakı}) + (-0,00203 \times \text{yükseklik}) + (0,000187 \times \text{yerleşimlere uzaklık}) + (0,000145 \times \text{yollara uzaklık}) + (0,000429 \times \text{tarım alanlarına uzaklık})$$

Üretilen yangın riski haritası çok düşük riskten, çok yüksek riske kadar 5 sınıfa ayrılmıştır ve çalışma alanının sadece %16'sı yüksek ve çok yüksek riskli sınıfta kalmıştır. CBS ve Lojistik regresyon yöntemlerinin bütünleşik çalışılması, risk haritalarının ve modelin oluşturulmasında güvenilir olduğu söylenmiştir. Kullanılan

veri setlerinin de yangınlar için yüksek korelasyona sahip olduğu, eğim faktörünün yangın yayılmasında etkili olduğu ancak bu çalışmada düşük eğimdeki alanlarda yangınların gözlemlendiği ve bunun sebebinin tarımsal arazilerden kaynaklı olduğu, yükseklik faktörünün arazi örtüsünü etkilediği ve yüksek sıcaklık ve düşük yağış sebebiyle yangın riskinin alçak rakımlarda daha fazla olduğu, insanlara ve her türlü insan faaliyetlerine yakın yerlerde riskin arttığı bu çalışmadan elde edilen sonuçlardır (Atmaca vd., 2022).

Maniatis vd. (2022) Yunanistan’da 2020 ve 2021 yıllarında çıkan 2 büyük yangının değiştirdiği arazi örtünün yangın risk haritasını nasıl etkileyeceğini bulmak, orman yangınına duyarlı alanları belirlemek ve haritalamak amacıyla yaptıkları çalışmada 2019 ve 2021 yıllarına ait 2 adet harita üretmişlerdir. Uydu görüntülerinin sınıflandırılması için Makine öğrenmesi, yangına etki eden kriterlere ağırlıklar vermek için Analitik Hiyerarşi Prosesi (AHP) ve riski haritalamak için Coğrafi bilgi sistemleri yöntemlerinden faydalanmışlardır. İlk olarak arazi örtüsü verisini oluşturmak için uydu görüntülerini, denetimli bir makine öğrenmesi algoritması olan Destek vektör makinesi (SVM) kullanarak sınıflandırmışlardır. Bununla birlikte çalışmada kullanılan diğer faktörler; Yükseklik, Eğim, Bakı, Topoğrafik ıslaklık indeksi (TWI), Yollara uzaklık ve Yerleşim yerlerine uzaklıktır. Her bir kriterin ağırlığını belirlemek için uzman görüşleri ve geçmiş çalışmalar incelenerek çok kriterli karar verme yöntemi olan AHP kullanılmış ve her kritere ağırlıklar atanmıştır. AHP’den elde edilen sonuçlarla oluşturulan risk denklemi aşağıdaki gibidir:

$$\text{Yangın Riski} = (0,27 \times \text{Arazi örtüsü}) + (0,09 \times \text{Yükseklik}) + (0,05 \times \text{Bakı}) + (0,07 \times \text{Eğim}) + (0,12 \times \text{TWI}) + (0,23 \times \text{Yollara uzaklık}) + (0,17 \times \text{Yerleşim yerlerine uzaklık})$$

Denklem kullanılarak oluşturulan her 2 harita kıyaslandığında; yangın riskinin çok yüksek olduğu bölgeler her iki sene içinde %5’lik bir alan kapsayarak eşittir. Yüksek riskli olan bölgeler 2019’da %50 iken 2021 yılında %48 e gerilemiştir. Normal olan bölgeler 2019’da %33, 2021’de %34 iken düşük riskli bölgeler 2019’da %11, 2021’de %12 ve çok düşük riskli bölgeler 2019 ve 2021’de %1 olarak hesaplanmıştır.

İki harita da incelendiğinde, yangın riski haritasının büyük ölçüde sabit kaldığını, ancak yangınların etkilediği bölgelerde ortalama riskin belirgin bir şekilde azaldığını gözlemlenmiştir. Kriter ağırlıklarına bakıldığında da ise arazi örtüsü en büyük ağırlığa

sahip kriter olmuştur. Geçmiş yangınlardan kaynaklanan arazi örtüsü değişikliklerinin, etkilenen bölgelerin yangın riskinde belirgin bir düşüşe yol açtığı açıkça görülmektedir. Bu durumun temel nedeni, çalışma alanının yangın çıkan kısımlarında bulunan yangına yüksek dereceden duyarlı olan çam ağaçlarının yanmış olmasıdır (Maniatis vd., 2022).

Literatürdeki benzer çalışmalar incelenmiştir. Kullandıkları yöntemler, veri setleri, araçlar ve yazılımlar değişiklik gösterse de ortak amaç; orman yangınları için bir erken tahmin sistemi oluşturmak, yangına etki eden kriterler arasındaki en riskli faktörü belirlemek, yangına en riskli bölgeleri haritalayarak önlem alınması konusunda yönetici ve karar vericilere yol göstermek ve yardımcı olmaktır.

Bu çalışmalarda tek yöntemle sonuca gitmeye çalışmak çok doğru bir yaklaşım değildir çünkü kullanılan her bir yöntemin kendine has çalışma ilkeleri vardır. Örneğin belirlenen kriterlere ağırlıkların atanması görevinde çok kriterli karar verme yöntemlerinin kullanılması veya bu kriterlere atanan ağırlıkların CBS ortamında karşılaştırılması daha etkili sonuçlar verecektir. Doğru yöntemler doğru adımlarda uygulanmalıdır.

Literatürde bulunan veriler daha geniş kapsamlı ve daha genel sonuçlara, uzman görüşlerinin ise bilgi ve deneyimlerine dayanarak çalışma sahasının karakteristik yapısına göre daha özgül cevaplar verir. Ayrıca yalnızca literatürde yer alan bilgileri kullanmak günümüz koşullarını ve sahanın özelliklerini yansıtmada yetersiz kalabilir. Tek başına uzman görüşleri ise deneyim ve bilgi konusunda kısıtlı olabilir. Her iki yaklaşımında avantaj ve dezavantajları vardır. En etkili yaklaşım, her yöntemi de bir arada kullanmaktır.

Yangın risk haritalarının doğruluğu, kullanılan verilerin kalitesine bağlıdır. Literatürde kullanılan veri setleri genellikle çok kısıtlıdır. Oysa yangına etki eden kriterler bundan çok daha fazlasıdır. Literatürde yapılan çalışmaların çoğunda yangın risk haritalamasında statik veriler kullanılmıştır. Ancak yangın riski, iklim değişiklikleri, arazi kullanımı değişiklikleri ve insan faaliyetleri gibi dinamik faktörlerden etkilenebilir. Bu faktörlerin göz ardı edilmesi, güncel olmayan risk haritaları üretme olumsuzluğunu taşır. Hem dinamik hem de statik faktörler incelenmeli ve yangına

etkisi göz önünde bulundurulmalıdır. Bazı çalışmalar orman örtüsünü sınıflandırmak için orta-düşük çözünürlüklü uydu görüntüleri kullanmıştır. Bazıları meteorolojik parametrelerin verilerini ücretsiz kaynakları kullanmak adına veri kalitesi doğrulanmamış internet kaynaklarından almıştır. Bu veriler de yine çalışmanın doğruluğunu ve güvenilirliğini etkileyecektir. Ayrıca görülmüştür ki yangına etki eden faktörleri ağırlıklandırmak için sabit bir denklem bulunmuş ve aynı denklem farklı çalışma alanlarında da birebir uygulanmıştır. Kriterlerin yangına etkileri her coğrafyada aynı olmayabilir. Bu yüzden aynı denklemi farklı bir bölgede uygulamak hatadır. Örneğin tamamı çam ağacından oluşan bir ormanlık alanda meşcere tipi faktörünü ağırlıklandırma formülüne katmak önemsiz olacaktır.

Çalışmaların doğrulanması için bazı çalışmalar geçmiş yangın verilerini kullanmıştır, bazı çalışmalar ise kurdukları modelleri yalnızca istatistiksel yöntemlerle değerlendirmişlerdir. Bir çalışmayı yalnızca istatistiksel metriklerle değerlendirmek çalışmanın amacının tam anlamıyla anlaşılmasına, bağlamın göz ardı edilmesine, kapsamının sınırlı kalmasına, nitel verilerin ihmal edilmesine ve uygulama yönünde eksiklerin görülememesine neden olabilir. Çünkü istatistiksel metrikler genellikle verilerin sayısal analizini sağlar ve bağlamı dikkate almaz. Nicel verilere dayanır ve çalışmanın nitel sonuçlarını göz ardı edebilir. Gerçek dünyada insan davranışlarını ve olayların karmaşıklığına odaklanmaz. Bir çalışma istatistiksel olarak anlamlı olsa dahi, gerçek dünyada bu sonuçlar önemli olmayabilir. Bu sebeple yalnızca istatistiksel metriklere dayanarak çalışmanın sonuçlarını değerlendirmek yanıltıcı olabilir. Hem istatistiksel metriklerle hem geçmiş yangınlara bakarak yapılan bir doğruluk değerlendirmesi daha anlamlı olacaktır.

1.10. Çalışmanın Amacı, Önemi ve Kapsamı

Bu çalışma, olası orman yangınları için riskli bölgeleri belirleyerek, yangın çıkmadan önce önlemlerin alınmasını, yangın sırasında kaynakların daha etkin kullanılmasını ve yangın söndürme planlamaları konusunda stratejiler geliştirerek yangın tahribatını minimum düzeye indirmeyi amaçlamıştır.

Orman yangınlarını önlemek ve yönetmek; can, mal, habitat ve ekonomik kayıpları azaltmak, orman varlığını ve doğal seleksiyonu korumak amacıyla son derece önemlidir.

Oluşturulan haritalar ile literatürde yer edinmiş çalışmaların bulgularından ve bölgeye hâkim uzmanların cevaplarından olmak üzere 2 risk haritası oluşturulmuş, en doğru risk bölgelerini belirlemeye çalışmıştır. Bu haritalar oluşturulurken kullanılan farklı yöntemler kıyaslanarak farklı yaklaşımların sonuçları da irdelenmiştir. CBS yardımıyla geliştirilen risk bilgi sistemi ile birden fazla parametre aynı anda değerlendirilerek risk haritaları elde edilmiş ve görselleştirilerek desteklenmiştir. Bu sistem ve model, kullanıcı dostu ara yüzü ve esnek yapısı sayesinde farklı topoğrafya, orman yapısı ve iklim koşullarına sahip ormanlık alanlarda da kullanılabilir ve tüm orman alanlarının korunmasına yönelik bir bilgi sistemi olacak şekilde tasarlanmıştır. Makine öğrenmesi algoritmalarından Yapay Sinir Ağları modeli kullanılarak, makine öğrenmesinin bu tür sınıflandırmalardaki başarısı test edilmiştir. Aynı zamanda literatür araştırması yöntemi ile yapılmış olan sınıflandırmanın da performansı değerlendirilmiştir.

Ortaya çıkan sonuçların kontrolü hem geçmişte çıkmış yangın verileriyle hem makine öğrenmesi sistemleri ile istatistiksel analizler kullanılarak güvenilirliği ve doğruluğu test edilmiştir.


Literatüre bakıldığında aynı anda çok sayıda parametrenin farklı teknolojiler ve yöntemler kullanılarak değerlendirildiği ve doğrulandığı çalışmalara çok sık rastlanmamaktadır. Bu çalışmada, önem derecelerine göre 13 farklı parametre ve CBS, AHP, Makine Öğrenmesi teknolojileri ile literatür araştırmasından elde edilen veriler bir arada kullanılmıştır.

Manavgat, Türkiye’de orman varlığının en yoğun olduğu, aynı zamanda yangın bakımından en riskli konumda bulunması ve orman varlığının büyük bir kısmının yangına en duyarlı ağaç türü olan kızılçam ormanlarından oluşması nedeniyle çalışma alanı olarak seçilmiştir.

2. KAVRAMSAL ÇERÇEVE

2.1. Yangın

Yangın; ısı, oksijen ve yanıcı maddelerin belirli oranlarda bir araya gelmesiyle oluşur. Bu üçlüye yangın üçgeni denir (Şekil 2). Yangının kontrol altına alınabilmesi için veya yangın tehlikesinin engellenebilmesi için bu üç etkenden en az birini ortamdaki kaldırmak yeterlidir. Zira bu üç etkenden birisinin olmadığı durumda yanma olayı gerçekleşmeyecektir. Yangın, yanıcı maddenin tutuşma sıcaklığına gelmesi, oksijenin belirli bir düzeyin üzerinde (%15'ten fazla) ve yeterli miktarda yanıcı madde bulunması koşullarında meydana gelir. Aynı zamanda bu üç etkenin oransal değişimleri yangın yoğunluğunu belirler (Orman Yangınlarının Önlenmesi ve Söndürülmesinde Uygulama Esasları: Tebliğ No: 285., 1995; Peker & Atılgan, 2015). Tutuşma sıcaklığı, bir maddenin yanmaya başlaması için gereken minimum sıcaklıktır (Bilgili, 2014).



Şekil 2 Yangın Üçgeni

(Bilgili, 2014) “düzenlenmiştir”

2.2. Orman Yangını Türleri

Yangın türleri, yangının gerçekleştiği yere göre 3'e ayrılır.

Toprak yangınları; toprak yüzeyi altındaki organik madde katmanının (ham humus veya kuru turbalıklar) yanmasıyla oluşan, genellikle yüzey altından usulca ilerleyen ve görünmediği için de kontrol altına alınması zor olan bir yangın türüdür. Türkiye'de kalın humus tabakası ve turbalıkların bulunmaması nedeniyle oldukça nadir görülür (Bilgili, 2014). Bu tip yangınlar topraktaki organik maddeyi yok edip mineral maddeye dönüştürdüğü için en zararlı yangın türü olarak nitelendirilir ve bu alanlarda tekrar bitki örtüsü oluşmaz (Zainalabden, 2022).

Örtü yangınları; toprağın üzerindeki ölü ve/veya diri örtüyü yakan yangınlardır. Bu yangınlar ağaçlara çoğunlukla zarar vermez (Orman Yangınlarının Önlenmesi ve Söndürülmesinde Uygulama Esasları: Tebliğ No: 285., 1995). Ancak orman yangınlarının tümü örtü yangınıyla başlayarak gelişir (Bilgili, 2014).

Tepe yangınları; yüzey yangınlarının, zemin ve ağaç gövdesi üzerindeki yakıtları yakarak alevleri ve çıkan gazı taç yapraklarına taşınmasıyla oluşur. Tepe yangınları yüzeyden bağımsız olarak hareket eder ve ağaç tepelerini yakarak ilerler. Genellikle sürekli taç yapısına sahip ve kozalaklı ağaç meşcerelerinde ortaya çıkar. Kontrol altına alınması oldukça zor olan bu yangın türü çok hızlı yayılır (Santiago & Kheladze, 2011). Büyük yangınlarda yanan alanların çoğunluğu bu yangınlarla oluşur (Butler & Cohen, 1998).

2.3. Yangın Çıkış Nedenleri

Yangınların çıkış sebepleri önlenabilir ve önlenemez olarak 2 ye ayrılır. Önlenabilir yangınlar, kasıtlı ve kasıtsız çıkan yangınlardır. Kasıtlı yangınlar kundakçıların çıkardıkları yangınlardır. Kasıtsız yangınlar; ihmal, dikkatsizlik, kaza veya yıldırım gibi doğal nedenlerden çıkan yangınlardır. Önlenemez yangınlar ise faili meçhul olan yangınlardır (Plummer, 1912).

Türkiye’de 2002 ile 2023 yılları arasında sebeplerine göre çıkan yangınlar alansal ve sayısal olarak listelenmiştir (Tablo 8) (OGM, 2024).

Tablo 8 Orman yangınlarının çıkış sebeplerine göre sayısal ve alansal dağılımı

	Orman Yangınlarının Çıkış Nedenleri							
	Kasıt		İhmal/Dikkatsizlik/Kaza		Doğal		Faili Meçhul	
	Adet	Ha	Adet	Ha	Adet	Ha	Adet	Ha
2002	218	509	809	7.287	181	261	263	457
2003	258	665	1.317	4.520	120	694	482	765
2004	242	748	1.033	3.093	128	233	359	802
2005	272	402	867	2.084	140	48	251	288
2006	166	206	1.315	5.873	330	543	416	1.139
2007	292	1.705	1.642	7.994	407	243	488	1.722
2008	377	797	1.018	26.283	330	699	410	1.970
2009	231	792	884	3.082	333	105	345	700
2010	146	526	861	1.851	281	69	573	871
2011	153	283	1.067	2.368	130	39	604	922
2012	197	1.615	936	5.780	373	334	944	2.725
2013	260	1.478	1.419	4.051	258	138	1.818	5.789
2014	127	85	801	1.682	328	77	893	1.273
2015	138	167	794	1.198	257	95	961	1.759
2016	157	240	990	5.222	310	170	1.731	3.524
2017	151	621	721	7.152	259	84	1.280	4.136
2018	94	179	676	2.120	400	142	997	3.203
2019	124	686	883	6.529	372	373	1.309	3.744
2020	72	718	1.156	8.285	312	197	1.859	11.771
2021	110	46.148	1.001	46.878	353	208	1.329	46.269
2022	86	4.722	830	5.428	358	517	886	2.132
2023	92	662	1.113	11.260	399	365	955	3.233
Toplam	3.963	63.954	22.133	170.020	6.359	5.633	19.153	99.195
Yüzde Oran	8%	19%	43%	50%	12%	2%	37%	29%

Tablo incelendiğinde son 22 yılda ülkemizde gerçekleşen orman yangınlarının en büyük sebebinin ihmal, dikkatsizlik ve kaza yoluyla çıkan yangınlar olduğu belirlenmiştir. Çıkan 51.608 adet yangında toplamda 338.802 hektarlık ormanlık alan yanmıştır. Yanan alanların %50’si ihmal, dikkatsizlik ve kaza, %29’u faili meçhul, %19’u kasıtlı ve %2’si doğal nedenlerden çıkan yangınlardan etkilenmiştir.

2.4. Yangına Sebebiyet Veren Etkenler

Yangına sebebiyet veren tüm etmenlerin bir arada incelenmesi, olası yangınların meydana gelmesi ve büyümesinin önüne geçilmesinde önemli bir yere sahiptir. Bu etmenler başlıca; bitki örtüsü, insan faaliyetleri, meteorolojik ve topoğrafik koşullardan oluşur (Sepetçi, 2014; Tien Bui vd., 2018).

2.4.1. Topoğrafik veriler:

Topoğrafyadaki değişimler hava şartlarını ve yakıtı etkileyeceğinden, topoğrafyanın yangın oluşumu ve davranışında büyük etkisi vardır. Yangın öncesi ve sırasında etkili rol oynar (Karabulut vd., 2013; K. Şahin, 2006; Teketay, 2000; Sari, 2021).

Arazi yapısı, rüzgarların yönüne ve şiddetine etki eder, yerel mikro iklimleri etkiler. Bu sebeple orman yangını başlatmaya neden olabilir (Gai vd., 2011).

Eğimin arttığı yerlerde yangın, alevlerin yaydığı sıcaklığın, etrafındaki nem oranını azaltıp, sıcaklığı artırması ve alevlerin önündeki yakıtı daha kolay ulaşabilmesi nedeniyle hızlı ilerler. Eğimdeki ani değişimler yüzeysel akış hızı oluşturarak yakıtın kurumasına yol açar ve bu da yangın riskini artırmaktadır. Ayrıca eğim, yangının hızını, alev uzunluğunu ve yönünü etkiler (Burgess, 2011; Gai vd., 2011; Hacısalihoğlu, 2018; How Fire Behaves, 2023; Karabulut vd., 2013; Rothermel, 1972; Santiago & Kheladze, 2011; Şahin, 2006; Teie, 1997; Zainalabden, 2022).

Eğimdeki her 10°'lik artış yangın hızının 2 katına çıkmasına sebep olur. Bunun tam tersi de geçerlidir. Yani eğimdeki her 10°'lik azalış yangın hızını yarıya düşürür (How Fire Behaves, 2023).

Bakı, yangın çıkma koşullarını büyük oranda etkiler. Bunun nedeni farklı bakılarda farklı miktarda güneş ışığı alınması ve farklı oranda rüzgâr şiddetine maruz kalınmasıdır (Barrows, 1951).

Güney bakılar güneş ışığına ve hâkim rüzgarlara daha fazla maruz kaldığından, bu durum hava ve yakıt sıcaklığının artmasına, yakıt miktarının fazlalaşmasına ve nemin daha azalmasına yol açarak tutuşma riskini artırmaktadır (Barrows, 1951; Bozer, 2011;

Burgess, 2011; Dilekçi, 2019; Karabulut vd., 2013; Santiago & Kheladze, 2011; Zainalabden, 2022).

Yüksekliğin az olduğu yerlerde genelde sıcaklıklar yüksektir ve bağıl nem ise düşüktür. Yükseklik arttıkça orografik yağışlar artacağından dolayı yakıttaki nemlilik ve bağıl nem artar, bağıl sıcaklık düşer (Gai vd., 2011; Hacısalihoğlu, 2018; Karadeniz, 2020; Santiago & Kheladze, 2011).

Rüzgâr hızı artar, çimenler daha geç çıkar ve karlar daha geç erir dolayısıyla yangın riski azalır (Perry, 1990).

Yükseklik, bitki örtüsü ve yakıt modelini değiştireceğinden, arazi örtüsünü ve yoğunluğunu da etkilemektedir. Yüksekliğin arttığı yerlerde bitki örtüsü azalacağından yangın çıkma riski de düşer (Atmaca vd., 2022; Tezcan & Eren, 2023).

2.4.2. Biyolojik veriler:

Yangınların davranışı ve ortaya çıkma konumlarına etki eden en önemli etkenlerden birisi de ağaç türleridir (Karabulut vd., 2013).

Orman yangınları için gerekli yakıtı sağlayan bitki örtüsü yangın üçgeninin önemli bir parçasıdır. Bitki türleri farklı özellikleri, farklı yakıt miktarları ve boyutları dolayısıyla yangınların başlangıç konumlarını ve yangın davranışını etkilemektedir (Burgess, 2011).

Özellikle Kızılçam gibi iğne yapraklılar yangınlara karşı daha hassastır türlerdir. Bunun sebebi içerisinde düşük nem, reçine bulundurması ve kurak yetişme çevrelerinde saf tür olarak bulunmasıdır (Bilgili, 2014; Karabulut vd., 2013; Sivrikaya & Küçük, 2022).

İğne yapraklıların aksine Kayın gibi geniş yapraklı ve nemli ağaç türleri ise yangın direnci göstererek yanmaya karşı dayanıklıdırlar. Bu sebeple kayın ormanları yangın riskini azaltır (Karabulut vd., 2013).

Gelişme çağı ağaçların 1,30 metre yüksekliğindeki çapını ifade eder. Yani en genç ağaçlar en az kalınlığa sahip ağaçlardır. Yangına en hassas olan gelişme çağı, ağaçların gençlik ve sırlıklık dönemleridir. Ağaç yaşı ilerledikçe risk oranı azalır. Büyük

gövdeler daha fazla nemi daha uzun süre bünyelerinde tutmalarından dolayıdır. Ayrıca ölü örtü olmayan yaşlı ağaçlık alanlarda yangın riski azdır (Bilgili, 2014).

Kapalılık ise meşcerelerin tepe yoğunluğudur. Yanıcı madde türüne, nemine ve miktarına etki eder. Kapalı meşcerelere yeterince gün ışığı ve sıcaklık girmez. Bu da ağaç diplerinde yangınların başlaması için oldukça elverişli olan ölü örtünün oluşmasına ve birikmesine neden olur. Orta kapalılığa sahip meşcerelerde, tam kapalı meşcerelere oranla daha az ölü örtü ve gevşek kapalı meşcerelere oranla daha az diri örtü birikimi vardır. Bu da kapalılık arttıkça yangın riskini de artırır (Baltacı, 2021; Küçük vd., 2009).

2.4.3. Meteorolojik veriler:

Hava koşulları, orman yangınları için çok önemli bir faktördür. Yangın riskini ve yangının davranışını büyük ölçüde etkiler. Hava koşulları zamana ve mekâna bağlı olarak büyük değişiklikler gösteren dinamik faktörlerdir. Öte yandan gün içerisinde yangın riskini belirleyen en baskın etkidir. Bu sebeple yakıt nemi, tutuşma, yangın şiddeti ve yangın yayılışında önemli farklılıklar göstererek yangın davranışını ciddi ölçüde etkilemektedir (Bilgili, 2014; Zainalabden, 2022).

Meteorolojik faktörler yangın oluşumunda olduğu kadar yayılmasında da önemli rol oynamaktadır (Dimuccio vd., 2011).

Hava koşullarının değerlendirilmesi, değişkenliği ve etkilerinin büyüklüğünden ötürü önemlidir (Barrows, 1951).

Rüzgâr, yanma olayının gerçekleşebilmesi için en önemli unsur olan oksijeni sağlar. Yangının büyümesini tetikler. Alevlerin sıcaklığını diğer yakıtlara taşır ve konveksiyon yöntemiyle tutuşmaya ve yanmayı artırmaya yardımcı olur. Ayrıca yakıtların hızlı kurummasını ve ön ısınmasının arttırmasını sağlar. Yakıt nemini de düşürerek yangın riskini artırır. Rüzgâr hızının düşük olması, yakıtları daha geç kurutacağından riski azaltır (Bilgili, 2014; Küçük & Sağlam, 2004; Santiago & Kheladze, 2011).

Yangın davranışı üzerine hem dolaylı hem doğrudan etkisi olan sıcaklık, bağıl nemi ve yanıcı maddelerin nemini azaltarak kurumalarını sağlar. Yakıtlar radyasyon yoluyla

güneşten, konveksiyon yoluyla da çevrelerindeki hava kütesinden ısı olarak sıcaklığını artırır. Böylece daha hızlı yanmalarına sebep olarak riski artırır (Barrows, 1951; Bilgili vd., 2002; Perry, 1990).

Sıcaklık, yangın hızını da etkiler. Ayrıca sıcaklığın fazla olduğu yerlerde tutuşmak için gereken ısı miktarı düşeceğinden yanma olayı daha hızlı gerçekleşecektir. Bu da yangın riskini artırır. Her 10 °C sıcaklık artışı, bağıl nemi %50 oranında düşürmektedir (Barrows, 1951; Küçük & Sağlam, 2004).

Bağıl nem, yanıcı madde nemini de etkilediğinde aralarında yakın bir ilişki vardır. Bağıl nem arttığında yanıcı madde nemi de artar ve bağıl nem azaldığında yanıcı madde nemi de azalır. Bağıl nemin en düşük olduğu saatler günün öğlen saatleridir. Bu da yangın riskini artırır. Özellikle ince dallar, kuru otlar ve çalılar gibi yanıcı maddelerin tutuşmasında etkili olan en önemli günlük değişkendir (Küçük & Sağlam, 2004).

Yağışlar hem havanın hem de yakıtların nem oranını artırdıkları için yangın riskini azaltırlar. Yakıtlardaki nem miktarı tutuşma riskini azaltan en önemli etkidir. Yaş yakıtlar kolaylıkla yanmaz (Bilgili vd., 2002; Santiago & Kheladze, 2011).

Yakıt nem miktarı %30'un altına düştüğünde yangınlar için riskli bir hal almış demektir (Küçük & Sağlam, 2004).

2.4.4. İnsan faktörlü veriler:

Orman yangınlarının büyük çoğunluğu insan etkinliklerinden kaynaklanmaktadır. Bu yangınlar kasıtlı veya kasıtsız olarak çıkabilir (Baltacı & Yıldırım, 2021; Pham vd., 2020; Tezcan & Eren, 2023; Nikhil vd., 2021).

Kentsel büyüme ve nüfustaki hızlı artış, arazi kaynakları üzerindeki baskıyı artırmaktadır. Bu da tarımsal sürdürülebilirliği tehlikeye atmaktadır (Bozdağ vd., 2016).

Tarımsal faaliyetler sırasında gerçekleşen dikkatsizlikler ve kazalar, insan kaynaklı orman yangınlarının en önemli sebeplerinden birisidir. Başlıca anız yakma ve tarım arazilerinde yapılan temizlik sebebiyle ormanlara sıçrayan ve sıçramayan tarımsal yangınlarla her sene sıkça karşılaşilmektedir (Baltacı & Yıldırım, 2021).

Uzmanlara göre son yıllardaki yangın artışlarının sebepleri arasında; ormanlar çevresindeki nüfusun artması, turizm faaliyetleri, ormanlarda yapılan piknik ve rekreasyon faaliyetleri sonrasında yakılan ateşler ve atılan sigara izmaritleri sayılmaktadır (Avcı & Korkmaz, 2020).

Yollar ve yerleşim yerleri, insan ve araç faaliyetlerinden kaynaklı olarak yoğun yerler olduğu için ormanların yola ve yerleşime yakın yerlerinde ihmal ve kaza dolayısıyla da yangın çıkma riski yüksektir (Alkayış vd., 2022; Erten vd., 2005; Hacısalihoğlu, 2018; Jaiswal vd., 2002).

Aynı zamanda yol ve yerleşime yakın olan yerlerdeki ormanlık alanlara erişimin kolay olması, insanların ihmal ve dikkatsizliklerinden dolayı yangın çıkma riskini artırmaktadır (Alkayış vd., 2022).

2.5. Makine Öğrenmesi

Makine öğrenimi, verileri öğrenebilmeleri için bilgisayarları programlama bilimi ve sanatıdır. Yapay zekanın bir alt dalı olarak, deneyim yoluyla performansın iyileştirilmesine odaklanır (Géron, 2022; Russell & Norvig, 2020).

Programlanmış algoritmalar, belirli bir doğruluk aralığında tahminler yapabilmek için girdi verilerini analiz eder ve işlemleri öğrenip en uygun hale getirir. Bu algoritmalar, geçmiş birikimlerden faydalanan büyük ve karmaşık haldeki veri yığınlarından anlamlı kalıplar çıkarabilmek ve daha önce öğrenilmemiş olan girdilerin çıktıları tahmin edilebilmek amacıyla için çeşitli istatistiksel, olasılıksal ve optimizasyon tekniklerinden yararlanır. Veri setindeki veri sayısı artırıldıkça, algoritmalar daha isabetli tahminlerde bulunma yeteneğini de artırmaktadır (Mitchell, 1997; Yıldırım, 2023).

Makine öğrenmesinin günümüzde kullanım alanı oldukça artmıştır. Gündelik hayatta bile sıkça karşımıza çıkan makine öğrenimi; eğitim, sağlık, e-ticaret, telekomünikasyon, finansal hizmetler, satış ve pazarlama, ulaşım, tarım, siber güvenlik, otomotiv, enerji, meteoroloji, akıllı şehir hizmetleri, doğal dil işleme, görüntü işleme, risk tahmin sistemleri gibi birçok farklı alanda, sınıflandırma,

regresyon, kümeleme, sıralama, anomali tespiti vb. problemlerin çözümünde kullanılmaktadır (Çelik, 2018; Sarker, 2021; Shinde & Shah, 2018).

Makine öğrenmesi algoritmaları 3 temel kategoride incelenmektedir.

1. Denetimli öğrenme (supervised learning)

Denetimli öğrenme, daha önceden etiketlenmiş bir eğitim veri setine dayalı olarak, bilinmeyen çıktı verilerini tahmin etmeye çalışan bir modeldir. Bu yöntem sınıflandırma, regresyon ve sıralama problemleri ile ilgili en çok kullanılan senaryodur. Maillerde kullanılan spam filtresi bu modele en iyi örnektir (Mohri vd., 2018).

K-En yakın komşu, lineer regresyon, lojistik regresyon, destek vektör makineleri, karar ağaçları, rastgele orman ve yapay sinir ağları denetimli öğrenme algoritmalarındandır (Géron, 2022).

2. Denetimsiz öğrenme (unsupervised learning)

Denetimsiz öğrenmede etiketlenmiş bir veri seti bulunmaz. Bilinmeyen değerler için çıktı verileri tahmin edilir. Genel olarak bu ortamda etiketli örnek bulunmadığından, bir öğrencinin performansını nicel olarak değerlendirmek zor olabilir. Denetimsiz öğrenme problemlerine örnek olarak kümeleme ve boyut azaltma verilebilir (Mohri vd., 2018).

3. Yarı denetimli öğrenme (semi-supervised learning)

Yarı denetimli öğrenmede hem etiketli hem de etiketsiz veriler kullanılır. Bu yöntem, etiketlenmemiş verilere kolayca erişilebildiği ancak etiketlerin toplanmasının maliyetli veya zor olduğu durumlarda kullanılmaktadır. Sınıflandırma, regresyon ve sıralama gibi çeşitli problemler yarı denetimli öğrenme örnekleridir. Bu yöntemin amacı, etiketsiz verilerin dağılımından yararlanarak denetimli öğrenme modellerinin performansını artırmaktır (Mohri vd., 2018).

Bunlar dışında takviyeli öğrenme (reinforcement learning), derin öğrenme (deep learning) gibi farklı makine öğrenmesi türleri de vardır.

Bu çalışmada kullanılan sınıflandırma algoritmaları ise şunlardır:

2.5.1. Yapay sinir ağıları (NN):


Yapay sinir ağı, girdi ve çıktı nöronlarından oluşan, eğitilebilir ve nöronlar arasındaki bağlantıları öğrenme yeteneği bulunan bir sistemdir (Gündoğdu, 2023).

İnsan beyninin işleyişini taklit etmek için bir dizi bağlantılı düğüm kullanır. İnsan beynini; bilgiyi edinme süreci ve öğrenme yoluyla elde edilen bilginin depolanması için sinaptik ağırlıkların kullanımı olmak üzere iki şekilde taklit eden matematiksel modeldir. Biyolojik sinir ağlarından ilham alınarak geliştirilmiştir ve bu ağlara benzer bazı performans özellikleri gösterir (Ghorbanzadeh vd., 2019; Kaynar & Taştan, 2009, 2009).

Bu model birbiriyle bağlantılı sinir hücreleri (nöronlar) ve bu hücreler arasındaki bağlantılardan (sinapslar) oluşur. Yapay sinir ağları girdi verilerini işler ve çıktı verileri üretir (Öztürk & Şahin, 2018).

İnsan beyninde bulunan biyolojik sinir ağları, sinir hücrelerinden oluşur. Yapay sinir ağları da tıpkı bunlar gibi birbirine bağlı birçok yapay sinir hücrelerinden oluşmaktadır (Kargı, 2013).

Yapay sinir hücreleri, yapay sinir ağlarının en küçük birimini oluşturur. Sinir hücresi; girdi, ağırlık, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş bileşene sahiptir (Şekil 3) (Kaynar & Taştan, 2009).



Şekil 3 Yapay sinir hücresi


(Kaynar & Taştan, 2009) “düzenlenmiştir”

Burada (x) girdileri temsil eder ve hücreye gelen bilgilerdir. Ağırlıklar (w) ile temsil edilir ve işlem elemanlarının birbirleri üzerindeki etkileridir. Her girdi, kendisine tanımlanan ağırlık değeri ile çarpılır ve toplama fonksiyonu ile birleştirilir. Toplama fonksiyonu (Σ) ile temsil edilir ve toplama fonksiyonundan elde edilen değer, işlem elemanının çıktısını hesaplamak için doğrusal veya doğrusal olmayan türevlenebilir bir aktivasyon fonksiyonuna tabi tutulur. Aktivasyon fonksiyonu (f) ile temsil edilir. Çıktı ise (y) ile temsil edilir ve işlenmiş verilerin sonuçlarını aktarır (Kaynar & Taştan, 2009).

Yapay sinir ağları ise nöronların birbirleri arasında bağlantılar kurarak katmanlar oluşturması ilkesine dayanır. Girdi katmanı, çıktı katmanı ve bir veya birden fazla gizli katmandan oluşur. Başlangıçta girdiler ilk katmana aktarılır ve ağ içinde işlenerek çıktı katmanında sonuç üretilir. Katmanlar nöron gruplarından oluşur ve aralarındaki bağlantılar ağırlıklarla tanımlanır. Bu bağlantılar yardımıyla girdi verileri ağa aktarıldıktan sonra işlemler gerçekleştirilir ve sonuç çıktıları elde edilir (Rumelhart vd., 1986).

Girdi katmanında, dışarıdan gelen girdi verileri gizli katmana aktarılır ve burada herhangi bir işlem yapılmaz. Gizli katmanda, giriş sinyalleri ile ağırlıklar çarpılır ve toplamları alınır. Daha sonra aktivasyon veya transfer fonksiyonu yardımıyla sonucu bir sonraki gizli katmana veya çıktı katmanına iletir. Çıktı katmanı bir sinir ağının sonunda yer alır. Gizli katmanın ilettiği veri burada ağ fonksiyonu ile çalıştırılarak diğer bir sinir ağına ya da dışarı aktarılır (Kargı, 2013).

Yapay sinir ağlarının yapısı Şekil 4'deki gibidir.



Şekil 4 Yapay sinir ağlarının yapısı

(Şen, 2004) “düzenlenmiştir”

YSA’nın eğitimi, nöronların bağlantı ağırlıklarının bulunmasıyla olur. Önce rastgele belirlenen ağırlıklar, eğitim veri kümesi denilen girdi-çıkı çiftleriyle güncellenir. Eğitim sürecinde, aynı veri kümesi birden fazla kere kullanılarak ağırlıklar en makul seviyeye getirilir. Tüm eğitim kümesinin ağı verilmesi işlemi bir iterasyon (epoch) olarak adlandırılır. Eğitim tamamlandığında ağı doğru çıktılar üretiyorsa, ağırlık değerleri aynı kalacak şekilde korunur.

Ağı, eğitim sürecince verilmeyen yeni verilerle (test veri kümesi) test edilir. Bu test sırasında ağırlıklar değiştirilmez, sadece daha önce belirlenen ağırlıklarla yeni çıktılar üretilir. Test sonuçları ağı öğrenme performansını gösterir. İyi bir sinir ağı, eğitim verilerinden öğrenir ve genelleme yaparak yeni verilere doğru tahminler yapabilir. Eğer ağı sadece eğitim verilerini ezberlerse, test verilerinde yüksek hata oranları ortaya çıkar ve genelleme yeteneği zayıf olur. Öğrenme algoritması, istenen ve gerçekleşen çıkış vektörleri arasındaki farkı minimize ederek ağırlıkları ayarlar ve doğru tahminler yapmaya çalışır (Kargı, 2013).

YSA, büyük girdilere sahip karmaşık verilerden daha doğru modeller oluşturabilmesi ve kullanımını kolay hale getirebilmesiyle oldukça avantajlıdır (Abiodun vd., 2018).

Esas kuralların belirsiz olduđu karmaşık senaryolarda bile doğrusal olmayan veri yapılarını incelemek ve modellemek için kullanılan kritik bir makine öğrenmesi algoritmasıdır (Walczak, 2019).

Sıkça; sınıflandırma, tahmin, veri filtreleme ve yorumlama uygulamalarında kullanılmaktadır.

2.5.2. Destek vektör makineleri (SVM):


Destek vektör makinelerine ait ilk örnekler; 1936 yılında (Fisher, 1936) tarafından çoklu ölçümlerin kullanımıyla popülasyonları ayırt etmenin bir yöntemini sunmak amacıyla, popülasyonlar arasındaki ayrımı en üst düzeye çıkaran ve yanlış sınıflandırma olasılığını en aza indiren doğrusal fonksiyonlara dayanmaktadır. Daha sonra 1995 yılında (Cortes & Vapnik, 1995) tarafından geliştirilen model bugünkü halini almıştır.

SVM, istatistiksel öğrenme teorisine dayalı bir makine öğrenmesi algoritmasıdır (Vapnik & Vapnik, 1998).

Gözetimli öğrenme ve sınıflandırma problemleri için kullanılan güçlü bir algoritma olan SVM, veri kümesindeki en önemli noktaları (destek vektörleri) belirleyerek ve bu noktalara dayalı bir karar sınırı oluşturur (Cortes & Vapnik, 1995).

Farklı sınıflara ait verilerin, hiper düzlemler oluşturularak, birbirinden en net şekilde ayrılması ilkesiyle çalışır. Bu amaçla, SVM algoritması, sınıflar arasındaki en büyük ayrımı yaratan ve sınırın en büyük genişlikteki ayırıcı düzlemi keşfetmeye çalışır. İki veriye ait sınıflandırma yaparken, hiper düzlemler arasındaki mesafe marj olarak adlandırılır ve sınıflandırma hatasının en az, marjın ise en büyük olması beklenir (Çapkurt, 2023).

Destek vektörler ve marjın bir örneği Şekil 5’de gösterilmektedir.



Şekil 5 SVM sınıflandırması

(Cortes & Vapnik, 1995) “düzenlenmiştir”

2.5.3. Naive bayes (NB):

Naive bayes 1800’lü yıllarda Thomas Bayes tarafından ortaya atılmış bir olasılıksal sınıflandırma yöntemidir. Sınıflandırma, yeni verileri önceden tanımlanmış sınıflardan birine atamak için bir dizi sınıflandırma arasından en uygun eşleşmeyi bulma işlemidir (Yang, 2018).

Naive Bayes, sınıflandırma yaparken tüm niteliklerin birbirinden bağımsız olduğunu varsayar. Bu varsayım, eğitim verilerindeki tüm olasılık kombinasyonlarını doğrudan tahmin etmenin zor olmasından kaynaklanır. Bu yöntem, koşullu bağımsızlık varsayımı sayesinde bu zorluğu aşar ve birçok gerçek dünya uygulamasında etkili bir sınıflandırıcı olarak kullanılır (S. Chen vd., 2020).

Bu sınıflandırmayı olasılıksal olarak hesaplamak için, ortak olasılıkları, önceki olasılıklar ve koşullu olasılıkların çarpımları olarak ifade edilir (Yang, 2018).

Bayes denklemi, Denklem 2.1’ de gösterilmektedir (Jackins vd., 2021).

$$P(A | Y) = \frac{P(Y | A) P(A)}{P(Y)} \quad [2.1]$$

$P(A | Y)$: B olayının gerçekleşmesi durumunda A olayının meydana gelme olasılığı,

$P(Y | A)$: A olayının gerçekleşmesi durumunda B olayının meydana gelme olasılığı,


$P(A)$ ve $P(Y)$: A ve Y olaylarının önsel olasılıklarıdır.

Naive bayes algoritması veri madenciliği başta olmak üzere, sağlık, iletişim, dil bilimi, yapay zekâ gibi alanlarda sıkça kullanılmaktadır (H. Chen vd., 2021).

2.5.4. Doğrusal diskriminant analizi (LDA):

1936 yılında (Fisher, 1936) tarafından ilk kez ortaya atılan Lineer Diskriminant Analizi, günümüzde veri işleme ve denetimli boyut azaltmada yaygın olarak kullanılan istatistiksel bir sınıflandırma yöntemidir. Birden çok veri kümesinin ortak ve farklı yönlerini belirlemek ve bu bilgilere dayanarak sınıflandırma veya tahminleme gibi işlemler yapmak için kullanılır. İki sınıf problemine uygulanan LDA, özellik uzayında sınıflar arası ayrımı maksimize ederken sınıf içi ayrımı minimize eden bir doğrusal fonksiyon bulmayı amaçlar (Ricciardi vd., 2020; Servi & Erişoğlu, 2020).

LDA'nın bir örneği Şekil 6'da gösterilmektedir.



Şekil 6 LDA sınıflandırması

(Zhu vd., 2022) “düzenlenmiştir”

Yeşil yuvarlaklar sınıf 1, kırmızı paraleller ise sınıf 2'yi temsil eder. Sınıf 1 iki ayrı kümeden oluşur ve gauss dağılımı izler. Siyah çizgi, LDA tarafından üretilen ve

tahmin edilen alt uzaydır. Mavi çizgi ise istenen alt uzayı göstermektedir (Zhu vd., 2022).

Diskriminant analizi, tahmin edici ve tanımlayıcı olmak üzere iki türü vardır.

Tahmin edici diskriminant analizi, yeni gözlemlerin hangi gruba ait olduğunu tahmin etmeye odaklanır. Satış tahmini, ekonomik büyüme, akademik başarı gibi araştırmalarda uygulanabilir. Tanımlayıcı diskriminant analizi ise bağımsız değişkenlerin grupları ayırmada ne kadar etkili olduğunu belirlemeye odaklanır. Hangi değişkenlerin grupları en iyi ayırt ettiğini gösterir.

Diskriminant analizi, pazarlama, eğitim, sağlık ve diğer birçok alanda kullanılmaktadır (Çiftçi vd., 2020).


2.5.5. K-En yakın komşu (KNN):

K-En Yakın Komşu algoritması, veri noktalarının birbirlerine olan benzerliklerine ve uzaklıklarına göre sınıflandırma ilkesine dayanan basit ve etkili bir denetimli öğrenme algoritmasıdır. Algoritma, yeni bir veri noktasının sınıfını, eğitim kümesindeki en yakın k komşusunun sınıfına göre tahmin eder. Bu, "benzer şeyler birbirine yakındır" fikrinden ortaya çıkarılmıştır (Altman, 1992).

K değeri Öklid mesafesi kullanarak veriler arasındaki uzaklığı hesaplar.

KNN, basitliğiyle öne çıkan bir algoritmadır ancak düşük verimliliği, 'k' değerinin seçimi zorluğu, gürültüye karşı hassasiyeti ve gibi bazı dezavantajlara da sahiptir. Model performansının artırılması, k değerinin en doğru şekilde seçilmesine bağlıdır (Singh vd., 2016).

K değerinin doğru seçilmesinin önemi Şekil 7’de görselleştirilmiştir.



Şekil 7 KNN sınıflandırması

(Yıldırım, 2023) “düzenlenmiştir”

Şekilde kırmızı yuvarlaklar sınıf 1, yeşil yuvarlaklar ise sınıf 2’yi temsil eder. Mavi renkli yuvarlak, bir sınıfa atanmak istendiğinde k değerinin seçimine bağlı olarak; eğer 5 seçilirse en yakın komşu seçilerek sınıf 1’e, k eğer 9 seçilirse sınıf 2’ye atanacaktır.

K değeri seçilirken çapraz doğrulama tekniği kullanılabilir (Singh vd., 2016).

KNN, arama sorgularında sonuçların mevcut veriye benzemesi gerektiğinde yaygın olarak kullanılır. Örneğin, benzer görsellerin tespiti ve öneri sistemlerinde kullanılır. Ayrıca, aykırı değer tespitinde de sıkça kullanılmaktadır (Jain vd., 2020).

2.5.6. Karar ağaçları (DT):


Karar ağaçları; sınıflandırma, regresyon ve çoklu çıktılara sahip görevlerde kullanılan çok yönlü bir algoritmadır (Géron, 2022).

Karar Ağacı, verileri sürekli olarak bölerek sınıflandırma ve regresyon sorunlarını çözen bir denetimli makine öğrenimi yöntemidir. Sınıflandırma ağacında sonuç evet veya hayır şeklinde kategorik, regresyon ağacında ise sürekli. Avantajları,

yorumlama kolaylığı, kategorik ve niceliksel değerleri işleyebilme, eksik verileri doldurabilmesidir. Dezavantajları ise kararsızlık, boyut kontrolünün zor olması, örnekleme hatasına yatkınlık ve genel değil yerel çözümler sunmasıdır (Ray, 2019).

Karar Ağaçları, if-then-else kurallarıyla birleştirilen ve yaprak düğümlerle sonuçlanan dallardan oluşur. Karar düğümleri, ağacın farklı yollara çıktığı noktalardır ve yaprak düğümler modelin çıktısını temsil eder. Karar ağaçlarında amaç, ezberlemeyi önleyerek girdi ve çıktılar arasındaki bağlantıyı en küçük ağaç yapısıyla doğru bir şekilde yakalamaktır (Jain vd., 2020).

Karar ağaçlarının yapısı Şekil 8’de gösterilmektedir.



Şekil 8 DT sınıflandırması

(Yıldırım, 2023) “düzenlenmiştir”

Makine öğrenmesi algoritmaları kullanılarak yapılan bir çalışmada en önemli aşamalardan birisi, oluşturulan modelin eğitim ve test performanslarının değerlendirilmesidir.

Alıcı İşletim Karakteristiği (Receiver Operating Characteristic, ROC) eğrisi, sınıflandırma modellerinin performansını değerlendirmede yaygın olarak kullanılan önemli bir araçtır. Farklı eşik değerlerinde modelin doğruluğunu ölçer. Bu eğri, modelin ne kadar iyi genelleştirilebildiğini ve ne kadar iyi uyum sağladığını gösterir. Başka bir deyişle, ROC eğrisi, modelin doğru pozitifleri ve yanlış pozitifleri ayırt etme yeteneğini görsel olarak temsil eder (Pham vd., 2020).

Y ekseninde özgüllük ve X ekseninde duyarlılık arasındaki ilişkiyi gösterir (Abedi Gheshlaghi vd., 2020; Mandrekar, 2010).

Eğrinin Altında Kalan Alan (Area Under the Curve) ise ROC eğrisinin altındaki alanı temsil eder. 0,5 ile 1 arasında değerler alabilir (Fawcett, 2006). 0,9'ın üzerindeki AUC performansı, bir model için çok iyi performans olarak nitelendirilir (Hosmer vd., 2013).

Sınıflandırıcıların yani algoritmaların performansının değerlendirilmesinde istatistiksel metrikler kullanılmaktadır. Farklı metrikler bir algoritmanın farklı özelliklerini değerlendirir. Bunlardan sıkça kullanılan bazıları Denklem 2.2, 2.3, 2.4, 2.5 ve 2.6'da gösterilmektedir (Hossin & Sulaiman, 2015).

Öncelikle 2x2 karışıklık matrisinin oluşturulması ve bunlara karşılık gelen tanımların bilinmesi gerekir. Gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP), yanlış negatif (FN) olmak üzere:

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad [2. 2]$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad [2. 3]$$

$$\text{Özgüllük} = \frac{TN}{FP + TN} \quad [2.4]$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad [2.5]$$

$$\text{F1 Skor} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad [2. 6]$$

şeklinde hesaplanır.

2.6. CBS

CBS, Dünya'yı konumsal bir bakış açısıyla anlamamızı, yönetmemizi ve geliştirmemizi sağlar. Mekânsal verileri toplayan, depolayan, analiz eden ve görselleştiren, problem çözme ve karar verme süreçlerini optimize eden, farklı disiplinleri birleştiren ve sürdürülebilir bir dünya inşa etmemize katkıda bulunan dinamik bir bilgi sistemidir (DeMers, 2008).

Bu sistem, kullanıcıların dünya üzerindeki çeşitli karmaşık sorunları analiz etmelerine, çözümler üretmelerine ve bu çözümleri uygulamaya koymalarına yardımcı olur. CBS, sosyal, ekonomik ve çevresel sorunlar gibi geniş bir yelpazede kullanılabilir (Sepetçi, 2014).

CBS, birbirine bağlı görevleri yerine getirmesine izin veren, düzenlenmiş bir dizi parçadan oluşur (DeMers, 2008).

Bunlar; veri, yazılım, donanım, insan ve yöntemdir.

2.6.1. Veri:


Bir coğrafi bilgi sistemi oluştururken en zor ve meşakkatli aşama veri toplama aşamasıdır (Özmen, 2010).

Coğrafi Bilgi Sistemleri'nin temelini oluşturan veri, adeta bir hazine gibidir. Haritalar ve uydu görüntüleri gibi grafik coğrafi veriler ile tablolar ve öznitelik bilgilerini içeren tanımlayıcı veriler, çeşitli kaynaklardan toplanabilir veya piyasadan satın alınabilir. CBS'nin gücü, bu konumsal verileri diğer veri kaynaklarıyla birleştirebilmesinde yatar. Bu sayede birçok kurum ve kuruluştan gelen bilgiler organize edilir ve coğrafi boyut kazanarak anlamlı hale gelir.

Uzmanlar tarafından CBS'nin en temel ögesi olarak kabul edilen verinin, aynı zamanda en zor elde edilen bileşen olduğu da bir gerçektir. Veri kaynaklarının düzensiz olması, sayıca çok fazla kaynak bulunması ve bunların farklı formatlarda olması, veri toplama sürecini zorlaştırmakta ve büyük zaman ve büyük maliyetlere yol açmaktadır. Öyle ki, CBS kurulum maliyetlerinin yarısından fazlası veri toplama aşamasında harcanmaktadır (Yomralıoğlu, 2005).

CBS projelerinin temelini oluşturan veriler, konumsal ve konumsal olmayan bilgileri bir araya getirerek, karmaşık analizler yapmamızı sağlar. Bu veriler, veri tabanlarında depolanarak istenildiğinde kolayca erişilebilir ve kullanılabilir hale gelir. CBS'de kullanılan veriler iki ana kategoriye ayrılır:

Grafik veriler; raster ve vektör verilerden oluşur (Şekil 9). Raster veriler; piksellerden oluşan ve uydu görüntüleri, hava fotoğrafları gibi sürekli değişen yüzeyleri temsil eden verilerdir. Arazi yüksekliği, toprak kullanımı gibi konularda kullanılırlar. Vektör veriler; nokta, çizgi ve poligon gibi geometrik objelerden oluşan ve binalar, yollar, sınırlar gibi keskin hatlı unsurları temsil eden verilerdir.



Şekil 9 Raster ve vektör veri türleri

(Escobar vd., 2008)

Uygulama alanına ve mevcut veri kaynaklarına göre her iki grafik veri formu da kullanılabilir.

Grafik olmayan veriler ise; konum bilgisi barındırmayan ve semboller ile tanımlanan verilerdir. Nüfus istatistikleri, sosyoekonomik veriler, anket sonuçları gibi soyut bilgileri içerir (Dilekçi, 2019; Yomralıoğlu, 2005).

2.6.2. Yazılım:

CBS yazılımları, mekânsal bilgileri incelemek, analiz etmek ve yönetmek için tasarlanmış güçlü araçlardır (Zainalabden, 2022).

CBS'nin temel taşı olan yazılımlar; coğrafi verileri depolamak, analiz etmek, sorgulamalar yapmak ve kullanıcılara veri sunmak amacıyla farklı programlama dillerinde yazılmış algoritmalar. CBS yazılımlarının temel işlevleri; veri girişi ve işleme için bir arayüz, bir veri tabanı yönetimi sistemi, sorgulama, analiz ve görüntüleme işlevlerine sahip olması olarak sıralanabilir. Veri tabanı yönetimi konusunda en önemli husus, yazılımın farklı veri tabanlarıyla uyumlu olmasıdır. Esri, MapInfo, QGIS gibi birçok yazılım bu kapsamda en çok kullanılan yazılımlardandır (Sepetçi, 2014).

2.6.3. Donanım:

CBS yazılımlarının çalıştığı bilgisayarlardır. CBS'nin kalbinde bilgisayar yer alsa da sistemin işleyişi için tek başına yeterli değildir. Donanım, bilgisayarın yanında yan ürünlerden de oluşan ve CBS'nin veri toplama, işleme ve sunma becerilerini tamamlayan bir bileşendir (Satır, 2011).

CBS, sayısal haritaları depolamak, işlemek ve gerektiğinde kullanabilmek amacıyla geniş bir belleğe (RAM) ve veri saklama alanına (diskler) sahip hızlı bir bilgisayara ihtiyaç duyar. Bunun yanında; yüksek çözünürlüklü renkli monitör, haritaları ve diğer görselleri net ve ayrıntılı bir şekilde görüntülemeye imkân verir. Renkli çizici ise büyük boyutlu haritaları ve afişleri yüksek kalitede basmaya olanak tanır. Renk uyumu iyi olan renkli yazıcı da haritaları ve raporları gerçeğe yakın renklerde basarak kullanıcılara yüksek kaliteli çıktı sunar. CBS bileşenleri içerisinde donanım ve yazılım, diğer bileşenler gibi önemli bir yere sahiptir.

2.6.4. İnsan:

İnsanlar CBS'nin kullanıcılarıdır ve insanlar olmadan bu sistem sınırlı kalır (Yomralıoğlu, 2005).

CBS kullanıcıları, kullanım becerilerine göre ikiye ayrılır: Basit amaçlı kullanıcılar, temel harita görüntüleme, sorgulama ve analiz gibi işlemleri gerçekleştirirken, gelişmiş seviye kullanıcılar ise karmaşık analizler, harita yapımı, veri modelleme ve sistem yönetimi gibi görevleri üstlenir. CBS operatörleri ise gerçek zamanlı problem çözme ve kritik karar verme süreçlerine katkıda bulunur (E. K. Şahin, 2012).

Başarılı bir CBS için insan en önemli bileşendir (Zainalabden, 2022).

2.6.5. Yöntem:

Etkin bir CBS, titizlikle planlanmış ve sağlam iş kurallarıyla yönetilen bir sistemdir. Bu tür sistemler, her kurumun özel gereksinimlerine göre uyarlanmış modeller ve uygulamalardan oluşur. CBS'nin, kurum içi birimler ve kurumlar arasında konumsal bilginin akıcı bir şekilde dolaşabilmesi için, uygun yöntemlerin geliştirilmesi ve uygulanması kritik önem taşır. Kullanıcı taleplerine göre konumsal verilerin toplanması, işlenmesi ve sunulması ise belirli standartlara ve kurallara bağlıdır. Bu uygulamalar, genellikle standartların belirlenmesini de içerir ve kurumun kurumsal yapısı ile doğrudan ilişkilidir. Yasal düzenlemeler ve gerekli yönetmelikler aracılığıyla ilkelerin belirlenmesi ve uygulanması, CBS'nin başarısı için temel oluşturur (Yomralıoğlu, 2005).

CBS; trafik kazalarının analizinde (Saplıoğlu & Karaşahin, 2006), arazi ve toprak özelliklerinin değerlendirilmesinde (Özyazıcı vd., 2014), arazi örtüsü / arazi kullanımı haritalarının oluşturulmasında (Dengiz & Demirağ Turan, 2014), yer altı (Başçiftçi vd., 2013) ve yer üstü su seviyelerinin tespitinde (Susam vd., 2006), kıyı çizgisi değişimlerini belirlemede (Tağıl & Cürebal, 2005), en uygun yer belirleme analizlerinde (Ertunç & Çay, 2020), gürültü haritalarının oluşturulmasında (Morova

vd., 2014), hava kalitesi belirlemelerinde (İncecik & Daylan, 2002), taşınmaz değerlemesinde (Alkan & Özfidan, 2016), ulaşımda (Thill, 2000), sağlıkta (Frados vd., 2014), turizmde (Wei, 2012), afet yönetimi ve risk haritalarının oluşturulması uygulamalarında (Arca, 2012) gibi bir çok farklı alanda yaygın bir şekilde kullanılmaktadır.

2.7. AHP

Analitik Hiyerarşi Prosesi (AHP), karmaşık karar verme problemlerini yapılandırmak ve çözmek için kullanılan, çok kriterli karar verme yöntemidir. 1977 yılında (T. L. Saaty, 1977) tarafından geliştirilmiş olan bu yöntem, karar vericilerin karmaşık problemleri daha yönetilebilir hale getirmelerine ve rasyonel kararlar vermelerine yardımcı olmaktadır. AHP, nicel ve nitel kriterleri bir arada değerlendirerek, grup veya bireyin tercihlerini, deneyimlerini, sezgilerini, bilgilerini, yargılarını ve düşüncelerini karar sürecine dahil eden bir yöntemdir.


AHP'nin temel prensibi, hiyerarşik bir yapı içinde oluşturulan karar problemini (amaç, kriterler, alt kriterler ve alternatifler), alt problemlere bölerek ve bu alt problemleri ikili karşılaştırma yoluyla değerlendirerek çözmektir. Bu sayede, karar verici her bir kriterin ve alternatifin göreceli önemini/ağırlığını belirleyebilir ve en uygun seçeneği seçebilir (Ozdemir & Saaty, 2006; T. L. Saaty, 1990; T. Saaty & Sagir Ozdemir, 2003).

Analitik Hiyerarşi Süreci, insanın doğuştan sahip olduğu karar verme mekanizmasını modelleyen sezgisel bir yaklaşımdır. AHP, niteliksel kriterleri de dikkate alarak, sayısallaştırılabilen somut ve soyut kriterleri karşılaştırır ve bu kriterlerin birbirine göre önceliklerini hesaplar. Bu sayede, diğer yöntemlerle ele alınması zor olan faktörleri de değerlendirerek kararları etkileyen tüm unsurları analiz eder ve önem sıralarını belirler (Güngör & İşler, 2005).

AHP; problemin tanımlanması, ikili karşılaştırmaların oluşturulması, ağırlıkların hesaplanması ve duyarlılık analizi olmak üzere 4 aşamadan oluşur (Forman & Selly, 2001).

2.7.1. Problemin tanımlanması veya hiyerarşik yapının oluşturulması:

İlk adım hiyerarşik yapının oluşturulmasıdır. Bu adımda önce problem (amaç) net bir şekilde belirlenir ve sonra her bir kriter bu amaca hizmet edecek şekilde tanımlanır. Bu kriterler alt kriterlere ayrılabilir ve son olarak alternatifler belirlenerek, hiyerarşik yapı oluşturulmuş olur (Şekil 10) (Scholl vd., 2005).



Şekil 10 AHP'nin yapısı

(R. W. Saaty, 1987) “düzenlenmiştir”

Burada belirlenen kriter ve alt kriterler, anketler yardımıyla veya uzman görüşleri alınarak yapılmaktadır (Dilekçi, 2019).

Karar vermenin en kritik aşaması, nihai sonucu büyük ölçüde belirlediği için dikkatli bir şekilde ele alınmalıdır. Bu aşamada yapılan seçimler, kararın başarısı veya başarısızlığı üzerinde doğrudan bir etkiye sahiptir (Ünal, 2011).

Hiyerarşi, tıpkı bir piramit gibi, en tepeden başlayarak amaca ulaşmayı sağlar. En üstte kararın temelini oluşturan amaç (goal) yer alır. Ardından, bu amaca ulaşmak için geniş bir bakış açısıyla belirlenen hedefler (objectives) gelir. Hedeflere ulaşmak için gerekli adımları gösteren kriterler ara seviyelerde yer alır. En alt seviyede ise her kritere göre değerlendirilecek alternatifler bulunur (Forman & Selly, 2001; T. Saaty, 2008).

Saaty'nin hiyerarşik yapı oluşturulurken, her adımdaki bileşen sayını belirlemede ortaya koyduğu 7 ± 2 kuralı, hiyerarşik yapıyı insan beyninin işleme kapasitesine uygun hale getirmeyi amaçlamaktadır. Bu sayede, karar vericiler, aşırı bilgi yükü ile karşı karşıya kalmadan, problemleri daha net bir şekilde analiz edebilir ve en uygun seçeneği yapabilirler (T. Saaty & Sagir Ozdemir, 2003).

2.7.2. İkili karşılaştırmaların oluşturulması:

AHP, temelinde ikili karşılaştırmaların olduğu bir tekniktir (Çoban & Erdin, 2020a).

İkili karşılaştırmalarda her kriter kendi grubundaki kriterlerle önem derecelerine göre puanlamaya tabi tutulur. Bu puanlama ölçeği (T. L. Saaty, 1980) tarafından önerilen 1 ile 9 arasındaki önem ölçeğine göre yapılır (Tablo 9).

Tablo 9 Saaty önem ölçeği tablosu

(T. L. Saaty, 1986) “düzenlenmiştir”

Önem derecesi	Tanım	Açıklama
1	Eşit önem	İki kriter birbirine göre eşit derecede önemlidir.
3	Orta önem	Deneyim ve kararlar bir kriteri diğerine göre biraz daha tercih eder.
5	Kuvvetli önem	Deneyim ve kararlar bir kriteri diğerine göre daha kuvvetli tercih eder.
7	Çok kuvvetli önem	Bir kriter güçlü bir şekilde tercih edilir ve üstünlüğü kanıtlanmıştır.
9	Kesin önem	Bir kriteri diğerine tercih eden kanıtlar, en yüksek onaylama derecesine sahiptir.
2, 4, 6, 8	Ara değerler	Yukarıdaki değerler arasında uzlaşma gerektiğinde kullanılır.

Burada n sayıda kriter arasında bir ikili karşılaştırma yapılacaksa, oluşturulacak A matrisinin boyutu $n \times n$ olacaktır (Tablo 10).

Tablo 10 İkili karşılaştırma matrisinin oluşturulması

Kriterler	A ₁	A ₂	...	A _n
A ₁	w ₁ / w ₁	w ₁ / w ₂	...	w ₁ / w _n
A ₂	w ₂ / w ₁	w ₂ / w ₂	...	w ₂ / w _n
⋮	⋮	⋮		⋮
A _n	w _n / w ₁	w _n / w ₂	...	w _n / w _n

Bu matristeki w_i / w_j ifadesinde anlatılmak istenen, i. kriterin j. kritere göre ne kadar önemli olduğudur. İ, j'den x kat daha önemliyse, j'de i'den $\frac{1}{x}$ kat daha önemlidir (Vargas, 1990).

2.7.3. Kriterlerin ağırlıklarının hesaplanması:

İkili karşılaştırma matrisi oluşturulduktan sonra, matrisin normalize edilmesi gerekir. Normalize etmek için, her sütunun toplamı hesaplanır ve matris elemanları kendi sütunlarının toplamına bölünerek b matrisi oluşturulur (Denklem 2.7).

$$b_{ij} = \frac{a_{ij}}{\sum_{i=1}^n a_{ij}} \quad [2.7]$$

Daha sonra, normalize edilmiş matriste her kriter için satır ortalamaları alınır. Bu ortalamalar, kriterlerin öncelik değerlerini oluşturur ve w öncelik vektör matrisini meydana getirir (Denklem 2.8).

$$w_i = \frac{\sum_{j=1}^n c_{ij}}{n} \quad [2.8]$$

Öncelik vektör matrisindeki her kriterin öncelik değeri, ilgili ikili karşılaştırma matrisinin sütun elemanlarıyla çarpılarak ağırlıklandırılmış toplam matris oluşturulur.

Ağırlıklandırılmış toplam matrisin satır toplamları, öncelik vektör matrisi satır değerlerine bölünerek $n \times 1$ boyutunda sonuç matrisi elde edilir. Son olarak, bu matrisin aritmetik ortalaması alınarak öz değer (λ_{max}) hesaplanır (Denklem 2.9) (Özyörük & Özcan, 2008).

$$\lambda_{max} = \frac{1}{n} \sum_{i=1}^n \left(\frac{\sum_{j=1}^n a_{ij} w_j}{w_i} \right) \quad [2. 9]$$

2.7.4. Duyarlılık analizi veya tutarlılıkların belirlenmesi:

Elde edilen λ_{max} değeri kriter sayısından çıkarılıp, kriter sayısının bir eksiğine bölünerek tutarlılık indeksi (Tİ) hesaplanır (Denklem 2.10).

$$TI = \frac{\lambda_{max} - n}{n - 1} \quad [2. 10]$$

Tutarlılık oranı (TO) ise tutarlılık indeksinin, rassallık indeksine (Rİ) oranıyla hesaplanır (Denklem 2.11).

$$TO = \frac{TI}{RI} \quad [2. 11]$$

Rassallık indeksi, Saaty tarafından hazırlanmış tablo yardımıyla bulunur (Tablo 11).

Tablo 11 Rassallık indeksi değerleri tablosu

(T. L. Saaty, 1980) “düzenlenmiştir”

n	1	2	3	4	5	6	7	8	9	10	11	12	13
RI	0	0	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49	1,51	1,48	1,56

Burada n kriter sayısıdır. Tutarlılık oranı 0,1'den küçükse söz konusu matris kabul edilebilir bir tutarlılıktadır aksi takdirde karşılaştırma matrisinin yeniden gözden geçirilmesi gerekir (T. L. Saaty, 1980). Tutarlılık değeri kontrol edildikten sonra elde edilen ağırlık değerleri kullanılır.



3. MATERYAL VE METOT

3.1. Çalışma Sahasına Ait Bilgiler

Çalışma sahası, Antalya'nın Manavgat ilçesinde 31°19'49" Doğu ile 31°43'33" Doğu boylamları ve 36°47'25" Kuzey ile 37°1'35" Kuzey enlemleri arasında yer almakta olup, yaklaşık 36 bin hektarlık bir alana sahiptir (Şekil 11).



Şekil 11 Çalışma bölgesi

(Esri, 2024) “düzenlenmiştir”

Manavgat ilçesi yaklaşık 228 bin hektar alanıyla Antalya'nın yüzölçümü bakımından 2. en büyük ilçesidir. Yaklaşık 253 bin nüfuslu Manavgat, Antalya şehir merkezinin doğusunda yer alır (Ak, 2019; Manavgat, 2023).

Önünde 64 km uzunluğunda sahil şeridi ve arkasında kimi yerlerde 2 bin m'ye kadar uzanan Toroslar ile Manavgat, topoğrafik olarak çoğunluğu düz olmak üzere dalgalı bir yapıya sahiptir (Dinç, 2020).

İklimsel olarak bölgeye Akdeniz iklimi hâkimdir. En soğuk günlerini ortalama 10,7 °C ile Ocak ve Şubat aylarında, en sıcak günlerini ise 28,0 °C ile Temmuz ayında yaşayan Manavgat'ta yıllık ortalama sıcaklık 18,7 °C olarak hesaplanmıştır. Yağış bakımından yine en fazla yağışı 251,3 mm ile en soğuk ay olarak ölçülen Ocak ayında, en az ise 1,7 mm ile sıcaklığın en fazla olduğu Temmuz ayında gerçekleşir. Ortalama yağış miktarı 1.117,7 mm olarak hesaplanmıştır (Manavgat OİM Yangın Yönetim Planı, 2019).

Nem bakımından; nispi nemin en düşük olduğu günler %59,7 ortalama ile Ekim ayında, en yüksek olduğu günler %68,4 ortalaması ile Nisan ayında gerçekleşir. Yıllık nispi nem ortalaması ise %63,9 olarak hesaplanmıştır (Ak, 2019).

Çalışma sahasının ormanlık alanları yüzölçümü ile kıyaslandığında Manavgat ormanlarının %56'sını (26.039 ha) oluşturmaktadır (OGM, t.y.).

Bu orman varlığı içerisinde Kızılçam, sahanın %57,8 ini kaplayarak en fazla alana sahip olan arazi örtüsüdür. Tarım alanları %20,2 ile 2. sırayı alırken %3,5 ile Maki 3. ve %3,3 ile Su alanları 4. Sıradadır (Sayısal meşcere haritaları, 2021).

1.200 metrelere kadar kızılçam görmek mümkündür. Daha yüksek rakımlarda ise karşımıza karaçam, sedir, ardıç, köknar gibi türler çıkmaktadır (Ak, 2019).

Yazın sıcaklıkların yüksek, yağışın düşük olması, topoğrafik yapı, rüzgârlar, bağıl nem ve meşcere tipinin kızılçam gibi yangına en hassas türlerden oluşması gibi sebepler Akdeniz ormanlarını yangına karşı en riskli bölgelerden birisi haline getirmektedir (Sepetçi, 2014).

3.2. Materyal

3.2.1. Veri seti:

Bu arařtırmada toplam 4 adet ana (topoğrafik, biyolojik, meteorolojik, insan) ve 13 adet alt kriter (yükseklik, bakı, eğim, arazi örtüsü, meşcere kapalılığı, gelişme çağları, sıcaklık, nem, rüzgâr şiddeti, yağış, yollara uzaklık, yerleşime uzaklık ve tarıma uzaklık) yangın risk haritalarını oluşturmak için parametre olarak kullanılmıştır. Bu parametrelerin neler olacağına, nasıl sınıflandırılacağı ve yangın risk derecelerinin ne olacağına orman yangını riskini belirleme konusunda yapılan çalışmaların literatürde kabul görmüş ve güvenilir olanlarından seçilerek karar verilmiştir (Tablo 12).

Tablo 12 Parametrelerin, sınıflarının ve risk derecelerinin seçiminde kullanılan literatür çalışmaları

Parametre	Literatür çalışması
Yükseklik	(Adab vd., 2013; Atmaca vd., 2022; Baltacı & Yıldırım, 2021; Çoban & Erdin, 2020; Eskandari, 2017; Eugenio vd., 2016; Gülçin & Deniz, 2020; Kant Sharma vd., 2012; Naderpour vd., 2019; H. reza Pourghasemi vd., 2016; Pourtaghi vd., 2015; Sari, 2021; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023; Van Hoang vd., 2020; You vd., 2017)
Bakı	(Adab vd., 2013; Akay & Erdoğan, 2017; Atmaca vd., 2022; Baltacı & Yıldırım, 2021; Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Eugenio vd., 2016; Gülçin & Deniz, 2020; Kant Sharma vd., 2012; Naderpour vd., 2019; Özenen Kavlak vd., 2020; H. reza Pourghasemi vd., 2016; Pourtaghi vd., 2015; Sari, 2021; Sivrikaya vd., 2014; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023; Van Hoang vd., 2020; You vd., 2017)
Eğim	(Adab vd., 2013; Akay & Erdoğan, 2017; Atmaca vd., 2022; Baltacı & Yıldırım, 2021; Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Eugenio vd., 2016; Gülçin & Deniz, 2020; Kant Sharma vd., 2012; Naderpour vd., 2019; Özenen Kavlak vd., 2020; H. reza Pourghasemi vd., 2016; Pourtaghi vd., 2015; Sari, 2021; Sivrikaya vd., 2014; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023; Van Hoang vd., 2020; You vd., 2017)

Tablo 12 Parametrelerin, sınıflarının ve risk derecelerinin seçiminde kullanılan literatür çalışmaları (devam)

Arazi örtüsü	(Akay & Erdoğan, 2017; Atmaca vd., 2022; Baltacı & Yıldırım, 2021; Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Kant Sharma vd., 2012; Naderpour vd., 2019; Özenen Kavlak vd., 2020; Pourtaghi vd., 2015; Sivrikaya vd., 2014; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023; Van Hoang vd., 2020)
Meşcere kapalılığı	(Akay & Erdoğan, 2017; Atmaca vd., 2022; Baltacı & Yıldırım, 2021; Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Kant Sharma vd., 2012; Naderpour vd., 2019; Özenen Kavlak vd., 2020; Sari, 2021; Sivrikaya vd., 2014; Sivrikaya & Küçük, 2022)
Gelişme çağları	(Akay & Erdoğan, 2017; Atmaca vd., 2022; Baltacı & Yıldırım, 2021; Çoban & Erdin, 2020; Sivrikaya vd., 2014; Sivrikaya & Küçük, 2022; You vd., 2017)
Sıcaklık	(Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Eugenio vd., 2016; Naderpour vd., 2019; H. reza Pourghasemi vd., 2016; Pourtaghi vd., 2015; Sari, 2021; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023; You vd., 2017)
Nem	(Eskandari, 2017; Naderpour vd., 2019; Sari, 2021; Tezcan & Eren, 2023; Van Hoang vd., 2020)
Rüzgâr şiddeti	(Eskandari, 2017; Naderpour vd., 2019; H. reza Pourghasemi vd., 2016; Pourtaghi vd., 2015; Sari, 2021; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023)
Yağış	(Eskandari, 2017; Eugenio vd., 2016; Naderpour vd., 2019; Pourtaghi vd., 2015; Sivrikaya & Küçük, 2022)
Yollara uzaklık	(Adab vd., 2013; Atmaca vd., 2022; Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Eugenio vd., 2016; Gülçin & Deniz, 2020; Kant Sharma vd., 2012; Naderpour vd., 2019; Özenen Kavlak vd., 2020; Pourtaghi vd., 2015; Sivrikaya vd., 2014; Sivrikaya & Küçük, 2022; Van Hoang vd., 2020; You vd., 2017)
Yerleşime uzaklık	(Adab vd., 2013; Atmaca vd., 2022; Çoban & Erdin, 2020; Çolak & Sunar, 2020; Eskandari, 2017; Gülçin & Deniz, 2020; Kant Sharma vd., 2012; Özenen Kavlak vd., 2020; Pourtaghi vd., 2015; Sivrikaya & Küçük, 2022; Tezcan & Eren, 2023; Van Hoang vd., 2020; You vd., 2017)
Tarıma uzaklık	(Atmaca vd., 2022; Çoban & Erdin, 2020; Eskandari, 2017; Kant Sharma vd., 2012; Sivrikaya & Küçük, 2022; You vd., 2017)

Çalışma için kullanılacak veriler seçildikten sonra topoğrafik verileri üretmek amacıyla ilk olarak Ulusal Havacılık ve Uzay Dairesi'nin (National Aeronautics and Space Administration, NASA) çeşitli uydu görüntüleri sağladığı ("Earth data search",

t.y.) internet sitesinden, TERRA uydusuna ait Gelişmiş Uzay Kaynaklı Termal Emisyon ve Yansıma Radyometresi (Advanced Spaceborne Thermal Emission and Reflection Radiometer, ASTER) modülünün 30 metre çözünürlüklü sayısal yükseklik modeli (SYM) verisi indirilmiştir. Bu modelden yükseklik, eğim ve bakı verileri oluşturulmuştur.

Biyolojik veriler; arazi örtüsü, meşcere kapalılığı ve gelişme çağları, Manavgat Orman İşletme Müdürlüğü'nün (OİM) 2021 yılına ait güncel sayısal meşcere haritalarından elde edilmiştir.

İnsan faktörlü veriler yani yollar, yerleşim yerleri ve tarım arazileri de yine sayısal meşcere haritalardan sınıflandırılarak üretilmiştir.

Meteorolojik veriler ise (sıcaklık, nem, rüzgâr şiddeti ve yağış) Meteoroloji Genel Müdürlüğü'nden (MGM) tamamı 2012 ve 2022 yılları arasındaki aylık veri ortalamaları olacak şekilde temin edilmiştir.


Çalışmada kullanılan verilere ait genel bilgiler Tablo 13'de gösterilmektedir.

Tablo 13 Veri seti

Veri	Veri Tipi	Detay	Kaynak
SYM	Raster	Yükseklik, Bakı, Eğim verilerini üretmek amacıyla	NASA Earth Data
Arazi Örtüsü	Poligon	Bölgeye ait ağaç türleri ve diğer doğal alanlar	Manavgat OİM
Meşcere kapalılığı	Poligon	Ağaç tepelerinin yeri örtme derecesi	Manavgat OİM
Gelişme çağları	Poligon	Ağaç gövde kalınlıklarına göre yapılan sınıflandırma	Manavgat OİM
Yollar	Çizgi	Bölgeye ait her türlü stabilize, asfalt ve otoyol	Manavgat OİM
Yerleşim Yerleri	Poligon	Bölgede bulunan sivil yaşam yerleri	Manavgat OİM
Tarım Arazileri	Poligon	Üzerinde faal olarak tarım faaliyetleri yapılan yerler	Manavgat OİM
Yangın Sicil Fişi	Nokta	Geçmiş yangın bilgilerinin yer aldığı tutanak	Manavgat OİM
Sıcaklık	Nokta	Geçmiş 11 yılın aylık ortalama sıcaklık bilgileri	MGM
Nem	Nokta	Geçmiş 11 yılın aylık ortalama nem bilgileri	MGM
Rüzgâr Şiddeti	Nokta	Geçmiş 11 yılın aylık ortalama rüzgâr şiddeti bilgileri	MGM
Yağış	Nokta	Geçmiş 11 yılın aylık ortalama yağış bilgileri	MGM

3.2.2. Tarihsel yangın verileri:

Elde edilecek haritaları geçmiş yangın verileriyle kıyaslamak ve çalışmayı doğrulamak amacıyla Manavgat bölgesine ait 2015’den 2023’e kadar çıkan yangınların kayıt edildiği yangın sicil fişleri Manavgat OİM’den alınmıştır. Geçmiş yangın verilerinden çalışma bölgesinde kalan toplam 117 yangın verisi bulunmaktadır (Şekil 12).



Şekil 12 Tarihsel yangın verileri

3.3. Metot

Çalışmanın iş akış şeması Şekil 13’de gösterilmiştir.

Bkz. EK-1

Şekil 13 İş akış şeması

3.3.1. Parametreler:

Bu çalışmada yapılan tüm coğrafi işlemler ArcMap 10.7 yazılımı vasıtasıyla gerçekleştirilmiştir. Çalışma sahasına bir sınır belirlenmiştir ve verilerin tamamı bu sınıra göre kesilmiştir.

Topoğrafik veriler, TERRA uydusunun 30 metre mekânsal çözünürlüğe sahip sayısal yükseklik modeli verilerinden eğim ve bakı analizi yapılarak üretilmiştir.

Biyolojik veriler, OGM’nin sayısal verilerinden filtreleme, yeniden sınıflandırma ve eleme yapılarak alınmış, raster formata dönüştürülerek kullanılmıştır.

İnsan faktörlü veriler, Öklid mesafesi (Euclidean Distance) analizi ile tampon bölgeler dikkate alınıp, sınıflara göre uzaklıklar belirlenerek oluşturulmuştur.

Meteorolojik veriler, meteoroloji istasyonlarının noktasal verilerinde oluşmaktadır. Bu yüzden ters mesafe ağırlıklı (Inverse Distance Weighted, IDW) enterpolasyon yöntemiyle tüm sahaya enterpole edilmiştir. Aynı zamanda meteorolojik veriler aylık ortalamalardan oluştuğu için bunların mevsimsel bazda ortalamaları alınarak sürece mevsimsel ortalamalar şeklinde dâhil edilmiştir. Meteorolojik verilerin haritaları oluşturulurken yangınların en sık ve riskin en yüksek olduğu yaz ayları seçilmiştir. Bu nedenle haritalar, oluşturulan sınıfların tamamını içermeyip 1 veya 2 risk sınıfıyla sınırlı kalmış ve sadece bu sınıflarda oluşmuştur. Bu veriler bireysel anlamda etkili olmasa da sonuç haritalarının belirlenmesinde ağırlıkları ile belirleyici olmuşlardır.

Yangın başlatmada risk teşkil eden kriterler belirlendikten sonra kriterlerin her biri yangın oluşumuna aynı derecede etki etmeyeceği için 4 ana kriter ile 13 adet alt kritere ağırlıkların belirlenmesi gerekmektedir. Bunun için hem literatürde yapılan çalışmalarda kullanılan değerler hem de Analitik Hiyerarşi Prosesi (AHP) kullanılmıştır.

3.3.2. Literatür:

Ağırlıkların belirlenebilmesi için orman yangını riskini haritalama konusunda literatürde kabul görmüş 24 adet çalışma incelenmiştir. Çalışmaların her bir parametreye verdikleri ağırlıklar tablo halinde toplanmıştır (Tablo 14).

Tablo 14 Literatürdeki çalışmaların parametrelere verdikleri ağırlık değerleri

Kaynakça	Y ¹	B ²	E ³	AT ⁴	AK ⁵	GÇ ⁶	S ⁷	N ⁸	RS ⁹	Ya ¹⁰	YU ¹¹	YeU ¹²	TU ¹³
Eugenio vd., 2016	2,34	3,20	13,47	6,59			26,98			37,97	9,45		
Nikhil vd., 2021		19,05	27,38	39,29							5,95	8,33	
Çolak & Sunar, 2020		9,68	16,13	32,26	16,13		19,35				3,23	3,23	
Sivrikaya vd., 2014		7,14	11,90	23,81	23,81	23,81					4,76	2,38	2,38
Çoban & Erdin, 2020	5,78	2,46	1,01	17,30	2,69	7,94	4,87		1,07	1,87	38,30	11,68	5,04
Sari, 2021	10,61	7,58	12,12	12,12	12,12		10,61	6,06	4,55	9,09	6,06	9,09	
Kant Sharma vd., 2012	8,33	25,00	16,67	33,33							8,33	8,33	
You vd., 2017	10,45	4,54	1,97	16,31	6,14	1,75	7,41			2,46	22,58	4,96	21,41
Akay & Erdoğan, 2017		12,87	18,81	27,72	18,81	21,78							
Sivrikaya & Küçük, 2022	3,27	10,67	8,75	20,61	7,91	9,05	5,74		3,40	2,16	11,09	9,76	7,59
Adab vd., 2013		21,74	21,74	30,43							13,04	13,04	
Nuthammachot & Stratoulis, 2021	15,00	7,50	11,25	21,25						35,00		10,00	
Garcia Strino vd., 2007		21,74	21,74	30,43							13,04	13,04	
Gülçin & Deniz, 2020	10,26	17,95	20,51	23,08							15,38	12,82	
Zelege, 2019	1,53	6,91	2,65	29,59	14,80		19,02		9,12		6,86	9,51	
Özenen Kavlak vd., 2020		16,67	16,67	8,89	6,67	6,67					22,22	22,22	
Karabulut vd., 2013		21,74	21,74	30,43							13,04	13,04	
Baltacı & Yıldırım, 2021	11,70	11,70	11,70	16,37	16,37	16,37					5,26	5,26	5,26
Erten vd., 2005		21,74	21,74	30,43							13,04	13,04	
Eskandari, 2017	5,76	8,08	6,65	6,06	5,81		7,80	7,00	7,97	6,63	14,28	12,34	11,61
Bozdağ vd., 2016	1,87	9,39	5,62	35,68						47,44			
Jaiswal vd., 2002			17,65	58,82							11,76	11,76	
Atmaca vd., 2022	0,10	48,82	2,46		28,90	19,69					0,01	0,01	0,02
Tezcan & Eren, 2023	2,67	12,10	2,38	19,63			5,48	35,16	16,13			6,44	

1: Yükseklik, 2: Bakı, 3: Eğim, 4: Ağaç türleri, 5: Ağaç kapallılığı, 6: Gelişme çağları, 7: Sıcaklık, 8: Nem, 9: Rüzgâr Şiddeti, 10: Yağış, 11: Yollara uzaklık, 12: Yerleşime uzaklık, 13: Tarıma uzaklık

Her çalışmanın yaptığı ağırlıklandırma sonucu farklı olduğundan, diğer çalışmalarla kıyaslayabilmek ve tek bir ortak payda da toplayabilmek için her bir çalışmanın kendi içinde kullandığı etmenlerin ağırlıklarının toplamı 100 olacak şekilde hesaplanmış ve o haliyle ele alınmıştır. Başka bir deyişle her çalışmanın hangi parametreye yüzde kaç ağırlık verdiği hesaplanmıştır. Daha sonra her parametrenin kendi içinde ortalaması alınmış ve yine yüzde karşılıkları bulunmuştur (Tablo 15).

Tablo 15 Literatür araştırması sonucu elde edilen nihai ağırlıklar

Ana kriterler	Ağırlık w_a	Alt kriterler	Ağırlık w_b	Genel ağırlık w_g $= w_a \times w_b$	Yüzde ağırlık $\frac{w_{gi}}{\sum_{i=1}^n w_g}$
Topoğrafik	0,20	Bakı	0,42	0,09	8,54
		Eğim	0,39	0,08	7,80
		Yükseklik	0,19	0,04	3,83
Biyolojik	0,31	Meşcere kapalılığı	0,26	0,08	7,99
		Arazi örtüsü	0,48	0,15	14,84
		Gelişme çağları	0,26	0,08	8,01
Meteorolojik	0,32	Nem	0,30	0,10	9,62
		Rüzgâr şiddeti	0,13	0,04	4,21
		Sıcaklık	0,23	0,07	7,13
		Yağış	0,34	0,11	10,67
İnsan	0,17	Tarım uzaklık	0,26	0,05	4,56
		Yerleşime uzaklık	0,33	0,06	5,71
		Yollara uzaklık	0,41	0,07	7,11

Literatür taraması sonucu elde edilen bulgular ile orman yangını riskinin hesaplanması ise Denklem 3.1’de gösterilmektedir.

$$\begin{aligned}
 \text{Risk} = & 8,54 \times \text{Bakı} + 7,80 \times \text{Eğim} + 3,83 \times \text{Yükseklik} + \\
 & 7,99 \times \text{Meşcere kapalılığı} + 14,84 \times \text{Ağaç türleri} + 8,01 \times \text{Gelişme çağları} + \\
 & 9,62 \times \text{Nem} + 4,21 \times \text{Rüzgar şiddeti} + 7,13 \times \text{Sıcaklık} + 10,67 \times \text{Yağış} + \\
 & 4,56 \times \text{Tarım uzaklık} + 5,71 \times \text{Yerleşime uzaklık} + 7,11 \times \text{Yollara uzaklık} \quad [3. 1]
 \end{aligned}$$

3.3.3. Analitik hiyerarşi prosesi:

Thomas Saaty tarafından geliştirilen AHP, karmaşık karar verme problemlerini hiyerarşik bir yapıya indirgeyerek ve her bir kriterin önemini sistematik bir şekilde değerlendirerek çözüm sunar. Bu yöntem, ağırlıkların belirlenmesinde de oldukça iyi sonuçlar vermektedir, zira her bir kriterin karar vericinin genel hedefine göre ne kadar önemli olduğunu nitelendirmeye imkân tanır. Hiyerarşik yapı oluşturulurken karar vericilerin cevapları esas alınmıştır. Karar vericiler, orman yangınları konusunda uzman kişilerden oluşmaktadır. Önce 4 ana kriterin kendi aralarında ikili karşılaştırma matrisleri oluşturulmuştur (Tablo 16).

Tablo 16 Ana kriterlerin ikili karşılaştırma matrisi

Kriterler	Biyolojik	İnsan	Meteorolojik	Topoğrafik
Biyolojik	1,00	1,00	3,00	3,00
İnsan	1,00	1,00	2,00	5,00
Meteorolojik	1/3	1/2	1,00	4,00
Topoğrafik	1/3	1/5	1/4	1,00
Toplam:	2,67	2,70	6,25	13,00
CR: 0,062				

Daha sonra her ana kriterin alt kriteri kendi aralarında ikili karşılaştırmalar yapılarak ağırlıkları belirlenmiştir. Biyolojik kriterler için (Tablo 17),

Tablo 17 Biyolojik kriterlerin ikili karşılaştırma matrisi

Kriterler	Ağaç Türleri	Gelişme Çağları	Meşcere Kapalılığı
Ağaç Türleri	1,00	2,00	3,00
Gelişme Çağları	1/2	1,00	2,00
Meşcere Kapalılığı	1/3	1/2	1,00
Toplam:	1,83	3,50	6,00
CR: 0,008			

İnsan kriterleri için (Tablo 18),

Tablo 18 İnsan kriterlerinin ikili karşılaştırma matrisi

Kriterler	Yollara Uzaklık	Yerleşime Uzaklık	Tarım Alanlarına Uzaklık
Yollara Uzaklık	1,00	2,00	2,00
Yerleşime Uzaklık	1/2	1,00	2,00
Tarım Alanlarına Uzaklık	1/2	1/2	1,00
Toplam:	2,00	3,50	5,00
CR: 0,046			

Meteorolojik kriterler için (Tablo 19),

Tablo 19 Meteorolojik kriterlerin ikili karşılaştırma matrisi

Kriterler	Sıcaklık	Rüzgâr Şiddeti	Yağış	Nem
Sıcaklık	1,00	2,00	1,00	4,00
Rüzgâr Şiddeti	1/2	1,00	2,00	2,00
Yağış	1	1/2	1,00	1,00
Nem	1/4	1/2	1	1,00
Toplam:	2,75	4,00	5,00	8,00
CR: 0,092				

Topoğrafik kriterler için (Tablo 20).

Tablo 20 Topoğrafik kriterlerin ikili karşılaştırma matrisi

Kriterler	Bakı	Eğim	Yükseklik
Bakı	1,00	2,00	4,00
Eğim	1/2	1,00	4,00
Yükseklik	1/4	1/4	1,00
Toplam:	1,75	3,25	9,00
CR: 0,046			

Belirlenen ağırlıkların tutarlılık oranları (CR), 0,1'den küçük çıkmıştır. Bu da elde edilen sonuçların kabul edilebilir bir sınır içerisinde ve tutarlı olduklarını göstermiştir. AHP ile elde edilen sonuçlar Tablo 21'de gösterilmektedir.

Tablo 21 AHP sonucu elde edilen nihai ağırlıklar

Ana kriterler	Ağırlık w_a	Alt kriterler	Ağırlık w_b	Genel ağırlık w_g $= w_a \times w_b$	Yüzde ağırlık $\frac{w_{gi}}{\sum_{i=1}^n w_g}$
Topoğrafik	0,08	Bakı	0,55	0,04	4,21
		Eğim	0,34	0,03	2,65
		Yükseklik	0,11	0,01	0,83
Biyolojik	0,37	Meşcere kapalılığı	0,16	0,06	6,04
		Arazi örtüsü	0,54	0,20	19,95
		Gelişme çağları	0,30	0,11	10,98
Meteorolojik	0,19	Nem	0,13	0,03	2,59
		Rüzgâr şiddeti	0,27	0,05	5,19
		Sıcaklık	0,39	0,08	7,59
		Yağış	0,20	0,04	3,93
İnsan	0,36	Tarıma uzaklık	0,20	0,07	7,05
		Yerleşime uzaklık	0,31	0,11	11,20
		Yollara uzaklık	0,49	0,18	17,78

AHP yöntemiyle elde edilen bulgular ile orman yangını riskinin hesaplanması ise Denklem 3.2’de gösterilmektedir.


$$\begin{aligned}
 \text{Risk} = & 4,21 \times \text{Bakı} + 2,65 \times \text{Eğim} + 0,83 \times \text{Yükseklik} + \\
 & 6,04 \times \text{Meşcere kapalılığı} + 19,95 \times \text{Ağaç türleri} + 10,98 \times \text{Gelişme çağları} + \\
 & 2,59 \times \text{Nem} + 5,19 \times \text{Rüzgar şiddeti} + 7,59 \times \text{Sıcaklık} + 3,93 \times \text{Yağış} + \\
 & 7,05 \times \text{Tarıma uzaklık} + 11,20 \times \text{Yerleşime uzaklık} + 17,78 \times \text{Yollara uzaklık} \quad [3. 2]
 \end{aligned}$$

3.3.4. Coğrafi bilgi sistemleri:

CBS ortamına aktarılan verilerin etkin bir şekilde kullanılabilmesi ve çeşitli arazi, iklim ve bitki örtüsü koşullarında özelleştirilebilmesi amacıyla bir model geliştirilmiştir (Şekil 14). Bu model, veriler arasındaki ilişkilerin daha rahat bir şekilde belirlenebilmesi ve analiz edilebilmesini sağlamak için tasarlanmıştır.

Şekil 14 CBS ortamında kurulan modelin arka planı

Model içerisindeki temel içerik zinciri Şekil 15’de görselleştirilmiştir.



Şekil 15 Model içerisindeki semboller

Girdi öğeleri, verilerin yollarını ve diğer özelliklerini depolar. Şekil dosyaları, vektör ve raster bütün veriler girdi öğesini oluşturur.

Bağlayıcılar, verileri ve değerleri araçlara bağlar. Bağlantı okları, işlemin yönünü gösterir.

Türetilmiş değerler, araçların içerisinde bulunan bazı girdi değerlerini aracın dışında görüntülemek, daha erişilebilir hale getirerek gerektiğinde değiştirmek içindir kullanışlıdır.

Coğrafi işlem araçları, modelin temel taşlarıdır. Bu araçlar, coğrafi veya tablosal veriler üzerinde çeşitli işlemler yapabilen öğelerdir.

Çıktı verileri, araçlar tarafından oluşturulmuş yeni verilerdir (ModelBuilder Vocabulary, 2023; U. Şahin, 2019).

Girdi verileri; çalışmada kullanılan 13 adet veri seti, çalışmayı doğrulamak için kullanılan geçmiş orman yangını verileri ve çalışma alanı sınırıdır. Bu veriler model içerisinde; IDW, Euclidean distance, slope, aspect, reclassify, feature to raster, raster to polygon, clip, dissolve, add field, spatial join, calculate field, table to table, weighted

overlay gibi çok farklı, toplamda 122 adet olmak üzere çeşitli coğrafi işlemde sonra ağırlıklı çakıştırma aracına girdi olacak hale getirilmiştir. Ağırlıklı çakıştırma aracına 13 adet veri seti raster formatta girdi olarak eklenmiştir. Burada literatürden ve AHP’den elde edilen farklı ağırlık değerleri için aynı veri setleri her 2 ağırlık değeri için 2 farklı ağırlıklı çakıştırma aracına girdi olmuştur. Araçların içerisinde 13 adet alt kritere ve bunların sınıflarına ağırlıklar girilmiştir (Tablo 22).


Tablo 22 Genel ağırlıklar tablosu

Bkz. EK-3

Girilen ağırlıklara göre model çalıştırılmış ve raster formatında, 5 sınıflı, 2 çıktı verisi üretilmiştir.

Model, çalışmanın arka planıdır ve işlemlerin gerçekleştiği kısımdır. Coğrafi işlemlerin otomatik ve hızlı bir şekilde gerçekleştirilmesi, herkesin kolaylıkla kullanabileceği bir arayüzün eklenmesiyle desteklenmiştir. Kullanıcı dostu arayüz, coğrafi verilerin sisteme entegrasyonunu ve özelleştirilmesini sağlamakla kalmayıp aynı zamanda sonuç haritalarının üretimini de basitleştirmiştir. Arayüz, kullanıcıların karmaşık coğrafi ilişkiler kurmadan, yalnızca girdi verilerini arayüze ekleyerek de sonuç haritaları oluşturmaya olanak tanır. Bu sayede, CBS teknolojisinin herkesçe erişilebilir geniş bir kullanıcı kitlesi tarafından etkin bir şekilde kullanılması ve çeşitli uygulama alanlarında da verimli ve doğru kararların alınması amaçlanmıştır.

Bu çalışmanın bütün girdi verileri arayüz yardımıyla eklenir, çalıştırılır ve çıktıları alınır. Model arayüzü Şekil 16’da gösterilmektedir.



Şekil 16 Model arayüzü

Arayüze bakıldığında, çalışma alanının sınır verisini isteğe bağlı olarak ekleyip eklemeyeceğiniz sorulmaktadır. Altında ise geçmiş yangınlara ait yangın konumları verilerini eklemeniz gerekir. Sayısal yükseklik modelini, eğim, bakı ve yükseklik haritalarını oluşturmak için eklemeniz gerekir. Sonrasında sıcaklık, nem, rüzgâr hızı ve yağış verilerini eklemeniz ardından risk haritasını hangi periyotlarda (aylık ortalamalar, mevsimsel ortalamalar ve yıllık ortalama) oluşturacağınız sorulur. Bu çalışmada yangınların en çok çıktığı yaz aylarının (haziran, temmuz, ağustos) ortalaması kullanılmıştır ancak bu seçenek arayüzden değiştirilerek örneğin yıllık bazda risk haritaları da oluşturulabilir. Yollar, yerleşim yerleri, tarım alanları, gelişme

çağları, meşcere kapalılığı ve meşcere verilerini eklemeniz gerekmektedir. Son olarak sonuç haritasını geçmiş yangın konumları ile doğrulama yaptıktan sonra çıktılarının yazılı olarak kayıt edileceği konumu seçmenizi ister. Arayüzün sağ tarafında kullanıcılara, her bir seçim için ne yapması gerektiğin detaylı olarak anlatıldığı bir Yardım kısmı bulunur. Tüm veriler eklendikten sonra Tamam butonuna basarak süreç başlatılır ve bittiğinde tüm çıktılar ekrana otomatik basılır. Burada her iki yöntemle (AHP ve literatür araştırması) elde edilen ağırlıklı veriler karşılaştırılarak 2 ayrı yangın risk haritası üretilmiştir.

Üretilen her 2 yangın riski haritasının birbirlerinden sınıfsal ve bu sınıfların alansal olarak farkını ortaya koymak için risk haritalarının geometrik kesişimleri hesaplanmıştır.

Yangın risk haritalarının gerçek verilerle doğrulanması için geçmişte meydana gelen yangınların konumları verileri kullanılmıştır. Bu veriler, oluşturulan yangın risk haritasıyla karşılaştırılarak, geçmiş yangınların hangi bölgelere denk geldiği ve bu bölgelerin yüzdelik risk değerleri belirlenmiştir.

Son olarak 2021 yılı yangınlarındaki hasarı göz önüne sermek için yangın öncesi ve sonrası uydu görüntüleri edinilmiş ve bunlara Normalize Edilmiş Fark Bitki İndeksi (NVDI) analizi yapılarak çalışma sahasının bitki örtüsünde meydana gelen hasarın boyutları değerlendirilmiştir.

NDVI değerleri -1 ve 1 arasında değişmektedir. Su alanları için genelde negatif değerler, kaya, kum gibi yüzeyler için sıfıra yakın değerler ve ekinler, çalılar, otluk alanlar ve ormanlar için pozitif değerler alır. Değer 1'e yaklaştıkça bitki örtüsü yeşilliği ve yoğunluğu artıyor demektir (Jones & Vaughan, 2010).

3.3.5. Makine öğrenmesi:

Makine öğrenmesinde en önemli aşama veri setini oluşturma aşamasıdır. CBS ile oluşturulan yangın risk haritalarını istatistiksel olarak da test etmek ve doğrulamak amacıyla 13 özniteliğe sahip 3000 örneklemden oluşan bir veri seti hazırlanmıştır (Tablo 23).

Tablo 23 Makine öğrenmesi için hazırlanan veri setinden alınan rastgele 10 örneklem

cikti	Y	B	E	AT	AK	GÇ	S	N	RŞ	Ya	YU	YeU	TU
cok_dusuk	1600	360	25	38	0	4	10	75	1	130	250	900	1000
cok_dusuk	1700	315	15	163	2	4	10	60	0	150	500	1200	2200
dusuk	1600	315	20	163	0	2	30	70	4	160	400	2400	1000
dusuk	200	255	30	206	0	4	5	70	2	130	250	1200	500
normal	200	360	35	8	0	2	20	70	0	100	100	1200	1200
normal	1500	165	15	149	1	3	10	60	1	30	0	1000	1800
yuksek	300	0	35	1	2	4	0	20	2	15	50	300	1800
yuksek	200	285	0	53	3	3	35	40	0	0	400	750	0
cok_yuksek	200	195	2	2	2	2	15	50	4	30	0	900	400
cok_yuksek	700	135	50	2	3	2	20	60	3	80	300	1000	600

Veri seti hazırlanırken literatür araştırmasında elde edilen ağırlıklar kullanılmıştır. Çok yüksek sınıfına 5 ve çok düşük sınıfına 1 verilmek suretiyle bir puanlama sistemi uygulanmıştır. Bu değerler, her bir kritere verilen ağırlık değerleri ile çarpılmış ve her kriterin alt sınıfları için yeni ağırlık katsayıları elde edilmiştir. Bu katsayılar toplamda 13 kriterin 5 risk derecesi için de ayrı ayrı toplanarak puantaj oluşturulmuştur. Bu puantajlar baz alınarak veri seti hazırlanmıştır ve makine öğrenmesi algoritmalarında kullanılmak üzere %80'i eğitim ve %20'si test için ayrılmıştır.

Bu çalışmada orman yangın riskini sınıflandırmak için makine öğrenmesi algoritmalarından; Destek Vektör Makineleri (SVM), K-En Yakın Komşu (KNN), Karar Ağaçları (DT), Naïve Bayes (NB), Doğrusal Diskriminant Analizi (LDA) ve Yapay Sinir Ağı (NN) sınıflandırma yöntemleri kullanılmıştır. Makine öğrenmesi algoritmaları Matlab R2021a sürümü üzerinde "Classification Learner Toolbox" kullanılarak veri seti üzerinde uygulanmıştır.

4. SONUÇLAR


Bu çalışma; Türkiye’de orman yangını riskinin en yüksek olduğu bölgelerden biri olan Antalya’nın Manavgat ilçesinde, yaklaşık 36 bin hektarlık bir alanda gerçekleştirilmiştir. Sahanın yaklaşık %72’sini (26.039 ha.) Ormanlar, %20’sini (7.308 ha.) Tarım alanları, %4’ünü (1.266 ha.) Yapay ve yarı doğal alanlar, %3’ünü (1.175 ha.) Su ve %1’ini (332 ha.) Yerleşim yerleri oluşturmaktadır. Ormanların ise %81’den fazlası Kızılçam ve Karaçam gibi yangına çok duyarlı ağaçlardan oluşur.

2021 yılında bölgede çıkan yangınlar tarihteki en büyük yangınlardan birisidir ve 10 günde toplam 60 bin hektar yanmıştır. Çalışma sahasının yarısından fazlası ise yine bu yangınlarda yanan alan içerisindedir. Yanan alanları ve hasarı göstermek için yangın öncesi ve sonrası uydu görüntülerine yapılan kontrollü sınıflandırma sonucu Tablo 24’de gösterilmektedir.


Tablo 24 2021 yangını sonrasında çalışma sahasındaki değişim

Sınıflar	Yangın Öncesi Alan (ha.)	Yangın Sonrası Alan (ha.)	Yangın Öncesi Yüzde Alan	Yangın Sonrası Yüzde Alan	Yüzde Değişim
Yeşil Alan	26.039	10.041	72%	28%	-44%
Su	1.175	1.168	3%	3%	0%
Tarım Alanı	7.308	4.609	20%	13%	-7%
Diğer Alanlar	1.598	1.515	4%	4%	0%
Yanan Alan	0	18.787	0%	52%	52%

Uydu görüntülerine yapılan NDVI analizi sonucu, yangın öncesi görüntüsünde sahanın genel NDVI değerinin 0,49’larda olduğu ve yangın sonrası görüntüsünde ise değer 0,20’ye kadar düşerek azaldığı görülmüştür. Bu sonuçlar NDVI analizi sonucu üretilen haritalarda da açıkça görülmektedir (Şekil 17, Şekil 18).



Şekil 17 Yangın öncesi NDVI sınıflandırması



Şekil 18 Yangın sonrası NDVI sınıflandırması

Çalışmada, 13 farklı faktör -yükseklik, eğim, bakı, arazi örtüsü, meşcere kapallılığı, gelişme çağları, sıcaklık, nem, rüzgâr şiddeti, yağış, yola uzaklık, yerleşime uzaklık ve tarıma uzaklık- analiz edilmiştir. Bu faktörlerin analizinde AHP ve CBS tekniklerinden faydalanılmıştır. Doğrulamasında ise makine öğrenmesi algoritmaları kullanılmıştır. Elde edilen bulgular temel alınarak, yangın riski bilgi sistemi için bir model tasarlanmış ve 2 farklı sonuca sahip 2 yangın risk haritası oluşturulmuştur. Üretilen haritalar; çok düşük, düşük, normal, yüksek ve çok yüksek olmak üzere beş risk sınıfında değerlendirilmiştir. Kurulan model ise kullanım kolaylığı ve hızlı işlem üstünlüğü bakımından arayüzle desteklenmiştir.

Çalışmada kullanılan 13 kriterin her biri tek tek ele alınmış ve kriterlerin sınıflarındaki çıkan yangın sayıları, sınıfların arazide kapladıkları alanlar, yangın sayısı ve alanlarına göre sınıfların risk teşkil etme yüzdeleri ve kriterlerin risk haritaları oluşturulmuştur.

4.1. Sınıflandırma Sonuçları

4.1.1. Yükseklik:

En fazla yangının çıktığı (87 adet) 500 metreden daha alçak yerlerde yangın oranı sahanın tamamına kıyasla %74,4 iken, alanına oranı %35'tir. Yüksekliğin 1.000 ile 1.500 metre arasında olduğu yerler ise sahanın yalnızca %8,9'unu kaplamasına rağmen yangınların %12,8'i (15 adet) bu sınıfta çıkmıştır ve oranı %46 ile en yüksek sınıf olmuştur. (Tablo 25).


Tablo 25 Yükseklik kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Yükseklik	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<500	87	74,4%	24.572	68,0%	35%

Tablo 25 Yükseklik kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları
(devam)

500-1.000	15	12,8%	8.046	22,3%	19%
1.000-1.500	15	12,8%	3.221	8,9%	46%
1.500>	0	0,0%	281	0,8%	0%

Yükseklik kriterine ait oluşturulan risk haritası Şekil 19’da gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 19 Yükseklik sınıflarının risk haritası


4.1.2. Bakı:

En fazla yangının çıktığı (25 adet) 225 ile 270 derece (güneybatı) bakılar arasında yangın oranı sahanın tamamına kıyasla %21,4 iken, alanına oranı %14’tür. Bakının 45 ile 90 derece (kuzeydoğu) arasında olduğu yerler ise sahanın yalnızca %9,7’sini kaplamasına rağmen yangınların %11,1’i (13 adet) bu sınıfta çıkmıştır ve oranı %15 ile en yüksek sınıf olmuştur. (Tablo 26).

Tablo 26 Bakı kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Bakı	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
0-45	11	9,4%	3.012	8,3%	14%
45-90	13	11,1%	3.491	9,7%	15%
90-135	17	14,5%	4.634	12,8%	14%
135-180	15	12,8%	5.012	13,9%	12%
180-225	21	17,9%	6.883	19,1%	12%
225-270	25	21,4%	6.925	19,2%	14%
270-315	10	8,5%	4.060	11,2%	10%
315-360	5	4,3%	2.103	5,8%	9%

Bakı kriterine ait oluşturulan risk haritası Şekil 20’de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 20 Bakı sınıflarının risk haritası


4.1.3. Eğim:

En fazla yangının çıktığı (62 adet) 10 ile 25 derece eğimler arasında yangın oranı sahanın tamamına kıyasla %53,0 iken, alanına oranı %20'dir. Eğimin 5 dereceden az olduğu yerler ise sahanın yalnızca %10,5'ini kaplamasına rağmen yangınların %13,7'si (16 adet) bu sınıfta çıkmıştır ve oranı %26 ile en yüksek sınıf olmuştur. (Tablo 27).

Tablo 27 Eğim kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Eğim	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<5	16	13,7%	3.793	10,5%	26%
5-10	28	23,9%	7.393	20,5%	24%
10-25	62	53,0%	19.518	54,0%	20%
25-35	8	6,8%	4.346	12,0%	11%
35-50	3	2,6%	977	2,7%	19%
50>	0	0,0%	94	0,3%	0,00%

Eğim kriterine ait oluşturulan risk haritası Şekil 21'de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 21 Eğim sınıflarının risk haritası

4.1.4. Arazi örtüsü:

En fazla yangının çıktığı (77 adet) Kızılçam meşceresinde yangın oranı sahanın tamamına kıyasla %65,8 iken, alanına oranı %7'dir. Örtü tipinin Karaçam olduğu yerler ise sahanın yalnızca %0,3'ünü kaplamasına rağmen yangınların %1,7'si (2 adet) bu sınıfta çıkmıştır ve oranı %30 ile en yüksek sınıf olmuştur. (Tablo 28).


Tablo 28 Arazi örtüsü kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Arazi Örtüsü	Yangın adedi	Yangın Oranı	Arazide Kapladiğ ı Alan (ha)	Arazide Kapladiğ ı Alan Oranı	Yangın Adedi/Arazid e Kapladığı Alan Oranı
Kızılçam	77	65,8%	20.893	57,8%	7%
Ziraat	21	17,9%	7.308	20,2%	5%
İskân	0	0,0%	332	0,9%	0%
Orman toprağı	8	6,8%	956	2,6%	15%

Tablo 28 Arazi örtüsü kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları (devam)

Su	0	0,0%	1.175	3,3%	0%
Ocak	0	0,0%	3	0,0%	0%
Elektrik Hattı	0	0,0%	60	0,2%	0%
Saçlı meşe	0	0,0%	75	0,2%	0%
Ardıç	1	0,9%	1.074	3,0%	2%
Maki	1	0,9%	1.263	3,5%	1%
İzin verilmiş alanlar	0	0,0%	14	0,0%	0%
Mezarlıklar	0	0,0%	15	0,0%	0%
Kum	0	0,0%	43	0,1%	0%
Fıstık çamı	0	0,0%	8	0,0%	0%
Kızılçam ve Harnup	0	0,0%	149	0,4%	0%
Kızılçam ve Defne	2	1,7%	280	0,8%	13%
Kızılçam ve Saçlı meşe	1	0,9%	177	0,5%	10%
Kadaastro dışı alanlar	0	0,0%	54	0,1%	0%
Diğer alanlar	0	0,0%	43	0,1%	0%
Yangın durdurma zonu	0	0,0%	5	0,0%	0%
Defne	3	2,6%	1.044	2,9%	5%
Karaçam	2	1,7%	122	0,3%	30%
Karaçam ve Kızılçam	1	0,9%	147	0,4%	12%
Karaçam ve Sedir	0	0,0%	99	0,3%	0%
Gökmar	0	0,0%	354	1,0%	0%
Kızılçam ve Servi	0	0,0%	179	0,5%	0%
Gökmar ve Sedir	0	0,0%	151	0,4%	0%
Taşlık	0	0,0%	73	0,2%	0%
Çınar	0	0,0%	12	0,0%	0%
Sedir	0	0,0%	2	0,0%	0%
Karaçam ve Gökmar	0	0,0%	10	0,0%	0%

Arazi örtüsü kriterine ait oluşturulan risk haritası Şekil 22’de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 22 Arazi örtüsü sınıflarının risk haritası


4.1.5. Meşcere kapalılığı:

En fazla yangının çıktığı (43 adet) boşluklu kapalılıkta yangın oranı sahanın tamamına kıyasla %36,8 iken, alanına oranı %20'dir. Gevşek kapalı olan yerler ise sahanın yalnızca %15,3'ünü kaplamasına rağmen yangınların %29,1'i (34 adet) bu sınıfta çıkmıştır ve oranı %43 ile en yüksek sınıf olmuştur. (Tablo 29).

Tablo 29 Meşcere kapalılığı kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Meşcere kapalılığı	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
Boşluklu kapalı	43	36,8%	15.558	43,1%	20%
Gevşek kapalı	34	29,1%	5.531	15,3%	43%
Orta kapalı	25	21,4%	8.392	23,2%	21%
Tam kapalı	15	12,8%	6.639	18,4%	16%

Meşcere kapalılığı kriterine ait oluşturulan risk haritası Şekil 23’de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 23 Meşcere kapalılığı sınıflarının risk haritası


4.1.6. Gelişme çağları:

En fazla yangının çıktığı (43 adet) boş veya boşaltılmış ormanda yangın oranı sahanın tamamına kıyasla %36,8 iken, alanına oranı %35’tir. Yine bu sınıf sahanın yalnızca %14,1’ini kaplamasına rağmen oranı %35 ile en yüksek sınıf olmuştur. (Tablo 30).

Tablo 30 Gelişme çağları kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Gelişme çağları	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
Gençlik ve sıklık	9	7,7%	15.558	43,1%	2%
Sırlıklık ve direklik	16	13,7%	2.848	7,9%	23%
İnce ağaçlık	30	25,6%	4.067	11,3%	30%
Orta ve kalın ağaçlık	19	16,2%	8.553	23,7%	9%
Boş veya boşaltılmış orman	43	36,8%	5.094	14,1%	35%

Gelişme çağları kriterine ait oluşturulan risk haritası Şekil 24’de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 24 Gelişme çağları sınıflarının risk haritası

4.1.7. Sıcaklık:

25 °C sıcaklık sınıfında yangınların tamamının (117 adet) çıkması ve sahanın tümünü (36.120 ha.) kaplamasının sebebi, çalışma sahasının genel olarak yüksek sıcaklıklara sahip olması ve risk haritalaması yaparken yangına en riskli ayların yaz ayları olduğu için bu aylardaki mevsimsel ortalamaların seçilmesi sonucu sıcaklık oranlarının yüksek seyretmesi olmuştur. (Tablo 31).

Tablo 31 Sıcaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları


Sıcaklık	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<10	0	0,0%	0	0,0%	0%
10-15	0	0,0%	0	0,0%	0%
15-20	0	0,0%	0	0,0%	0%
20-25	0	0,0%	0	0,0%	0%
25>	117	100,0%	36.120	100,0%	100%

Sıcaklık kriterine ait oluşturulan risk haritası Şekil 25’de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.

Tablo 32 Nem kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Nem	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<30	0	0,0%	0	0,0%	0%
30-40	0	0,0%	0	0,0%	0%
40-50	0	0,0%	0	0,0%	0%
50-60	106	90,6%	33.444	92,6%	44%
60>	11	9,4%	2.676	7,4%	56%

Nem kriterine ait oluşturulan risk haritası Şekil 26’da gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 26 Nem sınıflarının risk haritası


4.1.9. Rüzgâr şiddeti:

En fazla yangının çıktığı (88 adet) 1 ile 2 bofor rüzgâr şiddetinin yangın oranı sahanın tamamına kıyasla %75,2 iken, alanına oranı %62'dir. Yine bu sınıf sahanın yalnızca %64,7'sini kaplamasına rağmen oranı %62 ile en yüksek sınıf olmuştur. Sıcaklık ve nemde olduğu gibi diğer sınıflarda veri olmamasının sebebi, çalışma sahasının risk haritalaması yaparken mevsimsel ortalamaların seçilmesi sonucu rüzgâr sınıflarının ne çok yüksek ne çok düşük seyretmesi olmuştur. (Tablo 33).

Tablo 33 Rüzgâr şiddeti kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Rüzgâr şiddeti	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<1	0	0%	0	0,0%	0%
1-2	88	75,2%	23.363	64,7%	62%
2-3	29	24,8%	12.757	35,3%	38%
3>	0	0,0%	0	0,0%	0%

Rüzgâr şiddeti kriterine ait oluşturulan risk haritası Şekil 27'de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 27 Rüzgâr şiddeti sınıflarının risk haritası

4.1.10. Yağış:

30 milimetreden az yağış sınıfında yangınların tamamının (117 adet) çıkması ve sahanın tümünü (36.120 ha.) kaplamasının sebebi, risk haritalaması yaparken yangına en riskli ayların yaz ayları olduğu için bu aylardaki mevsimsel ortalamaların seçilmesi sonucu yağış oranlarının çok düşük seyretmesi olmuştur. (Tablo 34).


Tablo 34 Yağış kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Yağış	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<30	117	100,0%	36.120	100,0%	100%
30-60	0	0,0%	0	0,0%	0%
60-90	0	0,0%	0	0,0%	0%
90-120	0	0,0%	0	0,0%	0%
120>	0	0,0%	0	0,0%	0%

Tablo 35 Yollara uzaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Yollara uzaklık	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<100	40	34,2%	6.326	17,5%	33%
100-200	9	7,7%	4.280	11,8%	11%
200-300	15	12,8%	3.596	10,0%	22%
300-400	13	11,1%	3.025	8,4%	23%
400>	40	34,2%	18.893	52,3%	11%

Yollara uzaklık kriterine ait oluşturulan risk haritası Şekil 29’da gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 29 Yollara uzaklık sınıflarının risk haritası


4.1.12. Yerleşime uzaklık:

En fazla yangının çıktığı (48 adet) 500 ile 1000 metre arası yerlerde yangın oranı sahanın tamamına kıyasla %41,0 iken, alanına oranı %36'dır. Yine bu sınıf sahanın yalnızca %23,0'ını kaplamasına rağmen oranı %36 ile en yüksek sınıf olmuştur (Tablo 36).

Tablo 36 Yerleşime uzaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Yerleşime uzaklık	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<200	4	3,4%	2.280	6,3%	11%
200-500	20	17,1%	4.539	12,6%	27%
500-1000	48	41,0%	8.313	23,0%	36%
1000-2000	29	24,8%	11.511	31,9%	16%
2000>	16	13,7%	9.476	26,2%	10%

Yerleşime uzaklık kriterine ait oluşturulan risk haritası Şekil 30'da gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 30 Yerleşime uzaklık sınıflarının risk haritası


4.1.13. Tarıma uzaklık:

En fazla yangının çıktığı (87 adet) 200 metreden yakın yerlerde yangın oranı sahanın tamamına kıyasla %74,4 iken, alanına oranı %49'dur. Yine bu sınıf sahanın yalnızca %52,7'sini kaplamasına rağmen oranı %49 ile en yüksek sınıf olmuştur (Tablo 37).

Tablo 37 Tarıma uzaklık kriteri sınıflarının arazide kapladıkları alanlar ve yangın sayıları

Tarıma uzaklık	Yangın adedi	Yangın Oranı	Arazide Kapladığı Alan (ha)	Arazide Kapladığı Alan Oranı	Yangın Adedi/Arazide Kapladığı Alan Oranı
<200	87	74,4%	19.032	52,7%	49%
200-500	20	17,1%	7.087	19,6%	30%
500-1000	7	6,0%	5.519	15,3%	13%
1000-2000	3	2,6%	4.049	11,2%	8%
2000>	0	0,0%	434	1,2%	0%

Tarıma uzaklık kriterine ait oluşturulan risk haritası Şekil 31’de gösterilmektedir. Renk skalası kırmızıdan yeşile doğru gittikçe risk azalmaktadır.



Şekil 31 Tarıma uzaklık sınıflarının risk haritası

Bu koşullar altında orman yangını için örnek risk senaryosu Tablo 38’de verilmiştir.

Tablo 38 Orman yangını örnek risk senaryosu

Yangın risk dereceleri	Riskin tanımı
Çok yüksek	Yükseklik 500 m’den az, Bakı 135 ile 225 derece arasında, Eğim 35 dereceden fazla, Arazi örtüsü Kızılçam ve Karaçam, Meşcere kapalılığı tam kapalı, Gelişme çağları gençlik ve sıklık, sırkılık ve direklik, ince ağaçlık, Sıcaklık 25 °C fazla, Bağıl nem %40’dan az, Rüzgâr şiddeti 3 bofordan fazla, Yağış 60 mm’den az, Yollara uzaklık 100 m’den az, Yerleşime ve Tarıma olan uzaklık 200 m’den az.


Tablo 38 Orman yangını örnek risk senaryosu (devam)

Yüksek	Bakı 225 ile 315 derece arasında, Eğim 25 ile 35 derece arasında, Arazi örtüsü Ziraat alanı, İskân alanı, Elektrik hatları, Mezarlıklar, Karaçam ve Kızılçam karışımı, Meşcere kapalılığı orta kapalı, Gelişme çağları orta ve kalın ağaçlık, Sıcaklık 20 ile 25 °C arasında, Bağıl nem %40 ile 50 arasında, Yağış 60 ile 90 mm arasında, Yollara uzaklık 100 ile 200 m arasında, Yerleşime ve Tarıma uzaklık 200 ile 500 m arasında. Yükseklik 500 ile 1.500 m arasında, Bakı 45 ile 135 derece arasında, Eğim 10 ile 25 derece arasında, Arazi örtüsü Ardıç, Maki, Fıstık çamı, Kızılçam ve Saçlı meşe karışımı, Gökmar, Sedir, Meşcere kapalılığı gevşek kapalı, Sıcaklık 15 ile 20 °C arasında, Bağıl nem %50 ile 60 arasında, Rüzgâr şiddeti 2 ile 3 bofor arasında, Yağış 90 ile 120 mm arasında, Yollara uzaklık 200 ile 300 m arasında, Yerleşime ve Tarıma uzaklık 500 ile 1.000 m arasında.
Normal	Yükseklik 1.500 m'den fazla, Bakı 315 ile 45 derece arasında, Eğim 5 ile 10 derece arasında, Arazi örtüsü Saçlı meşe, Kızılçam ve Harnup karışımı, Kızılçam ve Defne karışımı, Karaçam ve Sedir karışımı, Kızılçam ve Servi karışımı, Gökmar ve Sedir karışımı, Karaçam ve Gökmar karışımı, Meşcere kapalılığı boşluklu kapalı, Sıcaklık 15 °C'den az, Bağıl nem %60 dan fazla, Rüzgâr şiddeti 2 bofordan az, Yollara uzaklık 300 ile 400 m arasında, Yerleşime ve Tarıma uzaklık 1.000 ile 2.000 m arasında.
Düşük	Eğim 5 dereceden az, Arazi örtüsü Orman toprağı, Su, Ocak, İzin verilmiş alanlar, Kum, Kadaastro dışı alanlar, diğer alanlar, Yangın durdurma zonu, Defne, Taşlık, Çınar, Gelişme çağları boş veya boşaltılmış orman, Yağış 120 mm'den fazla, Yollara uzaklık 400 m'den fazla, Yerleşime ve Tarıma uzaklık 2.000 m'den fazla.
Çok düşük	

Kriterlerin risk haritaları oluşturulduktan sonra hem literatür araştırması kullanılarak hem AHP kullanılarak ağırlıkları belirlenmiştir (Bkz. Tablo 22). Farklı yöntemlerle elde edilen bu ağırlıklara göre 2 farklı orman yangını risk haritası oluşturulmuş ve sonuçları birbirleri ile kıyaslanmıştır.

4.2. Literatür Ağırlıklarıyla Elde Edilen Sonuçlar


Literatür araştırması neticesinde ağırlıklı karşılaştırma sonucu üretilen yangın risk haritası Şekil 32'deki gibidir. Üretilen yangın risk haritası; çok yüksek risk, yüksek risk, normal risk, düşük risk ve çok düşük risk olmak üzere 5 sınıfta değerlendirilmiştir.



Şekil 32 Literatür sonuçlarına göre oluşturulan orman yangını risk haritası

Literatür sonuçlarına göre oluşturulan harita incelendiğinde; çok düşük riskli alanlar çalışma sahasının %0,1'ini (34 ha.), düşük riskli alanlar %8,3'ünü (3.002 ha.), normal riskli alanlar %48,5'ini (17.529 ha.), yüksek riskli alanlar %42,2'sini (15.232 ha.) ve çok yüksek riskli alanlar %0,9'unu (321 ha.) kaplamıştır.

Tarihsel yangın verileri bu harita üzerinde incelendiğinde; çok düşük riskin bulunduğu alanlarda herhangi yangın verisi yoktur yani daha önce bu haritaya göre çok düşük risk alanlarında yangın çıkmamıştır. Düşük riskli alanlarda 5 adet, normal riskli alanlarda 45 adet, yüksek riskli alanlarda 66 adet ve çok yüksek riskli alanlarda 1 adet yangın çıktığı Şekil 33'de gözlemlenmiştir.



Şekil 33 Literatür sonuçlarına göre oluşturulan risk haritasının tarihsel yangın konumları ile doğrulanması


Literatür cevaplarına göre elde edilen risk sonuçlarının yüzdesi belirlenirken riskin arazide kapladığı alan ile çıkan yangın sayılarındaki doğru orantı göz önünde bulundurularak, $yüzde\ risk = (yüzde\ yangın) / (yüzde\ alan)$ olmak üzere bir formülasyon geliştirilmiştir. Bunun amacı sınıfların arazide kapladığı alanın büyüklüğüne göre yangın çıkma ihtimalinin çokluğudur. Bu sebeple çok az alan kaplayan sınıfta çıkan 1 adet yangın, çok fazla alan kaplayan sınıfta çıkan bir adet yangına göre daha riskli olması gerekmektedir şeklinde yorumlanmıştır. Buna göre çok düşükten çok yükseğe sırasıyla risk oranları; %0, %14, %22, %37 ve %27 olarak bulunmuştur (Tablo 39).

Tablo 39 Literatür sonuçları

Risk Derecesi	Yangın Sayıları	Yüzde Yangın	Riskin Kapladığı Alan (ha.)	Yüzde Alan	Yüzde Risk
Çok düşük	0	0,0%	34	0,1%	0%
Düşük	5	4,3%	3.002	8,3%	14%
Normal	45	38,5%	17.529	48,5%	22%
Yüksek	66	56,4%	15.232	42,2%	37%
Çok yüksek	1	0,9%	321	0,9%	27%

4.3. Analitik Hiyerarşi Prosesi Sonuçları


AHP ile yapılan ağırlıklandırma neticesinde ağırlıklı çakıştırma sonucu üretilen yangın risk haritası Şekil 34'deki gibidir. Üretilen yangın risk haritası; çok yüksek risk, yüksek risk, normal risk, düşük risk ve çok düşük risk olmak üzere 5 sınıfta değerlendirilmiştir.



Şekil 34 AHP sonuçlarına göre oluşturulan orman yangını risk haritası

AHP sonuçlarına göre oluşturulan harita incelendiğinde; çok düşük riskli alanlar çalışma sahasının %4,2'sini (1.505 ha.), düşük riskli alanlar %22,8'ini (8.243 ha.), normal riskli alanlar %41,6'sını (15.027 ha.), yüksek riskli alanlar %25,3'ünü (9.127 ha.) ve çok yüksek riskli alanlar %6,1'ini (2.217 ha.) kaplamıştır.

Tarihsel yangın verileri bu harita üzerinde incelendiğinde; çok düşük riskli alanlarda 1 adet, düşük riskli alanlarda 17 adet, normal riskli alanlarda 49 adet, yüksek riskli alanlarda 35 adet ve çok yüksek riskli alanlarda 15 adet yangın çıktığı Şekil 35'de gözlemlenmiştir.



Şekil 35 AHP sonuçlarına göre oluşturulan risk haritasının tarihsel yangın konumları ile doğrulanması

AHP'ye göre elde edilen risk sonuçlarının yüzdesi belirlenirken riskin arazide kapladığı alan ile çıkan yangın sayılarındaki doğru orantı göz önünde bulundurularak, $yüzde\ risk = (yüzde\ yangın) / (yüzde\ alan)$ olmak üzere bir formülasyon geliştirilmiştir. Bunun amacı sınıfların arazide kapladığı alanın büyüklüğüne göre

yangın çıkma ihtimalinin çokluğudur. Bu sebeple çok az alan kaplayan sınıfta çıkan 1 adet yangın, çok fazla alan kaplayan sınıfta çıkan bir adet yangına göre daha riskli olması gerekmektedir şeklinde yorumlanmıştır. Buna göre çok düşükten çok yükseğe sırasıyla risk oranları; %4, %12, %20, %23 ve %41 olarak bulunmuştur (Tablo 40).


Tablo 40 AHP sonuçları

Risk Derecesi	Yangın Sayıları	Yüzde Yangın	Risk Kapladığı Alan (ha.)	Yüzde Alan	Yüzde Risk
Çok düşük	1	0,9%	1.505	4,2%	4%
Düşük	17	14,5%	8.243	22,8%	12%
Normal	49	41,9%	15.027	41,6%	20%
Yüksek	35	29,9%	9.127	25,3%	23%
Çok yüksek	15	12,8%	2.217	6,1%	41%

4.4. Literatür ve AHP Sonuçlarının Karşılaştırılması

Her iki yöntemin 13 kriter için verdikleri ağırlık puanları incelendiğinde; literatür sonuçlarına göre 7,11 ve AHP sonuçlarına göre 17,78 puanı olan yollara uzaklık kriteri 10,67 puanlık bir farkla en büyük farka sahip kriter olmuştur. Daha sonra sırasıyla; nem 7,03 puan fark, yağış 6,74 puan fark, yerleşime uzaklık 5,49 puan fark, eğim 5,15 puan fark, arazi örtüsü 5,11 puan fark, bakı 4,33 puan fark, yükseklik 3,00 puan fark, gelişme çağları 2,97 puan fark, tarıma uzaklık 2,49 puan fark, meşcere kapallılığı 1,95 puan fark, rüzgâr şiddeti 0,98 puan fark ve sıcaklık 0,46 puan fark almıştır (Tablo 22).

Literatür ve AHP sonuçlarıyla üretilen haritaları birbirleri ile kıyaslamak ve farklarını belirlemek amacıyla raster formatındaki veriler üst üste çakıştırılarak geometrik kesişimleri hesaplanmıştır. Her iki haritada da aynı risk sınıfında ve farklı risk sınıfında kalan alanlar Şekil 36'da gösterilmektedir.



Şekil 36 Literatür ve AHP sonuçlarının fark haritası

Risk sınıfları arasındaki ayrımın temel nedeni, kriterlere verilen ağırlık puanları arasındaki farktır. Tablo 41 her iki harita ile üretilen risk sınıflarının kıyasını sunmaktadır.

Tablo 41 Literatür ve AHP sonuçlarının fark tablosu

Literatür Risk Sınıfı	AHP Risk Sınıfı	Literatür → AHP	Değişiklik Alan (ha.)	Değişiklik Yüzde
Çok düşük risk (1)	Çok düşük risk (1)	1 → 1	33,7	99,1%
Çok düşük risk (1)	Düşük risk (2)	1 → 2	0,2	0,5%
Çok düşük risk (1)	Normal risk (3)	1 → 3	0,1	0,4%
Çok düşük risk (1)	Yüksek risk (4)	1 → 4	0,0	0,0%
Çok düşük risk (1)	Çok yüksek risk (5)	1 → 5	0,0	0,0%
Düşük risk (2)	Çok düşük risk (1)	2 → 1	1.391,3	46,3%
Düşük risk (2)	Düşük risk (2)	2 → 2	1.478,6	49,2%
Düşük risk (2)	Normal risk (3)	2 → 3	125,1	4,2%
Düşük risk (2)	Yüksek risk (4)	2 → 4	7,8	0,3%
Düşük risk (2)	Çok yüksek risk (5)	2 → 5	0,2	0,0%

Tablo 41 Literatür ve AHP sonuçlarının fark tablosu (devam)

Normal risk (3)	Çok düşük risk (1)	3 → 1	61,9	0,4%
Normal risk (3)	Düşük risk (2)	3 → 2	6.687,5	38,1%
Normal risk (3)	Normal risk (3)	3 → 3	9.420,6	53,7%
Normal risk (3)	Yüksek risk (4)	3 → 4	1.346,2	7,7%
Normal risk (3)	Çok yüksek risk (5)	3 → 5	12,7	0,1%
Yüksek risk (4)	Çok düşük risk (1)	4 → 1	2,8	0,0%
Yüksek risk (4)	Düşük risk (2)	4 → 2	47,7	0,3%
Yüksek risk (4)	Normal risk (3)	4 → 3	5.505,3	36,1%
Yüksek risk (4)	Yüksek risk (4)	4 → 4	7.775,8	51,1%
Yüksek risk (4)	Çok yüksek risk (5)	4 → 5	1.900,3	12,5%
Çok yüksek risk (5)	Çok düşük risk (1)	5 → 1	0,0	0,0%
Çok yüksek risk (5)	Düşük risk (2)	5 → 2	0,0	0,0%
Çok yüksek risk (5)	Normal risk (3)	5 → 3	1,0	0,3%
Çok yüksek risk (5)	Yüksek risk (4)	5 → 4	29,7	9,3%
Çok yüksek risk (5)	Çok yüksek risk (5)	5 → 5	290,3	90,4%

Çalışma sahasının %52,6'sında (18.999 ha.) her iki haritayla üretilmiş risk sınıflarında da bir değişiklik olmamıştır. Yani bu kısımlarda Literatür ile üretilen haritadaki risk sınıfı ile AHP ile üretilen risk sınıfı aynıdır. Çok düşük risk sınıfı %99, düşük risk sınıfı %49, normal risk sınıfı %54, yüksek risk sınıfı %51 ve çok yüksek risk sınıfı %90 eşleşmiştir. En büyük farkların olduğu diğer sınıflarda ise durum; 1.391 ha alanın literatürde düşük olarak sınıflandırılmasına rağmen AHP'de çok düşük, 6.687 ha alanın literatürde normal olarak sınıflandırılmasına rağmen AHP'de düşük, 1.346 ha alanın ise yüksek ve 5.505 ha alanın literatürde yüksek olarak sınıflandırılmasına rağmen AHP'de normal, 1.900 ha alanın ise çok yüksek olarak sınıflandırılmasıyla oluşmuştur.

4.5. Makine Öğrenmesi Sonuçları

Makine öğrenmesi kullanılarak yapılan doğrulama ile hem kriterlerin genel sonuçları hem de algoritmaların sınıflandırma performansları değerlendirilmiştir. 3.000 örneklemden oluşan veri setinin %80'i eğitim için kullanılmış %20'si ise test için kullanılmıştır. Performansların ölçümü için hazırlanan veri seti üzerinde NN, SVM, LDA, NB, KNN ve DT olmak üzere altı farklı makine öğrenimi algoritmasıyla eğitim

ve test işlemi gerçekleştirilmiştir. Bu algoritmaların eğitimini doğrulamak için her algoritmanın eğitimi beş kez tekrarlanmış ve ortalamaları alınmıştır. Böylece sonuçların güvenilirliği arttırılmıştır. Eğitim sonrası algoritmaların performansları Tablo 42’de, test sonrası performansları ise Tablo 43’de gösterilmektedir.

Tablo 42 Eğitim sonrası performans değerlendirmesi

Eğitim veri seti	NN	SVM	LDA	NB	KNN	DT
1. sınıflandırma doğruluğu	86,7%	80,7%	76,3%	74,0%	65,7%	60,0%
2. sınıflandırma doğruluğu	88,0%	81,3%	76,3%	74,0%	65,7%	60,0%
3. sınıflandırma doğruluğu	85,3%	80,7%	76,3%	74,0%	65,7%	60,0%
4. sınıflandırma doğruluğu	86,7%	80,3%	76,3%	74,0%	65,7%	60,0%
5. sınıflandırma doğruluğu	85,7%	80,3%	76,3%	74,0%	65,7%	60,0%
Ortalama Doğruluk	86,5%	80,7%	76,3%	74,0%	65,7%	60,0%

Tablo 43 Test sonrası performans değerlendirmesi

Test veri seti	NN	SVM	LDA	NB	KNN	DT
1. sınıflandırma doğruluğu	82,4%	79,0%	71,6%	69,3%	64,3%	55,0%
2. sınıflandırma doğruluğu	84,2%	79,9%	71,6%	69,3%	64,3%	55,0%
3. sınıflandırma doğruluğu	83,8%	79,0%	71,6%	69,3%	64,3%	55,0%
4. sınıflandırma doğruluğu	82,2%	79,9%	71,6%	69,3%	64,3%	55,0%
5. sınıflandırma doğruluğu	83,5%	79,5%	71,6%	69,3%	64,3%	55,0%
Ortalama Doğruluk	83,2%	79,5%	71,6%	69,3%	64,3%	55,0%

Yapılan çalışmalar sonucunda, Neural Network algoritmasının, özelinde Narrow Neural Network algoritmasının, %86,5 eğitim ve %83,2 test doğruluğu ortalamaları ile en yüksek doğruluk değerine ulaştığı gözlenmiştir. Diğer algoritmalarından; SVM %80,7 eğitim ve %79,5 test, LDA %76,3 eğitim ve %71,6 test, NB %74,0 eğitim ve %69,3 test, KNN %65,7 eğitim ve %64,3 test ve DT %60,0 eğitim ve %55,0 test veri doğruluğu ortalamalarına ulaşmıştır. Bu bulgular, NN algoritmasının veri seti üzerindeki sınıflandırma problemlerinde etkili bir seçenek olduğunu göstermiştir.

En iyi sonuç veren NN modelinin sınıflandırmalar üzerindeki performansını değerlendirmek için karışıklık matrisinden (confusion matrix) elde edilen; doğruluk (accuracy), duyarlılık (recall), özgüllük (specificity), kesinlik (precision), f-1 skor, kappa ve ROC eğrisi gibi farklı ölçü performansları kullanılmıştır. Karışıklık matrisi Tablo 44’de ölçü metrikleri ise Tablo 45’de gösterilmiştir.

Tablo 44 Karışıklık matrisi


Gerçek sınıf	Tahmin edilen sınıf					
	Sınıflar	Çok düşük	Düşük	Normal	Yüksek	Çok yüksek
Çok düşük		457	56	0	0	0
Düşük		16	376	8	0	0
Normal		0	16	614	32	0
Yüksek		0	0	47	424	24
Çok yüksek		0	0	0	48	282

Tablo 45 Sınıflandırma performansının ölçülmesi için kullanılan metrikler


	Çok düşük	Düşük	Normal	Yüksek	Çok yüksek
Doğruluk	0,970	0,960	0,957	0,937	0,970
Duyarlılık	0,891	0,940	0,927	0,857	0,855
Özgüllük	0,992	0,964	0,968	0,958	0,988
Kesinlik	0,966	0,839	0,918	0,841	0,922
Kappa	0,908	0,863	0,893	0,809	0,870
F1-Skor	0,927	0,887	0,923	0,849	0,887

Metriklerin performans değerleri incelendiğinde şu sonuçlara ulaşılmıştır.

Doğruluk 0,97 ile 0,94 arasında değişmektedir. Çok düşük ve çok yüksek sınıfta en büyük değerleri, yüksek sınıfta en küçük değeri almıştır. Duyarlılık 0,94 ile 0,86 arasında değişmektedir. Düşük sınıfta en büyük değeri, çok yüksek sınıfta en küçük değeri almıştır. Özgüllük 0,99 ile 0,96 arasında değişmektedir. Çok düşük sınıfta en büyük değeri, yüksek sınıfta en küçük değeri almıştır. Kesinlik 0,97 ile 0,84 arasında değişmektedir. Çok düşük sınıfta en büyük değeri, düşük sınıfta en küçük değeri almıştır. Kappa 0,91 ile 0,81 arasında değişmektedir. Çok düşük sınıfta en büyük değeri, yüksek sınıfta en küçük değeri almıştır. F1-Skor 0,93 ile 0,85 arasında değişmektedir. Çok düşük sınıfta en büyük değeri, yüksek sınıfta en küçük değeri almıştır. Bu sonuçlara göre çok düşük sınıf, en iyi sınıflandırma performansına sahip sınıf olurken; yüksek sınıf, en kötü sınıflandırma performansına sahip sınıf olmuştur Eğitim ve test modellerinin ROC eğrisi Şekil 37 ve Şekil 38’de görselleştirilmiştir.



Şekil 37 Eğitim veri setinin ROC eğrisi



Şekil 38 Test veri setinin ROC eğrisi

ROC eğrisi altında kalan alanlar eğitim veri setinde çok yüksek sınıftan çok düşüğe sırasıyla; 0,94, 0,96, 0,99, 0,96 ve 0,93 olmuştur. Test veri setinde ise sırasıyla; 0,86, 0,87, 0,97, 0,90 ve 0,96 olarak hesaplanmıştır. Literatürde ROC eğrisi altında kalan alan 0,90'ın üzerinde ise çok iyi bir sınıflandırma yapıldığı anlamına gelmektedir. Test verisinde elde edilen sonuçlar, ML ile gerçekleştirilen orman yangını sınıflandırma algoritmasının oldukça başarılı bir sınıflandırma yaptığını gösterir.



5. TARTIŞMA VE ÖNERİLER

5.1. Tartışma

Bu çalışma ile orman yangınlarına oldukça hassas bir bölgede, yangının olası etki ve zararlarını en aza indirmek amacıyla, yangına riskli bölgeleri sınıflandırarak bir orman yangını risk bilgi sistemi oluşturulmuştur.

Yangına risk teşkil eden kriterlerin ağırlıklarının belirlenebilmesi için literatürde benzer çalışmaların verileri tablo halinde toplanmış ve değerlendirilmiştir. Bu çalışmaların her biri farklı sayılarda, farklı ağırlıklandırma yöntemleriyle ve farklı puanlarda ağırlıklandırmalar yapmıştır. Örneğin bir çalışmada yangın riskini haritalamak için 6 adet kriter kullanılırken başka bir çalışmada 12 adet kriter ile risk belirlenmeye çalışılmıştır. Dolayısıyla az kriter kullanılan çalışmalarda, bir kriter başına düşen ağırlık puanı fazla olduğundan genel ortalamayı etkilemektedir.

Kriterlere verilen ağırlıklar için; literatürde bulunan çalışmalar ve uzman görüşleri ayrılmıştır. Örneğin; literatür için en büyük öneme sahip kriterler meteorolojik ve en az öneme sahip olan insan kriterleri iken, uzman görüşleri en önemli kriteri biyolojik kriterler ve en az öneme sahip olanı topoğrafik kriterler olarak belirlemiştir.

AHP ve literatür arasındaki bu farkların sebebi; literatürde bulunan verilerin genellikle daha kapsamlı ve genel bir bakış açısına sahip olması, uzman görüşlerinin ise saha deneyimi ve bilgisine dayanarak çalışma sahasının karakteristik yapısına göre daha özgün cevaplar sunmasıyla ilişkilendirilebilir.

Daha geniş kapsamda bakılırsa, her iki yaklaşımın da farklı avantajları ve dezavantajları bulunmaktadır. AHP uzmanların bilgi ve deneyimine bağlı olarak değerlendirme yapmasını ve karar almasını sağlarken, Literatür mevcut bilgi birikimine dayanır. AHP tutarlılık kontrolü yaparak sonuçların güvenilirliğini artırır. Literatür ise geniş kapsamlı bilgi sunarak farklı bakış açılarını içerir ve geçmiş tecrübelerden faydalanır. AHP uzmanların kişisel deneyimleri olduğundan bazı konularda sınırlı kalabilir ve önyargılara dayanabilir. Literatürde de bilgiler zamanla eskiyebilir veya değişebilir, bu da karar verme sürecinde güncel olmayan bilgilerin

oluşmasına yol açabilir. Ancak, en etkili yöntem, her iki yaklaşımı bir arada kullanarak hem genel hem de özel bakış açılarını değerlendirmektir.

Aynı zamanda bu çalışmada kullanılan kriterler ve ağırlıklandırmalar Akdeniz havzasında bulunan ormanlık alanlara hatta özelinde Türkiye'nin Akdeniz kıyılarındaki bulunan ormanlarına yönelik bir yaklaşım olmuştur. Dolayısıyla aynı kriterleri ve aynı ağırlıkları farklı bölgelerde kullanmak yanlış bir yaklaşım olacaktır. Örneğin amazon ormanlarında insan faktörünün önemi yok denecek kadar az iken yağış ve nemin önemi son derece fazla olacaktır.

Sınıflandırma sonuçlarında, kriterlerin sınıflarında çıkan yangın sayıları ve çalışma sahasında kapladıkları alanlarıyla orantılı olarak belirlenen risk yüzdeleri, sınıfların risk dereceleriyle kısmen uyumlu olduğunu göstermiştir. Bazı kriterlerin çok yüksek riskli sınıflarında, diğer sınıflara oranla çok daha az yangın çıktığı görülürken, bazı düşük risk sınıflarında ise hem yangın sayısının hem risk oranının yüksek olduğu görülmektedir. Örneğin gelişme çağları kriterinin gençlik ve sıklık sınıfı yangına çok yüksek riskli bir sınıf olmasına rağmen yalnızca 9 adet yangın çıkmıştır, bu sınıfın arazide kapladığı alan ise %43 olduğu için geçmiş yangın verileri ve bu sınıfın arazide kapladığı alan göz önüne alınarak risk oranı hesaplandığında %2 gibi çok az bir orana sahip olduğu görülmüştür. Bunun en büyük sebeplerinden birisi orman yangınlarının yalnızca bu kritere bağlı olarak çıkmaması, ortamda bulunan birçok kriter ve durumdan etkilenmesidir. Yani kriterleri tek tek ele alarak risk sonuçlarını değerlendirmeye çalışmak bir hata olacaktır. Diğer bir sebebi ise çalışma sahasındaki tarihsel yangın verilerinin azlığından kaynaklı olabilir. Öte yandan, kriterler arasında özellikle tarıma uzaklık kriterinin sınıflarındaki belirlenen risk yüzdeleri, sınıfın risk dereceleriyle oldukça uyumlu sonuçlar göstermiştir.

Çalışmada kullanılan meteorolojik kriterler, sınıflarının kapsam olarak tamamını yansıtmamıştır. Örneğin sıcaklık kriterinin 10 °C'den az, 10 - 15 arası, 15 - 20 arası, 20 - 25 arası ve 25 °C'den fazla olmak üzere 5 sınıfı vardır fakat risk haritalarında yalnızca 25 °C'den fazla olan sınıfı vardır. Bunun sebebi çalışma sahasının iklime bağlı olarak sıcaklık değerlerinin yüksek olması ve bununla birlikte yangınların en çok risk arz eden mevsimin yaz ayları olması sebebiyle yaz mevsiminin ortalama sıcaklık değerlerinin kullanılmasından kaynaklıdır. Yaz aylarının mevsimsel ortalamaları alınarak risk haritaları oluşturulduğu için meteorolojik kriterlerin tamamında aynı

durum söz konusudur. Bu da yalnızca o sınıf özelinde bakıldığında saha için anlamlı bir risk yorumu yapılamamasına sebep olurken genel bağlamda, yani diğer kriterlerle birlikte kullanılıp, ağırlıklar dikkate alınarak yorumlandığında sonucu belirlemede etkili olmuştur.

Literatür ve AHP sonuçlarından oluşturulan risk haritası tarihsel yangın konumlarıyla karşılaştırılmış, risk sınıflarını bu verilerle doğrulamak ve yeni bir risk yüzdesi elde etmek amacıyla $yüzde\ risk = (yüzde\ yangın) / (yüzde\ alan)$ şeklinde bir formül kullanılmıştır. Bunun amacı risk sınıflarının yüzdesini belirlerken sadece yangın sayılarını baz almayıp, sınıfların arazide kapladığı alanlar da yangın sayılarına etki ettiğinden o sınıfta çıkan yangın sayısını, sınıfın arazide kapladığı alana bölerek bir risk yüzdesi oluşturmaktır. Buna göre A sınıfının 100 hektar alan kapsadığı ve 1 adet yangın çıktığı, B sınıfının ise 10 hektar alan kapladığı ve yine 1 adet yangın çıktığı varsayıldığında; B, A'dan daha risklidir denilir.

Her iki risk haritası sınıfsal bazda karşılaştırıldığında (Şekil 36, Tablo 41) %52,6 oranında uyduğu bulunmuştur. Buradan sonuçla risk haritaları, görece birbirine yakın sonuçlar üretmemiştir denilebilir ancak sınıfların dağılımı incelendiğinde haritalar arasında büyük farklar bulunmadığı gözlemlenmiştir. Yani geriye kalan alanların çok büyük çoğunluğunda diğer haritaya göre sınıflar bir alt veya bir üst sınıfa dahil olmuştur. Örneğin literatüre göre normal riskli sınıflandırılan risk için AHP'de ya bir alt sınıf olan düşük risk ya da bir üst sınıf olan yüksek risk olarak sınıflandırılmıştır. Buna göre sınıflandırmaları her sınıfın bir alt ve bir üst sınıfı ile birleştirip 3 sınıf yaparak uyum oranı %75'lerin üzerine çıktığı tespit edilmiştir.

Çalışma sahasından elde edilen sınıflandırma verileri kullanılarak hazırlanan veri seti üzerinde ML algoritmaları kullanılarak yeniden bir sınıflandırma yapıldığında en yüksek başarıma eğitim verisi üzerinde %86,5, test verisi üzerinde ise %83,2 doğruluk değeri ile NN algoritması ulaşmıştır. Her bir sınıf için AUC değerleri incelendiğinde NN algoritmasının orta ve düşük risk sınıflarını %90'ın üzerinde bir başarıyla sınıflandırdığı, yüksek ve çok yüksek risk sınıflarında ise sırasıyla %86 ve %87'lik bir doğruluk yakaladığı görülmüştür. Literatür ve AHP sonuçlarından elde edilen veriler ile ML algoritmalarının ürettiği sonuçların birbirleri ile uyumlu olduğu ve doğru bir veri seti etiketlemesi yapıldığında yangın risk sınıflandırması için ML algoritmalarının kullanılabileceği gösterilmiştir.

CBS teknolojisi, karmaşık veri setlerini bir araya toplama, çok sayıda veriyi aynı anda analiz etme, bilgileri işleme, yönetme ve görselleştirme konularında bu çalışma için son derece başarılı sonuçlar üretmiştir. AHP'nin de büyük ve karmaşık verileri basitleştirip ayıran ve karar vericilere tutarlılık kontrolü yaparak daha doğru kararlar vermesini sağlayan yapısı bu gibi çok kriterli problemlerin çözümünde kullanışlı olduğunu göstermiştir. Veri seti üzerinde yapılan sınıflandırma işleminde, makine öğrenmesi algoritmalarında Neural Network algoritmasının yüksek performans gösterdiği görülmüş ve bu algoritmanın, veri setindeki örüntüleri daha etkili bir şekilde öğrenerek daha doğru tahminler yapabildiği sonucuna varılmıştır. Diğer algoritmalarından; SVM görece iyi sonuçlar verirken, LDA ve NB ortalamanın altında kalmış, KNN ve DT ise bu çalışma için yetersiz kalmıştır. Ayrıca, eğitim ve test işleminin beş kez tekrarlanması sonucunda elde edilen tutarlı sonuçlar, algoritmaların genel olarak stabil bir performans sergilediğini göstermiştir.

5.2. Öneriler

Elde edilen sonuçlar ile yangın yöneticilerinin, riskin fazla olduğu bölgelere yoğunlaşarak önlemlerini bu bölgelerde artırmaları beklenir. Yangın gözetleme kulelerinin stratejik yerlere konumlandırılması oldukça önemlidir. Bu kulelerin çok yüksek ve yüksek riskli bölgeleri görüp görmediği denetlenebilir. Yangın gözetleri gibi yangına müdahale için önemli unsurların yerleri de yine mümkün olduğunca riskin yüksek olduğu bölgelere ve ulaşımına yakın olacak şekilde yapılmalıdır. Hayvan barınakları, yeni yangın gözetleme kuleleri gibi tesislerin inşası sırasında, bu yapıların yerleri, risk analizlerine göre belirlenmelidir. Bu tesislerin hem yangından korunması hem de yangına müdahale için uygun noktalarda olması gerekir. Yine bu alanlar dikkate alınarak yangına hızlı ve kolay müdahale ile yangının yayılmasını önlemek amacıyla yangın emniyet yolları açılabilir.

Tarımsal alanlara yakın yerlerin, riskin ve yangınların çok olduğu bölgeler olduğu belirlenmiştir. Bu bölgelerde özellikle anız yakma gibi faaliyetlere azami dikkat edilmelidir. Benzer şekilde yerleşim alanlarına yakın yerlerde ormanlık alanlar içerisinde ateş yakılabilecek tüm faaliyetler engellenmelidir.

Risk haritalarının gösterdiği yangına sebep olabilecek hususlar ve kriterler konusunda toplumun her kesiminin eğitilmesi ve bilinçlendirmesi, yangın riskini azaltmada önemli bir rol oynayacaktır.

Yangın risk haritaları, hava durumu sistemleri gibi anlık olarak vatandaşlarla da paylaşılan bir bilgi sistemi haline gelirse, özellikle yaz dönemlerinde riskin fazla olduğu alanlara yakın yerlerde yaşayan insanların daha dikkatli olmasını sağlar. Bilinçli insanların olası bir ateş dumanı gördüklerinde yangına erken müdahale ve zararın azaltılması, yangın yöneticilerine hızlı haber verme ve yardım etme konularında da ortak mücadele hususunda faydalı olur.

Orman Genel Müdürlüğü veya işletme müdürlükleri gibi yangınlarda yetkili kurum ve kuruluşların bu gibi risk haritalama veya bilgi sistemlerini dikkate alarak hareket etmeleri, yangınlarla mücadelede çok daha etkili ve az maliyetli sonuca ulaşılmasını sağlayacaktır.

Yangın risk haritalarının güncelliği son derece önemlidir. Bu bakımdan risk bilgi sistemlerindeki verilerin güncellenebilir olması büyük avantajlar yaratacaktır. Topoğrafya, biyolojik veya insan kriterleri sık sık değişmediği için onların güncellenebilir olması kolaydır ancak hava koşulları fazlasıyla dinamik unsurlardır. Bu sebeple, meteorolojinin hava tahmin sistemleri ile yangın risk bilgi sistemleri entegre edilerek dinamik yapıda risk bilgi sistemleri kurulması sağlanabilir. Böylece yangın riskinin, güncel ve doğru bir şekilde değerlendirilmesine olanak tanıyacaktır.

Bununla birlikte risk bilgi sistemlerindeki kriterlerin sınıfları veya direkt olarak kendileri zaman zaman değişiklik gösterebilir. Sisteme bir kriterin dahil olması veya var olanın çıkarılması durumları söz konusu olabilir. Aynı şekilde, kriterlere atanan ağırlık değerleri de farklı arazi ve örtü tiplerinde, farklı meteorolojik koşullar altında, farklı topoğrafyalarda farklılıklar gösterebilir. Veya uzman görüşleri, çeşitli sebeplerle değişerek kriterlerin ağırlıklarını değiştirmeleri gerekebilir. Bu yönüyle düşünüldüğünde sistemde bu gibi değişikliklerin kullanıcılar tarafından hızlı ve basit bir şekilde değiştirilebilir, ayarlanabilir ve müdahale edilebilir sistemler olarak tasarlanması avantaj sağlayacak bir başka konudur.

Yangın risk haritaları ya da bilgi sistemleri, zaten araziye ait topoğrafya bilgisine, örtü yapısına, meşcere türlerine ve türlere ait bilgilere sahip olacağından, bu haritalar yangın simülasyonları ile desteklenerek, çıkan bir yangında alevlerin büyüme yönünü

ve büyüme hızını tahmin ederse ve hatta bu sistemler meteorolojik koşullar gibi anlık değişkenlik gösteren dinamikleri de hesaba katarsa, olası bir orman yangını çıktığında karar vericiler müdahale için çok hızlı kararlar alabilir. Bu da alevlerin büyümesinin ve yayılmasının önlenmesi, hasarın boyutlarının en aza indirilmesi, yangın söndürme çalışmalarında ve sonrasındaki zararların telafi edilmesinde harcanacak maddi kayıpların azalması ve alevlerin büyüme yönünde, eğer varsa korunması gereken ev, ahır, bahçe, tarla gibi yapı ve hasarı büyütecek etmenler bunlara erken önlemlerin alınması sebebiyle, hem yangın esnasında hem de yangın öncesinde oluşturulacak senaryolar ile itfaiyeciler, sivil toplum kuruluşları, ormanlardan sorumlu yetkili kurum ve kuruluşlar için büyük kolaylıklar ve faydalar sağlayacaktır.

Bu tip sistemlerin yapıldığı, risk analizi çalışmalarının birkaç parametre kullanılarak değil, bölgenin ve imkanların elverdiği durumlarda çok daha fazla parametre kullanılarak yapılması ve her çalışmanın parametreler üzerinde daha detaylı durması, gelecekte yapılacak çalışmalar açısından önem arz eder.

Orman yangını risk bilgi sistemleri, ormanlık bölgelerin tamamında kullanımı yaygın hale gelecek şekilde genişletilirse, en kıymetli doğal varlıklarımız olan ormanların geleceği ve korunmasında çok önemli roller üstlenecek sistemler olacaktır.

Son olarak;

- Çalışmada kullanılan yangına risk teşkil eden kriterlerin sayısı ve veri sayısı arttıkça,
- Veri kalitesi arttıkça,
- Meteorolojik veri istasyonları sıklaşıp ölçme güvenilirliği arttıkça,
- Verilerin güncelliği sağlandıkça
- Verilerin çözünürlükleri artıp, veriye ulaşılması kolay hale geldikçe,
- Tarihsel yangın verilerinin kayıtları titizlikle tutulup, geliştirilen modellerle kıyaslandıkça ve
- Modelleme ve doğrulama yöntem ve teknikleri geliştikçe, oluşturulan yangın risk haritalarının sonuç doğruluğu da artacaktır.

KAYNAKÇA

- Abedi Gheshlaghi, H., Feizizadeh, B., & Blaschke, T.** (2020). GIS-based forest fire risk mapping using the analytical network process and fuzzy logic. *Journal of Environmental Planning and Management*, 63(3), 481-499. <https://doi.org/10.1080/09640568.2019.1594726>
- Abid, F.** (2021). A Survey of Machine Learning Algorithms Based Forest Fires Prediction and Detection Systems. İçinde *Fire Technology* (C. 57, Sayı 2, ss. 559-590). Springer. <https://doi.org/10.1007/s10694-020-01056-z>
- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H.** (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11).
- 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(3), 1723-1743. <https://doi.org/10.1007/s11069-012-0450-8>
- Ak, M. M.** (2019). *Manavgat İlçesinin Ekonomik Coğrafyası* [Yüksek Lisans Tezi]. Ondokuz Mayıs Üniversitesi Sosyal Bilimler Enstitüsü.
- Akay, A. E., Erdaş, O., & Karaş, İ. R.** (2006). Sediment Üretimini En Aza İndiren Orman Yolu Güzergâhının Seçiminde CBS Ve Optimizasyon Tekniklerinin Kullanılması. *Uzaktan Algılama-CBS Çalıştayı*, 27, 29.
- Akay, A. E., & Erdoğan, A.** (2017). GIS-Based Multi-Criteria Decision Analysis For Forest Fire Risk Mapping. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-4/W4, 25-30. <https://doi.org/10.5194/isprs-annals-IV-4-W4-25-2017>
- Alkan, M., & Özfidan, F.** (2016). Taşınmaz Değerlemesine Yönelik Coğrafi Bilgi Sistemi Tasarımı ve Uygulaması. *Karaelmas Fen ve Mühendislik Dergisi*, 6(2), 334-344. <https://dergipark.org.tr/en/pub/karaelmasfen/issue/57122/805916>
- Alkayış, M. H., Onur, M. İ., & Karshoğlu, A.** (2022). Muğla İli Menteşe Yöresi Orman Yangını Risk Potansiyeli Haritasının Coğrafi Bilgi Sistemleri ile Belirlenmesi. *Journal*, 7(1), 10-16.
- Altman, N. S.** (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3), 175-185.
- Arca, D.** (2012). Afet Yönetiminde Coğrafi Bilgi Sistemi ve Uzaktan Algılama. *Karaelmas Fen ve Mühendislik Dergisi*, 2(2), 53-61. <https://dergipark.org.tr/en/pub/karaelmasfen/issue/57130/806051>
- Asri, İ., Çorumluoğlu, Ö., & Özdemir, E.** (2015). *CBS Destekli Orman Yangını Risk Dağılım Analizi; Antalya Örneği*. https://www.researchgate.net/publication/319182190_CBS_destekli_Orman_Yangini_Risk_Dagilim_Analizi_Antalya_Ornegi_Forest_Fire_Risk_Analysis_with_GIS_Support_Antalya_Sample

- Atmaca, İ., Pekkan, Ö. I., Özenen Kavlak, M., Tunca, Y. S., Çabuk, S. N., & Derakhshandeh, M.** (2022). Lojistik Regresyon ve Coğrafi Bilgi Sistemleri Kullanılarak Orman Yangını Risk Modellemesi: Muğla-Milas Örneği. *Journal*, 8(1), 66-75. <https://dacd.artvin.edu.tr/tr/download/article-file/1822069>
- Avcı, M., & Korkmaz, M.** (2020). Türkiye’de Orman Yangını Sorunu: Güncel Bazı Konular Üzerine Değerlendirmeler. *Turkish Journal of Forestry | Türkiye Ormancılık Dergisi*, 229-240. <https://doi.org/10.18182/tjf.942706>
- Baltacı, U.** (2021). *Türkiye’de Orman Yangını Riskinin Coğrafi Bilgi Sistemleri Tabanlı Olarak Çok Kriterli Analizi ve Haritalandırılması* [Doktora Tezi]. Gazi Üniversitesi Fen Bilimleri Enstitüsü.
- Baltacı, U., & Yıldırım, F.** (2021). Muğla Orman Bölge Müdürlüğü’nde Orman Yangını Riskinin Çok Kriterli Analizi ve Haritalandırılması. *Journal*, 8(1), 1-11. <https://dergipark.org.tr/en/download/article-file/1019319>
- Barrows, J. S.** (1951). *Fire behavior in northern Rocky Mountain forests*. Hassell Street Press.
- Başçiftçi, F., Durduran, S. savař, & İnal, C.** (2013). Konya Kapalı Havzasında Yeraltı Su Seviyelerinin Coğrafi Bilgi Sistemi (CBS) İle Haritalanması. *Harita Teknolojileri Elektronik Dergisi*, 5(2), 1-15. <https://dergipark.org.tr/en/pub/hartek/issue/7591/99633>
- Bilgili, E.** (2014). *Orman Koruma Dersi Geçici Ders Notları*.
- Bilgili, E., Dinç Durmaz, B., Baysal, İ., Sağlam, B., & Küçük, Ö.** (2010). Doğu Karadeniz Ormanlarında Orman Yangınları. *III. Ulusal Karadeniz Ormancılık Kongresi*.
- Bilgili, E., Küçük, Ö., & Sağlam, B.** (2002). Yangın Davranışının Tahmini ve Yangınlarla Mücadeledeki Önemi. *Kastamonu Orman Fakültesi Dergisi*, 124-134.
- Bozdağ, A., Yavuz, F., & Günay, A. S.** (2016). AHP and GIS based land suitability analysis for Cihanbeyli (Turkey) County. *Environmental Earth Sciences*, 75(9), 813. <https://doi.org/10.1007/s12665-016-5558-9>
- Bozer, R.** (2011). *Coğrafi Ve Meteorolojik Parametrelere Bağlı Olarak Orman Yangının Verdiği Zararın Yapay Zeka Yöntemleriyle Tespiti* [Yüksek Lisans Tezi]. TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü.
- Burgess, R.** (2011). *Development of a spatial, dynamic, fuzzy fire risk model for Chitwan District, Nepal*. ITC: Faculty of Geo-information Science and Earth Observation.
- Butler, B., & Cohen, J.** (1998). Firefighter Safety Zones: A Theoretical Model Based on Radiative Heating. *International Journal of Wildland Fire*, 8, 73-77. <https://doi.org/10.1071/WF9980073>

- Chen, H., Hu, S., Hua, R., & Zhao, X.** (2021). Improved naive Bayes classification algorithm for traffic risk management. *EURASIP Journal on Advances in Signal Processing*, 2021(1), 30. <https://doi.org/10.1186/s13634-021-00742-6>
- Chen, S., Webb, G. I., Liu, L., & Ma, X.** (2020). A novel selective naïve Bayes algorithm. *Knowledge-Based Systems*, 192, 105361. <https://doi.org/https://doi.org/10.1016/j.knosys.2019.105361>
- CIFFC.** (2023). National Fire Situation Report. İçinde *Canadian Interagency Forest Fire Centre*. <https://ciffc.net/situation/>
- Cortes, C., & Vapnik, V.** (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Çapkurt, Z.** (2023). *Coğrafi bilgi sistemi tabanlı destek vektör makineleri ile güneş enerji santrali optimum yer seçimi: Adıyaman örneği.*
- Çelik, Ö.** (2018). A Research on Machine Learning Methods and Its Applications. *Journal of Educational Technology and Online Learning*, 1(3), 25-40. <https://doi.org/10.31681/jetol.457046>
- Çepel, N.** (1975). Orman Yangınlarının Mikroklima ve Toprak Özellikleri Üzerine Yaptığı Etkiler. *İstanbul Üniversitesi Orman Fakültesi Dergisi*.
- Çiftçi, N., Çiftçi, K., & Güngör, M.** (2020). Birleşmiş Milletler İnsani Gelişme Endeksi Verileri Kullanılarak Ülkelerin Sınıflandırılmasının Diskriminant Analizi İle Karşılaştırılması. *Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Dergisi*, 5(1), 163-177. <https://doi.org/10.33905/bseusbed.736439>
- Çoban, H. O., & Erdin, C.** (2020). Forest Fire Risk Assessment Using GIS and AHP Integration in Bucak Forest Enterprise, Turkey. *Applied Ecology and Environmental Research*. https://www.aloki.hu/pdf/1801_15671583.pdf
- 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. <https://doi.org/https://doi.org/10.1016/j.ijdr.2020.101479>
- De Vasconcelos, M. J. P., Silva, S., Tome, M., Alvim, M., & Pereira, J. M. C.** (2001). Spatial prediction of fire ignition probabilities: comparing logistic regression and neural networks. *Photogrammetric engineering and remote sensing*, 67(1), 73-81.
- DeMers, M. N.** (2008). *Fundamentals of Geographical Information Systems*.
- Dengiz, O., & Demirağ Turan, İ.** (2014). Uzaktan Algılama ve Coğrafi Bilgi Sistem Teknikleri Kullanılarak Arazi Örtüsü / Arazi Kullanımı Zamansal Değişimin Belirlenmesi: Samsun Merkez İlçesi Örneği (1984-2011). *Türkiye Tarımsal Araştırmalar Dergisi*, 1(1), 78-90. <https://doi.org/10.19159/tutad.45474>

- Dilekçi, S.** (2019). *Zonguldak ve Ereğli Orman İşletme Müdürlükleri Orman Yangını Risk Alanlarının Belirlenmesi* [Yüksek Lisans Tezi]. Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü.
- Dimuccio, L. A., Ferreira, R., Cunha, L., & de Almeida, A. C.** (2011). Regional forest-fire susceptibility analysis in central Portugal using a probabilistic ratings procedure and artificial neural network weights assignment. *International Journal of Wildland Fire*, 20(6), 776-791.
- Dinç, Y.** (2020). *Karşılaştırmalı Bir Şehir Coğrafyası: Alanya Ve Manavgat Örneği* [Doktora Tezi]. Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Earth data search.** (t.y.). NASA. <https://search.earthdata.nasa.gov/>
- Eker, R., Uçar, Z., Aydın, A., & Alkış, K. C.** (2023). Ormancılıkta Makine Öğrenmesi Kullanımı. *Journal*, 24(2), 150-177.
- Erten, E., Kurgun, V., & Musaoğlu, N.** (2005). *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Kullanarak Orman Yangını Bilgi Sisteminin Kurulması*. https://obs.hkmo.org.tr/show-media/resimler/ekler/NDKO_109_ek.pdf
- Ertuğrul, M.** (2005). Orman Yangınlarının Dünyadaki ve Türkiye'deki Durumu. *Journal*, 7(7), 43-50.
- Ertunç, E., & Çay, T.** (2020). HAVAALANI YER SEÇİMİNDE COĞRAFİ BİLGİ SİSTEMLERİ (CBS) ve ANALİTİK HİYERARŞİ SÜRECİ (AHP) KULLANIMI. *Konya Journal of Engineering Sciences*, 8(2), 200-210. <https://doi.org/10.36306/konjes.590605>
- Escobar, F., Hunter, G., Bishop, I., & Zerger, A.** (2008). Introduction to GIS. *Department of Geomatics, The University of Melbourne, Available online at: <http://www.sli.unimelb.edu.au/gisweb/>* (Accessed 02 April 2008).
- Eskandari, S.** (2017). A new approach for forest fire risk modeling using fuzzy AHP and GIS in Hyrcanian forests of Iran. *Arabian Journal of Geosciences*, 10(8), 190. <https://doi.org/10.1007/s12517-017-2976-2>
- Esri.** (2024). *World Imagery*. Esri, Maxar, Earthstar Geographics, and the GIS User Community. http://goto.arcgisonline.com/maps/World_Imagery
- Eugenio, F. C., dos Santos, A. R., Fiedler, N. C., Ribeiro, G. A., da Silva, A. G., dos Santos, Á. B., Paneto, G. G., & Schettino, V. R.** (2016). Applying GIS to develop a model for forest fire risk: A case study in Espírito Santo, Brazil. *Journal of Environmental Management*, 173, 65-71. <https://doi.org/https://doi.org/10.1016/j.jenvman.2016.02.021>
- FAO.** (2020). Global Forest Resources Assessment 2020. İçinde *Global Forest Resources Assessment 2020*. FAO. <https://doi.org/10.4060/ca9825en>
- Fawcett, T.** (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/https://doi.org/10.1016/j.patrec.2005.10.010>

- Fisher, R. A.** (1936). The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 7(2), 179-188.
- Forest area burned and number of forest fires.** (2023). NFDPA. <http://nfdp.ccfm.org/en/data/fires.php>
- Forman, E. H., & Selly, M. A.** (2001). *Decision by Objectives: How to Convince Others That You are Right* (Sayı 4281). World Scientific Publishing Co. Pte. Ltd. <https://ideas.repec.org/b/wsi/wsbook/4281.html>
- Fradelos, E., Papathanasiou, I., Mitsi, D., Tsaras, K., Kleisiaris, C., & Kourkouta, L.** (2014). Health Based Geographic Information Systems (GIS) and their Applications. *Acta Informatica Medica*, 22, 402-405. <https://doi.org/10.5455/aim.2014.22.402-405>
- Gai, C., Weng, W., & Yuan, H.** (2011). GIS-Based Forest Fire Risk Assessment and Mapping. *2011 Fourth International Joint Conference on Computational Sciences and Optimization*, 1240-1244. <https://doi.org/10.1109/CSO.2011.140>
- Garcia Strino, J., Alhaddad, B., & Roca Cladera, J.** (2007). *Remote Sensing Analysis To Detect Fire Risk Locations*. <https://www.oicrf.org/documents/40950/43224/Remote+sensing+analysis+to+detect+fire+risk+locations.pdf/dc4db28d-bf28-c0b9-3954-afb98c5d362e?t=1510179925558>
- Géron, A.** (2022). *Hands-On Machine Learning With Scikit-Learn, Keras, and TensorFlow*. "O'Reilly Media, Inc."
- Ghorbanzadeh, O., Valizadeh Kamran, K., Blaschke, T., Aryal, J., Naboureh, A., Einali, J., & Bian, J.** (2019). Spatial Prediction of Wildfire Susceptibility Using Field Survey GPS Data and Machine Learning Approaches. *Fire*, 2(3). <https://doi.org/10.3390/fire2030043>
- 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. <https://dergipark.org.tr/en/download/article-file/1023405>
- Gündoğdu, E.** (2023). *Veri madenciliği çerçevesinde yapay sinir ağları ve birliktelik kuralı analizi üzerine Borsa İstanbul 30 endeksinde bir uygulama* [Yüksek Lisans Tezi]. Bursa Uludağ Üniversitesi Sosyal Bilimler Enstitüsü.
- Güngör, İ., & İşler, D. B.** (2005). ANALİTİK HİYERARŞİ YAKLAŞIMI İLE OTOMOBİL SEÇİMİ. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 1(2), 21-33. <https://dergipark.org.tr/tr/pub/ijmeb/issue/54839/750850>
- Hacısalıhoğlu, M.** (2018). *Çok Kriterli Karar Analizi ile Orman Yangını Risk Haritalarının Oluşturulması: Karabük Örneği* [Yüksek Lisans Tezi]. Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü.
- HISTORY & MAJOR FIRES.** (2023). CFA. <https://www.cfa.vic.gov.au/about-us/history-major-fires/major-fires>

- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X.** (2013). *Applied Logistic Regression*. Wiley. <https://books.google.com.tr/books?id=bRoxQBIZRd4C>
- Hossin, M., & Sulaiman, M. N.** (2015). A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2), 1.
- How Fire Behaves.** (2023). CFA. <https://www.cfa.vic.gov.au/plan-prepare/am-i-at-risk/how-fire-behaves>
- İncecik, S., & Daylan, B. E. G.** (2002). İstanbul’ da coğrafi bilgi sistemleri ile hava kalitesinin incelenmesi. *İTÜ Dergisi Seri D: Mühendislik*, 1(2), 51-62. <http://search/yayin/detay/32099>
- ISDR.** (2000). Wildfire Prevention in Australia. *Emergency Management Australia in conjunction with the Australasian Fire Authorities Council and Country Fire*. https://www.unisdr.org/2000/campaign/PDF/Articulo_6_Australia_eng.pdf
- Jackins, V., Vimal, S., Kaliappan, M., & Lee, M. Y.** (2021). AI-based smart prediction of clinical disease using random forest classifier and Naive Bayes. *The Journal of Supercomputing*, 77(5), 5198-5219. <https://doi.org/10.1007/s11227-020-03481-x>
- Jain, P., Coogan, S. C. P., Subramanian, S. G., Crowley, M., Taylor, S., & Flannigan, M. D.** (2020). A review of machine learning applications in wildfire science and management. *Environmental Reviews*, 28(4), 478-505. <https://doi.org/10.1139/er-2020-0019>
- Jaiswal, R. K., Mukherjee, S., Raju, K. D., & Saxena, R.** (2002). Forest fire risk zone mapping from satellite imagery and GIS. *International Journal of Applied Earth Observation and Geoinformation*, 4(1), 1-10. [https://doi.org/https://doi.org/10.1016/S0303-2434\(02\)00006-5](https://doi.org/https://doi.org/10.1016/S0303-2434(02)00006-5)
- Jones, H. G., & Vaughan, R. A.** (2010). *Remote sensing of vegetation: principles, techniques, and applications*. Oxford University Press, USA.
- Kant Sharma, L., Kanga, S., Singh Nathawat, M., Sinha, S., & Chandra Pandey, P.** (2012). Fuzzy AHP for forest fire risk modeling. *Disaster Prevention and Management: An International Journal*, 21(2), 160-171. <https://doi.org/10.1108/09653561211219964>
- Kantarcioglu, O., Kocaman, S., & Schindler, K.** (2023). Artificial Neural Networks For Assessing Forest Fire Susceptibility in Türkiye. *Ecological Informatics*, 75, 102034. <https://doi.org/https://doi.org/10.1016/j.ecoinf.2023.102034>
- Karabulut, M., Karakoç, A., Gürbüz, M., & Kızılelma, Y.** (2013). *Coğrafi Bilgi Sistemleri Kullanarak Başkonuş Dağında (Kahramanmaraş)Orman Yangını Risk Alanlarının Belirlenmesi*. https://www.researchgate.net/publication/269392574_Cografi_Bilgi_Sistemleri_Kullanarak_Baskonus_Daginda_Kahramanmaras_Orman_Yangini_Risk_Alan_larinin_Belirlenmesi

- Karadeniz, E.** (2020). *Urla Yarımadası Güneydoğusunda (Seferihisar-Menderes) Orman Yangını Risk Modellemesi ve Yangın Simülasyonu* [Yüksek Lisans Tezi]. Fırat Üniversitesi Sosyal Bilimler Enstitüsü.
- Kargı, V. S. A.** (2013). *Yapay sinir ağ modelleri ve bir tekstil firmasında uygulama* [Yüksek Lisans Tezi]. Uludağ Üniversitesi Sosyal Bilimler Enstitüsü.
- Kaynar, O., & Taştan, S.** (2009). Zaman Serisializinde Mlp Yapay Sinir Ağları Ve Arima Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161-172.
- Kumar, Y., Kaur, K., & Singh, G.** (2020). Machine Learning Aspects and its Applications Towards Different Research Areas. *2020 International Conference on Computation, Automation and Knowledge Management (ICCAKM)*, 150-156. <https://doi.org/10.1109/ICCAKM46823.2020.9051502>
- Küçük, Ö., & Bilgili, E.** (2006). Coğrafi Bilgi Sistemleri (CBS) Yardımıyla Yangın Davranışının Uygulamaya Aktarılması: Kastamonu Örneği. *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, 6(2), 262-273.
- Küçük, Ö., Bilgili, E., Durmaz, B. D., Sağlam, B., & Baysal, İ.** (2009). Örtü Yangınının Tepe Yangınına Geçişinde Etkili Olan Faktörler. *Kastamonu University Journal of Forestry Faculty*, 9(2), 80-85. <https://dergipark.org.tr/tr/pub/kastorman/issue/17239/180095>
- Küçük, Ö., & Sağlam, B.** (2004). Orman Yangınları ve Hava Halleri. *Kastamonu Orman Fakültesi Dergisi*, 220-231. https://www.researchgate.net/profile/Buelent-Saglam/publication/292656219_Orman_Yanginlari_ve_Hava_Halleri_Forest_Fires_and_Fire_Weather/links/56b09b5308ae9ea7c3b0fbfb/Orman-Yanginlari-ve-Hava-Halleri-Forest-Fires-and-Fire-Weather.pdf
- Küçükosmanoğlu, A.** (1990). Kızılçam-Orman Yangınları İlişkisi. *İstanbul Üniversitesi Orman Fakültesi Dergisi*.
- Küçükosmanoğlu, A.** (1993). Türkiye Orman Yangınlarına Ait Bazı Verilerin Değerlendirilmesi. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, 43(1-2), 85-102.
- Küçükosmanoğlu, A.** (1994). Ülkemizde Orman Yangınları ve Yangın Sezonları. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, 44(1-2), 123-124.
- Leite, F., Bento-Gonçalves, A., Vieira, A., & da Vinha, L.** (2015). *Mega-fires around the world: A literature review* (ss. 15-33). https://www.researchgate.net/profile/Jackson-Leonard/publication/296939300_Wildland_fire_Impacts_on_forest_woodland_and_grassland_ecological_processes/links/5d64738fa6fdccc32cd30884/Wildland-fire-Impacts-on-forest-woodland-and-grassland-ecological-processes.pdf
- Ma, W., Feng, Z., Cheng, Z., Chen, S., & Wang, F.** (2020). Identifying Forest Fire Driving Factors and Related Impacts in China Using Random Forest Algorithm. *Forests*, 11(5). <https://doi.org/10.3390/f11050507>

- Manavgat.** (2023). Wikipedia. <https://tr.wikipedia.org/wiki/Manavgat>
- Manavgat OİM Yangın Yönetim Planı.** (2019). <https://www.ogm.gov.tr/tr/e-kutuphane-sitesi/YanginYonetimPlanlari/AntalyaOBM-Manavgat%20Yang%C4%B1n%20Y%C3%B6netim%20Plan%C4%B1.pdf>
- Mandrekar, J. N.** (2010). Receiver Operating Characteristic Curve in Diagnostic Test Assessment. *Journal of Thoracic Oncology*, 5(9), 1315-1316. <https://doi.org/https://doi.org/10.1097/JTO.0b013e3181ec173d>
- Maniatis, Y., Doganis, A., & Chatzigeorgiadis, M.** (2022). Fire Risk Probability Mapping Using Machine Learning Tools and Multi-Criteria Decision Analysis in the GIS Environment: A Case Study in the National Park Forest Dadia-Lefkimi-Soufli, Greece. *Applied Sciences*, 12(6). <https://doi.org/10.3390/app12062938>
- Maser, C.** (1989). *Forest Primeval: The Natural History of an Ancient Forest*. Sierra Club Books.
- Mitchell, T. M.** (1997). *Machine Learning*. McGraw-Hill. <https://books.google.com.tr/books?id=EoYBngEACAAJ>
- ModelBuilder Vocabulary.** (2023). ESRI. <https://pro.arcgis.com/en/pro-app/3.1/help/analysis/geoprocessing/modelbuilder/modelbuilder-vocabulary.htm>
- Mohajane, M., Costache, R., Karimi, F., Bao Pham, Q., Essahlaoui, A., Nguyen, H., Laneve, G., & Oudija, F.** (2021). Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecological Indicators*, 129, 107869. <https://doi.org/10.1016/J.ECOLIND.2021.107869>
- Mohri, M., Rostamizadeh, A., & Talwalkar, A.** (2018). *Foundations of machine learning*. MIT press.
- Morova, N., Şener, E., Terzi, S., Beyhan, M., & Harman, B.** (2014). Süleyman Demirel Üniversitesi Yerleşkesinin Gürültü Haritalarının Coğrafi Bilgi Sistemleri ile Hazırlanması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(3), 271-278. <https://doi.org/10.19113/sdufbed.72954>
- Muhammad, A., Khloud K, A., Salma A, S., Samar O, A., Mashael E, A., Maram A, A., & Maryam, A.** (2021). Role of Machine Learning Algorithms in Forest Fire Management: A Literature Review. *Journal of Robotics and Automation*, 5(1). <https://doi.org/10.36959/673/372>
- Naderpour, M., Rizeei, H. M., Khakzad, N., & Pradhan, B.** (2019). Forest fire induced Natech risk assessment: A survey of geospatial technologies. *Reliability Engineering & System Safety*, 191, 106558. <https://doi.org/https://doi.org/10.1016/j.res.2019.106558>
- Nikhil, S., Danumah, J. H., Saha, S., Prasad, M. K., Rajaneesh, A., Mammen, P. C., Ajin, R. S., & Kuriakose, S. L.** (2021). Application of GIS and AHP

Method in Forest Fire Risk Zone Mapping: a Study of the Parambikulam Tiger Reserve, Kerala, India. *Journal of Geovisualization and Spatial Analysis*, 5(1), 14. <https://doi.org/10.1007/s41651-021-00082-x>

Nuthammachot, N., & Stratoulis, D. (2021). Multi-criteria decision analysis for forest fire risk assessment by coupling AHP and GIS: method and case study. *Environment, Development and Sustainability*, 23(12), 17443–17458. <https://doi.org/10.1007/s10668-021-01394-0>

OGM. (t.y.). *Orman Varlığı*. Orman Genel Müdürlüğü. Geliş tarihi 06 Ocak 2024, gönderen <https://www.ogm.gov.tr/antalyaobm/ormanlarimiz/orman-varligi>

OGM. (2021). *Türkiye Orman Varlığı*. <https://www.ogm.gov.tr/tr/ormanlarimiz-sitesi/TurkiyeOrmanVarligi/Yayinlar/2020%20T%C3%BCrkiye%20Orman%20Varl%C4%B1%C4%9F%C4%B1.pdf>

OGM. (2022). *Ormancılık İstatistikleri*. Orman Genel Müdürlüğü. <https://www.ogm.gov.tr/tr/e-kutuphane/resmi-istatistikler>

OGM. (2024). *Orman Genel Müdürlüğü 2023 Yılı Faaliyet Raporu*.

Ojha, V. K., Abraham, A., & Snášel, V. (2017). Metaheuristic design of feedforward neural networks: A review of two decades of research. *Engineering Applications of Artificial Intelligence*, 60, 97-116. <https://doi.org/https://doi.org/10.1016/j.engappai.2017.01.013>

Orman Yangınlarının Önlenmesi ve Söndürülmesinde Uygulama Esasları: Tebliğ No: 285. (1995). OGM. <https://www.ogm.gov.tr/tr/e-kutuphane/mevzuat/tebligler>

Ozdemir, M. S., & Saaty, T. L. (2006). The unknown in decision making: What to do about it. *European Journal of Operational Research*, 174(1), 349-359. <https://doi.org/https://doi.org/10.1016/j.ejor.2004.12.017>

Özelkan, E. (2008). *Uydu Görüntüleri Kullanarak Yangın Riski Değerlendirilmesi Kaş Örneği* [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Bilişim Enstitüsü]. <http://hdl.handle.net/11527/12276>

Özenen Kavlak, M., Kurtipek, A., & Çabuk, S. (2020). *Coğrafi Bilgi Sistemleri ile Orman Yangını Risk Haritası Oluşturulması: Ören Örneği*. 4, 33-54. <https://doi.org/10.32569/resilience.597887>

Özmen, S. (2010). *İstanbul İli Yangın Riski Analizi Ve Yangın Riski Haritalarının Oluşturulması* [Yüksek Lisans Tezi]. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.

Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-i Vekayi*, 6(2), 25-36. <https://dergipark.org.tr/en/pub/takvim/issue/40063/427526>

Özyazıcı, M. A., Dengiz, O., & İmamoğlu, A. (2014). Siirt İli Bazı Arazi ve Toprak Özelliklerinin Coğrafi Bilgi Sistem Analizleriyle Değerlendirilmesi. *Türkiye*

Tarımsal Araştırmalar Dergisi, 1(2), 128-137.
<https://doi.org/10.19159/tutad.67391>

Özyörük, Yrd.Doç.Dr.Bahar, & Özcan, E. C. (2008). ANALİTİK HİYERARŞİ SÜRECİNİN TEDARİKÇİ SEÇİMİNDE UYGULANMASI: OTOMOTİV SEKTÖRÜNDEN BİR ÖRNEK. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 13(1), 133-144.
<https://dergipark.org.tr/tr/pub/sduibfd/issue/20834/223215>

Peker, H., & Atılğan, A. (2015). Doğal Bir Enerji Kaynağı Odun: Yanma Özelliği ve Koruma Yöntemleri. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*.

Perry, D. G. (1990). *Wildland Firefighting : Fire Behavior, Tactics and Command*. Fire Publications.

Pham, B. T., Jaafari, A., Avand, M., Al-Ansari, N., Du, T. D., Hai Yen, H. P., Phong, T. Van, Nguyen, D. H., Van Le, H., Mafi-Gholami, D., Prakash, I., Thuy, H. T., & Tuyen, T. T. (2020). Performance evaluation of machine learning methods for forest fire modeling and prediction. *Symmetry*, 12(6).
<https://doi.org/10.3390/SYM12061022>

Plummer, F. G. (1912). *Forest Fires: Their Causes, Extent, and Effects, with a Summary of Recorded Destruction and Loss*. U.S. Department of Agriculture, Forest Service. <https://books.google.com.tr/books?id=3FcDAAAYAAJ>

Pourghasemi, H. R., Gayen, A., Lasaponara, R., & Tiefenbacher, J. P. (2020). Application of learning vector quantization and different machine learning techniques to assessing forest fire influence factors and spatial modelling. *Environmental Research*, 184, 109321.
<https://doi.org/10.1016/J.ENVRES.2020.109321>

Pourghasemi, H. reza, Beheshtirad, M., & Pradhan, B. (2016). A comparative assessment of prediction capabilities of modified analytical hierarchy process (M-AHP) and Mamdani fuzzy logic models using Netcad-GIS for forest fire susceptibility mapping. *Geomatics, Natural Hazards and Risk*, 7(2), 861-885.
<https://doi.org/10.1080/19475705.2014.984247>

Pourtaghi, Z. S., Pourghasemi, H. R., & Rossi, M. (2015). Forest fire susceptibility mapping in the Minudasht forests, Golestan province, Iran. *Environmental Earth Sciences*, 73(4), 1515-1533.
<https://doi.org/10.1007/s12665-014-3502-4>

Ray, S. (2019). A Quick Review of Machine Learning Algorithms. 2019 *International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, 35-39.
<https://doi.org/10.1109/COMITCon.2019.8862451>

Rayfield, J. A. (1997). Tragedy in the Chicago Fire and Triumph in the Architectural Response. *Northern Illinois University Library*.

- Ricciardi, C., Valente, A. S., Edmund, K., Cantoni, V., Green, R., Fiorillo, A., Picone, I., Santini, S., & Cesarelli, M.** (2020). Linear discriminant analysis and principal component analysis to predict coronary artery disease. *Health Informatics Journal*, 26(3), 2181-2192.
<https://doi.org/10.1177/1460458219899210>
- Romero-Calcerrada, R., Novillo, C. J., Millington, J. D. A., & Gomez-Jimenez, I.** (2008). GIS analysis of spatial patterns of human-caused wildfire ignition risk in the SW of Madrid (Central Spain). *Landscape Ecology*, 23(3), 341-354.
<https://doi.org/10.1007/s10980-008-9190-2>
- Rothermel, R. C.** (1972). A mathematical model for predicting fire spread in wildland fuels. *U.S. Department of Agriculture*.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J.** (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Russell, S., & Norvig, P.** (2020). *Artificial Intelligence: A Modern Approach (Fourth Edition)*. Pearson.
- Saaty, R. W.** (1987). The analytic hierarchy process—what it is and how it is used. *Mathematical Modelling*, 9(3), 161-176.
[https://doi.org/https://doi.org/10.1016/0270-0255\(87\)90473-8](https://doi.org/https://doi.org/10.1016/0270-0255(87)90473-8)
- Saaty, T.** (2008). Decision making with the Analytic Hierarchy Process. *Int. J. Services Sciences Int. J. Services Sciences*, 1, 83-98.
<https://doi.org/10.1504/IJSSCI.2008.017590>
- Saaty, T. L.** (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234-281.
[https://doi.org/https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/https://doi.org/10.1016/0022-2496(77)90033-5)
- Saaty, T. L.** (1980). The analytic hierarchy process (AHP). *The Journal of the Operational Research Society*, 41(11), 1073-1076.
- Saaty, T. L.** (1986). Axiomatic Foundation of the Analytic Hierarchy Process. *Management Science*, 32(7), 841-855. <http://www.jstor.org/stable/2631765>
- Saaty, T. L.** (1990). How to make a decision: The analytic hierarchy process. *European Journal of Operational Research*, 48(1), 9-26.
[https://doi.org/https://doi.org/10.1016/0377-2217\(90\)90057-I](https://doi.org/https://doi.org/10.1016/0377-2217(90)90057-I)
- Saaty, T., & Sagir Ozdemir, M.** (2003). Why the magic number seven plus or minus two. *Mathematical and Computer Modelling*, 38, 233-244.
[https://doi.org/10.1016/S0895-7177\(03\)90083-5](https://doi.org/10.1016/S0895-7177(03)90083-5)
- Santiago, I. T. F., & Kheladze, N.** (2011). *GIS Wildland Fire Hazard Modeling in Georgia*.
- Saplıoğlu, M., & Karaşahin, M.** (2006). COĞRAFİ BİLGİ SİSTEMİ YARDIMI İLE ISPARTA İLİ KENTİÇİ TRAFİK KAZA ANALİZİ. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 12(3), 321-332.
<https://dergipark.org.tr/en/pub/pajes/issue/20521/218519>

- Sari, F.** (2021). Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla, Turkey: A comparative analysis of VIKOR and TOPSIS. *Forest Ecology and Management*, 480, 118644.
<https://doi.org/https://doi.org/10.1016/j.foreco.2020.118644>
- Sarker, I. H.** (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2(3), 160.
<https://doi.org/10.1007/s42979-021-00592-x>
- Satır, O.** (2011). *Dağlık Arazide Coğrafi Bilgi Sisteminden Yararlanarak Çevreye Duyarlı Orman Yolu Güzergahının Belirlenmesi* [Yüksek Lisans Tezi]. Artvin Çoruh Üniversitesi.
- Sayısal meşcere haritaları.** (2021). OGM.
- Scholl, A., Manthey, L., Helm, R., & Steiner, M.** (2005). Solving multiattribute design problems with analytic hierarchy process and conjoint analysis: An empirical comparison. *European Journal of Operational Research*, 164(3), 760-777. <https://doi.org/https://doi.org/10.1016/j.ejor.2004.01.026>
- Sepetçi, V.** (2014). *Coğrafi Bilgi Sistemi Yardımıyla Orman Yangınlarına İlk Müdahale Sürelerinin Değerlendirilmesi* [Yüksek Lisans Tezi]. Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü.
- Servi, T., & Erişoğlu, Ü.** (2020). Türkiye'deki Şehirlerin Sosyo-Ekonomik Gelişmişlik Düzeylerinin İstatistiksel Analizi. *Al Farabi Uluslararası Sosyal Bilimler Dergisi*, 5(2), 174-186.
<https://dergipark.org.tr/en/pub/farabi/issue/55179/757747>
- Shao, Y., Feng, Z., Sun, L., Yang, X., Li, Y., Xu, B., & Chen, Y.** (2022). Mapping China's Forest Fire Risks with Machine Learning. *Forests*, 13(6).
<https://doi.org/10.3390/f13060856>
- Shinde, P. P., & Shah, S.** (2018). A Review of Machine Learning and Deep Learning Applications. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, 1-6.
<https://doi.org/10.1109/ICCUBEA.2018.8697857>
- Singh, A., Thakur, N., & Sharma, A.** (2016). A review of supervised machine learning algorithms. *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, 1310-1315.
- Sivrikaya, F., Keleş, S., & Çakır, G.** (2007). Spatial Distribution and Temporal Change of Carbon Storage in Timber Biomass of Two Different Forest Management Units. *Environmental Monitoring and Assessment*, 132(1), 429-438. <https://doi.org/10.1007/s10661-006-9545-6>
- Sivrikaya, F., & Küçük, Ö.** (2022). Modeling forest fire risk based on GIS-based analytical hierarchy process and statistical analysis in Mediterranean region. *Ecological Informatics*, 68, 101537.
<https://doi.org/https://doi.org/10.1016/j.ecoinf.2021.101537>


- Sivrikaya, F., Sağlam, B., Akay, A., & Bozali, N.** (2014). Evaluation of Forest Fire Risk with GIS. *Polish Journal of Environmental Studies*, 23, 187-194.
https://www.researchgate.net/publication/288597149_Evaluation_of_Forest_Fire_Risk_with_GIS
- Susam, T., Karaman, S., & Öztekin, T.** (2006). Yüzey Suları Coğrafi Bilgi Sistemi; Tokat İli Örneği. *Journal of Agricultural Faculty of Gaziosmanpaşa University (JAFAG)*, 2006(1).
<https://dergipark.org.tr/en/pub/gopzfd/issue/7340/96038>
- Şahin, E. K.** (2012). *CBS tabanlı çok kriterli karar analizi yöntemi kullanılarak heyelan duyarlılık haritasının üretilmesi: Trabzon ili örneği* [Yüksek Lisans Tezi]. Gebze Yüksek Teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü.
- Şahin, K.** (2006). *Orman Yangınlarının İnternet Ortamında İnteraktif Olarak Sunumu* [Yüksek Lisans Tezi]. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Şahin, U.** (2019, Mart 27). *ArcGIS Pro'da ModelBuilder'la Çalışmak*. Esri Türkiye.
<https://blog.esri.com.tr/arcgis-proda-modelbuilderla-calismak/>
- Şen, Z.** (2004). *Yapay Sinir Ağları*. Su Vakfı.
<https://books.google.com.tr/books?id=4CliEAAAQBAJ>
- Tağıl, Ş., & Cürebal, İ.** (2005). Altınova Sahilinde Kıyı Çizgisi Değişimini Belirlemede Uzaktan Algılama ve Coğrafi Bilgi Sistemleri. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 15(2), 51-68. <http://search/yayin/detay/50473>
- Tehrany, M. S., Jones, S., Shabani, F., Martínez-Álvarez, F., & Tien Bui, D.** (2019). A novel ensemble modeling approach for the spatial prediction of tropical forest fire susceptibility using LogitBoost machine learning classifier and multi-source geospatial data. *Theoretical and Applied Climatology*, 137(1), 637-653. <https://doi.org/10.1007/s00704-018-2628-9>
- Teie, W. C.** (1997). *Fire Officer's handbook on wildland firefighting*. Deer Valley Press.
- Teketay, D.** (2000). Vegetation Types and Forest Fire Management in Ethiopia. *Proceedings of the Round Table Conference on Forest Fire in Ethiopia*, 1-35.
https://www.researchgate.net/publication/312474775_Vegetation_Types_and_Forest_Fire_Management_in_Ethiopia
- Tezcan, B., & Eren, T.** (2023). Orman Yangınına Sebep Olan Kriterlerin Bulanık Ortamda Değerlendirilmesi. *Journal*, 1.
<https://doi.org/https://doi.org/10.2339/politeknik.1138806>
- Thill, J.-C.** (2000). Geographic information systems for transportation in perspective. *Transportation Research Part C: Emerging Technologies*, 8(1), 3-12. [https://doi.org/https://doi.org/10.1016/S0968-090X\(00\)00029-2](https://doi.org/https://doi.org/10.1016/S0968-090X(00)00029-2)

- Thomas Ambadan, J., Oja, M., Gedalof, Z., & Berg, A. A.** (2020). Satellite-Observed Soil Moisture as an Indicator of Wildfire Risk. *Remote Sensing*, 12(10). <https://doi.org/10.3390/rs12101543>
- Tien Bui, D., Le, H. Van, & Hoang, N. D.** (2018). GIS-based spatial prediction of tropical forest fire danger using a new hybrid machine learning method. *Ecological Informatics*, 48, 104-116. <https://doi.org/10.1016/J.ECOINF.2018.08.008>
- Ünal, Ö. F.** (2011). ANALİTİK HİYERARŞİ PROSESİ VE PERSONEL SEÇİMİ ALANINDA UYGULAMALARI. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 3(2), 18-38. <https://dergipark.org.tr/tr/pub/uaifd/issue/21592/231845>
- Van Hoang, T., Chou, T. Y., Fang, Y. M., Nguyen, N. T., Nguyen, Q. H., Xuan Canh, P., Ngo Bao Toan, D., Nguyen, X. L., & Meadows, M. E.** (2020). Mapping Forest Fire Risk and Development of Early Warning System for NW Vietnam Using AHP and MCA/GIS Methods. *Applied Sciences*, 10(12). <https://doi.org/10.3390/app10124348>
- Vapnik, V. N., & Vapnik, V.** (1998). *Statistical learning theory*. Hoboken, NJ, USA:Wiley
- Vargas, L. G.** (1990). An overview of the analytic hierarchy process and its applications. *European Journal of Operational Research*, 48(1), 2-8. [https://doi.org/https://doi.org/10.1016/0377-2217\(90\)90056-H](https://doi.org/https://doi.org/10.1016/0377-2217(90)90056-H)
- Vieira, A., Gonçalves, A. B., Martins, C. O., Leite, F. F., & Mendes, L.** (2011). *Geographical Information Technology to support research on forest fires and soil erosion*.
- Walczak, S.** (2019). Artificial neural networks. İçinde *Advanced methodologies and technologies in artificial intelligence, computer simulation, and human-computer interaction* (ss. 40-53). IGI global.
- Wei, W.** (2012). Research on the Application of Geographic Information System in Tourism Management. *Procedia Environmental Sciences*, 12, 1104-1109. <https://doi.org/https://doi.org/10.1016/j.proenv.2012.01.394>
- WFOA.** (2022). *10 Largest Wildfires in U.S. History*. Western Fire Chiefs Association.
- Wildfires and Acres.** (2022). NIFC. <https://www.nifc.gov/fire-information/statistics/wildfires>
- Yang, F.-J.** (2018). An Implementation of Naive Bayes Classifier. 2018 *International Conference on Computational Science and Computational Intelligence (CSCI)*, 301-306. <https://doi.org/10.1109/CSCI46756.2018.00065>
- Yangının Acı Bilançosu.** (2021). <https://www.dha.com.tr/gundem/yanginin-aci-bilancosu-60-bin-hektar-kul-oldu-en-az-1-milyar-tl-lik-maddi-kayip-1841548>

- Yavuz, M., & Sağlam, B.** (2012). Uzaktan Algılama ve Coğrafi Bilgi Sistemlerinin Orman Yangınlarında Kullanılması. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 1, 235-242.
- Yıldırım, O.** (2023). *Makine Öğrenmesi Yöntemleriyle Orman Yangını Tahmini* [Yüksek Lisans Tezi]. Atatürk Üniversitesi.
- Yomralıoğlu, T.** (2005). *Coğrafi bilgi sistemleri: Temel kavramlar ve uygulamalar*. Karadeniz Teknik Üniversitesi.
- You, W., Lin, L., Wu, L., Ji, Z., Yu, J., Zhu, J., Fan, Y., & He, D.** (2017). Geographical information system-based forest fire risk assessment integrating national forest inventory data and analysis of its spatiotemporal variability. *Ecological Indicators*, 77, 176-184.
<https://doi.org/https://doi.org/10.1016/j.ecolind.2017.01.042>
- Yüksel, A., Akay, A. E., & Gundogan, R.** (2008). Using ASTER Imagery in Land Use/Cover Classification of Eastern Mediterranean Landscapes According to CORINE Land Cover Project. *Sensors*, 8(2), 1237-1251.
<https://doi.org/10.3390/s8021287>
- Zainalabden, T. I. A.** (2022). *Çok Kriterli Karar Analizi ile Oluşturulan Orman Yangını Risk Haritalarının Gerçekleşen Orman Yangınları ile Karşılaştırılması (Manavgat Örneği)* [Yüksek Lisans Tezi]. Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü.
- Zeke, W. M.** (2019). *Wildfire Hazard Mapping using GIS-MCDA and Frequency Ratio Models: A Case Study in Eight Counties of Norway*. <http://hig.diva-portal.org/smash/record.jsf?pid=diva2%3A1382747&dswid=2280>
- Zhu, F., Gao, J., Yang, J., & Ye, N.** (2022). Neighborhood linear discriminant analysis. *Pattern Recognition*, 123, 108422.
<https://doi.org/https://doi.org/10.1016/j.patcog.2021.108422>

EKLER

EK-1: İş akış şeması



EK-2: CBS ortamında kurulan modelin arka planı



EK-3: Genel ağırlıklar tablosu

Ana kriterler	Lit. ağırlığı	AHP ağırlığı	Alt kriter	Lit. ağırlığı 1	AHP ağırlığı 1	Sınıflar	Risk derecesi
Topoğrafik	20.17	7.69	Yükseklik	3.83	0.83	<500	Çok yüksek
Topoğrafik	20.17	7.69	Yükseklik	3.83	0.83	500-1000	Normal
Topoğrafik	20.17	7.69	Yükseklik	3.83	0.83	1000-1500	Normal
Topoğrafik	20.17	7.69	Yükseklik	3.83	0.83	1500>	Düşük
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	0-45	Düşük
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	45-90	Normal
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	90-135	Normal
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	135-180	Çok yüksek
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	180-225	Çok yüksek
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	225-270	Yüksek
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	270-315	Yüksek
Topoğrafik	20.17	7.69	Bakı	8.54	4.21	315-360	Düşük
Topoğrafik	20.17	7.69	Eğim	7.80	2.65	<5	Çok düşük
Topoğrafik	20.17	7.69	Eğim	7.80	2.65	5-10	Düşük
Topoğrafik	20.17	7.69	Eğim	7.80	2.65	10-25	Normal
Topoğrafik	20.17	7.69	Eğim	7.80	2.65	25-35	Yüksek
Topoğrafik	20.17	7.69	Eğim	7.80	2.65	35-50	Çok yüksek
Topoğrafik	20.17	7.69	Eğim	7.80	2.65	50>	Çok yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kızılçam	Çok yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Ziraat	Yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	İskân	Yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Orman Toprağı	Çok düşük

Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Su	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Ocak	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Elektrik Hattı	Yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Saçlı Meşe	Düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Ardıç	Normal
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Maki	Normal
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	İzin Verilmiş Alanlar	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Mezarlıklar	Yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kum	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Fıstık Çamı	Normal
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kızılçam ve Harnup	Düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kızılçam ve Defne	Düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kızılçam ve Saçlı Meşe	Normal
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kadastro Dışı Alanlar	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Diğer Alanlar	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Yangın Durdurma Zonu	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Defne	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Karaçam	Çok yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Karaçam ve Kızılçam	Yüksek
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Karaçam ve Sedir	Düşük

Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Gökmar	Normal
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Kızılçam ve Servi	Düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Gökmar ve Sedir	Düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Taşlık	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Çınar	Çok düşük
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Sedir	Normal
Biyolojik	30.83	36.97	Arazi örtüsü	14.84	19.95	Karaçam ve Gökmar	Düşük
Biyolojik	30.83	36.97	Meşcere kapallılığı	7.99	6.04	Boşluklu kapalı	Düşük
Biyolojik	30.83	36.97	Meşcere kapallılığı	7.99	6.04	Gevşek kapalı	Normal
Biyolojik	30.83	36.97	Meşcere kapallılığı	7.99	6.04	Orta kapalı	Yüksek
Biyolojik	30.83	36.97	Meşcere kapallılığı	7.99	6.04	Tam kapalı	Çok yüksek
Biyolojik	30.83	36.97	Gelişme çağları	8.01	10.98	Gençlik ve sıklık	Çok yüksek
Biyolojik	30.83	36.97	Gelişme çağları	8.01	10.98	Sırlıklık ve direklik	Çok yüksek
Biyolojik	30.83	36.97	Gelişme çağları	8.01	10.98	İnce ağaçlık	Çok yüksek
Biyolojik	30.83	36.97	Gelişme çağları	8.01	10.98	Orta ve kalın ağaçlık	Yüksek
Biyolojik	30.83	36.97	Gelişme çağları	8.01	10.98	Boş veya boşaltılmış orman	Çok düşük
Meteorolojik	31.63	19.31	Sıcaklık	7.13	7.59	<10	Düşük
Meteorolojik	31.63	19.31	Sıcaklık	7.13	7.59	10-15	Düşük
Meteorolojik	31.63	19.31	Sıcaklık	7.13	7.59	15-20	Normal
Meteorolojik	31.63	19.31	Sıcaklık	7.13	7.59	20-25	Yüksek

Meteorolojik	31.63	19.31	Sıcaklık	7.13	7.59	25>	Çok yüksek
Meteorolojik	31.63	19.31	Nem	9.62	2.59	<30	Çok yüksek
Meteorolojik	31.63	19.31	Nem	9.62	2.59	30-40	Çok yüksek
Meteorolojik	31.63	19.31	Nem	9.62	2.59	40-50	Yüksek
Meteorolojik	31.63	19.31	Nem	9.62	2.59	50-60	Normal
Meteorolojik	31.63	19.31	Nem	9.62	2.59	60>	Düşük
Meteorolojik	31.63	19.31	Rüzgâr şiddeti	4.21	5.19	<1	Düşük
Meteorolojik	31.63	19.31	Rüzgâr şiddeti	4.21	5.19	1-2	Düşük
Meteorolojik	31.63	19.31	Rüzgâr şiddeti	4.21	5.19	2-3	Normal
Meteorolojik	31.63	19.31	Rüzgâr şiddeti	4.21	5.19	3>	Çok yüksek
Meteorolojik	31.63	19.31	Yağış	10.67	3.93	<30	Çok yüksek
Meteorolojik	31.63	19.31	Yağış	10.67	3.93	30-60	Çok yüksek
Meteorolojik	31.63	19.31	Yağış	10.67	3.93	60-90	Yüksek
Meteorolojik	31.63	19.31	Yağış	10.67	3.93	90-120	Normal
Meteorolojik	31.63	19.31	Yağış	10.67	3.93	120>	Çok düşük
İnsan	17.38	36.03	Yollara uzaklık	7.11	17.78	<100	Çok yüksek
İnsan	17.38	36.03	Yollara uzaklık	7.11	17.78	100-200	Yüksek
İnsan	17.38	36.03	Yollara uzaklık	7.11	17.78	200-300	Normal
İnsan	17.38	36.03	Yollara uzaklık	7.11	17.78	300-400	Düşük
İnsan	17.38	36.03	Yollara uzaklık	7.11	17.78	400>	Çok düşük
İnsan	17.38	36.03	Yerleşime uzaklık	5.71	11.20	<200	Çok yüksek

İnsan	17.38	36.03	Yerleşime uzaklık	5.71	11.20	200-500	Yüksek
İnsan	17.38	36.03	Yerleşime uzaklık	5.71	11.20	500-1000	Normal
İnsan	17.38	36.03	Yerleşime uzaklık	5.71	11.20	1000-2000	Düşük
İnsan	17.38	36.03	Yerleşime uzaklık	5.71	11.20	2000>	Çok düşük
İnsan	17.38	36.03	Tarıma uzaklık	4.56	7.05	<200	Çok yüksek
İnsan	17.38	36.03	Tarıma uzaklık	4.56	7.05	200-500	Yüksek
İnsan	17.38	36.03	Tarıma uzaklık	4.56	7.05	500-1000	Normal
İnsan	17.38	36.03	Tarıma uzaklık	4.56	7.05	1000-2000	Düşük
İnsan	17.38	36.03	Tarıma uzaklık	4.56	7.05	2000>	Çok düşük