



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**ORMAN YANGINLARININ MAKİNE ÖĞRENMESİ VE UZAKTAN
ALGILAMA YÖNTEMLERİ KULLANILARAK TAHMİN
EDİLMESİ VE DUYARLILIK HARİTASININ OLUŞTURULMASI**

Yusuf Fırat SUMER

**Ocak-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**ORMAN YANGINLARININ MAKİNE ÖĞRENMESİ VE UZAKTAN
ALGILAMA YÖNTEMLERİ KULLANILARAK TAHMİN
EDİLMESİ VE DUYARLILIK HARİTASININ OLUŞTURULMASI**

Yusuf Fırat SUMER

**Danışman
Doç.Dr. Emrullah ACAR**

Diğer Jüri Yeleri

Doç. Dr. Ömer Türk

Dr. Mehmet Arslanoğlu

**Ocak-2025
BATMAN**

TEZ KABUL VE ONAYI

Yusuf Fırat SUMER tarafından hazırlanan “ORMAN YANGINLARININ MAKİNE ÖĞRENMESİ VE UZAKTAN ALGILAMA YÖNTEMLERİ KULLANILARAK TAHMİN EDİLMESİ VE DUYARLILIK HARİTASININ OLUŞTURULMASI” adlı tez çalışması 13/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Ömer Türk

.....

Danışman

Doç. Dr. Emrullah Acar

.....

Üye

Dr. Mehmet Arslanoğlu

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Yusuf Fırat Sumer
Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

ORMAN YANGINLARININ MAKİNE ÖĞRENMESİ VE UZAKTAN ALGILAMA YÖNTEMLERİ KULLANILARAK TAHMİN EDİLMESİ VE DUYARLILIK HARİTASININ OLUŞTURULMASI

Yusuf Fırat SUMER

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç.Dr. Emrullah ACAR

2025, 79 Sayfa

Türkiye’de orman yangınları, özellikle Akdeniz ve Ege Bölgesi’nde yaz aylarında meydana gelmektedir. İklim değişikliği, insani sebepler, bölgenin iklimsel özellikleri orman yangınlarına sebep olmakta, hem meydana geldiği yerdeki orman varlığını yok etmekte hem de ekonomik ve çeşitli çevresel sorunlara sebep olmaktadır. Bu sebeple orman yangınlarının önceden tespit edilmesi ve yangın meydana gelme potansiyeli bulunan alanların analiz edilmesi büyük önem arz etmektedir. Bu çalışmada Türkiye’de orman yangınları tespit ve tahmin edilmesi amacıyla uzaktan algılama ve makine öğrenmesi yöntemleri kullanılmıştır. Fire Information for Resource Management (FIRMS) veri setinden zamansal orman yangınlarına ilişkin veriler elde edilmiş, ECMWF Re-Analysis-5 (ERA-5), National Aeronautics and Space Administration (NASA) Global Land Data Assimilation System (GLDAS), National Aeronautics and Space Administration (NASA) Shuttle Radar Topography Mission (SRTM) veritabanlarından ise Antalya ilinin çeşitli iklim özellikleri elde edilerek yeni bir veri seti oluşturulmuştur. Veri seti, Ada Boost, Decision Tree (Karar Ağaçları), Gradient Boosting Machine (GBM), K-Nearest Neighbours (KNN), Logistic Regression (Lojistik Regresyon), Support Vector Machine (Destek Vektör Makinesi, SVM) ve Artificial Neural Network (Yapay Sinir Ağı, YSA) algoritmaları ile değerlendirilmiş ve sonuçlar Jenks Natural Breaks sınıflandırma yöntemi ile sınıflandırılarak bölgenin orman yangını duyarlılık haritalarının oluşturulması sağlanmıştır. Deneysel sonuçlara göre en başarılı algoritma Ada Boost olarak tespit edilmiştir (Sensitivity=0,93, Specificity=0,95, Accuracy=0,94, Kappa=0,88, AUC=0,99). Bu modeller Türkiye’de Akdeniz ve Ege Bölge’sinde orman yangınlarının aylık ve mevsimlik duyarlılık haritalarının oluşturulmasında kullanılabilecek, böylece orman yangınları meydana gelmeden önce gerekli önleyici tedbirler alınabilecektir.

Anahtar Kelimeler: Orman Yangınları, Yapay Zekâ, Makine Öğrenmesi, Coğrafi Bilgi Sistemleri, Antalya,

ABSTRACT

MASTER THESIS

PREDICTION AND SUSCEPTIBILITY MAPPING OF FOREST FIRES USING MACHINE LEARNING AND REMOTE SENSING METHODS

Yusuf Fırat SUMER

Batman University Graduate Education Institute

Elektrical and Electronical Engineering Department of Science

Advisor: Assoc. Prof. Dr. Emrullah ACAR

2025, 79 Pages

In Türkiye, forest fires occur during the summer months. This is especially the case in the Mediterranean and Aegean regions. Climate change, humanitarian reasons and climatic characteristics of the region cause forest fires, which destroy the forest resources where they occur and cause economic and various environmental problems. For this reason, it is of great importance to detect forest fires in advance and to analyze the areas with the potential of fire occurrence. In this study, remote sensing and machine learning techniques have been used to detect and predict forest fires in Türkiye. Temporal forest fire data has been obtained from the FIRMS dataset, and a new dataset has been created by obtaining various climatic characteristics of Antalya province from the ERA-5, NASA GLDAS, and NASA SRTM databases. The new data set has been evaluated using Ada Boost, Decision Tree, Gradient Boosting Machine (GBM), K-Nearest Neighbors (KNN), Logistic Regression, Support Vector Machine (SVM) and Artificial Neural Network (ANN) algorithms and the results have been classified using Jenks Natural Breaks classification method to create forest fire susceptibility maps of the region. According to the experimental results, the most successful algorithm has been determined to be Ada Boost (sensitivity=0.93, specificity=0.95, accuracy=0.94, kappa=0.88, AUC=0.99). These models can be used to create monthly and seasonal forest fire susceptibility maps for the Mediterranean and Aegean regions of Türkiye, so that necessary preventive measures can be taken before forest fires occur.

Keywords: Forest Fires, Artificial Intelligence, Machine Learning, Geographic Information System, Antalya,

ÖN SÖZ

Bu tez, ülkemizin ormanlarını tehdit eden ve doğal mirasımıza büyük zararlar veren orman yangınlarının artan etkilerine dikkat çekme amacı taşımaktadır. Türkiye, yıllar boyunca birçok yıkıcı orman yangınına tanıklık etmiş, bu süreçte hem doğa hem de insanlık büyük kayıplar yaşamıştır. Bu çalışma, orman yangınlarının oluşma risklerini daha iyi anlamak ve gelecekteki olası kayıpları en aza indirmek için bir katkı sunmayı hedeflemektedir.

Orman yangınlarına karşı mücadele eden fedakâr orman işçileri ve itfaiye ekiplerinin cesaretleri, bu araştırmanın ilham kaynağı olmuştur. Onların doğayı korumak uğruna gösterdikleri özveri, bu çalışmanın arkasındaki en güçlü motivasyonlardan biridir.

Tezin hazırlanması sürecinde, akademik danışman hocam Doç.Dr.Sn. Emrullah Acar'a, aileme ve bu zorlu yolculuk boyunca yanımda olan ve beni destekleyen arkadaşlarıma teşekkürlerimi sunarım.

Yusuf Fırat SUMER
BATMAN-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ	vi
İÇİNDEKİLER.....	vii
ÇİZELGELER/TABLolar LİSTESİ.....	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ	1
1.1. Türkiye’deki Genel Orman Çeşitliliği	2
1.2. Yangın Riskini Etkileyen Temel Kriterler	3
1.3. Küresel Orman Yangınlarının Genel Durumu	3
1.4. Son Yıllara Ait Orman Yangını İstatistikleri	4
1.5. Ülkemizde Orman Yangınları ve İstatistikleri	4
1.6. Yangınlarla Mücadelede Alınan Önlemler ve Stratejiler.....	6
1.7. Orman Yangınlarının Analizinde Uzaktan Algılamanın Kullanılması.....	9
1.8. Çalışmanın Amacı.....	10
2. KAYNAK ARAŞTIRMASI	11
2.1. Uzaktan Algılama ve Makine Öğrenmesi Yöntemleri ile Orman Yangını Analiz Çalışmaları	11
2.2. Orman Yangınlarının Meydana Gelmesinde Etkili Olan Faktörler	17
3. YÖNTEM.....	20
3.1. Önerilen Çalışma Mimarisi	20
3.2. Çalışma Alanı.....	21
3.3. Veri Seti Aşamaları	24
3.3.1. Uzaktan algılama	24
3.3.1.1. FIRMS.....	25
3.3.1.2. ERA-5	26
3.3.1.3. GLDAS	26
3.3.1.4. MODIS.....	27
3.3.1.5. NASA SRTM.....	27
3.3.2. Orman yangınlarına etki eden faktörler	28
3.3.3. Veri toplama	30
3.3.4. Veri ön işleme.....	30
3.3.4.1. Kayıp değerlerin Moving Average Imputation yöntemi ile elde edilmesi	30

3.3.4.2. Veri normalizasyonu	31
3.3.5. Özellik seçimi ve özelliklerin karşılıklı ilişkisi	31
3.3.6. Veri setinin oluşturulması	32
3.3.7. Makine öğrenmesi	40
3.3.7.1. AdaBoost	41
3.3.7.2. Decision Tree (Karar Ağacı)	42
3.3.7.3. Gradient Boosting Machine (GBM)	43
3.3.7.4. K-Nearest Neighbors (KNN)	44
3.3.7.5. Logistic Regression (Lojistik Regresyon)	44
3.3.7.6. Support Vector Machine (Destek Vektör Makinesi)	45
3.3.7.7. Artificial Neural Network (Yapay Sinir Ağı)	46
3.4. Modellerin Eğitilmesi, Test Edilmesi Ve Doğrulanması	47
3.5. Modellerin Başarım Metrikleri	47
4. BULGULAR VE TARTIŞMA	49
4.1. Orman Yangınlarına Sebep Olan Faktörlerin Öngörebilirlik Önemi	49
4.2. Modelin Başarımı ve Değerlendirilmesi	51
4.3. Orman Yangını Duyarlılık Analizi	61
4.3.1. Yangın olasılıklarının elde edilmesi	61
4.3.2. Haritanın oluşturulması	61
4.3.2.1. Jenks Natural Breaks sınıflandırma yöntemi	62
4.3.2.2. Antalya ili orman yangını duyarlılık haritaları	63
5. SONUÇLAR VE ÖNERİLER	67
5.1. Sonuçlar	67
5.2. Öneriler	67
KAYNAKLAR	69

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 1.1. Orman yangınları ile mücadelenin 12 ilkesi.....	8
Çizelge 3.1. Veri setini oluşturmak için kullanılan faktörler.....	29
Çizelge 4.1. Modellerin genel başarımlar tablosu.....	53
Çizelge 4.2. Ada Boost modeli başarımlar değerleri	54
Çizelge 4.3. Karar Ağaçları modeli başarımlar değerleri	55
Çizelge 4.4. GBM modeli başarımlar değerleri	56
Çizelge 4.5. KNN modeli başarımlar değerleri.....	57
Çizelge 4.6. Lojistik Regresyon modeli başarımlar değerleri.....	58
Çizelge 4.7. SVM modeli başarımlar değerleri.....	59
Çizelge 4.8. YSA modeli başarımlar değerleri	60
Çizelge 4.9. Jenks Natural Breaks Sınıflandırma	62

ŞEKİLLER LİSTESİ

Şekil 1.1. Türkiye orman varlığı haritası	2
Şekil 1.2. Türkiye’de yıllara göre yanmış alan miktarı	5
Şekil 1.3. Türkiye’de yangın çıkış nedenleri (OGM, 2023)	6
Şekil 3.1. Süreç Akış Diyagramı	20
Şekil 3.2. 1988-2023 Türkiye geneli yanan orman alanı miktarı	22
Şekil 3.3. 2023 yılı karşılaştırmalı orman yangını sayıları	22
Şekil 3.4. Antalya’da 2000-2023 arasındaki yangın sayısı.....	23
Şekil 3.5. Çalışma alanı olarak seçilen bölge	24
Şekil 3.6. 2012-2021 arasında yangın meydana gelmiş alanlar ve rastgele seçilmiş yangın meydana gelmemiş alanlar.....	33
Şekil 3.7. Antalya ilinin ortalama hava sıcaklığı haritası	34
Şekil 3.8. Antalya ilinin ortalama rüzgâr hızı haritası	34
Şekil 3.9. Antalya ilinin ortalama yağış haritası	35
Şekil 3.10. Antalya ilinin kara yüzey sıcaklığı ortalama haritası	35
Şekil 3.11. Antalya ilinin spesifik nem ortalama haritası	36
Şekil 3.12. Antalya ilinin NDVI ortalama haritası	36
Şekil 3.13. Antalya ilinin EVI ortalama haritası.....	37
Şekil 3.14. Antalya ilinin LAI ortalama haritası.....	37
Şekil 3.15. Antalya ilinin FPAR ortalama haritası	38
Şekil 3.16. Antalya ilinin yükseklik haritası.....	38
Şekil 3.17. Antalya ilinin eğim haritası	39
Şekil 3.18. Antalya ilinin bakı haritası	39
Şekil 3.19. Antalya ilinin NDWI haritası	40
Şekil 4.1. Korelasyon matrisi.....	50
Şekil 4.2. Özellik önem grafiği	51
Şekil 4.3. Ada Boost modeli AUC grafiği	54
Şekil 4.4. Karar Ağaçları modeli AUC grafiği	55
Şekil 4.5. GBM modeli AUC grafiği.....	56
Şekil 4.6. KNN modeli AUC grafiği	57
Şekil 4.7. Lojistik Regresyon modeli AUC grafiği	58
Şekil 4.8. SVM modeli AUC grafiği	59
Şekil 4.9. YSA modeli AUC grafiği	60
Şekil 4.10. “Çok Yüksek” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar.....	63
Şekil 4.11. “Yüksek” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar	63
Şekil 4.12. “Orta” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar	64
Şekil 4.13. “Düşük” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar.....	64
Şekil 4.14. “Çok Düşük” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar	65
Şekil 4.15. Antalya ili genel yangın duyarlılık haritası ve yangın çıkan noktalar	66

SİMGELER VE KISALTMALAR

Kısaltmalar

ADAM: Adaptive Moment Estimation

AHP: Analytic Hierarchy Process

AUC: Area Under Curve

AVHRR: Advanced Very-High-Resolution Radiometer

BUI: Buildup Index

CNN: Convolutional Neural Network

DMC: Duff Moisture Code

DPM: Damage Proxy Map

ECMWF: European Centre for Medium-Range Weather Forecasts

ERA: ECMWF Re-Analysis

ESA: European Space Agency

EUMETSAT: European Organisation for the Exploitation of Meteorological

Satellites

EVI: Enhanced Vegetation Index

FAO: Food and Agriculture Organization

FbSP: Fuzzy-Based Segmentation Parameter

FFMC: Fine Fuel Moisture Code

FIRMS: Fire Information for Resource Management

FN: False Negative

FP: False Positive

FPAR: Fraction of Absorbed Photosynthetically Active Radiation

FWI: Fire Weather Index

GBM: Gradient Boosting Machine

GEE: Google Earth Engine

GFA: Global Fire Atlas

GFED: Global Fire Emissions Database

GLDAS: Global Land Data Assimilation System

GOES: Geostationary Operational Environmental Satellite

GPM: Global Precipitation Measurement

GWO: Grey Wolf Optimizer

ICA: Imperialist Competitive Algorithm

ISI: Initial Spread Index

JMA: Japan Meteorological Agency

K: Kelvin

KNN: K-Nearest Neighbours

LAI: Leaf Area Index

LOAN: Location-Aware Adaptive Normalization Layer

LST: Land Surface Temperature

LSTM: Long Short Term Memory

MODIS: Moderate Resolution Imaging Spectroradiometer

NASA: National Aeronautics and Space Administration

NC: Neural Computing

NDMI: Normalised Difference Moisture Index

NDVI: Normalized Difference Vegetation Index

NDWI: Normalised Difference Water Index

NIR: Narrow Infrared

NGA: National Geospatial Intelligence Agency
NOAA: National Oceanic and Atmospheric Administration
NPP: National Polar-orbiting Partnership
NPV: Negative Prediction Value
OGM: Orman Genel Müdürlüğü
PPV: Positive Predictive Value
RMSE: Root Mean Square Error
ROC: Receiver Operating Characteristic
SAR: Syntethic Aparture Radar
SGD: Stochastic Gradient Descent
SRTM: Shuttle Radar Topography Mission
SVM: Support Vector Machine
TN: True Negative
TP: True Positive
TRMM: Tropical Rainfall Measuring Mission
TWI: Topographic Wetness Index
USGS: ; United States Geological Survey
VIIRS: The Visible Infrared Imaging Radiometer Suite

1. GİRİŞ

Ormanlar, dünya genelinde biyolojik çeşitliliğin korunmasında temel bir rol oynar ve birçok canlı türüne yaşam alanı sunar (Food and Agriculture Organization, 2020). Ayrıca, atmosferdeki karbonu tutarak küresel iklim değişikliğine karşı mücadelede önemli bir savunma hattı oluştururlar (Bonan, 2008). Ormanların sağladığı temiz hava ve su, yalnızca ekosistemler için değil, insan yaşamı için de büyük önem taşır (Costanza ve diğerleri, 1997).

Ormanlar, fotosentez yoluyla atmosferdeki karbondioksiti emer ve oksijen üretir, böylece hava kalitesini iyileştirir ve iklimi dengeler (Luyssaert ve diğerleri, 2008). Aynı zamanda, yağışların toprağa nüfuz etmesine yardımcı olur ve yeraltı su kaynaklarını besleyerek su döngüsünün sürdürülebilirliğine katkı sağlar (Ellison diğerleri, 2017).

Toprak erozyonunu önleyerek verimli tarım alanlarının korunmasına yardımcı olan ormanlar, toprak yapısını güçlendirir ve tarımsal üretimi destekler (Pimentel ve diğerleri, 1995).

Ormanların bu çevresel işlevleri, hem yerel hem de küresel ölçekte ekosistem hizmetlerinin devamlılığını sağlar ve doğanın dengesini korur (Millennium Ecosystem Assessment, 2005).

Türkiye'nin ormanları iklim değişikliği, erozyon, yasadışı kerestecilik, yangınlar, yerleşim alanlarının, tarım alanlarının ve kirliliğin artması sebebiyle tehdit altındadır (Kaya ve diğerleri, 2001; Varol ve diğerleri 2021).

Ayrıca, tarım ve kentleşme faaliyetleri, orman alanlarının azalmasına ve biyoçeşitliliğin kaybına neden olmaktadır (Şekercioğlu ve diğerleri, 2011)


Bu tehditler, Türkiye'nin doğal kaynaklarını koruma ve sürdürülebilir orman yönetimini sağlama gerekliliğini daha da ön plana çıkarmaktadır.

Ayrıca ekonomik anlamda ormanlar, kırsal topluluklara geçim kaynağı sağlamakta ve orman ürünleri ticaretiyle dünya çapında milyonlarca insana istihdam sunmaktadır. (World Bank Forest Action Plan, 2016).

1.1. Türkiye’deki Genel Orman Çeşitliliği

Türkiye orman ve bitki örtüsü çeşitliliği bakımından çok zengindir. Türkiye’nin orman ve bitki örtüsü bakımından zengin olmasında Dünya’da 37’ye ayrılan flora bölgesinden üçünün Türkiye’de bulunması etkili olmuştur (Yıldız ve diğerleri, 2000).

Ormanlık alanlar Türkiye’nin 78 milyonluk hektar alanının %29,4’lük kısmına karşılık gelmektedir. Türkiye’nin orman varlığı haritası Şekil 1.1.’de gösterilmiştir.



Şekil 1.1. Türkiye orman varlığı haritası

Karadeniz Bölgesi’nde deniz kıyısı şeridinde yıllık ortalama sıcaklıklar 10 ila 15 °C arasında seyrederken bu rakam yüksek bölgelerde 5 °C civarına kadar düşmektedir. Karadeniz Bölgesinde yağış miktarı yıllık olarak ortalama 1000 mm civarlarında ölçülmektedir. Kayın, kestane, gürgen, sarıçam, karaçam, köknar, akmeşe, kızılçam bölgede yaygın bulunan ağaç türleridir (Kaya ve Raynal, 2001).

Marmara bölgesi, Karadeniz ve Akdeniz iklim özelliklerini birlikte taşımaktadır. Bu bölgedeki ormanlarda kayın, kestane, gürgen, sarıçam, karaçam, köknar, akmeşe, kızılçam, meşe, sakız ağacı, mersin ağacı bulunabilmektedir (Kaya ve Raynal, 2001).

İç Anadolu, karasal iklimin etkisi altında olup, ardıç, karaçam ve meşe ve sarıçam gibi türlerle örtülüdür. Bölgenin iklimi daha kuru olduğu için orman alanları seyrektir (Kaya ve Raynal, 2001).

Doğu Anadolu, soğuk iklim koşulları ve yüksek rakım nedeniyle sınırlı orman alanlarına sahiptir. Bu bölgede sarıçam ve meşe türleri bulunur (Kaya ve Raynal, 2001).

Ege bölgesi orman alanlarında Akdeniz ikliminin etkisiyle meşe, kocayemiş, menengiç, mersin, kızılçam, karaçam, kestane, kayın ve sarıçam ağaçlarına sahiptir (Kaya ve Raynal, 2001).

Akdeniz Bölgesi 100 ila 2500 mm arasında yıllık yağış miktarına ve ortalama 5 ila 20 °C arasında bir sıcaklığa sahiptir. Akdeniz Bölgesi'nin orman ekosistemi, rüzgâr, uzun kuraklık, buna rağmen şiddetli fırtınalı yağışlar ve yüksek sıcaklıklar gibi belirgin ve aşırı iklimsel kısıtlamalara maruz kalmaktadır.

Akdeniz Bölgesi'nde bulunan ormanlar hem iklim değişikliği hem de arazi kullanımının artmasından dolayı orman yangınlarına ve diğer doğal felaketlere karşı oldukça açık duruma gelmiştir (Palahi ve diğerleri, 2008).

1.2. Yangın Riskini Etkileyen Temel Kriterler

Dünyada bulunan ormanlar ve bitki örtüsü, orman yangınlarına sebep olabilecek biyolojik yakıtlardır (Belcher, 2013). Orman yangınlarının şiddetinin belirlenmesi, yayılma hızı ve yangın hattının yoğunluğu gibi nicel değişkenler yardımıyla ölçülebilmektedir. Bununla birlikte orman yangınlarının meydana gelmesinde, iklimsel, topografik, sosyal, ekonomik veya termodinamik gibi farklı değişkenler etkilidir (Planas ve Pastor, 2013). Orman yangınlarının meydana gelmesinde kuraklığın meydana gelme frekansı ve şiddeti, iklimin yangına elverişli olması etkilidir. Bu faktörler bitki örtüsünün nem seviyesinde azalmaya sebep olmakta ve orman yangınlarının meydana gelmesine zemin hazırlamaktadır (Seneviratne ve diğerleri, 2022; United Nations Environment Program, 2022a; Jones ve diğerleri, 2022; Abatzoglou ve diğerleri, 2019; Cunningham diğerleri, 2024a). Buna ek olarak antropojenik faktörler ve arazi kullanımında meydana gelen değişiklikler yoğun, hızla ilerleyen yangın riskine sebep olabilmektedir (Lapola ve diğerleri, 2023).

1.3. Küresel Orman Yangınlarının Genel Durumu

Dünyada biyokütle tabanlı yangınların neredeyse yarısı Afrika kıtasında, dörtte biri Güney Amerika kıtasında ve geri kalan kısmı dünyanın diğer bölgelerinde meydana gelmektedir (Andreae, 1993)

2001'den 2023'e kadar dünya genelinde yangınlar nedeniyle toplam 138 milyon hektar alan, diğer tüm kayıp faktörleri nedeniyle ise 350 milyon hektar alan ağaç örtüsü kaybı yaşanmıştır. Bu dönemde yangınlar nedeniyle en fazla ağaç örtüsü kaybının yaşandığı yıl, 11,9 milyon hektar alan ile 2023 yılı olmuştur. Bu, o yılki tüm ağaç örtüsü kaybının %42'sine karşılık gelmektedir (Global Forest Watch, 2024).

Yanan ormanlık alan miktarı 2001 yılında bütün ağaç örtülerine ilişkin kaybın yalnızca ortalama %20'sini oluştururken, artık yaklaşık %33'ünü oluşturmaktadır. 2023 yılında dünya genelinde yanan ormanlık alan miktarı, bir önceki rekorun %24 fazlası olarak kaydedilerek tüm zamanların rekorunu kırmıştır. Yangın bakımından en kötü üçüncü yıl 2021, en kötü dördüncü yıl ise 2020 olarak kayıtlara geçmiştir (World Resources Institute, 2024).

Bu istatistikler son yıllarda orman yangınlarının ormanlarımızı ciddi şekilde etkilediğini ve etkilemeye devam edeceğini göstermektedir.

1.4. Son Yıllara Ait Orman Yangını İstatistikleri

Son yıllarda, 2019–2020 Avustralya “Kara Yaz” orman yangınları rekor düzeyde ormanlık alanın yanmasına sebep olmuştur (Abram ve diğerleri, 2021). Ayrıca Amerika Birleşik Devletleri'nin batısında (Higuera ve Abatzoglou, 2021), Sibiry'a'da (Zheng ve diğerleri, 2023), Avrupa'da (EU Science Hub, 2023) ve Güney Amerika'da (Kelley ve diğerleri, 2021; Ferreira Barbosa ve diğerleri, 2022; Silveira ve diğerleri, 2020) arka arkaya bir dizi orman yangınları meydana gelmiştir. 2023–2024 yıllarında Kanada, Hawaii ve Şili'de eşi benzeri görülmemiş yangınlar meydana gelmiştir (Jones ve diğerleri, 2024). Avrupa Birliği ve Kanada'da ve Brezilya, Bolivya, Kolombiya ve Venezuela gibi Amazon bölgeleri de dâhil olmak üzere Güney Amerika'nın kuzeybatısında da meydana gelen büyük çaplı yangınlar görülmüştür (Mataveli ve diğerleri, 2024; Kolden ve diğerleri, 2024; European Union Science Hub, 2023).


1.5. Ülkemizde Orman Yangınları ve İstatistikleri

Türkiye, Akdeniz iklim kuşağında yer alan ve geniş ormanlık alanlara sahip bir ülke olarak, orman yangınlarına karşı yüksek risk taşıyan bölgeler arasında yer almaktadır. Türkiye'deki orman yangınları hem insan kaynaklı hem de doğal sebeplerle

ortaya çıkmakta ve bu yangınlar, ormanların çevresel, ekonomik ve toplumsal değerlerine ciddi zararlar vermektedir.

Türkiye, 22 milyon hektar alan orman varlığına sahip olup, bu alan ülkenin yaklaşık %28,6'sını kaplamaktadır. Akdeniz ve Ege bölgeleri, orman yangınlarının en sık yaşandığı alanlar arasında yer almaktadır. Orman yangınlarının büyük bir kısmı yaz aylarında, özellikle Temmuz ve Ağustos aylarında meydana gelmekte ve yangınların büyük çoğunluğu insan kaynaklı nedenlerle ortaya çıkmaktadır. Türkiye’de her yıl yaklaşık 2.000 ila 3.000 arasında orman yangını meydana gelmektedir ve bu yangınlar ortalama 7.000 ila 10.000 hektar ormanlık alanı etkilemektedir.


2018–2023 yılları arasında ülkemizde meydana gelen orman yangınları sonucunda yanmış alanlar incelendiğinde 2018–2020 yılları arasında düzenli bir artış meydana gelmiştir. 2021 yılında Antalya ili ve çevresinde meydana gelen şiddetli orman yangınları sebebiyle yanmış alan miktarının bir önceki yıla göre 7 kata yakın arttığı görülmektedir. 2022 ve 2023 yılları ele alındığında yanan alan miktarının yine artış eğiliminde olduğu söylenebilmektedir. Şekil 1.2. ülkemizde 1988–2023 yılları arasındaki yanmış alan miktarını gösteren grafiği içermektedir (OGM, 2023).



Şekil 1.2. Türkiye’de yıllara göre yanmış alan miktarı

Ülkemizde orman yangınlarının sebepleri konusunda kayıtlar 1997 başlayarak tutulmuş ve günümüzde de yangınlara sebebiyet veren kayıtlar tutulmaya devam etmektedir. Veriler incelendiğinde ülkemiz ormanlarına zarar veren yangınların çıkış sebeplerinden en dikkat çekenini ihmal-kaza olduğu görülmektedir. Hem adet olarak hem de yanan alan olarak en fazla zarara ortaya çıkaran sebep olarak değerlendirilmektedir. Ardından sebebi bilinmeyen yangınlar ve kasıtlı çıkarılan yangınlar ormanlarımıza zarar

vermektedir. Türkiye ormanlarının yanmasında en az etkiye sahip olan faktörler ise doğal sebeplerdir. Şekil 1.3.'de ülkemizde meydana gelen orman yangınlarının sebeplerine ilişkin istatistikler verilmiştir (OGM, 2023).



Şekil 1.3. Türkiye’de yangın çıkış nedenleri (OGM, 2023)

İlerleyen bölümlerde, Türkiye’de meydana gelmiş orman yangınlarına ilişkin daha fazla ayrıntılı bilgiler sunulmuştur.

1.6. Yangınlarla Mücadelede Alınan Önlemler ve Stratejiler

Yangın yönetimi bağlamına orman yangınlarını önlenmesi, algılanması, kontrol altına alınması ve bastırılması dâhil edilebilir. Bununla birlikte doğal yaşamı, insan sağlığını, geleneksel ve yerli kültürleri, geçim kaynaklarını, arazilerdeki ve kırsal alanlardaki mülkleri ve kaynakları korumaya ilişkin hedefleri de içermektedir.

1990–2025 döneminde 236 ülke ve bölgede 60’tan fazla ormanla ilgili değişkenin durumunu ve eğilimlerini inceleme kabiliyetine sahip olan Forest and Agriculture Organization (FAO) tarafından yangın ve yangınlarla mücadele bilimsel bir disiplin olarak ele alındığında bu disiplinin sosyal ve ekonomik bilimlerden, çevrebilim, fizik ve kimyaya kadar birçok klasik alanı kapsadığı belirtilmektedir. (FAO, 2024).

Ormanların ve ekolojinin korunmasında çoğu kuruluşlar, geçmiş yıllarda meydana gelen olaylara ilişkin verilerin depolanması yoluyla bilgi yönetimini gerçekleştirmektedirler. Bazı kuruluşlar ise bu yaklaşımın ötesine geçerek bütüncül bir

bilgi yönetim süreci işletmekte ve geleneksel yöntemlerle teknolojinin kullanımını birleştirmektedirler (FAO, 2024).

Yangınların meydana geldiği bölgelerde yaşayan yerel halkın yangınlar konusunda eğitilmesi, orman yangınlarının önlenmesi ve ekolojik olarak güvenli bir kontrollü yakmanın uygulanması açısından çok önemlidir.

Yapılan bilimsel araştırmalardan elde edilen sonuçların, kamu yararı oluşması amacıyla toplum pratiğine aktarılması, çeşitli farkındalık programları ile halkın bu programlara katılması sayesinde gerçekleştirilebilir (FAO, 2024).

FAO tarafından 2024 yılında yayımlanan Integrated “Fire Management Voluntary Guidelines” başlıklı kitap ile orman yangınları ile mücadele konusu farklı bir yaklaşımla ele alınmıştır. Kitapta orman yangınları ile mücadele 12 farklı ilkeye dayandırılmıştır. Çizelge 1.1.’de FAO tarafından benimsenen ilkeler gösterilmiştir (FAO, 2024).

Çizelge 1.1. Orman yangınları ile mücadelenin 12 ilkesi

Alan	İlke	Yöntem
Ekonomik	Canlı ve cansız varlıkların korunması	Orman yangınlarının can, mal ve kaynaklar üzerindeki yıkıcı etkileri tamamen önlenemese bile en aza indirmek
	Ekonomik etkiler	Etkin bir bütünleşik yangın yönetim programı uygulayarak toplumun yangın kullanımından elde ettiği faydaları en üst düzeye çıkarmak ve orman yangını kayıplarını, hasarı ve diğer istenmeyen etkileri en aza indirmek
Çevresel	İklim değişikliği ve yangınlar arasındaki etkileşim	Kontrollü yakma yönteminin uygulanmasında iklim değişikliği, bitki örtüsü ve yangın rejimleri arasındaki etkileşimlerin anlaşılması ve uygun şekilde dikkate alınması
	Ekosistemdeki yangın etkisi	Uygun ekosistem yapısı, işlevi ve sürdürülebilirliğini sağlamak için yangını çevreye duyarlı bir şekilde yönetmek
Kurumsal	Mevzuat	Tüm bütünleşik yangın yönetim programı faaliyetlerini, bilgilendirilmiş politika ve prosedürlerle desteklenen yerleşik bir yasal çerçeve dâhilinde yürütmek
	Politika belirleme	Yangın yönetimi için politika oluşturmada bütünleşmiş bir yaklaşım benimsemek
	Çok paydaşlı yaklaşım	Kamu ve özel arazi sahipleri, itfaiye hizmetleri, yerel topluluklar ve çıkar grupları tarafından uygun şekilde paylaşılan bütünleşik yangın yönetim programının liderliği ve yönetimi için katılımcı yaklaşımlar kullanmak
Sosyal ve kültürel	Sürdürülebilir geçim kaynakları	Sürdürülebilir geçim kaynaklarını teşvik etmek için yangının uygun şekilde kullanılması ve yönetilmesi
	İnsan sağlığı ve güvenliği	Yangının olumsuz etkilerini minimize ederek insan sağlığının ve güvenliğinin geliştirilmesi
	Yangının geleneksel kullanımı	Herkesin yararına olacak uygulamalara ve deneyimlere erişim sağlamak için yerli halklar ve diğer yerel bilgi sahiplerinin sürece dâhil edilmesi
Yangın yönetim kapasitesinin artırılması	İşbirliği	Hiçbir ülke, kurum veya topluluk her durumu yönetemeyeceğinden ve yangınlar rutin olarak birden fazla yetki alanını etkilediğinden, yangının sınır ötesi etkilerini azaltmak için işbirliği düzenlemeleri geliştirilmesi

1.7. Orman Yangınlarının Analizinde Uzaktan Algılamanın Kullanılması

Orman yangınları, dünya genelinde orman ekosistemlerini tehdit eden önemli bir çevresel sorundur. Bu yangınlar, hem doğal yaşamı hem de insan yaşamını olumsuz etkilemekte, biyolojik çeşitliliğin kaybına ve ekonomik kayıplara neden olmaktadır. Yangınların erken tespiti ve etkili bir şekilde tahmin edilmesi, zararın azaltılması açısından büyük önem taşımaktadır. Uzaktan algılama, dünya yüzeyine ait bilgilerin uydu veya hava platformları aracılığıyla toplanmasını sağlayan bir yöntemdir. Bu yöntem, orman yangınlarının hem tespiti hem de izlenmesi için yaygın bir şekilde kullanılmaktadır. Uydu tabanlı sistemler, geniş alanların düzenli bir şekilde izlenmesine olanak tanır ve yangın bölgelerini hızlıca tespit eder. Özellikle Moderate Resolution Imaging Spectroradiometer (MODIS) ve The Visible Infrared Imaging Radiometer Suite (VIIRS) gibi sensörler, aktif yangın bölgelerini belirlemek ve yangınların zaman içindeki gelişimini izlemek için sıklıkla kullanılmaktadır (Giglio ve diğerleri, 2016). Uzaktan algılama teknolojileri, sıcaklık değişimleri, duman yoğunluğu ve topografya gibi faktörleri analiz ederek yangın risk haritaları oluşturulmasında da rol oynamaktadır (Chuvieco ve Kasischke, 2007).

NASA orman yangınlarının tespiti için Aqua ve Terra isimli uyduları kullanmaktadır. Bu uydular üzerinde bulunan MODIS sensörü yardımıyla yangınlara ilişkin birçok karakteristik özellik elde edilebilmektedir. Mevcut çalışmamızda da kullanılmış olan MODIS, yangınların termal anomali verilerini sağlayarak aktif yangınların yerini tespit edebilmektedir. Ayrıca, yangın sonrası hasarın değerlendirilmesi için de kullanılmaktadır (NASA, 2024a). Kara, okyanus ve atmosfer boyunca görünür ve kızılötesi dalga boylarını kapsayan küresel uyduların elde ettiği görüntüleri gözlemleyen ve toplayan VIIRS MODIS'ten daha yüksek çözünürlük sağlamakla birlikte özellikle gece yangınlarının tespitinde daha iyi sonuçlar vermektedir (NOAA, 2023; NASA, 2024e). Avrupa Uzay Ajansının (ESA) Copernicus programı kapsamında hizmet sunulan Sentinel-2 uydusu ile yüksek çözünürlüklü optik görüntüler sunulmakta ve özellikle yangın sonrası bitki örtüsü kaybını ve hasarı değerlendirmek için kullanılmaktadır (Copernicus, 2024).

1.8. Çalışmanın Amacı

Bu çalışmada tamamen farklı makine öğrenmesi yöntemleri yardımıyla orman yangınlarının tahmini ve analizi gerçekleştirilmiştir. Görünür ışık ve kızılötesi alanlarda dünya üzerinden görüntü toplayabilen MODIS uydusu ile çalışılmıştır. FIRMS veri set içerisinde bulunan ve MODIS uydusunun 2012-2023 yılları arasında Türkiye'nin Antalya ili sınırlarını kapsayan görüntülerden/verilerden yangın olayları elde edilmiştir. Bununla birlikte sıcaklık, rüzgâr ve yağış verileri birçok farklı uydudan veri toplayan European Centre for Medium-Range Weather Forecasts (ECMWF) Re-Analysis-5 (ERA-5) veri setinden elde edilmiştir. Nem verileri ise hem uzaktan algılama sistemlerini, hem de yer verilerini kullanan GLDAS sistemi üzerinden elde edilmiştir. Daha önce zamansal orman yangını verilerinin elde edilmesinde kullanıldığından bahsedilen MODIS ile aynı zamanda bitki örtüsü verileri de elde edilmiştir. Topografik veriler ise NASA'nın topografik veri toplayan NASA SRTM veri setinden elde edilmiştir.

Elde edilen yangın noktalarının seçilen 18 farklı topografik, bitki örtüsü ve iklimsel özellikleri çıkartılarak bir veri seti oluşturulmuştur. Bu veriler, uzaktan algılama yöntemleriyle elde edilen diğer veriler ile birlikte makine öğrenmesi algoritmalarında kullanılmak üzere hazır hale getirilmiştir.

2. KAYNAK ARAŞTIRMASI

Dünya’da ve Türkiye’de nispeten geleneksel yöntem olarak adlandırılabilir, hem teknolojik hem de analitik yaklaşımlar içeren yangın algılama yöntemleri kullanılmıştır. Orman yangınlarının mümkün olan en kısa sürede tespit edilmesi ve harekete geçilmesi için ormanlarda tepelik alanların üzerine yerleştirilen gözetleme kuleleri (Rego ve Catry, 2006; Matthews ve diğerleri, 2012), kamyonlarla yapılan yangın devriyeleri (Momeni, 2022), uçak, insansız hava aracı ve dronlarla yapılan hava devriyeleri (Alkhatib, 2014), duman, gaz ve mikrodalga algılama (Krüll ve diğerleri, 2012), gönüllü raporlama/halk tarafından yapılan raporlama yöntemleri kullanılmıştır.

Bununla birlikte son yıllarda geleneksel yöntemlerin yanında daha modern yöntemler de kullanılmaya başlanmıştır. Uydu tabanlı gözetleme sistemleri (Alkhatib, 2014), kablosuz sensör ağları (Bouabdellah ve diğerleri, 2013), makine öğrenmesi yöntemleri (Kansal ve diğerleri, 2015) kullanılmaktadır.

2.1. Uzaktan Algılama ve Makine Öğrenmesi Yöntemleri ile Orman Yangını Analiz Çalışmaları

Aşağıda, daha önce orman yangınlarının tespit edilmesi ve duyarlılık analizlerinin yapılmasında kullanılan uzaktan algılama ve makine öğrenmesi yöntemlerini içeren çalışmalara ait bir literatür özeti verilmiştir.

Mohajane ve arkadaşları tarafından yapılan bir çalışmada Akdeniz Bölgesinde meydana gelen orman yangınlarının duyarlılık haritaları uzaktan algılama ve makine öğrenmesi algoritmaları ile tespit edilmeye çalışılmıştır. Çalışmada temel olarak Multilayer Perceptron (Çok Katmanlı Algılayıcı), Lojistik Regresyon, Classification and Regression Tree (Sınıflandırma ve Regresyon Ağacı), SVM ve Random Forest (Rastgele Orman) algoritmaları Frequency Ratio (Frekans Oranı) yöntemi ile birlikte kullanılmıştır. Veri seti olarak ise zamansal orman yangınları verileri ve yükseklik, eğim, bakı, yola uzaklık, yerleşim alanlarına uzaklık, arazi kullanımı, bitki örtüsü indeksi, yağış, sıcaklık ve rüzgâr hızı verileri kullanılmıştır (Mohajane ve diğerleri, 2021).

Yang ve arkadaşları tarafından yapılan bir çalışmada Endonezya içinde seçilen bir bölgenin orman yangını tahmin haritası çıkartılmıştır. Makine öğrenmesi olarak denetimli öğrenme kullanılmıştır. Zamansal orman yangınları verileri FIRMS (FIRMS, 2024)

üzerinden alınmış ve uzaktan algılama görüntüleri Landsat 7 uydu üzerinden toplanmıştır (Yang ve diğerleri, 2021).

Zhang ve arkadaşları tarafından yapılan bir çalışmada Çin'in Yunnan eyaletinde orman yangını duyarlılığı modellemesi için Convolutional Neural Network (Evrişimsel Sinir Ağı)'e dayalı bir mekânsal tahmin modeli önerilmiştir. Bu Evrişimsel Sinir Ağı, üç evrişimsel katman, bir ReLU aktivasyon fonksiyonu, iki havuzlama (pooling) katmanı ve üç Fully Connected Layer (Tam Bağlantılı Katman) içermektedir. 2002'den 2010'a kadar olan uydu görüntülerinin ve geçmişe yönelik yangın raporlarının yorumlanması (7675 yangın meydana gelmiştir) dâhil olmak üzere çok sayıda veri, çıktı olarak bir orman yangını olay haritasını oluşturmak için kullanılmıştır. Ayrıca, üç kategoriye ayrılmış olarak, yangınları etkileyen on dört faktör kullanılmıştır. Bunlar; bitki örtüsüyle ilgili (yola olan mesafe, nehirlere olan mesafe, bitki örtüsü indeksi olan Normalized Difference Vegetation Index (NDVI) ve orman kapsam oranı), iklimle ilgili (ortalama sıcaklık, özgül nem, ortalama yağış, ortalama rüzgâr hızı, yağış oranı ve en yüksek sıcaklık) ve topografya ile ilgili (yön, eğim ve yükseklik) verilerdir. Çok Katmanlı Algılayıcı ile elde edilen sonuçlar incelendiğinde Sinir Ağı, Rastgele Orman, Kernel Lojistik Regresyon ve SVM'den oluşan dört kıyaslama modelini geride bırakarak %95,81'lik daha yüksek bir doğruluk elde edilmiştir (Zhang ve diğerleri, 2019).

Prapas ve arkadaşları tarafından yapılan bir çalışmada Yunanistan içindeki bölgelerde orman yangını tehlikesi tahmini için ConvLSTM (Long Short Term Memory) adlı bir derin öğrenme yöntemi kullanılmıştır. Bu modelin eğitimi ve testinde Datacube veri seti kullanılmıştır. Bu veri seti, 2009 ve 2020 yılları arasında yanmış alanlar ve yangın bilgilerini (iklim verileri, insan faaliyetleri ve bitki örtüsü bilgileri), günlük hava durumu, MODIS isimli sensörden toplanan uydu verileri yaprak alan indeksi olan Leaf Area Index (LAI), fotosentetik olarak emilen aktif radyasyon oranı olan Fraction of Absorbed Photosynthetically Active Radiation (FPAR), NDVI, geliştirilmiş bitki örtüsü indeksi olan Enhanced Vegetation Index (EVI), gündüz/gece kara yüzey sıcaklığı olan Land Surface Temperature (LST), yol yoğunluğu, arazi örtüsü bilgileri ve topoğrafya (yön, eğim ve yükseklik) verilerini içermektedir. ConvLSTM, Rastgele Orman ve LSTM'den %83,2 daha iyi bir hassasiyete ulaşmıştır (Prapas ve diğerleri, 2021).

Zhang ve arkadaşları tarafından yapılan bir çalışmada Evrişimsel Sinir Ağı'nın beş seviyeye (çok yüksek, yüksek, orta, düşük ve çok düşük) ayrılmış orman yangını duyarlılık haritalarını tahmin etme yeteneği incelenmiştir. İşleme hücresi türüne (ızgara

ve piksel) dayanarak, piksel hücrelerine dayalı Evrişimsel Sinir Ağı-1D ve ızgara hücrelerine dayalı Evrişimsel Sinir Ağı-2D olmak üzere iki Evrişimsel Sinir Ağı önerilmiştir. Evrişimsel Sinir Ağı-1D, iki adet 1D evrişimsel katman, üç tam bağlı katman, ReLU aktivasyon fonksiyonu ve bir sigmoid fonksiyonundan oluşmaktadır. Evrişimsel Sinir Ağı-2D, her biri ReLU aktivasyonu ve maksimum havuzlama katmanı tarafından takip edilen iki 2D evrişimsel katman ve ilk ikisini ReLU aktivasyon fonksiyonu ve sonuncusunu bir sigmoid fonksiyonu takip eden üç tam bağlı katman içermektedir. Evrişimsel Sinir Ağı eğitiminde çeşitli veriler kullanılmıştır. 2003'ten 2016'ya kadar Global Fire Atlas (GFA) veri setinden toplanan günlük dinamik yangın davranışları, bireysel yangın özellikleri ve tahmini yanma günü bilgileri; GLDAS'tan (NASA, 2024b) elde edilen metroloji verileri, ortalama sıcaklık, özgül nem, birikmiş yağış, toprak nemi, toprak sıcaklığı ve standartlaştırılmış yağış indeksi; United States Geological Survey (USGS) (USGS, 2019) web sitesinden indirilen bitki örtüsü verileri kullanılmıştır. Test sonuçları, Evrişimsel Sinir Ağı-2D'nin sırasıyla Mart-Mayıs, Haziran-Ağustos, Eylül-Kasım ve Aralık-Şubat olmak üzere dört mevsim için sırasıyla %91,08, %89,61, %93,18 ve %94,88 doğruluk elde ettiğini, Evrişimsel Sinir Ağı-1D ve çok katmanlı algılayıcı modellerinin doğruluklarını geride bıraktığını göstermiştir (Zhang ve diğerleri, 2021).

Van Le ve arkadaşları tarafından yapılan bir çalışmada Vietnam'daki Gia Lai eyaletinde orman yangını tehlikesini tahmin etmek için üç ReLU aktivasyon fonksiyonu ve bir sigmoid fonksiyonu içeren derin sinir ağı olan Deep-Neural Computing (NC) geliştirilmiştir. Toplam olarak 2007'den 2016'ya kadar 2530 zamansal yangın olayı tespit edilmiştir. Orman yangını meydana gelmeyen alanlardan 2530 veri noktası, eğim, arazi kullanımı, su indeksi olan Normalised Difference Water Index (NDWI), yön, yükseklik, nem indeksi olan Normalised Difference Moisture Index (NDMI), eğrilik, NDVI, rüzgâr hızı, bağıl nem, sıcaklık ve yağış bilgisi gürültüyü gidermek için değerlendirilmiş ve girdi olarak kullanılmıştır. Eğitim adımı, Deep-NC'nin ağırlıklarını optimize etmek için Stochastic Gradient Descent (SGD), Adaptive Moment Estimation (ADAM), Root Mean Square Propagation (RMSProp) ve Adadelta olmak üzere dört optimize edici yöntem kullanılmıştır. ADAM optimizasyonuna sahip Deep-NC ile %81,50 doğruluk oranına ulaşılmıştır (Van Le ve diğerleri, 2021).

Omar ve arkadaşları tarafından yapılan bir çalışmada orman yangınlarını tahmin etmede LSTM, tam bağlantılı katmanlar, dropout ve bir regresyon fonksiyonundan oluşan

bir derin öğrenme yöntemi kullanılmıştır. Toplam olarak, 536 örnek nokta ile sıcaklık, bağıl nem, yağmur, rüzgâr, Initial Spread Index (ISI), Duff Moisture Code (DMC), Fire Weather Index (FWI), Fine Fuel Moisture Code (FFMC) ve Buildup Index (BUI) dâhil olmak üzere on iki özellik önerilen modeli eğitmek için kullanılmış ve 0,021'lik bir Root Mean Square Error (RMSE) puanı elde edilmiştir. Bu model, makine öğrenmesi yöntemlerine göre (Karar Ağaçları, Linear Regression (Doğrusal Regresyon), SVM, Sinir Ağı) daha yüksek bir başarı sağlamıştır (Omar ve diğerleri, 2021).

Zhang ve arkadaşları tarafından yapılan bir çalışmada yanmış alan uydu verileri (Global Fire Emissions Database (GFED)) ve tarihsel zaman serisi tahmin edicilerine dayalı olarak orman yangınlarının küresel yanmış alanlarını tahmin etmek için bir hibrit derin sinir ağı (Evrişimsel Sinir Ağı-2D-LSTM) geliştirilmiştir. Evrişimsel Sinir Ağı-2D-LSTM, iki evrişimsel katman, üç tam bağlantılı katman, ReLU işlevleri, iki maksimum havuzlama katmanı ve iki LSTM katmanı içermektedir. GFED veri setinden toplanan 1997 ile 2016 arasındaki aylık yanmış alan verileri ve orman yangınlarını etkileyen zamansal dinamik tahmin ediciler (aylık maksimum/minimum sıcaklıklar, ortalama sıcaklık, özgül nem, toplam yağış, toprak nemi, toprak sıcaklığı, standartlaştırılmış yağış indeksi, LAI ve NDVI) kullanılarak 0,97'lik iyi bir determinasyon katsayısı (R^2) elde edilmiştir (Zhang ve diğerleri, 2022).

Shao ve arkadaşları tarafından yapılan bir çalışmada Çin'deki orman yangınlarının oluşumunu tahmin etmek için doğrusal katmanlar, Batch Normalisation ve LeakyReLU aktivasyon fonksiyonlarını içeren bir derin öğrenme modeli önerilmiştir. Önerilen modeli eğitmek için Çin'in belirli bölgelerindeki zamansal yangın verileri (2001'den 2019'a kadar MODIS'te toplanan 96.594 orman yangını noktası), iklim verileri (günlük maksimum sıcaklık, ortalama sıcaklık, günlük ortalama yer yüzeyi sıcaklığı, ortalama hava basıncı, maksimum rüzgâr hızı, güneşlenme saatleri, günlük ortalama bağıl nem ve ortalama rüzgâr hızı), bitki örtüsü verileri (kesirli bitki örtüsü), topografik verileri (eğim, yön ve yükseklik) ve insan aktiviteleri (nüfus, gayri safi yurtiçi hâsıla, özel tatil, yerleşim alanı ve yol) kullanılmıştır. Test sonuçları önerilen derin öğrenme modelinin %87,4'lük bir doğruluğa ulaştığını göstermiştir (Shao ve diğerleri, 2022).

Eddin ve arkadaşları tarafından yapılan bir çalışmada orman yangını tehlikesinin tahmin edilmesi amacıyla 2D/3D Evrişimsel Sinir Ağı yöntemi önerilmiştir. 2D Evrişimsel Sinir Ağı yöntemi, sayısal yükseklik modeli, eğim, yollara uzaklık, nüfus yoğunluğu, su yollarına uzaklık vb. gibi statik girdiler üretmek için kullanılırken, 3D

Evrişimsel Sinir Ağı sıcaklık, gündüz/gece kara yüzey sıcaklığı, toprak nem indeksi, bağıl nem, rüzgâr hızı, 2m mesafe hava sıcaklığı, NDVI, yüzey basıncı, 2m mesafe çiğ noktası sıcaklığı ve toplam yağış gibi dinamik girdiler üretmektedir. Statik özelliklere dayalı olarak dinamik özellikleri modüle etmek için iki Location-Aware Adaptive Normalization Layer (LOAN) bloğu 3D Evrişimsel Sinir Ağı'na entegre edilmiştir. FireCube (Nikolaou ve diğerleri, 2015) ve Next Day Wildfire Spread (Huot ve diğerleri, 2022) veri kümelerini kullanan 2D/3D Evrişimsel Sinir Ağı, Rastgele Orman, XGBoost, LSTM ve convLSTM gibi temel yöntemlerden daha yüksek bir başarımlar (% 96,48 doğruluk) göstermiştir (Eddin ve diğerleri, 2023).

Jamshed ve arkadaşları tarafından yapılan bir çalışmada 2022'den 2025'e kadar orman yangınlarının oluşumunu tahmin etmek için LSTM yöntemini kullanılmıştır. 2012 ve 2021 yıllarında Pakistan'dan alınan zamansal orman yangını verileri ve yanmış alan verileri eğitim verisi olarak kullanılmış ve %95 doğruluk sağlanmıştır (Jamshed ve diğerleri, 2022).

Naderpour ve arkadaşları tarafından yapılan bir çalışmada Sidney'in Northern Beaches bölgesinde orman yangını risk değerlendirmesi için mekânsal bir yöntem tasarlanmıştır. Bu yöntem iki adımdan oluşmaktadır. İlk adımda, on iki etkili orman yangını faktörü (NDVI, eğim, yağış, sıcaklık, arazi kullanımı, yükseklik, yol yoğunluğu, nehre olan uzaklık, yola olan uzaklık, rüzgâr hızı, nem ve yıllık sıcaklık) kullanılmıştır. Her faktörün ağırlığını belirlemek için üçten fazla gizli katman içeren bir duyarlılık modeli derin bir sinir ağı ile desteklenmiş ve ardından derin sinir ağı tarafından üretilen sonuçları optimize etmek için bir Fuzzy-Based Segmentation Parameter (FbSP) yöntemi kullanılmıştır. İkinci adımda, Analytic Hierarchy Process (AHP) yöntemi, nüfus yoğunluğu, yaş, istihdam oranı, konut, arazi kullanımı, yüksek yoğunluk, yüksek değer vb. gibi sosyal ve fiziksel parametreleri kullanarak fiziksel ve sosyal güvenlik açığı indeksini oluşturmak için güvenlik açığı modeli olarak benimsenmiştir (Yükseklik and Depth - Foundation Spatial Data, 2023). Son olarak, yangın olaylarının envanterini (çok düşük, düşük, orta, yüksek ve çok yüksek) veren bir risk fonksiyonu, orman yangını risk haritasını hesaplamak için kullanılmıştır. Önerilen yöntem, %94,3'lük bir Kappa katsayısı elde etmiştir (Naderpour ve diğerleri, 2021).

Nur ve arkadaşları tarafından yapılan bir çalışmada bir Evrişimsel Sinir Ağı ve bir metasezgisel yöntem içeren hibrit modeller olan Evrişimsel Sinir Ağı-Imperialist Competitive Algorithm (ICA) ve Evrişimsel Sinir Ağı-Grey Wolf Optimizer (GWO)

önerilmiştir. Bu yöntem ile beş sınıfa (çok düşük, düşük, orta, yüksek ve çok yüksek) ayrılmış orman yangını duyarlılığı değerlendirilmiştir. İlk olarak, 2016-2020 yılları arasında Plumas National Forest bölgelerinde Sentinel-1 Sentetik Açıklıklı Radar (SAR) görüntülerinde yanmış orman alanlarını belirlemek ve bir envanter veri seti oluşturmak için Damage Proxy Map (DPM) yöntemi benimsenmiştir. Daha sonra envanter verileri ve topografya faktörleri (yön, yükseklik, eğim ve düzlem eğriliği), meteorolojik faktörler (yağış, maksimum sıcaklık, güneş ışıınımı ve rüzgar hızı), çevresel faktörler (akıntıya uzaklık, kuraklık indeksi, toprak nemi, NDVI ve Topographic Wetness Index (TWI)) ve antropolojik faktörler (arazi kullanımı, mesafe kullanımı ve yerleşime uzaklık) dahil olmak üzere 16 orman yangını koşullandırma faktörü bu modeli eğitmek ve test etmek için kullanılmıştır. Son olarak, Evrişimsel Sinir Ağı hiperparametreleri ICA ve GWO yöntemleri kullanılarak optimize edilmiş ve orman yangını olasılıkları üretilmiştir. Elde edilen sonuç ile Evrişimsel Sinir Ağı-ICA başarımının (0,95'lik bir AUC ve 0,351'lik bir RMSE) Evrişimsel Sinir Ağı-GWO sonucundan (0,974'lük bir AUC 0,334'lük bir RMSE) daha iyi olduğu ortaya konulmuştur (Nur ve diğerleri, 2022).

Bjânes ve arkadaşları tarafından yapılan bir çalışmada Biobio ve Nuble bölgelerinden uydu verileri kullanılarak beş sınıfa (çok düşük, düşük, orta, yüksek ve çok yüksek) ayrılan orman yangını duyarlılık sınıflarını tahmin etmek için Evrişimsel Sinir Ağı-1 ve çok girişli Evrişimsel Sinir Ağı olmak üzere iki Evrişimsel Sinir Ağı mimarisine dayalı bir Ensemble Learning modeli tasarlanmıştır. Evrişimsel Sinir Ağı-1, ilk evrişimsel katmanda Batch Normalizasyon ve Tam Bağlantılı Katman'larda dropout eklenerek değiştirilmiş bir Zhang Evrişimsel Sinir Ağı'dır (Zang ve diğerleri, 2019). Çok girişli Evrişimsel Sinir Ağı, (Sun ve diğerleri, 2017) tarafından çiçek derecelendirmesi için önerilen basit bir Evrişimsel Sinir Ağı'dır. 2013'ten 2019'a kadar on beş yangın etki faktörü ve yangın geçmişi verisinden oluşan büyük bir veri, öğrenme verisi olarak kullanılmıştır (18.734 yangın dâhil). Yangını etkileyen faktörler dört kategoriye ayrılmıştır. Bu kategoriler Terra Climate veri setinden (Abatzoglou ve diğerleri, 2018) toplanan iklim verileri (minimum/maksimum sıcaklık, yağış, rüzgâr hızı, iklimsel su açığı ve gerçek buharlaşma), antropojenik veriler (kentsel bölgelere ve yollara uzaklık), bitki örtüsü verileri (NDVI, nehirlere uzaklık ve arazi örtüsü türü) ve topoğrafik verilerdir (yön, yüzey pürüzlülüğü, eğim ve yükseklik). Önerilen bu model, Evrişimsel Sinir Ağı-1, çoklu girdili Evrişimsel Sinir Ağı ve XGBoost ve SVM gibi geleneksel yöntemleri geride bırakarak %88,77'lik bir F1 skoru göstermiştir (Bjânes ve diğerleri, 2021).

Yukarıda literatür özeti olarak bir çok çalışma sunulmuştur. Bu çalışmalarda çok kapsamlı, farklı materyaller ve yöntemler kullanılmıştır. Çalışmalarda orman yangınlarının tespit ve tahmin edilmesi amacıyla tarihsel orman yangınları verileri ve farklı ana kategorilerde yükseklik, eğim, bakı, yola uzaklık, nehirlere uzaklık yerleşim alanlarına uzaklık, arazi kullanımı, bitki örtüsü indeksi, yağış, sıcaklık ve rüzgâr hızı, nem, LAI, FPAR, EVI, NDVI, NDWI, NDMI, hava basıncı, TWI gibi özellikler ile çok katmanlı algılayıcı, lojistik regresyon, sınıflandırma ve regresyon ağaçları, SVM, rastgele orman, Convolutional Neural Network (CNN), YSA, kernel lojistik regresyon, LSTM, Boosting Machine algoritmaları gibi makine öğrenmesi yöntemleri kullanılmıştır.

Orman yangınlarının tespit ve analiz edilmesinde yapılan çalışmaların geneli incelendiğinde uzaktan algılama yöntemleri ile birlikte hem istatistiksel hem de makine öğrenmesi yöntemleri kullanılmaktadır. Fakat son yıllarda yapılan çalışmaların uzaktan algılama yöntemlerinin makine öğrenmesi algoritmaları ile birlikte kullanıldığı ve yüksek başarımlarına sahip çalışmalar ortaya çıktığı tespit edilmiştir.

Yukarıda verilen çalışmaların ışığında, çalışmamızda daha çok iklim, bitki örtüsü ve topografik veriler analiz edilmiştir. İnsan faktörünün orman yangınları üzerine etkisi çalışmaya dâhil edilmemiştir. Seçilen 18 özellik Antalya ilinden alınan koordinatlara uygunmuş ve bahsi geçen bölgenin iklim, bitki örtüsü ve topografik verilerinin orman yangınlarının meydana gelme olasılığı üzerindeki etkileri değerlendirilmiştir. Ayrıca çalışmamızda seçilen 18 farklı özellik ve Ada Boost, Karar Ağaçları, GBM, KNN, Lojistik Regresyon, SVM ve YSA algoritmalarının Antalya bölgesinin iklim, bitki örtüsü ve topografik yapısı için kullanılması çalışmamızı özgün bir hale getirmektedir.

2.2. Orman Yangınlarının Meydana Gelmesinde Etkili Olan Faktörler

Yangın davranışları hava koşulları (Balling ve diğerleri, 1992), insan faaliyetleri (Velez, 1993), yakıt özellikleri (Schoenberg ve diğerleri, 2003; Mouillot ve diğerleri, 2002) yangın yönetimi faaliyetleri (Fried ve diğerleri, 2004) ve iç kullanımlardaki değişiklikler (Rego, 1992) ve iklim (Flannigan ve diğerleri, 2000; Fried ve diğerleri, 2004) gibi birçok faktörden etkilenmektedir. Bu faktörler arasında iklim değişikliğinin orman yangınlarına atfedilen temel bir faktör olduğu düşünülmektedir (Stephens, 2005; Westerling ve diğerleri, 2006).

Orman yangınlarına etki eden temel faktörlerin belirlenmesi, daha önce orman yangını meydana gelmiş alanlarla birlikte analiz edildiğinde, duyarlılık haritalarının oluşturulmasında büyük öneme sahiptir.

Orman yangınlarının oluşumunu etkileyen en önemli faktörler yanabilen materyaller, iklim ve topografyadır. Yanabilen materyaller literatürde yakıt (fuel) olarak adlandırılmakta olup yakıtın içeriğinde ölü örtü, moloz, kesme atıkları, alt katmandaki otlar ve ot bitkileri, çeşitli çalılar ve ağaçlar yer almaktadır (Eron, 1988; OGM, 1995; Bilgili ve diğerleri, 2002; Güngöroğlu, 2018).

İklimsel açıklamalar, nem koşullarındaki artan değişkenliğin (biyokütle büyümesini ve ardından yanmayı teşvik eden ıslak/kuru salınımlar) ve/veya artan kuraklık sıklığı eğiliminin ve/veya ısınan sıcaklıkların orman yangını aktivitesinin artmasına yol açtığını ileri sürmektedir (Balling ve diğerleri, 1992; Heyerdahl ve diğerleri, 2002).

Uzun vadeli (on yıllık veya daha uzun) iklimsel değişimler yakıt türleri ve yükleri üzerinde büyük bir etkiye sahipken, yıllık iklimsel değişimlerin yakıt kuruması üzerindeki etkileri yoluyla yangın rejimlerini etkilemesi muhtemeldir (Rothermel, 1972; Crimmins ve Comrie, 2004). Önceki çalışmalar, yakıt nem içeriğini düzenleyen yağış rejimlerindeki kısa vadeli (mevsimsel ile yıllık) değişimlerin orman yangını değişkenliğiyle bağlantılı olduğunu göstermiştir (Swetnam ve Betancourt, 1998; Littell ve diğerleri, 2009).

Kuraklık, orman yangını oluşumunun temel bir faktörüdür (Hall ve Brown, 2003; Keetch ve Byram, 1968). Kuraklık orman yakıtını kurutabilir ve yakıt nem içeriğini azaltarak daha kolay tutuşabilir hale getirebilir ve dolayısıyla yakıt tutuşma olasılığını artırabilir. Birçok çalışma, ölü ince yakıtın nemi ile insan faaliyetleriyle orman yangını oluşumu arasında güçlü ilişkiler olduğunu göstermiştir (Vega-Garcia ve diğerleri, 1995; Wotton ve diğerleri, 2003). Kuraklık, yanma koşullarını ciddi şekilde kötüleştirse de, orman yangınlarının yaktığı alanları etkileyen birincil çevresel faktör rüzgârdır (Rothermel, 1983; Maingi ve Henry, 2007). Sıcak ve kuru koşullar rüzgâr olaylarıyla çakıştığında orman yangınları hızla büyük boyutlara ulaşabilir (Crimmins, 2006; Moritz ve diğerleri, 2010).

Bir bölgenin nem oranı ve yakıt yükleri bulunduğu coğrafyanın sahip olduğu topografik özellikler tarafından belirlenir (Maingi ve Henry, 2007). Örneğin Orta İspanya'da, yangınların güney yamaçlarında toplandığı ve yeniden yanan alanların alçak

rakımlı ve daha alçak yamaçlı olduğu ve muhtemelen daha üretken alanlar oldu tespit edilmiştir (Vazquez ve Moreno, 2001).

Antropojenik faktörler incelendiğinde insan aktiviteleri, orman yangınlarının önemli bir tetikleyicisidir. Kundaklama, ateş yakarak kazara yangına sebebiyet verme gibi insan kaynaklı sebeplerle birçok orman yangını meydana gelmektedir (Maingi ve Henry, 2007).


Yakıt durumu olarak bilinen bitki örtüsü türleri ile orman yangınlarının meydana gelme süreci arasında doğrudan bir ilişki olmasa aralarında karmaşık bir ilişki mevcuttur (Turner ve Romme, 1994). Bölgede bulunan bitki örtüsü türleri, ormanın yaşı ve bitki örtüsünün ormandaki dağılımı orman yangınlarının meydana gelme olasılığına katkıda bulunmaktadır (Rollins ve diğerleri, 2002). Ormandaki bitki örtüsünün mekânsal düzeni, normal hava koşullarında yangının yayılma düzenine katkı sağlamaktadır (Brown, 1983). Örneğin, yüksek oranda birbiri ile bağlantılı bitki örtüsü düzeni yangının yayılmasına yardımcı olur (Turner ve Romme, 1994), düzensiz şekilli bitki örtüsü ise yangının yayılma oranını azaltır (Ryu ve diğerleri, 2007).

Buna göre meteorolojik, topografik, antropojenik ve bitki örtüsü faktörleri, orman yangınlarının meydana gelmesinde ve yayılmasında kritik bir rol oynamaktadır. Bu faktörlerin detaylı analizi, orman yangını duyarlılık haritalarının oluşturulmasında ve yangın yönetim stratejilerinin geliştirilmesinde büyük önem taşımaktadır. Her bir faktörün etkileşimi, yangınların davranışını etkileyerek, etkili bir yangın yönetimi için gereken stratejilerin belirlenmesine yardımcı olmaktadır.

3. YÖNTEM

3.1. Önerilen Çalışma Mimarisi

Çalışmada orman yangınlarına ilişkin zamansal veriler, orman yangınlarının meydana gelmesinde etkisinin olduğu değerlendirilen topografik, bitki örtüsü ve hava durumu verileri ile birleştirilerek bir veri seti oluşturulmuştur. Oluşturulan veri seti makine öğrenme algoritmalarına sokularak eğitilmiş ve orman yangını duyarlılık haritası oluşturulmuştur. Şekil 3.1.'de veri setinin oluşturulması, makine öğrenme algoritmalarına sokularak eğitilmesi ve son olarak duyarlılık haritasının oluşturulması süreci gösterilmiştir.




Şekil 3.1. Süreç Akış Diyagramı


3.2. Çalışma Alanı

Bu çalışma, Türkiye'de en çok orman yangını olayı meydana gelen şehirlerinden biri olan ve Akdeniz Bölgesi'nde yer alan Antalya ilinin orman yangını duyarlılık haritasının oluşturulması amaçlamaktadır. Antalya ili toplam olarak 20177 km² yüzölçümüne sahip olup bu alanın 11772 km²'si ormanlık alanlardan oluşmaktadır. Bu da Antalya ilinin kapladığı alanın yarısından fazlasının ormanlık alanlardan oluştuğunu göstermektedir. Antalya ili Türkiye'nin güneybatısında 29° 20'-32°35' doğu boylamları ile 36° 07'-37° 29' kuzey enlemleri arasında yer almaktadır. Antalya ili iklimi genel olarak Akdeniz iklim tipinden oluşmaktadır. Yaz ayları sıcak ve kurak geçerken, kış aylarında ılık ve yağmurlu bir iklim gözlenmektedir. Yazın ortalama sıcaklık 28-36 °C derece arasındadır. Ocak ayında ise sıcaklık 10 ila 20 °C civarlarında seyretmektedir. Denize yakın bölgelerde kar yağışı çok nadir görülür, don olayı ise nadir olmakla beraber, denize yakın bölgelerde her kış mevsiminde gözlenmemektedir. Yağış olmadığı günler hava açık ve güneşlidir. İlde yıllık ortalama nispi nem %64 civarındadır.

2023 yılında Türkiye'de meydana gelen 2579 adet orman yangını olayından 171 adedi Antalya ilinde meydana gelmiş olup bu rakamlar Antalya'da meydana gelen orman yangınlarının Türkiye'de meydana gelen orman yangınlarının %6,63'ünü oluşturduğunu göstermektedir. Ayrıca aynı yıl Türkiye genelinde 15520 hektar orman alanı yangınlar nedeniyle zarar görürken bu sayının 768 hektar alan kısmı Antalya ili sınırlarında oluşmuştur. Bu da toplam yangınlardan zarar gören alana oranın %4,95 olduğunu göstermektedir. 1988 ile 2023 yılları arasında Antalya ilinde meydana gelen orman yangınları sonucunda yanan alan miktarı Şekil 3.2.'de gösterilmiştir. Şekil 3.3.'de ise Türkiye geneli ve Antalya ilinin 2023 yılına ait orman yangını sayıları gösterilmiştir (OGM, 2024).




Şekil 3.2. 1988-2023 Türkiye geneli yanan orman alanı miktarı



Şekil 3.3. 2023 yılı karşılaştırmalı orman yangını sayıları

OGM verilerine göre Antalya ilinin toplam orman alanı Türkiye'nin toplam orman alanının %8,3'ünü oluşturmaktadır. Antalya'daki orman gençleştirme faaliyetlerinin oranı %8,1 oranında olup Türkiye genelinden (%6,1) daha yüksektir. Orman bakım alanı oranı Antalya'da (%91,9) Türkiye geneline (%85,1) kıyasla daha yüksektir, bu da Antalya'da mevcut ormanların korunmasına daha fazla önem verildiğini


göstermektedir. Ayrıca Şekil 3.4.'de Antalya'da 2000-2023 yılları arasında meydana gelen yangın sayılarını gösterilmektedir.



Şekil 3.4. Antalya'da 2000-2023 arasındaki yangın sayısı

OGM'ye bağlı olarak Antalya Bölge Müdürlüğüne bağlı ormanlı alanlarda 1176630 hektar koru orman alanı bulunmakta olup Türkiye genelinin %5.2'sine, 3611 hektar baltalık orman alanı bulunmakta olup Türkiye genelinin %0.3'üne, 1180241 hektar genel ormanlık alanı bulunmakta olup Türkiye genelinin %5'ine karşılık gelmektedir.

Şekil 3.5.'de çalışma alanı olarak seçilen bölge işaretlenerek gösterilmiştir. Çalışmada kullanılan zamansal yangın verileri ve bu koordinatlara ait özellikler Antalya ili sınırları içerisinde seçilmiştir.



Şekil 3.5. Çalışma alanı olarak seçilen bölge

3.3. Veri Seti Aşamaları

3.3.1. Uzaktan algılama

Bu çalışmada, orman yangınlarının duyarlılık haritalarının oluşturulmasında uzaktan algılama verileri ve yöntemleri temel alınmıştır. Uzaktan algılama, geniş alanlardan toplanan verilerin analiz edilmesini sağlayarak yangın gibi çevresel olayların modellenmesinde önemli bir araç olarak kullanılmaktadır. Çalışmada kullanılan veriler, çeşitli uydu kaynaklı veri tabanlarından alınmış ve Google Earth Engine (GEE) platformunda analiz edilmiştir. GEE, geniş çaplı veri işleme kapasitesiyle uzaktan algılama verilerinin hızlı ve verimli bir şekilde analiz edilmesini sağlamıştır. Zamansal orman yangınlarına ilişkin FIRMS MODIS verileri, NASA'nın FIRMS veri tabanından elde edilmiştir. FIRMS, MODIS sensörlerinden alınan termal bant verileriyle yangınların coğrafi koordinatlarını ve zaman bilgilerini sağlamaktadır. Bu veriler, 2013-2023 yılları arasında Antalya il sınırları içinde gerçekleşen yangınların tespiti için kullanılmıştır. ERA-5 verileri, atmosferik değişkenler konusunda yüksek çözünürlüklü veriler sunarak sıcaklık, rüzgâr hızı ve yağış miktarı gibi meteorolojik değişkenlerin analizinde kullanılmıştır. ERA-5, hem geçmiş verilerin detaylı bir şekilde modellenmesini hem de bölgesel ölçeklerde meteorolojik koşulların değerlendirilmesini sağlamıştır. Bu çalışmada sıcaklık ve rüzgâr hızlarının maksimum ve minimum değerleri ile günlük

toplam yağış miktarı, yangın riski üzerinde etkili parametreler olarak değerlendirilmiştir. Nem verileri GLDAS veri setinden alınmıştır. GLDAS, kara yüzeyi nem durumlarını modelleyerek bölgedeki toprak ve bitki örtüsünün yangın riskine etkisini incelemek için temel bir veri kaynağı oluşturmıştır. Bitki örtüsü değişkenleri (NDVI, EVI, NDWI, LAI ve FPAR), MODIS sensöründen elde edilen veriler kullanılarak hesaplanmıştır. NDVI ve EVI, bitki örtüsünün sağlığını ve yoğunluğunu değerlendirirken, bitki örtüsünün su içeriğini belirlemiştir. LAI ve FPAR değerleri ise bitkilerin fotosentetik aktivitesini ve ışık kullanma kapasitesini ortaya koymuştur. Bu parametreler, yangınların özellikle bitki örtüsü üzerindeki etkilerini analiz etmek için kritik öneme sahiptir. Topografik değişkenler, NASA'nın SRTM veri setinden alınmıştır. SRTM, yüksek çözünürlüklü arazi modelleri sağlayarak eğim, bakı ve yükseklik gibi faktörlerin analiz edilmesine olanak tanımıştır. Bu veriler, yangınların topografya ile ilişkisini değerlendirmek için kullanılmıştır.

GEE, akademik, coğrafi veri kümelerinin bilimsel analizi ve görselleştirilmesine yönelik bir platformdur. GEE, uydu görüntülerini içermekte ve bunları kırk yıldan daha eskiye dayanan tarihsel dünya görüntülerini içeren genel bir veri arşivinde saklamaktadır. GEE veri setlerinden faydalanabilmek amacıyla günlük olarak alınan görüntüler daha sonra küresel ölçekte veri madenciliği için kullanılabilir hale getirilmektedir. GEE ayrıca büyük veri kümelerinin analizini mümkün kılan birçok farklı araca sahiptir (Google, 2024c).

Veri setinin oluşturulması kapsamında yapılan kullanılan tüm veriler, GEE ortamında işlenmiş ve analiz edilmiştir.

3.3.1.1. FIRMS

NASA'nın FIRMS veri tabanı, orman yangını aktivitesiyle ilgili neredeyse gerçek zamanlı verilere erişim sağlayabilmektedir. FIRMS websitesi üzerinden dünya üzerinde meydana gelen tüm yangınlar, neredeyse gerçek zamanlı olarak izlenebilmektedir. Sistem ağırlıklı olarak Amerika Birleşik Devletleri ve Kanada'da meydana gelen yangınların tespiti için çalışsa da tüm dünyada meydana gelen yangınlar için bilgi sağlamaktadır.

Bunun yanında FIRMS veri tabanının çalışmamıza en büyük katkısı zamansal orman yangınlarına ilişkin verileri içermesi olmuştur. FIRM veri tabanında MODIS ve VIIRS S-NPP enstrümanlarından alınan verilere ulaşılabilir. Ülke bazında olmak

üzere MODIS sensöründen 2000 ile 2003 yılları arasında VIIRS S-NPP sensöründen ise 2012 ile 2023 yılları arasındaki veriler elde edilebilmektedir. (FIRMS, 2024)

FIRMS veri tabanından elde edilen zamansal orman yangınlarına ilişkin veriler tek bir koordinata ait birçok farklı bilgi içermektedir. Yangının meydana geldiği enlem, boylam ve tarih bilgisinin yanısıra sensörün tespit ettiği parlaklık değeri, “confidence” olarak bilinen güven değeri gibi diğer önemli bilgileri içermektedir.

Çalışmamızda Antalya ilinde yangının meydana geldiği noktaları tespit etmek ve bu noktalardaki diğer 18 farklı özellik değerlerini çıkarabilmek için enlem, boylam ve tarih bilgileri kullanılmıştır. Ayrıca sistem tespit ettiği her bir yangın olayına bir güven değeri atadığı için çalışmamızda sadece “confidence” değeri 70 ve üzeri olarak tespit edilen yangın olayları dikkate alınmıştır.

3.3.1.2. ERA-5

ERA5, Ocak 1940'tan günümüze kadar olan dönemi kapsayan beşinci nesil ECMWF atmosferik küresel iklim yeniden analiz veri tabanıdır. ERA5, ECMWF'deki Copernicus İklim Değişikliği Servisi (C3S) tarafından üretilmektedir. ERA5, çok sayıda atmosferik, kara ve okyanus iklim değişkeninin saatlik tahminlerini sağlayabilmektedir. Veriler, Dünya'yı 31 km'lik bir şebekede kapsamakta ve atmosferi yüzeyden 80 km yüksekliğe kadar 137 farklı seviye kullanarak çözümlemektedir (ECMWF, 2024).

ERA-5 veri tabanı kullanılarak, çeşitli atmosferik ve yüzey özellikleri hesaplanmıştır. Bu hesaplamalar, kara, deniz ve göller gibi su yüzeylerinden 2 metre yükseklikte ölçülen hava sıcaklığı ile günlük maksimum ve minimum yüzey sıcaklıklarını içermektedir. Ayrıca, 10 metre yükseklik seviyesinde rüzgârların doğu-batı ve kuzey-güney yönündeki bileşenlerinin en yüksek ve en düşük hızları ile günlük toplam maksimum yağış miktarları elde edilmiştir (Google, 2024a).

3.3.1.3. GLDAS

GLDAS'ın amacı, gelişmiş arazi yüzeyi modelleme ve veri asimilasyon teknikleri kullanılarak uydu ve yer tabanlı gözlem veri ürünleri yardımıyla arazi yüzeyi durumlarını ve yüzey akışlarının optimum alanlarını oluşturmaktır (Rodell ve diğerleri, 2004a).

GLDAS veri tabanında bulunan özgül nem değerleri Antalya ili için belirtilen tarih ve koordinatlarda elde edilmiştir (Google, 2024b).

3.3.1.4. MODIS

NASA'nın Terra ve Aqua uyduları orman yangınlarını tespit etmede en önemli uzaktan algılama araçlarıdır. Bahse konu uydular üzerlerinde bulunan MODIS aracıyla yangın tespitini gerçekleştirmektedirler. Terra'nın Dünya etrafındaki yörüngesi, sabah saatlerinde ekvatorun üzerinden kuzeyden güneye geçerken, Aqua'nın öğleden sonra ekvatorun üzerinden güneyden kuzeye geçmesi için zamanlanmıştır. Terra MODIS ve Aqua MODIS, her 1 ila 2 günde bir tüm Dünya yüzeyini görüntüleyerek 36 spektral bantta veya dalga boyu gruplarında veri toplamaktadır (NASA, 2024c).

16 günlük zamansal çözünürlük ve birden fazla mekânsal çözünürlükte üretilen MODIS bitki örtüsü indeksleri, yaprak alanı, klorofil ve kanopi yapısının bileşik bir özelliği olan bitki örtüsü gölgelik yeşilliğinin tutarlı mekânsal ve zamansal karşılaştırmalarını sağlamaktadır. İki bitki örtüsü indeksi (NDVI ve EVI), kırmızı, yakın kızılötesi ve mavi dalga bantlarındaki atmosferik olarak düzeltilmiş yansımalarından türetilmektedir.

LAI, geniş yapraklı kanopilerde birim zemin alanı başına tek taraflı yeşil yaprak alanı ve iğne yapraklı kanopilerde birim zemin alanı başına toplam iğne yüzey alanının yarısı olarak tanımlanmaktadır. FPAR, yeşil bitki örtüsü tarafından emilen fotosentetik olarak aktif radyasyonun (400-700 nm) oranı olarak tanımlanmaktadır. Her iki değişken de yüzey fotosentezini, buharlaşmayı ve net birincil üretimi hesaplamak için kullanılır ve bunlar da karasal enerjiyi, karbonu, su döngüsü süreçlerini ve bitki örtüsünün biyojeokimyasını hesaplamak için kullanılmaktadır (NASA, 2024d).

NDWI ise su kütlelerinin analizi için kullanılmaktadır. Bu indeks uzaktan algılama görüntülerinin yeşil ve Narrow Infrared (NIR) bantlarını kullanırken NDVI ise yeşil ve yakın kızılötesi bantları kullanmaktadır.

3.3.1.5. NASA SRTM

SRTM veri kümeleri, NASA ve National Geospatial Intelligence Agency (NGA)'nın işbirlikçi çabalarının yanı sıra Alman ve İtalyan uzay ajanslarının katılımının

bir sonucu olarak ortaya çıkmıştır. Bu uluslararası uzay iş birliği, radar interferometrisi kullanarak Dünya'nın küresele yakın bir dijital yükseklik modelini oluşturmaktadır (SRTM, 2015). SRTM, 60° kuzey ve 56° güney enlemleri arasında Dünya kara yüzeyinin %80'inden fazlasına ait radar verilerini toplamıştır. Bu veriler, her 1 yay saniyesinde yükseklik kayıtları olan küresel bir dijital yükseklik modeli oluşturmak için kullanılmıştır (SRTM, 2024).

SRTM verilerinden ilgili koordinatlara ait yükseklik, bakı ve eğim değerleri elde edilmiştir.

3.3.2. Orman yangınlarına etki eden faktörler

Bölüm 2.2.'de yapılan literatür araştırmaları sonucunda Çizelge 3.1. yer alan faktörler orman yangınlarının duyarlılık haritalarının oluşturulması sürecinde kullanılmak amacıyla seçilmiştir.

Çizelge 3.1. Veri setini oluşturmak için kullanılan faktörler

Değişken	Birim	Kaynak	Çözünürlük/Skala	Veri Tipi
Geçmiş Yangın Verileri				
Yangın	#YOK	FIRMS	#YOK	Vector
Meteorolojik Faktörler				
En Yüksek Hava Sıcaklığı	°K	ERA5	11132 meters	NetCDF
En Düşük Hava Sıcaklığı	°K	ERA5	11132 meters	NetCDF
En Yüksek Doğu Batı Yönlü Rüzgar Hızı	m/s	ERA5	11132 meters	NetCDF
En Düşük Doğu Batı Yönlü Rüzgar Hızı	m/s	ERA5	11132 meters	NetCDF
En Yüksek Kuzey Güney Yönlü Rüzgar Hızı	m/s	ERA5	11132 meters	NetCDF
En Yüksek Kuzey Güney Yönlü Rüzgar Hızı	m/s	ERA5	11132 meters	NetCDF
Nem	mass fraction	GLDAS	27830 meters	NetCDF
En Yüksek Yağış Miktarı	m	ERA5	11132 meters	NetCDF
En Yüksek Kara Yüzey Sıcaklığı	°K	ERA5	11132 meters	NetCDF
En Düşük Kara Yüzey Sıcaklığı	°K	ERA5	11132 meters	NetCDF
Bitki Örtüsü				
NDVI	ratio	MODIS	463 meters	HDF
EVI	ratio	MODIS	463 meters	HDF
FPAR	%	MODIS	500 meters	HDF
LAI	m ²	MODIS	501 meters	HDF
NDWI	ratio	MODIS	463 meters	HDF
Topografik Faktörler				
Bakı	°	NASA SRTM	28 meters	Raster
Eğim	°	NASA SRTM	29 meters	Raster
Yükseklik	m	NASA SRTM	30 meters	Raster

3.3.3. Veri toplama

Veri setinin oluşturulması sürecinde Antalya ilinde 2013-2023 yılları arasında meydana gelen ve NASA FIRMS veri tabanında bulunan ve yangın güvenilirlik oranı olan “confidential” değerinin %70 ve üzerinde bulunan yangın noktaları belirlenmiştir. Bu kapsamda yıllık yangın sayılarının en fazla olduğu haziran, temmuz, ağustos ve eylül ayları seçilmiş ve toplam olarak 1468 adet yangın noktası tespit edilmiştir. Her bir yangın noktasına ait koordinatlar ve yangınların meydana geldiği tarihler belirlenmiştir. Veri setinin oluşturulmasının ardından veriler makine öğrenmesi algoritmaları ile eğitileceğinden aşırı öğrenme sorununun meydana gelmemesi amacıyla tespit edilen yangın noktaları sayısı kadar rastgele tarihlere karşılık gelen rastgele noktalar belirlenmiştir. Bu noktalara ait koordinatlar elde edilerek yangın meydana gelmemiş noktaların da tespit edilmesi planlanmıştır. Bu kapsamda Antalya ili genelinden yerleşim alanlarını, ormanlık alanları, nehir, göl gibi su alanlarını, tarım alanlarını, orman içermeyen verimsiz alanları içeren 1468 adet rastgele nokta ve rastgele tarih GEE platformu kullanılarak üretilmiş ve toplam olarak 2936 adet nokta belirlenmiştir. Belirlenen noktaların koordinatları elde edildikten sonra, koordinatların kendilerine karşılık gelen tarihlerde GEE platformu aracılığıyla yukarıda bahsi geçen 18 farklı özelliğe ait değer elde edilmiştir. Yangın meydana gelmiş noktalar veri seti çıktısı olarak 1 ve yangın meydana gelmemiş noktalar veri seti çıktısı 0 olarak sınıflandırılmıştır.

3.3.4. Veri ön işleme

3.3.4.1. Kayıp değerlerin Moving Average Imputation yöntemi ile elde edilmesi

Veri toplama esnasında bazı uydu ve sistemlerin dâhili hatalarından meydana gelen ve belirli bir noktada veri elde edememe durumu ile karşılaşmıştır. Çok nadir olarak karşılaşılan bu durum sonucunda, 2936 noktanın her biri için 18 farklı özellik elde edildiği ve toplam olarak 52848 adet değer oluşturulduğu göz önüne alındığında yaklaşık 100 kadar değer elde edilemediği tespit edilmiştir. Elde edilemeyen bu değerlere karşılık gelen noktalardaki yangın bilgisini kaybetmemek amacıyla Moving Average Imputation yöntemi kullanılmıştır (Saeipourdizaj ve diğerleri, 2021). Moving Average Imputation yöntemine ait denklem Denklem (3.1)’de verilmiştir. Bu yöntemle verilerin

kendinden önceki dört ve kendinden sonraki 4 değerin aritmetik ortalamaları alınarak boş olan değerler doldurulmuştur. Bu sayede ilgili noktalar veri setinden çıkartılarak yaklaşık 100 noktanın yangın bilgisinin kaybedilmesi sorununun önüne geçilmiştir.

$$X_{kayıp} = \frac{\sum_{i=k_1}^{k_2} X_i}{n} \quad (3.1)$$

3.3.4.2. Veri normalizasyonu

2936 adet noktanın her biri için elde edilen 18 adet veriye ait sayısal değerler incelendiğinde her biri arasında aritmetik, geometrik veya oransal bir ilişki bulunmadığından bu verilerin tamamı makine öğrenmesi algoritmalarının öğrenme sürecini kolaylaştırmak amacıyla 0 ile 1 değerleri arasında bir değer alacak şekilde normalize edilmiştir. Bunun sonucunda 52848 adet veri 0 ile 1 değerleri arasında bir değere sahip olmuştur. Verilerin normalize hale getirilmesinde Denklem (3.2)'de işlem uygulanmıştır.

$$x_{normalize} = \frac{x - x_{küçük}}{x_{büyük} - x_{küçük}} \quad (3.2)$$

Veri normalizasyonu işlemi ayrıca makine öğrenmesi modellerinin öğrenim süreci tamamlandıktan sonra modele verilecek gerçek veriler üzerinde ve modellerin gerçek veriler ile yapmış olduğu orman yangını meydana gelme olasılığına ilişkin değerler üzerinde de uygulanmıştır. Bahse konu gerçek veriler ile modelin ortaya koyduğu olasılık değerlerine ilişkin daha ayrıntılı bilgi Bölüm 4.3.1'de verilmiştir.

3.3.5. Özellik seçimi ve özelliklerin karşılıklı ilişkisi

İki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü ölçen istatistiksel bir yöntem olan Korelasyon yöntemi, özellikler arasındaki ilişkiyi anlamak ve değerlendirmek için kullanılmıştır.

Korelasyon analizi, genellikle Pearson korelasyon katsayısı (r) kullanılarak yapılmakta olup bu katsayı -1 ile +1 arasında bir değer almaktadır. Korelasyon katsayısı Denklem (3.3)'ye göre hesaplanmaktadır.

$$r = \frac{Cov(X,Y)}{\sigma_X \cdot \sigma_Y} \quad (3.3)$$

Korelasyon analizi, özelliklerin sınıflandırma sonucuna olan etkisini değerlendirmek amacıyla yapılmıştır. Özelliklerin karşılıklı ilişkisi ve özellik seçim süreci Bölüm 4.1’de ayrıntılı olarak açıklanmıştır.

3.3.6. Veri setinin oluşturulması

Veri setinde kullanılan FIRMS veri tabanında yangınların ölçümünde kullanılan ve bir güven indeksi olan “confidence” değerinden faydalanılmıştır. Algılama sensörünün tespit ettiği yangının ne derece doğru olduğunun bir ölçüsü olan bu değer “Yangın Var” ya da “Yangın Yok” çıktı değerleri yerine konulmuştur. Veri setinin oluşturulması sürecinde “confidence” değerleri %70’den fazla olan olaylar yangın var olarak değerlendirilmiştir. Burada “Yangın Var” olarak sınıflandırma yapılan “1” değerleri yerine olaya karşılık gelen “confidence” değeri girilmiştir. Yangın çıkmamış noktalardan elde edilen değerlerin “confidence” karşılığına ise “0” girilmiştir. Burada dikkat edilecek husus ise “confidence” değerleri %70’den az fakat yangın tespit edilmiş noktalar veri setinde kullanılmadığından herhangi bir veri girişi yapılmamıştır.

Seçilen 18 farklı özellik farklı uydular kullanılarak toplanmıştır. Zamansal yangın verileri NASA’nın Terra ve Aqua adlı iki uydusunda bulunan MODIS sensörleri tarafından tespit edilerek FIRMS veri tabanına aktarılan verilerden süzülerek elde edilmiştir. Sıcaklık, rüzgâr ve yağış verileri ECMWF tarafından geliştirilen bir yeniden analiz veri seti olan ERA-5 veri tabanından elde edilmiştir.


Nem verileri ise kara yüzeyi ile ilgili meteorolojik ve hidrolojik verileri birleştiren bir veri asimilasyon sistemi olan GLDAS veri tabanından toplanmıştır.

NDVI, NDWI, EVI, PAR, LAI gibi özellikler MODIS uydusu aracılığıyla elde edilmiştir.


Bakı, eğim ve yükseklik gibi topolojik faktörler ise NASA tarafından gerçekleştirilen bir radar topografya görevi olan SRTM veri tabanından elde edilmiştir.

Veriler bahsi geçen veri tabanlarından ve sistemlerden elde edilirken mümkün olduğu kadar günlük olarak yinelenen veriler kullanılmıştır. Özellikle belirli tarihlerden sonra günlük olarak yinelenemeyen verilerde, verilerin elde edilme frekansına göre 4, 8 ve 16 günlük veriler kullanılmıştır. Bu verilerin istenen tarihe en yakın tarihlerdeki


ortalamaları alınarak deęerler elde edilmiřtir. 2013-2022 yılları arasında tm veriler gnlk olarak elde edilmiř, 2022-2023 yılları arasında ise FPAR ve LAI deęerleri 4 gnlk EVI, NDVI ve NDWI deęerleri ise 16 gnlk frekanslar ile toplanmıřtır. řekil 3.6. ve řekil 3.19. arasında Antalya ilinin seilen tm zelliklere ait haritalar gsterilmiřtir.




řekil 3.6. 2012-2021 arasında yangın meydana gelmiř alanlar ve rastgele seilmiř yangın meydana gelmemiř alanlar




Şekil 3.7. Antalya ilinin ortalama hava sıcaklığı haritası




Şekil 3.8. Antalya ilinin ortalama rüzgâr hızı haritası




Şekil 3.9. Antalya ilinin ortalama yağış haritası




Şekil 3.10. Antalya ilinin kara yüzey sıcaklığı ortalama haritası




Şekil 3.11. Antalya ilinin spesifik nem ortalama haritası




Şekil 3.12. Antalya ilinin NDVI ortalama haritası




Şekil 3.13. Antalya ilinin EVI ortalama haritası




Şekil 3.14. Antalya ilinin LAI ortalama haritası




Şekil 3.15. Antalya ilinin FPAR ortalama haritası




Şekil 3.16. Antalya ilinin yükseklik haritası



Şekil 3.17. Antalya ilinin eğim haritası



Şekil 3.18. Antalya ilinin bakı haritası



Şekil 3.19. Antalya ilinin NDWI haritası

3.3.7. Makine öğrenmesi

Makine öğrenmesi, bilgisayarların deneyimlerden öğrenerek ve geçmiş verilere dayanarak karar alarak insan müdahalesine gerek kalmadan kendini geliştirmesini sağlayan bir yapay zekâ alt alanıdır (Alpaydin, 2020). Bu teknoloji, özellikle büyük veri ve gelişmiş hesaplama gücüyle birlikte hızla büyümüş ve hayatın birçok alanında yaygın hale gelmiştir (Goodfellow ve diğerleri, 2016). Makine öğrenmesi, istatistik, yapay zekâ, felsefe, bilgi teorisi, biyoloji, bilişsel bilim, hesaplamalı karmaşıklık ve kontrol teorisi dâhil olmak üzere birçok alandaki kavram ve sonuçlardan yararlanır (Mitchell, 1997). Makine öğrenmesi genellikle denetimli, denetimsiz ve pekiştirmeli öğrenme olarak üç ana kategoride incelenir. Denetimli öğrenme, algoritmanın etiketli bir veri seti ile eğitildiği ve yeni, benzer verilere dayanarak tahminlerde bulunmayı öğrendiği süreçtir. Bu yöntem, sınıflandırma ve regresyon gibi alanlarda kullanılır. Denetimsiz öğrenme ise, algoritmaların etiketsiz verilerdeki kalıpları tanımasını sağlamak için kullanılır. Kümeleme ve boyut azaltma gibi yöntemler, büyük ve karmaşık veri kümelerinin analizinde tercih edilir. Son olarak, pekiştirmeli öğrenme, bir ajanın çevresiyle etkileşim kurarak ödül veya ceza mekanizmalarına dayalı olarak öğrenmesini içerir ve robotik, oyun geliştirme ve özerk sistemlerde sıklıkla kullanılır (Goodfellow ve diğerleri, 2016).

3.3.7.1. AdaBoost

Boosting, birçok nispeten zayıf ve yanlış kuralı birleştirerek oldukça doğru bir tahmin kuralı oluşturma fikrine dayanan bir makine öğrenmesi yaklaşımıdır (Freund ve Schapire, 1997). Freund ve Schapire'nin Ada Boost algoritması (Freund ve Schapire, 1997) ilk pratik boosting algoritmasıdır ve çok sayıda alanda uygulamaları olan en yaygın kullanılan ve incelenen algoritmalarından biridir (Schapire, 2013).

Çalışmamızda, oluşturulan veri seti bir Ada Boost algoritmasına tanıtılmıştır. Ada Boost algoritmasının iki sınıflı verilerde karar ağaçlarını kullanan AdaBoostM1 versiyonu kullanılmıştır. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür. Modelin öğrenme oranı 0.1 seçilmiştir.

Modele her veri noktası için eşit ağırlıklar atanmıştır. Ağırlık denklemi Denklem (3.4)'de verilmiştir.

$$w_i = \frac{1}{n} \quad (3.4)$$

İlk sınıflandırıcı eğitime başlandıktan sonra ve her veri noktasının ağırlıklarına göre doğruluğu ölçülmüştür. İlk sınıflandırıcıya göre yapılan yanlış sınıflandırmaların ağırlıklı hata oranı hesaplanmıştır. Hata oranı denklemi Denklem (3.5)'de gösterilmiştir. Hata oranı, her bir sınıflandırıcının gösterdiği başarımı yansıtmaktadır.

$$\epsilon = \frac{\sum_{\text{yanlış sınıflandırılan } i} w_i}{\sum_i w_i} \quad (3.5)$$

Ardından her sınıflandırıcının ağırlığı, hata oranına göre ayarlanmıştır. Model, hata oranı düşük olan sınıflandırıcıya daha fazla ağırlık atamaktadır. Sınıflandırıcı ağırlığı denklemi Denklem (3.6)'de gösterilmiştir.

$$\alpha = \ln\left(\frac{1-\epsilon}{\epsilon}\right) \quad (3.6)$$

Hatalı sınıflandırılmış örneklerin ağırlıkları arttırılmış, doğru sınıflandırılmış örneklerin ağırlıkları ise azaltılmıştır. Bu, bir sonraki adımda bu örneklere daha fazla dikkat edileceği anlamına gelmektedir. Ağırlık güncelleme denklemi Denklem (3.7)'da verilmiştir.

$$w_i \leftarrow w_i x e^{axy_i h(x_i)} \quad (3.8)$$

Son olarak tüm zayıf sınıflandırıcılar ağırlıklarına göre birleştirilerek daha iyi bir genel sınıflandırıcı oluşturulmuştur.

3.3.7.2. Decision Tree (Karar Ağacı)

Bir karar ağacı, kökten başlayan herhangi bir yolun, yaprak düğümünde bir ya da sıfır olarak ikili bir sonuç elde edilene kadar bir veri ayırma dizisiyle tanımlandığı ağaç tabanlı bir yöntemdir (Yang, 2019;Liang ve diğerleri, 2021;Mohsin ve diğerleri, 2021;Eesa ve diğerleri, 2015). Düğümler ve bağlantılar içeren bilgi ilişkilerinin hiyerarşik örneklemesidir. Sınıflandırma için ilişkiler kullanıldığında, düğümler amaçları temsil eder(Shamim ve diğerleri, 2010;Suresh ve diğerleri, 2020;Priyanka ve Kumar, 2020;Eesa ve diğerleri, 2017).

Oluşturulan veri seti bir karar ağacı algoritmasına tanıtılmıştır. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür.

Karar ağacı algoritmasının temelini oluşturan temel kavramlar, entropi ve bilgi kazancı ile ilgilidir. Entropi verinin karışıklığını ölçen bir kavramdır. Entropi denklemi Denklem (3.8)'de verilmiştir.

$$H(S) = - \sum_{i=1}^C p_i \log_2(p_i) \quad (3.8)$$

Bir özellik kullanarak veri kümesini bölündüğünde elde edilen bilgi kazancı, entropinin azalması olarak tanımlanmaktadır. Bilgi kazancı denklemi Denklem (3.9)'de verilmiştir.

$$IG(S, A) = H(S) - \sum_{u \in A} \frac{|S_u|}{|S|} H(S_u) \quad (3.9)$$

Bu formüller kullanılarak, en yüksek bilgi kazancına sahip olan özellik seçilmiş ve veri kümesi bu özellik üzerinden bölünmüştür. Süreç, tüm veriler belirli bir sınıfa ulaşana kadar devam etmiştir.

3.3.7.3. Gradient Boosting Machine (GBM)

Temel yaklaşım, weak learners (zayıf öğreniciler) olarak adlandırılan birkaç basit modeli yinelemeli olarak birleştirerek gelişmiş tahmin doğruluğuna sahip bir strong learner (güçlü öğrenici) elde etmektir (Touzani ve diğerleri, 2018). GBM yöntemi, kayıp fonksiyonunu en aza indiren bir katkı modeli bulmayı amaçlayan sayısal bir optimizasyon algoritması olarak görülebilir. Bu nedenle, GBM algoritması her adımda yinelemeli olarak kayıp fonksiyonunu en iyi şekilde azaltan yeni bir karar ağacı (zayıf öğrenen) eklemektedir (Friedman, 2001).

Oluşturulan veri seti bir GBM algoritmasına tanıtılmıştır. Ensemble methodları arasında Logit Boost methodu kullanılmıştır. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür. Modelin öğrenme saykılı 100 olarak seçilmiştir.

GBM algoritması, her bir tahmin adımında hataları minimize eden bir dizi işlem kullanmaktadır.

$$L(y, F(x)) = \sum_{i=1}^n l(y_i, F(x_i)) \quad (3.10)$$

$$F_m(x) = F_{m-1}(x) + v h_m(x) \quad (3.11)$$

Denklem (3.10) ve (3.11)'da verilen denklemlerle modelin her adımda hata düzeltme işlemleri uygulanmıştır.

3.3.7.4. K-Nearest Neighbors (KNN)

KNN, hem sınıflandırma hem de regresyon problemlerinde kullanılan, oldukça basit ancak etkili bir örnek tabanlı algoritmadır. KNN, verileri sınıflandırmak veya değer tahmini yapmak için veri noktasının en yakın komşularına (k komşusu) bakarak karar verir. Örneğin, sınıflandırma problemlerinde bir veri noktasının hangi sınıfa ait olduğunu tahmin etmek için bu noktaya en yakın K komşunun sınıfına bakar ve çoğunluğun sınıfını seçer.

Oluşturulan veri seti bir KNN algoritmasına tanıtılmıştır. Modelde komşuluk sayısı 5 olarak seçilmiştir. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür. KNN algoritmasında kullanılan en yaygın mesafe hesaplama yöntemi Öklidyen mesafedir. Bu yöntem iki veri noktası arasındaki mesafeyi hesaplayarak hangi noktaların daha yakın olduğunu belirlemeye yardımcı olmaktadır. Öklidyen mesafe hesaplama denklemi Denklem (3.12)'de verilmiştir.

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.12)$$

3.3.7.5. Logistic Regression (Lojistik Regresyon)

Lojistik regresyon, özellikle ikili sınıflandırma problemlerinde yaygın olarak kullanılan, istatistiksel temellere dayalı bir algoritmadır. Bu algoritma, verilen girdilere dayalı olarak bir olayın gerçekleşme olasılığını tahmin etmektedir.

Oluşturulan veri seti bir Lojistik Regresyon algoritmasına tanıtılmıştır. Modelde komşuluk sayısı 5 olarak seçilmiştir. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt

grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür. Lojistik Regresyon’da, girdiler ve çıktılar arasında doğrusal bir ilişki kurulması yerine, veriler “sigmoid fonksiyon” adı verilen bir eğriye oturtularak sonuç alınmaktadır. Sigmoid fonksiyonu Denklem (3.13)’de verilmiştir.

$$P(Y = 1|X) = \frac{1}{1+e^{-(\beta_0+\beta_1X_1+\beta_2X_2+\dots+\beta_nX_n)}} \quad (3.13)$$

Sigmoid fonksiyonu, verilen girdi özelliklerine göre çıkan değeri 0 ve 1 arasında sınırlayarak bir olayın gerçekleşme olasılığını tahmin etmektedir. Lojistik Regresyonun amacı, modeldeki katsayıları belirlemek ve en uygun hale getirmektir. Bu sayede, veri setindeki faktörler ve yangın olasılığı arasındaki ilişkiyi anlamak mümkün olmaktadır.

3.3.7.6. Support Vector Machine (Destek Vektör Makinesi)

Destek Vektör Makinesi, iki sınıflı sınıflandırma problemlerini çözmek için kullanılan bir makine öğrenimi yöntemidir. Kavramsal olarak giriş vektörleri doğrusal olmayan bir şekilde çok yüksek boyutlu bir özellik alanına eşlenmektedir. Bu özellik alanında doğrusal bir karar yüzeyi oluşturulmaktadır. Karar yüzeyinin özel özellikleri, öğrenme makinesinin yüksek genelleme yeteneğini garanti etmektedir (Cortes ve Vapnik, 1995).

Oluşturulan veri seti bir SVM algoritmasına tanıtılmıştır. Modelde komşuluk sayısı 5 olarak seçilmiştir. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür. Sınıflandırma işlemini yapmak için Kernel Fonksiyonu kullanılmıştır.

SVM algoritmasının çalışma prensibi, iki sınıf arasındaki en geniş aralığı bulma prensibine dayanmaktadır. Ayrım çizgisi olarak adlandırılan hiperdüzlem, her iki sınıftaki verilerden belirli bir mesafede bulunur. Bu mesafe, destek vektörleri adı verilen, sınırlara en yakın veriler tarafından belirlenir. Buna göre en iyi ayırıcı hiper düzlem elde etme formülü Denklem (3.14)’de verilmiştir.

$$Kısıt: y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, n$$

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (3.14)$$

3.3.7.7. Artificial Neural Network (Yapay Sinir Ağı)

Yapay Sinir Ağları, biyolojik sinir sistemlerini temel alan matematiksel modellerin geliştirilmesiyle geliştirilmiştir. Sinir ağlarının temel işleme elemanlarına yapay nöronlar veya basitçe nöronlar veya düğümler adı verilmektedir (McCulloch ve Pitts, 1943). Nöronun basitleştirilmiş matematiksel modelinde, sinapsların etkileri, ilişkili giriş sinyallerinin etkisini düzenleyen bağlantı ağırlıklarıyla temsil edilir ve nöronlar tarafından sergilenen doğrusal olmayan özellik bir transfer fonksiyonuyla temsil edilmektedir. Daha sonra nöron dürtüsü, transfer fonksiyonu tarafından dönüştürülen giriş sinyallerinin ağırlıklı toplamı olarak hesaplanmaktadır. Yapay bir nöronun öğrenme kapasitesi, seçilen öğrenme algoritmasına bağlı olarak ağırlıkların güncellenmesiyle sağlanmaktadır (Abraham, 2005).

Oluşturulan veri seti bir YSA algoritmasına tanıtılmıştır. Modelde komşuluk sayısı 5 olarak seçilmiştir. 5 katlı çapraz doğrulama yöntemi kullanılarak veri seti beş eşit alt gruba ayrılmıştır. Her adımda, bu alt gruplardan biri test verisi olarak seçilirken, diğer dört grup modelin eğitimi için değerlendirilmiştir. Bu süreç, her bir alt grubun sırayla test verisi olarak kullanılmasıyla toplam olarak beş kez gerçekleştirilmiştir, böylece modelin her parça üzerindeki başarımı ayrı ayrı ölçülmüştür. Modelde 10 adet gizli ağ kullanılmıştır.

Her bir nöronun çıkışı, kendisine bağlı girişlerin ağırlıklandırılmış toplamına dayanmaktadır. Bir nöronun çıkış değerini hesaplayan işlem Denklem (3.15)'de verilmiştir.

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (3.15)$$

3.4. Modellerin Eğitilmesi, Test Edilmesi Ve Doğrulanması

Orman yangınları duyarlılık haritasının elde edilmesi amacıyla hazırlanan veri seti toplam olarak 19 sütundan oluşmaktadır. İlk 18 sütun orman yangınlarına etki eden faktörleri 19'uncu sütun ise yangın olup olmama durumu bilgisini içermektedir.

2936 satırdan oluşan veri kullanılan tüm modellerde 5 parçaya bölünmüştür. Bu bölümlerden bir tanesi test için kullanılırken kalan 4 bölüm eğitim için kullanılmıştır. Bu süreç 5 kez tekrarlanarak modelin farklı veri parçaları üzerinde nasıl başarımlar gösterdiği değerlendirilmiştir. Yani her bir farklı döngüde farklı 587 adet veri test için farklı 2349 adet veri eğitim için kullanılmıştır. Her bir döngü için eğitilmiş ve tahmin edilen olasılık değerleri elde edilerek nihai olarak test seti ile karşılaştırma yapılmıştır.

Son olarak Antalya ili genelinden rastgele olarak tespit edilen 30000 adet noktaya ait 18 adet özellikle ilgili veriler elde edilmiş, elde edilen veriler daha önce eğitilmiş olan modele girilmiştir. Model tarafından yeni tahminler yapılmış ve seçilen ilgili tarihten itibaren orman yangını duyarlılık değerleri raster formata çevrilerek duyarlılık haritası oluşturulmuştur.

3.5. Modellerin Başarım Metrikleri

Orman yangını duyarlılık haritalarının oluşturulması problemi ikili (binary) sınıflandırmaya dayandığı için True Positive (TP), True Negative (TN), False Positive (FP) ve False Negative (FN) değerleri hesaplanmış ve karışıklık matrisleri ile gösterilmiştir.

Ayrıca modellerin başarımlarını Accuracy (Doğruluk), Precision (Hassasiyet, Positive Predictive Value (PPV)), Negative Prediction Value (NPV), Sensitivity (Duyarlılık, Recall), Spesificity (Kesinlik), F1 skoru, kappa index değerleri ve Receiver Operating Characteristic (Alıcı Çalışma Karakteristiği, ROC) eğrisi altında kalan alan olan Area Under Curve (AUC) ile de değerlendirilmiştir. Doğruluk denklemi Denklem (3.16)'de, hassasiyet denklemi Denklem (3.17)'de, NPV denklemi Denklem (3.18)'de, duyarlılık denklemi Denklem (3.19)'de, kesinlik denklemi Denklem (3.20)'de, F1 skor denklemi Denklem (3.21)'de, kappa index denklemi Denklem (3.22)'de verilmiştir.

$$Doğruluk = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.16)$$

$$Hassasiyet = \frac{TP}{TP+FP} \quad (3.17)$$

$$NPV = \frac{TN}{TN+FN} \quad (3.18)$$

$$Duyarlılık = \frac{TP}{TP+FN} \quad (3.19)$$

$$Kesinlik = \frac{TN}{TN+FP} \quad (3.20)$$

$$F1\ Skor = 2 \cdot \frac{Hassasiyet \cdot Duyarlılık}{Hassasiyet + Duyarlılık} \quad (3.21)$$

$$Kappa = \frac{p_0 - p_e}{1 - p_e} \quad (3.22)$$

4. BULGULAR VE TARTIŞMA

4.1. Orman Yangınlarına Sebep Olan Faktörlerin Öngörebilirlik Önemi

Şekil 4.1.'de 18 adet özelliğin birbirleri arasındaki ilişkisi gösterilmiştir. Pearson korelasyon katsayısı, değişkenlerin birbirleri ile olan ilişkilerini belirlemede en yaygın ölçülerinden biridir (Kijisipongse ve diğerleri, 2011). Korelasyon matrisinde değişkenler arasındaki ilişki -1 ile 1 arasında değişmektedir. 1 değerine yakın değerler pozitif güçlü bir ilişki (bir değişkenin değeri artarken ilişkili diğer değişkenin değeri de artar) olduğunu, -1 değerine yakın değerleri negatif güçlü bir ilişki (bir değişkenin değeri artarken ilişkili diğer değişkenin değeri azalır) olduğunu ve 0 değerine yakın değerler ise zayıf ilişki olduğunu veya anlamlı bir ilişki olmadığını göstermektedir. Sarı tonlar pozitif güçlü ilişkileri ve mor tonlar negatif güçlü ilişkileri ifade etmektedir. Pearson korelasyon katsayısı Denklem (4.1)'de gösterilmiştir.

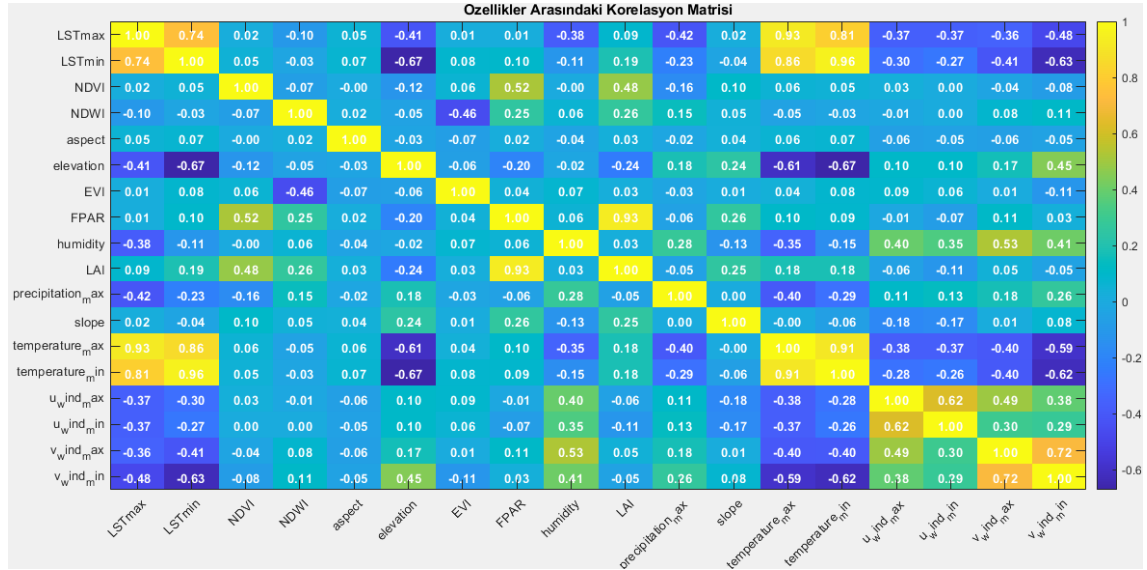
$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.1)$$

Tüm değişkenler arasında en güçlü pozitif ilişki 0.96 değeri ile en düşük hava sıcaklığı (temperature_min) ile en düşük kara yüzey sıcaklığı (LST_min) arasında olduğu tespit edilmiştir. Bu da en düşük hava sıcaklığı ile en düşük yüzey sıcaklığının neredeyse doğrusal pozitif bir ilişki olduğunu göstermektedir. En yüksek hava sıcaklığı ile en yüksek kara yüzey sıcaklığı arasında ise 0.93 değeri ile pozitif bir ilişki tespit edilmiştir. Bununla birlikte yine 0.93 değeri ile LAI ve FPAR değişkenleri arasında pozitif bir ilişki tespit edilmiştir.

Değişkenler arasındaki negatif güçlü ilişkiler incelendiğinde -0.67 değeri ile en güçlü negatif ilişkinin yükseklik (elevation) ile en düşük kara yüzey sıcaklığı (LST_min) arasında olduğu tespit edilmiştir. Bu da yüksek noktalara çıkıldıkça kara yüzey sıcaklığının düştüğü anlamına gelmektedir. Bu bulguyu destekleyecek şekilde ayrıca -0.67 değeri ile yükseklik ile en düşük hava sıcaklığı arasında negatif bir ilişki olduğu tespit edilmiştir.

Değişkenler arasındaki en zayıf ilişkiler incelendiğinde ise bakı ve NDVI, nem ve NDVI, rüzgârların doğru batı yönlü en düşük hızları (u_wind_min) ile NDVI, rüzgârların doğru batı yönlü en düşük hızları (u_wind_min) ile NDWI, eğim ile en yüksek yağış

miktarı (precipitation_max), eğim ile en yüksek hava sıcaklığı arasında herhangi bir ilişki tespit edilememiştir. Bunlar dışındaki diğer değişkenler arasındaki güçlü ve zayıf ilişkiler Şekil 4.1.'de gösterilmiştir.




Şekil 4.1. Korelasyon matrisi

Özellik seçimi süreci veri setinin makine öğrenmesi algoritmaları ile eğitilmesinden önceki işlemlerden biridir. Literatürde üç farklı özellik seçim yöntemi kullanılmaktadır. Bunlar sarmalayıcı (wrapper), filter (filtreli) ve embedded (gömülü) algoritmalarıdır (Ladha ve Deepa, 2011). Filtreli model herhangi bir öğrenme algoritmasına ihtiyaç duymadan özellik seçimini yapabilmektedir (Doshi, 2014). Çalışmamızda özelliklerin sonuca olan etkisini değerlendirmek amacıyla filtreli modeller arasında yer alan Korelasyona Dayalı Özellik Seçimi (Correlation-Based Feature Selection - CFS) yöntemi kullanılmıştır. CFS denklemi Denklem (4.2)'de gösterilmiştir.

$$M_S = \frac{k \cdot r_{cf}}{\sqrt{k + k(k-1) \cdot r_{ff}}} \quad (4.2)$$

Orman yangınlarının meydana gelmesinde etkili olduğu düşünülen faktörlerin orman yangını sonucuna olan etkileri analiz edilerek sonuçlar Şekil 4.2.'de gösterilmiştir. Literatür taramalarından elde edilen sonuçlarla uyumlu olarak hava sıcaklığı, kara yüzey sıcaklığı ve rüzgârların kuzey güney yönlü bileşeni yangınların meydana gelme durumunda en yüksek olasılığa sahip değerler olarak tespit edilmiştir.

Veri setinin içerdği özellikler dâhilinde orman yangınlarının meydana gelmesinde en az etkiye sahip olan değişkenlerin sırasıyla ise NDWI, FPAR, NDVI, bakı, eğim, EVI ve LAI olduğu tespit edilmiştir. Elde edilen sonuçlar değerlendirildiğinde orman yangınlarında sıcaklık ve rüzgâr hızlarının önemli bir etkiye sahip olduğu fakat bitki örtüsü yapısının ve topografik özelliklerin daha az etkiye sahip olduğu değerlendirilmiştir.



Şekil 4.2. Özellik önem grafiği

Özellik seçim sonuçlarına göre en az etkiye sahip 5 özellikler (NDWI, FPAR, NDVI, bakı, eğim) sırasıyla veri setinden çıkartılarak sonuçlar tek tek değerlendirilmiştir. Fakat tüm özelliklerin veri setine dâhil olduğu durum ile en az etkiye sahip özelliklerin veri setinden çıkarıldığı durum arasında başarımleri etkileyen kayda değer bir fark gözlenmemiştir. Ayrıca bu çalışmada Antalya bölgesinin kendine has bitki örtüsünün, topografik yapısının ve iklim özelliklerinin orman yangınlarına olan etkisi görülmek istendiğinden çalışmanın başından itibaren veri setine dâhil edilen tüm özellikler çıkartılmadan kullanılmıştır.

4.2. Modelin Başarımı ve Değerlendirilmesi

Orman Yangınlarının duyarlılık haritasının oluşturulmasında kullanılan 18 farklı özellikten oluşan veri seti Ada Boost, Karar Ağaçları, GBM, KNN, Lojistik Regresyon,

SVM ve YSA algoritmaları ile tek tek eğitilmiştir. Tüm algoritmaların test ve doğrulama süreçlerinde 5 katlı çapraz doğrulama yapılarak modelin yanlış öğrenmediğinden emin olunmuştur.

Elde edilen sonuçlar değerlendirildiğinde GBM modeli %96 ile en yüksek doğruluk değeri kaydedilmiştir. %95 duyarlılık ve %96 kesinlik değerleri ile hem pozitif hem de negatif yangın vakalarını doğru bir şekilde tespit etmede mükemmel başarımla sergilediği görülmüştür. %96 hassasiyet ve %95 NPV oranları ile hem pozitif hem de negatif tahminlerde yüksek doğruluk elde edilmiştir. GBM modelinde ayrıca 0,91 oranla en yüksek Kappa değeri elde edilmiş olup bu sonucun şans eseri başarılı olmadığını bunun yerine özellik seçimlerinin doğru ve öğrenmenin sağlıklı olduğunu göstermektedir. Ayrıca eğrinin altında kalan alan 0,99 olarak kaydedilmiş olup bu da modelin sınıfları ayırt etme yeteneğinin mükemmelliğini göstermektedir.

Ada Boost ve YSA incelendiğinde her ikisinin de %94 gibi yüksek bir doğruluğa sahip olduğu görülmüştür. AUC incelendiğinde sırasıyla 0,99 ve 0,98 değerleri elde edilmiştir. Bu da sınıfları ayırt etme yeteneklerinin çok iyi olduğunu göstermektedir. Kappa değerleri ise 0,88 ve 0,89 olarak ölçülmüştür.

KNN, Karar Ağaçları, Lojistik Regresyon ve SVM modelleri, GBM, Ada Boost ve YSA modelleri ile karşılaştırıldığında nispeten daha düşük başarımla göstermiş olup buna rağmen genel tabloda seçilen tüm modellerin iyi bir başarımla sergilediği söylenebilmektedir.


Çizelge 4.1.'de tüm modellerin genel başarımla metrikleri verilmiş olup ayrıca Çizelge 4.2.'den Çizelge 4.8.'e kadar ve Şekil 4.3.'den Şekil 4.9'a kadar her bir modelin her bir doğrulama adımına ait başarımla metrikleri ve AUC grafikleri verilerek modellerin mükemmel uyumuna dikkat çekilmiştir.

Çizelge 4.1. Modellerin genel başarımlar tablosu

Model	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Ada Boost	1367	1399	69	101	0,95	0,93	0,93	0,95	0,94	0,88	0,99
Karar Ağaçları	1368	1347	121	100	0,92	0,93	0,93	0,92	0,93	0,85	0,95
GBM	1398	1410	58	70	0,96	0,95	0,95	0,96	0,96	0,91	0,99
KNN	1373	1387	81	95	0,95	0,94	0,93	0,95	0,94	0,88	0,98
Lojistik Regresyon	1350	1370	98	118	0,93	0,92	0,92	0,93	0,93	0,85	0,98
SVM	1349	1380	88	119	0,94	0,92	0,92	0,94	0,93	0,86	0,97
YSA	1362	1405	63	101	0,96	0,93	0,93	0,96	0,94	0,89	0,98

Çizelge 4.2. Ada Boost modeli başarımlar değerleri


Validasyon Adımları	Ada Boost										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	273	273	20	21	0,93	0,93	0,93	0,93	0,93	0,86	0,99
Fold-2	273	281	13	21	0,95	0,93	0,93	0,96	0,94	0,88	0,99
Fold-3	276	283	11	17	0,96	0,94	0,94	0,96	0,95	0,90	0,99
Fold-4	273	284	10	20	0,96	0,93	0,93	0,97	0,95	0,90	0,99
Fold-5	272	278	15	22	0,95	0,93	0,93	0,95	0,94	0,87	0,98
Model	1367	1399	69	101	0,95	0,93	0,93	0,95	0,94	0,88	0,99



Şekil 4.3. Ada Boost modeli AUC grafiği

Çizelge 4.3. Karar Ağaçları modeli başarımlar değerleri


Validasyon Adımları	Karar Ağaçları										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	277	265	28	17	0,91	0,94	0,94	0,90	0,92	0,85	0,93
Fold-2	278	262	32	16	0,90	0,94	0,95	0,89	0,92	0,84	0,96
Fold-3	276	276	18	17	0,94	0,94	0,94	0,94	0,94	0,88	0,96
Fold-4	272	266	28	21	0,91	0,93	0,93	0,90	0,92	0,83	0,95
Fold-5	265	278	15	29	0,95	0,91	0,90	0,95	0,93	0,85	0,95
Model	1368	1347	121	100	0,92	0,93	0,93	0,92	0,93	0,85	0,95



Şekil 4.4. Karar Ağaçları modeli AUC grafiği

Çizelge 4.4. GBM modeli başarımlar değerleri


Validasyon Adımları	GBM										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	270	288	5	24	0,98	0,92	0,92	0,98	0,95	0,90	0,98
Fold-2	278	282	12	16	0,96	0,95	0,95	0,96	0,95	0,90	0,99
Fold-3	289	279	15	4	0,95	0,99	0,99	0,95	0,97	0,94	0,99
Fold-4	276	277	17	17	0,94	0,94	0,94	0,94	0,94	0,88	0,98
Fold-5	285	284	9	9	0,97	0,97	0,97	0,97	0,97	0,94	0,99
Model	1398	1410	58	70	0,96	0,95	0,95	0,96	0,96	0,91	0,99



Şekil 4.5. GBM modeli AUC grafiği

Çizelge 4.5. KNN modeli başarımlı değerleri


Validasyon Adımları	KNN										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	269	273	20	25	0,93	0,92	0,91	0,93	0,92	0,85	0,97
Fold-2	274	272	22	20	0,93	0,93	0,93	0,93	0,93	0,86	0,97
Fold-3	275	283	11	18	0,96	0,94	0,94	0,96	0,95	0,90	0,98
Fold-4	279	278	16	14	0,95	0,95	0,95	0,95	0,95	0,90	0,99
Fold-5	276	281	12	18	0,96	0,94	0,94	0,96	0,95	0,90	0,98
Model	1373	1387	81	95	0,95	0,94	0,93	0,95	0,94	0,88	0,98



Şekil 4.6. KNN modeli AUC grafiği

Çizelge 4.6. Lojistik Regresyon modeli başarımlar değerleri


Validasyon Adımları	Lojistik Regresyon										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	269	275	18	25	0,94	0,92	0,91	0,94	0,93	0,85	0,97
Fold-2	272	279	15	22	0,95	0,93	0,93	0,95	0,94	0,87	0,98
Fold-3	273	267	27	20	0,91	0,93	0,93	0,91	0,92	0,84	0,98
Fold-4	272	275	19	21	0,93	0,93	0,93	0,94	0,93	0,86	0,98
Fold-5	264	274	19	30	0,93	0,90	0,90	0,94	0,92	0,83	0,97
Model	1350	1370	98	118	0,93	0,92	0,92	0,93	0,93	0,85	0,98



Şekil 4.7. Lojistik Regresyon modeli AUC grafiği

Çizelge 4.7. SVM modeli başarımlar değerleri


Validasyon Adımları	SVM										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	265	273	20	29	0,93	0,90	0,90	0,93	0,92	0,83	0,96
Fold-2	270	274	20	24	0,93	0,92	0,92	0,93	0,93	0,85	0,97
Fold-3	272	275	19	21	0,93	0,93	0,93	0,94	0,93	0,86	0,98
Fold-4	275	281	13	18	0,95	0,94	0,94	0,96	0,95	0,89	0,98
Fold-5	267	277	16	27	0,94	0,91	0,91	0,95	0,93	0,85	0,97
Model	1349	1380	88	119	0,94	0,92	0,92	0,94	0,93	0,86	0,97



Şekil 4.8. SVM modeli AUC grafiği

Çizelge 4.8. YSA modeli başarımlar değerleri

Validasyon Adımları	YSA										
	Metrikler										
	TP	TN	FP	FN	Prec.	NPV	Sensv.	Spec.	Accur.	Kappa	AUC
Fold-1	264	285	8	28	0,97	0,91	0,90	0,97	0,94	0,88	0,98
Fold-2	273	278	16	20	0,94	0,93	0,93	0,95	0,94	0,88	0,97
Fold-3	275	282	12	18	0,96	0,94	0,94	0,96	0,95	0,90	0,97
Fold-4	270	286	8	22	0,97	0,93	0,92	0,97	0,95	0,90	0,98
Fold-5	280	274	19	13	0,94	0,95	0,96	0,94	0,95	0,89	0,99
Model	1362	1405	63	101	0,96	0,93	0,93	0,96	0,94	0,89	0,98



Şekil 4.9. YSA modeli AUC grafiği

4.3. Orman Yangını Duyarlılık Analizi

Orman yangınları duyarlılık haritalarının oluşturulmasından önce tatmin edici istatistiksel sonuçların elde edilmesinin ardından eğitilen modelin Antalya ilinin yangın duyarlılığını tahmin etmesi amacıyla 1000 metre aralıklarla Antalya sınırları içerisinde 30000 adet örnek koordinat alınmıştır. Antalya sınırları içerisinde elde edilen 30000 adet koordinat noktalarına 2013-2023 yılları Haziran, Temmuz, Ağustos ve Eylül aylarının tüm günleri rastgele olarak atanmış ve bu noktalara ve bu tarihlere ilişkin 18 adet özellik elde edilmiştir. Elde edilen değerler Bölüm 3.4.4.2’de yapılan normalizasyon işlemine tabi tutularak verilerin standartlaştırılması sağlanmıştır. Orman yangını duyarlılık haritasının oluşturulması için makine öğrenmesi yöntemlerinden GBM modeli seçilmiştir. Eğitilen modele belirlenen 30000 adet koordinata ait 18 özellik verilmiştir.

4.3.1. Yangın olasılıklarının elde edilmesi

Model “yangın var” ya da “yangın yok” sınıflandırmasını, belirli olasılık değerleri sıfırın altında ise “yangın yok”, değer sıfırın üstünde ise “yangın var” olarak işaretlemektedir. Çalışmamızda bu olasılık değerleri GBM modelinde -15 ile 25 arasında belirlenmiştir. -15 ile 0 arasındaki olasılık değerleri yangın ihtimalinin olmadığı durum olduğundan kalan 0 ile 25 arasındaki tüm değerler 0 ile 100 arasına normalize edilmiştir. Yapılan normalizasyon işlemine ilişkin denklem Denklem (4.3)’de verilmiştir.

$$x_{normalize} = \frac{x - x_{kucuk}}{x_{buyuk} - x_{kucuk}} * 100 \quad (4.3)$$

4.3.2. Haritanın oluşturulması

Modellerden çıktı olarak elde edilen olasılık sonuçları her bir çıktı değerine karşılık gelen koordinat ile eşleştirilerek QGIS 3.38.3 yazılımı aracılığıyla haritalandırılmıştır.

4.3.2.1. Jenks Natural Breaks sınıflandırma yöntemi

Natural Breaks yöntemi (aynı zamanda Jenks' optimizasyonu olarak da bilinir) verilerde bulunan doğal gruplamalara dayanmaktadır. Benzer değerleri en iyi şekilde gruplayan ve sınıflar arasındaki varyansı en üst düzeye çıkaran sınıf kırılmaları belirlenmektedir. Özellikler, sınırları veri değerlerinde nispeten büyük varyansın olduğu yerlere ayarlanan sınıflara ayrılmaktadır. Doğal kırılma sınıflandırması kümelenmiş değerleri aynı sınıfa yerleştirdiği için, bu yöntem eşit olarak dağıtılmamış veri değerlerini eşlemek için uygun bir yöntem olarak değerlendirilmektedir (ArcGIS, 2024). Jenks Natural Breaks sınıflandırma yöntemine göre verilerin toplam varyansını hesaplayan denklem Denklem (4.4)'de, sınıflar arası ve sınıf içi varyansı hesaplayan denklem ise Denklem (4.5)'de verilmiştir.

$$V_t = \sum_{i=1}^n (x_i - \mu)^2 \quad (4.4)$$

$$V_w = \sum_{j=1}^k \sum_{i=1}^{n_j} (x_i - \mu_j)^2 \quad (4.5)$$

Daha önce ilgili koordinatlarla eşleştirilen olasılık değerleri Natural Breaks işlemine tabi tutulmuş ve bu yöntemle beş farklı sınıf aşağıdaki değerlere göre oluşturulmuştur.


Çizelge 4.9. Jenks Natural Breaks sınıflandırma

Jenks Natural Breaks Sınıflandırma			
Büyük Aralık (%)	Küçük Aralık (%)	Sınıflandırma	Atanan Renk
100	56	Çok Yüksek	
56	34.8	Yüksek	
34.8	19.6	Orta	
19.6	6.8	Düşük	
6.8	0	Çok Düşük	


Olasılık dağılımlarının ise orman yangını meydana gelme ihtimaline göre % 56-100 arası kırmızı (çok yüksek), %34.8-56 arası turuncu (yüksek), % 19.6-34.8 arası sarı (orta), % 6.8-19.6 arası yeşil (düşük) ve % 0-6.8 arası gri (çok düşük) renk ile işaretlenerek Jenks Natural Breaks Sınıflandırma yöntemi ile 5 farklı sınıfa ayrılmıştır.

4.3.2.2. Antalya ili orman yangını duyarlılık haritaları


Ayrıca 2024 yılı Haziran, Temmuz, Ağustos ve Eylül aylarında meydana gelmiş gerçek yangın olayları, GBM modelinin çıktısı olan tahmin verileri ile karşılaştırılabilmesi amacıyla mavi renk ile gösterilmiştir. Şekil 4.10.'dan Şekil 4.15.'e kadar GBM algoritması ile oluşturulan orman yangını duyarlılık haritaları gösterilmektedir.




Şekil 4.10. “Çok Yüksek” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar




Şekil 4.11. “Yüksek” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar




Şekil 4.12. “Orta” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar



Şekil 4.13. “Düşük” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar



Şekil 4.14. “Çok Düşük” ihtimalle yangın çıkması beklenen ve yangın çıkan noktalar



Şekil 4.15. Antalya ili genel yangın duyarlılık haritası ve yangın çıkan noktalar

5. SONUÇLAR VE ÖNERİLER

5.1. Sonuçlar

Orman yangınlarına ilişkin geçmiş yıllara ait verilerin makine öğrenmesi algoritmaları ile kullanılması, bir bölgenin uzaktan algılama yöntemleri kullanılarak yangın duyarlılığının elde edilmesinde umut verici sonuçlar ortaya koymuştur. Bu çalışmada Antalya bölgesine ait geçmiş yangın verileri ve seçilen 18 adet özellik ilgili yangın noktasına karşılık gelecek şekilde elde edilerek Ada Boost, Karar Ağaçları, GBM, KNN, Lojistik Regresyon, SVM ve YSA algoritmaları ile eğitilmiştir. Her bir model ile defalarca kez eğitim, test ve validasyon işlemi tekrarlanmış ve sonuçlar elde edilmiştir. Son olarak Antalya ili genelinden rastgele olarak tespit edilen 30000 adet nokta eğitilen modele maruz bırakılarak orman yangını duyarlılık olasılıkları elde edilmiştir. Olasılık değerleri görselleştirilerek harita oluşturulmuştur. Oluşturulan harita ilgili tarihlerde meydana gelen gerçek orman yangını olayları ile de ayrıca karşılaştırılmış ve sonuçların büyük oranda tutarlı olduğu teyit edilmiştir. Model bazında başarımlar değerlendirildiğinde GBM, Ada Boost ve YSA modellerinin en başarılı modeller olduğu ortaya çıkmıştır. Kullanılan özellikler bazında inceleme yapıldığında ise yüzey sıcaklıkları, hava sıcaklıkları ve rüzgârların orman yangınlarının meydana gelmesinde etkili faktörler olduğu tespit edilmiştir.

5.2. Öneriler

Bu çalışma ile Türkiye'nin Antalya ilinin yangın duyarlılık haritasının oluşturulabileceği ortaya konmuştur. Çalışmada, modellerin sonuçlarını göstermek amacıyla örnek bir tarih seçilmiş olmasına rağmen, gerek ülkemizde gerekse Antalya ili ile benzer iklimsel ve topografik özelliklere sahip Akdeniz ülkelerinde orman yangınlarının meydana geldiği tarihlerden hemen önce (aylık, iki aylık veya mevsimlik olabilir) ilgili bölgenin verileri ile bir veri seti oluşturularak bölgenin yangın duyarlılığı tespit edilebilecektir.

Duyarlılık haritasının oluşturulmasının ardından ülkemiz özelinde OGM veya Tarım ve Orman Bakanlığı nezdinde ülkemiz Akdeniz ve Ege Bölgelerinde yangın meydana gelme ihtimalinin bulunduğu alanlara özel tedbirler alınabilecek, kaynak ve personel planlaması bu doğrultuda gerçekleştirilebilecektir. Aynı şekilde iklim ve topografik özelliklerin benzerlik gösterdiği ülkelerde de ilgili otoriteler tarafından gerekli proaktif tedbirler alınabilecektir. Bu sayede dünyanın oksijen kaynağı olan, ekolojik dengenin anahtarı olan, birçok sanayi alanında faydalanan ve ekonomik bir varlık olarak değerlendirilen ormanlarımızın, bölgede yaşayan insanlarımızın ve aynı ekoloji içinde yaşayan, biyoçeşitliliği oluşturan diğer canlıların korunması ve sürdürülebilirliği sağlanabilecektir.

KAYNAKLAR

- Abatzoglou, J. T., Dobrowski, S. Z., Parks, S. A., & Hegewisch, K. C. (2018). TerraClimate, a high-resolution global dataset of monthly climate and Climatic Water Balance from 1958–2015. *Scientific Data*, 5(1). <https://doi.org/10.1038/sdata.2017.191>
- Abatzoglou, J. T., Williams, A. P., & Barbero, R. (2019). Global emergence of anthropogenic climate change in fire weather indices. *Geophysical Research Letters*, 46(1), 326–336. <https://doi.org/10.1029/2018gl080959>
- Abraham, A. (2005). Artificial Neural Networks. *Handbook of Measuring System Design*. <https://doi.org/10.1002/0471497398.mm421>
- Abram, N. J., Henley, B. J., Sen Gupta, A., Lippmann, T. J., Clarke, H., Dowdy, A. J., Sharples, J. J., Nolan, R. H., Zhang, T., Wooster, M. J., Wurtzel, J. B., Meissner, K. J., Pitman, A. J., Ukkola, A. M., Murphy, B. P., Tapper, N. J., & Boer, M. M. (2021). Connections of climate change and variability to large and extreme forest fires in Southeast Australia. *Communications Earth & Environment*, 2(1). <https://doi.org/10.1038/s43247-020-00065-8>
- Alkhatib, A. A. (2014). A review on Forest Fire Detection Techniques. *International Journal of Distributed Sensor Networks*, 10(3), 597368. <https://doi.org/10.1155/2014/597368>
- Alpaydin, E. (2020, June 18). *Introduction to machine learning*. MIT Press. <https://mitpress.mit.edu/9780262043793/introduction-to-machine-learning/>
- Andreae, M. O. (1993). Global distribution of fires seen from space. *Eos, Transactions American Geophysical Union*, 74(12), 129–135. <https://doi.org/10.1029/93eo00166>
- Balling, R. C., Meyer, G. A., & Wells, S. G. (1992a). Relation of surface climate and burned area in Yellowstone National park. *Agricultural and Forest Meteorology*, 60(3–4), 285–293. [https://doi.org/10.1016/0168-1923\(92\)90043-4](https://doi.org/10.1016/0168-1923(92)90043-4)
- Balling, R. C., Meyer, G. A., & Wells, S. G. (1992b). Relation of surface climate and burned area in Yellowstone National park. *Agricultural and Forest Meteorology*, 60(3–4), 285–293. [https://doi.org/10.1016/0168-1923\(92\)90043-4](https://doi.org/10.1016/0168-1923(92)90043-4)
- Belcher, C. M. (2013). *Fire Phenomena and the Earth System: An Interdisciplinary Guide to Fire Science*, John Wiley & Sons, First Edition, 53-75. <https://doi.org/10.1002/9781118529539>
- Beth, L., & Brown, T. J. (2003, November). A comparison of precipitation and drought indices related to fire activity in the US. In *5th symposium on fire and Forest meteorology*.

- Bilgili, E., Küçük, Ö., & Sağlam, B. (2002). Fire behavior prediction and its importance in firefighting. *Kast Univ J Fac Forestry*, 2(2), 124-134.
- Bjånes, A., De La Fuente, R., & Mena, P. (2021). A Deep Learning Ensemble model for wildfire susceptibility mapping. *Ecological Informatics*, 65, 101397. <https://doi.org/10.1016/j.ecoinf.2021.101397>
- Bonan, G. B. (2008). Forests and climate change: Forcings, feedbacks, and the climate benefits of forests. *Science*, 320(5882), 1444–1449. <https://doi.org/10.1126/science.1155121>
- Bouabdellah, K., Noureddine, H., & Larbi, S. (2013). Using wireless sensor networks for reliable forest fires detection. *Procedia Computer Science*, 19, 794–801. <https://doi.org/10.1016/j.procs.2013.06.104>
- Brown, J. K. (1983). The unnatural fuel buildup issue. In: Proceedings of a symposium and workshop on wilderness fire. General technical report INT-182. US Forest Service, Ogden, UT, pp. 127–128. <https://digitalcommons.usu.edu/barkbeetles/159/>
- Celebrating national native American Heritage month*. USGS.gov | Science for a changing world. (2019). <https://www.usgs.gov/>
- Chuvieco, E., & Kasischke, E. S. (2007). Remote Sensing Information for fire management and fire effects assessment. *Journal of Geophysical Research: Biogeosciences*, 112(G1). <https://doi.org/10.1029/2006jg000230>
- Copernicus Data Space Ecosystem. (2024). *Sentinel-2*. <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/bf00994018>
- Costanza, R., d’Arge, R., de Groot, R., Farber, S., Grasso, M., Hannon, B., Limburg, K., Naeem, S., O’Neill, R. V., Paruelo, J., Raskin, R. G., Sutton, P., & van den Belt, M. (1997). The value of the world’s ecosystem services and Natural Capital. *Nature*, 387(6630), 253–260. <https://doi.org/10.1038/387253a0>
- Crimmins, M. A. (2006). Synoptic climatology of extreme fire-weather conditions across the southwest United States. *International Journal of Climatology*, 26(8), 1001–1016. <https://doi.org/10.1002/joc.1300>
- Crimmins, M. A., & Comrie, A. C. (2004). Interactions between antecedent climate and wildfire variability across south-eastern Arizona. *International Journal of Wildland Fire*, 13(4), 455. <https://doi.org/10.1071/wf03064>
- Cunningham, C. X., Williamson, G. J., & Bowman, D. M. (2024). Increasing frequency and intensity of the most extreme wildfires on Earth. *Nature Ecology & Evolution*, 8(8), 1420–1425. <https://doi.org/10.1038/s41559-024-02452-2>

- Doshi, M. (2014). Correlation based feature selection (CFS) technique to predict student Performance. *International Journal of Computer Networks & Communications*, 6(3), 197.
- Ecosystems and human well-being. Millenium Assessment.* (2005). <https://www.millenniumassessment.org/documents/document.356.aspx.pdf>
- Eesa, Adel S., Abdulazeez, A. M., & Orman, Z. (2017). A dids based on the combination of cuttlefish algorithm and decision tree. *Science Journal of University of Zakho*, 5(4), 313–318. <https://doi.org/10.25271/2017.5.4.382>
- Eesa, Adel Sabry, Orman, Z., & Brifcani, A. M. (2015). A novel feature-selection approach based on the cuttlefish optimization algorithm for intrusion detection systems. *Expert Systems with Applications*, 42(5), 2670–2679. <https://doi.org/10.1016/j.eswa.2014.11.009>
- Elevation and depth - foundation spatial data.* Elvis. (2023). <https://elevation.fsd.org.au/>
- Ellison, D., Morris, C. E., Locatelli, B., Sheil, D., Cohen, J., Murdiyarso, D., Gutierrez, V., Noordwijk, M. van, Creed, I. F., Pokorny, J., Gaveau, D., Spracklen, D. V., Tobella, A. B., Ilstedt, U., Teuling, A. J., Gebrehiwot, S. G., Sands, D. C., Muys, B., Verbist, B., ... Sullivan, C. A. (2017). Trees, forests and water: Cool insights for a hot world. *Global Environmental Change*, 43, 51–61. <https://doi.org/10.1016/j.gloenvcha.2017.01.002>
- Eron, Z. (1988). Forest fires and fighting methods. *Forestry Research Institute Publications-Variou Publications Series*, 5-6.
- FAO. Global Forest Resources Assessments | Food and Agriculture Organization of the United Nations. (2024). <https://www.fao.org/forest-resources-assessment/en/>
- Ferreira Barbosa, M. L., Haddad, I., da Silva Nascimento, A. L., Máximo da Silva, G., Moura da Veiga, R., Hoffmann, T. B., Rosane de Souza, A., Dalagnol, R., Susin Streher, A., Souza Pereira, F. R., Oliveira e Cruz de Aragão, L. E., & Oighenstein Anderson, L. (2022). Compound impact of land use and extreme climate on the 2020 Fire Record of the Brazilian pantanal. *Global Ecology and Biogeography*, 31(10), 1960–1975. <https://doi.org/10.1111/geb.13563>
- Flannigan, M. D., Stocks, B. J., & Wotton, B. M. (2000). Climate change and forest fires. *Science of The Total Environment*, 262(3), 221–229. [https://doi.org/10.1016/s0048-9697\(00\)00524-6](https://doi.org/10.1016/s0048-9697(00)00524-6)
- Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1), 119–139. <https://doi.org/10.1006/jcss.1997.1504>
- Fried, J. S., Torn, M. S., & Mills, E. (2004). The impact of climate change on wildfire severity: A regional forecast for Northern California. *Climatic Change*, 64(1/2), 169–191. <https://doi.org/10.1023/b:clim.0000024667.89579.ed>

- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5). <https://doi.org/10.1214/aos/1013203451>
- Garcia, C., Woodard, P., Titus, S., Adamowicz, W., & Lee, B. (1995). A logit model for predicting the daily occurrence of human caused forest-fires. *International Journal of Wildland Fire*, 5(2), 101. <https://doi.org/10.1071/wf9950101>
- Giglio, L., Schroeder, W., & Justice, C. O. (2016). The collection 6 modis active fire detection algorithm and Fire Products. *Remote Sensing of Environment*, 178, 31–41. <https://doi.org/10.1016/j.rse.2016.02.054>
- Global deforestation rates & statistics by country: GFW. Forest Monitoring, Land Use & Deforestation Trends. (2024). <https://www.globalforestwatch.org/dashboards/global/>
- Global Forest Resources Assessment 2020. (2020) <https://doi.org/10.4060/ca8753en>
- Goodfellow, I., Courville, A., & Bengio, Y. (2016, June 18). *Deep learning*. MIT Press. <https://mitpress.mit.edu/9780262035613/deep-learning/>
- Google. (2024a). *Era5-land daily aggregated - ECMWF climate reanalysis | Earth Engine Data catalog google for developers*. Google. https://developers.google.com/earth-engine/datasets/catalog/ECMWF_ERA5_LAND_DAILY_AGGR#bands
- Google. (2024b). *Gldas-2.1: Global Land Data Assimilation System | Earth Engine Data catalog | google for developers*. Google. https://developers.google.com/earth-engine/datasets/catalog/NASA_GLDAS_V021_NOAH_G025_T3H
- Google. (2024c). *FAQ – google earth engine*. Google. <https://earthengine.google.com/faq/>
- Güngöroğlu, C. (2018). Forest fire studies on fire behaviour: key topics and their importance. Proceedings of the 14th International Combustion Symposium (INCOS2018). https://www.researchgate.net/publication/330280398_Forest_Fire_Studies_on_Fire_Behaviour_Key_Topics_and_Their_Importance
- Heyerdahl, E. K., Brubaker, L. B., & Agee, J. K. (2002). Annual and decadal climate forcing of historical fire regimes in the interior Pacific Northwest, USA. *The Holocene*, 12(5), 597–604. <https://doi.org/10.1191/0959683602hl570rp>
- Higuera, P. E., & Abatzoglou, J. T. (2020). Record-setting climate enabled the extraordinary 2020 fire season in the Western United States. *Global Change Biology*, 27(1), 1–2. <https://doi.org/10.1111/gcb.15388>
- Huot, F., Hu, R. L., Goyal, N., Sankar, T., Ihme, M., & Chen, Y.-F. (2022). Next day wildfire spread: A machine learning dataset to predict wildfire spreading from remote-sensing data. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1–13. <https://doi.org/10.1109/tgrs.2022.3192974>

- Jamshed, M. A., Theodorou, C., Kalsoom, T., Anjum, N., Abbasi, Q. H., & Ur-Rehman, M. (2022). Intelligent computing based forecasting of deforestation using fire alerts: A deep learning approach. *Physical Communication*, 55, 101941. <https://doi.org/10.1016/j.phycom.2022.101941>
- Jenks Natural Breaks Classification Method. Classification methods-ArcGIS for Microsoft 365 | Documentation. (2024). <https://doc.arcgis.com/en/microsoft-365/latest/get-started/classification-methods.htm#:~:text=The%20natural%20breaks%20classification%20method,a%20national%20forest%E2%80%9494are%20identified.>
- Jones, M. W., Abatzoglou, J. T., Veraverbeke, S., Andela, N., Lasslop, G., Forkel, M., Smith, A. J., Burton, C., Betts, R. A., van der Werf, G. R., Sitch, S., Canadell, J. G., Santín, C., Kolden, C., Doerr, S. H., & Le Quéré, C. (2022). Global and regional trends and drivers of fire under climate change. *Reviews of Geophysics*, 60(3). <https://doi.org/10.1029/2020rg000726>
- Jones, M. W., Kelley, D. I., Burton, C. A., Di Giuseppe, F., Barbosa, M. L., Brambleby, E., Hartley, A. J., Lombardi, A., Mataveli, G., McNorton, J. R., Spuler, F. R., Wessel, J. B., Abatzoglou, J. T., Anderson, L. O., Andela, N., Archibald, S., Armenteras, D., Burke, E., Carmenta, R., ... Xanthopoulos, G. (2024). State of wildfires 2023–2024. *Earth System Science Data*, 16(8), 3601–3685. <https://doi.org/10.5194/essd-16-3601-2024>
- Kansal, A., Singh, Y., Kumar, N., & Mohindru, V. (2015). Detection of forest fires using machine learning technique: A perspective. *2015 Third International Conference on Image Information Processing (ICIIP)*, 241–245. <https://doi.org/10.1109/iciip.2015.7414773>
- Kaya, Z., & Raynal, D. J. (2001). Biodiversity and conservation of Turkish forests. *Biological Conservation*, 97(2), 131–141. [https://doi.org/10.1016/s0006-3207\(00\)00069-0](https://doi.org/10.1016/s0006-3207(00)00069-0)
- Kelley, D. I., Burton, C., Huntingford, C., Brown, M. A., Whitley, R., & Dong, N. (2021). Technical note: Low meteorological influence found in 2019 Amazonia fires. *Biogeosciences*, 18(3), 787–804. <https://doi.org/10.5194/bg-18-787-2021>
- Kijsipongse, E., Suriya, U., Ngamphiw, C., & Tongsimma, S. (2011, May). Efficient large Pearson correlation matrix computing using hybrid MPI/CUDA. In *2011 Eighth International Joint Conference on Computer Science and Software Engineering (JCSSE)* (pp. 237-241). IEEE.
- Kolden, C. A., Abatzoglou, J. T., Jones, M. W., & Jain, P. (2024). Wildfires in 2023. *Nature Reviews Earth & Environment*, 5(4), 238–240. <https://doi.org/10.1038/s43017-024-00544-y>
- Krüll, W., Tobera, R., Willms, I., Essen, H., & Von Wahl, N. (2012). Early forest fire detection and verification using optical smoke, gas and microwave sensors. *Procedia Engineering*, 45, 584-594.

- Ladha, L., & Deepa, T. (2011). Feature selection methods and algorithms. *International journal on computer science and engineering*, 3(5), 1787-1797.
- Lapola, D. M., Pinho, P., Barlow, J., Aragão, L. E., Berenguer, E., Carmenta, R., Liddy, H. M., Seixas, H., Silva, C. V., Silva-Junior, C. H., Alencar, A. A., Anderson, L. O., Armenteras, D., Brovkin, V., Calders, K., Chambers, J., Chini, L., Costa, M. H., Faria, B. L., ... Walker, W. S. (2023). The drivers and impacts of Amazon forest degradation. *Science*, 379(6630). <https://doi.org/10.1126/science.abp8622>
- Le, H. V., Hoang, D. A., Tran, C. T., Nguyen, P. Q., Tran, V. H., Hoang, N. D., Amiri, M., Ngo, T. P., Nhu, H. V., Hoang, T. V., & Tien Bui, D. (2021). A new approach of deep neural computing for spatial prediction of wildfire danger at Tropical Climate Areas. *Ecological Informatics*, 63, 101300. <https://doi.org/10.1016/j.ecoinf.2021.101300>
- Liang, J., Qin, Z., Xiao, S., Ou, L., & Lin, X. (2021). Efficient and secure decision tree classification for cloud-assisted online diagnosis services. *IEEE Transactions on Dependable and Secure Computing*, 18(4), 1632–1644. <https://doi.org/10.1109/tdsc.2019.2922958>
- Littell, J. S., McKenzie, D., Peterson, D. L., & Westerling, A. L. (2009). Climate and wildfire area burned in western U.S. ecoprovinces, 1916–2003. *Ecological Applications*, 19(4), 1003–1021. <https://doi.org/10.1890/07-1183.1>
- Luyssaert, S., Schulze, E.-D., Börner, A., Knohl, A., Hessenmöller, D., Law, B. E., Ciais, P., & Grace, J. (2008). Old-growth forests as global carbon sinks. *Nature*, 455(7210), 213–215. <https://doi.org/10.1038/nature07276>
- Maingi, J. K., & Henry, M. C. (2007). Factors influencing wildfire occurrence and distribution in Eastern Kentucky, USA. *International Journal of Wildland Fire*, 16(1), 23. <https://doi.org/10.1071/wf06007>
- Mataveli, G., Jones, M. W., Carmenta, R., Sanchez, A., Dutra, D. J., Chaves, M., de Oliveira, G., Anderson, L. O., & Aragão, L. E. (2024). Deforestation falls but rise of wildfires continues degrading Brazilian amazon forests. *Global Change Biology*, 30(2). <https://doi.org/10.1111/gcb.17202>
- Matthews, S., Sullivan, A., Gould, J., Hurley, R., Ellis, P., & Larmour, J. (2012). Field evaluation of two image-based wildland fire detection systems. *Fire Safety Journal*, 47, 54-61.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/bf02478259>
- Michelle, T. (1997). *Machine Learning*. McGraw-Hill.
- 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>
- Momeni, M., Soleimani, H., Shahparvari, S., & Afshar-Nadjafi, B. (2022). Coordinated routing system for fire detection by patrolling trucks with drones. *International Journal of Disaster Risk Reduction*, 73, 102859.
- Moritz, M. A., Moody, T. J., Krawchuk, M. A., Hughes, M., & Hall, A. (2010). Spatial variation in extreme winds predicts large wildfire locations in chaparral ecosystems. *Geophysical Research Letters*, 37(4). <https://doi.org/10.1029/2009gl041735>
- Mouillot, F., Rambal, S., & Joffre, R. (2002). Simulating climate change impacts on fire frequency and vegetation dynamics in a mediterranean-type ecosystem. *Global Change Biology*, 8(5), 423–437. <https://doi.org/10.1046/j.1365-2486.2002.00494.x>
- Naderpour, M., Rizeei, H. M., & Ramezani, F. (2021). Forest fire risk prediction: A spatial deep neural network-based framework. *Remote Sensing*, 13(13), 2513. <https://doi.org/10.3390/rs13132513>
- NASA. (2024a). *FIRMS*. NASA. <https://firms.modaps.eosdis.nasa.gov/country/>
- NASA. (2024b). *Gldas: Project goals*. NASA. <https://ldas.gsfc.nasa.gov/gldas>
- NASA. (2024c). *Modis web*. NASA. <https://modis.gsfc.nasa.gov/about/>
- NASA. (2024d). *Modis web*. NASA. <https://modis.gsfc.nasa.gov/data/dataproduct/mod13.php>
- NASA. (2024e). Visible Infrared Imaging Radiometer Suite (VIIRS) - LAADS DAAC. NASA. [https://ladsweb.modaps.eosdis.nasa.gov/missions-and-measurements/viirs/National Oceanic and Atmospheric Administration](https://ladsweb.modaps.eosdis.nasa.gov/missions-and-measurements/viirs/National%20Oceanic%20and%20Atmospheric%20Administration). (2023). <https://www.noaa.gov/>
- Nikolaou, C., Dogani, K., Bereta, K., Garbis, G., Karpathiotakis, M., Kyzirakos, K., & Koubarakis, M. (2015). Sextant: Visualizing time-evolving linked Geospatial Data. *Journal of Web Semantics*, 35, 35–52. <https://doi.org/10.1016/j.websem.2015.09.004>
- Nur, A. S., Kim, Y. J., & Lee, C.-W. (2022). Creation of wildfire susceptibility maps in Plumas National Forest using insar coherence, deep learning, and metaheuristic optimization approaches. *Remote Sensing*, 14(17), 4416. <https://doi.org/10.3390/rs14174416>
- Omar, N., Al-zebair, A., & Sengur, A. (2021). Deep learning approach to predict forest fires using meteorological measurements. *2021 2nd International Informatics and Software Engineering Conference (IISEC)*, 1–4. <https://doi.org/10.1109/iisec54230.2021.9672446>
- Orman Genel Müdürlüğü 2023 Yılı Faaliyet raporu. (2023). <https://www.ogm.gov.tr/tr/e-kutuphane-sitesi/FaaliyetRaporu/>

- Orman Genel Müdürlüğü*. OGM. (1995). <https://www.ogm.gov.tr/>
- Palahi, M., Mavsar, R., Gracia, C., & Birot, Y. (2008). Mediterranean forests under focus. *International Forestry Review*, 10(4), 676–688. <https://doi.org/10.1505/ifor.10.4.676>
- Pimentel, D., Harvey, C., Resosudarmo, P., Sinclair, K., Kurz, D., McNair, M., Crist, S., Shpritz, L., Fitton, L., Saffouri, R., & Blair, R. (1995). Environmental and economic costs of soil erosion and conservation benefits. *Science*, 267(5201), 1117–1123. <https://doi.org/10.1126/science.267.5201.1117>
- Planas, E., & Pastor, E. (2013). Wildfire behaviour and Danger Ratings. *Fire Phenomena and the Earth System*, 53–75. <https://doi.org/10.1002/9781118529539.ch4>
- Prapas, I., Kondylatos, S., Papoutsis, I., Camps-Valls, G., Ronco, M., Fernández-Torres, M.-Á., Guillem, M. P., & Carvalhais, N. (2021, November 4). *Deep learning methods for daily wildfire danger forecasting*. arXiv.org. <https://arxiv.org/abs/2111.02736>
- Priyanka, N. A., & Kumar, D. (2020). Decision Tree Classifier: A detailed survey. *International Journal of Information and Decision Sciences*, 12(3), 246. <https://doi.org/10.1504/ijids.2020.108141>
- Rego, F. C., & Catry, F. X. (2006). Modelling the effects of distance on the probability of fire detection from lookouts. *International Journal of Wildland Fire*, 15(2), 197–202.
- Rego, F. C. (1992). Land use changes and wildfires. *Responses of Forest Ecosystems to Environmental Changes*, 367–373. https://doi.org/10.1007/978-94-011-2866-7_33
- Resmi istatistikler*. OGM. (2024). <https://www.ogm.gov.tr/tr/e-kutuphane/resmi-istatistikler>
- Rodell, M., Houser, P. R., Jambor, U., Gottschalck, J., Mitchell, K., Meng, C.-J., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., Entin, J. K., Walker, J. P., Lohmann, D., & Toll, D. (2004). The Global Land Data Assimilation System. *Bulletin of the American Meteorological Society*, 85(3), 381–394. <https://doi.org/10.1175/bams-85-3-381>
- Rollins, M. G., Morgan, P., & Swetnam, T. (2002). Landscape-scale controls over 20th century fire occurrence in two large Rocky Mountain (USA) wilderness areas. *Landscape Ecology*, 17(6), 539–557. <https://doi.org/10.1023/a:1021584519109>
- Rothermel, R. C. (1972). *A mathematical model for predicting fire spread in wildland fuels* (Vol. 115). Intermountain Forest & Range Experiment Station, Forest Service, US Department of Agriculture.
- Rothermel, R. C. (1983). *How to Predict the Spread and Intensity of Forest and Range Fires*. <https://doi.org/10.2737/int-gtr-143>

- R. Velez, "High intensity forest fires in the Mediterranean Basin:natural and socioeconomic causes," *Disaster Manage*, vol. 5, pp.16–20, 1993.
- Ryu, S.-R., Chen, J., Zheng, D., & Lacroix, J. J. (2007). Relating surface fire spread to landscape structure: An application of FARSITE in a managed Forest Landscape. *Landscape and Urban Planning*, 83(4), 275–283. <https://doi.org/10.1016/j.landurbplan.2007.05.002>
- Sabry Issa, A., & Mohsin Abdulazeez Brifcani, A. (2011). Intrusion detection and attack classifier based on three techniques: A comparative study. *Engineering and Technology Journal*, 29(2), 386–412. <https://doi.org/10.30684/etj.29.2.17>
- Saeipourdizaj, P., Sarbakhsh, P., & Gholampour, A. (2021). Application of imputation methods for missing values of PM10 and O3 data: Interpolation, moving average and K-nearest neighbor methods. *Environmental Health Engineering and Management Journal*, 8(3), 215-226.
- Schapire, R. E. (2013). Explaining adaboost. *Empirical Inference*, 37–52. https://doi.org/10.1007/978-3-642-41136-6_5
- Schoenberg, F. P., Peng, R., Huang, Z., & Rundel, P. (2003). Detection of non-linearities in the dependence of burn area on fuel age and climatic variables. *International Journal of Wildland Fire*, 12(1), 1. <https://doi.org/10.1071/wf02053>
- Seneviratne, S. I., Zhang, X., Adnan, M., Badi, W., Dereczynski, C., Luca, A. D., ... & Allan, R. (2021). Weather and climate extreme events in a changing climate.
- Setchell, H. (2024, October 2). *ECMWF reanalysis V5*. ECMWF. <https://www.ecmwf.int/en/forecasts/dataset/ecmwf-reanalysis-v5>
- Shamim, A., Hussain, H., & Maqbool Uddin Shaikh. (2010). A framework for generation of rules from decision tree and decision table. *2010 International Conference on Information and Emerging Technologies*, 1–6. <https://doi.org/10.1109/iciet.2010.5625700>
- Shams Eddin, M. H., Roscher, R., & Gall, J. (2023). Location-aware adaptive normalization: A deep learning approach for wildfire danger forecasting. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1–18. <https://doi.org/10.1109/tgrs.2023.3285401>
- Shao, Y., Wang, Z., Feng, Z., Sun, L., Yang, X., Zheng, J., & Ma, T. (2022). Assessment of China's forest fire occurrence with deep learning, geographic information and Multisource Data. *Journal of Forestry Research*, 34(4), 963–976. <https://doi.org/10.1007/s11676-022-01559-1>
- Shuttle Radar Topography Mission (SRTM) - LP DAAC*. Shuttle Radar Topography Mission (SRTM). (2024). https://lpdaac.usgs.gov/documents/13/SRTM_Quick_Guide.pdf

- The shuttle radar topography mission (SRTM) collection ... The Shuttle Radar Topography Mission (SRTM) Collection User Guide.* (2015). https://lpdaac.usgs.gov/documents/179/SRTM_User_Guide_V3.pdf
- Silveira, M. V., Petri, C. A., Broggio, I. S., Chagas, G. O., Macul, M. S., Leite, C. C., Ferrari, E. M., Amim, C. G., Freitas, A. L., Motta, A. Z., Carvalho, L. M., Silva Junior, C. H., Anderson, L. O., & Aragão, L. E. (2020). Drivers of fire anomalies in the Brazilian amazon: Lessons learned from the 2019 Fire Crisis. *Land*, 9(12), 516. <https://doi.org/10.3390/land9120516>
- Stephens, S. L. (2005). Forest fire causes and extent on United States Forest Service Lands. *International Journal of Wildland Fire*, 14(3), 213. <https://doi.org/10.1071/wf04006>
- Sun, Y., Zhu, L., Wang, G., & Zhao, F. (2017). Multi-input convolutional neural network for flower grading. *Journal of Electrical and Computer Engineering*, 2017, 1–8. <https://doi.org/10.1155/2017/9240407>
- Suresh, A., Udendhran, R., & Balamurgan, M. (2019). Hybridized neural network and decision tree based classifier for prognostic decision making in breast cancers. *Soft Computing*, 24(11), 7947–7953. <https://doi.org/10.1007/s00500-019-04066-4>
- Swetnam, T. W., & Betancourt, J. L. (1998). Mesoscale Disturbance and ecological response to decadal climatic variability in the American Southwest. *Journal of Climate*, 11(12), 3128–3147. [https://doi.org/10.1175/1520-0442\(1998\)011<3128:mdaert>2.0.co;2](https://doi.org/10.1175/1520-0442(1998)011<3128:mdaert>2.0.co;2)
- Touzani, S., Granderson, J., & Fernandes, S. (2018). Gradient boosting machine for modeling the energy consumption of commercial buildings. *Energy and Buildings*, 158, 1533–1543. <https://doi.org/10.1016/j.enbuild.2017.11.039>
- Turner, M. G., & Romme, W. H. (1994). Landscape Dynamics in Crown Fire Ecosystems. *Landscape Ecology*, 9(1), 59–77. <https://doi.org/10.1007/bf00135079>
- UNEP. (2022). *Spreading like wildfire: The rising threat of extraordinary landscape fires*. <https://www.unep.org/resources/report/spreading-wildfire-rising-threat-extraordinary-landscape-fires>
- Varol, T., Canturk, U., Cetin, M., Ozel, H. B., & Sevik, H. (2021). Impacts of climate change scenarios on European ash tree (*Fraxinus excelsior* L.) in Turkey. *Forest Ecology and Management*, 491, 119199. <https://doi.org/10.1016/j.foreco.2021.119199>
- Vázquez, A., & Moreno, J. M. (2001). Spatial distribution of forest fires in Sierra de Gredos (Central Spain). *Forest Ecology and Management*, 147(1), 55–65. [https://doi.org/10.1016/s0378-1127\(00\)00436-9](https://doi.org/10.1016/s0378-1127(00)00436-9)
- Westerling, A. L., Hidalgo, H. G., Cayan, D. R., & Swetnam, T. W. (2006). Warming and earlier spring increase western U.S. forest wildfire activity. *Science*, 313(5789), 940–943. <https://doi.org/10.1126/science.1128834>

- Wildfires in the Mediterranean: Effis Data reveal extent this summer*. EU Science Hub. (2023, September 8). https://joint-research-centre.ec.europa.eu/jrc-news-and-updates/wildfires-mediterranean-effis-data-reveal-extent-summer-2023-09-08_en
- World Bank Group Forest Action Plan FY16–20*. (2016) <https://doi.org/10.1596/k8864>
- World Resources Institute. (2024). <https://www.wri.org/data>
- Wotton, B. M., Martell, D. L., & Logan, K. A. (2003). Climate change and people-caused forest fire occurrence in Ontario. *Climatic Change*, Vol. 60, No. 3, Pp. 275–295, 2003., 60(3), 275–295. <https://doi.org/10.1023/a:1026075919710>
- Yang, F.-J. (2019). An extended idea about decision trees. *2019 International Conference on Computational Science and Computational Intelligence (CSCI)*, 349–354. <https://doi.org/10.1109/csci49370.2019.00068>
- Yang, S., Lupascu, M., & Meel, K. S. (2021). Predicting forest fire using remote sensing data and machine learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(17), 14983–14990. <https://doi.org/10.1609/aaai.v35i17.17758>
- Yıldız, K., Sipahioğlu, S., & Yılmaz, M. (2000). *Çevre bilimi. Gündüz Eğitim ve Yayıncılık*.
- Zhang, G., Wang, M., & Liu, K. (2019). Forest fire susceptibility modeling using a convolutional neural network for Yunnan Province of China. *International Journal of Disaster Risk Science*, 10(3), 386–403. <https://doi.org/10.1007/s13753-019-00233-1>
- Zhang, G., Wang, M., & Liu, K. (2021). Deep Neural Networks for global wildfire susceptibility modelling. *Ecological Indicators*, 127, 107735. <https://doi.org/10.1016/j.ecolind.2021.107735>
- Zhang, G., Wang, M., & Liu, K. (2022). Dynamic prediction of global monthly burned area with Hybrid Deep Neural Networks. *Ecological Applications*, 32(5). <https://doi.org/10.1002/eap.2610>
- Zheng, B., Ciais, P., Chevallier, F., Yang, H., Canadell, J. G., Chen, Y., van der Velde, I. R., Aben, I., Chuvieco, E., Davis, S. J., Deeter, M., Hong, C., Kong, Y., Li, H., Li, H., Lin, X., He, K., & Zhang, Q. (2023). Record-high CO2 emissions from boreal fires in 2021. *Science*, 379(6635), 912–917. <https://doi.org/10.1126/science.ade0805>
- Şekercioğlu, Ç. H., Anderson, S., Akçay, E., Bilgin, R., Can, Ö. E., Semiz, G., Tavşanoğlu, Ç., Yokeş, M. B., Soyumert, A., İpekdağ, K., Sağlam, İ. K., Yücel, M., & Nüzhet Dalfes, H. (2011). Turkey's globally important biodiversity in crisis. *Biological Conservation*, 144(12), 2752–2769. <https://doi.org/10.1016/j.biocon.2011.06.025>