

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMA SİSTEMLERİ İLE YANGINA HASSAS
BÖLGELERİN TAHMİN EDİLMESİ**

Semanur ÇÖKEKOĞLU

**Danışman
Dr. Öğr. Üyesi Fatih Ahmet ŞENEL**

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI
ISPARTA – 2023**



© 2023 [Semanur ÇÖKEKOĞLU]

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER.....	i
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR.....	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
SİMGELER VE KISALTMALAR DİZİNİ	x
1.GİRİŞ.....	1
1.1. Türkiye’ deki Orman Varlığı	2
1.2.Orman Yangınları.....	5
1.3. Uzaktan Algılama Yöntemleri	8
1.4.Tezin Amacı.....	10
2. LİTERATÜR ÖZETİ.....	11
3. MATERYAL VE KULLANILAN METOTLAR.....	16
3.1. Landsat 8 Uydu.....	16
3.1.1. Landsat 8 uydusunun avantajları	19
3.2. USGS Earth Explorer.....	20
3.2.1. USGS earth explorer tarafından Landsat 8 verilerine erişim.....	21
3.3. Uydu Görüntülerin İşlenmesinde Kullanılan Yöntemler	22
3.3.1. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI)	22
3.3.2. Kara yüzey sıcaklığı (LST)	25
3.4. Verilerin Tahmininde Kullanılan Derin Öğrenme Yöntemleri.....	27
3.4.1. Konvolüsyonel sinir ağı (CNN).....	28
3.4.2. Uzun kısa süreli bellek sinir ağı (LSTM).....	31
3.5. Makine Öğrenmesi	33
3.5.1. Random forest (RF)	34
3.5.2. K-fold çapraz doğrulama yöntemi (KF)	35
3.6. Orman Yangınları Tahmini için Kullanılan Program ve Kütüphaneler	36
3.6.1. Python programa dili.....	36
3.6.2. Keras kütüphanesi	38
3.6.3. Pandas kütüphanesi.....	38
3.6.4. NumPy kütüphanesi.....	39
3.6.5. TensorFlow kütüphanesi	40
3.6.6. Scikit – learn kütüphanesi	41
3.6.7. Rasterio kütüphanesi.....	42
4. ARAŞTIRMA BULGULARI.....	44
4.1. Orman Yangını Çıkan Bölgelerin Belirlenmesi.....	44
4.2. Hava Durumu Değerlerinin Toplanması	46
4.3. Orman Yangını Meydana Gelen Bölgelerin Uydu Görüntüleri	47
4.3.1. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI)	48
4.3.2. Kara yüzey sıcaklığı (LST)	50
4.4. Orman Yangını Tahmininde Kullanılan Algoritmalar ve Sonuçları.....	51
4.4.1. Konvolüsyonel sinir ağı (CNN).....	51
4.4.2. Uzun kısa süreli bellek sinir ağı (LSTM).....	55
4.4.3.Rastgele orman (Random forest (RF)) algoritması	58
4.5. Karşılaştırma Sonuçları.....	60

5. TARTIŞMA VE SONUÇLAR.....	63
KAYNAKLAR.....	66
EKLER.....	75
EK A. HARİTALAR.....	76
EK. B. GRAFİKLER.....	81
ÖZGEÇMİŞ.....	82



ÖZET

Yüksek Lisans Tezi

UZAKTAN ALGILAMA SİSTEMLERİ İLE YANGINA HASSAS BÖLGELERİN TAHMİN EDİLMESİ

Semanur ÇÖKEKOĞLU

**Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Dr. Öğr. Üyesi Fatih Ahmet ŞENEL

Bu tez çalışmasında, Türkiye'de 28 Temmuz 2021 ile 12 Ağustos 2021 tarihleri arasında meydana gelen orman yangınları üzerine odaklanmış ve makine öğrenimi ile derin öğrenme yöntemlerini kullanarak orman yangını tahmini gerçekleştirmiştir.

İlk aşamada, 2021 yılında etkilenen iller ve ilçeler tespit edilerek bir veri seti oluşturulmuştur. Bu bölgelerin geçmiş hava koşulları, yani hava sıcaklığı, bağıl nem ve rüzgar hızı verileri toplanmış ve analiz edilerek veri setine dahil edilmiştir. Aynı zamanda, Landsat 8 uydu görüntüleri indirilmiştir. Landsat 8 uydu görüntüleri elde edildikten sonra Python programlama dili kullanılarak Normalleştirilmiş Fark Bitki Örtü İndeksi (NDVI) ve Yüzey Sıcaklığı (LST) analizleri gerçekleştirilmiş ve elde edilen sonuçlar da veri setine eklenmiştir.

Veri seti oluşturulduktan sonra, çeşitli makine öğrenimi ve derin öğrenme algoritmaları kullanarak orman yangını tahminleri yapılmıştır. Bu makine öğrenimi ve derin öğrenme yöntemleri olarak yapılan deney ve çalışmalar sonucunda Evrişimli Sinir Ağları (CNN), Uzun Kısa Dönemli Hafıza (LSTM) ve Rastgele Orman (RF) algoritması seçilmiştir. Daha sonra makine öğrenimi ve derin öğrenme algoritmaları oluşturulan veri setinde üzerinde tahmin performansları değerlendirilmiştir. Bu tahmin değerlendirilmesi yapılırken her bir algoritmanın kendi içerisinde en iyi tahmin sonuçlarını elde edebilmesi için Grid arama modeli kullanılarak; CNN algoritmasında epoch ve kernel size'ına, LSTM algoritmasında epoch ve units'e ve RF algoritmasında ise derinlik ve karar ağaç sayılarına farkı değerler denilerek en yüksek doğruluk oranlarının tespiti sağlanmıştır.

Elde edilen tahmin sonuçları detaylı bir şekilde analiz edilerek tablolar halinde sunulmuştur. Yapılan karşılaştırmalar sonucunda, tüm algoritmalar arasında en iyi tahmin performansını Rastgele Orman (RF) algoritmasının gösterdiği görülmüştür. Derin öğrenme algoritmaları içerisinde ise Uzun Kısa Dönemli Hafıza (LSTM) yöntemi en başarılı sonuçları elde etmiştir.

Bu çalışmanın sonucunda, Türkiye'deki orman yangınlarının tahmininde makine öğrenimi ve derin öğrenme tekniklerinin etkin bir şekilde kullanılabileceği ortaya konmuştur. Rastgele Orman (RF) ve Uzun Kısa Dönemli Hafıza (LSTM) gibi yöntemlerin öne çıkması, gelecekteki yangınların tahmin edilmesinde bu algoritmaların tercih edilmesi gerektiğini göstermektedir.

Bu sayede, erken uyarı sistemlerinin ve yangın önleme stratejilerinin geliştirilmesi yoluyla, orman yangınlarının olumsuz etkileri en aza indirgenebilir.

Anahtar Kelimeler: Makine Öğrenmesi, Derin Öğrenme, Görünürlük Analizi, Yangın Risk Haritası, Uzaktan Algılama, Orman Yangını.

2023, 82 sayfa



ABSTRACT

M.Sc. Thesis

FORECASTING FIRE PRONE REGIONS UTILIZING REMOTE SENSING SYSTEMS

Semanur ÇÖKEKOĞLU

**Süleyman Demirel University
School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Asst. Prof. Dr. Fatih Ahmet ŞENEL

In this thesis, the focus was directed towards forest fire prediction in Turkey during the period spanning from July 28, 2021, to August 12, 2021, employing both machine learning and deep learning methodologies.

The initial phase encompassed the construction of a comprehensive dataset, achieved by identifying the provinces and districts affected throughout the year 2021. Pertinent historical weather metrics, including temperature, relative humidity, and wind speed, were meticulously collected and subsequently subjected to rigorous analysis, facilitating their seamless integration into the dataset. Furthermore, the acquisition of Landsat 8 satellite images ensued, and through the utilization of the Python programming language, the Normalized Difference Vegetation Index (NDVI) and Land Surface Temperature (LST) were effectively derived. These derived indices were then thoughtfully incorporated into the burgeoning dataset.

Upon the establishment of this dataset, the forecasting of forest fires ensued, employing a diverse array of machine learning and deep learning algorithms. Following a series of methodical experiments and analyses, the Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), and Random Forest (RF) algorithms emerged as the focal points for predictive modeling. Subsequently, an exhaustive evaluation of prediction performance ensued, with each algorithm undergoing a thorough optimization process through the utilization of the Grid Search approach. This involved the fine-tuning of hyperparameters such as epoch and kernel size for CNN, epoch and units for LSTM, and depth and quantity of decision trees for RF, all geared towards attaining the utmost accuracy.

The culmination of these efforts materialized in a robust presentation and analysis of the prediction results, elegantly synthesized in the form of comprehensive tables. Comparative analyses notably underscored the superior predictive capacity of the Random Forest (RF) algorithm, transcending all others. Among the ambit of deep learning methodologies, the Long Short-Term Memory

(LSTM) algorithm demonstrated exceptional predictive prowess, warranting its recognition.

Collectively, the outcomes of this study underscore the potent applicability of machine learning and deep learning techniques in the context of forest fire prediction within the Turkish landscape. The resounding prominence of methodologies such as Random Forest (RF) and Long Short-Term Memory (LSTM) resonates with their potential as formidable tools for imminent fire forecasting endeavors. In effect, these findings further advocate for the augmentation of preemptive warning systems and fire abatement strategies, constituting a pivotal step towards the minimization of the deleterious consequences precipitated by forest fires.

Keywords: Machine Learning, Deep Learning, Visibility Analysis, Fire Risk Map, Remote Sensing, Forest Fire

2023, 82 pages

TEŞEKKÜR

Tez çalışması boyunca değerli tecrübelerini ve bilgilerini benden esirgemeyerek, eleştirileri ve desteğiyle bana yol gösteren, akademik alanda gelişimime katkıda bulunarak emek harcayan çok kıymetli saygı değer tez danışmanım Dr. Öğr. Üyesi Fatih Ahmet ŞENEL'e çok teşekkür ederim.

Tavsiye ve desteklerini esirgemeyen Hitit Üniversitesi Mühendislik Fakültesi'ndeki saygı değer sayın hocalarıma teşekkür ederim.

Tüm bu süreçlerde sabrını, hoşgörüsünü ve desteklerini esirgemeyen, fedakarlıklarıyla hayatımı kolaylaştıran, hayatımın her aşamasında hep arkamda duran, maddi ve manevi en büyük desteği veren canım annem Dilek ÇÖKEKOĞLU'na, canım babam Haruni Hüseyin ÇÖKEKOĞLU'na, çok sevdiğim kardeşim Neslişah ÇÖKEKOĞLU'na, sonsuz sevgi ve saygılarımla teşekkür ederim.

Semanur ÇÖKEKOĞLU
ISPARTA, 2023

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Türkiye’de toplam orman alanındaki artış grafiği.....	3
Şekil 1.2. Türkiye’de yıllara göre orman yangınlarının sayısı.....	6
Şekil 1.3. 2022 yılı orman yangınlarının nedenleri	7
Şekil 3.1. Landsat 8 uydusu.....	16
Şekil 3.2. Landsat 8 verilerinin indirilmesi için USGS web arayüzü	22
Şekil 3.3. K-fold algoritması çapraz doğrulama	36
Şekil 4.1. İş akış şeması	44
Şekil 4.2. Türkiye haritasında seçilen bölgelerin gösterimi	46
Şekil 4.3. Python ile NDVI hesabı.....	48
Şekil 4.4. Görüntünün min ve max değerlerine göre kaydedilmesi	49
Şekil 4.5. LST değerlerinin hesaplanması.....	50
Şekil 4.6. LST ve NDVI koşullandırma	51
Şekil 4.7. CNN farklı değerlere göre doğruluk analizi	54
Şekil 4.8. CNN algoritması çapraz doğrulama toplam tahmin sonuçları.....	55
Şekil 4.9. CNN algoritması çapraz doğrulama ile doğruluk ve kesinlik analizi.....	55
Şekil 4.10. LSTM değerlere göre doğruluk oranı.....	56
Şekil 4.11. LSTM algoritması çapraz doğrulama toplam tahmin sonuçları	57
Şekil 4.12. LSTM algoritması çapraz doğrulama ile doğruluk ve kesinlik analizi.....	58
Şekil 4.13. Rastgele orman algoritması çapraz doğrulama toplam tahmin sonuçları	59
Şekil 4.14. RF algoritması farklı değerlere göre doğruluk analizi	59
Şekil 4.15. RF algoritması çapraz doğrulama doğruluk ve kesinlik analizi	60
Şekil 4.16. Karşılaştırma sonuçları	61
Şekil 4.17. Çapraz doğrulama karşılaştırma sonuçları.....	61
Şekil 4.18. K-fold çapraz doğrulama ile doğruluk tahminleri karşılaştırması.....	62
Şekil A.1. Fethiye NDVI görüntüsü	76
Şekil A.2. Fethiye NDVI renklendirilmiş görüntüsü	77
Şekil A.3. Manavgat NDVI görüntüsü	78
Şekil A.4. Manavgat yangın öncesi NDVI görüntüsü	79
Şekil A.5. Köyceğiz NDVI görüntüsü	80

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. Landsat 8 uydusu OLI bant aralıkları ve özellikleri.....	17
Çizelge 4.1. 2021 yılı en çok orman yangını meydana gelen iller	45
Çizelge 4.2. 2021 yılı orman yangını meydana gelen ilçeler	45
Çizelge 4.3. 2021 yılı hava durumu verileri.....	47
Çizelge 4.4. NDVI değer aralığı renklendirmesi.....	49
Çizelge B.1. Manavgat 31 Temmuz 2021 tarihli analizi.....	81
Çizelge B.2. Fethiye 31 Temmuz 2021 tarihli analizi	81



SİMGELER VE KISALTMALAR DİZİNİ

CNN	Konvolüsyonel sinir ağı
KF	K-Fold çapraz doğrulama yöntemi
LST	Kara yüzey sıcaklığı
LSTM	Uzun kısa süreli bellek sinir ağı
NDVI	Normalleştirilmiş fark bitki örtüsü indeksi
OGM	Orman Genel Müdürlüğü
RF	Random forest (Rastgele Orman)



1.GİRİŞ

Ormanlar, dünya üzerindeki en önemli ekosistemlerden biridir. Geniş alanlara yayılan ağaçlar, bitkiler, hayvanlar ve diğer canlı organizmaların bir araya gelerek oluşturduğu bu yaşam alanları, birçok ekolojik sürecin merkezinde yer almaktadır (FAO, 2020).

Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) tarafından yapılan bir rapora göre, dünya genelinde ormanlık alanlar toplamda yaklaşık 4,06 milyar hektarlık bir alanı kaplamaktadır (FAO, 2020).

Ormanlar, atmosferdeki karbondioksiti kullanarak oksijen üretirler ve iklim düzenlemesine katkı sağlamaktadır. Ayrıca su döngüsünü düzenleyerek su kaynaklarının sürdürülebilirliğini desteklemektedirler. Ormanlar aynı zamanda biyolojik çeşitliliğin korunması, toprak erozyonunun önlenmesi ve habitat sağlanması gibi ekosistem hizmetleri sunmaktadır (FAO, 2020). Dünya genelindeki ormanların çeşitlilik gösterdiği birçok ekosistem bulunmaktadır. Bu ekosistemler arasında tropikal yağmur ormanları, boreal ormanlar, subtropikal ormanlar, maki ormanları ve ova ormanları gibi farklı türler bulmakta ve her bir ekosistem, kendine özgü bitki ve hayvan türlerine ev sahipliği yapar ve benzersiz bir biyolojik çeşitlilik sunmaktadır (Lewis ve Maslin, 2015).

Ormanlar, karbon depolama ve karbon emilimi açısından büyük bir rol oynamaktadır. Ağaçlar, atmosferde bulunan karbondioksiti kullanarak oksijen üretmektedir. Bu süreç, fotosentez olarak bilinir ve ormanlar tarafından gerçekleştirilen birincil üretim sürecidir. Büyük miktarlarda karbonu depolarlar ve atmosferdeki karbondioksit miktarının düşmesine yardımcı olurlar. Bu nedenle, ormanların tahrip edilmesi veya ormansızlaşma, atmosferdeki karbon miktarının artmasına ve iklim değişikliğinin hızlanmasına neden olabilir (Bonan, 2008).

Ormanlar, aynı zamanda ekonomik açıdan da büyük bir değere sahiptir. Ahşap ve orman ürünleri, inşaat malzemeleri, mobilya, kâğıt ve enerji kaynakları olarak

kullanmakta, yerel topluluklar için istihdam ve geçim kaynağı oluşturmaktadır. Ayrıca, turizm ve rekreasyon faaliyetleri için popüler mekanlar olarak hizmet verir ve ormanlarda doğa yürüyüşleri, kampçılık, avcılık, kuş gözlemciliği gibi birçok aktivite gerçekleştirilebilmektedir. Bu turistik faaliyetler, yerel ekonomilere katkı sağlamakta ve ormanların sürdürülebilir yöntemlerine teşvik edilebilmektedir (Mackey vd., 2015). Dünya genelindeki orman alanları, ne yazık ki, sürekli olarak azalmaktadır. Tarım, yerleşim, endüstriyel faaliyetler, aşırı odun kesimi ve ormansızlaşma gibi insan faaliyetleri, ormanların tahrip olmasına ve orman alanlarının azalmasına yol açmaktadır.


Bu durum, biyolojik çeşitlilik kaybına, toprak erozyonuna, su kaynaklarının azalmasına ve iklim değişikliği gibi bir dizi olumsuz etkiye sebep olmaktadır. Sonuç olarak, dünyadaki ormanlar, biyolojik çeşitlilik, iklim düzenlemesi, su kaynaklarının korunması, toprak erozyonunun önlenmesi ve sosyo ekonomik faydalar gibi önemli ekosistem hizmetlerini sağlayan yaşamsal öneme sahip ekosistemlerdir. Ormanların korunması ve sürdürülebilir yönetimi, insanlığın geleceği için büyük bir öneme sahiptir.

1.1. Türkiye’deki Orman Varlığı

Türkiye, zengin, geniş orman kaynaklarına sahip olan bir ülkedir ve ormanlar, ekolojik, ekonomik ve sosyal açıdan büyük bir öneme sahiptir. Orman Genel Müdürlüğü’nün 2022 verilerine göre, Türkiye’nin toplam yüzölçümünün %29,6’sı ağaçlarla kaplı ormanlık alanlardan oluşur (OGM, 2022).

Türkiye’deki orman varlığındaki artış Şekil 1.1’de de gösterildiği gibi yıllar içinde hektar kilometre olarak büyük ölçüde artmaktadır. Bu ormanların büyük bir bölümü devlet ormanlarıdır ve yönetimi Orman Genel Müdürlüğü tarafından gerçekleştirilir. Özel mülkiyetli ormanlar ise toplam ormanlık alanın çok küçük bir kısmını oluşturmaktadır (OGM, 2020).

Türkiye'nin ormanları, biyolojik çeşitlilik, ekosistem hizmetleri, toprak ve su kaynaklarının korunması, iklim düzenlemesi, ahşap ürünler ve turizm gibi birçok alanda önemli katkılar sağlamaktadır (OGM, 2022).



Şekil 1.1. Türkiye’ toplam orman alanındaki artış grafiği (OGM, 2022)

Türkiye, zengin orman kaynaklarına sahip olan bir ülkedir ve ormanlar, ekolojik, ekonomik ve sosyal açıdan büyük bir öneme sahiptir. Ormanlar, biyolojik çeşitlilik, iklim düzenlemesi, su kaynaklarının korunması, erozyon kontrolü, habitat sağlama ve ahşap ürünlerin temini gibi birçok önemli ekosistem hizmetini yerine getirmektedirler.

Türkiye’deki ormanlar bölgesel olarak farklı dağılımlara sahiptir. Karadeniz Bölgesi, Türkiye’nin en büyük orman varlığına sahip olan bölgedir. Burada nemli iklim ve yüksek yağış miktarı, yoğun orman örtüsünün oluşmasını sağlar. Karaçam, kayın, gürgen ve köknar gibi ağaç türleri bu bölgede yaygındır.

Marmara Bölgesi, Türkiye’nin ikinci en büyük orman varlığına sahip olan bölgedir. Bu bölge, farklı iklim özelliklerine sahip alt bölgelerden oluşur. Marmara Bölgesinde meşe, karaçam, sedir ve çınar gibi ağaç türleri yaygındır. Ormanlar, bölgenin su kaynaklarının korunması, erozyonun önlenmesi ve yerel ekonomiye katkı sağlama açısından büyük bir öneme sahiptir.

Ege Bölgesi, Akdeniz ikliminin etkisi altında olan ve orman varlığı açısından önemli bir bölgedir. Bu bölgede çam, ardıç, mazi, defne ve zeytin gibi ağaç türleri bulunur. Ege Bölgesi'ndeki ormanlar, turizm ve tarım faaliyetleri için büyük bir potansiyele sahiptir. Aynı zamanda biyolojik çeşitlilik açısından da zengindir ve endemik bitki ve hayvan türlerine ev sahipliği yapar.

Akdeniz Bölgesi, kıyı şeridi boyunca uzanan iklimi ve bitki örtüsü ile tanınır. Bu bölgede çam, sedir, sandal ve zeytin gibi ağaç türleri yaygındır. Akdeniz Bölgesi'ndeki ormanlar, iklim düzenlemesi, erozyon kontrolü ve tarımsal faaliyetler için büyük bir öneme sahiptir. Aynı zamanda turizm sektörüne de katkı sağlar.

İç Anadolu Bölgesi, kara iklimi etkisi altında olan ve kuraklıkla mücadele eden bir bölgedir. Bu bölgede karaçam, sarıçam, meşe, kavak ve söğüt gibi ağaç türleri bulunur. İç Anadolu Bölgesi'ndeki ormanlar, erozyon kontrolü, toprak koruması ve su kaynaklarının sürdürülebilir yönetimi için büyük bir öneme sahiptir.

Doğu Anadolu ve Güneydoğu Anadolu bölgeleri, daha kuru ve yarı çöl iklimine sahip olup orman varlığı daha sınırlıdır. Bu bölgelerde genellikle karaçam, meşe, ardıç ve sarıçam gibi ağaç türleri bulunur. Bu ormanlar, erozyonun önlenmesi, toprak koruması ve su kaynaklarının sürdürülebilir yönetimi için büyük bir öneme sahiptir.

Türkiye'deki orman varlıklarının korunması ve sürdürülebilir yönetimi, ormansızlaşma, plansız kentleşme, tarım faaliyetleri ve yangınlar gibi tehditlere karşı mücadele gerektirir. Ormancılık politikalarının geliştirilmesi, ağaçlandırma ve rehabilitasyon çalışmalarının artırılması, ormancılık sektöründe sürdürülebilir ekonomik büyüme teşvik edilmesi ve ormancılıkla ilgili bilgi, farkındalık ve eğitim faaliyetlerinin güçlendirilmesi önemlidir.

1.2. Orman Yangınları

Orman yangınları, dünya genelinde büyük bir tehdit oluşturan doğal afetlerden biridir. Bu yangınlar, orman ekosistemlerine ve biyolojik çeşitliliğe ciddi zararlar verirken, ekonomik kayıplara, insan sağlığına ve yaşam alanlarının yok olmasına da sebep olabilmektedir (Cruz ve Alexander, 2010).

Yangınların orman ekosistemlerine etkileri oldukça çeşitlidir. Yangınlar, orman bitki örtüsünün zarar görmesine ve habitat kaybına neden olarak biyolojik çeşitlilik üzerinde olumsuz etkiler yaratabilmektedir. Ayrıca, toprak erozyonunu artırabilir, su kaynaklarını kirletebilir ve iklim değişikliğiyle ilişkili olan karbon emisyonlarını artırarak atmosferdeki sera gazı seviyelerini yükseltebilir (Keeley ve Syphard, 2021).


İklim değişikliği ve insan faaliyetlerinin etkisiyle orman yangınlarının sıklığı ve şiddeti dünya genelinde artmaktadır. Bu nedenle, sürdürülebilir ormancılık politikalarının geliştirilmesi, yangın risk analizlerinin yapılması, yangın güvenliğiyle ilgili altyapının güçlendirilmesi ve bilimsel araştırmaların desteklenmesi gibi uzun vadeli stratejilerin uygulanması büyük önem taşımaktadır (Doğanay vd., 2004; Türkiye Cumhuriyeti Tarım ve Orman Bakanlığı, 2011).

Bu yüzden orman yangınlarının önlenmesi ve etkilerinin azaltılması için çeşitli stratejiler ve önlemler alınmaktadır. Bunlar arasında yangın önleme çalışmaları, yangın izleme ve erken uyarı sistemlerinin geliştirilmesi, ormancılık personelinin eğitimi, yangın söndürme ekiplerinin hazırlığı, yangın güvenlik şeritlerinin oluşturulması ve halkın bilinçlendirilmesi gibi önlemler yer almaktadır (Cruz ve Alexander, 2010; Türkiye Cumhuriyeti Tarım ve Orman Bakanlığı, 2021).

Türkiye’de orman yangınlarına karşı sık sık mücadele etmek zorunda olan bir ülkedir. Yangınlar, özellikle yaz aylarında yüksek sıcaklık, düşük bağıl nem ve rüzgar gibi faktörlerin etkisiyle hızla yayılabilir.

Türkiye'nin coğrafi konumu, iklim özellikleri ve orman varlığı, orman yangınlarının sıklığı ve şiddeti üzerinde etkili olmaktadır (Abay vd., 2021).


Orman Genel Müdürlüğünün yayınlamış olduğu 2022 Orman Yangınları faaliyet raporundaki sonuçlara göre oluşturulan Şekil 1.2'de ormanda çıkan yangınların yıllara göre sayısı gösterilmektedir. Bu yangınlar en çok 2020 ve 2021 yıllarında büyük çaplı ve çok sayıda yangın çıkmıştır (OGM, 2022).



Şekil 1.2. Türkiye’de yıllara göre orman yangınlarının sayısı (OGM, 2022)

Türkiye’de büyük çaplı yangınların meydana gelmesinin birçok çeşitli faktörü bir araya gelmesiyle oluşmaktadır. Yangınların çıkmasına sebep olan faktörlere bakıldığında ise insan kaynaklı faktörler, iklim değişikliği ve kuralık, orman yönetiminde yapılan hatalar, doğal ve yapay tehlikeler neden olduğu görülmektedir (Günşen ve Atmış, 2019).

2022 yılında Orman Genel Müdürlüğünün yayınlamış olduğu orman yangınları raporunda Şekil 1.3’te de gösterildiği gibi bu yangınların büyük çoğunluğunun nedenlerine bakıldığında %40’nın sebebi bilinmeyen nedenlerden, %38’ i ihmalden, %17 doğal nedenlerden ve %4’ü kasıtlı olarak ormanların yakılmasından kaynaklandığı görülmektedir.



Şekil 1.3. 2022 yılı orman yangınlarının nedenleri (OGM, 2022)

Hangi sebeple olursa olsun meydana gelen orman yangınlarının Türkiye'ye çevresel, ekonomik ve sosyal açılardan ciddi zararlara yol açmakta ve yıkıcı etkilere sahiptir (Şen ve Güngör, 2018).

Çevresel zarar açısından orman yangınları, doğal ekosistemleri yok eder ve biyolojik çeşitlilik üzerinde ciddi bir etkiye sahiptir. Ağaçların, bitki örtüsünün ve habitatların yakılması, doğal süreçlerin uzun yıllar boyunca yarattığı zengin kaynakların kaybolmasına, endemik türlerin habitatlarının ve ekosistemlerinin denge kaybına ve tahribatına yol açmaktadır. Bunun sonucunda ekosistem hizmetleri azalmakta ve ekolojik denge bozulmaktadır (Kala, 2023).

Orman yangınlarının ekonomik zararlarına bakıldığında ise ormanların tahrip olmasından kaynaklı odun ve kereste rezervlerin azalmasına neden olmaktadır. Ayrıca yangınlar orman alanlarına yakın turistik bölgeleri ve tarım arazilerini de etkilemektedir. Tarım arazilerinin yanmasından dolayı üretilen tarım ürünlerinin yok olmasına ve üreticinin maddi kayıp yaşamasına neden olmaktadır. Turizm bölgelerinde ise yangınların meydana gelmesi tatil için gelen kişilerde korku ve endişe yaşatmasından dolayı turizm oranında azalma görülmektedir. Bu yüzden çıkan orman yangınları bölgelerde iş kaybına ve ekonomin zarar görmesiyle sonuçlanmaktadır (Bayazıt ve Koç, 2022).

Orman yangınları sosyal açıdan da büyük zararlar oluşturmaktadır. Yangınlar insanların yaşadığı kent ve yerleşim yerlerini de etkilemektedir.

İnsanların yangından dolayı evlerini ve çalıştıkları yerleri terk etmesine neden olmaktadır. Bu sonuçlardan kaynaklı kişilerde psikolojik travmalara ve kalıcı sorunlara neden olmaktadır. Bu sorunlar sadece psikolojik açıdan değil ayrıca yangından kaynaklı havanın kirliliğine sebep olmakta ve bundan kaynaklı hava kalitesinin bozulmasından dolayı insanlarda birçok sağlıksal sorunlara neden olmaktadır (Kala, 2023).

Türkiye'deki orman yangınlarının neden olduğu büyük çaplı hasarlardan kaynaklı gelişen zararlardan çok fazla etkilenmektedir. Bu yüzden uzun vadeli önlemler alınması gerekmektedir (Tariq vd., 2023). Önlemlerin alınabilmesi için yangın öncesi öngörülebilir analizler üzerine çalışılması ve tahmin geliştirilmesi ve yaygınlaştırılması gerekmektedir.

1.3. Uzaktan Algılama Yöntemleri

Teknolojinin gelişmesiyle birlikte dünyada uzay çağı da başlamıştır ve teknolojik ilerlemeler meydana geldikçe uzaktan algılama yöntemlerinin geliştiği görülmektedir (Shahabi vd., 2020).

Uzaktan algılama dediğimiz kavram yüzeydeki nesnelerin sensörler yardımıyla görüntülenip, verilerin kaydedilerek analiz edilmesi ve sonuçlandırılmasıdır (Thakur vd., 2020).

Uzaktan algılamada kullanılan araçlar ise uydular, insanlı veya insansız hava araçlarıdır. Bu araçlarda yerleştirilen farklı elektromanyetik dalga boyutlarından veri toplayan sensörlerin geliştirilip, yerleştirilmesiyle istenilen veriler toplanabilmektedir (Mountrakis vd., 2011).

Uzaktan algılama araçlarında kullanılan sensörlere birkaç örnek verilirse optik, termal, radar, mikrodalga, ultraviyole, ışık algılama ve hiperspektral sensörler kullanılmaktadır (Woodhouse, 2005).

Uzaktan algılama araçlarında kullanılan sensörler 2 farklı algılama yöntemiyle verileri elde etmektedir. Bu yöntemler aktif ve pasif algılama olarak ikiye ayrılmaktadır (Wang vd., 2004).

Aktif algılama yöntemi, yeryüzündeki canlı veya cansız nesnelerden yansıyan kendisine ait enerji kaynağı veya sinyallerin ölçülmesiyle nesnenin özellikleri ve uzaklığı analiz edilebilmektedir (Wang vd., 2004). Aktif algılama tekniklerine Radyo algılama (RADAR) ve Işık algılama (LIDAR) örnek olarak gösterilebilir (Wang vd., 2004).

Pasif algılama yöntemi ise kendi enerji kaynağı olmadan canlı veya cansız nesnelerden yayılan elektromanyetik dalgaların sensörler tarafından radyasyonu ölçülerek nesneler hakkında verileri elde etme yöntemidir (Wang vd., 2004). Pasif uzaktan algılama yönteminde nesnelerin kendi enerji kaynakları olmadığı için güneş ışığı gibi doğal kaynaklı oluşan radyasyonu kullanmasından dolayı genel olarak gündüz veriler toplanmaktadır (Mountrakis vd., 2011). Bu yöntemde kullanılan sensörlere örnek olarak; kızılötesi, termal, mikrodalga ve spektral bant aralığına sahip sensörler kullanılmaktadır (Wang vd., 2004).

Uzaktan algılama araçların kullanılmaya başlanmasıyla dünyanın her bir yerinden büyük ölçekli veriler kolay bir şekilde toplanabilmektedir. Bu veriler sayesinde dünyanın her bir yerindeki çevresel değişimleri tespit etmeyi ve analizlemeyi mümkün kılmaktadır (Nagendra, 2001). Uzaktan algılamayla elde edilen veriler coğrafi bilgi sistemleri, güvenlik, tarım, ormancılık, şehir planlama, iklim değişikliği ve daha birçok alanda kullanılmasına olanak sağlamaktadır (Weng, 2009). Bu sayede geniş alanları kapsayan ve ulaşılması zor yerlere de erişim sağlanması mümkün kılınmıştır.

Ayrıca uzaktan algılama yöntemlerinin kullanılmasıyla hızlı veri toplayabilmesi, analiz etme potansiyeli, yüksek çözünürlüğü, sürekli ve tekrarlanabilir gözlem imkânı sunması sayesinde insanlara büyük avantajlar sağlamaktadır.

1.4. Tezin Amacı

Başta ülkemiz olmak üzere tüm dünya için çok büyük bir sorun olan orman yangınları her alanda çalışma konusu olmaktadır. Türkiye’de 2021 yılında temmuz ve ağustos aylarında Ege, Marmara ve Akdenizde meydana gelen orman yangınlarından kaynaklı maddi ve manevi çok büyük hasar almıştır. Orman yangınların çok büyük zarar ve felaketlere sebep olmasından dolayı, bu yangınlar sonucu oluşan hasarların boyutunu en aza indirebilmek, önlenmesi veya tedbir alınabilmesi amacıyla uzaktan algılama, derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak tahmin edilebilirliği amaçlanmıştır. Bu çalışmada; Türkiye’de 28 Temmuz 2021 ve 12 Ağustos 2021 tarihleri arasında meydana gelen orman yangınlarında Manavgat, Milas, Fethiye, Akseki, Bilecik, Datça, Denizli, Kavaklıdere, Yatağan, Taşagıl ve Köyceğiz’de yanan alanlar incelenmiştir. Bu yerlerdeki orman yangınlarının sonucunda meydana gelen incelemeleri elde edebilmek için uzaktan algılama tespitinde Landsat 8 uydusundan elde edilen görüntüler indirilerek, görüntü işleme yöntemleriyle veriler elde edilip, kullanılmıştır. Elde edilen görüntülere ek olarak bölgelerdeki orman yangınları zamanında havadaki bağıl nem, sıcaklık, rüzgar hızı verileri de elde edilip, çalışmaya dahil edilmiştir.

2. LİTERATÜR ÖZETİ

Ganteume vd. (2007), Akdeniz bölgesindeki çıkan orman yangınlarının nedenleri hakkında yaptıkları çalışmada Amerika ve Kanada da çıkan orman yangınlarıyla karşılaştırma yapılarak, nedenleri bulunmaya çalışılmıştır. Yapılan çalışmada Avrupa ve özellikle Akdeniz havzasında çıkan yangınların nedenleri; insan kaynaklı, yıldırım düşmesi sonucuna ve daha çok hava ve iklim koşullarındaki değişimden kaynaklandığını sonucuna varılmış. İnceledikleri bölgedeki orman yangınlarının çoğunlukla öğleden sonra ve hava durumuna bağlı olduğu görülmüştür.

Prasad vd. (2013), Orman yangınlarının çevresel ve ekonomik açıdan çok büyük zararlara sebep olmasından dolayı, bu yangınların hızlı bir şekilde yayılım göstermeden yangınların engellenebilmesi için çalışma yapmışlardır. Yaptıkları bu çalışmada orman yangınlarının tespitinin önemli olduğunu savunmuşlar ve bu tespit için duman hız dağılımı, sensörler ve sondaj sistemlerinin kullanılmasıyla ilgili birçok teknik denenmiş lakin başarı oranını düşük olmasından kaynaklı olarak, uydu görüntülerinden arazi yüzey sıcaklığının gerçek zamanlı olarak tespitinde araştırılması ve çalışılmasını daha etkili bulmuşlardır. Çalışmalarında orman yangınlarının çıktığı çevredeki anormal sıcaklık dağılımlarına ve dalga boylarına bakarak k-mean kümeleme yaklaşımı kullanılarak %90'a yakın yangın tahminini analiz etmişlerdir.

Blackett (2014), Volkanik aktiviteler üzerine yapmış olduğu çalışmada uzaktan algılama yöntemlerinden Landsat 8 uydusundan elde ettiği görüntülerle çalışma yapmayı tercih etmiştir. Sebebinin ise Landsat 8 termal kızılötesi sensörlerinin termal emisyonlarının iyi bir şekilde gösteriyor olmasından kaynaklanmaktadır. Landsat 8 uydusunun termal kızılötesi sensörlerin veri tespitindeki başarısını göstermek için ayrıca NASA'nın Dünya Gözlem Sistemi orta çözünürlüklü görüntüleme spektrometrisinin termal gözlemleriyle karşılaştırma yapmıştır ve bu karşılaştırma sonucunda görüntüleme ve verilerden elde edilen sonuçların aynı doğruda olduğu sonucuna ulaşmıştır.

Vhengani vd. (2015), yangın çıkmış alanların tespitinde Landsat 8 kullanarak çok zamanlı yanmış alanları haritalandırarak, birden fazla yanmış alan endeks hesaplamasıyla karşılaştırma yapmışlardır. Çalışmalarında Python programlama dilini kullanmışlardır. Hesaplamalarında Python kütüphanesinde numpy, scipy, GDAL kitaplıklarını eklemişlerdir. Yangın çıkan bölgelerin hesabını yaparken görüntüdeki bulutluğu maskelemek için FMASK algoritmasını uygulamışlardır. Yanmış bölgelerin endekslerini hesaplamak için Normalleştirilmiş Yanma Oranı(NBR), Kısa Dalga Kızılötesi(SWIR) ve Orta Kızılötesi Yanma İndeksi(MIRBI) kullanmışlardır.

Wu vd. (2015), 2013 yılında çıkan San Carlos Apache'de çıkan Creek yangınındaki bitki örtüsünü kullanarak yanma şiddetini tahmin etmek için Landsat 8 ve WorldView-2 uydularını çalışmalarında kullanmışlardır. Uydulardan elde edilen görüntüleri Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI) hesaplamasını kullanarak bitkilerin yanma şiddeti tahmin edilmiş ve her iki uydunun sonuçları çalışmalarında karşılaştırılmıştır. WorldView-2 uydusunun %80 üzerinde doğruluğu hesaplandığı ancak Landsat 8 uydusundan elde edilen görüntülerdeki verilerin NDVI değeri hesaplandığında WorldView-2 uydusu gibi yüksek düzeyde doğruluk ve uyum sağladığı çalışmalarında görülmüştür.

Chowdhury ve Hassan (2015), yaptıkları çalışmalarında 2009 - 2011 yıllarında Kanada'nın Alberta eyaletinde meydana gelen yangınların günlük ölçeekte orman yangını tehlike tahmini sistemi (FFDFS) geliştirmiş ve uygulanmıştır. Bu orman yangını tehlike tahmini sisteminde uzaktan algılama yöntemleri kullanmışlardır. Bu çalışmada sistemi geliştirirken günlük olarak ölçümler alınarak Düşük Çözünürlüklü Görüntüleme Spektrofotometresi (MODIS) geliştirilmiş ve dört farklı giriş değerleri oluşturulmuştur. Bu değişkenler yüzey sıcaklığı kompoziti (TS), normalize edilmiş çok bantlı kuraklık indeksi (NMDI), havadan günlük verisi alınan su buharı (PW) ve normalize edilmiş bitki indeksi (NDVI) hesaplanılarak, birleştirilmiş ve model geliştirilmiştir. Bu değerler hesaplatılırken beş farklı sınıflandırılmaya ayrılmıştır. Bu sınıflandırmalar "aşırı yüksek, çok yüksek, yüksek, orta ve düşük " olarak ayrılmıştır. Orman yangını

tahmini sistemlerinde hesaplanan deęerler aşırı yüksek ve orta sınıflandırma sonuçlarının tehlikeli olduęu sonucuna ulaşmışlardır.

Littell vd. (2016), orman yangınlarının hem bitki örtüsüne hem de topraęa olan zararları hakkında çalışmalar yapmışlardır. Çalışmalarında orman yangınlardan sonra oluşan sonuçların topraęın, nemin ve sıcaklık faktörlerine baęlı olarak sonuçların deęiştiiğinin ve buna baęlı olarak incelenmesi gerektiğinin sonucuna varmışlardır.

Baranovskiy vd. (2017), yaptıkları çalışmada iklim kaynaklı yangınlarda çayır alanlarda yangının yayılma hızını tahmin etmek için bitki örtüsü indeksi (NDVI) ve uzaktan algılama verilerini kullanmışlardır. Çalışmada verilere gündüz hava sıcaklığı, çiy noktası, rüzgâr yönü ve rüzgâr hızı, günlük yağış hacmi ve yoğunlukları da tahmin modellerine dahil etmişlerdir. NDVI hesaplamak için MOD09GQK' ya ait kırmızı ve yakın kızılötesindeki 1-6 kanallarından elde ettikleri görüntüleri kullanmışlardır.

Reddy ve Prasad (2018), NDVI zaman serisi verilerini kullanarak bitki örtüsü dinamiklerinin tahmini için yapay sinir aęlarından RNN mimarisine ait uzun kısa süreli bellek (LSTM) algoritması kullanarak tahmini gerçekleştirilmiştir. MODIS NDVI'a ait 500'den fazla veri setleri kullanmışlardır. LSTM aęının doğruluğunu ölçmek için kök kare hatasını hesaplamışlardır. Ve sonuçlar ek veri sağlanmadan iyi bir doğrulukla tahmin etmeyi başarmışlardır.

Vega-Nieva vd. (2018), Meksika'daki bitki türleri ve bölgedeki birikmiş yakıt kuruluęu indeksi ile yangın sayısını tahmin etmede uzaktan algılama yöntemleri kullanarak çalışmalarını gerçekleştirmişlerdir. Bu çalışmada tahmin modelleri oluşturulurken uzaktan algılanan hava durumu ve NDVI bilgileri kullanılarak, beklenen sıcaklık deęerleri hesaplanmıştır. Yapılan çalışmada on gün boyunca gözlemlenmiş ve Orta Çözünürlüklü Görüntüleme Spektrometresi (MODIS) tahmin etmek için aktif olan yangın sayısını Yangın Sıcak Nokta Yoęunluk indeksi (FHD) ve Birikmiş Yakıt Kuruluk İndeksi (AcFDI) geliştirmişlerdir. Modelde 2011 ve 2015 yılları arasındaki dönemler ele alınarak 17 farklı ana bitki örtüsünü

incelemişlerdir. Elde edilen veriler hesaplanırken doğrusal ve doğrusal olmayan regresyon modelleriyle test etmişlerdir. Modellerin test edilmesi sonucu çok iyi bir oranda R2 değerlerine ulaşılmıştır.

Maffei vd. (2018), orman yangınlarında yanan alanları anomali süresinin ilişkilendirmek için arazi yüzey sıcaklığı (LST) hesaplayarak çalışmışlardır. Sıcaklık değerlerini hesaplayabilmek için verileri termal kızılötesi bant ile uzaktan algılama ile tespit etmişlerdir. 2003-2011 yıllarında İtalya'nın Campania'da çıkan orman yangınlarından bir veri seti oluşturmuşlardır. Bu veri dizisini oluştururken Zamansal Serilerin Harmonik Analizi algoritması (HANTS) ile eksiksiz veri kümesini oluşturmuşlardır. Daha sonra çalışmalarında yaptıkları güven testlerinde şu sonuca varmışlardır; Arazi yüzey sıcaklığını hesaplandığında aşırı olayların olasılık koşullarıyla pozitif ve artan doğrultuda sapmaların olduğu görmüşlerdir. Bu da arazi yüzey sıcaklığının orman yangınlarında yakılan alanı ve süresini etkilediği hipotezlerini doğrulamışlar ve LST'nin yangın tehlikesi ve zaman serileri hakkında bilgilendirici olduğunu belirtmişlerdir.

Kalantar vd. (2020), orman yangını duyarlılık tahmini için uzaktan algılama verileri üzerinde yeniden örneklendirir, algoritma ve makine öğrenme modellerine dayalı tahmin modeli geliştirmişlerdir. Çalışmalarında üç makine öğrenmesi modeli kullanılarak tahminleme yapmışlardır. Bunlar; çok değişkenli uyarlanabilir regresyon çizgileri (MARS), artırılmış regresyon ağacı (BRT) ve destek vektör makinesi (SVM) modelidir. Makine öğrenmesi modelleri karşılaştırıldığında MARS ve SVM'nin en iyi performans gösterdiği sonucuna ulaşmışlardır.

Mohammed vd. (2020), coğrafi bilgi sistemi haritalarını kullanarak orman yangınlarının etkilerini en aza indirebilmek için makine öğrenme algoritmaları ve karar verme modelleri ile çalışmalarını gerçekleştirmişlerdir. Çalışmalarında makine öğrenme modellerinden Random Forest, SVM ve KNN algoritma modellerini kullanmışlardır. Bu modelleri karşılaştırdıklarında Random forest modelinin hem büyük hem de küçük yangınları diğer modellere göre daha doğru

bir şekilde tahmin ettiđi sonucuna ulařmıřlardır. Modellerin performanslarını dođru bir şekilde deđerlendirmek iin ROC eđirisini kullanmıřlardır.

Majid vd. (2022), dnya zerindeki yangın grntlerini algılamak ve tespit etmek iin derin đrenme algoritmalarından olan CNN modelini kullanmıřlardır. Veri setlerini yangın grselleřtirilmesi ve yerleřtirilmesi iin Grad- Cam yntemi kullanmıřtır. Seilen veri setlerine CNN algoritması uygulandıđında yangın tespitindeki dođruluk oranının %95 olduđunu alıřmalarında gstermiřlerdir.

Zheng vd. (2022), orman yangınlarının dumanından gerek zamanlı tespit iin evriřimli sinir ađına dayalı tespit modeli geliřtirmiřlerdir. alıřmalarında orman yangınlarının neden olduđu olumsuz etkileri azaltmak ve erken tespit ve uyarı iin alıřmıřlardır. Grntlerde birden ok derin evriřimli sinir ađı kullanmıřlar ve bunlardan birisi CNN algoritmasıdır. CNN algoritmasının orman yangının olduđu farklı karmařık grntlerde yangın zelliklerini otomatik olarak hesaplayıp, sonulandırdıđını gstermiřlerdir. %85 zerinde dođruluk elde etmiřlerdir.

3. MATERYAL VE KULLANILAN METOTLAR

Tezin bu bölümünde çalışmamızda gerçekleştirmek için kullandığımız materyal ve yöntemler hakkında genel bilgiler verilmiştir.

3.1. Landsat 8 Uydusu

Amerikan Uzay ve Havacılık Dairesi (NASA) ve ABD Jeoloji Araştırma Merkezi (USGS) tarafından 1972 yılında başlatmış oldukları Landsat programı uzay tabanlı bir uzaktan algılama programıdır. Landsat programının amacı, Dünya yüzeyinde düzenli zamansal sürekli aralıklarla yer yüzünü tarayarak yüksek kalite ve sürekli veri sağlamaktır (Francis ve Rothery, 1987).

Landsat 8 uydusu NASA ve USGS iş birliği ile geliştirilen bir uydu olup, 2013 yılında uzaya gönderilmiştir. Landsat 8 uydusunun görevi; yeryüzündeki değişimleri izlemek, ormancılık, tarım, su kaynakları, çevresel değişimler ve doğal afetler hakkında görüntüler elde edilerek bilgi toplamasını sağlamaktır (Morfit vd., 2015).



Şekil 3.1. Landsat 8 uydusu (Vikipedi, 2012)

Uydunun tasarımı Lockheed Martin tarafından tasarlanmış ve üretilmiştir. Uydunun diğer adı ise Landsat Data Continuity Mission (LDCM) olarak bilinmektedir. Bu uydunun çeşitli görüntüler elde edilmesini sağlayan çeşitli sensörler vardır. Bu sensörler; Operasyon Arazi Görüntüleyici (OLI) ve Termal Kızılötesi Sensör (TIRS) leri kullanılmaktadır (Roy vd., 2014).

Operasyon Arazi Görüntüleyici (OLI); Landsat 8 uydusunun en önemli sensördür. Yüksek çözünürlüklü görüntüler elde etmek amacıyla tasarlanmıştır. OLI dokuz spektral banttan oluşmaktadır. Çizelge 3.1’de gösterilmektedir (Anejionu vd., 2014).

Çizelge 3.1. Landsat 8 uydusu OLI bant aralıkları ve özellikleri

Bant Numarası	Merkez Dalga Boyu (nm)	Bant Genişliği (nm)	Açıklama
1	433-453	20	Görünür Yeşil
2	450-515	60	Görünür Mavi
3	525-600	75	Görünür Kırmızı
4	630-680	50	Kızılötesi Kırmızı
5	845-885	40	Kızılötesi Kırmızı
6	1560-1660	100	Kızılötesi Kısa Dalga
7	2110-2290	180	Kızılötesi Orta Dalga
8	500-680	180	Pankromatik
9	1360-1390	30	Kızılötesi Su Buharı

Termal Kızılötesi Sensör (TIRS); Landsat 8 uydusunun ikincil sensörüdür. Bu sensör termal kızılötesi bantlarındaki verileri toplamaktadır. İki termal kızılötesi banda sahiptir ve yüzey sıcaklıklarını ölçmek için kullanılmaktadır.

Landsat 8 uydusu güneşe bağlı senkronize bir yörüngede dolaşmaktadır. Yeryüzündeki her bir periyodunu 16 günde tamamlamaktadır. Landsat 8 uydusu dünya yüzeyindeki farklı bölgeleri kapsayacak şekilde görüntüler çekerek veri toplar ve hafıza birimine kaydetmektedir. Topladıkları bu veriler yüksek çözünürlüklü ve spektral görüntülerdir. Daha sonra verileri dünya üzerindeki uydu istasyonlarına aktarmaktadır ve daha sonra görüntülere ön veri işleme yapılmaktadır.

Burdaki amaç görüntüler düzeltilip, spektral kalibrasyon ayarlarının yapılıp kullanıcılar için yüksek kaliteli hazır veri elde edilebilmesi amacıyla çalışılmaktadır (Iron, Dwyer ve Barsi, 2012).

Toplanan bu veriler USGS tarafından işlenerek ücretsiz olarak herkese açık erişimli bir şekilde sunulmaktadır. Bu veri arşivlerini bilim insanları, araştırmacılar tarafından çoğunlukla kullanılmaktadır. Verilere erişim USGS EarthExplorer veya GloVis gibi çevrimiçi erişim sağlanabilen araçlar yardımıyla kullanılarak sağlanır. USGS nin sağlamış olduğu veri arşivi geçmişten günümüze kadar geniş bir koleksiyon içermektedir. Verilerin uzun vadeli bir şekilde tutulması sayesinde uzun vadeli analizler ve değişikliklerin izlenebilirliği sağlanabilmektedir.

Landsat 8 uydusunda elde edilen görüntü verileri birçok farklı uygulama alanlarında kullanılmaktadır. Bu kullanım alanları şu şekilde sınıflandırarak açıklanmaktadır.

- Tarım alanlarında kullanımı: Tarım alanlarının izlenilmesi ve yönetiminde önemli bir araçtır. Uydudaki sensörler sayesinde bitki sağlığı ve büyümesi hakkında değerlendirebilmek için bitkilerin aktif radyasyonunu fotosentetik olarak ölçülmesini sağlamaktadır. Bu ölçümler sayesinde tarım arazilerindeki bitkilerde meydana gelen hastalıkları, bitkinin stresini, sulama ihtiyacını ve hasat zamanlanması gibi çeşitli faktörlerin takibini anlamamızda yardımcı olmaktadır. Buna ek olarak arazi ve tarım parsellerin belirlenmesini ve izlenmesini sağlamaktadır (Loveland ve Dwyer, 2012).
- Ormancılık yönetimi ve orman alanları izleminde kullanımı: Ormanlık alanların büyüklüğünü, yoğunluğunu ve değişimlerini izleyebilmek için yüksek çözünürlüklü görüntü verileri sağlamaktadır. Bu veriler ormancılık yönetimi ve sürdürülebilirliği açısından temel bilgileri sağlar. Aynı zamanda ormanların tahrip edilen ve yanan alanların belirlenmesinde veri sağlamaktadır (Lehman vd., 2013).

- Su kaynaklarının yönetimi ve su kalitesinin izlenmesi: Landsat 8 uydusu su yüzeylerini, göllerin, nehirlerin ve barajların durumlarını gözlemleme olanağı sağlamaktadır. Elde edilen veriler su kaynaklarındaki değişimi, hacmini, su düzeylerinde ve kuruklağın etkilerini izlemek için kullanılmaktadır. Bu özelliklerine ek olarak su kalitesinin değerlendirilebilmesi için su renkleri, çökelme düzeyleri ve kirlilik izlerini belirlemek için spektral veriler kullanılmaktadır (Williams, 2006).
- Çevresel değişiklikler ve doğal afetleri takibi: Uydudan elde edilen görüntülerle toprak erozyonu, kıyı erozyonu, volkanik faaliyetler, buzullarda meydana gelen erimeler, doğada meydana gelen değişimleri ve çevresel faktörleri takip edilebilmesi için kullanılmaktadır. Aynı zamanda Orman yangını, sel , deprem ve kasırga gibi doğal afetlerin izlenebilmesi için de kullanılması tercih edilmektedir. Bu veriler erken uyarı tahmin sistemleri geliştirilmesine, risk analizi ve afet yönetimi için önemli bilgi kaynağı olarak kullanılmasını sağlamaktadır (Oppenheimer, 1991).

3.1.1. Landsat 8 uydusunun avantajları

Landsat programı 1972 yılından itibaren uzun süreli veri sürekliliği sağlamaktadır. Bu sayede zamana dayalı değişikliklerin izlenebilmesi ve analiz edilebilmesi açısından büyük bir fırsat sağlamaktadır. 30 metrelik yüksek çözünürlüğü sayesinde yüzeysel alanları detaylı ve hassas bir şekilde görüntülenebilmesine imkân sunmaktadır. Ayrıca 11 spektral banda sahip olmasından dolayı kapsamlı analizler yapılabilmektedir (Zhu vd., 2012; Thome vd., 2011). Bu sayede tarım, ormancılık, su kaynakları ve çevresel değişiklikler hakkında veriler toplanabilmektedir. Landsat 8 tarafından toplanan veriler açık erişim imkânı sağlamasından dolayı diğer uydulara göre kullanıcılara avantaj sağlamaktadır.

3.2. USGS Earth Explorer

Amerika Birleşik Devletleri Jeolojik Araştırması (USGS) Amerika Birleşik Devletleri federal hükümetine bağlı olan bilimsel bir araştırma ajansıdır (Frankel vd., 2000). Doğal kaynakların yönetilmesi, deprem, volkanik faaliyetler, coğrafi ve biyolojik bilimler sistemleri gibi konularda hizmet ve araştırma sunmaktadırlar (Clark vd., 2003).

Temel görevleri ise şu şekildedir (Interface ve Documentation, 2000);

- Jeolojik ve Doğal Kaynak Araştırmaları; USGS, hidroloji, mineral, enerji, jeoloji ve diğer doğal kaynaklar alanlarında araştırmalar yapmaktadırlar. Bu araştırmalar madencilik, petrol ve gaz endüstrisinde ayrıca su ve çevresel kaynakların sürdürülebilirliği ve yönetimi alanlarında da bilgi sağlamaktadır.
- Deprem ve Volkan Araştırmaları; Doğal tehlikeler, deprem, volkanik ve yer kabuğundaki etkinliği hakkında çalışma yapmaktadırlar. Bu çalışmalarda deprem tahminleri, volkanik hareketlilik izleme, afetlere karşı önlem ve risk değerlendirmesi gibi konularda bilgilendirme ve koruma önlemlerinin geliştirilmesinde yardımcı olmaktadır.
- Coğrafi Bilgi Sistemleri (CBS); CBS teknolojileri kullanılarak verilerin toplanması sağlanır ve analizler yapılarak çalışmalar yayınlanmaktadır. Coğrafi bilgi sistemleri haritalama, arazi kullanımın planlanması, afet müdahale ve çevresel analizler gibi birçok farklı alanda kullanılmaktadır. USGS bu yapılan çalışmalar alanında veri tabanları, haritalar ve coğrafi bilgiler sağlayıp, sunmaktadır.
- Biyolojik Bilimler; USGS, habitat yönetimi, çevresel faktörler ve ekosistemler üzerine çalışmalarını yürütmektedirler. Çalışmalarında amaç ise ekosistemin korunması, türlerin izlenmesi, iyileştirme sağlanarak doğanın sürekliliğinin sağlanmasıdır.

USGS, sadece bilimsel arařtırmalar için deęil aynı zamanda herkese açık erişim imkânı sunmaktadır. Toplanan veriler veri tabanında depolanılarak, arařtırmacılar, mühendisler, hükümet kurumları ve çalışma yapan herkes tarafından kullanılabilir (Faundeen vd., 2002). Bu veriler sayesinde iklim deęişikliği, afet riskleri, arazi ve doğal kaynakların kullanımı gibi birçok konuda analiz etme ve karar verme süreçlerine yardımcı olmaktadır.


3.2.1. USGS earth explorer tarafından Landsat 8 verilerine erişim

USGS Earth Explorer tarafından Landsat 8 görüntülerine erişim ücretsiz ve herkese sağlanmaktadır. Bu görüntülere erişimin sağlanması için Şekil 3.1’de gösterildiği gibi USGS’ nin web arayüzünden erişim sağlanmaktadır. Landsat 8 verilerinin indirilebilmesi yapılması gereken adımlar şunlardır;

- USGS EarthExplorer'a Erişim: İnternet tarayıcınızda USGS EarthExplorer'a gidilmesi gerekmektedir.
- Hesap Oluşturularak veya Oturum Açma kısmından: USGS EarthExplorer'a erişmek için bir hesap oluşturmanız veya mevcut bir hesabınıza giriş yapmanız gerekecektir.
- Alan Seçimi: Üst menüde "Araştırma Alanını Seç" düğmesine tıklandıktan sonra istenilen bölgeyi harita üzerinden seçilebilmektedir. Alan belirledikten sonra, "Alan Seçimi" düğmesine tıklanması gerekmektedir.
- Veri Seti Seçimi: Sol taraftaki menüde "Veri Setleri" sekmesinden "Landsat" başlığı altında "Landsat 8 OLI/TIRS" seçeneğini seçilmeli ve üzerine tıklanmalıdır.
- Zaman Aralığı ve Bulut Örtüsü Ayarları: İndirmek istediğiniz verilerin zaman aralığını ve maksimum kabul edilebilir bulut örtüsü yüzdesini belirlenmesi gerekmektedir.. Daha sonra istenilen zaman ve tarih

aralığından verilerin bulutluluk düzeyine göre filtreleme yapmanızı sağlamaktadır.

- **Ön izleme ve Seçenekler:** Veri seti seçildikten sonra, ön izleme penceresi açılacaktır. Açılan sayfada veri setinin ön izlemesi görüntülenmektedir. Daha sonra istenilen bölgedeki verinin indirme seçeneklerini belirlemek için sağ üst köşedeki "Veri İndir" düğmesine tıklanılması gerekmektedir.
- **İndirme Seçenekleri:** Burada, indirmek istediğiniz bantları, formatı, koordinat sistemini ve diğer özellikleri belirlenebilmektedir.
- **İndirme İşleminin Tamamlanması:** istenilen verilerin indirme işlemi tamamlandığında, USGS EarthExplorer size bir indirme bağlantısı sağlayacak veya indirme işlemi tamamlandığında bildirim gönderecektir.



Şekil 3.2. Landsat 8 verilerinin indirilmesi için USGS web arayüzü (USGS, 2023)

3.3. Uydu Görüntülerin İşlenmesinde Kullanılan Yöntemler

3.3.1. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI)

Bu bölümde orman yangınlarını derin öğrenme yöntemleriyle tahmin etmek için veri setine eklenen, bitki örtüsünün varlığı, yoğunluğu ve durumu hakkında bilgi edinmek için eklediğimiz NDVI uzaktan algılama indeksi tanımlanmıştır.

Normalleştirilmiş fark bitki örtüsü indeksi (NDVI) bitki örtüsünün yoğunluğu ve sağlığını ölçmek için geliştirilen uzaktan algılama indeksidir (Benek ve Şahap, 2017). NDVI ilk olarak 1970'li yılların sonlarında Jordan (1969) ve Pearson (1970) gibi araştırmacılar tarafından bitki örtüsünün miktarının ölçülmesinde yakın kızılötesi ve kırmızı bantlardaki yansıma oranının kullanılmasının başarılı olduğunu çalışmalarında göstermişlerdir. Bu NDVI indeksi, bitki örtüsünün fotosentetik olarak yaprakların aktif yeşil ve yakın kızılötesi spektrumlarından gelen yansımaların farkını hesaplamak için kullanılmaktadır (Perry ve Lautenschlager, 1984).

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3.1)$$

Bu formülde;

- NIR (Near Infrared / Yakın Kızılötesi): Bitki örtüsü tarafından yansıtılan veya saçılan yakın kızılötesi ışınları temsil etmektedir.
- RED (RED / Kırmızı): Bitki örtüsü tarafından yansıtılan veya saçılan kırmızı ışınları temsil etmektedir.

Öncelikle NIR ve RED bantlarının yansıma değerlerinin farkı alınır. Daha sonra bitki örtüsünün yansıttığı kızılötesi ışınlarının yoğunluğunu ve bitki tarafından saçılan kırmızı ışınların yoğunluğu karşılaştırılır. Bu fark değeri NIR ve RED bantlarındaki yansıma değerlerinin toplamına bölünmektedir.

Landsat 8 uydu görüntülerinde NDVI hesaplamasını elde edebilmek için bant 5 (NIR) ve bant 4 (RED) kullanılması gerekmektedir. Daha sonra bu farkı bant 5 ve bant 4'ün toplamına bölünür. Bu işlem sonucunda ise çıkan değer bitki örtüsünün miktarının ölçüsünü hesaplayıp, elde etmemizi sağlamaktadır.

NDVI analizinde çıkan sonuçlar genellikle -1 ve +1 arasında ölçeklendirilmiştir. Bu ölçekler ve aralık değerleri yapılan çalışmaya göre istenilen aralıkta ayarlanabilmektedir. (Hatfield vd., 1985).

NDVI deęer aralıkları řu řekilde yorumlanabilir;

- -1 ile 0: Genellikle su veya kar gibi dūřuk bitki rts yoęunluęunu temsil etmektedir.
- 0 ile 0.1: Bu aralıktaki deęerler genellikle aık alanları, kısmi bitki rts veya karmařık arazi kořullarını temsil etmektedir. Bu deęerler, bitki rts olmayan alanlar veya bitki rts ok dūřuk yoęunlukta olduęunda gstermektedir.
- 0.1 ile 0.3: Bu aralıktaki deęerler, ılıman blgelerdeki tipik bitki rts yoęunluęunu temsil etmektedir. Ormanlar, tarım alanları veya doęal otlaklar gibi orta dzeyde yoęun bitki rts ieren alanların hasarlı veya saęlıksız bitki rtsnn varlıęını temsil etmektedir.
- 0.3 ile 0.6: Bu aralıktaki deęerler, yksek bitki rts yoęunluęunu temsil etmektedir. Genellikle ormanlar, yaęmur ormanları veya yoęun tarım alanları gibi alanlarda grlmekte olup, saęlıklı ve yoęun bitki rtsn gstermektedir.
- 0.6 ile 1: Bu aralıktaki deęerler genellikle yaprakların ok yoęun olduęu veya ok kalın bitki rtsne iřaret edebilir. Bu tr alanlar, ormanlarda yoęun yapraklı aęaların bulunduęu blgelerde veya tropikal yaęmur ormanlarında gstermektedir.

NDVI deęerleri, bitki rtsnn izlenmesi, su kaynakları ynetimi, evre deęiřikliklerinin izlenilmesi ve iklim deęiřiklięi analizi gibi birok alanda kullanılmaktadır. Bu deęerler, bitki rts saęlıęı, byme potansiyeli ve bitki rtsnn evresel etkileri hakkında bilgi saęlamaktadır (Yıldız vd., 2012).

3.3.2. Kara yüzey sıcaklığı (LST)

Kara yüzey sıcaklığı (LST - Land Surface Temperature), Dünya'nın kara yüzeyinin sıcaklık durumunu ifade eden bir ölçümdür. Bu ölçüm, uzaktan algılama teknikleriyle elde edilen veriler kullanılarak hesaplanmaktadır (Butuc ve Moldovean, 2012).

LST, atmosferden etkilenmeden sadece yeryüzünün sıcaklık durumunu gösterir. Uydu tabanlı LST ölçümleri, 1970'lerden itibaren çeşitli uydu görevleriyle gerçekleştirilmeye başlanmıştır. Bu görevler, farklı dalga boylarında (kızılötesi, termal) sensörler kullanarak yüzey sıcaklığı verilerini elde etmek için tasarlanmıştır (Sobrino vd., 2004).

LST verileri, termal görüntülerin işlenmesi ve analiziyle elde edilir. Birçok farklı yöntem ve algoritma kullanılarak LST hesaplanabilir, ancak genellikle yaygın olarak kullanılan bir formül vardır. Bu formül, ışıyım dengesi prensibine dayanmaktadır (Markham and Barker, 1986; Thome vd., 1997).

$$L_{\lambda} = \frac{L_{MAX} - L_{MIN}}{QCAL_{MAX} - QCAL_{MIN}} (DN - QCAL_{MIN}) + L_{MIN} \quad (3.2)$$

Burada Landsat TM/ETM termal sensörlerden aldığı sinyallerin sayısal değerlerle temsil edilmektedir. Bu sayısal değerler sensörler tarafından ölçülen yansıma veya atmosfer üstü (TOA) birimlerine dönüştürmek için kullanılmaktadır.

L_{λ} : Bu değer, sensörün açıklığındaki spektral yansımayı temsil etmektedir.

$QCAL_{MAX}$: Sayısal değerlerdeki yansımanın en yüksek noktasını temsil etmektedir. Ölçeklenmiş yansıma değerleri DN cinsinden ifade edilmektedir.

$QCAL_{MIN}$: Sayısal değerlerdeki yansımanın en düşük noktasını temsil etmektedir. Ölçeklenmiş yansıma değerleri DN cinsinden ifade edilmektedir.

L_{MAX} : Bu değer, $QCAL_{MAX}$ 'a ölçeklenen TOA yansımısını temsil etmektedir.

L_{MIN} : Bu değer, $QCAL_{MIN}$ 'e ölçeklenen TOA yansımısını temsil etmektedir (Chavez, 1996).

$$P_p = \frac{\pi * (L_\lambda - L_h) * d^2}{SUN_\lambda * \cos \theta_s * \tau} \quad (3.3)$$

Bu parametreler, atmosferik etkilerin düzeltilmesi için kullanılan bir modelin bileşenlerini temsil etmektedir. P_p , yeryüzünden yansıyan elektromanyetik ışığın atmosferdeki etkileşimlerden arındırılmış gezegen yansımısını ifade eder.

L_λ , sensör tarafından ölçülen spektral yansımayı temsil etmektedir. L_h , atmosfer bileşenlerinin neden olduğu yansımayı temsil etmektedir. d , Dünya ile Güneş arasındaki ortalama mesafeyi ifade etmektedir. SUN_λ , Güneşin atmosfer dışı ışıyım miktarını belirtir. θ_s , Güneşin geniş açısını temsil etmektedir ve atmosferik iletkenliliği olan τ ile birlikte kullanılmaktadır (Chavez, 1996).

$$L_h = L_m - L_{1\%} \quad (3.4)$$

Bu değerler, Landsat görüntülerinin kalibrasyonu ve atmosferik düzeltilmesi için kullanılır. L_m , karanlık nesnelerin yansıma değerini temsil ederken, $L_{1\%}$ teorik değer yüzde biridir ve referans değeri olarak kullanılmaktadır. Bu referans değeri, Landsat görüntülerinin atmosferik etkilerden arındırılması ve kalibrasyonu için önemlidir. Karanlık nesnenin yansımısını bilerek, diğer nesnelerin yansıma değerleri doğru bir şekilde hesaplanabilir ve görüntülerin karşılaştırılabilirliği ve analizi artırmaktadır.

$$L_m = L_{min} + DN_{min} \left(\frac{L_{MAX} - L_{MIN}}{QCAL_{MAX}} \right) \quad (3.5)$$

Bu ifade, karanlık bir nesnenin sayısal değerine karşılık gelen yansımayı (L_m) hesaplamak için kullanılan bir formüldür.

$$\varepsilon = 0.004 * Pv + 0.986 \quad (3.6)$$

ε , yüzey yayılımını temsil eder ve yüzeyin ışınmı emme yeteneğini ifade etmektedir (Sobrino vd., 2004).

$$P_v = \left(\frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \right)^2 \quad (3.7)$$

Bu denklem, NDVI değerlerine dayalı olarak bitki örtüsü yüzdesini (P_v) hesaplamak için kullanılmaktadır. Bu şekilde, NDVI değerlerini kullanarak bitki örtüsü yüzdesini tahmin etmek, arazi kullanımı analizleri, bitki büyüme izleme, değerlendirmeleri gibi uygulamalarda önemli bir rol oynamaktadır (Carlson ve Ripley, 1997).

$$L_T = \frac{L_\lambda - L_\mu \tau (1 - \varepsilon) * L_d}{\tau * \varepsilon} \quad (3.8)$$

Bu denklem, kinetik sıcaklığı τ 'ye sahip bir siyah cismin yaydığı radyans L_T ile temsil etmektedir (Barsi vd., 2005).

$$T = \frac{K_2}{\ln\left(\frac{K_1}{L_T} + 1\right)} \quad (3.9)$$

Bu denklemde kullanılan değişkenler önceden belirlenen kalibrasyon sabitleri (K_1 ve K_2), enstrüman kalibrasyon sürecinde belirlenen spesifik parametrelerdir. Belirtilen K_2 belirsizlik, özellikle açık atmosfer koşullarında, elde edilen yüzey sıcaklığının olası hata payını gösterir (Chander and Markham, 2003).

3.4. Verilerin Tahmininde Kullanılan Derin Öğrenme Yöntemleri

Rosenblatt (1957) ve diğerleri 1950'li yılların sonlarına doğru insan zekâsı gibi hesaplama yapabilecek ve sistemlerin hesaplama zekâsını geliştirmek için çalışmışlardır. Rosenblatt'ın ileri sürdüğü "perceptron" sistemlerde hesaplama yapabilecek zekânın temellerini sağlamıştır. Perceptron, çok katmanlı derin

öğrenme ağlarının temelidir ve Derin Öğrenme kavramının çıkışını sağlamıştır. Son zamanlarda derin öğrenme dünya üzerinden gerçek veri setleri oluşturularak karmaşık yapıları öğrenmek için kullanılan bir bilim dalıdır. Derin öğrenme, makine öğrenmesinin bir alt dalıdır. Kavramın ortaya çıkmasının sebebi ise makine öğrenme mekanizmalarının, sadece verileri ham haliyle işleme yeteneğine sahip olmasıdır. Bundan dolayı özellik çıkarıcı oluşturmak için uzun süren çalışmalar sonucunda derin öğrenme kavramı ortaya çıkmıştır. Bu kavram çok katmanlı, insan beynine benzeyen bir şekilde giriş ve çıkışları bulunan sinir ağlarından oluşmaktadır. Derin öğrenme, geri yayılım algoritmasını kullanarak, makinelerin her katmanda bir önceki katmandan çıktıyı doğru bir şekilde hesaplamak için parametrelerin hangi oranda değişmesi gerektiğini belirlemektedir. Veri girişine yakın olan alt katmanlarda özellikleri basit olanları öğrenirken, üst katmanlarda ise daha karmaşık özelliklere sahip olan verileri öğrenmektedir.

Derin öğrenmenin en önemli özelliklerden biri ise, insanlar tarafından öğretilip tasarlanmadığı halde kendi başına öğrenme prosedürü ile otomatik olarak öğrenmesidir (Bengio, 2009). Bundan dolayı derin öğrenme diğer yapay zeka teknolojilerinde makine öğrenmesi gibi kavramlardan daha önemli başarılar sağlamıştır (Chen, Xu, He ve Wang, 2017).

Derin öğrenme modelinin kullanıldığı birçok farklı kullanım alanında kullanılmaktadır. Bu alanlar tekrarlayan ağlar, konuşmacıdan bağımsız konuşma tanıma, el yazısı tanıma, derin inanç ağları, otomatik kodlayıcılar, nesne sınıflandırma, yüksek düzeyde özellik algılayıcıları, model optimizasyonu, imageNet, insan tanıma, dil ve görsel veri arasında ara model ilişkisi gibi daha birçok farklı kullanım alanı bulunmaktadır.

3.4.1. Konvolüsyonel sinir ağı (CNN)

Derin öğrenme yöntemlerinden olan konvolüsyonel sinir ağı (CNN), görsel verilerin analizinin yapılması ve işlenmesi için özel olarak tasarlanmış bir sinir ağı türüdür (Makantasis, 2015). CNN'ler nesne algılama, yüz tanıma, görüntü

tanıma ve segmentasyon gibi görsel işleme ve analizlerinde başarılı bir şekilde sonuç elde edilmektedir. CNN'ler özellikle görüntüler üzerine çalışırken konvolüsyon yöntemini kullanmaktadır. CNN'ler konvolüsyon katmanlarından sonra aktivasyon fonksiyonu, havuzlama (pooling) ve tam bağlantı katmanlarından oluşan bir yapıya sahiptir (Krizhevsky, 2017).

Aktivasyon fonksiyonları, çıktı ve eşik değerlerine göre sınırlayarak sinir ağının daha karmaşık özellikleri öğrenmesini sağlamaktadır. Havuzlama katmanı, haritaların özellikle boyutunu küçültmek ve özelliklerin ölçeklendirilmesini sağlamak için kullanılmaktadır (Guisti vd., 2013). Havuzlama katmanları sinir ağının hesaplamasını kolaylaştırmaktadır. Sinir ağının aşırı öğrenmesini veya uydurmasını engellemektedir. Havuzlama katmanı; maksimum havuzlama ve ortalama havuzlama diye iki türe ayrılmaktadır. Havuzlama katmanı performansı iyileştirirken aynı zamanda boyut azaltma, ölçek değişmezliği ve enformasyon koruma avantajlarına sahiptir (Guisti vd., 2013).

Ölçek değişmezliği, bir nesnenin farklı boyutlara sahip görüntülediği zamanlarda, özdeş özellikleri tanımlayabilir ve ölçek değişikliklerine karşı değişmezlik sağlamaktadır. Bu sayede görüntüler farklı boyut ve ölçeklerde olsa bile sinir ağının tutarlı sonuçlar elde etmesini sağlamaktadır.

Enformasyon koruma, işlenen verilerin önemli özelliklerinin bazı kısımlarının genel özetini alır ve bilgilerin korunmasını sağlamaktadır. Bu sayede değişikliklere karşı önlem alarak gerekli olmayan ayrıntılara karşı hassasiyetini azaltmasını sağlamaktadır (Ji vd., 2012).

Tam bağlantı katmanı, sinir ağının sonunda yer alan bir katmandır. Bu katman her bir özellik haritasındaki her bir nörona tam bağlantılı bir ağ yapısına sahiptir. Her nöronun bütün özelliklerini değerlendirerek çıktı üretmesini sağlamaktadır. Tam bağlantı katmanı girdileri düzleştirilmiş özellik vektörünü kullanarak sınıflandırma işlemini gerçekleştirmektedir. Bu işlem sayesinde görüntünün hangi sınıfa ait olduğu tahmin edilebilmektedir. Tam bağlantı katmanındaki aktivasyon fonksiyonu doğrusal olmayan analiz kullanılarak sınıflandırma işlemi

yapmaktadır. Bu fonksiyon sayesinde tam bağlantı katmanındaki çıktılar, sınırlar ve daha karmaşık esnek karar sınırları oluşturabilmektedir. Tam bağlantı katmanında yaygın olarak kullanılan aktivasyon fonksiyonları ise; sigmoid fonksiyonu, düzleştirilmiş doğrusal birimi (RELU) ve hiperbolik teğet (Tanh) fonksiyonlarıdır (Sharma vd., 2017).

$$f(x) = \sigma(x) = \frac{1}{1 + \exp(-x)} \quad (3.10)$$

Sigmoid fonksiyonu, herhangi bir sayı değerini 0 ile 1 arasında değere dönüştürmektedir. Bu fonksiyon özellikler çoklu sınıflandırma işlemlerinde kullanılmaktadır (Sharma vd., 2017).

$$f(x) = (x)^+ = \max(0, x) \quad (3.11)$$

RELU fonksiyonu ise derin öğrenme modellerinde en çok kullanılan bir aktivasyon fonksiyonudur. Pozitif değerleri doğrusal değere dönüştürürken aynı zamanda negatif değerleri 0'a eşitlemektedir (Nwankpa vd., 2017).

$$\tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (3.12)$$

Tanh fonksiyonu, gerçek sayı değerlerini -1 ile 1 arasındaki değerlere dönüştürmektedir. Bu fonksiyon regresyon ve sınıflandırma problemlerinde kullanılmaktadır (Nwankpa vd., 2017).

Sinir ağları eğitimi bu fonksiyonları kullanılarak üç farklı şekilde gerçekleştirmektedir. İleri yayılım, geri yayılım ve ağırlık güncelleme işlemleridir. İleri yayılımda girdi verisi CNN'in ilk konvolüsyon katmanında eğitilir. Giriş verisinin haritalanması çıkarılmaktadır. Çıkan özellik haritaları aktivasyon fonksiyonunda işlemi yapılır. Daha sonra havuzlama katmanında işlem gördükten sonra bir sonraki çıktıya yönlendirmektedir (Ma, 2015).

Geri yayılım işleminde ilk başta giriş yapılan veriler ileri yayılım ile hesaplanır daha sonra çıktı alınarak hata hesaplama işlemi yapılmaktadır. Hata, çıktı katmanındaki her bir nöronun değeri ve hedef çıktının değeri arasındaki farkı temsil eden bir vektördür. Daha sonra hata vektöründen geriye doğru zincir kuralı kullanılarak iletimi sağlanır. Bu işlem, her bir ağırlığa katkıda bulunan nöronların çıktılarına göre hesaplanmaktadır (Zhang, 2017). Ağdaki her bir ağırlığın hatası ve katkısı belirlenmektedir. Geri yayılım sonucunda elde edilen her bir ağırlığın hata türevi elde edilir. Türevleri alınarak gradient yöntemiyle güncelenir. Yani hata öğrenme oranına bağlı olarak azaltılır ve artırılması sağlanmaktadır. Bu işlemler her bir ağırlığın eğitilmesi süresi boyunca tekrar etmektedir. Bu sayede hedef çıktılara daha yakın ve doğru oranı yüksek tahminler yapabilmektedir.

Ağırlık güncelleme işlemi aslında geri yayılım işleminin bir parçasıdır. Ağdaki hata miktarını azaltır ve üretilmek istenen çıktı değerlerinin ağırlıklarını hesaplamaktadır.

3.4.2. Uzun kısa süreli bellek sinir ağı (LSTM)

Uzun kısa süreli bellek sinir ağı (LSTM) derin öğrenme algoritmalarından olan özyinelemeli bir yapay sinir ağıdır. LSTM özellikle zamansal uzun ve bağımlılıkları olan veri dizilerini analiz etmek için kullanılmaktadır. LSTM diğer yapay sinir ağlarına göre daha karmaşık bir yapıya sahiptir (Zhang vd., 2019). LSTM, önceki girdi ve çıktıları hatırlayarak uzun süreli bağımlılıkları tespit eden bir hafıza mekanizmasına sahiptir. LSTM'nin ana bileşenleri hücre durumu, unutma kapısı, giriş kapısı, çıkış kapısı bileşine sahiptir. Bu bileşenler şu formüllerle hesaplanmaktadır (Hochreiter ve Schmidhuber, 1997);

$$f_t = \sigma_9(w_f \times x_t + U_f \times h_{t-1} + b_f) \quad (3.13)$$

f_t , unutma kapısının hesaplanmasını sağlayan formüldür. Geçmişten gelen verilerden hangilerinin tutulacağına karar vermektedir.

$$i_t = \sigma(w_i \times x_t + u_i \times h_{t-1} + b_i) \quad (3.14)$$

i_t , giriş kapısının hesaplanma formülüdür. Geçerli zamanda ne kadar yeni bilgilerin alınacağını kontrol etmektedir. Yeni bilgilerden ne kadarının hafızaya kaydedileceğini belirlemektedir. σ , Sigmoid fonksiyonu, değerleri 0 ile 1 arasına sıkıştırarak aktivasyon işlemi için kullanılmaktadır. Bu formülde ağırlık matrisleri “w” ile biasları ise “b” ile gösterilmektedir (Gers vd., 2000).

$$o_t = \sigma(w_o \times x_t + u_o \times h_{t-1} + b_o) \quad (3.15)$$

o_t , çıkış kapısının hesaplandığı kısımdır. Burada mevcut durumdaki gizli durum ne kadarının çıkışa yönlendirileceğini belirlemektedir (Graves, 2013, Greff vd., 2017).

$$\hat{c}_t = \sigma(w_c \times x_t + u_c \times h_{t-1} + b_c) \quad (3.16)$$

$\hat{c}_t$, iç durum adaydır yani yeni giriş bilgisinin hafızaya eklenmeden önce ne kadar önemli olduğunu belirlemektedir.

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \hat{c}_t \quad (3.17)$$

c_t , iç durumdur. Burada geçmiş adımdan gelen hafızanın ne kadarının korunacağını ve yeni bilgilerinin kaçının hafızaya kaydedileceğini belirlemektedir.

$$h_t = o_t \cdot \sigma(c_t) \quad (3.18)$$

h_t , gizli durumdur. Bu adımda gelen bilgi dışarıya çıkışı yapılır. LSTM'nin son hücre çıkışıdır.

LSTM'nin ağlarında kullanılan bu bileşenler sayesinde bağımlılıkları olan ardışık modellerle ilgi birçok problemin çözümünü sağlamaktadır.

Bu özellikleri sayesinde dil işleme, metin analizi, konuşma tanıma ve zaman serisi gibi çeşitli alanların tahmininde başarılıdır.

3.5. Makine Öğrenmesi

Makine öğrenmesi, programların belirlenen görevlerini yerine getirmek için veri ve deneyimlerinden öğrenme yeteneği kazanmasını sağlamak için çalışılan bir yapay zekâ dalıdır. Makine öğrenmesi yöntemi algoritmaların veriler üzerinde analizler yaparak gelecekteki olayların tahmin etmesini sağlamaktadır. Makine öğrenmesi algoritmaları üç ana kategoriye ayrılmaktadır. Bunlar güdümsüz, güdümlü ve yarı güdümlü öğrenme olmak üzere sınıflandırılmaktadır.

Güdümsüz öğrenme, etiketlenmemiş veriye göre desenleri ve yapılarda gizli ilişkileri keşfetmeyi amaçlamaktadır. Veri setindeki yapıları tanımlamak için kullanılmaktadır.

Güdümlü öğrenme, etiketli verilerle öğrenme yöntemidir yani; bir ajanın belirli bir ortamda bir görevi yerine getirirken deneyimlerine göre öğrenmesini içermektedir. Ajan, çevresiyle etkileşim halindeyken, doğru veya yanlış geri bildirimler alır ve bu geri bildirimlere göre en iyi eylemleri seçmeyi öğretir.

Yarı güdümlü öğrenme, algoritma, veri setindeki etiketli veya etiketlenmemiş verilerle işlem yapılarak eğitilmektedir. Etiketlenmiş verileri doğru tahmin edebilir, etiketlenmemiş verileri ise giriş yapılan verilerin benzerliklerini ve yoğunluklarının öğrenilmesini sağlamaktadır.

Makine öğrenmesi, veri sorunlarını çözmek için birçok farklı algoritma içermektedir.

Yaygın olarak kullanılan bazı algoritmalar şunlardır;

- Karar Ağaçları (Decision Trees)
- Destek Vektör Makineleri (Support Vector Machines)

- Doğrusal Regresyon (Linear Regression)
- Lojistik Regresyon (Logistic Regression)
- K-En Yakın Komşu (K-Nearest Neighbors)
- K-Means Kümeleme (K-Means Clustering)
- Yapay Sinir Ağları (Artificial Neural Networks)
- Rastgele Ormanlar (Random Forests)
- Derin Öğrenme (Deep Learning)

Bu algoritmalarından hangisinin kullanılacağı, problemin türüne, veri setinin özelliklerine ve çözülmek istenen sorunun gereksinimlerine göre değişmektedir.

3.5.1. Random forest (RF)

Random forest algoritması makine öğrenmesi yöntemlerinden karar ağacı ailesine, algoritmasına aittir. RF yöntemi genellikle regresyon problemleri ve sınıflandırma yapmak için kullanılmaktadır. Karar ağacı modeli gibi ağaç yapısıyla temsil edilmektedir. Ağaca ait her bir düğüm ve girdi verisindeki bir değeri temsil etmektedir. Her bir dal karar noktasını ve yapraklar ise değerini karşılığı olan çıktıyı temsil etmektedir (Breiman, 2001).


Karar ağaçları kolay oluşturulup uygulanabilmektedir. Ancak, karar ağaçları yeni verilere uyarlandıklarında güvenlik eksikliği göstermektedirler. Bunun nedeni ise tüm örnekleri eğitim setinde tamamen uydurma eğiliminde olmalarıdır. Bu karar ağacındaki soruna çözüm ise RF yöntemidir (Lannace vd., 2019). RF’de her ağaç zayıftır çünkü veriye tam erişimleri yoktur. Ancak hepsi bir araya geldiklerinde sınıflandırmada çoğunluk oylaması yapılarak veya regresyonda ortalama alınarak karar verme topluluğu oluştururlar. Bu, ormanda tek başına ağaçların potansiyel hatalarını telafi eder ve modelin gerçek değerlere daha uzak sonuçlar üretme olasılığını azaltır (Peters vd., 2007). RF’lerin birçok uygulaması genellikle 100 ile 500 arasında ağaç boyutları kullanır. Uygulamalarında çok yüksek kaliteye sahip oldukları kanıtlanmıştır.

3.5.2. K-fold apraz doęrulama yntemi (KF)

K-fold apraz doęrulama yntemi, makine ęrenmesi modellerinin eęitimini, doęruluęunu ve performansını deęerlendirmek iin kullanılmakta olan bir yntemdir. Eęitim veri setindeki tm deęerler doęrulama iin kullanılmaktadır. Bu KF yntemi modelin tek bir eęitim ve test blmlenmesine baęlı olarak performansının deęiřebileceęi durumlarda kullanılmaktadır (Tamilarasi vd., 2020). Bu durumun yanı sıra veri setindeki deęiřkenlerin sınıfsal daęılımlarında veya zelliklerindeki tutarsızlık olduęu gibi durumlarda da kullanılabilir olması kolaylık saęlamaktadır. Modelin eęitim verisindeki performansını test verisine baęımlı olmadan da genel bir fikir edinilmesini saęlamaktadır (Wong vd., 2019).

K-fold apraz doęrulama, modelin doęruluęunu, hatasını veya istenilen dięer performans zelliklerini hesaplamak iin kullanılan istatiksel hesaplama yntemidir (Jung vd., 2018). Ayrıca, hiperparametrelerin ayarlanması ve modelin optimizasyon srelerinde de kullanılabilir. K-fold apraz doęrulamayı hesaplama sreci řekil 3.1’de grldę gibi řu ařamalardan gemektedir (Wong vd., 2017);

1. Tm rnekler veri setinin zellik deęerlerine gre artan/azalan sırayla sıralanır.
2. Sıralanmış rnekler i eřit byklkteki alt kmeler $E_1, E_2, \dots, E_i$ olarak blnr.
3. İkinci alt kme E_2 'den bařlayarak, E_2 doęrulama seti olarak belirlenir ve ilk alt kme E_1 eęitim seti olarak belirlenir. E_1 zerinde bir model eęitilir ve E_2 zerinde performansı deęerlendirilir.
4. Sonraki turda, nc alt kme E_3 doęrulama seti olarak belirlenir ve E_3 'ten nceki tm alt kmeler eęitim verisi olarak belirlenir, yani E_1 ve E_2 zerinde bir model eęitilir ve E_3 zerinde performansı deęerlendirilir.
5. Adım 4 tekrarlanır ve E_2 'den E_i 'ye kadar tm alt kmeler deęerlendirilir. Tm modellerin genel performansı hesaplanır.



Şekil 3.3. K-fold algoritması çapraz doğrulama

Kullanılan veri setinin artan veya azalan özellik değerlerine göre sıralanması, modelin hangi tarafta yüksek veya düşük tahmin etmesini beklediğimize bağlıdır. Nispeten büyük bir i değeriyle, eğitim setinin boyutu başlangıçta çok küçük olabilmektedir. Bu sorunun sonuçlarıyla bozulmasını engellemek için minimum bir eğitim veri boyutu belirlenmesi daha iyi sonuçlar elde edilmesini sağlayacaktır (Anguita vd., 2012).

3.6. Orman Yangınları Tahmini için Kullanılan Program ve Kütüphaneler

3.6.1. Python programa dili

Python programlama dili projesi 1990'lı yıllarda Hollanda'da Guido Van Rossum tarafından başlatılmıştır. ABC programlama diline alternatif olarak geliştirilmiştir. Daha sonra python laboratuvarları oluşturuldu ve devamında python yazılım enstitüsü kurularak açık kaynaklı olarak kullanılması için sunulmuştur (Tulchak ve Msrchuk, 2016).

Python, esnek ve basit bir programlama dilidir. Python, genel amaçlı olup, yüksek seviyede dinamik, işlevsel, nesne yönelimli ve yorumlayıcı bir programlama dilidir (Summerfield, 2007). Bu sayede geniş bir uygulama alanına sahiptir .

Yapısal ve nesne yönelimli bir programlama dili olmasından kaynaklı başka programlama dili stillerini de destekleyebilmektedir. Kısaca başka bir dilde yazılan bir programın, python'a modül olarak eklenip kullanılmasına imkân sağlamaktadır (Warsaw vd., 2011).

Python programlama dili herkes tarafından kullanılabilmesi ve anlaşılabilmesi için kolay bir şekilde tasarlanmıştır. Bu dil günümüzde birçok kullanıcı ve programlamayı yeni öğrenmeye başlayanların dostu olarak kabul edilmektedir (O'Grady, 2013). Dünya çapında yıllarca popüler olan Java dilinin yerini almış ve bu özellikleri sayesinde popüler olmuştur. Dinamik ve esnek yazılabilen bir dildir ve ayrıca hatalara karşı hoşgörülüdür.

Bu programlama dili kullanıcılar için birçok avantaja sahiptir. Python'ın çok basit bir söz dizimi vardır bu sayede kolay ve eğlenceli hale getirmektedir. Buradaki amaç programlamada sözcük yazılımına değil, sadece çözümlere odaklanılmasını amaçlamaktadır (Tulchak ve Msrchuk, 2016). Python taşınabilir bir programlama dilidir. Birçok farklı işletim sisteminde kullanılabilir ve herhangi bir değişiklik veya kurulum yapılmasına gerek kalmamaktadır. Python ücretsiz ve herkese açık bir kaynak koduna sahip olmasından dolayı herhangi bir kısıtlama yoktur. Hatta kullanıcılar isterlerse kaynak kodlarını değiştirebilmektedir (Sievert vd., 2019). Python diğer dillerden farklı olarak bellek yönetiminde de çok fazla avantajı vardır. Gerek olmayan bilgilerle ve karmaşık görevlerle uğraştırmaz ve otomatik olarak kodu bilgisayarın anlayacağı dile dönüştürmektedir.

Python nesne yönelimli ve yorumlanabilir bir dil olmasından kaynaklı MATLAB, R programlama gibi yapay zekâ, makine öğrenmesi ve derin öğrenme yöntemlerinde de kullanılmaya başlanmıştır (Pedrogosa vd., 2011). Nesne yönelimli programlaması diğer dillerden daha kolay ve kullanışlıdır. Bunun nedeni ise python programlama dilinin verimliliğini arttırmak için geliştirilirken derlenmiş kodların tasarlanmış olmasından kaynaklanmaktadır.

Hesaplama bilimlerinde için python paralel programlama ve geniş kütüphane özellikleri vardır. Bunlardan bazıları TensorFlow, Pytorch, Keras, NumPy, SciPy

ve Scikit-learn kütüphaneleridir (Raschka ve Mirjalili, 2019). Bu kütüphaneler bilimsel hesaplamalar, lineer cebir, optimizasyon, istatistiksel analiz ve sinyal işleme gibi birçok matematiksel işlemlerde kullanılmaktadır.

3.6.2. Keras kütüphanesi

Keras, python da hızlı bir şekilde modelleme ve verilerin eğitiminin yapılmasını sağlamak için oluşturulan ücretsiz ve açık kaynaklı bir derin öğrenme kütüphanesidir (Lee vd., 2019).

Hızlı deney ve prototip yapılmasını sağlamaktadır. Modellerin analizleri için sadece veriseti hakkında kullanılmak istenilen özel sınıflandırmalara ve analizi için eğitimin tekrar sayılarının belirtilmesi yeterli olmaktadır. Derin öğrenme uygulamasında kod yazım yükümlülüğünün azaltılmasını sağlayarak modellerin uygulanabilirliğini kolaylaştırmaktadır (Moolayil ve Moolayil, 2019).

Keras, bağımsız bir derin öğrenme kütüphanesi değildir. Başka bir kütüphanenin alt yapısını içerisindedir. Kerasın ara yüzü kullanımı da iyi bir şekilde optimize edildiğinden kolaydır. Genişletilmesi için kullanıcılar tarafından özel bloklar yazılabilmektedir. Keras TensorFlow modülü içeriğinde de kullanılabilmektedir (Chico ve Sallow, 2021). Bu sayede TensorFlow içeriğinde yapılacak olan uzun ve karmaşık kodlamaları, birkaç satırda yazılmasına imkân sağlamaktadır ve basit ve tutarlı bir yapı sağlayarak, kullanıcıların işlem sayısını azaltmaktadır (Ramasubramanian, 2019). Ayrıca, hata oluşması durumunda anlaşılabilir ve uygulanabilir geri bildirim sağlayarak, kullanıcı için hataların tespitinde kolaylık sağlaması büyük bir avantajdır.

3.6.3. Pandas kütüphanesi

Pandas, python'a ait açık kaynaklı bir kütüphanedir. Bu kütüphanenin amacı gerçek dünya veri setlerinin tablolu ve zaman serisi verilerini analiz etmek için oluşturulan bir kütüphanedir (McKinney, 2010). Pandas'ın kullanımı basit ve kolaydır, ayrıca yüksek performans sağlamaktadır (McKinney, 2015).

Pandas dataframe nesnelerini etiketleme mantığıyla çalışmaktadır. Bu yüzden her sütun bir isim sınıflandırması yapılmaktadır. Bu isimler üzerinden işlemler yapılabilir.

Kullanıcılar tarafından pandas kütüphanesinin çok sık tercih edilme nedeni ise verileri boolean olarak indeksleme yapabilir ve veri kümelerinde NaN kontrolü yaparak hataların oluşmasını engelleyebilmektedir (Lemenkova, 2019). Aynı zamanda oluşturulan sütunlar döngü kullanılmadan rahat bir şekilde seçme ve gönderme işlemleri yapılabilir.

Kısacası pandas kütüphanesi ile verileri dosyalara yükleme filtreleme, eksikleri doldurma, indeksleme, seçme ve dönüştürme işlemleri yapılabilir (Chen, 2017).

Bu özelliklerinden dolayı pandas kütüphanesi birçok veri bilimi görevlerinde kullanılabilir.

3.6.4. NumPy kütüphanesi

1990'lı yıllarda Jim Hugunin tarafından temeli atılan, zamansal ve sayısal hesaplamaların yapılabilmesini sağlayan bir python kütüphanesidir (Oliphant, 2007)

Aslında açılımı Sayısal (Numerical) Python'dır. Bilimsel ve sayısal hesaplamalar yapmak için çok boyutlu diziler ile çalışmaktadır (NumPy community, 2019). Matematiksel işlemler, trigonometriye, istatistiksel ve lineer hesaplamalara kadar birçok işlevi gerçekleştirmektedir (Van Der Walt ve Varoquaux, 2011). Pandas, SciPy, Matplotlib gibi popüler veri analizi ve görselleştirme kütüphaneleri, NumPy içermektedir ve birlikte kullanılmaktadır.

Numpy kütüphanesinin içeriğini iyi bir şekilde bilmek programın performansını büyük bir oranda arttırılmasını sağlar. Kısaca NumPy, bilimsel hesaplamalar, veri analizi, makine öğrenmesi, görüntü işleme ve daha birçok alanda yaygın olarak

kullanılan temel bir kütüphanedir. Yüksek performans, verimli veri işleme ve geniş işlevsellik sunması nedeniyle bilim insanları ve veri analistleri tarafından tercih edilen bir araçtır.

3.6.5. TensorFlow kütüphanesi

TensorFlow, Google tarafından yönetilen bir araştırma ekibi tarafından geliştirilmiştir. TensorFlow, makine öğrenmesi ve derin öğrenme için açık kaynaklı güçlü bir kütüphanedir (Abadi vd., 2016). Ancak TensorFlow sadece derin öğrenme ve makine öğrenmeyle sınırlı değildir. Aynı zamanda yapay sinir ağları içinde kullanılmaktadır.

Bu kütüphane sayesinde doğal dil işleme, görüntü işleme, tekrarlayan sinir ağları gibi alanlarda da eğitimi ve analizi için kullanılmaktadır (Bergstra vd., 2010). Kullanıcılar istediğinde kendileri veri akış grafiği oluşturabilme imkânı sağlamaktadır. Grafik düğümlerden oluşmaktadır ve bu düğümler aslında matematiksel işlemlerdir. Düğümler arasındaki kenarlar tensör adında çok boyutlu bir veri dizisini oluşturmaktadır. Tensör, n boyutlu dizilerdir. Ve bu dizilerin veri türleri int32, float32 veya string olarak tutulmaktadır (Learning, 2017). Bu tensörlerin grafikler aracılığıyla veri akışını temsil etmesiyle TensorFlow adını almaktadır.

TensorFlow da düğümler işlem yapmaktadır. Bu işlemlerde giriş sıfır veya daha çok olabilir ve bundan dolayı çıktılar sıfır veya daha fazla olabilmektedir (Kavukçuoğlu, 2016). Bundan dolayı işlem, matematiksel bir denklemi, değişkeni veya bir dosyanın işlemlerini bile temsil edebilmektedir.

TensorFlow yüksek performanslı, çoklu platform desteği ve uygulama esnekliği sayesinde güçlü bir makine öğrenme ve derin öğrenme model çözümü sunmaktadır. Bu sayede kullanıcılar birçok farklı uygulama alanında karmaşık modeller oluşturabilir ve veri setlerinin analizlerini gerçekleştirebilirler.

3.6.6. Scikit – learn kütüphanesi

Scikit-learn Google tarafından geliştirilen genel amaçlı bir makine öğrenmesi kütüphanesidir. Bu kütüphane yüksek performans elde edilebilmek için cython ve python programlama dilleri ile yazılmıştır (Pedregosa vd., 2011). Scikit-learn kütüphanesi içeriğinde birçok denetimli ve denetimsiz öğrenme algoritmalarının kullanılmasını sağlamaktadır.

Scikit-learn kütüphanesinin içeriği yüksek seviyeli bir ara birimde tamamının sunulamayacağı kadar geniş içeriğe sahiptir. Bu kütüphane tüm algoritmaları, nesneleri veya iki boyutlu diziler şeklinde giriş verisi olarak kabul etmektedir. Bu yüzden bağımsız ve genel bir kütüphane olmasını sağlamaktadır (Abraham vd., 2014).

Scikit-learn kütüphanesinin içeriğinden denetimli ve denetimsiz öğrenme algoritması içeren birçok öğrenme modelini içermektedir (Pedregosa vd., 2011).

Denetimli öğrenme, eğitim verisindeki hedeflenen tahminin elde edilmesi için istenilen nitelikleri veri setinde bulunduran yöntemdir. Bu sayede girdiye yeni bir test kümesi verildiğinde benzer değer sonuçları elde edilmesini sağlamaktadır. Denetimli öğrenme modeline şu örnekler verilebilir (Abraham vd., 2014);

- Iris Veri Kümesi kullanarak Sınıflandırma
- K-En Yakın Komşu Sınıflandırıcısı
- Destek Vektör Makineleri (SVC)
- Doğrusal Regresyon
- Destek Vektör Makineleri (SVR)

Denetimsiz öğrenme ise veri setinin herhangi bir etiketlenen veri değeri olmadan verilen giriş verisiyle değer sonucu oluşturan bir modeldir. Denetimsiz öğrenme modeline şu örnekler verilebilir;

- Kümeleme (Clustering)
- Boyut azaltma (Dimensionality Reduction)
- Yoğunlaştırma (Densification)
- Özellik çıkarma (Feature Extraction)

Scikit-learn geniş algoritma kütüphanesi, yüksek performansı ve verimliliği, veri ön işleme ve veri özellik çıkarması, modellerin performansını değerlendirme ve doğrulamasıyla kullanım kolaylığı sayesinde makine öğrenimlerini kolaylaştırır ve kullanıcılara geniş bir model sunmaktadır.

3.6.7. Rasterio kütüphanesi

Coğrafi Bilgi Sistemi (GIS), coğrafi verilerin toplanması, depolanması, yönetimi, analizi ve görselleştirilmesi için kullanılan bir bilgi sistemidir (Gillies, 2019).

Coğrafi veriler, dünya üzerindeki nesnelerin konumunu ve özniteliklerini temsil etmektedir. Rasterio kütüphanesi, coğrafi bilgi sistemleri alanında raster verilerini erişmek ve işlemler yapmak için python programlama diline entegre bir kütüphanedir (Wasser vd., 2019).

Rasterio, coğrafi veri işleme için kullanılan önemli bir araç olarak kabul görmektedir. Bu kütüphane raster veri formatlarını desteklemektedir. Bu sayede verileri kolayca okunmasını ve üzerinde işlem yapılarak kaydedilmesini sağlamaktadır.

Rasterio kütüphanesi GeoTIFF, Erdas Imagine, ArcInfo ASCII Grid gibi yaygın kullanılan formatları desteklemektedir. Büyük boyutlu raster verilerini işlemede iyi bir performansa sahiptir. Coğrafi verileri ölçeklemede ve veri işleme süresini optimize etmede büyük bir avantaj sağlamaktadır (Rey ve Anselin, 2007).


Rasterio, verilerini numpy dizileri kullanarak temsil etmektedir. Bu sayede coğrafi veriler üzerinde yapılan matematiksel işlemlerin analizlerinin iyi bir şekilde hesaplanmasını sağlamaktadır. Bu yüzden veriler üzerinde istatistiksel veriler hesaplanabilmektedir.

Rasterio kütüphanesi, verilerin koordinat sistemleri, projeksiyon bilgileri, boyutları, yükseklik bilgileri gibi veri özelliklerini ayarlamaya imkân sağlamaktadır. Ayrıca rasterio açık kaynaklı bir kütüphanedir. Bu yüzden coğrafi bilgi sistemlerinde verilerin etkili kolay ve doğru bir şekilde işlenmesi ve yönetilebilmesi için tercih edilmelidir.



4. ARAŞTIRMA BULGULARI

Bu bölümde, yaptığımız tez çalışmasındaki orman yangını çıkan bölgelerin belirlenmesini, belirlenen bölgelere ait verilerin toplanma yöntemi ve sürecini, analiz ve doğruluk oranlarının sonuçlarının karşılaştırılmasını içermektedir (Şekil 4.1).



Şekil 4.1. İş akış şeması

4.1. Orman Yangını Çıkan Bölgelerin Belirlenmesi

Türkiye’de 2021 yılında çıkan orman yangınları 28 Temmuz 2021 tarihinde Manavgat’ta orman yangını çıkmış ve diğer yangınların başlangıç nedeni olmuştur. Manavgat’ta çıkan bu orman yangını Akdeniz, Ege, Marmara ve Güneydoğu Anadolu’ya kadar yayılmış ve söndürülmesi günler sürmüştür. Bu orman yangınları 12 Ağustos 2021 tarihinde Muğla ilinin Köyceğiz ilçesinde yangının söndürülmesiyle kontrol altına alınmıştır.

2021 yılı çıkan orman yangınları büyük bir felakete yol açmıştır. Ülkeye maddi ve manevi büyük zararlara ve kayıplara neden olmuştur. Bu yüzden orman yangınlarının çıkmadan önce tahmin edilebilmesi ve önlem alınabilmesi için çalışmamızda bu sorun çalışma konumuzu oluşturmaktadır.

Öncelikle 2021 yılında 28 Temmuz 2021 ve 12 Ağustos 2021 tarihleri arasında çıkan orman yangınında hasar alan il ve ilçeler belirlenmiştir. Orman Genel Müdürlüğünün yayınlamış olduğu 2021 orman yangınları veri raporundan illerin tespiti sağlanmıştır (Çizelge 4.1).

Çizelge 4.1. 2021 yılı en çok orman yangını meydana gelen iller (OGM, 2021)

Şehir	Adet	Hektar
Antalya	294	60366,56
İzmir	148	672,01
Adana	126	4919,26
Manisa	115	153,56
Balıkesir	89	117,66
Mersin	89	9661,2
Aydın	77	1596,51
Çanakkale	74	103,57
Osmaniye	66	3149,79
Hatay	64	334,63


Daha sonra bu illerdeki Orman Bölge Müdürlüklerinin yayınladığı Orman Yangınları Değerlendirme raporunda ilçelerinde meydana gelen yangınların nerelerde olduğu ve büyüklüğü araştırılarak, incelenmiştir (Çizelge 4.2).

Çizelge 4.2. 2021 yılı orman yangını meydana gelen ilçeler (Muğla Orman Bölge Müdürlüğü, 2021)

İlçeler	Yanmış Hektar Alanı
Fethiye	18,209
Köyceğiz	10.745,70
Marmaris	9.102,11
Dalaman	140,12
Nazilli	701,172
Yatağan	3.447,80
Kavaklıdere	5.529,22

Araştırmalar sonucunda en çok yangından etkilenen yerler şunlardır; Manavgat, Milas, Fethiye, Akseki, Datça, Kavaklıdere, Yatağan, Taşağıl, Köyceğiz, Gündoğmuş ve Denizli 28 Temmuz 2021 ve 12 Ağustos 2021 tarihlerinde çıkan orman yangınlarından etkilenen yerlerdir. Tez çalışmamızda bu il ve ilçelerdeki orman yangınlarını ve diğer koşulları birleştirerek veri setimizi oluşturulmuştur.

Şekil 4.2’de seçilen yerlerin Türkiye haritasında işaretlenerek gösterilmiştir.



Şekil 4.2. Türkiye haritasında seçilen bölgelerin gösterimi

4.2. Hava Durumu Değerlerinin Toplanması

Orman yangınlarının çıktığı bölgeler tespiti sağlandıktan sonra makine öğrenmesi ve derin öğrenmeyle orman yangını tahmin analizinin yapılabilmesi için bölgelerin bağıl nem, sıcaklık ve rüzgar hızı yangından bir hafta öncesi ve sonrasına ait bağıl nem, sıcaklık ve rüzgarı hızı verileri araştırılıp, veri setine eklenmiştir.

28 Temmuz 2021 ve 12 Ağustos 2021 tarihlerinde çıkan orman yangınlarındaki bölgelere ait bağıl nem, sıcaklık ve rüzgar hızı geçmişe ait verileri hava kayıt altında ücretsiz bir şekilde kullanıcıya sunan hava durumu tahmin sitesinden her biri gün gün değerleri veri setine eklenmiştir (Çizelge 4.3.).

Çizelge 4.3. 2021 yılı hava durumu verileri (Freemeteo, 2021)

Şehir	Tarih	Bağıl nem	Sıcaklık	Rüzgâr hızı km/h
Manavgat	28.07.2021	12%	41°C	15
Milas	28.07.2021	14%	38°C	19
Bodrum	28.07.2021	14%	38°C	19
Fethiye	28.07.2021	17%	39°C	11
Dalaman	28.07.2021	17%	39°C	11
Datça	28.07.2021	49%	34°C	15
Yatağan	28.07.2021	14%	38°C	19
Köyceğiz	28.07.2021	17%	39°C	11
Kavaklıdere	28.07.2021	14%	38°C	19
Taşagöl	28.07.2021	11%	39°C	15
Akseki	28.07.2021	12%	39°C	15
Gündoğmuş	28.07.2021	12%	39°C	15
Denizli	28.07.2021	30%	30°C	19

4.3. Orman Yangını Meydana Gelen Bölgelerin Uydu Görüntüleri

Orman yangını tahmin veri setimize NDVI, LST değerlerini hesaplayıp, eklemek için 28 Temmuz 2021 ve 12 Ağustos 2021 tarihlerinde çıkan orman yangın bölgelerine ait görüntüler USGS Earth Explorer sitesi üzerinden Landsat 8 görüntüleri indirilmiştir.

Bu indirilen görüntüler içeriğinde NDVI ve LST hesabında kullanacağımız şu bantları içermektedir;

Bant 4; Lansat 8 uydusunun 4. bandıdır. 0.64 - 0.67 mikrometre aralığında kırmızı (RED) dalga boyunu temsil etmektedir.

Bant 5; Lansat 8 uydusunun 5. bandıdır. 0.85 - 0.88 mikrometre aralığında yakın kızılötesi (NIR - Near Infrared) dalga boyunu temsil etmektedir.

Bant 10; Landsat 8 uydusunun termal kızıl ötesi (TIR- Thermal Infrared) dalga boyunu temsil etmektedir. Bu bant 10.60 - 11.19 mikrometre aralığındadır.

Bu bantlara ait görüntüler indirilirken yer yüzündeki NDVI ve LST hesabında daha hassas ve net bilgiler elde edebilmek için bulutluluk oranı %10'un altında filtreleme yapılarak seçilmiştir. İndirilen görüntüler eğitim verilerinde kullanmak ve iyi bir tahmin sonucu elde edebilmek için yangından bir hafta öncesi ve 30 Ağustos 2021 tarihine kadar içermektedir. Yangın öncesi ve sonrası şeklinde verilerin indirilme sebebi orman yangının çıkma olasılığı tahmin edilirken en küçük değişimlere daha hassas olmasını ve doğru karar tahminleri yapabilmesi için veri setine eklenmiştir.

4.3.1. Normalleştirilmiş fark bitki örtüsü indeksi (NDVI)

Landsat 8 uydusuna ait indirilmiş olan uydu görüntülerini NDVI hesaplamasını yapılabilmesi için Python programlama dili kullanılmıştır. Python'da NDVI hesabı yapabilmek için algoritma oluşturulup, yazılmıştır. Python programlama dilinin kullanılmasının amacı daha hızlı işlem yeteneğine sahip olmasıdır.

Öncelikle python'a numpy, pandas ve PIL kütüphaneleri import edilerek yüklenmiştir. Daha sonra calculate_ndvi sınıfı adında fonksiyon oluşturulmuş ve bant 4 ve bant 5 görüntüleri seçilerek NDVI değerleri hesaplanmıştır. Bu hesaplanan veriler veri setine yeni bir boyut olarak eklenmiştir.

Bu çıkan değerlere göre sınıflandırma yapılmıştır. Bu sınıflandırmada negatif değerler su yüzeyi olarak, 0 ve 0,1 değer aralığı bitki örtüsünün tamamen yok olduğu veya toprak yüzeyi olabileceğini, 0,1 ve 0,33 aralığı hasarlı veya sağlıklı bitkileri, 0,33 ve 0,66 aralığında sağlıklı bitki örtüsünü, 0,66 ve 1 aralığında ise çok sağlıklı ve bitki örtüsünün çok olduğunu temsil etmektedir (Şekil 4.3)

```
def calculate_ndvi(red_band, nir_band):
    red = red_band.astype(float)
    nir = nir_band.astype(float)

    ndvi = np.true_divide((nir - red), (nir + red), where=(nir + red) != 0)

    return ndvi

def classify_ndvi(ndvi_data):
    classes = [-np.inf, 0, 0.1, 0.33, 0.66, 1.0]
    labels = ['su yüzeyi', 'bitki örtüsü yok', 'hasarlı bitki örtüsü', 'sağlıklı bitki örtüsü', 'çok sağlıklı bitki örtüsü']

    ndvi_classes = np.digitize(ndvi_data, classes, right=True) - 1
```

Şekil 4.3. Python ile NDVI hesabı

Daha sonra hesaplanılan her uydu görüntüsünün maksimum ve minimum NDVI değerlerine göre görüntünün sınırları olarak belirlenip, .tif formatında kaydedilmiştir. Bu formatta kaydedilmesinin amacı, görüntünün coğrafi sistem yazılım programlarında görüntünün açılabilmesi amacıyla yapılmıştır (Şekil 4.4).

```
# min ve max değerlerini bulma
min_value = np.min(ndvi_result)
max_value = np.max(ndvi_result)

# dosya yolunu seçme
output_directory = askdirectory(title='Select Output Directory')

# NDVI görüntüsünü min ve max değerlerine göre kaydetme
ndvi_image = Image.fromarray(ndvi_result.astype(np.float32))
ndvi_image_filename = input("Enter the filename for the NDVI image: ")
ndvi_image_path = f"{output_directory}/{ndvi_image_filename}.tif"
ndvi_image.save(ndvi_image_path, compression='lzw')
```

Şekil 4.4. Görüntünün min ve max değerlerine göre kaydedilmesi

Elde edilen NDVI görüntüleri ile daha sonra belirlenen NDVI değer aralığına göre renklendirilmesi yapılmıştır (Çizelge 4.4). -1 – 0 aralığı mavi, 0 – 0.1 aralığı kırmızı, 0.1 – 0.33 aralığı sarı, 0.33 – 0.66 aralığı yeşil ve 0.66 – 1 değer aralığı koyu yeşil ile NDVI hesaplaması sonucu oluşan .tif formatındaki görüntünün renklendirmesi yapılmıştır.

Çizelge 4.4. NDVI değer aralığı renklendirmesi

NDVI Değer Aralığı	NDVI Değer Temsil Aralığı Tanımı	Renklendirme
-1 – 0	Su veya kar yüzeyi	Mavi
0 – 0.1	Açık alanlar veya çok düşük yoğunlukta bitki örtüsü	Kırmızı
0.1 – 0.33	Orta düzey bitki örtüsü veya sağlıklı bitki örtüsü	Sarı
0.33 – 0.66	Sağlıklı ve yoğun bitki örtüsü	Açık Yeşil
0.66 – 1	Çok yoğun ve kalın bitki örtüsü	Koyu Yeşil

4.3.2. Kara yüzey sıcaklığı (LST)

Landsat 8 uydusuna ait indirilmiş olan uydu görüntülerini LST hesaplamasını yapılabilmesi için Python programlama dili kullanılmıştır.

Python'da LST hesabını yapabilmek için algoritma oluşturulup, yazılmıştır.

Kara yüzey sıcaklığı (LST) hesaplanması için numpy, pandas, PIL, tikenter ve rasterio kütüphanelerini yüklenmiştir. Landsat 8 uydusundan indirilen belirlenen bölgenin görüntüsüne ait bant 10 seçilerek LST hesaplanması yapılmıştır (Şekil 4.5).

```
# L hesaplama
L = 0.0003342 * band10_array + 0.1

# BT hesaplama
BT = (K2 / np.log((K1 / L) + 1)) - 273.15

# Pv hesaplama
NDVImin = np.nanmin(NDVI)
NDVImax = np.nanmax(NDVI)
Pv = np.divide((NDVI - NDVImin), (NDVImax - NDVImin), out=np.zeros_like(NDVI), where=(NDVImax + NDVImin) != 0)

# ε hesaplama
ε = 0.004 * Pv + 0.986

# LST hesaplama
LST = (BT / (1 + (0.00341802 * BT / 143809) * np.log(ε)))
```

Şekil 4.5. LST değerlerinin hesaplanması

Daha önceden yapılan NDVI hesabı LST algoritmasının içeriğine tekrardan eklenmiştir. Daha sonra LST değerleri ve NDVI değerleri koşullandırılarak fire ya da no fire olarak her bir koşuldan 20 tane seçilerek LST, sınıflandırma ve NDVI değerleri tek bir veri setine eklenmiştir (Şekil 4.6). Hesaplanan LST değerinin görüntüsü normalize edilerek, minimum ve maksimum değerleri sınır aralıkları olarak kabul edilip, .tif formatında kaydedilmiştir.

```

# ndvi_values_1 için NDVI değerlerini seçme ve karşılık gelen LST değerlerini getirme
ndvi_values_1 = NDVI[(LST > 0) & (NDVI >= 0) & (NDVI < 0.1)][:20]
for ndvi in ndvi_values_1:
    selected_ndvi_values.append(ndvi)
    lst_value = LST[np.where(NDVI == ndvi)][0]
    selected_lst_values.append(lst_value)
    selected_bitki_ortusu.append('Bitki Örtüsü Yok')
    selected_fire_values.append('Fire' if lst_value > 35 and ndvi > 0 and ndvi < 0.33 else 'No Fire')

# ndvi_values_2 için NDVI değerlerini seçme ve karşılık gelen LST değerlerini getirme
ndvi_values_2 = NDVI[(LST > 0) & (NDVI >= 0.1) & (NDVI < 0.33)][:20]
for ndvi in ndvi_values_2:
    selected_ndvi_values.append(ndvi)
    lst_value = LST[np.where(NDVI == ndvi)][0]
    selected_lst_values.append(lst_value)
    selected_bitki_ortusu.append('Hasarlı Bitki Örtüsü')
    selected_fire_values.append('Fire' if lst_value > 35 and ndvi > 0 and ndvi < 0.33 else 'No Fire')

# ndvi_values_3 için NDVI değerlerini seçme ve karşılık gelen LST değerlerini getirme
ndvi_values_3 = NDVI[(LST > 0) & (NDVI >= 0.33) & (NDVI < 0.66)][:20]
for ndvi in ndvi_values_3:
    selected_ndvi_values.append(ndvi)
    lst_value = LST[np.where(NDVI == ndvi)][0]
    selected_lst_values.append(lst_value)
    selected_bitki_ortusu.append('Sağlıklı Bitki Örtüsü')
    selected_fire_values.append('Fire' if lst_value > 35 and ndvi > 0 and ndvi < 0.33 else 'No Fire')

# ndvi_values_4 için NDVI değerlerini seçme ve karşılık gelen LST değerlerini getirme
ndvi_values_4 = NDVI[(LST > 0) & (NDVI >= 0.66) & (NDVI < 1)][:20]
for ndvi in ndvi_values_4:
    selected_ndvi_values.append(ndvi)
    lst_value = LST[np.where(NDVI == ndvi)][0]
    selected_lst_values.append(lst_value)
    selected_bitki_ortusu.append('Çok Sağlıklı Bitki Örtüsü')
    selected_fire_values.append('Fire' if lst_value > 35 and ndvi > 0 and ndvi < 0.33 else 'No Fire')

```

Şekil 4.6. LST ve NDVI koşullandırma

Kara yüzey sıcaklığının hesaplamasında kullanılan K_1 ve K_2 parametreleri aşağıda belirtildiği gibi tanımlanmıştır;

K_1 ve K_2 ; bu değerler Landsat 8 verilerini radyometrik ayarını düzenlemek için kullanılan kat sayılardır. Bu sayıları uydu görüntüleri indirildiğinde var olan dosyanın içerisinde var olan metin dosyasında K1_CONSTANT_BAND_10 ve K2_CONSTANT_BAND_10 isimlendirmesiyle uyduya ait değerler bulunmaktadır.

4.4. Orman Yangını Tahmininde Kullanılan Algoritmalar ve Sonuçları

4.4.1. Konvolüsyonel sinir ağı (CNN)

Orman yangınları tahmini için oluşturulan veri setinde 3218 adet veri bulunmaktadır. Bu veri setimizin %80'ni eğitim için %20'si test verisi olarak kullanılmıştır. Derin öğrenme sinir ağlarından olan konvolüsyonel sinir ağı (CNN) modülü kullanılmıştır. Python programlama dilinde CNN algoritması yazılmıştır. Bu algoritmada ilk başta doğruluğu, F1 skoru ve ROC AUC değerleri hesaplanmıştır. Bu değerler aşağıdaki gibi tanımlanmaktadır;

Doğruluk (Accuracy); istenilen sınıflandırma modelinin doğru tahmin edilen örnek oranını gösteren bir parametredir. Hesaplama mantığı, doğru tahmin ettiği yangın var ve doğru tahmin edilen yangın yok durumunun tüm doğru ve yanlış

tahmin edilen yangın sonuçlarına bölünmesiyle bulunmakta ve yüzde olarak ifade edilmektedir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (4.1)$$

- TP (True Positive - (Doğru Tahmin)); modelde pozitif yani yangın var durumu olarak tahmin edilmesi gerçekte yangın var olması durumunun sayısı ifade edilmektedir.
- TN (True Negative - (Doğru Tahmin)); modelde negatif yani yangın yok durumu olarak tahmin edilmesi gerçekte yangın yok olması durumunun sayı ifade edilmektedir.
- FP (False Positive - (Hatalı Tahmin)); modelde pozitif yani yangın var durumu olarak tahmin edilmesi gerçekte yangın yok olması durumunun sayı ifade edilmektedir.
- FN (False Negative - (Hatalı Tahmin)); modelde negatif yani yangın yok durumu olarak tahmin edilmesi gerçekte yangın var olması durumunun sayısı ifade edilmektedir.

Duyarlılık(Recall); sınıflandırma modelinde istenilen pozitif sonucun yani doğru tahmin edilmesi gereken yangın var durumunun ne kadarının pozitif olarak tahmin edildiğini, yanlış ve doğru yangın var tahmin sonucuna bölünmesiyle hesaplanılarak, oransal olarak gösterilmektedir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4.2)$$

Kesinlik (Precision); sınıflandırma modelinde istenilen pozitif sonucun yani doğru tahmin edilen yangın var durumunun, yanlış ve doğru yangın var tahmin sonucuna bölünmesiyle hesaplanılarak, tahmin sonucu oransal olarak gösterilmektedir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (4.3)$$

F1 skoru; sınıflandırma modelinin performansının ölçülmesini sağlayan bir parametredir. Doğruluk ve duyarlılığın harmonik ortalaması hesaplanılarak bulunmaktadır. F1 skoru 0 ile 1 arasında değerler almaktadır ve bu değerler 1'e yaklaştıkça iyi bir performans değerine sahip olduğunu göstermektedir.

$$F1 = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (4.4)$$

ROC AUC (Receiver Operating Characteristic - Alıcı Çalışma Karakteristiği);


Tahmin 1; bu durum yangın olma durumunun pozitif yani yangın var olarak tahmin edildiği sonuçtur. Bu durumu veri setinde algoritmanın anlayabilmesi için yangın var yani fire durumuna 1 değeri verilerek tanımlanmıştır.

Tahmin 0; bu durum yangın olma durumunun negatif yani yangın yok olarak tahmin edildiği sonuçtur. Bu durumu veri setinde algoritmanın anlayabilmesi için yangın yok yani no_fire durumuna 0 değeri verilerek tanımlanmıştır.

Gerçek 1; veri setindeki sonuçta yangın durumunun gerçekte yangın var olması durumudur.

Gerçek 0; veri setindeki sonuçta yangın durumunun gerçekte yangın yok olması durumudur.


Bu hesaplama da aynı zamanda CNN algoritmasının epochs, filters ve kernel size'ına da değerler verilerek en iyi performans için test edilmiştir. Epochs 30 a kadar denenmiş ve 30'da, filters 64'te ve kernel size 3'te iyi sonuçlar elde edilmiştir. CNN algoritmamızla veri setimizi eğittiğimiz de doğruluk oranının %87, F1 skorunun %84 ve ROC AUC oranının %86 olduğu tahmin sonucu elde edilmiştir (Şekil 4.7).




Şekil 4.7. CNN farklı değerlere göre doğruluk analizi

Bu doğruluk oranlarının tutarlılıklarını daha doğru sonuçların anlaşılabilmesi ve modelin performansını değerlendirme için K-fold çapraz doğrulama ile CNN algoritmasını uygulanmıştır. Bu koşulda k değeri beş parçaya bölünüp her durumda dört verinin eğitim içeriğine dahil edilmesinden dolayı veri setinin %80'i eğitim için kullanılmıştır.

CNN algoritmasına K-fold çapraz doğrulama yapıldığında Şekil 4.8'de görüldüğü gibi tahmin sonuçlarına göre TP tahmini yani yangın var tahmininde bulunması, gerçekte ise yangın var olması durumu 1216, FN tahmini algoritma yangın yok tahmininde bulunması, gerçekte ise yangının var olması durumu 310, FP tahmini yangın var tahmininde bulunması, gerçekte ise yangının yok olması durumu 256 ve TN tahmini yangın yok tahmininde bulunması, gerçekte ise yangının yok olması durumu ise 1436 olarak algoritma tahmin etmiştir. Her bir kümeleme adımında hesaplanan kesinlik ve doğruluk analizi Şekil 4.9'da gösterildiği gibidir. Bu her kümelemede elde edilen doğruluk ve kesinlik oranının toplam ortalamasını aldığımız da toplam doğruluk tahmini %82 ve toplam kesinlik tahmini %85 elde edilmiştir (Şekil 4.9).



Şekil 4. 8. CNN algoritması çapraz doğrulama toplam tahmin sonuçları



Şekil 4.9. CNN algoritması çapraz doğrulama ile doğruluk ve kesinlik analizi

4.4.2. Uzun kısa süreli bellek sinir ağı (LSTM)


Orman yangınları tahmini için oluşturulan veri setinde 3218 adet veri bulunmaktadır. Bu veri setimizin %80'ni eğitim için %20'si test verisi olarak kullanılmıştır. Derin öğrenme sinir ağlarından olan uzun kısa süreli bellek (LSTM) modülü kullanılmıştır. Python programlama dilinde LSTM algoritması yazılmıştır. Bu algoritmada ilk başta doğruluğu, F1 skoru ve ROC AUC değerleri hesaplanmıştır. Bu hesaplama yapılırken aynı zamanda LSTM modülünün en iyi değer ve performansı için gizli katman ve epoch sayısına da bakılmıştır. Epoch sayısına bakılmasının nedeni veri setindeki veri kümesinin kaç kez

hesaplanacağını belirtmektedir. Bazen epoch sayısının yüksek olması modelin daha iyi öğrenmesini sağlayabilmektedir.

Bu katmanların sayılarını değiştirmek için grid arama modeli oluşturulmuştur. Bu model gizli katman sayılarının otomatik bir şekilde kombinasyonlarının denenmesine olanak sağlamaktadır. Grid arama modelini kullanmak için keras kütüphanesinde sargı (wrapper) sınıfı kullanılması gerekmektedir.

Gizli katmanının units adlı parametreyle tanımlanmıştır ve 64'e kadar değer atayarak denenmiştir. Epoch sayısı da onar artış sağlanarak 30'a kadar denenmiştir. Her gizli katman için epoch değerleri ayarlanmıştır. Ve bu hesaplamaların sonucunda doğruluk, F1 skoru ve ROC AUC değerlerine baktığımızda en yüksek doğruluk performansını gizli katman sayısı 30'da elde edilmiştir.

Bu sayının aşağısı ve yukarısında doğruluk değerleri düşük çıkmaktadır. Epoch sayımızda 30'da ve units sayısı 32'de en iyi öğrenme performansını göstermektedir (Şekil 4.10).




Şekil 4.10. LSTM değerlere göre doğruluk oranı

Bu hesaplama sonucunda doğruluk oranı %98, F1 skoru %96 ve ROC AUC oranını %96 olarak tahmin sonucu elde edilmiştir.

Bu doğruluk oranlarının tutarlılıklarını daha doğru sonuçların anlaşılabilmesi ve modelin performansını değerlendirme için K-fold çapraz doğrulama ile CNN algoritmasını uygulanmıştır.

Bu koşulda k değeri beş parçaya bölünüp her durumda dört verinin eğitim içeriğine dahil edilmesinden dolayı veri setinin %80'i eğitim için kullanılmıştır. LSTM algoritmasını K-fold çapraz doğrulama yapıldığında Şekil 4.11'de görüldüğü gibi tahmin sonuçlarına göre TP tahmini; yangın var tahmininde bulunması, gerçekte ise yangın var olması durumu 1504, FN tahmini; algoritma yangın yok tahmininde bulunması, gerçekte ise yangının var olması durumu 22, FP tahmini; yangın var tahmininde bulunması, gerçekte ise yangının yok olması durumu 29 ve TN tahmini; yangın yok tahmininde bulunması, gerçekte ise yangının yok olması durumu ise 1663 olarak algoritma tahmin etmiştir.



Şekil 4.11. LSTM algoritması çapraz doğrulama toplam tahmin sonuçları

Her bir kümeleme adımında hesaplanan kesinlik ve doğruluk analizi şekil 4.12'de gösterildiği gibidir.

Bu her kümelemede elde edilen doğruluk ve kesinlik oranının toplam ortalamasını aldığımızda toplam doğruluk tahmini %98 ve toplam kesinlik tahmini %98 elde edilmiştir (Şekil 4.12).



Şekil 4.12. LSTM algoritması çapraz doğrulama ile doğruluk ve kesinlik analizi


4.4.3. Rastgele orman (Random forest (RF)) algoritması

Rastgele orman algoritması bir makine öğrenmesi algoritmasıdır. Bu algoritmayı kullanılmasının amacı makine öğrenmesi algoritmaları arasında yüksek oranda doğruluğa sahiptir. Bu sayede derin öğrenme algoritmalarının makine öğrenmesi algoritmaları karşısındaki performansını karşılaştırmasını sağlamaktadır.

Orman yangınları tahmini için oluşturulan veri setinde 3218 adet veri bulunmaktadır. Bu veri setimizin %80'ni eğitim için %20'si test verisi olarak kullanılmıştır.

Python programlama dilinde random forest algoritması yazılmıştır. Bu algorithmada ilk başta doğruluğu, F1 skoru ve ROC AUC değerleri hesaplanmıştır. RF modülü karar ağaçları bulunmaktadır ve bunların derinlik ve düğüm bölünmesi sayıları da modülün eğitilmesi için çok önemlidir. Modelin eğitiminde karar ağaç sayısı 30'a kadar denenmiştir. Maksimum derinliği 10'a kadar denenmiştir.


Bu hesaplamda çıkan sonuçlar değerlendirildiğinde karar ağaç sayısı 30, maksimum derinlik none olduğu zaman en iyi performansı gösterdiği tespit edilmiştir. En iyi doğruluk tahmini %99, F1 skoru 1 ve ROC AUC değeri 1 sonucuna ulaşılmıştır (Şekil 4.13).



Şekil 4.13. RF algoritması farklı değerlere göre doğruluk analizi

RF algoritması yangın durumunu yüksek bir oranda tahmin etmiştir. Burada aşırı öğrenme olma durumunun kontrolü için K-fold çapraz doğrulama algoritması kullanılarak kontrolü ve performansı tekrar değerlendirilmiştir.


RF algoritmasına K-fold çapraz doğrulama yapıldığında Şekil 4.14'te görüldüğü gibi tahmin sonuçlarına göre TP tahmini; yangın var tahmininde bulunması, gerçekte ise yangın var olması durumu 1524, FN tahmini; algoritma yangın yok tahmininde bulunması, gerçekte ise yangının var olması durumu 0, FP tahmini; yangın var tahmininde bulunması, gerçekte ise yangının yok olması durumu 2 ve TN tahmini; yangın yok tahmininde bulunması, gerçekte ise yangının yok olması durumu ise 1692 olarak algoritma tahmin etmiştir.



Şekil 4.14. RF algoritması çapraz doğrulama toplam tahmin sonuçları

Her bir kümeleme adımında hesaplanan kesinlik ve doğruluk analizi Şekil 4.15'te gösterildiği gibidir.


Bu her kümelemede elde edilen doğruluk ve kesinlik oranının toplam ortalamasını aldığımızda toplam doğruluk tahmini 0,99 ve toplam kesinlik tahmini 1 sonucu elde edilmiştir.



Şekil 4.15. RF algoritması çapraz doğrulama doğruluk ve kesinlik analizi

4.5. Karşılaştırma Sonuçları


CNN, LSTM ve RF algoritmaların sonuçları karşılaştırılmıştır. Şekil 4.16'da gösterildiği gibi doğruluk oranları incelendiğinde RF algoritmasının en yüksek doğru tahmin etme olasılığı olduğu görülmektedir. Derin öğrenme yöntemleri arasında bakıldığında ise LSTM algoritması %98 doğruluk oranıyla iyi bir tahminde bulunduğu sonucuna ulaşılmıştır.



Şekil 4.16. Karşılaştırma sonuçları


CNN, LSTM ve RF algoritmaların K-fold çapraz doğrulama sonuçları karşılaştırılmıştır.

Şekil 4.17'ye bakıldığında tahmin edilen sonuçlara bakıldığında gerçekte yangın var olması durumunu yangın var olarak tahmin eden rastgele orman algoritmasıdır. Lakin sonuçlara bakıldığında LSTM modeliyle arasındaki farkın çok az olduğu görülmektedir. Gerçekte yangının olmadığı durumda yangın yok olarak tahmin eden RF algoritmasıdır. Ancak sonuçlar incelendiğinde derin öğrenme yöntemlerinden LSTM modelinin makine öğrenme algoritması olan RF algoritmasına çok yakın sonuçlar elde edildiği görülmektedir.



Şekil 4.17. Çapraz doğrulama karşılaştırma sonuçları

Modüllerin çapraz doğrulama oranları karşılaştırıldığında derin öğrenme yöntemlerinden en yüksek doğruluğa sahip LSTM algoritması olduğu görülmektedir. Makine öğrenme yöntemlerinden RF algoritması ise makine öğrenmesi ve derin öğrenme yöntemleri arasında en yüksek doğruluk oranına sahip olduğu hesaplanmıştır (Şekil 4.18).



Şekil 4.18. K-fold çapraz doğrulama ile doğruluk tahminleri karşılaştırması

5. TARTIŞMA VE SONUÇLAR

Orman yangınları, geçmişten günümüze doğal ekosistemlere ve insanlara her daim tehlike oluşturan ciddi bir felakettir. Orman yangınları, ormanların tahrip ve yok olmasına neden olarak kalıcı olarak biyoçeşitlilik hasarına ve kaybına neden olmaktadır. Ayrıca orman yangınları sırasında açığa çıkan tehlikeli düzeyde karbon salınımdan dolayı atmosfere zarar vermekte ve iklim değişikliğinin nedenlerinden biri olmaktadır.

2021 yılında Türkiye’de temmuz ve ağustos aylarında meydana gelen orman yangını ülkenin birçok bölgesinde hasara neden olmuştur. Bu yangınlar özellikle Akdeniz bölgesini ciddi oranda etkilemiştir. Binlerce hektarlık alan tahrip olmuş ve sosyo ekonomik kayıplar yaşanmıştır.

Sadece orman yangınları doğayı değil aynı zamanda yangının meydana geldiği bölgelerde yaşayan insan ve hayvanları da etkilemiştir. Birçok ev, iş yeri, tarım arazisi tahrip olmuştur. Yangınlardan dolayı birçok insan sağlık sorunu yaşamış veya yaşamını kaybetmiştir. Bu acı olay orman yangınlarının ciddi ve önemli bir konu olduğunu bir kez daha hatırlanmasına neden olmuştur.

Bu tez çalışmasında orman yangınlarının önceden tahmin edilebilirliği ve önlem alınabilmesi için makine ve derin öğrenme yöntemleriyle analiz yapılmıştır.

Öncelikle çalışmaya Orman Genel Müdürlüğü’nün yayınlamış olduğu 2021 orman yangını raporu incelenmiştir. Buradaki verilere göre orman yangınından etkilenen il ve ilçeler belirlenmiştir. Bu bölgelerin yangın dönemine ait geçmiş hava durumu verileri sıcaklık, bağıl nem ve rüzgar hızı toplanmış ve veri setine eklenmiştir.

Belirlenen bu bölgelerin Landsat 8 uydusundan görüntüleri indirilmiştir. Bu görüntüler python programlama diliyle NDVI ve LST analizi yapılmıştır. Bu analiz sonuçları da veri setine eklenmiştir.

Oluşturulan bu veri setiyle derin öğrenme yöntemlerinden CNN ve LSTM, makine öğrenmesi yöntemlerinden ise rastgele orman algoritmasıyla analiz yapılarak, incelenmiştir.

Bu analiz sonuçlarına göre derin öğrenme yöntemi olan CNN algoritması orman yangınları tahmininde 3218 verinin %80'i eğitilmiştir. Doğruluk oranının %87, F1 skorunun %84 ve ROC AUC oranının %86 olduğu tahmin sonucu elde edilmiştir. CNN modülümüzün performansını değerlendirmek için K-fold çapraz doğrulama algoritması kullanılmıştır. Çapraz doğrulama sonrasın elde edilen toplam doğru tahmin sayısı 2652 olduğu sonucuna ulaşılmıştır. Bu doğruluk oranı ise %85'tir. Ayrıca algoritmalarla analiz yapılırken en yüksek doğruluk oranını elde edebilmek için derin öğrenme katman sayılarına da bakılmıştır. Gizli katman sayısında 32'de en yüksek doğruluk elde edilmiştir.

LSTM algoritmasında orman yangınları tahmininde 3218 verinin %80'i eğitilmiş ve gizli katman sayısında 30'da en yüksek doğruluk elde edilmiştir. Epoch sayısı da 30'da en iyi doğruluğu olduğu saptanmıştır. Çıkan sonuçta toplam doğru tahmin sayısı 3167 olduğu sonucuna ulaşılmıştır. Doğruluk oranı hesaplandığında %97, F1 skoru %96 ve ROC AUC oranını %96 olarak tahmin sonucu elde edilmiştir. LSTM modülümüzün performansını değerlendirmek için K-fold çapraz doğrulama algoritması kullanılmıştır. Çapraz doğrulama sonrasın elde edilen toplam doğru tahmin sayısı 3167 olduğu sonucuna ulaşılmıştır. Bu doğruluk oranı ise %98'dir.

Makine öğrenmesi yöntemlerinden olan RF algoritması orman yangınları tahmininde 3218 verinin %80'i eğitilmiş ve karar ağacı sayısı 30 olarak belirlenmiştir. Maksimum derinlik 30 ve düğüm bölünme sayısı none olduğunda en iyi tahmin sonucunu elde edilmiştir. En iyi doğruluk tahmini 0,99, F1 skoru 1 ve ROC AUC değeri 1 sonucuna ulaşılmıştır. RF modülümüzün performansını değerlendirmek için K-fold çapraz doğrulama algoritması kullanılmıştır. Çapraz doğrulama sonrasın elde edilen toplam doğru tahmin sayısı 3216 olduğu sonucuna ulaşılmıştır. Bu doğruluk oranı ise %99 sonucuna ulaşılmıştır.

Bu alıřma sonucunda makine ğrenmesi ve derin ğrenme yöntemleriyle orman yangınlarının önceden tahminlemesi yapılmıştır. Orman yangını veri setinde analiz yapılırken algoritmaların en iyi doğruluk için gizli katman sayılarına ve karar ağa sayılarıda tek tek deneme yapılarak tespit edilmiştir. En iyi derin ğrenmesi LSTM algoritması olmuştur. Makine ğrenme yöntemi olan RF algoritması bizim problemimiz için derin ğrenme yöntemlerinden de daha iyi olduğu ispatlanmıştır.



KAYNAKLAR

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... Zheng, X., 2016, November. Tensorflow: a system for large-scale machine learning. In *Osd* (Vol. 16, No. 2016, pp. 265-283).
- Abay, E., Sözüay, K., Şahin, Ö. C., Temel, R. E., Tarhan, Y., Mihçioğur, S., 2022. Küresel İklim Değişliği ve Orman Yangınları Ülke ve Dünya Etkileri. *Sağlık ve Toplum*, 32(3), 3-13.
- Abraham, A., Pedregosa, F., Eickenberg, M., Gervais, P., Mueller, A., Kossaifi, J., ... Varoquaux, G., 2014. Machine learning for neuroimaging with scikit-learn. *Frontiers in neuroinformatics*, 14.
- Anejionu, O. C. D., Blackburn, G. A., Whyatt, J. D., 2014. Satellite survey of gas flares: Development and application of a Landsat-based technique in the Niger Delta. *International Journal of Remote Sensing*, 35(5), 1900–1925.
- Anguita, D., Ghelardoni, L., Ghio, A., Oneto, L., Ridella, S., 2012, April. The K'in K-fold Cross Validation. In *ESANN* (pp. 441-446).
- Baranovskiy, N. V., Kogan, R. M., Glagolev, V. A., Zubareva, A. M., 2017, November. Grassland fire spread simulation using NDVI data. In *23rd International Symposium on Atmospheric and Ocean Optics: Atmospheric Physics* (Vol. 10466, pp. 708-713). SPIE.
- Barsi J., Schott J., Palluconi F., Hook S., 2005, Validation of a web-based atmospheric correction tool for single thermal band instruments, Proc. SPIE Conference on Earth Observing Systems X, July 31- August 2, San Diego, CA, 136-142.
- Bayazıt, Y., Koç, C., 2022. The impact of forest fires on floods and erosion: Marmaris, Turkey. *Environment, Development and Sustainability*, 24(11), 13426-13445.
- Benek S., Şahap A., 2017. Şanlıurfa Şehrinde Coğrafi Bilgi Sistemleri (Cbs) ve Uzaktan Algılama (Ua) Kullanılarak Yeşil Alanların Yeterliliğinin Belirlenmesi. *Marmara Coğrafya Dergisi*, 36: 304- 314.
- Bergstra, J., Breuleux, O., Bastien, F., Lamblin, P., Pascanu, R., Desjardins, G., ... Bengio, Y., 2010, June. Theano: A CPU and GPU math compiler in Python. In *Proc. 9th python in science conf* (Vol. 1, pp. 3-10).
- Blackett, M., 2014. Early analysis of Landsat-8 thermal infrared sensor imagery of volcanic activity. *Remote sensing*, 6(3), 2282-2295.
- Bonan, G. B., 2008. Forests and climate change: forcings, feedbacks, and the climate benefits of forests. *Science*, 320(5882), 1444-1449.

- Breiman, L., 2001. Random forests. *Machine learning*, 45, 5-32.
- Butuc B.R., Moldovean G., 2011. Environmental impact scenario of an azimuthal tracked PV platform based on CO2 emissions reduction, *Environmental Engineering and Management Journal*, 10, 271-276
- Carlson, T.N. and Ripley, D.A., 1997 On the Relation between NDVI, Fractional Vegetation Cover, and Leaf Area Index. *Remote sensing of Environment*, 62,241-252. [http://dx.doi.org/10.1016/S0034-4257\(97\)00104-1](http://dx.doi.org/10.1016/S0034-4257(97)00104-1).
- Chander G., Markham B., 2003. Revised Landsat-5 TM radiometric calibration procedures and postcalibration dynamic ranges, *IEEE Transactions on Geoscience and Remote Sensing*, 41, 2674-2677.
- Chavez P.S., 1996. Image-based atmospheric correction – revisited and improved, *Photogrammetric Engineering Remote Sensing*, 62, 1025-1036.
- Chen, D. Y., 2017. *Pandas for everyone: Python data analysis*. Addison-Wesley Professional.
- Chicho, B. T., Sallow, A. B., 2021. A Comprehensive Survey of Deep Learning Models Based on Keras Framework. *Journal of Soft Computing and Data Mining*, 2(2), 49-62.
- Chowdhury, E. H., Hassan, Q. K., 2015. Development of a new daily-scale forest fire danger forecasting system using remote sensing data. *Remote Sensing*, 7(3), 2431-2448.
- Clark, R. N., Swayze, G. A., Wise, R., Livo, K. E., Hoefen, T. M., Kokaly, R. F., Sutley, S. J., 2003. USGS digital spectral library splib05a. *US Geological Survey, Open File Report*, 3, 395.
- Cruz, M. and Alexander, M., 2010. Assessing crown fire potential in coniferous forests of western North America: a critique of current approaches and recent simulation studies. *International Journal of Wildland Fire*, 19(4) 377–398.
- Doğanay, H., Doğanay, S., 2004. Türkiye’de orman yangınları ve alınması gereken önlemler. *Doğu Coğrafya Dergisi*.
- FAO, UNEP (Birleşmiş Milletler Gıda ve Tarım Örgütü)., 2020. The State of the World's Forests 2020 - Forests, Biodiversity and People. Roma.
- Faundeen, J. L., Kanengieter, R. L., Buswell, M. D., 2002. US geological survey spatial data access. *Journal of Geospatial Engineering*, 4(2), 145-145.
- Francis, P. W., Rothery, D. A., 1987. Using the Landsat Thematic Mapper to detect and monitor active volcanoes: An example from Lascar volcano, northern Chile. *Geology*, 15, 614–617

- Frankel, A. D., Mueller, C. S., Barnhard, T. P., Leyendecker, E. V., Wesson, R. L., Harmsen, S. C., ... Hopper, M. G., 2000. USGS national seismic hazard maps. *Earthquake spectra*, 16(1), 1-19.
- Freemeteo, 2021. Erişim Tarihi: 1.10. 2022. <https://tr.freemeteo.com>
- Ganteaume, A., Camia, A., Jappiot, M., San-Miguel-Ayanz, J., Long-Fournel, M., Lampin, C., 2013. A review of the main driving factors of forest fire ignition over Europe. *Environmental management*, 51, 651-662.
- Gers, F. A., Schmidhuber, J., Cummins, F., 2000. Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10), 2451-2471.
- Gillies, S., 2019. Rasterio documentation. *MapBox, July*, 23.
- Giusti, A., Ciresan, D. C., Masci, J., Gambardella, L. M., Schmidhuber, J., 2013. Fast image scanning with deep max-pooling convolutional neural networks. In Proc. ICIP.
- Graves, A., 2013. Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., Schmidhuber, J., 2016. LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
- Günşen, H. B., Atmiş, E., 2019. Analysis of forest change and deforestation in Turkey. *International Forestry Review*, 21(2), 182-194.
- Hatfield JL, Kanemasu ET, Asrar G, Jackson RD, Pinter PJJ, Reginato RJ, Idso SB., 1985. Leaf Area Estimates From Spectral Measurements Over Various Planting Dates of Wheat. *Int. J. Remote Sens*, 6: 167–175.
- Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Iannace, G., Ciaburro, G., Trematerra, A., 2019. Wind turbine noise prediction using random forest regression. *Machines*, 7(4), 69.
- Interface, E. E., Documentation, P., 2000. Earth Explorer.
- Irons, J. R., Dwyer, J. L., Barsi, J. A., 2012. the next landsat satellite: the landsat data continuity mission. *Remote Sensing of Environment*, 112, 11–21.
- Ji, S., Xu, W., Yang, M., Yu, K., 2012. 3D convolutional neural networks for human action recognition. *IEEE transactions on pattern analysis and machine intelligence*, 35(1), 221-231.

- Jordan, C. F., 1969, Derivation of leaf area index from quality of light on the forest floor, *Ecology* 50:663-666.
- Jung, Y., 2018. Multiple predicting K-fold cross-validation for model selection. *Journal of Nonparametric Statistics*, 30(1), 197-215.
- Kala, C. P., 2023. Environmental and socioeconomic impacts of forest fires: A call for multilateral cooperation and management interventions. *Natural Hazards Research*.
- Kalantar, B., Ueda, N., Idrees, M. O., Janizadeh, S., Ahmadi, K., Shabani, F., 2020. Forest fire susceptibility prediction based on machine learning models with resampling algorithms on remote sensing data. *Remote Sensing*, 12(22), 3682.
- Kavukcuoglu, K., 2016. Deepmind moves to tensorflow. *Google Research Blog*, Apr.
- Keeley, J. E., Syphard, A. D., 2021. Large California wildfires: 2020 fires in historical context. *Fire Ecology*, 17(1), 1-11.
- Krizhevsky, A., Sutskever, I., Hinton, G. E., 2017. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Learning, A. G. H. O. M. , 2017. with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems.
- Lee, H., Song, J., 2019. Introduction to convolutional neural network using Keras; an understanding from a statistician. *Communications for Statistical Applications and Methods*, 26(6), 591-610.
- Lehmann, E. A., Wallace, J. F., Caccetta, P. A., Furby, S. L., Zdunic, K. , 2013. Forest cover trends from time series Landsat data for the Australian continent. *International Journal of Applied Earth Observation and Geoinformation*, 21, 453-462.
- Lemenkova, P., 2019. Processing oceanographic data by Python libraries NumPy, SciPy and Pandas. *Aquatic Research*, 2(2), 73-91.
- Lewis, S. L., Maslin, M. A. (2015). Defining the Anthropocene. *Nature*, 519(7542), 171-180.
- Littell, J. S., Peterson, D. L., Riley, K. L., Liu, Y., Luce, C. H. , 2016. A review of the relationships between drought and forest fire in the United States. *Global change biology*, 22(7), 2353-2369.
- Loveland, T. R., Dwyer, J. L., 2012. Landsat: Building a strong future. *Remote Sensing of Environment*, 122, 22-29.

- Ma, X., Yu, H., Wang, Y., Wang, Y., 2015. Large-scale transportation network congestion evolution prediction using deep learning theory. *PLoS ONE* 10, 1–17.
- Mackey, B., DellaSala, D. A., Kormos, C., Lindenmayer, D., Kumpel, N., Zimmerman, B., 2015. Policy options for the world's primary forests in multilateral environmental agreements. *Conservation Letters*, 8(2), 139-147.
- Maffei, C., Alfieri, S. M., Menenti, M., 2018. Relating spatiotemporal patterns of forest fires burned area and duration to diurnal land surface temperature anomalies. *Remote Sensing*, 10(11), 1777.
- Majid, S., Alenezi, F., Masood, S., Ahmad, M., Gündüz, E. S., Polat, K., 2022. Attention based CNN model for fire detection and localization in real-world images. *Expert Systems with Applications*, 189, 116114.
- Makantasis, K., Karantza, K., Doulamis, A., Doulamis, N., 2015, July. Deep supervised learning for hyperspectral data classification through convolutional neural networks. In *2015 IEEE international geoscience and remote sensing symposium (IGARSS)* (pp. 4959-4962). IEEE.
- Markham B.L., Barker J.L., 1986. Landsat MSS and TM post-calibration dynamic ranges, exoatmospheric reflectances and at-satellite temperatures, Earth Observation Satellite Co., Lanham, MD, Landsat Tech. Note 1, Aug
- McKinney, W., 2010, June. Data structures for statistical computing in python. In *Proceedings of the 9th Python in Science Conference* (Vol. 445, No. 1, pp. 51-56).
- McKinney, W., 2015. Pandas, python data analysis library. URL <http://pandas.pydata.org>, 3-15.
- Mohammed, Z., Hanae, C., Larbi, S., 2020. Comparative study on machine learning algorithms for early fire forest detection system using geodata. *International Journal of Electrical and Computer Engineering*, 10(5), 5507-13.
- Moolayil, J., Moolayil, J., 2019. An introduction to deep learning and keras. *Learn Keras for Deep Neural Networks: A Fast-Track Approach to Modern Deep Learning with Python*, 1-16.
- Morfitt, R., Barsi, J., Levy, R., Markham, B., Micijevici, E., Ong, L., ... Vanderwerff, K., 2015. Landsat-8 Operational Land Imager (OLI) radiometric performance on-orbit. *Remote Sensing*, 7, 2208–2237.
- Mountrakis, G., Im, J., Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing*, 66(3), 247-259.

- Nagendra, H., 2001. Using remote sensing to assess biodiversity. *International journal of remote sensing*, 22(12), 2377-2400.
- Nwankpa, C., Ijomah, W., Gachagan, A., Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
- O'Grady, S., 2013. The RedMonk Programming Language Rankings: January 2013. Redmonk.
- Oliphant, T.E., 2007. Python for scientific computing. *Com-puting in Science Engineering* 9(3), 10-20.
- Oppenheimer, C., 1991. Lava flow cooling estimated from Landsat Thematic Mapper data: The Lonquimay Eruption (Chile, 1989). *Journal of Geophysical Research*, 96. <http://dx.doi.org/10.1029/91JB01902>.
- Pearson, R. L., and Miller, L. D. , 1972. Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass prairie, in *Proceedings of the Eighth International Symposium on Remote Sensing of Environment*, Environmental Research Institute of Michigan, Ann Arbor, MI, pp. 1357-1381.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, E., 2011. Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- Perry, C. R., Jr., and Lautenschlager, L. F., 1984. Functional equivalence of spectral vegetation indices, *Remote Sens. Environ.* 14:169-182.
- Peters, J., De Baets, B., Verhoest, N. E., Samson, R., Degroeve, S., De Becker, P., Huybrechts, W., 2007. Random forests as a tool for ecohydrological distribution modelling. *ecological modelling*, 207(2-4), 304-318.
- Phillips, O. L., Lewis, S. L., Baker, T. R., et al., 2008. Increasing carbon storage in intact African tropical forests. *Nature*, 457(7232), 1003-1006.
- Prasad, N., Bandi, R. G., Padmaja, B., 2013, November. Monitoring and extracting abnormalities in land surface temperature images for automatic identification of forest fires. In *2013 European Modelling Symposium* (pp. 215-219). IEEE.
- Ramasubramanian, K., Singh, A., Ramasubramanian, K., Singh, A., 2019. Deep learning using keras and tensorflow. *Machine Learning Using R: With Time Series and Industry-Based Use Cases in R*, 667-688.

- Raschka, S., Mirjalili, V., 2019. *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. Packt Publishing Ltd.
- Reddy, D. S., Prasad, P. R. C., 2018. Prediction of vegetation dynamics using NDVI time series data and LSTM. *Modeling Earth Systems and Environment*, 4, 409-419.
- Rey, S. J., Anselin, L., 2007. PySAL: A Python Library of Spatial Analytical Methods. *The Review of Regional Studies*, 37, 5-27.
- Roy, D., Wulder, M. A., Loveland, T. R., Woodcock, C. E., Allen, R. G., Anderson, M. C., ... Zhu, Z., 2014. Landsat-8: Science and product vision for terrestrial global change research. *Remote Sensing of Environment*, 145, 154-172.
- Schroeder, W., Oliva, P., Giglio, L., Quayle, B., Lorenz, E., Morelli, F., 2016. Active fire detection using Landsat-8/OLI data. *Remote sensing of environment*, 185, 210-220.
- Shahabi, H., Shirzadi, A., Ghaderi, K., Omidvar, E., Al-Ansari, N., Clague, J. J., ... Ahmad, A., 2020. Flood detection and susceptibility mapping using sentinel-1 remote sensing data and a machine learning approach: Hybrid intelligence of bagging ensemble based on k-nearest neighbor classifier. *Remote Sensing*, 12(2), 266.
- Sharma, S., Sharma, S., Athaiya, A., 2017. Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- Sievert, S., Augspurger, T., Rocklin, M., Calloway, C., Lippa, D., Niederhut, D., Shupe, D., 2019, July. Better and faster hyperparameter optimization with Dask. In *Proceedings of the 18th Python in Science Conference* (pp. 118-125).
- Sobrino J.A., Jimenez-Munoz J.C., Paolini L., 2004. Land surface temperature retrieval from Landsat TM 5, *Remote Sensing of Environment*, 90, 434-440.
- Summerfield, M., 2007. *Rapid GUI Programming with Python and Qt: The Definitive Guide to PyQt Programming (paperback)*. Pearson Education.
- Şen, G., Güngör, E., 2018. Analysis of land use/land cover changes following population movements and agricultural activities: a case study in northern Turkey. *Applied Ecology and Environmental Research*, 16(2), 2073-2088.
- Tamilarasi, P., Rani, R. U., 2020, March. Diagnosis of crime rate against women using k-fold cross validation through machine learning. In *2020 fourth international conference on computing methodologies and communication (ICCMC)* (pp. 1034-1038). IEEE.

- Tariq, S., ul-Haq, Z., Mariam, A., Mehmood, U., Ahmed, W., 2023. Assessment of air quality during worst wildfires in Mugla and Antalya regions of Turkey. *Natural Hazards*, 115(2), 1235-1254.
- Thakur, P. K., Ranjan, R., Singh, S., Dhote, P. R., Sharma, V., Srivastav, V., ... Chouksey, A., 2020. Synergistic use of remote sensing, GIS and hydrological models for study of august 2018 Kerala floods. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 1263-1270.
- Thome K., Markham B., Barker J., Slater P., Biggar S., 1997. Radiometric calibration of landsat, *Photogrammetric Engineering Remote Sensing*, 63, 853-858.
- Thome, K., Reuter, D., Lunsford, A., Montanaro, M., Smith, R., Tesfaye, Z., Wenny, B., 2011. Calibration of the thermal infrared sensor on the Landsat Data Continuity
- Tulchak, L. V., Marchuk, A. O., 2016. *History of python* (Doctoral dissertation, BHTY).
- Türkiye Cumhuriyeti Tarım ve Orman Bakanlığı., 2021. Türkiye'nin Ormancılık Stratejisi 2019-2023. Ankara.
- Türkiye Orman Genel Müdürlüğü (OGM), 2021. Orman İstatistikleri Yıllığı 2020. Ankara.
- Van Der Walt, S., Colbert, S. C., Varoquaux, G., 2011. The NumPy array: a structure for efficient numerical computation. *Computing in science engineering*, 13(2), 22-30.
- Vega-Nieva, D. J., Briseño-Reyes, J., Nava-Miranda, M. G., Calleros-Flores, E., López-Serrano, P. M., Corral-Rivas, J. J., Preisler, H. K., 2018. Developing models to predict the number of fire hotspots from an accumulated fuel dryness index by vegetation type and region in Mexico. *Forests*, 9(4), 190.
- Vhengani, L., Frost, P., Lai, C., Booii, N., van den Dool, R., Raath, W., 2015, July. Multitemporal burnt area mapping using Landsat 8: merging multiple burnt area indices to highlight burnt areas. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 4153-4156). IEEE.
- Wang, Z., Sassen, K., Whiteman, D. N., Demoz, B. B., 2004. Studying altocumulus with ice virga using ground-based active and passive remote sensors. *Journal of Applied Meteorology and Climatology*, 43(3), 449-460.
- Warsaw, B., Hylton, J., Goodger, D., Coghlan, N., 2011. PEP 1-PEP purpose and guidelines. *Python Enhancement Proposals. Python Software Foundation. Retrieved, 19.*

- Wasser, L., Joseph, M. B., McGlinchy, J., Palomino, J., Korinek, N., Holdgraf, C., Head, T., 2019. EarthPy: A Python package that makes it easier to explore and plot raster and vector data using open source Python tools. *Journal of Open Source Software*, 4(43), 1886.
- Weng, Q., 2009. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. *ISPRS Journal of photogrammetry and remote sensing*, 64(4), 335-344.
- Williams, D. L., Goward, S., Arvidson, T., 2006. Landsat: yesterday, today, and tomorrow. *Photogrammetric Engineering Remote Sensing*, 72(10), 1171-1178.
- Wong, T. T., Yang, N. Y., 2017. Dependency analysis of accuracy estimates in k-fold cross validation. *IEEE Transactions on Knowledge and Data Engineering*, 29(11), 2417-2427.
- Wong, T. T., Yeh, P. Y., 2019. Reliable accuracy estimates from k-fold cross validation. *IEEE Transactions on Knowledge and Data Engineering*, 32(8), 1586-1594.
- Woodhouse, I. H., 2005. *Introduction to microwave remote sensing*. CRC press.
- Wu, Z., Middleton, B., Hetzler, R., Vogel, J., Dye, D. (2015). Vegetation burn severity mapping using Landsat-8 and WorldView-2. *Photogrammetric Engineering Remote Sensing*, 81(2), 143-154.
- Yıldız H, Mermer A, Ünal E, Akbaş F 2012. Türkiye Bitki Örtüsünün NDVI Verileri ile Zamansal ve Mekansal Analizi. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 21(2): 50-56
- Zhang, J., Zheng, Y., Qi, D., 2017. Deep spatio-temporal residual networks for citywide crowd flows prediction. In: *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*. AAAI Press, pp. 1655-1661.
- Zhang, T., Song, S., Li, S., Ma, L., Pan, S., Han, L., 2019. Research on gas concentration prediction models based on LSTM multidimensional time series. *Energies*, 12(1), 161.
- Zheng, X., Chen, F., Lou, L., Cheng, P., Huang, Y., 2022. Real-Time Detection of Full-Scale Forest Fire Smoke Based on Deep Convolution Neural Network. *Remote Sensing*, 14(3), 536.
- Zhu, Z., Woodcock, C. E., Olofsson, P., 2012. Continuous monitoring of forest disturbance using all available Landsat imagery. *Remote Sensing of Environment*, 122, 75-91.

EKLER


Ek A. Haritalar

Ek B. Grafikler




EK A. HARİTALAR

Şekil A.1’de Fethiye ilçesine ait 31 Temmuz 2021 tarihinde başlayan orman yangının olduğu NDVI görüntüsü gösterilmektedir.




Şekil A.1. Fethiye NDVI görüntüsü

Şekil A.2’de Fethiye ilçesine ait 31 Temmuz 2021 tarihinde başlayan orman yangının olduğu Şekil A.1’deki NDVI görüntüsünün renklendirilmiş hali gösterilmektedir. Burada kırmızı alanlar bitki örtüsünün yok olduğu veya topraklaşmış olan alanları, sarı renkli alanlar ise hasarlı bitki örtülerini gösterilmektedir. Görüntüde maviyle gösterilen yerler su yüzeylerini, yeşil alanlar ise sağlıklı bitki örtüsü gösterilmektedir.




Şekil A.2. Fethiye NDVI renklendirilmiş görüntüsü

Şekil A.3'te Manavgat ilçesine ait yangının olduğu tarihlerde NDVI görüntüsü gösterilmektedir. Haritada görülen kırmızı alanlar bitki örtüsünün yok olduğu veya topraklaşmış olan alanları, sarı renkli alanalar ise hasarlı veya sağlıklı bitki örtülerini göstermektedir. Görüntüde maviyle gösterilen yerler su yüzeylerini, yeşil alanlar ise sağlıklı bitki örtüsünü göstermektedir.




Şekil A.3. Manavgat NDVI görüntüsü

Şekil A.4'te Manavgat bölgesinde çıkan orman yangınından önce, Şekil A.2'deki gösterilen bölge ile aynı olup 29 Haziran 2021 tarihli çekilen uydu görüntüsünün NDVI analizi gösterilmektedir. Burdaki görüntüde bitki örtüsünün durumu hakkında bilgilenmekteyiz. Bitki örtü yoğunluğu çoğunlukla sarı renkte görülmektedir. Bitkilerin çoğunluğu hasarlı ya da sağlıklı olmayan bitki örtüleri olduğunu görmekteyiz.



Şekil A.4. Manavgat yangın öncesi NDVI görüntüsü

Şekil A.5'te Köyceğiz ilçesine ait yangın söndürölme çalışmaları bittikten hemen sonra çekilen uydu görüntüsünün NDVI görüntüsü gösterilmektedir. Haritada görülen kırmızı alanlar bitki örtüsünün tamamen yok olduđu veya toprak yüzeyini gösterilmektedir. Sarı alanlar hasarlı veya sağlıklı olan bitki örtülerini göstermektedir. Görüntüde maviyle görülen yerler su yüzeylerini, yeşil alanlar ise sağlıklı bitki örtüsü göstermektedir.



Şekil A.5. Köyceğiz NDVI görüntüsü

EK. B. GRAFİKLER

Çizelge B.1. Manavgat 31 Temmuz 2021 tarihli analizi

LST	NDVI	Sınıflandırma	NDVI sınıflandırması	Bağıl nem	Sıcaklık	Rüzgâr hızı
69,6837	0,12373	Fire	hasarlı bitki örtüsü	13	41	11
69,6647	0,12376	Fire	hasarlı bitki örtüsü	13	41	11
69,453	0,12431	Fire	hasarlı bitki örtüsü	13	41	11
69,5346	0,11531	Fire	hasarlı bitki örtüsü	13	41	11
69,6317	0,10789	Fire	hasarlı bitki örtüsü	13	41	11
69,5988	0,11028	Fire	hasarlı bitki örtüsü	13	41	11
69,6387	0,11807	Fire	hasarlı bitki örtüsü	13	41	11
69,6161	0,11938	Fire	hasarlı bitki örtüsü	13	41	11
65,6612	0,44069	No Fire	sağlıklı bitki örtüsü	13	41	11
66,5219	0,34121	No Fire	sağlıklı bitki örtüsü	13	41	11
67,0633	0,42457	No Fire	sağlıklı bitki örtüsü	13	41	11
58,7223	0,66517	No Fire	çok sağlıklı bitki örtüsü	13	41	11
59,0853	0,72604	No Fire	çok sağlıklı bitki örtüsü	13	41	11

Çizelge B.2. Fethiye 31 Temmuz 2021 tarihli analizi

LST	NDVI	Sınıflandırma	NDVI sınıflandırması	Bağıl nem	Sıcaklık	Rüzgâr hızı
67,3466	0,16174	Fire	hasarlı bitki örtüsü	16	42	24
67,3026	0,18475	Fire	hasarlı bitki örtüsü	16	42	24
64,8798	0,24778	Fire	hasarlı bitki örtüsü	16	42	24
65,0225	0,23316	Fire	hasarlı bitki örtüsü	16	42	24
65,2897	0,25165	Fire	hasarlı bitki örtüsü	16	42	24
65,7766	0,22472	Fire	hasarlı bitki örtüsü	16	42	24
66,3063	0,26115	Fire	hasarlı bitki örtüsü	16	42	24
66,8272	0,23561	Fire	hasarlı bitki örtüsü	16	42	24
63,7825	0,3314	No Fire	sağlıklı bitki örtüsü	16	42	24
68,1829	0,33006	No Fire	sağlıklı bitki örtüsü	16	42	24
67,8205	0,34303	No Fire	sağlıklı bitki örtüsü	16	42	24
67,9606	0,46254	No Fire	sağlıklı bitki örtüsü	16	42	24