

Orman yangını yönetiminde Google Earth Engine (GEE) ve Python Engine (PE) ile yakıt yükü analizi: Karşılaşılan güçlükler ve sağlanan avantajlar

Muhammed Çetin^{1*} 

¹Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Coğrafya Bölümü, Bursa, Türkiye.

Anahtar Kelimeler

Ekoloji
Orman
Coğrafi Bilgi Sistemleri
Google Earth Engine
Yakıt Yükü Haritası

Araştırma Makalesi

Geliş: 08.05.2025
Kabul: 27.06.2025
Yayınlanma: 29.06.2025



Özet

Yakıt yükü, orman yangını davranışını belirleyen temel unsurlardan biridir. Yangının şiddeti, alev uzunluğu ve yakıt tüketimi gibi dinamikler doğrudan bu parametreye bağlıdır. Ancak geleneksel saha ölçümleri büyük alanlarda tekrarlandığında yüksek maliyet ve zaman kaybı yaratmaktadır. Uzaktan algılama (UA) teknolojileri bu sınırlamaları aşarak geniş alanlarda hızlı ve etkin yakıt yükü tahmini imkânı sunmaktadır. Bu çalışmada, 2021'de Manavgat'ta meydana gelen mega yangın örneği üzerinden Google Earth Engine (GEE) platformu ve Sentinel-2 multispektral görüntüleri kullanılarak yangın öncesi ve sonrası yakıt yükü davranışı analiz edilmiştir. Normalize Fark Bitki Örtüsü (NDVI) ve Normalize Yanma Oranı (NBR) indeksleri kullanılarak, Rothermel modeline uygun yüzey yakıt yükü haritaları oluşturulmuş; bulut örtüsü %20'nin altında olan görüntülerden zaman serisi bazı medyan kompozitler elde edilmiştir. Google Colab ortamında Python diliyle yürütülen analizlerde betimleyici istatistikler ve meta-analiz yöntemleriyle veri tutarlılığı sağlanmıştır. Örnekleme yöntemiyle belirlenen noktadaki NDVI ve NBR değerleri dört sınıfa ayrılmış ve yangın davranışı modellerine doğrudan veri sağlamıştır. NDVI ve NBR değerleri, persentile sınıflandırmasıyla “Düşük” (< %20), “Orta” (%20–50), “Yüksek” (%50–80) ve “Çok Yüksek” (> %80) olarak gruplandırılmış; bu ayrım Rothermel denkleminin parametrelerine doğrudan girdi sağlamıştır. Ayrıca yangın öncesi kuraklık dinamiklerini incelemek amacıyla Bitki Örtüsü Durumu Endeksi (VCI) ve Bitki Örtüsü Kuraklık Şiddeti İndeksi (SDVI) analizleri yapılmıştır. Sonuçlar, bu mekânsal yaklaşımın yangın öncesi müdahale planlamasında karar vericilere güçlü bir öngörü sunduğunu göstermektedir.

Fuel load analysis with Google Earth Engine (GEE) and Python Engine (PE) in forest fire management: Challenges and benefits

Keywords

Ecology
Forest
GIS
Google Earth Engine
Fuel Load Map

Research Article

Received: 08.05.2025
Accepted: 27.06.2025
Published: 29.06.2025

Abstract

Fuel load is one of the fundamental factors determining forest fire behavior. Dynamics such as fire intensity, flame length, and fuel consumption are directly related to this parameter. However, while traditional field measurements provide detailed data, repeating these processes over large areas leads to high costs and time loss. Remote sensing (RS) technologies overcome these limitations by enabling rapid and effective fuel load estimation over wide regions. In this study, the fuel load dynamics before and after the 2021 Manavgat megafire were analyzed using the cloud-based Google Earth Engine (GEE) platform and Sentinel-2 multispectral imagery. Maps of surface fuel load were generated in accordance with the Rothermel model by utilizing the Normalized Difference Vegetation Index (NDVI) and Normalized Burn Ratio (NBR); median composites were created from time-series data with cloud coverage below 20%. Descriptive statistics and meta-analysis techniques were applied using Python in the Google Colab environment to ensure data consistency. NDVI and NBR values at sampling points were classified into four groups to directly support fire behavior models. These values were grouped by percentile classification as “Low” (< 20%), “Moderate” (20–50%), “High” (50–80%), and “Very High” (> 80%), providing direct input to the Rothermel equation parameters. Additionally, to assess pre-fire drought dynamics, analyses of the Vegetation Condition Index (VCI) and the Vegetation Drought Severity Index (SDVI) were conducted. The results demonstrate that this integrated spatial approach offers strong predictive power for decision-makers in pre-fire intervention planning.

1. Giriş

Biyosfer içerisinde önemli bir konuma sahip olan ormanlar, yerküredeki oksijenin üçte ikisinin üretiminde canlı yaşamı için önemli bir çevresel kaynaktır (Bowman vd., 2020; McKinley vd., 2011; Pan vd., 2024). Bununla birlikte ormanlar, fotosentez yoluyla büyük miktarda karbondioksiti emerek su döngüsünün yönetiminde ve bölgesel iklimlerin şekillenmesinde de belirleyici bir rol üstlenmektedirler (Psistaki vd., 2024). Ancak antropojenik baskıların (arazi kullanım değişiklikleri, yasa dışı kesimler, su döngüsü değişimleri vb.) yanı sıra doğal faktörlerin de etkisiyle orman ekosistemlerinde geri döndürülemez parçalanmalarda artışlara bağlı olarak karbon tutulumlarında dalgalanmalar dikkat çekmektedir (Bosela vd., 2024); Hansen vd., 2013).

Bu durum, biyolojik çeşitlilik için derin bir tehdit oluşturarak ekosistem direncini zayıflatan bir süreç evrilmiştir (Díaz vd., 2019). Şüphesiz birbiri ardınca süregelen bu bozulmalar mikrobiyal çeşitlilikten toprak fonksiyonlarına kadar birçok biyotik stres eğilimine neden olmaktadır (Laurance vd., 2011). Örneğin iklimsel dengeleyiciler olarak ekvatorial yağmur ormanları biyomu incelendiğinde bölgede son yıllarda eski ormanların hızlı kaybı ve parçalanması tropikal biyoçeşitliliğe yönelik en büyük tehditlerden birisi olarak değerlendirilmektedir (Lovejoy vd., 1986).

Ayrıca bozulmaların mekânsal dağılımı ve zamansal hızı, ekosistemlerin kritik eşikleri (*tipping points*) aşmasına neden olarak kalıcı değişimlere yol açmaktadır. Bu süreç, ormanların "rejim kayması" (*regime shift*) adı verilen bir fenomenle, iklimi düzenleyen bir sistemden, karbon salınımını artıran ve iklim krizini besleyen bir kaynağa dönüşmesine sebep olmuştur (Scheffer vd., 2001). Bu açıdan bozulmanın etkileri yalnızca ağaçlar ve bitki örtüsü gibi görünür biyokütleyle sınırlı kalmayıp, orman tabanındaki mikroorganizmaların (örneğin mikorizal mantarlar) toprak-karbon döngüsündeki rolünü bozarak yeraltı ekosisteminde de geri dönüşü zor hasarlara neden olmuştur (Van Der Heijden vd., 2008).

Orman yangınları fenomeni ise bu çerçevede ekosistemler üzerinde hem yıkıcı hem de yenileyici bir ikili role sahiptir (Sivrikaya vd., 2024). Bu yangınlar, belirli bitki türlerini seçici olarak destekleyerek (örneğin yangın sonrası çimlenen tohumlara sahip türler) istilacı türlerin yayılmasını kolaylaştırarak bitki örtüsünün bileşimini, yapısal karmaşıklığını ve işlevsel dinamiklerini radikal bir şekilde değiştirebilir. Fakat, bu değişim her zaman olumsuz değildir. Örneğin Akdeniz iklimi gibi yangına adapte olmuş ekosistemlerde, periyodik yangınlar biyolojik çeşitliliği korumak ve habitat sağlığını sürdürmek için kritik bir rol oynar. Bu doğrultuda yangınların oluşturduğu "*mozaik peyzajlar*", farklı yaşam evrelerindeki bitki topluluklarını bir arada barındırarak besin döngüsünü hızlandırır ve karbon depolama kapasitesini optimize eder (Flannigan vd., 2000; Mooney, 1981). Buna rağmen, iklim değişikliği ve insan müdahaleleri sonucunda kontrolsüz artan yangın şiddeti, ekosistemlerin bu adaptasyon kapasitesini aşarak geri dönüşü zor kayıplara yol açmıştır (Pausas & Keeley, 2019).

Günümüzde küresel iklim değişikliği, kentleşme ve arazi kullanımındaki çeşitli dönüşümler, bu yangın rejimlerinin dengesini bozarak tehlikeli boyutlara ulaşmasına neden

olmaktadır (Datta, 2021). Araştırmalar, 1980'lerden bu yana yangın sıklığında %27, yanan alan büyüklüğünde ise %41'lik istatistiksel olarak anlamlı bir artış olduğunu göstermektedir (Bowman vd., 2019). Bu durum, yangınların artık doğal bir ekosistem düzenleyicisi olmaktan çıkıp toplum sağlığını, ekonomik istikrarı ve ekolojik dengeyi tehdit eden küresel bir risk faktörüne dönüştüğünü ortaya koymaktadır (Carmona-Moreno vd., 2005).

Son zamanlarda yapılan iklim araştırmaları incelendiğinde küresel ölçekte yangın mevsimlerinin dünya genelinde uzadığını ve yangın hava koşullarının şiddetinin arttığı görülmektedir (Jolly vd., 2015). Bu nedenle, yıkıcı yangın risklerini önleme ve etkilerini azaltma amacıyla, orman yangınlarının etkin yönetimi ve erken uyarı sistemlerinin geliştirilmesi için yüksek çözünürlüklü ve neredeyse gerçek zamanlı yangın tehlike değerlendirmeleriyle kritik önem taşımaktadır (Özcan vd., 2024). Çünkü geleneksel yangın tehlikesi değerlendirme sistemleri, temel olarak meteorolojik parametrelere (sıcaklık, bağıl nem, rüzgâr hızı ve yağış) odaklanmaktadır. Diğer bir deyişle, orman yangını tehlikelerini ve davranışını anlamak, yangın çevresi üçgenindeki yakıt ve topoğrafya faktörlerini içermeyi gerektirir (Countryman, 1972).

Bu kapsamda BehavePlus (Andrews, 2007) ve FARSITE (Finney, 1998) gibi yangın modelleme sistemleri, yakıt özellikleri, topoğrafya ve hava durumu verilerini birleştirerek yangın davranışını tahmin etmede önemli bir gelişme sağlamıştır. Bu modeller sayesinde, son yıllarda yangınların nasıl başlayacağı ve yayılacağı konusunda daha doğru tahminler yapılabilmekte ve yangın ekolojisi araştırmaları hem zamansal hem de mekânsal açıdan derinlik kazanmıştır (Yebra vd., 2018). Böylece bu yakıt özelliklerinin gerçekçi mekânsal ve zamansal tahminleri, yangın yöneticilerine, belirli yakma uygulamaları ve aktif olaylar sırasında daha etkili yangın yayılma tahmini ile büyük ölçekli yangın risklerini azaltmalarında yardımcı olmaktadır (Alexander & Cruz, 2006).

Yangın ekolojisindeki söz konusu gelişmelere rağmen, uzaktan algılama yöntem ve teknikleri kullanımının yaygınlaşmasıyla geleneksel yangın yönetimine göre daha bütüncül yakıt yönetimi ve bileşimi yaklaşımları yeni yangın çağına vazgeçilmez araçlarından birisi olarak halen yerini korumaktadır (Miller & Urban, 2000; Viegas vd., 2013). Yakıt sınıflandırma sistemleri burada, yangın yönetiminde kritik bir rol oynayarak yakıt tiplerinin bilimsel kriterlere göre sınıflandırılması, yakıt özelliklerinin nicel olarak ölçümü, üç boyutlu yakıt dağılımlarının gösterilmesinde, yangın davranışı modellemesinde temel veri kaynağı sağlamaktadır (Ottmar vd., 2007; Rothermel, 1972). Ancak yapılan araştırmalar, yangın modelleme çalışmalarında yerel olmayan veri kullanımının önemli hatalara yol açabileceğini göstermektedir (Lopes Queiroz vd., 2019). Bu durum başta topografik yapı ve mikro iklim koşullarının bölgeden bölgeye değişiklik göstermesinin yanı sıra, farklı bölgelerden alınan standart verilerin yerel koşulları yansıtmaması, genelleştirilmiş yakıt modellerinin gerçek yanıcı madde dağılımını tam anlamıyla temsil edememesi gibi koşullara bağlı olarak farklı sonuçlar doğurmaktadır. Sonuç olarak yangın modelleme çalışmalarında mümkün olduğunca yerel ölçümlerin ve bölgeye özgü verilerin kullanılması büyük önem taşımaktadır. Özellikle yakıt örnekleme çalışmaları ve lokal meteorolojik veri toplama

sistemleri, simülasyonların doğruluğunu artırmak için vazgeçilmezdir.

Yakıt yükleri katmamsal yapısı itibarıyla orman yangınlarının davranış biçimlerini anlamada önemli bir yapıya sahip olup, yanma esnasındaki yakıt birikim hızı, ayrışma oranı yakıtın eklenme oranındaki dengenin de bir fonksiyonu olarak tanımlanmaktadır (Agee vd., 1973). Örneğin, ormanlardaki yangınlardan sonra, yakıt genellikle hızlı ve sürekli bir şekilde birikir ve ardından birikim hızı yavaş yavaş denge seviyesine düşer (Olson, 1963). Bu nedenle, yakıt yükleri, arazi yönetimi karar verme süreçlerinde uygulanmış olan yakıt birikim modelleri kullanılarak tahmin edilebilir ve öngörülebilir (Jurskis, 2005) bir kolaylık sağlar.

Bu doğrultuda bu çalışma, orman yangınlarının dinamiklerini ve ekosistem üzerindeki etkilerini anlamak üzere yakıt yükü tahmin modellerinin mevcut eksikliklerini incelemeyi, uzaktan algılama yöntem ve teknikleriyle yer ölçümlerinin entegrasyonunun yangın yönetim stratejilerine katkısını değerlendirmeyi ve Google Earth Engine (GEE), Python Engine (PE) gibi platformların yakıt yükü modellenmesinde sağladığı yüksek çözünürlüklü analiz kapasitesini ekosistem dinamikleri bağlamında test etmeyi amaçlamaktadır. Buna göre nicel veri analizini takiben Sistematik Literatür Taraması (SLR) entegrasyonunda şu hipotezler oluşturulmuştur:

- **H1:** Mevcut yakıt yükü modelleri (BehavePlus, FARSITE vb.) yakıt katmanları arasındaki dinamik etkileşimleri, mekânsal heterojeniteyi ve iklim değişikliğinin yakıt birikimine etkilerini ortaya koymada kolaylık sağlamasına rağmen; zaman zaman mega yangın davranışı tahminlerinde belirsizliklere ve yönetimsel açıkların ortaya çıkmasına yol açmaktadır? hipotezi ilgili literatür boşluklarından hareketle değerlendirilmiş ve stratejik yakıt modelleme teknikleri eşliğinde sınıflandırılmıştır.

- **H2:** Uydu verisi ile yer tabanlı ölçümlerin entegrasyonu, yakıt yükü tahminlerinde Rothermel yangın yayılım modelinin proaktif yaklaşımını nasıl desteklemektedir? Hipotezi yakıt nemi ve topoğrafya faktörlerinin gerçek zamanlı etkileşimi düzeyinde modellenerek açıklanmaya çalışılmıştır.


- **H3:** GEE'nin orman yangınlarında yakıt yükü tahmininde kapasitesi, ekosistem dinamiklerini anlamadaki kabiliyet ve becerisi nasıldır? Hipotezi doğrulamasında ise amaçlı örneklem çerçevesinde yangın riskinin yüksek olduğu başlıca örnek alanlar GEE işlevleri (ör. imageCollection.filterDate, reduceRegion, sampleRegions) ile belirlenerek entegre indeks kütüphaneleri ile analiz edilmiştir.

2. Materyal ve Yöntem

2.1. Çalışma alanının yeri ve özellikleri

Çalışma alanı, Antalya ilinin Manavgat ilçesi sınırlarında ve yaklaşık 36.000 ha orman alanına sahip, 31°19'54" ve 31°35'00" Doğu boylamları ile 36°50'46" ve 37°1'35" Kuzey enlemleri arasında yer almaktadır (Şekil 1). Bu alanın seçilmesinde orman yangınlarının sıklıkla meydana geldiği, yangına hassas bir ekolojik bölge olması yanı sıra zengin tür çeşitliliğine sahip olması önemli bir rol oynamıştır. Çalışma alanı yüksekliği yaklaşık olarak deniz seviyesinden başlamakta olup 2700 m'ye kadar ulaşır. Çalışma alanının litostratigrafik yapısı büyük ölçüde kalkerli bir yapıda

gelişmiştir. Alanın ortalama sıcaklık değişimleri 18.6 °C ve ortalama yağış miktarı 1089,6 mm'dir. Çalışma alanında bulunan bitki türlerinin başında kızılçam (*pinus brutia*), karaçam (*Pinus nigra*), fıstıkçamı (*Pinus pinea*), servi (*Cupressus sempervirens*), sedir (*Cedrus libani*), toros göknarı (*Abies cilicica*), kokulu ardıç (*Juniperus foetidissima*), boylu ardıç (*Juniperus excelsa*), andız (*Juniperus drupaceae*), katran ardıcı (*Juniperus oxycedrus*), Kermes meşesi (*Quercus coccifera*), Saçlı meşe (*Quercus cerris*), Lübnan meşesi (*Quercus libani*), saplı meşe (*Quercus robur*), defne (*Laurus nobilis*) ve çınar (*Platanus orientalis*) gelmektedir (Güney vd., 2015).




Şekil 1. Çalışma alanı yeri ve sınırları

2.2. Örneklem alanı arazi kullanım özellikleri


Şekil 2 incelendiğinde Avrupa Uzay Ajansı tarafından üretilen 10 m çözünürlüklü küresel arazi örtüsü veri seti Sentinel-1 ve Sentinel-2'ye dayanmaktadır. Bu veri setine göre, çalışma alanının %57,68'i ağaç örtüsü, %7,47'si çalılık, %18,43'ü mera, %7,12'si tarım arazisi, %1,9'u binalar, %6,46'sı çıplak/seyrekle bitki örtüsü, %0,85'i kalıcı su kütelleri ile kaplı ve %0,09'u otsu sulak alan ile kaplı durumundadır.

2.3. Örneklem alanı yerleşim yerlerine uzaklık

Şekil 3 incelendiğinde yangın hızının yayılımında, orman yangınların meydana gelmesinde önemli bir yere sahip olan yerleşim yerleri ve yoldan uzaklık en önemli beşeri kaynaklı faktörlerdendir (Adab vd., 2013). Ayrıca bilindiği üzere yerleşim yerlerine yakın orman alanları ve meralar yangına daha yatkın olmakla birlikte yerleşim yerlerinde yaşayan insanlar çeşitli etkinlikler nedeniyle yangınlara neden olmaktadır (Jaiswal vd., 2002). Bu noktada yüksek nüfus yoğunluğu, insan kaynaklı yangınlara neden olurken, bitki örtüsü yapısını değiştirir ve yanıcı malzeme miktarını azaltarak yangın olasılığını düşürmektedir. Bu açıdan çalışma alanındaki yerleşimlere olan mesafe 0 ile 12,133.34 m arasında değişmektedir. Konut alanlarına olan mesafe 10 alt sınıftan oluşmaktadır (0–250, 250–500, 500–1000, 1000–2000, 2000–3000, 3000–4000, 4000–5000, 5000–6000, 6000–7000, 7000–12,133.34 m; (Akıncı & Akıncı, 2023).




Şekil 2. Örneklem alanı arazi kullanım haritası (Akıncı & Akıncı, 2023'den yeniden düzenlenerek).



Şekil 3. Örneklem alanı yangın-yerleşim yerlerine uzaklık haritası (Akıncı & Akıncı, 2023'den yeniden düzenlenerek).


2.4. Araştırma deseni

Bu çalışmada öncelikle çalışmanın metodolojik bağlamını kuvvetlendirmek amacıyla uzaktan algılama teknolojisinin çeşitli yakıt türleri arasında farklı yakıt katmanlarından yakıt yükünü tahmin etmek için nasıl kullanıldığı? sorusundan hareketle kavramsal ve kuramsal çerçevede SLR bileşenli literatür analizi gerçekleştirilmiştir. Bu aşamada “Yakıt yükü ve uzaktan algılama” anahtar kelimeleri paralelinde literatür haritalaması ve atıf ağlarının görselleştirilmesi için “Litmaps” yazılımı kullanılmıştır (Şekil 4). Çünkü araştırma sorularının belirlenmesi ve literatürdeki boşlukların tespiti amacıyla, literatür taramasında Litmaps’in dinamik atıf ağı son yıllarda tercih edilen bir haritalamadır (Kaur vd., 2022). Diğer bir deyişle Litmaps, açık bir eğitim ağı kaynağıdır (Colvard vd., 2018; Ikahihifo vd., 2017).



Şekil 4. Literatür ağı özeti

Bu noktada literatür ağı özeti ortaya koyulmasını takiben orman yangınlarının önlenmesi ve yönetimi kapsamında yakıt yükünün zamansal ve mekânsal sınırlılığı nasıl olmalıdır? Araştırma problemini takiben Merriam kodlarından oluşturulan (Şekil 5)'de verilen iş-akış şeması oluşturulmuştur. Merriam kodları temel sentaks dizinde Javascript programı temelinde dinamik bir diyagram ve grafik oluşturma aracıdır.



Şekil 5. Çalışmanın birleşik (covergent paralel) karma yöntemler deseni (Creswell & Plano Clark, 2017)

Daha sonra çalışmada, CORINE arazi-kullanım örtüsü, (European Environment Agency, 2018), Sentinel-2 tabanlı NDVI, MODIS TERRA platformuna ait NCV ve SDVI indeks verileri kullanılmıştır. CORINE verileri Avrupa Çevre Ajansı (European Environment Agency) tarafından, Avrupa çevresi hakkında nesnel, hedefe dayalı bir arazi örtüsü sağlamaktadır. Bu veriler, uydu görüntülerinin manuel vektörizasyonu ile oluşturulmaktadır. Türkiye’de ilk kez 2000 ve 2006 yılları arasında arazi örtüsü verileri üretilmiş olup, ardından 2012-2018’de geriye dönük olarak 1990 yılı arazi kullanım-örtüsü şeklinde üretilmiştir.

Manuel veri işleme uzun zaman alıcı, kullanıcı kabiliyetine bağlı olarak türetilmesine rağmen farklı kullanıcı verilerinin birleştirilmesiyle oluşturulmaktadır. Bu yüzden bilhassa 2000 ve 2006 yılı Türkiye tabanlı arazi örtüsü verileri, ülke çapında aynı duyarlılıkla yapılmayıp aynı arazi örtüleri farklı sınıflarla tanımlanmıştır (Özcanlı & Yılmaz, 2024).

Bu çalışmada, orman yangını yönetiminde uzaktan algılama temelli yakıt yükü analizinin Google Earth Engine (GEE) ortamında gerçekleştirilmesini konu edinmiş ve bu kapsamda hem nicel hem de nitel verileri içeren bir yaklaşım benimsemiştir. Araştırmada, Sentinel-2 uydu verileri kullanılarak NDVI ve NBR (Normalized Burn Ratio) gibi spektral indeksler hesaplanmış; bunlardan elde edilen verilerle yakıt yükü tahmini yapılmıştır. Ayrıca, Rothermal yangın davranış modeli yardımıyla yangının yayılma potansiyeli ve risk düzeyi simüle edilmiştir. Tüm bu süreçler, nicel veri analizine dayanmaktadır.

Bununla birlikte, çalışmanın sadece sayısal verilerle sınırlı kalmaması amacıyla, uzman görüşleri, alan gözlemleri ve literatür yorumları gibi nitel veri kaynakları da araştırma sürecine dâhil edilmiştir. Bu bağlamda, elde edilen nicel çıktılar, saha verileri ve uzman değerlendirmeleriyle desteklenmiş; böylece analizlerin bağlamsal geçerliliği artırılmıştır.

Bu yönüyle araştırma, karma yöntem araştırma deseni içinde yer almakta olup, Birleşik Karma Yöntem (Convergent Parallel Mixed Methods Design) çerçevesinde yapılandırılmıştır (Dawadi vd., 2021; Fontán-Vela vd., 2021; Kim vd., 2024). Bu desene göre, nicel ve nitel veriler eşzamanlı olarak toplanmış, ayrı ayrı analiz edilmiş ve sonuç aşamasında bütüncül biçimde birleştirilerek yorumlanmıştır. Bu yaklaşım, uzaktan algılama verilerinden elde edilen nesnel çıktılar, alana özgü bağlamsal bilgilerle desteklenmesini sağlayarak, yangın yönetimi açısından daha kapsamlı ve uygulanabilir sonuçlar elde edilmesine olanak tanımıştır.

2.5. Veri kaynakları

Bu çalışmada Python Engine 3 Google Engine (PEGE), Google Earth Engine platformu aracılığıyla orman yangını yönetiminde karşılaşılan yakıt yükü (diri örtü, yüzey örtüsü, ölü örtü) kaynaklı sorunsalına proaktif çözüm önerileri sunulmaya çalışılmıştır. Bu bağlamda amaçlı örnekleme çerçevesinde seçilen Türkiye sınırları içerisinde belirlenen örnek orman yangını riskine duyarlı alanların Manavgat (Antalya) sınırları Open Street Map, ESA verileri kullanılarak tespit edilmiş, daha sonra yakıt yönetimi modelleri çerçevesinde GEE’de Manavgat kıyı kordonunu kapsayacak şekilde NDVI, NBR indeks hesaplamaları yapılmıştır. Araştırma sahası üzerine yapılan analizlerde vejetasyon sezonunun kesintisiz 365 gün sürdüğü göz önüne

alınarak (Kaya, 2024) biyokütle net artışında pozitif ölçekte artışlar gözlemlenmiştir.

GEE platformu, geniş spektral boyutta uydu veri setlerinin hızlı ve verimli bir şekilde indirgenmesi, birleştirilmesi ve analizinde kolaylık sağlamakta olup, araştırmanın Sentinel-2 verileriyle gerçekleştirilmesine uygun bir zemin hazırlamaktadır (Xulu vd., 2021). Sentinel-2 kaynakları Sentinel-2, klorofil içeriği karakterizasyonu için uygun kırmızı kenar bantları da dahil olmak üzere üstün spektral özellikleri sayesinde yanmış alan izleme için cazip bir kaynak potansiyeli taşımaktadır (Puletti vd., 2018). Örneğin "yangın şiddeti" haritalaması için yeni indeksler oluşturma imkânı da sağlamaktadır (Filipponi, 2019). Konuyla bağlantılı ilgili literatür ağı incelendiğinde normalize edilmiş yanma oranı (NBR) kullanarak yanan alan hasarı tespitinde önemli bir ilerleme sağlandığı dile getirilmektedir (Santos vd., 2020).


NBR ise, elektromanyetik spektrumun yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bölgelerini kullanır (Eidenshink vd., 2007). Bu indeks diğer bir ifadeyle bitki örtüsündeki yangınları tespit etmek için uygunluk gösterir. Çünkü NIR’deki değişiklikler genellikle fotosentetik olarak aktif bitki örtüsündeki değişimleri temsil eder; bu da yangınla birlikte azalır ya da SWIR’deki değişikliklerin nem içeriğini yansıtmamasını kolaylaştırır (Keeley, 2009). Dolayısıyla bu çalışmada GEE çerçevesi içinde Sentinel-2 kaynaklı NBR ve dNBR indekslerini kullanarak yakıt yükünü izlemek için hızlı ve uygun maliyetli bir yöntem sunulmaya çalışılmıştır.

2.6. Veri analiz yöntemleri

Bu çalışmada orman yangını yönetiminde yakıt yükü analizinin izlenmesinde GEE ve PEGE platformu kullanılarak Sentinel-2 tabanlı NDVI verilerinden hareketle yakıt kullanım sınıfları belirlenmiş ve analizler 2022-2023 yılları arasındaki veri setleriyle sınırlandırılmıştır. Söz konusu veri setleri 2023 yaz verilerinde piksel bulut sorunlarını aşmak amacıyla bulut maskeleme işlemleri yapılarak verinin işlenmesi sağlanmaya çalışılmıştır. Analizler, seçilen arazi kullanım sınıfları, vejetasyon örtüsü kabiliyeti vb. koşullara göre sınıflandırılmıştır.

2.6.1. Çalışma alanının belirlenmesi

Araştırma alanı olarak, örneklem alanı olarak seçilen Manavgat çayı havzası sınırları, GEE üzerinde depolanabilir “projects/tur-dr/assets/Manavgat” veri seti kullanılarak tanımlama yapılmıştır:



2.6.2. Sentinel-2 NDVI verilerinin hazırlanması

Bitki örtüsünün sağlık, yoğunluk gibi fizyolojik özelliklerini belirlemek için Sentinel-2 sensöründen elde edilen NDVI (Normalized Difference Vegetation Index) verileri kullanılmıştır. GEE’de daha sonra mevcut “COPERNICUS/S2_SR” veri seti üzerinden 2023-08-01, 2023-08-31 NDVI verileri aşağıdaki gibi filtrelenmiştir:

```
2 var sentinel2 = ee.ImageCollection('COPERNICUS/S2_SR')
3   .filterDate('2023-08-01', '2023-08-31')
4   .filterBounds(geometry)
5   .median()
6   .clip(geometry);
7 var ndvi = sentinel2.normalizedDifference(['B8', 'B4']);
8 var nbr = sentinel2.normalizedDifference(['B8', 'B12']);
```

Bu adımda, NDVI değerleri 0.0001 ile çarpılarak normalize edilmiştir. Ayrıca, veriler çalışma alanı sınırları içinde olacak şekilde filtrelenmiştir.

2.6.3. NBR verilerinin hazırlanması

Örneklem alanı çevresindeki yanan alan özelliklerini görmek amacıyla “COPERNICUS/S2_SR” veri seti üzerinden NBR verileri aşağıdaki gibi filtrelenmiştir:

```
New Script*
9 var fuelload = ndvi.multiply(nbr).rename('fuel_load');
10 var percentiles = fuelload.reduceRegion({
11   reducer: ee.Reducer.percentile([20, 50, 80]), // %20, %50, %80 percentil
12   geometry: geometry,
13   scale: 10,
14   maxPixels: 1e9
15 });
16
17 var p20 = ee.Number(percentiles.get('fuel_load_p20'));
18 var p50 = ee.Number(percentiles.get('fuel_load_p50'));
19 var p80 = ee.Number(percentiles.get('fuel_load_p80'));
20 var fuelClass = fuelload
```

2.6.4. Yakıt yükü verilerinin hazırlanması

Örneklem alanı çevresindeki diri ve kuru yakıt yüklerinin tespiti ve özelliklerinin belirlemek amacıyla “COPERNICUS/S2_SR” “COPERNICUS/CORINE/v20/100 m/2010” veri seti üzerinden aşağıdaki gibi filtrelenmiştir:

```
New Script*
17 var p20 = ee.Number(percentiles.get('fuel_load_p20'));
18 var p50 = ee.Number(percentiles.get('fuel_load_p50'));
19 var p80 = ee.Number(percentiles.get('fuel_load_p80'));
20 var fuelClass = fuelload
21   .where(fuelload.lt(p20), 1) // Düşük (320-50)
22   .where(fuelload.gte(p20).and(fuelload.lt(p50)), 2) // Orta (50-80)
23   .where(fuelload.gte(p50).and(fuelload.lt(p80)), 3) // Yüksek (80-100)
24 var areaStats = fuelClass.reduceRegion({
25   reducer: ee.Reducer.frequencyHistogram(),
26   geometry: geometry,
27   scale: 10,
28   maxPixels: 1e13
29 });
30
31 var areas = ee.Dictionary(areaStats.get('classification'));
32 var totalArea = geometry.area().divide(1e4); // Toplam alan (ha)
33
34 // Alanları konsola yazdır
35 print('Yakıt Sınıfları (HA):', areas.map(function(key, value) {
36   return ee.Number(value).divide(1e4); // Pikel sayısını ha'ya çevir.
37 }));
38 print('Toplam Alan (HA):', totalArea);
39 Map.centerObject(geometry, 10);
40 Map.addLayer(fuelClass, {
41   min: 1,
42   max: 4,
43   palette: ['green', 'yellow', 'orange', 'red']
44 }, 'Yakıt Yüğü (K)');
```

Yakıt yükünün alansal dağılımındaki farklılıklar dikkate alındığında, sürekli durum yakıt birikim modelleri; saha ölçümlerine başvurmadan veya sabit tablo değerleri kullanmadan, toprak tipi, yakıt türü ve tepe örtüsü yoğunluğu gibi etkenleri dikkate alarak yakıt yükündeki değişimi tahmin edebilir. Bu özellikle yangın geçmişi bilinmeyen alanlarda büyük avantaj sağlar (Bresnahan, 2003). Yapılan araştırmalar, mavi okaliptüs (*Eucalyptus globulus*) ormanlarında ağaç taban alanı ile yüzey kuru yakıt miktarı arasında belirgin bir ilişki olduğunu göstermektedir. Özellikle geniş taç hacmine sahip ağaçların altında daha fazla yaprak/dal biriktiği gözlenmiştir (Agee vd., 1973). Daha yakın tarihli çalışmalar ise istatistiksel yöntemlerle (çok değişkenli regresyon analizi) yüzey örtüsü kaplama oranı ve yakıt derinliği gibi faktörlerin yakıt birikimini nasıl etkilediğini ortaya koymuştur (Gilroy & Tran, 2020).

Uzun vadeli ve büyük ölçekli yer gözlem veya uzaktan algılama teknolojileri sayesinde günümüzde bu tarz farklı ölçekler ve yakıt türleri arasında çeşitli yakıt katmanları için yakıt yükünün sistematik, verimli ve doğru bir şekilde nicelendirilebilmesi için umut verici bir yol sunmaktadır (Forkuor vd., 2020; Rollins vd., 2004). Bu, yangınlar ve fırtınalar gibi ekstremler ve yağış gibi yakıt yüklerini etkileyen faktörlerdeki yıllar arası değişimlerin neden olduğu dinamik koşullarda özellikle önemli olmakla birlikte yakıt yüklerinin uzaktan algılama yoluyla geniş bölgelerde kapsamlı ve yüksek kaliteli yakıt haritalarının sürekli olarak mevcut olmasını sağlamak, yangın yönetim stratejilerine değerli destek sunabilir.

Yakıt yükü hesaplamada yaygın olarak kullanılan bir üstel fonksiyon, yüzey kuru örtü yakıtının hızla sabit bir duruma ulaştığını tanımlamakta kullanılır (Formül 1).

$$w_t = L / (1 - e^{-kt})$$

Burada k'nin ayrışma sabiti olduğu, L'nin durağan koşullar altında biriken yüzey litter yakıt kütlesini temsil ettiği ve w_t'nin t zamanındaki (son yangından bu yana geçen yıllar) yüzey atık yakıt kütlesi olduğu yer karşımıza çıkmaktadır. Bu modelde t (son yangından bu yana geçen yıl sayısı), yakıt yükü birikimini belirleyen tek bağımsız değişkendir; mekânsal farklılıklar (örneğin yakıt yükünün alana göre değişimi) doğrudan ele alınmaz. Ayrıca, bir önceki yangında ne kadar yakıtın tüketildiği, birikim eğrisinin başlangıç değeri (*intersept*) üzerinde kritik bir sınır oluşturur: eğer son yangında çok az yakıt kalmışsa, birikim sıfır yükten değil, daha düşük bir değerden başlar. Sonuç olarak, yakıtın birikim şekli yalnızca çevresel faktörlere, mevcut bitki türlerine ve yangından bu yana geçen zamana bağlı olarak değil, aynı zamanda yanma şiddetine de bağlı olarak değişir (Murphy & Russell-Smith, 2010; Keifer vd., 2006).

2.6.5. ROS model yakıt yükü model hazırlanması

Orman yangını davranış biçimlerini anlama adına geliştirilen ve günümüzde halen yaygın biçimde kullanılan deterministik, matematiksel bir model olan “Rothermel” modeli 1972 yılında bir tür yangın yayılım modelinin (*fire spread model*) temellerini oluşturmaktadır (Rothermel, 1972). Model, yangının yayılma hızını hesaplamak için yakıt yükü, nem içeriği, rüzgâr hızı, eğim, yakıt parçacıklarının boyutu ve dağılımı gibi fiziksel ve çevresel değişkenleri bir araya getirir. Özünde, model yangının enerji üretimini ve bu enerjinin ne kadarının yangının yayılmasına katkı sağladığını tahmin eder. Temel parametreleri ise şu şekildedir:

- **Yakıt karakteristikleri:** İnce yanıcı maddelerin (1-h, 10-h sınıfı) oranı, yükü (kg/m²), yüzey alanı/hacim oranı (SA/V), düzen faktörü.
- **Hava koşulları:** Rüzgâr hızı (özellikle 20-ft seviyesinde), hava sıcaklığı, bağıl nem.
- **Topografya:** Eğimin yangının yönüyle olan ilişkisi.
- **Nem durumu:** Yakıtın nem içeriği, canlı ve cansız ayrımıyla birlikte

Matematiksel yapı çerçevesinde model formül 2’de açıklandığı gibidir:

$$R = \frac{I_R \cdot \epsilon \cdot \phi_w \cdot \phi_s}{P_b \cdot \epsilon \cdot Q_{ig}}$$

Buna göre;

- I_R : Yangının reaksiyon yoğunluğu (*reaction intensity*)
- ϵ : Verimlilik faktörü
- ϕ_w : Rüzgâr düzeltme faktörü
- ϕ_s : Eğim düzeltme faktörü
- ρ_b : Yakıtın bulk yoğunluğu
- ϵ : Isının etkili oran
- Q_{ig} : Tutuşma için gereken ısı miktarı

Bu doğrultuda temel fiziksel parametreler eşliğinde Python 3 Google Compute Engine platformunda temel düzeyde 3D interaktif destekli Antalya merkezli Rothermel

yangın yayılım modeli oluşturulmuştur (Şekil 6). Söz konusu yayılım modeli oluşturulurken izlenen veri kodlamaları Tablo 1’de verilmiştir.

Tablo 1. Rothermal model temsiliyetleri

Bileşen	Açıklama	Rolü
X Eksen	Rüzgâr hızı (mph)	Yangın yayılma hızı
Y Eksen	Eğim derecesi (°)	Yangın davranışı
Z Eksen	Yayılma hızı (ft/dk)	Yangın ilerleme hızı

Basitleştirilmiş Rothermal modeli oluşturma adımları aşağıdaki gibi verilmiştir.

```

!pip install numpy matplotlib folium

import numpy as np
import matplotlib.pyplot as plt
from mpl_toolkits.mplot3d import Axes3D
import folium
import plotly.graph_objects as go
from matplotlib.colors import LinearSegmentedColormap
from IPython.display import display

class WildfireVisualizer:
    def __init__(self):
        # Başlangıç koordinatları (Örnek: Antalya)
        self.fire_origin = [36.8969, 30.7133]
        self.fire_data = None

    def simple_rothermal(self, wind_speed, slope_deg, fuel_moisture):
        """Basitleştirilmiş Rothermal modeli"""
        wind_factor = 0.1 * wind_speed
        slope_factor = 0.05 * slope_deg
        moisture_factor = 0.03 / (fuel_moisture + 0.01)
        return max(0.1, wind_factor + slope_factor + moisture_factor)

    def generate_fire_spread_data(self):
        """3D yangın yayılım verisi oluşturur"""
        # Parametre aralıkları
        wind_speeds = np.linspace(0, 20, 15)
        slopes = np.linspace(0, 30, 15)

        # 3D grid oluştur
        W, S = np.meshgrid(wind_speeds, slopes)
        ros = np.zeros_like(W)

        # ROS değerlerini hesapla
        for i in range(W.shape[0]):
            for j in range(W.shape[1]):
                ros[i,j] = self.simple_rothermal(W[i,j], S[i,j], 0.08)

        self.fire_data = {'wind': W, 'slope': S, 'ros': ros}
        return W, S, ros

    def plot_3d_surface(self):
        """3D yüzey grafiği oluşturur"""

    def plot_3d_surface(self):
        """3D yüzey grafiği oluşturur"""
        if self.fire_data is None:
            self.generate_fire_spread_data()

        fig = plt.figure(figsize=(12, 8))
        ax = fig.add_subplot(111, projection='3d')

        # Yangın şiddeti için özel renk haritası
        fire_cmap = LinearSegmentedColormap.from_list('fire', ['green', 'yellow', 'orange', 'red'])


        surf = ax.plot_surface(
            self.fire_data['wind'],
            self.fire_data['slope'],
            self.fire_data['ros'],
            cmap=fire_cmap,
            edgecolor='none',
            alpha=0.8)

        ax.set_xlabel('Rüzgâr Hızı (mph)', fontsize=12)
        ax.set_ylabel('Eğim (derece)', fontsize=12)
        ax.set_zlabel('Yayılma Hızı (ft/dak)', fontsize=12)
        ax.set_title('3D Yangın Yayılım Modeli (Rothermal)', fontsize=14)

        fig.colorbar(surf, shrink=0.5, aspect=5, label='Yayılma Hızı')
        plt.tight_layout()
        plt.show()

```

Şekil 6 incelendiğinde yapısal düzeyde modelin anatomisi Tablo 2’de, fiziksel dinamikleri Tablo 3’te, kritik eşik değerleri Tablo 4’te, model sınırlamaları Tablo 5’te, operasyonel çıkarımlar Böylece taktik karar desteği ve risk haritalama düzeyinde sağlam bir eğitsel pedagojik araç sunulmaya çalışılmıştır karar vericiler için.



Şekil 6. Basitleştirilmiş örnek bir Rothermal yangın yayılım modeli.

Tablo 2. Modelin yapısal düzeyde anatomik gösterimi

Bileşen	Teknik Detay	Yangın Dinamiği Açıklaması
X Eksen	0-20 mph aralığı	10 mph+ rüzgâr yayılma hızı
(Rüzgâr)		
Y Eksen	0-30 °eğim	15° sonrası ROS’a kadar azalma
(Eğim)		
Z Eksen (ROS)	0-5ft/dk	Tehlikeli seviye
Renk Skalası	Mavi (0) → Sarı (2.5)	Kritik yayılma zonu
	→ Kırmızı (5)	

Tablo 3. Modelin fiziksel dinamikleri

Bölge	Matematiksel İlişki	Fiziki Boyut
Düşük	$ROS \propto 0.1 \times W$	Rüzgârın oksijen taşıması
Rüzgâr	$ROS \propto e^{(0.15 \times W)}$	Rüzgârın ısı transferi
Dik	$ROS \propto \tan(\text{slope})$	Alev dili ve ısı yayılımı artışı
Eğimler		
Nem		%10 nem azalımı ROS kritiği
Etkisi		

Tablo 4. Modelin kritik eşik değerleri

Parametre	ROS Değeri	Yangın Davranışı
Kombinasyonu		
15 mph + 20° eğim	3.2 ft/dak	“Torç etkisi” gelişme
5 mph + 30° eğim	2.1 ft/dak	Dominant yayılma
20 mph + 10° eğim	4.7 ft/dak	Dominant yayılma

Tablo 5. Modelin sınırlamaları

Gerçeklik	Simülasyon Yaklaşımı	Farklar
Faktörü		
Yakıt Heterojenliği	Tek tip yakıt kabulü	13 farklı NFDRS yakıt
Rüzgâr Türbülansı	Sabit rüzgâr yönü	mikro-türbülans
Topografya Etkisi	Tek boyutlu eğim	vadi dinamikleri

2.3.6. Veri değerlendirme

Elde edilen NDVI/NBR ve CORINE verileri GEE portalında tematik sınıflandırmalar doğrultusunda grafikler ve haritalar aracılığıyla görselleştirilmiştir. Ayrıca betimsel istatistiksel yöntemler çerçevesinde NDVI/NBR kombinasyonları çerçevesinde mevcut verilere istatistik bir anlam katabilmek için tablo, histogram, kovaryans matrisi gibi görselleştirmeler de yapılmıştır.


3. Bulgular

Çalışmanın bu bölümünde örneklem alanı olarak belirlenen Manavgat (Antalya) merkezli kapsamlı jeo-mekansal veri setlerinden elde edilen bulguların sistematik bir değerlendirmesi, yakıt yükü tanımlaması ve orman yangınları davranışlarının uzamsal boyutu, UA yöntemleriyle yakıt yükü analizinin tahmin model sonuçları bu bölümde sunulmuştur. Araştırmada kullanılan ısı haritaları, eğim, yükselti, bakı, rüzgâr hızı kaynaklı yangın davranışı ve yakıt yükü tahmini sağlamaya yönelik yapısal değişimler yangın şiddeti ve derinliğini anlama ve yorumlama da kantitatif bir katkı sağlamaktadır.

Elde edilen veriler, bu coğrafi özelliklerin orman yangını yönetiminde yakıt yükü sorunsalına proaktif bir çözüm bulabilmek ve sürdürülebilir yangın yönetim stratejileri içinde temel oluşturmaktadır. Bu veriler ve değerlendirmeler aynı zamanda, çalışmanın daha önceki motivasyon kaynağı ve hedef soruları ile ele alınarak yangın davranışlarının nasıl bir bilişsel, entropik düzeyde ilişki içerisinde olduğunu ortaya koyarak mega yangın yönetimlerinde işlevsel pedagojik ve ampirik bir envanter kaynağı sağlamaktadır.

3.1. Yakıt yükü tanımı ve yangın davranışı üzerindeki etkisi

Kavramsal çerçevede orman yangın yönetiminde yakıt (*fuel load*), hem ölü hem de canlı yakıtın fiziksel özelliklerinden oluşur ve orman yangınlarının meydana gelmesi, şiddeti ve yayılması üzerinde kritik bir rol oynar. Orman ekosistemlerinde, yakıt katmanları yüzey, alt katman (yüksek ve yüzeye yakın) ve kapallık yakıt katmanları olarak kategorize edilir (Gould vd., 2011) (Şekil 7).



Şekil 7. Yakıt yükü ve nem oranının yangın şiddetine etkisini gösteren kavramsal bir ısı haritası (*heat map*)

Şekil 7’de verilen 6x5’lik matris, X: Yakıt Yüğü [5-30 ton/ha], Y: Nem [5-25%] veri setinden oluşan yakıt yükü-nem oranı-yangın şiddeti ilişkisine dayalı ısı haritası incelendiğinde yakıt yükünün >20 ton/ha + Nem <%10 olduğu koşulda yüksek risk bölgeleri (koyu kırmızı/turuncu)

olarak ifade edilirken, yangın davranışı düzeyinde kalın ve kuru yakıtların hızla tutuşmasını temsil eden yangın derinliğinin 8-10 m’yi aştığı durumlarda yüksek ısı çıkışı sıcak sektörlü GB’lı siklonik sistemlerle bağlantılı olarak kor atlamalarına neden olabilir. Bu yüzden yakıt aralıklarının açılması prensibi (*fuel breaks*) tedbirlerine geçilmesi önleyici tedbirler kapsamında değerlendirilebilir.

Yakıt yükünün 10-20 ton/ha + Nem %10-15 olduğu koşullarda ise beklenen yangın davranışı ince yakıt yükü kontrolüne dayanan kontrollü yakmalar şeklinde nem artırıcı önlemler (su püskürtme) ile önlenebilir. Bu yangın riskine duyarlı yerleşimler orta risk bölgeleri (sarı/açık turuncu) bölgeler kapsamında değerlendirilmiştir. Bu koşulların yanı sıra yakıt yükü <10 ton/ha + Nem >%20 olduğu düşük seviyeli yangın davranışlarında alev boyu <1 metre, yayılma hızı <0.5 m/dak olarak kabul edildiğinde zayıf yangınlık meydana gelir. Bu tarz yangın davranışı bölgeleri haritada düşük risk bölgeleri (açık beyaz/açık sarı) şeklinde gösterilmiştir. Özetle bu sıcaklık haritası, yangın davranışını niceliksel olarak modellemekle kalmaz, aynı zamanda önleyici stratejiler için bilimsel bir temel sağlamak amacıyla özellikle iklim değişikliği nedeniyle nem oranlarının düştüğü bölgelerde, yakıt yükünü azaltmaya yönelik projelere altlık oluşturması hedeflenmiştir. Ayrıca Şekil 8’de verilen ısı haritası örnek model kodları ise aşağıdaki gibidir:

```
import numpy as np
import matplotlib.pyplot as plt


# Veri
fuel_load = np.array([5, 10, 15, 20, 25, 30]) # ton/ha
moisture = np.array([5, 10, 15, 20, 25]) # %
heat_output = np.array([
    [800, 500, 300, 100, 50],
    [1500, 900, 600, 200, 80],
    [2500, 1500, 800, 400, 100],
    [3500, 2000, 1200, 500, 150],
    [4000, 2500, 1500, 700, 200],
    [4500, 3000, 1800, 900, 250]
])

# Heatmap
plt.figure(figsize=(10, 6))
plt.imshow(heat_output, cmap="YlOrRd", aspect="auto")
plt.colorbar(label="Isı Çıkışı (kW/m²)")
plt.xticks(np.arange(len(moisture)), moisture)
plt.yticks(np.arange(len(fuel_load)), fuel_load)
plt.xlabel("Nem Oranı (%)")
plt.ylabel("Yakıt Yüğü (ton/ha)")
plt.title("Yakıt Yüğü ve Nem Oranının Yangın Şiddetine Etkisi")
plt.show()

import plotly.express as px

fig = px.imshow(
    heat_output,
    labels=dict(x="Nem Oranı (%)", y="Yakıt Yüğü (ton/ha)", color="Isı Çıkışı (kW/m²)"),
    x=moisture,
    y=fuel_load,
    color_continuous_scale="hot"
)
fig.update_layout(title="Yangın Risk Isı Haritası")
fig.show()
```

Bu bağlamda yakıt yükünün ısı akışı kontrolünü temsil eden örnek matris veri üzerinden interaktif bir haritada oluşturulmuştur (Şekil 8).



Şekil 8. Yakıt yükü ve nem oranının yangın şiddetine etkisini gösteren kavramsal ısı haritası örneği (*heat map*).

Bu zeminde yakıt yükü yönetiminde kuru biyokütle de birim alan başına yanma için mevcut olan canlı biyokütle miktarı da oldukça önemlidir (Keane, 2013). Çünkü yakıt yükü haritalamasında belirli yangınlarda söndürme işlemlerinde piroçeşitlik (*pyrodiversity*) ekosistem yönetimi açısından oldukça önemlidir. Terimsel düzeyde bir peyzajda yangın rejimlerinin (yangın sıklığı, süresi, yoğunluğu, mevsimselliği, kapsamı) çeşitliliğini ifade eden (Abdollahi & Yebra, 2025) piroçeşitlik, ekosistemlerde ekolojik direnç sağlamada habitat potansiyelini ortaya koymada bir yangın mozaiki görevi de üstlenir. Tablo 6 incelendiğinde yüzey yakıt yükünü belirleme de ve bunun yangınlar üzerindeki etkisini ölçme de rol oynayan başlıca yakıt özelliklerine yer verilmiştir.

Tablo 6. Yüzey yakıt yükünü belirleme de ve yangınlar üzerindeki potansiyel etkiyi anlama da kritik rol oynayan başlıca çeşitli orman yakıt özellikleri (Abdollahi & Yebra, 2025).

Yakıt katmanı	Özellik	Tanım	Yangındaki rolü
Kapalılık katmanı		Birim hacim başına gölgelik katmanındaki yakıt miktarı	
	Taç hacimsel yoğunluk (THC)	(kg/m ³) (KHC), Köprü	
	Kanopi yakıt yükü (KYY)	katmanlı yakıt miktarı	
	Taç yüksekliği (TYİ)	(kg/m ²) (KYY),	Taç yangını yayılması
	Taç taban yüksekliği (TTYİ)	Rüzgâr hızı ve yönünü etkileyen örneklem alanındaki en yüksek ağacın yüksekliği (KYİ)	
Alt katman	Çalılar, otlar, sarmaşıklar ve küçük ağaçların	Belirli bir alandaki bu bitki	Yüzeyden kanopiye

alt katman yakıt yükü	tabakasında bulunan yanıcı malzemelerin kuru ağırlığı (kg/m ²)	yangın geçişi
	Belirli bir alanda yer yüzeyinde veya yakınında bulunan yanıcı malzemelerin kuru ağırlığı (kg/m ²) ve tüm yüzey yakıt katmanlarında tahmin edilen yüklerin toplanması	Yüzey yangını başlatma ve yayılma
Yüzey katmanı	Tüm yüzey yakıt elemanlarının (yani yaprak örtüsü, kütükler, dalcıklar, dallar, otsu bitkiler ve odunsu atıklar) yüzey yakıt yükü	

Bu açıdan taç yangınları, şiddetli ve uzun süreli etkileri ile kontrol edilmesinin zorluğu nedeniyle özellikle endişe vericidir ve bu durum, yangın yöneticilerini taç yakıt özelliklerini anlamaya öncelik vermeye yöneltmektedir. Taç yakıt yükü (TYY), taç yüksekliği (TY), taç hacim yoğunluğu (THY) ve taç taban yüksekliği (TTYİ) gibi ana taç özellikleri, taç yangınlarının yayılmasını belirlemedeki kritik rolleri nedeniyle yaygın olarak kabul edilmektedir (Cruz vd., 2003).

Taç yakıt yükü (TYY), kg/m² veya mg/ha cinsinden ifade edilen, ateşleme için potansiyel olarak mevcut alan başına kanopi yakıtının kuru ağırlığını temsil eder, yangın yoğunluğunu ve yayılma hızını etkiler (Wagner, 1977). Taç taban yüksekliği (TTYİ), yüzey ve en alt taç yapraklar arasındaki dikey mesafe, yüzey yangınlarının taç yaprağına ulaşma olasılığını etkiler; daha düşük TTYİ genel yakıt yükünü ve taç yangın riskini artırır (Scott & Reinhardt, 2001). Taç hacim yoğunluğu (THY), taç tepe kısmındaki yakıt miktarını birim hacim başına (kg/m³) nicelendirir ve korunmuş bir ağaçtan diğer ağaca yayılma hızını etkiler (Chuvieco vd., 2003).

Alt katman yakıt tabakaları, çalılar, otlar, sarmaşıklar ve küçük ağaçlardan oluşarak orman yangını davranışı ve yayılmasında kritik bir rol oynar. Çalılar, yangınların yüzeyden kanopiye tırmanmasına olanak tanıyan merdiven yakıtları olarak işlev görebilirken, otlar ince yakıtlar olarak kolayca tutuşur ve yangını hızla yayar. Kuru dönemlerde, bu alt katman yakıtları son derece yanıcı hale gelir, yangın yoğunluğunu artırır ve taç yangınlarına geçiş olasılığını yükseltir. Alt katman yakıtlarının bileşimini ve durumunu anlamak, etkili orman yangını yönetimi ve azaltma stratejileri için hayati öneme sahiptir (Chuvieco vd., 2003).

Yüzey yakıtları, orman yangını bağlamında yönetilmesi en karmaşık yakıt türleri olarak kabul edilmektedir. BEHAVE, FlamMap ve FARSITE dahil olmak üzere çoğu yangın davranışı tahmin modeli, bu yakıt katmanının kesin bir fiziksel tanımını gerektirmektedir (Finney, 1998). Yüzey yakıtları, ölü ve canlı biyokütle (yani, litter, kütükler, dalcıklar, dallar, otsu bitkiler ve odunsu atıklar) içeren,

yüzey yangınlarının başlaması ve yayılması için hayati öneme sahiptir (Reich vd., 2004).

Ölü yakıtlar, bitki örtüsünün düzenini ve yanıcılığını etkileyerek orman yangını tahmininde önemli bir rol oynamaktadır. Yüzey yakıt yükü, yüzey yakıt katmanının birim alan başına kuru ağırlığı (kg/m^2) olarak ölçülen, yangın davranış modellerinde anahtar bir parametredir ve yangın yayılma hızı ile yangın hattı yoğunluğunu etkiler (Ivanova vd., 2020). Bu durumun yanı sıra belirli yüzey yakıt türlerinin yükü kritik öneme sahiptir. Çünkü farklı yakıt türleri yangın davranış modellerini farklı şekillerde etkiler. Yangın davranış modellerini ve tehlike sistemlerini etkili bir şekilde kullanmak için, her yakıt türünün fiziksel parametreleri sayısal olarak nicelendirilmelidir (Arroyo vd., 2008).

3.2. Yakıt yükü haritalama için UA teknikleri

Uzaktan algılama, yakıt yüklerini haritalamak için geniş bir sensör ve metodoloji yelpazesi sunar. Bu bölümde, kullanılan sensör türüne göre kategorize edilmiş yakıt yükü ve diğer ilgili yakıt özelliklerinin haritalanması için çeşitli uzaktan algılama teknikleri sunulmuştur. Bu kategoriler, pasif sensörler, aktif sensörler veya birleşik yaklaşımları kapsamaktadır.

3.2.1. Pasif Sensörler

Pasif sensörler, kendi enerjilerini yaymadan nesneler tarafından yayılan veya yansıtılan elektromanyetik radyasyonu yakalayan uzaktan algılama cihazlarıdır. Landsat, Sentinel, Terra/Aqua ve QuickBird gibi pasif optik sensörler, elektromanyetik spektrumun görünür ve kızılötesi kısımlarında elektromanyetik radyasyonu yakalar ve ölçer ve genellikle yakıt özelliklerini, yakıt yükü dahil, değerlendirmek için kullanılır. Genel olarak, yakıt yükü modelleri, bu sensörler tarafından elde edilen spektral veriler ile yer gözlemleri arasındaki ampirik ilişkilerin kalibrasyonu yoluyla oluşturulur (Falkowski vd., 2005). Multispektral optik uzaktan algılama ise, kanopinin spektral yansımaları yakalar; bu, hem dik duran odunsu bileşenlerin geometrik özelliklerini hem de yaprakların biyokimyasal özelliklerini ortaya çıkarabilir (Massetti vd., 2019). Birçok araştırma çabası, yakıt yükünün mekânsal farklılıklarını tasvir eden öngörücü teknikler geliştirmek için optik görüntüleme kullanmıştır. Bu paralelde çalışmada optik ve mikrodalga uzaktan algılama verileri ve bunların, yakıt yükünü şekillendirmede kritik öneme sahip yakıt yükü parametreleri ve diğer anahtar değişkenlerin modellenmesindeki kullanımını temsilen çalışmada tercih edilen Sentinel-2 parametreleri Tablo 7’de yer verilmiştir.

Temel spektral analizler kullanarak, yakıt yükleri ile gövde çapı ve ağaç yüksekliği arasındaki spektral ilişkiyi doğrulamak adına Python 3B spektral grafik koduyla örnek bir veri seti doğrultusunda ağaç morfometrisi (ağaçların fiziksel yapısal özellikleri, gövde çapı (DBH: Göğüs yüksekliği çapı), taç yüksekliği, dallanma, kök morfometrisi ve birikimi vb.) arasındaki ilişkiyi görmek adına Şekil 9’da verilen spektral grafik konsepti oluşturulmuştur. Buna göre küçük gövdeli genç ağaçlar (DBH <20 cm), orta gövdeli genç ağaçlar (DBH <20-50 cm), kalın gövdeli ağaçlar (DBH <50 cm) olmak üzere 3 ana ağaç morfometrisi üzerinden yakıt yükü-gövde çapı-ağaç yüksekliği arasındaki davranış ilişkisi ortaya koyulmaya çalışılmıştır. Söz konusu ilişkiyi temsil eden örnek veri seti fiziksel parametreleri

Tablo 8’de verilmiştir. Morfometrik düzeyde yorumu şu şekildedir:

Küçük gövdeli genç ağaçlar (DBH<20 cm); yüzey yangın riskine neden olur ve hızlı yanma, düşük ısı çıkışı gözlemlenir. Orta boylu ağaçlar (DBH 20-50 cm); yakıt yükünün yaklaşık olarak (20-50 ton/ha) arttığı, taç yangınları (crown fire) şeklinde başlayabilir. Kalın gövdeli ağaçlar (DBH>50 cm); çok yüksek yakıt yükü (ort. >50 ton/ha) yoğun ısı çıkışı, uzun süreli yanmalara neden olabilir.

Tablo 7. Yakıt yükünün mekânsal değişimlerini tasvir eden Sentinel-2 bant optik özellikleri

Veri kaynağı	Parametre	Tanım	Değişken	Referans
Sentinel-2	Bant 2	Mavi	Yüzey yakıt yükü	(Arellano-Pérez vd., 2018)
	Bant 3	Yeşil		
	Bant 4	Kırmızı		
	Bant 5	Kırmızı		
	Bant 6	kenar		
	Bant 7	Kırmızı		
	Bant 8	kenar		
	Bant 8A	NIR	Yakıt tablası boşluğu, taç taban yüksekliği vb.	(Wells vd., 2021)
		NIR		
		SWIR1		
		SWIR2		
	Bant 11		Mera yakıt yükü	
	Bant 12			
	SAVI	Toprak ayarlı bitki endeksi		
	EVI	Gelişmiş vejetasyon indeksi		
	NDVI	Bitki sağlığı indeksi		

Tablo 8. Örnek veri seti fiziksel parametreleri

DBH (cm)	Ağaç yüksekliği (m)	Yakıt yükü (ton/ha)
10	8	5
30	15	20
50	25	50
70	35	80

```
import matplotlib.pyplot as plt
import numpy as np
from mpl_toolkits.mplot3d import Axes3D

# Örnek veri
DBH = np.array([10, 20, 30, 40, 50, 60, 70]) # cm
height = np.array([8, 12, 15, 20, 25, 30, 35]) # m
fuel_load = np.array([5, 10, 20, 35, 50, 65, 80]) # ton/ha


# Grafik
fig = plt.figure(figsize=(12, 8))
ax = fig.add_subplot(111, projection='3d')

# Noktaları çiz (renk ve boyut yakıt yüküne göre)
scatter = ax.scatter(
    DBH, height, fuel_load,
    c=fuel_load, cmap='viridis', s=fuel_load*10, alpha=0.7
)

# Eksenler
ax.set_xlabel('Gövde Çapı (DBH, cm)', fontsize=10)
ax.set_ylabel('Ağaç Yüksekliği (m)', fontsize=10)
ax.set_zlabel('Yakıt Yüğü (ton/ha)', fontsize=10)
ax.set_title('Yakıt Yüğü, Gövde Çapı ve Ağaç Yüksekliği İlişkisi', fontsize=14)

# Renk barı
cbar = fig.colorbar(scatter, pad=0.1)
cbar.set_label('Yakıt Yüğü Yoğunluğu (ton/ha)', fontsize=10)

plt.tight_layout()
plt.show()
```



Şekil 9. Yakıt yükü, gövde çapı ve ağaç yüksekliği arasındaki ilişki.

3.2.2. Aktif Sensörler

Pasif sensörlerin aksine aktif bir uzaktan algılama kolaylığı sağlayan bu sensörler polarimetrik bilgileri kullanarak aktif bir görüntüleme kolaylığı sağlayan teknoloji özelliği taşırlar. Bu sensörlerden sıklıkla en yaygın kullanılanları; RADAR (*Radio Detecting and Ranging*) ve LİDAR'dır (Bai vd., 2017). Örneğin RADAR sistemleri özellikle uzun dalga boylarına sahip olanlar, yaprak biyokütlesi, gövde yakıt yükü (GY), dal yakıt yükü (DYY) gibi yakıt yüklerini tahmin etme konusunda büyük bir potansiyel göstermiştir (Saatchi vd., 2007). LİDAR sistemleri bu çerçevede diğer uzaktan algılama verilerine kıyasla, orman yapısı ve yüzey yakıtının derinliği ve kaplama, kanopi yoğunluğu ve topografya gibi mekânsal özellikler hakkında üç boyutlu bilgiler vermektedir (Chen vd., 2017).

Diğer yakıt yükü tahminini iyileştirme yaklaşımlarına bakıldığında saha anketleri, yangın sonrası süre ölçümleri, topografik unsurlar ve yakıt özellikleri sınıflandırma sistemleri gibi çeşitli veri setlerini LİDAR ölçümleri ile entegre etmeye odaklanmıştır. Bu çabalar, mekânsal değişkenliği yakalama ve çeşitli peyzajlarda yakıt yükü modellenmesinin doğruluğunu artırma konusundaki zorlukları ele almayı amaçlamıştır.

Bu düzlemde Python'da 50x50 m'lik bir ağaçlık alanda LİDAR veri setini temel düzeyde tanımlayabilecek ağaç yüksekliği- yakıt yükü arasındaki modelsel ilişki Şekil 10 ve Şekil 11'de GEE tabanlı bir yakıt yükü haritası verilmiştir. Bu sayede yangın önleme planlaması ve acil müdahale rotaları belirleme de stratejik bir katkı sunulmaya çalışılmıştır. Genel bir yorum ekseninde haritanın yorumu şu şekildedir: 0-10 m arası; genç ağaç/çalı vejetasyonu bileşenli yüzey yangın riski taşıırken, 10-20 m arası; taç yangına geçiş potansiyelli taşıyan olgun ağaç meşcerelerini içeren bir yangın riski koşulunu sentetik düzeyde oluştururken, <20 m yüksek ısı çıkışına dayalı yaşlı ve kuru ağaç birliklerini ifade etmektedir.

```
# 1. Örnek LİDAR Verisi Oluşturma (50x50m alan)
np.random.seed(42)
x = np.linspace(0, 50, 100)
y = np.linspace(0, 50, 100)
X, Y = np.meshgrid(x, y)

# Ağaçlar için rastgele yükseklikler (5-25m arası)
heights = np.random.rand(100, 100) * 20 + 5
heights = gaussian_filter(heights, sigma=2) # Düzgünleştirme

# 2. Yakıt Yüğü Hesaplama (Basit Model)
fuel_load = np.where(heights < 10, heights * 0.5, heights * 1.2) # 10m altı/aşanı farklı ağırlık


# 3. Görselleştirme
plt.figure(figsize=(12, 5))

# Yükseklik Haritası
plt.subplot(121)
plt.contourf(X, Y, heights, levels=20, cmap='viridis')
plt.colorbar(label='Yükseklik (m)')
plt.title('Ağaç Yükseklik Dağılımı')

# Yakıt Yüğü Haritası
plt.subplot(122)
heatmap = plt.contourf(X, Y, fuel_load, levels=20, cmap='hot')
plt.colorbar(label='Yakıt Yüğü (ton/ha)')
plt.title('Yakıt Yüğü Tahmini')

plt.tight_layout()
plt.show()

fuel_load = heights**2 * 0.03 # Kuadratik model
```




Şekil 10. Ağaç yüksekliği ve yakıt yükü tahmini haritası

Şekil 12 incelendiğinde 2021 Manavgat mega yangını sırasında rüzgâr-eğim, topografik hassasiyetin yüksek olduğu 8 lokasyonda 1 km üzerinde alev ilerlemelerin görüldüğü, GB siklonlarının egemen olduğu cephelerdeki yangın yayılma hızının sentetik bir örneği oluşturulmuştur. Buna göre; grafikte kırmızı tonlarının yoğunlaştığı bölgeler, rüzgâr hızı ve arazi eğiminin yangın yayılım hızını (ROS) maksimum seviyeye çıkardığı "kritik zonları" oluştururken, Yüksek rakımlı bölgelerde (500m+) çam ormanlarının yoğun olduğu alanlarda ROS değerleri 4 ft/dk'ya (≈ 2 m/dak) olarak kabul edilmiştir. Diğer bir ifadeyle, kıyı-dağ geçişi Antalya kıyı şeridinden Toroslar'a doğru ROS değerlerinin progresif artışı, kıyı çalılıklarından dağ ormanlarına geçişteki risk farkını yansıtmaktadır.



Şekil 11. Örneklem alanı yakıt yükü sınıfları



Şekil 12. 2021 Manavgat mega yangını alev toplarını temsilen 1 km’lik bir alandaki yangın yayılma hızı

Şekil 13’de ise mega yangın öncesi kuraklık koşullarını ortaya koymak amacıyla uydu tabanlı Bitki Örtüsü Durum İndisi (VCI) ve Standartlaştırılmış Bitki Örtüsü Kuraklık İndisi (SDVI) kullanılmıştır (Şekil 14). Ayrıca NDVI değişim ilişkisine bakılarak yangın öncesi ve sonrasındaki vejetasyon sağlığı da incelenmeye çalışılmıştır (Şekil 15).


VCI değerleri göz önüne alındığında yangın öncesi VCI koşullarında Manavgat ve çevresini içine alana net biyokütle veriminde düşüşlerin gözlemlendiği kuru örtü sahasında yüksek bitki stres seviyesinin (kırmızı tonlar) izlendiği (VCI 0-20) izlenmiştir. Özellikle de Gündoğmuş ve Çakışlar mahallerinde yangının bitki örtüsü üzerindeki yıkıcı etkileri dikkat çekmektedir. Bu durumun yanı sıra sarı bantlarla ifade edilen VCI 20-40 arasında değiştiği yakıt yükü sahaslarında örneğin Selge ve çevresinde kısmi yanmış ve orta stres seviyesinde bitki kompozitleri bulunmaktadır. Çünkü bu bölgelerdeki bitki komünitelerinin, odunlu her dem yeşil kurakçıl çalı formasyonundan oluşması, yaz kuraklığının ve

kurutucu rüzgarların varlığı bu bölgelerdeki kurakçıl vejetasyonun tutuşma süresini artırmaktadır (Tavşanoğlu & Gürkan, 2004).

Akdeniz havzası yangın ekosistem/habitatını temsil eden, kızılçam (*Pinus brutia*), ardıç (*Juniperus* sp.), fıstıkçanı (*Pinus pinea*) yanı sıra meşe (*Quercus* sp.) topluluklarını takiben her dem yeşil bazı zakkum (*Nerium oleander*), kocayemiş (*Arbutus onedo*), keçiboyunu (*Ceratonia siliqua*) gibi maki toplulukları bölgedeki yanan alanlarda tespit edilen başlıca ekosistemleri oluşturmaktadır. Bu ekosistemler içerisinde kuraklık koşullarından en fazla etkilenen kızılçam (*Pinus brutia*) ekosistemleri ise genel olarak yenilenme stratejileriyle birlikte yangın sonrası saklı tepe tohum bankalarının serbest kalması sonucunda sürgünden gençleşme göstererek son derece hızlı ve kolay bir şekilde toparlanarak yenilenme sürecine girmektedir (Rodrigo vd., 2004). Ancak yeterince toprak tohum bankasına sahip olmayan genç kızılçam meşcerelerin yanması gibi bazı özel durumlarda ormanın kendini yenileme potansiyeli zorlaşmakta ve tür içi yenileme zorlaşarak ormandan makiliğe dönüşüm gerçekleşmektedir (Kavgacı vd., 2016).

Yangının bitki örtüsü üzerindeki etkisi dikkate almak ve kuraklık riskini anlamak amacıyla uydu tabanlı SDVI kullanılarak bir tematik harita türetilmiştir (Şekil 14). Buna göre, yangın öncesi ve sonrası SDVI dağılımına bakıldığında özellikle ormanlık bölgelerde (Gündoğmuş, Çakışlar ve Tilkiler) SDVI değerleri <2 seviyesindedir. Bu, yangının bitki örtüsünü uzun vadeli ortalamalara göre 3 standart sapma altına düşürdüğünü gösteriyor. Bu alanlar haritada koyu kırmızı bantlarla ifade edilmiştir.

Buna karşın mikro iklim, toprak özellikleri ve bitki örtüsü ilişkisi değerlendirildiğinde yanmış alanlarda toprak nemi heterojen bir dağılım göstermiştir. Söz konusu



Şekil 13. Çalışma alanı Bitki Örtüsü Durum İndisi (VCI) haritası

heterojen dağılım yangın sonrasındaki kül tabakası, NDVI'yi geçici olarak artırarak SDVI sonuçlarında hesaplama da toprak nemi ve SDVI ilişkisinde $R^2 = 0.76$ ilişkisi gözlemlenmiştir.

```

1 // 1. Çalışma Alanı ve Veri Yükleme
2 var roi = ee.Geometry.Rectangle([31.0, 36.6, 31.7, 37.1], 'EPSG:4326', false);
3
4 var modisNDVI = ee.ImageCollection('MODIS/006/MOD13Q1')
5   .select('NDVI')
6   .filterDate('2000-01-01', '2023-12-31')
7   .filterBounds(roi);
8
9 print('MODIS Görüntü Sayısı:', modisNDVI.size()); // Veri kontrolü
10
11 // 2. VCI Hesaplama (Düzeltilmiş)
12 function calculateVCI() {
13   // Uzun dönem (2000-2020) istatistikleri
14   var ndviClimatology = modisNDVI
15     .filter(ee.Filter.calendarRange(2000, 2020, 'year'));
16
17   var minMax = ndviClimatology.reduce(ee.Reducer.minMax());
18   var minNDVI = minMax.select('NDVI_min');
19   var maxNDVI = minMax.select('NDVI_max');
20
21   // Analiz yılı (2021) NDVI ortalaması
22   var ndvi2021 = modisNDVI
23     .filter(ee.Filter.calendarRange(2021, 2021, 'year'))
24     .mean()
25     .select('NDVI');
26
27   // VCI Hesapla
28   var vci = ndvi2021.subtract(minNDVI)
29     .divide(maxNDVI.subtract(minNDVI))
30     .multiply(100)
31     .rename('VCI')
32     .clip(roi);
33
34   return vci.updateMask(vci.gte(0).and(vci.lte(100))); // 0-100 arası maskesi
35 }
36
37 var vci2021 = calculateVCI();
38 print('VCI Metaveri:', vci2021); // Veri kontrolü
39
40 // 3. Görselleştirme (Düzeltilmiş)
41 var vciVis = {
42   min: 0,
43   max: 100,
44   palette: ['FF0000', 'FFA500', 'FFFF00', '00FF00', '006400']
45 };
46
47 Map.centerObject(roi, 9);
48 Map.addLayer(vci2021, vciVis, 'VCI 2021');
49
50 // 4. Lejant Ekleme (Güncellenmiş)
51 var legend = ui.Panel({
52   style: {
53     position: 'bottom-right',
54     padding: '10px',
55     backgroundColor: 'white',

```

```


56   border: '1px solid #ccc'
57   });
58 });
59
60 var legendTitle = ui.Label({
61   value: 'VCI Değerleri',
62   style: {fontWeight: 'bold', fontSize: '14px', margin: '0 0 5px 0'}
63 });
64 legend.add(legendTitle);
65
66 [[['FF0000', '0-20: Şiddetli Stres'],
67   ['#FFA500', '20-40: Orta Stres'],
68   ['#FFFF00', '40-60: Hafif Stres'],
69   ['#00FF00', '60-80: Normal'],
70   ['#006400', '80-100: İyi']].forEach(function(colorInfo) {
71   var colorBox = ui.Label({
72     style: {backgroundColor: colorInfo[0], padding: '12px', margin: '0 5px 0 0'}
73   });
74   var label = ui.Label(colorInfo[1], {margin: '0 0 0 5px'});
75   legend.add(ui.Panel([colorBox, label], ui.Panel.Layout.flow('horizontal')));
76 });
77
78 Map.add(legend);
79 var northArrow = ui.Panel({
80   widgets: [
81     ui.Label('↑ K', {
82       fontSize: '24px',
83       fontWeight: 'bold',
84       style: {
85         position: 'top-left',
86         padding: '8px',
87         backgroundColor: 'white',
88         border: '1px solid #333',
89         margin: '10px'
90       }
91     )
92   ]
93 });
94
95 Map.add(northArrow);
96
97 // 5. Veri Kontrolleri
98 print('NDVI 2021 Min:', ndvi2021.reduceRegion(ee.Reducer.min(), roi, 250));
99 print('VCI 2021 Max:', vci2021.reduceRegion(ee.Reducer.max(), roi, 250));
100
101 // 1. Yumuşatma filtresi uygula (3x3 piksel)
102 var vciSmoothed = vci2021.focalMean({
103   radius: 1, // 3x3 pencere (radius=1)
104   kernelType: 'circle',
105   units: 'pixels'
106 }).rename('VCI_Smoothed');
107
108 // 2. Görselleştirme parametreleri
109 var visParams = {
110   min: 0,
111   max: 100,
112   palette: ['FF0000', 'FFA500', 'FFFF00', '00FF00', '006400']
113 };

```

```

100 print('VCI 2021 Max:', vci2021.reduceRegion(ee.Reducer.max(), roi, 250));
101 // 1. Yumuşatma filtresi uygula (3x3 piksel)
102 var vciSmoothed = vci2021.focalMean({
103   radius: 1, // 3x3 pencere (radius=1)
104   kernelType: 'circle',
105   units: 'pixels'
106 }).rename('VCI_Smoothed');
107
108 // 2. Görselleştirme parametreleri
109 var visParams = {
110   min: 0,
111   max: 100,
112   palette: ['FF0000', 'FFA500', 'FFFF00', '00FF00', '006400']
113 };
114
115 // 3. Haritayı yeniden oluştur
116 Map.addLayer(vciSmoothed, visParams, 'VCI Smoothed (3x3)');

```



Şekil 14. Çalışma alanı SDVI Bitki Örtüsü Kuraklık İndisi (SDVI) haritası

Şekil 15 incelendiğinde Manavgat (Antalya) bölgesinin 2021 öncesi ve sonrası bakımından NDVI değişim haritası oluşturularak bitki örtüsü dinamiklerindeki bozulma ve rejenerasyon süreçleri incelenmiştir. Ardından GEE platformunda Sentinel-2 Level-2A görüntülerinin %20'den az bulutlu tarihleri seçilmiş, zamansal medyan kompozitler üzerinden NDVI değerleri hesaplanmıştır. Öncesi (2021 Haziran–Ağustos) ve sonrası (2021 Ekim–Aralık) dönemler arasındaki piksel bazlı fark (Δ NDVI) haritası, bitki örtüsündeki azalma (Δ NDVI < -0.1), stabilite ($-0.1 \leq \Delta$ NDVI ≤ 0.1) ve artış (Δ NDVI > 0.1) bölgelerini ortaya koymuştur. Elde edilen Δ NDVI haritası, yangın hattı boyunca %65 oranında anlamlı bitki örtüsü kaybı gösterirken, yanmanın ardından hızlı rejenerasyon gösteren kenar kuşakları da harita üzerinde belirginleşmiştir. Bu bulgular, benzer ekosistemlerde NDVI değişim analizlerinin yangın sonrası rejenerasyon takiplerinde etkinliğini ortaya koyan önceki çalışmalarla uyumludur (Myneni vd., 1995; Pettorelli vd., 2005).

Çalışma aynı zamanda Δ NDVI haritalarının yangın yönetimi ve ekosistem restoratif planlamada hızlı karar desteği sunduğunu göstermiş; özellikle yüksek Δ NDVI azalma bölgelerinde önleyici yakıt yönetimi ve rehabilitasyon stratejilerinin önceliklendirilmesi önerilmiştir.

4. Sonuçlar ve Tartışma

Çalışmada, Manavgat (Antalya) 2021 mega yangınının tetikleyici unsurları olan yakıt yükü (kurumuş dal ve parçalar, yapraklar vb.) sorunsalı 2020-221 yılları arasındaki sonbahar ve yaz NDVI değerleri, mega yangın öncesi kuraklık koşullarının vejetasyon örtüsü fenolojik gelişimi değerlerine odaklanılarak, bölgedeki uzun dönemli doğal ortam değişimlerinin mega orman yangın davranışına olan etkileri incelenmiştir. Bulgular, UA temelli karma yaklaşımların, geleneksel saha ölçümlerine kıyasla hem maliyet hem de süre etkinliği sağladığını göstermiştir. Özellikle GEE'nin bulut platformu üzerinde zamansal

medyan kompozitler üretme yeteneği, %20'nin altındaki bulut örtüsüne rağmen tutarlı veri girişi sunarak, tropik ve Akdeniz ikliminde sık rastlanan bulut sorununu büyük ölçüde aşmıştır. Bu sonuçlar, mevcut literatürdeki bulgularla uyumludur. Örneğin (Chuvieco ve ark. 2023), NDVI-NBR entegrasyonunun CBS ve UA paralelindeki yakıt yükü tahminlerinde anahtar olduğunu tespit etmiştir. Benzer şekilde (Abdollahi ve Yebra 2025), orman yangınları davranışları ve yönetiminde UA entegrasyonuna dayalı çalışmalar da UA araçlarının kullanımın sağlamış olduğu üstün spektral özellikleri, yakıt biyokütlesi takibinde yanmış alanların incelenmesinde faydalı olduğu bir kaynak alanı olarak değerlendirilmiştir.


Bunun yanı sıra, son yıllarda yakıt yükünü değerlendirmek için kullanılan çeşitli UA teknikleri bu incelemede değerlendirilmiştir. Makalenin merkezi odak noktası, farklı yakıt katmanlarından farklı yakıt kategorileri üzerindeki yakıt yükünü nicelendirirken UA, GEE ve PE teknolojilerini açıklamaya yöneliktir. Her çalışmada kullanılan bu yaygın teknikler, devam eden araştırma örnekleriyle birlikte ele alınmıştır. İncelenen çalışmalardaki belirlenen sınırlamalar, büyük ölçüde mevcut UA teknolojilerinin doğasında bulunan kısıtlamalara atfedilebilir. Özellikle yüzey yakıt katmanlarıyla ilgili olarak yakıt yükünü doğru bir şekilde tahmin etme görevi zorluklar içermekte olup, yalnızca tek bir UA veri kaynağına dayanmak, yakıt yükünü karakterize etme konusunda her zaman kapsamlı bir yaklaşım sağlamayabilir.

Bununla birlikte yenilikçi yakıt yükü tahmin yöntemlerini keşfetmek, çağdaş teknolojinin yetenekleri ve kısıtlamalarıyla uyumlu olarak, sürekli gelişen uzaktan algılama tekniklerine sahip olmakla mümkündür. Sonuç olarak, UA teknolojisini kullanma şeklimizde önemli ilerlemeler ve daha yüksek mekânsal ve zamansal çözünürlüklere sahip gelecek optik ve RADAR görevleri gibi sensör teknolojisindeki öngörülen gelişmeler, ince ölçeklerde ayrıntılı yakıt yükü haritalamanın evrimi için umut verici olanaklar sunmaktadır.

Bu kapsamda çalışmada Sentinel-2 uyduları ve GEE platformları, PE motoru kullanılarak orman yangınları davranışları, yakıt yükü arasındaki ilişki orman yangını şiddetinin belirlenmesinde önem taşıyan NDVI ve NBR indeksleri eşliğinde belirlenmeye çalışılmıştır. Geliştirilen GEE ve PE tabanlı entegre mekânsal analizler sonucunda elde edilen yüksek çözünürlüklü yakıt yükü haritaları örneklem alanı olarak belirlenen Manavgat (Antalya) sınırları çerçevesinde uygulanmıştır. Çünkü 2021 mega orman yangını ile gündeme gelen ekoton geçiş özellikleri ile birlikte bir biyotop özelliği yansıtan örneklem alanı yangın riski, tehlike, duyarlılığı bakımından Akdeniz biyoikliminin tipik bir yangın klimaksı özelliğini yansıtmaktadır.

Bu doğrultuda yakıt yükü potansiyeli ilişkisini ortaya koymak amacıyla GEE, PE platformunda oluşturulan katalog veri kütüphaneleriyle birlikte hızlı ve kolay bir şekilde 10 m mekânsal çözünürlüklü tematik veriler üretilmiştir. Bu gelişme paralelinde GEE ve PE tabanlı entegre mekânsal analizler sonucunda elde edilen yüksek çözünürlüklü yakıt yükü haritaları, Manavgat (Antalya) bölgesinde yangın öncesi riskli alanların belirlenmesinde etkin bir araç olarak öne çıkmıştır.

Yüzdelik dilim tabanlı sınıflandırmaya (Persentile) göre saha genelinde yakıt yükü dağılımı şu şekilde hesaplanmıştır: Düşük ($< 20\%$): %22, Orta ($20-50\%$): %38, yüksek ($50-80\%$): %27. Betimsel istatistik analizleri, NDVI



Şekil 15. Çalışma alanı NDVI değişim haritası.

ve NBR indeksleri arasındaki yüksek pozitif korelasyonu ($r > 0.8$) ortaya koyarken, Rothermel modeline girdi sağlayan bu iki parametrenin yakıt yükü tahminlerindeki hassasiyetini doğrulamıştır. Kovaryans ısı haritaları, özellikle eğim ve güney cepheli alanlarda yakıt yükü varyasyonunun arttığını göstererek, mikro-topografik etkilerin uzaktan algılama ile başarılı şekilde saptanabildiğini ortaya koymuştur. Histogram analizleri ise her bir kategorideki yakıt yükü dağılımının simetrik ve aykırı değerlerin sınırlı olduğunu, böylece modelin tutarlılığını desteklediğini doğrulamıştır.

Bu çalışmanın bugüne kadar yangın ekolojisi literatüründe yapılan yangın risk, tehlike, duyarlılık ve yangın şiddeti çalışmalarından en belirgin farkı istatistiksel analiz ve modelleme sürecinde sadece CBS mekânsal organizasyonu ile sınırlı kalmayıp PE diliyle Colab ortamında hızlı ve tekrarlanabilir analize dayalı olmasıdır. Modelleme ilişkiselinde çalışma, yalnızca yangın sonrası hasar analizine değil, yangın öncesi yakıt yükü dinamiklerinin modellenmesine de odaklanması yönüyle risk öngörüsü ve müdahale planlamasında diğer çalışmalarla entegre bir şekilde proaktif (bütüncül) bir bakış açısı sunmaktadır.

Litmaps ile oluşturulan literatür ağı, çalışmanın metodolojik tercihlerinin uluslararası alanda benzer çalışmalarda da kullanıldığını ortaya koymuştur. Literatür taraması ekseninde diğer çalışmalardan ayrılan diğer bir yönü ise kuramsal bağlamda da sistematik olarak görselleştirilmiş bir literatür ağı özelliği yansıtmaktadır. Çalışmanın yangın ekolojisi, orman yangınları yönetimi, yangın coğrafyası disiplinlerine en önemli katkıları ise kısaca şu şekildedir: Her şeyden önce çalışma UA temelindeki mekânsal organizasyonların yangın simülasyonlarına entegre edilebileceğini göstermesi bakımından uygulamalı bir mekânsal model önerisi sunmaktadır.

Aynı zamanda, çalışmanın bazı sınırlılıkları da mevcuttur. İlk olarak, yalnızca Sentinel-2 tabanlı spektral veriler kullanılması, LİDAR veya termal görüntülemeyle sağlanabilecek dikey yapı ve yakıt yoğunluğu ayrıntılarını göz ardı etmiştir. İkinci olarak, amaçlı rastgele örnekleme nokta sayısının nispeten sınırlı kalması, bölgesel genellemelerde dikkatli yorumlanması gereken belirsizlikler yaratabilir. Gelecekte, LİDAR verileri ve yüksek çözünürlüklü dron görüntüleri ve saha çalışmaları entegrasyonunun model doğruluğunu daha da artırması beklenmektedir. Bunun yanı sıra BehavePlus, FARSITE yangın model metriklerinin Rothermel modeliyle bir arada değerlendirildiği, saha çalışmaları destekli yakıt biyokütle yükü çalışmaları mekânsal ve istatistiksel düzeyde daha anlamlı katkılar sunabilir. Sonuç olarak, GEE ve Python tabanlı mekânsal analizler; yangın yöneticilerine, büyük ölçekli orman yangınlarını azaltma ve önleme stratejilerini bilimsel temelli mekânsal-zamansal tahminlere dayandırma imkânı tanımaktadır. Üstelik proaktif müdahale planlarının geliştirilmesinde bu yaklaşımlar hem maliyet hem de zaman avantajı sunarak karar destek süreçlerini güçlendirecektir.

Bilgilendirme/Teşekkür

Makalenin ampirik ve metodolojik kurgusal yapısına değerli katkılarından dolayı hakemlerimize teşekkür ederim.

Araştırmacıların katkı oranı

Muhammed Çetin: Literatür taraması, düzenleme, makale yazımı, modelleme.

Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

Kaynakça

- Abdollahi, A. & Yebra, M. (2025). Challenges and opportunities in remote sensing-based fuel load estimation for wildfire behavior and management: A comprehensive review. *Remote Sensing*, 17(3), 415. <https://doi.org/10.3390/rs17030415>.
- Adab, H., Kanniah, K. D. & Solaimani, K. (2013). Modeling forest fire risk in the northeast of Iran using remote sensing and GIS techniques. *Natural Hazards*, 65(3), 1723-1743. <https://doi.org/10.1007/s11069-012-0450-8>.
- Agee, J., Wakimoto, R., Darley, E. & Biswell, H. (1973). Eucalyptus fuel dynamics, and fire hazard in the Oakland hills. *California Agriculture*, 27(9), 13-15.
- Akıncı, H. A. & Akıncı, H. (2023). Machine learning based forest fire susceptibility assessment of Manavgat district (Antalya), Turkey. *Earth Science Informatics*, 16(1), 397-414. <https://doi.org/10.1007/s12145-023-00953-5>.
- Alexander, M. E. & Cruz, M. G. (2006). Evaluating a model for predicting active crown fire rate of spread using wildfire observations. *Canadian Journal of Forest Research*, 36(11), 3015-3028. <https://doi.org/10.1139/x06-174>.
- Andrews, P. L. (2007). BehavePlus fire modeling system: Past, present, and future. In *Proceedings of 7th Symposium on Fire and Forest Meteorology*. American Meteorological Society. <https://research.fs.usda.gov/treesearch/31549>.
- Arellano-Pérez, S., Castedo-Dorado, F., López-Sánchez, C. A., González-Ferreiro, E., Yang, Z., Díaz-Varela, R. A., Álvarez-González, J. G., Vega, J. A. & Ruiz-González, A. D. (2018). Potential of Sentinel-2A data to model surface and canopy fuel characteristics in relation to crown fire hazard. *Remote Sensing*, 10(10), 1645. <https://doi.org/10.3390/rs10101645>.
- Arroyo, L. A., Pascual, C. & Manzanera, J. A. (2008). Fire models and methods to map fuel types: The role of remote sensing. *Forest Ecology and Management*, 256(6), 1239-1252. <https://doi.org/10.1016/j.foreco.2008.06.048>.
- Bai, X., He, B., Li, X., Zeng, J., Wang, X., Wang, Z., Zeng, Y. & Su, Z. (2017). First assessment of sentinel-1a data for surface soil moisture estimations using a coupled water cloud model and advanced integral equation model over the Tibetan Plateau. *Remote Sensing*, 9(7), 714. <https://doi.org/10.3390/rs9070714>.
- Bosela, M., Larocque, G. R., Baycheva, T., Valbuena, R. & Lier, M. (2024). Criteria and indicators of sustainable forest management. In G. R. Larocque (Ed.), *Ecological forest management handbook* (2nd ed., pp. 356-385). CRC Press.
- Bowman, D. M. J. S., Kolden, C. A., Abatzoglou, J. T., Johnston, F. H., van der Werf, G. R. & Flannigan, M. (2020). Vegetation fires in the Anthropocene. *Nature Reviews Earth & Environment*, 1(10), 500-515. <https://doi.org/10.1038/s43017-020-0085-3>.
- Bowman, D. M. J. S., Moreira-Muñoz, A., Kolden, C. A., Chávez, R. O., Muñoz, A. A., Salinas, F., González-Reyes, Á., Rocco, R., de la Barrera, F., Williamson, G. J., Borchers, N., Cifuentes, L. A., Abatzoglou, J. T. & Johnston, F. H. (2019). Human–environmental drivers and impacts of the globally extreme 2017 Chilean fires. *Ambio*, 48(4), 350-362. <https://doi.org/10.1007/s13280-018-1084-1>.
- Bresnahan, S. J. (2003). *An assessment of fuel characteristics and fuel loads in the dry sclerophyll forests of South-East Tasmania* [Unpublished doctoral dissertation]. University of Tasmania. <https://doi.org/10.25959/23207204.v1>.
- Carmona-Moreno, C., Belward, A., Malingreau, J.-P., Hartley, A., Garcia-Alegre, M., Antonovskiy M., Buchshtaber, V. & Pivovarov, V. (2005). Characterizing interannual variations in global fire calendar using data from earth observing satellites. *Global Change Biology*, 11(9), 1537-1555.
- Chen, Y., Zhu, X., Yebra, M., Harris, S. & Tapper, N. (2017). Development of a predictive model for estimating forest surface fuel load in Australian eucalypt forests with LiDAR data. *Environmental Modelling & Software*, 97, 61-71. <https://doi.org/10.1016/j.envsoft.2017.07.007>.
- Chuvieco, E., Riaño, D., Van Wagtenok, J. & Morsdorf, F. (2003). Fuel loads and fuel type mapping. In E. Chuvieco (Ed.), *Wildland fire danger estimation and mapping: The role of Remote sensing data* (pp. 119-142). World Scientific. https://doi.org/10.1142/9789812791177_0005.
- Colvard, N. B., Watson, C. E. & Park, H. (2018). The impact of open educational resources on various student success metrics. *International Journal of Teaching and Learning in Higher Education*, 30(2), 262-276.
- Countryman, C. M. (1972). *The fire environment concept*. Pacific Southwest Forest and Range Experiment Station.
- Creswell, J.W. & Plano Clark. (2017). *Designing and conducting mixed methods research*. Sage Publications.
- Cruz, M. G., Alexander, M. E. & Wakimoto, R. H. (2003). Assessing canopy fuel stratum characteristics in crown fire prone fuel types of western North America. *International Journal of Wildland Fire*, 12(1), 39-50. <https://doi.org/10.1071/WF02024>.
- Datta, R. (2021). To extinguish or not to extinguish: The role of forest fire in nature and soil resilience. *Journal of King Saud University Science*, 33(6), 101539. <https://doi.org/10.1016/j.jksus.2021.101539>.
- Dawadi, S., Shrestha, S. & Giri, R. A. (2021). Mixed-methods research: A discussion on its types, challenges, and criticisms. *Journal of Practical Studies in Education*, 2(2), 25-36. <https://doi.org/10.46809/jpse.v2i2.20>.
- Díaz, S. M., Settele, J., Brondízio, E., Ngo, H., Guèze, M., Agard, J., Arneth, A., Balvanera, P., Brauman, K., Butchart, S., Chan, K. M. A., Garibaldi, L. A., Ichii, K., Liu, J., Subramanian, S., Midgley, G., Miloslavich, P., Molnár, Z., Obura, D. & Zayas, C. (2019). *The global assessment report on biodiversity and ecosystem services: Summary for policy makers*. Intergovernmental Science-Policy Platform on Biodiversity and Ecosystem Services. [https://www.ipbes.net/system/files/2021-06/2020%20IPBES%20GLOBAL%20REPORT\(FIRST%20PART\)_V3_SINGLE.pdf](https://www.ipbes.net/system/files/2021-06/2020%20IPBES%20GLOBAL%20REPORT(FIRST%20PART)_V3_SINGLE.pdf)
- Eidenshink, J., Schwind, B., Brewer, K., Zhu, Z.-L., Quayle, B. & Howard, S. (2007). A project for monitoring trends in burn severity. *Fire Ecology*, 3(1), 3-21. <https://doi.org/10.4996/fireecology.0301003>.
- European Environment Agency (2018). *Corine land cover [Data set]*. Copernicus Programme. <https://doi.org/10.2909/960998c1-1870-4e82-8051-6485205ebbac>.

- Falkowski, M. J., Gessler, P. E., Morgan, P., Hudak, A. T. & Smith, A. M. S. (2005). Characterizing and mapping forest fire fuels using ASTER imagery and gradient modeling. *Forest Ecology and Management*, 217(2), 129-146. <https://doi.org/10.1016/j.foreco.2005.06.013>.
- Filipponi, F. (2019). Exploitation of Sentinel-2 time series to map burned areas at the national level: A case study on the 2017 Italy wildfires. *Remote Sensing*, 11(6), <https://doi.org/10.3390/rs11060622>.
- Finney, M. A. (1998). *FARSITE, Fire area simulator—model development and evaluation* (No. 4). U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station.
- Flannigan, M. D., Stocks, B. J. & Wotton, B. M. (2000). Climate change and forest fires. *Science of The Total Environment*, 262(3), 221-229. [https://doi.org/10.1016/S0048-9697\(00\)00524-6](https://doi.org/10.1016/S0048-9697(00)00524-6).
- Fontán-Vela, M., Rivera-Navarro, J., Gullón, P., Díez, J., Anguelovski, I. & Franco, M. (2021). Active use and perceptions of parks as urban assets for physical activity: A mixed-methods study. *Health & Place*, 71, 102660. <https://doi.org/10.1016/j.healthplace.2021.102660>.
- Forkuor, G., Benewinde Zoungrana, J.-B., Dimobe, K., Ouattara, B., Vadrevu, K. P. & Tondoh, J. E. (2020). Above-ground biomass mapping in West African dryland forest using Sentinel-1 and 2 datasets A case study. *Remote Sensing of Environment*, 236, 111496. <https://doi.org/10.1016/j.rse.2019.111496>.
- Gilroy, J. & Tran, C. (2020). A new fuel load model for eucalypt forests in southeast Queensland. *The Proceedings of the Royal Society of Queensland*, 115, 137-143. <https://doi.org/10.3316/ielapa.591547606338230>.
- Gould, J. S., Lachlan McCaw, W. & Phillip Cheney, N. (2011). Quantifying fine fuel dynamics and structure in dry eucalypt forest (*Eucalyptus marginata*) in Western Australia for fire management. *Forest Ecology and Management*, 262(3), 531-546. <https://doi.org/10.1016/j.foreco.2011.04.022>.
- Güney, C. O., Özkan, K. & Şentürk, Ö. (2015). Antalya-Manavgat yöresi ormanlarında tutuşma riskinin coğrafi dağılım modellemesi. *İstanbul Üniversitesi Orman Fakültesi Dergisi*, 66(2), 459-470. <https://doi.org/10.17099/jffiu.42696>.
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D., Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O. & Townshend, J. R. G. (2013). High-resolution global maps of 21st-century forest cover change. *Science*, 342(6160), 850-853. <https://doi.org/10.1126/science.1244693>.
- Ikahihifo, T. K., Spring, K. J., Rosecrans, J. & Watson, J. (2017). Assessing the savings from open educational resources on student academic goals. *International Review of Research in Open and Distributed Learning*, 18(7), 126-140. <https://doi.org/10.19173/irrodl.v18i7.2754>.
- Ivanova, G. A., Kukavskaya, E. A., Ivanov, V. A., Conard, S. G. & McRae, D. J. (2020). Fuel characteristics, loads and consumption in Scots pine forests of central Siberia. *Journal of Forestry Research*, 31(6), 2507-2524. <https://doi.org/10.1007/s11676-019-01038-0>.
- Jaiswal, R. K., Mukherjee, S., Raju, K. D. & Saxena, R. (2002). Forest fire risk zone mapping from satellite imagery and GIS. *International Journal of Applied Earth Observation and Geoinformation*, 4(1), 1-10. [https://doi.org/10.1016/S0303-2434\(02\)00006-5](https://doi.org/10.1016/S0303-2434(02)00006-5).
- Jolly, W. M., Cochrane, M. A., Freeborn, P. H., Holden, Z. A., Brown, T. J., Williamson, G. J. & Bowman, D. M. J. S. (2015). Climate-induced variations in global wildfire danger from 1979 to 2013. *Nature Communications*, 6(1), 7537. <https://doi.org/10.1038/ncomms8537>.
- Jurskis, V. (2005). Decline of eucalypt forests as a consequence of unnatural fire regimes. *Australian Forestry*, 68(4), 257-262. <https://doi.org/10.1080/00049158.2005.10674974>.
- Kaur, A., Gulati, S., Sharma, R., Sinhababu, A. & Chakravarty, R. (2022). Visual citation navigation of open education resources using Litmaps. *Library Hi Tech News*, 39(5), 7-11. <https://doi.org/10.1108/LHTN-01-2022-0012>.
- Kavgacı, A., Örtel, E., Torres, I. & Safford, H. (2016). Early postfire vegetation recovery of Pinus brutia forests: Effects of fire severity, prefire stand age, and aspect. *Turkish Journal of Agriculture and Forestry*, 40(5), 723-736.
- Kaya, B. (2024). Manavgat çayı havzasında vejetasyon devresi ve bitki yetiştirme şartlarından sıcaklık ve yağış özellikleri. *Journal of Turkish Studies*, 13(10), 457-486. <https://doi.org/10.7827/TurkishStudies.13183>.
- Keane, R. E. (2013). Describing wildland surface fuel loading for fire management: A review of approaches, methods and systems. *International Journal of Wildland Fire*, 22(1), 51-62. <https://doi.org/10.1071/WF11139>.
- Keeley, J. E. (2009). Fire intensity, fire severity and burn severity: A brief review and suggested usage. *International Journal of Wildland Fire*, 18(1), 116-126. <https://doi.org/10.1071/WF07049>.
- Keifer, M., van Wagendonk, J. W. & Buhler, M. (2006). Long-term surface fuel accumulation in burned and unburned mixed-conifer forests of the Central and Southern Sierra Nevada, CA (USA). *Fire Ecology*, 2(1), 53-72. <https://doi.org/10.4996/fireecology.0201053>.
- Kim, S. S., Prasad, A., Nayak, M. M., Chen, H., Srisoem, C., DeMarco, R. F., Castaldi, P. & Cooley, M. E. (2024). Predictors of nicotine replacement therapy adherence: Mixed-methods research with a convergent parallel design. *Annals of Behavioral Medicine*, 58(4), 275-285. <https://doi.org/10.1093/abm/kaee006>.
- Laurance, W. F., Camargo, J. L. C., Luizão, R. C. C., Laurance, S. G., Pimm, S. L., Bruna, E. M., Stouffer, P. C., Bruce Williamson, G., Benítez-Malvido, J., Vasconcelos, H. L., Van Houtan, K. S., Zartman, C. E., Boyle, S. A., Didham, R. K., Andrade, A. & Lovejoy, T. E. (2011). The fate of Amazonian forest fragments: A 32-year investigation. *Biological Conservation*, 144(1), 56-67. <https://doi.org/10.1016/j.biocon.2010.09.021>.
- Lopes Queiroz, G., McDermid, G. J., Castilla, G., Linke, J. & Rahman, M. M. (2019). Mapping coarse woody debris with random forest classification of centimetric aerial imagery. *Forests*, 10(6), 471. <https://doi.org/10.3390/f10060471>.
- Lovejoy, T.E., Bierregaard, R. O., Rylands, A. B., Malcolm, J.R., Quintela, C., Harper, L., Brown, K., Powell, A., Powell, G., Schubart, H. & Hays, M. (1986). Edge and other effects of isolation on Amazon forest fragments. In M. E. Soule (Ed.), *Conservation biology: The science of scarcity and diversity* (pp. 257-285). Sinauer Associates.

- Massetti, A., Rüdiger, C., Yebra, M. & Hilton, J. (2019). The vegetation structure perpendicular index (VSPI): A forest condition index for wildfire predictions. *Remote Sensing of Environment*, 224, 167-181. <https://doi.org/10.1016/j.rse.2019.02.004>.
- McKinley, D. C., Ryan, M. G., Birdsey, R. A., Giardina, C. P., Harmon, M. E., Heath, L. S., Houghton, R. A., Jackson, R. B., Morrison, J. F., Murray, B. C., Pataki, D. E. & Skog, K. E. (2011). A synthesis of current knowledge on forests and carbon storage in the United States. *Ecological Applications*, 21(6), 1902-1924. <https://doi.org/10.1890/10-0697.1>.
- Miller, C. & Urban, D. L. (2000). Connectivity of forest fuels and surface fire regimes. *Landscape Ecology*, 15(2), 145-154. <https://doi.org/10.1023/A:1008181313360>.
- Mooney, H. (1981). *Fire regimes and ecosystem properties: Proceedings of the conference: December 11-15, 1978, Honolulu, Hawaii. USDA Forest Service general technical report WO (USA) No. 26.* United States Forest Service. <https://agris.fao.org/search/en/providers/123819/records/647357fc08fd68d54601590e>.
- Murphy, B. P. & Russell-Smith, J. (2010). Fire severity in a northern Australian savanna landscape: The importance of time since previous fire. *International Journal of Wildland Fire*, 19(1), 46-51.
- Myneni, R. B., Hall, F. G., Sellers, P. J. & Marshak, A. L. (1995). The interpretation of spectral vegetation indexes. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2), 481-486. <https://doi.org/10.1109/TGRS.1995.8746029>.
- Olson, J. S. (1963). Energy storage and the balance of producers and decomposers in ecological systems. *Ecology*, 44(2), 322-331. <https://doi.org/10.2307/1932179>.
- Ottmar, R. D., Sandberg, D. V., Riccardi, C. L. & Prichard, S. J. (2007). An overview of the fuel characteristic classification system quantifying, classifying, and creating fuelbeds for resource planning. *Canadian Journal of Forest Research*, 37(12), 2383-2393. <https://doi.org/10.1139/X07-077>.
- Özcan, Z., Caglayan, İ. & Kabak, Ö. (2024). A comprehensive taxonomy for forest fire risk assessment: Bridging methodological gaps and proposing future directions. *Environmental Monitoring and Assessment*, 196(9), 825. <https://doi.org/10.1007/s10661-024-12982-8>.
- Özcanlı, M. & Yılmaz, E. (2024). Türkiye’de arazi örtüsü/kullanımı değişimlerinin belirlenmesi ve iklim değişimine olası etkileri. *Türk Coğrafya Dergisi*, 86, 7-24. <https://doi.org/10.17211/tcd.1408186>.
- Pan, Y., Birdsey, R. A., Phillips, O. L., Houghton, R. A., Fang, J., Kauppi, P. E., Keith, H., Kurz, W. A., Ito, A., Lewis, S. L., Nabuurs, G.-J., Shvidenko, A., Hashimoto, S., Lerink, B., Schepaschenko, D., Castanho, A. & Murdiyarso, D. (2024). The enduring world forest carbon sink. *Nature*, 631(8021), 563-569. <https://doi.org/10.1038/s41586-024-07602-x>.
- Pausas, J. G. & Keeley, J. E. (2019). Wildfires as an ecosystem service. *Frontiers in Ecology and the Environment*, 17(5), 289-295. <https://doi.org/10.1002/fee.2044>.
- Pettorelli, N., Vik, J. O., Myserud, A., Gaillard, J.-M., Tucker, C. J. & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, 20(9), 503-510. <https://doi.org/10.1016/j.tree.2005.05.011>.
- Psistaki, K., Tsantopoulos, G. & Paschalidou, A. K. (2024). An overview of the role of forests in climate change mitigation. *Sustainability*, 16(14), 6089. <https://doi.org/10.3390/su16146089>.
- Puletti, N., Chianucci, F. & Castaldi, C. (2018). Use of Sentinel-2 for forest classification in Mediterranean environments. *Annals of Silvicultural Research*, 42(1), 32-38. <https://doi.org/10.12899/asr-1463>.
- Reich, R. M., Lundquist, J. E. & Bravo, V. A. (2004). Spatial models for estimating fuel loads in the Black Hills, South Dakota, USA. *International Journal of Wildland Fire*, 13(1), 119-129.
- Rodrigo, A., Retana, J. & Picó, F. X. (2004). Direct regeneration is not the only response of Mediterranean forests to large fires. *Ecology*, 85(3), 716-729.
- Rollins, M. G., Keane, R. E. & Parsons, R. A. (2004). Mapping fuels and fire regimes using remote sensing, ecosystem simulation, and gradient modeling. *Ecological Applications*, 14(1), 75-95. <https://doi.org/10.1890/02-5145>.
- Rothermel, R. C. (1972). *A mathematical model for predicting fire spread in wildland fuels.* Intermountain Forest & Range Experiment Station, Forest Service, U.S. Department of Agriculture.
- Saatchi, S., Halligan, K., Despain, D. G. & Crabtree, R. L. (2007). Estimation of forest fuel load from radar remote sensing. *IEEE Transactions on Geoscience and Remote Sensing*, 45(6), 1726-1740. <https://doi.org/10.1109/TGRS.2006.887002>.
- Santos, S. M. B., Bento-Gonçalves, A., Franca-Rocha, W. & Baptista, G. (2020). Assessment of burned forest area severity and postfire regrowth in Chapada Diamantina National Park (Bahia, Brazil) using dNBR and RdNBR spectral indices. *Geosciences*, 10(3), 106. <https://doi.org/10.3390/geosciences10030106>.
- Scheffer, M., Carpenter, S., Foley, J. A., Folke, C. & Walker, B. (2001). Catastrophic shifts in ecosystems. *Nature*, 413(6856), 591-596. <https://doi.org/10.1038/35098000>.
- Scott, J. H. & Reinhardt, E. D. (2001). *Assessing crown fire potential by linking models of surface and crown fire behavior* (No. 29). U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station.
- Sivrikaya, F., Günlü, A., Küçük, Ö. & Ürker, O. (2024). Forest fire risk mapping with Landsat 8 OLI images: Evaluation of the potential use of vegetation indices. *Ecological Informatics*, 79, 102461. <https://doi.org/10.1016/j.ecoinf.2024.102461>.
- Tavşanoğlu, Ç. & Gürkan, B. (2004). Akdeniz havzasında bitkilerin kuraklık ve yangına uyumları, *OT Sistematik Botanik Dergisi*, 11(1), 119-132.
- Van Der Heijden, M. G. A., Bardgett, R. D. & Van Straalen, N. M. (2008). The unseen majority: Soil microbes as drivers of plant diversity and productivity in terrestrial ecosystems. *Ecology Letters*, 11(3), 296-310. <https://doi.org/10.1111/j.1461-0248.2007.01139.x>.
- Viegas, D. X., Soares, J. & Almeida, M. (2013). Combustibility of a mixture of live and dead fuel components. *International Journal of Wildland Fire*, 22(7), 992-1002. <https://doi.org/10.1071/WF12031>.

- Wagner, C. E. V. (1977). Conditions for the start and spread of crown fire. *Canadian Journal of Forest Research*, 7(1), 23-34. <https://doi.org/10.1139/x77-004>.
- Wells, A. G., Munson, S. M., Sesnie, S. E. & Villarreal, M. L. (2021). Remotely sensed fine-fuel changes from wildfire and prescribed fire in a semi-arid Grassland. *Fire*, 4(4), 84. <https://doi.org/10.3390/fire4040084>.
- Xulu, S., Mbatha, N. & Peerbhay, K. (2021). Burned area mapping over the Southern Cape Forestry Region, South Africa using Sentinel data within GEE cloud platform. *ISPRS International Journal of Geo-Information*, 10(8), 511. <https://doi.org/10.3390/ijgi10080511>.
- Yebra, M., Quan, X., Riaño, D., Rozas Larraondo, P., van Dijk, A. I. J. M. & Cary, G. J. (2018). A fuel moisture content and flammability monitoring methodology for continental Australia based on optical remote sensing. *Remote Sensing of Environment*, 212, 260-272. <https://doi.org/10.1016/j.rse.2018.04.053>.



© Author(s) 2025. This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>