

# TEK ZAMANLI SENTİNEL-2 VE GOOGLE EARTH ENGINE KULLANILARAK NESNE-TABANLI YANMIŞ ORMAN ALANI HARİTALAMASI: MANAVGAT VE KAVAKLIDERE ÖRNEKLERİ ÜZERİNE BİR ÇALIŞMA

Fidan Şevval BULUT<sup>1</sup>, Mustafa TÜRKER<sup>2</sup>, Ayhan ATEŞOĞLU<sup>3</sup>

<sup>1</sup>Arş. Gör., Bartın Üniversitesi, Orman Mühendisliği Bölümü, 74100, Merkez, Bartın, fbulut@bartin.edu.tr

<sup>2</sup>Prof. Dr., Hacettepe Üniversitesi, Harita Mühendisliği Bölümü, 06800, Merkez, Ankara, mturker@hacettepe.edu.tr

<sup>3</sup>Prof. Dr., Bartın Üniversitesi, Orman Mühendisliği Bölümü, 74100, Merkez, Bartın, aatesoglu@bartin.edu.tr

## ÖZET

Orman ekosistemine verdiği zararlar nedeni ile orman yangınları en büyük doğal afetlerden biri olarak kabul edilmektedir. Yanan orman alanların hızlı ve yüksek doğrulukla belirlenmesi hızlı müdahale planlarına, yeniden ormanlaştırma çalışmalarına ve yanmış alanda meydana gelebilecek erozyon, sel ve heyelan gibi doğal afetlerin önlenmesi çalışmalarına katkı sunar. Uydu verileri, hızlı afet yönetiminin etkinliğinin artırılması, zaman ve işgücünden tasarruf sağlanması için önemlidir. Bulut tabanlı platformların son yıllarda hızla gelişmesi ve kullanılabilirliğinin artması ile kullanıcıların bilgisayar işlem gücünden bağımsız yüksek çözünürlüklü uydu görüntülerini hızlı bir şekilde analiz etmesine imkân sunan platformlar gelişmiştir. Bu çalışmada 2021 yılında orman yangınlarının meydana geldiği Antalya ili, Manavgat ilçesi ve Muğla ili Kavaklıdere ilçesi çalışma alanlarına ait yangın sonrası tek zamanlı Sentinel-2 görüntüleri kullanılarak nesne-tabanlı görüntü sınıflandırması Google Earth Engine (GEE) platformunda gerçekleştirilmiştir. İlk olarak Sentinel-2 görüntüleri ön hazırlık işlemlerinden sonra segmentasyon aşamasını gerçekleştirmek için hazır hale getirilmiştir. Sentinel-2'nin ham bantlarına (B2, B3, B4, B8, B11, B12) ek olarak orta kızılötesi yanma indeksi (MIRBI), normalize edilmiş yanma şiddeti (NBR2), yanmış alan indeksi (BAI) ve normalize edilmiş bitki indeksi (NDVI) bantları hesaplanmış ve görüntüye ek bantlar olarak dahil edilmiştir. Basit yinelemesiz kümeleme (Simple Non-Iterative Clustering-SNIC) algoritması ile görüntü segmentasyonu gerçekleştirilerek nesne-tabanlı sınıflandırma için görüntü nesnelere oluşturulmuştur. Görüntü segmentasyonu işleminden sonra, rastgele orman makine öğrenmesi algoritması ile görüntünün nesne-tabanlı sınıflandırılması yapılmıştır. Elde edilen sonuçlar nokta bazlı değerlendirmeye dayanan doğruluk matrisi ile değerlendirilmiştir. Sonuçlar Manavgat çalışma alanı için %94,8 ve Kavaklıdere çalışma alanı için %97,7 genel doğruluk ile yüksek performans göstermiştir. Sonuçlar ücretsiz temin edilebilen Sentinel-2 uydusundan yangın sonrasına ait tek-zamanlı görüntü kullanımı ile GEE platformunda nesne-tabanlı rastgele orman makine öğrenimi algoritması ile yanmış orman alanlarının yüksek doğrulukla tespit edilebileceğini göstermiştir. Ayrıca bu çalışma, ücretsiz ve bulut tabanlı GEE platformunun özellikle orman yangınları başta olmak üzere afet yönetimi için güçlü ve tercih edilen bir araç olma potansiyeline sahip olduğunu vurgulamaktadır.

**Anahtar Sözcükler:** Google Earth Engine, nesne tabanlı sınıflandırma, orman yangını, tek zamanlı Sentinel-2

## ABSTRACT

### OBJECT-BASED BURNED FOREST AREA MAPPING USING UNI-TEMPORAL SENTINEL-2 AND GOOGLE EARTH ENGINE: A STUDY OF MANAVGAT AND KAVAKLIDERE CASES

Forest fires are recognized as one of the biggest natural disasters due to the damages they cause to the forest ecosystem. Determination of burned forest areas quickly and with high accuracy contributes to rapid response plans, reforestation efforts and prevention of natural disasters such as erosion, flooding and landslides that may occur in the burned area. Satellite data is important for increasing the effectiveness of rapid disaster management and saving time and labour. With the rapid development and increased availability of cloud-based platforms in recent years, platforms that allow users to quickly analyze high-resolution satellite images independent of computer processing power have developed. In this study, object-based image classification was performed on the Google Earth Engine (GEE) platform using uni-temporal Sentinel-2 images of the post-fire study areas of Antalya province, Manavgat district and Muğla province, Kavaklıdere district, where forest fires occurred in 2021. Firstly, Sentinel-2 images were made ready to perform the segmentation stage after pre-preparation procedures. In addition to the raw bands of Sentinel-2 (B2, B3, B4, B8, B11, B12), mid-infrared burn index (MIRBI), normalized burn ratio 2 (NBR2), burn area index (BAI) and normalized difference vegetation index (NDVI) bands were calculated and included as additional bands in the image. Image objects were created for object-based classification by performing image segmentation with the Simple Non-Iterative Clustering (SNIC) algorithm. After image segmentation, object-based classification of the image was performed with a random forest machine learning algorithm. The results obtained were evaluated with an accuracy matrix based on point-based evaluation. The results showed high performance with an overall accuracy of 94.8% for the Manavgat study area and 97.7% for the Kavaklıdere study area. The results showed that burning forest areas can be detected with high accuracy by using object-based random forest machine learning algorithm on GEE platform with the use of uni-temporal post-fire image from Sentinel-2 satellite, which is freely available. Furthermore, this study emphasizes that the free and cloud-based GEE platform has the potential to be a powerful and preferred tool for disaster management, especially for forest fires.

**Keywords:** Forest fire, Google Earth Engine, object-based classification, uni-temporal Sentinel-2

## 1. GİRİŞ

Orman yangınları ekosistemin bozulmasının ve ekolojik zararın başlıca nedenlerinden biridir (Pulvirenti vd., 2020). Son yıllarda orman yangınlarının küresel boyutta milyonlarca hektarlık orman alanının yok olmasına ve orman ekosistemi içerisindeki dengenin bozulmasına sebep olması orman yangınlarının önlenmesi ve azaltılması konularını dünya çapında gündeme getirmiştir. Yanan ve tahrip olan alanların belirlenmesi, hasar boyutunun tespit çalışmaları ekosistemin devamlılığı amacıyla gelecek çalışmalar ve planlamalar için önemlidir (Amos vd., 2019; Bar vd., 2020; Çolak ve Sunar, 2020; Çömert vd., 2019). Orman yangınları hava kalitesini etkilemenin yanı sıra arazi ve bitki örtüsünün özelliklerini değiştirerek yanmış alanları erozyon, sel ve heyelana karşı da savunmasız hale getirir (Pulvirenti vd., 2020). Bu nedenle yanmış alanın doğru ve hassas şekilde belirlenmesi hem yangın sonrası yanmış alanda meydana gelebilecek ikincil tehlikelerin önlenmesi hem de bitki örtüsü ve ekosistem servislerinin planlanması ve izlenmesi için temel oluşturur (Pulvirenti vd., 2020).

Uzaydan yeryüzü gözlemlerinin başlamasıyla yanmış alanı tespit etmek ve haritalamak için uydu görüntüleri yaygın bir şekilde kullanılmaya başlamıştır (Chuvieco vd., 2002). Uydu görüntüleri yanmış alanların tespit edilmesi ve haritalanması için zaman ve iş gücü açısından önemli ölçüde kolaylık sağlamaktadır. Orta çözünürlüklü ve zamansal çözünürlüğü yüksek uydu görüntülerine ücretsiz erişim imkânı yanmış orman alanlarının haritalanmasında çok önemli avantajlar sunmaktadır (Taşcı vd.). Yakın geçmişte mevcut ve devam eden çalışmalarda mekânsal çözünürlüğün de etkisi ile daha hassas ve doğru sonuçlar elde etmek adına daha çok Landsat-8, Sentinel-2 uyduları çalışmalarda tercih edilmeye başlanmıştır (Achour vd., 2022; Konkathi ve Shetty, 2021). Son yıllarda uzaktan algılama verilerinin kullanılabilirliğinin artması ile kullanıcıların web tabanlı arayüzler aracılığı ile coğrafi verilere anında erişmesine ve analiz etmesine olanak sağlayan bulut tabanlı platformlar hızlı bir şekilde gelişmiştir. Google Earth Engine (GEE) bu platformlar arasında en yaygın kullanıma sahip olması ile öne çıkmaktadır (Tassi vd., 2021). GEE, analiz yapmak ve karar alma mekanizmasını yürütmek için büyük veri kümelerini depolamak ve işlemek üzere tasarlanmış bir bulut bilişim platformudur (Mutanga ve Kumar, 2019). GEE kullanıcılara uydu görüntüleri, iklim verileri, arazi örtüsü haritaları, arazi verileri gibi kaynakları kapsayan kapsamlı veri setlerine ücretsiz erişim sunar (GEE, 2024). Kullanıcılar ayrıca kendi verilerini ve koleksiyonlarını ekleyebilir, düzenleyebilir ve tüm analizlerini gerçekleştirmek için Google'ın bulut kaynaklarını kullanabilirler (Mutanga ve Kumar, 2019). GEE ayrıca görüntü sınıflandırma, değişiklik algılama, zaman serisi analizleri ve mekânsal modelleme gibi çeşitli analizler için makine öğrenimi algoritmaları da dahil olmak üzere çeşitli araçlar ve işlevler sağlar. Kullanıcılar görüntüleri işlemek ve analiz etmek, bilgi çıkarmak ve arazi örtüsü, arazi kullanımı, bitki örtüsü dinamikleri ve daha fazlası hakkında algoritmalar uygulayabilir. Ayrıca GEE, kullanıcıların veri kümelerini keşfetmelerine ve sonuçları dinamik haritalar ve grafikler aracılığıyla analiz etmelerine olanak tanıyan etkileşimli görselleştirme özellikleri de sunmaktadır (Kumar ve Mutanga, 2018).

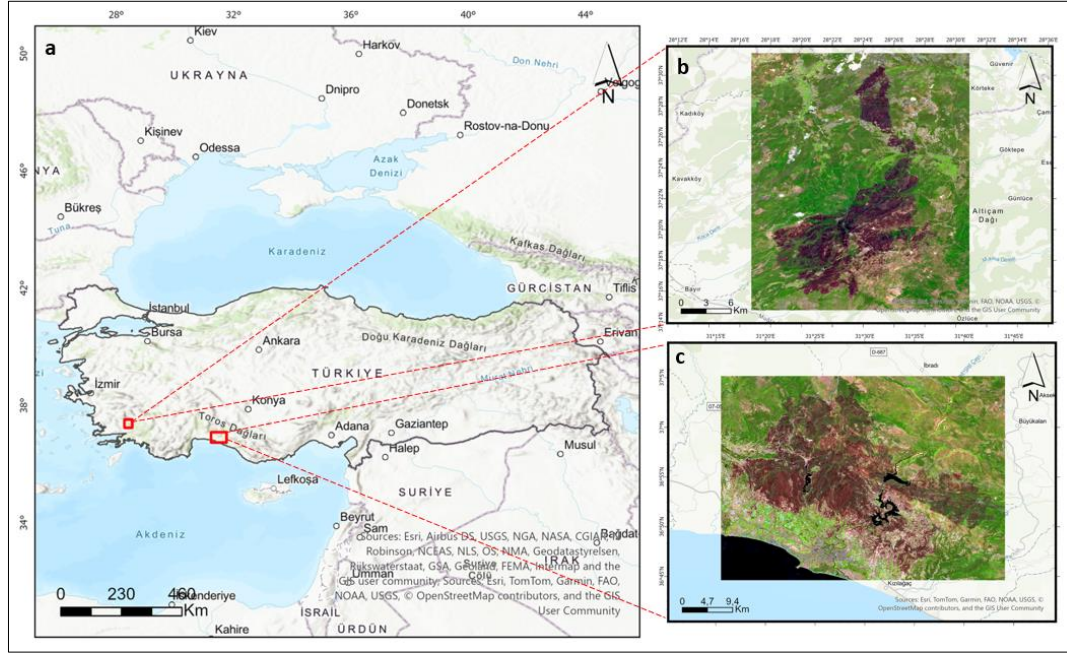
Farklı platformlarla birlikte yanan orman alanlarının haritalanması için farklı veriler ve farklı yöntemler uygulanmış olup özellikle piksel-tabanlı ve nesne-tabanlı görüntü analizi ile uydu görüntülerinin sınıflandırılması ve yanan alanların belirlenmesi yaygın kullanılan yaklaşımlar olmuştur (Florath ve Keller, 2022). Son yıllarda literatürde yanmış alanların haritalanması için piksel tabanlı sınıflandırmadan daha doğru sonuçlar veren nesne-tabanlı görüntü sınıflandırması farklı çözünürlüklü uydu görüntülerine çeşitli platformlar aracılığı ile uygulanmıştır (Çömert vd., 2019; Georgopoulos vd., 2019; Liu vd., 2023; Polychronaki ve Gitas, 2012). Nesne-tabanlı görüntü sınıflandırmasının, yanmış orman alanlarını haritalamada umut verici sonuçlar sağladığı gösterilmiştir (Polychronaki ve Gitas, 2010). Nesne-tabanlı sınıflandırma yönteminin etkinliği farklı alanlarda kanıtlanmış olsa da yanmış orman alanlarının Sentinel-2 görüntülerinden tespiti ile ilgili çalışmalarda kullanımı hala nadirdir (Kulinar vd., 2024). Özellikle tek-zamanlı Sentinel-2 görüntülerinden GEE gibi bulut platformlar üzerinde nesne-tabanlı sınıflandırma ile yanmış orman alanlarının tespiti çalışmaları sınırlıdır. Mevcut uygulamaların çoğunda yangın öncesi ve sonrası olmak üzere iki zamanlı görüntünün teminine ve iki zaman arasındaki bitki örtüsünün değişimine dayalı yaklaşımlar kullanılmıştır (Alcaras vd., 2022; Arellano-Pérez vd., 2018; Bar vd., 2020; Shimabukuro vd., 2020). Tek zamanlı yaklaşım yalnızca yangın sonrası görüntü teminine ve tek görüntü üzerinden analize odaklanır ve daha hızlıdır. İki zamanlı yaklaşımın aksine bitki fenolojisindeki farklılıklar, atmosferik etkiler ve farklı zamana ait bulut örtüsü az olan görüntüleri bulma gibi konularda dezavantaj oluşturmaz (Alcaras vd., 2022).

Bu çalışmanın temel amacı son yıllarda yaygın kullanıma sahip olan bulut tabanlı GEE platformunda Sentinel-2 verisi ile sadece yangın sonrasına ait tek görüntü kullanarak nesne-tabanlı makine öğrenmesi sınıflandırması ile yanmış orman alanlarının haritalanmasını gerçekleştirmektir. 2021 yılında orman yangınlarının meydana geldiği Antalya ili, Manavgat ilçesi ve Muğla ili Kavaklıdere ilçesi çalışma alanları olarak seçilmiştir.

## 2. MATERYAL VE YÖNTEM

### 2.1 Çalışma Alanı

Türkiye'de orman yangınları genellikle ülkenin güney ve batı bölgelerinde, özellikle Akdeniz ve Ege kıyıları boyunca yoğunlaşmaktadır. Bu bölgeler genellikle yaz aylarında yüksek sıcaklıklar ve düşük nem seviyeleri gösterir ve bu durum orman yangını riskini ortaya çıkarır (Bilgiç vd., 2023). Bu çalışmada, iki çalışma alanı son 5 yılda Türkiye'de meydana gelen büyük orman yangınları arasından seçilmiştir. Seçilen alanlar, 2021 yılında orman yangınının meydana geldiği Muğla- Kavaklıdere bölgesi ve Antalya- Manavgat bölgesinde yer almaktadır. Çalışma alanlarının harita üzerindeki dağılımı Şekil 1'de gösterilmektedir. Kavaklıdere bölgesinde orman yangını 2 Ağustos 2021 tarihinde başlamış ve 6 gün sonra 8 Ağustos 2021 tarihinde kontrol altına alınmıştır. Sentinel-1 ve Sentinel-2 görüntülerine dayanan Avrupa Uzay Ajansı (ESA) WorldCover 10 m ürününe göre, 2021 yılında bu çalışma alanı 52388,2 ha ağaçlık, 1679,9 ha çalılık, 7022,9 ha otlak, 1894,8 ha ekili alan, 292,6 ha yapılaşma, 1000 ha çorak/seyrek bitki örtüsü ve 14,4 ha açık su içermektedir (Zanaga vd., 2022). Bu alanda hâkim ağaç türleri kızılçam ve karaçamdır. Orman alanının %13'ü bozuk meşcere, %46'sı yüksek orman arazisi ve %15'i maki bitki örtüsüdür. Manavgat çalışma alanında ise 28 Temmuz 2021 tarihinde başlayan orman yangını 8 Ağustos 2021 tarihinde kontrol altına alınmıştır. Yangın orman alanıyla birlikte yoğun bir ekili alana da zarar vermiştir. ESA WorldCover'a göre 2021'deki alan 94048,1 ha ağaçlık, 11293,1 ha çalılık, 30544,1 ha otlak, 9217,2 ha ekili alan, 3427 ha yapılaşma, 1877,3 ha çorak/seyrek bitki örtüsü, 10712,3 ha açık su ve 57,8 ha otsu sulak alan içermektedir (Zanaga vd., 2022). Bu alanda hâkim ağaç türleri kızılçam, karaçam ve kısmen ardıçtır. Ormanlık alanlarda az miktarda meşe, kayın ve gürgen bulunmaktadır. Orman alanının %13'ü bozuk meşcere, %31'i yüksek orman arazisi, %7'si maki vejetasyonu ve %13'ü bozuk baltalıktır. Çalışma alanlarının seçiminde, yanan alanların orman, tarım ve yerleşim gibi farklı arazi kullanımı ve arazi örtüsünü temsil etmesine dikkat edilmiştir. Yangının davranışı farklı arazi örtüsü türlerinde farklılık gösterebilir. Ayrıca, yangın sadece homojen ormanlık alanlarda değil heterojen ormanlık alanlarda da meydana gelebileceğinden, farklı arazi örtüsü dağılımına sahip test alanları seçilmiştir.



**Şekil 1.** a) Çalışma Alanları b) Kavaklıdere çalışma alanında yangından sonra 17 Ağustos 2021 tarihinde alınan Sentinel-2 uydu görüntüsü (Yalancı renklendirme: B11, B8 ve B4) c) Manavgat çalışma alanında yangından sonra 09 Ağustos 2021 tarihinde alınan Sentinel-2 uydu görüntüsü (Yalancı renklendirme: B11, B8 ve B4).

## 2.2. Veri Seti

GEE kullanıcılara uydu görüntüleri, iklim verileri, arazi örtüsü haritaları, arazi verileri gibi kaynakları kapsayan veri setlerine GEE veri kataloğu aracılığı ile ücretsiz erişim sunar (GEE, 2024). GEE veri kataloğu, optik ve optik olmayan dalga boylarında çeşitli uydu sistemlerinden yapılan gözlemler, çevresel değişkenler, hava ve iklim tahminleri ve geçmiş tahminler, arazi örtüsü, topografik ve sosyoekonomik veri kümeleri dahil olmak üzere, kamuya açık geniş bir coğrafi veri kümesi deposunu barındırır. Veri kataloğunun büyük bir kısmı Landsat, Sentinel-1 ve Sentinel-2'den gelen verilerin eksiksiz arşivini içerir (Gorelick vd., 2017). Bu çalışmada, GEE'de 'COPERNICUS/S2\_SR' kimliğine sahip Sentinel-2 Seviye 2A ürünleri kullanılmıştır (Çizelge-1). Sentinel-2, Avrupa'nın Copernicus programına adanmış olan misyonu ile aynı yörüngede bulunan iki özdeş uydudan (Sentinel-2A ve Sentinel-2B) oluşan bir takımyıldızına dayanmaktadır. Kara ve bitki örtüsüne dair uygulamaları destekler (ESA, 2024). Sentinel-2 10 metre mekânsal çözünürlükte dört bant, 20 m mekânsal çözünürlükte altı bant ve 60 metre mekânsal çözünürlükte üç bant

olmak üzere toplam 13 spektral bant içerir. Sentinel-2 ikiz uyduları, 5 günlük yüksek bir tekrar ziyaret sıklığı ile mevcut gözlemlere büyük katkı sağlayan çok bantlı görüntü hizmeti sağlar (Copernicus, 2024).

**Çizelge 1.** Çalışmada kullanılan Sentinel-2 verileri

Çalışma Alanı	Yangın Sonrası Görüntü	Görüntü Tarihi
Kavaklıdere	COPERNICUS/S2_SR/20210817T084601_20210817T085325_T35SPB	17.08.2021
Manavgat	COPERNICUS/S2_SR/20210809T083559_20210809T083843_T36SUF COPERNICUS/S2_SR/20210809T083559_20210809T083843_T36SUG	09.08.2021

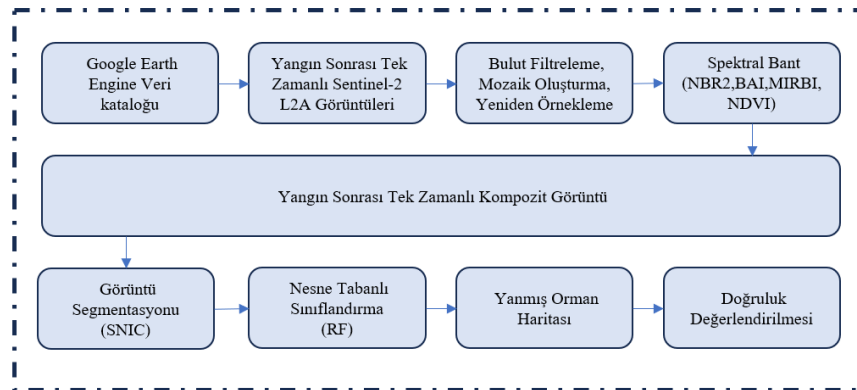
Literatürdeki çalışmalar yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantların yangın etkilerine karşı hassas olduğunu göstermiştir (Chuvieco vd., 2019; García ve Caselles, 1991; Oliva vd., 2011; Pereira vd., 1999). Roteta vd. (2021) tarafından yapılan çalışmada görünür bantlarda yangına karşı daha az hassasiyet tespit edilmiştir, ancak çalışmalarda bulutları maskeleyen ve ekili alanlar hakkındaki karışıklığı azaltmak için kullanılmıştır. Mevcut çalışmaların kapsamına dayanarak, bu çalışmada B2, B3, B4, B8, B11 ve B12 bantları kullanılmıştır (Çizelge-2).

**Çizelge 2.** Çalışmada kullanılan Sentinel-2 bantları

Bant	Tanım	Çözünürlük
B2	Mavi	10 m
B3	Yeşil	10 m
B4	Kırmızı	10 m
B8	NIR	10 m
B11	SWIR1	20 m
B12	SWIR2	20 m

## 2.3 Metodoloji

GEE Kod editör platformunda yangın sonrası tek zamanlı Sentinel-2 görüntüleri kullanılarak yanmış orman alanlarının haritalanması için kullanılan işlem adımları Şekil 2’de gösterilmiştir. İlk olarak GEE veri kataloğu üzerinden Sentinel-2 L2A verilerine erişilmiş ve çalışma alanına göre görüntü kırma, mozaikleme ve bulut filtreleme işlemleri yapılmıştır. Sonra çalışmada kullanılan tüm spektral bantların aynı geometrik çözünürlüğe sahip olmasını sağlamak için, 20 m çözünürlüklü bantlar 10 m çözünürlüğe yeniden örneklenmiştir. Çalışmada kullanılan Sentinel-2 görüntüsünün ham bantlarına ek olarak orta kızılötesi yanma indeksi (Mid-Infrared Burn Index- MIRBI), normalize edilmiş yanma şiddeti (Normalized Burn Ratio 2- NBR2), yanmış alan indeksi (Burn Area Index- BAI) ve normalize edilmiş bitki indeksi (Normalized Difference Vegetation Index – NDVI) bantları hesaplanmış ve görüntüye ek bantlar olarak dahil edilmiştir. Elde edilen kompozit görüntü basit yinelemesiz kümeleme (Simple Non-Iterative Clustering- SNIC) algoritması ile segmentlere bölünmüştür. Nesne tabanlı sınıflandırma için eğitim örnekleri GEE platformu üzerinde toplanmış ve rastgele orman (RO) algoritması ile çalışma alanlarına ait yangın sonrası tek zamanlı Sentinel-2 görüntülerine nesne-tabanlı sınıflandırma uygulanmıştır. Doğruluk değerlendirilmesi haricindeki tüm iş akışı GEE platformunda gerçekleştirilmiştir. Doğruluk değerlendirilmesi için yüksek çözünürlüklü Google Earth görüntüleri, doğal renk ve sahte renk kompozitleri kullanılmış ve ArcGIS Pro yazılımı ile hata matrisi oluşturulmuştur.



**Şekil 2.** İşlem adımları

### 2.3.1 Ön Hazırlık

Bu çalışmada ön hazırlık sürecini GEE veri kataloğundan gelen verilerin çalışma alanına göre kesilmesi, mozaik oluşturma, tarih filtreleme, bulut filtreleme gibi işlemler oluşturmaktadır. Çalışmada kullanılan B2, B3, B4, B8, B11 ve B12 Sentinel-2 bantların aynı mekânsal çözünürlüğe sahip olmasını sağlamak için 20 m çözünürlüklü B11 ve B12 bantları 10 m çözünürlüğe yeniden örneklenmiştir. Ayrıca bu çalışmada, hesaplanan dört spektral indeks (NBR2, BAI, MIRBI ve NDVI) kullanılmıştır. Bu spektral indeksler yanmış alanların tespitinde yaygın olarak kullanıldığı ve literatürde çeşitli araştırmacılar tarafından Sentinel-2 görüntülerinden yanmış alanların tespiti için performansları çeşitli çalışmalarla değerlendirildiği için seçilmiştir (Kulinar vd., 2024; Liu vd., 2023; Roteta vd., 2019). Dolayısıyla, bu çalışmalardan esinlenerek MIRBI, BAI, NBR2 ve NDVI spektral indeksler olarak seçilmiştir. Bu spektral indeksler görüntülere ek bantlar olarak eklenmiştir. Böylece çalışmada kullanılan Sentinel-2 görüntüsü B2, B3, B4, B8, B11 ve B12 bantları ile beraber toplam 10 bantlı görüntüler segmentasyon için hazır hale getirilmiştir.

### 2.3.2 Basit Yinelemesiz Kümeleme (Simple Non-Iterative Clustering- SNIC) Algoritması ile Görüntü Segmentasyonu

Nesne-tabanlı sınıflandırma işleminden önce görüntünün amaca uygun şekilde segmentasyonu gerekir. Segmentasyon, benzer özelliklere sahip pikselleri homojen görüntü nesnelere ayırmak için nesne-tabanlı sınıflandırmanın en önemli ve ilk adımıdır (Kulinar vd., 2024; Torunlar vd., 2021). GMeans, KMeans ve SNIC, GEE'de görüntü bölütleme için kullanılabilen üç algoritmadır. Bu çalışmada segmentasyon algoritması olarak basit yinelemesiz kümeleme (Simple Non-Iterative Clustering- SNIC) algoritması seçilmiştir. SNIC algoritması GEE'de kullanıma sunulan ve basit doğrusal yinelemeli kümeleme (Simple Linear Iterative Clustering- SLIC) algoritmasının yinelemeli olmayan versiyonu olarak geliştirilmiş halidir. SNIC algoritması hesaplama verimliliğini ve segmentasyon kalitesini artırır, daha az bellek gerektirir ve daha hızlı ve basit bir algoritmadır (Achanta ve Susstrunk, 2017). SNIC algoritması, SLIC algoritması gibi, merkez noktalarını normal ızgarada seçilen piksellerle başlatır. Ardından, bir pikselin merkeze yakınlığını belirlemek için SLIC algoritması gibi normalleştirilmiş uzamsal mesafeler ve renk mesafeleri kullanılır. Bu, homojen süper pikseller oluşturur ve merkeze olan en küçük mesafe hangi aday pikselin seçileceğini belirler. Tohum boyutu, kompaktlık, bağlanabilirlik ve komşuluk boyutu SNIC algoritmasının temel parametreleridir. Kompaktlık parametresi kümelerin şeklini etkiler ve daha büyük değerler daha kompakt, yani kareye daha yakın kümeler üretir. Bağlanabilirlik parametresi, komşu piksellerin süper piksele atanırken nasıl alınacağını ifade eder. Komşuluk boyutu parametresi kümeleme için kullanılan pencere boyutunu belirtir. Tohum boyutu parametresi piksel cinsinden süper piksel tohum konumu aralığını tanımlar (Achanta ve Susstrunk, 2017; Kulinar vd., 2024; Mahdianpari vd., 2018; Shafizadeh-Moghadam vd., 2021; Tassi vd., 2021; Tassi ve Vizzari, 2020).

Bu çalışmada SNIC algoritmasına dayalı süper piksel kümeleme için GEE platformunda “ee.Algorithms.Image.Segmentation.SNIC” algoritması kullanılmıştır. SNIC algoritması girdi bantlarının her biri için tüm bantların ortalama değerini içeren segmentlerden oluşan ve her bir segmente atanan id numarasından oluşan bant dahil olmak üzere çok bantlı bir raster oluşturulur. Bu şekilde her bir segment için o segmentin içinde yer alan pikseller ile girdi bantlarının her biri için ortalama değerler hesaplanmış ve bir segmentteki her piksele o segmentin ortalama değeri atanmış olur. SNIC çıktıları, GEE platformundaki görselleştirme ölçeğine bağlı olarak değişmektedir (Tassi ve Vizzari, 2020). Bunun için “ee.Image.reproject” fonksiyonu kullanılarak çıktı ölçeği sabitlenmiştir. Böylelikle SNIC algoritması sonucu oluşan ve her bir segment için ortalama değerleri içeren çıktı görüntü artık sınıflandırma aşamasının girdisi olarak hazır edilmiştir.

### 2.3.3 Nesne-Tabanlı Sınıflandırma

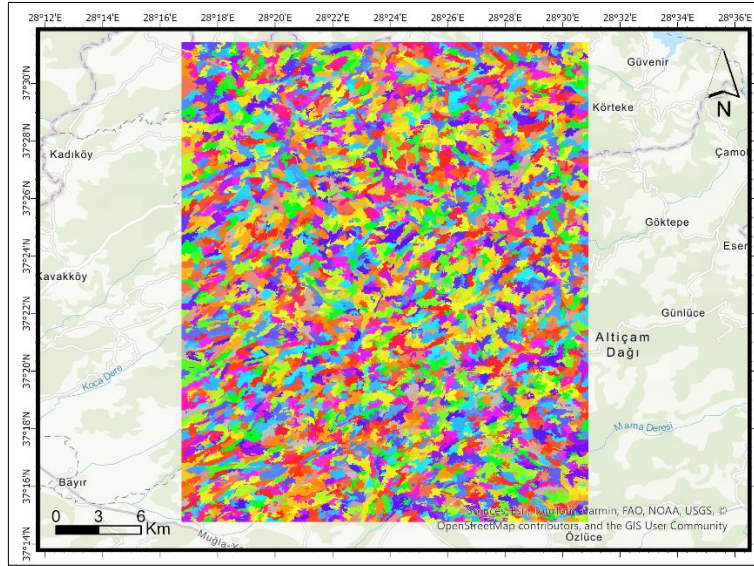
Nesne-tabanlı görüntü analizi spektral bilginin yanında mekânsal bilgiyi de kullanan bir yaklaşımdır (Mitri ve Gitas, 2004). Nesne-tabanlı sınıflandırmanın görüntünün renk, şekil, boyut gibi özelliklerini kullanması ve böylelikle nesnelere analiz etmesi ve ardından sınıflandırma aşamasına geçmesi diğer sınıflandırmalarda karşılaşılan birçok soruna çözüm sunmaktadır. Bu çalışmada, görüntü sınıflandırması nesne-tabanlı yaklaşım kullanılarak gerçekleştirilmiştir. Sınıflandırma algoritması olarak RO makine öğrenmesi modeli seçilmiştir. GEE'de RO algoritması başta olmak üzere çeşitli makine öğrenim algoritmaları yer almaktadır. Ma vd. (2017) tarafından yapılan çalışmada, nesne-tabanlı arazi örtüsü sınıflandırması üzerine yapılan 173 bilimsel çalışma incelenmiş ve RO algoritmasının nesne-tabanlı sınıflandırma için en iyi performans gösteren ve son yıllarda en yaygın kullanılan algoritma olduğu sonucuna varılmıştır.

Bu çalışmada eğitim verilerinin toplanması segmentasyon aşamasından sonra gerçekleştirilmiştir ve eğitim örnekleri, oluşturulan segmentlere dayalı olarak toplanmıştır. GEE platformunda sınıflandırıcı piksel bazında standartlaştırılmıştır (Firigato, 2024). Bu nedenle, her segment için SNIC algoritması ile segment içinde kalan piksellerden ortalama değer hesaplanmış ve bir segment içinde kalan tüm piksellere o segmentin hesaplanan ortalama değeri atanmıştır (Tassi ve Vizzari, 2020). Segmente edilmiş görüntülerden GEE web tabanlı kod editörünün geometri araçları kullanılarak segment sayısının %5-20'si kadarki eğitim örnekleri olarak seçilmiştir. Eğitim verileri “yanmış”

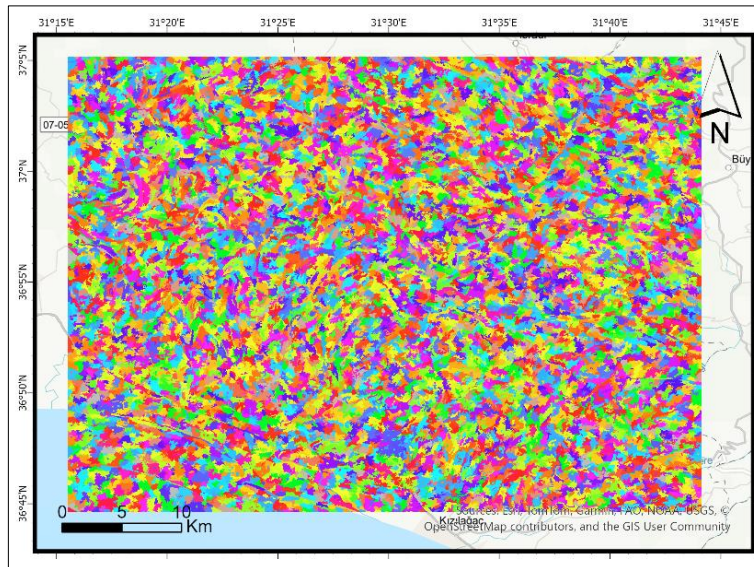
ve “yanmamış” olmak üzere iki sınıf için toplanmıştır. Eğitim verileri özellik koleksiyonu olarak toplanmıştır ve sınıf etiketini saklayan bir özelliğe sahiptir. Seçilen eğitim örnekleri yüzde 70'e yüzde 30 oranında eğitim ve doğrulama olarak rastgele bölünmüştür. Eğitim için ayrılan veriler modeli eğitmek için kullanılmıştır. Böylelikle Kavaklıdere ve Manavgat çalışma alanları için toplanan eğitim verileri kullanılarak RO modeli oluşturulmuş ve bu model kullanılarak nesne-tabanlı sınıflandırma işlemi gerçekleştirilmiştir.

### 3. BULGULAR VE TARTIŞMA

GEE, SNIC segmentlerini, yani kümeleri tanımladıktan sonra çıktı olarak çok bantlı bir raster veri kümesi oluşturmuştur. Bu çok bantlı raster veri kümesi, kümeleri ve giriş bantlarının ortalama değerlerini içeren ek katmanı içerir. Bu çalışmada, giriş görüntüsü 10 bantlı bir kompozit görüntüdür. SNIC algoritmasının çıktısı 11 bantlı bir veri kümesidir. Bu 11 bantlı veri kümesinin 10 bantı, her bir segment için segment içinde kalan piksellerden hesaplanan giriş bantlarının ortalama değerlerini içerir. Bir bant ise küme kimlik bilgilerini(id) içerir. Segmentasyon işlemi ile Kavaklıdere çalışma alanında toplam 4056 segment, Manavgat çalışma alanında toplam 10176 segment üretilmiştir. Dolayısıyla, segmentasyon işlemi ile girdi veri elemanı sayısı (piksel/segment sayısı) Kavaklıdere çalışma alanı için 6425837 adet pikselden 4056 adet segmente, Manavgat çalışma alanı için ise 20210553 adet pikselden 10176 adet segmente düşmüştür. Kavaklıdere ve Manavgat çalışma alanlarına ait görüntü segmentasyonu sonuçları sırasıyla Şekil 3 ve Şekil 4'te gösterilmiştir.



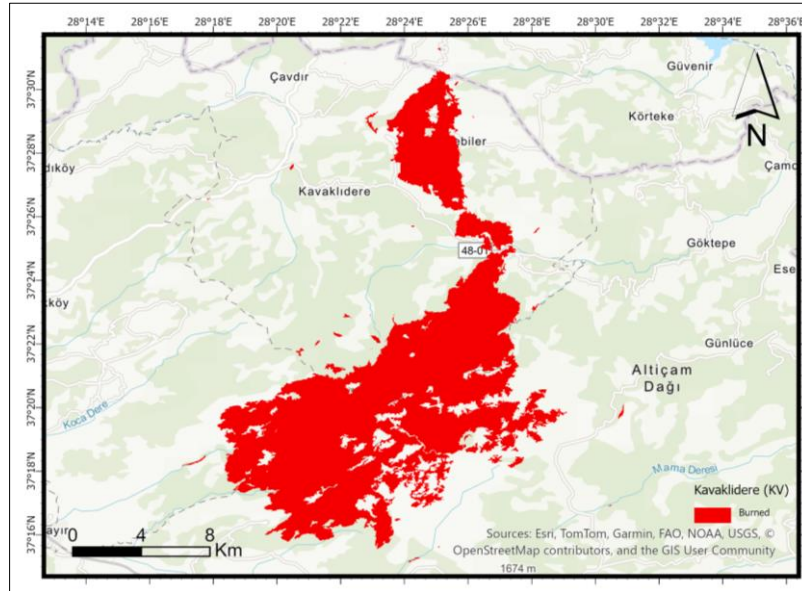
Şekil 3. Kavaklıdere segmentasyon sonucu



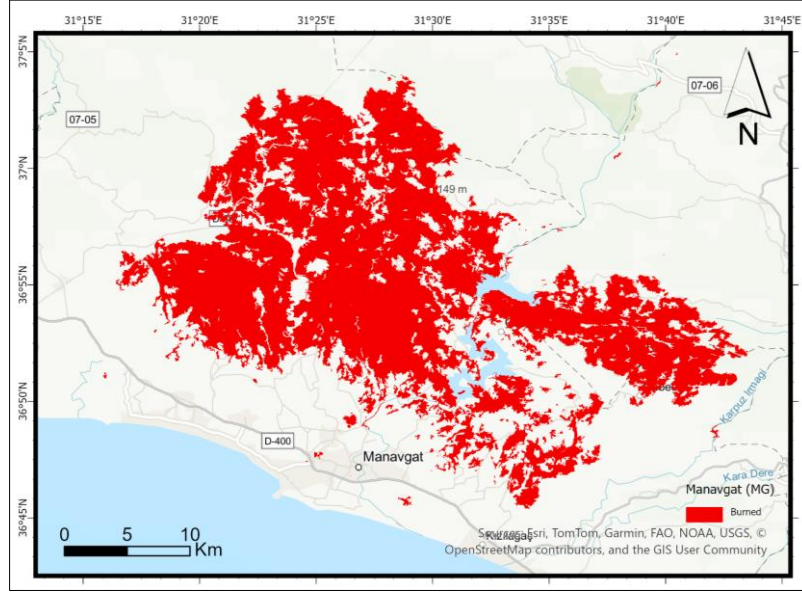
Şekil 4. Manavgat segmentasyon sonucu

SNIC çıktı görüntüsü GEE platformundaki görselleştirme ölçeğine bağlı olarak değiştiğinden, segmentasyon çıktıları olan kümeler için çıktı ölçeği sabit olmalıdır. Bu çalışmada, küme çıktı ölçekleri Sentinel-2'nin doğal çözünürlüğü olan 10m'ye sabitlenmiştir. Kümelerin çıktı ölçeği işlem süresini etkiler. Örneğin, kümeleri daha düşük bir ölçeğe ayarlamanın işlem süresini hızlandırdığı görülmüştür. SNIC algoritması düzenli aralıklı bir tohum ızgarasına dayanmaktadır. Seçilen tohum ızgarası parametresi, yani piksel cinsinden süper piksel tohum konumu aralığı, küme sayısını etkiler. Çalışmanın amacına ve çalışma alanının durumuna göre daha etkili bir küme boyutu bulmak için farklı tohum ızgarası parametreleri ile farklı küme şekillerinin değerlendirilmesi gereklidir. Tassi ve Vizzari (2020) Sentinel-2 ve Landsat-8 görüntüleri ile arazi kullanımı ve sınıflandırması için farklı veri setlerine çeşitli tohum ızgarası parametreleri uygulayarak farklı sınıflandırma algoritmalarının genel doğruluğunu karşılaştırmış ve çeşitli tohum ızgarası parametrelerinin test edilmesinin etkili küme boyutunun bulunmasında faydalı olacağını vurgulamıştır. Bu çalışmada, iki çalışma alanı için tohum ızgarası parametre değeri, çalışma alanlarının heterojenliği dikkate alınarak birkaç denemeye dayalı olarak belirlenmiştir. Aşırı ve yetersiz segmentasyondan kaçınmak için uygun boyutlarda segmentler oluşturmak önemlidir. Yetersiz segmentasyon daha karmaşık nesnelere ve sınıflandırmada doğal bir hataya neden olur (Ma vd., 2015). Segmentleri bölmek birleştirmekten daha karmaşık bir işlem olduğu için aşırı segmentasyon yetersiz segmentasyona tercih edilebilir (Kotaridis ve Lazaridou, 2023). Bu çalışmada, seçilen çalışma alanları oldukça heterojendir. Ayrıca, yanmış alanların kendileri de farklı şiddette yanma eğiliminde oldukları için heterojenlik göstermektedir. Bu nedenle, bu çalışmada aşırı segmentasyon tercih edilmiştir. Aşırı segmentasyon, daha küçük boyutlarda daha fazla sayıda segment üretir. Bu durum sınıflandırma için hesaplama süresini artırsa da sınıflandırma doğruluğunu etkilemez (Qu vd., 2021). GEE'de segmentasyon ve nesne-tabanlı sınıflandırma için gereken hesaplama ve analiz, hesaplama ve analitik olarak ağırdır ve bu durum, GEE'nin kullanıcılara ücretsiz olarak sunduğu işlem ve bellek limiti kotaları nedeniyle hatalara veya analizin daha uzun sürmesine neden olabilir (Kulinar vd., 2024). Özellikle raster formundaki segmentlerin vektör formuna dönüştürülmesi, tohum grid parametresinin düşük tutulması ve segment sayısının fazla olması durumunda uzun zaman almaktadır. Bu çalışmada görüntü bölütleme sonucu sadece bölütlerin görsel analizi ve bölütlerden eğitim örnekleri toplamak için vektör formuna dönüştürülmüştür. Geliştirilen kodun hızlı çalışması ve aşırı bölütlemeye kaynaklanan sorunların yaşanmaması için bölütlerin görsel analizi dışındaki tüm işlemler raster veri kümesi üzerinde başarıyla gerçekleştirilmiştir.

Segmentasyon aşamasından sonra iki çalışma alanından da eğitim verileri ayrı ayrı toplanmış ve toplanan eğitim verileriyle RO algoritması eğitilmiş ve nesne-tabanlı sınıflandırma mantığına dayalı olarak yanmış alan haritaları oluşturulmuştur. Şekil 5 ve Şekil 6 sırası ile Kavaklıdere ve Manavgat çalışma alanları için üretilen yanmış orman alanı haritalarını göstermektedir.



Şekil 5. Kavaklıdere çalışma alanına ait nesne-tabanlı RO sınıflandırması ile elde edilmiş yanmış orman alanı haritası



Şekil 6. Manavgat çalışma alanına ait nesne-tabanlı RO sınıflandırması ile elde edilmiş yanmış orman alanı haritası

Çizelge 3'de tek zamanlı Sentinel-2 ve GEE kullanılarak nesne-tabanlı RO sınıflandırması sonuçlarının genel doğruluğu ve Kappa değerleri sunulmaktadır. Sonuçlar, yüksek çözünürlüklü Google Haritaları ve gerçek renkli ve sahte renkli Sentinel-2 görüntüleri temel alınarak doğrulanmıştır. Kavaklıdere çalışma alanının genel doğruluğu %97.7 ile Manavgat çalışma alanından daha yüksektir. Kavaklıdere çalışma alanı Manavgat çalışma alanına kıyasla hem daha fazla orman örtüsü hem de daha az heterojenlik içermektedir. Yüksek orman arazisi bu çalışma alanının yaklaşık %46'sını oluşturmaktadır. Bu da çalışma alanının yapısının sınıflandırma doğruluğu üzerinde etkili olduğu anlamına gelmektedir.

Çizelge 3. Kavaklıdere ve Manavgat çalışma alanlarına ait nesne-tabanlı RO sınıflandırma doğrulukları

Çalışma Alanı	Genel Doğruluk	Kappa
Kavaklıdere	97.7%	92.8%
Manavgat	94.8%	87%

#### 4. SONUÇLAR

Orman yangınları alanında Sentinel-2 kullanılarak nesne-tabanlı makine öğrenme sınıflandırma çalışmaları sınırlıdır. Bu çalışmada, ücretsiz bir coğrafi işleme ve analiz platformu olan GEE platformu üzerinde SNIC segmentasyonu ve RO makine öğrenmesi algoritması entegre edilmiş ve iki farklı çalışma alanındaki yanmış alanlar, yangın sonrası Sentinel-2 görüntülerinden nesne-tabanlı sınıflandırma yaklaşımı ile başarılı bir şekilde çıkarılmıştır. Sentinel-2 görüntüleri, ön işleme işlemlerinden sonra segmentasyon aşamasının gerçekleştirilmesi için kullanıma hazır hale getirilmiştir. Görüntü segmentasyonu gerçekleştirildikten sonra segmente edilen görüntü üzerinde nesne-tabanlı RO sınıflandırması gerçekleştirilmiştir.

Bu çalışmadan elde edilen temel sonuçlar aşağıdaki gibi özetlenebilir:

- Sonuçlar, nesne-tabanlı RO modelinin %94'ün üzerinde bir genel doğruluk ile yanmış orman alanlarının tespiti ve haritalanması için etkin bir şekilde kullanılabilirliğini göstermektedir.
- Sonuçlar, yangın sonrası tek zamansal yaklaşımla, yanmış orman alanlarının Sentinel-2 görüntülerinden başarılı bir şekilde tespit edilebileceğini göstermektedir.
- Farklı segmentasyon parametreleri görüntü nesnelere boyutunu ve sayısını etkileyerek sınıflandırma sonuçlarını doğrudan etkileyebilmektedir. Süper piksel tohum aralığını piksel cinsinden tanımlayan tohum boyutu parametresinin segmentasyon sonuçları üzerinde oldukça etkili olduğu görülmüştür. Bu nedenle, en iyi segmentasyon sonuçlarını elde etmek için tohum boyutu parametresini ve diğer segmentasyon parametrelerini test etmek ve değerlendirmek önemlidir, çünkü uygun parametrenin seçilmemesi aşırı veya yetersiz segmentasyona yol açabilir ve sınıflandırma sonuçlarını doğrudan etkileyebilir.

- Test edilen SNIC parametreleri sonucunda daha küçük boyutlu segmentler toplam alanda daha fazla sayıda segment ile sonuçlanmış, çalışma alanı büyüdükçe sınıflandırılacak segment sayısı artmış ve işlem süresi uzamıştır. Bu durum, GEE'nin hesaplama ve bellek sınırlamaları nedeniyle uzun ve yoğun analizlere veya hatalara yol açabilir.

Özet olarak bu çalışma, bulut tabanlı GEE platformu kullanılarak yangın sonrası tek zamanlı Sentinel-2 görüntülerinden nesne-tabanlı RO sınıflandırması ile yanmış orman alanlarının etkili bir şekilde tespit edilebildiğini göstermiştir. Ayrıca bu çalışma, GEE platformunun özellikle orman yangınları olmak üzere afet yönetimi için güçlü ve tercih edilen bir araç olma potansiyeline sahip olduğunu vurgulamaktadır.

## 5. TEŞEKKÜR

Bu çalışma da Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Geomatik Mühendisliği Anabilim dalında Fidan Şevval Bulut tarafından hazırlanan “Burned Forest Area Mapping From Post-Fire Sentinel-2 Imagery Using Object-Based Machine Learning Classification” isimli yüksek lisans tezi kapsamındaki bazı verilerden yararlanılmıştır.

## KAYNAKLAR

**Achanta, R. ve Susstrunk, S.**, 2017. Superpixels and polygons using simple non-iterative clustering. *Proceedings of the IEEE conference on computer vision and pattern recognition*, syf: 4651-4660.

**Achour, H., Toujani, A., Trabelsi, H. ve Jaouadi, W.**, 2022. Evaluation and comparison of Sentinel-2 MSI, Landsat 8 OLI, and EFFIS data for forest fires mapping. Illustrations from the summer 2017 fires in Tunisia. *Geocarto International*, 37(24): 7021-7040.

**Alcaras, E., Costantino, D., Guastaferrero, F., Parente, C. ve Pepe, M.**, 2022. Normalized Burn Ratio Plus (NBR+): a new index for Sentinel-2 imagery. *Remote Sensing*, 14(7): 1727.

**Amos, C., Petropoulos, G.P. ve Ferentinis, K.P.**, 2019. Determining the use of Sentinel-2A MSI for wildfire burning & severity detection. *International Journal of Remote Sensing*, 40(3): 905-930.

**Arellano-Pérez, S., Ruiz-González, A.D., Álvarez-González, J.G., Vega-Hidalgo, J.A., Díaz-Varela, R. ve Alonso-Rego, C.**, 2018. Mapping fire severity levels of burned areas in Galicia (NW Spain) by Landsat images and the dNBR index: Preliminary results about the influence of topographical, meteorological and fuel factors on the highest severity level.

**Bar, S., Parida, B.R. ve Pandey, A.C.**, 2020. Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya. *Remote Sensing Applications: Society and Environment*, 18: 100324.

**Bilgiç, E., Tuygun, G.T. ve Gündüz, O.**, 2023. Development of an emission estimation method with satellite observations for significant forest fires and comparison with global fire emission inventories: Application to catastrophic fires of summer 2021 over the Eastern Mediterranean. *Atmospheric Environment*, 308: 119871.

**Chuvieco, E., Martín, M.P. ve Palacios, A.**, 2002. Assessment of different spectral indices in the red-near-infrared spectral domain for burned land discrimination. *International Journal of Remote Sensing*, 23(23): 5103-5110.

**Chuvieco, E., Mouillot, F., Van der Werf, G.R., San Miguel, J., Tanase, M., Koutsias, N., García, M., Yebra, M., Padilla, M. ve Gitas, I.**, 2019. Historical background and current developments for mapping burned area from satellite Earth observation. *Remote Sensing of Environment*, 225: 45-64.

**Copernicus**, 2024. Copernicus. [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/Sentinel-2](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2) [Erişim tarihi: 19.09.2024].

**Çolak, E. ve Sunar, F.**, 2020. Evaluation of forest fire risk in the Mediterranean Turkish forests: A case study of Menderes region, Izmir. *International Journal of Disaster Risk Reduction*, 45: 101479.

**Çömert, R., Matcı, D.K. ve Avdan, U.**, 2019. Object based burned area mapping with random forest algorithm. *International Journal of Engineering and Geosciences*, 4(2): 78-87.

**ESA**, 2024. ESA. [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/Sentinel-2](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2) [Erişim tarihi: 19.09.2024].

- Firigato, J.O.N.**, 2024. Object Based Image Analysis on Google Earth Engine. <https://joaootavionf007.medium.com/object-based-image-analysis-on-google-earth-engine-1b80e9cb7312> [Erişim tarihi: 19.09.2024].
- Florath, J. ve Keller, S.**, 2022. Supervised machine learning approaches on multispectral remote sensing data for a combined detection of fire and burned area. *Remote Sensing*, 14(3): 657.
- García, M.L. ve Caselles, V.**, 1991. Mapping burns and natural reforestation using Thematic Mapper data. *Geocarto International*, 6(1): 31-37.
- GEE**, 2024. GEE. <https://earthengine.google.com/> [Erişim tarihi: 19.09.2024].
- Georgopoulos, N., Stavrakoudis, D. ve Gitas, I.Z.**, 2019. Object-Based Burned Area Mapping Using Sentinel-2 Imagery and Supervised Learning Guided by Empirical Rules. *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium*, syf: 9980-9983.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. ve Moore, R.**, 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202: 18-27.
- Konkathi, P. ve Shetty, A.**, 2021. Inter comparison of post-fire burn severity indices of Landsat-8 and Sentinel-2 imagery using Google Earth Engine. *Earth Science Informatics*, 14(2): 645-653.
- Kotaridis, I. ve Lazaridou, M.**, 2023. Integrating image segmentation in the delineation of burned areas on Sentinel-2 and Landsat 8 data. *Remote Sensing Applications: Society and Environment*, 30: 100944.
- Kulinan, A.S., Cho, Y., Park, M. ve Park, S.**, 2024. Rapid wildfire damage estimation using integrated object-based classification with auto-generated training samples from Sentinel-2 imagery on Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, 126: 103628.
- Kumar, L. ve Mutanga, O.**, 2018. Google Earth Engine applications since inception: Usage, trends, and potential. *Remote Sensing*, 10(10): 1509.
- Liu, P., Liu, Y., Guo, X., Zhao, W., Wu, H. ve Xu, W.**, 2023. Burned area detection and mapping using time series Sentinel-2 multispectral images. *Remote Sensing of Environment*, 296: 113753.
- Ma, L., Cheng, L., Li, M., Liu, Y. ve Ma, X.**, 2015. Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102: 14-27.
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P. ve Liu, Y.**, 2017. A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130: 277-293.
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S. ve Gill, E.**, 2018. The first wetland inventory map of newfoundland at a spatial resolution of 10 m using sentinel-1 and sentinel-2 data on the google earth engine cloud computing platform. *Remote Sensing*, 11(1): 43.
- Mitri, G.H. ve Gitas, I.Z.**, 2004. A semi-automated object-oriented model for burned area mapping in the Mediterranean region using Landsat-TM imagery. *International Journal of Wildland Fire*, 13(3): 367-376.
- MUTANGA, O. VE KUMAR, L.**, 2019. Google Earth Engine Applications. MDPI, p. 591.
- Oliva, P., Martín, P. ve Chuvieco, E.**, 2011. Burned area mapping with MERIS post-fire image. *International Journal of Remote Sensing*, 32(15): 4175-4201.
- Pereira, J.M., Sá, A.C., Sousa, A.M., Silva, J.M., Santos, T.N. ve Carreiras, J.M.**, 1999. Spectral characterisation and discrimination of burnt areas. *Remote Sensing of Large Wildfires: In the European Mediterranean Basin*: 123-138.
- Polychronaki, A. ve Gitas, I.Z.**, 2010. The development of an operational procedure for burned-area mapping using object-based classification and ASTER imagery. *International Journal of Remote Sensing*, 31(4): 1113-1120.

- Polychronaki, A. ve Gitas, I.Z.**, 2012. Burned area mapping in Greece using SPOT-4 HRVIR images and object-based image analysis. *Remote Sensing*, 4(2): 424-438.
- Pulvirenti, L., Squicciarino, G., Fiori, E., Fiorucci, P., Ferraris, L., Negro, D., Gollini, A., Severino, M. ve Puca, S.**, 2020. An automatic processing chain for near real-time mapping of burned forest areas using sentinel-2 data. *Remote Sensing*, 12(4): 674.
- Qu, L.a., Chen, Z., Li, M., Zhi, J. ve Wang, H.**, 2021. Accuracy improvements to pixel-based and object-based lulc classification with auxiliary datasets from Google Earth engine. *Remote Sensing*, 13(3): 453.
- Roteta, E., Bastarrika, A., Ibisate, A. ve Chuvieco, E.**, 2021. A preliminary global automatic burned-area algorithm at medium resolution in Google Earth Engine. *Remote Sensing*, 13(21): 4298.
- Roteta, E., Bastarrika, A., Padilla, M., Storm, T. ve Chuvieco, E.**, 2019. Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. *Remote Sensing of Environment*, 222: 1-17.
- Shafizadeh-Moghadam, H., Khazaei, M., Alavipanah, S.K. ve Weng, Q.**, 2021. Google Earth Engine for large-scale land use and land cover mapping: An object-based classification approach using spectral, textural and topographical factors. *GIScience & Remote Sensing*, 58(6): 914-928.
- Shimabukuro, Y.E., Dutra, A.C., Arai, E., Duarte, V., Cassol, H.L.G., Pereira, G. ve Cardozo, F.d.S.**, 2020. Mapping burned areas of Mato Grosso state Brazilian Amazon using multisensor datasets. *Remote Sensing*, 12(22): 3827.
- Tassi, A., Gigante, D., Modica, G., Di Martino, L. ve Vizzari, M.**, 2021. Pixel-vs. Object-based landsat 8 data classification in google earth engine using random forest: The case study of maiella national park. *Remote Sensing*, 13(12): 2299.
- Tassi, A. ve Vizzari, M.**, 2020. Object-oriented lulc classification in google earth engine combining snic, glcm, and machine learning algorithms. *Remote Sensing*, 12(22): 3776.
- Taşcı, İ., Avdan, Z.Y., Avdan, U. ve Çömert, R.**, Orta Çözünürlüklü Uydu Görüntülerinden Değişim Saptama İle Yanmış Orman Alanlarının Haritalanması. *VII. Uzaktan Algılama-CBS Sempozyumu*, 880-887.
- Torunlar, H., Tuğaç, M.G. ve Duyan, K.**, 2021. Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; Konya-Karapınar Örneği. *Türkiye Uzaktan Algılama Dergisi*, 3(2): 36-46.
- Zanaga, D., Van De Kerchove, R., Daems, D., De Keersmaecker, W., Brockmann, C., Kirches, G., Wevers, J., Cartus, O., Santoro, M. ve Fritz, S.**, 2022. ESA WorldCover 10 m 2021 v200.