




## Geomatik

<https://dergipark.org.tr/tr/pub/geomatik>

e-ISSN 2564-6761



# Google Earth Engine kullanılarak makine öğrenmesi tabanlı iyileştirilmiş arazi örtüsü sınıflandırması: Atakum, Samsun örneği

Zelalem Getachew Ayalke\*<sup>1</sup>, Aziz Şişman<sup>1</sup>

<sup>1</sup>Ondokuz Mayıs Üniversitesi Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Samsun, Türkiye, 19211596@stu.omu.edu.tr, asisman@omu.edu.tr

Kaynak Göster: Ayalke, G. Z., & Şişman, A. (2024). Google Earth Engine kullanılarak makine öğrenmesi tabanlı iyileştirilmiş arazi örtüsü sınıflandırması: Atakum, Samsun örneği. Geomatik, 9 (3), 375-390

DOI: 10.29128/geomatik.1472160

### Anahtar Kelimeler

Arazi örtüsü sınıflandırması  
Makine öğrenmesi  
Landsat görüntüleri  
Google Earth Engine

### Araştırma Makalesi

Geliş: 22.04.2024  
Revize: 12.07.2024  
Kabul: 23.07.2024  
Çevrim İçi Yayınlanma:  
17.10.2024



### Öz

Uzaktan algılama görüntüleri kullanılarak üretilen arazi örtüsü (AÖ) haritaları çevre yönetimi, kentsel planlama, ekolojik araştırmalar vb. çalışmalarda önemli bir temel bileşendir. Bu çalışmada, Google Earth Engine (GEE) ortamında makine öğrenmesi yöntemleri kullanarak Atakum ilçesi sınıflandırılmış arazi örtüsü haritası üretilmesi amaçlanmıştır. Çalışmada, Rastgele Orman (RO) ve Gradyan Ağaç Hızlandırma (GTB) yöntemleri kullanılmıştır. Veri seti olarak Landsat 8 uydu görüntüleri ve ALOS DEM kullanılmıştır. Sınıflandırmayı geliştirmek için; Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), Normalleştirilmiş Fark Yapılaşma İndeksi (NDBI), Normalleştirilmiş Fark Su İndeksi (NDWI), Çıplak Toprak İndeksi (BSI), Toprağa Göre Ayarlanmış Bitki Örtüsü İndeksi (SAVI) ve Geliştirilmiş Bitki Örtüsü İndeksi (EVI) kullanılmıştır. Çalışma alanında arazi örtüsü; kentsel alanlar, bitki örtüsü, tarım arazisi, çıplak arazi ve su kütleleri olarak sınıflandırılmıştır. Kullanılan modelin performansını optimize etmek için tüm girdi değişkenleri normalize edilmiştir. Modelin performansı, kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve kappa katsayısı doğruluk değerlendirme teknikleri ile değerlendirilmiştir. Bu çalışmada, hazırlanan arazi örtüsü için RO ve GTB'nin hesaplanan kappa katsayıları sırasıyla %95,6 ve %96,0, ortalama genel doğruluk ise %96,8 ve %97,1'dir. Çalışmada kullanılan iki makine öğrenmesi yönteminden, GTB'nin RO'dan daha iyi performans gösterdiği gözlemlenmiştir.

## Machine learning-based improved land cover classification using Google Earth Engine: case of Atakum, Samsun

### Keywords

Land cover classification  
Machine learning  
Landsat imagery  
Google Earth Engine

### Research Article

Received: 22.04.2024  
Revised: 12.07.2024  
Accepted: 23.07.2024  
Online Published:  
17.10.2024

### Abstract

Land cover (LC) mapping using remote sensing images is essential in studies such as environmental management, urban planning, ecological research, etc. The study aims to produce a classified land cover map of the Atakum district using machine learning methods in a Google Earth Engine (GEE) environment. Random Forest (RF) and Gradient Tree Boosting (GTB) methods were used in the study. Landsat 8 satellite images and ALOS DEM were used as datasets. Normalized Difference Vegetation Index (NDVI), Normalised Difference Building Index (NDBI), Normalised Difference Water Index (NDWI), Bare Soil Index (BSI), Soil-Adjusted Vegetation Index (SAVI), and Enhanced Vegetation Index (EVI) were used to improve the classification. The land cover in the study area was classified as impervious, vegetation, farmland, barren land, and water bodies. All input variables were normalized to optimize the performance of the model. The performance of the model was evaluated using user accuracy, producer accuracy, overall accuracy, and kappa coefficient accuracy evaluation techniques. In this study, the calculated kappa coefficients of RO and GTB for the prepared land cover are 95.6% and 96.0%, and the average overall accuracy is 96.8% and 97.1%, respectively. In the study, it was observed that GTB outperformed RO among the two machine learning methods.

## 1. Giriş

Çevre yönetimi, kentsel planlama ve ekolojik araştırmalar gibi pek çok çalışmanın ayrılmaz bir parçası olan arazi örtüsü haritalaması, dünya yüzeyini ormanlar, su kütleleri ve kentsel alanlar vb. çeşitli kategorilere ayırır (DeFries ve ark., 2004; Foody, 2001; Siraj ve ark., 2023). Bu sınıflandırma, politika oluşturma ve çevre koruma için hayati önem taşımakta ve temel mekansal bilgiler sunmaktadır (Disperati & Virdis, 2015). Arazi kullanımı ve arazi örtüsü (AKÖ) değişikliklerinin etkili bir şekilde izlenmesi için hem doğru hem de güvenilir AKÖ haritalarının oluşturulması çok önemlidir (Gebhardt ve ark., 2014; Karip & Göksel, 2017). Bu haritaların doğruluğu ve duyarlılığı, etkili karar alma ve politika oluşturma süreçlerinde büyük önem taşımaktadır (Rwanga & Ndambuki, 2017).

Geleneksel olarak, arazi örtüsü verileri yersel ölçmeler yoluyla toplanır ve hava fotoğraflarından yorumlanırdı, bu ölçeklenebilirlik ve zamansal çözünürlük sınırlamaları olan yoğun emek gerektiren bir süreçtir (Loveland, 2016). Özellikle 1972 yılında Landsat uydu sistemlerinin devreye girmesi ve uydu uzaktan algılamanın ortaya çıkışı bu alanı dönüştürmüştür. İlk uydular, Dünya'nın iki haftada bir kapsamlı şekilde gözlemlenmesini sağlayarak, çevresel değişikliklerin haritalanmasını ve izlenmesini önemli ölçüde iyileştirmiştir (Cohen ve Goward, 2004; Lam, 2008; Rimal ve ark., 2019). ABD Jeolojik Araştırmalar Kurumu'nun (United States Geological Survey - USGS) 2008 yılında Landsat için açık veri politikasını uygulamaya koyması, araştırmacıların bu verilere serbestçe erişebilmelerini ve analiz edebilmelerini sağlayarak arazi örtüsü değişikliklerini daha önce mümkün olmayan şekillerde ölçebilmelerine olanak tanımıştır (Wulder ve ark., 2012).

Uydu görüntüleri sayesinde ve özellikle de çeşitli elektromanyetik spektrum bantlarında veri yakalayan çok spektrumlu görüntülerle, büyük ölçekte ayrıntılı arazi örtüsü haritalaması mümkün hale gelmiştir (Rogan ve Chen, 2004; Tirmanoğlu ve ark., 2023). Bu görüntüler, tarımsal izleme, kentsel planlama ve çevre araştırmaları başta olmak üzere pek çok çalışma için çok önemli olan yüzey özelliklerini ortaya koymaktadır (Gu ve ark., 2021; Li ve ark., 2020). Ancak asıl zorluk, bu teknolojiler tarafından üretilen büyük miktardaki verinin işlenmesi ve yorumlanmasındadır. Başka bir deyişle, uydu verilerinin hacmi ve karmaşıklığı arttıkça, temel istatistiksel yöntemler ve manuel yorumlama giderek daha yetersiz hale gelmiştir (Adalı, 2009).

Bu noktada, makine öğrenmesi teknikleri çok önemli bir rol oynamaktadır. Makine öğrenmesinin birincil amacı, bilgisayarların otonom olarak öğrenmesini sağlayan yöntemler geliştirmek, sadece gerçekleri ezberlemeye değil, deneyim kazanmaya ve önceden gözlemlenen koşulları yeni senaryolara uygulamaya odaklanmaktadır (Kanevski, 2009). Büyük veri kümelerini verimli bir şekilde işleyerek, geleneksel yöntemlerle ulaşılamayan bir doğruluk ve hız seviyesiyle desen ve sınıflandırmaları tanımlarlar (Yuh ve ark., 2023; Zhang ve Li, 2022). Makine öğrenmesinin arazi örtüsü haritalamasına entegrasyonu, özellikle denetimli

öğrenme teknikleri aracılığıyla, bu alanda devrim niteliğinde gelişmeler sağlamıştır. Eğitim veri setlerinden öğrenen bu algoritmalar, Dünya yüzeyinin dinamik doğasına uyum sağlayarak karmaşık arazi örtüsü türlerini yüksek hassasiyetle sınıflandırmaktadır (Lary ve ark., 2016; Mardani ve ark., 2019).

Uydu görüntülerinden kesin AKÖ verilerinin elde edilmesi, etkili görüntü sınıflandırma tekniklerine bağlıdır. Bu sınıflandırıcılar tipik olarak denetimli ve denetimsiz, parametrik ve parametrik olmayan, sert ve yumuşak (bulanık) sınıflandırma veya piksel başına ve alt piksel tabanlı sınıflandırıcılar gibi çeşitli türlere ayrılır (Efe ve Alganci 2023). Bu çok sayıda sınıflandırıcının performansı, eğitim örneklerinin seçimi, çalışma alanının heterojenliği, sensör özellikleri ve tanımlanacak sınıfların sayısı gibi çeşitli faktörlerden etkilenmektedir (Lu ve Weng, 2007).

Uydu görüntülerine bağlı olarak üretilen haritaların doğruluğunu artırmak için sürekli çalışmalar yapılmakta ve sonuçta literatüre yeni sınıflandırma yöntemlerinin eklenmektedir. Farklı algoritmaların karşılaştırmalı analizleri, bu yeni sınıflandırıcılardaki ilerlemeleri ayırt etmek için gereklidir. Literatürde yer alan bazı kaynaklar, çeşitli sınıflandırıcılar hakkında kapsamlı bilgiler sunarak alana önemli katkılar sağlamaktadır (Basheer ve ark., 2022; Mangkhaseum ve Hanazawa, 2021; Oo ve ark., 2022; Sellami ve Rhinane, 2023).

Makine öğrenmesi sınıflandırıcıları, özellikle karmaşık veriler ve çok sayıda girdi özelliği içeren senaryolarda yüksek doğrulukları ile tanınmaktadır. (Maxwell ve ark., 2018). Önemli sınıflandırıcılar arasında Rastgele Orman (RO), Sınıflandırma ve Regresyon Ağacı (CART), Yapay Sinir Ağı (YSA), k-En Yakın Komşu (k-NN), Destek Vektör Makinesi (DVM) ve Gradyan Ağaç Hızlandırma (GTB) vb. yer almaktadır. CART, eğitim için kullanılan verilerden bir karar ağacı oluştururken, RO eğitim verilerinin rastgele seçilen bir bölümünü kullanarak birkaç karar ağacı oluşturur. GTB, etkili sınıflandırma ve regresyon için karar ağacı ve artırma algoritmalarını birleştirerek geleneksel modellere göre hesaplama avantajları sunar (Friedman, 2001). Buna karşılık, bir YSA, Çok Katmanlı Algılayıcı adı verilen bir mekanizma aracılığıyla girdi gözlemlerini işleyen birbirine bağlı düğüm katmanlarından oluşan bir sinir ağı yapısı üzerinde çalışır ve bu, önceden belirlenmiş bir sonlandırma koşuluna ulaşılan kadar devam eder (Mas ve Flores, 2008). k-NN, çevredeki piksellerden gelen bilgileri analiz ederek eğitim veri kümesindeki altta yatan örüntüyü belirler (Calvo-Zaragoza ve ark., 2015). DVM, destek vektörleri olarak adlandırılan eğitim verilerinin bir alt kümesini tanımlayarak ve optimum sınıf ayrımı için bir hiper düzlem oluşturarak çalışır (Huang ve ark., 2002). Çeşitli sınıflandırıcılar arasında yapılan karşılaştırmalarda, literatürdeki fikir birliği, RO ve DVM'nin genellikle çok çeşitli sınıflandırma senaryolarında üstün performans gösterdiğini ve diğer makine öğrenimi sınıflandırıcılarından daha iyi sonuçlar verdiğini göstermektedir (Belgiu ve Drăgu, 2016; Avci ve ark., 2023).

Çeşitli arazi sınıflandırma platformlarının ve yazılımlarının makine öğrenmesi metodolojileriyle entegre edilmesi, arazi örtüsü analizinin verimliliğini ve

doğruluğunu önemli ölçüde artırmaktadır. Bu alandaki başlıca platform ve yazılımlar arasında Google Earth Engine (GEE) ve ArcGIS, QGIS, ERDAS Imagine ve ENVI yer almaktadır. Bu platformlardan, GEE, geniş uydu görüntüleri arşivi ve güçlü bulut tabanlı işleme yetenekleriyle öne çıkmakta ve büyük veri kümelerini işlemek için son derece verimli hale getirmektedir.

GEE'nin 40 yılı aşkın veri setini kapsayan arşivi, özellikle zamansal ve değişim analizleri için etkilidir. Mekansal çalışmalarda ve zaman içindeki arazi kullanım ve arazi örtüsü değişikliklerin izlenmesinde çok önemli olan sürekli değişim tespiti ve sınıflandırması için çeşitli işlevler içerir (Zhu ve Woodcock, 2014). GEE'nin her biri kapsamlı veri havuzundan ve sağlam analitik işlevlerinden avantaj sağlayan çok sayıda alana uyarlanabilirliğini gösteren pek çok çalışma bulunmaktadır. Başlıcaları; kentsel çalışmalar (Arpitha ve ark., 2023; Demuzere ve ark., 2019; Huang ve ark., 2018; Liu ve ark., 2020; Middel ve ark., 2018), arazi kullanımı (Desai ve Gaikwad, 2022; Ge ve ark., 2019; Midekisa ve ark., 2017; Murray ve ark., 2018), doğal afet yönetimi (Khan ve ark., 2020; Uddin ve ark., 2019), tarım (Ghazaryan ve ark., 2018; Liang ve ark., 2019; Poortinga ve ark., 2019), atmosfer ve iklim çalışmaları (Chen ve ark., 2020; Huntington ve ark., 2017), bitki örtüsü izleme (Xie ve ark., 2019; Zhang ve ark., 2019) ve hidroloji (Cao ve ark., 2020; Nguyen ve ark., 2019) olarak sayılabilir.

Makine öğrenmesi ve GEE entegrasyonu, arazi örtüsü sınıflandırmasına bütünsel bir yaklaşım için veri erişilebilirliğini ve işleme yeteneklerini birleştirerek her sistemin birbirinden farklı güçlü yönlerinden yararlanır. Arazi örtüsü belirlenmesi için makine öğrenmesi sınıflandırıcılarını karşılaştırmak üzere makine öğrenmesi ve GEE entegrasyonu kullanılarak çeşitli çalışmalar yapılmıştır (Basheer ve ark., 2022; Dabija ve ark., 2021; Oo ve ark., 2022; Sellami ve Rhinane, 2023).

Yukarıdaki çalışmalar, DVM, RO, CART gibi farklı makine öğrenmesi algoritmalarının farklı çalışma alanlarında ve farklı uydu veri kümelerinde kullanımını göstermektedir. Bu çalışmalarda ortak bulgu, DVM ve RO yöntemlerinin kentsel alanlardan maden bölgelerine kadar değişik alanlarda en iyi doğruluk oranlarını elde ettiği yönündedir. Bu görüşler, sürdürülebilir kaynak yönetimi ve iklim etkisine bağlı çevresel değişikliklerini anlamak için çok önemlidir. Makine öğrenmesi sınıflandırıcılarını karşılaştırmak, algoritmaları çeşitli çevresel ortamlarda daha fazla keşfetmek için faydalı olacaktır.

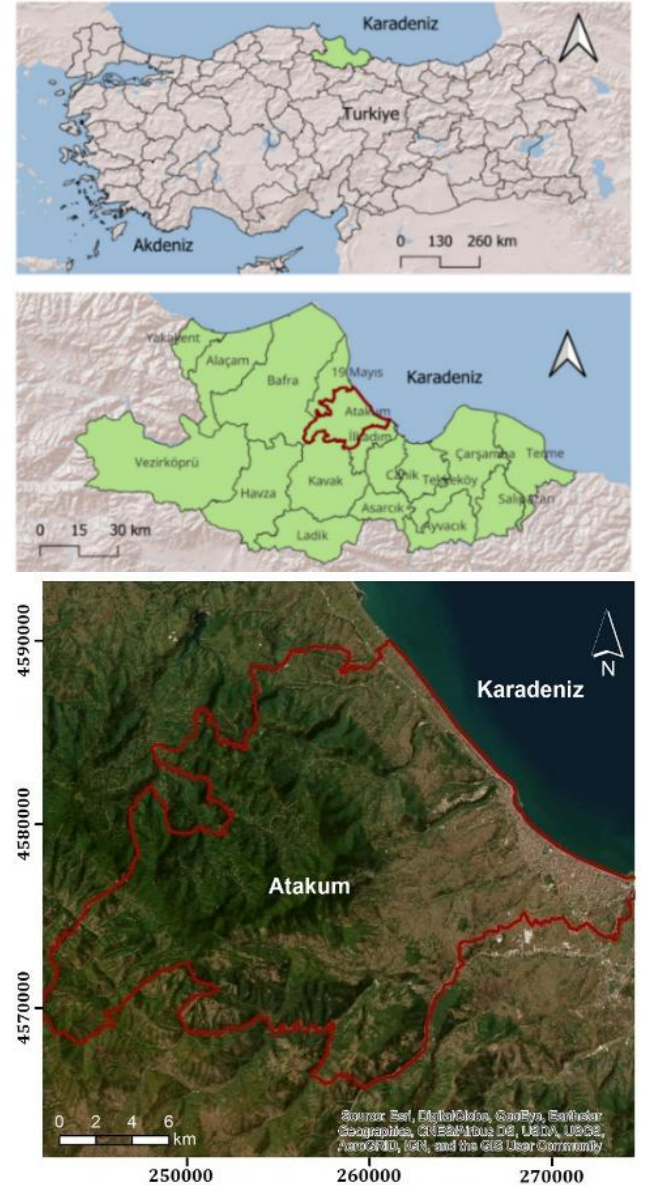
Bu çalışma, Samsun ili Atakum ilçesinde arazi örtüsü haritalaması için RO ve GTB topluluk makine öğrenimi sınıflandırıcılarını karşılaştırmayı amaçlamaktadır. Bu karşılaştırma, spektral indeksler ve topografik bilgiler de dahil olmak üzere ek yardımcı verilerle desteklenen Landsat 8'den elde edilen verilerin işlenmesi ve analiz edilmesindeki performanslarına dayanmaktadır. Çalışmada, büyük ölçekli mekânsal verilerin ele alınması ve işlenmesindeki sağlam yetenekleriyle bilinen GEE bulut bilişim platformu kullanılmıştır.

Bu çalışmalarda sınıflandırma doğruluğunu artırmak için GEE ve yardımcı verilerin kullanılmasının, çalışma alanında henüz yaygınlaşmadığı düşünüldüğünde, bu yaklaşım özellikle önemlidir. Literatür araştırmaları

sonucunda, bu bölgede RO ve GTB yöntemlerinin performans karşılaştırmasına dair yapılmış çalışmalara rastlanmamıştır. Bu tür araştırmalar, arazi örtüsü analizi ve daha geniş çevresel izleme amaçları için büyük önem taşımaktadır.

### 1.1. Çalışma alanı

Türkiye'nin kuzeyinde yer alan Samsun ili Atakum ilçesi çalışma alanı olarak belirlenmiştir. Atakum, önemli bir kısmı kırsal olmak üzere Karadeniz'e yaklaşık 20 km kıyısı bulunan (Şekil 1) ve nüfus artışı ve kentleşme açısından hızlı değişimlerin yaşandığı bir yerleşim birimidir. İlçe'nin nüfusu 2014 yılında 158,031 iken 2023 yılında 245,328'e ulaşarak, 10 yıllık bir süre zarfında toplam % 55.24'lük bir artış göstermiştir (TÜİK, 2024). Atakum'da yerleşimlerin büyük çoğunluğu ilçenin doğu kıyılarında yoğunlaşmıştır. Güney bölgelerde yer alan mahallelerde nüfus yoğunluğu oldukça düşüktür.



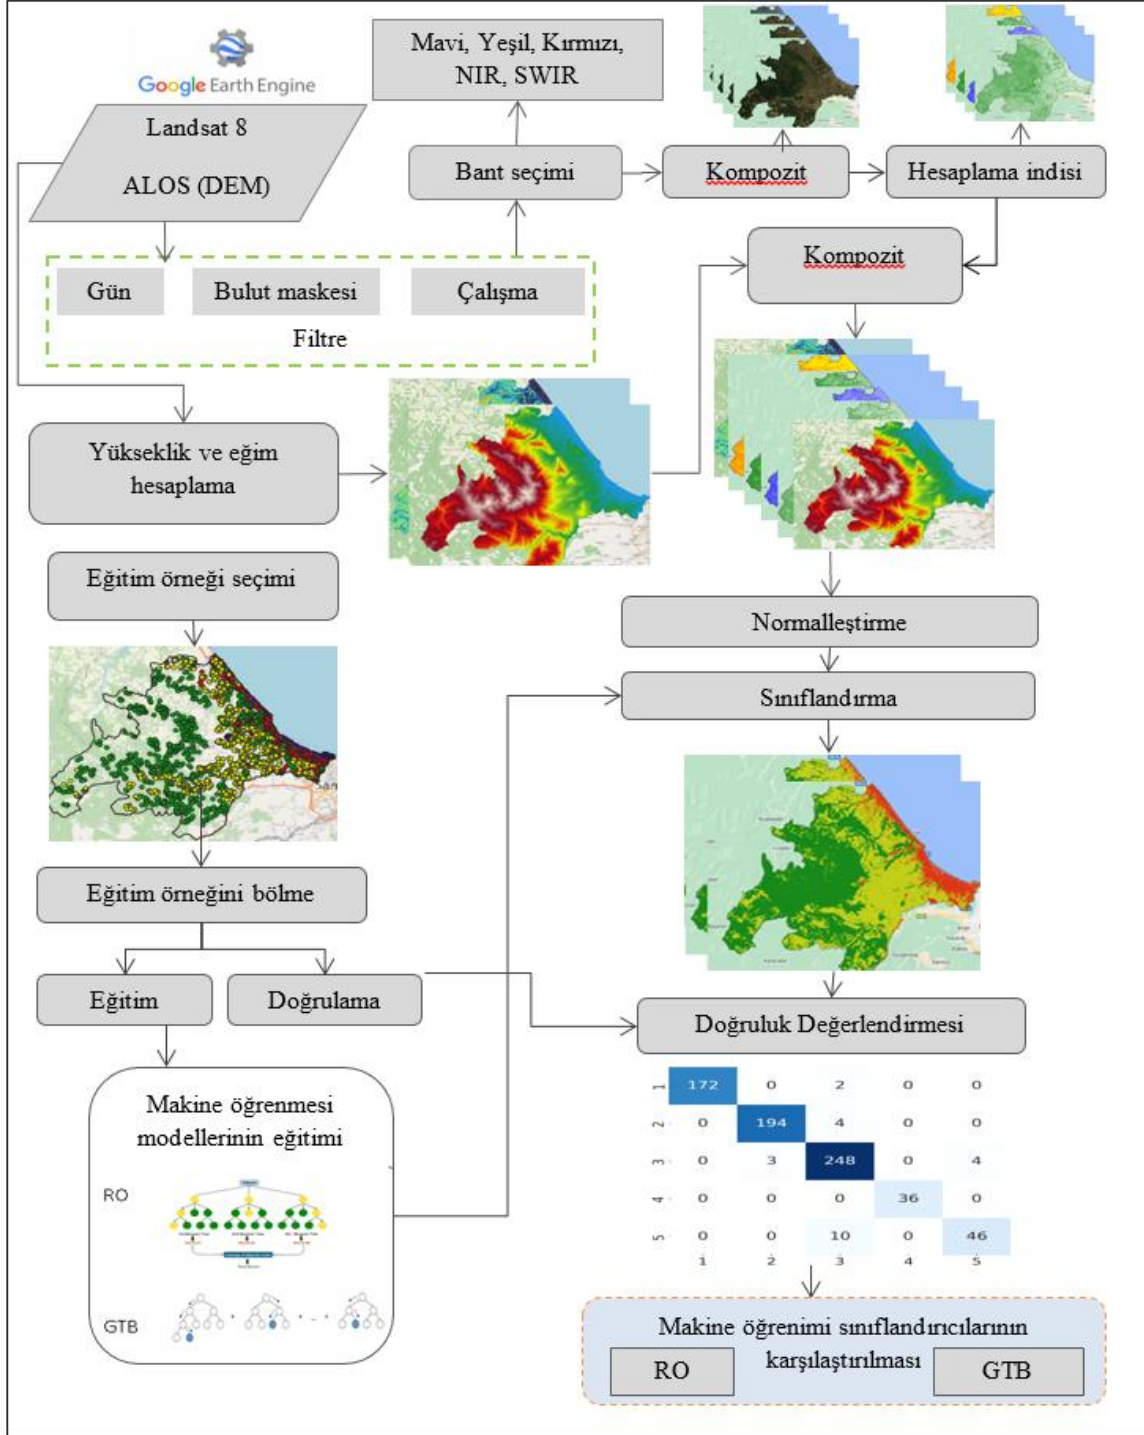
Şekil 1. Çalışma alanının konumu.



## 2. Materyal ve Yöntem

Bu çalışmada, RO ve GTB yöntemleri kullanılarak arazi örtüsü sınıflandırması yapılmıştır. Daha önceki çalışmalarda kullanılan ve bölgenin genel yapısını ifade edeceği düşünülen 5 arazi sınıfı (kentsel alan, bitki örtüsü, tarım arazisi, çıplak arazi, su kütleleri) belirlenmiştir. RO ve GTB algoritmalarının karşılaştırılması, Atakum ilçesine ait veriler kullanılarak, GEE ortamında Şekil 2’de verilen iş adımları doğrultusunda gerçekleştirilmiştir.

Başlıca işlem adımları; Landsat 8 görüntüsünün ön işlemden geçirilmesi; seçilen bantlardan NDVI, NDWI, NDBI, BSI, SAVI ve EVI ve ALOS DEM'den yükseklik ve eğim gibi sınıfları uygun şekilde kategorize etmek için modeli destekleyen özellik çıkarımı; aynı ölçek aralığında (0-1) veri oluşturmak için normalleştirme; eğitim ve doğrulama verilerinin toplanması; eğitim algoritmaları ve doğruluk değerlendirmesi olarak sıralanmaktadır.



Şekil 2. Çalışmanın iş akışı.

## 2.1. Veri seti ve yazılım

Bu çalışmada, uzaktan algılama verileri kullanılarak Atakum ilçesindeki arazi örtüsünün sınıflandırılması yapılmıştır. 2023 yılı Mayıs-Ağustos arası döneme ait Landsat 8 görüntüsüne GEE ortamı aracılığıyla USGS'den erişilmiştir. Doğruluğu artırmak için, 2023 yılı Mayıs ve Ağustos ayları arasındaki %10'dan daha az bulut kapallılığı olan veri kümeleri seçilmiş ve 1 aylık kompozit görüntü oluşturulmuştur. USGS'den alınan veriler, LANDSAT\_8 OLI sensör tipidir. Orta çözünürlüklü (30 m) olan Landsat verileri, arazi örtüsü sınıflandırmasının ilçe ölçeğinde analizi için yeterince ayrıntılıdır.

Landsat verilerini kullanarak sınıflandırma işlemlerini yapmak için GEE platformu seçilmiştir. Arazi örtüsünün sınıflandırılması, kullanıcının temsili örnekler seçerek arazi örtüsü sınıflarını tanımlamasını ve belirlemesini gerektiren denetimli sınıflandırma yoluyla gerçekleştirilir. Landsat verileri, belirli dalga boylarına duyarlı görüntü veri seti, bu süreçte etkili olmaktadır. Sensör tipleri ve dalga boyu hassasiyetlerine ilişkin ayrıntılar **Tablo 1**'de özetlenmiştir. GEE'de kırmızı, yeşil ve maviyi görselleştirmek için uzaktan algılama verilerinden belirli bant kombinasyonlarını seçerek, farklı arazi örtüleri arasındaki ayrımlar fark edilebilir hale gelir. Belirli bant kombinasyonları, eğitim verilerini toplamak için her bir arazi örtüsü türünü ayırt etmek için kullanılır. Doğal renkli görüntüler için spektral bant kombinasyonları 4, 3 ve 2'dir. Kentsel alanlar için sahte renkli görüntülerin kombinasyonu 7, 6 ve 4'tür. Bitki örtüsü için renkli kızılötesi görüntülerde 5, 4 ve 3 numaralı bantlar kullanılır. Tarım arazileri için kombinasyon 6, 5 ve 2'dir. Son olarak, kara ve su kütleleri ayırt etmek için kullanılan bantlar 5, 6, 4'tür (Butler, 2013; Quinn, 2001).

**Tablo 1.** Landsat 8 sensörlerinin özellikleri.

Band	Dalga boyu	Çözünürlük
SR_B1	0.435 - 0.451 µm	30m
SR_B2	0.452 - 0.512 µm	30m
SR_B3	0.533 - 0.590 µm	30m
SR_B4	0.636 - 0.673 µm	30m
SR_B5	0.851 - 0.879 µm	30m
SR_B6	1.566 - 1.651 µm	30m
SR_B7	2.107 - 2.294 µm	30m
QA_PIXEL	--	--

## 2.2. Görüntü ön işleme ve kompozit oluşturma

Görünürden kısa dalga kızılötesine kadar uzanan bantları kapsayan optik uydu görüntüleri, arazi kullanımı ve arazi örtüsü, ekosistem izleme ve arazi yüzey sıcaklıklarının tahmin edilmesi de dahil olmak üzere bir dizi dünya özelliğinin haritalanması için yaygın olarak kullanılmaktadır (Hansen ve Loveland, 2012). Bununla birlikte, özellikle Landsat uyduları söz konusu olduğunda, çok zamanlı optik uydu görüntülerinde bulut örtüsünden kaynaklanan eksik veriler veya sensör

kayıtlarındaki hatalar nedeniyle zorluklar ortaya çıkmaktadır (Kussul ve ark., 2016). Bu sorunlar yerdeki nesnelerin yansımaları değiştirerek optik görüntülerin uygulamalarda kullanılabilirliğini azaltmaktadır (Embury ve ark., 2012). Bir bulut filtresinin kullanılması, hassas gözlemler için uygun piksellerin seçilmesini sağlayarak görüntülerin bulutlardan ve bulut gölgelerinden arındırılmasını sağlar (Sulova ve Arsanjani, 2021).

GEE platformu, 2023 yılı Mayıs ve Ağustos ayları arasında çekilen Landsat 8 görüntülerinin bileşimi yoluyla arazi örtüsünü temsil eden bireysel kompozit görüntüler oluşturmak için kullanılmıştır. Bu çalışmada Landsat 8 görüntüleri için 1 ila 7 spektral bantlar kullanılmıştır. Zaman serisi uydu görüntüleri, tek tarihli görüntüye göre daha yüksek sınıflandırma doğrulukları vermektedir (Noi Phan ve ark., 2020). Uydu görüntülerinin zaman serisi analizinde, yağmur mevsimi ve değişen uydu tekrar ziyaret aralıkları gibi zorluklar piksel verilerinde belirsizlikler meydana getirir. Bunu ele almak ve arazi türlerini ayırt etmek için istatistiksel göstergelere odaklanarak zaman serisi görüntülerinden tam olarak yararlanılır. Bu görüntülerin medyan değeri yaygın olarak kullanılan bir göstergedir ve çevresel veri değişimlerine karşı kararlılığı nedeniyle arazi kullanımı sınıflandırmasında etkili olduğu kanıtlanmıştır (Mahdianpari ve ark., 2019; Zhang ve ark., 2021).


## 2.3. Eğitim ve doğrulama örnek verileri

Makine öğrenmesinde denetimli sınıflandırmanın etkinliği büyük ölçüde kullanılan eğitim örneklerinin miktarına ve kalitesine bağlıdır (Shetty ve ark., 2021). İdeal olarak, değişken sayısının birçok katı olmak üzere, uygun sayıda eğitim örneğine sahip olunması gerekmektedir. Daha büyük ve daha doğru eğitim veri kümeleri her algoritma için faydalıdır. Eğitim verisi sayısı, verinin boyutuna, dağılımına ve kalitesine göre farklılık gösterir; bazıları örneklem boyutundaki azalmadan veya veri kalitesi sorunlarından daha fazla etkilenir (Elmes ve ark., 2020; Foody ve ark., 2016). Topluluk yöntemleri genellikle daha küçük eğitim veri kümelerine ve gürültülü verilere karşı tek modellere göre daha fazla üstünlük gösterir. Daha az örnek veya düşük veri kalitesiyle doğruluk önemli ölçüde azalabilir. Bazı algoritmalar eğitim örneği boyutuna daha az duyarlı olsa da yine de eğitim verilerinin kalitesinden etkilenebilirler. Genel olarak, eğitim verilerinin hem boyut hem de kalite açısından yeterliliği, etkili sınıflandırma için çok önemlidir (Maxwell ve ark., 2018).

Eğitim ve doğrulama süreci için GEE ortamında yeterli sayıda örnek nokta toplanmıştır. Örnek noktalarının %80'i eğitim için, %20'si ise doğruluğu değerlendirmek üzere, doğrulama için ayrılmıştır. Seçilen sınıflar için çalışma alanındaki eğitim ve doğrulama verilerinin sayıları **Tablo 2**'de ve konumları **Şekil 3**'te gösterilmiştir.

**Tablo 2.** Farklı AÖ sınıfları için eğitim ve doğrulama veri sayıları.

AÖ sınıfları	Eğitim ve doğrulama verileri	Eğitim verileri %80	Doğrulama verileri %20
Kentsel Alan	870	696	174
Bitki örtüsü	990	792	198
Tarım arazi	1275	1020	255
Çıplak arazi	180	144	36
Su kütleleri	280	224	56

**Şekil 3.** Eğitim ve doğrulama verilerinin konumları.

#### 2.4. Sınıflandırma doğruluğunun iyileştirilmesi

GEE veri platformunun temel özelliklerinden biri, farklı sınıflandırmalar arasında başarılı bir şekilde ayırım yapabilmesidir. Bu yetenek, sınıflandırıcıya ek bilgiler sağlayarak veri kümesi içindeki çeşitli kategoriler arasında ayırım yapma yeteneğini geliştirerek elde edilir. Sınıflandırıcının performansını iyileştirmek ve artırmak için GEE ortamında çeşitli teknikler uygulanabilir (Gandhi, 2021). Bu yöntemler aşağıda sıralanmıştır.

**Bulut Maskeleyme:** Bulut maskeleymenin uygulanması, sınıflandırıcının doğruluğunu artırmada etkilidir. Görüntülerdeki bulut örtüsünün tanımlanması ve maskelenmesiyle, model atmosferik koşulların neden olduğu bozulmalara daha az duyarlı hale gelir. Bu adım, eğitim ve doğrulama verilerinin doğruluğunu artırmak ve sınıflandırma sonuçlarını iyileştirmek için kritik öneme sahiptir (Mateo-García ve ark., 2018).

**Spektral İndeksler:** Spektral indekslerin dahil edilmesi, sınıflandırıcının ayırt edici gücünü artırmak için bir başka tekniktir. Normalleştirilmiş Fark Bitki Örtüsü Endeksi (NDVI), Normalleştirilmiş Fark Yapı

Endeksi (NDBI), Normalleştirilmiş Fark Su Endeksi (NDWI), Çıplak Toprak Endeksi (BSI), Toprağa Göre Ayarlanmış Bitki Örtüsü Endeksi (SAVI) ve Geliştirilmiş Bitki Örtüsü Endeksi (EVI) gibi çeşitli spektral indekslere karşılık gelen bantlar eklenerek sınıflandırıcı ek spektral bilgilere erişim kazanır. Bu genişletilmiş özellik seti, yüzeyin daha incelikli bir şekilde anlaşılmasını sağlayarak modelin farklı arazi örtüsü sınıfları arasında daha büyük bir hassasiyetle ayırım yapmasına olanak tanır (Sinha ve ark., 2015).

**Yükseklik ve Eğim:** ALOS DEM'den elde edilen veriler, eğim ve yüksekliği temsil eden bantlar önemli topografik bilgiler sağlar. Bu bilgiler, özellikle arazinin, arazi örtüsü modellerini önemli ölçüde etkilediği alanlarda faydalı olmaktadır. Bu bantların dahil edilmesiyle sınıflandırıcı daha bütünsel bir bakış açısı kazanarak çalışma alanının daha doğru bir şekilde temsil edilmesine katkıda bulunur (Noi Phan ve ark., 2020)

**Normalleştirme:** Makine öğrenmesi modellerinin performansını optimize etmek için tüm girdi değişkenlerinin karşılaştırılabilir bir ölçekte olmasını sağlamak zorunludur. Girdilerin normalleştirilmesi, tüm



girdi özellikleri arasında ölçekte standart sağlayan kritik bir ön işleme adımdır. Makine öğrenmesi modelleri, tutarlı bir ölçeği paylaşan girdiler üzerinde çalışırken doğal olarak daha iyi performans gösterir (Mhanna ve ark., 2023). Bu çalışmada tüm değişkenler aşağıda sunulan Denklem (1) ile normalize edilmiştir.

$$\text{Norm} = \frac{(\text{Orjinal değer} - \text{minimum değer})}{(\text{maksimum değer} - \text{minimum değer})} \quad (1)$$

#### 2.4.1. Spektral indeks haritaları

Spektral indeksler, spektral bantların matematiksel kombinasyonlarından elde edilen sayısal değerlerdir. Bu indeksler, istenmeyen gürültünün etkisini azaltırken aynı zamanda bitki örtüsü ve su kaynaklarının ayırt edilebilir özelliklerini geliştirmek tanımlanmıştır. (Alexander, 2020; Billah ve ark., 2023). Uzaktan algılama görüntülerinden arazi örtüsü sınıflandırma


çalışmalarında en yaygın olarak kullanılan ve Landsat 8 için özel olarak tanımlanan indeksler Tablo 3'te gösterilmektedir.

#### 2.4.2. Yükseklik ve eğim haritaları

Arazi örtüsündeki değişiklikler eğim ve yükseklik gibi topografik unsurlarla yakından ilişkili görünmektedir. Düşük rakımlı bölgelerde, erişilebilirlik gibi faktörler, tarımsal faaliyetler ve insan yerleşimleri ile bağlantılıdır. Eğim (derece cinsinden ölçülmüştür) Dijital Yükseklik Modelinden (AİOS-DEM) elde edilmiştir. Eğim, çeşitli arazi kullanım amaçlarının bir göstergesi olarak kullanılır; örneğin, ormanlık alanlar daha yüksek ve daha dik alanlarda yer alma eğilimindeyken, inşaat için uygun alanlar genellikle daha düz arazilerde bulunur (Birhanu ve ark., 2019). 2023 AÖ için kullanılan endeksler ve topografik unsurlara ait haritalar Şekil 4'te gösterilmektedir.

**Tablo 3.** Sınıflandırma doğruluğunu artırmak için kullanılan indeksler.

İndeks	Açıklama	Kaynaklar
NDVI	$\frac{(NIR - Red)}{(NIR + Red)}$ Kırmızı ve yakın kızılötesi spektrumu kullanarak bitki örtüsünü algılar	(Rouse ve ark., 1974)
NDWI	$\frac{(GREEN - NIR)}{(GREEN + NIR)}$ Yeşil ve yakın kızılötesi bantları kullanarak su kütlelerini analiz eder.	(Gao, 1996)
NDBI	$\frac{(SWIR - NIR)}{(SWIR + NIR)}$ NIR ile karşılaştırıldığında SWIR aralığında yerleşik ve çıplak toprak alanlarını gösterir.	(Zha ve ark., 2003)
BSI	$\frac{((Red + SWIR) - (NIR + Blue))}{((Red + SWIR) + (NIR + Blue))}$ Mavi, kırmızı, yakın kızılötesi ve SWIR bantlarını birleştirerek toprak özelliklerini tespit eder.	(Rikimaru ve ark., 2002)
SAVI	$1.5 * \left( \frac{(NIR - Red)}{(NIR + Red + 0.5)} \right)$ Seyrek bitki örtüsüne sahip alanlarda toprak parlaklığı için NDVI'yi düzeltir.	(Huete, 1988)
EVI	$2.5 * \frac{(NIR - Red)}{(NIR + 6 * Red - 7.5 * Blue + 1)}$ NDVI'ye benzer ancak atmosferik ve kanopi arka plan etkilerini telafi eder. Yoğun bitki örtüsü alanlarında daha duyarlıdır.	(Huete ve ark., 2002)



Şekil 4. Spektral indeksler, yükseklik ve eğim.

## 2.5. Makine öğrenmesi sınıflandırıcıları

### 2.5.1. Rastgele orman

Bir makine öğrenmesi sınıflandırıcısı olan Rastgele Orman (RO), her bir ağacın belirli bir girdinin sınıflandırılmasında bir oy sağladığı çok sayıda karar ağacından oluşur (Breiman, 2001). Breiman tarafından geliştirilen bu topluluk tekniği, birleştirilmiş bir karar vermek için çeşitli ağaçların çıktılarını bütünleştirir. Çok yönlülüğü ile bilinir hem sınıflandırma hem de regresyon görevlerini etkili bir şekilde ele alır. RO, regresyon için sürekli değişkenler ve sınıflandırma için kategorik değişkenler içeren veri kümelerini yönetir.

RO'nun prensibi, birden fazla sınıflandırıcıdan elde edilen çıktılarının birleştirilmesinin sınıflandırma doğruluğunu artırdığı fikrine dayanmaktadır (Tumer ve Ghosht, 1996). RO, bir düğüm içindeki homojenliği ölçen Gini İndeksini kullanarak en iyi bölünmeyi seçer. Bu teknik, bölünmeden sonra entropinin azalmasına ve bilgi kazanımının artmasına neden olur, ancak etkinliği seçilen budama yöntemlerine de bağlıdır (Pal ve Mather, 2003). RO'nun gürültü ve aykırı değerlere karşı sağlamlığı ve torbalama ve artırma gibi diğer topluluk yöntemlerine kıyasla üstün performansı, onu çeşitli uygulamalarda tercih edilen bir seçenek haline getirmektedir (Gislason ve ark., 2006).

### 2.5.2. Gradyan ağacı hızlandırma

GTB, bir karar ağaçları koleksiyonundan yararlanan RO'ya benzer bir topluluk yöntemidir. Bununla birlikte,

yaklaşımı her ağacı zayıf bir tahmin modeliyle sınırlandırması, dolayısıyla ağaç karmaşıklığını azaltması bakımından farklılık gösterir. Bir grup zayıf öğreniciyi iteratif olarak güçlü öğrenicilerle birleştirerek, her adımda farklı bir kayıp fonksiyonunu en aza indirerek ve bir gradyan iniş yöntemi kullanarak sınıflandırma doğruluğunu artırır (Friedman, 2002). Ağaçlar arasındaki ilişkinin derecesini azaltmak için, her yeni ağaç rastgele seçilen bir eğitim verisi örneğinden oluşturulur. GTB'ler, parametreleri değiştirerek azaltılabilen aşırı uyuma eğilimlidir. Değiştirilecek parametreler açısından, ağaç sayısı 10'luk bir adım boyutuyla 50 ila 200 arasında değişmektedir. Ağaç sayısı ayarlama önerilerinin tipik olarak ilave ağaçlar içerdiği belirtilmelidir (Elith ve ark., 2008).

Bu çalışmada Google Colab platformundaki eğitim verileri kullanılarak gridsearch çapraz sorgulama yöntemi kullanılarak her iki yöntem için de ağaç sayısı belirlenmiş, bu değer RO için 100, GTB için 200 olarak hesaplanmıştır.

## 2.6. Doğruluk değerlendirilmesi

Bir modelin doğruluk değerlendirmesi, makine öğrenmesi iş akışında önemli bir aşamadır ve modelin güvenilirliğini ifade eder. Bu bağlamda, sınıflandırma için aşağıda Denklemelerde (2-5) gösterilen; genel doğruluk (GD), kullanıcı doğruluğu (KD), üretici doğruluğu (ÜD) ve kappa katsayısı (k) dahil olmak üzere çeşitli ölçütler kullanılmıştır.



$$\text{Genel Doğruluk} = \frac{(\text{Doğru Sınıflandırılan Piksellerin Toplam Sayısı (köşegen)})}{(\text{Toplam doğrulama piksel sayısı})} * 100 \quad (2)$$

$$\text{Kullanıcı Doğruluğu} = \frac{(\text{Her Kategorideki Doğru Sınıflandırılmış Piksel Sayısı})}{(\text{Kategorideki Toplam Sınıflandırılmış Piksel Sayısı (Satır toplamı)})} * 100 \quad (3)$$

$$\text{Üretici Doğruluğu} = \frac{(\text{Her Kategoride Doğru Sınıflandırılan Piksel Sayısı})}{(\text{Kategorideki Toplam Doğrulama Piksel Sayısı (Sütun toplamı)})} * 100 \quad (4)$$

$$\text{Kappa katsayısı} (\hat{K}) = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (X_{i+} * X_{+i})}{N^2 - \sum_{i=1}^r (X_{i+} * X_{+i})} \quad (5)$$

r= hata matrisindeki satır sayısı,  $X_{ij}$ = i. satır ve j. sütundaki gözlem sayısı,  $X_{(i+)}$ = i. satırdaki gözlemlerin toplamı,  $X_{(+i)}$ = i. sütundaki gözlemlerin toplamı, N= matriste yer alan toplam gözlem sayısı.

Modelin performansını değerlendirmek için doğruluk, kesinlik, duyarlılık, özgüllük ve F1-puanı kullanılmıştır.

*Doğruluk*, tüm sınıflar arasında doğru tahmin edilen sınıfların (hem gerçek pozitifler hem de gerçek negatifler) yüzdesini ölçmek için kullanılır (Denklem 6).

$$\text{Doğruluk} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (6)$$

*Kesinlik*, sınıflandırıcının belirli bir arazi örtüsü sınıfını tanımlamadaki doğruluğunu ölçmek için kullanılır. (Denklem 7).

$$\text{Kesinlik} = \frac{(TP)}{(TP+FP)} \quad (7)$$

*Duyarlılık*, sınıflandırıcının belirli bir arazi örtüsü sınıfının tüm örneklerini doğru bir şekilde tanımlama yeteneğini ölçer. (Denklem 8).

$$\text{Duyarlılık} = \frac{(TP)}{(TP+FN)} \quad (8)$$

*Özgüllük*, sınıflandırıcının belirli bir arazi örtüsü sınıfına ait olmayan örnekleri doğru bir şekilde tanımlama yeteneğini ölçer (Denklem 9).

$$\text{Özgüllük} = \frac{(TN)}{(TN+FP)} \quad (9)$$

*F1-skoru*, Kesinlik ve duyarlılığın harmonik ortalamasıdır. Hem Kesinliği hem de duyarlılığı dengeleyen tek bir ölçü sağlar ve sınıflandırıcının performansının daha kapsamlı bir değerlendirmesini verir (Denklem 10).

$$\text{F1 puanı} = \frac{2 * \text{Kesinlik} * \text{Duyarlılık}}{(\text{Kesinlik} + \text{Duyarlılık})} \quad (10)$$

Burada, TP: Doğru Pozitif, FP: Yanlış Pozitif, TN: Doğru Negatif, FN: Yanlış Negatif ifade etmektedir.

### 3. Bulgular ve Tartışma

Hazırlanan çalışmada, iki farklı makine öğrenmesi tekniği irdelenmiştir. Bunu gerçekleştirmek için çalışma, Landsat 8 görüntülerinden ve ALOS sayısal yükseklik modelinden türetilen yükseklik ve eğim ile altı spektral indeksin (NDVI, NDWI, NDBI, BSI, SAVI ve EVI) hesaplanmasını içermektedir. Bu algoritmalar çalışma alanını kentsel, bitki örtüsü, tarım arazileri, çıplak arazi ve su kütleleri gibi beş ana arazi örtüsü kategorisine sınıflandırmak için uygulanmıştır. Sınıflandırma sürecinde seçilen bantlar, hesaplanan spektral indeksler, yükseklik ve eğim verileri kullanılmıştır. Veri kümelerinin bileşimi, Atakum İlçesi'ndeki arazinin kapsamlı bir analizine olanak sağlamaktadır. Bileşik görüntü, tüm özelliklerin aynı aralığa sahip olmasını sağlamak için normalleştirilmiştir, bu da makine öğrenmesi algoritmalarının etkili bir şekilde çalışması için önemlidir.

Detay analizinden önce, spektral bantlar ve kombinasyon verileri (spektral bantlar, spektral indeksler ve topoğrafik bilgiler) kullanılarak arazi örtüsü sınıflandırılmıştır. Tablo 4'te görüldüğü gibi, yalnızca spektral bantlar kullanılarak sınıflandırılan haritanın doğruluğu, spektral bantlar, endeksler ve topoğrafik bilgilerin bir kombinasyonuna kıyasla daha düşüktür. Bu çalışmada analiz, spektral bantlar, spektral endeksler ve topoğrafik bilgiler kullanılarak üretilen sonuçlara odaklanmıştır.

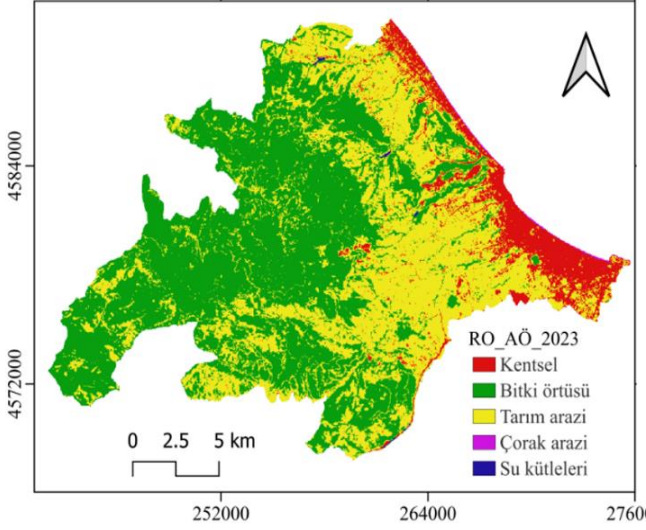
**Tablo 4.** Spektral bantlar ve kombinasyon elde edilen GD ve Kappa değeri.

Modeller	Spektral bantlar		Kombinasyon	
	GD	Kappa	GD	Kappa
RF	0.932	0.907	0.968	0.956
GBT	0.954	0.937	0.971	0.942

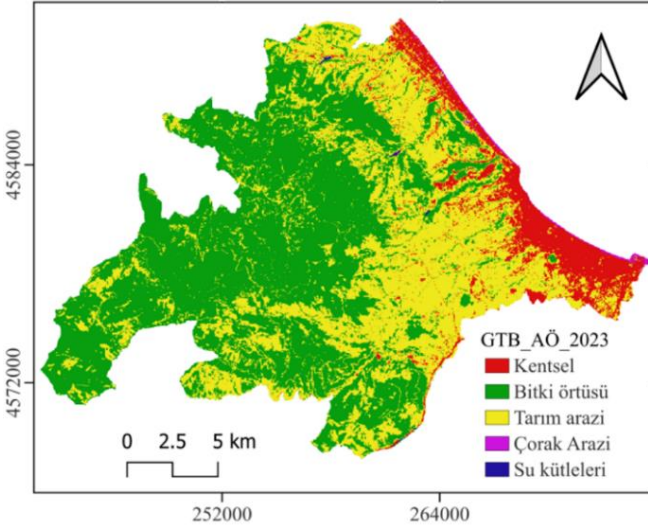
Çalışma bölgesi için GEE ortamında oluşturulan arazi örtüsü kategorilerinin dağılım haritaları Şekil 5a ve 5b'de sunulmuştur.

Çalışmada elde edilen arazi örtüsü sınıflandırma sonuç verileri Şekil 6'da sunulmuştur. Her iki modelde de arazide baskın sınıfın bitki örtüsü olduğu belirlenmiştir. RO sınıflandırma modeli kullanılarak yapılan analizde

arazinin 20458.06 ha (%52.77) lık kısmı, GTB sınıflandırma modeli kullanılarak yapılan analizde arazinin 20589.00 ha (%53.31) lık kısmının bitki örtüsü oluşu belirlenmiştir. Uygulanan her iki modelde de arazide en az görünen sınıfın su kütleleri olduğu belirlenmiştir. RO sınıflandırma modeli kullanılarak yapılan analizde arazinin 44.02 ha (%0.11) lık kısmı, GTB sınıflandırma modeli kullanılarak yapılan analizde arazinin 48.40 ha (%0.13) lık kısmının su kütlesi oluşu belirlenmiştir.




(a)



(b)

**Şekil 5 (a,b).** Atakum ilçesinin (a) RO ve (b) GTB kullanılarak oluşturulan arazi örtüsü haritaları.



**Şekil 6.** İki makine öğrenmesi sınıflandırıcısı kullanılarak her bir sınıfın hesaplanan alanları.

### 3.1. Sınıflandırıcıların kullanıcı doğruluğu ve üretici doğruluğuna göre değerlendirilmesi

Sınıflandırma modellerinin performansını değerlendirmek için AÖ sınıfları için kullanıcı doğruluğu (KD) ve üretici doğruluğu (ÜD) kullanılmıştır. Farklı arazi örtüsü sınıflarındaki farklı sonuçlar nedeniyle, her sınıf için kapsamlı bir analiz yapılmıştır. RO ve GTB kullanılarak üretilen sınıflar için KD ve ÜD Tablo 5, Tablo 6'da ve Şekil 7 ve Şekil 8'de, sunulmuştur.

Kentsel alanlar sınıfında, RO'da KD %98.9; ÜD %100 olarak, GTB'de KD %97.7; ÜD %100 olarak hesaplanmıştır. Birbirlerine çok yakın olsa da, RO kentsel alanların sınıflandırılması için GTB sınıflandırıcılarından daha iyi performans gösterdiği izlenmiştir.

Çalışma alanının bitki örtüsü sınıfı değerlendirilmesinde; RO yönteminde %98.0; KD ve %98.5; ÜD ye ulaşılırken, GTB yönteminde %97.0 KD ve %99.0 ÜD ulaşılmıştır. Mevcut araştırma alanında, her iki sınıflandırıcı da bitki örtüsü çıkarımı için iyi performans göstermiştir.

Araştırma bölgesindeki tarım arazileri sınıflandırılmasında; RO'da %97.3 KD ve %93.9 ÜD; GTB'de %98.0 KD ve %94.7 ÜD değerine ulaşılmıştır. GTB'nin tarım arazisi haritalamasında daha iyi sonuç verdiği gözlemlenmiştir.

Çalışma alanında çıplak arazi için sınıflandırma çalışmalarında; RO, %100.0 KD ve %100.0 ÜD göstermiştir. GTB ise KD'yi %100.0 ve ÜD'yi %94.5 olarak göstermiştir. Çıplak arazilerin sınıflandırılmasında; RO'nun araştırma alanında daha iyi sonuç verdiği belirlenmiştir.



Çalışma alanındaki su kütlelerine dair sınıflandırmanın değerlendirilmesinde; RO; %82.1 KD ve %92.0 ÜD değerine ulaşmış, GTB ise %89.3 KD ve %94.3 ÜD değerine ulaşmıştır. Sonuçlar, GTB'nin araştırma alanındaki Su kütleleri sınıflandırılmasında daha iyi sonuç verdiğini göstermiştir.

**Tablo 5.** Rastgele Orman sınıflandırıcısının arazi örtüsü karışıklık matrisi.

RO	Doğrulama verileri					Toplam	Kullanıcı Doğruluğu
	Kentsel Alanlar	Bitki Örtüsü	Tarım Arazisi	Çıplak Arazi	Su Kütleleri		
Kentsel Alanlar	172	0	2	0	0	174	0.989
Bitki örtüsü	0	194	4	0	0	198	0.980
Tarım arazi	0	3	248	0	4	255	0.973
Çıplak arazi	0	0	0	36	0	36	1.000
Su kütleleri	0	0	10	0	46	56	0,821
Toplam	172	197	264	36	50	719	
Üretici Doğruluğu	1.00	0.985	0.939	1.000	0.920		
Genel Doğruluk	0.968						
Kappa katsayısı	0.956						

**Tablo 6.** Gradyan Ağaç Hızlandırma sınıflandırıcısının arazi örtüsü karışıklık matrisi.


GTB	Doğrulama verileri					Toplam	Kullanıcı Doğruluğu
	Kentsel Alanlar	Bitki Örtüsü	Tarım Arazisi	Çıplak Arazi	Su Kütleleri		
Kentsel Alanlar	170	0	2	2	0	174	0.977
Bitki örtüsü	0	192	6	0	0	198	0.970
Tarım arazi	0	2	250	0	3	255	0.980
Çıplak arazi	0	0	0	36	0	36	1.000
Su kütleleri	0	0	6	0	50	56	0.893
Toplam	170	194	264	38	53	719	
Üretici Doğruluğu	1.00	0.990	0.947	0.947	0.943		
Genel Doğruluk	0.971						
Kappa katsayısı	0.960						

**Şekil 7.** Sınıflandırıcıların kullanıcı doğruluğu (KD).**Şekil 8.** Sınıflandırıcıların üretici doğruluğu (ÜD).



### 3.2. Sınıflandırıcıların genel doğruluk (GD) ve Kappa katsayısı (K) bazında değerlendirilmesi

GEE platformundaki modeller kullanılarak elde edilen arazi örtüsü haritasının genel doğruluk ve kappa katsayısı verileri Şekil 9'da sunulmuştur. GD ve K kullanılarak yapılan doğrulamada, RO'nin %96.8 GD ve %95.6 K'ya, GTB'nin ise %97.1 GD ve %96.0 K'ya sahip olduğu belirlenmiştir. Genel olarak, çalışmadaki tüm modellerle elde edilen veriler kabul edilebilir düzeydedir, bunun dışında GTB ile elde edilen veriler RO'dan daha başarılı olarak gözlemlenmiştir.



Şekil 9. Kullanılan makine öğrenmesi sınıflandırıcıları için genel doğruluk ve Kappa katsayısı.

Tablo 7'de gösterilen doğruluk, kesinlik, duyarlılık, özgüllük ve F1-puanı ve doğruluğa dayalı olarak, RF Kentsel, Bitki Örtüsü için biraz daha iyi ve Çıplak Arazi için önemli ölçüde daha iyidir. GTB ise Tarım Arazileri ve Su Kütleleri için daha iyi performans göstermektedir.

Tablo 7. Kullanılan yöntemler için doğruluk, hassasiyet, duyarlılık, özgüllük ve F1 puanları.

Model	Sınıflar	Kesinlik	Duyarlılık	Özgüllük	F1-puanı	Doğruluk
RO	Kentsel alanlar	1.000	0.989	1.000	0.994	0.997
	Bitki örtüsü	0.985	0.980	0.994	0.982	0.990
	Tarım arazisi	0.939	0.973	0.966	0.956	0.968
	Çıplak arazi	1.000	1.000	1.000	1.000	1.000
	Su kütleleri	0.920	0.821	0.994	0.868	0.981
GTB	Kentsel alanlar	1.000	0.976	1.000	0.988	0.994
	Bitki örtüsü	0.989	0.969	0.996	0.979	0.989
	Tarım arazisi	0.945	0.980	0.970	0.962	0.973
	Çıplak arazi	0.929	1.000	0.997	0.963	0.997
	Su kütleleri	0.943	0.893	0.995	0.917	0.987

Çalışmada, arazi örtüsü sınıflandırması için makine öğrenmesi yöntemlerinden RO ve GTB kullanılmıştır. Sınıflandırma süreçlerinde Landsat veri kümeleri ve

eğim ve yükseklik gibi yardımcı veriler kullanılmıştır. Yöntemin kesinliği ve doğruluk ölçütleri için kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve kappa katsayısı kullanılarak değerlendirilmiştir. GEE bağlamında, GTB arazi örtüsünü kategorize ederek, karmaşık ilişkileri tanımlayarak ve güvenilir tahminler yaparak RO'dan daha iyi performans gösterdiği belirlenmiştir.

Mevcut araştırma, GEE platformunda farklı AÖ sınıflarının tanınmasını her iki modelin de tutarlı ve birbirine yakın hassasiyette performans gösterdiği genel değerlendirmede ise GTB'nin RO'dan daha iyi performans gösterdiği gözlemlenmiştir.

### 4. Sonuçlar

Bu çalışma, Atakum ilçesinde Google Earth Engine uygulaması kullanılarak, arazi örtüsü sınıflandırması için makine öğrenimi sınıflandırıcılarının performansını değerlendirmek amacıyla yapılmıştır. Araştırma, 2023 yılına ait Landsat 8 verilerini kullanarak GTB ve RO'nun performansını karşılaştırmaya odaklanmıştır. Sınıflandırma doğruluğunu artırmak için yükseklik ve eğim verileriyle birlikte altı spektral indeks "NDVI, NDBI, NDWI, BSI, SAVI, EVI" analize entegre edilmiştir. Sınıflandırılan arazi örtüleri arasında kentsel, bitki örtüsü, tarım arazileri, çıplak araziler ve su kütleleri yer almış ve tüm girdi değişkenleri optimum makine öğrenimi modeli performansı için normleştirilmiştir.

Bu modellerin doğruluğu, kullanıcı doğruluğu, üretici doğruluğu, genel doğruluk ve kappa katsayısı kullanılarak irdelenmiştir. Sonuçlar, topluluk yöntemleri RO ve GTB'nin sınıflandırma doğruluğunda iyi sonuçlar verdiğini göstermiştir. RO ve GTB için Kappa katsayıları sırasıyla %95.6 ve %96.0, genel doğruluk ise %96.8 ve %97.1'dur. GTB, RO'dan daha iyi performans göstermiş olsa da, her iki yöntemin de karmaşık verileri işleme ve güvenilir tahminler sunma konusundaki etkinliğini ortaya çıkarmıştır ve bu yöntemlerin arazi örtüsü sınıflandırmasında ve büyük ölçekli konumsal veri analizi için uygun olduğu gözlemlenmiştir.

Çalışma ayrıca, GEE'nin uydu görüntülerini hızlı bir şekilde işleyerek yüksek doğrulukta arazi örtüsü haritaları elde etmedeki etkinliğini vurgulamıştır. Bu yetenek, çevresel izleme, kaynak yönetimi, kentsel planlama, afet müdahalesi ve iklim değişikliği çalışmaları gibi çeşitli uygulamalar için hayati önem taşımaktadır.

Sonuç olarak, makine öğrenmesi sınıflandırıcılarını GEE ile entegre etmek, arazi örtüsü sınıflandırmasına verimli bir yaklaşım sunmaktadır. Bu çalışmada gösterilen RO ve GTB modellerinin etkinliği, gelecekteki araştırmalar ve çalışma alanındaki arazi örtüsü haritalamasında pratik kullanımlar için temel perspektifler sunmaktadır. Bu teknoloji, karmaşık ve büyük ölçekli konumsal verilerin doğru bir şekilde analiz edilmesini sağlayarak çevre yönetimi ve politika kararlarını önemli ölçüde iyileştirebileceği öngörülmektedir. İlerleyen çalışmalarda SPOT ve Sentinel gibi yüksek çözünürlüklü uydu görüntüleri kullanılarak daha yüksek doğruluk ve duyarlılıkta sonuçlar elde edilmesi hedeflenmektedir.

**Araştırmacıların katkı oranı**

**Zelalem Getachew Ayalke:** Literatür taraması, Uygulama, Makale yazımı; **Aziz Şişman:** Düzenleme

**Çatışma Beyanı**

Herhangi bir çıkar çatışması bulunmamaktadır.

**Kaynakça**

- Adali, T. (2009). Machine Learning for Signal Processing XIX : Proceedings of the 2009 IEEE Signal Processing Society Workshop : MLSP 2009 : Nineteenth in a Series of Workshops. IEEE.
- Alexander, C. (2020). Normalised difference spectral indices and urban land cover as indicators of land surface temperature (LST). *International Journal of Applied Earth Observation and Geoinformation* 86. Elsevier B.V.
- Arpitha, M., Ahmed, SA. & Harishnaika, N. (2023). Land use and land cover classification using machine learning algorithms in google earth engine. *Earth Science Informatics*. Springer Science and Business Media Deutschland GmbH.
- Avcı, C. Budak, M. Yagmur, N., & Balçık, F. B. (2023). Comparison between random forest and support vector machine algorithms for LULC classification. *International Journal of Engineering and Geosciences*, 8(1), 01-10
- Basheer, S., Wang, X., Farooque, AA., Nawaz, RA., Liu, K., Adekanmbi, T., & Liu, S. (2022). Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing* 14(19): 1-18.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*. Elsevier B.V.
- Billah, M., Islam, AKMS., Mamoon, W.B., Rahman, M.R. (2023). Random forest classifications for landuse mapping to assess rapid flood damage using Sentinel-1 and Sentinel-2 data. *Remote Sensing Applications: Society and Environment* 30. Elsevier B.V.
- Birhanu, L., Hailu, BT., Bekele, T., & Demissew, S. (2019). Land use/land cover change along elevation and slope gradient in highlands of Ethiopia. *Remote Sensing Applications: Society and Environment* 16. Elsevier B.V.
- Breiman, L. (2001). Random forests. *Statistics Department University of California Berkeley*. Epub ahead of print 2001.
- Breiman, L., Friedman, JH., Olshen, RA., & Stone, C. J. (1984). *Classifications and Regression Trees*. Chapman & Hall/CRC.
- Butler, K. (2013). Band Combinations for Landsat 8. Available at: <https://www.esri.com/arcgis-blog/products/product/imagery/band-combinations-for-landsat-8/> (accessed 4 December 2023).
- Calvo-Zaragoza, J., Valero-Mas, JJ., & Rico-Juan, JR. (2015). Improving kNN multi-label classification in Prototype Selection scenarios using class proposals. *Pattern Recognition* 48(5). Elsevier Ltd: 1608–1622.
- Cao, W., Zhou Y., Li, R., & Li, X. (2020). Mapping changes in coastlines and tidal flats in developing islands using the full time series of Landsat images. *Remote Sensing of Environment* 239. Elsevier Inc.
- Chen ,W., Wang, H., Zhao, H., & Qin, K. (2020). Google Earth Engine–assisted black carbon radiative forcing calculation over a heavy industrial city in China. *Air Quality, Atmosphere and Health* 13(3). Springer: 329–338.
- Cohen warren, B. & Goward, SN. (2004). Landsat’s Role in Ecological Applications of Remote Sensing WARREN. *BioScience* 54.
- Cortes, C., Vapnik, V., & Saitta, L. (1995). *Support-Vector Networks*. Editor. Machine Learning. Kluwer Academic Publishers.
- Dabija, A., Kluczek, M., Zagajewski, B., Raczko, E., Kycko, M., Al-Sulttani, A. H., Tardà, A., Pineda, L., & Corbera, J. (2021). Comparison of support vector machines and random forests for corine land cover mapping. *Remote Sensing* 13(4). MDPI AG: 1–35.
- DeFries, RS., Foley, JA., & Asner, GP. (2004). Land-use choices: Balancing human needs and ecosystem function. *Frontiers in Ecology and the Environment*. Ecological Society of America.
- Demuzere, M., Bechtel, B., & Mills, G. (2019). Global transferability of local climate zone models. *Urban Climate* 27. Elsevier B.V.: 46–63.
- Desai, GT., & Gaikwad, AN. (2022). Automatic land cover classification with SAR imagery and Machine learning using Google Earth Engine. *International Journal of Electrical and Computer Engineering Systems* 13(10): 909–916.
- Disperati, L., & Viridis, SGP. (2015). Assessment of land-use and land-cover changes from 1965 to 2014 in Tam Giang-Cau Hai Lagoon, central Vietnam. *Applied Geography* 58. Elsevier Ltd: 48–64.
- Efe, E., & Algancı, U. (2023). Çok zamanlı Sentinel 2 uydu görüntüleri ve makine öğrenmesi tabanlı algoritmalar ile arazi örtüsü değişiminin belirlenmesi. *Geomatik*, 8(1), 27-34
- Elith, J., Leathwick, JR., & Hastie, T. (2008). A working guide to boosted regression trees. *Journal of Animal Ecology*.
- Elmes, A., Alemohammad, H., Avery, R., Caylor, K., Eastman, J. R., Fishgold, L.,... & Estes, L. (2020). Accounting for training data error in machine learning applied to earth observations. *Remote Sensing*. MDPI AG.
- Embury, O., Merchant. CJ., & Filipiak, MJ. (2012). A reprocessing for climate of sea surface temperature from the along-track scanning radiometers: Basis in radiative transfer. *Remote Sensing of Environment* 116: 32–46.
- Foody, GM. (2001). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*. Epub ahead of print 2001.
- Foody, GM., Pal, M., Rocchini, D., Garzon-Lopez, C.X., & Bastin, L. (2016). The sensitivity of mapping methods to reference data quality: Training supervised image classifications with imperfect reference data. *ISPRS*

- International Journal of Geo-Information 5(11). MDPI AG.
- Friedman, JH. (2001). 999 Reitz Lecture Greedy Function Approximation: A Gradient Boosting Machine 1. The Annals of Statistics.
- Friedman, JH. (2002). Stochastic gradient boosting. Computational Statistics & Data Analysis. Available at: [www.elsevier.com/locate/csda](http://www.elsevier.com/locate/csda).
- Gandhi, U. (2021). End-to-End Google Earth Engine (Full Course Material). Available at: <https://courses.spatialthoughts.com/end-to-end-gee.html#accuracy-assessment> (accessed 17 December 2023).
- Gao, B.-C. (1996).. NDWI- A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. REMOTE SENS. ENVIRON, 7212, 257–266.
- Ge, Y., Hu, S., Ren, Z., Jia, Y., Wang, J., Liu, M., ...& Chen, Y. (2019). Mapping annual land use changes in China's poverty-stricken areas from 2013 to 2018. Remote Sensing of Environment 232. Elsevier Inc.
- Gebhardt, S., Wehrmann, T., Ruiz, MAM., Maeda, P., Bishop, J., Schramm, M., ... & Schmidt, M. (2014). MAD-MEX: Automatic wall-to-wall land cover monitoring for the mexican REDD-MRV program using all landsat data. Remote Sensing 6(5). MDPI AG: 3923–3943.
- Ghazaryan, G., Dubovyk, O., Löw, F., Lavreniuk, M., Kolotii, A., Schellberg, J., & Kussul, N. (2018). A rule-based approach for crop identification using multi-temporal and multi-sensor phenological metrics. European Journal of Remote Sensing 51(1). Taylor and Francis Ltd.: 511–524.
- Gislason, PO., Benediktsson, JA., & Sveinsson, JR. (2006). Random forests for land cover classification. In: Pattern Recognition Letters, March 2006, pp. 294–300.
- Gu, Y., Liu, T., Gao, G., Ren, G., Ma, Y., Chanussot, J., & Jia, X. (2021). Multimodal hyperspectral remote sensing: an overview and perspective. Science China Information Sciences. Science in China Press.
- Hansen, MC., & Loveland, TR. (2012). A review of large area monitoring of land cover change using Landsat data. Remote Sensing of Environment.
- Huang, C., Davis, LS., & Townshend, JRG. (2002). An assessment of support vector machines for land cover classification. International Journal of Remote Sensing 23(4): 725–749.
- Huang, C., Yang, J., & Jiang, P. (2018). Assessing impacts of urban form on landscape structure of urban green spaces in China using Landsat images based on Google Earth Engine. Remote Sensing 10(10). MDPI AG.
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment, 25(3), 295–309.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. Remote Sensing of Environment, 83, 195–213.
- Huntington, JL., Hegewisch, KC., Daudert B., Morton, CG., Abatzoglou, JT., McEvoy, DJ., & Erickson, T. (2017). Climate engine: Cloud computing and visualization of climate and remote sensing data for advanced natural resource monitoring and process understanding. Bulletin of the American Meteorological Society 98(11) 2397–2409.
- Karip, A.G.B., & Göksel, Ç. (2017). İğneada Koruma Alanının Arazi Örtüsü/Arazi Kullanımının Zamana Bağlı Değişiminin Markov Zincirleri İle Modellenmesi. Geomatik, 2(2); 94-105.
- Kanevski M (2009). Machine Learning for Spatial Environmental Data.
- Khan, R., Gilani, H., Iqbal, N., & Shahid, I. (2020). Satellite-based (2000–2015) drought hazard assessment with indices, mapping, and monitoring of Potohar plateau, Punjab, Pakistan. Environmental Earth Sciences 79(1). Springer.
- Kussul, N., Lemoine, G., Gallego, FJ., Skakun, SV., Lavreniuk, M., & Shelestov, AY. (2016). Parcel-Based Crop Classification in Ukraine Using Landsat-8 Data and Sentinel-1A Data. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 9(6) 2500–2508.
- Lam, NS-N. (2008). Advances in Land Remote Sensing System, Modeling, Inversion and Application (S Lianged. ). Springer Scnce+Business Media B.V.
- Lary, DJ., Alavi, AH., & Gandomi, AH. (2016). Machine learning in geosciences and remote sensing. Geoscience Frontieers 7(1) 3–10.
- Li, Y., Liu, C., Zhao, W., & Huang, Y. (2020). Multi-spectral remote sensing images feature coverage classification based on improved convolutional neural network. Mathematical Biosciences and Engineering 17(5) 4443–4456.
- Liang, L., Runkle, BRK., Sapkota, BB., & Reba, M.. (2019). Automated mapping of rice fields using multi-year training sample normalization. International Journal of Remote Sensing 40(18) 7252–7271.
- Liu, D., Chen, N., Zhang, X., Wang, C., & Du, W. (2020). Annual large-scale urban land mapping based on Landsat time series in Google Earth Engine and OpenStreetMap data: A case study in the middle Yangtze River basin. ISPRS Journal of Photogrammetry and Remote Sensing 159 337–351.
- Loveland, TR. (2016). History of land-cover mapping. USGS Publications Warehouse. CRC Press: 13–22.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. International Journal of Remote Sensing. Taylor and Francis Ltd.
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Homayouni, S., & Gill, E. (2019). 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).
- Mangkhaseum, S., & Hanazawa, A. (2021). Comparison of Machine Learning Classifiers for Land Cover Changes using Google Earth Engine. Proceedings of the 2021 IEEE International Conference on Aerospace Electronics and Remote Sensing Technology, ICARES 2021. IEEE: 1–7.
- Mardani, M., Mardani, H., De Simone, L., Varas, S., Kita, N., & Saito, T. (2019). Integration of machine learning



- and open access geospatial data for land cover mapping. *Remote Sensing* 11(16).
- Mas, JF., & Flores JJ (2008). The application of artificial neural networks to the analysis of remotely sensed data. *International Journal of Remote Sensing*. Taylor and Francis Ltd.
- Mateo-García, G., Gómez-Chova, L., Amorós-López, J., Muñoz-Marí, J., & Camps-Valls, G. (2018). Multitemporal cloud masking in the Google Earth Engine. *Remote Sensing* 10(7).
- Maxwell, AE., Warner, TA., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*. Taylor and Francis Ltd.
- Mhanna, S., Halloran, LJS., Zwahlen, F., Asaad, AH., & Brunner, P. (2023). Using machine learning and remote sensing to track land use/land cover changes due to armed conflict. *Science of the Total Environment* 898. Elsevier B.V.
- Middel, A., Lukasczyk, J., Maciejewski, R., Demuzere, M., & Roth, M. (2018). Sky View Factor footprints for urban climate modeling. *Urban Climate* 25 120–134.
- Midekisa, A., Holl, F., Savory, DJ., Andrade-Pacheco, R., Gething, PW., Bennett, A., & Sturrock, H.J.W. (2017). Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. *PLoS ONE* 12(9).
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*.
- Murray, NJ., Keith, DA., Simpson, D., Wilshire, JH., & Lucas, RM. (2018). Remap: An online remote sensing application for land cover classification and monitoring. *Methods in Ecology and Evolution* 9(9) 2019–2027.
- Nguyen, UNT., Pham, LTH., & Dang, TD. (2019). An automatic water detection approach using Landsat 8 OLI and Google Earth Engine cloud computing to map lakes and reservoirs in New Zealand. *Environmental Monitoring and Assessment* 191(4).
- Noi Phan, T., Kuch, V., & Lehnert, LW. (2020). Land cover classification using google earth engine and random forest classifier-the role of image composition. *Remote Sensing* 12(15).
- Oo, TK., Arunrat, N., Sereenonchai, S., Ussawarujikulchai, A., Chareonwong, U., & Nutmagul, W. (2022). Comparing Four Machine Learning Algorithms for Land Cover Classification in Gold Mining: A Case Study of Kyaukpahto Gold Mine, Northern Myanmar. *Sustainability* 14(17).
- Pal, M., & Mather, PM. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment* 86(4) 554–565.
- Poortinga, A., Tenneson, K., Shapiro, A., Nquyen, Q., Aung, KS., Chishtie, F., & Saah, D. (2019). Mapping plantations in Myanmar by fusing Landsat-8, Sentinel-2 and Sentinel-1 data along with systematic error quantification. *Remote Sensing* 11(7).
- Quinn, JW. (2001). Band Combinations. Available at: [https://web.pdx.edu/~nauna/resources/10\\_BandCombinations.htm](https://web.pdx.edu/~nauna/resources/10_BandCombinations.htm) (accessed 4 December 2023).
- Rikimaru, A., Roy, P., & Miyatake, S. (2002). Tropical Forest cover density mapping. *Tropical ecology*, 43(1), 39-47.
- Rimal, B., Keshtkar, H., Sharma, R., Stork, N., Rijal, S., & Kunwar, R. (2019). Simulating urban expansion in a rapidly changing landscape in eastern Tarai, Nepal. *Environmental Monitoring and Assessment* 191(4).
- Rogan, J., & Chen, DM. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning*.
- Rouse, R. W. H., Haas, J. A. W., & Deering, D. W. (1974). Monitoring Vegetation Systems in the Great Plains with ERTS. Third ERTS-1 Symposium NASA, NASA SP-351, 309–317
- Rwanga, SS., & Ndambuki, JM. (2017). Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *International Journal of Geosciences* 08(04) 611–622.
- Sellami, EM., & Rhinane, H. (2023). A New Approach for Mapping Land Use / Land Cover Using Google Earth Engine: a Comparison of Composition Images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* - 48(4) 343–349.
- Shetty, S., Gupta, PK., Belgiu, M., & Srivastav, S. K. (2021). Assessing the effect of training sampling design on the performance of machine learning classifiers for land cover mapping using multi-temporal remote sensing data and google earth engine. *Remote Sensing* 13(8).
- Sinha, S., Sharma, LK., & Nathawat, MS. (2015). Improved Land-use/Land-cover classification of semi-arid deciduous forest landscape using thermal remote sensing. *Egyptian Journal of Remote Sensing and Space Science* 18(2) 217–233.
- Siraj, M., Mahmood, S., & Habib, W. (2023). Geo-spatial assessment of land cover change in District Dera Ismail Khan, Khyber Pakhtunkhwa, Pakistan. *Advanced Remote Sensing*, 3(1), 1-9.
- Sulova, A., & Arsanjani, JJ. (2021). Exploratory analysis of driving force of wildfires in australia: An application of machine learning within google earth engine. *Remote Sensing* 13(1) 1–23.
- Tırmanoğlu, B., İsmailoğlu, İ., Kokal, A. T., & Musaoğlu, N. (2023). Yeni nesil multispektral ve hiperspektral uydu görüntülerinin arazi örtüsü / arazi kullanımı sınıflandırma performanslarının karşılaştırılması: Sentinel-2 ve PRISMA Uydusu. *Geomatik*, 8(1), 79-90
- Tso, B., & Mather, Paul. (2009). *Classification Methods for Remotely Sensed Data*. Taylor & Francis Group, LLC.
- TÜİK, (2024). Adrese dayalı nüfus kayıt sistemi, <https://biruni.tuik.gov.tr/medas/?locale=tr> (Erişim Tarihi; 10.02.2024)
- Tumer, K., & Ghosht, J. (1996). Analysis of Decision Boundaries in Linearly Combined Neural Classifiers. *Pattern Recognition*.
- Uddin, K., Matin, MA., & Meyer, FJ. (2019). Operational flood mapping using multi-temporal Sentinel-1 SAR images: A case study from Bangladesh. *Remote Sensing* 11(13).
- Wulder, MA., Masek, JG., Cohen, WB., Loveland, TR., & Woodcock, CE. (2012). Opening the archive: How free data has enabled the science and monitoring promise

- of Landsat. *Remote Sensing of Environment* 122: 2–10.
- Xie, Z., Phinn, SR., Game, ET., Pannell, DJ., Hobbs, RJ., Briggs, PR., & McDonald-Madden, E. (2019). Using Landsat observations (1988–2017) and Google Earth Engine to detect vegetation cover changes in rangelands - A first step towards identifying degraded lands for conservation. *Remote Sensing of Environment* 232.
- Yuh, YG., Tracz, W., Matthews, HD., & Turner, SE. (2023). Application of machine learning approaches for land cover monitoring in northern Cameroon. *Ecological Informatics* 74. Elsevier B.V.
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594.
- Zhang, C., & Li, X. (2022). Land Use and Land Cover Mapping in the Era of Big Data. *Land*.
- Zhang, M., Gong, P., Qi, S., Liu, C., & Xiong, T. (2019). Mapping bamboo with regional phenological characteristics derived from dense Landsat time series using Google Earth Engine. *International Journal of Remote Sensing* 40(24) 9541–9555.
- Zhang, Z., Wei, M., Pu, D., He, G., Wang, G., & Long, T. (2021). Assessment of annual composite images obtained by google earth engine for urban areas mapping using random forest. *Remote Sensing* 13(4) 1–21.
- Zhu, Z., & Woodcock, CE. (2014). Continuous change detection and classification of land cover using all available Landsat data. *Remote Sensing of Environment* 144: 152–171.

