



## Geomatik

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

e-ISSN 2564-6761



# Orman ekosistemindeki ağaç boylarının, optik, radar, lazer altimetre uydu verileri ve yardımcı kaynaklar kullanılarak Google Earth Engine platformunda modellenmesi

Eren Gürsoy Özdemir<sup>\*1</sup>, Tarık Utku Zengin<sup>1</sup>, Halit Abdullah Güleç<sup>1</sup>

<sup>1</sup> Bartın Üniversitesi, Ulus Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Tapu ve Kadastro Programı, Bartın, Türkiye, eozdemir@bartin.edu.tr, tarikzengin7474@gmail.com, gulecabdullah999@gmail.com

Kaynak Göster: Özdemir, E. G., Zengin, T. U., & Güleç, H. A. (2024). Orman ekosistemindeki ağaç boylarının, optik, radar, lazer altimetre uydu verileri ve yardımcı kaynaklar kullanılarak Google Earth Engine platformunda modellenmesi. *Geomatik*, 9 (2), 259-268

<https://doi.org/10.29128/geomatik.1449670>

### Anahtar Kelimeler

Uzaktan algılama  
Makine öğrenmesi  
GEDI  
Uydu altimetrisi  
Google Earth Engine

### Araştırma Makalesi

Geliş: 09.03.2024  
Revize: 30.03.2024  
Kabul: 16.04.2024  
Yayınlanma: 15.08.2024



### Öz

Ormanlar, karada biyolojik çeşitliliği korurken, bitki örtüsünde ve toprakta önemli miktarda karbon depolayarak atmosferdeki karbon dengesini düzenlemekte ve buna bağlı olarak küresel ısınmanın hafifletilmesine katkı sağlamaktadır. Ormanlardaki ağaç boylarının belirlenmesi, orman kaynaklarının sürdürülebilir yönetimi, sağlığı ve olası tehditlerin tespitleri için önem arz etmektedir. Bu çalışmada, bulut tabanlı Google Earth Engine (GEE) platformunda, Sentinel-1 radar, Sentinel-2 optik uydu verileri, Global Ecosystem Dynamics Investigation (GEDI) lazer uydu altimetrisi ve Sayısal Yükseklik Modeli (SYM) verileri kullanılarak ağaç boyları Rastgele Orman (RO) algoritması ile modellenmiştir. Elde edilen ağaç yükseklikleri Bartın İli sınırlarında karaçam (*Pinus nigra Arnold*) ve sahil çamı (*Pinus pinaster Aiton*) türlerinin bulunduğu 45 adet örnekleme alanından elde edilen ağaç boyları ile karşılaştırılmıştır. Optik, radar, altimetre ve yardımcı veriler ile elde edilen model sonuçlarının istatistik analizleri yapılmış, başarılı sonuçlar elde edilmiştir: (Ortalama Mutlak Hata (OMH)= 1,42 m, Karesel Ortalama Hata (KOH)= 1,54 m ve Belirtme Katsayısı ( $R^2$ ) = 0,60. Ayrıca eğimin fazla olduğu örnekleme alanlarında doğruluk değerlerinin azaldığı görülmüştür.

## Modeling of tree heights in forest ecosystems using optical, radar, laser altimeter satellite data, and auxiliary on Google Earth Engine Platform

### Keywords

Remote sensing  
Machine learning  
GEDI  
Satellite altimetry  
Google Earth Engine

### Research Article

Received: 09.03.2024  
Revised: 30.03.2024  
Accepted: 16.04.2024  
Published: 15.08.2024

### Abstract

Forests play a crucial role in maintaining terrestrial biological diversity and regulating the carbon balance in the atmosphere by storing significant amounts of carbon in vegetation and soil, mitigating global warming. Determining accurate measurements of tree heights in forests is essential for the sustainable management, health, and detection of potential threats to forest resources. In this study, tree heights were modeled using the Random Forest (RF) on the cloud-based Google Earth Engine (GEE) platform, integrating Sentinel-1 radar, Sentinel-2 optical satellite data, Global Ecosystem Dynamics Investigation (GEDI) laser satellite altimetry, and Digital Elevation Model (DEM) data. The obtained tree heights were compared with the measurements from 45 sample plots of black pine (*Pinus nigra Arnold*) and maritime pine (*Pinus pinaster Aiton*) species within the boundaries of Bartın Province. Statistical analyses were conducted on the model results obtained from optical, radar, altimeter, and auxiliary data, yielding successful outcomes: (Mean Absolute Error (MAE) = 1,42 m, Root Mean Square Error (RMSE) = 1,54 m, and Coefficient of Determination ( $R^2$ ) = 0,60). Additionally, it was observed that accuracy values decreased in sampling areas with high slopes.

## 1. Giriş

Karbon tutucu özelliği ve doğadaki karbon döngüsünü koruması bakımından Dünya'nın karasal yüzeyinin neredeyse %30'unu kaplayan ormanlar, iklim değişikliği ile mücadelede öncelikli bir rol oynar (Kindermann ve ark., 2008). Bölgesel ve küresel ölçekte ormanlık alanların envanterlerinin çıkarılması, karbon kestirimlerinin yapılması, karbon salınımlarının azaltılması bakımından değerlidir. Bu envanterlerin belirlenmesi ve hesaplamaların doğru şekilde yapılması da iklim değişikliği ile mücadelede etkilidir.

Ormanlık personeli, ormanların sağlık ve hasar durumunu izlemek, ağaçlandırma süreçlerini optimize etmek ve orman meşcerelerindeki ağaç boyları ve kütleyi tahmin etmek için doğru ve ayrıntılı yükseklik verilerine ihtiyaç duyar (Vatandaşlar ve ark., 2023). Bu parametreler, ekosistemin iklim ve arazi kullanımını değiştikliklerine ve biyolojik çeşitliliğe nasıl tepki verdiğini, ormanların tahribatı ve ormansızlaşmanın değerlendirilmesini izlemek için de kullanılır. Araştırmacılar ormanda bu bilgileri toplamak için geleneksel olarak yersel saha ölçmelerini kullanırlar. Ancak bu yöntem ile ormanlardaki ağaçların boy verilerinin toplanması zaman alıcı, maliyetli ve genellikle mekânsal olarak kısıtlıdır (Morin ve ark., 2022).

Uydu teknolojilerinin gelişmesiyle beraber orman alanlarında geleneksel yöntemlere (yersel ölçmeler) ek olarak uzaktan algılama teknikleri de kullanılmaya başlanmıştır. Optik uydu verilerinin genellikle ağacın tepe tacında ve yaprak bileşenlerinde etkili olduğu görülmüştür. Odunsu kütlenin tahmini için bu yöntem uygun değildir (Wang ve ark., 2019). Aktif sistemler ormanların hacim ve boy ölçmelerinde önemli bir araç olarak kabul edilmektedir (Zadbagher ve ark., 2023). Sentetik Açıklıklı Radar (SAR) uydu görüntüleri, tüm hava koşullarında kullanılabilir ve gece-gündüz fark etmeksizin görüntü sağlayabilir. Ayrıca, ormanlık bölgelerde, dalga boyları sayesinde ağaçların tepelerinden gövdelerine kadar nüfuz edebilir (Santoro ve ark., 2019). Doğal orman statüsünde bulunan orman varlıklarının çoğunluğu, farklı topografik koşullarda yer alır ve SAR görüntülerinin işlenmesi ve değerlendirilmesi sürecinde çeşitli teknikler ve ek veriler gerektirir (Flores-Anderson ve ark., 2019; Guerra-Hernandez ve Pascual, 2021).

Bu yöntemlerin yanı sıra orman alanlarında da kullanılan ve ışık tespiti ve uzaklık tayini anlamına gelen Light Detection and Ranging (LIDAR) sistemleri, karasal, havadan (drone, uçak vb.) ve uydu LIDAR sistemleri olmak üzere üç sınıfa ayrılmaktadır. Karasal lazer tarama sistemleri (el tipi, tripoda kurulu vb.) büyük orman alanlarında kısıtlayıcı olmakta ve zaman/maliyet konusunda havadan ve uydu sistemlerine göre geride kalmaktadır (Xi ve ark., 2022). Ormanlıkta da önemli bir araç olan, havadan tarama yapan LIDAR sistemlerinde, Küresel Konumlama Sistemi (GPS), hava aracında anlık koordinat değerlerini elde ederken, Eylemsizlik Ölçüm Birimi (Inertial Measurement Unit-IMU) sistemi de dikey eksene göre konum bilgilerini sağlar (Özdemir ve ark., 2021). Bu veriler, lazer taramasıyla elde edilen bilgilerle bütünleştirilir. Meşçere yüksekliklerinin elde edilmesi çalışmalarında da

kullanılan bu sistemler, çok yüksek çözünürlüklü, hassas konum doğruluklu nokta bulutları sunarken, orman örtüsüne nüfuz ederek de topoğrafya ve orman örtüsünün modellenenbilmesini sağlamaktadır (Sefercik ve ark., 2021).

Global Ecosystem Dynamics Investigation (GEDI), 2018 yılında Uluslararası Uzay İstasyonunda konumlandırılan, Dünya'nın üç boyutlu (3B) yapısını gözlemleyen yüksek çözünürlüklü lazer konumlama yapan bir uydu altimetri sistemidir. Dünya ormanlarının ve topografyasının üç boyutlu (3B) yapısını ve dinamiklerini incelemek için tasarlanmıştır. Bu sistem yeryüzüne saniyede 242 kez atış yapabilen üç farklı lazer sistemine sahiptir. 1064 nm (kıızılötesi) dalga boyuna ve 25 m ışın çapına (ayak izi) sahip sistem, orman örtüsü yüksekliğini ölçmek için tasarlanmıştır. Bir diğer sistem 532 nm (yeşil) dalga boyuna sahip olup atmosferik aerosol ve bulut özelliklerini ölçmek için kullanılmaktadır (URL-1). 2019 yılı itibarıyla veri toplamaya başlayan GEDI ölçmeleri ile optik ve radar uydu verileri entegrasyonu sayesinde ormanların 3B yapıları hakkında bilgiler edinmek biyokütle değişikliklerini ve karbon döngüsünü daha iyi anlamak amacıyla tasarlanmış bir ABD Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration-NASA) projesidir (Rishmawi ve ark., 2021). GEDI verileri, ormanlık uygulamalarını geliştirmek, ormansızlaşmayı izlemek, biyoçeşitliliği incelemek ve iklim değişikliği ile mücadelede stratejiler oluşturmak gibi bir dizi bilimsel ve çevresel uygulamada kullanılabilen ormanların mekânsal ve zamansal değerlendirmesinde önemli bir bileşendir (Coops ve ark., 2018).

Google Earth Engine (GEE), herhangi bir yazılıma ve güçlü bir bilgisayar donanımına bağlı olmaksızın, ön işleme ve analizlerin bulut platformu üzerinden gerçekleştirilebildiği, ücretsiz olarak kullanılabilen bulut tabanlı bir platformdur (Gorelick ve ark., 2017; Aghmand ve ark., 2021). Veri edinim ve işlemeyi saniyeler içerisinde gerçekleştiren GEE, çoklu uydu görüntülerini analiz etmek, sınıflandırmak, ağaç, orman ve su alanlarını, arazi kullanımı/arazi örtüsü değişikliklerini belirlemek, tarım alanlarının gelişimini takip etmek gibi birçok amaç doğrultusunda kullanılmaktadır. GEE, son 40 yılı içeren çok sayıda veri sunmaktadır (Wang ve ark., 2019). Bu platform, kayıtlı kullanıcılara GEE Explorer ve Kod Düzenleyici olmak üzere iki web tabanlı platform sunmaktadır. GEE Explorer, kullanıcılara sınırlı uydu görüntüsü görüntüleme imkânı sunar, diğer yandan GEE Kod Düzenleyici ile kullanıcılar programlama (JavaScript veya Python) kodları kullanarak analiz ve özelleştirme yapabilirler. Kod Düzenleyici ortamı, matematiksel ve mekânsal işlemlerle donatılmıştır ve kullanıcılar bu işlemleri görüntüler üzerinde ayrı ayrı veya birleştirilmiş olarak kullanabilir ve araştırma amaçlarına göre özelleştirebilirler.

Günümüzde karbon salınımı ve iklim değişiminin etkileriyle mücadele ederken, ormanların korunması ve genişletilmesi önemli bir öncelik haline gelmiştir. GEDI verilerinin optik, radar uydu verileri ile ayrı veya birlikte kullanılarak oluşturulan modellerle orman yapısını belirleme, Toprak Üstü Biyokütle (TÜB) kestirimi, arazi sınıflandırma, ağaç boyu tahmini çalışmaları mevcuttur

(Saarela ve ark., 2018; Dubayah ve ark., 2020; Guerra-Hernández ve Pascual, 2021; Potapov ve ark., 2021; Spracklen ve Spracklen, 2021; Duncanson ve ark., 2022; Vatandaşlar ve ark., 2023; Zhou ve ark., 2023; Padalia ve ark., 2023; Narin ve Yılmaz, 2024; Özdemir ve ark., 2024).

Makine öğrenmesi algoritmaları, hassas sınıflandırma ve regresyon yetenekleri, daha az parametre ayarı gerektirmesi ve çoklu kaynak verileriyle yüksek entegrasyon yeteneği gibi özellikleri sayesinde geniş uygulama alanları bulmaktadır (Bao ve ark., 2023). Rastgele Orman (RO), bir karar ağacı algoritmasıdır ve veri madenciliğinde farklı uygulamalarda sıklıkla kullanılan yöntemlerden biridir (Çömert ve ark., 2019; Apaydın ve Abdikan, 2021; Üstüner ve Sanli, 2021; Özdemir ve ark., 2024). Karar ağaçları, veri kümesini çok sayıda küçük gruba bölen karar verme adımlarını uygulayarak çalışır ve benzer özelliklere sahip verileri gruplandırır. Breiman (2001) tarafından geliştirilmiş algoritma, birden fazla çok değişkenli ağacın eğitildiği farklı eğitim kümelerinden gelen kararları birleştirme amacını taşır. Her bir veri seti orijinal veri setinden yer değiştirmeli olarak üretilir ve daha sonra rastgele özellik seçimi kullanılarak ağaçlar geliştirilir. RO algoritması için kullanıcı tarafından belirlenen iki parametre bulunmaktadır. Bu parametreler, her düğümde kullanılacak değişken sayısı (mtry) ve oluşturulacak ağaçların toplam sayısı (n) olarak tanımlanır. Algoritma başlangıçta eğitim veri setinden üçte ikisini önyükleme örnekleri hazırlamak için kullanır. Üçte bir kısmı ise hataları tespit etmek için kullanır (Out of Bag-OOB). Sonrasında, ayrı ayrı önyükleme setlerinden karar ağaçları geliştirilir. Düğümlerin her birinde, m değişkeni tüm değişkenler içinden rastgele seçilir ve sonuç olarak değişkenlerdeki en iyi dallanma belirlenir.

GEE’de kullanılan RO algoritmasının ilk aşamasında model oluşturulmaktadır. “ee.Classifier” modülünden

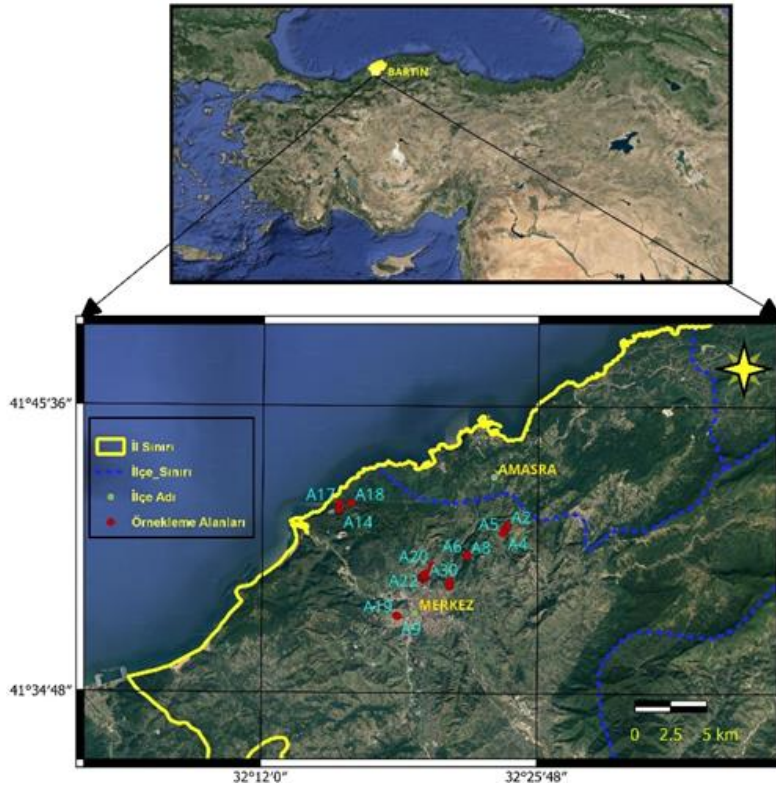
“RandomForestRegressor” regresyon algoritması çağrılır. “smileRandomForestRegressor(100)” metodu, Python Scikit-learn ile uyumlu olan Smile kütüphanesinden rastgele orman regresyon algoritmasını döndürür. Opsiyonel olan 100 argümanı, rastgele orman algoritmasında kullanılacak ağaç sayısını belirtmektedir. İkinci aşama ise modelin eğitilmesi aşamasıdır. Eğitim verileri, özellikler (features) ve hedef değişkeni (label) olarak ayrılmaktadır. Özellikler, tahmin yapmak için kullanılacak girdi verilerini (bant değerleri, yükseklik, altimetri değerleri) içerirken, hedef değişken tahmin edilmek istenen ağaç boyunu ifade etmektedir.

Bu çalışmada, GEE platformundan ücretsiz olarak elde edilen, Sentinel-1 radar, Sentinel-2 optik uydu, Sayısal Yükseklik Modeli (SYM) ve GEDI verileri kullanılarak örnekleme alanlarındaki ağaç boyları RO algoritması ile modellenmiş, örnekleme alanlarındaki karaçam (*Pinus nigra Arnold*) ve sahil çamı (*Pinus pinaster Aiton*) ağaçlarının yersel yöntemlerle elde edilen ağaç boyları ile karşılaştırılmıştır.

## 2. Yöntem


### 2.1. Çalışma alanının tanıtımı

Çalışma alanı olarak, Batı Karadeniz Bölgesinin, Bartın ili merkezinde, 41° 34' 48"- 41° 45' 36" Kuzey enlemleri ve 32° 12' 0"- 32° 25' 48" Doğu boylamları arasında yer alan karaçam ve sahil çamı ağaçlandırmaları seçilmiştir (Şekil 1). Çalışma alanının yükseltisi 30-250 m aralığında, genel bakışı ise kuzey, güney, güneydoğu ve batıdır. Bartın meteoroloji istasyonunun (30 m yükseklikte) 1961-2021 yılları arasındaki 50 yıllık verilerine göre, yıllık ortalama yağış miktarı 1049 mm, yıllık ortalama sıcaklık ise 12,8 °C olup, yıllık ortalama en yüksek sıcaklık ise 18,7 °C'dir (URL-2).



Şekil 1. Çalışma alanının konumu.





Şekil 2. Örneklem alanlarından görüntüler.

Çalışma, Bartın ili merkez ilçe sınırlarında, 12 adet karaçam ve 33 adet sahil çamı türüne ait alanlar dahil olmak üzere toplamda 45 örneklem alanında, 2023 yılı Ağustos ve Eylül aylarında gerçekleştirilmiştir. Örneklemelerin yapıldığı alanlar Şekil 2a ( $d_{1,3}=8,0-19,9$  cm) ve Şekil 2b ( $d_{1,3}=20,0-35,9$  cm) b ve c gelişim çağıında ve mesçeradaki tüm ağaçların toprağı örtme durumu, yani toprağın kapalılık düzeyi %70 ile %100 arasındadır. ( $d_{1,3}$ = ağacın 1,30 m yüksekliğindeki göğüs çapı ölçümü değeri, b gelişim çağı ormancılık amenajman planlarında çapa bağlı olarak sıricılık ve direklik, c gelişim çağı ise ince ağacılık çağını ifade etmektedir).

## 2.2. Örneklem alanlarının seçimi

Karaçam, Marmara ve Karadeniz sahillerinden başlayarak Akdeniz Bölgesi'nin kuzeyine kadar uzanır ve 2000 metreye kadar yükselebilir. Özellikle Karadeniz ve Marmara bölgelerinde dağların kuzey yamaçlarında yaygın olarak görülürken, İç Anadolu'da daha az rastlanır. Karaçam, Türkiye'nin çeşitli habitatlarında yetişebilen bir türdür ve ağaçlandırma projelerinde sıkça tercih edilen ikinci türdür (Konukcu, 2001).

Kuzey yarımkürede yayılım gösteren ve Dünya'da 109 farklı türe sahip olan Pinus cinsinin bir üyesi olan sahil çamı (*Pinus pinaster Aiton*), doğal olarak Güneybatı Avrupa, Batı Akdeniz ve Kuzeybatı Afrika'da bulunmaktadır (Kandemir ve Mataracı, 2018). Korsika kökenli sahil çamı üzerine yapılan araştırma, Türkiye'de özellikle Batı ve Orta Karadeniz bölgeleri ile Marmara Bölgesi'nde, deniz seviyesinden 500 metre yüksekliğe kadar olan alanlarda ağaçlandırma için uygun olduğunu belirtmektedir (Şimşek ve ark., 1995). Türkiye'deki sahil çamı ağaçlarının yaklaşık %83'ü Marmara Bölgesi'nde, %15'i Karadeniz Bölgesi'nde ve geri kalan %2'si ise Ege ve Akdeniz bölgelerinde bulunmaktadır (Güner ve ark., 2019). Pinaceae Familyasına dahil Pinus cinsinin 113

türünden biri olan karaçam (Farjon, 2010; Roskov ve ark., 2015), Kuzey Afrika'da Fas ve Cezayir'de sınırlı yayılışı yanında, Güney Avrupa'nın dağlık kesimleri, Kıbrıs, Anadolu, Suriye ve Akdeniz Adaları'nda geniş yayılışı olan önemli bir orman ağacıdır (Gausson ve ark., 1964).

Çalışma alanında, karaçam ve sahil çamı türlerine ait örneklem alanlarından veri toplama işlemi aşağıdaki adımlarla gerçekleştirilmiştir:

1- İçerisine 15 ve üstü sayıda fert girecek büyüklükte (Çepel, 1977; Güner ve ark., 2022) örneklem alanları belirlenmiştir.

2- Fertlerin yayılışına dikkat edilerek 21 adet  $20 \times 20$  m, 12 adet  $20 \times 30$  m ve 12 adet  $20 \times 15$  m genişliğinde örneklem alanları belirlenmiş ve bu alanlardaki tüm fertlerin boyları ( $h_m$ ) ölçülerek ortalama ağaç boyları hesaplanmıştır.

3- Saha çalışmalarında örneklem alanlarından ağaç boyları ölçümü gerçekleştirirken, örneklem içerisinde olan ve ortalama ağaç boylarını etkileyen ucu kırık ağaç boyları hesaplamalardan çıkarılmıştır.

4- Örneklem alanlarında ölçülen  $h_m$  değerlerinin yanında eğim, bakı, alan yükseltisi, merkez konum koordinatları ve yamaç konumu gibi verilerde elde edilmiştir.

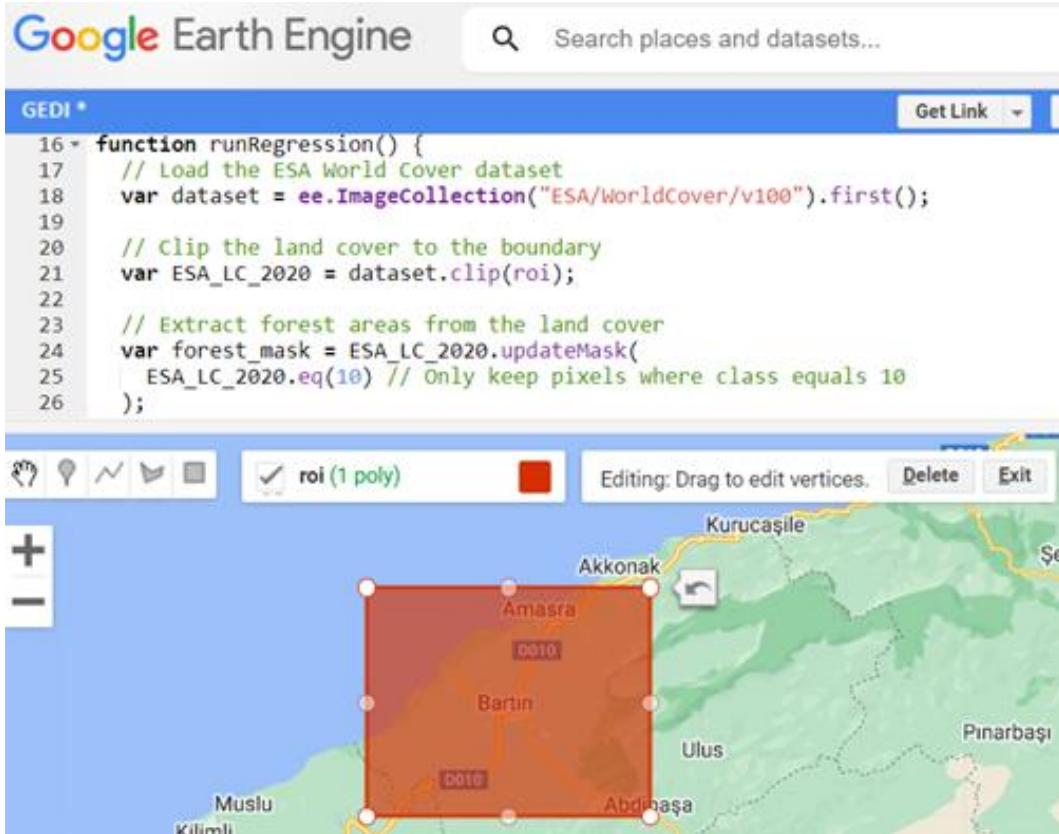
5- Merkez konum koordinatları, el tipi Garmin Oregon GPS cihazı kullanılarak WGS84 koordinat sisteminde kaydedilmiştir. Arazi eğimi ve ağaç boyu Haglöf marka elektronik klizimetre ile ölçülmüş, örneklem alanları belirlenirken ise çelik şerit metre kullanılmıştır.

## 2.3. Uydu görüntüleri temini ve ön işleme adımları

ESA tarafından ücretsiz sağlanan S1 ve S2 uydu görüntüleri (URL-3) adresinden elde edilmiştir. SAR

uydu görüntüsünün ön işleme sürecinde, 13 Ağustos 2023 tarihli S1 GRD Ascending uydu görüntüsü için, yörünge dosyasının eklenmesi, termal gürültünün giderilmesi, kalibrasyonun yapılması, görüntü beneklerinin filtrelenmesi ve arazi düzeltmesi adımları sırasıyla uygulanmıştır. 04.08.2023 tarihli Sentinel-2 Seviye 2A atmosfer altı (BOA) görüntüsü için (atmosferik ve geometrik düzeltmeler uygulanmış kullanıma hazır veri) sadece 10 m ve 20 m mekânsal çözünürlüğe sahip olan bant 2, bant 3, bant 4, bant 5, bant 6, bant 7, bant 8, bant 11 ve bant 12 kullanılmıştır. 20 m olanlar 10 m çözünürlüğe örneklenmiştir. İki uydu görüntüsü için ön işleme çalışmalarında ESA'nın SNAP programı kullanılmıştır.

Avrupa Uzay Ajansı (ESA), 10 m mekânsal çözünürlüğe sahip, 2020 yılı küresel arazi örtüsü haritası olan WorldCover 10 m 2020 ürününü sunmaktadır. Bu ürün S1 ve S2 uydularından alınan 11 arazi örtüsü veri setini içermektedir. Bu arazi örtüsü setlerinden biri olan orman alanları, SAR görüntüsünü kullanarak çalışmada belirtilen alana ait orman örtüsü verisini indirmekte ve istenilen uzamsal çözünürlüğe göre yeniden örnekleme yapabilmektedir (Bao ve ark., 2023). Bu çalışmada GEE bulut platformundaki ESA/WorldCover/v100 veri seti kullanılmıştır. Orman olmayan alanlar ESA World Cover ile filtrelenerek, orman alanları dışındaki dağlık alanlar, deniz, şehir merkezi ve bina bilgileri bu model dışında bırakılmıştır (Şekil 3).



Şekil 3. GEE de ESA World Cover verisi ile orman alanları dışındaki alanların çıkarılması.

GEE kataloğundan "GEDI L2A ürünü Relative Height (Göreceli Yükseklik) (RH)98 verisi kullanılmış, çalışma alanına göre filtrelenen 25 m çözünürlüklü veriler yeniden örneklenerek 10 m'ye dönüştürülmüştür. GEE platformundan SRTM V3.0 SYM ile yükseklik ve eğim değerleri de elde edilmiştir. Uydu görüntüleri geri saçılım değerleri, bant, GEDİ, yükseklik ve eğim verileri birleştirilerek mozaik oluşturulmuştur. RO algoritması uygulanarak bu mozaik verisinin %70'i eğitim verisi %30'u test verisi olarak kullanılmış, ağaç boyları haritası elde edilmiştir.

Ağaç boyları sahadan toplanırken örnekleme alanları merkezinden alınan konum bilgisi, olası konum hataları olabileceği sebebiyle örnekleme alanlarında 5x5 m alanlar oluşturularak modeli kesen 4 köşenin ortalama değerleri QGIS 3.18 programı ile elde edilmiştir.

Sahadan elde edilen ortalama ağaç boyları(m) ile modelden tahmin edilen ağaç boylarının farkı bulunarak, örnekleme alanları model performansını ölçebilmek için

3 farklı metrik olan Ortalama Mutlak Hata (OMH) (Eşitlik 1), Karesel Ortalama Hata (KOH) (Eşitlik 2) ve Belirtme Katsayısı (R<sup>2</sup>) (Eşitlik 3) değerleri hesaplanmıştır. Model ve yersel değerlerin performans analizleri ve görselleştirme çalışmaları için Python (3.10.12) kullanılmıştır.

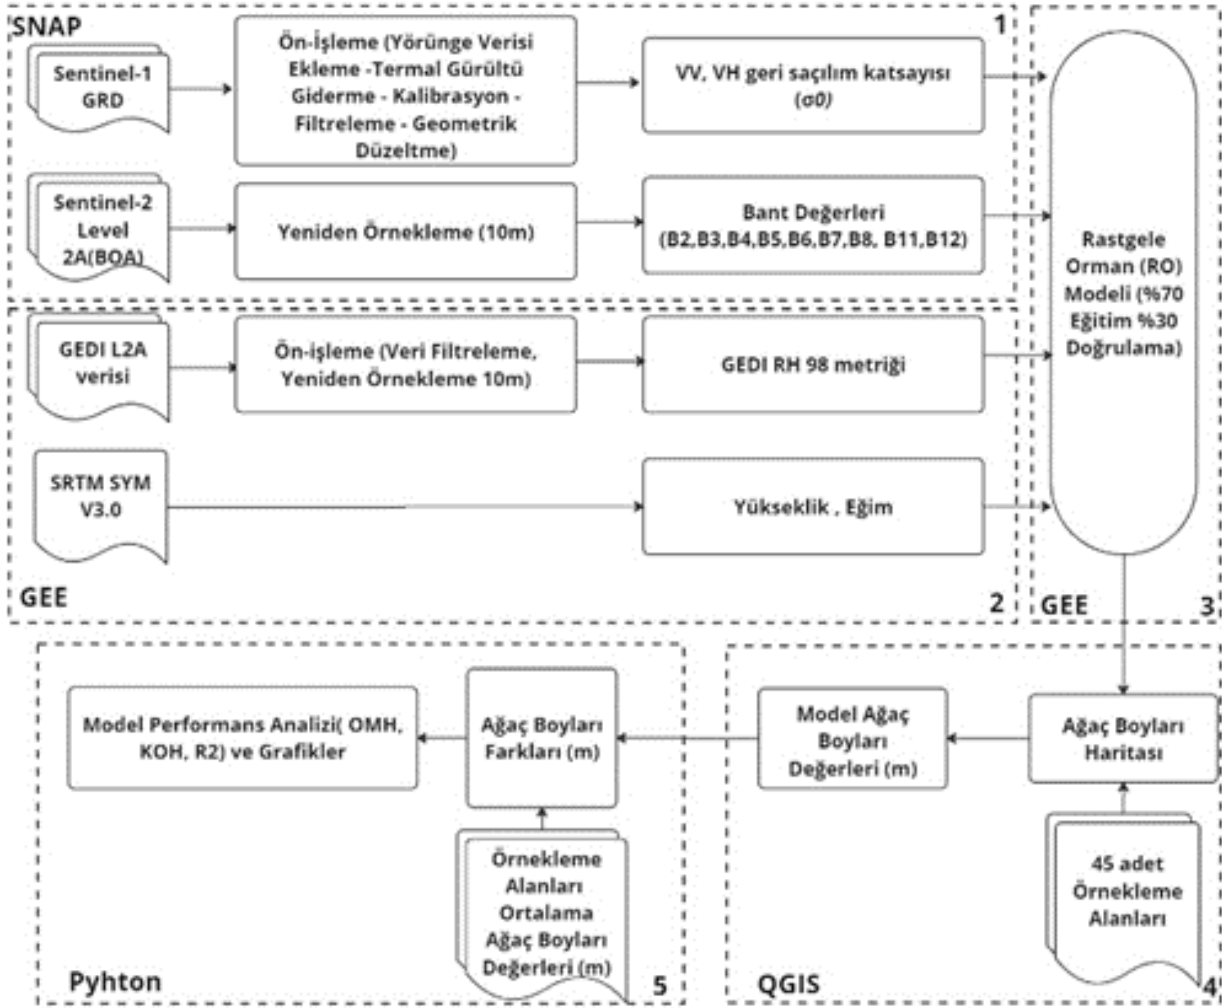
$$OMH = \frac{1}{n} \sum_{i=1}^n |h_{\text{öa}} - h_{\text{model}}| \quad (1)$$

$$KOH = \sqrt{\frac{1}{n} \sum_{i=1}^n (h_{\text{öa}} - h_{\text{model}})^2} \quad (2)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (h_{\text{öa}} - h_{\text{model}})^2}{\sum_{i=1}^n (h_{\text{öa}} - h_{\text{ort}})^2} \quad (3)$$

n, örnekleme alan sayısını ifade ederken,  $h_{0a}$  örnekleme alanlarından elde edilen ağaç boylarını,  $h_{model}$  modelden elde edilen ağaç boylarını ve  $h_{ort}$  örnekleme

alanındaki ortalama boyu ifade etmektedir. Çalışma iş akış diyagramı Şekil 4’de verilmektedir.



Şekil 4. Çalışma iş akış diyagramı.

### 3. Bulgular ve tartışma

Örnekleme alanlarından elde edilen ortalama ağaç boyları(m) ile modelden elde edilen ağaç boyları arasında ilişki incelendiğinde değişkenler arasında pozitif yönde güçlü bir ilişki olduğunu gözlenmiştir (r pearson korelasyon katsayısı: 0,77)

Çalışmamızda S1, S2, GEDI, SYM verileri ile 10 m çözünürlüğe yeniden örneklenen geri saçılım değerleri, bantlar, GEDI ve topografya verileri bileşiminin RO algoritması kullanılarak oluşturulduğu modeldeki tüm noktalar ve saha çalışmalarından elde edilen değerlerin farkları analizi için OMH=1,42 m, KOH=1,54 m ve  $R^2$  ise 0,60 olarak elde edilmiştir. Sonuçların  $\alpha = 0,05$  düzeyinde istatistiki olarak farklı ve p değerinin 0,05’ den küçük olması istatistik olarak anlamlı olduğunu ifade etmektedir. Yüksek  $R^2$  ve Çoklu R değerleri, modelin veri setini iyi açıkladığını gösterirken, düşük standart hata, modelin iyi tahminler yaptığını göstermektedir.

Regresyon modelinin istatistiksel anlamlılığını değerlendiren ANOVA testine ilişkin 64,437735 olan F değeri, regresyon modelinin gruplar arasında anlamlı bir farkının olduğunu göstermektedir ve p değeri (Anlamlılık F) 4,34E-10 (veya yaklaşık olarak sıfıra çok

yakın) olduğundan, bu fark istatistiksel olarak anlamlı kabul edilmektedir. Regresyon istatistikleri ve tek yönlü varyans (ANOVA) testi Tablo 1’de gösterilmiştir.

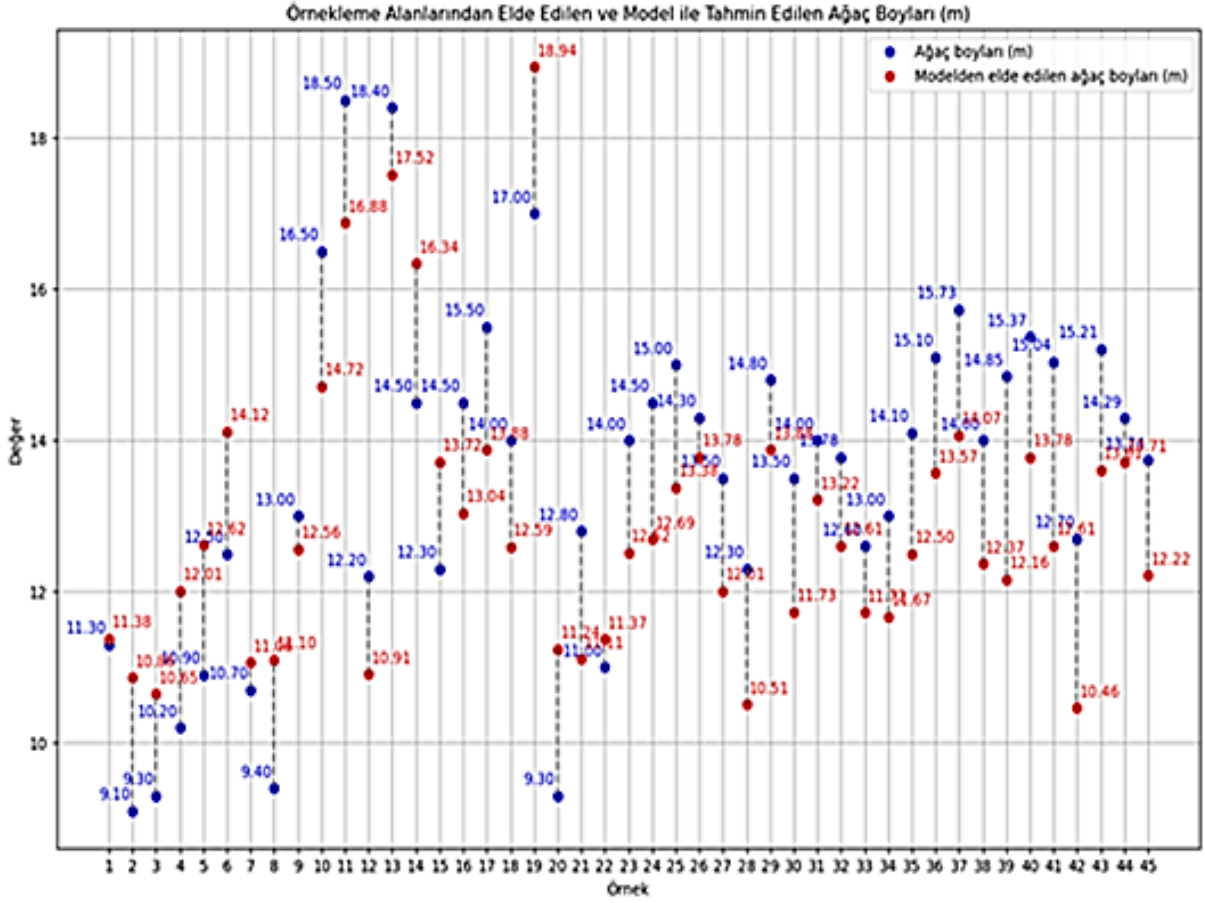
Tablo 1. Regresyon istatistikleri ve ANOVA testi

| Regresyon istatistikleri |    |        |        |         |              |
|--------------------------|----|--------|--------|---------|--------------|
| Çoklu R                  |    |        |        |         | 0,7744       |
| R Kare                   |    |        |        |         | 0,5997       |
| Ayarlı R Kare            |    |        |        |         | 0,5904       |
| Standart Hata            |    |        |        |         | 1,4248       |
| Gözlem                   |    |        |        |         | 45           |
| ANOVA                    |    |        |        |         |              |
|                          | df | SS     | MS     | F       | Anlamlılık F |
| Regresyon                | 1  | 130,82 | 130,82 | 64,4377 | 4,33672E-10  |
| Fark                     | 43 | 87,303 | 2,03   |         |              |
| Toplam                   | 44 | 218,13 |        |         |              |

\* $p < 0,05$

Çalışmamızda tüm örnekleme alanları için saha verileri ile modelden elde edilen ağaç boyları doğrulukları araştırılmıştır. Boy farkları incelendiğinde 10 adet alanda metre altı doğruluk elde edilirken, 32 alanda 1-2 m arasında doğruluk elde edilmiştir. 3 alanda ise 2 m’den fazla farklar görülmüştür (Şekil 5).



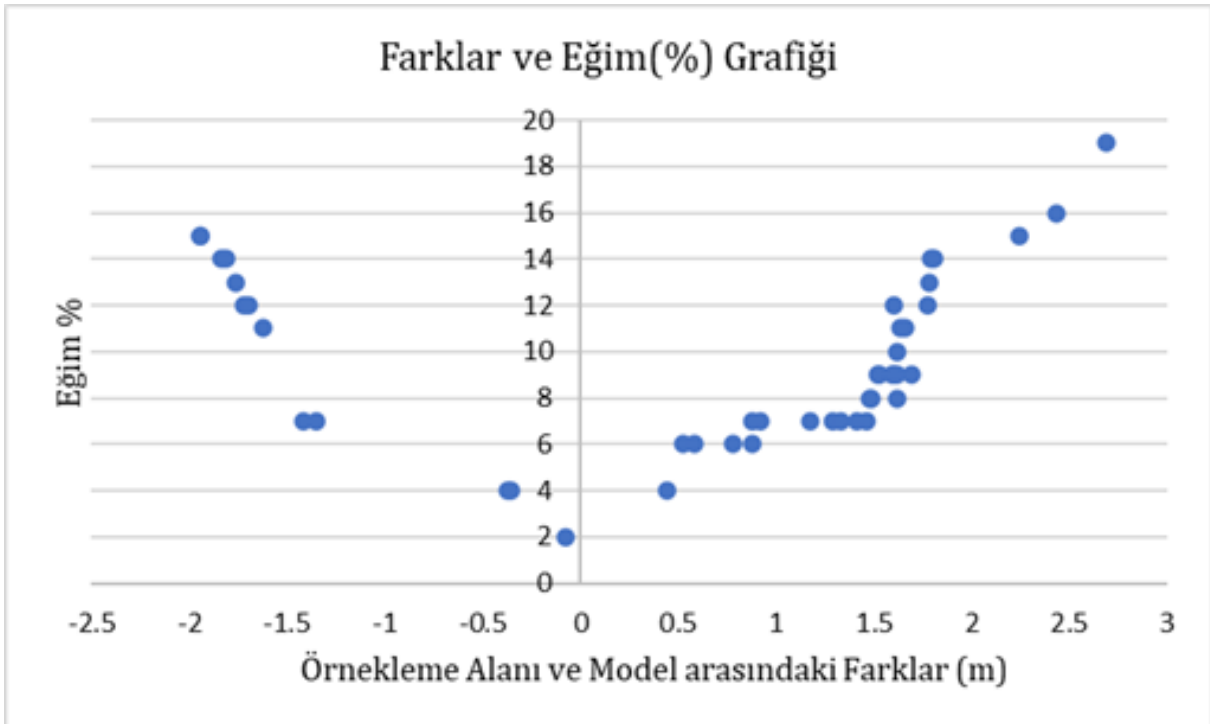


**Şekil 5.** Örnekleme alanlarından elde edilen ve model ile tahmin edilen ağaç boyları.

Örnekleme alanlarının eğim değerleri %2 ile %19 arasında değişkenlik göstermektedir. 11 örnekleme alanında %7'den küçük, 15 alanda %7 ile %12 arasında, 12 alanda %12 ile %15 arasında, 7 alanda ise %15 ile %19 arasındadır. Örnekleme alanlarında eğim arttıkça

hatalarda artış gözlenmiştir (Şekil 6).

S1, S2, SYM ve GEDI verileri ile RO algoritması kullanılarak GEE' de üretilen model de en düşük ağaç boyu 4,28 m iken en yüksek 33,18 m olarak elde edilmiştir (Şekil 7).



**Şekil 6.** Örnekleme alanlarından elde edilen ve model ile tahmin edilen ağaç boyları farkları ve eğim (%) grafiği.





bunun yanında Radar, optik, GEDI, SYM verilerinin oluşturduğu modelin ağaç boyu tahmininde etkili olduğu sonucuna varılmıştır.

GEE platformunun orman alanlarında gerçekleştirilecek çalışmalarda gerek hızlı çözüm üretmesi gerekse güçlü bir bilgisayar donanımına ihtiyaç duymadan geniş alanlarda kolaylıkla kullanılabilmesi nedeniyle elde edilecek sonuçların, odun kaynaklarının tahmin edilmesi, odun stoklarının yönetimi, amenajman planlaması, yangın riskinin belirlenmesi ve habitat kalitesinin değerlendirilmesi gibi uygulamalar için de önemli olduğu düşünülmektedir.

### Bilgilendirme/Teşekkür

Bu araştırma, TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı tarafından "Orman ekosistemindeki ağaçların bitki örtüsü(kanopi) yüksekliklerinin, Optik, Radar, LIDAR uydu verileri ve yardımcı kaynaklar kullanılarak Google Earth Engine Platformunda Modellenmesi (1919B012215642)" isimli proje kapsamında desteklenmiştir. Desteklerinden dolayı TÜBİTAK BİDEB 'e, uydu görüntülerinin ücretsiz olarak temin edilmesinde sağladığı imkanlardan dolayı Avrupa Uzay Ajansına (ESA) ve GEDI altimetri verisi için National Aeronautics and Space Administration (NASA)'ya, makalenin değerlendirme süreçlerinde kıymetli görüş ve önerileri için hakemlere teşekkür ederiz.

### Araştırmacıların katkı oranı

**Eren Gürsoy Özdemir:** Literatür taraması, Arazi çalışması, Modelleme, Makale yazımı; **Tarık Utku Zengin:** Literatür taraması, Arazi çalışması, Modelleme; **Halit Abdullah Güleç:** Literatür taraması, Arazi çalışması, Modelleme.

### Çatışma Beyanı

Herhangi bir çıkar çatışması bulunmamaktadır.

### Kaynakça

Aghlmand, M., Kalkan, K., Onur, M. İ., Öztürk, G., & Ulutak, E. (2021). Google Earth Engine ile arazi kullanımı haritalarının üretimi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 10(1), 38-47. <https://doi.org/10.28948/ngumuh.795977>

Apaydın, C., & Abdikan, S. (2021). Fındık bahçelerinin Sentinel-2 verileri kullanılarak piksel tabanlı sınıflandırma yöntemleriyle belirlenmesi. *Geomatik*, 6(2), 107-114. <https://doi.org/10.29128/geomatik.705988>

Bao, J., Zhu, N., Chen, R., Cui, B., Li, W., & Yang, B. (2023). Estimation of Forest Height Using Google Earth Engine Machine Learning Combined with Single-Baseline TerraSAR-X/TanDEM-X and LiDAR. *Forests*, 14(10), 1953. <https://doi.org/10.3390/f14101953>

Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>

Coops, N. C., Kearney, S. P., Bolton, D. K., & Radeloff, V. C. (2018). Remotely-sensed productivity clusters capture global biodiversity patterns. *Scientific Reports*, 8(1), 16261. <https://doi.org/10.1038/s41598-018-34162-8>

Çepel, N. (1977). Türkiye'nin önemli yetiştirme bölgelerindeki saf sarıçam ormanlarının gelişimi ile bazı edafik ve fizyografik etkenler arasındaki ilişkiler. *Journal of the Faculty of Forestry Istanbul University*, 26(2), 25-64.

Çömert, R., Matcı, D. K., & Avdan, U. (2019). Object based burned area mapping with random forest algorithm. *International Journal of Engineering and Geosciences*, 4(2), 78-87. <https://doi.org/10.26833/ijeg.455595>

Dubayah, R., Blair, J. B., Goetz, S., Fatoyinbo, L., Hansen, M., Healey, S., ... & Silva, C. (2020). The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. *Science of Remote Sensing*, 1, 100002. <https://doi.org/10.1016/j.srs.2020.100002>

Duncanson, L., Kellner, J. R., Armston, J., Dubayah, R., Minor, D. M., Hancock, S., ... & Zraggen, C. (2022). Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. *Remote Sensing of Environment*, 270, 112845. <https://doi.org/10.1016/j.rse.2021.112845>

Gausson, H., Heywood, V. H., & Chater, A. O., (1964). *The Genus Pinus L. Flora Europaea*, Cambridge University Press, Cambridge, 1, 32-35.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>

Guerra-Hernández, J., & Pascual, A. (2021). Using GEDI lidar data and airborne laser scanning to assess height growth dynamics in fast-growing species: a showcase in Spain. *Forest Ecosystems*, 8, 1-17. <https://doi.org/10.1186/s40663-021-00291-2>

Güner, Ş. T., Özel, C., Türkkan, M., & Akgül, S. (2019). Türkiye'deki sahilçamı ağaçlandırmalarında ağaç bileşenlerine ait karbon yoğunluklarının değişimi. *Ormanlık Araştırma Dergisi*, 6(2), 167-176. <https://doi.org/10.17568/ogmoad.546116>

Güner, Ş. T., Diamantopoulou, M. J., Poudel, K. P., Çomez, A., & Özçelik, R. (2022). Employing artificial neural network for effective biomass prediction: An alternative approach. *Computers and Electronics in Agriculture*, 192, 106596. <https://doi.org/10.1016/j.compag.2021.106596>

Farjon, A. (2010). *A Handbook of the World's Conifers: Revised and Updated Edition*. Brill. <https://doi.org/10.1163/9789047430629>

Flores-Anderson, A. I., Herndon, K. E., Thapa, R. B., & Cherrington, E. (2019). *The SAR handbook: Comprehensive methodologies for forest monitoring and biomass estimation* (No. MSFC-E-DAA-TN67454).

Kandemir, A., & Mataracı, T. (2018). Pinus L. Resimli Türkiye Florası, 2, 324-354.

Kindermann, G., McCallum, I., Fritz, S., & Obersteiner, M. (2008). A global forest growing stock, biomass and

- carbon map based on FAO statistics. *Silva Fennica*, 42(3), 387-396.  
<https://doi.org/10.14214/sf.244>
- Konukçu, M., (2001). *Ormanlar ve Ormancılığımız*. DPT Yayınları, 2630, Ankara.
- Morin, D., Planells, M., Baghdadi, N., Bouvet, A., Fayad, I., Le Toan, T., ... & Villard, L. (2022). Improving heterogeneous forest height maps by integrating GEDI-based forest height information in a multi-sensor mapping process. *Remote Sensing*, 14(9), 2079. <https://doi.org/10.3390/rs14092079>
- Narin, Ö. G., & Yilmaz, M. (2024). GEDI Uydu Tabanlı Lazer Altimetre Verisinin Arazi Yükseklik Tahmininin Araştırılması. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 24(1), 85-89.  
<https://doi.org/10.35414/akufemubid.1349854>
- Özdemir, S., Akbulut, Z., Karşlı, F., & Acar, H. (2021). Automatic extraction of trees by using multiple return properties of the lidar point cloud. *International Journal of Engineering and Geosciences*, 6(1), 20-26.  
<https://doi.org/10.26833/ijeg.668352>
- Özdemir, E. G., Demiralay, A., & Şahin, B. (2024). Bartın'daki Sahil Çamı (*Pinus pinaster* Ait.) Ağaçlandırma Alanlarında Sentinel-1 ve Sentinel-2 Uydu Görüntüleri Kullanılarak Toprak Üstü Biyokütle Kestirilmesi. *Türk Uzaktan Algılama ve CBS Dergisi*, 5(1), 15-27.  
<https://doi.org/10.48123/rsgis.1327406>
- Padalia, H., Prakash, A., & Watham, T. (2023). Modelling aboveground biomass of a multistage managed forest through synergistic use of Landsat-OLI, ALOS-2 L-band SAR and GEDI metrics. *Ecological Informatics*, 77, 102234.  
<https://doi.org/10.1016/j.ecoinf.2023.102234>
- Potapov, P., Li, X., Hernandez-Serna, A., Tyukavina, A., Hansen, M. C., Kommareddy, A., ... & Hofton, M. (2021). Mapping global forest canopy height through integration of GEDI and Landsat data. *Remote Sensing of Environment*, 253, 112165.  
<https://doi.org/10.1016/j.rse.2020.112165>
- Rishmawi, K., Huang, C., & Zhan, X. (2021). Monitoring key forest structure attributes across the conterminous United States by integrating GEDI LiDAR measurements and VIIRS data. *Remote Sensing*, 13(3), 442.  
<https://doi.org/10.3390/rs13030442>
- Roskov Y., Abucay L., Orrell T., Nicolson D., Kunze T., Culham A., Bailly N., Kirk P., Bourgoin T., DeWalt R.E., Decock W., De Wever A. (2015). *Species 2000 & ITIS Catalogue of Life, 2015 Annual Checklist*. DVD. Species 2000: Naturalis, Leiden, the Netherlands.
- Saarela, S., Holm, S., Healey, S. P., Andersen, H. E., Petersson, H., Prentius, W., ... & Ståhl, G. (2018). Generalized hierarchical model-based estimation for aboveground biomass assessment using GEDI and landsat data. *Remote Sensing*, 10(11), 1832.  
<https://doi.org/10.3390/rs10111832>
- Santoro, M., Cartus, O., Fransson, J. E., & Wegmüller, U. (2019). Complementarity of X-, C-, and L-band SAR backscatter observations to retrieve forest stem volume in boreal forest. *Remote Sensing*, 11(13), 1563. <https://doi.org/10.3390/rs11131563>
- Sefercik, U. G., Ateşoğlu, A., & Atalay, C. (2021). Orman meşcere yükseklik haritası üretiminde hava kaynaklı lazer tarama performans analizi. *Geomatik*, 6(3), 179-188. <https://doi.org/10.29128/geomatik.721916>
- Spracklen, B., & Spracklen, D. V. (2021). Determination of structural characteristics of old-growth forest in Ukraine using spaceborne LiDAR. *Remote Sensing*, 13(7), 1233.  
<https://doi.org/10.3390/rs13071233>
- Şimşek, Y., Erkuloğlu, Ö.S., Tosun, S., (1995). Türkiye'de Karaçam (*Pinus nigra* Arn. Ssp. *Pallasiana* (Lamb.) Holmboe) Orijin Denemelerinin İlk Sonuçları. İç Anadolu Ormancılık Araştırma Enstitüsü, Teknik Bülten Serisi, 247, Ankara.
- Tamiminia, H., Salehi, B., Mahdianpari, M., & Goulden, T. (2024). State-wide forest canopy height and aboveground biomass map for New York with 10 m resolution, integrating GEDI, Sentinel-1, and Sentinel-2 data. *Ecological Informatics*, 79, 102404.  
<https://doi.org/10.1016/j.ecoinf.2023.102404>
- Üstüner, M., & Sanli, F. B. (2021). Crop classification from multi-temporal PolSAR data with regularized greedy forest. *Advanced Remote Sensing*, 1(1), 10-15.
- Xi, Z., Xu, H., Xing, Y., Gong, W., Chen, G., & Yang, S. (2022). Forest canopy height mapping by synergizing icesat-2, sentinel-1, sentinel-2 and topographic information based on machine learning methods. *Remote Sensing*, 14(2), 364.  
<https://doi.org/10.3390/rs14020364>
- Vatandaşlar, C., Narin, O. G., & Abdikan, S. (2023). Retrieval of forest height information using spaceborne LiDAR data: a comparison of GEDI and ICESat-2 missions for Crimean pine (*Pinus nigra*) stands. *Trees*, 37(3), 717-731.  
<https://doi.org/10.1007/s00468-022-02378-x>
- Wang, Y., Ma, J., Xiao, X., Wang, X., Dai, S., & Zhao, B. (2019). Long-term dynamic of Poyang Lake surface water: A mapping work based on the Google Earth Engine cloud platform. *Remote Sensing*, 11(3), 313.  
<https://doi.org/10.3390/rs11030313>
- Zadbagher, E., Marangoz, A. M., & Becek, K. (2023). Characterizing and estimating forest structure using active remote sensing: An overview. *Advanced Remote Sensing*, 3(1), 38-46.
- Zhou, X., Hao, Y., Di, L., Wang, X., Chen, C., Chen, Y., ... & Jancso, T. (2023). Improving GEDI Forest Canopy Height Products by Considering the Stand Age Factor Derived from Time-Series Remote Sensing Images: A Case Study in Fujian, China. *Remote Sensing*, 15(2), 467. <https://doi.org/10.3390/rs15020467>
- URL-1: <https://gedi.umd.edu/mission/mission-overview/>
- URL-2: MGM, (2024). Meteorolojik Veri. <https://www.mgm.gov.tr/>
- URL-3: <https://browser.dataspace.copernicus.eu/>

