

Bartın'daki Sahil Çamı (*Pinus pinaster* Ait.) Ağaçlandırma Alanlarında Sentinel-1 ve Sentinel-2 Uydu Görüntüleri Kullanılarak Toprak Üstü Biyokütlenin Kestirilmesi

Estimation of Aboveground Biomass of Maritime Pine (*Pinus pinaster* Ait.) Plantations Using Sentinel-1 and Sentinel-2 Satellite Images in Bartın

Eren Gürsoy Özdemir^{1*}, Aziz Demiralay¹, Batuhan Şahin¹

¹Bartın Üniversitesi, Ulus Meslek Yüksekokulu, Tapu ve Kadastro Programı, 74600, Ulus, Bartın/Türkiye.

ARAŞTIRMA MAKALESİ

***Sorumlu yazar:**

Eren Gürsoy Özdemir
eozdemir@bartin.edu.tr

doi: 10.48123/rsgis.1327406

Yayın süreci

Geliş tarihi: 14.07.2023
Kabul tarihi: 01.11.2023
Basım tarihi: 28.03.2024

Özet

Ormanlar, yaklaşık olarak yeryüzünün üçte birini kaplayan, gezegendeki biyoçeşitliliğin yarısından fazlasına ev sahipliği yapan, atmosfere salınan karbonun önemli bir miktarını tutan, iklim değişimi konusunda da güçlü bir etkiye sahip dünya ekosistemindeki çok önemli bir bileşendir. Ormanlık alanların biyokütlesinin doğru bir şekilde kestirilmesi, karbon salınımlarının azaltılması ve karbon yutak alanlarının artırılması kapsamında büyük önem taşımaktadır. Uydu teknolojilerinin ve uzaktan algılama sistemlerinin gelişmesiyle birlikte aktif ve pasif sistemler ile Toprak Üstü Biyokütlenin (TÜB) kestiriminin yapılması mümkün hale gelmiştir. Bu çalışmada, Bartın'daki sahil çamı (*Pinus pinaster* Ait.) ağaçlandırmalarında, Avrupa Uzay Ajansı (ESA) tarafından araştırmacılara ücretsiz sunulan Sentinel-1 radar, Sentinel-2 optik uydu verileri ile Çoklu Doğrusal Regresyon (ÇDR) ve Rastgele Orman (RO) yöntemlerinden yararlanılarak bant ve bitki örtüsü indeksi değerlerinin TÜB kestirimine etkileri ve yersel örnekleme alan verilerinden elde edilen TÜB değerleri ile ilişkileri araştırılmaktadır. 16 modelin geliştirildiği çalışmada, Sentinel-1 VH geri saçılım değeri, Sentinel-2'den türetilmiş normalize edilmiş fark bitki örtüsü indeksi değeri (NDVI) füzyonu ve RO yöntemi kullanıldığı model ile TÜB kestiriminde en iyi sonuç elde edilmiştir ($R^2=0.61$, $RMSE= 49.412$ t/ha).

Anahtar kelimeler: Biyokütle, Toprak üstü biyokütle, Sentinel-1, Sentinel-2, Sahil çamı

Abstract

Forests are a crucial component in the world ecosystem, covering approximately one-third of the earth's surface, hosting more than half of the biodiversity on the planet, holding a significant amount of carbon released into the atmosphere, and strongly impacting climate change. Accurate forest biomass estimation is essential in reducing carbon emissions and increasing carbon sink areas. With the development of satellite technologies and remote sensing systems, estimating the Above Ground Biomass (AGB) with active and passive systems has become possible. In this study, the effects of band and vegetation index values on Above Ground Biomass (AGB) estimation were investigated in Maritime pine (*Pinus pinaster* Ait.) reforestation areas in Bartın using data from the Sentinel-1 radar and Sentinel-2 optical satellite provided free of charge to researchers by the European Space Agency (ESA), along with the Multiple Linear Regression (MLR) and Random Forest (RF) methods. The relationships between AGB values obtained from ground sample plot data and the satellite data were examined, and 16 models were developed. The best results for AGB estimation were achieved using the model that incorporated the Sentinel-1 VH backscatter value, the Normalized Difference Vegetation Index (NDVI) derived from Sentinel-2, and the RF method ($R^2=0.61$, $RMSE= 49.412$ t/ha).

Keywords: Biomass, Above ground biomass, Sentinel-1, Sentinel-2, Maritime pine

1. Giriş

Dünya'nın kara yüzeyinin yaklaşık üçte birini kaplayan ormanlar, biyoçeşitliliği destekleyen ve karbon-su-enerji döngüleri yoluyla iklim sistemini etkileyen modern toplumların temel sosyo-kültürel bir unsurudur (Bonan, 2008). Dünya genelinde ormansızlaşma ve endüstrileşme hızla artmaktadır. Atmosfere yayılan karbondioksit miktarının endüstri öncesi döneme göre artış gösteren ivmede olması, Dünyamız için büyük bir tehlikenin habercisidir (Cox vd., 2000). Ormanların karbon tutucu ve iklim değişikliğinin yarattığı tahribatı engelleme adına önemli bir bileşen olma özelliği, canlı yaşamı için büyük önem arz etmektedir (Cheng vd., 2009). Ekosistemdeki organik karbonun %76-98'ini depolama özelliğine sahip ormanlar, atmosferdeki karbondioksit artışının neden olduğu küresel ısınmanın azaltılmasında yeri doldurulamaz bir rol oynamaktadır (Wang vd., 2013).

Ormanlık alanların biyokütlesinin doğru bir şekilde kestirilmesi, karbon salınımlarının azaltılması ve karbon yutak alanlarının artırılması kapsamında büyük önem taşımaktadır (Dixon, 1994). Toprak üstü biyokütlenin (TÜB) belirlenmesinde sıklıkla kullanılan metot, yersel çalışmalardır. TÜB belirlemenin en doğru sonuç veren yöntemi olan yersel metot, örnek alanlarda kesilen ağaçların ibrelerinin, yapraklarının, dallarının, gövdelerinin, köklerinin ayrılması, çap ve yüksekliklerinin, ağırlıklarının ölçülmesi prensibine dayanır. Saha çalışmaları neticesinde elde edilen biyokütle denklemleri kullanılarak, örnekleme alanlarındaki ağaçların göğüs yüksekliğindeki çap ($d_{1.3m}$) ve boy ölçmeleri ile TÜB miktarı belirlenebilir (Vickers vd., 2012).

Geleneksel yöntemlerin kullanıldığı arazi çalışmaları ile biyokütle ve karbon kestiriminin yapılması maliyetli, zaman alıcı ve laboratuvarında analizlerle birlikte yoğun emek gerektirmesi, alternatif yöntem olan uzaktan algılama sistemlerine olan ilgiyi gün geçtikçe artırmıştır (Vafaei vd., 2018). Optik ve Sentetik Açıklı Radar (SAR) uzaktan algılama sistemleri ile orman yapısının belirlenmesi, sınıflandırılması, TÜB'ün kestirilmesi mümkün olmaktadır (Lu vd., 2016).

Önceki çalışmalarda, optik uydu verilerinden üretilen Normalize Edilmiş Fark Bitki Örtüsü ve Gelişmiş Bitki İndeksleriyle (NDVI, EVI) çeşitli regresyon yöntemleri kullanılarak TÜB kestirimi yapıldığı görülmektedir (Wang vd., 2019). Ancak optik uydu verilerinin genellikle yaprak biyokütle bileşenlerinin tahmininde iyi olduğu, hava koşullarından etkilenmesi ve yoğun orman örtüsünde ağaç gövdesine erişemediğinden dolayı TÜB kestirimi için tek başına uygun olmadığı belirtilmektedir (Dobson vd., 1992; Foody vd., 2003; Ghasemi vd., 2013). SAR ise her türlü hava koşullarında, gece ve gündüz görüntü elde edebilir ve biyokütle kestiriminde dalga boyu özellikleri sayesinde ağacın tepe tacı ile gövdesine de nüfuz edebilir (Santoro vd., 2019). Radar görüntüleri farklı dalga boylarına göre biyokütle tahmininde farklı duyarlılıklar gösterir. Dalga boyu arttıkça radar geri saçılımı ile biyokütle arasındaki korelasyon artar (Li vd., 2020; Vatandaşlar & Abdikan, 2022). SAR uydu görüntülerinin kullanıldığı TÜB kestirimi çalışmalarında topografik koşulların da önemli bir etken olduğu yadsınmaz. Bu durumun olumsuzluklarını gidermek adına, SAR görüntü işleme ve değerlendirme aşamaları için farklı teknik ve yardımcı veri kullanımı söz konusu olmaktadır (Flores-Anderson vd., 2019; Guerra-Hernández vd., 2022).

Uydu görüntülerinin füzyonunun kullanıldığı çalışmalarda, yoğun bitki örtüsüne sahip alanlarda bitki örtüsünün biyokütlesini doğru bir şekilde tahmin etmede uydu sensörlerinin sınırlamalarıyla ilgili uzaktan algılama ve ekolojik çalışmalarda kullanılan bir kavram olan saturation (doygunluk) probleminin büyük ölçüde çözüldüğü ve biyokütle kestiriminde doğruluğu artırdığı görülmektedir (Bao vd., 2019; Nuthammachot vd., 2022). Bu doygunluklar orman bileşenleri, çalışma alanları ve sensör özellikleriyle de ilişkilidir (Vaglio Laurin vd., 2017).

Yapılan çalışmalarda TÜB kestiriminde kullanılan modellerin önemine de vurgu yapılmaktadır. Çoklu Doğrusal Regresyon (ÇDR) yöntemi, TÜB çalışmaları için en sık kullanılan algoritmalarından biridir (Li vd., 2019). Destek Vektör Makinesi (DVM), karar ağaçları, K-en yakın komşu ve yapay sinir ağları (YSA) gibi makine öğrenme yöntemleri de TÜB kestiriminde başvurulan algoritmalarından olmaktadır (Nelson vd., 2009; Monnet vd., 2011). Son zamanlarda, Aşırı Gradyan Artırma (AGA) ve Rastgele Orman (RO) gibi makine öğrenme yöntemlerinin kullanıldığı TÜB kestirimi çalışmalarında da önemli sonuçlar elde edildiği görülmektedir (Pham vd., 2020; Tavasoli & Arefi, 2021).

Karbon salınımı ve iklim değişikliğinin canlı yaşamına etkisinin konuşulduğu şu günlerde, orman alanlarının çoğaltılması, korunması, ormansızlaşmaya karşı önlemler alınması önemli bir konudur. Dünya'da, SAR ve optik uydu veri füzyonu ile farklı teknik ve modeller kullanılarak TÜB kestirimi çalışmaları gerçekleştirilmektedir (Schmidt vd., 2016; Santoro vd., 2019; Wang vd., 2019; George-Chacón vd., 2022; Georgopoulos vd., 2022; David vd., 2022). Ülkemizde ise SAR ve optik uydu görüntülerinin birlikte kullanıldığı TÜB kestirimi çalışmaları bakımından sınırlıdır (Keleş vd., 2021; Güverçin & Günlü, 2023). Bu çalışmanın, Küresel iklim değişikliği özelinde orman varlığının ekosisteme olan etkilerinin, karbon tutma miktarlarının uzaktan algılama teknikleriyle tespit edilebilmesi çalışmaları için SAR verisi kullanımının ve biyokütle hesaplarına yönelik bilgi birikim kapasitesinin artırılması bakımından literatüre katkı sağlayacağı düşünülmektedir.

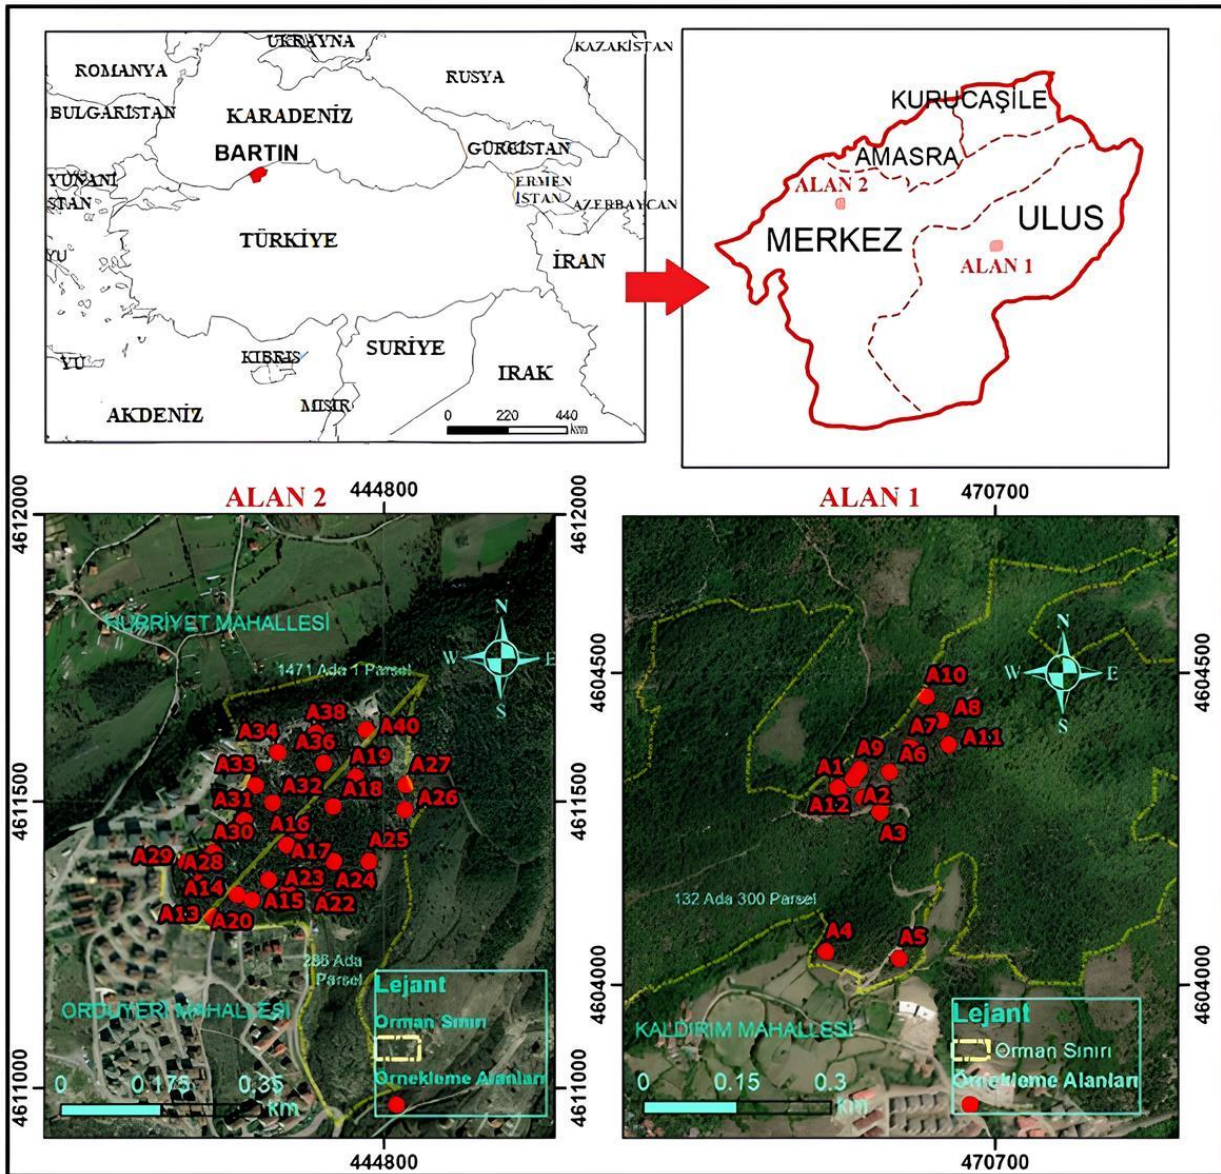
2. Materyal ve Yöntem

2.1 Çalışma alanı

Çalışma alanı, Batı Karadeniz Bölgesinde yer alan Bartın ili, Ulus ilçesi, Kaldırım Mahallesi 130 ada 300 parseldeki 44 hektarlık alanda yaklaşık 35 yıl önce tesis edilen sahil çamı (*Pinus pinaster Ait*) ağaçlandırmalarının olduğu (36T 0444820 D – 4611800 K) ve Merkez ilçesi, Orduyeri mahallesinde 36 yıl önce tesis edilen, 286 ada 1 parselde 11 hektar (ha), Hürriyet Mahallesi 1471 ada 1 parselde 7 ha olmak üzere toplamda 18 ha yüzölçümüne sahip sahil çamı ağaçlandırmalarından oluşmaktadır (36T 0460396 D – 4604750 K) (Şekil 1).

Araştırma alanının topografik durumu incelendiğinde Alan 1'in yükseltisi 200-400 m, genel bakışı güney, batı ve doğudur. Araştırma alanı 2'in yükseltisi 90-180 m, genel bakışı güney, batı ve doğudur. Bartın meteoroloji istasyonunun (30 m) 50 yıllık (1961-2021) verilerine göre yıllık yağış 1049 mm, yıllık ortalama sıcaklık 12,8 °C, yıllık ortalama yüksek sıcaklık 18,7 °C'dir (Meteoroloji Genel Müdürlüğü, 2023).

Çalışma, 2022 yılı temmuz ayı Ulus sınırları içerisinde sahil çamı ağaçlandırma sahasının olduğu Alan 1'de 12 adet ve Ekim ayında ise Merkez ilçe sınırlarında sahil çamı ağaçlandırma sahasının olduğu Alan 2'de 28 adet olmak üzere toplamda 40 adet örnekleme alanında gerçekleştirilmiştir. Örnekleme alanları b ($d_{1,3}=8,0-19,9$ cm) ve c ($d_{1,3}=20,0-35,9$ cm) gelişim çağındaki olup, normal kapalılığa (0,7-1,0) sahiptir.



Şekil 1. Çalışma alanlarının konumu



Şekil 2. Örnek alanları 1 saha fotoğrafları



Şekil 3. Örnek alanları 2 saha fotoğrafları

2.2 Örnek alanı seçimi ve meşcere parametrelerinin elde edilmesi

Kuzey yarım kürede yayılış gösteren ve Dünya’da 109 farklı türe sahip *Pinus* cinsinin bir türü olan Sahil çamı (*Pinus pinaster* Ait.) Güneybatı Avrupa’da, Batı Akdeniz’de ve Kuzeybatı Afrika’da doğal olarak bulunmaktadır (Kandemir & Mataracı, 2018). Ülkemizde doğal bir tür olmayan Sahil çamındaki yapılan çalışmalarda, Korsika orijinine ülkemizin özellikle Batı ve Orta Karadeniz kesimleri ile Marmara Bölgelerindeki ağaçlandırmalarda denizden 500 m yükseltiye kadar olan alanlarda kullanılabileceği bildirilmektedir (Ürgenç, 1972; Şimşek vd., 1985). Sahil çamının Türkiye’de yaklaşık %83’ü Marmara Bölgesi’nde, %15’i Karadeniz Bölgesi’nde, %2’si Ege ve Akdeniz Bölgelerinde yer almaktadır (Güner vd., 2019). Çalışma alanında, sahil çamı türü özelinde örnek alanlarından veriler toplanırken aşağıdaki adımlar uygulanmıştır:

1. Örnek alanı, içerisine en az 15 adet fert girecek büyüklükte (Çepel vd., 1977; Güner vd., 2022) belirlenmiştir.
2. TÜB kestiriminde gerçekleştirilen çalışmalarda farklı ebatlarda ve farklı geometrik şekillerle (kare, dikdörtgen, daire) 10x10 m (Yadav vd., 2021), 50x50 m (Hamdan vd., 2011), 10x50 m (Eckert, 2012), 30 m çapında (Naik vd., 2021) örnek alanları kullanılmıştır. Çalışmamızda örnek alanı, fertlerin yayılışı da göz önünde bulundurularak 28 adet 20x20 m, 11 adet 20x30 m ve 1 adet 30x30 m genişliğinde olmak üzere, bu alanlardaki tüm fertlerin, çapları ($d_{1.3m}$) ve boyları (h_m) ölçülmüştür. Uydu görüntülerinin mekânsal çözünürlüklerinin de 10x10m olarak yeniden örneklendirilmesi ile yersel alanlar ile olan ilişkileri irdelenmiştir.

3. Biyokütlenin hesaplanmasında birim alan yöntemi kullanılmıştır (Günel, 1981). Örnek alandaki tüm ağaçların TÜB değerleri, Türkiye’de tür ile ilgili yersel metotlarla İstanbul Durusu Kumul alanlarında Tolunay vd. (2017), gerçekleştirdiği çalışmada üretilen biyokütle denkleminde, örnekleme alanlarından ölçülen ($d_{1.3m}$) ve h_m değerleri kullanılarak elde edilmiş olup hektara çevirme katsayısı kullanılarak da hektar alandaki ağaç kütlesi stoku (t/ha) hesaplanmıştır.
4. Yersel çalışmalar kapsamında örnekleme alanlarından ölçülecek ($d_{1.3m}$) ve h_m değerlerinin yanında merkez konum, arazi yükseltisi, eğimi, bakı ve yamaç konumu gibi veriler de elde edilmiştir.
5. Örnekleme alanlarında elde edilecek merkez koordinatları, Garmin Oregon marka metre altı GPS ile WGS84-UTM Zone 36T koordinat sisteminde kaydedilmiştir. Ağaç boyu ve arazi eğimi Haglöf marka elektronik klizimetre ile ölçümü gerçekleştirilecek, örnekleme alanları belirlerken çelik şerit metre kullanılmış, arazi durumundan kaynaklı metre çekilemeyen alanlarda Leica Disto D8 marka lazer metre cihazından yararlanılmıştır.

$$K_{TÜ} = 10,4909 + (0,0222 \times d_{1,3}^2 h) \quad (R^2=0.958; SH=37.276) \quad (1)$$

Denklemlerde $K_{TÜ}$: toprak üstü ağaç kütlesini (kg/ağaç), $d_{1,3}$: göğüs yüksekliğindeki çapı (cm), h : ağaç boyunu (m), R^2 : belirtme katsayısını, SH: tahmini standart hatayı ifade etmektedir.



Şekil 4. Örnekleme alanlarındaki veri toplama ekipmanları

2.3 Uydu görüntülerinin elde edilmesi, ön işleme adımları

Çalışma kapsamında, alana ait örnekleme alanlarını kapsayan 23.09.2022 tarihli Sentinel-1 GRD IW SAR ve 18.09.2022 tarihli Sentinel-2 (Seviye 2A Atmosfer Altı (BOA)) optik uydu görüntüleri, Avrupa Uzay Ajansı (ESA) tarafından ücretsiz sağlanan (<https://browser.dataspace.copernicus.eu/>) adresinden elde edilmiştir.

Temin edilen optik görüntü 2A işleme seviyesinde olduğundan geometrik ve atmosferik düzeltmeleri hâlihazırda gerçekleştirilmiş olup bantlar yüzey yansıtım değerlerini içermektedir. Bu görüntünün 10 m ve 20 m mekânsal çözünürlüğe sahip bantları, 10 m çözünürlüğe yeniden örnekleme çalışması gerçekleştirilmiştir. Bant değerlerinden yararlanılarak NDVI ve NDI45 bitki indeksleri hesaplanmıştır (Tablo 1).

Sentinel-1 SAR görüntüleri sırasıyla, yörünge dosyası ekleme, termal gürültü silme, kalibrasyon, görüntü benek filtreleme, arazi düzeltmesi aşamaları gerçekleştirildikten sonra geri saçılım katsayısına (dB) dönüştürülmüştür. Radar görüntüler için dikey-dikey (VV), dikey-yatay (VH) polarimetri geri saçılım değerleri biyokütle kestirimi için test edilmiştir. Geri saçılım değerlerine çevirme adımında, Eşitlik 2’ de verilen logaritmik dönüşüm kullanılarak herhangi bir birim değeri olmayan geri saçılım katsayıları dB birimine çevrilmiştir.

$$\sigma^{\circ}_{dB} = 10 \times \log(\sigma^{\circ}) \quad (2)$$

Ayrıca bu iki geri saçılım verisi kullanılarak radar bitki örtüsü indeksi (RVI) de test edilmiştir (Nasirzadehdizaji vd., 2019). Uydu görüntüleri ön-işleme çalışmaları ESA’nın SNAP yazılımı ile gerçekleştirilmiştir. Çalışmada kullanılan indeks eşitlikleri Tablo 1 ve çalışma iş akışı Şekil 5’ deki gibidir.

Tablo 1. Çalışmada kullanılan bitki indeksleri

| Bitki İndeksleri | Eşitlikler | Referans |
|--|---|------------------------------|
| Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI) | $(B8 - B4) / (B8 + B4)$ | (Tucker, 1979) |
| Normalize Edilmiş Fark İndeksi 45 (NDI45) | $(B5 - B4) / (B5 + B4)$ | (Ghosh vd., 2018) |
| Radar Bitki Örtüsü İndeksi (RVI) | $4 * \sigma^{VH} / (\sigma^{VV} + \sigma^{VH})$ | (Nasirzadehdizaji vd., 2019) |

Çalışmada, örnekleme alanlarının metre altı GPS ile elde edilmesinden kaynaklı koordinat hatalar olabileceği düşüncesiyle örnekleme alanı koordinatı merkez olacak şekilde 5x5 m kare oluşturularak QGIS 3.28 programı ile kare alanı kesen piksellerde bant yansıma değerlerinin aritmetik ortalamaları alınmış olup, eşitliklerden yararlanılarak da bitki indeks değerleri hesaplanmıştır.

2.4 Örnekleme alan verileri ile uydu verilerinin irdelenmesi

Örnekleme alanları saha çalışmalarında toplanan verilerden ve tür özelinde üretilen biyokütle denkleminde faydalanarak hesaplanan toprak üstü ağaç kütleleri ile uydu verilerinden elde edilen bant değerleri ilişkileri, t testi ve varyans analizi ile incelenmiştir. Analizler öncesinde veri setlerinin normal dağılım gösterip göstermediği Shapiro-Wilk testi, varyansların homojenliği ise Leneve testi ile kontrol edilmiş ve tüm bant değerlerinin normal dağılıma sahip olduğu belirlenmiştir. Sonuçlar $\alpha = 0,05$ düzeyinde istatistik olarak farklı kabul edilmiş, Sentinel-1, Sentinel-2 uydu görüntüleri ve kombinasyonları kullanılarak, geri saçılım değerleri ve bitki indeks değerleri, çalışma alanları içinde biyokütle kestirimi için test edilmiştir. Analizlerde SPSS (<https://www.ibm.com/support/pages/spss-statistics-220-available-download>) paket programı kullanılmıştır.

Çalışmada, Python scikit-learn kütüphanesi (<https://scikit-learn.org/>) paketlerinden ÇDR, RO modelleri kullanılarak, 40 adet örnekleme alanı verisi rastgele (random) olarak eğitim verisi (%75) modellenmiş ve test verisinin (%25) biyokütle kestirimi gerçekleştirilmiştir. Elde edilen sonuçlar ile yersel veriler ile kestirilen değerler karşılaştırılarak analizler ve modellerin performanslarını ve biyokütle kestirimi doğruluklarını ölçmek için optik, radar ve her ikisinin olduğu seçenekler değerlendirilerek pearson korelasyon katsayısı (r), belirtme katsayısı (R^2) ve karesel ortalama hata (RMSE) gibi metrikler hesaplanmıştır. Yüksek korelasyon ve belirtme katsayısı, düşük karesel ortalama hata biyokütle kestirimi doğrulukları için önemli sonuçlardır.

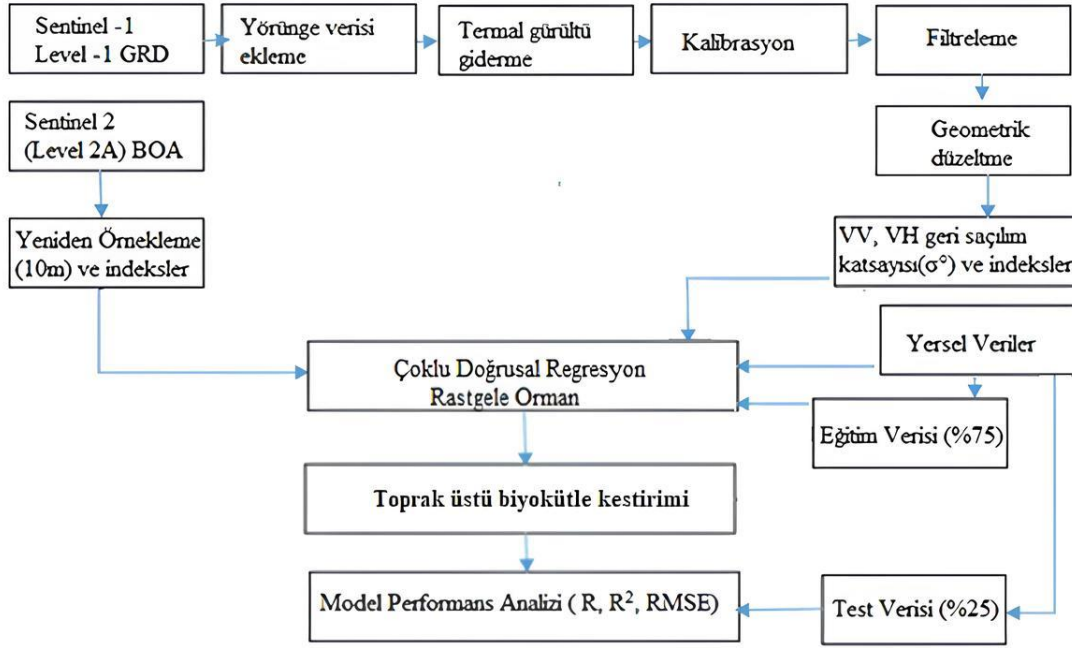
Yersel veriler ve biyokütle denklemleri kullanılarak elde edilen TÜB değerleri ve uydu görüntüsü bileşenlerinden oluşan 30 adet örnekleme alanı eğitim verisi ilk olarak ÇDR ile modellenmiştir (Eşitlik 3). Elde edilen denklemlerden yararlanılarak, 10 adet örnekleme alanı test verisi olarak kullanılıp sonuçları irdelenmiştir.

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \epsilon_i \quad (3)$$

Burada β sabit değeri ve x modeldeki değişkenlerin katsayılarını gösterirken, ϵ ise tesadüfi hatayı (rezidüeli) göstermektedir. Doğrusal regresyon modelinde birden fazla değişken olduğunda p tane bağımsız olduğu varsayılır.

Rastgele Orman (RO) olarak bilinen başka bir yöntem ise bir karar ağacı algoritmasıdır. Karar ağaçları, veri madenciliğinde yaygın olarak kullanılan bir tekniktir. Veri setini gruplara ayırmak için karar ağaçları kullanılır; bu gruplar, verileri benzer özelliklere sahip olanlar arasında böler. Bu algoritma, Breiman tarafından (2001) yılında geliştirilmiştir ve tek bir karar ağacı oluşturmak yerine birçok farklı eğitim kümesinde eğitilmiş çok sayıda çok değişkenli ağacın kararlarını birleştirmeyi amaçlar. Her veri seti, orijinal veri setinden önyükleme yöntemiyle oluşturulur ve ardından rastgele seçilen özelliklerle ağaçlar geliştirilir. RO algoritması için kullanıcı tarafından tanımlanması gereken iki önemli parametre vardır: her düğümde kullanılan değişken sayısı (mtry), ve geliştirilecek ağaçların sayısı (n). İlk olarak, eğitim veri setinin 2/3'ü önyükleme örnekleri oluşturmak için kullanılır. Geriye kalan 1/3'lük kısım ise hataları değerlendirmek için out-of-bag (OOB) verisi olarak adlandırılır. Ardından, her bir önyükleme örneği için karar ağaçları oluşturulur. Her düğümde, m değişken rastgele seçilir ve bu değişkenler arasından en iyi dal seçilir.

Çalışma iş akış diyagramı Şekil 5’ de verilmiştir.



Şekil 5. Çalışmanın iş akışı

3. Bulgular ve Tartışma

Çalışmada, sahi çamı türüne ait 40 adet örnekleme alanı (mxm) belirlenerek her bir alan için sahadan bilgiler toplanmıştır. Alanların yükselti (m), eğim, bakı bilgileri, hektardaki ağaç sayıları, fertlerin çap ($d_{1.3m}$) ve boy (h_m) ortalamaları ve biyokütle denklemi (Tolunay vd., 2017) kullanılarak alanlarda hesaplanan toplam ağaç kütleleri Tablo 2’de gösterilmiştir.

Tablo 2. Örnekleme alanlarına ilişkin parametreler

| Örnek Alan No | Örnekleme Alanı (mxm) | Yükselti (m) | %Eğim | Bakı | Ağaçlar (sayı/ha) | Çap (cm) (ortalama) | Ağaç Boyu (m) (ortalama) | Toplam Ağaç Kütleli (t/ha) |
|---------------|-----------------------|--------------|-------|------|-------------------|---------------------|--------------------------|----------------------------|
| A1 | 20x20 | 309.47 | 16 | GB | 375 | 27.6 | 13.8 | 98.33 |
| A2 | 20x20 | 315.98 | 19 | G | 475 | 25.3 | 13.1 | 100.06 |
| A3 | 20x20 | 289.88 | 16 | G | 375 | 28.3 | 13.7 | 108.89 |
| A4 | 20x20 | 301.13 | 22 | G | 225 | 30.2 | 12.7 | 61.87 |
| A5 | 20x20 | 298.81 | 18 | G | 525 | 28.2 | 13.0 | 140.86 |
| A6 | 20x20 | 257.14 | 13 | B | 350 | 27.2 | 12.3 | 75.71 |
| A7 | 20x20 | 256.55 | 20 | GD | 325 | 29.5 | 13.1 | 87.83 |
| A8 | 20x20 | 315.20 | 23 | G | 375 | 23.5 | 9.9 | 58.79 |
| A9 | 20x20 | 327.10 | 23 | G | 500 | 20.5 | 10.4 | 68.45 |
| A10 | 20x20 | 349.66 | 13 | G | 800 | 18.0 | 10.1 | 82.75 |
| A11 | 20x20 | 320.71 | 18 | G | 575 | 20.4 | 10.1 | 78.76 |
| A12 | 20x20 | 356.82 | 11 | G | 1300 | 18.5 | 11.2 | 157.69 |
| A13 | 20x20 | 91.05 | 9 | GB | 625 | 20.3 | 9.1 | 73.48 |
| A14 | 20x20 | 92.11 | 11 | G | 300 | 25.1 | 9.9 | 71.28 |
| A15 | 20x20 | 92.72 | 8 | G | 400 | 25.1 | 9.9 | 70.40 |
| A16 | 20x20 | 93.44 | 8 | G | 400 | 32.0 | 14.6 | 148.10 |
| A17 | 20x20 | 99.78 | 9 | G | 375 | 33.1 | 16.9 | 165.07 |
| A18 | 20x20 | 101.77 | 9 | G | 375 | 34.6 | 17.5 | 178.30 |
| A19 | 20x20 | 111.67 | 9 | G | 375 | 34.7 | 17.2 | 184.52 |
| A20 | 20x30 | 119.72 | 8 | GD | 250 | 36.9 | 17.3 | 135.90 |


Tablo 2'nin devamı

| Örnek Alan No | Örnekleme Alanı (mxm) | Yükselti (m) | %Eğim | Bakı | Ağaçlar (sayı/ha) | Çap (cm) (ortalama) | Ağaç Boyu (m) (ortalama) | Toplam Ağaç Kütlesi (t/ha) |
|---------------|-----------------------|--------------|-------|------|-------------------|---------------------|--------------------------|----------------------------|
| A21 | 20x30 | 118.93 | 8 | GD | 300 | 32.8 | 15.3 | 123.50 |
| A22 | 20x20 | 91.22 | 8 | G | 400 | 30.4 | 14.0 | 128.46 |
| A23 | 20x20 | 96.5 | 9 | G | 375 | 32.2 | 15.8 | 148.45 |
| A24 | 20x30 | 96.57 | 10 | G | 267 | 32.7 | 16.0 | 112.14 |
| A25 | 30x30 | 95.31 | 11 | G | 178 | 38.3 | 18.6 | 110.52 |
| A26 | 20x30 | 92.22 | 13 | G | 250 | 37.3 | 16.5 | 134.16 |
| A27 | 20x30 | 99.51 | 13 | GD | 300 | 31.8 | 15.3 | 121.83 |
| A28 | 20x30 | 109.24 | 9 | GD | 283 | 29.2 | 14.8 | 89.69 |
| A29 | 20x30 | 119.54 | 12 | G | 250 | 31.8 | 14.6 | 86.20 |
| A30 | 20x20 | 102.18 | 6 | GB | 375 | 32.4 | 16.2 | 152.45 |
| A31 | 20x30 | 99.43 | 8 | B | 267 | 31.1 | 15.1 | 90.30 |
| A32 | 20x20 | 105.54 | 5 | B | 475 | 32.9 | 15.7 | 189.23 |
| A33 | 20x20 | 111.48 | 7 | G | 450 | 31.2 | 15.0 | 158.04 |
| A34 | 20x20 | 115.33 | 6 | GB | 425 | 32.4 | 14.9 | 161.63 |
| A35 | 20x20 | 120.47 | 6 | GB | 425 | 32.3 | 15.0 | 160.36 |
| A36 | 20x20 | 127.95 | 6 | GB | 375 | 31.1 | 12.7 | 118.40 |
| A37 | 20x30 | 127.15 | 10 | G | 425 | 34.3 | 16.2 | 126.48 |
| A38 | 20x20 | 128.64 | 6 | G | 450 | 32.0 | 15.3 | 169.65 |
| A39 | 20x30 | 133.68 | 5 | GB | 317 | 32.5 | 14.7 | 116.26 |
| A40 | 20x30 | 133.09 | 10 | G | 250 | 34.4 | 14.4 | 105.63 |

S1 ve S2 uydu görüntüleri geri saçılım, indeks değerleri ve kombinasyonlarının yersel veriler ile elde edilen TÜB değerleri korelasyon ilişkileri incelendiğinde, korelasyon katsayısı değerleri 0.31 ile 0.66 aralığında ters (negatif) yönde değişirken, bileşenler arası farklılıklar önemli bulunmuştur. TÜB değerleri ile en yüksek korelasyonu NDI45 ve NDVI indeksleri göstermiştir (Tablo 3 ve Şekil6).

Tablo 3. TÜB değerleri ve Uydu Görüntüleri Bileşenleri Korelasyon Değerleri ve Anlamlılık Düzeyleri

| | TÜB | VH | VV | RVI | NDVI | NDI45 | |
|--|--------|--------|--------|--------|--------|--------|--------|
| Pearson Korelasyon Katsayısı (r) TÜB= Toprak Üstü Biyokütle | TÜB | 1 | -0.319 | -0.315 | -0.428 | -0.549 | -0.664 |
| | VH | -0.319 | 1 | 0.705 | 0.634 | 0.465 | 0.409 |
| | VV | -0.315 | 0.705 | 1 | 0.941 | 0.272 | 0.227 |
| | RVI | -0.428 | 0.634 | 0.941 | 1 | 0.289 | 0.275 |
| | NDVI | -0.549 | 0.465 | 0.272 | 0.289 | 1 | 0.813 |
| | NDI45 | -0.664 | 0.409 | 0.227 | 0.275 | 0.8126 | 1 |
| | p<0.05 | TÜB | | .033 | .035 | .009 | .001 |
| VH | | .033 | | .000 | .000 | .005 | .013 |
| VV | | .035 | .000 | | .000 | .030 | .014 |
| RVI | | .009 | .000 | .000 | | .040 | .007 |
| NDVI | | .001 | .005 | .030 | .040 | | .000 |
| NDI45 | | .000 | .013 | .014 | .007 | .000 | |



Şekil 6. TÜB değerleri ve Uydu Görüntüleri Bileşenleri Korelasyon Grafikleri

Çalışma kapsamında 16 farklı model oluşturularak her bir model için sadece radar, optik ve füzyonunda kestirilen toprak üstü biyokütle kestirimi sonuçları irdelenmiştir.

Sonuçlar incelendiğinde optik görüntü bant değerlerinden elde edilen NDVI ve NDI45 indekslerinin, diğerlerine göre yüksek korelasyon ve daha düşük RMSE değerlerine sahip olduğu görülmektedir. Radar bantlarından elde edilen RVI indeksinin en düşük korelasyonda ve en yüksek RMSE değerinde olduğu görülmektedir. Model 1, 2, 3 ve 6 dışında tüm modellerde RMSE değerleri yaklaşık 55 ile 74 t/ha aralığında değişmektedir. S1 ve S2 kombinasyonunda RO yöntemi ile en yüksek korelasyon ters yönde (-0.780) ve en düşük RMSE değeri (49.412 t/ha) ile Model 8 ile en iyi sonuçlar elde edilmiştir. Radar bantları tek başına düşük korelasyon ve yüksek RMSE olmasına karşın, NDVI ve NDI45 gibi indekslerle füzyonunda, değerleri arttırdığı görülmektedir. Ayrıca S1 VH geri saçılım değeri ile optik görüntü bitki indeksleri ile füzyonunda sonuçların daha iyi olduğu gözlenmektedir. Tablo 4' de modeller, görüntü bileşenleri ÇDR ve RO model sonuçları gösterilmektedir.

Önceki çalışmalarda, Li vd. (2020), Çin'de tropik orman alanında Sentinel-1A ve Landsat-8 uydu verileri ile ÇDR ve iki makine öğrenme modeli olan RO ve AGA tekniğini kullanmış, Çin Ulusal Orman envanter verileri ile karşılaştırılmış, sonuç olarak AGA tekniği ve uydu füzyonundan en iyi sonuçlar ürettiğini belirtmişlerdir. Theofanous vd. (2021), Yunanistan'ın kuzeydoğusunda bulunan kısa orman bitkilerinde TÜB kestirimi çalışmasında, S2 uydu verileri için farklı spektral indeksler ve biyokütle denklemlerine uygulanan saha verileri kullanılarak RO modeli geliştirilmiş ve Normalize Edilmiş Su İndeksi (NDWI) TÜB kestirimi için yüksek korelasyon göstermiştir.

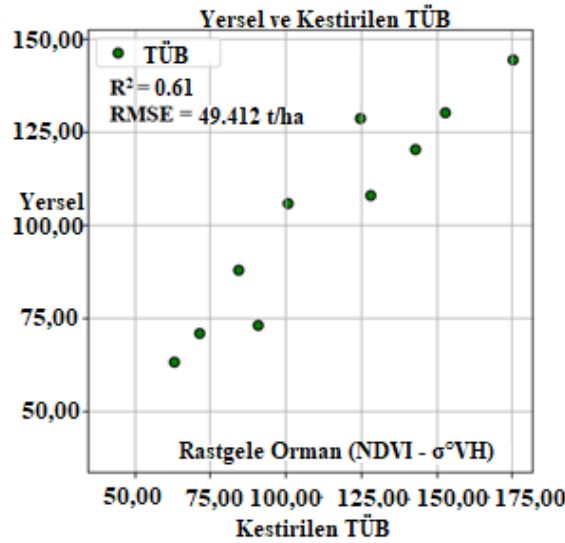
Georgopoulos vd. (2022), S1 ve S2 görüntüleri ile ibrelili yapraklı orman alanında TÜB kestirimi çalışmasında, sadece radar görüntüsü kullanıldığında en yüksek belirtme katsayısı elde edildiği ($R^2 = 0.74$), bu değer optik görüntüde $R^2 = 0.63$ olduğu ve iki görüntü füzyonunda $R^2 = 0.73$ değerinin elde edildiği ayrıca çalışmamıza benzer nitelikte NDVI ve VH geri saçılım değerinin yüksek korelasyon sonucu verdiğini belirtmişlerdir.

David vd. (2022), S1 ve S2 görüntüleri ve 11 bitki örtüsü indeksini ÇDR ve RO yöntemleriyle kullandığı TÜB kestirimi çalışmalarında, Normalize Edilmiş Farklılık Kırmızı Kenar bandı (NDRE1) ve NDVI bandının TÜB ile yüksek ilişkileri olduğunu ($R^2 = 0.71$ ve $R^2 = 0.56$), füzyon verisinin, VV geri saçılım bileşeninin ve RO yönteminin daha yüksek sonuçlar ürettiğini açıklamıştır. Benzer özellikte Omar vd. (2017) ve Pham vd. (2020) çalışmalarında VV geri saçılım değerinin TÜB kestiriminde VH değerine göre performansı artırdığı sonuçlarını elde etmişlerdir. Nuthammachot vd. (2022) tarafından yapılan çalışmada ise S1 ve S2 uydu görüntüleri ile 45 örnekleme alanında gerçekleştirdiği çalışmasında, TÜB ile sadece radar görüntüsü geri saçılım değerlerinde belirtme katsayısı $R^2 = 0.34$ iken S2 de bu değer $R^2 = 0.82$ ve iki görüntü, NDI45 bitki örtüsü indeksi, bant 6 ve VH geri saçılım füzyonunda bu değer $R^2 = 0.84$ olduğunu, çalışmasında sadece C bant radar geri saçılım değerlerinin biyokütle kestiriminde iyi sonuç vermediği, radar ve optik görüntü füzyonunun iyi sonuçlar ürettiğini belirtmişlerdir. Yine çalışmamız ile benzer özellikte, Liu vd. (2019)'ün çalışma sonucunda, TÜB kestiriminde, VH geri saçılım değerinin VV'ye göre daha iyi değerler elde ettiğini belirtmişlerdir ($R^2 = 0.43$ ve $R^2 = 0.09$). Keleş vd. (2021) tarafından gerçekleştirilen sarıçam türünü içeren 86 örnekleme alanında, S1 ve S2 uydu görüntülerinin birlikte kullanıldığı modelde başarılı sonuçlar elde edilmiştir. (DVM' de $R^2 = 0.88$, derin öğrenme modelinde $R^2 = 0.86$).

Güverçin ve Günlü, (2023) 22 farklı regresyon modeli geliştirdiği çalışmalarında, Landsat 8 OLI uydu görüntüsünün bant parlaklık, bitki indisi ve tekstür özellikleri, Sentinel-1A aktif uydu görüntüsünün her iki polarizasyona (VV ve VH) ilişkin parlaklık değerleri, yükselti ve bakı değişkenlerinin yer aldığı model ile en başarılı sonucu elde etmişlerdir ($R^2 = 0.51$, $Sy.x = 28.39$). Her iki çalışmada da optik ve SAR uydu görüntü bileşenlerinden oluşturulan modellerin çalışmamızda olduğu gibi daha başarılı sonuçlar elde ettiği görülmektedir.

Tablo 4. Test verileri için r , R^2 ve RMSE değerleri

| Model | Bileşen | ÇDR | | | RO | | |
|-------|--|---------------|--------------|---------------|---------------|--------------|---------------|
| | | r | R^2 | RMSE | r | R^2 | RMSE |
| S1 | $\sigma^{\circ}VH$ | -0.229 | 0.052 | 92.147 | -0.278 | 0.077 | 83.124 |
| S2 | $\sigma^{\circ}VV$ | -0.180 | 0.032 | 97.545 | -0.230 | 0.053 | 85.343 |
| S3 | RVI | -0.179 | 0.128 | 98.504 | -0.199 | 0.040 | 86.131 |
| S4 | NDVI | -0.626 | 0.392 | 66.074 | -0.660 | 0.436 | 55.008 |
| S5 | NDI45 | -0.562 | 0.316 | 67.385 | -0.590 | 0.348 | 57.765 |
| S6 | $\sigma^{\circ}VH - \sigma^{\circ}VV$ | -0.206 | 0.042 | 96.868 | -0.240 | 0.058 | 88.772 |
| S7 | NDVI - $\sigma^{\circ}VV$ | -0.619 | 0.383 | 66.750 | -0.710 | 0.504 | 48.872 |
| S8 | NDVI - $\sigma^{\circ}VH$ | -0.645 | 0.416 | 65.343 | -0.780 | 0.608 | 49.412 |
| S9 | NDVI - RVI | -0.575 | 0.331 | 67.200 | -0.670 | 0.449 | 55.538 |
| S10 | NDVI - NDI45 | -0.567 | 0.321 | 68.565 | -0.650 | 0.423 | 56.002 |
| S11 | NDI45 - $\sigma^{\circ}VV$ | -0.524 | 0.275 | 71.074 | -0.630 | 0.397 | 56.011 |
| S12 | NDI45 - $\sigma^{\circ}VH$ | -0.547 | 0.299 | 70.835 | -0.610 | 0.372 | 56.356 |
| S13 | NDI45 - RVI | -0.566 | 0.320 | 69.829 | -0.630 | 0.397 | 55.898 |
| S14 | NDI45 - RVI - $\sigma^{\circ}VV$ | -0.436 | 0.190 | 73.505 | -0.580 | 0.336 | 57.887 |
| S15 | NDI45 - RVI - $\sigma^{\circ}VH$ | -0.466 | 0.217 | 72.433 | -0.610 | 0.372 | 56.443 |
| S16 | NDVI - NDI45 - $\sigma^{\circ}VV - \sigma^{\circ}VH$ | -0.529 | 0.280 | 71.041 | -0.670 | 0.449 | 55.406 |



Şekil 7. Yersel ve kestirilen TÛB değerleri (t/ha)

4. Sonuçlar

Orman alanlarında gerçekleştirilen uzaktan algılama çalışmalarında çoğunlukla piksel değerleri, yansıma değeri ve bu değerlerden hesaplanan bitki indeks değerleri ile meşcere hakkında bilgiler edinmek mümkündür. Bu çalışmada, sahil çamı ağaçlandırma alanlarında saha çalışmaları ve ESA'nın ücretsiz olarak sağladığı Sentinel-1A C bant SAR ve Sentinel-2A optik uydu görüntülerinden yararlanarak TÛB değerlerinin kestirimi gerçekleştirilmektedir. 16 farklı modelde gerçekleştirilen araştırma sonuçlarına göre, optik ve radar görüntüleri füzyonunun biyokütle kestiriminde sonuçları iyileştirdiği gözlenmektedir. S1 ve S2 kombinasyonunda ve RO modelinde ters yönde en yüksek korelasyon (-0.780) ve en düşük RMSE değerine (49.412 t/ha) sahip NDVI ve VH geri saçılım füzyonu en başarılı performansı göstermektedir. S1 geri saçılım bileşenleri tek başına düşük korelasyon ve yüksek RMSE değerlerine sahip olmasına karşın, NDVI ve NDI45 gibi indeksleriyle füzyonunda, değerleri arttırdığı görülmektedir.

Gelecek çalışmalarda, çoklu zamansal ve farklı frekansta (X, L, P) bant SAR uydu görüntüleri ile optik görüntülerin füzyonu ile örnekleme alanı sayısının artırılması ve ÇDR, RO dışında farklı makine öğrenme yöntemleri (DVM, Extreme Gradient Boosting (XgBoost) vb.) de kullanılarak TÜB'nin kestirimine yönelik model başarıları artırılabilir. Sürdürülebilir kalkınma amaçlarından "İklim Eylemi" kapsamında hayati önemi olan ormanlarımız için elde edilecek bu sonuçların, ormanlarda yersel yöntemler dışında, uydu teknolojileri ile biyokütle bilgilerinin elde edilmesi açısından önem arz etmektedir.

Teşekkür

Bu araştırma, TÜBİTAK 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı tarafından "Sentinel-1 (Sentetik Açıklı Radar) ve Sentinel-2 Optik uydu görüntüleri kombinasyonundan yararlanılarak Ulus (Bartın) sınırlarında bulunan ağaçlandırma alanındaki Sahil Çamı (*Pinus pinaster* Ait.) türünün toprak üstü biyokütle miktarının kestirilmesi (1919B012106792)" isimli proje kapsamında desteklenmiştir. Desteklerinden dolayı TÜBİTAK BİDEB'e, uydu görüntülerinin ücretsiz olarak temin edilmesinde sağladığı imkânlardan dolayı Avrupa Uzay Ajansına (ESA) ve makalenin değerlendirme süreçlerinde kıymetli görüş ve önerileri için hakemlere teşekkür ederiz.

Kaynaklar

- Bao, N., Li, W., Gu, X., & Liu, Y. (2019). Biomass Estimation for Semiarid Vegetation and Mine Rehabilitation Using Worldview-3 and Sentinel-1 SAR Imagery. *Remote Sensing*, 11(23), 2855. <https://doi.org/10.3390/rs11232855>
- Bonan, G.B. (2008). Forests and climate change: forcings, feedbacks and the climate benefits of forests. *Science*, 320, 1444–1449. <https://doi.org/10.1126/science.1155121>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Çepel, N., Dündar, M., & Günel, A. (1977). *Türkiye'nin önemli yetiştirme bölgelerinde saf sarıçam ormanlarının gelişimi ile bazı edafik ve fizyografik etmenler arasındaki ilişkiler* (Proje No: TOAG 154). TÜBİTAK, Tarım ve Ormanlık Araştırma Grubu, TÜBİTAK Yayınları No:354, TOAG Seri No: 65, Ankara.
- Cheng, W., Yang, C., Zhou, J., Zhou, W., & Liu, Y. (2009). Research summary of forest volume quantitative estimation based on remote sensing technology. *Journal of Anhui Agricultural Sciences*, 37, 7746–7750.
- Cox, P., Betts, R., & Jones, C. (2000). Erratum: Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. *Nature*, 408, 750. <https://doi.org/10.1038/35047138>
- David, R. M., Rosser, N. J., & Donoghue Daniel, N. M. (2022). Improving above ground biomass estimates of Southern Africa dryland forests by combining Sentinel-1 SAR and Sentinel-2 multispectral imagery. *Remote Sensing of Environment*, 282, 113232. <https://doi.org/10.1016/j.rse.2022.113232>
- Dixon, R. K., Brown, S. A., Houghton, R. A., Solomon, A. M., Trexler, M. C., & Wisniewski, J. (1994) Carbon Pools and Flux of Global Forest Ecosystems. *Science*, 263, 185-190. <http://dx.doi.org/10.1126/science.263.5144.185>
- Dobson, M. C., Ulaby, F. T., LeToan, T., Beaudoin, A., Kasischke, E. S., & Christensen, N. (1992). Dependence of radar backscatter on coniferous forest biomass. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 412–415. <https://doi.org/10.1109/36.134090>
- Eckert, S. (2012). Improved Forest Biomass and Carbon Estimations Using Texture Measures from WorldView-2 Satellite Data. *Remote Sensing*, 4(4), 810–829. <http://dx.doi.org/10.3390/rs4040810>
- 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). https://gis1.servirglobal.net/TrainingMaterials/SAR/SARHB_FullRes.pdf
- Foody, G. M., Boyd, D. S., & Cutler, M. E. J. (2003). Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sensing of Environment*, 85(4), 463–474. [https://doi.org/10.1016/S0034-4257\(03\)00039-7](https://doi.org/10.1016/S0034-4257(03)00039-7)
- George-Chacón, S. P., Milodowski, D. T., Dupuy, J. M., Mas, J.-F., Williams, M., Castillo-Santiago, M. A., & Hernández-Stefanoni, J. L. (2022). Using satellite estimates of aboveground biomass to assess carbon stocks in a mixed-management, semi-deciduous tropical forest in the Yucatan Peninsula. *Geocarto International*, 37(25), 7659–7680. <https://doi.org/10.1080/10106049.2021.1980619>
- Georgopoulos, N., Sotiropoulos, C., Stefanidou, A., & Gitas, I. Z. (2022). Total Stem Biomass Estimation Using Sentinel-1 and -2 Data in a Dense Coniferous Forest of Complex Structure and Terrain. *Forests*, 13, 2157. <https://doi.org/10.3390/f13122157>
- Ghasemi, N., Sahebi, M. R., & Mohammadzadeh, A. (2013). Biomass Estimation of a Temperate Deciduous Forest Using Wavelet Analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 51(2), 765–776. <https://doi.org/10.1109/TGRS.2012.2205260>

- Ghosh, P., Mandal, D., Bhattacharya, A., Nanda, M. K., & Bera, S. (2018). Assessing Crop Monitoring Potential of Sentinel-2 in A Spatio-Temporal Scale. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-5, 227–231. <https://doi.org/10.5194/isprs-archives-XLII-5-227-2018>
- Guerra-Hernández, J., Narine, L. L., Pascual, A., Gonzalez-Ferreiro, E., Botequim, B., Malambo, L., Neuenschwander, A., Popescu, S. C., & Godinho, S. (2022). Aboveground biomass mapping by integrating ICESat-2, SENTINEL-1, SENTINEL-2, ALOS2/PALSAR2, and topographic information in Mediterranean forests. *GIScience & Remote Sensing*, 59(1), 1509–1533. <https://doi.org/10.1080/15481603.2022.2115599>
- Günel, A. (1981). *Orman Hasılat Bilgisi*. İstanbul Üniversitesi Yayınları.
- Güner, Ş. T., Özel, C., Türkkkan, M. & Akgül, S. (2019). Türkiye’deki sahilçamı ağaçlandırmalarında ağaç bileşenlerine ait karbon yoğunluklarının değişimi. *Ormanlık Araştırma Dergisi*, 6(2) , 167-176.
- Güner, Ş. T., Diamantopoulou, M. J., Poudel, K. P., Çömez, 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>
- Güverçin, İ., & Günlü, A. (2023). Saf Kızılcım (Pinus brutia Ten.) Meşcerelerinde Aktif ve Pasif Uydu Görüntüleri Kullanılarak Topraküstü Biyokütlenin Tahmin Edilmesi (Anamur Orman İşletme Şefliği Örneği). *Bartın Orman Fakültesi Dergisi*, 25(1), 177–191. <https://doi.org/10.24011/barofd.1261299>
- Hamdan, O., Aziz, H. K., & Rahman, K. A. (2011). Remotely Sensed L-Band SAR Data for Tropical Forest Biomass Estimation. *Journal of Tropical Forest Science*, 23(3), 318–327.
- Kandemir, A., & Mataracı T. (2018). Pinus L. In A. Güner, A. Kandemir, Y. Menemen, H. Yıldırım, S. Aslan, G. Ekşi, I. Güner & A. Ö. Çimen (Eds.), *Illustrated Flora of Turkey 2* (pp. 324–354). Nezahat Gökyiğit Botanical Garden Press.
- Keleş, S., Günlü, A., & Ercanlı, I. (2021). Estimating aboveground stand carbon by combining Sentinel-1 and Sentinel-2 satellite data: A case study from Turkey. In P. K. Shit, H. R. Pourghasemi, P. P. Adhikary, G. S. Bhunia & V. P. Sati (Eds.), *Forest Resources Resilience and Conflicts* (pp. 117–126). Elsevier. <https://doi.org/10.1016/B978-0-12-822931-6.00008-3>
- Li, C., Li, Y., & Li, M. (2019). Improving Forest Aboveground Biomass (AGB) Estimation by Incorporating Crown Density and Using Landsat 8 OLI Images of a Subtropical Forest in Western Hunan in Central China. *Forests*, 10(2), 104. <http://dx.doi.org/10.3390/f10020104>
- Li, Y., Li, M., Li, C., & Liu, Z. (2020). Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. *Scientific Reports*, 10, 9952. <https://doi.org/10.1038/s41598-020-67024-3>
- Liu, Y. A., Gong, W. S., Xing, Y. Q., Hu, X. Y., & Ong, J. Y. (2019). Estimation of the forest stand mean height and aboveground biomass in Northeast China using SAR Sentinel-1B, multispectral Sentinel-2A, and DEM imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151, 277–289. <https://doi.org/10.1016/j.isprsjprs.2019.03.016>
- Lu, D., Chen, Q., Wang, G., Liu, L., Li, G., & Moran, E. (2016). A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *International Journal of Digital Earth*, 9(1), 63–105. <https://doi.org/10.1080/17538947.2014.990526>
- Meteoroloji Genel Müdürlüğü. (2023, 20 Haziran). *Resmi İstatistikler*. Meteoroloji Genel Müdürlüğü (MGM). 20 Haziran 2023’de <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=BARTIN> adresinden alındı.
- Monnet, J. M., Chanussot, J., & Berger, F. (2011). Support Vector Regression for the Estimation of Forest Stand Parameters Using Airborne Laser Scanning. *IEEE Geoscience and Remote Sensing Letters*, 8(3), 580-84. <https://doi.org/10.1109/LGRS.2010.2094179>
- Naik, P., Dalponte, M., & Bruzzone, L. (2021). Prediction of forest aboveground biomass using multitemporal multispectral remote sensing data. *Remote Sensing*, 13(7), 1282. <https://doi.org/10.3390/rs13071282>
- Nasirzadehdizaji, R., Balik Sanli, F., Abdikan, S., Cakir, Z., Sekertekin, A., & Ustuner, M. (2019). Sensitivity Analysis of Multi-Temporal Sentinel-1 SAR Parameters to Crop Height and Canopy Coverage. *Applied Sciences*, 9(4), 655. <https://doi.org/10.3390/app9040655>
- Nuthammachot, N., Askar, A., Stratoulas, D., & Wicaksono, P. (2022). Combined use of Sentinel-1 and Sentinel-2 data for improving above-ground biomass estimation. *Geocarto International*, 37(2), 366-376.
- Nelson, R., Ranson, K. J., Sun, G., Kimes, D. S., Kharuk, V., & Montesano, P. (2009). Estimating Siberian Timber Volume Using MODIS and ICESat/GLAS. *Remote Sensing of Environment*, 113(3), 691-701.
- Omar, H., Misman, M., & Kassim, A. (2017). Synergetic of PALSAR-2 and Sentinel-1A SAR Polarimetry for Retrieving Aboveground Biomass in Dipterocarp Forest of Malaysia. *Applied Sciences*, 7(7), 675. <http://dx.doi.org/10.3390/app7070675>
- Pham, T. D., Yokoya, N., Xia, J., Ha, N. T., Le, N. N., Nguyen, T. T. T., Dao, T. H., ... Takeuchi, W. (2020). Comparison of Machine Learning Methods for Estimating Mangrove Above-Ground Biomass Using Multiple Source Remote Sensing Data in the Red River Delta Biosphere Reserve, Vietnam. *Remote Sensing*, 12(8), 1334. <http://dx.doi.org/10.3390/rs12081334>

- Santoro, M., Cartus, O., Fransson, J. E. S., & Wegmüller, U. (2019). Complementarity of X-, C-, and L-band SAR Backscatter Observations to Retrieve Forest Stem Volume in Boreal Forest. *Remote Sensing*, 11, 1563. <https://doi.org/10.3390/rs11131563>
- Schmidt, M., Carter, J., Stone, G., & O'Reagain, P. (2016). Integration of Optical and X-Band Radar Data for Pasture Biomass Estimation in an Open Savannah Woodland. *Remote Sensing*, 8(12), 989. <http://dx.doi.org/10.3390/rs8120989>
- Şimşek, Y., Tubukçu, M., Toplu, F., Akkan, A., & Avcioğlu, E. (1985). *Türkiye'de ithal edilen hızlı büyüyen yabancı türlerin büyümeleri üzerine araştırmalar*. Ormançılık Araştırma Enstitüsü Yayınları.
- Tavasoli, N., & Arefi, H. (2021). Comparison of Capability of SAR and Optical Data in Mapping Forest above Ground Biomass Based on Machine Learning. *Environmental Sciences Proceedings*, 5(1), 13. <https://doi.org/10.3390/IECG2020-07916>
- Theofanous, N., Irene, C., Giorgos, M., Christos D., Natalia, V., & Sofia, S. (2021). Aboveground Biomass Estimation in Short Rotation Forest Plantations in Northern Greece Using ESA's Sentinel Medium-High Resolution Multispectral and Radar Imaging Missions. *Forests*, 12(7), 902. <https://doi.org/10.3390/f12070902>
- Tolunay, D., Makineci, E., Şahin, A., Özturba, A. G., Pehlivan, S., & Abdelkaim, M. A. (2017). *İstanbul-Durusu Kumul Alanlarındaki Sahil Çamı (Pinus pinaster Ait.) ve Fıstık Çamı (Pinus pinea L.) Ağaçlandırmalarında Karbon Birikimi* (TÜBİTAK TOVAG Proje No: 1140797).
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://dx.doi.org/10.1016/0034-4257\(79\)90013-0](https://dx.doi.org/10.1016/0034-4257(79)90013-0)
- Ürgeç, S. (1972). *Hızlı gelişen bazı egzotik (yabancı) iğne yapraklı ağaç türlerinin Türkiye'ye ithali ve yetiştirilmesi imkânları üzerine araştırmalar* (Yayın No. 1750/188). İ.Ü. Orman Fakültesi Yayınları.
- Vaglio Laurin, G., Pirotti, F., Callegari, M., Chen, Q., Cuzzo, G., Lingua, E., Notarnicola, C., & Papale, D. (2016). Potential of ALOS2 and NDVI to Estimate Forest Above-Ground Biomass, and Comparison with Lidar-Derived Estimates. *Remote Sensing*, 9(1), 18. <http://dx.doi.org/10.3390/rs9010018>
- Vafaei, S., Soosani, J., Adeli, K., Fadaei, H., Naghavi, H., Pham, T., & Tien Bui, D. (2018). Improving Accuracy Estimation of Forest Aboveground Biomass Based on Incorporation of ALOS-2 PALSAR-2 and Sentinel-2A Imagery and Machine Learning: A Case Study of the Hyrcanian Forest Area (Iran). *Remote Sensing*, 10(2), 172. <http://dx.doi.org/10.3390/rs10020172>
- Vatandaşlar, C., & Abdikan, S. (2022). Carbon stock estimation by dual-polarized synthetic aperture radar (SAR) and forest inventory data in a Mediterranean forest landscape. *Journal of Forestry Research*, 33, 827–838. <https://doi.org/10.1007/s11676-021-01363-3>
- Vickers, D., Thomas, C., Pettijohn, J., Martin, J., & Law, B. (2012). Five years of carbon fluxes and inherent water-use efficiency at two semi-arid pine forests with different disturbance histories. *Tellus B: Chemical and Physical Meteorology*, 64(1), 17159. <https://doi.org/10.3402/tellusb.v64i0.17159>
- Wang, X., Shao, G., Chen, H., Lewis, B. J., Qi, G., Yu, D., Zhou, L., & Dai, L. (2013). An Application of Remote Sensing Data in Mapping Landscape-Level Forest Biomass for Monitoring the Effectiveness of Forest Policies in Northeastern China. *Environmental Management*, 52, 612–620. <https://doi.org/10.1007/s00267-013-0089-6>
- Wang, J., Xiao, X., Bajgain, R., Starks, P., Steiner, J., Doughty, R. B., & Chang, Q. (2019). Estimating leaf area index and aboveground biomass of grazing pastures using Sentinel-1, Sentinel-2 and Landsat images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 154, 189-201. <https://doi.org/10.1016/j.isprsjprs.2019.06.007>
- Yadav, S., Padalia, H., Sinha, S. K., Srinet, R., & Chauhan, P. (2021). Above-ground biomass estimation of Indian tropical forests using X band Pol-InSAR and Random Forest. *Remote Sensing Applications: Society and Environment*, 21, 100462. <https://doi.org/10.1016/j.rsase.2020.100462>