

ORMAN ALANLARININ TOPRAK ÜSTÜ KARBON TUTMA MİKTARLARININ YERSEL YÖNTEMLER VE UZAKTAN ALGILAMA TEKNİKLERİ KULLANILARAK KESTİRİMİ

Eren Gürsoy ÖZDEMİR^{1,2}, Saygın ABDİKAN³,

¹Öğr. Gör., Bartın Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, 74410, Ulus, Bartın, eozdemir@bartin.edu.tr
²Doktora Öğr., Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, 06800, Beytepe, Ankara, erenozdemir@hacettepe.edu.tr
³Doç. Dr., Hacettepe Üniversitesi, Harita Mühendisliği Bölümü, 06800, Beytepe, Ankara, sayginabdikan@hacettepe.edu.tr

ÖZET

Ormanlar, karasal ekosistemlerin kritik karbon yutakları olup, bitki örtüsü ve toprakta depoladıkları karbon ile atmosferik emisyonları azaltma potansiyeline sahiptir. Geleneksel biyokütle ve karbon kestirimi çalışmaları, maliyetli, zaman alıcı ve yoğun emek gerektiren yöntemlerle sınırlı bölgesel ölçekte gerçekleştirilebilmekte iken, gelişen ydu sistemleri ve uzaktan algılama teknolojileri, optik ve Sentetik Açıklıklı Radar (SAR) verileri ile orman biyokütlesi ve karbon stoklarının daha verimli bir şekilde tespit edilmesine olanak tanımaktadır. Bu çalışmada, Bartın ve Kastamonu illerinde yer alan Küre Dağları Milli Parkı tampon bölgesinde, doğu kayını (*Fagus orientalis* Lipsky) ve Uludağ göknarı (*Abies nordmanniana* subsp. *Bornmülleriana* Mattf.) özelinde 95 örnekleme alanından elde edilen ağaçların göğüs yüksekliği çapları ve boy uzunlukları, tür özelinde geliştirilen alometrik denklemlerle Toprak Üstü Biyokütle (TÜB) kestiriminde kullanılmış, ardından türler özelindeki karbona dönüşüm fraksiyonları ile karbon tutma miktarları hesaplanmıştır. ALOS-2 PALSAR-2 L-bandı tam polarimetrik radar, radar bitki indeksleri, Sentinel-2A optik verileri ve bitki indeksleri, ile Gradyan Artırma ve LightGBM makine öğrenimi yöntemleri kullanılarak Toprak Üstü Karbon (TÜK) kestirimi gerçekleştirilmiştir. Özellik seçimi için LASSO yöntemi uygulanarak 19 özellikten 9'u seçilmiş, model hiper parametrelerinin optimizasyonu ve aşırı uyumun önlenmesi için GridSearchCV kullanılmıştır. ALOS-2 PALSAR-2 radar veri polarizasyonları ((Düşey-Düşey), (Yatay-Düşey), (Düşey- Yatay)), Radar Oran Bitki İndeksi (RRVI) ve Sentinel-2A Bant 11 ve yeşil normalleştirilmiş fark bitki örtüsü indeksi (GNDVI) kombinasyonu ile oluşturulan LightGBM modeli, TÜK kestiriminde en iyi performansı göstermiştir ($R^2=0,71$, $RMSE=13,41$ t/ha, $MAE=11,27$ t/ha).

Anahtar Sözcükler: toprak üstü karbon stoğu, makine öğrenmesi, hafif gradyan artırma makineleri, Alos-2-Palsar-2, Sentinel-2A

ABSTRACT

ESTIMATION OF ABOVEGROUND CARBON STOCKS IN FOREST AREAS USING GROUND-BASED METHODS AND REMOTE SENSING TECHNIQUES

Forests serve as critical carbon sinks within terrestrial ecosystems, with the ability to reduce atmospheric emissions through the carbon stored in their biomass and soil. Traditional biomass and carbon estimation studies are often limited to regional scales due to their costly, time-consuming, and labor-intensive methods. However, advancements in satellite systems and remote sensing technologies, including optical and Synthetic Aperture Radar (SAR) data, have enabled more efficient detection of forest biomass and carbon stocks. In this study, tree diameter at breast height (DBH) and height measurements from 95 sampling plots within the buffer zone of Küre Mountains National Park, located in the Bartın and Kastamonu provinces, were utilized to estimate above-ground biomass (AGB) for Oriental beech (*Fagus orientalis* Lipsky) and Uludağ fir (*Abies nordmanniana* subsp. *Bornmülleriana* Mattf.). Species-specific allometric equations were applied, and the carbon storage amounts were subsequently calculated using species-specific carbon conversion fractions. Above-ground carbon (AGC) estimation was performed using ALOS-2 PALSAR-2 L-band full-polarimetric radar data, radar vegetation indices, Sentinel-2A optical data, and vegetation indices, with Gradient Boosting and LightGBM machine learning methods. Feature selection was made using the LASSO method, reducing the 19 initial features to 9, and GridSearchCV was applied to optimize model hyperparameters and prevent overfitting. The LightGBM model, incorporating ALOS-2 PALSAR-2 radar polarizations (HH, HV, VH), the Radar Ratio Vegetation Index (RRVI), and the Sentinel-2A Bant 11 and Green Normalized Difference Vegetation Index (GNDVI), demonstrated the best performance in AGC estimation ($R^2=0,71$, $RMSE=13,41$ t/ha, $MAE=11,27$ t/ha).

Keywords: above ground carbon stocks, machine learning, lightgbm, Alos-2-Palsar-2, Sentinel-2A.

1. GİRİŞ

Ormanlar, karasal karbon yutakları arasında kritik bir rol oynamaktadır. Ormanların üst kısımdaki biyokütlesi (TÜB), yani kökler, çalılar, otlar ve çürümüş yapraklar hariç, birim alandaki ağaçların kuru kütlesi, karbon havuzuna önemli katkılarda bulunur ve bu, küresel karbon döngüsü ile doğrudan ilişkilidir (Baccini vd., 2017; Cartus vd., 2019). Bu nedenle, bölgesel ve küresel ölçekte orman biyokütlesinin doğru bir şekilde envanterinin çıkarılması, izlenmesi ve kestirimi, karbon emisyonlarını azaltmak ve iklim değişikliği ile mücadelede karbon yutak alanlarını artırmak için kritik öneme sahiptir (Dixon vd., 1994). Küresel iklim değişikliğinin etkilerini hafifletmek amacıyla yapılan uluslararası anlaşmalar, ülkeleri karbon emisyonlarını ve karbon havuzlarını raporlamaya zorunlu kılmıştır. Orman ekosistemleri, yeraltı ve yerüstü canlı biyokütlesi, ölü organik madde (ölü odun ve döküntü) ve toprak üzerindeki

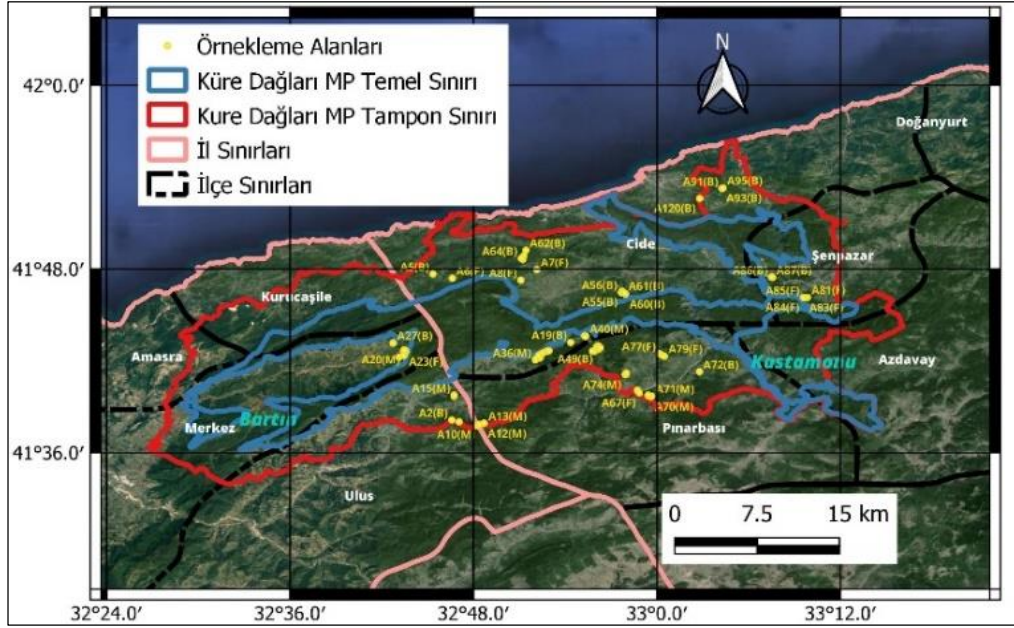
organik karbon olarak karbon havuzlarını üç ana sınıfa ayırmaktadır. Envanter verilerinin ülkeler arasında karşılaştırılabilirliğini sağlamak amacıyla, orman ekosistemlerindeki yıllık karbon stok değişiminin nasıl hesaplanacağı detaylı bir şekilde açıklanmış olan Tarım, Ormanlık ve Diğer Arazi Kullanımı (AFOLU) kılavuzu geliştirilmiştir (IPCC, 2013; IPCC, 2023; Güner vd., 2024). Orman envanterleri, ağaç verilerini (çap, boy, yaş vb.) kaydeder ve bu veriler, mevcut odun hacminin m³/ha cinsinden kestirimi için kullanılır. Aynı ağaç ölçümleri, orman ekosistemlerinin toplam biyokütlesi veya karbon içeriğini t/ha cinsinden elde etmek için de kullanılabilir. Biyokütle, belirli koşullar altında kestirilen odunun kuru ağırlığıdır (örneğin, odun örnekleri sabit bir ağırlığa ulaşana kadar fırında kurutulur). Karbon, bu fırında kurutulmuş biyokütlenin yaklaşık yarısını oluşturur ve genellikle selüloz, lignin ve hemiselüloz gibi polisakkaritlerden meydana gelir (McGroddy vd., 2004; Neumann vd., 2016). Ancak, çalışmalar, karbon rezervuarlarındaki karbon konsantrasyonlarının çevresel faktörler, ağaç türleri ve ağaç bileşenlerine bağlı olarak değiştiğini göstermektedir (Lamlom ve Savidge, 2003; Thomas ve Malczewski, 2007; Güner ve Comez, 2022). Geleneksel biyokütle ve karbon ölçüm yöntemleri maliyetli, zaman alıcı ve yoğun emek ister, bu nedenle genellikle bölgesel ölçekte uygulanmaktadır (Gibbs vd., 2007; Chen vd., 2024). Bu yöntemler, yıllardır doğruluğu ve detaylı sonuçları nedeniyle tercih edilmektedir ve ağaçların tüm parçalarının kesilerek kurutulup tartılması ya da ağaçların göğüs yüksekliğindeki çapı (DBH) ve boyuna dayanarak alometrik denklemler oluşturulmasını içerir (Forrester vd., 2017). Son yıllarda uydu teknolojileri ve uzaktan algılama sistemlerinde yaşanan ilerlemeler, bu alanda önemli gelişmelere yol açmıştır. Gelişen uydu sistemleri ve uzaktan algılama teknikleri, optik ve Sentetik Açıklıklı Radar (SAR) sistemleri ile orman biyokütlesi ve karbon stoklarının belirlenmesini etkin bir şekilde mümkün kılmaktadır (Lu 2006; Li vd., 2020). Bu teknikler, orman yapılarının belirlenmesi ve sınıflandırılmasını, arazi örtüsü değişikliklerinin haritalanmasını, ekosistem hizmetlerinin değerlendirilmesini, Toprak Üstü Biyokütle (TÜB) ve Toprak Üstü Karbon (TÜK) kestirimlerinin hassas bir şekilde yapılmasını sağlamaktadır (Batar vd., 2017; Agata vd., 2018; Vatandaşlar ve Abdikan, 2022; Özdemir ve Abdikan, 2024; Cheng vd., 2024). TÜK kestiriminde uygun model seçimi kritik öneme sahiptir. Önceki çalışmalarda, TÜK kestirimi için çeşitli makine öğrenimi modelleri kullanılmıştır; bunlar arasında Çok Değişkenli Doğrusal Regresyon (ÇDR), Rastgele Orman (RO) ve Destek Vektör Regresyonu (DVR) gibi modeller bulunmaktadır. Son yıllarda, Gradyan Artırma (GA), CatBoost ve LightGBM gibi modeller, TÜK kestiriminde başarılı sonuçlar elde etmiştir (Safari vd., 2017; Dou vd., 2018; Chen vd., 2022; Cheng vd., 2024).

Çalışma alanı olan ve Batı Karadeniz Bölgesi'nde önemli bir yere sahip Küre Dağları Milli Park'ı tampon sınırları içerisinde, kayın ve göknar türü özelinde TÜK kestiriminin çalışılacak olması ve L-bant tam (full) polarizasyona (YY, YD, DD, DY) sahip ALOS-2 PALSAR-2 uydu görüntüsünün ülkemizdeki TÜK kestirimi çalışmalarında daha önce kullanılmamış olması özgün bir yaklaşım sunmaktadır. Bu çalışmadan elde edilecek bulgular, ülkemizin orman ekosistemleri ve karbon değişim analizlerine katkı sağlamanın yanı sıra, farklı polarizasyonlara ve yüksek çözünürlüklü radar ile optik görüntüleme dayalı TÜK kestiriminde çeşitli makine öğrenimi yöntemlerinin kullanım potansiyelini incelemesi açısından da büyük önem taşımaktadır. Bu bağlamda, çalışma, ilgili kurumlar, kuruluşlar ve araştırmacılar için değerli bir bilgi ve yöntem kaynağı sunacaktır. Bu çalışmada, ALOS-2 PALSAR-2 L-bandı tam polarimetrik radar verileri, radar bitki indeksleri, Sentinel-2A optik verileri ve bitki indeksleri kullanılarak, GA ve LightGBM yöntemleri ile TÜK kestirimi gerçekleştirilmiş ve elde edilen sonuçlar, örnekleme alanlarından toplanan verilerle tür özelinde geliştirilmiş denklemlerden elde edilen TÜK değerleriyle karşılaştırılmıştır. Araştırmanın temel amacı, 1) radar ve optik verilerin ayrı ayrı ya da birlikte TÜK kestirimindeki etkinliğini, 2) radar ve optik bitki indekslerinin TÜK kestirimine katkılarını ve 3) farklı makine öğrenimi modellerinin TÜK kestirim potansiyelini incelemektir.

2. YÖNTEM

2.1 Çalışma Alanı ve Arazi Çalışmaları

Çalışma alanı, Batı Karadeniz Bölgesi'nde, Bartın ve Kastamonu illeri sınırlarında yer alan Küre Dağları üzerinde konumlanmıştır. Bu alan, 41° 36' 0"- 41° 55' 12" kuzey enlemleri ve 32° 38' 53"- 33° 15' 50" doğu boylamları arasında yer almaktadır (Şekil 1). Bu çalışmada, Küre Dağları tampon bölgesi sınırları içindeki 95 örnekleme alanından (Doğu kayını (*Fagus orientalis Lipsky*): 29 ve Uludağ göknarı (*Abies nordmanniana subsp. Bornmülleriana Mattf.*): 32, ve Karışık ormanlar: 34) farklı rakım, yön, eğim, konum ve ağaç gelişim yaşı gibi özellikler dikkate alınarak 2022 ve 2023 yılları ağustos, ekim ayları arasında veriler toplanmıştır. TÜB kestiriminde, bu örnekleme alanlarından elde edilen verilerle (çap ve boy) türlere özgü alometrik denklemler kullanılarak (Saraçoğlu, 1998; Karabürk, 2011) alandaki tüm ağaçların kütlesi hesaplanmış, ardından hektara çevirme katsayısı kullanılarak hektar başına ağaç kütlesi stoku (t/ha) hesaplanmıştır. Ardından kayın için %49,15, göknar için ise %52,31 karbona dönüşüm fraksiyonları ile karbon tutma miktarları hesaplanmıştır (Kaya, 2024; Güner, 2019).



Şekil.1 Çalışma Alanı

2.2 Uydu Verileri Ön İşleme ve Veri Seçimi

Tam polarimetrik polarizasyon (yatay-yatay (HH), yatay-düşey (HV), düşey-düşey (VV), düşey-yatay (VH)) sunan ALOS-2 PALSAR-2 verileri, Japonya Uzay Araştırma Ajansı'ndan (JAXA) temin edilmiştir. ALOS-2 PALSAR-2 görüntüsünün elde edilme tarihi 5 Ekim 2023'tür. Verilerin ön işlenmesi, veri doğruluğunu sağlamak için kalibrasyon, görüntü kalitesini artırmak amacıyla benek azaltma Lee filtresi uygulaması ve geometrik bozulmaları düzeltmek ve projeksiyon sistemini standartlaştırmak için ortorektifikasyon ve WGS84'e (EPSG:4326) projeksiyon dönüşümü gibi birkaç adım gerçekleştirilmiştir. 23 Ekim 2023 tarihli Sentinel-2 optik uydu görüntüsü (Seviye 2A) Avrupa Uzay Ajansı'ndan (ESA) Copernicus Açık Erişim Merkezi (<https://dataspace.copernicus.eu>) aracılığıyla ücretsiz olarak temin edilmiştir. Elde edilen optik görüntü, Seviye 2A işleme seviyesinde olduğundan, geometrik ve atmosferik düzeltmelerden geçmiş olup bantlar yüzey yansıma değerlerini içermektedir. Bu görüntü bantları ve radar polarizasyonlar için 10 metre çözünürlüğe yeniden örneklendirilmiştir. Ön işleme çalışmalarında ESA'nın SNAP programı kullanılmıştır. Bu çalışma için toplamda radar ve optik görüntüden toplamda 19 bileşen elde edilmiştir. Radar görüntüler için 4 polarizasyon, 2 adet RFDI ve RRVI radar bitki indisleri, optik görüntülerden 11 bant değeri (Bant 1 hariç), GNDVI ve NDI45 iki optik bitki örtüsü indeksi kullanılmıştır. Radar ve optik bitki indisleri Çizelge 1'de ayrıntılı olarak verilmiştir.

Çizelge.1 Radar ve Optik Bitki İndisleri

Veri Tipi	İndis Sayısı	İndis Adı	Ayrıntılar	Referanslar
Radar Bitki İndisleri	2	RFDI	Radar Forest Degradation Index ($\sigma^{\circ}HH - \sigma^{\circ}HV$) / ($\sigma^{\circ}HH + \sigma^{\circ}HV$)	Mithcard vd., 2012
		RRVI	Radar Ratio Vegetation Index ($\sigma^{\circ}HH / \sigma^{\circ}HV$)	Mithcard vd., 2011
Optik Bitki İndisleri	2	GNDVI	Green Normalized Difference Vegetation Index ($(B7 - B3) / (B7 + B3)$)	Buschmann ve Nagel, 1993
		NDI45	Normalized Difference Index 45 ($(B5 - B4) / (B4 + B4)$)	Delegido vd., 2011

Bu çalışmada, bileşenleri optimize etmek ve özellik seçimini iyileştirmek için model oluşturma sırasında gereksiz tahminicileri etkin bir şekilde tanımlayıp ortadan kaldıran LASSO (En Küçük Mutlak Büzülme ve Seçim Operatörü) ve aşırı uyumu önlemek için GridSearch 5 katlı Çapraz Doğrulama (CV) kullanılarak toplam 19 bileşenden en iyi 9 bileşen çıkarılmıştır. Uydu görüntülerinden elde edilecek yansıma değerlerinin çıkarılması sürecinde, örnekleme alanlarının merkez koordinatlarının metre altı GPS ile elde edilmesinden kaynaklanabilecek hatalar dikkate alınarak, merkez koordinat nokta verilerinden Quantum Geographic Information System (QGIS) 3.28 programı kullanılarak 5x5 m boyutunda kare maskeler oluşturulacaktır. Bu sayede, her bir alanın kapsadığı piksel değerlerinin ortalamaları

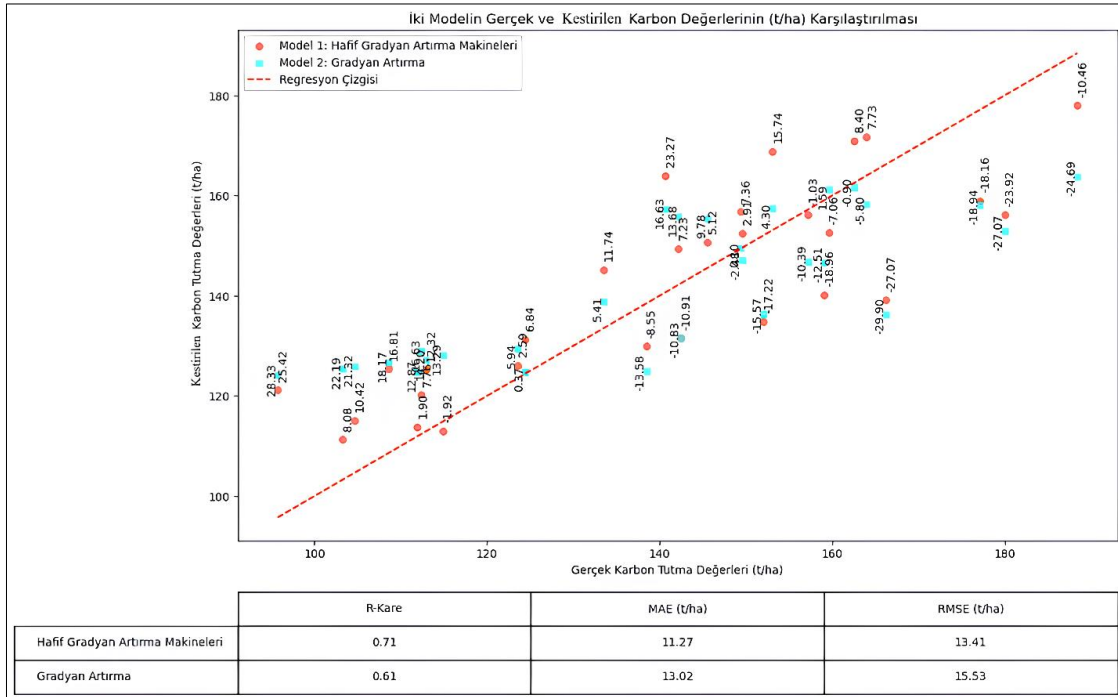
hesaplanarak yansıma değerleri elde edilecektir. Ayrıca, çalışmada kullanılacak bitki indekslerinin formülleri de programın hesaplama aracı olan bant aritmetiği ile belirlenecektir.

2.3 Makine Öğrenmesi Modelleri

Orman örtüsü ve TÜK kestirimi çalışmalarını gerçekleştirmek için yeni sınıflandırıcılar, regresyon veya optimizasyon algoritmaları tanıtılarak makine öğrenimi yöntemleri geliştirilmiştir. GA, Friedman (2001) tarafından geliştirilen, topluluk temelli karar ağaçları yöntemini kullanan popüler bir makine öğrenimi algoritmasıdır. GA modeli, ilk olarak eşit ağırlıklara sahip orijinal verilerden karar ağaçları oluşturur. Ardından, sonuç değerlendirilir ve sınıflandırılması zor olan değişkenlere daha yüksek ağırlık, kolay sınıflandırılan değişkenlere ise daha düşük ağırlık verilir. GA modeli, ek karar ağaçları kullanarak kestirim doğruluğunu artırır ve doğruluğu bir kayıp fonksiyonu kullanarak değerlendirir. Önemli olarak, GA algoritması kayıp fonksiyonunu optimize eder, zayıf bir denetimli öğrenici (karar ağacı) ile bir kestirim yapar ve ardından kayıp fonksiyonunu en aza indirmek için yeni karar ağaçları ekler. GA modelleri hem sınıflandırma hem de regresyon görevleri için karma veri türlerini işleyebilir. Bu teknikler genellikle özellik seçimi yapar ve aykırı değerlere karşı dayanıklıdır (Rao vd.,2019). Microsoft tarafından geliştirilen LightGBM, ağaç tabanlı öğrenme algoritmalarından biridir ve büyük veri setlerini hızlıca işleyerek kestirim performansını artırmak için tasarlanmıştır. Özellikle tablo verileri için uygundur. LightGBM, diğer yöntemlerden farklı olarak, kaybı daha etkin bir şekilde azaltan ve doğruluğu artıran yaprak bazlı bölme yöntemini kullanır. Bu yöntemle, küçük gradyanlara sahip veriler dışlanır ve kalan veriler bilgi kazancı tahmini ve ağaç büyümesi için kullanılır. Algoritma, Max_depth, Learning_rate ve gamma gibi Boosting parametreleri ile kayıp fonksiyonu türü, değerlendirme metriği ve yineleme sayısı gibi öğrenme görevi parametreleriyle kontrol edilir. Ağaç büyüdükçe model daha karmaşık hale gelir, ancak daha hızlı öğrenir ve seviye bazlı yaklaşıma göre daha fazla kayıp azaltılır (Pham vd., 2020; Tamiminia vd., 2021). Saha çalışmalarıyla elde edilen verilerin %70'i ise eğitim ve %30'i test verisine aktarılarak Python sci-kit learn kütüphanelerinden GA, LightGBM gibi makine öğrenme modelleri kullanılarak; TÜK kestirimi yapılacaktır.

3. BULGULAR VE TARTIŞMA

Bu çalışmada, ALOS-2 PALSAR-2 L-bandı tam polarimetrik radar, radar bitki indeksleri, Sentinel-2A optik verileri, bitki indeksleri, GA ve LightGBM makine öğrenimi yöntemleri kullanılarak TÜK kestirimi yapılmıştır. Özellik seçimi için LASSO yöntemi ile 19 bileşenden 9' u seçilmiş ve model hiper parametrelerinin optimizasyonu ile aşırı uyumun önlenmesi için GridSearchCV kullanılmıştır. LightGBM modeli, ALOS-2 PALSAR-2_VV + HV + VH + RRVİ radar bitki indeksi + Sentinel-2A Bant 11 + GNDVI bitki indeksi kombinasyonu ile TÜK kestiriminde en iyi performansı göstermiştir ($R^2=0,71$, RMSE=13,41 t/ha, MAE=11,27 t/ha) (Şekil 2).



Şekil.2 GA ve LightGBM makine öğrenmesi modellerinin gerçek ve kestirilen karbon tutma değerleri karşılaştırılması

Safari vd. (2017), İran'da meşe ağaçları üzerinde sadece Landsat 8 OLI optik görüntüler ve dört farklı makine öğrenmesi modeli kullanarak gerçekleştirdikleri TÜK kestirimi çalışmasında, RO modelinin en başarılı sonuçları elde ettiğini bildirmiştir (RMSE = %35, $R^2 = 0.65$). Morin vd. (2019), S1, S2 ve ALOS-2 PALSAR-2 kombinasyonlarının en iyi sonuçları sağladığını ve L-HV polarizasyonunun odun hacmine daha duyarlı olduğunu bulmuştur. Ayrıca, Omar vd. (2011) ve Bhavsar vd. (2024) çalışmaları HV polarizasyonunun biyokütle kestiriminde daha başarılı sonuçlar verdiğini belirtmiştir. Ancak, çalışmamızda HV polarizasyonuna ek olarak VH ve VV polarizasyonlarının birleşimi ile daha başarılı sonuçlar elde edilmiştir. Günlü ve Ercanlı (2020), Vatandaşlar ve Abdikan (2022) çalışmalarında ALOS HH polarizasyonunun biyokütle kestirimine pozitif yönde etkide bulunduğunu açıklamalarına rağmen, çalışmamızda negatif bir etki gözlemlenmiştir.

Yapılan testler, yalnızca radar veya optik görüntülerin biyokütle kestirimindeki etkisinin yetersiz olduğunu, ancak bu görüntülerin ikili kombinasyonlarının kestirimi önemli ölçüde iyileştirdiğini ortaya koymuştur. George-Chacón vd. (2021), Meksika tropik ormanlarında S2 ve ALOS PALSAR uydu görüntülerini kullanarak gerçekleştirdikleri TÜB kestirimi çalışmalarında, S2'nin ALOS'a kıyasla daha yüksek performans ($R^2 = 0.66$ ve $R^2 = 0.50$) gösterdiğini ve iki görüntü kombinasyonu ile makine öğrenmesi modelleri kullanarak en iyi sonucu ($R^2 = 0.70$) elde ettiklerini belirtmiştir. Pham vd. (2020), S1, S2 ve ALOS-2 PALSAR-2 verilerinin kombinasyonunun biyokütle kestiriminde umut verici bir doğruluk sağladığını ($R^2 = 0.68$) ve ALOS-2 PALSAR-2'nin önemli bir katkı sunduğunu ifade etmiştir; ancak çalışmamızda NDI45 radar bitki indeksinin sonuçları iyileştirdiği gözlemlenmiştir. Çalışmamızda radar bitki indeksi RRVI, TÜK kestiriminde R^2 değerinde olumlu bir artış (0.06) ve RMSE ile MAE değerlerinde ortalama bir azalma (1.2 – 2 t/ha) sağlamıştır. David vd. (2022), Afrika'nın güneydoğusundaki ormanlarda Sentinel-1 ve Sentinel-2 uydu görüntüleri ile 11 farklı bitki indeksinin biyokütle kestirimindeki etkilerini inceledikleri çalışmalarda, GNDVI bitki indeksinin biyokütle kestirimini olumlu yönde geliştirdiğini vurgulamıştır. Çalışmamızda da GNDVI bitki indeksi, tüm test bileşenlerinde kestirim doğruluğunu iyileştiren bir etki sağlamaktadır. Bui vd. (2024) ise, Vietnam'ın kuzeyindeki doğal ormanlarda Sentinel-1A, Landsat görüntüleri ve arazi verilerini kullanarak özellikle LightGBM modelinin ($R^2 \sim 0.79$, MAE ~ 10.62 t/ha) başarısını vurgulayarak, çalışmamıza benzer nitelikte yüksek doğrulukla sonuç veren bir orman biyokütlesi kestirim yöntemi geliştirmiştir.

4. SONUÇLAR

TÜK kestirimi yüksek doğruluk içermesi sebebiyle büyük ölçüde geleneksel yer tabanlı metodolojilere dayanmaktadır. Ancak uydu teknolojilerinin ortaya çıkışı, uzaktan algılama tekniklerini kullanan araştırmaların önemini önemli ölçüde artırmış ve bu tekniklerin yaygın olarak benimsenmesine yol açmıştır. TÜK'ün doğru ve zamanında hesaplanması, ormanların karbon döngüsündeki ve iklim değişikliğindeki rolünü daha iyi anlamak için kritik bir ihtiyaçtır. Bu nedenle, bu araştırma öncelikle çoklu uydu verilerinin, farklı makine öğrenmesi algoritmalarıyla entegrasyonunun, TÜK kestiriminin doğruluğunu artırma potansiyeline sahip olup olmadığını değerlendirmek amacıyla tasarlanmıştır. Çalışmamızda, LightGBM modelinin TÜK kestirimleri, gerçek TÜK değerlerine daha yakın sonuçlar verdiği gözlemlenmiştir. LightGBM'nin R^2 değeri, GA yöntemine kıyasla 0,10 daha yüksek bulunmuş olup, bu durum gerçek değerler ile kestirilen değerler arasında güçlü bir ilişki olduğunu göstermektedir. Tam polarizasyonlu L-bant ALOS-2 PALSAR-2 radar görüntü ve Sentinel-2A optik görüntü bant 11, RRVI radar bitki indeksi ve GNDVI optik bitki indeksi birleşiminin TÜK kestirimi için başarılı sonuçlar ürettiği gözlemlenmektedir ($R^2=0,71$, RMSE=13,41 t/ha, MAE=11,27 t/ha). Çalışmada, geleneksel yer tabanlı yöntemler genellikle maliyetli ve zaman alıcı olduğundan, pratik alternatif yaklaşımlara olan ihtiyaç vurgulanmaktadır. Sonuçlar, uzaktan algılama sistemleri ve yöntemlerinin bu zorluğa yönelik umut verici çözümler sunduğunu ortaya koymaktadır.

5. TEŞEKKÜR

Bu çalışma, birinci yazarın doktora tez araştırmasının bir parçası olup Hacettepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından FDK-2022-20004 proje kodu ile desteklenmiştir. Yazarlar, ER3A2N113 proje numarası kapsamında tam polarimetrik ALOS-2/PALSAR-2 verilerini sağlayan Japonya Uzay Araştırmaları Ajansı'na (JAXA) ve Sentinel-2 verilerini ücretsiz olarak sunan Avrupa Uzay Ajansı (ESA) Copernicus Açık Erişim Merkezi'ne teşekkür ederler.

KAYNAKÇA

Agata, H., Aneta, L., Dariusz, Z., Krzysztof, S., Marek, L., Christiane, S. ve Carsten, P., 2018. Forest Aboveground Biomass Estimation Using a Combination of Sentinel-1 and Sentinel-2 Data. *IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*, 9026-9029.

Baccini, A., Walker, W., Carvalho, L., Farina, M., Sulla-Menashe, D. ve Houghton, R. A., 2017. Tropical forests are a net carbon source based on aboveground measurements of gain and loss. *Science*, 358(6360), 230-234.

- Batar, A. K., Watanabe, T. ve Kumar, A.,** 2017. Assessment of Land-Use/Land-Cover Change and Forest Fragmentation in the Garhwal Himalayan Region of India. *Environments*, 4(2).
- Bhavsar, D., Das, A.K., Chakraborty, K., Patnaik, C., Sarma, K.K. ve Aggrawal, S.P.,** 2024. Above Ground Biomass Mapping of Tropical Forest of Tripura Using EOS-04 and ALOS-2 PALSAR-2 SAR Data. *Journal of the Indian Society of Remote Sensing*.
- Bui, Q.-T., Pham, Q.-T., Pham, V.-M., Tran, V.-T., Nguyen, D.-H., Nguyen, Q.-H., Nguyen, H.-D., Do, N. T. ve Vu, V.M.,** 2024. Hybrid machine learning models for aboveground biomass estimations. *Ecological Informatics*, 79, 102421.
- Buschmann, C. ve Nagel, E.,** 1993. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. *International Journal of Remote Sensing*, 14(4), 711–722.
- Cartus, O., Santoro, M., Wegmüller, U. ve Rommen, B.,** 2019. Benchmarking the Retrieval of Biomass in Boreal Forests Using P-Band SAR Backscatter with Multi-Temporal C- and L-Band Observations. *Remote Sensing*, 11(14).
- Chen, M., Qiu, X., Zeng, W. ve Peng, D.,** 2022. Combining Sample Plot Stratification and Machine Learning Algorithms to Improve Forest Aboveground Carbon Density Estimation in Northeast China Using Airborne LiDAR Data. *Remote Sensing*, 14(6).
- Chen, L., He, A., Xu, Z., Li, B., Zhang, H., Li, G., Guo, X. ve Li, Z.,** 2024. Mapping aboveground biomass of Moso bamboo (*Phyllostachys pubescens*) forests under Pantana *phyllostachysae* Chao-induced stress using Sentinel-2 imagery. *Ecological Indicators*, 158, 111564.
- Cheng, F., Ou, G., Wang, M. ve Liu, C.,** 2024. Remote Sensing Estimation of Forest Carbon Stock Based on Machine Learning Algorithms. *Forests*, 15(4).
- David, R.M., Rosser, N.J. ve Donoghue, D.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.
- Delegido, J., Verrelst, J., Alonso, L. ve Moreno, J.,** 2011. Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors*, 11(7), 7063–7081.
- Dixon, R. K., Brown, S., Houghton, R. A., Solomon, A. M., Trexler, M. C. ve Wisniewski, J.,** 1994. Carbon Pools and Flux of Global Forest Ecosystems. *Science*, 263(5144), 185-190.
- Dou, X., Yang, Y. ve Luo, J.,** 2018. Estimating Forest Carbon Fluxes Using Machine Learning Techniques Based on Eddy Covariance Measurements. *Sustainability*, 10(1).
- Forrester, D. I., Tachauer, I. H. H., Annighoefer, P., Barbeito, I., Pretzsch, H., Ruiz-Peinado, R., Stark, H., Vacchiano, G., Zlatanov, T., Chakraborty, T., Saha, S. ve Sileshi, G. W.,** 2017. Generalized biomass and leaf area allometric equations for European tree species incorporating stand structure, tree age and climate. *Forest Ecology and Management*, 396, 160-175.
- Friedman, J. H.,** 2001. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232.
- George-Chacón, S. P., Milodowski, D. T., Dupuy, J. M., Mas, J. F., Williams, M., Castillo-Santiago, M. A. ve Hernández-Stefanoni, J. L.,** 2021. 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.
- Gibbs, H. K., Brown, S., Niles, J. O. ve Foley, J. A.,** 2007. Monitoring and estimating tropical forest carbon stocks: Making REDD a reality. *Environmental Research Letters*, 2(4), 045023.
- Guner, S. T. ve Comez, A.,** 2022. Carbon Concentration in Tree Components of Mature *Pinus brutia* Ten. Forests in the Marmara Transition Zone. *Kastamonu University Journal of Forestry Faculty*, 22(3), 193-201.
- Güner, Ş. T.,** 2019. Changes in carbon concentration of tree components for Kazdag fir *Abies nordmanniana* subsp. *equi-trojani* forests. *Fresenius Environmental Bulletin*, 28(1), 116-123.

- Güner, Ş.T., Kiracioğlu, Ö. ve Sarimehmetoğlu, A.,** 2024. Changes in carbon stocks according to stand development stages in oriental beech forests in the Marmara Region of Türkiye. *Environmental Monitoring and Assessment*, 196, 571.
- Günlü, A. ve Ercanlı, İ.,** 2020. Artificial neural network models by ALOS PALSAR data for aboveground stand carbon predictions of pure beech stands: A case study from northern of Turkey. *Geocarto International*, 35(1), 17-28.
- IPCC.,** 2013. Revised supplementary methods and good practice guidance arising from the Kyoto protocol, Intergovernmental Panel on Climate Change.
- IPCC.,** 2023. Summary for Policymakers. In Core Writing Team, H. Lee, & J. Romero (Eds.), *Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (pp. 1-34).
- Karabürk, T.,** 2011. Bartın İli Göknaar Meşcerelerinin Biyokütle Tablolarının Düzen-lenmesi. Bartın Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi. (Estimation of Biomass Tables of Fir Stands in Bartın. Bartın University, Graduate School of Natural and Applied Sciences, M.Sc. Thesis.) Bartın.
- Kaya, S.,** 2024. Batı Karadeniz Bölgesindeki doğu kayını ormanlarında ağaç bileşenlerine ait karbon yoğunluklarının değişimi. Tübitak 2209-A Proje Sonuç Raporu. Proje Nu: 1919B012222516. 11 s. Bartın.
- Li, Y., Li, M., Li, C. ve Liu, Z.,** 2020. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. *Scientific Reports*, 10(1), 9952.
- Lu, D. S.,** 2006. The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing*, 27(7), 1297-1328.
- McGroddy, M., Daufresne, T. ve Hedin, L.,** 2004. Scaling of C: Nstoichiometry in forests worldwide: implications of terrestrial Redfield-type ratios. *Ecology*, 85(9), 2390-2401.
- Mitchard, E., Saatchi, S., Lewis, S., Feldpausch, T., Woodhouse, I., Sonk, B., Rowland, C. ve Meir, P.,** 2011. Measuring biomass changes due to woody encroachment and deforestation/degradation in a forest-savanna boundary region of central Africa using multi-temporal L-band radar backscatter. *Remote Sensing of Environment*, 115(11), 2861-2873.
- Mitchard, E. T. A., Saatchi, S. S., White, L. J. T., Abernethy, K. A., Jeffery, K. J., Lewis, S. L., Collins, M., Lefsky, M. A., Leal, M. E., Woodhouse, I. H. ve Meir, P.,** 2012. Mapping tropical forest biomass with radar and spaceborne LiDAR in Lope National Park, Gabon: Overcoming problems of high biomass and persistent cloud. *Biogeosciences*, 9(1), 179-191.
- Morin, D., Planells, M., Guyon, D., Villard, L., Mermoz, S., Bouvet, A., Thevenon, H., Dejoux, J.-F., Le Toan, T. ve Dedieu, G.,** 2019. Estimation and Mapping of Forest Structure Parameters from Open Access Satellite Images: Development of a Generic Method with a Study Case on Coniferous Plantation. *Remote Sensing*, 11(11), 1275.
- Neumann, M., Moreno, A., Mues, V., Härkönen, S., Mura, M., Bouriaud, O., Lang, M., Achten, W. M. J., Thivolle-Cazat, A., Bronisz, K., Merganič, J., Decuyper, M., Alberdi, I., Astrup, R., Mohren, F. ve Hasenauer, H.,** 2016. Comparison of carbon estimation methods for European forests. *Forest Ecology and Management*, 361, 397-420.
- Lamloom, S.H. ve Savidge, R.A.,** 2003. A reassessment of carbon content in wood: variation within and between 41 North American species. *Biomass and Bioenergy*, 25, 381-388.
- Omar, H., Khali, H., & Kassim, A. R.** 2011. Remotely sensed L-band sar data for tropical forest biomass estimation. *Journal of Tropical Forest Science*, 23, 318-327.
- Özdemir, E. G. ve Abdikan, S.,** 2024. The Estimation of Forest Aboveground Biomass Using Multiple Satellite Data and Different Machine Learning Models. Presented at the 32nd Signal Processing and Communications Applications Conference (SIU), Mersin.
- Pham, T. D., Yokoya, N., Xia, J., Ha, N. T., Le, N. N., Nguyen, T. T. T., Dao, T. H., Vu, T. T. P., Pham, T. D. ve 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.

Rao, H., Shi, X., Rodrigue, A. K., Feng, J., Xia, Y., Elhoseny, M., Yuan, X. ve Gu, L., 2019. Feature selection based on artificial bee colony and gradient boosting decision tree. *Applied Soft Computing*, 74, 634–642.

Safari, A., Sohrabi, H., Powell, S. ve Shataee, S., 2017. A comparative assessment of multi-temporal Landsat 8 and machine learning algorithms for estimating aboveground carbon stock in coppice oak forests. *International Journal of Remote Sensing*, 38(22), 6407–6432.

Tamiminia, H., Salehi, B., Mahdianpari, M., Beier, C. M., Johnson, L. ve Phoenix, D. B., 2021. A comparison of random forest and light gradient boosting machine for forest above-ground biomass estimation using a combination of Landsat, ALOS PALSAR, and airborne LiDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIV-M-3-2021, 163–168.

Thomas, S.C. ve Malczewski, G., 2007. Wood carbon content of tree species in Eastern China: Interspecific variability and the importance of the volatile fraction. *Journal of Environmental Management*, 85, 659-662.

Vatandaslar, C. ve 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*, vol.33, no.3, 827-838.