Bartın Orman Fakültesi Dergisi | Journal of Bartin Faculty of Forestry
2025, 27(3): 445 – 463 | DOI: 10.24011/barofd.1798937

Orman Ekosistemlerinde Hava Tabanlı LiDAR ile Toprak Üstü Karbon Stoklarının Tahmini

Tufan Demirel[1*]

[1] İstanbul Üniversitesi-Cerrahpaşa, Orman Fakültesi, Orman Mühendisliği Bölümü, İstanbul, Türkiye

Makale Tarihçesi
Gönderim: 07.10.2025
Kabul: 18.11.2025
Yayım: 15.12.2025

Araştırma Makalesi

Öz – Küresel iklim değişikliği, atmosferdeki karbondioksit (CO_2) ve diğer sera gazlarının hızla artışıyla ekosistemlerde geri dönüşü zor değişimlere yol açmakta, orman ekosistemleri ise bu süreçte karasal karbon yutakları olarak kritik bir rol üstlenir. Orman karbonu, REDD+ ve diğer iklim değişikliğiyle mücadele programlarının temel bileşenini oluşturmakta ve karbon tutma miktarının doğru biçimde hesaplanması, iklim değişikliği stratejilerinin etkinliğini doğrudan etkilemektedir. Geleneksel arazi tabanlı ölçümler, geniş alanlarda uygulanması güç, maliyetli ve orman yapısındaki heterojenliği tam olarak temsil edememeleri nedeniyle sınırlı kalmaktadır. Bu nedenle, uzaktan algılama teknikleri, özellikle LiDAR (Light Detection and Ranging) sistemi, orman yapısını üç boyutlu olarak incelemede giderek daha fazla önem kazanmaktadır. Bu çalışmada, İstanbul Üniversitesi-Cerrahpaşa Orman Fakültesi Araştırma Ormanı'nda 86 örnek alanda yapılan arazi ölçümleri kullanılarak toprak üstü karbon (TÜK) tahmini gerçekleştirilmiştir. ALS (Airborne Laser Scanning) verilerinden türetilen 101 yapısal metrik incelenmiş, yüksek korelasyonlu değişkenler elenerek 25 belirleyici metrik seçilmiştir. Random Forest regresyon modeli ve leave-one-out cross-validation (LOOCV) yöntemi ile TÜK tahminleri yapılmıştır. Model, belirtme katsayısı (R^2) = 0,76, kök ortalama kare hata (RMSE) = 4,25 ton C/ha ve ortalama mutlak hata (MAE) = 3,48 ton C/ha performans değerleri ile yüksek doğruluk göstermiştir. Değişken önem analizi, yükseklik yüzdelikleri ve canopy relief ratio (CRR) gibi dikey yapı heterojenliğini temsil eden metriklerin TÜK tahmininde en etkili değişkenler olduğunu ortaya koymuştur. Elde edilen sonuçlar, ALS verisinin farklı meşcere tipleri ve topoğrafik heterojenlik gösteren ormanlarda bile TÜK tahmininde güvenilir bir araç olduğunu doğrulamaktadır. Özellikle yükseklik, örtü kapanma oranı ve dikey yapı heterojenliğini temsil eden metrikler, karbon stoklarının doğru modellenmesinde kritik rol oynamaktadır. Elde edilen sonuçlar, havasal LiDAR verisinin bölgesel ve ulusal ölçekte karbon haritalaması ile iklim değişikliğiyle mücadele stratejilerinin geliştirilmesinde güvenilir bir yöntem sunduğunu göstermektedir.

Anahtar Kelimeler – *İklim Değişikliği, random forest, orman karbonu*

Aboveground Carbon Stock Estimation Using Airborne LiDAR in Forest Ecosystems

[1] Istanbul University-Cerrahpaşa, Faculty of Forestry, Department of Forest Engineering, İstanbul, Türkiye

Article History
Received: 07.10.2025
Accepted: 18.11.2025
Published: 15.12.2025

Research Article

Abstract – Global climate change, driven by the rapid increase of carbon dioxide (CO_2) and other greenhouse gases in the atmosphere, is causing profound and often irreversible shifts in ecosystems, with forest ecosystems playing a critical role as terrestrial carbon sinks. Forest carbon is a central component of REDD+ and other climate change mitigation programs, and accurate estimation of carbon sequestration is essential for the effectiveness of these strategies. Traditional field-based measurements are often costly, difficult to implement across large areas, and limited in capturing the heterogeneous structure of forests. Consequently, remote sensing technologies, particularly LiDAR (Light Detection and Ranging), have emerged as powerful tools for detailed three-dimensional characterization of forest structure. In this study, terrestrial measurements from 86 sample plots in the Istanbul University-Cerrahpaşa Faculty of Forestry Research Forest were used to estimate aboveground carbon (AGC). A total of 101 structural metrics derived from airborne laser scanning (ALS) data were analyzed, and highly correlated variables were removed, resulting in 25 key predictors. Random Forest regression, combined with leave-one-out cross-validation (LOOCV), was employed to predict AGC. The model achieved high accuracy with R^2 = 0.76, RMSE = 4.25 ton C/ha, and MAE = 3.48 ton C/ha. Variable importance analysis revealed that height percentiles and canopy relief ratio (CRR), representing vertical structural heterogeneity, were the most influential predictors for AGC estimation. The results demonstrate that ALS data provide a reliable tool for estimating AGC even in forests with diverse stand types and topographic variability. In particular, metrics representing canopy height, canopy cover, and vertical structural complexity are critical for accurate carbon stock modeling. These findings provide a reliable and practical approach for regional and national-scale carbon mapping and support the development of climate change mitigation strategies.

Keywords – *Climate Change, random forest, forest carbon*

[1] tufan.demirel@iuc.edu.tr
*Sorumlu Yazar / Corresponding Author

1. Giriş

Küresel ısınmaya paralel olarak gelişen küresel iklim değişikliği doğal kaynak yönetiminin karşılaştığı en önemli sorunlarından biridir. Sanayi devriminden sonra artan fosil yakıt kullanımı ile arazi kullanımı ve örtüsündeki değişimler, atmosferdeki sera gazı birikimini hızlandırmıştır (Soeder, 2021). Bu durum atmosferdeki karbondioksit (CO_2) miktarlarında artışa ve ekosistemlerde geri dönüşü zor yapısal değişimlerin yaşanmasına neden olmuştur (Friedlingstein vd., 2022). Ormanlar, karasal ekosistemlerdeki en büyük karbon havuzları olarak atmosferdeki CO_2'yi emme ve tutma yeteneğine sahiptir (Fang vd., 2014; Mitchard vd., 2018). Orman karbonu, ormanların korunması ve sürdürülebilir orman yönetimini amaçlayan REDD+ (Reducing Emissions from Deforestation and Forest Degradation) gibi küresel programlarının temel bileşenidir (Lederer, 2012). Bu bağlamda, karasal ekosistemlerin karbon döngüsündeki rolünün doğru anlaşılması ve karbon tutma miktarının güvenilir şekilde hesaplanması iklim değişikliğiyle mücadele açısından kritik bir ihtiyaçtır (Sokolov vd., 2008; Pan vd., 2011).

Orman ekosistemleri, karasal biyosferin en önemli karbon yutaklarıdır. Fotosentez yoluyla atmosferden CO_2 çekerek kök, gövde, dal ve yapraklarında karbon depolayan orman ekosistemleri, küresel karbon dengesinin korunmasında kilit bir rol oynamaktadır (Bonan, 2008; Keith vd., 2009). Orman ekosistemlerinde toplam karbon havuzunun büyük bir bölümünü toprak üstü bileşenler oluşturur (Dixon vd., 1994). Bu nedenle, ormanlarda toprak üstü karbon (TÜK) miktarlarının doğru ve güvenilir biçimde belirlenmesi ve tahmin edilmesi, hem ulusal sera gazı envanterleri (IPCC, 2006) hem de REDD+ gibi karbon yönetimi mekanizmaları açısından temel bir gerekliliktir (Gibbs vd., 2007).

Orman ekosistemlerinde karbon stoklarının belirlenmesinde geleneksel olarak arazi ölçümlerine dayalı yöntemler kullanılmaktadır. Bu yöntemler, tür, gövde çapı ve ağaç boyu gibi parametrelere dayalı allometrik denklemler aracılığıyla karbon miktarını tahmin etmektedir (Brown, 1997; Chave vd., 2005). Ancak geniş alanlarda uygulandığında bu yöntemler hem zaman alıcı hem de maliyetlidir; ayrıca orman yapısındaki mekânsal heterojenliği yeterince temsil edememektedir (Clark ve Kellner, 2012; Picard vd., 2012). Bu sınırlamalar, karbon stoklarının geniş alanlarda doğru ve etkin biçimde tahmin edilebilmesi için uzaktan algılama tekniklerine duyulan ihtiyacı artırmaktadır.

Son yıllarda, uzaktan algılama teknolojilerinin karbon stok tahmininde kullanımına yönelik araştırmalar dikkate değer bir ivme kazanmıştır. Optik sensörler geniş alanlarda düşük maliyetli veri sağlayabilmeleri açısından avantajlıdır. Ancak bu pasif uzaktan algılama verilerini kullanan çalışmalar, genellikle bitki indekslerini kullanır ve yüksek karbon yoğunluklarının bulunduğu alanlarda doygunluk sorunları ile karşı karşıya kalmaktadır (Asner, 2009). Bununla birlikte, bu pasif sensörlerden elde edilen orman karbonu ve biyokütle tahminleri, görece düşük miktarlarda orman biyokütlesi ve karbonu için doğru sonucu verebilmektedir (Laurin vd., 2016; Shi vd., 2024; Wigneron vd., 2024)

RADAR (Radio Detection and Ranging) ve LiDAR (Light Detection and Ranging) gibi aktif uzaktan algılama teknolojileri, biyokütle ve karbon tahmininde pasif optik teknolojilere göre önemli avantajlar sunmaktadır (Le Toan vd., 2004; Sinha vd., 2015; Lu vd., 2016). Bu teknolojiler orman örtüsünü daha derinlemesine nüfuz ederek, orman yapısı hakkında daha fazla bilgi toplanmasını sağlar. RADAR sistemleri bulut örtüsünden bağımsız veri toplayabilme özelliğiyle öne çıkmakta; ancak yoğun orman örtüsünün hâkim olduğu ekosistemlerdeki karbon tahmininde küresel sensör mevcudiyetinin yetersiz olması gibi belirli sınırlılıklar taşımaktadır (Mitchard vd., 2009; Le Toan vd., 2011).

LiDAR, mobil/sabit yer tabanlı sistemlerden uydu tabanlı sistemlere kadar çeşitli platformlardan çalışabilir (Wulder vd., 2013; Valbuena vd., 2020; Lin vd., 2022). Havasal LiDAR (ALS) verileri, yoğun bitki örtüsünü penetrasyon yetenekleri nedeniyle TÜK tahmininde sıkça kullanılmaktadır. ALS sistemleri dikey orman yapısının ayrıntılı biçimde tanımlayabilme kapasitesi sayesinde karbon stoklarının belirlenmesinde etkili teknolojilerden biri olarak öne çıkmaktadır (Asner, 2009; Hudak vd., 2012; White vd., 2018; Li vd., 2024). Özellikle orman amenajmanı, arazi modeli oluşturma ve çeşitli ekolojik uygulamalarda ALS yoğun biçimde

tercih edilmekte ve kullanım alanını hızla genişletmektedir. Günümüzde ALS, orman biyokütlesi ve karbonu tahminlerinde başvurulan temel yöntemlerden biri olarak kabul edilmektedir.

ALS sistemlerinden elde edilen metrikler (yükseklik yüzdelikleri, nokta yoğunluk dağılımları, spektral yoğunluk ve taç örtüsü oranları vb.), orman yapısını ayrıntılı olarak temsil etmekte ve toprak üstü karbon ile güçlü ilişkiler kurabilmektedir. Stephens vd. (2012), Yeni Zelanda ormanlarında ALS verisiyle karbon miktarını %74 açıklayıcılık ile modellemiştir. Saatchi vd. (2011) ise ALS ve optik verileri entegre ederek Amazon havzasında bölgesel karbon stok haritaları üretmiştir. Liu ve Shao (2012), ALS verilerinin orman karbon depolama miktarlarının güvenilir biçimde tahmin edilmesini sağladığını belirtmiştir. Silva vd. (2013), okaliptüs plantasyonlarında yürüttükleri bir çalışmada, ALS verilerinden türetilen 68 değişkene dayalı olarak çoklu doğrusal regresyon temelli bir karbon stok modeli geliştirmiştir. Nihai model, nokta bulutundan elde edilen yükseklik ve yansıma yoğunluğu (intensity) ile ilişkili altı değişken üzerine kurulmuş ve oldukça yüksek bir performans sergilemiştir ($R^2 = 0.93$).

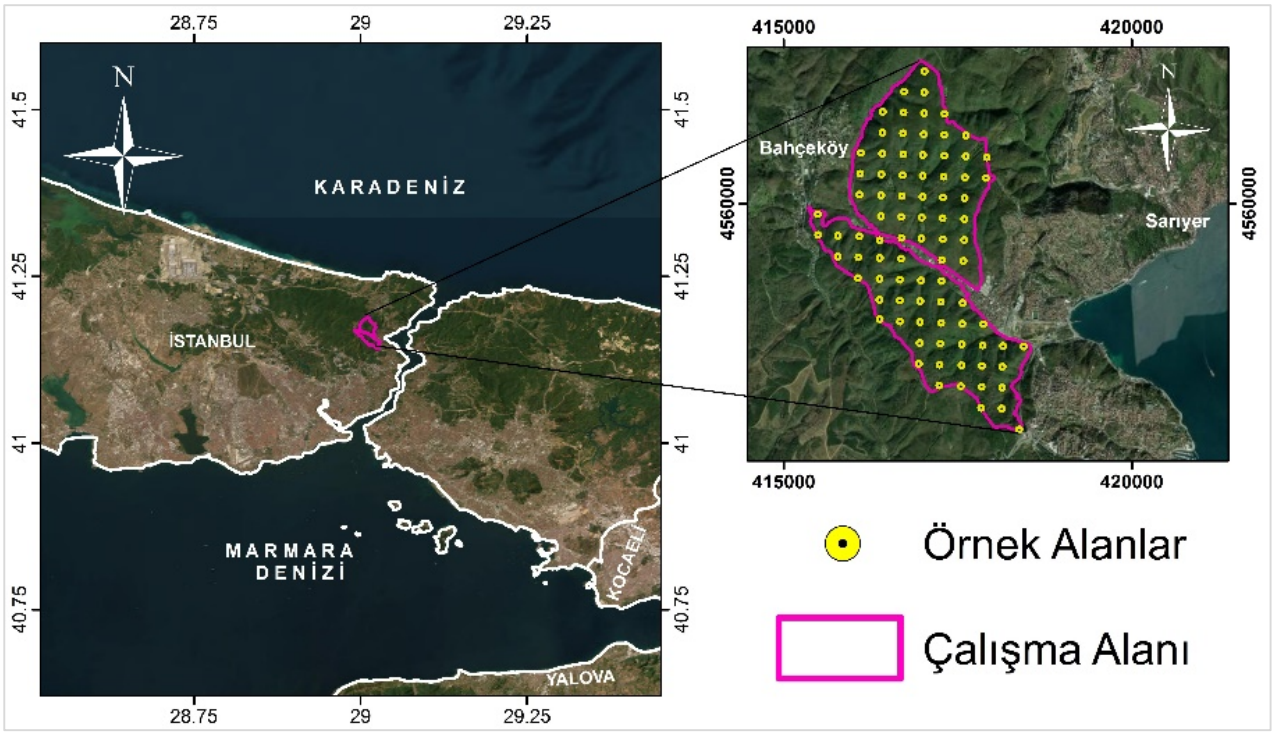
Yakın dönemde yapılan araştırmalar da ALS verisinin farklı ekosistemlerdeki potansiyelini doğrulamaktadır. Örneğin Strîmbu vd. (2023), Norveç boreal ormanlarında tekrarlanan orman envanterleri ile ALS verilerini birleştirerek toprak üstü ve toprak karbonundaki değişimleri yüksek doğrulukla tahmin etmiştir. Liu vd. (2024), Çin'de ALS metrikleri üzerinde özellik seçimi (feature screening) yöntemlerini uygulayarak karbon stok tahmin modelleri geliştirmiştir. Japonya'da yürütülen geniş ölçekli bir çalışmada ise ALS, Sentinel-2 ve PALSAR-2 verileri entegre edilerek yüksek çözünürlüklü karbon stok haritaları üretilmiş ve belirsizlik değerlendirmesi yapılmıştır (Li vd., 2024). Yine Çin'in Wuyishan Ulusal Parkı'nda gerçekleştirilen çalışmada, farklı orman tipleri ve dikey zonlarda UAV-LiDAR verileri kullanılarak karbon stoklarının mekânsal dağılımı incelenmiş, model doğrulukları $R^2 = 0.84$ seviyesine ulaşmıştır (Jian vd., 2025).

Bu çalışmanın amacı, hava tabanlı LiDAR (ALS) verilerinden türetilen metrikler ile ormanlarda toprak üstü karbon stokları arasındaki ilişkileri istatistiksel modeller aracılığıyla belirlemektir. Bu kapsamda, ALS metrikleri ile arazi ölçümlerine dayalı karbon stokları arasındaki ilişkiler incelenmiş, uygun modeller geliştirilerek tahmin performansları değerlendirilmiştir. Böylece, orman ekosistemlerinde karbon stoklarının doğru, hızlı ve geniş ölçekli biçimde tahmini için uygulanabilir bir yaklaşım ortaya konulması hedeflenmektedir.

2. Materyal ve Metot

2.1. Çalışma Alanı

Bu çalışma, İstanbul ili Sarıyer ilçesi sınırlarında yer alan ve Bahçeköy–Çayırbaşı yolu boyunca iki ayrı parçadan oluşan İstanbul Üniversitesi-Cerrahpaşa (İÜC) Orman Fakültesi Eğitim ve Araştırma Ormanı'nda yürütülmüştür (Şekil 1). Plan ünitesinin toplam alanı 748,20 ha olup, kuzey parça 393,56 ha, güney parça ise 354,62 ha büyüklüğe sahiptir. Her iki parça da İstanbul Üniversitesi-Cerrahpaşa Rektörlüğü mülkiyetinde olup, alanın 698 ha'sı orman, 50,2 ha'sı ormansız alan olarak sınıflandırılmaktadır. Çalışma alanı, 28° 59′ 17″ – 29° 32′ 25″ doğu boylamları ile 41° 09′ 15″ – 41° 11′ 01″ kuzey enlemleri arasında konumlanmakta olup, yükselti 10 m ile 237 m (Büyükdoğan Tepe) arasında değişen dalgalı bir topoğrafya sergilemektedir. Boğaz platosunun derin yarıklar ve sırtlarla parçalanmış yapısı, yükselti ve bakı farklılıkları, İstanbul Boğazı çevresinde belirgin mikroklimatik tiplerin oluşmasına neden olmaktadır. Bu topoğrafik heterojenlik, çalışma alanı içinde ısı, nem ve rüzgâr şiddeti açısından önemli yerel farklılıklar yaratmaktadır.

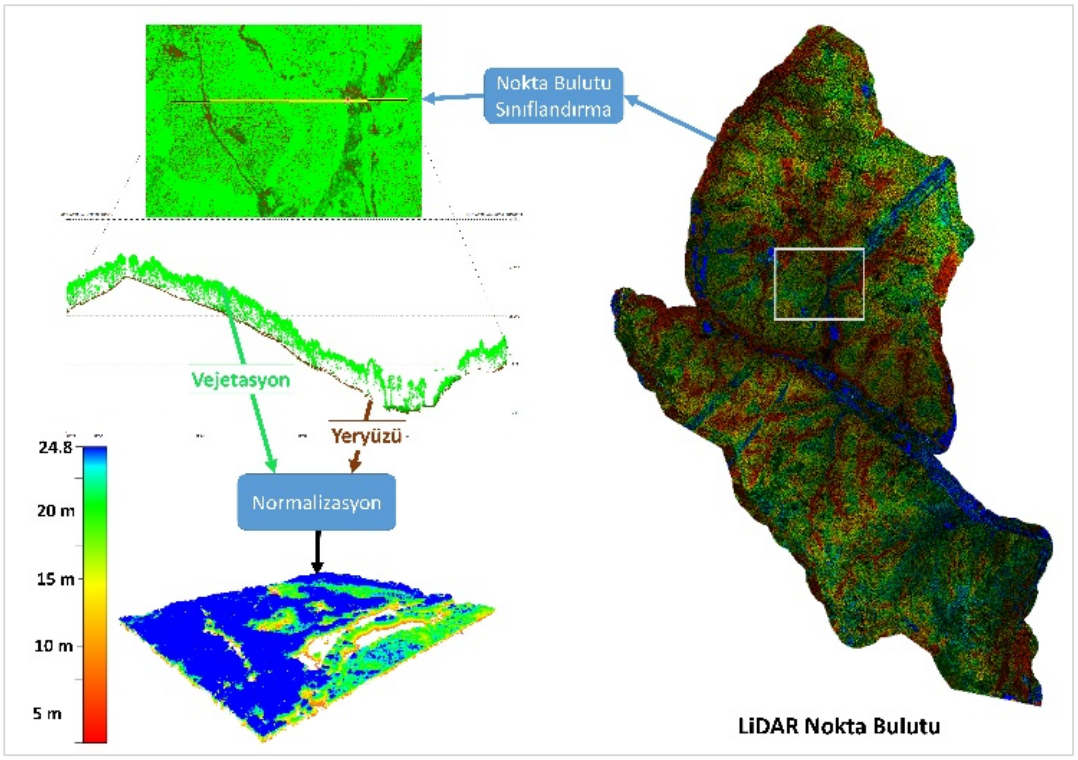


Şekil 1. Çalışma alanı

Çalışma alanı, Marmara Bölgesi'nin karakteristik iklim özelliklerini taşımakta olup, yazlar sıcak ve kurak, kışlar ılıman ve yağışlıdır. Yıllık yağış ortalaması 1129,4 mm olup, bunun yaklaşık %52'si vejetasyon dönemi (Nisan–Kasım) içinde gerçekleşmektedir. Bölgede Akdeniz ve Karadeniz iklimleri arasında geçiş niteliği bulunmakta, kuzey-güney ve doğu-batı yönlerinde mikroklimatik farklılıklar gözlenmektedir. Araştırma alanında ormanlar, Mayer'ın orman zonları taksimatına göre Cestanetum'un serin yarısı, Fagetum'un sıcak yarısı ve Quercetum'un optimum zonunda yer almaktadır. Çalışma alanının meşcere yapısı, tek türden oluşan veya farklı türlerin karışımı şeklinde çeşitlilik göstermektedir. Hakim türler arasında meşe, gürgen, kestane, yalancı akasya, ıhlamur, fıstıkçamı ve karaçam yer almakta, bunların farklı kombinasyonlarını içeren karışık meşcereler de yaygın olarak bulunmaktadır. Çalışma alanının mikroklimatik ve topoğrafik heterojenliği ile zengin orman kompozisyonu, çalışmanın biyolojik ve ekolojik süreçlerin değerlendirilmesi açısından yüksek temsil kapasitesine sahip olduğunu göstermektedir.

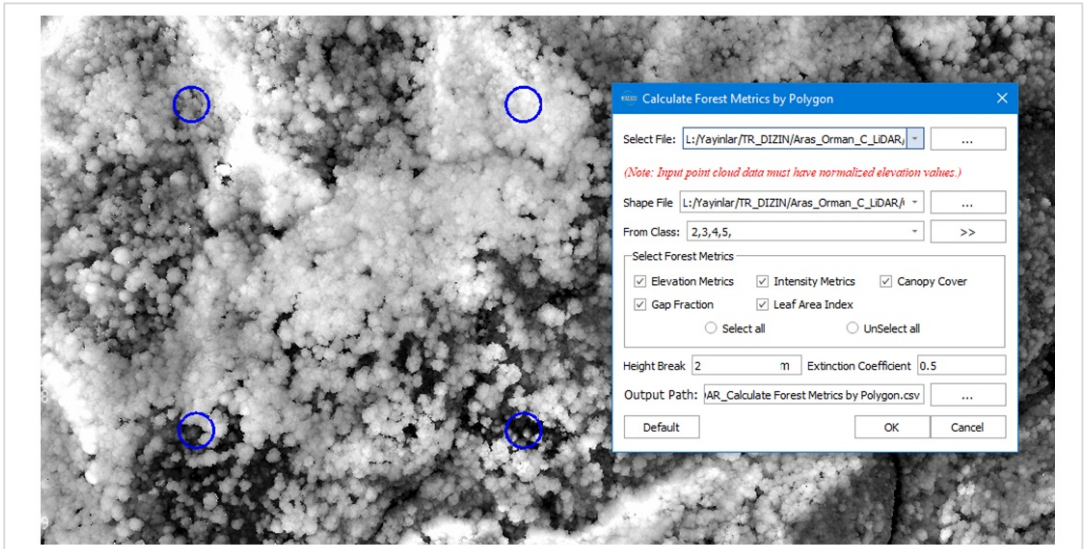
2.2. Hava Tabanlı LiDAR Verisi

LiDAR, orman örtüsüne nüfuz ederek taç yüksekliği, taç örtüsü ve taç yapısı gibi üç boyutlu orman parametrelerini doğrudan ölçebilen aktif bir uzaktan algılama teknolojisidir. Bu çalışmada, 12 nokta/m² yoğunluk ve her darbe için 7 geri dönüş sağlayan bir nokta bulutu kullanılmıştır. Veri toplama işlemleri 22 Temmuz 2018'de LMS-Q680i havasal LiDAR (ALS) sensörü ile gerçekleştirilmiş, uçak 400 kHz darbe frekansı, 720 m irtifa ve 100 knot hız ile uçurulmuştur. Nokta bulutu verileri, gürültü temizleme, filtreleme ve normalizasyon olmak üzere üç aşamalı bir ön işleme tabi tutulmuştur. İlk adımda, kuş veya sis gibi aykırı noktalar çıkarılmış; ikinci adımda IPTD (Iterative Point-based Terrain Detection) algoritması ile yer ve vejetasyon geri dönüşleri ayrıştırılmış; üçüncü adımda ise yükseklikler normalize edilerek topografyanın etkisi giderilmiştir (Şekil 2).



Şekil 2. Havasal LiDAR veri işleme

Her bir örnek alan için merkez koordinatlar yardımıyla nokta bulutları örnek alan büyüklüklerine göre kırpılmıştır. Çalı ve otsu bitki örtüsünü ayırmak amacıyla 2 m yükseklik eşiği uygulanmış, bunun altındaki geri dönüşler gürültü olarak sınıflandırılmıştır. ALS verilerinden orman yapısal metriklerinin türetilmesi amacıyla LiDAR360 yazılımı (Green Valley International, 2023) kullanılmıştır. Poligon bazında orman metriklerinin hesaplanması için yazılımda "Poligon Bazlı Orman Metrikleri Hesaplama" (Calculate Forest Metrics by Polygon) aracı tercih edilmiştir.



NO	CanopyCover	GapFraction	LAI	elev_aad_z	elev_canopy_relief_ratio	elev_AIH_1st	elev_AIH_5th	elev_AIH_10th	elev_AIH_20th	.....
44	0.950436	0.049564	10.67255	2.752496	6.133282	2.419999	3.29	4.04	5.179999	.....
45	0.961538	0.038462	11.62621	3.087577	7.963528	2.37	3.570001	4.829999	6.329999	.....
46	0.901411	0.098589	5.682578	2.457267	8.540785	2.53	3.98	6.19	8.160001	.....
48	0.849983	0.150017	7.065516	2.373223	7.904208	2.23	3.249999	4.669999	7.749999	.....
49	0.751872	0.248128	2.589887	6.099613	11.445868	2.099999	2.429999	3.749999	6.52	.....
:	:	:	:	:	:	:	:	:	:	.....
:	:	:	:	:	:	:	:	:	:	.....

Şekil 3. ALS verilerinden orman yapısal metriklerinin türetilmesi

ALS nokta bulutu verilerinden türetilen yükseklik metrikleri, istatistiksel parametreler olarak tahmin modellerinde bağımsız değişkenler şeklinde kullanılmaktadır. Bu çalışmada, yükseklikle ilişkili 46 ve nokta bulutu yoğunluğu ile ilişkili 10 parametre hesaplanmıştır. Hesaplanan metrikler arasında maksimum, minimum, ortalama ve medyan yükseklik; yükseklik yüzdelikleri; ortalama mutlak sapma; çeyrekler arası mesafe; örtü tabakası yüksekliği (canopy relief ratio); yaprak alan indeksi (Leaf Area Index, LAI); açıklık oranı (gap fraction); varyasyon katsayısı; basıklık (kurtosis); çarpıklık (skewness) ve genelleştirilmiş ortalamalar yer almaktadır. Ayrıca, nokta bulutu yoğunluğu metrikleri, verinin yükseklik aralığına göre eşit 10 dilime bölünmesi ve her dilimdeki geri dönüş oranının hesaplanması ile elde edilmiştir. Yükseklik yüzdelikleri ve AIH (Accumulated Height Index) değerleri, her istatistiksel birimdeki normalleştirilmiş LiDAR noktalarının yüksekliklerine göre sıralanması ve ilgili yüzdelik veya kümülatif yükseklik değerlerinin hesaplanması ile belirlenmiştir.

ALS nokta bulutu verilerinden türetilen yoğunluk metrikleri, yükseklik metriklerine benzer şekilde hesaplanmakla birlikte, burada nokta yüksekliği yerine spektral yoğunluğu (intensity) kullanılmaktadır. Bu metrikler yalnızca nokta bulutu verisinin yoğunluk bilgisi içerdiği durumlarda hesaplanabilir. Çalışmada, bir istatistiksel birimdeki maksimum, minimum, ortalama ve medyan yoğunluk değerleri, ortalama mutlak sapma, medyan mutlak sapma (MADMedian), çarpıklık (skewness), basıklık (kurtosis), varyasyon katsayısı ve yüzdelik değerler gibi toplam 42 istatistiksel parametre hesaplanmıştır. Ayrıca, yoğunluk değerlerinin kümülatif dağılımına dayalı Accumulated Intensity Index (AII) ve yoğunluk yüzdelikleri (Intensity Percentiles) hesaplanmış, yüzdelik çeyrekler arası mesafe (Interquartile Distance) ile birimlerin yoğunluk dağılımının heterojenliği değerlendirilmiştir.

Elde edilen tüm metrikler, LiDAR360 yazılımı kullanılarak her örnek alan için hesaplanmış ve hesaplanan toprak üstü biyokütle karbon stokları ile ilişkilendirilmiştir. Böylece, her örnek alanda toplam 101 LiDAR metriği (42 yoğunluk, 59 yükseklik) elde edilmiştir (Tablo 1). Bununla birlikte, spektral yoğunluk metriklerinden Int_min değeri tüm örnek alanlar için sabit (0) olduğundan veri setinden çıkarılmıştır.

Tablo 1
LiDAR nokta bulutu verilerinden türetilen metrikler

Kategori	Metrik	Açıklama
Yükseklik Metrikleri (59)	Maximum (Z_max)	Birimdeki en yüksek nokta yüksekliği
	Minimum (Z_min)	Birimdeki en düşük nokta yüksekliği
	Mean (Z_mean)	Birimdeki yüksekliklerin ortalaması
	Median (Z_median)	Birimdeki yüksekliklerin medyanı
	Standard Deviation, SD	Birimdeki Z değerlerinin standart sapması.
	Variance	Birimdeki Z değerlerinin varyansı.
	Average Absolute Deviation (MAD)	Yüksekliklerin ortalama mutlak sapması
	MAD Median	Medyan mutlak sapma
	Coefficient of Variation (CV)	Yüksekliklerin standart sapmasının ortalamaya oranı
	Skewness	Yükseklik değerlerinin simetrisi
	Kurtosis	Yükseklik değerlerinin basıklığı
	AIH (15)	Accumulated Height Index; %1-%99 arası kümülatif yükseklikler
	AlH Interquartile Distance	AIH25%-AIH75% yükseklik farkı
	Elevation Percentiles (15)	%1-%99 yükseklik yüzdelikleri
	Percentile Interquartile Distance	25%-75% yükseklik farkı
	Generalized Mean (2nd & 3rd power)	Yüksekliklerin 2. ve 3. kuvvetli genelleştirilmiş ortalamaları
	Density Metrics (10)	Nokta bulutunun yükseklik aralığına göre yoğunluk oranları
	Canopy Relief Ratio (CRR)	Örtü tabakası yüksekliği oranı
	Leaf Area Index, LAI	Yaprak Alan İndeksi
	Gap Fraction	Boşluk Oranı

Tablo 1
LiDAR nokta bulutu verilerinden türetilen metrikler (devam ediyor)

Kategori	Metrik	Açıklama
Yoğunluk Metrikleri (42)	Maximum (I_max)	Birimdeki en yüksek nokta yoğunluğu
	Mean (I_mean)	Birimdeki yoğunlukların ortalaması
	Median (I_median)	Birimdeki yoğunlukların medyanı
	Standard Deviation, SD	Birimdeki yoğunluk değerlerinin standart sapması.
	Average Absolute Deviation (MAD)	Yoğunlukların ortalama mutlak sapması
	MAD Median	Medyan mutlak sapma
	Coefficient of Variation (CV)	Yoğunlukların standart sapmasının ortalamaya oranı
	Skewness	Yoğunluk değerlerinin simetrisi
	Kurtosis	Yoğunluk değerlerinin basıklığı
	AII (15 seviyesi)	Accumulated Intensity Index; %1-%99 arası kümülatif yoğunluklar
	Intensity Percentiles (15 seviyesi)	%1-%99 yoğunluk yüzdelikleri
	Interquartile Distance	25%-75% yoğunluk farkı
	Minimum (Int_min)	*Tüm örnek alanlarda sabit 0 olduğu için veri setinden çıkarılmıştır

2.3. Arazi Verisi ve Toprak Üstü Karbon Stok Hesaplaması

Bu çalışmada, 2018 yılında arazi çalışması yürütülen orman amenajman planı envanter verilerinin bir kısmı kullanılmıştır. Seçilen örnek alanlar 300 × 300 m aralıklarla sistematik olarak yerleştirilen toplam 86 örnek alandan oluşmaktadır. Her örnek alanda 400, 600 ve 800 m² büyüklüğünde dairesel alanlar alınmıştır. Örnek alan büyüklükleri meşcere kapalılığına bağlı olarak tam kapalı meşcerelerde (3 kapalı, %71-100) 400 m², orta kapalı meşcerelerde (2 kapalı, %41-70) 600 m² ve düşük kapalı meşcerelerde (1 kapalı, %11-40) 800 m² olarak belirlenmiştir. Her örnek alanda, göğüs yüksekliği 1,30 m'de çapı 8 cm veya daha büyük olan tüm ağaçların tür ve göğüs çapı ölçümleri yapılmıştır. Arazi ölçümlerinden elde edilen tür ve göğüs çapı verileri kullanılarak, her ağaç için öncelikle hektardaki ağaç hacmi hesaplanmıştır. Hacim hesabı için amenajman planındaki türe özgü tek girişli hacim artım tablosu kullanılmıştır.

Çalışma alanında toprak üstü karbon(TÜK) tahmini, arazi verileri kullanılarak gerçekleştirilmiştir. IPCC'nin (2006) belirlemiş olduğu kılavuz esas alınarak, toprak üstü biyokütlede biriken karbon miktarları Denklem 2.1 kullanılarak belirlenmiştir.

$$C_{TÜK} = DGH \times HA \times BGF \times CF \quad (2.1)$$

Denklemde yer alan $C_{TÜK.}$, toprak üstü biyokütlede depolanan karbon miktarını (tonC/ha), *DGH* ise dikili kabuklu gövde hacmini (m³/ha) göstermektedir. *HA*, her bir ağaç türü veya tür grubuna ait kabuklu gövde odunu hacim ağırlığını (ton/m³), *BGF* ise biyokütle genişletme faktörünü temsil etmektedir. Bu faktör, her bir tür veya tür grubunun dikili kabuklu gövde hacminden hareketle, biyokütlenin toprak üstü toplam biyokütleye dönüştürülmesinde kullanılmaktadır.

Bu çalışmada, Türkiye'nin başlıca ağaç türleri için Tolunay (2019) tarafından önerilen *BGF* ve *HA* katsayıları kullanılmıştır (Tablo 2). *CF* katsayısı, biyokütlenin karbon miktarına çevrilmesinde kullanılan karbon dönüşüm faktörünü ifade etmektedir. IPCC (2006) yönergelerine göre, bu katsayı yapraklı ormanlar için 0,48, ibreli ormanlar için ise 0,51 olarak belirlenmiştir. Her örnek alandaki bireysel ağaçlar için karbon miktarı Denklem 2.1 kullanılarak ayrı ayrı hesaplanmış, daha sonra bu değerlerin toplamı alınarak ilgili örnek alanın toplam karbon miktarı belirlenmiştir.

Tablo 2
Çalışmada kullanılan ağaç türleri için hacim ağırlığı ve gövde odunu biyokütlesi katsayıları (Tolunay, 2019)

Ağaç Türü		Gövde Odunu Hacim Ağırlığı (GHA)	Biyokütle Genişletme Faktörü (BGF)	Karbon Faktörü (CF)
Pinus nigra	Karaçam	0,47	1,071	0,51
Pinus pinea	Fıstıkçamı	0,47	1,212	0,51
Pinus pinaster	Sahil çamı	0,44	1,212	0,51
Diğer İbreliler		0,446	1,212	0,51
Fagus orientalis	Kayın	0,53	1,305	0,48
Quercus sp.	Meşe	0,57	1,322	0,48
Carpinus sp.	Gürgen	0,63	1,482	0,48
Alnus sp.	Kızılağaç	0,407	1,103	0,48
Castanea sativa	Kestane	0,48	1,32	0,48
Fraxinus sp.	Dişbudak	0,562	1,31	0,48
Robinia pseudoacacia	Yalancı akasya	0,68	1,315	0,48
Diğer Yapraklılar		0,541	1,31	0,48

2.4. Veri Analizi

Arazi çalışmaları kapsamında ölçülen ağaç özelliklerinden örnek alan düzeyinde TÜK değerleri hesaplanmıştır. Aynı örnek alanlara karşılık gelen ALS verileri normalize edilmiş ve yükseklik ile örtü özelliklerini temsil eden çeşitli yapısal metrikler türetilmiştir. Bu metrikler, orman yapısının yatay ve dikey bileşenlerini yansıtarak TÜK tahmininde kullanılan temel değişken setini oluşturmuştur. ALS üzerinden türetilen yapısal metriklerin sayıca fazla olması ve aralarındaki yüksek ilişkiler, değişken seçimini zorunlu kılmıştır. Zira benzer veri kaynaklarından türetilen pek çok değişkenin güçlü korelasyon göstermesi, model sonuçlarını bozabilmekte ve çoklu doğrusal bağlantıya (multicollinearity) neden olabilmektedir. Model karmaşıklığını azaltmak ve farklı açıklayıcı değişkenlerin TÜK üzerindeki katkısını daha sağlıklı değerlendirebilmek amacıyla, modelleme öncesinde sistematik bir değişken seçimi süreci uygulanmıştır.

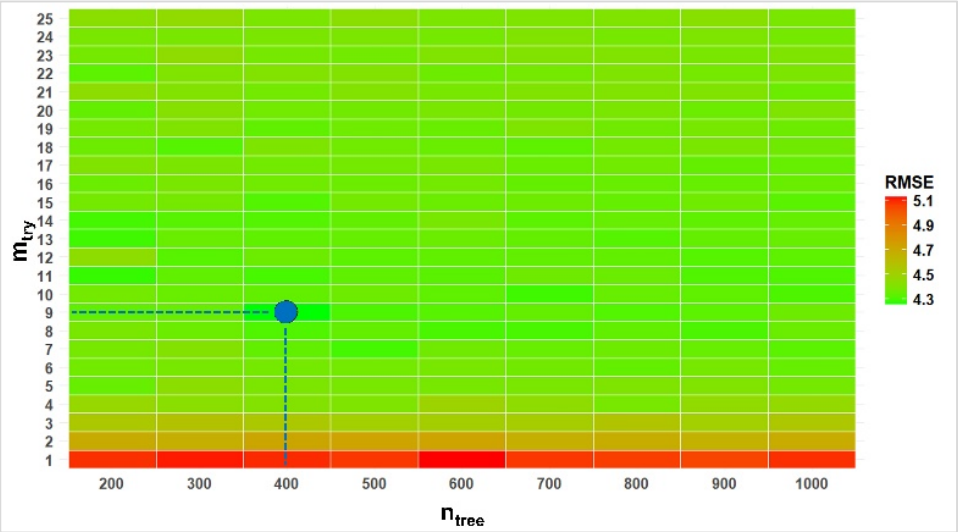
Bu amaçla tüm ALS metrikleri için Pearson korelasyon matrisi hesaplanmış ve değişkenler arasındaki çiftler incelenmiştir. Eşik değer olarak $r > 0,90$ alınmış ve bu değerin üzerindeki yüksek korelasyonlu değişken çiftleri tespit edilmiştir. Benzer çalışmalarda daha düşük korelasyon eşik değerleri tercih edilebilmektedir (Asner vd., 2009; Silva vd., 2013). Ancak bu çalışmada kullanılan makine öğrenmesi yaklaşımı, değişkenler arasında belirli düzeydeki korelasyona karşı nispeten dayanıklı bir algoritmadır. Buna ek olarak, LiDAR verilerinden türetilen metriklerin çoğu benzer yapısal özellikleri temsil ettiğinden, daha düşük eşik değerleri potansiyel olarak bilgi kaybına yol açabilecek çok sayıda değişkenin elenmesine neden olabilmektedir. Bu nedenle, değişken çeşitliliğini koruyarak modelin açıklayıcılığını artırmak amacıyla daha yüksek bir eşik değeri tercih edilmiştir. Her bir yüksek korelasyonlu çift/grup içerisinde yalnızca tek bir temsilci metrik tutulmuştur. Seçim sürecinde, TÜK ile daha güçlü korelasyon gösteren ve dolayısıyla daha yüksek açıklayıcı güce sahip olan değişken korunmuş, diğerleri veri setinden çıkarılmıştır.

Sonuç olarak, her bir korelasyon grubundan yalnızca bilgi açısından en uygun metrik modele dâhil edilmiştir. Böylece değişken sayısı azaltılmış, çoklu doğrusal bağlantı riski minimize edilmiş ve modele gereksiz veya tekrarlı bilginin girmesi engellenmiştir. Bu yaklaşım, hem modelin genelleme performansını ve istikrarını yükseltmiş hem de yorumlanabilirliğini artırmıştır.

Elde edilen seçilmiş değişkenler, TÜK tahmininde kullanılmak üzere Rastgele Orman (Random Forest-RF) regresyon modeline girdi olarak tanımlanmıştır. RF algoritması, regresyon ve sınıflandırma görevlerinde yaygın olarak kullanılan, parametrik olmayan bir makine öğrenme yöntemidir (Breiman, 2001). Algoritma, bootstrap örneklemesi (bagging) yaklaşımına dayalı olarak çok sayıda karar ağacı üretmekte, rastgele seçilen alt kümeleri üzerinde çalışmakta ve kalan "out-of-bag" (OOB) örnekleri üzerinden hata oranını içsel olarak tahmin etmektedir. RF'in en önemli avantajlarından biri, aşırı uyuma (overfitting) karşı dayanıklı olmasıdır.

Ağaç sayısının artırılması ile birlikte genelleme hatası belirli bir noktadan sonra sabitlenme eğilimi göstermektedir (Breiman, 2001; Cutler vd., 2007). Ayrıca RF, açıklayıcı değişkenler arasındaki çoklu doğrusal bağlantıya karşı görece dirençlidir (Dormann vd., 2013; Biau ve Scornet, 2016).

Bu çalışmada RF modeli, randomForest paketi (Liaw ve Wiener, 2002) kullanılarak R yazılımı (v4.3.1) ortamında uygulanmıştır. Modelin başarısını belirleyen iki temel hiperparametre vardır. Bunlar ağaç sayısı (n_{tree}) ve her bölünmede denenen değişken sayısıdır (m_{try}). Regresyon uygulamalarında genellikle varsayılan değerler olan n_{tree} için 500 ve m_{try} için değişken sayısının üçte biri tercih edilmekte olup, çoğu durumda yeterli performans sağlamaktadır (Gislason vd., 2006). Grid Search yaklaşımı, makine öğrenmesinde hiperparametre ayarlaması için kullanılan geleneksel bir yöntemdir. Bu yöntem, verilen hiperparametre değerlerinin tüm olası kombinasyonlarını ayrıntılı bir şekilde dener ve en iyi modeli bulmaya çalışır. Bu çalışmada Hiperparametre optimizasyonu için Grid Search yaklaşımı kullanılmış ve ALS verilerine özgü en uygun parametreler m_{try} için 9 ve n_{tree} için 400 olarak belirlenmiştir (Şekil 4). Modelin genelleme performansını değerlendirmek amacıyla çapraz doğrulama tekniği olarak LOOCV (Leave-One-Out Cross Validation-birini dışarı bırakarak çapraz doğrulama) yöntemi kullanılmıştır. LOOCV ile veri setindeki her bir örnek, birer kez test verisi olarak ayrılır; kalan tüm örnekler ise eğitim verisi olarak kullanılır. Bu yaklaşım, modelin gereksiz veya tekrarlı bilgiden arındırılmasını sağlayarak hem yorumlanabilirliği hem de kararlılığı artırmış, ayrıca TÜK tahminlerinin güvenilirliğini test etme olanağı sunmuştur.



Şekil 4. RF algoritması için uygun hiperparametre seçimi

Model performansı üç ölçütle değerlendirilmiştir: kök ortalama kare hata (RMSE), ortalama mutlak hata (MAE) ve determinasyon katsayısı (R^2). RMSE (Denklem 2.2) ve MAE (Denklem 2.3), tahmin edilen ve gözlenen TÜK değerleri arasındaki mutlak farkların büyüklüğünü ortaya koyarak modelin genel doğruluğunu yansıtmaktadır. R^2 (Denklem 2.4) ise LiDAR verilerine dayalı tahminlerin açıklayıcılık ve güvenilirlik düzeyini göstermektedir. Daha yüksek R^2 ve daha düşük RMSE ile MAE değerleri, modelin tahmin doğruluğunun arttığını ifade etmektedir (Cheng vd., 2024).

$$\text{RMSE}=\sqrt{\sum_{i=1}^{n}\frac{(T\ddot{U}K_{Gerçek}-T\ddot{U}K_{LiDAR})^2}{n}} \quad (2.2)$$

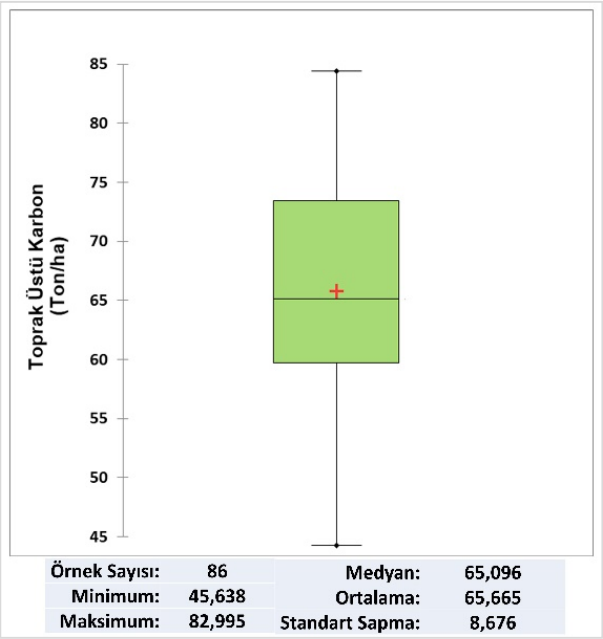
$$\text{MAE}=\frac{1}{n}\sum_{i=1}^{n}T\ddot{U}K_{Gerçek}-T\ddot{U}K_{LiDAR} \quad (2.3)$$

$$R^2=1-\frac{\sum_{i=1}^{n}(T\ddot{U}K_{Gerçek}-T\ddot{U}K_{LiDAR})^2}{\sum_{i=1}^{n}(T\ddot{U}K_{Gerçek}-T\ddot{U}K_{Ort.})^2} \quad (2.4)$$

Burada, n gözlem sayısını, $T\ddot{U}K_{Gerçek}$ yersel verilerden elde edilen toprak üstü karbonu, $T\ddot{U}K_{LiDAR}$ LiDAR verilerden elde edilen toprak üstü karbonu, $T\ddot{U}K_{Ort.}$ yersel verilerden elde edilen toprak üstü karbon ortalamasını ifade etmektedir.

3. Bulgular

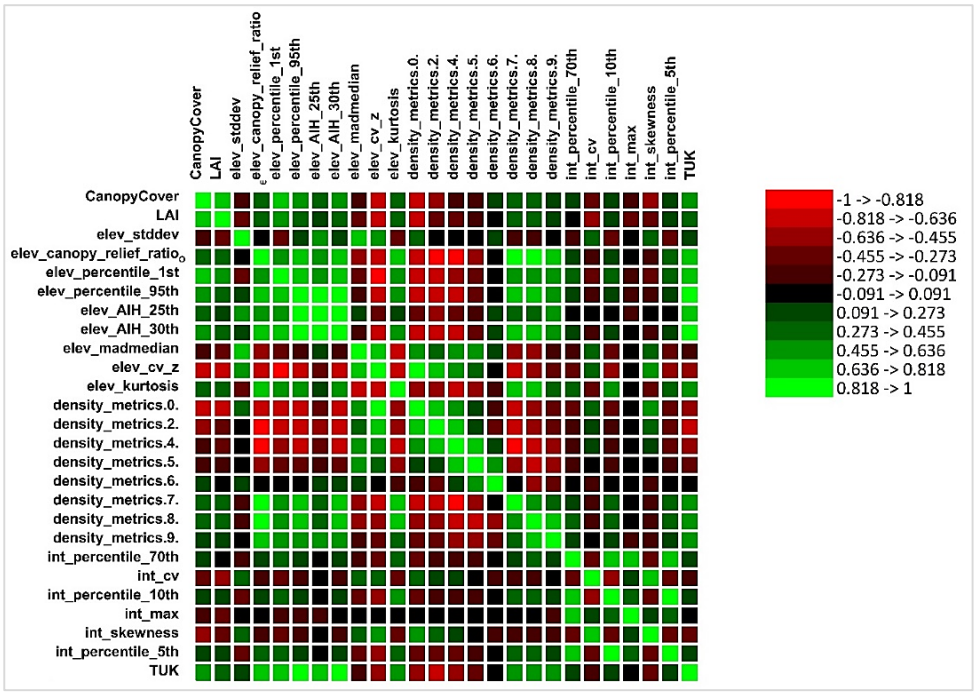
Arazi çalışmaları 86 farklı örnek alanda yapılmıştır. Arazi çalışmaları sonucu elde edilen envanter verisine ait göğüs çapı ve ağaç türü bilgileri yardımıyla her bir ağaç ilgili amenajman planından sağlanan tek girişli hacim tablosu ile hacimlendirilmiş ve IPCC (2006) tarafından oluşturulan yönergeleri izleyerek toprak üstü biyokütlede depolanan karbon miktarları Denklem 2.1 yardımıyla hesaplanmıştır. Hesaplamalar sonucunda veri setindeki TÜK değerleri en düşük 45,64 tonC/ha, en yüksek 82,99 tonC/ha olarak belirlenmiştir. Ortalama ve medyan TÜK değerleri sırasıyla 65,67 tonC/ha ve 65,10 tonC/ha olarak bulunmuştur. Standart sapma değeri 8,68 tonC/ha olup, verinin ortalamadan ne ölçüde saptığını göstermektedir. Bu yüksek standart sapma ve geniş aralık, örnek alanlar arasındaki TÜK değerlerinin önemli ölçüde değiştiğini göstererek veri setinin yüksek heterojenliğe sahip olduğunu ortaya koymaktadır. Aşağıda, örnek alan bazında yapılan hesaplamalara ait özet tanımlayıcı istatistik değerler sunulmaktadır (Şekil 5).



Şekil 5. Örnek alanlara ait özet tanımlayıcı istatistik değerler

ALS verisinden elde edilen metrikler ile yersel çalışmalar sonucu türe özgü katsayılarla hesaplanan TÜK değerleri arasındaki korelasyon analizi sonucunda, birbirinin yerine kullanılabilecek yüksek korelasyonlu değişkenler elenmiştir. Bu eleme işlemi sonucunda, toplam 101 metrikten 25 metrik seçilmiş ve geri kalan metrikler model dışında bırakılmıştır (Şekil 6). Böylece değişkenler arasındaki otokorelasyon problemi en düşük seviyeye indirilmiş ve TÜK tahmin modeli için yalnızca bu seçilmiş alt küme kullanılmıştır. Değişken seçim sonuçları incelendiğinde, hem yükseklik hem de yoğunluk metriklerinin alt kümede yer aldığı görülmektedir. Beklendiği üzere, modelin açıklayıcılığını en fazla sağlayan metrikler yükseklik temelli metrikler olmuştur.

Seçilen değişkenler ile TÜK tahmini için RF regresyon modeli kurulmuş ve algoritmanın hiperparametreleri (n_{tree} = 400, m_{try} = 9) optimize edilmiştir. Modelin performansı LOOCV yöntemi ile değerlendirilmiş olup, LOOCV sonuçlarına göre belirtme katsayısı (R^2) 0,76, kök ortalama kare hatası (RMSE) 4,25 tonC/ha, ortalama mutlak hata (MAE) ise 3,48 tonC/ha olarak hesaplanmıştır (Tablo 3). Bu sonuçlar, LiDAR verisine dayalı yapısal metriklerin TÜK değişimini yüksek doğrulukla açıkladığını göstermektedir.



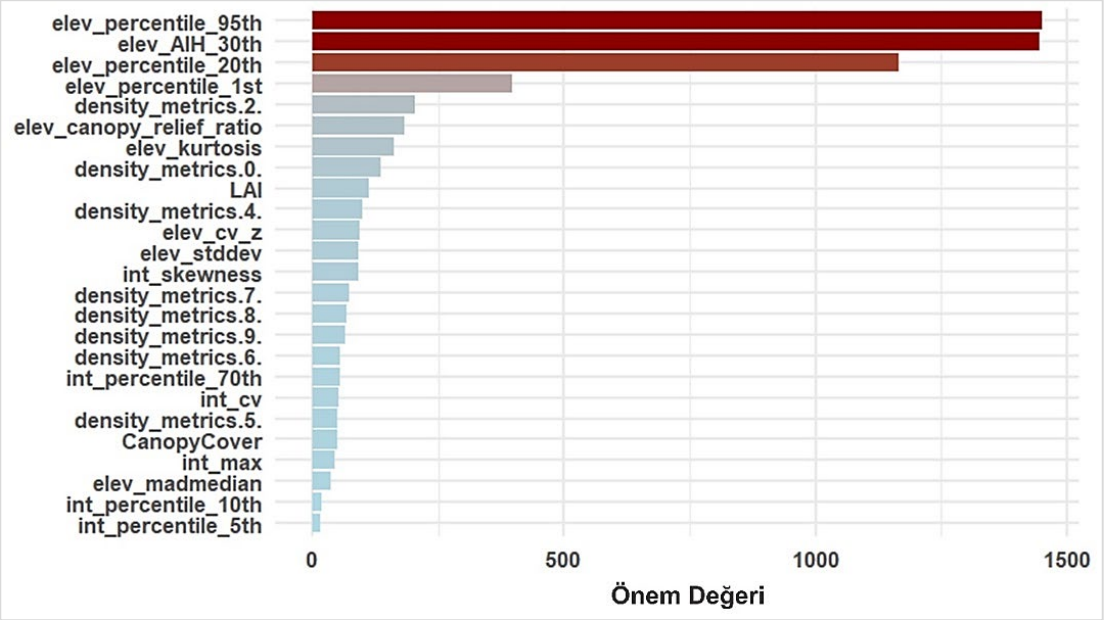
Şekil 6. Seçilen değişkenlere ait korelasyon ısı haritası

Tablo 3
RF modelinin tahmin performansı

R^2	RMSE	MAE
0,759	4,254	3,476

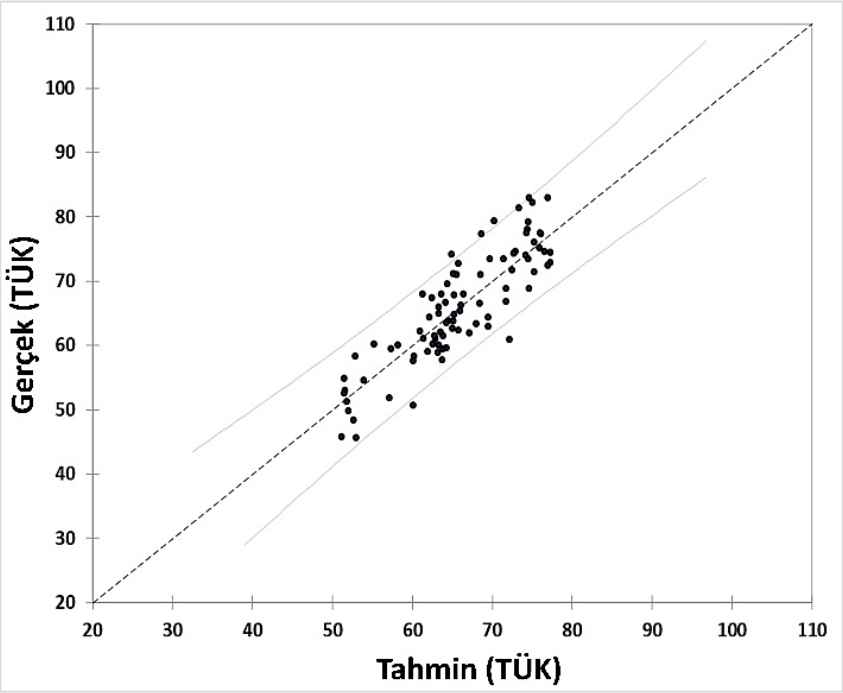
RF modelinde değişkenlerin TÜK tahminine katkısı, variable importance (değişken önem) analizi ile değerlendirilmiştir. Bu analiz, her bir değişkenin model performansını ne ölçüde artırdığını gösterir. Değişken önem analizi sonuçlarına göre, özellikle yükseklik yüzdelik değerleri ve örtü oranı metrikleri modelin en belirleyici girdileri olmuştur. Ayrıca nokta yoğunluğu ve dikey yapı çeşitliliğini temsil eden metrikler de TÜK tahmininde önemli katkılar sağlamıştır. Şekil 7'de sunulan değişken önem grafiği, bu bulguları görsel olarak desteklemektedir. Grafiğe göre, modelin tahmin performansına en fazla katkı sağlayan değişkenler arasında yükseklik yüzdeliklerini ölçen metrikler ilk sıralarda yer almaktadır

Yükseklik yüzdelik değerleri (20. ve 95. persentiller) ve CRR metrikleri TÜK tahmininde en belirleyici değişkenler olarak öne çıkmıştır. CRR, orman örtüsünün yüksekliğe göre nasıl dağıldığını ortaya koyan göreceli bir yükseklik dağılım göstergesidir. Bu metrik, orman örtüsünün üst tabakada yoğunlaşan (üst baskın) ya da alt tabakalarda yoğunlaşan (alt baskın) bir yapıya sahip olup olmadığını değerlendirmek için kullanılır. Ayrıca, nokta yoğunluğu ve dikey yapı çeşitliliğini temsil eden metrikler de modele önemli katkı sağlamıştır. Bu sonuçlar, orman yapısının hem yatay (CRR, yoğunluk) hem de dikey (yükseklik ve dikey heterojenlik) boyutlarının, karbon stoklarının modellenmesinde kritik öneme sahip olduğunu göstermektedir.



Şekil 7. RF değişken önem grafiği

Gözlenen ve tahmin edilen TÜK değerlerinin karşılaştırıldığı analizde, tahminlerin arazi verisi ile yüksek uyum gösterdiği, sapmaların ise özellikle düşük ve çok yüksek karbon değerlerinde arttığı belirlenmiştir (Şekil 8). Bu bulgu, modelin orta değerlerde daha istikrarlı bir performans sergilediğini ortaya koymaktadır.



Şekil 8. RF ile tahmin edilen ve gerçek TÜK grafiği

RF hata oranının n_{tree} ile değişimi incelendiğinde, ağaç sayısının artışıyla model hatasının başlangıçta hızlı bir şekilde azaldığı, yaklaşık 400 ağaçtan sonra ise stabil hale gelerek belirgin bir iyileşme göstermediği görülmüştür (Şekil 9). Bu bulgu, hiperparametre optimizasyonu sürecinde seçilen n_{tree} = 400 ve m_{try} = 9 kombinasyonunun modelin önyargı-varyans dengesine yakın bir yapı sergilediğini göstermektedir.



Şekil 9. RF OOB hata grafiği

Sonuç olarak, korelasyon analizi ile değişken sayısının 101'den 25'e düşürülmesi, LOOCV tabanlı doğrulama ve hiperparametre optimizasyonu ile geliştirilen RF modeli, LiDAR verisine dayalı yapısal metriklerin TÜK tahmininde güvenilir ve etkin biçimde kullanılabileceğini ortaya koymuştur. Özellikle yükseklik, örtü kapanma oranı ve dikey yapı heterojenliğini temsil eden değişkenler, orman karbon stoklarının modellenmesinde kritik öneme sahiptir.

4. Tartışma

Bu çalışmada, havasal LiDAR (ALS) verilerinden türetilen yapısal metriklerin, orman ekosistemlerinde toprak üstü karbon stoklarının (TÜK) tahmininde kullanılabilirliği değerlendirilmiştir. Elde edilen bulgular, ALS temelli metriklerin orman yapısını başarıyla temsil ettiğini ve karbon stoklarındaki mekânsal değişimlerin yüksek doğrulukla modellenebildiğini göstermektedir. RF regresyon modeli ile elde edilen R^2 = 0,76, RMSE = 4,25 tonC/ha ve MAE = 3,48 tonC/ha değerleri, ALS verilerinin TÜK tahmininde güçlü bir açıklayıcılığa sahip olduğunu ortaya koymaktadır. Bu doğruluk düzeyi, farklı ekosistemlerde gerçekleştirilen benzer çalışmalarla karşılaştırıldığında tatmin edici olup, literatürde raporlanan değerlerle uyum içerisindedir (Asner vd., 2009; Stephens vd., 2012; Liu vd., 2024).

Elde edilen yüksek model performansı, özellikle yükseklik yüzdelikleri (20. ve 95. persentiller) ile Canopy Relief Ratio (CRR) gibi metriklerin, TÜK tahmininde belirleyici rol oynadığını ortaya koymuştur. Bu bulgu, karbon stoklarının büyük ölçüde orman örtüsünün dikey ve yatay yapısal özelliklerine bağlı olduğunu vurgulayan önceki çalışmalarla uyumludur (Drake vd., 2002; Saatchi vd., 2011; White vd., 2018). Yükseklik metrikleri, ağaç boyu dağılımı ve taç mimarisi gibi parametreleri temsil ederek orman biyokütlesiyle doğrudan ilişki kurarken; yoğunluk ve CRR metrikleri, meşcere kapalılığı ve yaprak alan indeksi (LAI) ile ilişkili olarak karbon stoklarındaki mekânsal farklılıkları yansıtmaktadır. Nitekim Jian vd. (2025) ve Li vd. (2024) tarafından yürütülen çalışmalar da LiDAR verilerinden türetilen dikey yapı heterojenliği metriklerinin karbon tahmininde en etkili değişkenler arasında yer aldığını ortaya koymuştur.

TÜK tahmini, büyük ölçüde ağaç boyu ile toprak üstü karbon stoku arasındaki allometrik ilişkilere dayanmaktadır. Ancak, karmaşık orman yapıları bu ilişkiyi zayıflatabilir ve tahmin sonuçlarının doğruluğunu olumsuz yönde etkileyebilir. Kuramsal olarak, baskın türlere göre ayrı modellerin oluşturulması bu etkiyi azaltarak model performansını artırabilir. Bunun yanında, ağaç türüne özgü allometrik katsayıların kullanılması, TÜK hesaplamalarının doğruluğunu önemli ölçüde etkilemektedir. García vd. (2010) tarafından yapılan bir çalışmada da bu durum açıkça ortaya konmuştur. Söz konusu çalışmada, ormanın bir bütün olarak ele alındığı modelleme sonucunda açıklayıcılığın oldukça sınırlı olduğu; buna karşılık, türe özgü modelleme

yaklaşımlarında model başarısının belirgin biçimde arttığı görülmüştür. Bu bulgu, bu çalışmanın sonuçlarıyla da paralellik göstermektedir.

Benzer çalışmalarda benimsenen istatistiksel modelleme yaklaşımı da elde edilen sonuçlar üzerinde doğrudan etkili olmaktadır. LiDAR metrikleri, temelde tek bir veri kaynağından türetildikleri için genellikle birbirleriyle yüksek düzeyde ilintilidir. Bu durum, geleneksel parametrik yaklaşımların başarısını olumsuz yönde etkilemektedir. Parametrik analiz yöntemlerinin ön koşullarının sağlanamadığı durumlarda modellerin geçerliliği azalmakta ya da otokorelasyon gibi sorunlar nedeniyle doğruluk düzeyi düşmektedir. Buna karşın, parametrik olmayan regresyon modelleri, bu tür dezavantajları ortadan kaldırmada önemli avantajlar sağlamaktadır. Bu durumu destekler nitelikte, De Oliveira vd. (2021) tarafından yapılan bir çalışmada çoklu doğrusal regresyon (MLR), aşamalı çoklu doğrusal regresyon (stepwise MLR) ve temel bileşenler analizi (PCA) ile birleştirilmiş çoklu doğrusal regresyon olmak üzere üç farklı parametrik yaklaşım denenmiş; ancak modellerin açıklayıcılık düzeylerinin oldukça sınırlı kaldığı rapor edilmiştir. Buna karşılık, bu çalışmada RF regresyon algoritması kullanılmış ve modelleme öncesinde değişken seçim süreci uygulanarak en uygun alt değişken kümesi belirlenmiştir. Böylece modelleme süreci başarıyla tamamlanmış ve yüksek doğruluk elde edilmiştir.

Modelde kullanılan değişken seçimi yaklaşımı, çoklu doğrusal bağlantıyı azaltarak modelin genelleme performansını artırmıştır. Korelasyon eşiği yöntemi ile 101 metrik arasından 25'inin seçilmesi, modeldeki bilgi fazlalığının önlenmesini sağlamış ve özellikle RF algoritmasının değişken önem analizi sonuçlarında, yükseklik temelli metriklerin baskın rolünü açıkça ortaya koymuştur. Benzer şekilde, Liu vd. (2024) tarafından gerçekleştirilen bir çalışmada da LiDAR metriklerinde özellik seçimi (feature screening) uygulanmış ve model performansında belirgin bir iyileşme elde edilmiştir; söz konusu çalışmada R^2 = 0,78 düzeyinde sonuçlar bildirilmiştir. Bu bulgu, model karmaşıklığının azaltılmasının, doğruluk kaybına yol açmadan yorumlanabilirliği artırdığını göstermektedir. Nitekim, bu çalışmada elde edilen sonuçlar da Liu vd. (2024) tarafından raporlanan bulgularla yüksek düzeyde örtüşmektedir. Ayrıca, LOOCV tekniğiyle yürütülen doğrulama süreci, modelin aşırı uyumdan (overfitting) kaçındığını ve genelleme yeteneğinin yüksek olduğunu doğrulamıştır.

LiDAR verisine dayalı karbon tahminlerinde en önemli avantajlardan biri, yüksek dikey çözünürlük sayesinde orman yapısındaki dikey heterojenliğin doğrudan gözlemlenebilmesidir. Bu özellik, özellikle karmaşık yapılı ve tür çeşitliliği yüksek karışık meşcerelerde, klasik optik uzaktan algılama yöntemlerine kıyasla önemli bir üstünlük sağlamaktadır (Lefsky vd., 2002; Hudak vd., 2012). Çalışma alanının tür çeşitliliği, farklı kapalılık düzeyleri ve değişken topoğrafik yapısı dikkate alındığında, LiDAR verisinin sunduğu ayrıntılı yükseklik bilgisi modelin başarısında belirleyici bir rol oynamıştır. Özellikle farklı meşcere tiplerinin (ibreli, yapraklı ve karışık) bir arada bulunduğu alanlarda, yükseklik yüzdeliklerinin orman yapısındaki değişkenliği yakalama kapasitesinin yüksek olduğu görülmüştür. Bu bulgu, Strîmbu vd. (2023) ve Næsset (2002) tarafından raporlanan sonuçlarla da uyumluluk göstermektedir. Bunun yanı sıra, çoklu sensör füzyonu, tahmin doğruluklarının artırılmasında önemli bir çözüm yöntemi olarak değerlendirilebilir. Qin vd. (2021), bireysel ağaçlardaki karbon stoklarını tahmin etmek amacıyla hiperspektral görüntüler ile İHA (UAV) tabanlı LiDAR verisini birleştirmenin potansiyelini incelemiştir. Bulgular, LiDAR ve hiperspektral verilerin tek başına kullanılması durumunda, karbon tahminlerinin sırasıyla R^2 = 0,74 ve R^2 = 0,75 düzeyinde olduğunu göstermiştir. Buna karşın, LiDAR ve hiperspektral veri setlerinin birleştirilmesi, tahmin doğruluğunu R^2 = 0,89 değerine yükseltmiştir. Bu sonuç, yapısal ve spektral bilgilerin karbon stok modellemesinde tamamlayıcı bir rol oynadığını ortaya koymaktadır.

Bununla birlikte, LiDAR verisinin TÜK tahmininde sunduğu önemli avantajlara karşın bazı teknik ve operasyonel sınırlılıkları da bulunmaktadır. Hava tabanlı LiDAR verisinin temini yüksek maliyetli olup, uçuş yüksekliği, tarama yoğunluğu ve sensör özelliklerindeki farklılıklar metriklerin tutarlılığını etkileyebilmektedir. Özellikle kapalılığın yüksek olduğu meşcerelerde LiDAR ışınlarının alt katmanlara penetrasyonu sınırlı olabilir. Bu durum, yapısal metriklerin meşcere özelliklilerini yeterince yansıtmamasına

ve biyokütle tahminlerinde belirsizliklere yol açabilir. Ayrıca, LiDAR verilerinin işlenmesi uzmanlık gerektirmektedir. Nokta bulutunun sınıflandırma, filtreleme ve metrik üretimi gibi aşamalarındaki metodolojik değişkenlikler model performansı üzerinde doğrudan etkili olabilmektedir. Ayrıca topoğrafik gölgelenme veya uçuş hatları arasındaki yoğunluk farkları da model performansını sınırlayabilen unsurlar arasındadır.

5. Sonuç

Çalışmada elde edilen bulgular genel olarak değerlendirildiğinde, havasal LiDAR (ALS) verisinin, orman karbon stoklarının izlenmesi ve raporlanması süreçlerinde güvenilir bir araç olarak kullanılabileceğini ortaya koymaktadır. Özellikle REDD+ ve ulusal sera gazı envanteri çalışmalarında, yüksek mekânsal çözünürlüklü ALS verilerinin bölgesel ölçekli karbon tahminlerinde referans veri kaynağı olarak değerlendirilebileceği söylenebilir. Bununla birlikte, bu yaklaşımın daha geniş alanlara uygulanabilmesi için maliyet-etkin veri toplama stratejilerinin geliştirilmesi gerekmektedir. Ayrıca, farklı orman tipleri ve gelişim çağları için tür bazlı allometrik denklemlerin LiDAR verisiyle bütünleştirilmesi, model doğruluğunu artıracak bir diğer önemli adım olacaktır.

Öte yandan, modelin düşük ve yüksek uç değerlerde gözlenen sapmaları, özellikle ekstrem karbon stok miktarlarının tahmininde LiDAR metriklerinin sınırlı temsil gücünden kaynaklanabilir. Bu tür uç değerler genellikle çok genç meşcerelerde (düşük karbon) veya çok yaşlı ve kapalı meşcerelerde (yüksek karbon) görülmekte olup, lazer sinyallerinin taç yoğunluğuna bağlı olarak veri doygunluğu etkisi ortaya çıkabilmektedir. Bu durumun, yüksek karbon yoğunluklu ormanlarda LiDAR verisinin alt tabakaları yeterince temsil edememesi nedeniyle ortaya çıktığı düşünülmektedir. Dolayısıyla, gelecekte bu tür sapmaların azaltılması amacıyla çoklu platform verilerinin entegrasyonunun sağlanması, karbon stok tahminlerinin doğruluğunu daha da artırabilecek bir yaklaşım olarak değerlendirilmektedir. Yüksek çözünürlüklü UAV-LiDAR veya mobil LiDAR sistemleriyle yapılacak çok zamanlı ölçümler ise, karbon stoklarındaki zamansal değişimlerin izlenmesi açısından büyük potansiyel taşımaktadır.

Sonuç olarak, bu çalışma hava tabanlı LiDAR teknolojisinin orman karbon stoklarının mekânsal olarak yüksek doğrulukla tahmin edilmesinde güvenilir bir araç olduğunu ortaya koymuştur. Geliştirilen metodoloji hem bölgesel hem de ulusal ölçekte karbon izleme çalışmalarında kullanılabilir bir yaklaşım sunmaktadır. Bu kapsamda, LiDAR tabanlı modellerin ulusal orman envanteri sistemlerine entegre edilmesi, Türkiye ormanlarının karbon dinamiklerinin izlenmesinde bilimsel ve pratik açıdan önemli katkılar sağlayacaktır.

Teşekkür

Makalede kullanılan yersel envanter verisi, İstanbul Üniversitesi - Cerrahpaşa Orman Fakültesi Eğitim ve Araştırma Ormanı amenajman planı çalışmasında kullanılan veri setinden derlenmiştir. Bu vesileyle, İstanbul Üniversitesi - Cerrahpaşa Orman Fakültesi Orman Amenajmanı Anabilim Dalı öğretim üyelerine değerli katkılarından dolayı teşekkür ederim.

Yazar Katkıları

Çalışmanın tamamı yazar tarafından gerçekleştirilmiştir.

Çıkar Çatışması

Yazar çıkar çatışması bildirmemiştir.

Kaynaklar

Asner, G. P. (2009). Tropical forest carbon assessment: integrating satellite and airborne mapping approaches. *Environmental Research Letters*, *4*(3), 034009. https://doi.org/10.1088/1748-9326/4/3/034009

Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, *25*(2), 197–227.

https://doi.org/10.1007/s11749-016-0481-7
Bonan, G. B. (2008). Forests and climate change: forcings, feedbacks, and the climate benefits of forests. *Science*, *320*(5882), 1444–1449. https://doi.org/10.1126/science.1155121
Breiman, L. (2001). Random Forests. *Machine Learning*, *45*(1), 5–32. https://doi.org/10.1023/a:1010933404324
Brown, S. (1997). *Estimating biomass and biomass change of tropical forests: A primer*. Retrieved from http://ci.nii.ac.jp/ncid/BA52417799
Chave, J., Andalo, C., Brown, S., Cairns, M. A., Chambers, J. Q., Eamus, D., . . . Yamakura, T. (2005). Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia*, *145*(1), 87–99. https://doi.org/10.1007/s00442-005-0100-x
Cheng, F., Ou, G., Wang, M., & Liu, C. (2024). Remote sensing estimation of forest carbon stock based on machine learning algorithms. Forests, 15(4), 681.
Clark, D. B., & Kellner, J. R. (2012). Tropical forest biomass estimation and the fallacy of misplaced concreteness. *Journal of Vegetation Science*, *23*(6), 1191–1196. https://doi.org/10.1111/j.1654-1103.2012.01471.x
Cutler, D. R., Edwards, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). RANDOM FORESTS FOR CLASSIFICATION IN ECOLOGY. *Ecology*, *88*(11), 2783–2792. https://doi.org/10.1890/07-0539.1
De Oliveira, C. P., Ferreira, R. L. C., Da Silva, J. a. A., De Lima, R. B., Silva, E. A., Da Silva, A. F., . . . De Melo, C. L. S. S. (2021). Modeling and spatialization of biomass and carbon stock using LIDAR metrics in Tropical Dry Forest, Brazil. *Forests*, *12*(4), 473. https://doi.org/10.3390/f12040473
Dixon, R. K., Solomon, A. M., Brown, S., Houghton, R. A., Trexier, M. C., & Wisniewski, J. (1994). Carbon pools and flux of global forest ecosystems. *Science*, *263*(5144), 185–190. https://doi.org/10.1126/science.263.5144.185
Dormann, C. F., Elith, J., Bacher, S., Buchmann, C., Carl, G., Carré, G., . . . Lautenbach, S. (2013). Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. *Ecography*, *36*(1), 27–46. https://doi.org/10.1111/j.1600-0587.2012.07348.x
Drake, J. B., Dubayah, R. O., Clark, D. B., Knox, R. G., Blair, J., Hofton, M. A., . . . Prince, S. (2002). Estimation of tropical forest structural characteristics using large-footprint lidar. *Remote Sensing of Environment*, *79*(2–3), 305–319. https://doi.org/10.1016/s0034-4257(01)00281-4
Fang, J., Guo, Z., Hu, H., Kato, T., Muraoka, H., & Son, Y. (2014). Forest biomass carbon sinks in East Asia, with special reference to the relative contributions of forest expansion and forest growth. *Global Change Biology*, *20*(6), 2019–2030. https://doi.org/10.1111/gcb.12512
Friedlingstein, P., Jones, M. W., O'Sullivan, M., Andrew, R. M., Bakker, D. C. E., Hauck, J., . . . Zeng, J. (2022). Global Carbon Budget 2021. *Earth System Science Data*, *14*(4), 1917–2005. https://doi.org/10.5194/essd-14-1917-2022
García, M., Riaño, D., Chuvieco, E., & Danson, F. M. (2010). Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote Sensing of Environment*, *114*(4), 816–830. https://doi.org/10.1016/j.rse.2009.11.021
Gibbs, H. K., Brown, S., Niles, J. O., & Foley, J. A. (2007). Monitoring and estimating tropical forest carbon stocks: making REDD a reality. *Environmental Research Letters*, *2*(4), 045023. https://doi.org/10.1088/1748-9326/2/4/045023
Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2005). Random Forests for land cover classification. *Pattern Recognition Letters*, *27*(4), 294–300. https://doi.org/10.1016/j.patrec.2005.08.011
Green Valley International, 2023. LiDAR360 User Guide, GreenValley International Ltd., https://www.greenvalleyintl.com/gvi/web/us/file/EN-User-Guide-LiDAR360.pdf, Erişim:

27.06.2025.

Hudak, A. T., Strand, E. K., Vierling, L. A., Byrne, J. C., Eitel, J. U., Martinuzzi, S., & Falkowski, M. J. (2012). Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. *Remote Sensing of Environment*, *123*, 25–40. https://doi.org/10.1016/j.rse.2012.02.023

IPCC. (2006). *2006 IPCC Guidelines for National Greenhouse Gas Inventories*. Prepared by the National Greenhouse Gas Inventories Programme.

Jian, K., Lu, D., & Li, G. (2025). Modeling Forest Carbon Stock Based on Sample Plots and UAV Lidar Data from Multiple Sites and Examining Its Vertical Characteristics in Wuyishan National Park. *Remote Sensing*, *17*(3), 377. https://doi.org/10.3390/rs17030377

Keith, H., Mackey, B. G., & Lindenmayer, D. B. (2009). Re-evaluation of forest biomass carbon stocks and lessons from the world's most carbon-dense forests. *Proceedings of the National Academy of Sciences*, *106*(28), 11635–11640. https://doi.org/10.1073/pnas.0901970106

Laurin, G. V., Pirotti, F., Callegari, M., Chen, Q., Cuozzo, G., Lingua, E., . . . 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. https://doi.org/10.3390/rs9010018

Le Toan, T., Quegan, S., Davidson, M., Balzter, H., Paillou, P., Papathanassiou, K., . . . Ulander, L. (2011). The BIOMASS mission: Mapping global forest biomass to better understand the terrestrial carbon cycle. *Remote Sensing of Environment*, *115*(11), 2850–2860. https://doi.org/10.1016/j.rse.2011.03.020

Le Toan, Thuy, Quegan, S., Woodward, I., Lomas, M., Delbart, N., & Picard, G. (2004). Relating radar remote sensing of biomass to modelling of forest carbon budgets. *Climatic Change*, *67*(2–3), 379–402. https://doi.org/10.1007/s10584-004-3155-5

Lederer, M. (2012). REDD+ governance. *Wiley Interdisciplinary Reviews Climate Change*, *3*(1), 107–113. https://doi.org/10.1002/wcc.155

Lefsky, M. A., Cohen, W. B., Parker, G. G., & Harding, D. J. (2002). Lidar Remote Sensing for Ecosystem Studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. *BioScience*, *52*(1), 19–30.

Li, H., Hiroshima, T., Li, X., Hayashi, M., & Kato, T. (2024). High-resolution mapping of forest structure and carbon stock using multi-source remote sensing data in Japan. *Remote Sensing of Environment*, *312*, 114322. https://doi.org/10.1016/j.rse.2024.114322

Lin, Y., Shao, J., Shin, S., Saka, Z., Joseph, M., Manish, R., . . . Habib, A. (2022). Comparative analysis of Multi-Platform, Multi-Resolution, Multi-Temporal LIDAR data for forest inventory. *Remote Sensing*, *14*(3), 649. https://doi.org/10.3390/rs14030649

Liu, C., & Shao, Z. F. (2012). Estimation of forest carbon storage based on airborne LiDAR data. *Applied Mechanics and Materials*, *195–196*, 1314–1320. https://doi.org/10.4028/www.scientific.net/amm.195-196.1314

Liu, X., Wang, R., Shi, W., Wang, X., & Yang, Y. (2024). Research on estimation model of carbon stock based on airborne LIDAR and feature screening. *Sustainability*, *16*(10), 4133. https://doi.org/10.3390/su16104133

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

Mitchard, E. T. A. (2018). The tropical forest carbon cycle and climate change. *Nature*, *559*(7715), 527–534. https://doi.org/10.1038/s41586-018-0300-2

Mitchard, E. T. A., Saatchi, S. S., Woodhouse, I. H., Nangendo, G., Ribeiro, N. S., Williams, M., . . . Meir, P. (2009). Using satellite radar backscatter to predict above-ground woody biomass: A

consistent relationship across four different African landscapes. *Geophysical Research Letters*, *36*(23). https://doi.org/10.1029/2009gl040692

Næsset, E. (2002). Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment*, *80*(1), 88–99. https://doi.org/10.1016/s0034-4257(01)00290-5

Pan, Y., Birdsey, R. A., Fang, J., Houghton, R., Kauppi, P. E., Kurz, W. A., . . . Hayes, D. (2011). A large and persistent carbon sink in the world's forests. *Science*, *333*(6045), 988–993. https://doi.org/10.1126/science.1201609

https://doi.org/10.1109/igarss.2013.6721324

Sinha, S., Jeganathan, C., Sharma, L. K., & Nathawat, M. S. (2015). A review of radar remote sensing for biomass estimation. *International Journal of Environmental Science and Technology*, *12*(5), 1779–1792. https://doi.org/10.1007/s13762-015-0750-0

Soeder, D. J. (2021). Greenhouse gas sources and mitigation strategies from a geosciences perspective. *ADVANCES IN GEO-ENERGY RESEARCH*, *5*(3), 274–285. https://doi.org/10.46690/ager.2021.03.04

Sokolov, A. P., Kicklighter, D. W., Melillo, J. M., Felzer, B. S., Schlosser, C. A., & Cronin, T. W. (2008). Consequences of Considering Carbon–Nitrogen Interactions on the Feedbacks between Climate and the Terrestrial Carbon Cycle. *Journal of Climate*, *21*(15), 3776–3796. https://doi.org/10.1175/2008jcli2038.1

Stephens, P. R., Kimberley, M. O., Beets, P. N., Paul, T. S., Searles, N., Bell, A., . . . Broadley, J. (2012). Airborne scanning LiDAR in a double sampling forest carbon inventory. *Remote Sensing of Environment*, *117*, 348–357. https://doi.org/10.1016/j.rse.2011.10.009

Strîmbu, V. F., Næsset, E., Ørka, H. O., Liski, J., Petersson, H., & Gobakken, T. (2023). Estimating biomass and soil carbon change at the level of forest stands using repeated forest surveys assisted by airborne laser scanner data. *Carbon Balance and Management*, *18*(1). https://doi.org/10.1186/s13021-023-00222-4

Tolunay, D. (2019). Biomass factors used to calculate carbon storage of Turkish forests. *Forestist*, *69*(2), 144–155. https://doi.org/10.26650/forestist.2019.110719

Valbuena, R., O'Connor, B., Zellweger, F., Simonson, W., Vihervaara, P., Maltamo, M., . . . Coops, N. (2020). Standardizing Ecosystem Morphological Traits from 3D Information Sources. *Trends in Ecology & Evolution*, *35*(8), 656–667. https://doi.org/10.1016/j.tree.2020.03.006

White, J. C., Tompalski, P., Coops, N. C., & Wulder, M. A. (2018). Comparison of airborne laser scanning and digital stereo imagery for characterizing forest canopy gaps in coastal temperate rainforests. *Remote Sensing of Environment*, *208*, 1–14. https://doi.org/10.1016/j.rse.2018.02.002

Wigneron, J., Ciais, P., Li, X., Brandt, M., Canadell, J. G., Tian, F., . . . Fensholt, R. (2024). Global carbon balance of the forest: satellite-based L-VOD results over the last decade. *Frontiers in Remote Sensing*, *5*. https://doi.org/10.3389/frsen.2024.1338618

Wulder, M., Coops, N., Hudak, A., Morsdorf, F., Nelson, R., Newnham, G., & Vastaranta, M. (2013). Status and prospects for LiDAR remote sensing of forested ecosystems. *Canadian Journal of Remote Sensing*, *39*(sup1), S1–S5. https://doi.org/10.5589/m13-051

Picard, N., Saint-André, L., & Henry, M. (2012). Manual for Building Tree Volume and Biomass Allometric Equations: From field measurement to prediction. FAO.

Qin, H., Zhou, W., Yao, Y., & Wang, W. (2021). Estimating aboveground carbon stock at the scale of individual trees in subtropical forests using UAV LIDAR and hyperspectral data. *Remote Sensing*, *13*(24), 4969. https://doi.org/10.3390/rs13244969

Saatchi, S. S., Harris, N. L., Brown, S., Lefsky, M., Mitchard, E. T. A., Salas, W., . . . Morel, A. (2011). Benchmark map of forest carbon stocks in tropical regions across three continents. *Proceedings of the National Academy of Sciences*, *108*(24), 9899–9904.

https://doi.org/10.1073/pnas.1019576108

Shi, Y., Wang, Z., Zhang, G., Wei, X., Ma, W., & Yu, H. (2024). Evaluating the research status of the Remote Sensing-Mediated Monitoring of Forest Biomass: A Bibliometric Analysis of WOS. *Forests*, *15*(3), 524. https://doi.org/10.3390/f15030524

Silva, C. A., Klauberg, C., De Padua Chaves E Carvalho, S., & Rodriguez, L. C. E. (2013). Estimation of aboveground carbon stocks in Eucalyptus plantations using LIDAR. *2013 IEEE International Geoscience and Remote Sensing Symposium-IGARSS* (pp. 972–974).