

Saf Kızılçam (*Pinus brutia* Ten.) Meşcerelerinde Aktif ve Pasif Uydu Görüntüleri Kullanılarak Topraküstü Biyokütlenin Tahmin Edilmesi (Anamur Orman İşletme Şefliği Örneği)

İzzet Güverçin¹, Alkan Günlü^{2,*}

¹Çankırı Karatekin Üniversitesi, Fen Bilimleri Enstitüsü, Orman Mühendisliği Bölümü, Çankırı, Türkiye

^{2,*}Çankırı Karatekin Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, Çankırı, Türkiye

Makale Tarihiçesi

Gönderim: 07.03.2023

Kabul: 11.04.2023

Yayın: 15.04.2023

Araştırma Makalesi



Öz – Bu çalışmada; saf kızılçam (*Pinus brutia* Ten.) meşcerelerinde aktif (Sentinel-1A) ve pasif (Landsat 8 OLI) uydu görüntüleri ile bazı topoğrafik veriler kullanılarak topraküstü biyokütle (TÜB)'nin tahmini amaçlanmıştır. Çalışmada toplam 404 adet örnek alan verisi kullanılmıştır. Bu örnek alan verilerininin 323 (%80) modellerin oluşturulmasında ve 81 (%20) ise modellerin test edilmesinde kullanılmıştır. Her bir örnek alana ilişkin TÜB değerleri allometrik biyokütle denklemi kullanılarak hesaplanmıştır. Ayrıca her bir örnek alana ilişkin Landsat 8 OLI uydu görüntüsünden bant reflektans, vejetasyon indis ve tekstür değerleri, Sentinel-1A uydu görüntüsünün her iki polarizasyonu (VV ve VH) için parlaklık ve geri yansıtım değerleri ile ALOS-PALSAR uydu görüntüsünden üretilen Sayısal Yükseklik Model (SYM) verisinden yükselti, eğim ve baki değerleri hesaplanmıştır. TÜB ile Landsat 8 OLI, Sentinel-1A ve SYM verisinden elde edilen değişkenler arasındaki ilişkiler regresyon analizi ile modellenmiştir. Toplam 22 farklı regresyon modeli geliştirilmiştir. Geliştirilen modeller arasında en iyi ilişki ($R^2_{düz} = 0,509$; $Sy.x = 28,39$), Landsat 8 OLI uydu görüntüsünün bant reflektans değerleri, vejetasyon indisleri, tekstür değerleri, Sentinel-1A uydu görüntüsünün iki polarizasyona ilişkin parlaklık değerleri ile yükselti ve bakının bağımsız değişkenler olarak yer aldığı modelde elde edilmiştir.

Anahtar Kelimeler – Topraküstü biyokütle, Sentinel 1A, Landsat 8 OLI, allometrik biyokütle denklemi, kızılçam

Estimating Aboveground Biomass Using Active and Passive Satellite Images in Pure Calabrian Pine (*Pinus brutia* Ten.) Stands (A Case Study in Anamur Forest Planning Unit)

¹Çankırı Karatekin University, Graduate School of Natural and Applied Sciences, Department of Forest Engineering, Çankırı, Türkiye

²Çankırı Karatekin University, Faculty of Forestry, Department of Forest Engineering, Çankırı, Türkiye

Article History

Received: 07.03.2023


Accepted: 11.04.2023


Published: 15.04.2023

Research Article

Abstract – The aim of this study is to estimate aboveground biomass in pure Calabrian pine (*Pinus brutia* Ten.) stands using active (Sentinel-1A) and passive (Landsat 8 OLI) satellite images and some topographic data. Sample plot data of a total of 404 sample areas were used in the study. Of these sample plot data, 323 (80%) were used to create models and 81 (20%) to test models. Aboveground biomass values for each sample plot were calculated using the allometric equation. In addition, band reflectance, vegetation indices and texture values from Landsat 8 OLI satellite image for each sample plot, brightness and backscattering values for both polarizations (VV and VH) of Sentinel-1A satellite image, and the elevation, slope and aspect values were calculated from the Digital Elevation Model (DEM) data produced from the ALOS-PALSAR satellite image. Relationships between aboveground biomass and variables obtained from Landsat 8 OLI, Sentinel-1A and DEM data were modelled regression analysis. A total of 22 different regression models were developed. The best success among the developed models was obtained with the model ($R^2_{adj} = 0.509$; $Sy.x = 28.39$) in which the band reflectance values, vegetation indices and texture values of the Landsat 8 OLI satellite image, the brightness values of the two polarizations of the Sentinel-1A satellite image, elevation and aspect are included as independent variables.

Keywords – Aboveground biomass, Sentinel 1A, Landsat 8 OLI, allometric equation, calabrian pine

¹  izzetguv@gmail.com.tr

²  alkangunlu@karatekin.edu.tr

*Sorumlu Yazar / Corresponding Author: alkangunlu@karatekin.edu.tr

1. Giriş

Ormanlar, küresel iklim değişiminde ve atmosferdeki karbonun tutulmasında önemli rol oynamaktadır. (Zianis ve Mencuccini, 2004; Hall ve ark., 2006). Önemli bir havuz görevi gören orman ekosistemlerindeki karbon döngülerinin daha iyi anlaşılması için ormanların biyokütlesinin doğru bir şekilde tahmin edilmesi gerekmektedir (Houghton, 2005). Genel olarak biyokütle, toprakaltı ve topraküstü biyokütle olmak üzere iki farklı biçimde değerlendirilmektedir. Topraküstü biyokütle (TÜB)'nin tahmin edilmesinde farklı yaklaşımlar kullanılmaktadır. Bunlar yersel ölçümler (Brown ve ark., 1989, Brown ve Iverson. 1992; Schroeder ve ark., 1997; Brown, 2002), Uzaktan Algılama (UA) yöntemleri (Tiwari, 1994; Roy ve Ravan, 1996; Nelson ve ark., 2000; Tomppo ve ark., 2002; Foody ve ark., 2003; Zheng ve ark., 2004; Lu, 2005) ve Coğrafi Bilgi Sistemleri (CBS) (Brown ve Gaston, 1995) olarak sınıflandırmak mümkündür.

TÜB'nin tahmin edilmesinde en doğru ve güvenilir yöntemler yersel ölçümlerdir. Yersel veriler yardımıyla elde edilen allometrik biyokütle denklemler kullanılarak TÜB doğru bir şekilde tahmin edilmektedir. Bu yöntem, oldukça zaman alıcı, yoğun işgücü isteyen ve geniş alanlarda uygulaması oldukça zor bir yöntemdir (Lu, 2005). CBS ile TÜB tahminlerinin yapılması ise, çok sayıda, doğru, güvenilir bir veri tabanı ve bu veriler arasında kaliteli ilişkilerin olmasını gerektirdiğinden, yaygın olarak kullanılan bir yöntem değildir. UA yöntemi, veri toplamanın kolaylığı, verilerin hızlı bir şekilde değerlendirilmesine imkân vermesi, bant parlaklık değerleri, vejetasyon indisleri ve tekstür değerleri arasında yüksek korelasyonların olması ve özellikle çok zor ulaşılan alanlarda TÜB tahmininde tercih edilmektedir (Nelson ve ark., 1988; Sader ve ark., 1989; Steininger, 2000; Foody ve ark., 2003; Santos ve ark., 2003; Zheng ve ark., 2004).

Son zamanlarda UA verileri kullanılarak geniş ormanlık alanlarda TÜB'nin tahmin edilmesine yönelik çalışmalar yapılmaktadır (Gallaun ve ark., 2010; Günlü ve ark., 2014; Turgut ve Günlü, 2022; Bulut ve ark., 2022; Bulut, 2023). Özellikle ilk doğal kaynak uydusu olan Landsat uydu görüntüleri kullanılarak TÜB'nin tahmin edilmesine yönelik çok sayıda çalışma vardır (Maynard ve ark., 2007; Turgut ve Günlü, 2022). Bununla birlikte farklı uydu görüntüleri kullanılarak TÜB'nin tahmin edilmesine yönelik çok sayıda çalışmada literatürde yer almaktadır (Thenkabail ve ark., 2004; Muukkonen ve Heiskanen, 2005; Eckert, 2012). Aynı zamanda, radar ve lidar verileri kullanılarak TÜB'nin tahmin edilmesine ilişkin çalışmalar da yapılmakta ve bu çalışmalardan elde edilen model tahmin sonuçlarının optik uydu görüntülerinden elde edilen model tahmin sonuçlarına göre daha iyi sonuçlar verdiği ifade edilmektedir (Lu, 2006; Goetz ve ark., 2009). Lidar ve radar uydu verileri farklı orman ekosistemlerinde TÜB'nin tahmin edilmesinde kullanılmaktadır (Zhao ve ark., 2012; Keleş ve ark., 2021). Özellikle uzun dalga boyuna sahip radar verilerinin karışık orman ekosistemlerinde TÜB'nin tahmin edilmesinde kullanılabileceği ifade edilmiştir (Zimble ve ark., 2003).

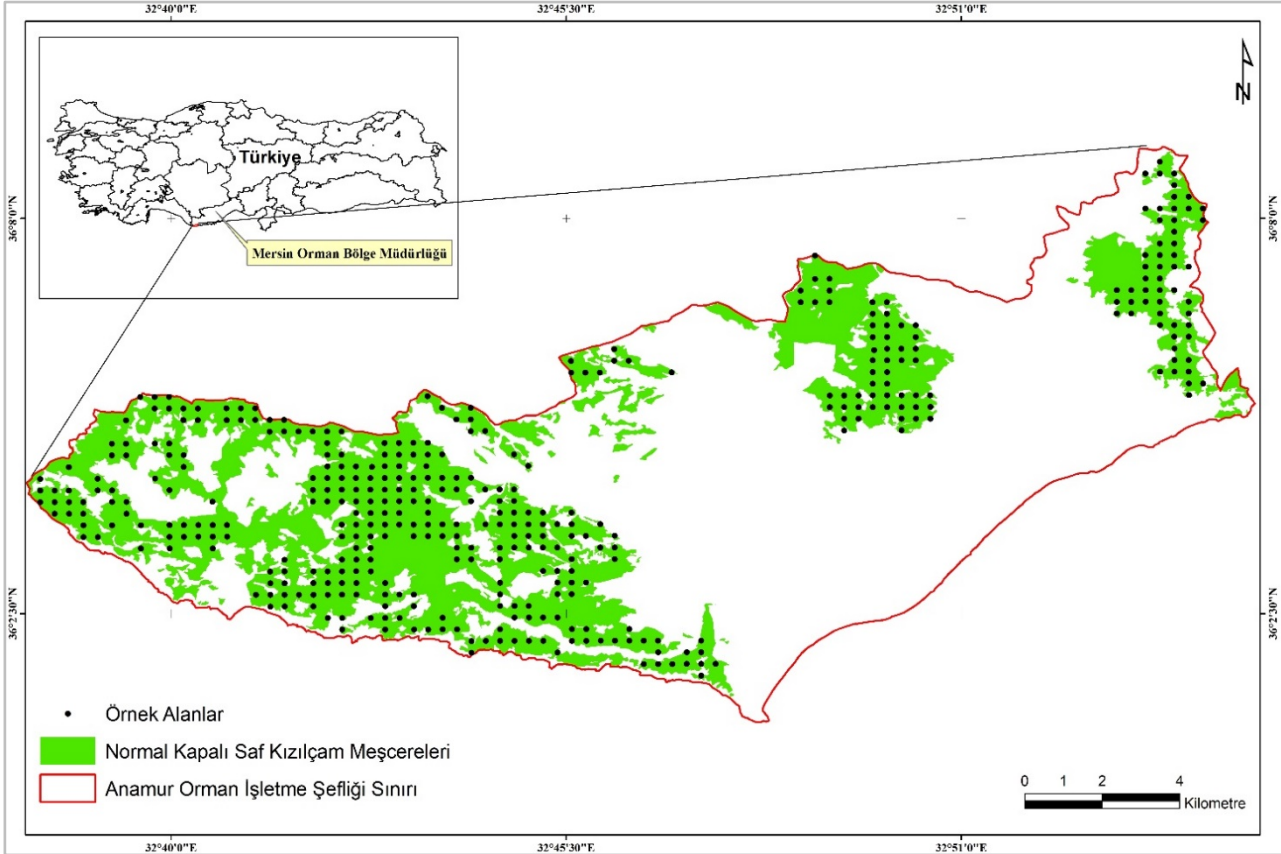
Bu çalışmada; (i) saf kızılçam meşcerelerinde her bir örnek alana ilişkin TÜB değerlerinin hesaplanması (ii) Landsat 8 Operational Land Imager (OLI) uydu görüntüsünden her bir örnek alana ilişkin bant reflektans, vejetasyon indis ve tekstür değerlerinin elde edilmesi (iii) Her bir örnek alan için Sentinel-1A uydu görüntüsünün her iki polarizasyonuna ilişkin geri yansıtım değerlerinin elde edilmesi (iv) her bir örnek alana ilişkin eğim, bakı ve yükselti değerlerinin hesaplanması ve (v) her bir örnek alana ilişkin hesaplanan TÜB ile uydu görüntülerinden ve topografik verilerden elde edilen değişkenler arasındaki ilişkilerin regresyon analizi ile araştırılması ve modellenmesi amaçlanmıştır.

2. Materyal ve Yöntem

Bu çalışmada saf kızılçam meşcereleri için yerleri sistematik olarak 300 m x 300 m mesafeyle belirlenen toplam 404 adet örnek alan için elde edilen envanter karnelerindeki 8 cm ve üzerindeki ağaçlara ilişkin göğüs yüksekliğindeki çap verileri, 10.09.2015 tarihli Landsat 8 OLI uydu görüntüsü, 06.09.2015 tarihli Sentinel-1A uydu görüntüsü ve çalışma alanına ait ALOS-PALSAR görüntüsünden üretilen sayısal arazi modeli verisi materyal olarak kullanılmıştır.

2.1. Çalışma Alanı

Çalışma alanı (Anamur Orman İşletme Şefliği), Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğü sınırları içerisinde yer almaktadır. Çalışma alanı, 32°53' 32"-32°48'16" kuzey enlemleri ve 36°2' 24"-36°52' 26" doğu boylamları arasında yer almaktadır. Çalışma alanının ortalama yükseltisi 1083 metredir. Çalışma alanının 5657.5 hektara (ha) normal kapalı orman, 2749.5 ha boşluklu kapalı orman ve 8201.5 ha ise açıklık alan olmak üzere toplam 16.608,5 ha'dan oluşmaktadır. Ortalama yıllık sıcaklığı 23.1°C ve yıllık yağış miktarı ise 635.4 mm'dir (Anonim, 2016). Çalışma alanındaki hâkim ağaç türleri kızılçam, meşe ve maki alanlarından oluşmaktadır. Çalışma alanının Türkiye üzerindeki konumunu ve saf kızılçam meşcerelerinin yayılışını gösterir harita Şekil 1'de verilmiştir.



Şekil 1. Çalışma alanının konumu

2.2. Örnek Alanlara İlişkin Topraküstü Biyokütle Değerlerinin Hesaplanması

Saf kızılçam meşcerelerine ilişkin çalışma kapsamında kullanılan 404 adet envanter karnesi verileri Orman İdaresi ve Planlama Dairesi Başkanlığı'ndan temin edilmiştir. Her bir örnek alan için alınan envanter karnesi verisinde her bir ağacın göğüs yüksekliğindeki ($d_{1,3}$) çap verileri kullanılarak önce her bir ağacın topraküstü biyokütle (TÜB)'si, örnek alan içindeki ağaçların biyokütellerinin toplamı ile örnek alanın toplam TÜB miktarı hesaplanmıştır. Daha sonra örnek alan büyüklüğüne (400, 600 ve 800 m²) bağlı olarak örnek alandaki TÜB değerleri hektara çevirme katsayısı ile çarpılarak hektardaki TÜB değerleri hesaplanmıştır. TÜB hesaplanmasında, Şahin (2015) tarafından Mersin Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren saf kızılçam meşcereleri için geliştirilen ve aşağıda yer alan tek girişli TÜB denklemi kullanılmıştır.

$$\ln Y = -2,80486 + 2,16137/d_{1,3} + 2,41102 \times \ln(d_{1,3}) \quad R^2 = 0,957 \quad (2.1)$$

Y= topraküstü biyokütle miktarı (ton)

$d_{1,3}$ = her bir ağacın göğüs yüksekliğindeki çapı (cm)

2.3. Landsat 8 OLI Uydu Görüntüsünden Değişkenlerin Elde Edilmesi

Landsat 8 OLI uydu görüntüsü ücretsiz olarak <https://earthexplorer.usgs.gov> internet adresinden indirilmiştir. Bu çalışma kapsamında, Landsat 8 OLI uydu görüntüsünün bantlarından; 2, 3, 4, 5, 6, 7, 8, 10 ve 11 bantları kullanılmıştır. Çalışmada kullanılan Landsat 8 OLI uydu görüntüsü radyometrik ve geometrik düzeltmeleri içeren Level-1 C formatında elde edildiğinden sadece atmosferik düzeltme yapılmıştır. QGIS 3.22.0 yazılım programı kullanılarak atmosferik düzeltme yapılarak çalışmada kullanılan bantların yansıma değerleri reflektans değerlerine dönüştürülmüştür. Daha sonra elde edilen görüntü çalışma alanının dış sınırına göre kesilerek analize hazır hale getirilmiştir. Bu işlem için ArcGIS 10.6.1 yazılımından yararlanılmıştır. Çalışmada kullanılan Landsat 8 OLI uydu görüntüsüne ait bantlarının üzerine, sayısal örnek alanlar ArcGIS 10.6.1 yazılımı yardımıyla aktarılmıştır. Her bant için her bir örnek alana ait bant reflektans değerleri hesaplanmıştır. Araziye envanter aşamasında örnek alanların konumları GPS ile belirlenmesi nedeniyle örnek alanların koordinatlarının alınması sürecinde oluşabilecek hataları azaltmak ve en aza indirmek amacıyla her bir örnek alana ilişkin reflektans değerlerinin hesaplanmasında örnek alanların düştüğü pikselin (x=GPS ile alınan koordinatların uydu görüntüsü ile çakıştığı nokta) çevresinde yer alan 3x3 pencere genişliğinde yer alan piksellerin reflektans değerlerinin ortalaması alınarak her bir örnek alanın reflektans değeri hesaplanmıştır. Her bir örnek alan ve her bir bant için hesaplanan reflektans değerleri kullanılarak Tablo 1’de verilen bazı vejetasyon indisleri hesaplanmıştır.

Ayrıca bu çalışmada; contrast (CON), correlation (COR), dissimilarity (DIS), entropy (ENT), homogeneity (HOM), mean (M), second moment (SM) ve variance (VAR) olmak üzere toplam sekiz adet tekstür özelliği kullanılmıştır. Bu tekstür özellikleri dört farklı pencere boyutu (3x3, 5x5, 7x7 ve 9x9) ve çalışmada kullanılan Landsat 8 OLI uydu görüntüsünün her bir bandı için ayrı ayrı elde edilmiştir. Her bir bant ve her bir pencere boyutuna göre tekstür özelliklerine ilişkin görüntülerinin elde edilmesinde ENVI yazılımı ve her bir örnek alanın tekstür özelliklerinin hesaplanmasında ArcGIS 10.6.1 yazılımından yararlanılmıştır. Toplamda her bir örnek alana ilişkin 288 (4 adet pencere boyutu x 8 adet tekstür özelliği x 9 adet bant) adet tekstür değeri elde edilmiştir.

Tablo 1
Çalışmada kullanılan vejetasyon indisleri (Vİ)

Vİ	Formül	Kaynak	Vİ	Formül	Kaynak
NDVI	$(B5-B4) / (B5+B4)$	Rouse ve ark. (1974)	NLI	$((B05^2)-B04) / ((B05^2) + B04)(B052) + B04)$	Goel ve Qin (1994)
NDMI	$(B5-B6) / (B5+B6)$	Hardisky ve ark. (1983)	NDTI	$(B5-B7)/(B5+B7)$	Van Deventer ve ark. (1997)
NBR	$(B5-B7) / (B5+B7)$	Key ve Benson (2006)	GDVI	B5-B3	Sripada (2005)
EVI	$2.5x((B5-B4) / (B5+6xB4-7.5xB2+1))$	Liu ve Huete (1995)	SR	B5/B3	Birth ve McVey (1968)
SAVI	$((B5-B4) / (B5+B4+0.5))x(1.5)$	Huete (1988)	FII	$(B7/B5)/(B3/B5)$	Kalinowski Ve Oliver (2004)
GCI	B5-B3-1	Gitelson ve ark. (2003)	GRVI	$(B3-B4)/(B3+B4)$	Sripada ve ark. (2006)
WRI	$(B3+B4)/(B5+B7)$	Mukherjee ve Samuel (2016)	BI	$\text{Sqrt} (B3xB3)+(B4xB4)$	Khan ve ark. (2005)
DVI	(B5-B4)	Tucker (1980)	TCW	$0.0315(B1)+0.2021(B2)+0.3102(B3)+0.1594(B4)-0.6806(B5)-0.6109(B7)$	Frazier ve ark. (2015)

Tablo 1

Çalışmada kullanılan vejetasyon indisleri (devam ediyor)

Vİ	Formül	Kaynak	Vİ	Formül	Kaynak
ARVI	$(B5 - 2(B4) + (B3) / (B5) + 2(B4) - (B3))$	Kaufman ve Tanre (1992)	TCG	$-0.1603(B1) - 0.2819(B2) - 0.4934(B3) + 0.7940(B4) - 0.0002(B5) - 0.1446(B7)$	Frazier ve ark. (2015)
NDMI	$(B5-B6) / (B5+B6)$	Hardisky ve ark. (1983)	MSAVI	$(2 \times B5 + 1 - \sqrt{(2 \times B5 + 1)^2 - 8 \times (B5 - B4)}) / 2$	Qi ve ark. (1994)
NDBal	$(B6-B10)/(B6+B10)$	Li ve Chen (2014)	EVI2	$2.4 \times (B05 - B04) / (B05 + B04 + 1.0)$	Jiang ve ark. (2008)
NBR2	$(B6-B7)/(B6+B7)$	DeVries ve ark. (2016)	IPVI	$(B5 / (B5 + B4))$	Crippen (1990)
SIPI	$(B5-B3)/(B5+B4)$	Penuelas ve ark. (1995)	NDPI	$(B5*B5)/(B5+B4)*(B5+B3)$	Wang ve ark. (2017)
PSSR	$(B5 / B4)$	Blackburn (1998)	ND32	$(B4 - B3) / (B4 + B3)$	Lu ve ark. (2004)
ND73	$(B7-B4)/(B7+B4)$	Lu ve ark. (2004)			

2.4. Sentinel-1A Uydu Görüntüsüne İlişkin Değişkenlerin Elde Edilmesi

Sentinel-1A görüntüsüne bazı ön işlemler (benek azaltma, filtreleme vb.) uygulanarak analize hazır hale getirilmiştir. Sentinel-1A görüntüsü üzerinde çeşitli sebeplerden oluşan ve benek olarak ifade edilen gürültüler olmaktadır. Bu gürültülerin azaltılması gerekmektedir. Bu amaçla, bu çalışmada 5x5 pencere boyutunda Lee-sigma filtresi uygulanmıştır. Daha sonra Sentinel-1A uydu görüntüsüne ait iki farklı (VH ve VV) polarizasyonundan her bir örnek alana ilişkin geri yansıtım değerleri elde edilmiştir. Sentinel-1A görüntüsüne ilişkin tüm ön işlemler Sentinel görüntüleri için geliştirilen SNAP (Sentinel Application Platform) yazılım programında yapılmıştır.

2.5. Topoğrafik Verilerin Elde Edilmesi

Çalışmada topoğrafik veri olarak yükselti, eğim (%) ve bakı (derece) verileri kullanılmıştır. Çalışma alanına ait ALOS-PALSAR uydu görüntüsünden üretilen sayısal arazi modeli verisi kullanılarak ArcGIS 10.6.1 yazılımı kullanılarak eğim ve bakı haritaları üretilmiştir. Üretilen eğim ve bakı haritalarından her bir örnek alana ilişkin eğim (%) ve bakı değerleri (derece) belirlenmiştir. Bununla birlikte sayısal arazi yükselti modelinden her bir örnek alana ilişkin yükselti değerleri elde edilmiştir.

2.6. İstatistiksel Analiz

Topraküstü biyokütle (TÜB) miktarını tahmin eden modellerin geliştirilmesi amacıyla Landsat 8 OLI uydu görüntüsünden elde edilen bant reflektans, vejetasyon indis ve tekstür özelliklerine ilişkin değerler, Sentinel-1A uydu görüntüsünün her iki polarizasyonundan elde edilen geri yansıtım değerleri ve topoğrafik (eğim, bakı ve yükselti) verilerinden yararlanılmıştır. Söz konusu açıklayıcı değişkenlerden hangisinin/hangilerinin TÜB değerleri ile istatistiksel olarak anlamlı ilişkiler gösterdiği ileri aşamalı regresyon metodu ile belirlenmiştir. Geliştirilen regresyon modellerinin matematiksel ifadesi denklem 2.2'de verilmiştir. Modellerin oluşturulmasında SPSS istatistik paket programından yararlanılmıştır (SPSS 15.0 Inc. 2007). Çalışmada 404 adet örnek nokta verisinin %80'i (323 adedi) modellerin oluşturulmasında ve %20'si (81 adedi) ise modellerin uygunluğunun test edilmesinde kullanılmıştır. Modellerin uygunluğunun test edilmesinde eşleştirilmiş iki örnek t testinden (paired t test) yararlanılmıştır.

$$TÜB = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n + \varepsilon \quad (2.2)$$

Denklemdede; $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ regresyon katsayılarını, $X_1, X_2, X_3, \dots, X_n$ açıklayıcı değişkenleri, ε ise normal ve homojen dağıldığı varsayılan model hatalarını ifade etmektedir. Bu çalışmada kullanılan istatistiksel model başarı ölçütleri ise düzeltilmiş belirtme katsayısı ($R_{düz}^2$) ve standart hata ($S_{y.x}$)'dır.

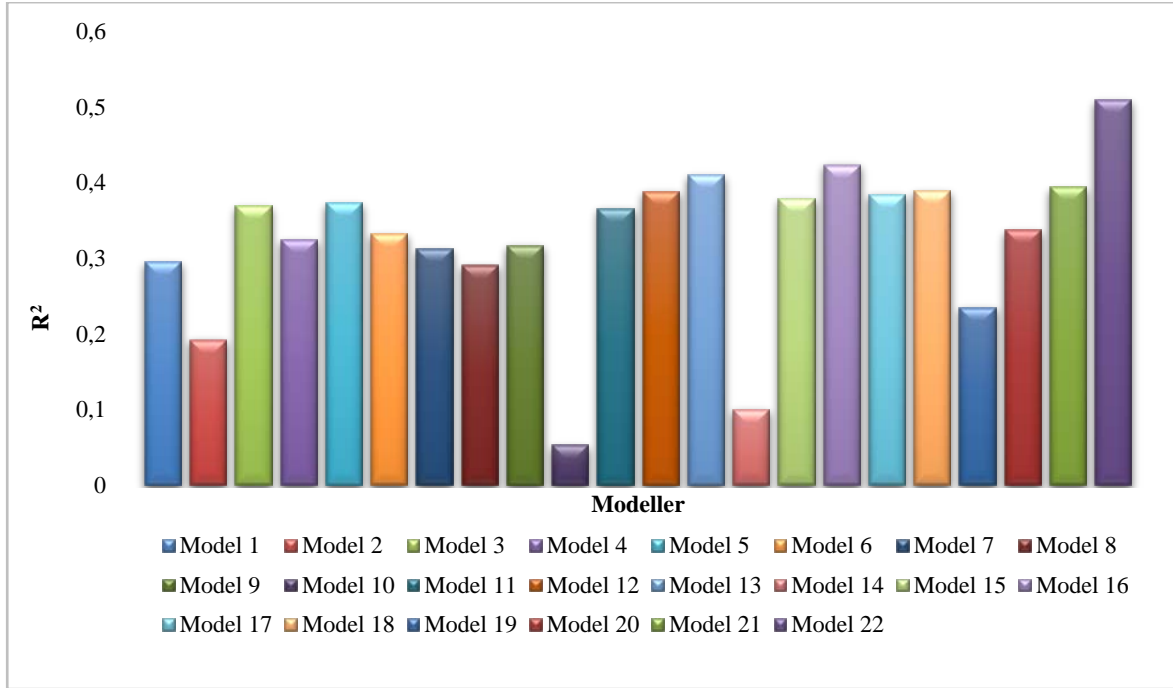
3. Bulgular ve Tartışma

Topraküstü Biyokütle (TÜB)'nin miktarının tahminine ilişkin olarak toplam 22 adet regresyon modeli geliştirilmiştir (Güverçin, 2022). Geliştirilen modellerde yer alan açıklayıcı değişken grupları ve bu modellere ilişkin model belirtme katsayısı ve standart hata değerleri Tablo 2'de verilmiştir. Ayrıca, geliştirilen 22 farklı regresyon modelinin temsil kabiliyetini daha açık bir şekilde göstermek amacıyla model belirtme katsayıları Şekil 2 üzerinde de gösterilmiştir. Bununla birlikte, geliştirilen en iyi regresyon modele (model 22) ilişkin sonuçlar Tablo 3'te verilmiştir.

Tablo 2

Geliştirilen regresyon modellerine ilişkin değişken grubu, model belirtme katsayısı ve standart hata değerleri

Model No	Modele Giren Değişken Grubu	Belirtme Katsayısı ($R_{düz}^2$)	Standart hata ($S_{y.x}$)
1	Landsat 8 OLI bant reflektans değerleri	0.295	35.48
2	Landsat 8 OLI vejetasyon indisi değerleri	0.192	48.24
3	Landsat 8 OLI tekstür değerleri	0.369	30.97
4	Landsat 8 OLI bant reflektans ve vejetasyon indisi değerleri	0.325	35.21
5	Landsat 8 OLI bant reflektans ve tekstür değerleri	0.373	34.92
6	Landsat 8 OLI vejetasyon indisi ve tekstür değerleri	0.332	36.57
7	Landsat 8 OLI bant reflektans ve Sentinel-1A (VV/VH) yansımaya değerleri	0.313	36.47
8	Landsat 8 OLI vejetasyon indisi ve Sentinel-1A (VV/VH) yansımaya değerleri	0.292	36.46
9	Landsat 8 OLI tekstür ve Sentinel-1A (VV/VH) yansımaya değerleri	0.317	32.87
10	Sentinel-1A (VV/VH) yansımaya değerleri	0.053	36.59
11	Landsat 8 OLI bant reflektans ve topoğrafik veri değerleri	0.366	33.80
12	Landsat 8 OLI vejetasyon indisi ve topoğrafik veri değerleri	0.388	32.04
13	Landsat 8 OLI tekstür ve topoğrafik veri değerleri	0.410	32.48
14	Sentinel-1A (VV/VH) yansımaya ve topoğrafik veri değerleri	0.100	38.11
15	Landsat 8 OLI bant reflektans, vejetasyon indisi ve topoğrafik veri değerleri	0.379	33.64
16	Landsat 8 OLI vejetasyon indisi, tekstür ve topoğrafik veri değerleri	0.424	32.78
17	Landsat 8 OLI bant reflektans, Sentinel-1A (VV/VH) yansımaya ve topoğrafik veri değerleri	0.384	33.89
18	Landsat 8 OLI vejetasyon indisi, Sentinel-1A (VV/VH) yansımaya, Sentinel-1A (VV/VH) geri yansıtım ve topoğrafik veri değerleri	0.389	33.76
19	Landsat 8 OLI tekstür, Sentinel-1A (VV/VH) yansımaya ve topoğrafik veri değerleri	0.235	47.46
20	Landsat 8 OLI bant reflektans, vejetasyon indisi, tekstür ve Sentinel-1A (VV/VH) yansımaya değerleri	0.337	37.39
21	Landsat 8 OLI bant reflektans, vejetasyon indisi, tekstür ve topoğrafik veri değerleri	0.394	34.52
22	Landsat 8 OLI bant reflektans, vejetasyon indisi, tekstür, Sentinel-1A (VV/VH) yansımaya ve topoğrafik veri değerleri	0.509	28.40



Şekil 2. Regresyon modellerine ilişkin başarı düzeyleri


Tablo 3

Topraküstü biyokütleyi en iyi tahmin eden model sonuçları


Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	P değeri
Sabit değişken	2.320.132	451.983	5.133	0.000
Bant 2	0.060	0.018	3.332	0.001
Bant 8	-0.071	0.011	-6.748	0.000
Sentinel 1A_VH_DN	-0.136	0.047	-2.905	0.004
Sentinel 1A_VV_DN	0.084	0.023	3.627	0.000
Bant 4_77_ENT	-0.124	0.059	-2.103	0.036
Bant 5_77_M	1.547	0.274	5.656	0.000
Bant 6_33_M	-0.567	0.188	-3.018	0.003
Bant 10_55_M	-1.020	0.249	-4.090	0.000
Bant 10_77_SM	-0.141	0.056	-2.516	0.013
Bant 10_99_SM	0.210	0.070	2.980	0.003
Bant 11_55_ENT	-0.111	0.036	-3.099	0.002
WRI	-2.058.689	493.233	-4.174	0.000
GCI	-1.057.723	166.528	-6.352	0.000
DVI	0.034	0.016	2.195	0.029
ARVI	-1.784.760	225.199	-7.925	0.000
NDMI	1.709.558	314.643	5.433	0.000
Yükselti	0.0106	0.013	8.267	0.000
Bakı	-0.056	0.024	-2.353	0.019
R ² =0.509 Sy. x= 28.39				

*33:3x3, 55:5x5, 77: 7x7 ve 99: 9x9 pencere boyutunu ifade etmektedir.

Model 22'ye göre tahmin edilen TÜB'nin örnek alanlardan hesaplanan TÜB'ye göre değişimi Şekil 3'te verilmiştir. Söz konusu modele ait hata terimlerinin tahmini TÜB'ye göre dağılımı Şekil 4'te verilmiştir.



Şekil 3. En iyi modele göre hesaplanan topraküstü biyokütle ile tahmin edilen topraküstü biyokütle ilişkisi



Şekil 4. En iyi modelle elde edilen hatalar-tahmini topraküstü biyokütle ilişkisi

Model 22'nin örneklenen topluma istatistiksel olarak uygun olup olmadığı eşleştirilmiş iki örnek t-testi kullanılarak bağımsız bir veri grubu ile test edilmiştir. Söz konusu test sonuçları ($t=-1.817$ ve $p=0.073$) Model 22'nin çalışma alanına uygun olduğunu göstermiştir. Diğer bir ifade ile, Model 22'nin TÜB verilerinin alındığı saf Kızıldağ meşcerelerinde güvenle kullanılabileceği sonucuna ulaşılmıştır. Çalışma kapsamında geliştirilen 22 farklı regresyon model (üçü hariç) sonuçlarının düşük çıkması birçok faktöre bağlı olabilmektedir. Bu faktörlerin bazılarını şu şekilde açıklanabilir. Çalışmada kullanılan uydu görüntülerinin çekim saatinin sabah saatlerinde olması ve çalışma alanında kuzey bakılarda yer alan örnek alanların gölgede kalması nedenleriyle bantların yansıma değerlerinin hatalı olarak hesaplanmasına neden olmuş olabilir.

Elde edilen modellerin başarı düzeyleri (Şekil 2) incelendiğinde Landsat 8 OLI uydu görüntüsünün bant parlaklık, vejetasyon indis ve tekstür değerleri, Sentinel-1A uydu görüntüsünün her iki polarizasyona (VH ve VV) ilişkin parlaklık değerleri ile yükselti ve bakının bağımsız değişkenler olarak yer aldığı 22 nolu model en başarılı model ($R_{düz}^2 = 0.509$) olarak bulunmuştur. İkinci en başarılı model ($R_{düz}^2 = 0.424$) ise vejetasyon indisleri ve tekstür özellikleri ile yükselti ve bakının bağımsız değişkenler olarak yer aldığı 16 nolu model olmuştur. Üçüncü en başarılı model ($R_{düz}^2 = 0.410$) ise tekstür ile yükselti ve bakının bağımsız değişkenler olarak yer aldığı 13 nolu model olmuştur. Diğer 19 modelin başarı düzeyleri %40'ın altındadır. En iyi üç modelde modele giren bağımsız değişkenler incelendiğinde yükseklik ve bakının üç modelde yer aldığı görülmüştür. Bu bakımdan yükselti ve bakının model başarısına katkı sağladığı görülmüştür. Benzer sonuçlar, Xie ve ark. (2017) tarafından Spot-5 uydu görüntüsü kullanılarak bazı meşcere parametrelerinin tahmin edilmesine ilişkin yapılan çalışmada elde edilmiştir. Çalışmada Spot-5 uydu görüntüsünden elde edilen vejetasyon indisleri ve tekstür verileri kullanılarak meşcere hacmi, göğüs yüzeyi ve ağaç sayısı gibi meşcere parametreleri ayrı ayrı tahmin edilmiştir. Daha sonra topoğrafik özellikler eklenerek oluşturulan modellerin önceki modellere göre daha başarılı sonuçlar verdiği görülmüştür. Diğer bir ifadeyle topoğrafik faktörler modellerin başarı düzeylerini artırmıştır. Landsat ve Sentinel uydu verilerinin kullanıldığı bazı literatür çalışmaları incelendiğinde, bu çalışmalarda uydu görüntülerinin bant yansıma veya reflektans, vejetasyon indis ve tekstür özelliklerine ilişkin verilerinin yalnız ya da kombinasyonları kullanılarak tahminler yapılmıştır (Luo ve ark., 2021; Askar ve ark., 2018; Phua ve ark., 2017; López-Serrano ve ark., 2020; Keleş ve ark., 2021). Yapılan bu çalışmalarda elde edilen modellerin başarı oranı, örnek alan verilerinin elde edildiği meşcerelerin yapısı, uydu verilerinin kullanılma ve işleme aşamasında ortaya çıkan hatalar, verilerin elde edildiği alanın coğrafik, topoğrafik özellikleri ve farklı modelleme (çoğul regresyon, makine öğrenimi regresyon, yapay sinir ağı, destek vektör regresyon, derin öğrenme v.b) yöntemleri nedeniyle farklılıklar gösterebilmektedir.

Maynard ve ark. (2007) tarafından yapılan TÜB ile Landsat 7 ETM+ uydu görüntüsünden elde edilen bant yansıma ve vejetasyon indisleri arasındaki ilişkilerin araştırıldığı çalışmada NDVI indisinin bağımsız değişken olarak yer aldığı modelde, model belirtme katsayısı 0.41, SAVI indisinin bağımsız değişken olarak yer aldığı modelde ise 0.44, GVI ve WI indislerinin birlikte bağımsız değişkenler olarak yer aldığı modelde ise 0.51 bulunmuşken, bant 4 ve bant 7'nin bağımsız değişkenler olarak yer aldığı modelde ise 0.53 olarak bulunmuştur. Benzer sonuçlar bu çalışma ile birlikte Turgut ve Günlü (2022) tarafından yapılan çalışmada da görülmüştür. Bu çalışmada sadece bantların bağımsız değişken olarak yer aldığı modelde, model belirtme katsayısı 0.295 bulunmuşken, sadece vejetasyon indislerinin yer aldığı model ise 0.192 (Tablo 1) bulunmuştur. Bununla birlikte Li ve ark. (2009) tarafından yapılan bir çalışmada farklı orman ekosistemlerinde Landsat TM uydu görüntüsünden elde edilen bant parlaklık ve vejetasyon indisleri kullanılarak TÜB tahmin edilmiştir. Bu çalışmanın aksine TÜB'nin tahmin edilmesinde vejetasyon indisleri bant parlaklık değerlerine göre daha iyi sonuçlar vermiştir. Li ve ark. (2009) çalışmasına benzer sonuçlar Heiskanen, 2006; Gaspari ark., (2010) ve Günlü ark., (2014) tarafından yapılan çalışmalarda da görülmüştür. Farklı vejetasyon indisleri ile TÜB değerleri arasında güçlü ilişkiler bulunmaktadır. Landsat TM uydu görüntüsünden elde edilen vejetasyon indisleri (özellikle de NDVI ve SR) ile TÜB değerleri arasında yüksek ilişkiler bulunmuştur (Zheng ve ark., 2007; Yan ve ark., 2015). Ancak bu çalışmada vejetasyon indislerinin bağımsız değişken olarak yer aldığı modellerde NDVI değişkeni hiçbir modelde yer almamıştır. Buna karşın SR vejetasyon indisleri ise sadece iki modelde bağımsız değişken olarak yer almıştır. Oysaki Turgut ve Günlü (2022) tarafından saf karaçam meşcerelerinde TÜB'nin tahmin edilmesine yönelik çalışmada, vejetasyon indisleriyle geliştirilen modelde yer alan bağımsız değişkenlerle (FII, EVI, DVI, IPVI) bu çalışmada geliştirilen modellerde yer alan bağımsız değişkenler arasında benzerlik olduğu görülmüştür.

Dube ve Mutanga (2015) yaptıkları bir çalışmada TÜB ile Landsat 8 OLI uydu görüntüsünden elde edilen bant parlaklık, vejetasyon indis ve tekstür değerleri arasındaki ilişkiler incelenmiştir. Elde edilen sonuçlar incelendiğinde tekstür değerlerinin bağımsız değişken olarak yer aldığı modelin daha başarılı sonuç verdiği görülmüştür. Benzer sonuçlar bu çalışmada da bulunmuştur (Tablo 1). Tekstür özellikleri; bant parlaklık, reflektans ve vejetasyon indis değerlerine göre TÜB'nin tahmin edilmesinde daha iyi sonuçlar vermiştir. Bununla birlikte hangi tekstür özelliğinin TÜB ile en iyi ilişki verdiğinin bilinmesi önem arz etmektedir. Yapılan çalışmalarda TÜB'nin tahmin edilmesinde farklı tekstür özelliklerinin modellerde yer aldığı buna ilişkin belirgin bir standart olmadığı görülmektedir. Bu durum çalışma alanının topoğrafik yapısı, meşcere

yapısı, uydu görüntülerinin alım zamanı, kullanılan uydu görüntüsü vb. durumlara bağlı olarak değişiklik göstermektedir. Dolayısıyla TÜB'nin tahmin edilmesine ilişkin hangi tekstür özelliğinin daha etkili olduğu konuyla ilgili yapılacak çalışmaların sayısının artmasıyla mümkün olabilecektir. Burada uygun tekstür özelliğinin belirlenmesinde bant ve pencere boyutunun da belirlenmesi önem arz etmektedir (Chen ve ark., 2004). Bu çalışmada modellerde yer alan tekstür değişkenleri incelediğinde yukarıda yapılan açıklamaları desteklemektedir. Çalışmada bulunan en başarılı model (Model 22; Tablo 2) incelendiğinde farklı bantlara, pencere boyutlarına ve tekstür özelliklerine ilişkin farklı değişkenlerin modelde yer aldığı görülmektedir. Benzer durum tekstür değişkenlerinin yer aldığı diğer modellerde de mevcuttur. Diğer bir ifadeyle farklı bantlar ve farklı pencere boyutları modellere girmiştir. Bu çalışmada tekstür özelliklerine ilişkin dikkat çekici unsur dört farklı tekstür özelliğinin (ağırlıklı olarak da M, ENT ve SM gibi tekstür özellikleri) modellerde yer aldığı görülmüştür. Turgut ve Günlü (2022) tarafından saf karaçam meşcerelerinde yapılan çalışmada ise tekstür özelliklerinden ağırlıklı olarak COR ve M gibi tekstür özelliklerinin modelde yer aldığı görülmüştür.

Kumaar ve ark. (2016) tarafından yapılan bir çalışmada Landsat 8 OLI ve ALOS-2 uydu görüntüleri kullanılarak çoğul regresyon analizi ile TÜB tahmin edilmeye çalışılmıştır. Çalışmada Landsat 8 OLI uydu görüntüsünden elde edilen değişkenler ve ALOS-2 uydu görüntüsünden elde edilen değişkenler ayrı ayrı kullanılarak modelleme yapılmıştır. Landsat 8 OLI görüntüsünün değişkenleriyle model belirtme katsayısı 0.788 ve ALOS-2 görüntüsünün değişkenleriyle ise belirtme katsayısı 0.742 bulunmuştur. Aynı çalışmada her iki uydu görüntüsünden elde edilen değişkenlerin birlikte kullanılmasıyla model belirtme katsayısının arttığı görülmüştür ($R^2=0.859$). Nuthammachot vd. (2022) tarafından yapılan çalışmada Sentinel-1 ve Sentinel-2 uydu görüntülerinden elde edilen değişkenlerin modellerde ayrı ayrı ve birlikte kullanılarak TÜB tahmin edilmeye çalışılmıştır. Elde edilen sonuçlara bakıldığında sadece Sentinel-1 geri yansıtım değerlerinin yer aldığı modelde model belirtme katsayısı 0.34, sadece Sentinel-2 uydu görüntüsünden elde edilen değişkenlerin kullanılmasıyla model belirtme katsayısı 0.82 ve her iki uydu görüntüsünden elde edilen değişkenlerin birlikte yer aldığı modelde ise model belirtme katsayısı 0.84 bulunmuştur. Benzer sonuçlar bu çalışmada da bulunmuştur. Sadece Sentinel-1A uydu görüntüsünün her iki polarizasyonu ilişkin elde edilen yansıma değerleri ile geliştirilen modelin (Tablo 2) model belirtme katsayısı 0.053 bulunmuşken, modele yükselti değişkenin girilmesiyle model belirtme katsayısı 0.10'a yükselmiştir. Bununla birlikte çalışmada kullanılan diğer değişkenler birlikte yer aldığı modellerde model başarılarının yükseldiği görülmüştür (Tablo 2). Keleş ve ark. (2021) tarafından yapılan bir çalışmada saf sarıçam meşcerelerinde Sentinel-1 ve Sentinel-2 uydu görüntüleri kullanılarak topraküstü meşcere karbonunu tahmin etmeye çalışmışlardır. Bu çalışmada üç farklı modelleme (çoğul regresyon, destek vektör makinesi ve derin öğrenme) kullanılmıştır. Yedi farklı regresyon modeli (bant, vejetasyon indis, tekstür, bant-vejetasyon indis, bant-geri yansıtım, vejetasyon indis-geri yansıtım ve bant-vejetasyon indis-geri yansıtım) geliştirilmiştir. Elde edilen sonuçlar incelendiğinde en düşük model belirtme katsayısı 0.442 ile Sentinel-1 geri yansıtım değerlerinin bağımsız değişken olarak yer aldığı modelde elde edilmiştir. Bununla birlikte geri yansıtım değişkenlerinin bant yansıma değerleri ile birlikte yer aldığı modelde model belirtme katsayısı 0.634 ve vejetasyon indis değerleri ile 0.672 olarak bulunmuştur. Bu sonuçlara bakıldığında Sentinel-1 uydu görüntüsünden elde edilen değişkenlerin diğer optik görüntülerden elde edilen değişkenlerin birlikte kullanılması halinde modellerin başarı düzeylerinin artabileceği kanaatine varılmaktadır. Benzer sonuçlar Norovsuren ve ark. (2019) tarafından yapılan çalışmada bulunmuştur.

Konuyla ilgili yapılan çalışmalarda çoğul regresyon analizinden farklı modelleme tekniklerinin kullanıldığı çalışmalarda literatürde yer almaktadır. Xie ve ark. (2009) yaptığı çalışmada Landsat ETM+ uydu görüntüsünden hesaplanan vejetasyon indis ve bant parlaklık değerleri ile TÜB arasındaki ilişkiler çoğul regresyon ve yapay sinir ağları modelleme teknikleri kullanılarak modellenmiştir. Model başarıları incelendiğinde yapay sinir ağlarının, regresyon modeline göre daha iyi sonuç verdiği görülmüştür. Shao ve Zhang (2016) tarafından yapılan çalışmada, Landsat 8 OLI ve Radarsat-2 uydu görüntülerinden elde edilen değişkenler birlikte kullanılarak TÜB rasgele orman modelleme tekniğini kullanarak modellemişler ve model belirtme katsayısı 0.82 bulunmuştur. Keleş ve ark. (2021) tarafından yapılan çalışmada regresyon analizi ile birlikte destek vektör makinesi ve derin öğrenme modelleme teknikleri de kullanılmıştır. Bu modelleme tekniklerinde elde edilen başarı düzeyi regresyon modelindeki başarı düzeyine göre daha yüksek bulunmuştur (destek vektör makinesi için model belirtme katsayısı 0.877 ve derin öğrenme için ise model belirtme katsayısı 0.857). Baloloy ve ark. (2018) Sentinel-2 ve Rapideye uydu görüntülerinden elde edilen vejetasyon indisleri ve bant yansıma değerleri ile TÜB arasındaki ilişkiler Multivariate Adaptive Regression Splines (MARS)

modelleme tekniği ile modellenmiştir. Elde edilen sonuçlar incelendiğinde, bant değerleri ile Sentinel-2 için model belirtme katsayısı 0.62 ve Rapideye için ise 0.92, vejetasyon indisleri ile Sentinel-2 için 0.89 ve Rapideye için ise 0.82 olarak bulunmuştur.

4. Sonuçlar

Bu çalışmada, Landsat 8 OLI uydu görüntüsünden elde edilen bant parlaklık, vejetasyon indis ve tekstür özelliği değerleri, Sentinel-1A uydu görüntüsünden elde edilen parlaklık ve geri yansıtım değerleri ve ALOS-PALSAR görüntüsünden üretilen sayısal arazi modeli verisinden elde edilen yükselti, eğim ve bakı değerleri ile topraküstü biyokütle (TÜB) arasındaki ilişkiler çoğul regresyon analizi ile modellenmiştir. Toplam 22 adet farklı regresyon modeli geliştirilmiştir. Bu modellerin başarı düzeyleri bir model hariç (Model 10; $R_{düz}^2=0.053$), $R_{düz}^2=0.10$ ile $R_{düz}^2=0.509$ arasında değiştiği görülmüştür. En iyi üç model sıralandığında; Landsat 8 OLI uydu görüntüsünün bant parlaklık, vejetasyon indis ve tekstür özellikleri, Sentinel-1A aktif uydu görüntüsünün her iki polarizasyona (VV ve VH) ilişkin parlaklık değerleri, yükselti ve bakı değişkenlerinin yer aldığı model ($R_{düz}^2=0.509$; $Sy.x=28.40$) birinci sırada, Landsat 8 OLI uydu görüntüsünün vejetasyon indis ve tekstür özellikleri, yükselti ve bakı değişkenlerinin yer aldığı model ($R_{düz}^2=0.424$; $Sy.x=32.78$) ikinci sırada, Landsat 8 OLI uydu görüntüsünün tekstür özellikleri, yükselti ve bakı değişkenlerinin yer aldığı model ($R_{düz}^2=0.410$; $Sy.x=32.48$) ise üçüncü sırada yer almıştır. Landsat 8 OLI, Sentinel-1A uydu görüntüleri ve ALOS-PALSAR görüntüsünden üretilen sayısal arazi modeli verisinden elde edilen yükselti, eğim ve bakı verileri kullanılarak TÜB tahminine ilişkin geliştirilen modellerin sadece üç tanesinde orta düzeyde başarı sağlanmış ve geri kalan modellerin başarı düzeylerinin düşük olduğu görülmüştür. Orta düzeyde başarılı olan bütün modellerde bağımsız değişken olarak topoğrafik faktörlerinden yükselti ve bakı özelliklerinin yer aldığı görülmüştür. Bu nedenle, topoğrafik faktörlerin özellikle de yükselti ve bakı faktörlerinin TÜB'nin tahmin edilmesinde başarı düzeylerini olumlu yönde etkilediği söylenebilir. Bununla birlikte gelecekte konuyla ilgili yapılacak çalışmalarda yüksek çözünürlüklü pasif uydu görüntüleri ile uzun dalga boyuna sahip (P ve L bantları) aktif uydu görüntüleri, gelişen teknolojiyle birlikte günümüzde yaygın olarak kullanılan insansız hava araçları ile LİDAR görüntülerinden elde edilecek farklı değişkenler farklı modelleme teknikleriyle (derin öğrenme, yapay sinir ağları, destek vektör makinesi, rasgele orman yöntemi vb.) kullanılarak TÜB'nin tahminine yönelik model başarıları artırılabilir.

Teşekkür

Bu makale, Doç. Dr. Alkan GÜNLÜ danışmanlığında Yüksek Lisans öğrencisi İzzet GÜVERÇİN tarafından hazırlanan "Saf Kızılçam Meşcerelerinde Sentinel-1A ve Landsat 8 OLI Uydu Görüntüsü Kullanılarak Topraküstü Biyokütlenin Tahmin Edilmesi (Anamur Orman İşletme Şefliği Örneği)" adlı Yüksek Lisans tezinden üretilmiştir. Çalışmada kullanılan envanter verilerinin temin edilmesinde destek veren Orman Genel Müdürlüğüne ve Orman İdaresi ve Planlama Dairesi Başkanlığı'na teşekkür ederiz.

Yazar Katkıları

İzzet GÜVERÇİN: Verileri elde etmiş, gerekli hesaplamaları yapmış ve makale yazımına katkı sağlamıştır.

Alkan GÜNLÜ: Çalışmanın istatistiksel analizlerini yapmış ve makaleyi yazmıştır.

Çıkar Çatışması

Yazarlar çıkar çatışması bildirmemişlerdir.

Kaynaklar

- Anonim (2016). Orman Genel Müdürlüğü, Anamur Orman Amenajman Planı 2016-2025. Mersin Orman Bölge Müdürlüğü, Ankara: OGM, p.220.
- Askar, N.N., Phairuang, W., Wicaksono, P. and Sayektiningsih, T. (2018). Estimating Aboveground Biomass on Private Forest Using Sentinel-2 Imagery Hindawi Journal of Sensors, 1-11.

- Baloloy, A. B., Blanco, A. C., Candido, C. G., Argamosa, R. L., Dimalag, J. C., Dimapilis, L. C. and Paringit, E. C. (2018). Estimation of mangrove forest aboveground biomass using multispectral bands, vegetation indices and biophysical variables derived from optical satellite imageries: rapideye, planetscope and sentinel-2. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4(3).
- Birth, G. S., and McVey, G. R. (1968). Measuring the color of growing turf with a reflectance spectrophotometer 1. *Agronomy Journal*, 60(6): 640-643.
- Blackburn, G. A. (1998). Spectral indices for estimating photosynthetic pigment concentrations: a test using senescent tree leaves. *International Journal of Remote Sensing*, 19(4): 657-675.
- Brown, S. (2002). Measuring carbon in forests: current status and future challenges. *Environmental Pollution*, 116(3): 363-372.
- Brown, S. and Gaston, G. (1995). Use of forest inventories and geographic information systems to estimate biomass density of tropical forests: application to tropical Africa. In *African greenhouse gas emission inventories and mitigation options: Forestry, land-use change, and agriculture*, pp. 51-62. Springer, Dordrecht.
- Brown, S. and Iverson, L.R. (1992). Biomass estimates for tropical forests. *World Resource Review*, 4 (3): 366-384.
- Brown, S., Gillespie, A.J. and Lugo, A.E. (1989). Biomass estimation methods for tropical forests with applications to forest inventory data. *Forest Science*, 35(4): 881-902.
- Bulut, S., Sivrikaya, F. and Günlü, A. (2022). Evaluating statistical and combine method to predict stand above-ground biomass using remotely sensed data. *Arabian Journal of Geosciences*, 15(9) : 838.
- Bulut, S. (2023). Machine learning prediction of above-ground biomass in pure Calabrian pine (*Pinus brutia* Ten.) stands of the Mediterranean region, Türkiye. *Ecological Informatics*, 74 :101951.
- Chen, D.W., Stow, D.A. and Gong, P. (2004). Examining the effect of spatial resolution and texture window size on classification accuracy: an urban environment case. *International Journal of Remote Sensing*, 25: 2177 - 2192.
- Crippen, R.E. (1990). Calculating the vegetation index faster. *Remote Sensing of Environment*, 34, 71–73.
- DeVries, B., Pratihast, A. K., Verbesselt, J., Kooistra, L., and Herold, M. 2016. Characterizing forest change using community-based monitoring data and Landsat time series. *PloS one*, 11(3).
- Dube, T. and Mutanga, O. (2015). Evaluating the utility of the medium-spatial resolution Landsat 8 multispectral sensor in quantifying aboveground biomass in Umgeni catchment, South Africa. *ISPRS Journal of Photogrammetry and Remote Sensing*, 101: 36-46.
- Eckert, S. (2012). Improved forest biomass and carbon estimations using texture measures from WorldView-2 satellite data. *Remote Sensing*, 4(4): 810-829.
- Foody, G.M. (2003). Remote sensing of tropical forest environments: towards the monitoring of environmental resources for sustainable development. *International Journal of Remote Sensing*, 24(20): 4035-4046.
- Frazier, R.J., Coops, N.C., Wulder, M.A. (2015). Boreal Shield forest disturbance and recovery trends using Landsat time series. *Remote Sens. Environ.*, 170, 317–327.
- Gallaun, H., Zanchi, G., Nabuurs, G.J., Hengeveld, G., Schardt, M. and Verkerk, P.J. (2010). EU-wide maps of growing stock and above-ground biomass in forests based on remote sensing and field measurements. *Forest Ecology and Management*, 260(3): 252-261.
- Gasparri, N. I., Parmuchi, M. G., Bono, J., Karszenbaum, H. and Montenegro, C. L. (2010). Assessing multi-temporal Landsat 7 ETM+ images for estimating above-ground biomass in subtropical dry forests of Argentina. *Journal of Arid Environments*, 74(10): 1262-1270.
- Gitelson, A.A., Gritz, U. and Merzlyak, M.N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271-282.
- Goel, N.S. and Qin, W. (1994). Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. *Remote Sensing Reviews*, 10(4), 309-347.

- Goetz, S. J., Baccini, A., Laporte, N. T., Johns, T., Walker, W., Kellndorfer, J., Houghton R.A. and Sun, M. (2009). Mapping and monitoring carbon stocks with satellite observations: a comparison of methods. *Carbon Balance and Management*, 4(1): 1-7.
- Günlü, A., Ercanlı, İ., Sönmez, T. and Başkent, E.Z. (2014). Prediction of some stand parameters using pan-sharpened IKONOS satellite image. *European Journal of Remote Sensing*, 47(1): 329-342.
- Güverçin, İ. (2022). *Saf kızılçam meşcerelerinde Sentinel-1A ve Landsat 8 OLI uydu görüntüsü kullanılarak topraküstü biyokütlenin tahmin edilmesi (Anamur orman işletme şefliği örneği)* (Yüksek lisans tezi). Erişim adresi: <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Hall, R.J., Skakun, R.S. and Arsenault E.J. (2006). Modeling forest stand structure attributes using Landsat ETM+ data: Application to mapping of aboveground Biomass and stand volume. *Forest Ecology and Management*, 225: 378–390.
- Hardisky, M.A., Klemas, V. and Smart, R.M. (1983). The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, 49: 77 – 83.
- Heiskanen, J. (2006). Estimating aboveground tree biomass and leaf area index in a mountain birch forest using ASTER satellite data. *International Journal of Remote Sensing*, 27(6): 1135-1158.
- Houghton, R.A. (2005). Aboveground forest biomass and the global carbon balance. *Global Change Biology*, 11(6): 945-958.
- Huete, A.R. (1988). A Soil Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, 25:295-309.
- Jiang, Z.Y., Huete, A.R., Didan, K. and Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112, 3833–3845.
- Kalinowski, A. and Oliver, S. (2004). ASTER mineral index processing manual. *Remote Sensing Applications, Geoscience Australia*, pp. 37-36.
- Kaufman, Y.J. and Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE transactions on Geoscience and Remote Sensing*, 30(2): 261-270.
- Keleş, S., Günlü, A. and Ercanlı, İ. (2021). Estimating aboveground stand carbon by combining Sentinel-1 and Sentinel-2 satellite data: a case study from Turkey. In *Forest Resources Resilience and Conflicts* pp. 117-126, Elsevier.
- Key, C.H. and Benson, N.C. (2006). Landscape assessment (LA). In: Lutes, Duncan C.; Keane, Robert E.; Caratti, John F.; Key, Carl H.; Benson, Nathan C.; Sutherland, Steve; Gangi, Larry J. 2006. FIREMON: Fire effects monitoring and inventory system. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins, CO: US Department of Agriculture, Forest Service, Rocky Mountain Research Station, p. LA-1-55, 164.
- Khan, N. M., Rastoskuev, V. V., Sato, Y. and Shiozawa, S. (2005). Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agricultural Water Management*, 77(1-3): 96-109.
- Kumar, K. K., Nagai, M., Witayangkurn, A., Kritiyutanant, K. and Nakamura, S. (2016). Above ground biomass assessment from combined optical and SAR remote sensing data in Surat Thani Province, Thailand. *Journal of Geographic Information System*, 8(04): 506.
- Li, J. J., Wang, X. R., Wang, X. J., Ma, W. C. and Zhang, H. (2009). Remote sensing evaluation of urban heat island and its spatial pattern of the Shanghai metropolitan area, China. *Ecological Complexity*, 6(4): 413-420.
- Li, S., and Chen, X. (2014). A New Bare-Soil Index for rapid mapping developing areas using landsat 8 data. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 2(4).
- Liu, H.Q. and Huete, A. (1995). A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. *IEEE transactions on geoscience and remote sensing*, 33(2), 457-465.
- López-Serrano, P. M., Cárdenas Domínguez, J. L., Corral-Rivas, J. J., Jiménez, E., López-Sánchez, C. A. and Vega-Nieva, D. J. 2020. Modeling of aboveground biomass with Landsat 8 OLI and machine learning in temperate forests. *Forests*, 11(1): 11.

- Lu, D. (2005). Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. *International Journal of Remote Sensing*, 26(12): 2509-2525.
- Lu, D. (2006). The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing* 27(7): 1297–1328.
- Lu, D., Mausel, P., Brondizio, E. and Moran, E. (2004). Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. *Forest Ecology and Management*, 198(1–3): 149–167.
- Luo, K., Wei, Y., Du, J., Liu, L., Luo, X., Shi, Y., Pei, X., Lei, N., Song, C., Li, J. and Tang, X. (2021). Machine learning-based estimates of aboveground biomass of subalpine forests using Landsat 8 OLI and Sentinel-2B images in the Jiuzhaigou National Nature Reserve, Eastern Tibet Plateau. *Journal of Forestry Research*, 1-12.
- Maynard, C. L., Lawrence, R. L., Nielsen, G. A. and Decker, G. (2007). Modeling vegetation amount using bandwise regression and ecological site descriptions as an alternative to vegetation indices. *GIScience and Remote Sensing*, 44(1): 68-81.
- Mukherjee, N. R., and Samuel, C. (2016). Assessment of the temporal variations of surface water bodies in and around Chennai using Landsat imagery. *Indian Journal of Science and Technology*, 9(18): 1-7.
- Muukkonen, P. and Heiskanen, J. (2005). Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. *Remote sensing of Environment*, 99(4): 434-447.
- Nelson, R., Krabill, W. and Tonelli, J. (1988). Estimating forest biomass and volume using airborne laser data. *Remote Sensing of Environment*, 24(2): 247-267.
- Nelson, R.F., Kimes, D.S., Salas, W.A. and Routhier, M. (2000). Secondary forest age and tropical forest biomass estimation using thematic mapper imagery: single-year tropical forest age classes, a surrogate for standing biomass, cannot be reliably identified using single-date tm imagery. *Bioscience*, 50(5): 419-431.
- Norovsuren, B., Tseveen, B., Batomunkuev, V. and Renchin, T. (2019). Estimation for forest biomass and coverage using Satellite data in small scale area, Mongolia. In *IOP Conference Series: Earth and Environmental Science* (Vol. 320, No. 1, p. 012019). IOP Publishing.
- Nuthammachot, N., Askar, A., Stratoulis, D. and Wicaksono, P. (2022). Combined use of Sentinel-1 and Sentinel-2 data for improving above-ground biomass estimation. *Geocarto International*, 37(2): 366-376.
- Penuelas, J., Baret, F. and Filella, I. (1995). Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica*, 31(2): 221-230.
- Phua, M. H., Johari, S. A., Wong, O. C., Ioki, K., Mahali, M., Nilus, R., Coomes, D. A., Maycock, C.R. and Hashim, M. (2017). Synergistic use of Landsat 8 OLI image and airborne LiDAR data for above-ground biomass estimation in tropical lowland rainforests. *Forest Ecology and Management*, 406: 163-171.
- Qi, J., Chehbouni, A.L., Huete, A.R., Kerr, Y.H. and Sorooshian, S. (1994). A modified soil adjusted vegetation index (MSAVI). *Remote Sensing of Environment* 48, 119–126.
- Rouse, J.W., Hass, R.H., Shell, J.A. and Deering, D.W. (1974). Monitoring vegetation systems in the great plains with ERTS-1. *Proceedings, 3rd Earth Resources Technology Satellite Symposium*, 1: 309-317.
- Roy, P.S. and Ravan, S.A. (1996). Biomass estimation using satellite remote sensing data—an investigation on possible approaches for natural forest. *Journal of Biosciences*, 21(4): 535-561.
- Sader, S.A., Waide, R.B., Lawrence, W. T. and Joyce, A.T. (1989). Tropical forest biomass and successional age class relationships to a vegetation index derived from Landsat TM data. *Remote Sensing of Environment*, 28: 143-198.
- Santos, J.R., Freitas, C.D., Araujo, L.S., Dutra, L.V., Mura, J.C., Gama, F.F., Soler, L.D. and Sant’anna, S. J. (2003). Airborne P-band SAR applied to the aboveground biomass studies in the Brazilian tropical rainforest. *Remote Sensing of Environment*, 87: 482-493.

- Schroeder, P., Brown, S., Mo, J., Birdsey, R. and Cieszewski, C. (1997). Biomass estimation for temperate broadleaf forests of the United States using inventory data. *Forest Science*, 43(3): 424-434.
- Shao, Z. and Zhang, L. (2016). Estimating forest aboveground biomass by combining optical and SAR data: a case study in Genhe, Inner Mongolia, China. *Sensors*, 16(6): 834.
- SPSS. (2007). Institute Inc. SPSS Base 15.0 User's Guide.
- Sripada, R. P. (2005). Determining in-season nitrogen requirements for corn using aerial color-infrared photography. North Carolina State University.
- Sripada, R. P., Heiniger, R. W., White, J. G. and Meijer, A. D. (2006). Aerial color infrared photography for determining early in-season nitrogen requirements in corn. *Agronomy Journal*, 98(4): 968-977.
- Steininger, M.K. (2000). Satellite estimation of tropical secondary forest above-ground biomass: data from Brazil and Bolivia. *International Journal of Remote Sensing*, 21(6-7): 1139-1157.
- Şahin, A. (2015). *Mersin yöresi saf Kızılçam (Pinus brutia Ten.) meşcerelerinde hasılat araştırmaları* (Doktora tezi). Erişim adresi: <https://tez.yok.gov.tr/UlusalTezMerkezi>
- Thenkabail, P. S., Stucky, N., Griscom, B. W., Ashton, M. S., Diels, J., Van der Meer, B. and Enclona, E. (2004). Biomass estimations and carbon stock calculations in the oil palm plantations of African derived savannas using IKONOS data. *International Journal of Remote Sensing*, 25(23): 5447-5472.
- Tiwari, A.K. (1994). Mapping forest biomass through digital processing of IRS-IA data. *International Journal of Remote Sensing*, 15(9): 1849-1866.
- Tomppo, E., Nilsson, M., Rosengren, M., Aalto, P. and Kennedy, P. (2002). Simultaneous use of Landsat-TM and IRS-1C WiFS data in estimating large area tree stem volume and aboveground biomass. *Remote Sensing of Environment*, 82(1): 156-171.
- Tucker, C.J. (1980). A spectral method for determining the percentage of green herbage material in clipped sample. *Remote Sensing of Environment*, 9(2): 175-181.
- Turgut, R. and Günlü, A. (2022). Estimating aboveground biomass using Landsat 8 OLI satellite image in pure Crimean pine (*Pinus nigra* J.F. Arnold subsp. *pallasiana* (Lamb.) Holmboe) stands: a case from Turkey. *Geocarto International*, 37(3) : 720-734.
- Van Deventer, A. P., Ward, A. D., Gowda, P. H. and Lyon, J. G. (1997). Using thematic mapper data to identify contrasting soil plains and tillage practices. *Photogrammetric Engineering and Remote Sensing*, 63, 87-93.
- Wang, C., Chen, J., Wu, J., Tang, Y., Shi, P., Black, T.A. and Zhu, K. (2017). A snow-free vegetation index for improved monitoring of vegetation spring green-up date in deciduous ecosystems. *Remote Sens. Environ.* 196, 1-12.
- Xie, S., Wang, W., Meng, J., Zhao, T. and Huang, G. (2017). Estimation of forest stand parameters using SPOT-5satellite images and topographic information. Preprints.<https://doi.org/10.20944/preprints201710.0017.v1>
- Xie, Y., Sha, Z., Yu, M., Bai, Y. and Zhang, L. (2009). A comparison of two models with Landsat data for estimating above ground grassland biomass in Inner Mongolia, China. *Ecological Modelling*, 220(15): 1810-1818.
- Yan, F., Wu, B. and Wang, Y. (2015). Estimating spatiotemporal patterns of aboveground biomass using Landsat TM and MODIS images in the Mu Us Sandy Land, China. *Agricultural and Forest Meteorology*, 200: 119-128.
- Zhao, F., Guo, Q. and Kelly, M. (2012). Allometric equation choice impacts lidar-based forest biomass estimates: A case study from the Sierra National Forest, CA. *Agricultural and Forest Meteorology*, 165: 64-72.
- Zheng, D., Rademacher, J., Chen, J., Crow, T., Bresee, M., Le Moine, J. and Ryu, S.R. (2004). Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. *Remote Sensing of Environment*, 93(3): 402-411.

- Zheng, G., Chen, J. M., Tian, Q. J., Ju, W. M. and Xia, X. Q. (2007). Combining remote sensing imagery and forest age inventory for biomass mapping. *Journal of Environmental Management*, 85(3): 616-623.
- Zianis, D. and Mencuccini, M. (2004). On simplifying allometric analyses of forest biomass. *Forest Ecology And Management*, 187(2-3): 311-332.
- Zimble, D. A., Evans, D. L., Carlson, G. C., Parker, R. C., Grado, S. C. and Gerard, P. D. (2003). Characterizing vertical forest structure using small-footprint airborne LiDAR. *Remote sensing of Environment*, 87(2-3): 171-182.