ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

SAF KIZILÇAM MEŞCERELERİNDE SENTİNEL-1A VE LANDSAT 8 OLI UYDU GÖRÜNTÜSÜ KULLANILARAK TOPRAKÜSTÜ BİYOKÜTLENİN TAHMİN EDİLMESİ (ANAMUR ORMAN İŞLETME ŞEFLİĞİ ÖRNEĞİ)

İzzet GÜVERÇİN

ORMAN MÜHENDİSLİĞİ ANA BİLİM DALI

ÇANKIRI
2022

Her hakkı saklıdır

TEZ ONAYI

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 tez çalışması 28/02/2022 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman **:** Doç. Dr. Alkan GÜNLÜ

Jüri Üyeleri **:**

Başkan **:** Doç. Dr. Alkan GÜNLÜ
Orman Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye **:** Prof. Dr. Sedat KELEŞ
Orman Mühendisliği Anabilim Dalı
Çankırı Karatekin Üniversitesi

Üye **:** Prof. Dr. Fatih SİVRİKAYA
Orman Mühendisliği Anabilim Dalı
Kastamonu Üniversitesi

Yukarıdaki sonucu onaylarım

Prof. Dr. İbrahim ÇİFTÇİ

Enstitü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğine göre hazırlamış olduğum "**Saf Kızılçam Meşcerelerinde Sentinel-1A Ve Landsat 8 OLI Uydu Görüntüsü Kullanılarak Topraküstü Biyokütlenin Tahmin Edilmesi (Anamur Orman İşletme Şefliği Örneği)**" konulu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, tezin Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü'nden başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve bu çalışmanın Çankırı Karatekin Üniversitesi tarafından kullanılan "Bilimsel İntihal Tespit Programı"yla tarandığını, "intihal içermediğini" beyan ederim. Çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması halinde ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm. Çankırı Karatekin Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim (28/02/2022).

İzzet GÜVERÇİN

ÖZET

Yüksek Lisans Tezi

SAF KIZILÇAM MEŞCERELERİNDE SENTİNEL-1A VE LANDSAT 8 OLI UYDU GÖRÜNTÜSÜ KULLANILARAK TOPRAKÜSTÜ BİYOKÜTLENİN TAHMİN EDİLMESİ (ANAMUR ORMAN İŞLETME ŞEFLİĞİ ÖRNEĞİ)

İzzet GÜVERÇİN

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Alkan GÜNLÜ

Bu çalışmada, Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğü, Anamur Orman İşletme Şefliği sınırları içerisinde yayılış gösteren saf kızılçam meşcrelerinde; Landsat 8 OLI, Sentinel-1A ve bazı topoğrafik veriler kullanılarak topraküstü biyokütlenin modellenmesi amaçlanmıştır. Çalışmada toplam 404 adet örnek alana ilişkin envanter karnesi verisi kullanılmıştır. Bu örnek alan verilerinin 323 (%80) adedi modellerin oluşturulmasında ve 81 (%20) adedi ise modellerin test edilmesinde kullanılmıştır. Her bir örnek alana ilişkin topraküstü biyokütle değerleri allometrik denklem kullanılarak hesaplanmıştır. Her bir örnek alana ilişkin Landsat 8 OLI uydu görüntüsünden bant reflektans, vejetasyon indis ve tekstür değerleri, Sentinel-1A uydu görüntüsünün her iki polarizasyonu için parlaklık ve geri yansıtım değerleri ile Alos-Palsar uydu görüntüsünden üretilen Sayısal Yükseklik Model (SYM) verisinden yükselti, eğim ve bakı değerleri hesaplanmıştır. Topraküstü biyokütle ile Landsat 8 OLI, Sentinel-1A ve DEM verisinden elde edilen değişkenler arasındaki ilişkiler çoğul regresyon analizi ile modellenmiştir. Toplam 22 farklı regresyon modeli geliştirilmiştir. Geliştirilen modeller arasında en iyi ilişki (R_a^2= 0,509 ; $Sy.x$= 28,39900), Landsat 8 OLI uydu görüntüsünün Bant2, Bant8 bant reflektans değerleri, WRI, GCI, DVI, ARVI, NDMI vejetasyon indisleri, B4_77_ENT, B5_77_M, B6_33_M, B10_55_M, B10_77_SM, B10_99_SM, B11_55_ENT tekstür değerleri, Sentinel-1A uydu görüntüsünün iki polarizasyona (VH_DN, VV_DN) ilişkin parlaklık değerleri ile yükselti ve bakının bağımsız değişkenler olarak yer aldığı modelle elde edilmiştir.

2022, 56 sayfa

ANAHTAR KELİMELER: Topraküstü biyokütle, Sentinel-1A uydu görüntüsü, Landsat 8 OLI uydu görüntüsü, Kızılçam

ABSTRACT

Master of Science Thesis

ESTIMATING ABOVEGROUND BIOMASS USING SENTINEL-1A AND LANDSAT 8 OLI SATELLITE IMAGE IN PURE CALABRIAN PINE (*PINUS BRUTIA* TEN.) STANDS (A CASE STUDY IN ANAMUR FOREST PLANNING UNIT)

İzzet GÜVERÇİN

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

Advisor: Assoc. Prof. Dr. Alkan GÜNLÜ

In this study, it was aimed to model the aboveground biomass by using Landsat 8 OLI, Sentinel-1A and some topographic data in pure red pine stands distributed within the boundaries of Anamur Forest Planning Unit, Anamur Forest Management Enterprise, Mersin Regional Directorate of Forestry. A total of 404 sample field data were used in the study. Of these sample field data, 323 (80%) were used in the creation of the models and 81 (20%) in the testing of the models. Above-ground biomass values for each sample area were calculated using the allometric equation in this study. Band brightness, vegetation indices and texture values from Landsat 8 OLI satellite image, reflectance and back scattering values for both polarizations (VH and VV) of Sentinel-1A satellite image, and elevation, slope and aspect values from Digital Elevation Model (DEM) data produced from Alos-Palsar satellite image were calculated for each sample plot. The relationships between aboveground biomass and variables obtained from Landsat 8 OLI, Sentinel-1A and DEM data were modeled by multiple regression analysis. A total of 22 different regression models were developed. The best relationship among the developed models (R_a^2= 0,509 ; $Sy.x$= 28,39900); Band2, Band8 brightness, WRI, GCI, DVI, ARVI, NDMI vegetation indices, B4_77_ENT, B5_77_M, B6_33_M, B10_55_M, B10_77_SM, B10_99_SM, B11_55_ENT texture values of Landsat 8 OLI satellite image, reflectance values for both polarizations (VH and VV) of Sentinel-1A image with the elevation and aspect as independent variables were obtained

2022, 56 pages

Keywords: Aboveground biomass, Sentinel-1A satellite image, Landsat 8 OLI satellite image, Red pine

ÖNSÖZ VE TEŞEKKÜR

Saf Kızılçam Meşcerelerinde Sentinel-1A ve Landsat 8 OLI Uydu Görüntüleri Kullanılarak Topraküstü Biyokütlenin Tahmin Edilmesi (Anamur Orman İşletme Şefliği Örneği) isimli bu çalışma, Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalı'nda yüksek lisans tezi olarak hazırlanmıştır.

Bu tez çalışmasının başından sonuna kadar her aşamasında, yardımlarıyla çalışmamın tamamlanmasını sağlayan, kendisinden sürekli yararlandığım danışman hocam Sayın Doç. Dr. Alkan GÜNLÜ'ye çok teşekkürlerimi sunarım.

Bu çalışmamda destek ve katkılarını esirgemeyen, bilgi ve tecrübelerinden yararlandığım hocalarım sayın Prof. Dr. Sedat KELEŞ'e ve sayın Prof. Dr. Fatih SİVRİKAYA'ya sonsuz teşekkürlerimi sunarım

Bu tez çalışması için gereken envanter karnelerini ve bölgenin haritalarına ulaşmamı sağlayan Orman İdaresi ve Planlama Dairesi Başkanlığı'na çok teşekkürlerimi sunarım.

Eğitim ve özel hayatımda bugüne kadar en büyük destekcim olan başta ilk öğretmenim olan babama, anneme, kardeşime teşekkürlerimi sunarım. Akademik olarak bu yola çıkmamda bana olan inançlarını her zaman gösteren sınıf arkadaşlarıma, birlikte çalıştığım meslektaşlarıma teşekkürlerimi sunmayı bir borç bilirim. Yapılan bu çalışmanın farklı araştırmalara öncü olması ve katkıda bulunabilmesini dilerim.

İzzet GÜVERÇİN

Çankırı, Şubat 2022

İÇİNDEKİLER

ÖZET ..... **i**
ABSTRACT ..... **ii**
ÖNSÖZ VE TEŞEKKÜR ..... **iii**
SİMGELER DİZİNİ ..... **v**
KISALTMALAR DİZİNİ..... **vi**
ŞEKİLLER DİZİNİ ..... **viii**
ÇİZELGELER DİZİNİ ..... **ix**
1. GİRİŞ **1**
2. MATERYAL VE YÖNTEM **7**
2.1 Çalışma Alanının Tanıtımı **7**
2.2 Çalışma Alanına İlişkin Yapılan Çalışmalar **8**
2.3 Materyal **8**
2.4 Yöntem **9**
2.4.1 Envanter karnelerine ilişkin değerlendirmeler **9**
2.4.2 Landsat 8 OLI uydu görüntüsüne ilişkin değerlendirmeler **10**
2.4.3 Landsat 8 OLI uydu görüntüsünden bant reflektans değerlerinin hesaplanması **11**
2.4.4 Landsat 8 OLI uydu görüntüsünden vejetasyon indis değerlerinin elde edilmesi **12**
2.4.5 Landsat 8 OLI uydu görüntüsünden tekstür değerlerinin üretilmesi..... **14**
2.4.6 Sentinel-1A uydu görüntüsüne ilişkin verilerin elde edilmesi..... **15**
2.4.7 Topogragik verilerin elde edilmesi..... **16**
2.5 İstatistiksel Analiz **17**
3. BULGULAR **19**
3.1 Regresyon Modellerine İle İlgili Bulgular **19**
4. TARTIŞMA **39**
5. SONUÇ VE ÖNERİLER **44**
KAYNAKLAR **46**
ÖZGEÇMİŞ **56**

SİMGELER DİZİNİ

cm	Santimetre
$d_{1.3}$	Göğüs yüksekliği çapı
dbh	Örnek alan içerinde yer alan ağaçların göğüs yüksekliğindeki çapı
h	Boy
ha	Hektar
N	Meşcere ağaç sayısı
r	Korelasyon Katsayısı
R^2_a	Düzeltilmiş belirleme katsayısı

KISALTMALAR DİZİNİ

Albedo	Yansıtabilirlik
AGB	Topraküstü biyokütle (above ground biomass)
ARVI	Atmosfere dayanıklı bitki örtüsü indeksi
ASVI	Atmosferik ve toprak bitki örtüsü indeksi
BI	Parlaklık İndeksi(brightness ındex)
BSTS	En iyi eğim zamansal segmentasyon filtreleme
CBS	Coğrafi bilgi sistemleri
CON	Kontrast (contrast)
COR	Korelasyon (correlation)
DIS	Benzeşmezlik (dissimilarity)
DL	Derin öğrenme (deep learning)
DNN	Derin sinir ağları (deep neural network)
DVI	Fark bitki indeksi (difference vegetation indeks)
ENT	Entropi (entropy)
ETM+	Gelişmiş tematik haritaıcı artı (enhanced thematic mapperplus)
EVI	Gelişmiş bitki indeksi (enhanced vegetation index)
EVI2	Gelişmiş bitki indeksi 2 (enhanced vegetation ındex 2)
FBC	Orman biyokütlesi karbon (forest biomass carbon)
FII	Demir indeksi (ferrous iron index)
GCI	Yeşil klorofil indeksi (green chlorophyll ındex)
GDVI	Genelleştirilmiş fark bitki örtüsü indeksi
GNDVI	Yeşil normalleştirilmiş fark bitki örtüsü indeksi
GPS	Küresel yer sistemi (global position system)
GRVI	Yeşil oran bitki örtüsü indeksi (green ratio veg. index)
HOM	Homojenlik (homogeneity)
IPVI	Kızılötesi yüzde bitki örtüsü indeksi
M	Ortalama (mean)
MID	Orta kızılötesi dalga boyları (middle ınfrared wavelenghts)
MID57	Orta kızılötesi dalga boyları 57(middle ınfrared wavelenghts57)
MLR	Çoklu doğrusal regrsyon (multiple linear regression)
MSAVI	Değiştirilmiş toprak düzeltilmiş bitki indeksi
MSI	Nem stres indeksi (moisture stress ındex)
MSR	Değiştirilmiş basit oran (modified simple ratio)
NBR2	Normalized burn ratio2
ND	Normalleştirilmiş fark normalized difference
ND32	Normalleştirilmiş fark 32 (normalized difference 32)
ND53	Normalleştirilmiş fark 53 (normalized difference 53)
ND73	Normalleştirilmiş fark 73 (normalized difference 73)
NDBal	Normalleştirilmiş fark çıplak arazi indeksi

NDMI	Normalleştirilmiş fark nem indeksi
NDTI	Normalize fark toprak işleme indeksi
NDVI	Normalize fark bitki örtüsü indeksi
NDWI	Normalize fark su indeksi (normalized difference water index)
NLI	Doğrusal olmayan indeks (non-linear index)
OLI	Operasyonel arazi görüntüleyici (operational land ımager)
PCL	Foton sayan lidar (photon counting lidar)
PSSR	Pigmente özgü basit oran (pigment specific simple ratio)
RFR	Rastgele orman regresyonu (random forest regression)
RMS	Karesel ortalama
RMSE	Karesel ortalama hata (root mean square deviation)
RVI	Oran bitki indeksi ratio vegetation index
SAVI	Toprak ayarlı bitki indeksi (soil adjusted vegetation index)
SGB	Stokastik gradyan artırma (stochastic gradient boosting)
SIPI	Yapısal duyarsız pigment indeksi
SM	İkinci an (second moment)
SR	Basit oran (simple ratio)
TCG	Püsküllü yeşillik (tasseled cap greenness)
TCW	Püsküllü ıslaklık (tasseled cap wetness)
TM	Tematik haritalayıcı (thematic mapper)
TÜB	Topraküstü biyokütle
VAR	Varyans (variance)
VIS123	Görünür bantlar (visible bands)
WRI	Su oranı indeksi (water ratio index)

ŞEKİLLER DİZİNİ

Şekil 2.1 Çalışma alanının konumu.....7
Şekil 2.2 Örnek alanlara ilişkin reflektans değerinin hesaplanması……...12
Şekil 2.4 Sentinel-1A uydu görüntüleri ön işlem şeması…….. 16
Şekil 3.1 Regresyon modellerine ilişkin başarı düzeyleri……..36
Şekil 3.2 Hesaplanan topraküstü biyokütle ile tahmin edilen topraküstü biyokütle ilişkisi……..37
Şekil 3.3 En iyi model (model 22) değerlerini esas alan modelle elde edilen hatalar-tahmini topraküstü biyokütle ilişkisi……...37

ÇİZELGELER DİZİNİ

Çizelge 2.2 Örnek alanlara ilişkin tanımlayıcı istatistiki değerler..... 8
Çizelge 2.3 Landsat 8 OLI uydu görüntüsüne ilişkin genel bilgiler..... 10
Çizelge 2.3.1 Landsat 8 OLI uydu görüntüsünün bantlarına ilişkin bazı bilgiler 10
Çizelge 2.4 Çalışmada kullanılan vejetasyon indis bilgileri 13
Çizelge 2.5 Çalışmalarda kullanılan bazı tekstür özelliklerine ilişkin semboller 15
Çizelge 3.1 Topraküstü biyokütleyi bant parlaklık değerlerine göre tahmin eden en iyi model sonuçları 19
Çizelge 3.2 Topraküstü biyokütleyi vejetasyon indis değerlerine göre tahmin eden en iyi model sonuçları…….20
Çizelge 3.3 Topraküstü biyokütleyi tekstür değerlerine göre tahmin eden en iyi model sonuçları…….20
Çizelge 3.4 Topraküstü biyokütleyi bant ve indis değerlerine göre tahmin eden en iyi model sonuçları……..21
Çizelge 3.5 Topraküstü biyokütleyi bant ve tekstür değerlerine göre tahmin eden en iyi model sonuçları……..22
Çizelge 3.6 Topraküstü biyokütleyi indis ve tekstür değerlerine göre tahmin eden en iyi model sonuçları……..23
Çizelge 3.7 Topraküstü biyokütleyi bant ve sentinel değerlerine göre tahmin eden en iyi model sonuçları…….....24
Çizelge 3.8 Topraküstü biyokütleyi indis ve sentinel değerlerine göre tahmin eden en iyi model sonuçları……..……...24
Çizelge 3.9 Topraküstü biyokütleyi indis ve sentinel değerlerine göre tahmin eden en iyi model sonuçları…….. 25
Çizelge 3.10 Topraküstü biyokütleyi sentinel değerlerine göre tahmin eden en iyi model sonuçları……..25
Çizelge 3.11 Topraküstü biyokütleyi bant ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……26
Çizelge 3.12 Topraküstü biyokütleyi indis ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……26
Çizelge 3.13 Topraküstü biyokütleyi tekstür ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……27
Çizelge 3.14 Topraküstü biyokütleyi sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……...27
Çizelge 3.15 Topraküstü biyokütleyi bant, indis ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……..28
Çizelge 3.16 Topraküstü biyokütleyi indis, tekstür ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……...29
Çizelge 3.17 Topraküstü biyokütleyi bant, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……...30

Çizelge 3.18 Topraküstü biyokütleyi indis, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……..31
Çizelge 3.19 Topraküstü biyokütleyi tekstür, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……32
Çizelge 3.20 Topraküstü biyokütleyi bant, indis, tekstür ve sentinel değerlerine göre tahmin eden en iyi model sonuçları……33
Çizelge 3.21 Topraküstü biyokütleyi bant, indis, tekstür ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……34
Çizelge 3.22 Topraküstü biyokütleyi bant, indis, tekstür, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları……...35

1. GİRİŞ

Orman ekosistemleri, sürdürülebilir bir şekilde planlanıp yönetildiğinde topluma birçok mal ve hizmet sunmaktadır. Ormanlar, birçok ekonomik işlevin yanı sıra iklim düzenleme, su koruma, toprak koruma ve biyoçeşitliliğin korunması gibi önemli ekolojik ve çevresel işlevlere sahiptir. Son zamanlarda, yüksek fosil yakıt tüketimi, ormansızlaşma ve arazi kullanımı ve arazi örtüsünde meydana gelen değişiklikler tüm dünyada iklim değişikliği ve küresel ısınma ile sonuçlanan atmosferde ciddi değişimlere neden olmuştur. Orman ekosistemleri, küresel iklim değişikliğinin azaltılması bağlamında CO_2 biyokütlelerinde ve toprakta daha uzun bir süre depolamaktadır (Evrendilek 2004). Orman ekosistemleri, karasal ekosistemlerde küresel karbon bütçesinin önemli bir bileşenidir ve bu ekosistemlerin depoladıkları karbon miktarının doğru bir şekilde belirlenmesine ihtiyaç vardır (Sharma and Rai 2007). Biyokütle tahmini, karbon bütçelerinin belirlenmesi için çok önemlidir.

Biyokütle; bir ağaçtan elde edilebilecek gövde, dal, yaprak, kabuk ve köklerden oluşan ve bu ağaçların oluşturduğu meşcerenin toplam kütle (ağırlık) miktarı olarak ifade edilmektedir (Sun vd. 1980). Biyokütle, ekosistemlerdeki madde birikimi ve değişimini, ormanların karbon stokları ile yıllık karbon depolama kapasitelerini ve ormanların biyoenerji kapasitelerini oluşturur (Saraçoğlu 1988). Son yıllarda dünyada petrol, kömür ve doğal gaz gibi fosil kaynaklı doğal kaynakların gün geçtikçe tükenmesi, petrol fiyatlarının artışı ve bu fosil kaynaklı yakıtların tüketilmesi ile atmosferde karbondioksit konsantrasyonun artması, orman biyokütlesi gibi yenilebilir kaynaklara olan ilgiyi artırmaktadır (Saraçoğlu 1988).

Ormanlar, küresel iklim değişimininde ve atmosferdeki karbonun tutulmasında önemli bir rol oynamaktadır. Ormanların biyokütlesinin tahmin edilmesi, orman ekosistemi verimliliğini değerlendirmek ve karbon bütçelerini kontrol etmek için çok önemlidir (Zianis and Mencuccini 2004, Hall *et al.* 2006). Önemli bir havuz görevi gören orman ekosistemlerindeki karbon döngülerini daha iyi anlamak için biyokütlenin doğru tahmini gereklidir (Houghton 2005).

Genel olarak biyokütle, toprak altı ve topraküstü biyokütle olmak üzere iki farklı biçimde değerlendirilmektedir. Topraküstü biyokütlenin tahmin edilmesinde farklı yaklaşımlar kullanılmaktadır. Bunlar yersel ölçümler (Brown *et al.* 1989, Brown and Iverson 1992, Honza´k et al. 1996, Schroeder *et al.* 1997, Houghton *et al*. 2001, Brown 2002), uzaktan algılama yöntemleri (Tiwari 1994, Roy and Ravan 1996, Nelson et al. 2000, Tomppo *et al*. 2002, Foody *et al.* 2003, Santos *et al*. 2003, Zheng *et al*. 2004, Lu 2005) ve Coğrafi Bilgi Sistemleri (CBS) (Brown and Gaston 1995) olarak sınıflandırmak mümkündür.

Topraküstü biyokütlenin tahmin edilmesinde en doğru ve güvenilir yöntemler yersel ölçümlerdir. Yersel veriler yardımıyla elde edilen allometrik denklemler kullanılarak topraküstü biyokütle doğru bir şekilde tahmin edilmektedir. Bu yöntem, oldukça zaman alıcı, yoğun işgücü isteyen ve uygulaması oldukça zor bir yöntemdir. Özellikle de geniş alanlar da yapılması güçtür (Lu 2005). CBS ile biyokütle tahminlerinin yapılması ise, çok sayıda, doğru, güvenilir bir veri tabanı ve bu veriler arasında kaliteli ilişkilerin olmasını gerektirdiğinden, yaygın olarak kullanılan bir yöntem değildir. Uzaktan algılama yöntemi, veri toplamanın kolaylığı, verilerin hızlı bir şekilde değerlendirilmesine imkan vermesi, bant parlaklık değerleri, vejetasyon indisleri ve tekstür değerleri arasında yüksek korelasyonların olması ve özellikle çok zor ulaşılan alanlarda topraküstü biyokütle tahmininde tercih edilmektedir (Nelson *et al.* 1988, Sader *et al.* 1989, Franklin and Hiernaux 1991, Steininger 2000, Foody *et al.* 2003, Santos *et al.* 2003, Zheng *et al*. 2004, Lu 2005).

Son zamanlarda uzaktan algılama verileri kullanılarak geniş ormanlık alanlarda topraküstü biyokütlenin tahmin edilmesine yönelik çalışmalar yapılmaktadır (Houghton *et al*. 2009, Gallaun *et al*. 2010, Günlü vd. 2014). Özellikle ilk doğal kaynak uydusu olan Landsat uydu görüntüleri kullanılarak herek küçük alanlarda gerekse büyük ormanlık alanlarda kullanılmaktadır. Bununla birlikte farklı uydu görüntüleri kullanılarak topraküstü biyokütlenin tahmin edilmesine yönelik çok sayıda çalışmada literatürde yer almaktadır (Thenkabail *et al.* 2004, Muukkonen and Heiskanen 2005, Eckert 2012).

Son yıllarda yapılan çalışmalarda, radar ve Lidar verileri kullanılarak topraküstü biyokütlenin tahmin edilmesine ilişkin çalışmalar 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 *et al.* 2009). Lidar ve radar uydu verileri farklı orman ekosistemlerinde topraküstü biyokütlenin tahmin edilmesinde kullanılmaktadır (Zhao *et al*. 2012, Zalkos *et al*. 2013, Keleş vd. 2021). Özellikle uzun dalga boyuna sahip radar verilerinin karışık orman ekosistemlerinde topraküstü biyokütlenin tahmin edilmesinde kullanılabileceği ifade edilmiştir (Zimble *et al*. 2003).

Literatürde yapılan çalışmalar incelendiğinde; uzaktan algılama verileri kullanılarak topraküstü biyokütlenin tahmin edilmesinde farklı modelleme teknikleri kullanılmaktadır. Bu modelleme tekniklerinden en çok kullanılanı regresyon analizidir (Zheng *et al*. 2004, Heiskanen 2006, Maynard *et al*. 2007, Günlü vd. 2014, Huang *et al.* 2018, Turgut ve Günlü 2020).

Farklı uzaktan algılama verileri kullanılarak topraküstü biyokütlenin tahmin edilmesine yönelik birçok çalışma literatürde yer almaktadır. Bu çalışmaların bazıları aşağıda açıklanmıştır. Lu (2005) tarafından yapılan bir çalışmada Landsat TM uydu görüntüsünü kullanarak topraküstü biyokütleyi tahmin etmiştir. Çalışmada Landsat TM uydu görüntüsünden elde edilen spektral bant, tekstür ve spektral bant ile tekstür değerlerinin kombinasyonu kullanılarak modeller geliştirilmiştir. Spektral bant verileri ile elde edilen en iyi modelin (R^2=0,75), tekstür için (R^2=0,71) ve spektral bant-tekstür verilerinin kombinasyonu için ise (R^2=0,78) olarak bulunmuştur.

Günlü vd. (2014) tarafından yapılan çalışmada Landsat TM uydu görüntüsünden elde edilen bant reflektans değerleri ve bu değerlerin kullanılmasıyla hesaplanan vejetasyon indis değerleri kullanılarak saf karaçam meşcerelerinde topraküstü biyokütleyi tahmin etmişlerdir. Çalışmada bant reflektans değerleri ile (R^2=0,465) düzeyinde ve vejetasyon indisleri ile (R^2=0,606) düzeyinde model başarıları elde edilmiştir.

Yapılan bir çalışmada, okaliptüs ve çam türlerinin yer aldığı meşcerelerde Landsat 7 ETM+ ve Landsat 8 OLI uydu görüntüleri kullanarak topraküstü biyokütleyi tahmin etmişlerdir. Çalışmada Landsat 7 ETM+ bant değerleri ile en yüksek sonuç (R^2=0,43) ve Landsat 8 OLI uydu görüntüsünün bant değerleri için ise (R^2=0,47) düzeyinde başarı elde edilmiştir. Aynı çalışmada, Landsat 7 ETM+ vejetasyon indis değerleri ile en yüksek sonuç (R^2=0,47) ve Landsat 8 OLI vejetasyon indis değerleri ile en yüksek sonuç (R^2=0,58) düzeyinde elde edilmiştir. (Dube and Mutanga 2015)

Yavaşlı ve Ölgen (2017) tarafından yapılan çalışmada saf kızılçam meşcerelerinde Landsat 8 OLI uydu görüntüsünden elde edilen veriler ile topraküstü biyokütle arasındaki ilişkileri araştırmışlardır. Elde edilen sonuçlarda, Landsat 8 OLI uydu görüntüsünden elde edilen vejetasyon indisleri ve bant parlaklık değerleri ile topraküstü biyokütle arasındaki modelin açıklayıcı %91 düzeyinde bulunmuştur.

Yapılan diğer bir çalışmada, L bantlı Alos palsar görüntüsüne ait HH ve HV polarizasyonları kullanılarak doğal ve plantasyon alanlarında topraküstü biyokütle tahmin edilmeye çalışılmıştır. Bu çalışmada regresyon analizi kullanılmıştır. Elde edilen sonuçlar incelendiğinde, doğal ormanları için HV ve HH polarizasyonlarında sırasıyla 0,88 ve 0,52 düzeyinde başarı bulunmuştur. Bununla birlikte plantasyon alanları için HV ve HH polarizasyonlarında sırasıyla 0,708 ve 0,511 düzeyinde başarı bulunmuştur. (Maina *et al*. 2017)

Huang vd. (2018) tarafından yapılan bir çalışmada Sentinel-1A ve Alos Palsar-2 uydu görüntüsünün kullanarak topraküstü biyokütlenin tahmin edilmesinde geri yansıtım değerlerine ilişkin regresyon denklemleri geliştirmiştir.

Sentinel-2 uydu görüntüsünden elde edilen vejetasyon indisleri ile topraküstü biyokütleyi tahmin etmeye çalışmışılan diğer bir çalışmada elde edilen sonuçlar incelendiğinde model başarısının (R^2 = 0,81) düzeyinde olduğu görülmüştür. (Pandit *et al*. 2018)

Landsat 8 OLI ve LiDAR verilerinin kullanıldığı başka bir çalışma örneğinde topraküstü biyokütle tahmin edilmeye çalışılmıştır. Çalışmada sadece LİDAR görüntüsünden elde edilen veriler kullanılarak elde edilen modelin başarı düzeyi (R^2 = 0,63) sadece Landsat uydu görüntüsünden elde edilen veriler kullanılarak elde edilen modelin başarı düzeyi (R^2= 0,52) ve her iki verinin birlikte kullanılmasıyla elde edilen modelin başarı düzeyi (R^2 = 0,81) olarak bulunmuştur. (Phua *et al*. 2017)

Yapılan diğer bir çalışmada, Sentinel-2 uydu görüntüsünden elde edilen vejetasyon indis değerleri ile topraküstü biyokütle arasındaki ilişkiler araştırılmıştır. Elde edilen sonuçlar incelendiğinde (NDI) 45 vejetasyon indisinin diğer indislere göre daha başarılı sonuç verdiği görülmüştür. Çalışmada (NDI) 45 indisi ile topraküstü biyokütle arasındaki ilişki (R^2 = 0,79) olarak bulunmuştur. (Askar *et al*. 2018)

LiDAR ve Landsat 8 OLI uydu verilerinin kullanıldığı bir çalışmada, görüntülerden elde edilen veriler ile topraküstü biyokütle arasındaki ilişkileri farklı modelleme teknikleri (K-en yakın komşuluk, rastgele orman, destek vektör regresyonu, derin öğrenme ve regresyon analizi) ile tahmin etmeye çalışmışlardır. Çalışmada regresyon analizi ile elde edilen modeller incelendiğinde; LİDAR verisinden elde edilen model başarısının (R^2 = 0,684) Landsat 8 OLI uydu görüntüsünden elde edilen model başarısından (R^2 = 0,594) daha yüksek olduğu görülmüştür. Bununla birlikte her iki verinin birlikte kullanılmasıyla elde edilen model başarısının (R^2 = 0,788) en iyi olduğu görülmüştür. (Zhang *et al*. 2019)

López-Serrano vd. (2020) yaptıkları çalışmada, Landsat 8 OLI uydu görüntüsünden elde edilen bant reflektans, vejetasyon indis ve tekstür değerleri ile topoğrafik ve iklim verilerini kullanarak farklı modelleme teknikleri (destek vektör makinesi ve rasgele orman) topraküstü biyokütleyi tahmin etmeye çalışmışlardır. Elde edilen sonuçlar değerlendirildiğinde destek vektör makinesi ile %80 düzeyinde başarı elde edildiği görülmüştür.

Keleş vd. (2021) yaptıkları çalışmada, Sentinel-1 ve Sentinel-2 uydu verilerinin kombine ederek, farklı modelleme teknikleri (regresyon, derin öğrenme ve destek vektör makinesi) yardımıyla topraküstü meşcere karbon değerleri arasındaki ilişkilerin başarısını belirlemeye çalışmışlardır. Sonuçlara göre Sentinel-1 ve Sentine-2 uydu verilerinin kombine kullanılmasıyla model başarılarının arttığı görülmüştür. Destek vektör makinesi ile elde edilen modelin başarısı (R^2=0,877), derin öğrenme ile elde edilen modelin başarısı (R^2=0,857) ve regresyon analizi ile elde modelin başarısı ise (R^2=0,748) olarak bulunmuştur.

Roy vd. (2021) yaptıkları çalışmada, Sentinel-1 ve Sentinel-2 uydu verilerini kullanarak topraküstü biyokütleyi regresyon analizi ile tahmin etmeye çalışmışlardır. Sonucalar incelendiğinde Sentinel-1 uydu görüntüsünün VH bandında elde edilen geri yansıma değerleri ile topraküstü biyokütle arasında en iyi ilişki (R^2=0,63) bulunmuştur. Sentinel-2 uydu görüntüsünden elde edilen EVI indisi ile topraküstü biyokütle arasında (R^2=0,45) düzeyinde bir ilişki bulunmuştur.

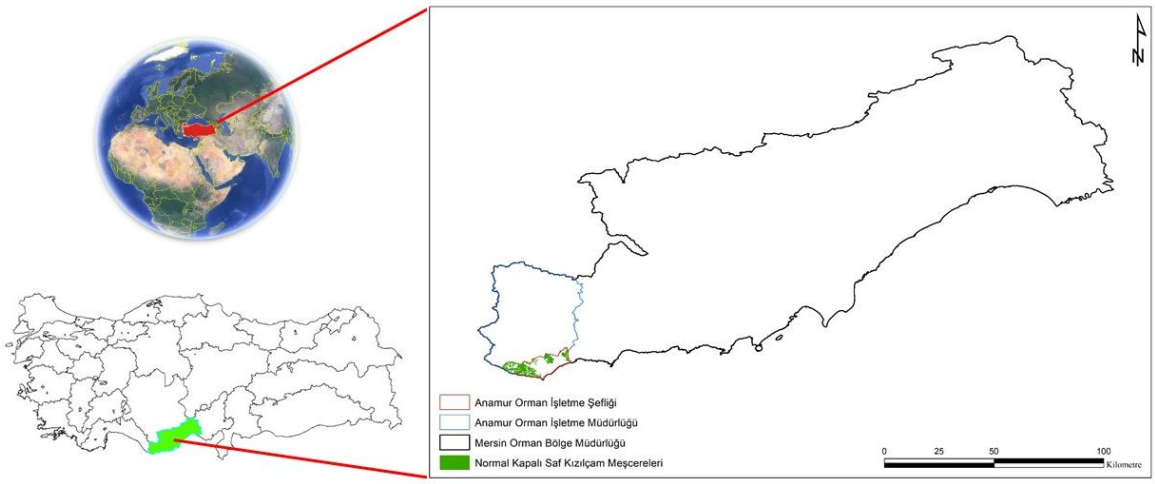
Turgut ve Günlü (2020) tarafından yapılan bir çalışmada saf karaçam meşcerelerinde Landsat 8 OLI uydu görüntüsünden elde edilen bant yansıma, vejetasyon indis ve tekstür verileri ile topraküstü biyokütle arasındaki ilişkiler regresyon analizi ile modellenmiştir. Sonuçlar incelendiğinde tekstür verileri kullanılarak oluşturulan model başarısının ($R^2 = 0,552$) bant yansıma ($R^2 = 0,445$) ve vejetasyon indislerinden ($R^2 = 0,387$) oluşturulan model başarılarından daha iyi sonuç verdiği görülmüştür.

Bu çalışmada; Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğü, Anamur Orman İşletme Şefliğinin Orman Amenajman planının yenilenmesi amacıyla, 2015 yılında yerleri sistematik olarak belirlenen örnek alanlarda yapılan envanter çalışması sonucu elde edilen 404 envanter karnesi verileri kullanılarak her bir örnek alana ilişkin hesaplanan topraküstü biyokütle miktarları ile Landsat 8 OLI uydu görüntüsünden örnek alanların bant reflektans, vejetasyon indis ve tekstür değerleri, Sentinel-1A uydu görüntüsünden her bir örnek alan için hesaplanan geri yansıtım değerleri ile birlikte her bir örnek alana ilişkin eğim, bakı ve yükselti değerleri arasındaki ilişkilerin çoğul regresyon analizi ile araştırılması ve modellenmesi amaçlanmıştır.

2. MATERYAL VE YÖNTEM

2.1 Çalışma Alanının Tanıtımı

Anamur Orman İşletme Şefliği, Mersin Orman Bölge Müdürlüğü, Anamur Orman İşletme Müdürlüğü sınırları içerisinde yer almaktadır. Çalışma alanı, 32^1 30^1-32^0 56^1 doğu meridyenleri ile 36^0 02^1-36^0 31^1 arasında yer almaktadır. Çalışma alanının ortalama yükseltisi 1083 m'dir. Çalışma alanının 5657,5 ha normal kapalı, 2749,5 ha boşluklu kapalı ve 8201,5 ha ise açıklık alan olmak üzere toplam 16.608,50 ha'dan oluşmaktadır. Ortalama yıllık sıcaklığı $23,1^0$C ve yıllık yağış miktarı ise 635,4 mm'dir. Çalışma alanındaki hakim ağaç türleri kızılçam, meşe ve maki alanlarından oluşmaktadır. Çalışma alanının Türkiye üzerindeki konumunu ve saf kızılçam meşcerelerinin yayılışını gösterir harita Şekil 2.1'de verilmiştir.



Şekil 2.1 Çalışma alanının konumu

2.2 Çalışma Alanına İlişkin Yapılan Çalışmalar

Bu çalışmada, 2015 yılında Anamur Orman İşletme Şefliğinin Orman Amenajman planının yenilenmesi sürecinde yapılan envanter çalışması sonucunda 300 m x 300 m mesafeyle alınan 404 örnek alana ilişkin envanter karnesi verileri kullanılmıştır. Çalışmada 404 adet örnek alana ilişkin topraküstü biyokütle değerlerin (ton) ilişkin tanımlayıcı istatistikler Çizelge 2.2'de verilmiştir.

Çizelge 2.2 Örnek alanlara ilişkin tanımlayıcı istatistiki değerler

	N	Minimum	Maksimum	Ortalama	Standart Sapma
Topraküstü Biyokütle(ton)	404	3,16	353,55	85,1806	54,81307

2.3 Materyal

Bu tez çalışmasının gerçekleşmesi aşamasında;

- 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 çap verileri ve örnek alana ilişkin diğer veriler
- Anamur Orman İşletme Şefliği Orman Amenajman planı ve meşcere tipleri haritası
- Anamur Orman İşletme Şefliğine ait Alos-Palsar uydu görüntüsünden üretilen DEM verisi
- 10.09.2015 tarihli Landsat 8 OLI uydu görüntüsü ile 06.09.2015 tarihli Sentinel-1A uydu görüntüsü materyal olarak kullanılmıştır.

2.4 Yöntem

2.4.1 Envanter karnelerine ilişkin değerlendirmeler

Anamur Orman İşletme Şefliğinin, Orman Amenajman planının yenilenmesi amacıyla sürecinde 2015 yılında işletme şefliği sınırları içerisinde envanter çalışmaları yapılmıştır. Envanter çalışmasında saf kızılçam meşcerelerine ilişkin tez 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 $d_{1.3}$ çap verileri kullanılarak önce her bir ağacın topraküstü biyokütlesi örnek alan içindeki ağaçların biyokütlelerinin toplamı ile örnek alanın toplam topraküstü biyokütle miktarı hesaplanmıştır.

Bununla birlikte örnek alan büyüklüğü (400, 600 ve 800 m^2) dikkate alınarak hektara çevirme katsayısı belirlenmiş ve hektara çevirme katsayısı ile örnek alan için hesaplanan topraküstü biyokütle değeri çarpılarak her bir örnek alanın hektardaki topraküstü değeri hesaplanmıştır. Topraküstü biyokütlenin hesaplanmasında, Şahin (2015) tarafından Mersin Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren saf kızılçam meşcereleri için geliştirilen tek girişli topraküstü biyokütle denklemi (2.1) kullanılmıştır.

$$lnY=-2,50486+2,16137/d+2,41102xln(d) \quad (2.1)$$

Y= topraküstü biyokütle miktarı (ton)

d= her bir ağacın göğüs yüksekliğindeki çapı (cm)

Kullanılan denklemin; $R^2=0,957$, $S_{y.x}=88,988$

2.4.2 Landsat 8 OLI Uydu görüntüsüne ilişkin değerlendirmeler

Çalışmada kullanılan Landsat 8 OLI uydu görüntüsü ücretsiz olarak https://earthexplorer.usgs.gov internet adresinden indirilmiştir. Landsat 8 OLI uydu görüntüsünün bantlarından; Bant2, Bant3, Bant4, Bant5, Bant6, Bant 7, Bant8, Bant 10 ve Bant11 bantları bu çalışmada kullanılmıştır. Landsat 8 OLI uydu görüntüne ilişkin genel bilgiler Çizelge 2.3'de ve bantlarına ilişkin bazı bilgiler Çizelge 2.4'de verilmiştir.

Çizelge 2.3 Landsat 8 OLI uydu görüntüsüne ilişkin genel bilgiler

Uydu Görüntüsü Adı	Veri Tipi	Path	Row	Görüntü Tarihi	Görüntü Saati	Bulutluluk (%)	Güneş Geliş Açısı	Güneş Yüksekliği
Landsat 8 OLI	L1TP	176	35	10.09.2015	08:22	8,95	144,33706240	53,82906661

Çizelge 2.3.1 Landsat 8 OLI uydu görüntüsünün bantlarına ilişkin bazı bilgiler

	Bantlar	Dalga boyu (nμ)	Çözünürlük(metre)
Landsat 8 OLI	Bant 2(Mavi)	0,45-0,51	30
	Bant 3(Yeşil)	0,53-0,59	30
	Bant 4 (Kırmızı)	0,64-0,67	30
	Bant 5 (kızılötesi)	0,85-0,88	30
	Bant 6 (Orta kızılötesi)	1,57-1,65	30
	Bant 7 (Termal kızılötesi)	2,11-2,29	30
	Bant8 (Siyah-beyaz)	0,50-0,68	15
	Bant 10 (Uzan Dalga Boyu kızılötesi)	10,60-11,19	100
	Bant 11 (Uzan Dalga Boyu kızılötesi)	11,50-12,.51	100

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 Coğrafi Bilgi Sistemleri yazılımından yararlanılmıştır.

2.4.3 Landsat 8 OLI uydu görüntüsünden bant reflektans değerlerinin hesaplanması

Çalışmada kullanılan Landsat 8 OLI uydu görüntüsüne ait Bant 2, Bant 3, Bant 4, Bant 5, Bant 6, Bant 7, Bant 8, Bant 10 ve Bant 11 bantlarının üzerine, sayısal örnek alanlar CBS yardımıyla aktarılmıştır. Her bant için her bir örnek alana ait bant reflektans değerleri hesaplanmıştır. Arazide envanter aşamasında örnek alanların konumları GPS ile belirlenmesi nedeniyle örnek alanların koordinatlarının alınması sürecinde oluşabilecek hataları azaltmak 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. (Şekil 2.2)

X_1	X_2	X_3
X_4	**X**	X_5
X_6	X_7	X_8

Şekil 2.2 Örnek alanlara ilişkin reflektans değerinin hesaplanması

Şekil 2.2'de X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8 ve **X** piksellerin reflektans değerleri (2.2), X örnek alanların düştüğü pikselin reflektans değeri olmak üzere;

$$\mathbf{X}=\frac{X1+X2+X3+X4+X5+X6+X7+X8+\mathbf{X}}{9} \quad (2.2)$$

Bu şekilde her bir örnek alan için Landsat 8 OLI uydu görüntüsünün çalışmada kullanılan her bir bantı için reflektans değerleri hesaplanmıştır.

2.4.4 Landsat 8 OLI uydu görüntüsünden vejetasyon indis değerlerinin elde edilmesi

Landsat 8 OLI uydu görüntüsünün çalışmada kullanılan her bir bantı için hesaplanan reflektans değerleri kullanılarak Çizelge 2.4'de verilen bazı vejetasyon indisleri hesaplanmıştır.

Çizelge 2.4 Çalışmada kullanılan vejetasyon indis bilgileri

Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
MID (Middle Infrared Wavelengths)	(B6 + B7)	Kaufman and Remer (1994)	GNDVI (Green Norm. Diff. Veg. Index)	(B05 - B03) / (B05 + B03)	Gitelson *et al.* (1996)
NDVI (Normalized Difference Vegetation Index)	(B5-B4) / (B5+B4)	Rouse *et al.* (1974)	NDWI (Norm. Diff. Water Index)	(B5 - B6) / (B5 + B6)	McFeeters (1996)
MSI (Moisture Stress Index)	(B6 / B5)	Hunt and Rock (1989)	MSR (Modified Simple Ratio)	((B5 / B4) -1) / √ ((B5 / B4) +1)	Chen (1996)
NDMI (Norm. Difference Moisture Index)	(B5-B6) / (B5+B6)	Hardisky *et al.* (1983)	NLI (Non-Linear index)	(($B05^2$) - B04) / (($B05^2$) + B04)	Goel and Qin (1994)
NBR (Norm. Burn Ratio)	(B5-B7) / (B5+B7)	Key and Benson (2006)	PSSR (Pigment Specific Simple Ratio)	(B5 / B4)	Blackburn (1998)
EVI (Enhanced Vegetation Index)	2.5 x ((B5 – B4) / (B5 + 6 x B4 – 7.5 x B2 + 1))	Liu and Huete (1995)	IPVI (Infrared Percentage Veg. Index)	(B5 / (B5 + B4))	Crippen (1990)
BI(Brightness Index)	$\sqrt{B3^2+B4^2}$	Khan *et al.* (2005)	FII	*B*Swır2/*B*Nır+ *B*Green/*B*Red	Kalinowski and Oliver (2004)
SR (Simple Ratio)	B_n/B_r	Birth and McVey (1968)	TCG	g1xB+g2xG+g3xR +g4xNır+g5xSwır1+ g6xSwır2	Baig *et al.* (2014)
SIPI (Structural insensitive pigment index)	(B5−B3)/(B5+B4)	Penuelas *et al.* (1995)	TCW	w1xB+w2xG+w3xR +w4xNır+w5xSwır1+ w6xSwır2	Baig *et al.* (2014)
NBR2 (Norm. Burn Ratio2)	Swır1-Swır2/Swır1+Swır2	DeVries *et al.* (2016)	WRI (water ratio index)	Green+Red/Nır+Swır2	Mukherjee and Samuel (2016)
SAVI (Soil Adjusted Vegetation Index)	((B5 – B4) / (B5 + B4 + 0.5)) x (1.5)	Huete (1988)	RVI (Ratio Vegetation Index)	(B5 / B4)	Jordan (1969)

Çizelge 2.4 Çalışmada kullanılan vejetasyon indis bilgileri (devamı)

MSAVI (Modified Soil Adjusted Vegetation Index)	(2xB5+1–sqrt((2xB5+1)^2 – 8x(B5 –B4)))/2	Qi *et al.* (1994)	EVI2 (Enhanced Vegetation Index 2)	2.4x(B05 - B04)/(B05 + B04+1.0)	Jiang *et al.* (2008)
ARVI (Atmospherically Resistant Vegetation Index)	(B5-2(B4)+(B3)/(B5)+2 (B4) -(B3)	Kaufman and Tanre (1992)	DVI (Difference Vegetation Index)	(B5-B4)	Tucker (1980)
ND32	(B4-B3)/(B4+B3)	Lu *et al.* (2004)	MID57	(B6+B7)	Lu *et al.* (2004)
ND53	(B6-B4)/(B6+B4)	Lu *et al.* (2004)	VIS123	(B2+B3+B4)	Lu *et al.* (2004)
ND73	(B7-B4)/(B7+B4)	Lu *et al.* (2004)	Albedo	(B2+B3+ B4+B5+B6+B7)	Lu *et al.* (2004)
NDTI (Norm. Diffe. tillage index)	(B5-B7)/(B5+B7)	Van Deventer *et al.*(1997)	NDBal (Norm. Diff. Bare Land Index)	(OLI 6-TIRs 10)/(OLI 6 + TIRs 10)	Li and Chen(2014)
GCI (Green Chlorophyll Index)	Nır-Green-1	Gitelson *et al.*(2003)	GRVI (Green ratio veg. index)	NIR/Green	Sripada *et al* (2006).
GDVI	Nır-Green	Sripada (2005)			

NDVI: Normalize Edilmiş Bitki İndeksi, NR: NIR-RED, DVI: Bitki Ayrım İndeksi, SAVI: Toprak Etkisi Azaltılmış Vejetasyon İndeksi, IPVI: Kızılötesi yüzde vejetasyon indeksi, EVI: Gelişmiş Vejetasyon İndeksi L=0.5 C1=6.0 C2=7.5

2.4.5 Landsat 8 OLI uydu görüntüsünden tekstür değerlerinin üretilmesi

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 bantı için ayrı ayrı üretilmiştir. Her bir bant ve her bir pencere boyutuna göre tekstür özelliklerinin hesaplanmasında ENVI klasik ve her bir örnek alanın tekstür değerlerinin hesaplanmasında CBS yazılım programlarından yararlanılmıştır. Toplamda her bir örnek alana ilişkin 288 (4 adet pencere x 8 adet teskstür özelliği x 9 adet bant) adet tekstür değeri elde edilmiştir.

Çalışmada kullanılan bazı tekstür özelliklerine ilişkin bilgiler Çizelge 2.5'de verilmiştir.

Çizelge 2.5 Çalışmada kullanılan bazı tekstür özelliklerine ilişkin semboller

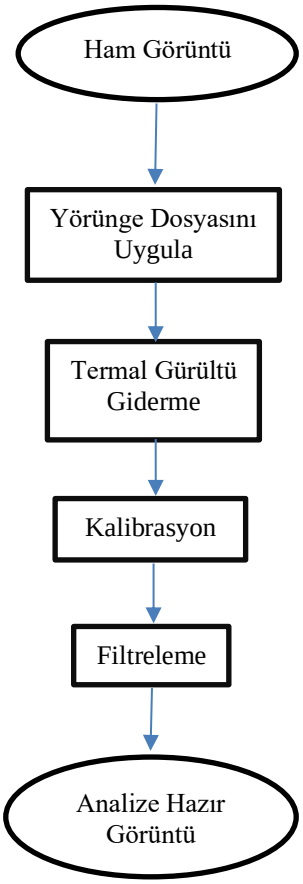
Tekstür Özelliği	Bantlar	Pencere Genişliği			
		3x3	5x5	7x7	9x9
Contrast	Bant 2	Bant 2_3x3_CON	Bant 2_5x5_CON	Bant 2_7x7_CON	Bant 2_9x9_CON
Correlation	Bant 3	Bant 3_3x3_COR	Bant 3_5x5_COR	Bant 3_7x7_COR	Bant 3_9x9_COR
Dissimilarity	Bant 4	Bant 4_3x3_DIS	Bant 4_5x5_DIS	Bant 4_7x7_DIS	Bant 4_9x9_DIS
Entropy	Bant 5	Bant 5_3x3_ENT	Bant 5_5x5_ENT	Bant 5_7x7_ENT	Bant 5_9x9_ENT
Homogeneity	Bant 6	Bant 6_3x3_HOM	Bant 6_5x5_HOM	Bant 6_7x7_HOM	Bant 6_9x9_HOM
Mean	Bant 7	Bant 7_3x3_M	Bant 7_5x5_M	Bant 7_7x7_M	Bant 7_9x9_M
Second	Bant 8	Bant 8_3x3_SM	Bant 8_5x5_SM	Bant 8_7x7_SM	Bant 8_9x9_SM
Moment	Bant 10	Bant 10_3x3_SM	Bant 10_5x5_SM	Bant 10_7x7_SM	Bant 10_9x9_SM
Variance	Bant 11	Bant 11_3x3_V	Bant 11_5x5_V	Bant 11_7x7_V	Bant 11_9x9_V

Bant 3_3x3_COR: Üçüncü bantın 3x3 pencere genişliğinde correlation özelliği,
Bant 5_5x5_ENT: Beşinci bantın 5x5 pencere genişliğinde entropy özelliği
Bant 7_7x7_M: Yedinci bantın 7x7 pencere genişliğinde mean özelliği
Bant 10_9X9_SM: Onuncu bantın 9x9 pencere genişliğinde second moment özelliği

2.4.6 Sentinel-1A uydu görüntüsüne ilişkin verilerin elde edilmesi

Bu çalışmada 06.09.2015 tarihli Sentinel-1A aktif uydu görüntüsü kullanılmıştır. Bu uydu görüntüsüne ait iki farklı (VH ve VV) polarizasyon vardır. Çalışmada Sentinel-1A aktif uydu görüntüsünün her iki polarizasyonundan elde edilen geri yansıtım değerleri kullanılmıştır.

Bu değerlerin elde edilmesinden önce Sentinel-1A uydu görüntüsü bazı ön işlemlerden geçirilerek analize hazır hale getirilmiştir. Bu ön işlemlere ilişkin akış diyagramı Şekil 4'de gösterilmiştir. Analize hazır gelen görüntü üzerine örnek noktalara CBS kullanılarak atılmış ve her bir örnek alanın iki farklı polarizasyona göre geri yansıtım değerleri hesaplanmıştır. Bununla alakalı işlem akış şeması Şekil 2.4 de gösterilmiştir



Şekil 2.4 Sentinel-1A uydu görüntüsü ön işlem aşaması

2.4.7 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 CBS yardımıyla eğim ve bakı haritaları üretilmiştir. Üretilen eğim ve bakı haritalarından her bir örnek alana ilişkin eğim ve bakı değerleri belirlenmiştir. Bununla birlikte sayısal arazi yükselti modelinden her bir örnek alana ilişkin yükselti değerleri elde edilmiştir.

2.5 İstatistiksel Analiz

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) veriler ile topraküstü biyokütle değerleri arasındaki istatistiksel ilişkileri modellemek üzere, çoğul regresyon (stepwise) analizi kullanılmıştır. Regresyon modellerinde tahmin edilmek istenen bağımlı değişken topraküstü biyokütle iken, bağımsız değişkenler ise; Landsat 8 OLI uydu görüntüsünden elde edilen bant reflektans, vejetasyon indis ve tekstür özelliklerine ilişkin değerler, Sentinel-1A uydu görüntüsünün her iki polarizasyonuna göre elde edilen geri yansıtım değerleri ile topoğrafik verilerdir. Topraküstü biyokütle (2.3) ile bant reflektans değerleri, vejetasyon indis ve tekstür özelliklerine, Sentinel-1A uydu görüntüsünün her iki polarizasyonuna göre elde edilen geri yansıtım ve topoğrafik verilere ilişkin değerlere göre tahmin eden regresyon model yapısı aşağıda verilmiştir. Modellerin oluşturulmasında SPSS istatistik paket programından yararlanılmıştır (SPSS 15.0 Inc. 2007) .

Çalışmada 404 adet örnek nokta verisinden %80'i (323 adedi) modellerin oluşturulmasında ve %20'si (81 adedi) ise modellerin test edilmesinde kullanılmıştır. Modellerin test edilmesinde Eşleştirilmiş t testi (Paired t test) kullanılmıştır.

$$\text{Topraküstü Biyokütle} = \beta_0+\beta_1X_1+\beta_2X_2+\beta_3X_3+\ldots\ldots\ldots\ldots\ldots\ldots+\beta_nX_n+\varepsilon \qquad (2.3)$$

Denklemde; β_0, β_1, β_2……βn denklem parametrelerini, X_1, X_2, X_3……Xn Landsat 8 OLI uydu görüntüsünden her bir örnek alan için hesaplanan bant reflektans, vejetasyon indis ve tekstür özelliklerine, Sentinel-1A uydu görüntüsünün her iki polarizasyonuna göre elde edilen geri yansıtım ve topoğrafik verilere ilişkin değerlerini ,ε ise model hatasını ifade etmektedir.

Landsat 8 OLI, Sentinel-1A uydu görüntülerinden ve topoğrafik verilerden elde edilen verilerde %95güven düzeyi için farklı bantların, vejetasyon indislerinin, tekstür özeliklerinin, geri yansıtım ve topoğrafik verilere ilişkin kombinasyonların üzerinden istatistiksel olarak anlamlı model seçenekleri belirlenmiştir.

3. BULGULAR

3.1 Regresyon Modellerine İlişkin Bulgular

Her bir örnek alan için Landsat 8 OLI uydu görüntüsünden elde edilen bant reflektans değerleri, vejetasyon indis değerleri ve tekstür özellikleri, Sentinel-1A uydu görüntüsünden elde edilen parlaklık ve geri yansıtım değerleri ve Alos-Palsar DEM verisinden elde edilen yükselti, eğim ve bakı değerleri ile topraküstü biyokütle değerleri arasındaki ilişkiler çoklu regresyon analizi ile ortaya konulmaya çalışılmıştır. Topraküstü biyokütleye ilişkin olarak toplam 22 adete regresyon modeli geliştirilmiştir. Geliştirilen modeller Çizelge 3.1–3.22'de verilmiştir.

Çizelge 3.1 Topraküstü biyokütleyi bant reflektans değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsyıları**	**Standart hata**	**t-istatistiği**	**p**
	1466,262	171,662	8,542	0,000
Bant 2	-0,1645	0,027	-6,143	0,000
Bant 3	0,0769	0,022	3,455	0,001
Bant 4	0,1329	0,026	5,193	0,000
Bant 7	-0,0387	0,007	-5,408	0,000
Bant 8	-0,0601	0,013	-4,508	0,000
Bant 11	-0,0292	0,005	-5,809	0,000
R_a^2= 0,295	$Sy.x$= 35,47907			

TÜB = 1466,262-0,1645xBant2+0,0769xBant3+0,1329xBant4-0,0387xBant7-0,0601x Bant8-0,0292xBant11

Çizelge 3.2 Topraküstü biyokütleyi vejetasyon indis değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	-5805,771	2539,173	-2,286	0,023
SR	-1881,722	736,210	-2,555	0,011
FII	2951,714	1077,285	2,739	0,007
NDTI	4405,269	1875,214	2,349	0,019
WRI	6500,421	2237,373	2,905	0,004
SIPI	5386,803	996,323	5,406	0,000
ND73	14201,510	5116,444	2,775	0,006
GRVI	4997,921	2324,199	2,150	0,032
EVI	1,5630	0,875	1,786	0,075
BI	-0,0753	0,014	-5,358	0,000
NDBal	1179,422	466,718	2,527	0,012
TCW	0,1000	0,032	3,097	0,002
TCG	-0,1115	0,046	-2,405	0,017

R_a^2=0,192 $Sy.x$= 48,23546

TÜB = -5805,771-1881,722x SR+2951,714x FII+4405,269x NDTI+6500,421xWRI +5386,803xSIPI+14201,510xND73+4997,921xGRVI+1,5630xEVI-0,0753 xBI+1179,422xNDBal+0,1000xTCW-0,1115xTCG

Çizelge 3.3 Topraküstü biyokütleyi tekstür değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	238,149	34,449	6,912	0,000
Bant 2_77_ENT	-0,1696	0,081	-2,094	0,037
Bant 3_55_ENT	0,2661	0,106	2,487	0,014
Bant 3_77_ENT	-0,5888	0,211	-2,786	0,006
Bant 3_99_ENT	0,4873	0,175	2,776	0,006
Bant 5_33_M	-0,5940	0,222	-2,669	0,008
Bant 5_77_M	1,0136	0,324	3,126	0,002
Bant 6_33_M	-0,3527	0,126	-2,780	0,006
Bant 6_77_ENT	-0,2018	0,084	-2,403	0,017
Bant 8_55_M	0,6599	0,200	3,291	0,001
Bant 10_55_M	-1,1304	0,268	-4,212	0,000
Bant 11_99_SM	0,1462	0,037	3,896	0,000

R_a^2= 0,369 $Sy.x$= 30,97156

TÜB=238,149-0,1696xBant2_77_ENT+0,2661xBant_3_55ENT-0,5888x Bant3_77_ENT+0,4873xBant3_99_ENT-0,5940xBant5_33_M+1,0136x Bant5_77_M-0,3527xBant6_33_M-0,2018 x Bant6_77_ENT +0,6599x Bant8_55_M-1,1304xBant10_55_M+0,1462xBant11_99_SM

Çizelge 3.4 Topraküstü biyokütleyi bant ve indis değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	17751534,798	4908897,563	3,616	0,000
Bant 2	0,162	0,069	2,348	0,020
Bant 5	-0,219	0,054	-4,041	0,000
Bant 7	-0,052	0,013	-3,871	0,000
Bant 8	-0,026	0,006	-4,326	0,000
Bant 11	216,029	48,117	4,490	0,000
FII	8613,870	1983,348	4,343	0,000
NDTI	1373,177	453,254	3,030	0,003
GDVI	-17756074,538	4910460,688	-3,616	0,000
GCI	0,301	0,059	5,102	0,000
NLI	-6748,214	1296,671	-5,204	0,000
IPVI	6442,041	1480,532	4,351	0,000
ARVI	17751534,798	4908897,563	3,616	0,000
GRVI	0,162	0,069	2,348	0,020
R_a^2= 0,325	$Sy.x$= 35,20705			

TÜB = 17751534,798+0,162xBant2-0,219xBant5-0,052xBant7-0,026xBant8+216,029 xBant11+8613,870xFII+1373,177xNDTI-17756074,538xGDVI+0,301xGCI-6748,214xNLI+6442,041xIPVI+17751534,798xARVI+0,162xGRVI

Çizelge 3.5 Topraküstü biyokütleyi bant ve tekstür değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	1330,786	207,163	6,423	0,000
Bant 2	-0,1715	0,030	-5,667	0,000
Bant 3	0,1144	0,034	3,313	0,001
Bant 4	0,1053	0,030	3,438	0,001
Bant 5	-0,0118	0,004	-2,852	0,005
Bant 7	-0,0204	0,008	-2,332	0,020
Bant 8	-0,0739	0,013	-5,508	0,000
Bant 11	-0,0191	0,007	-2,688	0,008
Bant 3_55_ENT	0,2100	0,108	1,932	0,054
Bant 3_77_ENT	-0,3430	0,158	-2,163	0,031
Bant 4_99_ENT	0,3032	0,151	1,996	0,047
Bant 5_77_M	0,5434	0,217	2,501	0,013
Bant 6_77_ENT	-0,3209	0,109	-2,923	0,004
Bant 10_33_M	-0,5602	0,238	-2,345	0,020
Bant 11_99_SM	0,1230	0,039	3,093	0,002
R_a^2= 0,373	$Sy.x$= 34,91713			

TÜB = 1330,786-0,1715xBant2+0,1144xBant3+0,1053xBant4-0,0118xBant5-0,0204 xBant7-0,0739xBant8-0,0191xBant11+0,2100xBant3_55_ENT-0,3430x Bant3_77_ENT+0,3032xBant4_99_ENT+0,5434xBant5_77_M-0,3209x Bant6_77_ENT-0,5602xBant10_33_M+0,1230xBant11_99_SM

Çizelge 3.6 Topraküstü biyokütleyi indis ve tekstür değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	1034,917	218,452	4,737	0,000
Bant 3_55_ENT	0,3630	0,115	3,134	0,002
Bant 3_77_ENT	-0,5136	0,165	-3,096	0,002
Bant 4_77_ENT	-0,5099	0,191	-2,655	0,008
Bant 4_99_ENT	0,9950	0,264	3,758	0,000
Bant 5_77_M	0,9114	0,326	2,794	0,006
Bant 6_99_ENT	-0,3999	0,149	-2,680	0,008
Bant 8_99_COR	-0,0859	0,042	-2,014	0,045
Bant 10_55_M	-0,8287	0,298	-2,780	0,006
Bant 11_99_SM	0,0986	0,040	2,437	0,015
SIPI	3449,254	516,722	6,675	0,000
BI	-0,0611	0,008	-6,874	0,000
NDBal	1077,702	288,297	3,738	0,000
TCW	0,0516	0,009	5,210	0,000
TCG	-0,1289	0,018	-7,055	0,000

R_a^2= 0,332 $Sy.x$= 36,56742

TÜB = 1034,917+0,3630xBant3_55_ENT-0,5136xBant3_77_ENT-0,5099x Bant4_77_ENT+0,9950xBant4_99_ENT+0,9114xBant5_77_M-0,3999x Bant6_99_ENT-0,0859xBant8_99_COR-0,8287xBant10_55_M+0,0986x Bant11_99_SM+3449,254xSIPI-0,0611xBI+1077,702xNDBal+0,0516xTCW-0,1289xTCG

Çizelge 3.7 Topraküstü biyokütleyi bant ve sentinel değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	1532,539	178,151	8,602	0,000
Bant 2	-0,1794	0,027	-6,555	0,000
Bant 3	0,0818	0,023	3,589	0,000
Bant 4	-0,1351	0,026	5,143	0,000
Bant 7	-0,0430	0,007	-5.843	0,000
Bant 8	-0,0507	0,014	-3,688	0,000
Bant 11	-0,0311	0,005	-5,970	0,000
Sentinel_VV_DN	0,0825	0,020	4,126	0,000
R_a^2= 0,313	$Sy.x$=36,46780			

TÜB = 1532,539-0,1794xBant2+0,0818xBant3-0,1351xBant4-0,0430xBant7-0,0507 xBant8-0,0311xBant11+0,0825xSentinel_VV_DN

Çizelge 3.8 Topraküstü biyokütleyi indis ve sentinel değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	1034,964	222,051	4,660	0,000
NDPI	-0,0409	0,005	-7,253	0,000
SIPI	3542,541	470,113	7,535	0,000
NDBal	1350,930	294,112	4,593	0,000
TCW	0,0595	0,009	6,465	0,000
TCG	-0,1326	0,017	-7,804	0,000
Sentinel_VH_DN	-0,1638	0,057	-2,866	0,004
Sentinel_VV_DN	0,1210	0,026	4,602	0,000
R_a^2=0,292	Sy. x=36,45909			

TÜB = 1034,964-0,0409x NDPI+3542,541xSIPI +1350,930x NDBal+0,0595xTCW-0,1326xTCG-0,1638xSentinel_VH_DN+0,1210xSentinel_VV_DN

Çizelge 3.9 Topraküstü biyokütleyi tekstür ve sentinel değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	186,429	33,234	5,609	0,000
Bant 2_77_ENT	-0,1641	0,086	-1,893	0,059
Bant 3_55_ENT	0,2365	0,111	2,118	0,035
Bant 3_77_ENT	-0,5345	0,221	-2,409	0,017
Bant 3_99_ENT	0,4484	0,191	2,347	0,020
Bant 7_33_M	-0,3673	0,120	-3,051	0,003
Bant 7_99_ENT	-0,1647	0,078	-2,092	0,037
Bant 8_55_M	0,5215	0,204	2,550	0,011
Bant 10_55_M	-0,5124	0,175	-2,927	0,004
Bant 11_77_SM	0,1246	0,034	3,622	0,000
Sentinel_VH_DN	-0,1352	0,053	-2,505	0,013
Sentinel_VV_DN	0,0845	0,026	3,192	0,002
R_a^2=0,317	$Sy.x$= 32,86734			

TÜB = 186,429-0,1641x Bant2_77_ENT+0,2365xBant3_55_ENT-0,5345x Bant3_77_ENT+0,4484xBant3_99_ENT-0,3673xBant7_33_M-0,1647x Bant7_99_ENT+0,5215xBant8_55_M-0,5124x Bant10_55_M+0,1246x Bant11_77_SM-0,1352x Sentinel_VH_DN +0,0845xSentinel_VV_DN

Çizelge 3.10 Topraküstü biyokütleyi sentinel değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	70,629	5,562	12,697	0,000
Sentinel_VH_DN	-0,1990	0,059	-3,362	0,001
Sentinel_VV_DN	0,1274	0,031	4,050	0,000
R_a^2= 0,053	$Sy.x$= 36,59125			

TÜB = 70,629-0,1990xSentinel_VH_DN+0,1274xSentinel_VV_DN

Çizelge 3.11 Topraküstü biyokütleyi bant ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	635,274	243,034	2,613	0,009
Bant 2	-0,0970	0,033	-2,924	0,004
Bant 3	0,1098	0,033	3,234	0,001
Bant 4	0,0793	0,029	2,734	0,007
Bant 5	-0,0108	0,003	-3,253	0,001
Bant 7	-0,0391	0,008	-4,478	0,000
Bant 8	-0,0517	0,013	-3,945	0,000
Bant 11	-0,0143	0,005	-2,473	0,014
Yükselti	0,0735	0,015	4,611	0,000
Bakı	-0,1174	0,025	-4,625	0,000
R_a^2= 0,366	$Sy.x$= 33,79876			

TÜB = 635,274-0,0970xBant2+0,1098xBant3+0,0793xBant4-0,0108xBant5-0,0391 xBant7-0,0517xBant8-0,0143xBant11+0,0735xYükselti-0,1174xBakı

Çizelge 3.12 Topraküstü biyokütleyi indis ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	-6619394,098	2736564,574	-2,418	0,016
FII	1412,002	621,777	2,270	0,023
NDTI	4061,062	1685,215	2,409	0,017
WRI	6815,929	2521,386	2,703	0,007
SIPI	1555,534	602,149	2,583	0,010
NLI	6614293,121	2734669,624	2,418	0,016
ND73	7204,089	3483,927	2,067	0,040
BI	-0,0576	0,017	-3,282	0,001
PSSR	-482,436	189,123	-2,550	0,011
NDBal	717,703	325,737	2,203	0,028
Yükselti	0,0962	0,015	6,264	0,000
Bakı	-0,1145	0,025	-4,571	0,000
R_a^2= 0,388	$Sy.x$= 32,03985			

TÜB = -6619394,098+1412,002x FII+4061,062xNDTI +6815,929x WRI+1555,534 xSIPI +6614293,121 x NLI +7204,089x ND73-0,0576x BI-482,436xPSSR +717,703xNDBal+0,0962x Yükselti-0,1145xBakı

Çizelge 3.13 Topraküstü biyokütleyi tekstür ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	132,788	40,705	3,262	0,001
Bant 3_33_M	1,9270	0,356	5,399	0,000
Bant 3_55_ENT	0,3269	0,103	3,147	0,002
Bant 3_77_ENT	-0,4261	0,150	-2,826	0,005
Bant 4_99_ENT	0,5512	0,138	3,987	0,000
Bant 5_55_M	-1,9649	0,497	-3,950	0,000
Bant 5_77_M	1,6040	0,493	3,251	0,001
Bant 6_77_ENT	-0,4618	0,100	-4,588	0,000
Bant 7_33_M	-0,5195	0,150	-3,457	0,001
Bant 8_33_M	-0,3685	0,211	-1,739	0,083
Bant 10_33_M	-0,8026	0,243	-1,739	0,001
Bant 11_99_SM	0,1494	0,037	3,967	0,000
Yükselti	0,0889	0,012	7,035	0,000
Bakı	-0,0860	0,024	-3,480	0,001
R_a^2= 0,410	$Sy.x$= 32,48295			

TÜB = -132,788+1,9270xBant3_33_M+0,3269xBant3_55_ENT-0,4261x Bant3_77_ENT+0,5512xBant4_99_ENT-1,9649x Bant5_55_M+1,6040x Bant5_77_M-0,4618x Bant6_77_ENT-0,5195xBant7_33_M-0,3685x Bant8_33M-0,8026xBant10_33_M+0,1494xBant11_99_SM+0,0889x Yükselti-0,0860xBakı

Çizelge 3.14 Topraküstü biyokütleyi sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	48,953	7,159	6,837	0,000
Sentinel_VH_DN	-0,1599	0,059	-2,709	0,007
Sentinel_VV_DN	0,1099	0,028	3,864	0,000
Yükselti	0,0465	0,009	4,737	0,000
R_a^2= 0,10	$Sy.x$= 38,10647			

TÜB =48,953-0,1599xSentinel_VH_DN+0,1099xSentinel_VV_DN+0,0465xYükselti

Çizelge 3.15 Topraküstü biyokütleyi bant, indis ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	22450680,097	5771964,446	3,890	0,000
Bant 2	0,759	0,204	3,723	0,000
Bant 5	-0,201	0,063	-3,221	0,001
Bant 7	0,110	0,050	2,185	0,030
Bant 8	-0,040	0,013	-3,004	0,003
Bant 11	-0,019	0,006	-3,240	0,001
GCI	-1954,646	466,976	-4,186	0,000
SIPI	17105,451	4077,874	4,195	0,000
NLI	-22456748,983	5773693,599	-3,889	0,000
IPVI	-0,363	0,131	-2,765	0,006
GRVI	-4729,033	1604,170	-2,948	0,003
NDBR	22450680,097	974,062	3,084	0,002
Yükselti	0,102	0,019	5,424	0,000
Bakı	-0,085	0,026	-3,325	0,001

R_a^2= 0,379 $Sy.x$= 33,63667

TÜB = 22450680,097+0,759xBant2-0,201xBant5+0,110xBant7-0,040xBant8-0,019xBant11-1954,646xGCI+17105,451xSIPI-22456748,983xNLI-0,363xIPVI-4729,033xGRVI+22450680,097xNDBR+0,102xYükselti-0,085xBakı

Çizelge 3.16 Topraküstü biyokütleyi indis, tekstür ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	-10443839,611	3287205,460	-3,177	0,002
Yükselti	0,101	0,016	6,343	0,000
Bakı	-0,082	0,025	-3,314	0,001
Bant 4_77_ENT	-0,488	0,164	-2,969	0,003
Bant 4_99_ENT	0,778	0,231	3,364	0,001
Bant 5_77_M	1,095	0,313	3,492	0,001
Bant 7_99_ ENT	-0,277	0,099	-2,809	0,005
Bant 10_55_M	-0,973	0,284	-3,421	0,001
Bant 11_99_SM	0,163	0,039	4,191	0,000
SR	-1771,499	551,293	-3,213	0,001
FII	3446,701	850,401	4,053	0,000
NDTI	7015,645	1731,773	4,051	0,000
WRI	9624,486	2592,030	3,713	0,000
SIPI	1785,878	661,770	2,699	0,007
NLI	10435999,339	3285685,936	3,176	0,002
ND32	-4247,746	1732,745	-2,451	0,015
ND73	17768,811	4266,540	4,165	0,000
EVI2	-1024,877	497,213	-2,061	0,040
BI	-0,066	0,020	-3,288	0,001
TCW	0,065	0,021		0,003

R_a^2= 0,424 $Sy.x$= 32,78436

TÜB = -10443839,611+0,101xYükselti-0,082xBakı-0,488xBant4_77_ENT+0,778x Bant4_99_ENT+1,095xBant5_77_M-0,277xBant7_99_ENT-0,973x Bant10_55_M+0,163xBant11_99_SM-1771,499xSR+3446,701xFII+ 7015,645xNDTI+9624,486xWRI+1785,878x SIPI+10435999,339x NLI-4247,746xND32+17768,811x ND73-1024,877xEVI2-0,066xBI+0,065x TCW

Çizelge 3.17 Topraküstü biyokütleyi bant, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	681,586	245,407	2,777	0,006
Bant 2	-0,0864	0,034	-2,570	0,011
Bant 3	0,0755	0,034	2,234	0,026
Bant 4	0,1066	0,029	3,651	0,000
Bant 5	-0,0081	0,003	-2,439	0,015
Bant 7	-0,0467	0,009	-3,337	0,000
Bant 8	-0,0521	0,013	-3,972	0,000
Bant 11	-0,0160	0,006	-2,743	0,006
Sentinel_VH_DN	-0,1603	0,052	-3,090	0,002
Sentinel_VV_DN	0,1144	0,024	4,692	0,020
Yükselti	0,0786	0,016	4,894	0,000
Bakı	-0,1053	0,026	-4,089	0,000
R_a^2= 0,384	$Sy.x$= 33,89925			

TÜB = 681,586-0,0864xBant2+0,0755xBant3+0,1066xBant4-0,0081xBant5-0,0467 xBant7-0,0521xBant8-0,0160xBant11-0,1603xSentinel_VH_DN+0,1144x Sentinel_VV_DN+0,0786xYükselti-0,1053xBakı

Çizelge 3.18 Topraküstü biyokütleyi indis, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	-6101685,040	1734186,962	-3,518	0,001
Yükselti	0,1192	0,013	9,167	0,000
Bakı	-0,1445	0,030	-4,700	0,000
Sentinel_VH_DN	-0,1336	0,053	-2,517	0,012
Sentinel_VV_dB	-1,9692	0,921	-2,137	0,033
Sentinel_VV_DN	0,1206	0,024	4,855	0,000
FII	255,892	104,019	2,460	0,015
WRI	2608,820	390,697	6,677	0,000
NLI	6102134,117	1734621,443	3,517	0,001
BI	-0,0607	0,011	-5,274	0,000
MSAVI	-1116,990	574,016	-1,945	0,053
NDBal	2025,152	411,927	4,916	0,000
NBR2	4507,653	1266,630	3,558	0,000
TCG	0,0926	0,027	3,359	0,000

R_a^2= 0,389 $Sy.x$= 33,75510

TÜB = -6101685,040+0,1192xYükselti-0,1445xBakı-0,1336xSentinel_VH_DN-1,9692 xSentinel_VV_dB+0,1206xSentinel_VV_DN+255,892xFII+2608,820xWRI+ 6102134,117xNLI-0,0607xBI-1116,990xMSAVI+2025,152xNDBal+4507,653 xNBR2+0,0926xTCG

Çizelge 3.19 Topraküstü biyokütleyi tekstür, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	Regresyon katsayıları	Standart hata	t-istatistiği	p
	101,809	43,886	2,319	0,021
Yükselti	0,0968	0,012	7,600	0,000
Bakı	-0,0880	0,025	-3,478	0,001
Sentinel_VH_DN	-0,1577	0,054	-2,917	0,004
Sentinel_VV_DN	0,1033	0,025	4,104	0,000
Bant 3_55_ENT	0,3490	0,107	3,248	0,001
Bant 3_77_ENT	-0,4758	0,156	-3,034	0,003
Bant 4_33_M	1,7434	0,293	5,937	0,000
Bant 4_99_ENT	0,3480	0,147	2,354	0,019
Bant 5_33_M	-0,6835	0,244	-2,796	0,006
Bant 5_77_M	0,9312	0,361	2,575	0,011
Bant 6_33_M	-1,1999	0,184	-6,518	0,000
Bant 6_77_ENT	-0,2783	0,106	-2,617	0,009
Bant 10_55_M	-0,6344	0,287	-2,204	0,028
Bant 11_77_SM	0,1107	0,033	3,307	0,001

R_a^2= 0,235 $Sy.x$= 47,4634

TÜB =101,809+0,0968xYükselti-0,0880xBakı-0,1577xSentinel_VH_DN+0,1033x Sentinel_VV_DN+0,3490xBant3_55_ENT-0,4758xBant3_77_ENT+1,7434x Bant4_33_M+0,3480xBant4_99_ENT-0,6835xBant5_33_M+0,9312x Bant5_77_M-1,1999x Bant6_33_M-0,2783xBant6_77_ENT-0,6344x Bant10_55_M+0,1107x Bant11_77_SM

Çizelge 3.20 Topraküstü biyokütleyi bant, indis, tekstür ve sentinel değerlerine göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	1537,653	347,360	4,426	0,000
Bant 2	-0,2626	0,039	-6,620	0,000
Bant 8	-0,0557	0,014	-3,889	0,000
Bant 11	-0,0187	0,007	-2,682	0,008
Sentinel_VH_DN	-0,1672	0,056	-2,956	0,003
Sentinel_VV_DN	0,1088	0,026	4,070	0,000
Bant 2_55_ENT	0,1206	0,058	2,078	0,039
Bant 5_77_M	1,2982	0,335	3,872	0,000
Bant 6_99_ENT	-0,2465	0,084	-2,915	0,004
Bant 8_99_COR	-0,0866	0,043	-1,983	0,048
Bant 10_55_M	-1,0705	0,315	-3,393	0,001
Bant 11_77_SM	0,0730	0,036	2,019	0,044
SR	-2137,607	435,680	-4,906	0,000
FII	1938,963	440,483	4,401	0,000
NDTI	2469,239	529,740	4,661	0,000
ND73	9210,493	1777,269	5,182	0,000
GRVI	6533,349	1442,242	4,529	0,000
BI	0,1372	0,018	7,349	0,000
TCW	0,1495	0,026	5,695	0,000
TCG	-0,2144	0,041	-5,171	0,000

R_a^2= 0,337 $Sy.x$= 37,39120

TÜB = 1537,653-0,2626xBant2-0,0557xBant8-0,0187xBant11-0,672x Sentinel_VH_DN+0,1088xSentinel_VV_DN+0,1206xBant2_55_ENT+1,2982 xBant5_77_M -0,2465xBant6_99_ENT-0,0866xBant8_99_COR-1,0705x Bant10_55_M+0,0730xBant11_77_SM-2137,607xSR+1938,963xFII+ 2469,239xNDTI+9210,493x ND73+6533,349xGRVI+0,1372xBI+0,1495x TCW-0,2144x TCG

Çizelge 3.21 Topraküstü biyokütleyi bant, indis, tekstür ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	-4651484,911	693749,541	-6,704	0,000
Bant 8	-0,0456	0,010	-4,403	0,000
Bant 11	-0,0193	0,006	-3,050	0,002
WRI	1277,391	156,270	8,174	0,000
NLI	4652059,433	693879,134	6,704	0,000
NDTI	836,987	298,681	2,802	0,005
ARVI	-933,951	157,007	-5,948	0,000
Bant 5_77_M	0,3483	0,169	2,049	0,041
Bant 11_99_SM	0,1708	0,035	4,816	0,000
Yükselti	0,1030	0,014	7,027	0,000
Bakı	-0,0797	0,025	-3,136	0,002

R_a^2= 0,394 $Sy.x$= 34,51575

TÜB=-4651484,911-0,0456xBant8-0,0193xBant11+1277,391xWRI+4652059,433 xNLI+836,987xNDTI-933,951xARVI+0,3483xBant5_77_M+0,1708x Bant11_99_SM-0,1030xYükselti-0,0797xBakı

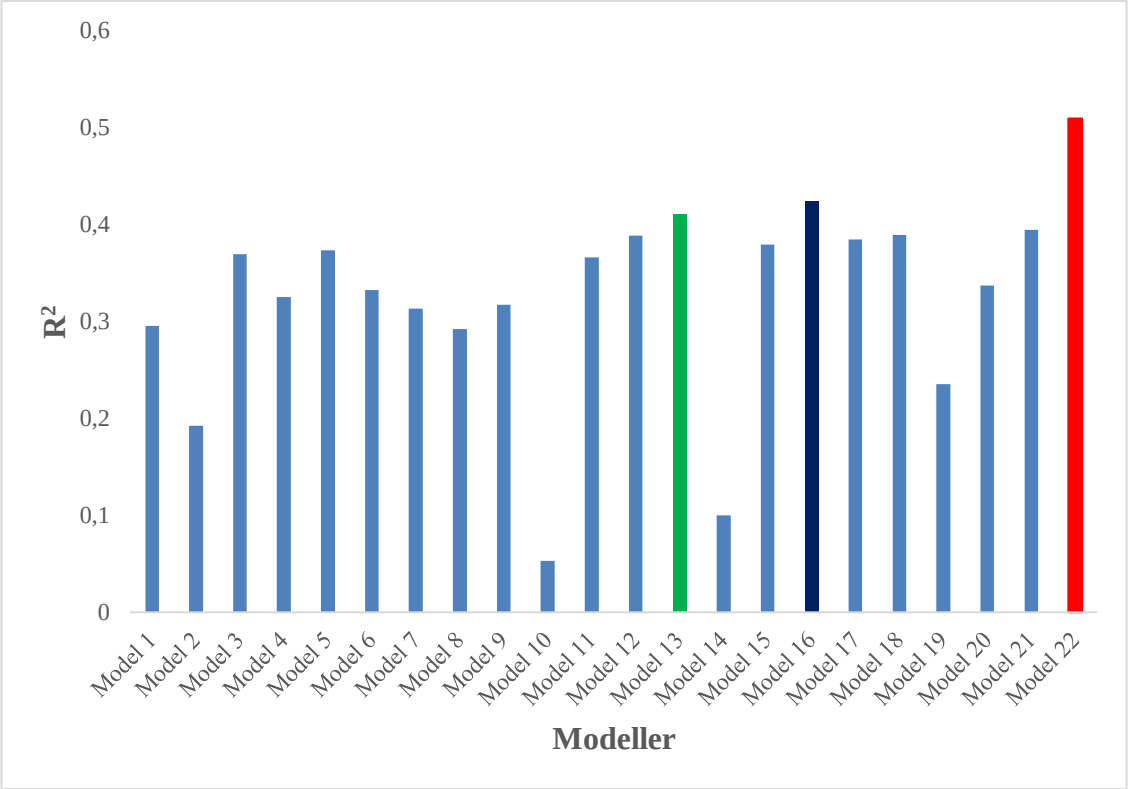
Çizelge 3.22 Topraküstü biyokütleyi bant, indis, tekstür, sentinel ve topoğrafik değerlere göre tahmin eden en iyi model sonuçları

Bağımsız değişkenler	**Regresyon katsayıları**	**Standart hata**	**t-istatistiği**	**p**
	2320,132	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
Yükselti	,0106	0,013	8,267	0,000
Bakı	-0,056	0,024	-2,353	0,019
Sentinel_VH_DN	-0,136	0,047	-2,905	0,004
Sentinel_VV_DN	0,084	0,023	3,627	0,000
B4_77_ENT	-0,124	0,059	-2,103	0,036
B5_77_M	1,547	0,274	5,656	0,000
B6_33_M	-0,567	0,188	-3,018	0,003
B10_55_M	-1,020	0,249	-4,090	0,000
B10_77_SM	-0,141	0,056	-2,516	0,013
B10_99_SM	0,210	0,070	2,980	0,003
B11_55_ENT	-0,111	0,036	-3,099	0,002
WRI	-2058,689	493,233	-4,174	0,000
GCI	-1057,723	166,528	-6,352	0,000
DVI	0,034	0,016	2,195	0,029
ARVI	-1784,760	225,199	-7,925	0,000
NDMI	1709,558	314,643	5,433	0,000

R_a^2= 0,509 $Sy.x$= 28,39900

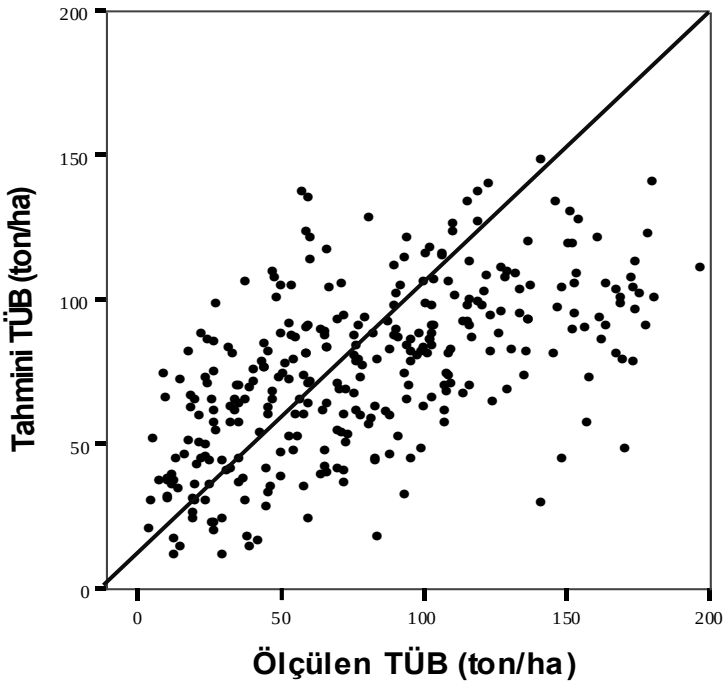
TÜB = 2320,132+0,060xBant2-0,071xBant8+0,106xYükselti-0,056xBakı-0,136x Sentinel_VH_DN+0,084xSentinel_VV_DN-0,124xBant4_77_ENT+1,547x Bant5_77_M-0,567xBant6_33_M-1,020xBant10_55_M-0,141xBant10_77_SM +0,210xBant10_99_SM-0,111xBant11_55_ENT-2058,689xWRI-1057,723xGCI +0,034xDVI-1784,760x ARVI+1709,558xNDMI

Ayrıca çalışmada elde edilen 22 farklı regresyon modelinin başarı düzeylerine gösterir grafik Şekil 3.1'de verilmiştir.

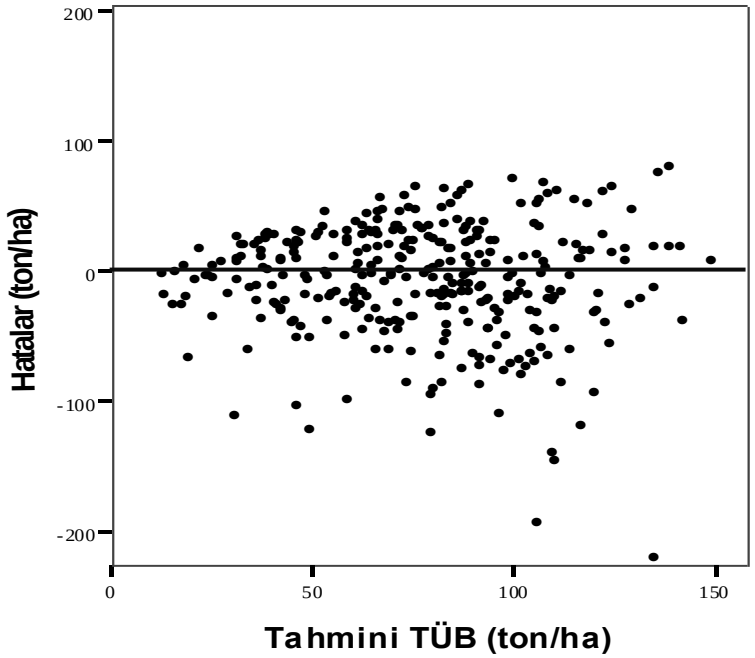


Şekil 3.1 Regresyon modellerine ilişkin başarı düzeleri

Geliştirilen 22 farklı regresyon modelinden en iyi tahmin sonucunu veren model 22 nolu modeldir (Çizelge 3.22). Bu modele göre tahmin edilen topraküstü biyokütlenin envanter karnelerinden hesaplanan topraküstü biyokütleye göre değişimi Şekil 3.2'de verilmiştir. Topraküstü biyokütleyi en iyi model (Çizelge 3.22) değerlerine göre tahmin eden modelle elde edilen hataların, tahmini topraküstü biyokütleye göre değişimi Şekil 3.3'de verilmiştir.



Şekil 3.2 Hesaplanan topraküstü biyokütle ile tahmin edilen topraküstü biyokütle ilişkisi



Şekil 3.3 En iyi modelle elde edilen hatalar-tahmini topraküstü biyokütle ilişkisi

Topraküstü biyokütlenin modellenmesine ilişkin elde edilen en iyi modelin örneklenen topluma istatistiksel olarak uygun olup olmadığı bağımsız bir veri grubu ile test edilmiştir. Her bir model için Eşleştirilmiş t testi (Paired t test) ile karşılaştırma yapılmıştır. Eşleştirilmiş t testi sonuçlarına göre (en iyi model için t=-1,817, p(=0,073)>0,05 tahmin edilen topraküstü biyokütle değerleri ve envanter karnelerinden elde edilen topraküstü biyokütle değerleri arasında α=0,05 önem düzeyi ile istatistiksel olarak bir fark olmadığı sonucuna varılmıştır. Bu çalışmada geliştirilen en iyi model topraküstü modelin, bu modelin geliştirilmesinde kullanılan verilerin alındığı saf kızılçam meşcerelerine uygun olduğu söylenebilir.

4. TARTIŞMA

Bu çalışmada, topraküstü biyokütle ile Landsat 8 OLI uydu görüntüsünden elde edilen bant parlaklık, vejetasyon indis ve tekstür değerleri, Sentinel-1A uydu görüntüsünün her iki polarizasyonundan (VH ve VV) yansıma ve geri yansıtım değerleri ve Alos-Palsar uydu görüntüsünden elde edilen sayısal yükseklik modelinden üretilen eğim, bakı ve yükselti değerleri arasındaki ilişkiler çoğul regresyon analizi ile modellenmiştir. Toplam 22 adet regresyon modeli geliştirilmiştir (Çizelge 3.1-3.22). Elde edilen modellerin başarı düzeyleri (Şekil 3.1) incelendiğinde Landsat 8 OLI uydu görüntüsünün bant parlaklık, vejetasyon indis ve tekstür değerleri, Sentinel-1A uydu görüntüsünün her iki polarizasyona ilişkin parlaklık değerleri ile yükselti ve bakının bağımsız değişkenler olarak yer aldığı 22 nolu model en başarılı model olarak bulunmuştur. İkinci en başarılı model ise vejetasyon indisleri ve tekstür özellikleri birlikte yükselti ve bakının bağımsız değişkenler olarak yer aldığı 16 nolu model olmuştur. Üçüncü en başarılı model 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 değişkenleri incelendiğinde yükselik ve bakının üç modelde yer aldığı görülmüştür. Bu durumda yükselti ve bakının model başarısına katkı sağladığı göstermiştir. Bununla birlikte Landsat 8 OLI uydu görüntüsünden ve Sentinel-1A uydu görüntüsünden elde edilen değişkenlere topoğrafik verilerin eklemesiyle geliştirilen modellerin başarı düzeylerinin arttığı görülmüştür (Çizelge 11-14). Benzer sonuçlar, Xie vd. (2017) tarafından Spot-5 uydu görüntüsü kullanılarak bazı meşcere parametrelerinin tahmin edilmesi 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 modeller göre daha başarılı sonuçlar verdiği görülmüştür. Diğer bir ifadeyle topoğrafik faktörler modellerin başarı düzeylerini artırmıştır.

Konuyla ilgili 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 yardımıyla tahminler gerçekleştirilmeye çalışılmıştır (Luo *et al*. 2021, Askar *et al*. 2018, Phua *et al*. 2017, López-Serrano *et al*. 2020, Keleş vd. 2021, Roy *et al.* 2016). 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. Genellikle konuyla ilgili yapılan çalışmalarda en çok tercih edilen modelleme tekniği regresyon analizidir (Li *et al*. 2020). Konuyla ilgili yapılan bazı çalışmalar incelendiğinde;

Maynard vd. (2007) tarafından yapılan topraküstü biyokütle ile Landsat 7 ETM+ uydu görüntüsünden elde edilen bant yansıma ve vejetasyon indisleri arasındaki ilişkilerin araştırıldığı çalışmada vejetasyon indislerinin yer aldığı modellerde başarı düzeyi (R^2 =0.41, R^2 =0.51) bulunmuşken, bantların bağımsız değişken olarak yer aldığı modelde ise başarı düzeyi (R^2 =0,53) olarak bulunmuştur. Benzer sonuçlar bizim ve Turgut ve Günlü (2020) tarafından yapılan çalışmada da görülmüştür. Bizim çalışmamızda sadece bantların bağımsız değişken olarak yer aldığı model başarı düzeyi (R^2 =0,295) (Çizelge 3.1) bulunmuşken, sadece vejetasyon indislerinin yer aldığı model ise başarı düzeyi (R^2 =0,192) (Çizelge 3.2) bulunmuştur. Bununla birlikte Li et al. (2009) tarafından çalışmada farklı orman ekosistemlerde Landsat TM uydu görüntüsünden elde edilen bant parlaklık ve vejetasyon indisleri kullanılarak topraküstü biyokütlenin tahmin edilmeye çalışılmıştır. Bizim çalışmanın aksine bu çalışmada topraküstü biyokütlenin tahmin edilmesinde vejetasyon indisleri bant parlaklık değerlerine göre daha iyi sonuçlar vermiştir. Li vd. (2009) çalışmasına benzer sonuçlar (Heiskanen 2006, Gapari vd. 2010 ve Günlü vd. 2014) tarafından yapılan çalışmalarda da görülmüştür. Farklı vejetasyon indisleri ile topraküstü biyokütle değerleri arasında güçlü ilişkiler bulunmaktadır. Landsat TM uydu görüntüsünden elde edilen vejetasyon indisleri (özellikle de NDVI ve SR) ile topraküstü biyokütle değerleri arasında yüksek ilişkiler bulunmuştur (Lu *et al.*, 2002; Zheng *et al.*, 2007; Yan *et al*., 2015). Ancak bizim çalışmamızda vejetasyon indislerinin

bağısız değişken olarak yer aldığı modellerde NDVI değişkeni hiçbir model yer almamıştır. Bun karşın SR vejetasyon indisi ise sadece iki modelde bağımsız değişken olarak yer almıştır. Oysaki Turgut ve Günlü (2020) tarafından saf karaçam meşcerelerinde topraküstü biyokütlenin tahmin edilmesine yönelik çalışmada, vejetasyon indisleriyle geliştirilen modelde yer alan bağımsız değişkenlerle (FII, EVI, DVI, IPVI) bizim çalışmamızda geliştirilen modellerde yer alan bağımsız değişkenler arasında benzerlik olduğu görülmüştür (Çizelge 3.2, 3.4, 3.16 ve 3.22).

Dube and Mutanga (2015) yaptıkları bir çalışmada topraküstü biyokütle ile Landsat 8 OLI uydu görüntüsünden üretilen tekstür, vejetasyon indis ve bat parlaklık değerleri arasındaki ilişkiler incelenmiştir. Elde edilen sonuçlar incelediğinde tekstür değerlerinin bağımsız değişken olarak yer aldığı modelin daha başarılı sonuç verdiği görülmüştür. Benzer sonuçlar bizim çalışmamızda da bulunmuştur (Çizelge 3.3). Tekstür özellikleri bant parlaklık ya da reflektans ve vejetasyon indis değerlerine göre topraküstü biyokütlenin tahmin edilmesinde daha sonuçlar göstermektedir. Bununla birlikte hangi tekstür özelliğinin topraküstü biyokütle ile en iyi ilişki verdiğinin bilinmesi önemli olmaktadır. Yapılan çalışmalarda topraküstü biyokütlenin 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. bağlı olarak değişiklik göstermektedir. Dolayısıyla topraküstü biyokütlenin 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 *et al*. 2004). Bizim çalışmamızda modellerde yer alan tekstür değişkenleri incelediğinde yukarıda yapılan açıklamaları desteklemektedir. Çalışmada bulunan en başarılı (Model 22; Çizelge 3.22) 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 faklı pencere boyutları modellere girmiştir. Bu çalışmada tekstür özelliklerine ilişkin dikkat çekici unsur dört farklı tekstür özelliklerinin (ağırlıklı olarak da M, ENT ve SM gibi tesktür özellikleri) modellerde yar aldığı görülmüştür (Çizelge 3.9-3.13-3.16-3.19-3.22). 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 vd. (2016) tarafından yapılan bir çalışmada Landsat 8 OLI ve Alos-2 uydu görüntüleri kullanılarak çoğul regresyon analizi ile topraküstü biyokütle 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 başarısı (R^2=0,788) ve Alos-2 görüntüsünün değişkenleriyle (R^2=0,742) düzeyinde ilişkiler bulunmuştur. Aynı çalışmada her iki uydu görüntüsünden elde edilen değişkenlerin birlikte kullanılmasıyla model başarısının 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 topraküstü biyokütle tahmin edilmeye çalışılmıştır. Elde edilen sonuçlara bakıldığında sadece Sentinel-1 geri yansıtım değerlerinin yer aldığı modelde model başarısı (R^2=0,34), sadece Sentinel-2 uydu görüntüsünden elde edilen değişkenlerin kullanılmasıyla model başarısı (R^2=0,82) ve her iki uydu görüntüsünden elde edilen değişkenlerin kullanılmasıyla da model başarısı (R^2=0.84) olarak bulunmuştur. Benzer sonuçlar bizim çalışmamızda bulunmuştur. Şöyle ki sadece Sentinel-1A uydu görüntüsünün her iki polarizasyonu ilişkin elde edilen yansıma değerleri ile geliştirilen modelin (Çizelge 3.10) başarı düzeyi (R^2=0,053) oldukça düşükken modele yükselti değişkenin girmesiyle model başarısı (R^2=0,10) yükselmiştir. Bununla birlikte çalışmada kullanılan diğer değişkenler birlikte yer aldığı modellerde model başarılarının yükseldiği görülmüştür (3.17-19, 3.20, 3.22). Keleş vd. (2021) tarafından yapılan bir çalışmada saf sarıçam meşcerelerinde Sentinel-1 ve Sentinel-2 uydu görüntüleri kullanılarak topraküstü meşcere karbonu tahmin edilmeye çalışılmıştır. Bu çalışmada üç farklı modelleme (çoğul regresyon, destek vektör makinesi ve derin öğrenme) kullanılmıştır. Yedi farklı regresyon modeli (bant, vejetasyon indis, tesktür, bant-vejetasyon indis, bant-geri yansıtım, vejetasyon indisi-geri yansıtım ve bant-vejetasyon indisi-geri yansıtım) geliştirilmiştir. Elde edilen sonucalar incelendiğinde en düşük başarı (R^2=0,442) Sentinel-1 geri yansıtım değerlerinin bağımsız değişken olarak yer aldığı modelde elde edilmiştir. Bununla birlikte geri yansıtım değişkenlerinin bant

yansıma değerleri (R^2=0,634) ve vejetasyon indis değerleri (R^2=0,672) birlikte yer aldığı modellerde model başarılarının arttığı görülmüştür. 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 vd. (2019) tarafından yapılan çalışmada bulunmuştur.

Konuyla ilgili yapılan çalışmalarda çoğul regresyon analizinden başka farklı modelleme tekniklerinin kullanıldığı çalışmalarda literatürde yer almaktadır. Xie vd. (2009) yaptığı çalışmada Landsat ETM+ uydu görüntüsünden hesaplanan vejetasyon indis ve bant parlaklık değerleri ile topraküstü biyokütle arasındaki ilişkiler çoğul regresyon ve yapay sinir ağları modelleme teknikleri kullanılarak modellenmiştir. Model başarıları incelediğinde yapay sinir ağalarının regresyon modeline göre daha iyi sonuç verdiği görülmüştür. Shao and Zhang (2016) tarafından yapılan çalışmada, Landsat 8 OLI ve Radarsat-2 uydu görüntülerinden elde edilen değişkenler birlikte kullanılarak topraküstü biyokütleyi rasgele orman modelleme tekniğini kullanarak modellemişler ve (R^2=0,82) düzeyinde başarı elde etmişlerdir. Yukarıda bahsedilen Keleş vd. (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 R^2=0,877 ve derin öğrenme için R^2=0,857). Baloloy vd. (2018) Sentinel-2 ve Rapideye uydu görüntülerinden elde edilen vejetasyon indisleri ve bant yansıma değerleri ile topraküstü biyokütle arasındaki ilişkiler Multivariate Adaptive Regression Splines (MARS) modelleme tekniği ile modellenmiştir. Elde edilen sonucalar incelendiğinde, bant değerleri ile Sentinel-2 için (R^2=0,62) ve Rapideye için (R^2=0,92) düzeyinde ilişki ve vejetasyon indisleri ile Sentinel-2 için (R^2=0,89) ve Rapideye için (R^2=0,82) düzeyinde ilişkiler bulunmuştur.

5. SONUÇ VE ÖNERİLER

Bu çalışmada, Landsat 8 OLI uydu görüntüsünden elde edilen bant parlaklık, vejetasyon indis ve tekstür özelliği değerleri, Sentinel-1A aktif uydu görüntüsünden elde edilen parlaklık ve geri yansıtım değerleri ve Alos-Palsar DEM verisinden elde edilen yükselti, eğim ve bakı değerleri ile topraküstü biyokütle arasındaki ilişkiler çoklu regresyon analizi ile modellenmiştir. Toplam 22 adet farklı regresyon denklemi geliştirilmiştir. Bu denklemleri başarı düzeyleri bir model hariç (model 10; R_a^2= 0,053) modellerin başarı düzeyleri R_a^2= 0,10 ile R_a^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 ilişkin parlaklık değerleri ile yükselti ve bakı değişkenlerinin yer aldığı model (R_a^2= 0,509 ; $Sy.x$= 28,39900) birinci sırada, Landsat 8 OLI uydu görüntüsünün vejetasyon indis ve tekstür özellikleri ile yükselti ve bakı değişkenlerinin yer aldığı model (R_a^2= 0,424 ; $Sy.x$= 32,78436) ikinci sırada, Landsat 8 OLI uydu görüntüsünün tekstür özellikleri ile yükselti ve bakı değişkenlerinin yer aldığı model (R_a^2= 0,410 ; $Sy.x$= 32,48295) ise üçüncü sırada yer almaktadır.

Landsat 8 OLI, Sentinel-1A uydu görüntüleri ve Alos-Palsar DEM verisinden elde edilen yükselti, eğim ve bakı verileri kullanılarak topraküstü biyokütle 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 topraküstü biyokütlenin tahmin edilmesinde başarı düzeylerini olumlu yönde etkilediği söylenebilir. Çalışma kapsamında elde edilen 22 farklı regresyon model (üçü hariç) sonuçlarının düşük çıkmasına birçok faktöre bağlı olabilir. Bu faktörlerin bazılarını şu şekilde açıklanabilir. Çalışmada kullanılan uydu görüntülerinin çekim saatinin sabah saatlerinde olması nedeniyle çalışma alanında kuzey bakılarda yer alan örnek alanların gölgede kalması nedeniyle bantların yansıma değenlerinin hatalı olarak hesaplanmasına neden olmuş olabilir.

Landsat 8 OLI uydu görüntüsünün konumsal çözünürlüğünün düşük olması, bununla birlikte çalışmada kullanılan Sentinel-1A aktif uydu görüntüsünün dalga boyunun kısa olması (C bant) nedeniyle penetrasyon (gelen ışının meşcere alt tabakasına geçme yeteneği) özelliğinin düşük olması, çalışma alanından meşcere yapılarının heterojen yapıda olması vb. gibi nedenlerden dolayı model başarıları düşük elde edilmiş olabilir. 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 topraküstü biyokütlenin tahminine yönelik model başarıları artırılabilir.

KAYNAKLAR

Askar, Nuthammachot, N., Phairuang, W., Wicaksono, P, and Sayektiningsih, T. 2018. Estimating Aboveground Biomass on Private Forest Using Sentinel-2 Imagery Hindawi Journal of Sensors Volume, 11 pages.

Baig, M. H. A., Zhang, L., Shuai, T., and Tong, Q. 2014. Derivation of a tasselled cap transformation based on Landsat 8 at-satellite reflectance. Remote Sensing Letters, 5(5): 423-431.

Baloloy, A. B., Blanco, A. C., Candido, C. G., Argamosa, R. L., Dumalag, 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., 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. 2021. Ankara Orman Bölge Müdürlüğü Saf Karaçam Meşcerelerinde Net Birincil Üretim Ve Yaprak Alan İndeksinin Uzaktan Algılama Teknikleri İle Modellenmesi. Doktora Tezi, Fen Bilimleri Enstitüsü, 148 sayfa, Ankara

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.

Chen, J. M. 1996. Evaluation of vegetation indices and a modified simple ratio for boreal applications. Canadian Journal of Remote Sensing, 22(3): 229-242.

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): e0147121.

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.

Evrendilek, F. 2004. An inventory-based carbon budget for forest and woodland ecosystems of Turkey. Journal of Environmental Monitoring, 6(1):26-30.

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.

Franklin, J., and Hiernaux, P. H. 1991. Estimating foliage and woody biomass in Sahelian and Sudanian woodlands using a remote sensing model. International Journal of Remote Sensing, 12(6): 1387-1404.

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, Y., 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.

Gitelson, A. A., Kaufman, Y. J., and Merzlyak, M. N. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote sensing of Environment, 58(3): 289-298.

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.

Günlü, A., Ercanlı, İ., Şenyurt, M., and Keleş, S. 2021. Estimation of some stand parameters from textural features from WorldView-2 satellite image using the artificial neural network and multiple regression methods: a case study from Turkey. Geocarto International, 36(8): 918-935.

Günlü, A., Ercanli, İ., Başkent, E. Z., and Çakır, G., 2014. Estimating aboveground biomass using Landsat TM imagery: A case study of Anatolian Crimean pine forests in Turkey. Ann. For. Res. 57(2): 289-298, 2014.

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.

Houghton, R.A., Lawrence, K.T., Hackler, J.L., and Brown, S. 2001. The spatial distribution of forest biomass in the Brazilian Amazon: a comparison of estimates. Global Change Biology, 7(7): 731-746.

Houghton, R.A., Hall, F., and Goetz, S.J. 2009, Importance of biomass in the global carbon cycle, J. Geophys. Res., 114 pages

Huang, X., Ziniti, B., Torbick, N., and Ducey, M.J. 2018. Assessment of forest above ground biomass estimation using multi-temporal C-band sentinel-1 and polarimetric L-band PALSAR-2 data. Remote Sensing, 10(9): 1424.

Huete, A. A. 1988. Soil-adjusted vegetation index (SAVI). Remote Sens. Environ., 25: 295–309.

Hunt Jr, E.R. and Rock, B.N. 1989. Detection of changes in leaf water content using near- and middle-infrared reflectances. Remote sensing of environment, 30(1): 43-54.

Imran, A. B., & Ahmed, S. 2018. Potential of Landsat-8 spectral indices to estimate forest biomass. International Journal of Human Capital in Urban Management, 3(4): 303-314.

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(10): 3833–3845.

Jordan, C.F. 1969. Derivation of leaf area index from quality of light on the forest floor. Ecology, 50: 663–666.

Kalinowski, A. and Oliver, S. 2004. ASTER mineral index processing manual. Remote Sensing Applications, Geoscience Australia, pp. 37-36.

Kaufman, Y. J., and Remer, L. A. 1994. Detection of forests using mid-IR reflectance: an application for aerosol studies. IEEE transactions on geoscience and remote sensing, 32(3): 672-683

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 Ercanli, 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.

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-Soıl Index for rapid mapping developing areas using landsat 8 data. ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, 2(4).

Li, Y., Li, M., Liu, Z., and Li, C. 2020. Combining Kriging interpolation to improve the accuracy of forest aboveground biomass estimation using remote sensing data. IEEE Access, 8, pp. 128124-128139.

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.

Lu, D., Mausel, P.E., Brondízio, E.S., and Moran, E.F. 2002. Above-Ground Biomass Estimation of Successional and Mature Forests Using TM Images in the Amazon Basin, pp. 183-196

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, pp. 1-12

Maina, E. W., Odera, P. A. and Kinyanjui, M. J. 2017. Estimation Of Above Ground Biomass İn Forests Using Alos Palsar Data İn Kericho And Aberdare Ranges, Open Journal Of Forestry, vol. 7, no. 2, pp. 79–96.

Maynard, C. L., Lawrence, R. L., Nielsen, G. A., 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.

McFeeters, S.K. 1996. The use of Normalized Difference Water Index (NDWI) in the delineation of open water features, International Journal of Remote Sensing, 17(7): 1425–1432.

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., 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.

Narine, L. L., Popescu, S., Neuenschwander, A., Zhou, T., Srinivasan, S., and Harbeck, K. 2019. Estimating aboveground biomass and forest canopy cover with simulated ICESat-2 data. Remote Sensing of Environment, 224: 1-11.

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.

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.

Norovsuren, B., Tseveen, B., Batomunkuev, V., and Renchin, T. 2019. August. 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., Stratoulias, 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.

Pandit, S, Tsuyuki, S, Dube, T. 2018. Estimating Above-Ground Biomass in Sub-Tropical Buffer Zone Community Forests, Nepal, Using Sentinel 2 Data. Remote Sensing.

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-l. 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.

Roy, S., Mudi, S., Das, P., Ghosh, S., Shit, P. K., Bhunia, G. S., and Kim, J. 2021. Estimating Above Ground Biomass (AGB) and Tree Density using Sentinel-1 Data. In Spatial Modeling in Forest Resources Management pp. 259-280, Springer, Cham.

Rui, B., Zhang, J., Lu, C., and Chen, P. 2021. Estimating above-ground biomass of Pinus densata Mast. using best slope temporal segmentation and Landsat time series. Journal of Applied Remote Sensing, 15(2): 024507.

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.

Saraçoğlu, N. 1998. Kayın (Fagus Orientalis Lipsky) Biyokütle Tabloları. Turkish Journal of Agriculture and Forestry, 22: 93-100

Saraçoğlu, Ö. 1988. Karadeniz Yöresi Göknar Meşcerelerinde Artım ve Büyüme. Orman Genel Müdürlüğü Yayınları, İstanbul, 312 sayfa, İstanbul

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.

Sharma, P., and Rai, S. C. 2007. Carbon sequestration with land-use cover change in a Himalayan watershed. Geoderma, 139(3-4): 371-378.

Shen, G., Wang, Z., Liu, C., and Han, Y. 2020. Mapping aboveground biomass and carbon in Shanghai's urban forest using Landsat ETM+ and inventory data. Urban Forestry & Urban Greening, 51: 126655.

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.

Sun, O., Uğurlu, S. ve Özer, E. 1980. Kızılçam (Pinus brutia Ten) Türüne Ait Biyolojik Kütlenin Saptanması, OAE Yayınları Teknik Bülten Serisi, No 104, 32 sayfa, Ankara.

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. 2020. Estimating aboveground biomass using Landsat 8 OLI satellite image in pure Crimean pine (Pinus nigra JF Arnold subsp. pallasiana (Lamb.) Holmboe) stands: a case from Turkey. Geocarto International, pp. 1-15.

Xie, S., Wang, W., Meng, J., Zhao, T., and Huang, G. 2017. Estimation of forest stand parameters using SPOT-5 satellite images and topographic information.

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.

Yavaşlı, D. D. and Ölgen, M. K. 2017. Modelıng above ground bıomass ın calabrıan pıne forests of düzlerçamı (antalya) . Ege Coğrafya Dergisi , 26 (2): 151-161. Retrieved from https://dergipark.org.tr/tr/pub/ecd/issue/33350/371317

Zhang, L., Shao, Z., Liu, J., and Cheng, Q. 2019. Deep Learning Based Retrieval of Forest Aboveground Biomass from Combined LiDAR and Landsat 8 Data. Remote. Sens., 11(12): 1459.

Zhao, F., Guo, Q., 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.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : İzzet GÜVERÇİN

Eğitim

Yüksek Lisans	Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalı	2018-Halen
Lisans	Karadeniz Teknik Üniversitesi Orman Fakültesi Orman Mühendisliği Bölümü	2012-2018

İş Deneyimi

Yıl	Kurum	Görev
2021-(mart-aralık)	OGM, Ankara Orman İşl. Müdürlüğü	Danışman Mühendis
2020-(eylül-aralık)	DMKP, Doğa Koruma ve Milli Parklar 9. Bölge Müdürlüğü	Danışman Mühendis
2019-(mart-aralık)	DMKP, Doğa Koruma ve Milli Parklar 5. Bölge Müdürlüğü	Danışman Mühendis