ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

SİNOP ORMAN BÖLGE MÜDÜRLÜĞÜ SAF SARIÇAM MEŞCERELERİNDE FARKLI UZAKTAN ALGILAMA VERİLERİ KULLANILARAK BAZI MEŞCERE PARAMETRELERİNİN MODELLENMESİ

Hasan AKSOY

ORMAN MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI
2023

Her hakkı saklıdır

TEZ ONAYI

Hasan AKSOY tarafından hazırlanan **"Sinop Orman Bölge Müdürlüğü Saf Sarıçam Meşcerelerinde Farklı Uzaktan Algılama Verileri Kullanılarak Bazı Meşcere Parametrelerinin Modellenmesi"** adlı tez çalışması 16/12/2022 tarihinde aşağıdaki jüri tarafından oy birliği ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında **Doktora 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	
Üye	: Prof. Dr. İlker ERCANLI Orman Mühendisliği Anabilim Dalı Çankırı Karatekin Üniversitesi	
Üye	: Doç. Dr. Oytun Emre SAKICI 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 "**Sinop Orman Bölge Müdürlüğü Saf Sarıçam Meşcerelerinde Farklı Uzaktan Algılama Verileri Kullanılarak Bazı Meşcere Parametrelerinin Modellenmesi**" 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 (16/12/2022).

Hasan AKSOY

ÖZET

Doktora Tezi

SİNOP ORMAN BÖLGE MÜDÜRLÜĞÜ SAF SARIÇAM MEŞCERELERİNDE FARKLI UZAKTAN ALGILAMA VERİLERİ KULLANILARAK BAZI MEŞCERE PARAMETRELERİNİN MODELLENMESİ

Hasan AKSOY

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Alkan GÜNLÜ

Bu çalışmada, Sinop Orman Bölge Müdürlüğünde yayılış gösteren saf sarıçam meşcerelerinde bazı meşcere parametreleri (meşcere orta çapı, meşcere üst boyu, meşcere ağaç sayısı, meşcere göğüs yüzeyi ve meşcere hacmi), yaprak alan indeksi, topraküstü biyokütle ve karbon değerleri ile aktif (Sentinel-1) ve pasif (Sentinel-2, Landsat 8 OLI ve dron) algılayıcılara ait görüntülerden elde edilen veriler arasındaki ilişkiler çoğul regresyon analizi (ÇRA) ve yapay sinir ağları (YSA) teknikleri ile modellenmiştir. Çalışmada toplam 184 adet örnek alan alınmıştır. Her bir örnek alana ilişkin klasik orman envanter ölçümleri yapılmış ve her bir örnek alan için bazı meşcere parametreleri, topraküstü biyokütle ve karbon değerleri hesaplanmıştır. Bununla birlikte her bir örnek alan için Sentinel-1 görüntüsü için geri yansıtım ve bant yansıma değerleri ile Sentinel-2, Landsat 8 OLI uydu ve dron görüntüleri için reflektans, vejetasyon indis ve tekstür değerleri hesaplanmıştır. Örnek alanlara ilişkin yersel ve uzaktan algılama verileri ÇRA ve YSA teknikleri ile modellenmiştir. Uygulanan modelleme teknikleri ile meşcere göğüs yüzeyi için Sentinel-2, 15x15 pencere boyutu tekstür ve YSA tekniği (Model R^2=0,84, Test R^2=0,77), meşcere hacmi için Landsat 8 OLI 135° tekstür ve YSA tekniği (Model R^2=0,83, Test R^2=0,77), meşcere orta çapı için Sentinel-2 7x7 pencere boyutu tekstür ve ÇRA tekniği (Model R^2=0,83, Test R^2=0,81), meşcere ağaç sayısı için Sentinel-2, 15x15 pencere boyutu tekstür ve YSA tekniği (Model R^2=0,81, Test R^2=0,69), meşcere üst boyu için Sentinel-2 5x5 pencere boyutu tekstür ve YSA tekniği (Model R^2=0,71, Test R^2=0,68), yaprak alan indeksi için Sentinel-2, 5x5 pencere boyutu tekstür ve YSA tekniği (Model R^2=0,74, Test R^2=0,32), topraküstü biyokütle için Sentinel-2, 9x9 pencere boyutu tekstür ve YSA tekniği (Model R^2=0,82, Test R^2=0,75) ve topraküstü karbon için Sentinel-2, 15x15 pencere boyutu tekstür ve YSA tekniği (Model R^2=0,89, Test R^2=0,77) ile en başarılı modeller bulunmuştur. Aynı zamanda dron görüntülerinden elde edilen vejetasyon indis verileri ile en başarılı modeller meşcere göğüs yüzeyi (R^2=0,40) ve meşcere üst boy (R^2=0,44) için bulunmuştur. Bununla birlikte dron görüntülerinden elde edilen reflektans değerleri ile en başarılı model (R^2=0,32) meşcere göğüs yüzeyi için bulunmuştur.

2023, 160 sayfa

Anahtar Kelimeler: *Pinus sylvestris*, Meşcere parametreleri, Modelleme, Uzaktan algılama, İnsansız hava aracı (İHA), Yapay sinir ağları

ABSTRACT

PhD Thesis

MODELING SOME STAND PARAMETERS USING DIFFERENT REMOTE SENSING DATA IN PURE SCOTS PINE STANDS IN SINOP REGIONAL DIRECTORATE OF FORESTRY

Hasan AKSOY

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

Advisor: Assoc. Prof. Dr. Alkan GÜNLÜ

In this study, the relationships between some stand parameters (stand mean diameter, stand dominant height, number of trees, stand basal area and stand volume), leaf area index, aboveground biomass and carbon values and, the remote sensing data obtained from active (Sentinel- 1) and passive (Sentinel-2, Landsat 8 OLI and Drone) sensors were modeled by multiple regression analysis (MLR) and artificial neural networks (ANN) techniques in pure Scots pine stands in Sinop Regional Directorate of Forestry. A total of 184 sample plots were taken in the study. Classical forest inventory measurements were made in each sample plot, and some stand parameters, aboveground biomass and carbon values were calculated for each sample plot. In addition, the backscattering and band values for the Sentinel-1 and the reflectance, vegetation indices and texture values for Sentinel-2, Landsat 8 OLI and Drone satellite images were calculated for each sample plot. Ground and remote sensing data of the sample plots were modeled with MLR and ANN techniques. When the modeling results obtained are examined, the best model results using textural features of Sentinel-2 15x15 window size for basal area with ANN technique (Model R^2=0.84, Test R^2=0.77), using textural features of Landsat 8 OLI 135° for stand volume with ANN technique (Model R^2=0,83, Test R^2=0,77), using textural features of Sentinel-2 7x7 window size for stand mean diameter with MLR (Model R^2=0,83, Test R^2=0,81), using textural features of Sentinel-2 15x15 window size for number of trees with ANN (Model R^2=0.81, Test R^2=0.69), using textural features of Sentinel-2 5x5 window size for stand dominant height and leaf area index with ANN (Model R^2=0.71, Test R^2=0.68) and (Model R^2=0.74, Test R^2=0.32), using textural features of Sentinel-2 9x9 window size for aboveground biomass with ANN technique (Model R^2=0.82, Test R^2=0.75) and using textural features of Sentinel-2 15x15 window size for aboveground carbon with ANN technique (Model R^2=0.89, Test R^2=0.77) were found. Also, with vegetation indices values obtained from drone images and the most successful model were found for stand basal area (R^2=0.40) and stand dominant height (R^2=0.44). In addition to, with the reflectance values obtained from the drone images, the most successful model (R^2=0.32) was found for the stand basal area.

2023, 160 pages

Keywords: *Pinus sylvestris*, Stand parameters, Modelling, Remote Sensing, Unmanned aerial vehicle (UAV), Artificial neural network (ANN)

ÖNSÖZ VE TEŞEKKÜR

“Sinop Orman Bölge Müdürlüğü Saf Sarıçam Meşcerelerinde Farklı Uzaktan Algılama Verileri Kullanılarak Bazı Meşcere Parametrelerinin Modellenmesi” adlı bu çalışma 2019-2022 yılları arasında hazırlanarak Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsüne “Doktora Tezi” olarak sunulmuştur.

Çankırı Karatekin Üniversitesi, Bilimsel Araştırma Projeleri Koordinatörlüğüne (BAP) desteklerinden dolayı teşekkür ederim (Proje No: OF211221D08).

Tez danışmanım Doç. Dr. Alkan GÜNLÜ’ye sabrı, rehberliği, anlayışı, çalışmamın her safhasında bana yol gösteren ve yakın ilgisi ile büyük destekleri için teşekkür ederim. Değerli fikir ve görüşlerinden yararlandığım ve yardımlarını esirgemeyen sayın Prof. Dr. Sedat KELEŞ, Prof. Dr. Fatih SİVRİKAYA, Dr. Öğr. Üyesi Sinan KAPTAN, Arş. Gör. Dr. Ferhat BOLAT ve Dr. Öğr. Üyesi Sinan BULUT hocalarıma sonsuz saygı ve teşekkürlerimi sunarım.

Orman Genel Müdürlüğü Orman İdaresi ve Planlama Daire Başkanlığı’na teşekkürlerimi sunarım. Ayrıca, envanter çalışmaları sürecinde yardımlarını esirgemeyen Sinop Orman Bölge Müdürü sayın Celal KANBUR, Orman İdaresi ve Planlama Şube Müdürü Fatih Deniz KILIÇ, 192 Nolu Orman Kadastro Komisyon Başkanı Zekeriya ASLAN, Sinop Orman İşletme Müdür vekili Hüseyin ALTINEL, Ayancık Orman İşletme Müdürü Hakan YASLIKAYA ve Sinop Orman Bölge Müdürlüğü, Ayancık, Boyabat, Gerze, Sinop ve Durağan Orman İşletme Müdürlüğü Şef ve Teknik personele süreçteki destekleri için çok teşekkür ederim.

Bu aşamaya gelmemde bana emeği geçen ve çalışmalarım süresince desteğini esirgemeyen sevgili aileme şükranlarımı sunarım.

Hasan AKSOY
Çankırı, 2023

İÇİNDEKİLER

ÖZET ..... **i**
ABSTRACT ..... **ii**
ÖNSÖZ VE TEŞEKKÜR ..... **iii**
İÇİNDEKİLER ..... **iv**
SİMGELER DİZİNİ ..... **vi**
ŞEKİLLER DİZİNİ ..... **vii**
ÇİZELGELER DİZİNİ ..... **ix**
1. GİRİŞ **1**
2. MATERYAL **10**
2.1. Çalışma Alanı Tanıtımı **10**
2.2. Yersel Veriler **12**
2.2.1. Örnek alan seçimi ve envanter **12**
2.2.2. Yaprak alan indeksi (YAİ) **13**
2.3. Uzaktan Algılama Verileri **13**
2.3.1. Landsat 8 OLI uydu görüntüsü **13**
2.3.2. Sentinel-2 uydu görüntüsü **15**
2.3.3. Sentinel-1 uydu görüntüsü **16**
2.3.4. Dron görüntüleri **18**
3. YÖNTEM **20**
3.1. Arazi Çalışması **22**
3.2. Yaprak Alan İndeksi Değerlerinin Elde Edilmesi **25**
3.3. Uzaktan Algılama Verilerinin Elde Edilmesi **27**
3.3.1. Reflektans değerleri ve görüntü kalibrasyonu **27**
3.3.2. Vejetasyon indis değerleri **28**
3.3.3. Tekstür değerleri **32**
3.3.4. Geri yansıtım değerlerin hesaplanması **33**
3.3.5. Dron görüntülerinin oluşturulması ve değerlerin hesaplanması **34**
3.4. Tahmin modellerin oluşturulması **42**
3.4.1. Çoğul regresyon analizi **43**
3.4.2. Bayesçi yapay sinir ağları **44**
3.4.3. Performans ölçütleri **47**
4. BULGULAR **49**
4.1. Meşçere Parametrelerine Ait Bulgular **49**
4.2. Uzaktan Algılama Verileri ile Modelleme **50**

4.2.1. Görüntülerden elde edilen reflektans verilerine ait bulgular 50
4.2.2. Vejetasyon indis verilerine ait bulgular 51
4.2.3. Dijital bant ve geri yansıtım verilerine ait bulgular 53
4.2.4. Tekstür verilerine ait bulgular 54
4.3. ÇRA Metodunda En Yüksek Başarıyı Sağlayan Modeller 66
4.4. ÇRA Metodunda En Yüksek Başarıyı Sağlayan Uzaktan Algılama Veri Setlerine YSA Metodunun Uygulanması 80
4.4.1. BYSAM meşcere hacmi (V) bulguları 81
4.4.2. BYSAM meşcere göğüs yüzeyi (G) bulguları 83
4.4.3. BYSAM meşcere ağaç sayısı (N) bulguları 85
4.4.4. BYSAM meşcere üst boy ($h_{üst}$) bulguları 87
4.4.5. BYSAM meşcere orta çap (d_g) bulguları 89
4.4.6. BYSAM yaprak alan indeksi (YAİ) bulguları 91
4.4.7. BYSAM topraküstü biyokütle (TÜB) bulguları 93
4.4.8. BYSAM topraküstü karbon (TÜK) bulguları 95
4.4.9. BYSAM meşçere parametreleri gözlem tahmin belirtme katsayısı ve hata grafikleri 97
4.5. ÇRA ve YSA Metotlarına Ait Sonuçların Denetimi 102
5. TARTIŞMA 109
5.1. Yersel Ölçümlere Ait Bulguların Değerlendirilmesi 109
5.1.1. Meşçere parametrelerine ait bulguların değerlendirilmesi 109
5.1.2. Topraküstü biyokütle (TÜB) ve topraküstü karbon (TÜK) bulgularının değerlendirilmesi 112
5.1.3. Yaprak alan indeksine (YAİ) ait bulguların değerlendirilmesi 113
5.2. Modelleme Bulgularının Değerlendirilmesi 116
5.2.1. Meşcere parametrelerine ilişkin modelleme bulgularının değerlendirilmesi 119
5.2.2. TÜB ve TÜK parametrelerine ilişkin modelleme bulgularının değerlendirilmesi 127
5.2.3. Yaprak alan indeksine ilişkin modelleme bulgularının değerlendirilmesi 131
6. SONUÇ VE ÖNERİLER 135
KAYNAKLAR 143
EKLER 157
ÖZGEÇMİŞ 158

SİMGELER DİZİNİ

AIC	Akaike ölçütü
BIAS	Ortalama Hata
BIC	Bayesian bilgi kriteri
BYSAM	Bayesçi Yapay Sinir Ağı Modeli
C	Karbon
cm	Santimetre
ÇRA	Çoğul Regresyon Analizi
d_g	Meşcere orta çapı
DSM	Digital Surface Model
DTM	Digital Terrain Model
G	Meşcere göğüs yüzeyi
g	Gram
GPS	Küresel Konumlandırma Sistemi
ha	Hektar
$h_{üst}$	Meşcere üst boyu
I_V	Hacim Artımı
İHA	İnsansız Hava Aracı
m	Metre
m^2	Metrekare
m^3	Metreküp
MAE	Ortalama mutlak hata
mm	Milimetre
N	Meşcere ağaç sayısı
OBM	Orman Bölge Müdürlüğü
OİM	Orman İşletme Müdürlüğü
OİŞ	Orman İşletme Şefliği
p	Önemlilik düzeyi
r	Korelasyon katsayısı
R^2	Belirtme katsayısı
RMSE	Hata kareler ortalamasının karekökü
SYM	Sayısal Yüzey Modeli
SAM	Sayısal Arazi Modeli
TÜB	Toprak Üstü Biokütle
TÜK	Toprak Üstü Karbon
V	Meşcere hacmi
V_{max}	Maksimum Hacim
V_{min}	Minimum Hacim
YAİ	Yaprak alan indeksi

ŞEKİLLER DİZİNİ

Şekil 2.1 Çalışma alanının konumu 10
Şekil 2.2 Landsat 8 OLI uydu görüntü konumu 14
Şekil 2.3 Sentinel-2 uydu görüntülerinin konumları 16
Şekil 2.4 Sentinel-1 uydu görüntülerinin konumları 17
Şekil 2.5 Dron, kamera ve gimbal görüntüsü 18
Şekil 2.6 Dron görüntülerinin parsel konumları 19
Şekil 3.1 Çalışma iş akış şeması 21
Şekil 3.2 Envanter çalışmasında alınan örnek alanların sayısal ve konumsal dağılımı 22
Şekil 3.3 Çalışmaya ait envanter karnesi, boy ölçümü ve artım kalemi 23
Şekil 3.4 Yaş ölçümü 23
Şekil 3.5 YAİ hesaplamasının akış diyagramı 26
Şekil 3.6 YAİ değerlerinin hesaplanması 27
Şekil 3.7 Seçilen referans piksel (n) için açıların gösterimi 32
Şekil 3.8 Sentinel-1 uydu görüntü kalibrasyon makrosu 34
Şekil 3.9 Dron görüntüleri iş akış diyagramı 35
Şekil 3.10 Dron uçuş plan örneği 37
Şekil 3.11 Uçuş sonrası ilgili parsele ait fotoğraf sıklığı ve sayısının görünümü 38
Şekil 3.12 Bağlama noktaları (Tie points) görünümü 39
Şekil 3.13 Dron görüntülerinden üretilmiş ortofoto, SAM, SYM, reflektans ve indeks haritalar 40
Şekil 3.14 Bantların indeks değerleri kullanılarak sınıflandırılmış görüntü 41
Şekil 3.15 Üç katmanlı ve üç nöronlu yapay sinir ağı modeli 45
Şekil 3.16 YSA'da yetersiz ve aşırı uyum gösterimi (IBM 2021) 46
Şekil 4.1 ÇRA metodu kullanılarak reflektans değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) grafiği, (Dron görüntüsü: D, Landsat 8 OLI: L8 ve Sentinel-2: S2) 51
Şekil 4.2 ÇRA metodu kullanılarak vejetasyon indis değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) (Dron görüntüsü: D, Landsat 8 OLI: L8 ve Sentinel-2: S2) 52
Şekil 4.3 ÇRA metou kullanılarak dijital bant ve geri yansıtım değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) (Dron görüntüsü: D ve Sentinel-1: S1) 54
Şekil 4.4 ÇRA metodu kullanılarak farklı pencere boyutlarına göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerine ilişkin toplam rölatif sıra (R_j) (Landsat 8 OLI: L8, Sentinel-2: S2) 67
Şekil 4.5 ÇRA metodu kullanılarak farklı derecelere göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerine ilişkin toplam rölatif sıra (R_j) (Landsat 8 OLI: L8, Sentinel-2: S2) 68
Şekil 4.6 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri 75
Şekil 4.7 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri 78

Şekil 4.8 BYSAM metodu ile elde edilen meşcere hacmine ait belirtme katsayı grafiği (R^2) 81
Şekil 4.9 BYSAM metodu ile elde edilen meşcere göğüs yüzeyine ait belirtme katsayı grafiği (R^2) 83
Şekil 4.10 BYSAM metodu ile elde edilen meşcere ağaç sayısına ait belirtme katsayı grafiği (R^2) 85
Şekil 4.11 BYSAM metodu ile elde edilen meşcere üst boyuna ait belirtme katsayı grafiği (R^2) 87
Şekil 4.12 BYSAM metodu ile elde edilen meşcere orta çapına ait belirtme katsayı grafiği (R^2) 89
Şekil 4.13 BYSAM metodu ile elde edilen yaprak alan indeksine ait belirtme katsayı grafiği (R^2) 91
Şekil 4.14 BYSAM metodu ile elde edilen topraküsütü biyokütleye ait belirtme katsayı grafiği (R^2) 93
Şekil 4.15 BYSAM metodu ile elde edilen topraküstü karbona ait belirtme katsayı grafiği (R^2) 95
Şekil 4.16 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri 97
Şekil 4.17 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri 100

ÇİZELGELER DİZİNİ

Çizelge 2.1 Çalışma alanı saf sarıçam meşcerelerinin gelişim çağlarına ilişkin alan dökümü 11
Çizelge 2.2 Çalışma alanı saf sarıçam meşcerelerinin bonitet sınıflarına ilişkin alan dökümü 11
Çizelge 2.3 Çalışma alanı saf sarıçam meşcerelerinin kapalılık sınıflarına ilişkin alan dökümü 12
Çizelge 2.4 Örnek alan seçim kriterleri ve ölçütleri 12
Çizelge 2.5 Landsat 8 OLI uydu görüntüsüne ait teknik özellikler 14
Çizelge 2.6 Sentinel-2 uydu görüntüsüne ait teknik özellikler 15
Çizelge 2.7 Sentinel-1 uydu görüntüsüne ait teknik özellikler 17
Çizelge 2.8 DJI Inspere 2 dron teknik özellikler 18
Çizelge 3.1 Meşcere parametreleri ve hesaplanması 24
Çizelge 3.2 Landsat 8 OLI uydu görüntüsü için hesaplanan vejetasyon indisleri 29
Çizelge 3.3 Sentinel-2 uydu görüntüsü için hesaplanan vejetasyon indisleri 30
Çizelge 3.4 Dron görüntüsü için hesaplanan vejetasyon indisleri 31
Çizelge 3.5 Elde edilen 8 farklı tekstür verisine ilişkin fonksiyonlar 33
Çizelge 4.1 Meşcere parametrelerine ilişkin tanımlayıcı istatistik değerleri 49
Çizelge 4.2 Landsat 8 OLI, Sentinel-2 ve dron görüntülerinden elde edilen reflektans değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2) 50
Çizelge 4.3 Landsat 8 OLI, Sentinel-2 ve dron görüntülerinden elde edilen vejetasyon indis değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2) 52
Çizelge 4.4 Sentinel-1 ve dron görüntülerinden elde edilen dijital bant ve geri yansıtım değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2) 53
Çizelge 4.5 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı pencere boyutuna ilişkin tekstür değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2) 56
Çizelge 4.6 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı derece değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2) 57
Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin performans ölçütleri 58
Çizelge 4.8 Landsat 8 OLI uydu görüntüsünden 135° tekstür verileri ile elde edilen meşcere hacim modeli 69
Çizelge 4.9 Sentinel-2 uydu görüntüsünden 15x15 pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere göğüs yüzeyi modeli 70
Çizelge 4.10 Sentinel-2 uydu görüntüsünden 15x15 f pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere ağaç sayısı modeli 70
Çizelge 4.11 Sentinel-2 uydu görüntüsünden 5x5 pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere üst boy modeli 71
Çizelge 4.12 Sentinel-2 uydu görüntüsünden 7x7 pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere orta çap modeli 71

Çizelge 4.13 Sentinel-2 uydu görüntüsünden 5x5 pencere boyutuna ilişkin tekstür verileri ile elde edilen yaprak alan indeksi modeli 72
Çizelge 4.14 Sentinel-2 uydu görüntüsünden 9x9 pencere boyutuna ilişkin tekstür verileri ile elde edilen topraküstü biyokütle modeli 72
Çizelge 4.15 Sentinel-2 uydu görüntüsünden 15x15 pencere boyutuna ilişkin tekstür verileri ile elde edilen topraküstü karbon modeli 73
Çizelge 4.16 ÇRA metodu ile elde edilen meşçere parametrelerine ait model – test performans ölçütleri 74
Çizelge 4.17 BYSAM metodu ile elde edilen meşcere hacmine ilişkin model – test performans ölçütleri 82
Çizelge 4.18 BYSAM metodu ile elde edilen meşcere göğüs yüzeyine ilişkin model – test performans ölçütleri 84
Çizelge 4.19 BYSAM metodu ile elde edilen meşcere ağaç sayısına ilişkin model – test performans ölçütleri 86
Çizelge 4.21 BYSAM metodu ile elde edilen meşcere orta çapına ilişkin model – test performans ölçütleri 90
Çizelge 4.22 BYSAM metodu ile elde edilen yaprak alan indeksine ilişkin model – test performans ölçütleri 92
Çizelge 4.23 BYSAM metodu ile elde edilen topraküsütü biyokütleye ilişkin model – test performans ölçütleri 94
Çizelge 4.24 BYSAM metodu ile elde edilen topraküstü karbona ilişkin model – test performans ölçütleri 96
Çizelge 4.25 Meşcere hacminin uzaktan algılama verileri ile model performans ölçütleri 103
Çizelge 4.26 Meşcere göğüs yüzeyinin uzaktan algılama verileri ile model performans ölçütleri 103
Çizelge 4.27 Meşcere ağaç sayısının uzaktan algılama verileri ile model performans ölçütleri 104
Çizelge 4.28 Meşcere üst boyunun uzaktan algılama verileri ile model performans ölçütleri 105
Çizelge 4.29 Meşcere orta çapının uzaktan algılama verileri ile model performans ölçütleri 105
Çizelge 4.30 Yaprak alan indeksinin uzaktan algılama verileri ile model performans ölçütleri 106
Çizelge 4.31 Yaprak alan indeksinin uzaktan algılama verileri ile hesaplanmasına ait performans ölçütleri 106
Çizelge 4.32 Topraküstü biyokütlenin uzaktan algılama verileri ile model performans ölçütleri 107
Çizelge 4.33 Topraküstü karbonun uzaktan algılama verileri ile model performans ölçütleri 107

1. GİRİŞ

İnsanlık tarihinin başlangıcından günümüze kadar insanoğlu hayatını sürdürebilmek için gerekli olan birçok temel ihtiyacını doğal kaynaklardan karşılamıştır. Doğal kaynaklar içerisinde yer alan ve birden fazla doğal kaynağa bizzat kendisi ev sahipliği yapan ormanlar, beslenme ve barınma evresinden başlayarak teknik ormancılık evresine kadar geçen süre zarfında her daim insanlık için önemini korumuş ve korumaya da devam edecektir. Ormanlar, toplumun doğrudan ya da dolaylı olarak faydalandığı pek çok ürün ve hizmeti doğal süreç içerisinde kendi kedine üretme yeteneğine sahiptir. Bu ürün ve hizmetler içerisinde odun hammaddesi en eskisi ve en bilinenidir. İnsanoğlu orman ve orman kaynaklarından en başta odun hammaddesi ihtiyacını karşılamak amacıyla faydalanırken zaman içerisinde dünya nüfusunda yaşanan artışlar ve gelişmelere bağlı olarak bu faydalanmaların şekli ve şiddeti de değişiklik göstermiştir (Kaptan 2018)

Ormanlar birçok ekonomik işlevin yanı sıra iklim düzenleme, su koruma, toprak koruma ve biyoçeşitliliğin korunması (Asan 2003), rekreasyon gibi çeşitli ekonomik, ekolojik ve çevresel faydalara hizmet eden en büyük karasal ekosistemlerdir (Eckert 2012). Endüstri için bir hammadde kaynağı olan ormanlar küresel karbon döngüsü açısından da hayati derecede önemli bir kaynaktır (FAO 2015). Özellikle son yıllarda etkisini ve şiddetini hissettiren küresel ve çevresel boyuttaki felaketlerin yavaşlatılması ve önlenmesinde oynadığı rol nedeniyle ormanlar tüm dünya geleceğinin sigortası konumdandırlar. Orman ekosistemleri uygun işletme teknikleri ile işletildiklerinde bir karbon deposu olarak rol oynarken, plansız ve ölçüsüz uygulamalar neticesinde ise bir karbon kaynağına dönüşebilmektedirler (McKinley *et al.* 2011). Sera etkisine neden olan gazların en önemlisi olan CO_2, yeşil bitkilerin biyolojik döngüsü içerisinde gerçekleşen fotosentezin ana girdilerindendir (Saraçoğlu 2018). Bütün bitkiler fotosentez yoluyla havadaki CO_2 ve güneş ışığını kullanarak organik madde üretmekte, bu şekilde tükettikleri CO_2'yi biyokütlelerinde depolamaktadırlar. CO_2 alımı bitkilerdeki yaprak miktarına bağlı olarak değişmektedir. Orman ağaçları diğer bitkilere kıyasla daha fazla yaprak miktarına sahip olduğundan CO_2 tüketimi en fazla orman alanlarında gerçekleşmektedir. Bu da orman ekosistemlerini yeryüzündeki karbon havuzlarının önemli bir parçası haline getirmektedir.

Ormanların karbon tutma kabiliyeti fotosentez ile doğrudan ilgilidir. Fotosentez su (H_2O), karbondioksit (CO_2), güneş ışığı ve klorofil tepkimesiyle gerçekleşir ve CO_2 deki karbon glikoz molekülüne bağlanarak tutunma gerçekleşmiş olur. Fotosentez olayının yapraklar tarafından gerçekleşiyor olması yaprak alanı indeksini (YAİ) karbon döngüsü üzerinde önemli bir yere koymaktadır. YAİ birim alana düşen ve aktif olarak fotosentez yapmakta olan yaprak alanı miktarını ifade eder. Meşcere kapalılığının önemli bir göstergesi olan YAİ, büyüme ve verimlilik ile ilgili önemli bir göstergedir. Fırtına, kar ve rüzgâr kaynaklı devrilmeler, kuraklık gibi doğal afetler ve planlama uygulamaları sonucu YAİ'deki herhangi bir değişiklik verimlilik ve üretkenliği doğrudan etkilemektedir. Dolayısıyla meşcere parametrelerinin modellenmesinde yaygın olarak kullanılan YAİ, özellikle artım, büyüme ve hacim gibi meşcere özellikleri ile yüksek oranda ilişki göstermektedir.

İnsanlığa çok yönlü fayda ve hizmetler sağlayan ormanların sürekliliğini sağlamak ve varlığını artırmak toplum taleplerinin karşılanması açısından oldukça büyük önem arz etmektedir. Ormanlardan gelişi güzel şekilde gerçekleştirilen düzensiz faydalanmalar erozyonla toprak kaybı, çevre kirliliği, doğal habitatların yok olması, ormanların sağlık durumlarının bozulması, biyolojik çeşitliliğin azalması ve uzun vadede ekosistem sürekliliğinin sağlanamaması gibi pek çok sorunları da beraberinde getirmiş ve planlı yaklaşımı mecburi kılmıştır (Başkent 1999, Sivrikaya 2008). Türkiye'de ormanların planlanması ve sürekliliğinin sağlanması orman amenajman planları ile sağlanmaktadır. Orman amenajman planlarının yapılması görevi ise Orman Genel Müdürlüğüne bağlı Orman İdaresi ve Planlama Dairesi Başkanlığına aittir. Genel anlamda orman amenajmanı; ormanların geleceği hakkında kararları etkileyen biyolojik, sosyal, ekonomik ve diğer faktörlerin tümünü birleştirerek orman ekosisteminin devamlılığını ve stabilitesini sağlamak, toplumun ormandan olan her türlü ihtiyacını optimal şekilde karşılamak için gerekli en modern yöntem veya metodu kullanmak, en uygun yararlanma şekline karar vermek ve ormanı kontrol altına almak gibi önemli görevleri üstlenmiş bir bilim dalıdır (Başkent 1996).

Sürdürülebilir ormancılığın sigortası olan orman amenajman planlarının yapım aşamasını oluşturan envanter çalışmaları yoğun emek, zaman ve masraf gerektiren iş ve işlemlerin yumağıdır. Ormancılıkta envanter, orman işletme sisteminde yer alan ve onun işlevini

etkileyen tüm iç ve dış öğeleri tanıyıp kavrayabilmek için belli zaman kesitinde sürdürülen ölçüm, sayım, değerlendirme ve yorumlama işlerini kapsamaktadır (Kapucu 2004). Türkiye'de orman amenajman planlama çalışmaları kapsamında yapılan envanter çalışmaları; alan envanteri, ağaç serveti ve artım envanteri, yetişme ortamı envanteri, biyolojik çeşitlilik envanteri, odun dışı orman ürünleri envanteri, sosyo-ekonomik durum envanteri ve sağlık durumu envanteri olmak üzere geniş bir yelpazeye sahiptir (OGM 2017).

Alan envanteri, orman amenajman plan yapımının ilk ve en önemli aşaması olup plan ünitesinin orman ve orman dışı alan bilgilerinin üretilmesi için gerçekleştirilir. Alan envanteri uzaktan algılama (hava fotoğrafları) ve yersel ölçümlerin bir arada kullanıldığı kombine envanter yöntemine göre gerçekleştirilmektedir. Bir plan ünitesi (genellikle orman işletme şefliği (OİŞ) bazında) için aylarca sürebilen bu çalışmalar, plan ünitesinin ormanlık alanlarına belirli aralık-mesafelerle sistematik olarak dağıtılan örnek alanların içine rast gelen ve göğüs yüksekliğindeki çapı ($d_{1,30}$) olan tüm ağaçların ağaç türü, adedi, kapalılığı gibi parametrelerin yersel ölçüm ve gözlemlere dayalı olarak tespitine dayanmaktadır. Ayrıca, bonitet sınıfının saptanması için hâkim ağaçların boyu (h) ve yaşı (t); hacim (V) ve hacim artım (Iv) tablolarını oluşturabilmek için orta ağacın yaşı, boyu, çift kabuk kalınlığı ve son on yıllık halka genişliği gibi parametreler de ölçülerek envanter karnelerine kaydedilmektedir (OGM 2017). Göğüs yüzeyi (G), ağaç sayısı (N), meşcere hacmi (V), meşcere orta çapı (D) gibi meşcere parametrelerinin tespiti ve ölçümü orman amenajman planlarının hazırlanmasının altyapısını oluşturmaktadır (Hyyppä *et al.* 2000, Günlü *et al.* 2008, Sakıcı 2009, Günlü vd. 2013, Yılmaz 2017). Meşcere hacmi (V), bir birim orman alanındaki tüm canlı ağaçların toplam stok hacmidir ve orman kaynaklarının kalitesini ve orman ekosistemlerinin sağlığını değerlendirmek için temel bir parametre ve anahtar göstergedir (Antropov *et al.* 2013). Ormanların sahip olduğu hacmin doğru tahmini, bir bölgenin orman yönetimi ve karbon tutma politikalarına rehberlik etmek için son derece önemlidir (Chrysafis *et al.* 2017).

Orman örtüsünü izlemek ve meşcere hacmi, meşcere orta çapı, meşcere göğüs yüzeyi, meşcere üst boyu, meşcere ağaç sayısı, topraküstü biyokütle ve karbon gibi meşcere parametrelerini tahmin etmek için çeşitli uzaktan algılama verileri kullanılmıştır (Ali *et*

al. 2015). Uzaktan algılama yüksek verimlilik, düşük maliyet, geniş zamansal ve mekânsal kapsama alanına sahip olma, az sayıda örnek alandan elde edilen yersel veriler ile uzaktan algılama verilerinin birleştirerek meşcere parametrelerinin mekansal dağılımının haritalanmasına imkân sunması gibi avantajları sebebiyle giderek daha popüler hale gelmiştir (Santoro *et al.* 2011). Öyle ki uydu görüntüleri, karasal ekosistemler içerisinde geniş yayılış alanına sahip orman alanlarının haritalanması, izlenmesi ve gerekli bilgilerin elde edilmesini sağlayan tek araç olmuştur (Achard *et al.* 2002, Hansen *et al*. 2008, Hansen *et al.* 2009, Pekkarinen *et al.* 2009, Eva *et al.* 2010, Raši *et al.* 2011, Kaptan *et al.* 2022). Latifi *et al.* (2015), yaklaşık olarak 300 km^2'lik bir orman alanı için lidar tabanlı veri toplamanın geleneksel orman envanterine kıyasla %90 daha ucuz olduğunu ortaya koymuşlardır.

Uzaktan algılama verileri kullanılarak meşcere parametrelerini tahmin etmeyi amaçlayan birçok çalışma vardır. Bu çalışmalardan birkaçı; Landsat 8 OLI uydu görüntüsü ile karaçam için meşcere parametrelerinin regresyon ve yapay sinir ağları (YSA) ile tahmin edilmeye çalışıldığı bir çalışmada, orta çap, göğüs yüzeyi, meşcere hacmi ve ağaç sayısı için en yüksek belirtme katsayıları YSA metodu ile elde edilmiştir (Sakıcı and Günlü 2018). Bulut (2021) yapmış olduğu doktora tezinde ise uydu görüntülerini kullanarak net birincil üretim ve yaprak alan indeksini tahmin etmeye çalışmıştır.

Özkan (2006) uydu görüntüleri yardımı ile meşcere parametrelerini, Özdemir ve Ahmet (2009) Quickbird uydu görüntüsü kullanarak kızılçam ormanında gövde hacmini tahmin etmeyi amaçlamıştır. Günlü (2012) Landsat uydu görüntüsü ile bazı meşcere parametrelerini ve arazi kullanım sınıflarının belirlenmesini araştırmış, Özdemir (2013) havasal Lidar verileri ile bazı meşcere parametrelerini tahmin etmiş, Günlü *et al.* (2013) Quickbird ve Landsat 7 ETM+ uydu görüntüleri ile meşcere hacmini tahmin etmeye çalışmış, Avcı vd. (2014) yapmış oldukları bir çalışmada meşcere tiplerini uydu görüntüleri ile belirlemeye çalışmışlardır. Günlü vd. (2014) Landsat TM uydu görüntüsü ile Yapraklı Orman İşletme Şefliğinde bazı meşcere parametrelerini tahmin etmiş, Ateşoğlu (2014) farklı uydu görüntü verileri ile meşcere parametreleri arasındaki ilişkiyi araştırmış, Anlar vd. (2015) Spot-4 uydu görüntüleri ile bazı meşcere parametrelerini tahmin edilmesini araştırmıştır. Özkan ve Yeşil (2016) Ikonos uydu görüntüleri ile

meşcere tiplerini ayırma olanaklarını araştırmış, Gögerçin (2017) Göktürk-2 uydu görüntüsü ile bazı meşcere parametrelerini tahmin etmiş, Şenyurt vd. (2017) Reşadiye Orman İşletme Şefliğinde Landsat TM uydu görüntüsü ile bazı meşcere parametrelerini tahmin etmeye çalışmışlardır. Karahalil vd. (2017) yerel uydu ve dijital kamera görüntüleri ile meşcere parametrelerini tahmin etmeye çalışırken, Bulut vd. (2021) saf karaçam meşcerelerinde yaprak alan indeksi ile meşcere parametreleri arasındaki ilişkileri modellemiş, Vatandaşlar ve Zeybek (2021) el Lidar teknolojisinin orman envanterinde kullanım olanaklarını araştırmıştırlardır. Demirel (2022) ise saf karaçam ve sarıçam meşcerelerin de Sentinel-1 ve Sentinel-2 uydu görüntüleri yardımıyla bazı meşcere parametrelerini tahmin etmeyi amaçlamıştır.

Diğer optik uzaktan algılama verileriyle karşılaştırıldığında, 30 m uzamsal çözünürlüğe sahip Landsat görüntüleri, uzun vadeli veri kayıtları ve dünya çapında ücretsiz erişimleri nedeniyle son yıllarda meşcere hacmi ve topraküstü biyokütle (TÜB) tahmini için en yaygın şekilde kullanılan pasif algılayıcı veri kaynağıdır (Li *et al.* 2020a). Sentinel-2 ise üç uzamsal çözünürlüğe (10 m, 20 m ve 60 m) sahip 13 spektral bant görüntüsü ile iki uydunun A/B şeması şeklinde veri sağlamaktadır (Jiang *et al.* 2020). Bu nedenle, Landsat 8 OLI'den daha yüksek spektrumlu ve uzaysal-zamansal çözünürlüğe sahip görüntüler sağlar. Sentinel-2 uydu sistemi tarafından sağlanan 10 m çözünürlüklü multispektral ve 20 m çözünürlüklü bitki örtüsü kırmızı kenar (VRE) kısa dalga boyuna sahip kızılötesi (SWIR) bant görüntüleri, orman kaynaklarının izlenmesi için yüksek kaliteli veriler elde etmemize izin vererek, meşcere parametrelerinin tahmin doğruluğuna büyük katkı sunmaktadır.

ALOS PALSAR ve Sentinel-1 gibi aktif uzaktan algılama sistemleri ele alınacak olursa, meşcere parametrelerinin tahmininde benzersiz avantajlara sahiptir (Sinha *et al.* 2015). Orman gölgelik yapısına nüfuz etme kabiliyetine sahip radar verileri, optik sensör görüntülerine kıyasla orman yoğunluğundaki değişikliklere karşı farklı hassasiyetlere gösterebilmektedir (Soja *et al.* 2021). Aktif algılayıcılar olan ALOS PALSAR ve Sentinel-1 gibi uydu görüntüleri ile meşcere parametrelerinin tahmin edilmesine yönelik çalışmalar ise sınırlı sayıdadır (Günlü and Ercanlı, 2020, Keleş *et al*., 2021, Yazdani *et al*. 2020, Demirel 2022).

Uçaklar, helikopterler, lidar sensörler ve multispektral (MS) veya hiperspektral kameralarla donatılmış dron gibi yenilikçi platformlar, kuşbakışı görünümünden yüksek çözünürlüklü verilerin elde edilmesini sağlar. Özellikle, lidar nokta bulutlarının ve optik çok kanallı görüntülerin birleşimi, orman yapısal değişkenlerinin envanteri için en belirgin seçeneklerden biri olduğu belirtilmektedir (Latifi and Heurich 2019). Bir ön işleme adımında, tek ağaçlar belirgin olarak havadan lazer tarama (ALS) verilerinden (Pyysalo and Hyyppa 2002, Solberg *et al.* 2006) veya orijinal 3B nokta bulutu üzerinde belirlenebildiği ortaya konulmuştur (Reitberger *et al.* 2009, Briechle *et al.* 2021). Son yıllarda, dron uzaktan algılama teknolojisinin hızlı gelişimi, yüksek çözünürlük ve basit veri toplamanın düşük maliyetli, hızlı ve düşük riskli olmasının avantajlarını vurgulamıştır (Lan *et al.* 2019). Bu avantajlar, geleneksel uzaktan algılamanın eksikliklerini tamamlamaktadır. Dron uzaktan algılama teknolojisi, arazi kullanımı sınıflandırmasında, tarımsal kaynak araştırmalarında (Lebourgeois *et al.* 2008), orman kaynakları araştırmalarında, orman zararlılarının kontrolünde ve yangın tespitinde (Komárek 2020) yaygın olarak kullanılmaktadır.

Dron uzaktan algılamada, küçük boyutlu orman alanlarının ve bunların uzamsal modellerinin tespit edilmesini sağlamaktadır (Getzin *et al.* 2014). Dronların orman araştırmalarında düşük malzeme ve işletme maliyetleri ile veri toplama esnekliği ve yüksek yoğunluklu veri toplama kabiliyeti gibi yönleri diğer uzaktan algılama veri kaynaklarından ayrıldığı en önemli avantajlarındandır (Tang *et al.* 2015). Dronların kullanımı, düşük uçuş irtifası nedeniyle uçuş başına küçük alanların kapsanması, sınırlı pil kapasitesi ve dronu görsel görüş hattında tutmak için mevcut düzenleyici gereklilikler gibi bir dizi zorluklar da yine dronların dezavantajları olarak karşımıza çıkmaktadır. Bununla birlikte, hafif sabit kanatlı dronlar, multikopter dronlarından tek uçuşla (150 ha'a kadar) daha geniş bir alanı kaplayabilir ve böylece bahsedilen dezavantajlar azaltılma yönleri araştırılmaktadır. Ayrıca, hafif sabit kanatlı dronlar da birden fazla pilin kullanılması, optimum hava koşullarında bir iş günü içinde havadan 1000 hektara kadar kapsama alanı sağlayabileceği belirtilmektedir (Giannetti *et al.* 2018).

Dronlar çeşitli sensörlerle donatılabilmekte ve böylece çalışmaya özgü görüntüleme sistemi sunma kabiliyetine sahiptirler (Torresan *et al.* 2017). Son yıllarda, uygulayıcılar

ormancılıkta dron uygulamalarına ya yalnızca optik kameralar kullanarak ya da bunları yeni teknolojiler sunan hareketli sistemler (Remondino *et al.* 2014) ile birleştirerek çalışmalar gerçekleştirmektedirler. Üç boyutlu (3B) verileri (örneğin, görüntü tabanlı nokta bulutu) ve 2B verileri sayısal yüzey modeli (SYM) ve ortomozaik) kolayca türetme kabiliyetleri veri sağlama noktasında kolaylık sağlamaktadır. Yüksek çözünürlüklü sayısal arazi modeli (SAM) ile normalleştirilen dron 3B görüntü tabanlı nokta bulutları, havadan taşınanlara daha ucuz bir alternatif olarak orman yapısal değişkenlerinin (örneğin sıklık, hacim veya topraküstü biyokütle) tahmini için araştırılmıştır (Alonzo *et al.* 2018).

Dron teknolojisindeki gelişmeler, geleneksel uzaktan algılama platformlarını kullanarak gerçekleştirilmesi zor veya imkânsız olan çevresel süreçleri ve değişiklikleri mekânsal ve zamansal ölçeklerde araştırmayı mümkün kılmıştır. Bu yetenekler, düşük veri toplama maliyetleri, giderek daha kullanıcı dostu esneklik ve anında veri teslimi ile birlikte ormanlarda araştırma ve ticari uygulamalar için teknolojinin daha fazla kullanımını kolaylaştırmaktadır. Dronlar, uçuş yolları boyunca otonom navigasyona ve veri toplamaya izin veren, ilgi alanlarının sistematik, hızlı ve verimli haritalanmasını sağlayan Global Konumlandırma Sistemi (GPS) alıcıları, atalet ölçüm teknikleri ve diğer sensörlerle donatılmıştır. Elde edilen görüntüler, santimetre aralığında çok yüksek uzamsal çözünürlüğe ve büyük örtüşmelere sahip olması ile sayısal yüzey modelin (SYM) hesaplanmasına olanak tanımaktadır. Böylece tek ağaç ve meşcereye ait yükseklik bilgileri sağlaması bakımından meşcere parametrelerinin birçoğunun hesaplanmasında yaygın olarak kullanılmaktadır (Komárek 2020).

Yapılan çalışmalarda ve ulusal karbon depolama miktarının belirlemesinde çoğunlukla meşcere hacmine dayalı denklemler kullanılmaktadır. Bu gibi meşcere parametrelerinin yersel ölçümlerle belirlenmesi pahalı ve zaman alıcı bir süreci içermektedir. Günümüzde uzaktan algılama verileri kullanılarak meşcere parametrelerinin tahminine yönelik çalışmalar yapılmaktadır. Özellikle gelişen teknoloji ile beraber uydu görüntülerine (Landsat TM- ETM+-8 OLI, Sentinel 1-2) ulaşımın kolaylaşması araştırmacıların bu tür çalışmalar üzerine yoğunlaşmasına olanak sağlamıştır. Fakat uydu görüntü çözünürlükleri araştırma tiplerine göre kısmen yetersi kalabilmektedir. Yüksek

çözünürlüklü uydu görüntüleri de maliyetli olduğu için her araştırma için olanak tanımamaktadır. Son yıllarda gelişen ve gelişmekte olan dronlar yüksek çözünürlüklü uydu görüntülerine daha uygun maaliyette alternatif oluşturmaktadır. Örneğin çalışmalarında örnek alanlara (300 m^2) ilişkin bir Landsat görüntüsünden reflektans verisi alındığında görüntü çözünürlüğü (30 m) 900 m^2 olduğundan tek bir piksel değeri örnek alan için yeterli gelmekte ve çok kapsayıcı olmaktadır. Dron görüntüleri ise cm hassasiyetinde çözünürlüğe sahip oldukları için bir örnek alanın (300 m^2) yüzlerce piksel ile temsil edilişi daha sipesifik ve ayrıntılı uzaktan algılama verisi sağlamaktadır. Bu yönüyle özellikle bu çalışmada dron görüntüleri önemli bir yere sahiptir.

Bu doktora tez çalışması kapsamında Sinop Orman Bölge Müdürlüğü saf sarıçam meşcerelerinde yersel ölçümlerle birlikte yaprak alan indeksi (YAİ), topraküstü biyokütle (TÜB), topraküstü karbon (TÜK) miktarı ve meşcere orta çapı, meşecere üst boyu, meşecere ağaç sayısı, meşcere göğüs yüzeyi, meşcere hacmi, uzaktan algılama verileri (aktif ve pasif uydu görüntüleri) ile son zamanlarda öne çıkan dron görüntüleri ve farklı modelleme teknikleri kullanılarak tahmin edilmeye çalışıldı. Ağaç türü olarak sarıçam meşcereleri seçilmiştir. Çünkü ülkemizde sarıçam ağaç türleri yayılış alanı bakımından beşinci sırada ve toplam orman alanlarımızın %6,8'lik kısmının (1,54 milyon ha) sarıçam ormanlarından oluşması Türkiye için önemli türlerden biri olmasının göstergesidir (OGM 2021). Sarıçam sadece kuzey yarımkürede çok geniş bir alanda yayılış göstermesi ile de öne çıkan bir türdür. Anadolu'nun dışında, kuzeyde, İskoçya, Norveç, İsveç ve Finlandiya'nın kuzeyine kadar yayılış göstermektedir. Güneyde ise İspanya'nın Pirene Dağları'na kadar iner. Alplerde, Karpatlarda serpilmiş olarak, Yugoslavya, Bulgaristan, Kırım ve Kafkaslar' da yayılır. Ülkemizde ise Doğu Anadolu'nun kuzeyi, Kuzey ve Kuzey-Batı Anadolu Bölgeleri'nde 0-2700 m yükseklik kademelerinde saf ya da diğer türlerle karışık olarak rastlanır. Türkiye'de genel yayılışının en güney sınırını Kayseri Pınarbaşı'nda yapmaktadır. (Gökmen 1970, Çepel 1976, Çömez 2010, Erkan vd. 2021). Türkiye'de özellikle dron'un da dahil edildiği bu yoğunlukta bir araştırma bu çalışmanın önemini artırmakta ve dron kullanarak Orman Bölge Müdürlüğü bazında ve saf sarıçam meşcerelerinde meşcere parametrelerini tahmin etmeyi amaçlayan ilk araştırma olması nedeniyle literatüre önemli katkı sağlayacağı düşünülmektedir.

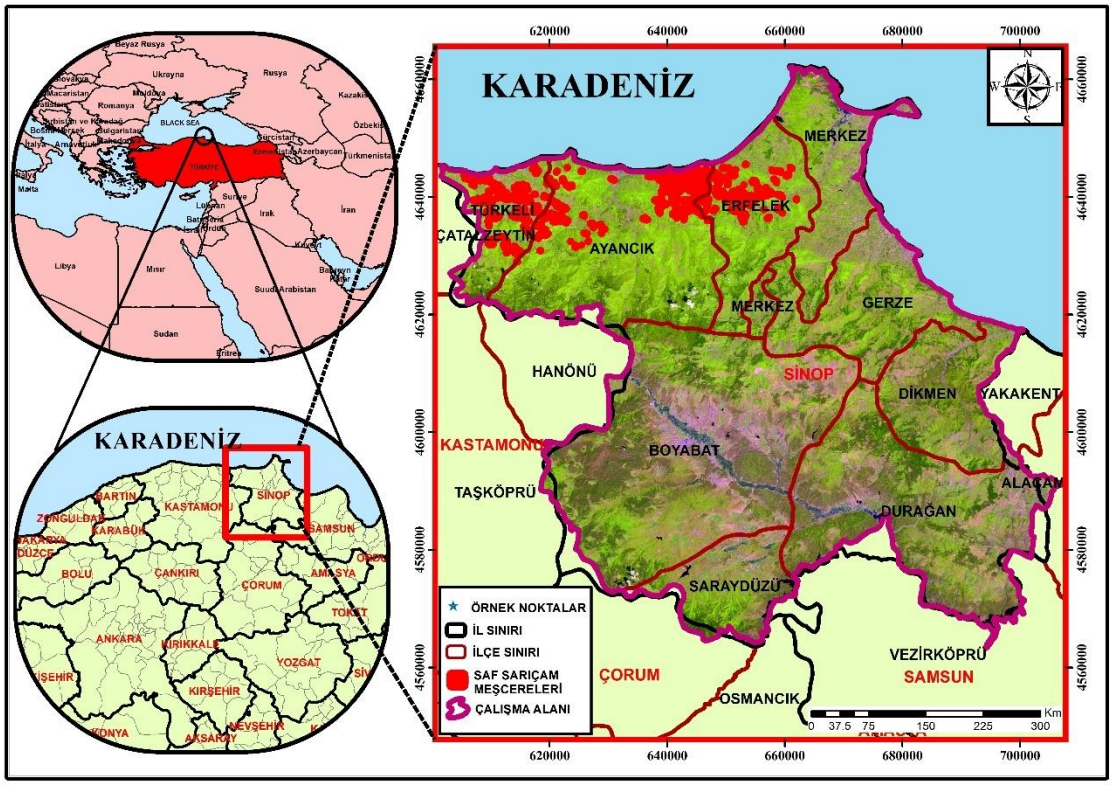
Sinop Orman Bölge Müdürlüğü sınırlarında yayılış gösteren saf sarıçam meşcereleri için yapılmış olan bu tez çalışmasının ana amaçları;

i. Çalışma alanında yayılış gösteren saf sarıçam meşcerelerinde gelişim çağı, bonitet ve kapalılık sınıflarına göre rastgele örnekleme yöntemine göre belirlenmiş olan örnek alanlarda ağaç serveti ve artımına yönelik envanter yapılmış, elde edilen envanter verileri kullanılarak meşcere orta çapı, meşcere üst boyu, meşcere ağaç sayısı, meşcere göğüs yüzeyi ve meşcere hacmi gibi meşcere parametrelerini hesaplanmış,
ii. Sarıçam meşçereleri için geliştirilmiş tek girişli biyokütle denklemleri kullanılarak topraküstü biyokütle ve karbon hesaplanmış,
iii. Örnek alanlara ilişkin yaprak alan indeksini (YAİ) dolaylı yöntemle belirlenmiş,
iv. Aktif (Sentinel-1) ve pasif (Landsat 8 OLI, Sentinel-2 ve dron) uydu görüntülerinden örnek alanlara ilişkin geri yansıtım, reflektans, vejetasyon indis ve tekstür değerleri hesaplanmış,
v. Örnek alanlardan elde edilen yersel veriler ile uzaktan algılama verileri arasındaki ilişkiler çoğul regresyon ve yapay sinir ağları metotları ile modellenmiştir.

2. MATERYAL

2.1. Çalışma Alanı Tanıtımı

Bu çalışma Sinop Orman Bölge Müdürlüğü (OBM) sınırları içerisinde yayılış gösteren saf sarıçam meşcerelerinde gerçekleştirilmiştir (Şekil 2.1). Sinop OBM 6 adet Orman İşletme Müdürlüğü ve 61 adet Orman İşletme Şefliğinden oluşmaktadır. Çalışma alanı konum itibariyle 601590-707391 doğu boylamları ile 4662313-4563463 kuzey enlemleri arasındadır. Sinop OBM'nin toplam alanı 556.275,50 ha olup saf sarıçam meşcerelerinin toplam alanı 7.548,49 ha'dır (OGM 2020).



Şekil 2.1 Çalışma alanının konumu

Çalışma alanı Türkiye'nin en kuzeyinde yer almakta ve yılın her zamanında yağış aldığından zengin orman ve bitki örtüsüyle kaplıdır. Ormanlar hem zengin, hem de çeşitlidir. Çalışma alanında yağışlar aylara göre oldukça düzenlidir. En çok Ekim ayında, en az Mayıs ayında yağış alan çalışma alnında yıllık ortalama yağış miktarı 685,7 mm'dir

(Url-1). Sinop OBM'de yayılış gösteren ağaç türleri; *Pinus nigra* (Çk), *Pinus sylvestris* (Çs), *Abies nordmanniana* (G), *Fagus orientalis* (Kn), *Carpinus betulus* (Gn), *Quercus (Quercus cerris, Quercus infectoria, Quercus frainetto, Quercus robur, Quercus petraea)* (M), *Juniperus sp.* (Ar), *Fraxinus excelsior* (Dş), *Ulmus* L., *Sp.* (Ka) ve *Populus tremula* (Kv) başlıca doğal yayılış gösteren türlerdir (Anonim 2022). Alanda saf sarıçama ait 1, 2 ve 3 kapalılığında Çsa, Çs0a, Çsa3, Çsab2, Çsab3, Çsb1, Çsb2, Çsb3, Çsbc3, Çsc1, Çsc2, Çsc3, Çscd1, Çscd2, Çscd3, Çsd1, Çsd2 ve Çsd3 meşcereleri bulunmaktadır. Orman amenajman planlarındaki meşcere tipleri haritalarına göre gelişim çağı, bonitet ve kapalılık sınıflarına göre detaylı alan dağılımı Çizelge 2.1, 2.2 ve 2.3'te verilmiştir.

Çizelge 2.1 Çalışma alanı saf sarıçam meşcerelerinin gelişim çağlarına ilişkin alan dökümü

Gelişim Çağı	**Alan (ha)**
a	1.179,24
b	2.048,52
c	3.686,08
d	634,65
Toplam	**7.548,49**

Çizelge 2.2 Çalışma alanı saf sarıçam meşcerelerinin bonitet sınıflarına ilişkin alan dökümü

Bonitet	**Alan (ha)**
I	884,87
II	3.083,99
III	3.196,62
IV	356,85
V	26,16
Toplam	**7.548,49**

Çizelge 2.3 Çalışma alanı saf sarıçam meşcerelerinin kapalılık sınıflarına ilişkin alan dökümü

Kapalılık	Alan (ha)
1	1.054,94
2	1.300,09
3	5.193,46
Toplam	**7.548,49**

2.2. Yersel Veriler

2.2.1. Örnek alan seçimi ve envanter

Bu çalışmada 4 farklı gelişim çağı, 3 farklı kapalılık ve 5 farklı bonitet sınıfından olmak üzere 3 tekerrürlü ölçüm yapılarak (4 x 3 x 5 x 3) 180 örnek alanda orman envanter çalışması gerçekleştirilmiştir (Çizelge 2.4). Envanter sırasında 4 örnek alan fazla alınmış ve toplamda 184 örnek alanda analizler gerçekleştirilmiştir. Örnek alanlar saf sarıçam meşcerelerinden gelişim çağı, kapalılık ve bonitet sınıflarını temsil edecek şekilde bilinçli olarak seçilmiştir. Çalışmada örnek alan seçimini etkileyen bir diğer faktör ise dron görüntüsü alma işlemleridir. Uydu görüntülerine ait çözünürlük değerleri ve dron görüntülerine ait çözünürlüklere bağlı olarak örnek alanlar arası mesafe en az 100 m olacak şekilde belirlenmiştir.

Çizelge 2.4 Örnek alan seçim kriterleri ve ölçütleri

Gelişim Çağı	Çap Aralığı (cm)	Bonitet	Bonitet endeksi (m)	Kapalılık	Yüzey örtüş oranı (%)
a	0,0-7,9	I	30-34	1	11-40
b	8,0-19,9	II	25-29	2	41-70
c	20,0-35,9	III	20-24	3	71-100
d	36,0-51,9	IV	15-19		
		V	10-14		

2.2.2. Yaprak alan indeksi (YAİ)

Herbir örnek alanda örnek alanı temsil edecek şekilde 5 farklı noktadan balıkgözü lens kullanılarak örnek alanların tepe çatılarına doğru fotoğraflar alınmıştır. Balıkgözü lens sayesinde 180^{o}'lik alanı kapsayan yarı-küresel fotoğraflar çekilmiş ve yaprak alan indeksleri (YAİ) Hemiwiev yazılımı ile hesaplanmıştır.

2.3. Uzaktan Algılama Verileri

Bu çalışmada meşcere parametreleri (meşcere orta çapı, meşecere üst boyu, meşecere ağaç sayısı, meşecere göğüs yüzeyi ve meşcere hacmi), YAİ, topraküstü biyokütle (TÜB) ve topraküstü karbon (TÜK) miktarlarının tahmini için orman envanterinin yapıldığı tarihlerde veya yakın tarihte olacak şekilde uzaktan algılama verileri; Landsat 8 Operational Land Imager (OLI), Sentinel-2 (USGS 2000), Sentinel-1 (ESA 2022) ve dron görüntüleri kullanılmıştır.

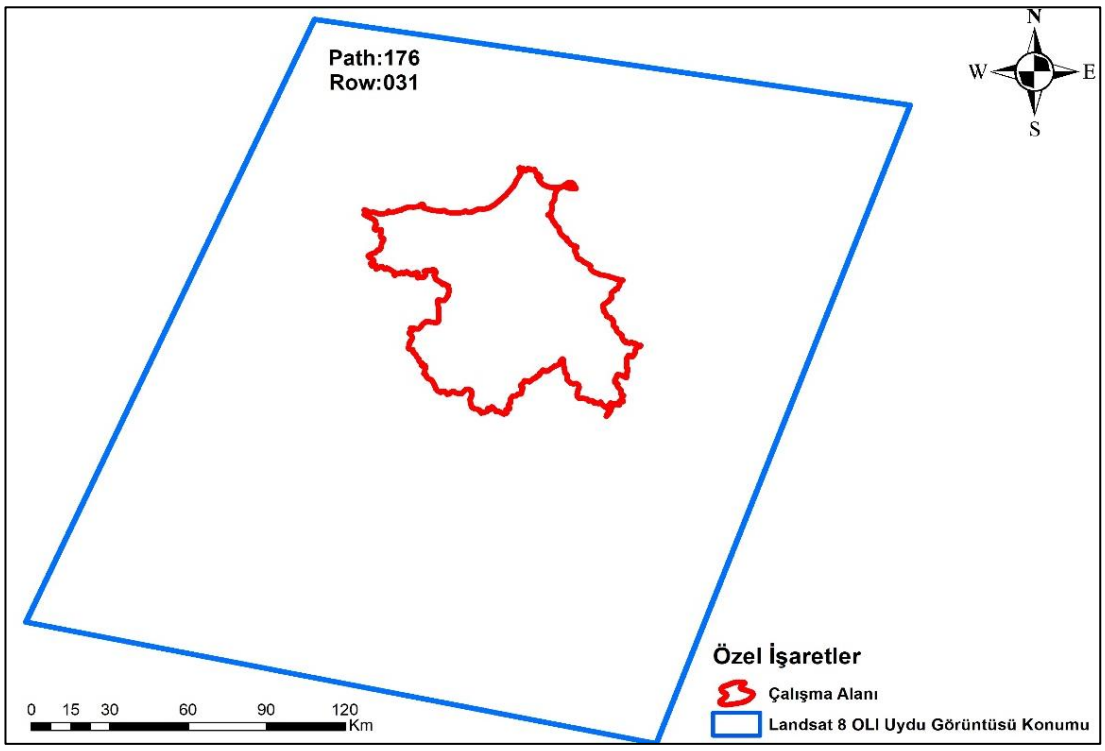
2.3.1. Landsat 8 OLI uydu görüntüsü

Landsat 8 OLI uydusu 2013 yılından beri veri sağlamaktadır. Pankromatik, multispektral ve termal bantlara ait konumsal çözünürlükleri sırasıyla 15, 30 ve 100 metredir. Toplamda 11 adet bandı bulunmaktadır. Bu bantların konumsal çözünürlükleri sırasıyla 15, 30 ve 100 metredir. Termal bantlar 12 bit ve diğer bantlar 8 bit radyometrik çözünürlüğe sahiptir (USGS 2013). Bu çalışmada kullanılan Landsat 8 OLI uydusuna ait bantlara ilişkin detaylı bilgiler Çizelge 2.5'te verilmiştir.

Çizelge 2.5 Landsat 8 OLI uydu görüntüsüne ait teknik özellikler

Bant	Elektromanyetik alan	Dalga boyu (nm)	Konumsal çözünürlük (m)
L2	Mavi (B)	450 – 515	30
L3	Yeşil (G)	525 – 600	30
L4	Kırmızı (R)	630 – 680	30
L5	Yakın kızıl ötesi (NIR)	845 – 885	30
L6	Kısa dalga kızıl ötesi (SWIR 1)	1560 – 1660	30
L7	Kısa dalga kızıl ötesi (SWIR 2)	2100 – 2300	30
L8	Siyah-Beyaz (Pankromatik)	500 – 680	15

Çalışma alanına ait ve orman envanterinin yapıldığı aylar olan Eylül 2022 tarihli 1 adet Landsat 8 OLI uydu görüntüsü kullanılmıştır. Görüntüye ait konumsal durum Şekil 2.2'de gösterilmiştir.



Şekil 2.2 Landsat 8 OLI uydu görüntü konumu

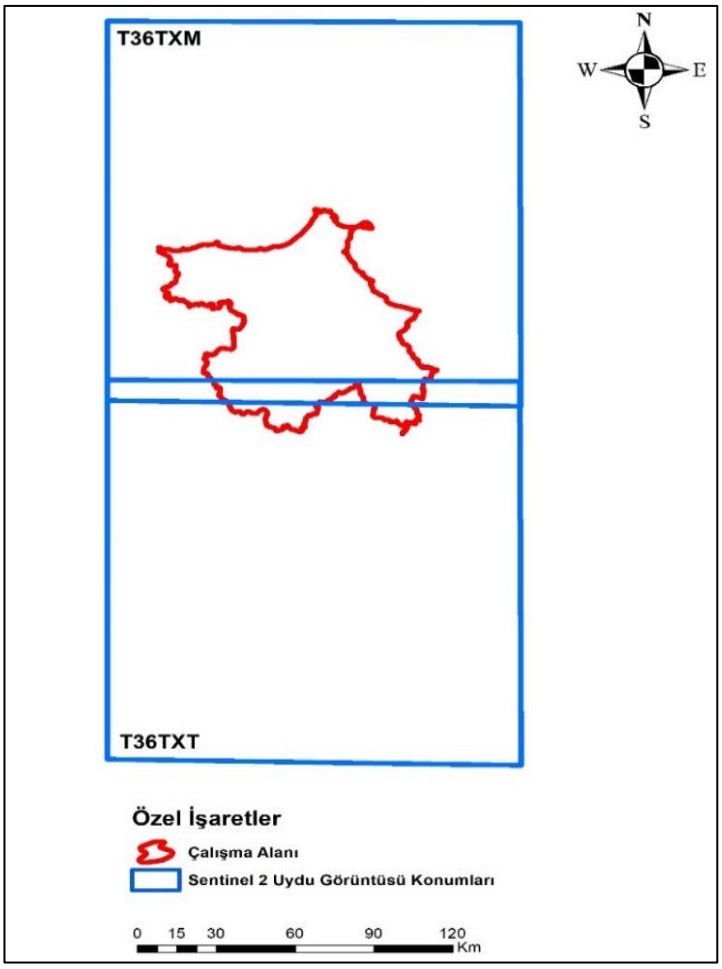
2.3.2. Sentinel-2 uydu görüntüsü

Sentinel-2 uydu görüntüsü toplamda 13 adet banta sahiptir. Bu bantların 4 adedi 10 m, 6 adedi 20 m ve 3 adedi ise 60 m konumsal çözünürlüğe sahiptir. Radyometrik çözünürlüğü 12 bit, şerit genişliği 290 km ve zamansal çözünürlüğü 10 gündür (ESA 2022). Sentinel-2 uydu bantlarına ilişkin detaylı bilgiler Çizelge 2.6'da verilmiştir.

Çizelge 2.6 Sentinel-2 uydu görüntüsüne ait teknik özellikler

Bant	Elektromanyetik alan	Dalga boyu (nm)	Konumsal çözünürlük (m)
S2	Mavi (B)	458 – 523	10
S3	Yeşil (G)	543 – 578	10
S4	Kırmızı (R)	650 – 680	10
S5	Kırmızı kenar 1 (Red Edge 1)	698 – 713	20
S6	Kırmızı kenar 2 (Red Edge 2)	733 – 748	20
S7	Yakın kızıl ötesi 1 (NIRNarrow 1)	773 – 793	20
S8	Yakın kızıl ötesi (NIR)	785 – 900	10
S8A	Yakın kızıl ötesi 2 (NIRNarrow 2)	855 – 875	20
S11	Kısa dalga kızıl ötesi (SWIR 1)	1565 – 1655	20
S12	Kısa dalga kızıl ötesi (SWIR 2)	2100 – 2280	20

Sentinel-2 uydu görüntü paftası Landsat 8 OLI görüntü paftasından daha küçük alanı kapsadığından dolayı Landsat 8 OLI uydu görüntüsünde bir pafta ile çalışma alanına ait veriler elde edilebilmiş iken Sentinel-2'de yine Eylül 2022 tarihli 2 pafta görüntüsü kullanılmıştır. Sentinel-2 uydu görüntülerinin konumları Şekil 2.3'te gösterilmiştir.



Şekil 2.3 Sentinel-2 uydu görüntülerinin konumları

2.3.3. Sentinel-1 uydu görüntüsü

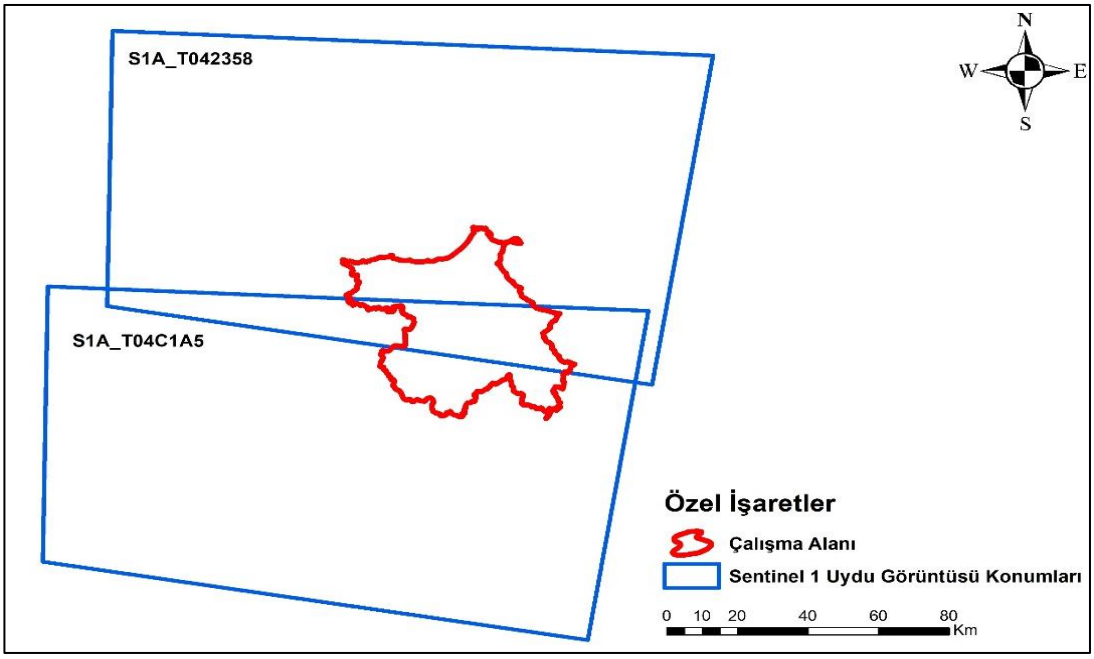
İlk uydu Sentinel-1A 3 Nisan 2014 tarihinde, Sentinel-1B uydusu ise 25 Nisan 2016 tarihinde yörüngelerine yerleştirilmiştir. Sentinel-1'de C-bandı SAR sensörü taşımaktadır. C-bandı Copernicus hizmetleri kapsamında gerekli olan yüksek çözünürlüklü verileri üretmek için tüm hava koşullarında gece gündüz görüntüleme sağlamak üzere tasarlanmıştır. Sentinel-1'in görevi, farklı çözünürlük (5 m'ye kadar) ve kapsama (400 km'ye kadar) ile dört özel görüntüleme modunda çalışan C-bant görüntülemeyi içerir. Çift polarizasyon kabiliyeti, çok kısa tekrar ziyaret süresi ve hızlı veri teslimatı sağlar. Her gözlem için, uzay aracının konumu ve tutumunun hassas ölçümleri mevcuttur (ESA 2022). Sentetik Açıklıklı Radar (SAR), aktif algılayıcı sistemlerdendir. Enerjisini güneşten bağımsız kendisi üretebilmektedir. SAR bulut örtüsü

veya aydınlatma eksikliğinden etkilenmeyen dalga boylarında çalışma avantajına sahiptir. Sentinel-1, 12 günlük bir tekrar döngüsü ve tek bir uydu için döngü başına 175 yörünge ile kutuplara yakın, güneşle eşzamanlı bir yörüngededir. Hem Sentinel-1A hem de Sentinel-1B, 180° yörünge faz farkı ile aynı yörünge düzlemini paylaşır. Sentinel-1'e ait bazı özellikler Çizelge 2.7'de belirtilmiştir.

Çizelge 2.7 Sentinel-1 uydu görüntüsüne ait teknik özellikler

Sentinel-1	**Özellikleri**
Fırlatılma Tarihleri	S1-A, 3 Nisan 2014 - S1-B, 25 Nisan 2016
Fırlatma Yeri ve Aracı	French Guina, Soyuz roketi
Veri Kapasitesi	1410 gb
Uydu Ağırlığı	2300 kg
Yörünge Yüksekliği	693 km
Yörünge Tipi	Güneş eşzamanlı, kutuplara yakın, dairesel yörünge
Sensör	C-SAR (C-band Sentetik Açıklıklı Radar)
Zamansal Çözünürlük	12 gün

Çalışma alanınan ait Sentinel-1 görüntü verilerini sağlayabilmek için yine Eylül 2021 tarihli 2 pafta görüntüsü kullanılmıştır. Sentinel-1 uydu görüntülerinin konumları Şekil 2.4'te gösterilmiştir.



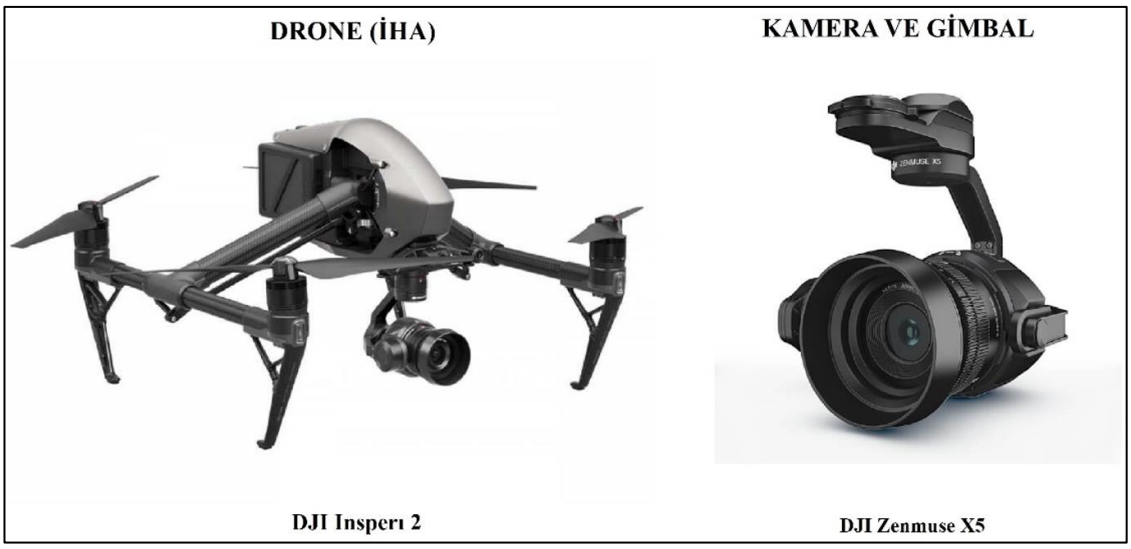
Şekil 2.4 Sentinel-1 uydu görüntülerinin konumları

2.3.4. Dron görüntüleri

Bu çalışmada daha yenilikçi ve güncel, görüntü parametrelerinin çalışma amacına göre ayarlanabildiği yüksek çözününürlükte dron görüntüleri çekilmiştir. Çalışmada DJI Inspire-2 dron kullanılmıştır (Şekil 2.5). Dron ve kameranın özellikleri Çizelge 2.8'de belirtilmiştir.

Çizelge 2.8 DJI Inspere 2 dron teknik özellikler

Ürün adı	**DJI Inspire 2**
Malzeme	Plastik
Ağırlık	7.58 lbs (3440g)
Maksimum kalkış ağırlığı	8.82 lbs (4000g)
Maksimum uçuş süresi	Yaklaşık 27 dk (zenzenx4s ile)
Çalışma sıcaklığı	-4 ° ila 104 ° F (-20 ° ila 40 ° C)
Pil kapasitesi	4280 mAh
Maksimum hız	58 mph veya 94 kph (spor modu)
Enerji	97.58 Wh
Voltaj	22.8 V
Pil tipi	LiPo 6S
Tipi	Quadcopter
Kontrol aralığı	7 km
Canlı görünüm	1080 p

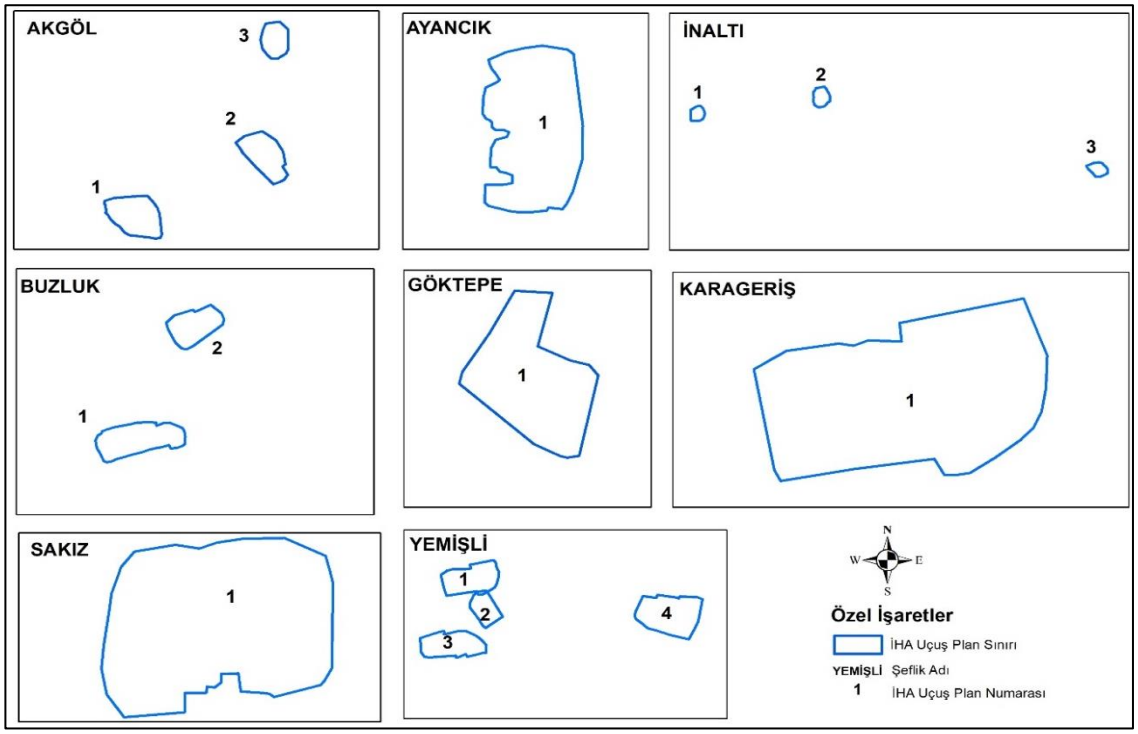


Şekil 2.5 Dron, kamera ve gimbal görüntüsü

DJI Zenmuse X-5S kamera ve gimbal genel özellikler (DJI 2022).

- Micro Four Thirds sensörü
- 9-45 mm (18-90 mm 35 mm eşdeğeri) odak uzunluklarına sahip sekiz adede kadar standart MFT lensi (zoom lensler dahil) destekler
- 30 fps'de 5.2K ve 60 fps'de 4K video kaydı
- 20,8 MP hareketsiz görüntü yakalama
- 12.8 durak dinamik aralık
- 12 bit ham fotoğraflar
- 20 fps sürekli seri çekim

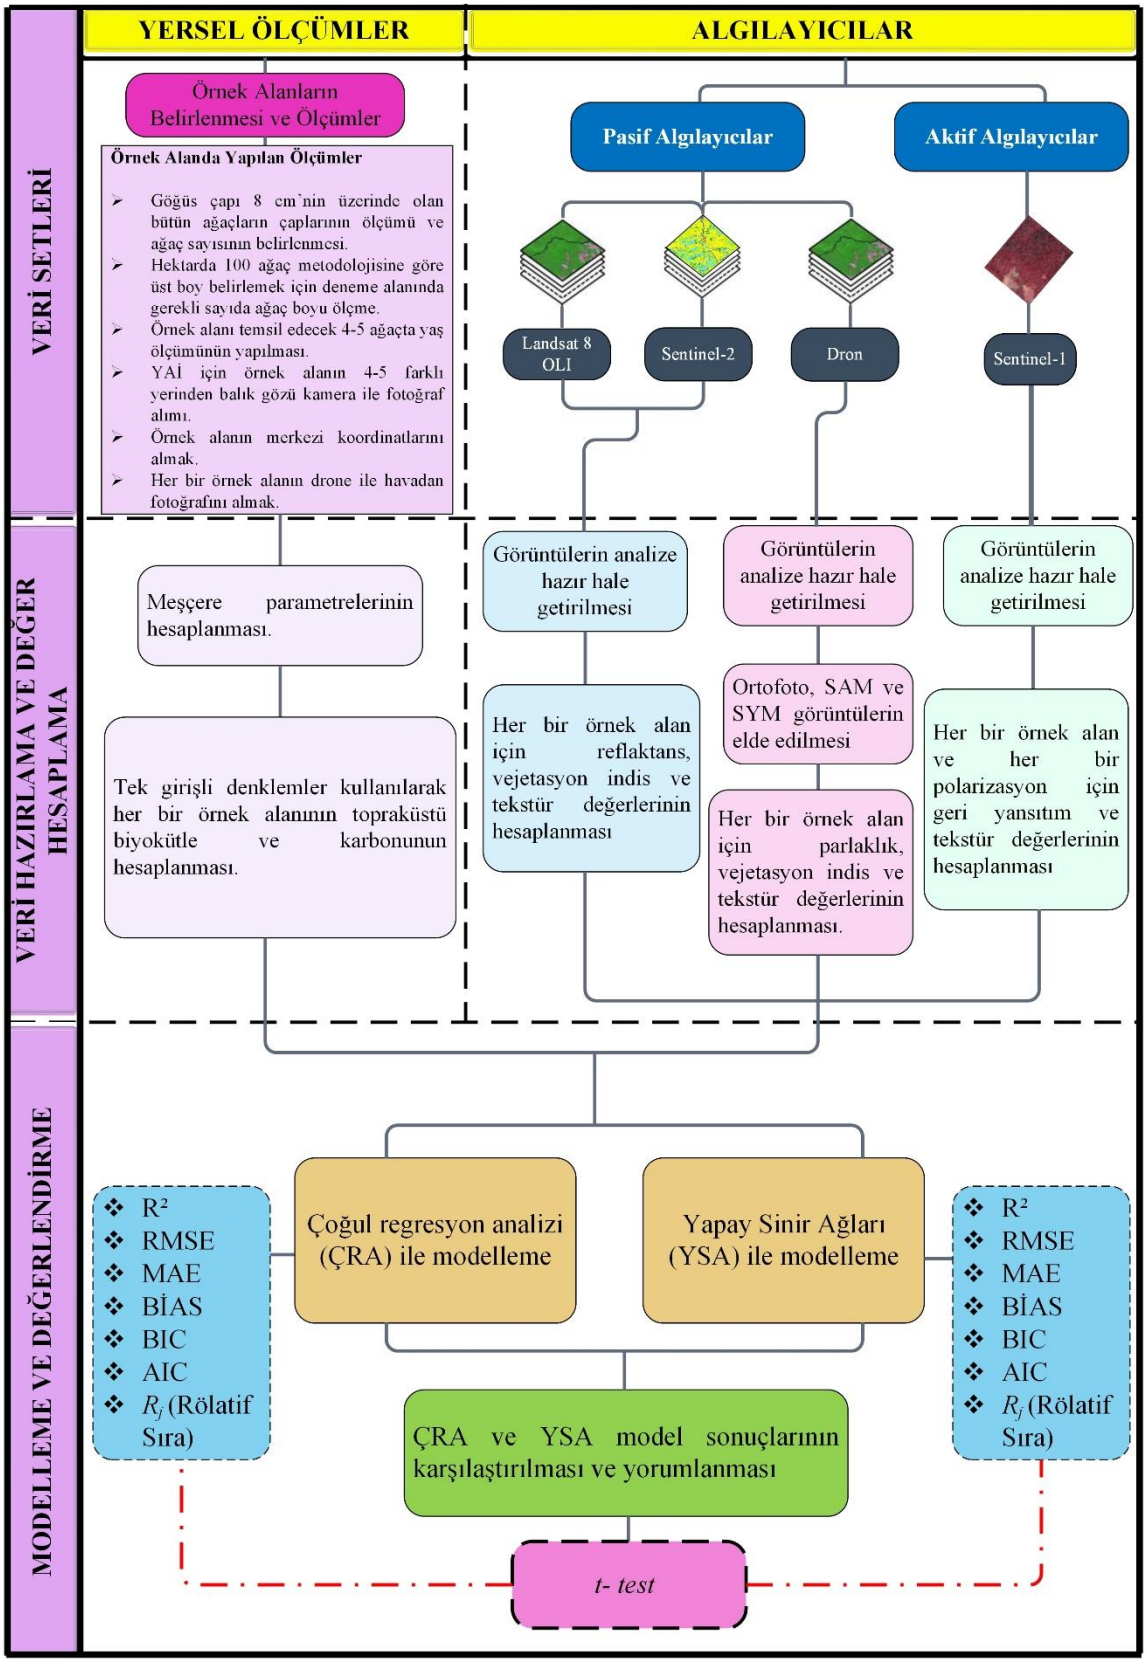
Çalışma alanına ait dron görüntüleri alımı için mevcut örnek alanlar dron uçuş kabiliyetleri gözönünde bulundurularak parsellere ayrılmış ve çekimler gerçekleştirilmiştir. Parsellere ait orman işletme şefliği (OİŞ) ve parsel sayısı Şekil 2.6'da gösterilmiştir.



Şekil 2.6 Dron görüntülerinin parsel konumları

3. YÖNTEM

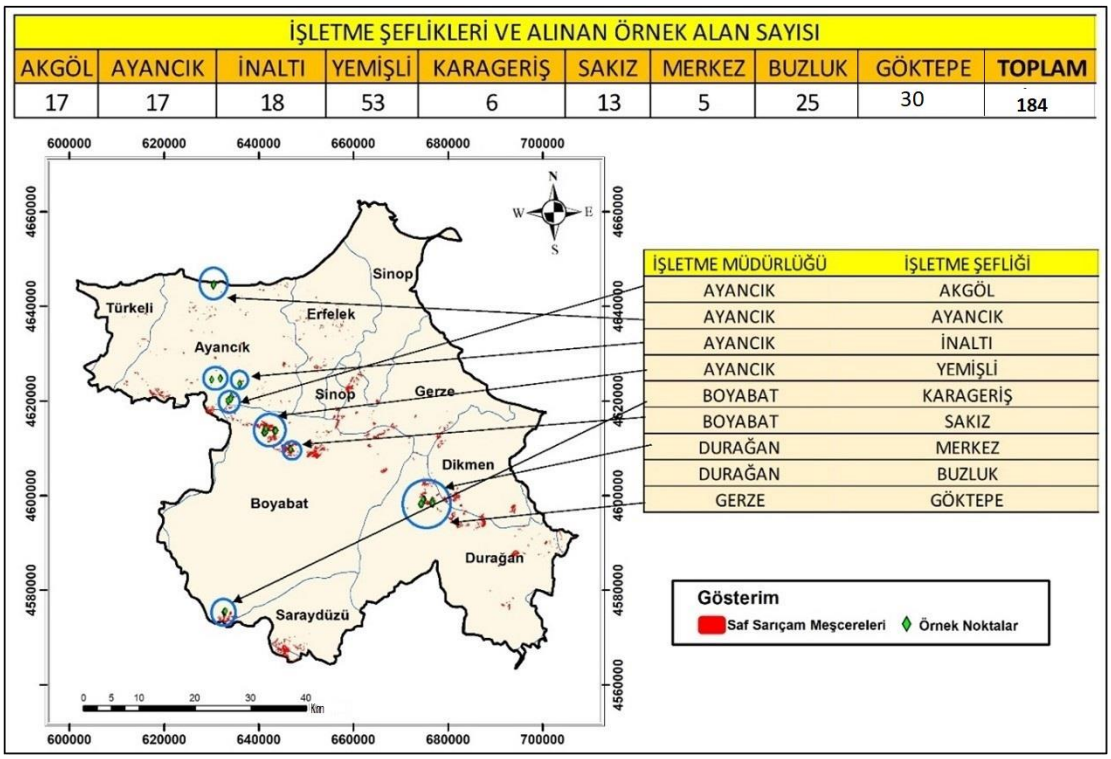
Bu çalışmanın gerçekleştirilmesinde yersel ve uzaktan algılama veri setleri kullanılmıştır. Yersel ölçümler yardımıyla elde edilen veri setleri olan meşcere parametreleri (meşcere orta çapı, meşcere üst boyu, meşecere ağaç sayısı, meşcere göğüs yüzeyi ve meşcere hacmi), yaprak alan indeksi (YAİ), topraküstü biyokütle (TÜB) ve topraküstü karbondan (TÜK) oluşmaktadır. Uzaktan algılama verileri ise pasif algılayıcılardan Landsat 8 Operational Land Imager (OLI), Sentinel-2 ve dron, aktif algılayıcı olarak da Sentinel-1 uydu görüntülerinden elde edilen veriler kullanılmıştır. Pasif algılayıcılardan elde edilen reflektans, vejetasyon indisi, tekstür ve parlaklık değerleri ile aktif algılayıcılardan elde edilen her bir polarizasyon için geri yansıtım ve dijital bant değerleri hesaplanarak veri setleri hazırlanmıştır. Çalışmaya ait genel metodoloji Şekil 3.1'de gösterilmiştir.



Şekil 3.1 Çalışma iş akış şeması

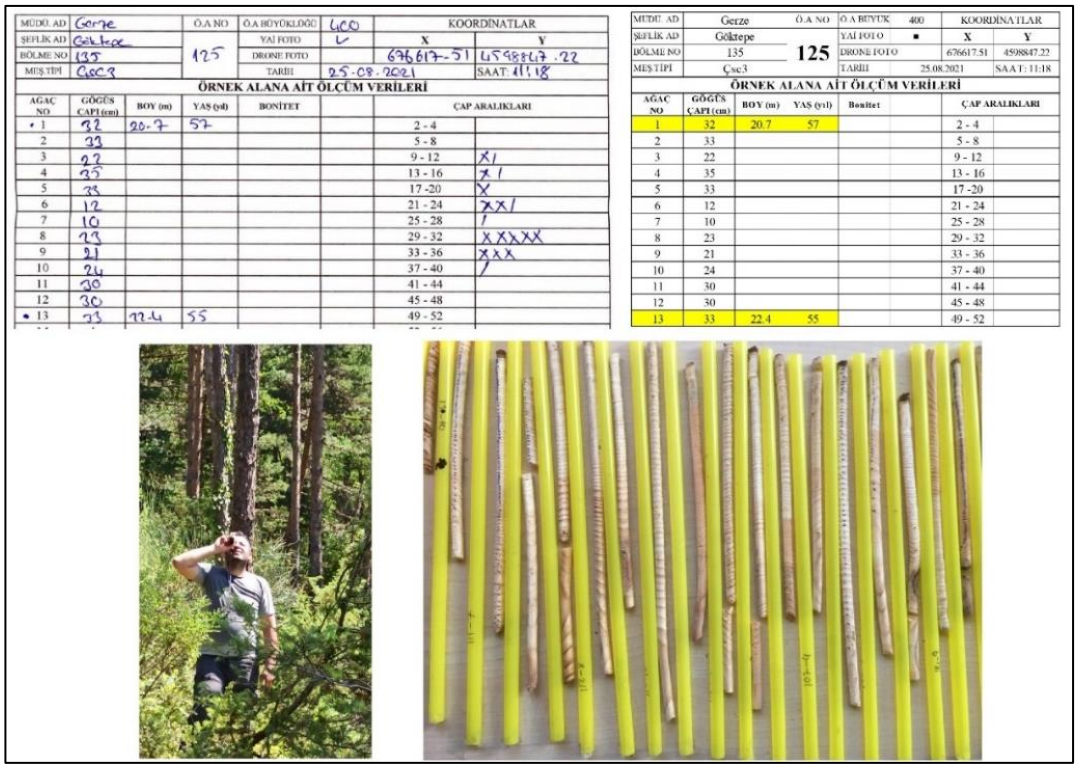
3.1. Arazi Çalışması

Bu çalışma Sinop Orman Bölge Müdürlüğü'nde (OBM) saf sarıçam meşcerelerinin yayılış gösterdiği Orman İşletme Müdürlüklerinde (OİM) gerçekleştirilmiştir. Örnek alan sayılarının OİM'lere dağılımı, ilgili OİM'de ve Orman İşletme Şefliğinde (OİŞ) yayılış gösteren saf sarıçam meşcereleri alanlarına oranlanarak düzenlenmiştir. Bu bağlamda çalışma alanına konu olan örnek noktaların OİM ve OİŞ'lere sayısal ve konumsal dağılımı Şekil 3.2'de gösterilmiştir. Yersel ölçümler toplamda 184 örnek alanda gerçekleştirilmiştir.



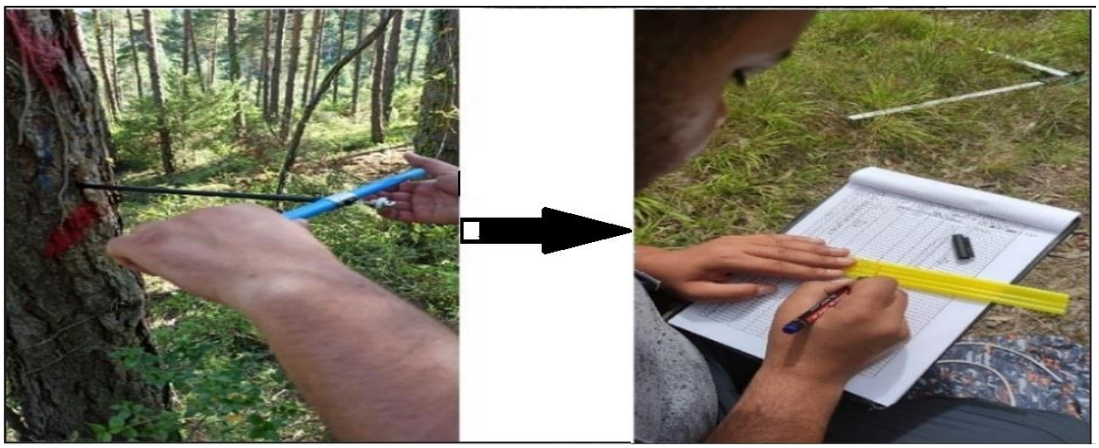
Şekil 3.2 Envanter çalışmasında alınan örnek alanların sayısal ve konumsal dağılımı

Arazi çalışmalarında meşcere kapalılığı dikkate alınarak 3 kapalı meşcerelerde 400 m^2, 2 kapalı meşcerelerde 600 m^2 ve 1 kapalı meşcerelerde ise 800 m^2 büyüklüğünde daire şeklinde toplam 184 adet örnek alan alınmıştır. Genç meşcerelerde 8 cm'den küçük, diğer meşcerelerde 8 cm ve daha kalın çaplı ağaçlarda göğüs yüksekliği hizasından çap değerleri çift taraflı ölçülerek envanter karnesine kaydedilmiş ve dijital ortama aktarılmıştır. Çalışmda kullanılan örnek envanter karnesi Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Çalışmaya ait envanter karnesi, boy ölçümü ve artım kalemi

Orta yaşı belirlemek üzere orta çapa yakın 4-5 ağaçta yaş ölçümü, boniteti belirlemek için hektarda 100 ağaç yöntemine göre belirlenen sayıda galip ve ortak galip ağaçlarda boy ölçümü yapılmıştır. Daha sonra yaş için artım burgusu ile alınan örnekler yaş sayımı ve başka ölçümler için plastik pipetler içerisine örnek alan numarası ve örnek ağaç numarası yazılarak muhafaza edilmiştir (Şekil 3.4).



Şekil 3.4 Yaş ölçümü

Yapılan envanter çalışması sonucunda her bir örnek alana ilişkin meşcere orta çapı (d_g), meşecere üst boyu ($h_{üst}$), meşcere ağaç sayısı (N), meşcere göğüs yüzeyi (G) ve meşcere hacmi (V) değerleri hesaplanmıştır (Çizelge 3.1). Meşcere hacminin hesaplanmasında Batı Karadeniz Bölgesi'nde yayılış gösteren saf ve doğal sarıçam meşcereleri için geliştirilen ve belirtme katsayısı R^2=0.993 olan tek girişli hacim denklemi (Eşitlik 1) kullanılmıştır (Yavuz vd. 2010).

$$lnV = -8.209 + 2.324\ x\ d - \frac{3.664}{d} \quad (1)$$

*V: Hacim, ln: Logaritma, d: Göğüs çapı ($d_{1.30}$)

Çizelge 3.1 Meşcere parametreleri ve hesaplanması

Meşcere parametresi	**Formül**	**Açıklama**
d_g (cm)	$\bar{d}_g = \sqrt{\frac{\bar{d}_1^2 + \bar{d}_2^2 + \cdots + \bar{d}_n^2}{n}}$	d_g= meşcere orta çapı $d_1 \ldots d_n$= ölçülen ağaç çapı n= örnek alan ağaç sayısı
$h_{üst}$ (m)	$h_{üst} = \frac{h_1 + h_2 + \cdots h_n}{n}$	$h_{üst}$= meşcere üst boyu $h_1 \ldots h_n$= ölçülen ağaç boyu n= ölçüm yapılan ağaç sayısı
N (adet/ha)	$N = \frac{10000}{ÖAB} \times n$	N= meşcere ağaç sayısı (ha) ÖAB= örnek alan büyüklüğü n= örnek alanın ağaç sayısı
G (m^2/ha)	$G = \frac{10000}{ÖAB} \times g$	G= meşcere göğüs yüzeyi (ha) ÖAB= örnek alan büyüklüğü g= örnek alanın göğüs yüzeyi
V (m^3/ha)	$V = \frac{10000}{ÖAB} \times \sum_{i=1}^{n} v_i$	V= meşcere hacmi (ha) ÖAB= örnek alan büyüklüğü v= tek ağacın hacmi

Çalışmada araştırılan TÜB ve TÜK miktarlarının belirlenmesinde de yine Yavuz vd. (2010) saf ve doğal sarıçam meşcereleri için geliştirmiş oldukları allometrik biyokütle denklemleri kullanılmıştır (Eşitlik 2 ve 3).

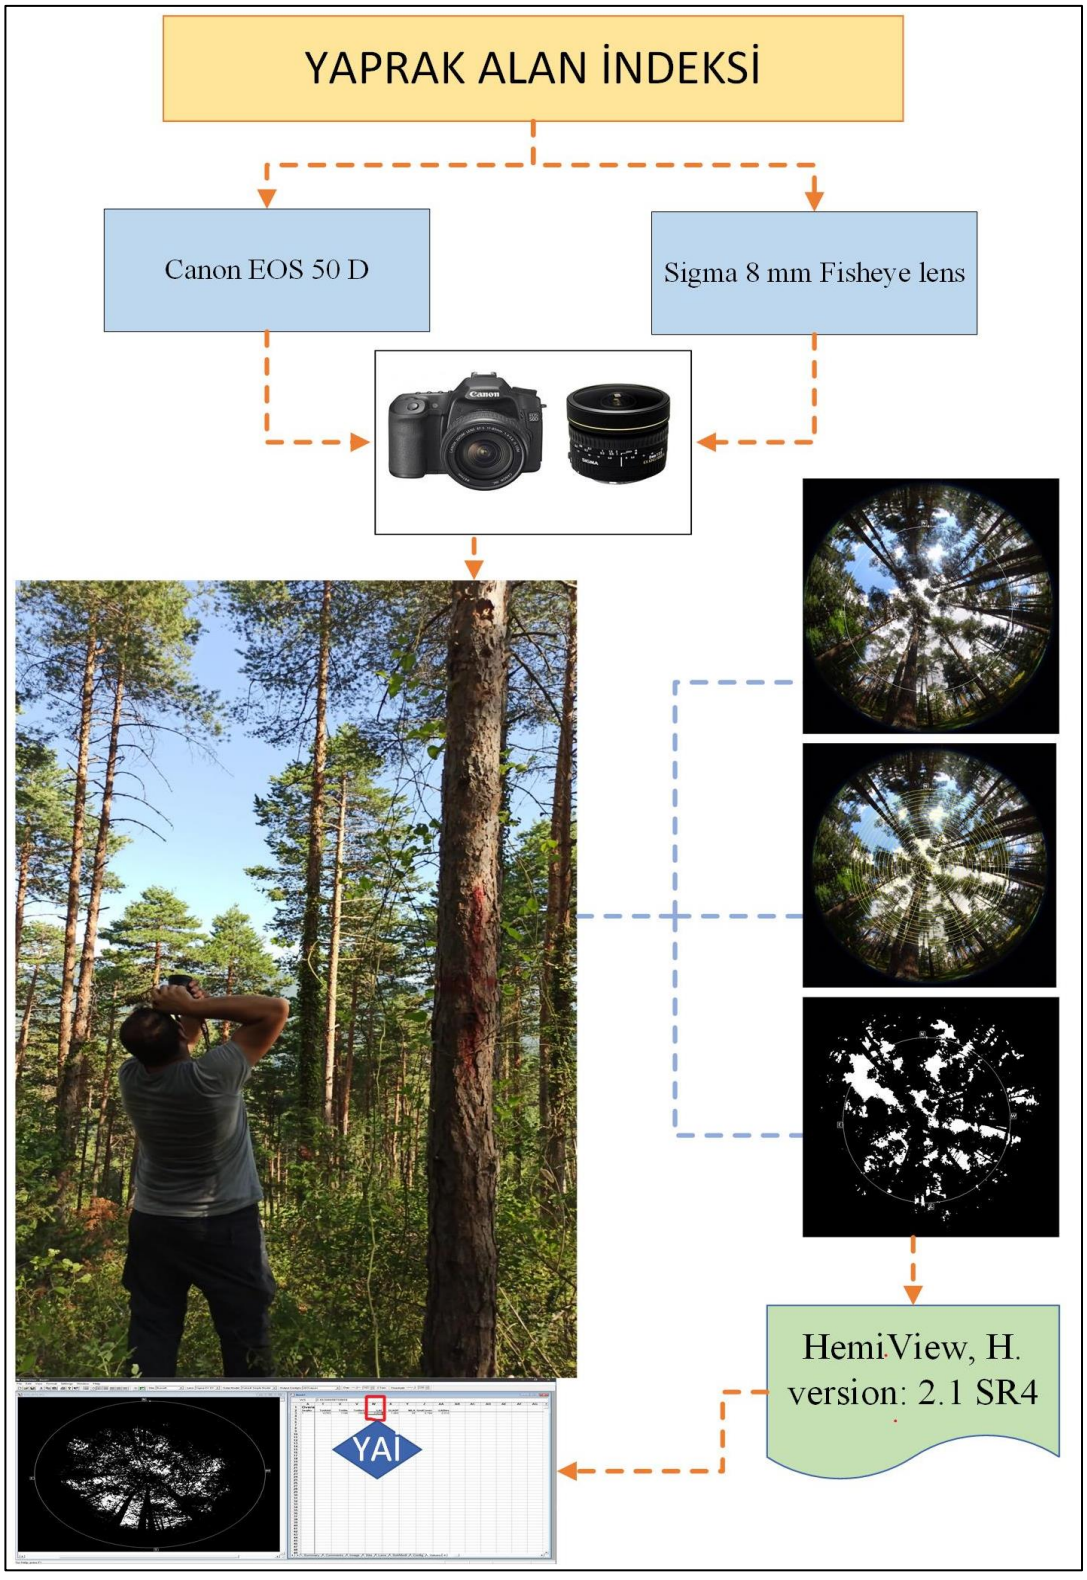
$$TÜB = 6.89952 - 2.423793\ x\ d + 0.373438\ x\ d^2 \quad (2)$$

$$T\ddot{U}K = -28.360 + 0.413\ x\ d \quad (3)$$

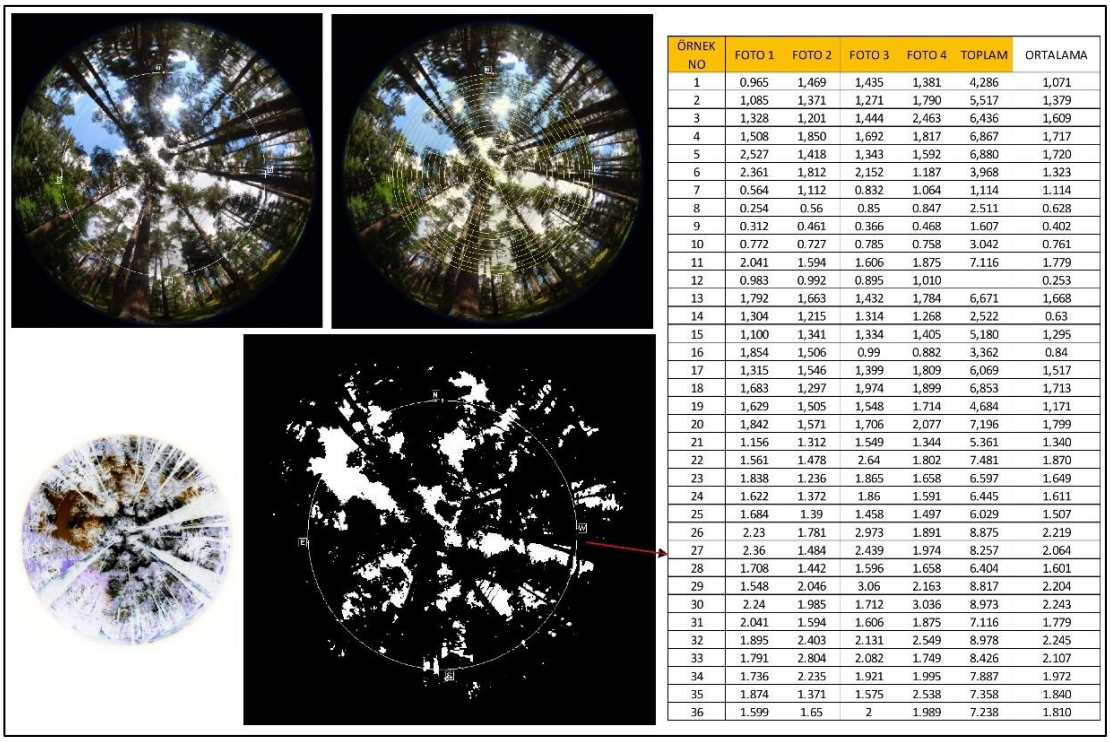
*TÜB: Toprak üstü biyokütle, TÜK: Toprak üstü karbon, d: Göğüs çapı ($d_{1.30}$)

3.2. Yaprak Alan İndeksi Değerlerinin Elde Edilmesi

Her bir örnek alanda yaprak alan indeksi (YAİ) değerini belirlemek için balıkgözü (Sigma 8 mm Fisheye lens) takılı fotoğraf makinesi (Canon EOS 50 D) kullanılmıştır. Balıkgözü sayesinde 180^{o}'lik alanı kapsayan yarı küresel fotoğraflar çekilmiştir. Bu fotoğraflar örnek alan merkezinden ve merkezden örnek alan dışına doğru koordinat düzlemde 4 bölgeden olmak üzere 5 farklı noktadan, yaklaşık 1,5 m yükseklikten ve meşcere tepe çatısına doğru çekilmiştir. Bununla birlikte doğrudan güneş ışınlarının geldiği vakitlerde fotoğraf çekilmemesine dikkat edilmiştir. Ardından dijital ortama aktarılan fotoğraflar HemiView, H. version: 2.1 SR4 yazılımı kullanılarak analiz edilmiştir. Analiz sonucu örnek alana ilişkin alınmış her bir küresel fotoğrafın YAİ değerlerinin aritmetik ortalaması alınarak, her bir örnek alana ilişkin YAİ değerleri hesaplanmıştır. YAİ genel akış diyagramı Şekil 3.5 ve Şekil 3.6'da gösterilmiştir.



Şekil 3.5 YAİ hesaplamasının akış diyagramı



ÖRNEK NO	FOTO 1	FOTO 2	FOTO 3	FOTO 4	TOPLAM	ORTALAMA
1	0.965	1,469	1,435	1,381	4,286	1,071
2	1,085	1,371	1,271	1,790	5,517	1,379
3	1,328	1,201	1,444	2,463	6,436	1,609
4	1,508	1,850	1,692	1,817	6,867	1,717
5	2,527	1,418	1,343	1,592	6,880	1,720
6	2.361	1,812	2,152	1.187	3,968	1.323
7	0.564	1,112	0.832	1.064	1,114	1.114
8	0.254	0.56	0.85	0.847	2.511	0.628
9	0.312	0.461	0.366	0.468	1.607	0.402
10	0.772	0.727	0.785	0.758	3.042	0.761
11	2.041	1.594	1.606	1.875	7.116	1.779
12	0.983	0.992	0.895	1,010		0.253
13	1,792	1,663	1,432	1,784	6,671	1,668
14	1,304	1,215	1.314	1.268	2,522	0.63
15	1,100	1,341	1,334	1,405	5,180	1,295
16	1,854	1,506	0.99	0.882	3,362	0.84
17	1,315	1,546	1,399	1,809	6,069	1,517
18	1,683	1,297	1,974	1,899	6,853	1,713
19	1,629	1,505	1,548	1.714	4,684	1,171
20	1,842	1,571	1,706	2,077	7,196	1,799
21	1.156	1.312	1.549	1.344	5.361	1.340
22	1.561	1.478	2.64	1.802	7.481	1.870
23	1.838	1.236	1.865	1.658	6.597	1.649
24	1.622	1.372	1.86	1.591	6.445	1.611
25	1.684	1.39	1.458	1.497	6.029	1.507
26	2.23	1.781	2.973	1.891	8.875	2.219
27	2.36	1.484	2.439	1.974	8.257	2.064
28	1.708	1.442	1.596	1.658	6.404	1.601
29	1.548	2.046	3.06	2.163	8.817	2.204
30	2.24	1.985	1.712	3.036	8.973	2.243
31	2.041	1.594	1.606	1.875	7.116	1.779
32	1.895	2.403	2.131	2.549	8.978	2.245
33	1.791	2.804	2.082	1.749	8.426	2.107
34	1.736	2.235	1.921	1.995	7.887	1.972
35	1.874	1.371	1.575	2.538	7.358	1.840
36	1.599	1.65	2	1.989	7.238	1.810

Şekil 3.6 YAİ değerlerinin hesaplanması

3.3. Uzaktan Algılama Verilerinin Elde Edilmesi

3.3.1. Reflektans değerleri ve görüntü kalibrasyonu

Örnek alanlara ilişkin reflektans verilerinin elde edilmesi iki aşamada gerçekleştirilmiştir. Birinci aşama uydu görüntülerinin (Landsat 8 OLI, Sentinel-2 ve Sentinel-1) kalibre edilmesi, ikinci aşama ise piksellerdeki reflektans değerlerinin örnek alan büyüklüklerine göre hesaplanmasıdır. İlk olarak Landsat 8 OLI ve Sentinel-2 uydu görüntüleri QGIS Desktop 3.8.1 programı kullanılarak kalibre edilmiştir. Böylece her iki uydu görüntüsü için bütün bantlara ilişkin reflektans değerleri elde edilmiştir. İkinci aşama ise bu verilerin örnek alanlara uyumlu bir şekilde elde edilmesini kapsamaktadır. Bunun için ArcGIS Desktop 10.7 programı kullanılarak her bir bant "vektör" katmanına dönüştürülmüş ve üzerine her bir örnek alan için örnek alan büyüklüklerine göre (1 kapalı örnek alanlar için 15,96 m, 2 kapalı örnek alanlar için 13,82 m ve 3 kapalı örnek alanlar için 11,28 m yarıçapında) "buffer zon" atılmıştır. Ardından üretilen "vektör" katmanı "buffer zon" ile "intersect" komutu kullanılarak çakıştırılmış ve örnek alan sınırına uygun "vektör" veri

elde edilmiştir. Vektör dönüşümü sayesinde örnek alan sınırına göre birebir çıkarım yapılmış ve sınıra denk gelen bütün piksellerden veri elde edilmiştir. Ardından tekrar "raster" veriye dönüştürülen katmana "zonal statistics" komutu uygulanarak her bir örnek alan için ortalama reflektans değerleri elde edilmiştir.

3.3.2. Vejetasyon indis değerleri

Vejetasyon indislerinin hesaplanması için Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden her bir örnek alan için elde edilen reflektans değerleri ile dron görüntülerinden her bir örnek alan için elde edilen reflektans değerleri kullanılmıştır. Landsat 8 OLI uydu görüntüsünün bantları kullanılarak 12 adet, Sentinel-2 uydu görüntülerinin bantları kullanılarak 12 adet ve dron görüntülerinin bantları kullanılarak 15 adet olmak üzere toplamda 39 adet vejetasyon indisi hesaplanmıştır. Çalışmada kullanılan vejetasyon indisleri ve formülleri Çizelge 3.2, Çizelge 3.3 ve Çizelge 3.4'te verilmiştir.

Çizelge 3.2 Landsat 8 OLI uydu görüntüsü için hesaplanan vejetasyon indisleri

Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
NDVI (Normalized Difference Vegetation Index)	(B5-B4) / (B5+B4)	Rouse *et al.* (1974)	GNDVI (Green Normalized Difference Vegetation Index)	(B5 - B3) / (B5 + B3)	Gitelson *et al.* (1996)
MSI (Moisture Stress Index)	(B6 / B5)	Hunt and Rock (1989)	NDWI (Normalized Difference Water Index)	(B5 - B6) / (B5 + B6)	McFeeters (1996)
NBR (Normalized Burn Ratio)	(B5-B7) / (B5+B7)	Key and Benson (2006)	MSR (Modified Simple Ratio)	((B5 / B4) -1) / √ ((B5 / B4) +1)	Chen (1996)
EVI (Enhanced Vegetation Index)	2.5 x ((B5 – B4) / (B5 + 6 x B4 – 7.5 x B2 + 1))	Liu and Huete (1995)	NLI (Non-Linear index)	((B5) - B4) / ((B5) + B4)	Goel and Qin (1994)
SAVI (Soil Adjusted Vegetation Index)	((B5 – B4) / (B5 + B4 + 0.5)) x (1.5)	Huete (1988)	PSSR (Pigment Specific Simple Ratio)	(B5 / B4)	Blackburn (1998)
DVI (Difference Vegetation Index)	(B5 - B4)	Tucker (1980)	EVI2 (Enhanced Vegetation Index 2)	2.4 x (B5 - B4) / (B5 + B4 + 1.0)	Jiang *et al.* (2008)

Çizelge 3.3 Sentinel-2 uydu görüntüsü için hesaplanan vejetasyon indisleri

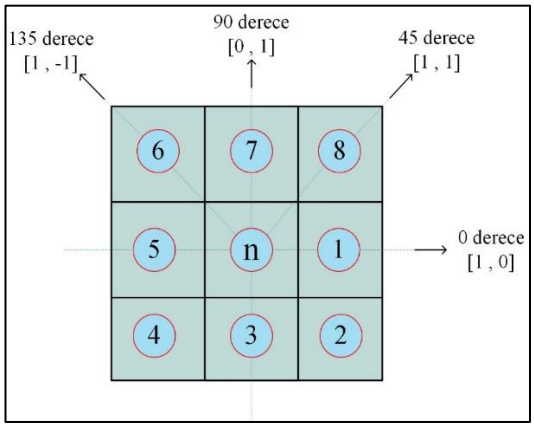
Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
NDVI (Normalized Difference Vegetation Index)	(B08 - B04) / (B08 + B04)	Rouse *et al.* (1974)	GNDVI (Green Normalized Difference Vegetation Index)	(B08 - B03) / (B08 + B03)	Gitelson *et al.* (1996)
MSI (Moisture Stress Index)	(B11 / B08)	Hunt and Rock (1989)	NDWI (Normalized Difference Water Index)	(B08-B11) / (B08+B11)	McFeeters (1996)
NBR (Normalized Burn Ratio)	(B08 - B12) / (B08 + B12)	Key and Benson (2006)	MSR (Modified Simple Ratio)	(B08 - B01) / (B04 - B01)	Chen (1996)
EVI (Enhanced Vegetation Index)	2.5 x (B08 - B04) / ((B08 + 6.0 x B04 - 7.5 x B02) + 1.0)	Liu and Huete (1995)	NLI (Nonlinear vegetation index)	$((B08^2) - B04)) / ((B08^2) + B04))$	Goel and Qin (1994)
SAVI (Soil Adjusted Vegetation Index)	(B08 - B04) / (B08 + B04 + L) x (1.0 + L); L = 0.428	Huete (1988)	PSSR (Pigment Specific Simple Ratio)	(B08 / B04)	Blackburn (1998)
DVI (Difference Vegetation Index)	(B08 / B04)	Tucker (1980)	EVI2 (Enhanced Vegetation Index 2)	2.4 x (B08 - B04) / (B08 + B04 + 1.0)	Jiang *et al.* (2008)

Çizelge 3.4 Dron görüntüsü için hesaplanan vejetasyon indisleri

Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
Red-Green-Blue Vegetation Index (RGBVI)	(G x G)- (R x B)/(G x G) +(R x B)	Bendig *et al.* (2015)	Green–red vegetation index (GRVI)	(G – R) / (G + R)	Tucker (1979)
Green Leaf Index (GLI)	(2 x G -R- B) / (2 x G + R+ B)	Louhaichi *et al.* (2001)	Modified green–red vegetation index (MGRVI)	$(G^2- R^2) / (G^2 + R^2)$	Bendig *et al.* (2015)
Visible Atmospherically Resistant Index (VARI)	(G-R) / (G + R-B)	Gitelson *et al.* (2002)	Simple blue–green ratio (BGI2)	B / G	Zarco-Tejada *et al.* (2005)
Normalized Green Red Difference Index (NGRDI)	(G-R) / (G+R)	Tucker (1979)	Vegetativen (VEG)	$G / (R^a \times B^{(1-a)})$; a=0.667	Hague *et al.* (2006)
Enhanced Red-Green-Blue Vegetation Index (ERGBVE)	π x $((G^2-(R \times B)) / (G^2 + (R \times B))$	Themistocleou (2019)	Excess green index (EXG)	2G – R- B	Woebbecke *et al.* (1995)
Simple red–green ratio (GR)	R / G	Gamon and Surfus. (1999)	Normalized green-blue difference index (NGBDI)	(G – B) / (G + B)	Du and Noguchi (2017)
RGB-based vegetation index 2 (RGBVI2)	(G – R) / B	García-Fernández *et al.* (2021)	RGB-based vegetation index 3 (RGBVI3)	(G + B) / R	García-Fernández *et al.* (2021)
Triangular Greenness Index (TGI)	G−0.39 x R−0.61 x B	Hunt *et al.* (2013)			

3.3.3. Tekstür değerleri

Tekstür analizi, görüntülerden bilgi çıkarmak için bazı matematiksel prosedürlere ve modellere dayanarak görüntü deseninin konumsal varyasyonunu karakterize etmektir. Bu özelliklerin belirlenmesinde Haralick *et al.* (1973) tarafından önerilen gri düzey eş oluşum matrisi (GLCM) kullanılmıştır. Kullanılan GLCM yönteminde her bir değer, belirli bir uzaklık ve yöndeki en yakın komşu yansıma değerinin olasılık değerlerini temsil eden simetrik bir matristir. Bir görüntü nesnesindeki gri seviyelerin konumsal düzenlemesini ortaya çıkarmaktadır. Tekstür analizi Landsat 8 OLI ve Sentinel-2 uydu görüntülerine ait her bir bant için ayrı ayrı ve 8 farklı doku özelliği için belirlenmiştir. Analiz sonucunda mean (M), variance (VAR), homogeneity (HOM), contrast (CONT), dissimilarity (DIS), entropy (ENT), second moment (SM) ve correlation (COR) tekstür verileri hesaplanmıştır (Çizelge 3.5). Ayrıca çalışmada 3x3, 5x5, 7x7, 9x9, 11x11, 13x13 ve 15x15 olmak üzere 7 farklı pencere boyutu kullanılmıştır. Her bir pencere boyutu ise kendi içinde 4 farklı açı (0°, 45°, 90°, 135°) için ayrı ayrı hesaplanmıştır. Bu hesaplama uzaklık (d) ve açısal (θ) ilişkinin bir fonksiyonudur (P (i, j I d, θ)). Gri seviyelerin i'den j'ye geçiş olasılığını temsil etmektedir. Uzaklık (d) 1 için, açı dereceleri ise θ = 0° [1,0], 45° [1,1], 90° [0,1] ve 135° [1,-1] için matrisler oluşturulmuştur (Şekil 3.7). Landsat 8 OLI ve Sentinel-2 uyduları için toplamda 17 bant kullanılmıştır. Böylece 17 bant, 8 tekstür, 7 pencere boyutu ve 4 farklı açı için toplam 3808 adet tekstür veri seti oluşturulmuştur. Tekstür verilerinin elde edilmesi ENVI 5.2 yazılımı kullanılmıştır.



Şekil 3.7 Seçilen referans piksel (n) için açıların gösterimi

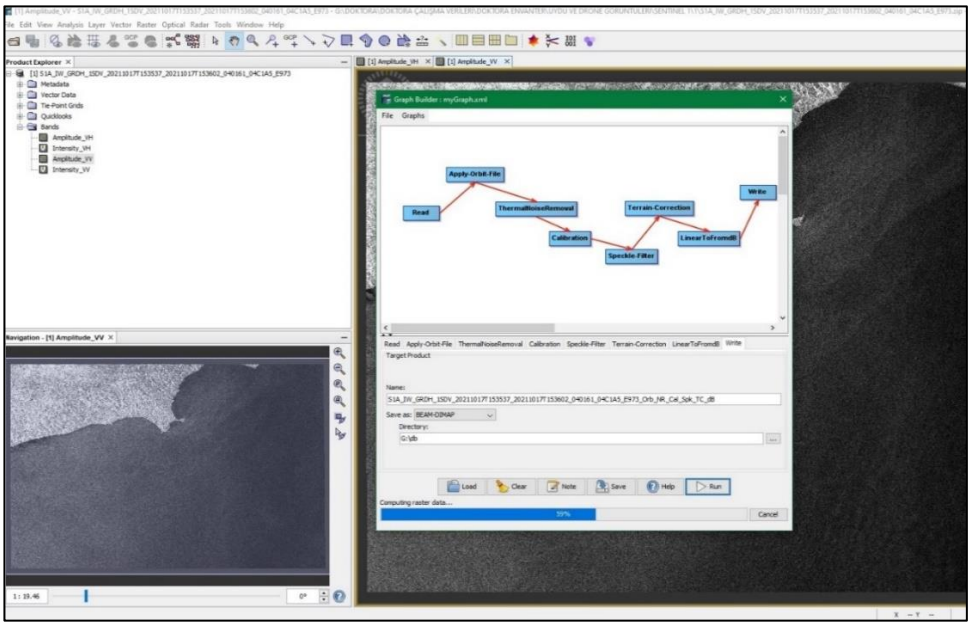
Çizelge 3.5 Elde edilen 8 farklı tekstür verisine ilişkin fonksiyonlar

Tekstür	**Fonksiyon**
Mean (M)	$\sum_{i,j=0}^{N-1} i\, P_{i,j}$
Variance (VAR)	$\sum_{i,j=0}^{N-1} \frac{(P_{i,j} - \mu)^2}{N-1}$
Homogeneity (HOM)	$\sum_{i,j=0}^{N-1} i \frac{P_{i,j}}{1+(i-j)^2}$
Contrast (CONT)	$\sum_{i,j=0}^{N-1} iP_{i,j}(i-j)^2$
Dissimilarity (DİS)	$\sum_{i,j=0}^{N-1} iP_{i,j}\lvert i-j\rvert$
Entropy (ENT)	$\sum_{i,j=0}^{N-1} iP_{i,j}(-\ln P_{i,j})$
Second moment (SM)	$\sum_{i,j=0}^{N-1} iP_{i,j} - \mu_1\mu_2$ $\mu_1 = \sum_{i=0}^{N-1} i \sum_{i=0}^{N-1} P_{i,j}$ $\mu_1 = \sum_{j=0}^{N-1} j \sum_{j=0}^{N-1} P_{i,j}$
Correlation (COR)	$\sum_{i,j=0}^{N-1} iP_{i,j}\left[\frac{(i-ME)(j-ME)}{\sqrt{VA_i\, VA_j}}\right]$

3.3.4. Geri yansıtım değerlerin hesaplanması

Diğer aşama ise Sentinel-1 uydu görüntüsünün kalibrasyon işlemleridir. Bu işlem ise SNAP yazılımı kullanılarak gerçekleştirilmiştir. Görüntüler yazılıma makro uygulaması ile kalibre edilmiştir (Şekil 3.8). Daha sonra VV ve VH bantlarına ait geri yansıtım değerleri ile dijital bant değerleri; ArcGIS Desktop 10.7 programı kullanılarak her bir bant "vektör" katmanına dönüştürülmüş ve üzerine her bir örnek alan için örnek alan büyüklüklerine göre (1 kapalı örnek alanlar için 15,96 m, 2 kapalı örnek alanlar için 13,82 m, 3 kapalı örnek alanlar için 11,28 m yarıçapında) "buffer zon" atılmıştır. Ardından

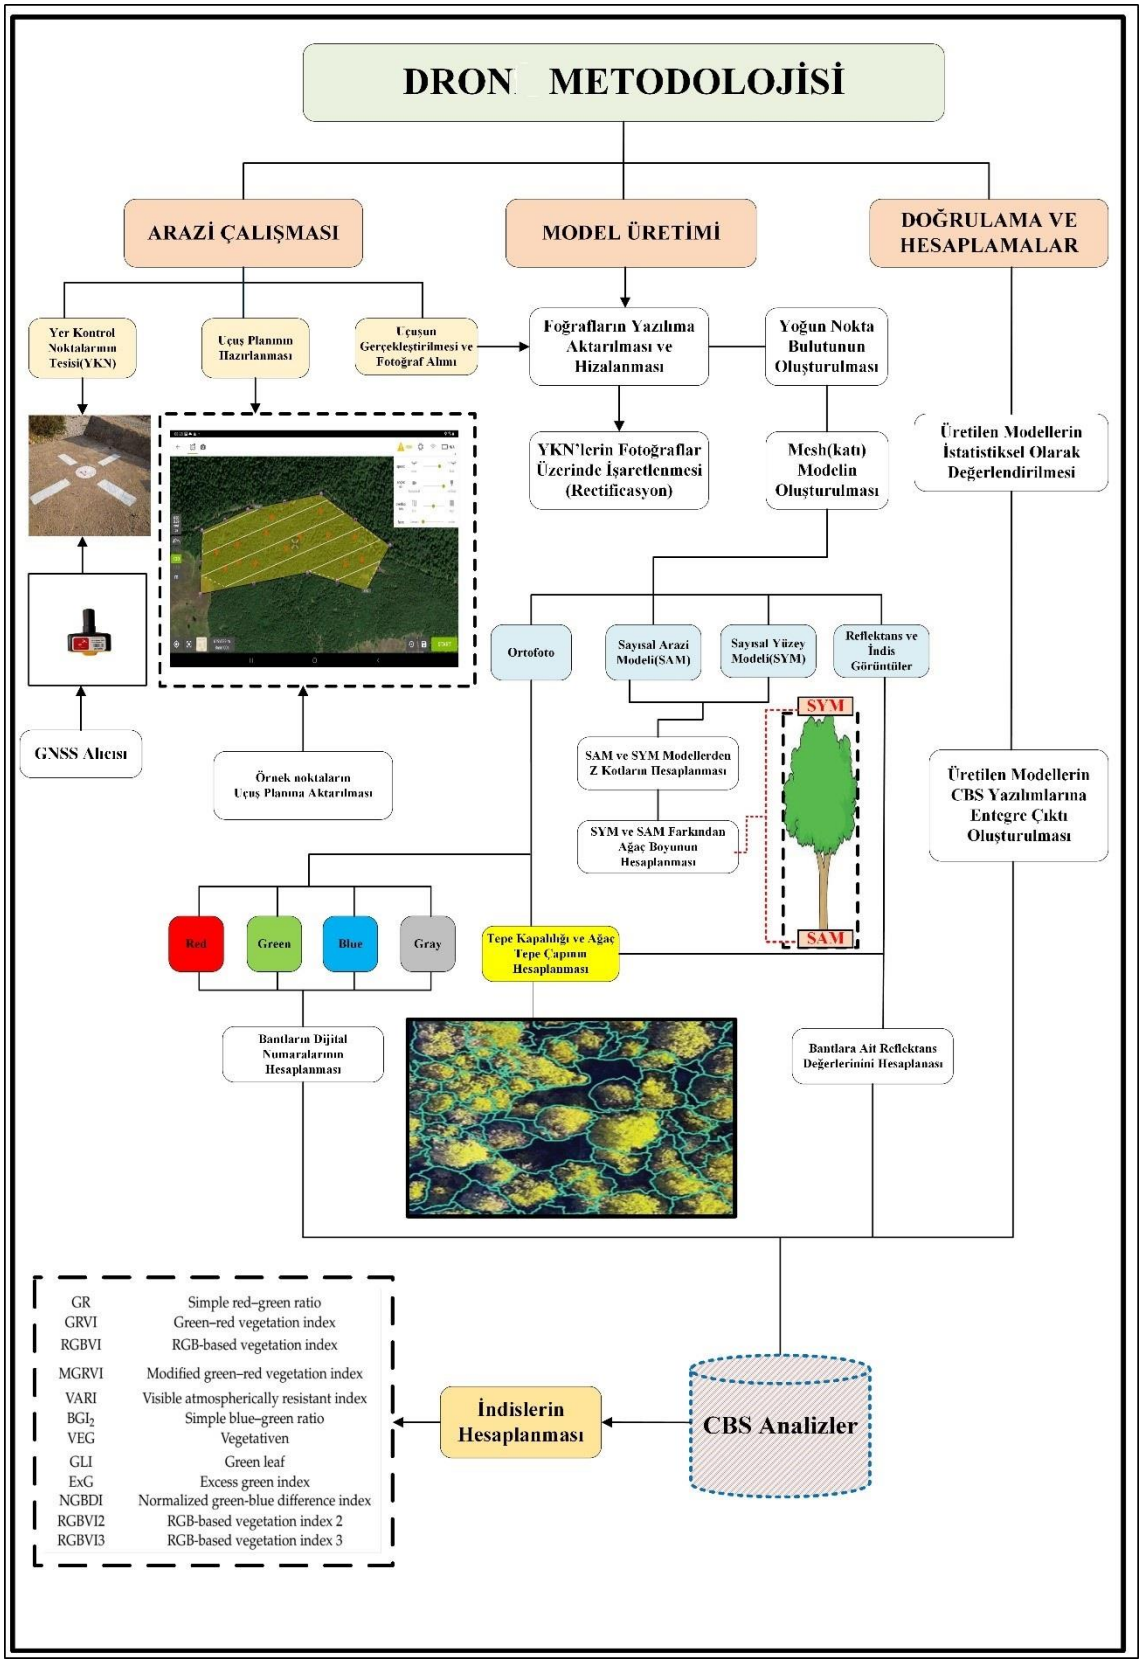
üretilen “vektör” katmanı “buffer zon” ile “intersect” komutu kullanılarak çakıştırılmış ve örnek alan sınırına uygun “vektör” veri elde edilmiştir. Vektör dönüşümü sayesinde örnek alan sınırına göre birebir çıkarım yapılmış ve sınıra denk gelen bütün piksellerden veri elde edilmiştir. Ardından tekrar “raster” veriye dönüştürülen katmana “zonal statistics” komutu uygulanarak her bir örnek alan için VV ve VH polarizasyonlarına ait geri yansıtım (dB) ile dijital bant değerleri elde edilmiştir.



Şekil 3.8 Sentinel-1 uydu görüntü kalibrasyon makrosu

3.3.5. Dron görüntülerinin oluşturulması ve değerlerin hesaplanması

Çalışma alanına ait dron görüntülerinin alınmasında ilk olarak çalışma alanı idari sınırlara bağlı ilgili kolluk kuvvetleri, sorumlu Orman İşletme Müdürlüğü ile Sivil Havacılık Genel Müdürlüğü’nden (SGHM) yer ve zaman bildirmek sureti ile uçuş izinleri alınmıştır. İzin onayları gerçekleştirildikten sonra model üretiminin yüksek doğrulukta koordinat ve kot değerleri elde edilmesi açısından yer kontrol noktaları (YKN) tesis edilmiştir. YKN’ler cm hassasiyetinde Küresel Konum Belirleme Sistemi (Global Navigation Satellite Systems (GNSS)) alıcıları kullanılarak tesis edilmiştir. Daha sonra çalışma alanında örnek alanları kapsayacak şekilde toplamda 16 uçuş parseli belirlenmiştir. Dron ile sayısal görüntü elde edilmesine ait metodoloji Şekil 3.9’da verilmiştir.



Şekil 3.9 Dron görüntüleri iş akış diyagramı

3.3.5.1 Yer kontrol noktalarının tesisi

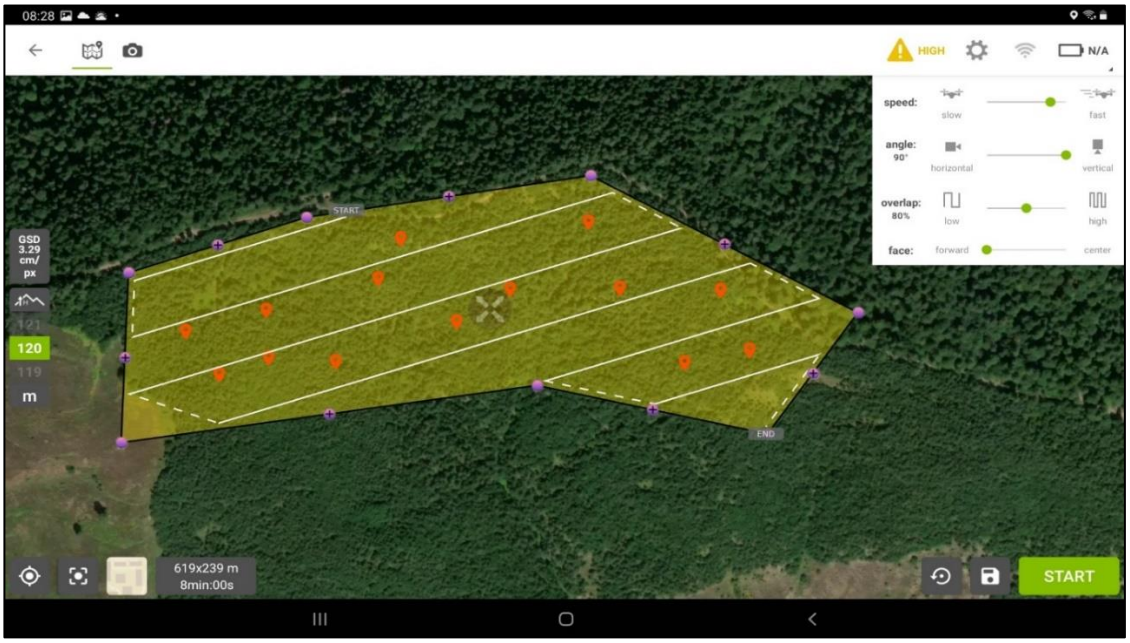
Dron ile uçuş planlamasından önce çalışma sınırı içerisinde olabildiğince dış köşelere yerleştirilmiş ve homojen bir şekilde dağılmış yer kontrol noktaları (YKN) belirlenmiştir. Çekilen hava fotoğrafların cm hassasiyetinde koordinat ve kot(rakım) bilgisi elde edebilmek için çalışma alanı içerisinde örnek alan uçuş parsellerini temsil edecek yeterli miktarda uçuştan önce yer kontrol noktaları tesis edilmiştir. Bu işlem için cm hassasiyetinde GNSS alıcıları kullanılmıştır. Daha sonra uçuş sonrası YKN bilgileri çekilen görüntüler üzerinde sayısal olarak işaretlenerek görüntünün sayısal hata miktarı cm hassasiyetine indirgenmiştir.

3.3.5.2 Uçuş planın belirlenmesi ve görüntüleme

Çalışma alanında örnek noktaları kapsayacak şekilde araziye çıkmadan uçuş planları oluşturulmuştur. Bu planların belirlenmesinde öncelikli olarak uçuş yapılacak yerin kot bilgisi sayısal arazi modeli (SAM) üzerinden belirlenmiştir. Daha sonra her bir uçuş planı içinde dronun kalkış yapacağı konum ve bu konuma ait kot bilgileri çıkarılmıştır. Böylece bu iki kot bilgisi göz önünde bulundurularak minimum uçuş yüksekliği belirlenmiştir. Daha sonra minimum uçuş yüksekliği göz önünde bulundurularak bütün uçuş planlarında (parsellerde) aynı uçuş yüksekliği kullanılacak şekilde uçuş yüksekliği 120 m olarak belirlenmiştir. Daha sonra görüntülere ait ön ve yan bindirme oranları çalışma amacına bağlı olarak kararlaştırılmıştır. Bu oranlar sırası ile %80 ve %70 olarak belirlenmiştir. Bütün uçuşlarda kamera açısı 90° olacak şekilde ayarlandı. Son olarak hava durumunun da etkisi olduğu uçuş hızı ayarlanarak uçuşlar gerçekleştirilmiştir. Alınan görüntülerin yüksek kalitede olması açısında bütün uçuşlar bulutluluk oranının en az olduğu ve güneş ışığının gün içinde yeryüzüne geliş açısının en dik olduğu 11:00 – 15:00 saatleri arasında gerçekleştirilmiştir. Böylece görüntüler üzerinde oluşabilecek gölgeler ve karanlık alanlar minimize edilmeye çalışılmıştır.

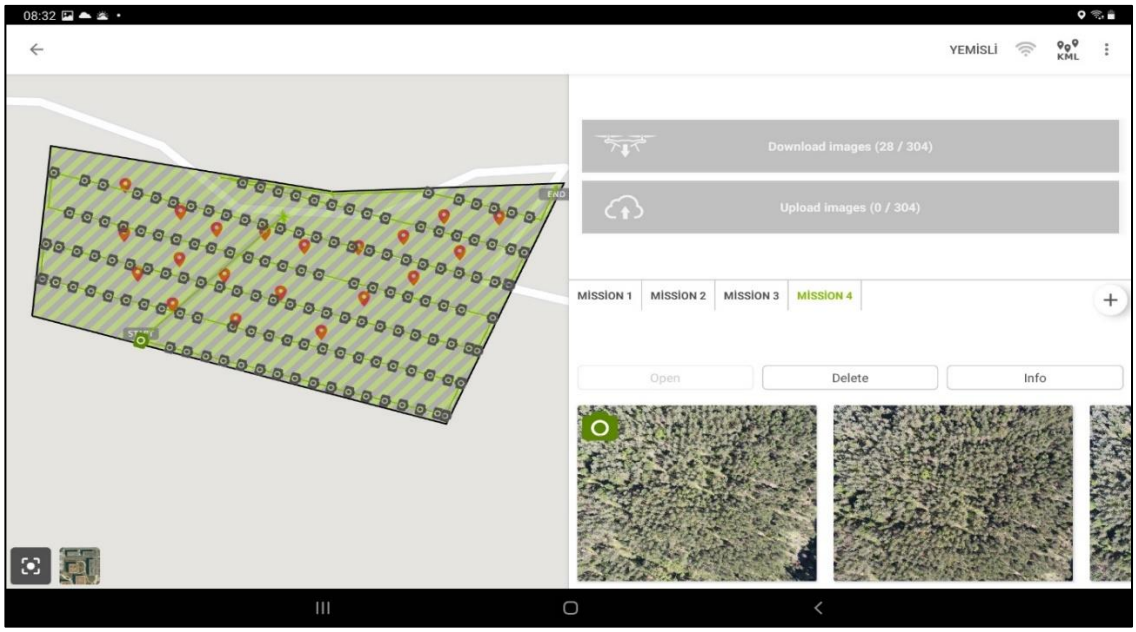
Dronların kumanda edilmesi için birçok program mevcuttur. Özellikle haritalama ve ortofoto üretmek amaçlı dron kullanıcıları Pix4D ve DJI Go 4 uygulamalarını kullanmaktadır. Çalışmada dron Pix4D uygulaması ile kumanda edilerek uçuş

gerçekleştirilmiştir. Çalışma alanına ait Ayancık OİM, Yemişli OİŞ'e ait bir uçuş planı görüntüsü Şekil 3.10'da verilmiştir.



Şekil 3.10 Dron uçuş plan örneği

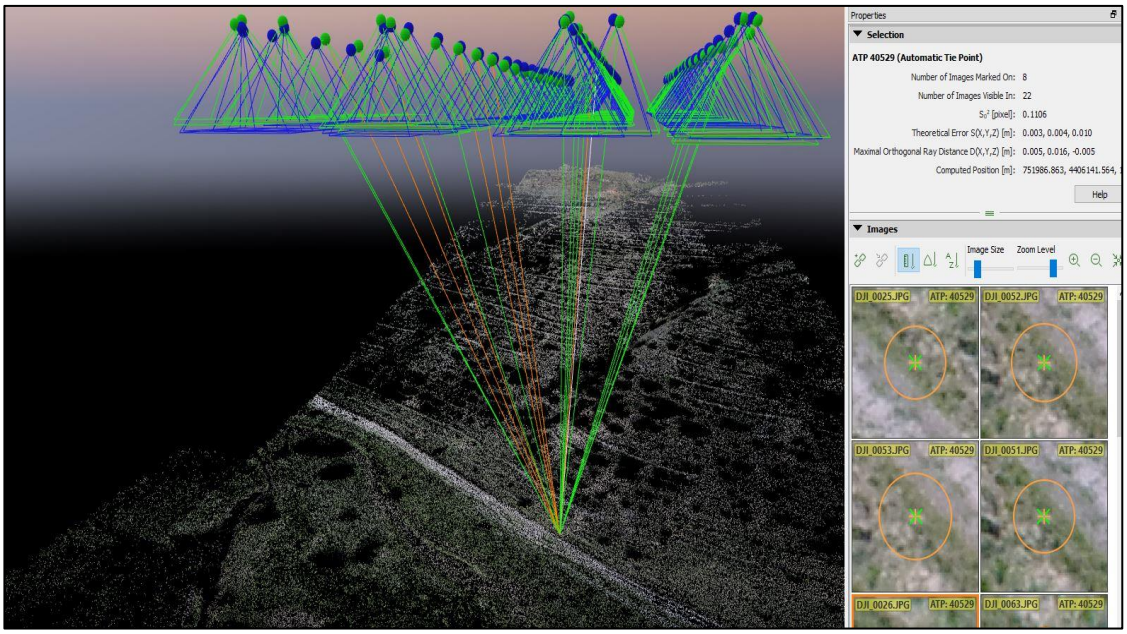
Şekil 3.10 incelendiğinde ilgili uçuşa ait teknik parametre bilgiler görünmektedir. Kırmızı noktalar yersel olarak orman envanterinin yapıldığı örnek alanları, köşesel karelaj uçuşun yapılacağı parsel sınırını ve son olarak beyaz düz çizgiler uçuşun gerçekleştirileceği hattı göstermektedir. Uçuş tamamlandıktan sonra alınan fotoğraf sayısı ve uçuş hattı üzerinde alınmış fotoğrafların konumu Şekil 3.11'de gösterilmiştir.



Şekil 3.11 Uçuş sonrası ilgili parsele ait fotoğraf sıklığı ve sayısının görünümü

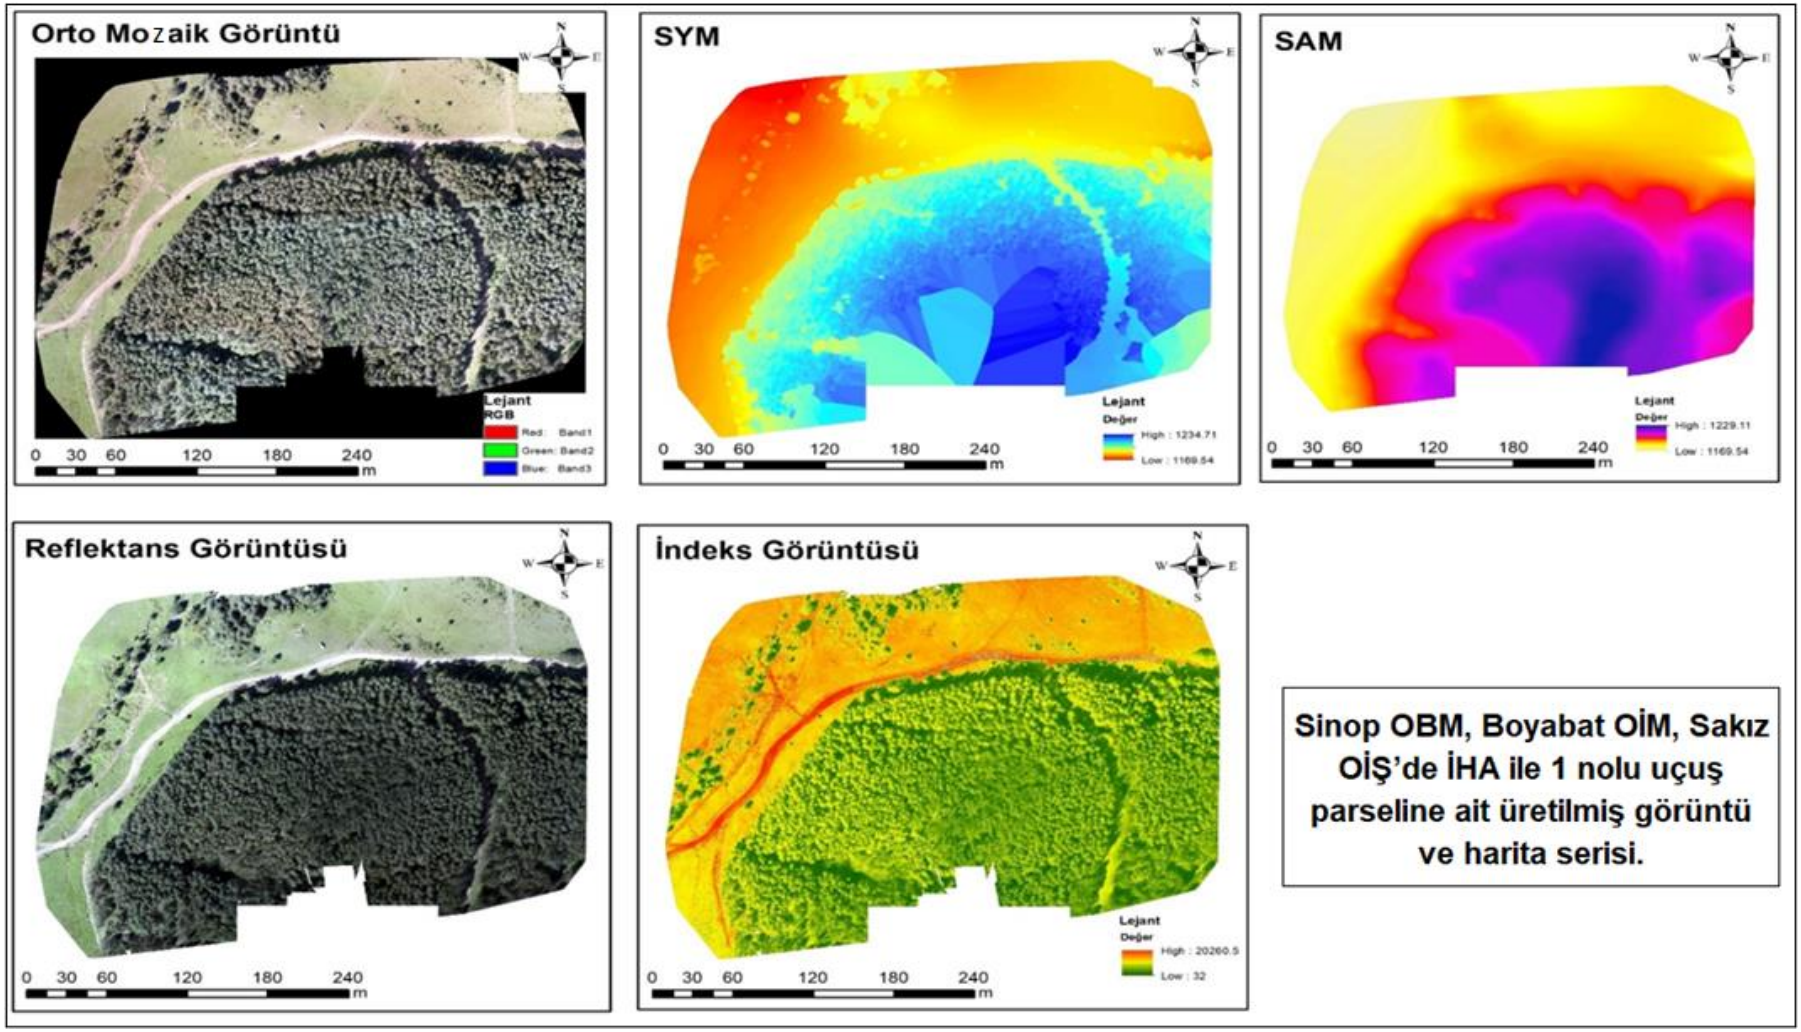
3.3.5.3 Ortofoto, sayısal arazi modeli (SAM) ve sayısal yüzey model (SYM) oluşturulması

Çalışmada elde edilen dron görüntülerine ait ortofoto, SAM ve SYM modellerin oluşturulmasında Pix4D yazılımı kullanılmıştır. Modellerin oluşturulması üç aşamada gerçekleştirilmiştir. İlk olarak alınan görüntüler koordinatlı bir şekilde hizalanmış ve görüntü kalibrasyon işlemleri gerçekleştirilmiştir. İkinci aşamada ise görüntülere ait bağlama noktaları (Tie points) oluşturulmuştur. Bu işlem fotoğraflar arasındaki bağlantı noktalarını belirlemek için kullanılmıştır. Bu noktalar ile nokta bulutu oluşturulmuştur. Nokta bulutu model hassasiyeti bakımından lowest (en düşük) ve ultra high (en yüksek) olacak şekilde farklı kalitede nokta sayıları kullanılarak modellenebilmektedir. Buradaki anahtar nokta istenilen hassasiyet kadar detaylı noktalar uygulanmasıdır. Çalışma alanı büyüklüğüne göre aynı alanda "high" seçeneğinde bir nokta bulutu 100 milyon nokta alırken, aynı model "medium" seçeneğinde 50-60 milyon arası nokta toplanabilmektedir. Oluşturulmak istenen nokta sayısı kullanılan bilgisayar teknik özellikleri ile de ilişkili olarak değişmektedir. Çalışmada nokta bulutu oluşturulurken lowest (en düşük) hassasiyet uygulanmıştır. Uçuş planlarından bir modelin bağlama noktalarının oluşturulmasına ait örnek bir görüntü Şekil 3.12'de verilmiştir.



Şekil 3.12 Bağlama noktaları (Tie points) görünümü

Son aşamada yoğun nokta bulutu oluşturulduktan sonra Sayısal Ortofoto, SAM, SYM, reflektans ve indeks haritaları oluşturulmuştur. Çalışmadan bir uçuş parseline ait sayısal görüntü serisine örnek Şekil 3.13'te gösterilmiştir.

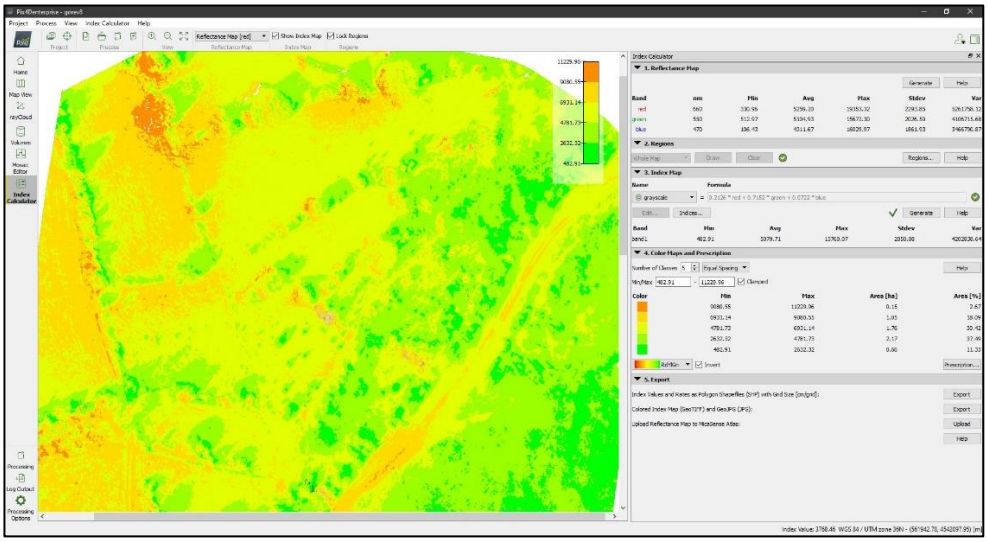


Şekil 3.13 Dron görüntülerinden üretilmiş ortofoto, SAM, SYM, reflektans ve indeks haritalar

Çalışmanın belirlenen bütün parsellerine ait sayısal görüntüler oluşturulmuştur. Parsellere ait ortofotolar red, green ve blue (RGB) olmak üzere üç banttan oluşmaktadır. Dördüncü bant olarak Greeyscale (Pankromatik) bant da Eşitlik 4'te (Pix4D, 2022) belirtilen şekli ile üretilerek toplam dört banttan oluşan görüntüler elde edilmiştir. Reflektans görüntü ve diğer görüntüler ArcGIS yazılımında kullanılmak ve analiz edilmek üzere tiff. formatında dışa aktarılarak analize hazır hale getirilmiştir.

$$Grayscale = 0.2126 \times Red + 0.7152 \times Green + 0.0722 \times Blue \quad (4)$$

Bantlara ait dijital bant değerleri ve reflektans değerleri; ArcGIS Desktop 10.7 programı kullanılarak her bir bant "vektör" katmanına dönüştürülmüş ve üzerine her bir örnek alan için örnek alan büyüklüklerine göre "buffer zon" atılmıştır. Ardından üretilen "vektör" katmanı "buffer zon" ile "intersect" komutu kullanılarak çakıştırılmış ve örnek alan sınırına uygun "vektör" veri elde edilmiştir. Vektör dönüşümü sayesinde örnek alan sınırına göre birebir çıkarım yapılmış ve sınıra denk gelen bütün piksellerden veri elde edilmiştir. Ardından tekrar "raster" veriye dönüştürülen katmana "zonal statistics" komutu uygulanarak her bir örnek alan için reflektans ve dijital bant değerleri elde edilmiştir. Daha sonra reflektans değerleri kullanılarak vejetasyon indisleri hesaplanmış ve veri setleri oluşturulmuştur. Modellenen indeks haritası ile sınıflandırılmış görüntü ise şekil 3.14'te gösterilmiştir.



Şekil 3.14 Bantların indeks değerleri kullanılarak sınıflandırılmış görüntü

3.4. Tahmin modellerin oluşturulması

Envanter çalışmalarından elde edilen meşcere parametreleri (meşcere orta çapı (d_g), meşcere üst boyu ($h_{üst}$), meşecere ağaç sayısı (N), meşecere göğüs yüzeyi (G) ve meşcere hacmi (V)), YAİ, TÜB ve TÜK ve Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen reflektans, vejetasyon indisi, tekstür, geri yansıtım ve dijital bant değerleri arasındaki ilişkilerin modellenmesi amacıyla veriler hazırlanmıştır. Bunun için yersel ölçümlerden (d_g, $h_{üst}$, N, G, V ve TÜB) elde edilen değerlerin logaritmaları alınarak modellerde "*ln*" değerleri kullanılmıştır. YAİ ve TÜK değerleri ise normal değerler olarak modellere dahil edilmiştir. Oluşturulan modelleri test edebilmek için veri setleri iki gruba ayrılmıştır. Veri setlerinin yaklaşık %80'ni model (150 adet) ve yaklaşık %20'si de test (34 adet) için ayrılmıştır. Veri ayırma işlemleri iki aşamada gerçekleştirilmiştir. İlk aşamada yersel ölçümlerden elde edilen göğüs çapı değerleri 4'er cm çap basamaklarına ayırılarak her çap basamağındaki yoğunluk değerleri hesaplanmıştır. Daha sonra karşılık gelen çap basamaklarından adet olarak Model ve Test verisi olarak dg, N, G, V, TÜB ve TÜK veri setleri oluşturulmuştur. YAİ ve $h_{üst}$ çaptan türetilmeyen ayrı yersel ölçümler ile doğrudan belirlenen parametreler olması sebebi ile veri ayrımı kendi içlerinde değer yoğunlukları baz alınarak yapılmıştır. YAİ değerleri 0,25 (m^2 m^{-2}) ve 2,50 (m^2 m^{-2}) değerleri arasında oluştuğu için 0,25 aralığında 8 sınıfa bölünmüş ve her sınıfa ilişkin yoğunluk sayıları belirlenmiştir. Üst boy içinde boy değerleri 5'er metrelik sınıflara bölünerek her sınıfa sayısal yoğunluk belirlenmiş ve model (150 adet) test (34 adet) ayrımı gerçekleştirilmiştir. Oluşturulan veri setlerine çoğul regresyon analizi (ÇRA) ve yapay sinir ağları (YSA) modelleme teknikleri uygulanmıştır. Bu tekniklerin kullanıldığı modelleme süreci 3 aşamada gerçekleştirilmiştir. İlk aşamada model veri seti kullanılarak her bir parametre uzaktan algılama verileri kullanılarak çoğul regresyon modelleme tekniği ile tahmin edilmiştir. İkinci aşamada model veri seti ile oluşturulan tahmin modelleri ile test verileri için tahminler elde edilmiştir. Üçüncü aşamada ise test bulgularına ilişkin tahminler ile gözlem verileri arasında fark olup olmadığını belirlemek için istatistiksel analizlerden birisi olan "eşlendirilmiş *t*-testi" kullanılmıştır.

3.4.1. Çoğul regresyon analizi

Uzaktan algılama verileri ile topraküstü biyokütle (TÜB), topraküstü karbon (TÜK), yaprak alan indeksi (YAİ) ve meşcere parametreleri (dg, $h_{üst}$, N, G, V) arasındaki ilişkilerin modellenmesinde çoğul regresyon analizi kullanılmıştır. Bu modeller ile meşcere parametreleri, uzaktan algılama verileri (reflektans, vejetasyon indis, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri) ile tahmin edilmiştir. Bu analizlere ilişkin model yapıları aşağıda verilmiştir.

Model 1: $T\ddot{U}B = \beta_0 + \beta_1.X_1 + \beta_2.X_2 + \cdots + \beta_n.X_n + \varepsilon$ (5)

Model 1'de TÜB bağımlı değişken olarak seçilmiş ve bağımsız değişkenler ise (X_1, X_2, …, X_n) Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen uzaktan algılama verileri; reflektans, vejetasyon indisi, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri olarak alınmıştır.

Model 2: $T\ddot{U}K = \beta_0 + \beta_1.X_1 + \beta_2.X_2 + \cdots + \beta_n.X_n + \varepsilon$ (6)

Model 2'de TÜK bağımlı değişken olarak seçilmiş ve bağımsız değişkenler ise (X_1, X_2, …, X_n) Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen uzaktan algılama verileri; reflektans, vejetasyon indisi, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri olarak alınmıştır.

Model 3: $YA\dot{I} = \beta_0 + \beta_1.X_1 + \beta_2.X_2 + \cdots + \beta_n.X_n + \varepsilon$ (7)

Model 3'te YAİ bağımlı değişken olarak seçilmiş ve bağımsız değişkenler ise (X_1, X_2, …, X_n) Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen uzaktan algılama verileri; reflektans, vejetasyon indisi, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri olarak alınmıştır.

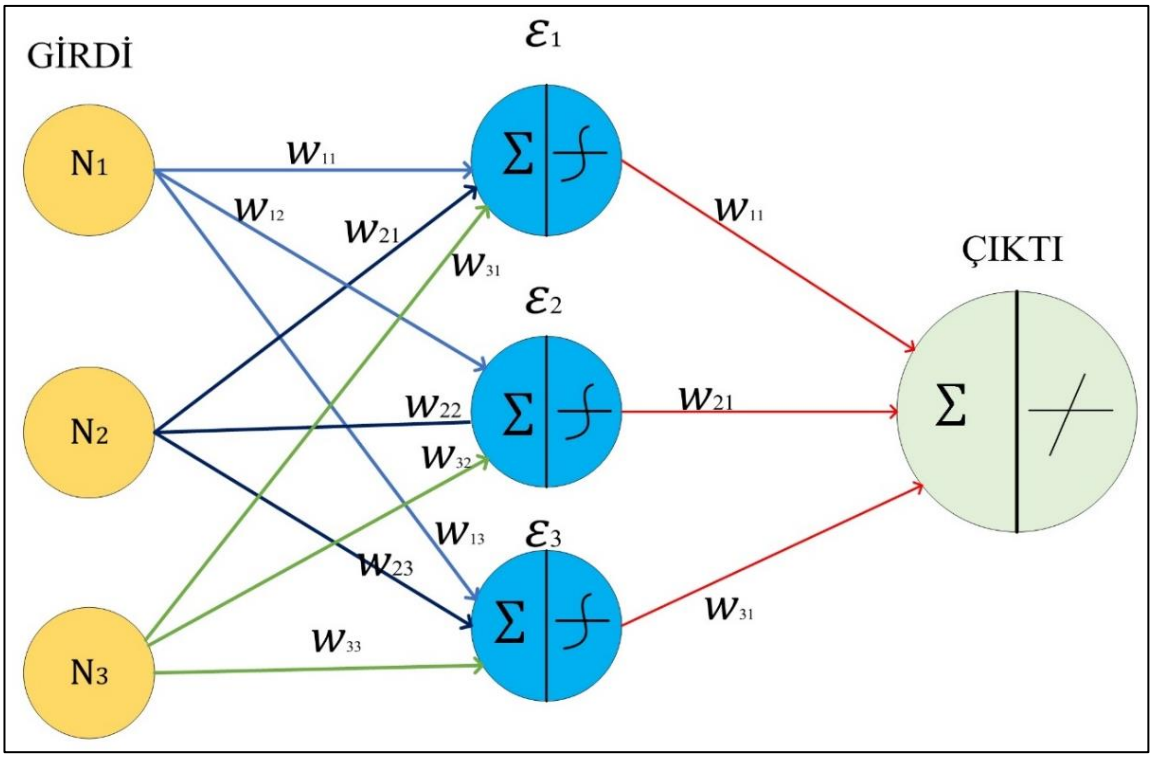
Model 4: $Meşçere\ Parametresi = \beta_0 + \beta_1.X_1 + \beta_2.X_2 + \cdots + \beta_n.X_n + \varepsilon$ (8)

Model 4'te Meşçere Parametresi (dg, $h_{üst}$, N, G ve V) bağımlı değişken olarak seçilmiş ve bağımsız değişkenler ise (X_1, X_2, …, X_n) Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen uzaktan algılama verileri; reflektans, vejetasyon indisi, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri olarak alınmıştır. Oluşturulan bu modellerde %5 önem düzeyinde farklı bağımsız değişken seçeneklerinden istatistiksel olarak anlamlı değişkenler içeren çoğul regresyon modeller "Aşamalı (Stepwise)", değişken seçim yöntemleri ile belirlenmiştir.

3.4.2. Bayesçi yapay sinir ağları

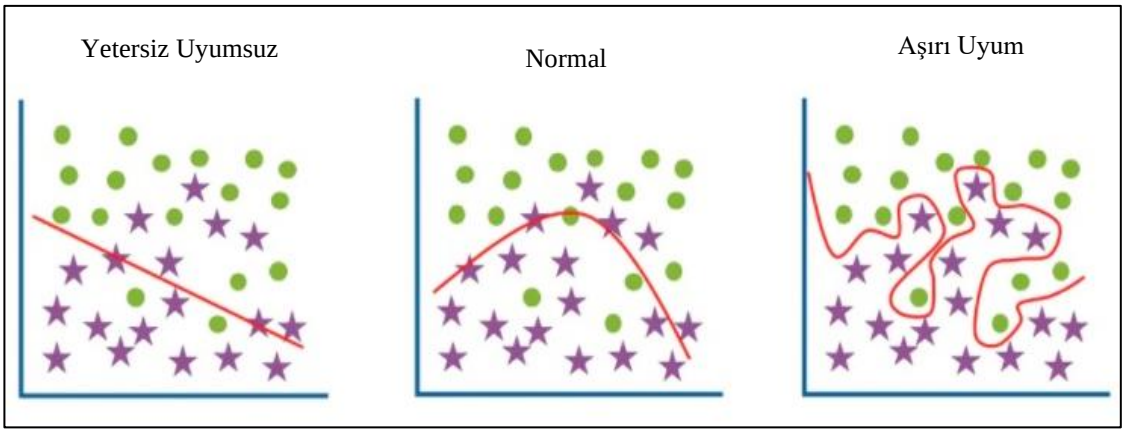
Bu çalışmada uygulanan bir diğer tahmin yöntemi ise ileri beslemeli geri yayılımlı Bayesçi Yapay Sinir Ağı (BYSAM) modeldir. Çalışmada bağımlı değişkenler TÜB, TÜK, YAİ ve meşcere parametreleri için uygulanan çağul regresyon analizi (ÇRA) modelde anlamlı bağımsız değişkenler (reflektans, vejetasyon indisi, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri) esas alınarak bir BYSAM ağı tasarlanmıştır (Bolat 2021) (EK 1).

Bu çalışmada hazır paket programları kullanmak yerine farklı YSA model seçeneklerini içerecek şekilde eğitimleri gerçekleştirmek için MATLAB Ek-1 de verilmiş kodlar kullanılmıştır (Bolat 2021). Üç katmanlı ve üç nöronlu bir yapay sinir ağı yapısı Şekil 3.15'te gösterilmiştir. Aşağıda verilen örnek yapay sinir ağı girdi-gizli katman arası 9 ağırlık parametresi, gizli-çıktı katman arası 3 ağırlık parametresi, 3 nöron ve 1 çıktı katmanının hata parametresi olmak üzere toplam 16 parametreden oluşmaktadır.



Şekil 3.15 Üç katmanlı ve üç nöronlu yapay sinir ağı modeli

Yapay sinir ağ modellerinde aşırı uyum problemi karşılaşılan en yaygın problemlerden biridir. Tasarlanan ağ eğitim veri setinde iyi sonuçlar, test veri setinde kötü performans gösterebilmekte ya da bunun tam tersi bir durum sergileyebilmektedir (Overfitting). Diğer bir ifade ile bu durum ağın sonuçları genelleştirme kabiliyeti kazanamaması ya da ağın modeli birebir taklit etmesi olarak belirtilmektedir (Bolat 2021) (Şekil 3.16). Aşırı uyum problemi bağımsız değişken sayısı ile de yakından ilgili olduğunu göstermektedir (Van Havre *et al*. 2015). YSA modellerin öne çıkan en büyük dezavantajlarından biri aşırı uyum problemidir. Genel olarak eğitim veri seti az olan YSA modeller için uyum problemi kaçınılmazdır. Bu durumdaki YSA modellerin uyum problemini gidermenin bir yolu basit sinir ağı modelleri uygulamaktır (Okut 2016, Bolat 2021). Aşırı uyumdan kaçınmanın bir başka yolu, Levenberg–Marquardt ve Bayesian gibi uygun bir düzenleme eğitimi işlevi seçmektir (Skudnik and Jevšenak 2022).



Şekil 3.16 YSA'da yetersiz ve aşırı uyum gösterimi (IBM 2021)

Aşırı uyum ya da yetersiz uyum problemlerini aşmak için bazı parametreler dikkate alınmıştır. Öncelikle yapılması gereken test veri setinin iyi bir şekilde seçilmesidir. Test veri seti, eğitim veri setinin değişkenliğini temsil edebilecek düzeyde olmalıdır. Bu veri seti ağın eğitimi sırasında, test verisine ait herhangi bir analiz gerçekleştirilmemelidir. Ağ eğitiminden önce önemli olan bir diğer husus eğitim veri seti olarak ayrılan verilerin ağ eğitimi sırasında eğitim, test ve validasyon olarak nasıl ayrılacağının belirlenmesidir (Bolat 2021).

Tasarlanan ağın birçok kez yeniden eğitilmesi (bir anlamda yeniden örnekleme) ağın öğrenme kabiliyetini artırmaktadır. Çünkü her eğitim aşamasında eğitim veri seti farklı şekilde gruplara ayrıldığından dolayı ağ, model hata değerini minimize edecek şekilde girdi değişkenlerinin ağırlıklarını değiştirmektedir. Örneğin, 5 nöronlu bir ağın 10 kez eğitilmesi, ağın ortalama performansı, bireysel ağ performanslarının çoğundan düşük olduğunda ağın genelleştirme kabiliyetinin iyi olduğu söylenilebilmektedir (Bolat 2021).

Ağın genelleştirme kabiliyetini etkileyen bir diğer husus da ağ eğitimi için belirlenen eğitim fonksiyonudur. Çünkü, seçilen eğitim fonksiyonuna göre parametre uyarlamaları değişmektedir (Piotrowski *et al.* 2013). Bu çalışmada Bayesçi ağ eğitimi kullanılmıştır. Çünkü Bayesçi ağ yapıları erken durdurma ve regülarizasyon parametresi ile daha iyi uyum içinde çalışır. YSA modellerde ağ karmaşıklığı ve uç değerlere karşı tutarlılığını artırmak için bağımsız değişkenler farklı tekniklerle normalleştirilebilirler (Akıllı and Hülya 2020, Bolat 2021). Bu çalışmada da bağımsız değişkenler minimum ve maksimum

tekniği kullanılarak eksi 1 ila artı 1 aralığında değerlere dönüştürülmüştür (Foresee and Hagan 1997, Bolat 2021). Bu ağ yapısında verilerin [-1 1] aralığında olacak şekilde düzenlenmesi ağın genelleştirme yeteneğini artırmaktadır. Ağ performansını etkileyen bir diğer husus katmanlar arası veri transferini sağlayan aktivasyon fonksiyonun seçimdir. Genellikle bir kırılma ve asimptot değerine sahip biyolojik yapıları iyi temsil edebilen lojistik sigmoid ve hiperbolik tanjant sigmoid fonksiyonları kullanılmaktadır. Bu çalışmada veriler [-1 1] aralığında düzenlendiğinden hiperbolik tanjant transfer fonksiyonu kullanılmıştır (Bolat 2021).

Ağ performansını etkileyen bir diğer husus öğrenme oranı ve momentum değeridir. Momentum değeri genellikle 0 ile 1 arasında seçilmektedir. Öğrenme oranı ağın eğitim sürecinde önemli parametrelerden bir diğeridir. Küçük öğrenme oranı ağın verilere aşırı uyum sağlamasına sebep olurken; büyük öğrenme oranı az öğrenmeye dolayısıyla büyük hatalara sebep olabilmektedir (Lawrence *et al.* 1997). Bu nedenlerle, öğrenme oranın ve momentum katsayısının eş zamanlı değerlendirilerek belirlenmesi ağ performansının iyileştirilmesi bakımından önemlidir (Bolat 2021). Bu çalışmada da öğrenme oranı ve momentum değerleri baz alındığında; öğrenme oranın sabit tutulduğu (0,1) momentumu (0,1…..0,9) arasında değiştirmek suretiyle 9 model, momentum oranının sabit tutulduğu (0,1) öğrenme oranının (0,1…..0,9) arasında değiştiği 8 model ile toplam her bir bağımlı değişken için 17 model oluşturulmuştur. 17 model içinden performans ölçütleri ve uyum durumları değerlendirilerek ağı temsil edecek en yüksek başarıya sahip modele karar verilmiştir.

3.4.3. Performans ölçütleri

Yapılan envanter çalışması ile elde edilen gözlem verileri ve modelleme teknikleri kullanılarak yapılan tahmin sonuçlarını karşılaştırmak için farklı kriterler kullanılmıştır. Kullanılan performans ölçütleri belirtme katsayısı (R^2), ortalama mutlak hata (MAE), hata kareler ortalamasının karekökü (RMSE), ortalama hata (BIAS), akaike ölçütü (AIC) ve Bayesian bilgi kriteri (BIC)'dir. Model başarılarının yüksek olması için R^2 değerlerinin büyük, MAE, RMSE, BIAS, AIC ve BIC değerlerinin küçük olması beklenmektedir. Her parametre için hesaplanan performans ölçütleri dikkate alındığında

bir ölçüte göre başarılı olan yöntem, diğer bir ölçüt değerine göre başarısız olabilmektedir. Bu nedenle tüm başarı ölçütlerinin kapsayacak şekilde, bir başarı sıralaması yapılmıştır. Bu amaçla, Poudel ve Cao (2013) tarafından önerilmiş olan Rölatif Sıralama Yöntemi kullanılmıştır (R_j). Bu başarı sıralama yönteminde, modeller başarı ölçütünün birbirine olan yakınlık ve uzaklık değerine göre rölatif olarak sıralanmaktadır (Ercanlı *et al.* 2018). Farklı ölçüt değerlerine ilişkin rölatif sıra numaraları toplanıp, en küçük toplam rölatif sıra numarasına sahip model ilgili parametre için en başarılı olarak belirlenmiştir (Özdemir 2018, *Ercanlı et al.* 2018).

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_g - y_t)^2}{\sum_{i=1}^{n}(y_g - y_{og})^2} \tag{9}$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|h_i| \tag{10}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(h_i)^2} \tag{11}$$

$$Bias = \frac{\sum_{i=1}^{n}(y_g - y_t)}{n} \tag{12}$$

$$AIC = \ln(RMSE) + 2k \tag{13}$$

$$BIC = \ln(RMSE) + \ln(k) \tag{14}$$

$$R_i = 1 + \frac{(m-1)x(S_i - S_{en\ küçük})}{(S_{en\ büyük} - S_{en\ küçük})} \tag{15}$$

**h*: Hata, *X:* Birincil değişken, *Y:* İkincil değişken, y_g: Gözlem, y_t: Tahmin, y_{og}: Ortalama gözlem, *n*: Örnek sayısı, *k:* Modeldeki parametre, *m:* Anlamlı bağımsız değişken sayısı, S_i: İstatistiki ölçüt değeri, $S_{en\ küçük;}$ Yöntemlere ilişkin en küçük başarı ölçüt değeri, $S_{en\ büyük}$*:* Yöntemlere ilişkin en büyük ölçüt değeri

4. BULGULAR

Bu çalışma Sinop Orman Bölge Müdürlüğü sınırları içerisindeki saf ve doğal sarıçam meşcereleri için gerçekleştirilmiştir. Yapılan envanter çalışması ile 184 adet örnek alan alınmıştır. Modellemeler 184 örnek alan için yaprak alan indeksi (YAİ) ve meşcere parametreleri (meşcere orta çapı: d_g, meşcere üst boyu: $h_{üst}$, ağaç sayısı: N, meşcere göğüs yüzeyi: G, meşcere hacmi: V, topraküstü biyokütle: TÜB ve topraküstü karbon: TÜK) hesaplanmıştır. Uzaktan algılama verileri olarak da Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen; reflektans, vejetasyon indisi, tekstür, parlaklık, geri yansıtım ve dijital bant değerleri hesaplanmıştır. TÜB, TÜK, YAİ ve meşcere parametrelerinin modellenmesinde çoğul regresyon analizi (ÇRA) ve yapay sinir ağları (YSA) metotları kullanılmıştır.

4.1. Meşçere Parametrelerine Ait Bulgular

Her bir örnek alana ilişkin meşcere parameterleri, YAİ, TÜB ve TÜK verilerine ilişkin tanımlayıcı istatistiki değerler Çizelge 4.1'de verilmiştir.

Çizelge 4.1 Meşcere parametrelerine ilişkin tanımlayıcı istatistik değerleri

Parametre	**N (Örnek sayısı)**	**Min.**	**Maks.**	**Ort.**	**Std. D**
d_g (cm)	184	5,62	55,98	24,13	13,18
$h_{üst}$ (m)	184	4,52	34,90	16,89	7,80
N (adet/ha)	184	100,00	2800,00	884,33	689,74
G (m^2/ha)	184	4,20	79,41	28,15	19,40
V (m^3/ha)	184	21,05	865,65	259,39	225,17
YAİ (m^2 m^{-2})	184	0,25	2,29	1,22	0,47
TÜB (ton/ha)	184	12,34	324,92	104,88	83,25
TÜK (ton/ha)	184	11,13	401,50	122,98	110,23

4.2. Uzaktan Algılama Verileri ile Modelleme

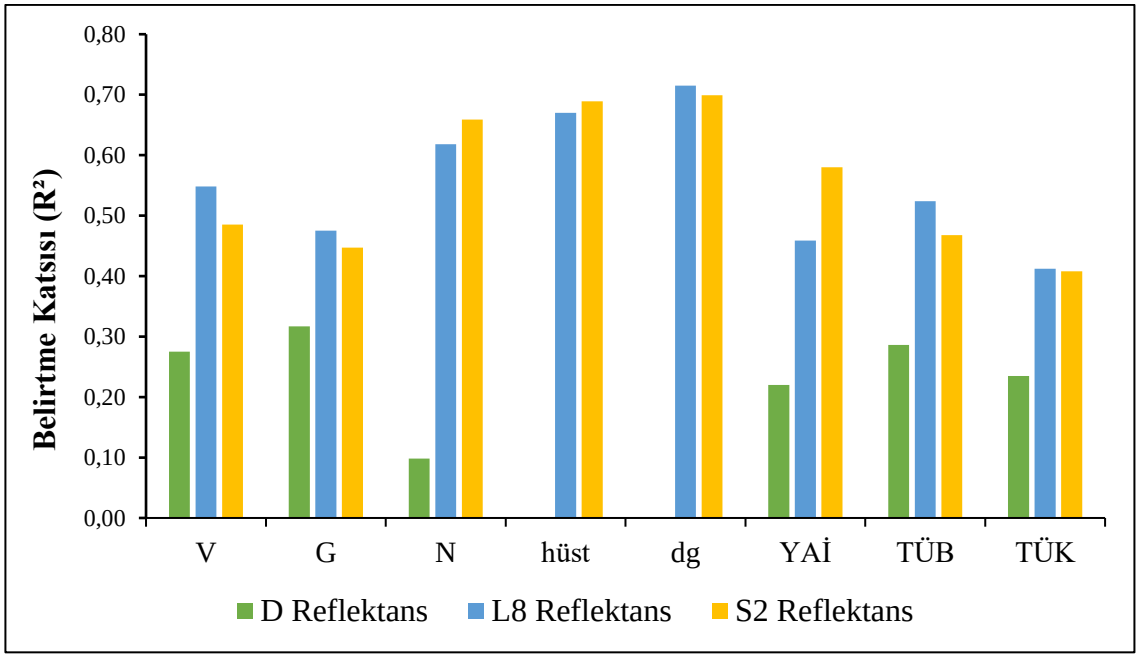
4.2.1. Görüntülerden elde edilen reflektans verilerine ait bulgular

ÇRA metodu ile bütün parametrelerin veri setleri ile modellenmesine ait çalışmaya ait başarı ölçüt değerleri ve toplam rölatif sıra numaraları Çizelge 4.7 'de verilmiştir. İlgili parametreye ait toplam rölatif sırası en düşük veri seti ile elde edilmiş modeller en başarılı model olarak belirlenmiştir. Reflektans verileri ile en yüksek başarı Landsat 8 OLI uydu görüntüsü kullanılarak toplam rölatif sıra numarası en düşük olan (R_j=49,97) meşcere orta çapı için bulunmuştur (R^2=0,72). Sentinel-2 uydu görüntüsü ile de en düşük toplam rölatif hataya sahip (R_j=55,26) meşcere orta çapı için en yüksek belirtme katsayısı 0,70 olarak hesaplanmıştır. En düşük belirtme katsayısı ise dron görüntülerine ait reflektans değerlerinde meşcere ağaç sayısı için bulunmuştur (R^2=0,10). Genel olarak reflektans değerleri kullanılarak meşçere parametrelerinin modellenmesinde Landsat 8 OLI uydu görüntüsünden elde edilen değişkenler ile en yüksek belirtme katsayıları bulunmuştur. Drone görüntülerinden elde edilen reflektans değerleri ile meşcere orta çapı ve üst boyu için anlamlı bağımsız değişken olmadığından ve model üretilemediğinden değerlendirme dışı bırakılmıştır (Çizelge 4.2 (-)). Reflektans değerleri kullanılarak meşçere parametrelerinin ÇRA ile modellenmesine ait belirtme katsayılarına ilişkin sonuçlar Çizelge 4.2 de ve Şekil 4.1'de gösterilmiştir.

Çizelge 4.2 Landsat 8 OLI, Sentinel-2 ve dron görüntülerinden elde edilen reflektans değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2)

Veri Seti	**Meşçere Parametreleri**							
	V	**G**	**N**	**$h_{üst}$**	**d_g**	**YAİ**	**TÜB**	**TÜK**
D Reflektans	0,28	0,32	0,10	-	-	0,22	0,29	0,24
L8 Reflektans	0,55	0,48	0,62	0,67	0,72	0,46	0,52	0,41
S2 Reflektans	0,49	0,45	0,66	0,69	0,70	0,58	0,47	0,41

D: Dron görüntüsü, L8: Landsat 8 OLI, S2: Sentinel-2



Şekil 4.1 ÇRA metodu kullanılarak reflektans değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) grafiği, (Dron görüntüsü: D, Landsat 8 OLI: L8 ve Sentinel-2: S2)

4.2.2. Vejetasyon indis verilerine ait bulgular

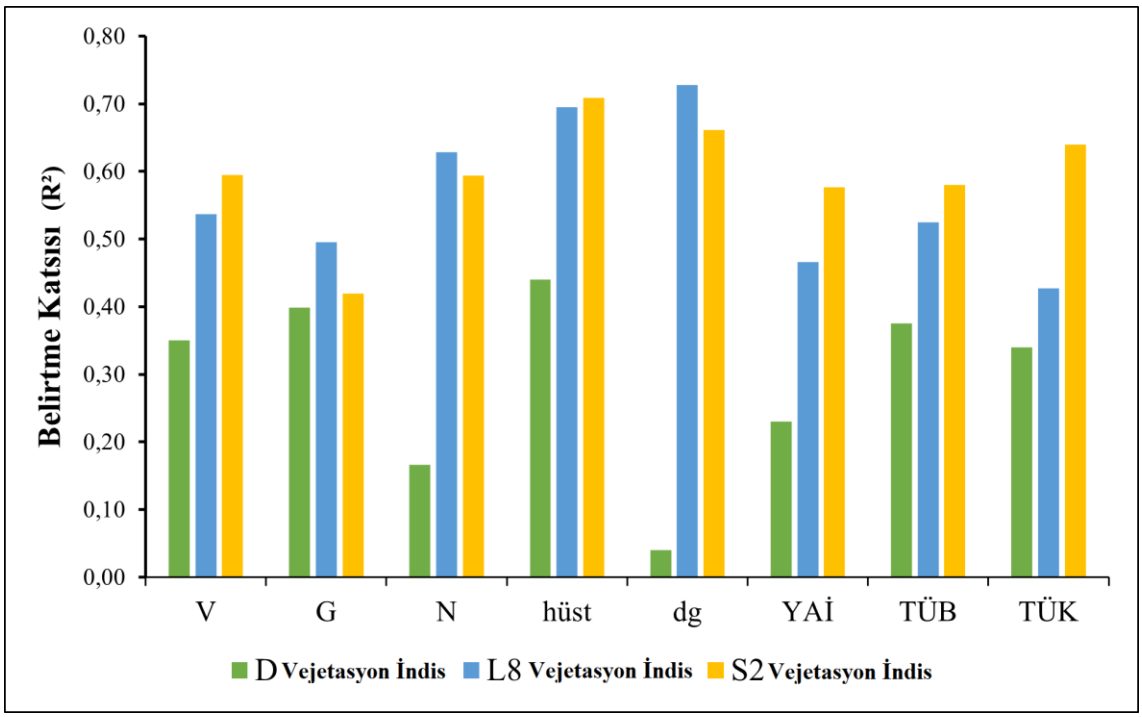
Landsat 8 OLI, Sentinel-2 ve dron görüntüleri kullanılarak sırası ile 12, 12 ve 15 adet vejetasyon indisi hesaplanmıştır. Landsat 8 OLI ve Sentinel-2 uydu görüntüleri için ortak vejetasyon indisler hesaplanmıştır ve ilk olarak ÇRA ile modellenmiştir. Vejetasyon indis verileri ile en yüksek başarı Landsat 8 OLI uydu görüntüsü kullanılarak toplam rölatif sıra numarası en düşük olan (R_j=47,09) (Çizelge 4.7) meşcere orta çapı için bulunmuştur (R^2=0,73). Sentinel 2 uydu görüntüsü ile de en yüksek başarı toplam rölatif sıra numarası en düşük olan (R_j=48,58) (Çizelge 4.7) meşcere üst boyu için elde edilmiştir (R^2=0,71). En düşük belirtme katsayısı ise dron görüntülerine ait vejetasyon indisleri elde edilen modellerde YAİ (m^2 m^{-2}) için bulunmuştur (R^2=0,23). Genel olarak vejetasyon indis değerleri kullanılarak meşçere parametrelerinin modellenmesinde Sentinel-2 uydu görüntüleri ile elde edilen vejetasyon indis değerleri ile en yüksek belirtme katsayıları elde edilmiştir (Çizelge 4.7). Dron görüntülerinden elde edilen vejetasyon indis değerlerine ait model sonuçları incelendiğinde de en yüksek model başarısı meşcere göğüs yüzeyi için bulunmuştur (R^2=0,40). Vejetasyon indis değerleri kullanılarak

meşçere parametrelerinin ÇRA ile modellenmesine ait belirtme katsayıları sonuçları Çizelge 4.3'te ve Şekil 4.2'de gösterilmiştir.

Çizelge 4.3 Landsat 8 OLI, Sentinel-2 ve dron görüntülerinden elde edilen vejetasyon indis değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2)

Veri Seti	Meşçere Parametreleri							
	V	**G**	**N**	**$h_{üst}$**	**d_g**	**YAİ**	**TÜB**	**TÜK**
D İndis	0,35	0,40	0,17	0,44	0,04	0,23	0,38	0,34
L8 İndis	0,54	0,50	0,63	0,70	0,73	0,47	0,53	0,43
S2 İndis	0,60	0,42	0,59	0,71	0,66	0,58	0,58	0,64

D: Dron görüntüsü, L8: Landsat 8 OLI, S2: Sentinel-2



Şekil 4.2 ÇRA metodu kullanılarak vejetasyon indis değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) (Dron görüntüsü: D, Landsat 8 OLI: L8 ve Sentinel-2: S2)

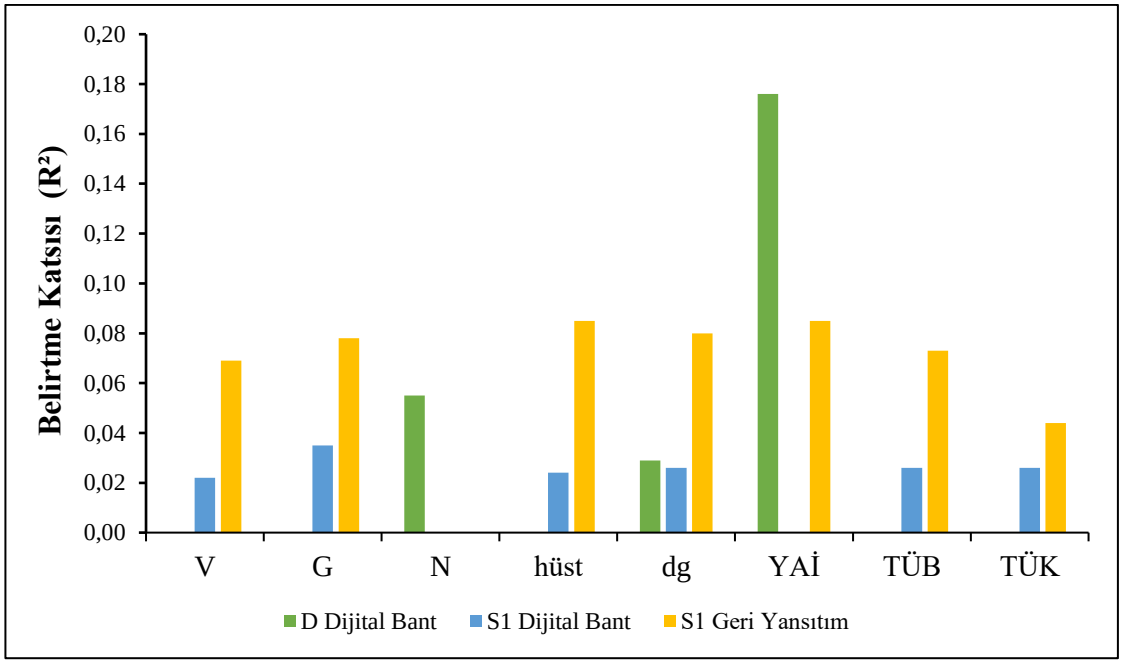
4.2.3. Dijital bant ve geri yansıtım verilerine ait bulgular

Dijital bant verileri ile en yüksek başarı dron görüntüsü kullanılarak YAİ (m^2 m^{-2}) için elde edilmiştir (R^2=0,18). Genel olarak Sentinel-1 görüntüsünden elde edilen modellerin başarı düzeyleri oldukça düşük çıkmıştır. Sentinel-1 görüntüsünden elde edilen geri yansıtım değerleri ile yapılan modellemede en düşük toplam rölatif sıra YAİ (m^2 m^{-2}) ve meşcere üst boyu için elde edilmiştir (R_j=40,56 ve R_j=9,33), (Çizelge 4.7). Belitme katsayısı ise en yüksek meşcere üst boyu için elde edilmiştir (R^2=0,09). Dron dijital bant değerleri ile meşcere hacmi, göğüs yüzeyi, üst boyu, TÜB ve TÜK için anlamlı bağımsız değişken olmadığından ve model üretilemediğinden değerlendirme dışı bırakılmıştır (Çizelge 4.4 (-)). Aynı şekilde Sentinel-1 dijital bant değerleri ile meşcere ağaç sayısı ve YAİ için, Sentinel-1 geri yansıtım değerleri ile de yine meşcere ağaç sayısı için anlamlı bağımsız değişken olmadığından ve model üretilemediğinden değerlendirme dışı bırakılmıştır (Çizelge 4.4 (-)). Sentinel-1 uydu görüntüsüne ilişkin dijital bant ve geri yansıtım değerleri ile dron dijital bant değerleri kullanılarak meşçere parametrelerinin ÇRA ile modellenmesine ait belirtme katsayılarına ilişkin sonuçlar Çizelge 4.4'te ve Şekil 4.3'te gösterilmiştir.

Çizelge 4.4 Sentinel-1 ve dron görüntülerinden elde edilen dijital bant ve geri yansıtım değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2)

Veri Seti	Meşçere Parametreleri							
	V	**G**	**N**	**$h_{üst}$**	**d_g**	**YAİ**	**TÜB**	**TÜK**
D Dijital Bant	-	-	0,06	-	0,03	0,18	-	-
S1 Dijital Bant	0,02	0,04	-	0,02	0,03	-	0,03	0,03
S1 Geri Yansıtım	0,07	0,08	-	0,09	0,08	0,09	0,07	0,04

D: Dron görüntüsü, S1: Sentinel-1



Şekil 4.3 ÇRA metou kullanılarak dijital bant ve geri yansıtım değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) (Dron görüntüsü: D ve Sentinel-1: S1)

4.2.4. Tekstür verilerine ait bulgular

Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden farklı pencere boyutunda ve derecede tekstür değerleri elde edilmiştir. Çoğul regresyon analizi (ÇRA) metodu ile bütün parametrelerin modellenmesine ait başarı ölçüt değerleri ve toplam rölatif sıra numaraları Çizelge 4.7 'de verilmiştir. Meşcere parametreleri, YAİ, TÜB ve TÜK için toplam rölatif sırası en düşük veri seti ile elde edilmiş modeller en başarılı model olarak belirlenmiştir. Tekstür değerleri ile meşcere parametrelerine ilişkin modeller incelendiğinde meşcere hacmi için en yüksek başarı Landsat 8 OLI uydu görüntüsü kullanılarak 135° tekstür değerleri ile toplam rölatif sıra numarası en düşük olan Rj=20,96 ve belirtme katsayısı 0,84 olduğu modelde elde edilmiştir (Çizelge 4.7). Meşcere hacmi hariç diğer bütün parametrelere ait en başarılı modeller Sentinel-2 uydu görüntüsünden elde edilen farklı pencere boyutundaki veri setleri ile elde edilmiştir (Çizelge 4.7). Meşcere göğüs yüzeyi için en yüksek başarı Sentinel-2 uydu görüntüsü kullanılarak 15x15 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olan (R_j=30,36) ve belirtme katsayısı 0,82 olan modelde elde edilmiştir (Çizelge 4.7). Meşcere ağaç sayısına ait sonuçlar incelendiğinde ise en yüksek başarı meşcere göğüs yüzeyinde olduğu gibi

Sentinel-2 uydu görüntüsünden elde edilen 15x15 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olan (R_j=23,40) ve belirtme katsayısı 0,79 olan modelde elde edilmiştir (Çizelge 4.7). Meşcere üst boyu için en yüksek başarı Sentinel-2 uydu görüntüsünden elde edilen 5x5 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olan (R_j=26,58) ve belirtme katsayısı 0,82 olan modelde elde edilmiştir (Çizelge 4.7). Meşcere orta çapı için en yüksek başarı ise Sentinel-2 uydu görüntüsünden elde edilen 7x7 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olan (R_j=15,89) ve belirtme katsayısı 0,83 olan modelde elde edilmiştir (Çizelge 4.7). YAİ de yine meşcere üst boyunda olduğu gibi en yüksek başarı Sentinel-2 uydu görüntüsünden elde edilen 5x5 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olan (R_j=36,38) ve belirtme katsayısı 0,69 olan modelde elde edilmiştir (Çizelge 4.7). TÜB de en yüksek başarı Sentinel-2 uydu görüntüsünden elde edilen 9x9 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olduğu (R_j=24,10) ve belirtme katsayısı 0,81 olan modelde elde edilmiştir (Çizelge 4.7). Son olarak Topraküstü TÜK için de en yüksek başarı, meşcere göğüs yüzeyi ve ağaç sayısında olduğu gibi Sentinel-2 uydu görüntüsünden elde edilen 15x15 pencere boyutundaki tekstür değerleri ile toplam rölatif sıra numarası en düşük olduğu (R_j=37,49) ve belirtme katsayısı 0,86 olan modelde elde edilmiştir (Çizelge 4.7)

Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden farklı pencere boyutunda ve derecelerde elde edilen tekstür değerleri kullanılarak meşçere parametrelerinin ÇRA ile modellenmesine ait belirtme katsayılarına ilişkin sonuçlar sırası ile Çizelge 4.5 ve Çizelge 4.6'da verilmiştir. Meşcere parametreleri, YAİ, TÜB ve TÜK'ün uzaktan algılama verileri ile oluşturulan bütün veri setlerinin ÇRA metodu kullanılarak modellenmesine ilişkin performans ölçütlerine ait bulgular Çizelge 4.7'de verilmiştir.

Çizelge 4.5 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı pencere boyutuna ilişkin tekstür değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2)

Veri Seti	Meşcere Parametreleri															
	V		G		N		$h_{üst}$		d_g		YAİ		TÜB		TÜK	
	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2
3×3	0,64	0,80	0,63	0,76	0,65	0,75	0,71	0,77	0,74	0,83	0,46	0,66	0,67	0,81	0,71	0,83
5×5	0,67	0,78	0,65	0,72	0,67	0,72	0,77	0,82	0,76	0,85	0,50	0,69	0,66	0,77	0,68	0,81
7×7	0,71	0,82	0,64	0,75	0,75	0,69	0,80	0,81	0,81	0,83	0,48	0,66	0,70	0,78	0,74	0,83
9×9	0,80	0,84	0,73	0,78	0,77	0,77	0,76	0,82	0,80	0,85	0,55	0,64	0,80	0,81	0,78	0,86
11×11	0,80	0,79	0,77	0,75	0,75	0,70	0,82	0,80	0,87	0,84	0,62	0,58	0,77	0,78	0,84	0,84
13×13	0,82	0,80	0,79	0,78	0,78	0,76	0,80	0,80	0,88	0,87	0,61	0,61	0,81	0,80	0,86	0,86
15×15	0,81	0,82	0,81	0,82	0,68	0,79	0,83	0,80	0,86	0,88	0,62	0,66	0,78	0,83	0,88	0,86

*V: L8: Landsat 8 OLI, S2: Sentinel-2

Çizelge 4.6 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı derece değerleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin belirtme katsayıları (R^2)

Veri Seti	Meşçere Parametreleri															
	V		G		N		$h_{üst}$		d_g		YAİ		TÜB		TÜK	
	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2	L8	S2
0°	0,72	0,75	0,76	0,78	0,65	0,67	0,78	0,81	0,80	0,78	0,61	0,57	0,75	0,76	0,86	0,86
45°	0,68	0,65	0,73	0,68	0,7	0,66	0,74	0,61	0,67	0,76	0,57	0,59	0,71	0,69	0,79	0,68
90°	0,61	0,69	0,80	0,72	0,77	0,72	0,76	0,71	0,80	0,75	0,57	0,52	0,82	0,80	0,77	0,77
135°	0,84	0,72	0,79	0,68	0,76	0,70	0,78	0,68	0,82	0,75	0,59	0,62	0,74	0,65	0,81	0,59

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellerine ilişkin performans ölçütleri

Veri Seti	Meşçere Parametreleri											
	V						G					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Dron D. Number	-	-	-	-	-	-	-	-	-	-	-	-
Dron İndis	0,35	179,07	149,73	5,88	9,19	112,56	0,40	14,87	12,25	3,39	6,70	112,16
Dron Reflektans	0,28	190,42	152,71	6,64	13,25	124,13	0,32	15,98	12,72	2,77	4,77	112,04
Landsat İndis	0,54	0,61	0,50	0,61	8,51	24,36	0,50	0,55	0,48	-0,03	13,28	31,62
Landsat Reflektans	0,55	0,61	0,50	0,60	9,50	24,67	0,48	0,59	0,52	0,38	9,28	32,38
Landsat 0°	0,72	0,47	0,38	1,74	23,25	34,18	0,76	0,32	0,26	1,74	34,85	52,68
Landsat 11×11	0,80	0,39	0,32	1,63	25,06	32,04	0,77	0,31	0,24	1,60	30,83	47,82
Landsat 13×13	0,82	0,37	0,30	1,57	25,01	30,98	0,79	0,30	0,24	1,27	22,78	37,41
Landsat 135°	0,84	0,34	0,27	1,37	13,93	20,96	0,79	0,30	0,25	1,44	26,80	42,38
Landsat 15×15	0,81	0,39	0,29	1,45	21,05	27,86	0,81	0,28	0,22	1,30	24,73	38,40
Landsat 3×3	0,64	0,54	0,44	1,18	11,38	25,50	0,63	0,40	0,33	1,17	15,09	36,74
Landsat 45°	0,68	0,50	0,38	1,78	23,30	35,80	0,73	0,34	0,28	1,62	28,91	47,98
Landsat 5×5	0,67	0,52	0,44	1,14	11,34	24,20	0,65	0,40	0,33	1,15	15,07	36,03
Landsat 7×7	0,71	0,48	0,39	1,46	17,27	28,73	0,64	0,40	0,32	1,16	15,08	36,35
Landsat 9×9	0,80	0,39	0,31	1,88	33,05	39,30	0,73	0,34	0,27	1,33	20,93	39,01
Landsat 90°	0,61	0,56	0,42	1,49	15,41	30,96	0,80	0,30	0,25	1,70	34,81	50,72

Dijital bant değeri: D. Number, Vejetasyon İndis değerleri: İndis, 0°: Tekstür derecesi, 11×11: Tekstür pencere boyutu

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

Veri Seti	Meşçere Parametreleri											
	N						$h_{üst}$					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Dron D. Number	0,06	686,56	535,85	6,53	8,53	127,68	-	-	-	-	-	-
Dron İndis	0,17	639.80	508,45	4,28	6,32	108,54	0,44	5,69	4,45	3,82	17,74	97,60
Dron Reflektans	0,10	0,74	0,61	-0,31	1,69	33,95	-	-	-	-	-	-
Landsat İndis	0,63	0,47	0,36	0,85	10,34	24,13	0,70	0,25	0,21	0,02	16,63	31,50
Landsat Reflektans	0,62	0,48	0,36	0,35	11,86	23,50	0,67	0,84	0,21	1,43	9,82	36,41
Landsat 0°	0,65	0,44	0,35	2,01	33,17	43,63	0,78	0,21	0,16	1,06	26,42	44,94
Landsat 11×11	0,75	0,37	0,27	1,31	19,01	27,15	0,82	0,20	0,15	0,57	16,38	29,89
Landsat 13×13	0,78	0,34	0,25	1,50	24,93	30,82	0,80	0,20	0,15	0,34	15,39	27,92
Landsat 135°	0,76	0,36	0,27	1,87	34,98	40,35	0,78	0,20	0,16	1,18	30,41	49,63
Landsat 15×15	0,68	0,43	0,33	1,35	17,15	28,96	0,83	0,19	0,13	0,81	22,32	37,20
Landsat 3×3	0,65	0,45	0,35	1,27	15,19	28,27	0,71	0,25	0,20	0,22	11,61	27,17
Landsat 45°	0,70	0,41	0,31	1,81	29,10	38,38	0,74	0,22	0,17	1,14	26,50	46,94
Landsat 5×5	0,67	0,43	0,34	1,24	15,17	27,48	0,77	0,22	0,18	0,44	12,49	27,17
Landsat 7×7	0,75	0,36	0,28	1,76	30,99	37,24	0,80	0,20	0,16	0,49	14,41	28,27
Landsat 9×9	0,77	0,36	0,27	1,61	26,98	33,40	0,76	0,22	0,17	0,10	15,49	28,15
Landsat 90°	0,77	0,34	0,26	2,07	44,93	47,50	0,76	0,21	0,16	1,10	26,46	45,80

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

Veri Seti	Meşçere Parametreleri											
	d_g						YAİ					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Dron D. Number	0,03	12,88	11,11	2,56	4,56	122,00	0,18	0,43	0,35	-0,84	1,16	59,72
Dron İndis	0,04	12,81	11,11	2,55	4,55	121,40	0,23	0,42	0,35	-0,18	3,13	65,39
Dron Reflektans	-	-	-	-	-	-	0,22	0,42	0,35	-0,87	1,13	56,25
Landsat İndis	0,73	0,30	0,25	0,39	8,78	27,57	0,47	0,34	0,27	0,03	4,93	44,14
Landsat Reflektans	0,72	0,30	0,26	0,59	10,80	31,35	0,46	0,35	0,27	0,04	4,94	45,14
Landsat 0°	0,80	0,24	0,19	1,35	30,58	50,01	0,61	0,28	0,22	1,61	34,72	72,48
Landsat 11×11	0,87	0,19	0,14	1,00	26,36	40,89	0,62	0,28	0,22	1,04	18,74	50,95
Landsat 13×13	0,88	0,19	0,14	0,93	14,36	30,94	0,61	0,29	0,21	1,31	24,75	59,92
Landsat 135°	0,82	0,23	0,17	1,52	38,52	56,79	0,59	0,29	0,22	1,34	24,77	62,48
Landsat 15×15	0,86	0,20	0,15	1,05	26,41	41,86	0,62	0,28	0,21	1,22	22,73	55,74
Landsat 3×3	0,74	0,29	0,23	0,83	14,76	35,70	0,46	0,34	0,27	0,54	8,93	53,55
Landsat 45°	0,67	0,32	0,24	1,49	26,85	53,15	0,57	0,30	0,23	1,35	24,79	64,91
Landsat 5×5	0,76	0,28	0,23	0,52	10,73	29,19	0,50	0,33	0,25	1,08	16,89	63,07
Landsat 7×7	0,81	0,24	0,19	0,89	18,59	36,48	0,48	0,34	0,27	0,86	12,91	59,84
Landsat 9×9	0,80	0,25	0,18	1,00	20,60	39,05	0,55	0,31	0,24	1,22	20,83	62,94
Landsat 90°	0,80	0,24	0,17	1,61	40,56	59,82	0,57	0,30	0,24	1,28	22,80	63,16

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

Veri Seti	Meşçere Parametreleri											
	TÜB						TÜK					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Dron D. Number	-	-	-	-	-	-	-	-	-	-	-	-
Dron İndis	0,38	65,13	54,46	4,87	8,18	103,92	0,34	88,43	74,79	5,18	8,48	50,02
Dron Reflektans	0,29	69,69	56,34	4,24	6,24	104,84	0,24	95,56	76,72	4,56	6,56	46,09
Landsat İndis	0,53	0,55	0,46	0,51	8,41	25,39	0,43	82,45	66,70	5,51	10,41	51,24
Landsat Reflektans	0,52	0,55	0,46	1,02	9,41	29,07	0,41	83,19	65,86	5,52	10,42	52,13
Landsat 0°	0,75	0,39	0,31	1,46	21,06	30,94	0,86	38,89	30,85	6,49	37,66	59,91
Landsat 11×11	0,77	0,38	0,31	1,32	19,02	28,04	0,84	42,24	31,77	6,31	29,74	52,06
Landsat 13×13	0,81	0,34	0,21	1,33	20,93	27,85	0,86	39,03	30,71	6,23	29,66	49,07
Landsat 135°	0,74	0,40	0,32	1,28	17,08	27,49	0,81	45,07	34,99	6,45	31,81	57,51
Landsat 15×15	0,78	0,36	0,28	1,29	18,99	27,25	0,88	37,64	29,33	6,27	31,63	50,25
Landsat 3×3	0,67	0,45	0,38	1,40	17,20	31,04	0,71	57,47	45,03	6,45	26,05	60,08
Landsat 45°	0,71	0,41	0,33	1,68	25,12	36,31	0,79	48,06	38,31	6,58	33,87	63,05
Landsat 5×5	0,66	0,46	0,39	1,17	13,23	27,48	0,68	60,53	36,15	6,05	18,10	49,45
Landsat 7×7	0,70	0,43	0,35	1,45	19,15	31,50	0,74	54,15	43,43	6,29	23,99	53,95
Landsat 9×9	0,80	0,35	0,29	1,51	24,95	32,01	0,78	49,43	38,14	6,39	27,90	55,74
Landsat 90°	0,82	0,32	0,26	1,99	44,85	47,20	0,77	50,35	38,08	6,40	27,92	56,61

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

Veri Seti	Meşcere Parametreleri											
	V						G					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Sentinel 1 D. Number	0,02	0,88	0,75	-0,13	1,87	34,77	0,04	0,66	0,55	-0,42	1,58	36,61
Sentinel 1 G. Yansıtım	0,07	0,88	0,74	-0,13	1,87	33,04	0,08	0,65	0,54	-0,43	1,57	34,85
Sentinel 2 İndis	0,60	0,57	0,47	1,05	9,44	24,91	0,42	0,59	0,48	0,03	9,34	31,71
Sentinel 2 Reflektans	0,49	0,65	0,53	0,66	5,57	24,24	0,45	0,50	0,42	0,41	7,31	31,56
Sentinel 2 0°	0,75	0,44	0,36	1,58	21,19	30,81	0,78	0,48	0,39	0,75	17,80	30,38
Sentinel 2 11×11	0,79	0,41	0,32	1,05	15,10	22,11	0,75	0,43	0,36	0,70	18,90	31,88
Sentinel 2 13×13	0,80	0,39	0,31	1,15	15,07	22,13	0,78	0,31	0,25	1,04	16,84	31,26
Sentinel 2 135°	0,72	0,45	0,37	2,10	35,21	44,76	0,68	0,37	0,29	1,71	29,00	50,82
Sentinel 2 15×15	0,82	0,38	0,30	1,11	17,03	22,87	0,82	0,28	0,22	1,27	15,71	30,36
Sentinel 2 3×3	0,80	0,39	0,32	1,62	25,05	31,84	0,76	0,32	0,26	1,17	18,87	34,74
Sentinel 2 45°	0,65	0,51	0,41	1,97	27,33	40,76	0,68	0,36	0,29	1,93	36,98	59,30
Sentinel 2 5×5	0,78	0,41	0,33	1,76	27,12	34,71	0,72	0,35	0,28	1,90	36,96	57,29
Sentinel 2 7×7	0,82	0,38	0,29	1,50	23,02	29,30	0,75	0,33	0,27	1,09	16,89	32,94
Sentinel 2 9×9	0,84	0,35	0,28	1,66	28,95	33,72	0,78	0,39	0,35	0,91	16,83	30,52
Sentinel 2 90°	0,69	0,48	0,37	1,97	29,26	40,63	0,72	0,34	0,28	1,69	30,92	50,48

Dijital bant değeri: D. Number, Vejetasyon İndis değerleri: İndis, Geri yansıtım (dB): G. Yansıtım, 0°: Tekstür derecesi, 11×11: Tekstür pencere boyutu

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

Veri Seti	Meşçere Parametreleri											
	N						$h_{üst}$					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Sentinel 1 D. Number	-	-	-	-	-	-	0,02	0,46	0,38	-0,09	3,21	42,91
Sentinel 1 G. Yansıtım	-	-	-	-	-	-	0,09	0,44	0,36	-0,81	1,19	33,81
Sentinel 2 İndis	0,59	0,49	0,39	1,20	5,90	23,84	0,71	0,25	0,19	0,39	10,60	27,12
Sentinel 2 Reflektans	0,66	0,44	0,35	1,27	15,19	27,98	0,69	0,25	0,20	0,57	12,62	31,12
Sentinel 2 0°	0,67	0,43	0,34	1,63	23,15	34,50	0,81	0,19	0,15	0,91	24,35	40,54
Sentinel 2 11×11	0,70	0,42	0,32	1,20	15,13	26,24	0,80	0,20	0,14	0,47	14,39	27,74
Sentinel 2 13×13	0,76	0,37	0,27	1,30	19,00	26,94	0,80	0,20	0,14	0,60	16,40	30,78
Sentinel 2 135°	0,70	0,41	0,33	1,59	23,11	33,33	0,68	0,25	0,20	0,92	18,62	39,78
Sentinel 2 15×15	0,79	0,34	0,25	1,47	14,91	23,40	0,80	0,20	0,15	0,47	14,39	27,78
Sentinel 2 3×3	0,75	0,38	0,29	1,22	17,02	25,55	0,77	0,22	0,17	0,66	16,47	32,63
Sentinel 2 45°	0,66	0,43	0,35	1,65	23,16	35,00	0,61	0,28	0,22	0,82	14,74	38,20
Sentinel 2 5×5	0,72	0,40	0,29	1,56	23,08	32,33	0,82	0,19	0,14	0,40	14,32	26,58
Sentinel 2 7×7	0,69	0,42	0,31	1,21	15,13	26,42	0,81	0,19	0,14	0,76	20,36	35,40
Sentinel 2 9×9	0,77	0,36	0,26	1,53	24,97	31,66	0,82	0,19	0,14	0,73	20,33	34,83
Sentinel 2 90°	0,72	0,39	0,31	1,63	25,07	34,04	0,71	0,24	0,19	0,78	16,58	35,79

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

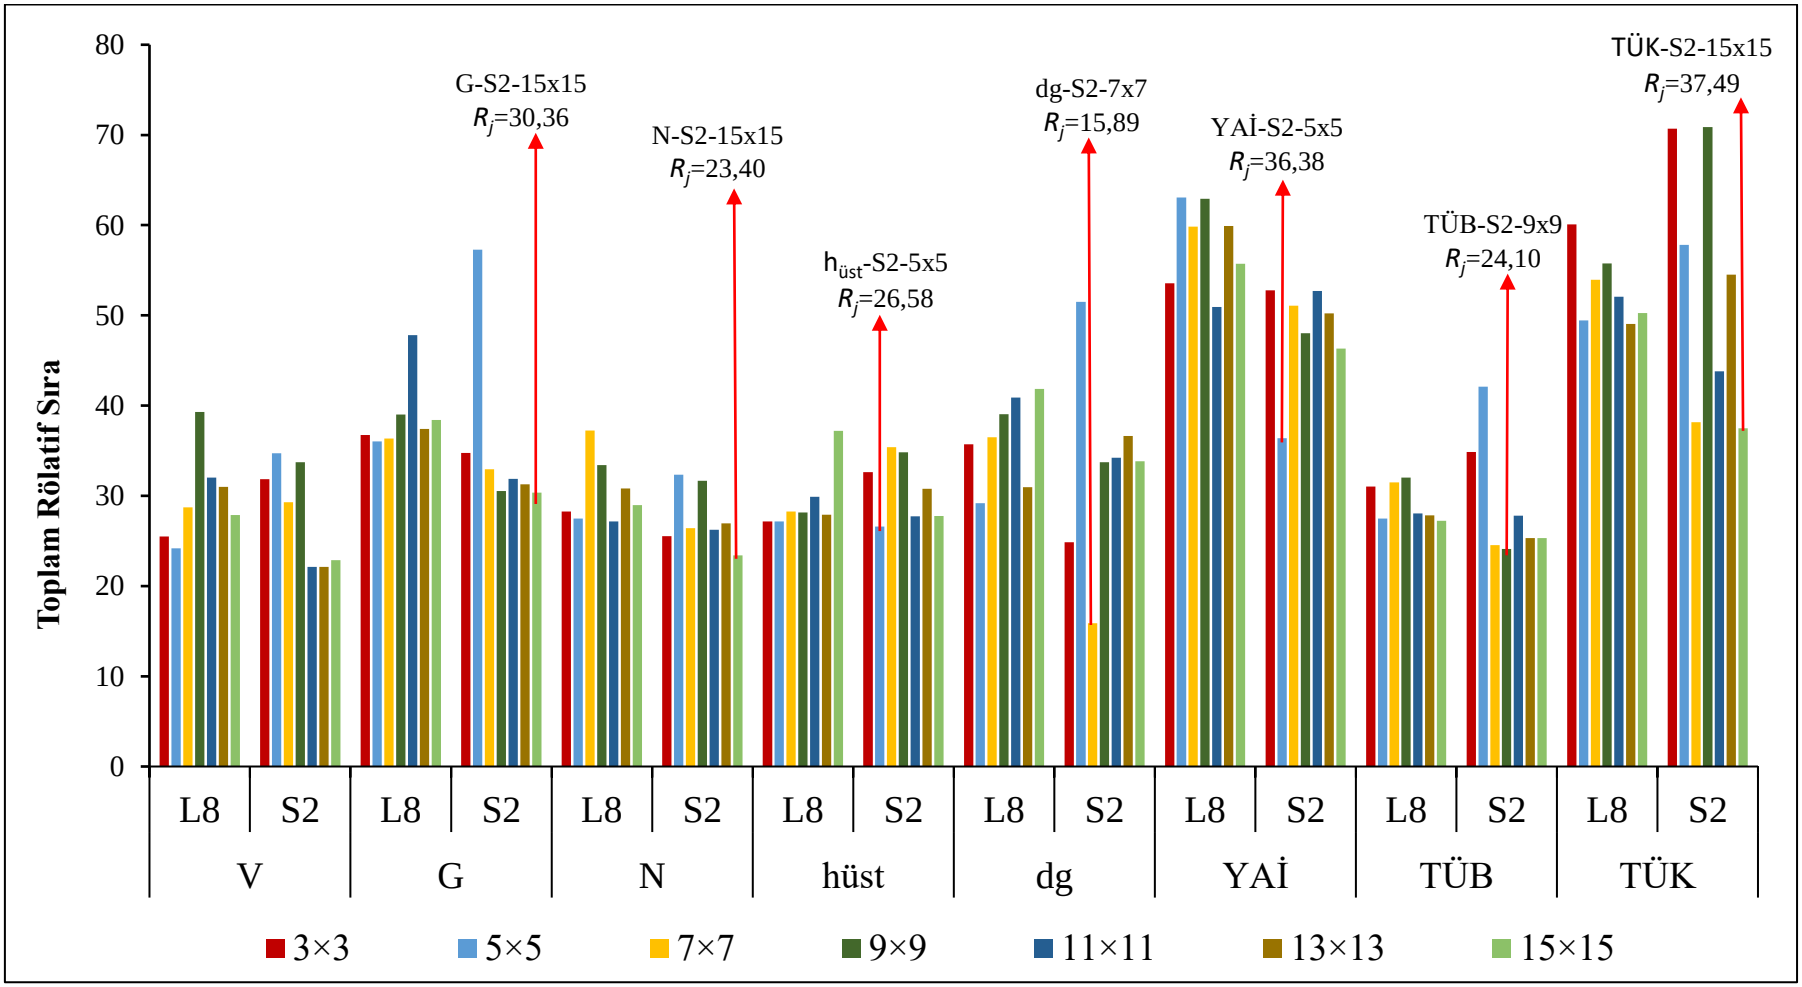
Veri Seti	Meşçere Parametreleri											
	d_g						YAİ					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Sentinel 1 D. Number	0,03	0,56	0,48	0,12	3,43	46,43	-	-	-	-	-	-
Sentinel 1 G. Yansıtım	0,08	0,55	0,47	-0,60	1,40	36,66	0,09	0,45	0,36	-0,79	1,21	67,26
Sentinel 2 İndis	0,66	0,33	0,27	0,28	6,89	27,57	0,58	0,30	0,24	0,60	10,81	44,92
Sentinel 2 Reflektans	0,70	0,31	0,26	0,90	14,82	37,75	0,58	0,30	0,24	0,20	9,81	38,30
Sentinel 2 0°	0,78	0,26	0,20	1,20	24,64	44,80	0,57	0,30	0,24	1,19	20,80	60,89
Sentinel 2 11×11	0,84	0,22	0,16	0,79	18,49	34,21	0,58	0,30	0,23	0,99	16,79	52,70
Sentinel 2 13×13	0,87	0,20	0,15	0,86	22,38	36,64	0,61	0,29	0,23	0,96	16,76	50,22
Sentinel 2 135°	0,75	0,27	0,21	1,34	26,70	48,58	0,62	0,28	0,22	1,37	26,73	62,37
Sentinel 2 15×15	0,88	0,19	0,14	0,75	20,35	33,83	0,66	0,27	0,21	0,99	18,69	46,33
Sentinel 2 3×3	0,83	0,05	0,18	-0,49	21,02	24,85	0,66	0,27	0,22	1,17	22,68	52,79
Sentinel 2 45°	0,76	0,26	0,21	1,56	34,67	56,41	0,59	0,29	0,22	1,17	20,77	56,96
Sentinel 2 5×5	0,85	0,22	0,17	1,37	34,48	51,50	0,69	0,25	0,20	1,03	10,63	36,38
Sentinel 2 7×7	0,83	0,05	0,18	-0,84	13,08	15,89	0,66	0,27	0,20	1,16	22,68	51,07
Sentinel 2 9×9	0,85	0,22	0,16	0,77	18,47	33,73	0,64	0,28	0,21	1,02	18,72	48,02
Sentinel 2 90°	0,75	0,28	0,22	1,28	24,72	46,81	0,52	0,32	0,26	0,94	14,86	58,11

Çizelge 4.7 Landsat 8 OLI, Sentinel-1, Sentinel-2 ve dron görüntülerinden elde edilen bütün veri setleri ile meşcere parametreleri için uygulanan ÇRA modellere ilişkin performans ölçütleri (devam)

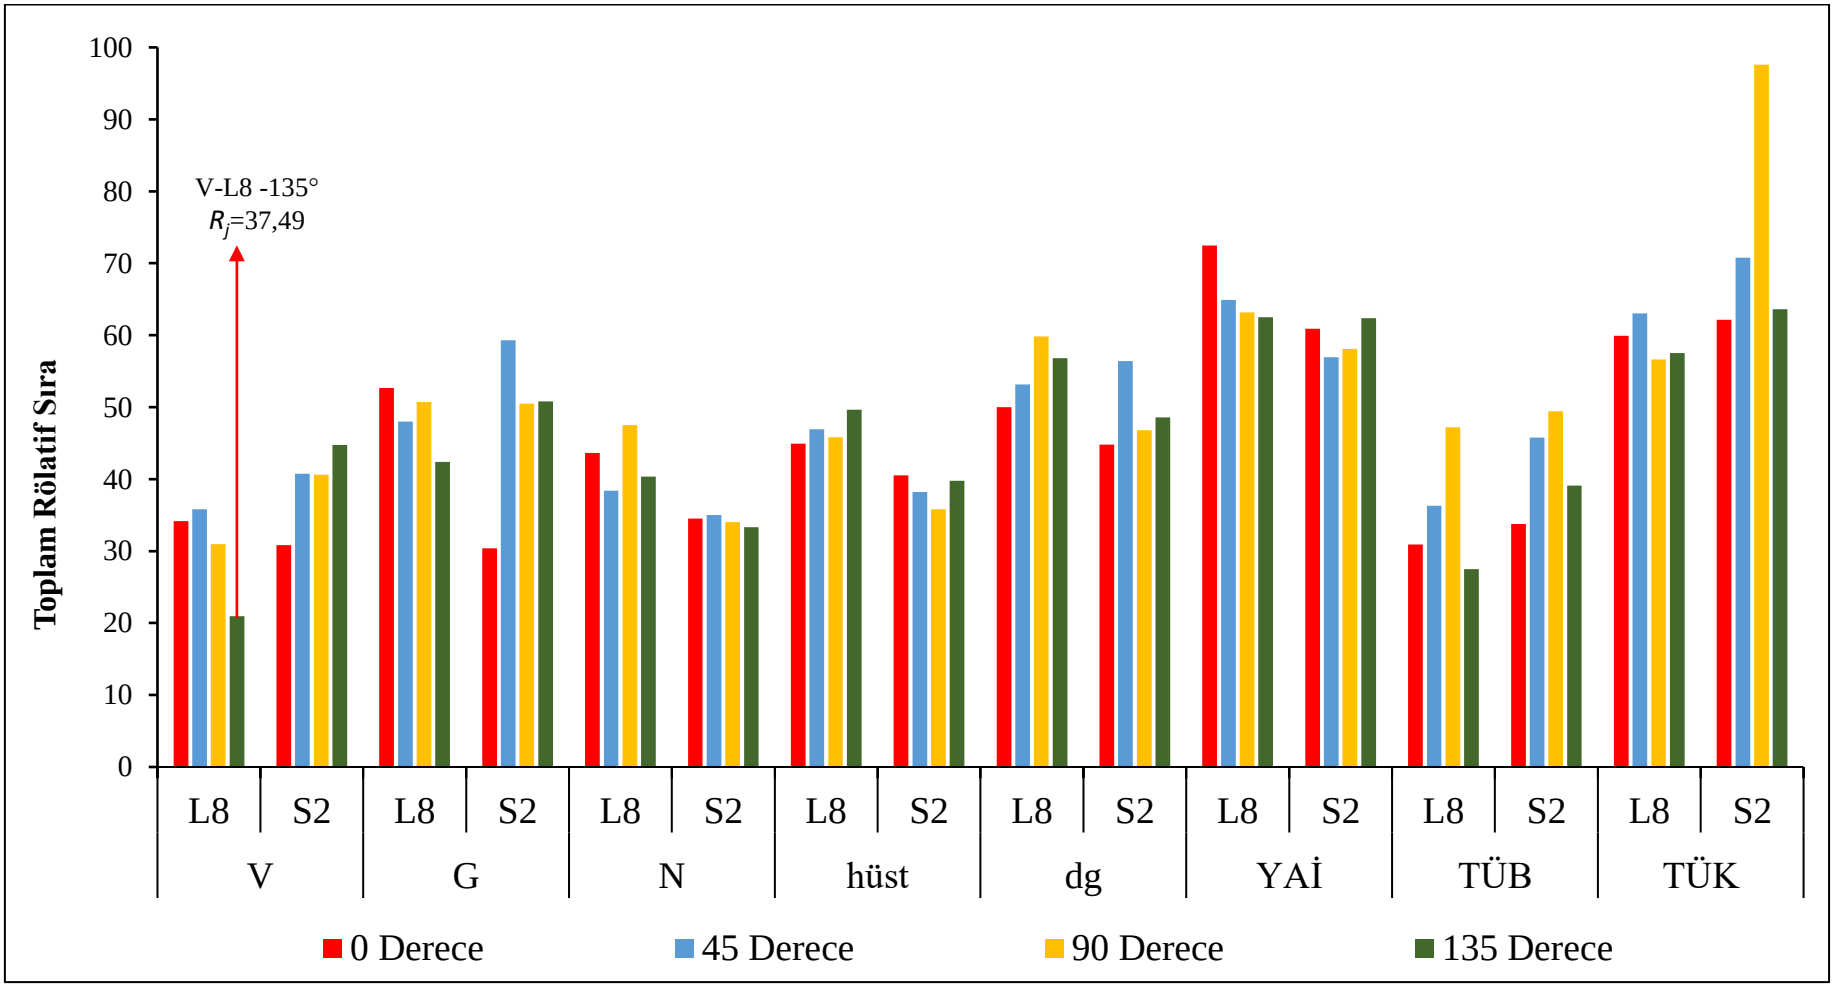
Veri Seti	Meşçere Parametreleri											
	TÜB						TÜK					
	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
Sentinel 1 D. Number	0,03	0,78	0,66	-0,25	1,75	35,41	0,03	104,03	86,55	4,64	6,64	57,26
Sentinel 1 G. Yansıtım	0,07	0,78	0,65	-0,25	1,75	33,60	0,04	106,78	87,48	4,67	6,67	57,89
Sentinel 2 İndis	0,58	0,51	0,42	1,12	11,33	28,85	0,64	78,59	50,55	6,44	20,36	63,96
Sentinel 2 Reflektans	0,47	0,58	0,48	0,56	5,46	25,90	0,41	83,45	67,98	5,52	10,42	52,39
Sentinel 2 0°	0,76	0,38	0,31	1,59	25,02	33,79	0,86	38,51	31,02	6,54	39,65	62,14
Sentinel 2 11×11	0,78	0,37	0,29	0,94	23,00	27,79	0,84	43,10	32,66	6,07	23,76	43,79
Sentinel 2 13×13	0,80	0,36	0,28	1,05	18,97	25,31	0,86	38,88	30,51	6,37	33,66	54,52
Sentinel 2 135°	0,65	0,45	0,35	1,78	25,21	39,11	0,59	68,04	51,93	6,42	22,22	63,63
Sentinel 2 15×15	0,83	0,32	0,25	1,50	16,86	25,31	0,86	39,74	31,17	5,88	21,68	37,49
Sentinel 2 3×3	0,81	0,34	0,28	1,62	28,91	34,86	0,83	54,66	32,73	6,83	38,00	70,69
Sentinel 2 45°	0,69	0,42	0,35	2,03	35,13	45,77	0,68	59,35	45,29	6,72	32,08	70,76
Sentinel 2 5×5	0,77	0,38	0,31	1,92	35,03	42,09	0,81	45,63	29,40	6,46	31,82	57,83
Sentinel 2 7×7	0,78	0,37	0,29	0,94	18,00	24,52	0,83	44,19	33,57	5,87	19,79	38,17
Sentinel 2 9×9	0,81	0,35	0,28	1,14	16,94	24,10	0,86	38,79	28585,00	6,22	29,66	70,87
Sentinel 2 90°	0,80	0,33	0,25	2,06	46,88	49,44	0,77	50,07	38917,00	6,69	35,91	97,62

4.3. ÇRA Metodunda En Yüksek Başarıyı Sağlayan Modeller

Uygulanan ÇRA metoduna ait başarı ölçütleri incelendiğinde uzaktan algılama veri setlerinde en yüksek başarı tekstür veri setleri ile elde edilmiştir. Özellikle veri setinin farklı derece ve pencere boyutu bakımından çeşitlendirilmesi model sonuçlarının başarısına büyük oranda katkı sağlamıştır. Farklı filtreler kullanılarak meşcere hacmi için en yüksek başarı Landsat 8 OLI uydu görüntüsüne ait 135° ile elde edilmiştir (R^2=0,82). Diğer bütün parametreler için en yüksek başarı farklı pencere boyutlarında üretilen tekstür değerleri ile elde edilmiştir. Meşcere göğüs yüzeyi için en yüksek belirtme katsayısı Sentinel-2 uydu görüntüsü kullanılarak elde edilen 15×15 pencere boyutunda elde edilmiştir (R^2=0,82). Benzer şekilde meşcere ağaç sayısı için en yüksek belirtme katsayısı Sentinel-2 uydu görüntüsü kullanılarak elde edilen 15×15 pencere boyutunda (R^2=0,79), meşcere üst boyu için en yüksek belirtme katsayısı Sentinel-2 görüntüsünden elde edilen 5×5 pencere boyutunda (R^2=0,82), meşcere orta çapı için en yüksek belirtme katsayısı Sentinel-2 görüntüsünden elde edilen 7×7 pencere boyutunda (R^2=0,83), yaprak alan indeksi için en yüksek belirtme katsayısı Sentinel-2 uydu görüntüsü kullanılarak elde edilen 5×5 pencere boyutunda (R^2=0,69), topraküstü biyokütle için en yüksek belirtme katsayısı Sentinel-2 uydu görüntüsü kullanılarak elde edilen 9×9 pencere boyutunda (R^2=0,81) ve son olarak topraküstü karbon için en yüksek belirtme katsayısı da yine Sentinel-2 görüntüsünden elde edilen 15×15 pencere boyutunda (R^2=0,86) elde edilmiştir. ÇRA metodunda elde edilen bütün modellere ilişkin toplam rölatif sıra grafikleri pencere boyutu ve dereceler için sırası ile Şekil 4.4 ve 4.5'te verilmiştir.



Şekil 4.4 ÇRA metodu kullanılarak farklı pencere boyutlarına göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerine ilişkin toplam rölatif sıra (R_j) (Landsat 8 OLI: L8, Sentinel-2: S2)



Şekil 4.5 ÇRA metodu kullanılarak farklı derecelere göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerine ilişkin toplam rölatif sıra (R_j) (Landsat 8 OLI: L8, Sentinel-2: S2)

Çizelge 4.8-4.15'te en yüksek başarıya sahip ÇRA modelleri ve modele giren bağımsız değişkenlerin önem düzeyleri verilmiştir. Modellerdeki bütün bağımsız değişkenler anlamlıdır ($p<0,05$). Bağımsız değişkenler, birbirinden ayırt edilebilmeleri için tekstür ismi, kullanılan bant, uygulanan pencere boyutu ve derece sırası ile kodlanmıştır.

Çizelge 4.8 Landsat 8 OLI uydu görüntüsünden 135° tekstür verileri ile elde edilen meşcere hacim modeli

Bağımsız değişken	**Katsayı**	**t**	**Önem düzeyi (p)**
(Sabit katsayı)	-11,875	-1,582	0,041
VAR_L2_15_135	2,519	3,874	0,000
M_L5_11_135	-0,303	-4,885	0,000
COR_L4_13_135	1,687	3,557	0,001
COR_L2_13_135	-0,988	-2,445	0,016
COR_L3_5_135	0,161	1,710	0,050
ENT_L7_13_135	-2,053	-6,338	0,000
SM_L7_13_135	-5,286	-6,076	0,000
CONT_L2_7_135	0,955	2,737	0,007
VAR_L2_13_135	-1,622	-2,839	0,005
COR_L6_5_135	0,544	3,522	0,001
VAR_L6_13_135	0,126	4,141	0,000
M_L4_15_135	3,095	8,066	0,000
SM_L3_13_135	1,973	5,121	0,000
DİS_L6_11_135	8,452	2,755	0,007
SM_L6_7_135	-4,911	-4,498	0,000
HOM_L6_11_135	19,349	2,929	0,004
ENT_L6_5_135	-0,766	-4,024	0,000
DİS_L7_7_135	0,574	1,976	0,050
M_L3_15_135	-1,258	-2,845	0,005
HOM_L4_13_135	5,750	3,201	0,002
CONT_L6_11_135	-0,797	-2,191	0,030

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation, VAR_L2_15_135: Landsat 8 OLI 2.bantın 15×15 pencere boyutunda ve 135° tekstür verilerine ilişkin varyans değeri

Çizelge 4.9 Sentinel-2 uydu görüntüsünden 15x15 pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere göğüs yüzeyi modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	-2,113	-1,675	0,056
CON_S5_15_0	-0,908	-1,861	0,055
CON_S8A_15_0	0,745	8,592	0,000
CON_S12_15_45	0,282	11,223	0,000
HOM_S7_15_135	2,559	4,742	0,000
CON_S5_15_135	0,430	5,445	0,000
CON_S11_15_0	-0,309	-5,553	0,000
CON_S8_15_135	1,197	5,481	0,000
SM_S5_15_0	1,732	4,889	0,000
SM_S7_15_0	-3,627	-4,593	0,000
HOM_S6_15_0	4,922	3,572	0,000
DİS_S8_15_135	-2,259	-4,365	0,000
M_S7_15_90	-0,115	-4,188	0,000
M_S4_15_45	0,443	2,545	0,012

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Çizelge 4.10 Sentinel-2 uydu görüntüsünden 15x15 f pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere ağaç sayısı modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	5,748	5,521	0,000
M_S8_15_0	0,664	10,511	0,000
M_S11_15_45	-0,718	-9,282	0,000
CON_S11_15_0	0,214	2,762	0,007
SM_S12_15_45	4,789	5,337	0,000
M_S5_15_45	1,499	5,380	0,000
ENT_S12_15_45	0,607	2,986	0,003
COR_S8_15_45	-0,607	-2,934	0,004
M_S4_15_45	-1,160	-4,463	0,000
VAR_S4_15_0	1,635	5,420	0,000
CON_S6_15_0	-0,892	-2,890	0,004
VAR_S8_15_135	0,123	2,938	0,004
HOM_S11_15_0	-3,796	-3,175	0,002
DİS_S7_15_135	-0,366	-2,326	0,022

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Çizelge 4.11 Sentinel-2 uydu görüntüsünden 5x5 pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere üst boy modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	4,040	2,538	0,012
M_S5_5_45	-0,549	-14,158	0,000
M_S6_5_45	0,769	12,595	0,000
SM_S7_5_45	-1,910	-4,228	0,000
DİS_S7_5_0	-1,591	-5,488	0,000
HOM_S4_5_135	7,304	7,739	0,000
ENT_S7_5_45	-0,471	-3,053	0,003
DİS_S6_5_135	0,659	4,178	0,000
HOM_S4_5_90	-5,486	-3,562	0,001
VAR_S4_5_135	0,499	6,132	0,000
VAR_S7_5_45	-0,163	-3,696	0,000
HOM_S5_5_135	1,668	3,296	0,001
DİS_S4_5_45	-0,878	-2,062	0,041

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Çizelge 4.12 Sentinel-2 uydu görüntüsünden 7x7 pencere boyutuna ilişkin tekstür verileri ile elde edilen meşcere orta çap modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	0,290	0,306	0,058
M_S7_7_45	-0,635	-2,109	0,037
M_S5_7_45	-0,664	-14,682	0,000
HOM_S6_7_45	4,484	6,693	0,000
M_S6_7_90	1,432	7,099	0,000
CON_S6_7_90	0,377	10,066	0,000
ENT_S7_7_0	-1,596	-9,286	0,000
HOM_S4_7_135	5,399	7,602	0,000
DİS_S5_7_0	0,513	3,365	0,001
SM_S4_7_0	-0,806	-2,961	0,004
SM_S6_7_0	-2,705	-4,229	0,000
SM_S7_7_0	-3,050	-6,196	0,000
COR_S3_7_135	0,301	3,389	0,001
DİS_L2_13_135	0,755	2,715	0,007

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Çizelge 4.13 Sentinel-2 uydu görüntüsünden 5x5 pencere boyutuna ilişkin tekstür verileri ile elde edilen yaprak alan indeksi modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	-0,293	-0,794	0,429
M_S8_5_0	0,239	5,477	0,000
M_S11_5_45	-0,283	-12,266	0,000
VAR_S12_5_0	0,095	3,584	0,000
DİS_S7_5_135	-0,220	-2,206	0,029
ENT_S5_5_0	0,234	3,839	0,000
CON_S5_5_135	0,699	5,361	0,000
SM_S7_5_45	1,442	3,409	0,001
CON_S8_5_90	0,614	5,212	0,000
HOM_S8_5_45	1,497	4,232	0,000
DİS_S11_5_135	-0,375	-4,005	0,000
COR_S5_5_45	-0,176	-2,351	0,020
COR_S8A_5_90	0,283	2,534	0,012
DİS_S8_5_0	-0,500	-2,706	0,008
SM_S8A_5_0	-0,702	-2,302	0,023
M_S7_5_0	0,094	2,491	0,014

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation, CON_S5_5_135: Sentinel-2 5.bantın 5×5 pencere boyutunda ve 135° tekstür verilerine ilişkin contras değeri

Çizelge 4.14 Sentinel-2 uydu görüntüsünden 9x9 pencere boyutuna ilişkin tekstür verileri ile elde edilen topraküstü biyokütle modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	3,815	7,098	0,000
M_S12_9_45	0,280	3,472	0,001
CON_S5_9_0	-1,525	-2,278	0,024
CON_S8A_9_0	0,621	4,691	0,000
CON_S5_9_45	0,812	5,531	0,000
CON_S5_9_135	0,262	2,777	0,006
COR_S5_9_135	0,501	2,586	0,011
M_S7_9_45	-0,459	-6,875	0,000
M_S7_9_0	0,458	5,709	0,000
DİS_S11_9_0	-0,975	-3,218	0,002
CON_S8_9_135	1,080	4,206	0,000
SM_S12_9_90	0,914	2,157	0,033
HOM_S7_9_90	1,469	3,330	0,001
DİS_S8_9_135	-1,810	-3,058	0,003
CON_S6_9_0	-0,947	-2,100	0,038

M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Çizelge 4.15 Sentinel-2 uydu görüntüsünden 15x15 pencere boyutuna ilişkin tekstür verileri ile elde edilen topraküstü karbon modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	-3500,740	-8,807	0,000
COR_S2_15_90	192,946	6,298	0,000
SM_S5_15_135	-2010,659	-4,265	0,000
CON_S6_15_0	-91,207	-3,802	0,000
COR_S5_15_90	-300,979	-6,092	0,000
SM_S7_15_0	-512,740	-9,566	0,000
HOM_S4_15_135	3599,181	9,218	0,000
M_S7_15_135	98,795	4,633	0,000
DİS_S4_15_135	1148,961	7,969	0,000
CON_S6_15_45	52,021	10,808	0,000
VAR_S2_15_0	-131,609	-1,932	0,055
SM_S5_15_0	3034,135	6,547	0,000
DİS_S4_15_0	632,743	4,802	0,000
SM_S3_15_90	236,889	8,673	0,000
CON_S7_15_0	-197,697	-3,841	0,000

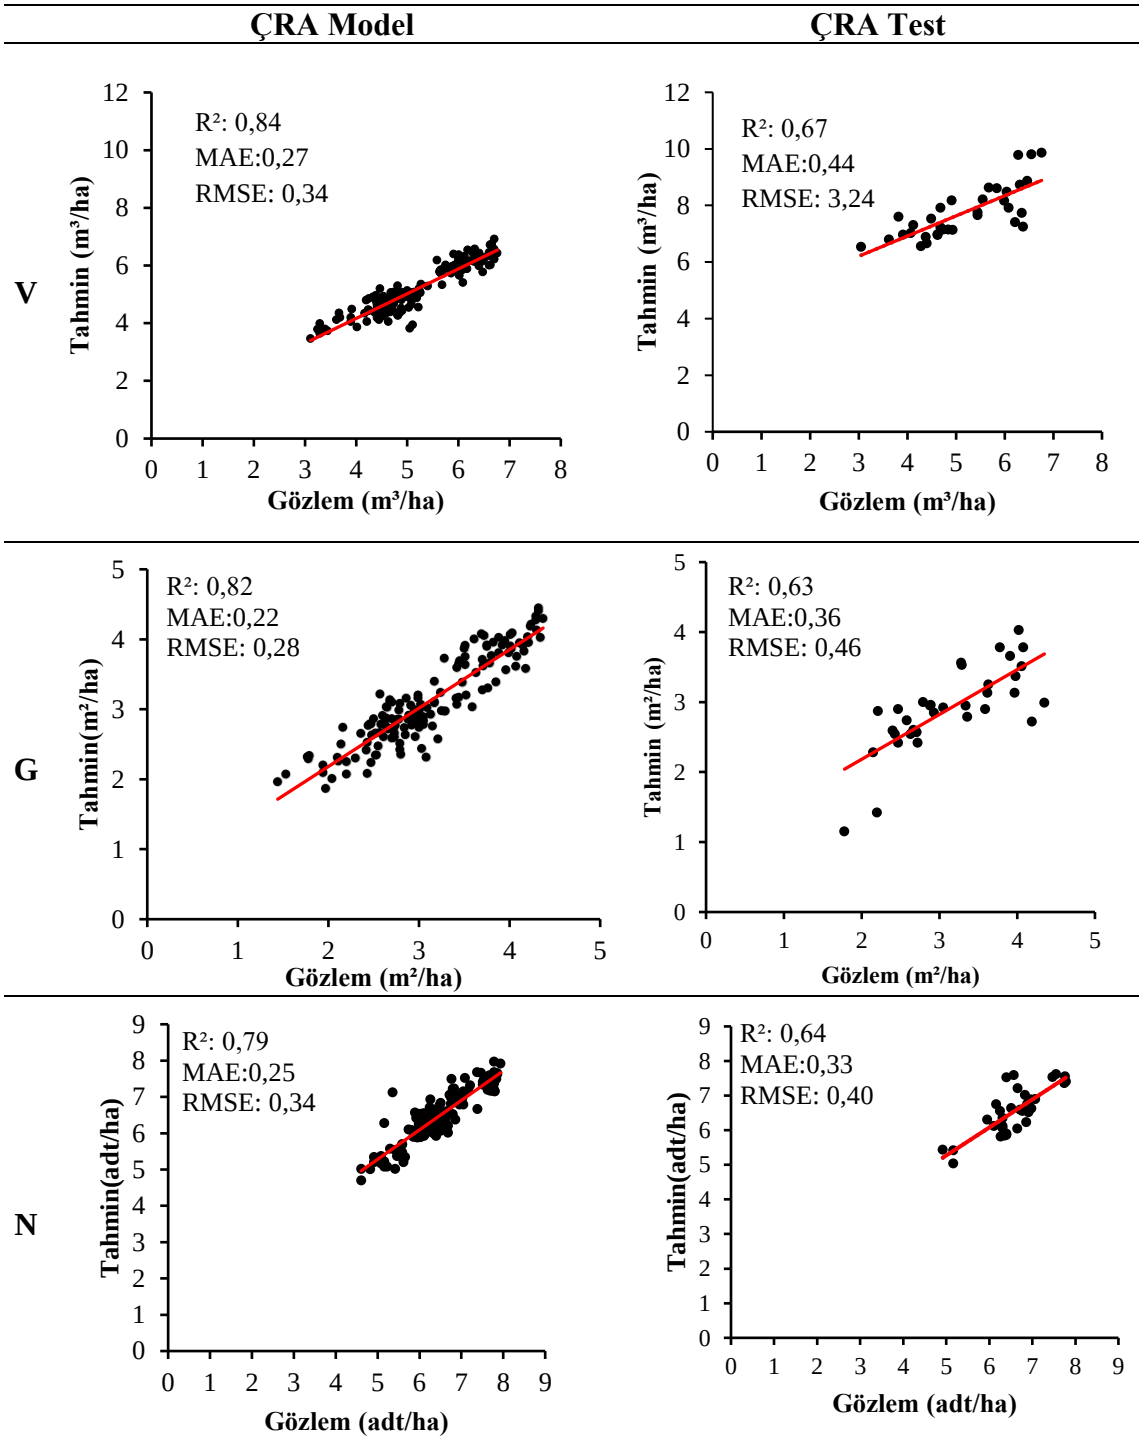
M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Model-test veri setlerine uygulanan ÇRA modellerine ait tahmin ve gözlem grafikleri Şekil 4.6'da ve ÇRA modellerine ait tahmin ve gözlem performans ölçütleri Çizelge 4.16'te verilmiştir. Çizelge 4.16 incelendiğinde genel olarak meşçere parametrelerinin tamamı model-test standart hataların normal dağılım gösterdiği görülmektedir. En yüksek belirtme katsayısının da TÜK'de olduğu görülmektedir (Model R^2= 0,86, Test R^2=0,82). Daha sonra en yüksek belirtme katsayısı meşcere hacmi için elde edilmiştir (Model R^2= 0,84, Test R^2=0,67). ÇRA modelde en düşük belirtme katsayısı ise YAİ de görülmektedir (Model R^2= 0,69, Test R^2=0,17). Meşcere orta çapı, göğüs yüzeyi, ağaç sayısı, üst boyu ve topraküstü karbona ilişkin model ve test belirtme katasıları sırası ile 0,83-0,81, 0,82-0,63, 0,79-0,64, 0,82-0,81 ve 0,81-0,84 elde edilmiştir. En düşük model tahmininin hatası ise meşcere üst boyu ve meşcere orta çapı için elde edilmiştir (RMSE ($h_{üst}$)= 0,19 m, RMSE (dg)= 0,05 cm).

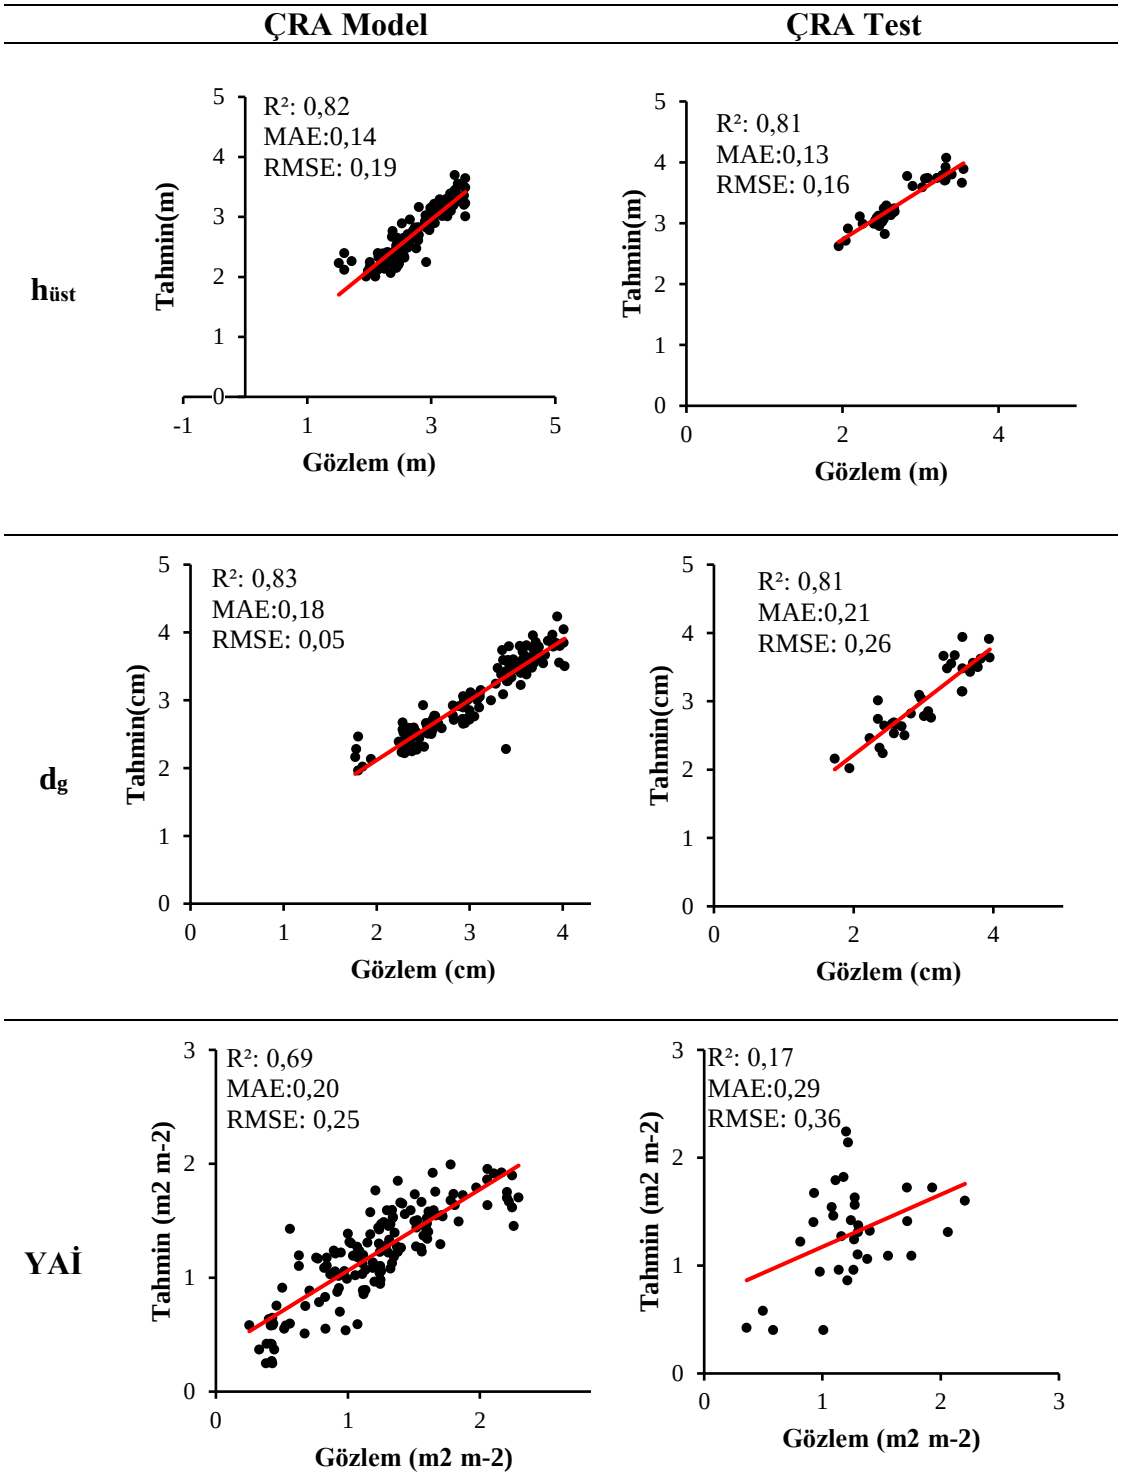
Çizelge 4.16 ÇRA metodu ile elde edilen meşçere parametrelerine ait model – test performans ölçütleri

ÇRA Model Performans Ölçütleri														
Meşcere Parametreleri	**Model**							**Test**						**Veri Seti**
	R^2	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Toplam Rölatif Sıra**	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	
V (m^3/ha)	0,84	0,34	0,27	1,37	13,93	$-2{,}31\times10^{-15}$	20,96	0,67	3,24	0,44	4,22	43,18	$2{,}14\times10^{-15}$	**Landsat OLI 135°**
G (m^2/ha)	0,82	0,28	0,22	1,27	15,71	$-8{,}86\times10^{-15}$	30,36	0,63	0,46	0,36	1,78	25,21	$-4{,}20\times10^{-16}$	**Sentinel-2 15x15**
N (adet/ha)	0,79	0,34	0,25	1,47	14,91	$8{,}35\times10^{-15}$	23,40	0,64	0,40	0,33	1,65	25,08	$-2{,}79\times10^{-15}$	**Sentinel-2 15x15**
$h_{üst}$ (m)	0,82	0,19	0,14	0,40	14,32	$-3{,}26\times10^{-14}$	26,58	0,81	0,16	0,13	0,66	22,17	$1{,}59\times10^{-15}$	**Sentinel-2 5x5**
d_g (cm)	0,83	0,05	0,18	-0,84	13,08	$3{,}15\times10^{-14}$	15,89	0,81	0,26	0,21	1,20	24,64	$1{,}33\times10^{-15}$	**Sentinel-2 7x7**
YAİ (m^2 m^{-2})	0,69	0,25	0,20	1,03	10,63	$1{,}88\times10^{-15}$	36,38	0,17	0,36	0,29	1,67	28,96	$1{,}94\times10^{-16}$	**Sentinel-2 5x5**
TÜB (ton/ha)	0,81	0,35	0,28	1,14	16,94	$-5{,}56\times10^{-15}$	24,10	0,84	0,33	0,27	1,54	26,90	$6{,}11\times10^{-15}$	**Sentinel-2 9x9**
TÜK (ton/ha)	0,86	39,74	31,17	5,88	21,68	$-7{,}38\times10^{-14}$	37,49	0,82	46,75	38,24	6,48	31,84	$7{,}13\times10^{-16}$	**Sentinel-2 15x15**

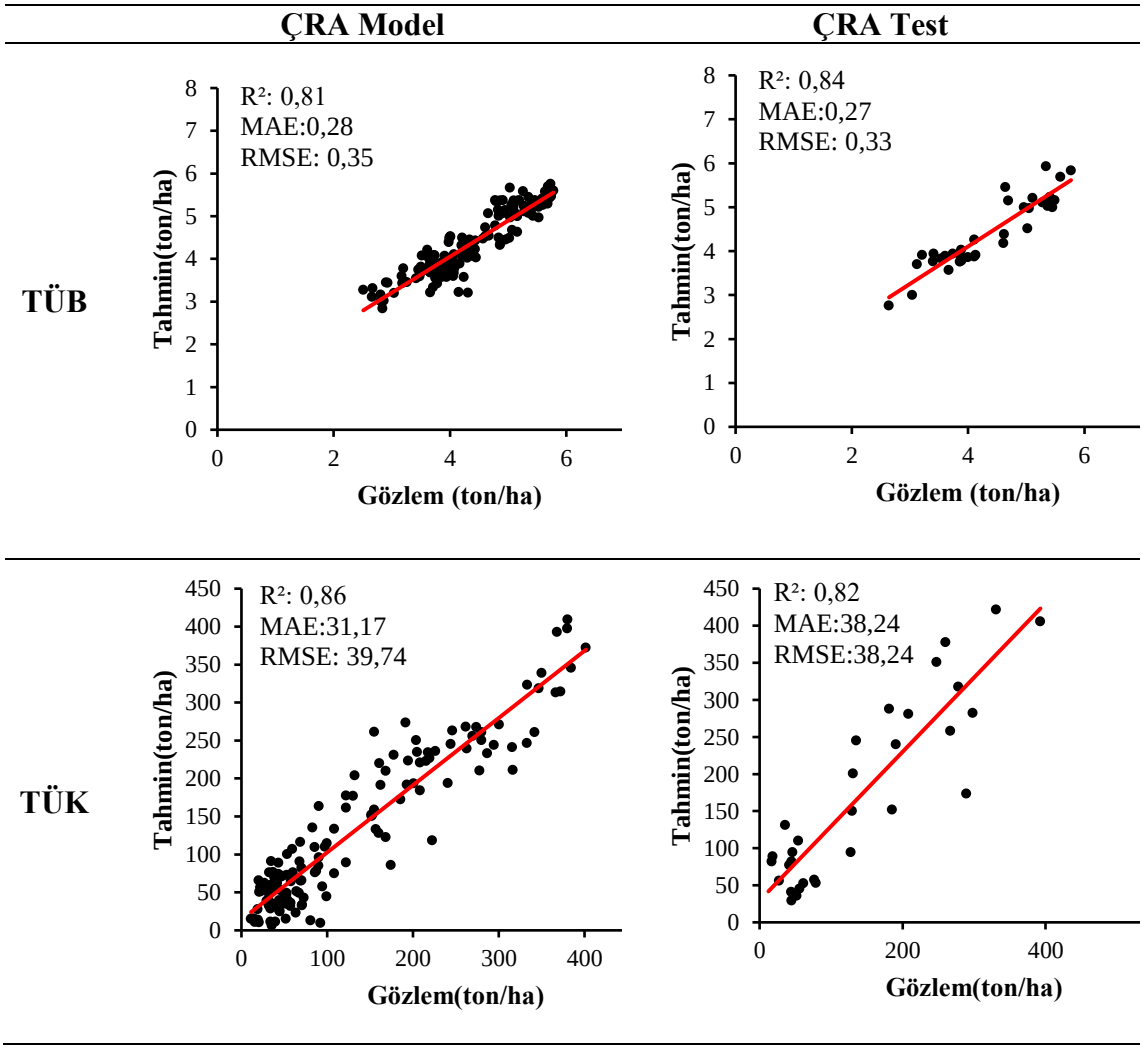
Meşcere hacmi: V, Meşcere göğüs yüzeyi: G, Meşcere ağaç sayısı: N, Meşcere üst boyu: $h_{üst,}$ Meşcere orta çapı: dg, Yaprak alan indeksi: YAİ, Topraküstü biyokütle: TÜB ve Topraküstü karbon: TÜK, 0°: derece, 11×11: pencere boyutu



Şekil 4.6 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri

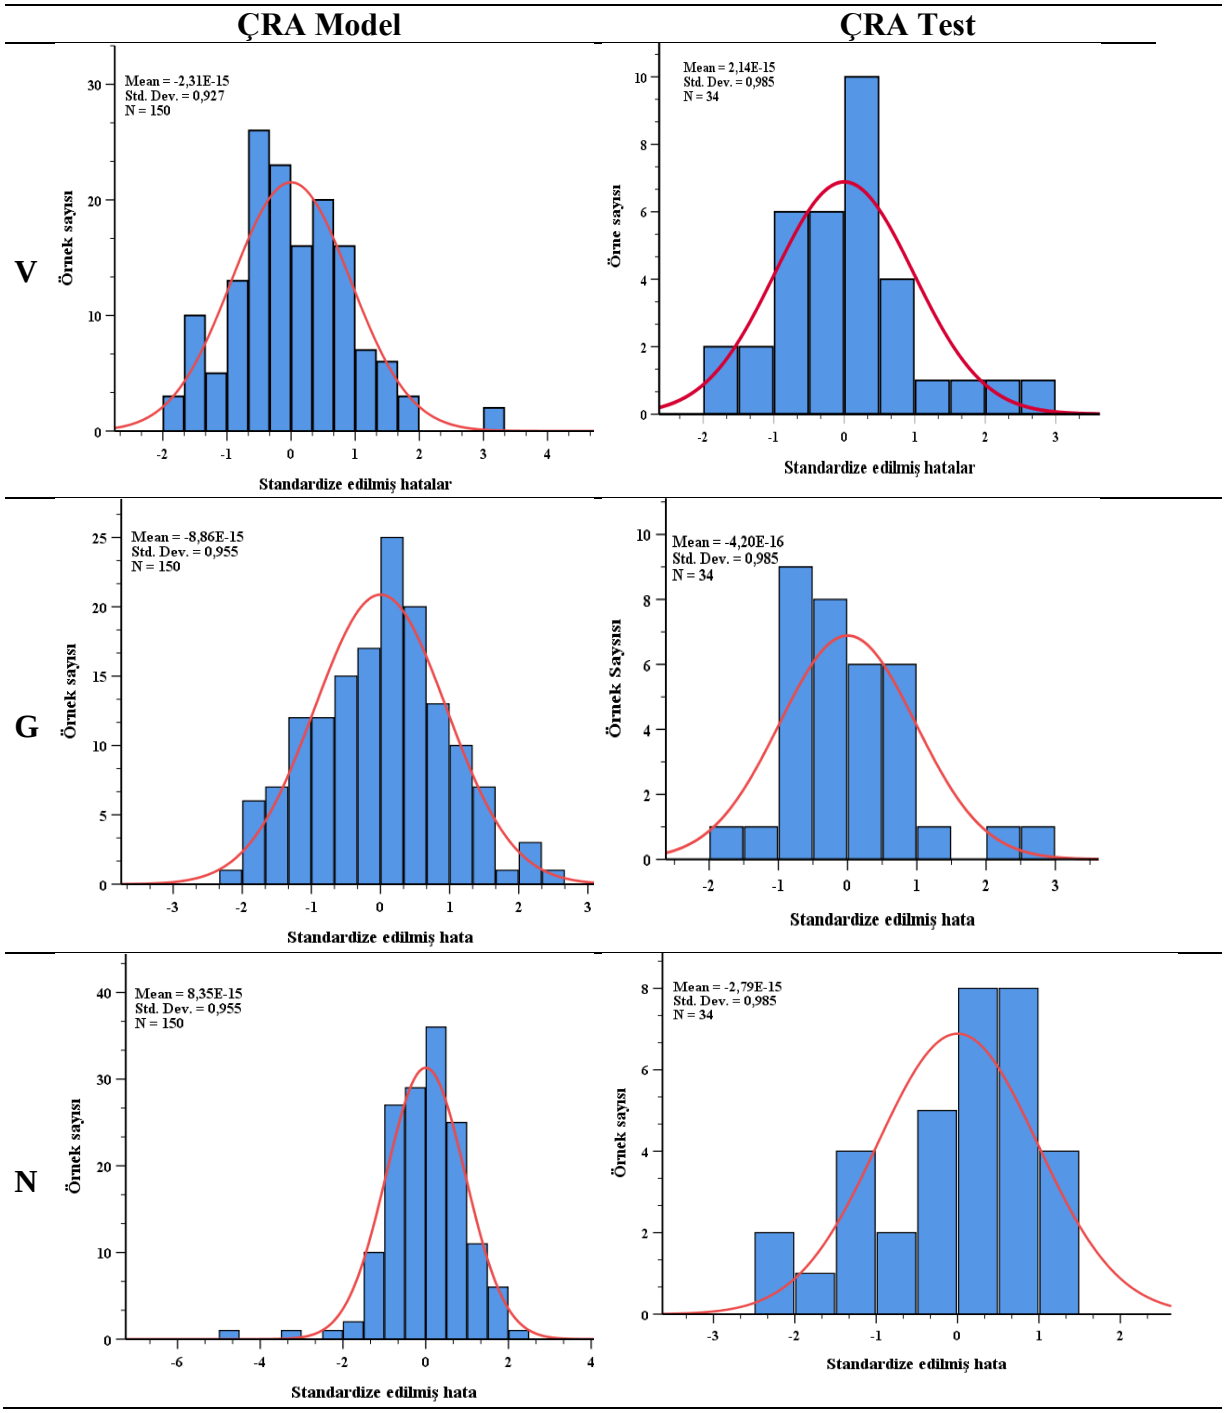


Şekil 4.6 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri (devam)

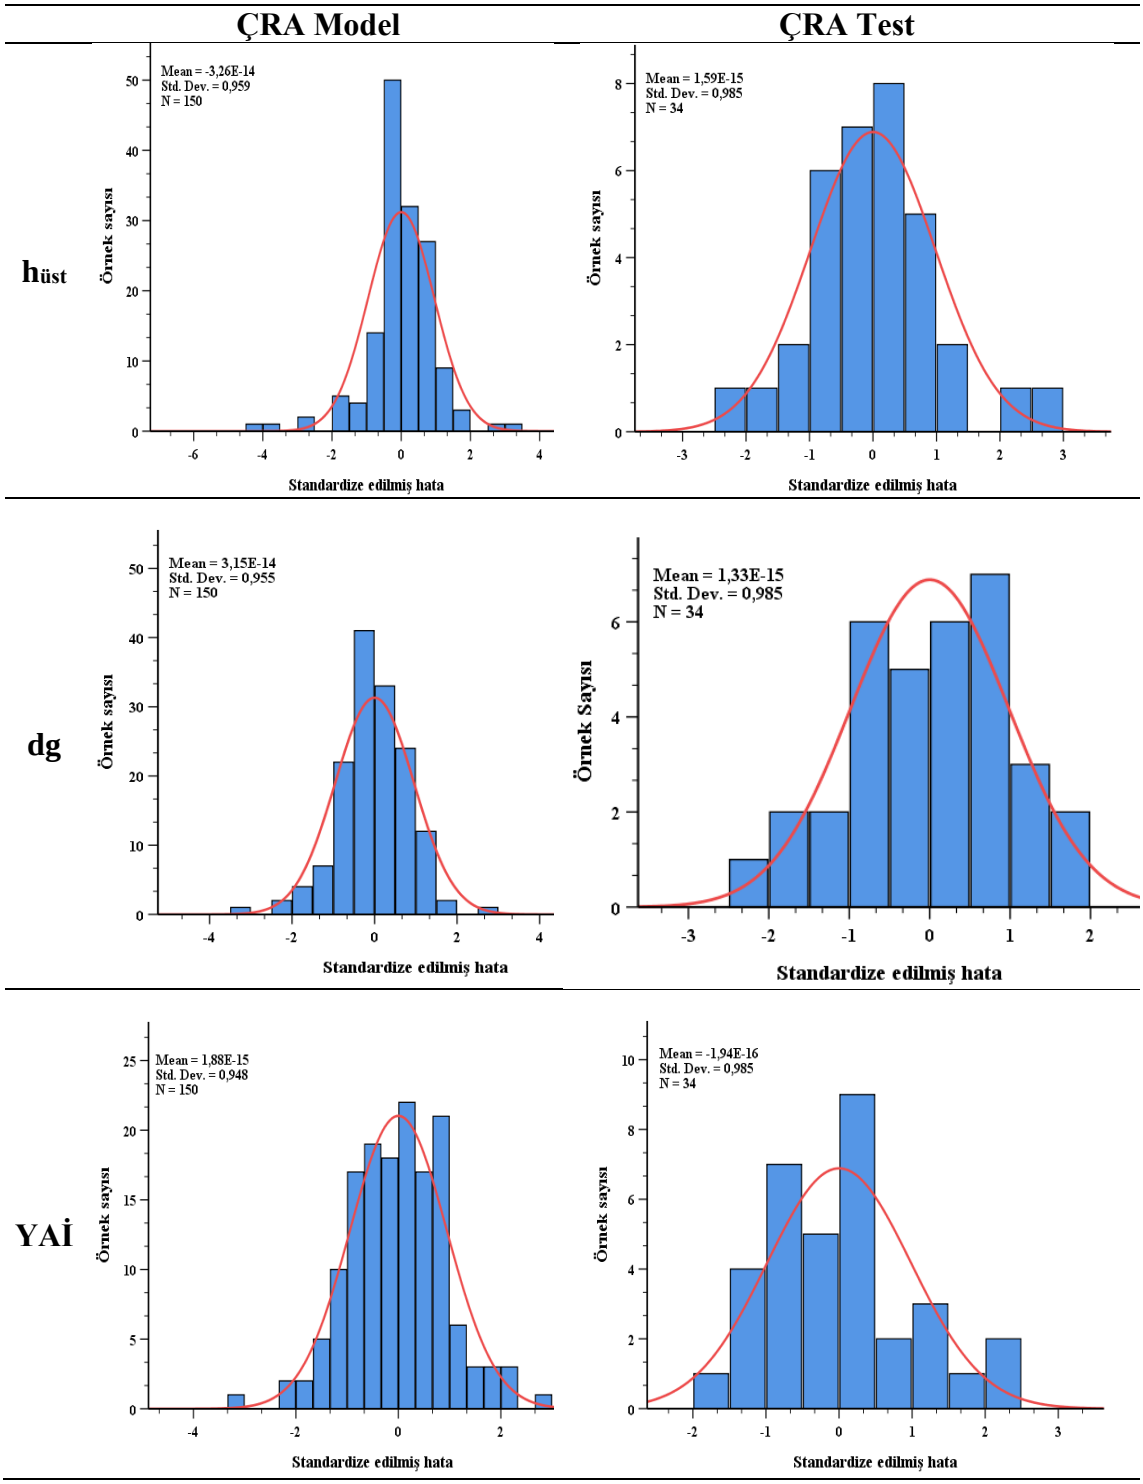


Şekil 4.6 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri (devam)

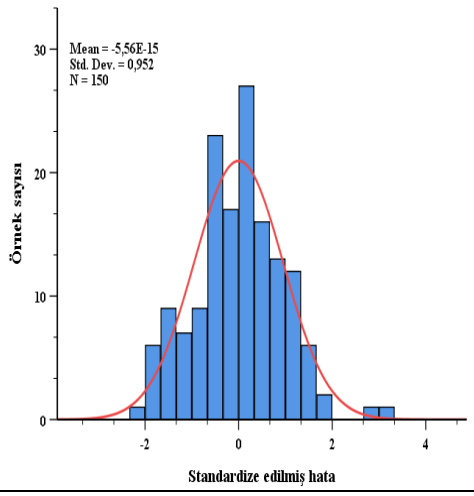
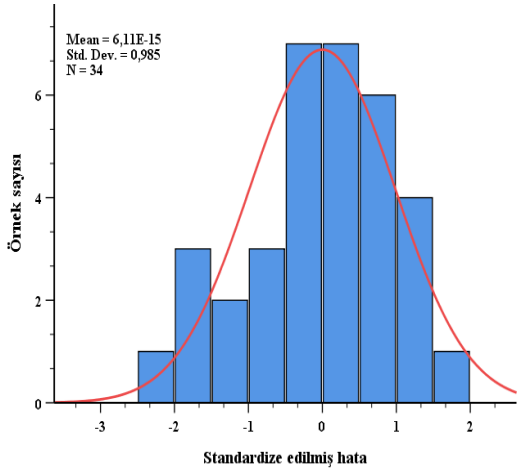
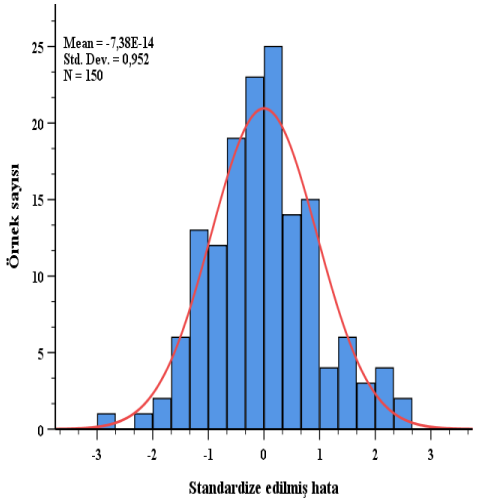
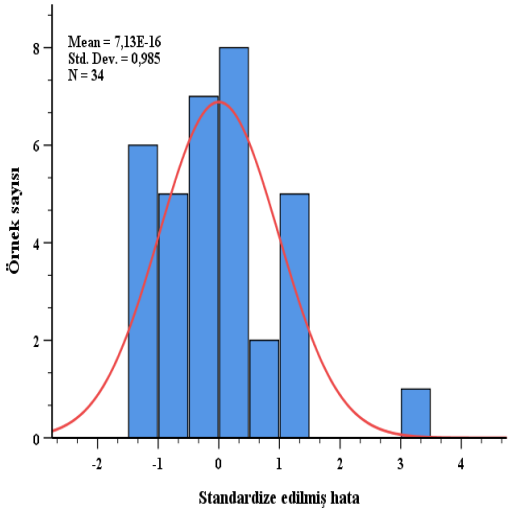
Kullanılan model performans ölçütlerine her bir bağımlı değişkenin modeline ilişkin standardize edilmiş hatalar hesaplanmıştır (BIAS). Meşçere parametrelerine ilişkin standardize edilmiş hata grafikleri Şekil 4.7'de verilmiştir.



Şekil 4.7 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri



Şekil 4.7 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri (devam)

	ÇRA Model	ÇRA Test
TÜB		
TÜK		

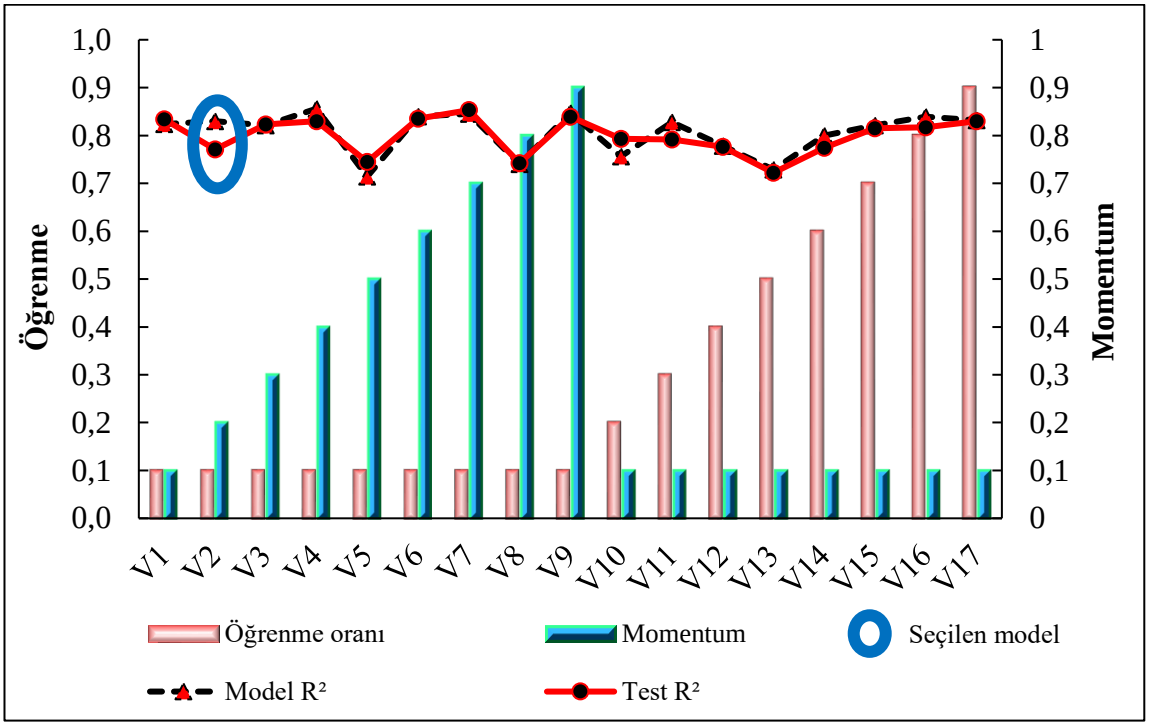
Şekil 4.7 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri (devam)

4.4. ÇRA Metodunda En Yüksek Başarıyı Sağlayan Uzaktan Algılama Veri Setlerine YSA Metodunun Uygulanması

ÇRA modellerinde meşçere parametreleri için en yüksek başarı sağlayan uzaktan algılama veri setleri ile Bayesçi yapay sinir ağı modeli (BYSAM) kullanılarak tahminler elde edilmiştir. Modellerde farklı değerlerde öğrenme oranı ve momentum değişkenleri uygulanarak her bir parametre için 17 model elde edilmiştir. BYSAM modele ait bulgular her bir meşçere parametresi için 8 başlıkta verilmiştir.

4.4.1. BYSAM meşcere hacmi (V) bulguları

Meşcere hacmi için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.17'de verilmiş ve en uygun belirtme katsayısı V2 modelde elde edilmiştir (Model R^2=0,83, Test R^2=0,77, öğrenme oranı=0,1, momentum=0,2). Çizelge 4.17 incelendiğinde en yüksek belirtme katsayısı ve en düşük toplam rölatif sıra V4, V6, V7 ve V9 modellerde olduğu görülmektedir. Fakat bu modeller de aşırı uyum (Overfitting) durumu olabilmesi nedeniyle bu modeller dışında uyum problemi olmadığı düşünülen ve yukarıda belirtilen dört modelden sonra en düşük toplam rölatif sıraya sahip V2 model kullanılmıştır (R_j=21,68). Meşcere hacmi için en düşük belirtme katsayısı ve en yüksek toplam rölatif sıra ise V5 modelde olduğu tespit edilmiştir (R^2=0,71; R_j=85,00). Meşcere hacmi için model ve test belirtme katsayılarını gösterir grafik Şekil 4.8'de verilmiştir.



Şekil 4.8 BYSAM metodu ile elde edilen meşcere hacmine ait belirtme katsayı grafiği (R^2)

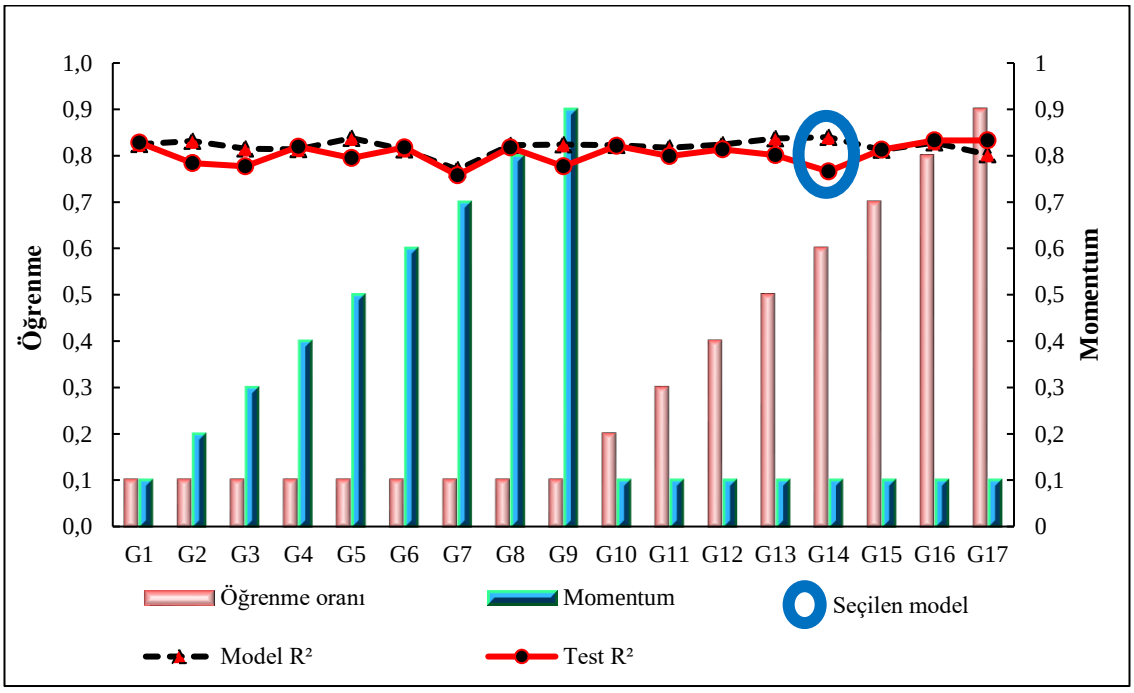
Çizelge 4.17 BYSAM metodu ile elde edilen meşcere hacmine ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
V1	0,1	0,1	21	1	1	2	0,82	0,38	0,30	2,08	41,04	28,28	0,83	0,40	0,33	2,12	41,08	20,42
V2	0,1	0,2	21	1	1	2	0,83	0,38	0,27	2,07	41,02	21,68	0,77	0,47	0,36	2,28	41,24	55,78
V3	0,1	0,3	21	1	1	2	0,82	0,39	0,30	2,09	41,05	30,19	0,82	0,41	0,32	2,15	41,11	25,12
V4	0,1	0,4	21	1	1	2	0,86	0,35	0,25	1,98	40,94	5,00	0,83	0,40	0,32	2,13	41,09	20,28
V5	0,1	0,5	21	1	1	2	0,71	0,49	0,38	2,33	41,28	85,00	0,75	0,49	0,39	2,34	41,29	71,48
V6	0,1	0,6	21	1	1	2	0,84	0,36	0,28	2,03	40,99	17,20	0,84	0,40	0,31	2,12	41,07	16,90
V7	0,1	0,7	21	1	1	2	0,85	0,36	0,27	2,02	40,97	13,78	0,85	0,37	0,30	2,06	41,01	5,00
V8	0,1	0,8	21	1	1	2	0,74	0,46	0,35	2,28	41,23	71,84	0,74	0,50	0,37	2,34	41,30	71,01
V9	0,1	0,9	21	1	1	2	0,85	0,36	0,27	2,01	40,97	12,81	0,84	0,39	0,32	2,11	41,06	15,23
V10	0,2	0,1	21	1	1	2	0,76	0,45	0,36	2,25	41,20	66,87	0,79	0,44	0,35	2,23	41,19	45,33
V11	0,3	0,1	21	1	1	2	0,83	0,38	0,29	2,07	41,02	24,66	0,79	0,45	0,35	2,23	41,19	45,05
V12	0,4	0,1	21	1	1	2	0,78	0,43	0,33	2,20	41,15	53,43	0,78	0,46	0,35	2,27	41,23	52,49
V13	0,5	0,1	21	1	1	2	0,73	0,47	0,36	2,30	41,25	77,57	0,72	0,51	0,41	2,38	41,33	85,00
V14	0,6	0,1	21	1	1	2	0,80	0,41	0,30	2,15	41,10	39,94	0,77	0,46	0,35	2,27	41,23	53,40
V15	0,7	0,1	21	1	1	2	0,82	0,39	0,29	2,09	41,05	28,17	0,82	0,42	0,34	2,17	41,13	31,15
V16	0,8	0,1	21	1	1	2	0,84	0,37	0,27	2,04	40,99	16,92	0,82	0,42	0,34	2,17	41,13	31,44
V17	0,9	0,1	21	1	1	2	0,83	0,37	0,28	2,06	41,01	22,51	0,83	0,40	0,32	2,13	41,09	21,68

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, V1: Hacim 1. model

4.4.2. BYSAM meşcere göğüs yüzeyi (G) bulguları

Meşcere göğüs yüzeyi için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.18'de verilmiş ve en yüksek belirtme katsayısı ve en düşük toplam rölatif sıra G14 modelde elde edilmiştir (Model R^2=0,84, Test R^2=0,77, öğrenme oranı=0,6, momentum=0,1, R_j=5,00). Çizelge 4.18 incelendiğinde G1, G4, G6, G8, G10, G12, G15; G16 ve G17 modellerde aşırı uyum ihtimali görülmektedir. Meşcere göğüs yüzeyi için en düşük başarı ve en yüksek toplam rölatif sıra ise G7 modelde olduğu tespit edilmiştir (Model R^2=0,77, Test R^2=0,76, R_j=85,00). Genel itibari ile momentum değeri arttıkça belirtme katsayısında bir azalma meydana geldiği görülmektedir. Meşcere göğüs yüzeyi için model ve test belirtme katsayılarını gösterir grafik Şekil 4.9'da gösterilmiştir.



Şekil 4.9 BYSAM metodu ile elde edilen meşcere göğüs yüzeyine ait belirtme katsayı grafiği (R^2)

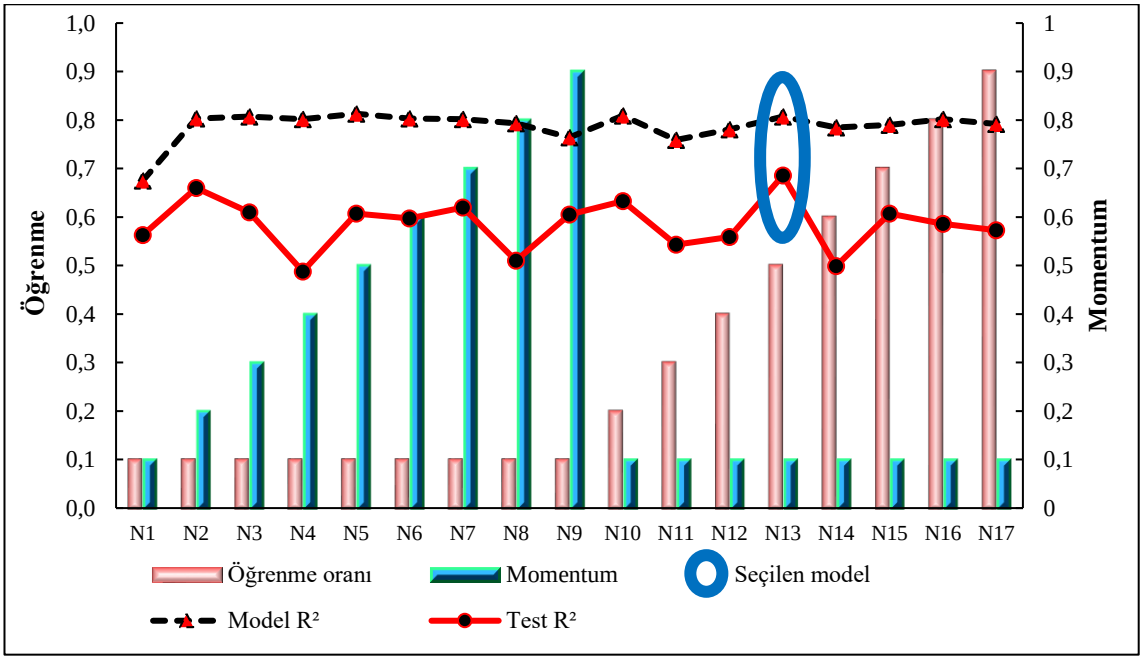
Çizelge 4.18 BYSAM metodu ile elde edilen meşcere göğüs yüzeyine ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
G1	0,1	0,1	13	1	1	2	0,83	0,28	0,23	1,31	24,74	26,43	0,83	0,29	0,23	1,31	24,75	13,47
G2	0,1	0,2	13	1	1	2	0,83	0,28	0,22	1,28	24,72	14,83	0,78	0,32	0,25	1,43	24,86	60,05
G3	0,1	0,3	13	1	1	2	0,82	0,29	0,23	1,33	24,77	36,88	0,78	0,33	0,25	1,44	24,88	65,86
G4	0,1	0,4	13	1	1	2	0,81	0,29	0,23	1,34	24,77	37,71	0,82	0,29	0,22	1,34	24,77	18,43
G5	0,1	0,5	13	1	1	2	0,84	0,27	0,21	1,27	24,71	8,53	0,80	0,31	0,24	1,40	24,84	46,97
G6	0,1	0,6	13	1	1	2	0,81	0,29	0,23	1,34	24,78	39,14	0,82	0,29	0,22	1,34	24,78	21,31
G7	0,1	0,7	13	1	1	2	0,77	0,33	0,26	1,44	24,88	85,00	0,76	0,34	0,27	1,48	24,92	85,00
G8	0,1	0,8	13	1	1	2	0,82	0,29	0,23	1,31	24,75	26,94	0,82	0,29	0,23	1,34	24,78	22,82
G9	0,1	0,9	13	1	1	2	0,82	0,29	0,23	1,31	24,74	26,68	0,78	0,33	0,26	1,44	24,88	66,77
G10	0,2	0,1	13	1	1	2	0,82	0,29	0,23	1,31	24,75	28,72	0,82	0,29	0,24	1,33	24,77	23,48
G11	0,3	0,1	13	1	1	2	0,82	0,29	0,23	1,33	24,76	33,43	0,80	0,31	0,24	1,39	24,83	42,52
G12	0,4	0,1	13	1	1	2	0,82	0,29	0,23	1,31	24,74	26,09	0,81	0,30	0,23	1,35	24,79	27,74
G13	0,5	0,1	13	1	1	2	0,84	0,28	0,22	1,27	24,71	11,77	0,80	0,31	0,25	1,38	24,82	42,54
G14	0,6	0,1	13	1	1	2	0,84	0,27	0,21	1,26	24,70	5,00	0,77	0,33	0,26	1,47	24,90	76,96
G15	0,7	0,1	13	1	1	2	0,81	0,30	0,24	1,34	24,78	40,85	0,81	0,30	0,24	1,35	24,79	32,12
G16	0,8	0,1	13	1	1	2	0,83	0,28	0,23	1,30	24,73	23,01	0,83	0,28	0,22	1,30	24,73	7,69
G17	0,9	0,1	13	1	1	2	0,80	0,30	0,24	1,36	24,80	49,73	0,83	0,28	0,23	1,30	24,73	9,23

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, G1: Göğüs yüzeyi 1. Model

4.4.3. BYSAM meşcere ağaç sayısı (N) bulguları

Meşcere ağaç sayısı için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.19'da verilmiştir. En yüksek belirtme katsayısı ve en düşük toplam rölatif sıra N13 modelde elde edilmiştir (Model R^2=0,81, Test R^2=0,69, öğrenme oranı=0,5, momentum=0,1, R_j=12,94). Çizelge 4.19 incelendiğinde Meşcere ağaç sayısı için hiçbir modelde aşırı uyum problemi olmadığı düşünülmektedir. Meşcere ağaç sayısı için en düşük model başarısı ve en yüksek toplam rölatif sıra N1 modelde (R^2=0,66, R_j=84,55), en düşük test başarısı ise N4 modelde (R^2=0,49, R_j=85,00) elde edilmiştir. Meşcere ağaç sayısı için model ve test belirtme katsayılarını gösterir grafik Şekil 4.10'da gösterilmiştir.



Şekil 4.10 BYSAM metodu ile elde edilen meşcere ağaç sayısına ait belirtme katsayı grafiği (R^2)

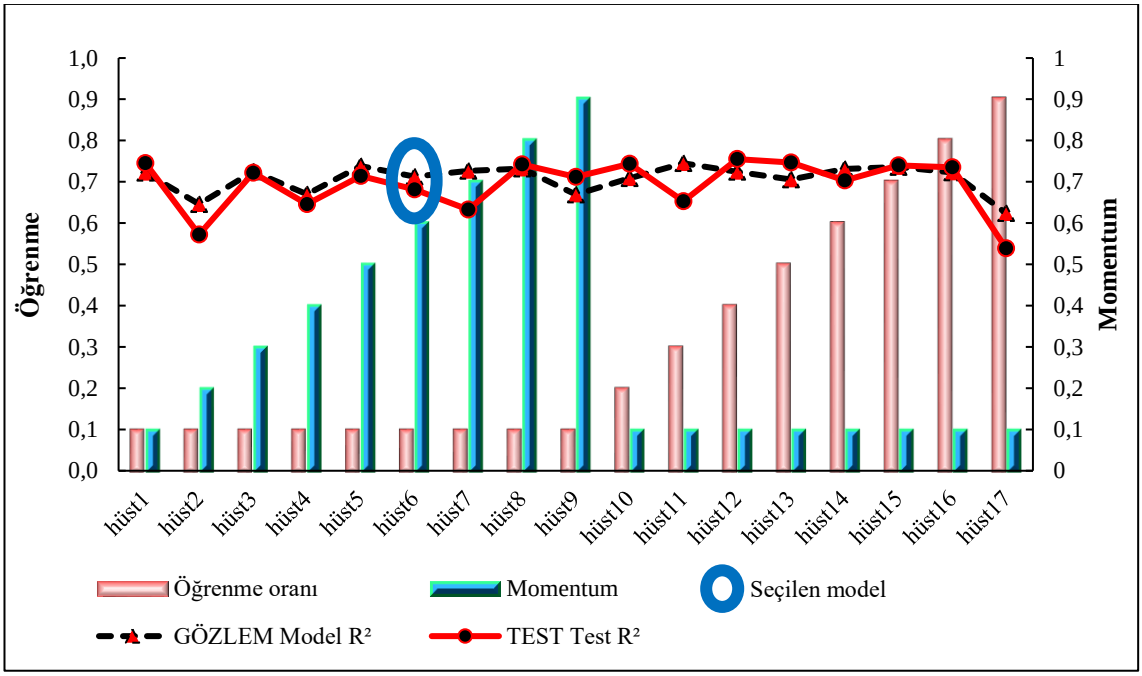
Çizelge 4.19 BYSAM metodu ile elde edilen meşcere ağaç sayısına ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
N1	0,1	0,1	13	1	1	2	0,68	0,44	0,34	1,75	25,19	84,55	0,56	0,44	0,32	1,74	25,18	54,64
N2	0,1	0,2	13	1	1	2	0,80	0,34	0,25	1,50	24,93	17,88	0,66	0,39	0,31	1,62	25,05	18,59
N3	0,1	0,3	13	1	1	2	0,81	0,34	0,25	1,49	24,92	20,41	0,61	0,42	0,32	1,69	25,12	38,84
N4	0,1	0,4	13	1	1	2	0,80	0,35	0,25	1,50	24,94	31,98	0,49	0,48	0,36	1,82	25,26	85,00
N5	0,1	0,5	13	1	1	2	0,81	0,34	0,25	1,47	24,91	18,31	0,61	0,42	0,33	1,69	25,13	41,23
N6	0,1	0,6	13	1	1	2	0,80	0,34	0,26	1,50	24,93	24,15	0,60	0,42	0,32	1,70	25,14	43,95
N7	0,1	0,7	13	1	1	2	0,80	0,35	0,26	1,50	24,94	23,67	0,62	0,41	0,31	1,68	25,11	34,07
N8	0,1	0,8	13	1	1	2	0,79	0,35	0,27	1,52	24,96	36,65	0,51	0,47	0,36	1,80	25,24	78,09
N9	0,1	0,9	13	1	1	2	0,76	0,38	0,29	1,59	25,02	44,59	0,61	0,42	0,33	1,70	25,13	43,27
N10	0,2	0,1	13	1	1	2	0,81	0,34	0,26	1,48	24,92	19,44	0,63	0,40	0,31	1,66	25,09	30,11
N11	0,3	0,1	13	1	1	2	0,76	0,38	0,29	1,60	25,04	51,20	0,54	0,45	0,35	1,77	25,20	66,79
N12	0,4	0,1	13	1	1	2	0,78	0,36	0,26	1,55	24,99	36,96	0,56	0,44	0,33	1,75	25,19	58,13
N13	0,5	0,1	13	1	1	2	0,81	0,34	0,25	1,49	24,92	12,94	0,69	0,37	0,29	1,58	25,01	5,00
N14	0,6	0,1	13	1	1	2	0,79	0,36	0,26	1,54	24,98	39,55	0,50	0,47	0,34	1,81	25,25	77,29
N15	0,7	0,1	13	1	1	2	0,79	0,36	0,27	1,53	24,97	30,12	0,61	0,42	0,33	1,69	25,13	41,37
N16	0,8	0,1	13	1	1	2	0,80	0,35	0,26	1,50	24,94	25,68	0,59	0,43	0,34	1,72	25,15	50,23
N17	0,9	0,1	13	1	1	2	0,79	0,35	0,26	1,53	24,96	30,89	0,57	0,44	0,34	1,73	25,17	55,22

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, N1: Ağaç sayısı 1. model

4.4.4. BYSAM meşcere üst boy ($h_{üst}$) bulguları

Meşcere üst boyu için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.20'de verilmiştir. Modellerde en düşük toplam rölatif hata $h_{üst}5$, $h_{üst}11$, $h_{üst}14$ ve $h_{üst}12$ de olmasına rağmen aşırı uyum (Overfitting) problemi olabilme ihtimaline karşı meşcere üst boyu için tercih edilmemiştir. Meşcere üst boyu içi en uygun belirtme katsayısı ve toplam rölatif sıra $h_{üst}6$ model seçilmiştir (Model R^2=0,71, Test R^2=0,68, öğrenme oranı=0,1, momentum=0,6, R_j=22,51). Çizelge 4.20 incelendiğinde meşcere üst boyu için $h_{üst}2$, $h_{üst}4$, $h_{üst}5$, $h_{üst}6$ ve $h_{üst}7$ modeller dışındaki diğer modellerde aşırı uyum (Overfitting) problemi olabileceği görülmektedir. Meşcere üst boyu için en düşük belirtme katsayısı ve en yüksek toplam rölatif sıra $h_{üst}2$ modelde (Model R^2=0,65, Test R^2=0,57, R_j=73,15) elde edilmiştir. Meşcere üst boyu için model ve test belirtme katsayılarını gösterir grafik Şekil 4.11'de gösterilmiştir.



Şekil 4.11 BYSAM metodu ile elde edilen meşcere üst boyuna ait belirtme katsayı grafiği (R^2)

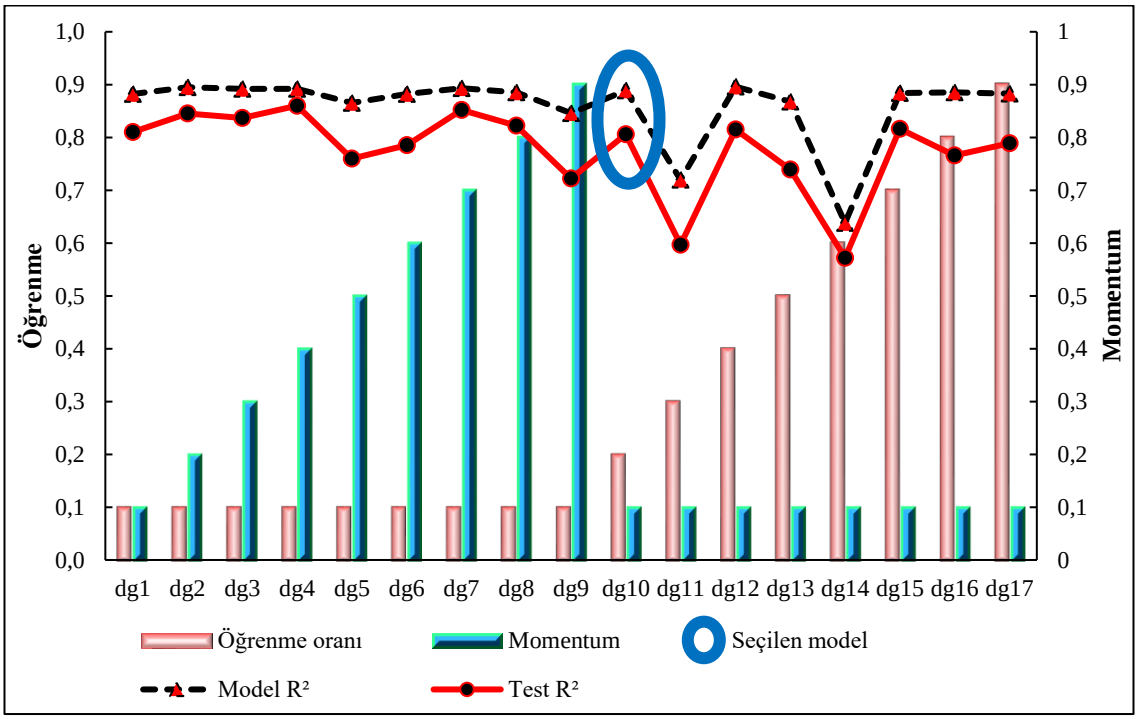
Çizelge 4.20 BYSAM metodu ile elde edilen meşcere üst boyuna ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
$h_{üst}1$	0,1	0,1	12	1	1	2	0,72	0,25	0,17	1,08	22,59	18,72	0,75	0,49	0,39	1,78	23,29	69,74
$h_{üst}2$	0,1	0,2	12	1	1	2	0,65	0,28	0,20	1,20	22,72	73,15	0,57	0,39	0,29	1,54	23,05	60,63
$h_{üst}3$	0,1	0,3	12	1	1	2	0,73	0,24	0,17	1,07	22,59	17,34	0,72	0,27	0,20	1,16	22,67	20,24
$h_{üst}4$	0,1	0,4	12	1	1	2	0,67	0,27	0,19	1,16	22,68	54,77	0,65	0,28	0,20	1,20	22,72	28,63
$h_{üst}5$	0,1	0,5	12	1	1	2	0,74	0,24	0,17	1,05	22,56	9,663	0,71	0,26	0,20	1,12	22,63	18,86
$h_{üst}6$	0,1	0,6	12	1	1	2	0,71	0,25	0,17	1,09	22,61	22,51	0,68	0,27	0,21	1,17	22,69	25,05
$h_{üst}7$	0,1	0,7	12	1	1	2	0,73	0,24	0,17	1,07	22,59	17,82	0,63	0,29	0,22	1,24	22,76	33,52
$h_{üst}8$	0,1	0,8	12	1	1	2	0,73	0,25	0,17	1,11	22,62	24,63	0,74	0,48	0,37	1,76	23,27	67,7
$h_{üst}9$	0,1	0,9	12	1	1	2	0,67	0,27	0,19	1,16	22,68	56,64	0,71	0,26	0,20	1,12	22,63	18,76
$h_{üst}10$	0,2	0,1	12	1	1	2	0,71	0,25	0,17	1,10	22,62	27,57	0,74	0,24	0,18	1,06	22,58	11,94
$h_{üst}11$	0,3	0,1	12	1	1	2	0,75	0,24	0,17	1,04	22,56	6,297	0,65	0,28	0,22	1,22	22,73	29,88
$h_{üst}12$	0,4	0,1	12	1	1	2	0,72	0,24	0,17	1,07	22,59	16,6	0,76	0,45	0,39	1,69	23,21	63,02
$h_{üst}13$	0,5	0,1	12	1	1	2	0,71	0,25	0,17	1,11	22,62	28,5	0,75	0,28	0,19	1,23	22,74	22,13
$h_{üst}14$	0,6	0,1	12	1	1	2	0,73	0,24	0,16	1,06	22,58	11,85	0,70	0,23	0,13	1,01	22,53	8,852
$h_{üst}15$	0,7	0,1	12	1	1	2	0,74	0,29	0,18	1,24	22,75	61,97	0,74	0,46	0,35	1,72	23,23	63,86
$h_{üst}16$	0,8	0,1	12	1	1	2	0,72	0,24	0,17	1,07	22,59	19,76	0,74	0,28	0,19	1,23	22,74	22,71
$h_{üst}17$	0,9	0,1	12	1	1	2	0,62	0,29	0,20	1,23	22,74	81,07	0,54	0,32	0,25	1,36	22,87	48,87

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, $h_{üst}1$: Üst boy 1. Model

4.4.5. BYSAM meşcere orta çap (d_g) bulguları

Meşcere orta çapı için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.21'de verilmiş ve en uygun belirtme katsayısı ve toplam rölatif sıra d_g10 modelde elde edilmiştir (Model R^2=0,89, Test R^2=0,81, öğrenme oranı=0,2, momentum=0,1, R_j=9,39). Çizelge 4.21 incelendiğinde meşcere orta çapı için d_g1, d_g2, d_g3, d_g4, d_g7 ve d_g8 modellerin belirtme katsayıları yüksek ve toplam rölatif sıraları düşük olmasına rağmen aşırı uyum problemi olabileceği düşünüldüğünden uygun model olarak tercih edilmemiştir. Meşcere orta çapı için en düşük model başarısı ve en yüksek toplam rölatif sıra d_g14 modelde (Model R^2=0,64, Test R^2=0,57, R_j=85,00) elde edilmiştir. Meşcere orta çapı için model ve test belirtme katsayılarını gösterir grafik Şekil 4.12'de gösterilmiştir.



Şekil 4.12 BYSAM metodu ile elde edilen meşcere orta çapına ait belirtme katsayı grafiği (R^2)

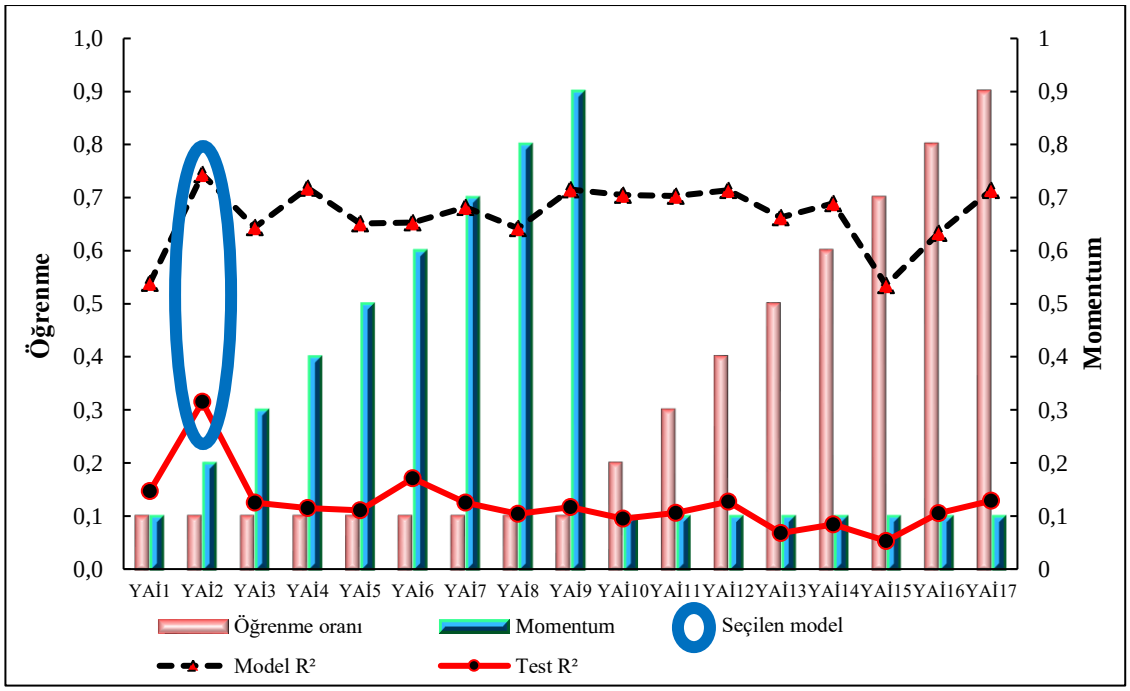
Çizelge 4.20 BYSAM metodu ile elde edilen meşcere orta çapına ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
dg1	0,1	0,1	13	1	1	2	0,88	0,20	0,13	0,95	24,38	11,74	0,81	0,26	0,21	1,20	24,63	22,74
dg2	0,1	0,2	13	1	1	2	0,90	0,19	0,13	0,89	24,32	6,01	0,85	0,23	0,19	1,11	24,54	10,85
dg3	0,1	0,3	13	1	1	2	0,89	0,19	0,12	0,90	24,33	6,362	0,84	0,24	0,19	1,13	24,57	13,74
dg4	0,1	0,4	13	1	1	2	0,89	0,19	0,13	0,90	24,34	7,19	0,86	0,22	0,18	1,06	24,49	5
dg5	0,1	0,5	13	1	1	2	0,87	0,21	0,14	1,01	24,45	18,71	0,76	0,29	0,24	1,33	24,76	40,47
dg6	0,1	0,6	13	1	1	2	0,88	0,20	0,14	0,95	24,38	12,78	0,79	0,28	0,23	1,27	24,71	33,34
dg7	0,1	0,7	13	1	1	2	0,89	0,19	0,13	0,90	24,33	7,451	0,85	0,23	0,18	1,08	24,52	7,828
dg8	0,1	0,8	13	1	1	2	0,89	0,20	0,14	0,94	24,37	10,96	0,82	0,25	0,21	1,17	24,61	20,29
dg9	0,1	0,9	13	1	1	2	0,85	0,23	0,16	1,08	24,51	26,72	0,72	0,31	0,25	1,40	24,84	50,85
dg10	0,2	0,1	13	1	1	2	0,89	0,19	0,13	0,92	24,35	9,394	0,81	0,26	0,22	1,22	24,66	26,43
dg11	0,3	0,1	13	1	1	2	0,72	0,31	0,22	1,38	24,82	65,05	0,60	0,38	0,29	1,59	25,02	79,96
dg12	0,4	0,1	13	1	1	2	0,90	0,19	0,13	0,88	24,32	6,036	0,82	0,26	0,21	1,20	24,63	22,75
dg13	0,5	0,1	13	1	1	2	0,87	0,21	0,15	1,00	24,44	18,41	0,74	0,30	0,24	1,37	24,81	46,23
dg14	0,6	0,1	13	1	1	2	0,64	0,35	0,26	1,51	24,94	85	0,57	0,39	0,29	1,62	25,05	85
dg15	0,7	0,1	13	1	1	2	0,88	0,20	0,14	0,94	24,37	11,25	0,82	0,25	0,21	1,19	24,63	22,52
dg16	0,8	0,1	13	1	1	2	0,89	0,20	0,13	0,93	24,37	10,37	0,77	0,29	0,23	1,31	24,75	38,54
dg17	0,9	0,1	13	1	1	2	0,88	0,20	0,14	0,94	24,38	11,67	0,79	0,27	0,22	1,26	24,70	30,78

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, dg1: Orta çap 1. model

4.4.6. BYSAM yaprak alan indeksi (YAİ) bulguları

YAİ parametresi için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.22'de verilmiş ve en uygun belirtme katsayısı ile toplam rölatif sıra YAİ2 modelde elde edilmiştir (Model R^2=0,74, Test R^2=0,37, öğrenme oranı=0,1, momentum=0,2, R_j=5,00). Çizelge 4.22 incelendiğinde YAİ için hiçbir modelde aşırı uyum problemi görülmemektedir. YAİ için en düşük model başarısı ve en yüksek toplam rölatif sıra YAİ15 modelde (Model R^2=0,54, R_j=85,00) elde edilmiştir. YAİ için model ve test belirtme katsayılarını gösterir grafik Şekil 4.13'te gösterilmiştir.



Şekil 4.13 BYSAM metodu ile elde edilen yaprak alan indeksine ait belirtme katsayı grafiği (R^2)

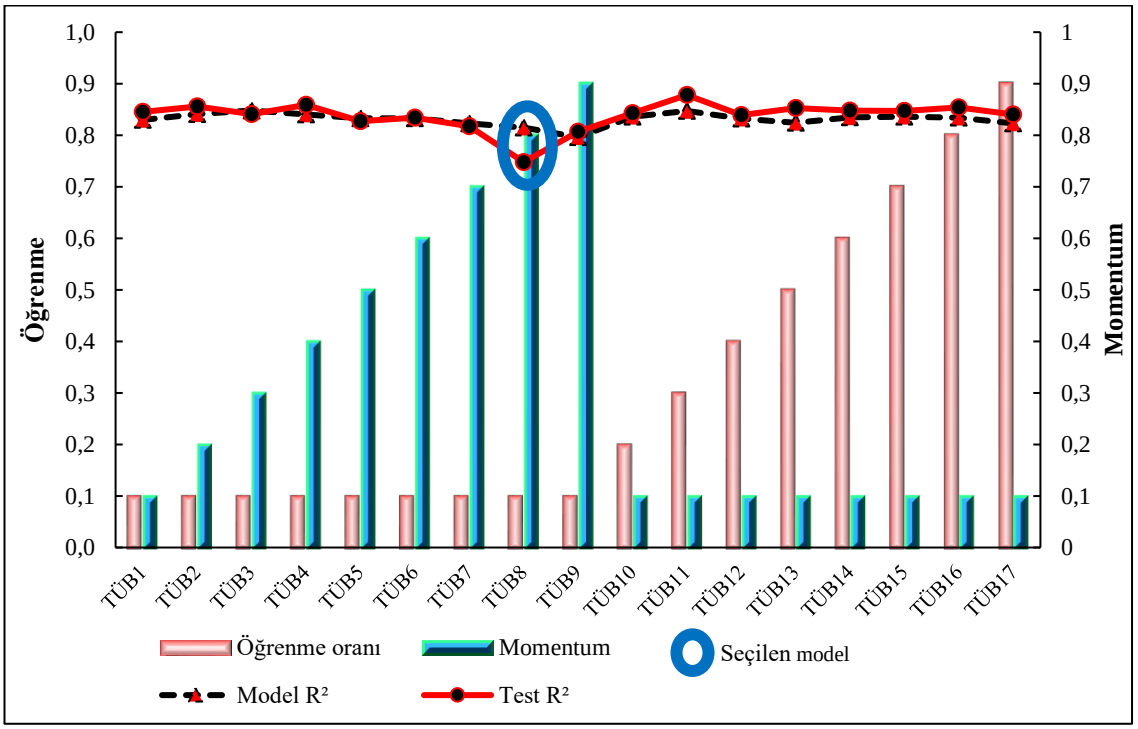
Çizelge 4.21 BYSAM metodu ile elde edilen yaprak alan indeksine ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
YAİ1	0,1	0,1	15	1	1	2	0,54	0,32	0,25	1,58	28,87	81,16	0,15	0,36	0,30	1,70	28,99	18,3
YAİ2	0,1	0,2	15	1	1	2	0,74	0,24	0,18	1,29	28,58	5,00	0,32	0,37	0,32	1,72	29,01	15,2
YAİ3	0,1	0,3	15	1	1	2	0,64	0,29	0,22	1,45	28,74	46,41	0,13	0,40	0,34	1,79	29,08	42,8
YAİ4	0,1	0,4	15	1	1	2	0,72	0,25	0,20	1,33	28,63	18,44	0,12	0,48	0,38	1,96	29,26	81,2
YAİ5	0,1	0,5	15	1	1	2	0,65	0,28	0,23	1,44	28,73	46,31	0,11	0,37	0,30	1,72	29,01	24,8
YAİ6	0,1	0,6	15	1	1	2	0,65	0,28	0,22	1,44	28,73	43,09	0,17	0,40	0,28	1,78	29,07	28,1
YAİ7	0,1	0,7	15	1	1	2	0,68	0,27	0,21	1,40	28,69	33,60	0,13	0,47	0,37	1,94	29,23	75,8
YAİ8	0,1	0,8	15	1	1	2	0,64	0,29	0,22	1,46	28,75	46,93	0,10	0,43	0,35	1,86	29,15	57,6
YAİ9	0,1	0,9	15	1	1	2	0,72	0,26	0,20	1,34	28,63	19,88	0,12	0,42	0,35	1,84	29,13	52,8
YAİ10	0,2	0,1	15	1	1	2	0,71	0,26	0,20	1,36	28,65	23,82	0,10	0,41	0,33	1,81	29,10	45,7
YAİ11	0,3	0,1	15	1	1	2	0,70	0,26	0,20	1,36	28,65	24,77	0,11	0,44	0,35	1,89	29,18	63,7
YAİ12	0,4	0,1	15	1	1	2	0,71	0,26	0,20	1,34	28,63	20,54	0,13	0,46	0,36	1,93	29,23	71,5
YAİ13	0,5	0,1	15	1	1	2	0,66	0,28	0,22	1,42	28,72	40,63	0,07	0,38	0,31	1,74	29,04	33
YAİ14	0,6	0,1	15	1	1	2	0,69	0,27	0,21	1,38	28,68	29,96	0,08	0,42	0,34	1,85	29,14	56
YAİ15	0,7	0,1	15	1	1	2	0,54	0,33	0,26	1,59	28,88	85,00	0,05	0,40	0,32	1,78	29,07	40,9
YAİ16	0,8	0,1	15	1	1	2	0,63	0,29	0,22	1,47	28,76	50,64	0,11	0,37	0,30	1,72	29,01	24,3
YAİ17	0,9	0,1	15	1	1	2	0,71	0,26	0,20	1,34	28,63	19,77	0,13	0,40	0,33	1,79	29,08	39,9

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, YAİ1: Yaprak alan indeksi 1. model

4.4.7. BYSAM topraküstü biyokütle (TÜB) bulguları

TÜB için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.23'te verilmiş ve en uygun belirtme katsayısı ve toplam rölatif sıra TÜB8 modelde elde edilmiştir (Model R^2=0,82, Test R^2=0,75, öğrenme oranı=0,1, momentum=0,8, R_j=56,22). Çizelge 4.23 incelendiğinde TÜB için TÜB5, TÜB7 ve TÜB8 modeller hariç diğer modellerde aşırı uyum problemi olduğu düşünülmektedir. TÜB11 model en yüksek model ve test belirtme katsayısı elde edilmesine rağmen uygun model olarak seçilmemiştir (Model R^2=0,85, Test R^2=0,88, Model R_j=6,30, Test R_j=5,00). Genel olarak bütün modeller incelendiğinde yüksek bir başarı elde edildiği görülmektedir. TÜB için model ve test belirtme katsayılarını gösterir grafik Şekil 4.14'de gösterilmiştir.



Şekil 4.14 BYSAM metodu ile elde edilen topraküsütü biyokütleye ait belirtme katsayı grafiği (R^2)

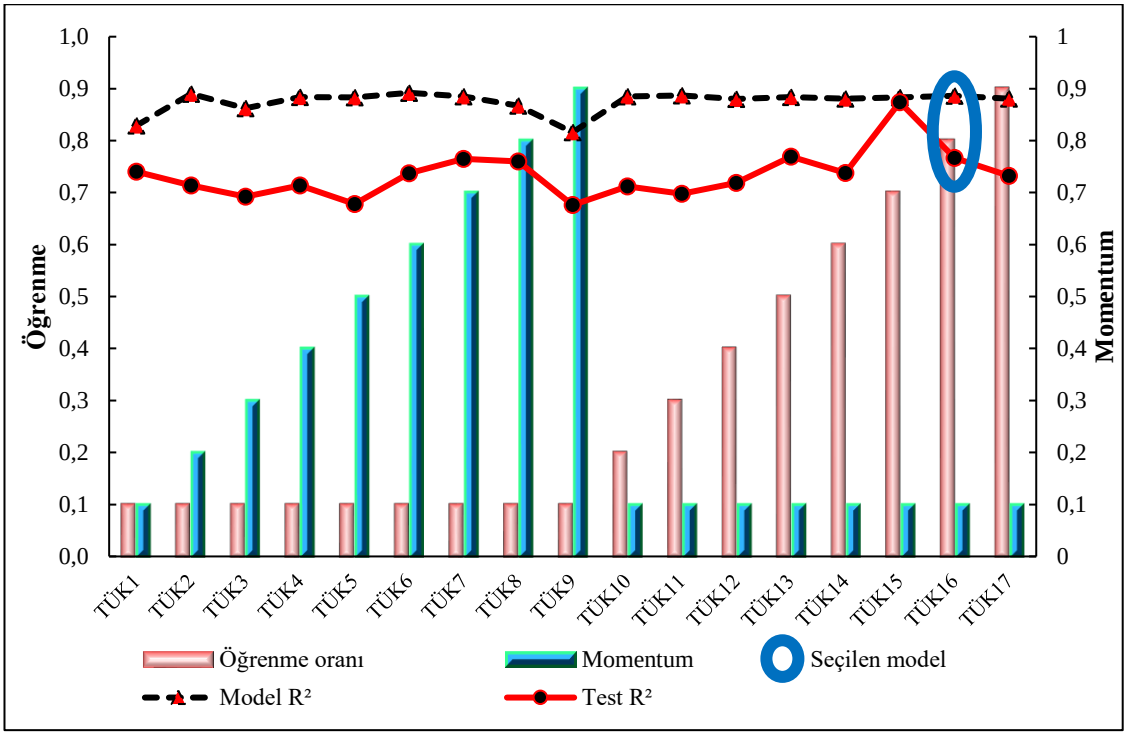
Çizelge 4.22 BYSAM metodu ile elde edilen topraküsütü biyokütleye ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
TÜB1	0,1	0,1	14	1	1	2	0,83	0,33	0,27	1,54	26,90	35,85	0,85	0,34	0,27	1,55	26,91	44,12
TÜB2	0,1	0,2	14	1	1	2	0,84	0,32	0,25	1,50	26,86	15,34	0,86	0,32	0,25	1,51	26,87	29,66
TÜB3	0,1	0,3	14	1	1	2	0,85	0,31	0,25	1,48	26,84	5,98	0,84	0,34	0,28	1,56	26,92	47,85
TÜB4	0,1	0,4	14	1	1	2	0,84	0,32	0,26	1,51	26,87	19,89	0,86	0,32	0,27	1,51	26,87	32,55
TÜB5	0,1	0,5	14	1	1	2	0,83	0,33	0,26	1,53	26,89	30,10	0,83	0,35	0,28	1,60	26,96	60,96
TÜB6	0,1	0,6	14	1	1	2	0,83	0,33	0,26	1,53	26,89	31,08	0,83	0,35	0,28	1,58	26,94	55,13
TÜB7	0,1	0,7	14	1	1	2	0,82	0,34	0,28	1,56	26,92	47,23	0,82	0,36	0,29	1,63	26,99	70,71
TÜB8	0,1	0,8	14	1	1	2	0,82	0,35	0,28	1,58	26,94	56,22	0,75	0,34	0,27	1,55	26,91	56,29
TÜB9	0,1	0,9	14	1	1	2	0,80	0,37	0,30	1,63	26,99	85,00	0,81	0,35	0,31	1,58	26,94	66,34
TÜB10	0,2	0,1	14	1	1	2	0,84	0,33	0,26	1,52	26,88	24,68	0,84	0,34	0,27	1,55	26,91	44,59
TÜB11	0,3	0,1	14	1	1	2	0,85	0,32	0,25	1,48	26,84	6,30	0,88	0,30	0,25	1,42	26,78	5,00
TÜB12	0,4	0,1	14	1	1	2	0,83	0,33	0,27	1,53	26,89	32,37	0,84	0,34	0,28	1,56	26,92	50,17
TÜB13	0,5	0,1	14	1	1	2	0,82	0,34	0,27	1,56	26,92	45,33	0,85	0,33	0,27	1,52	26,88	37,28
TÜB14	0,6	0,1	14	1	1	2	0,84	0,33	0,26	1,52	26,89	28,22	0,85	0,33	0,27	1,54	26,90	40,26
TÜB15	0,7	0,1	14	1	1	2	0,84	0,33	0,25	1,52	26,88	22,06	0,85	0,33	0,25	1,54	26,90	37,83
TÜB16	0,8	0,1	14	1	1	2	0,83	0,33	0,26	1,52	26,89	27,87	0,85	0,33	0,26	1,52	26,88	32,95
TÜB17	0,9	0,1	14	1	1	2	0,82	0,34	0,27	1,56	26,92	45,27	0,84	0,34	0,27	1,56	26,92	47,27

ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, TÜB1: Toprak üstü biyokütle 1. model

4.4.8. BYSAM topraküstü karbon (TÜK) bulguları

TÜK için uygulanan BYSAM modele ait performans ölçütleri Çizelge 4.24'te verilmiş ve en uygun belirtme katsayısı ve toplam rölatif sıra TÜK16 modelde elde edilmiştir (Model R^2=0,89, Test R^2=0,77, öğrenme oranı=0,8, momentum=0,1, R_j=13,44). Çizelge 4.24 incelendiğinde TÜK için TÜK16 modelden daha düşük toplam rölatif sıraya sahip modeller olmasına rağmen bu modellerde aşırı uyum problemi olabileceği düşüncesi ile uygun bulunmamıştır. TÜK için en düşük belirtme katsayısı model TÜK9 için elde edilmiştir (Model R^2=0,82, Test R^2=0,68, R_j=85,00). TÜK için model ve test belirtme katsayılarını gösterir grafik Şekil 4.15'de gösterilmiştir.



Şekil 4.15 BYSAM metodu ile elde edilen topraküstü karbona ait belirtme katsayı grafiği (R^2)

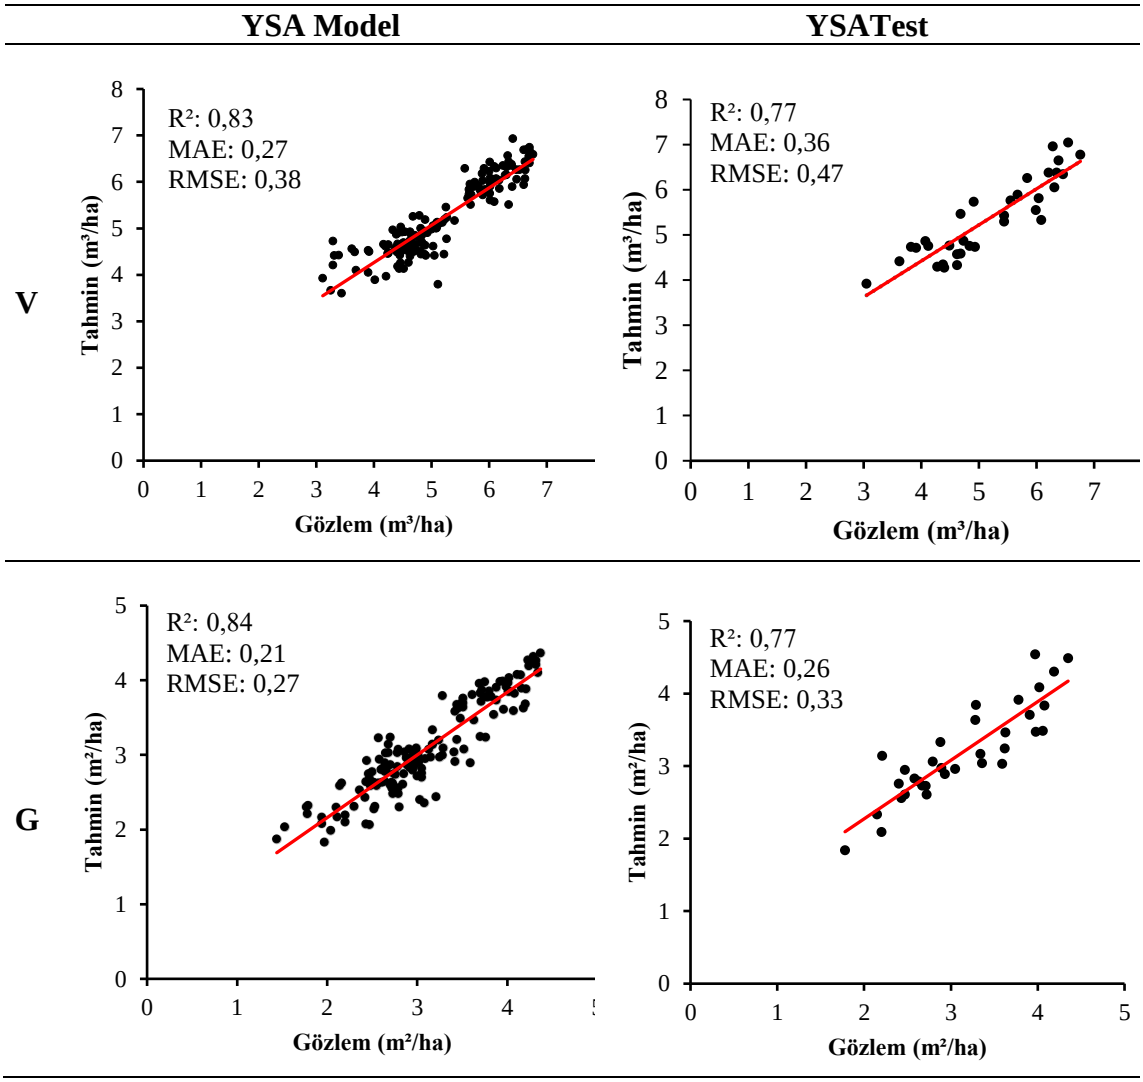
Çizelge 4.23 BYSAM metodu ile elde edilen topraküstü karbona ilişkin model – test performans ölçütleri

Model No	Parametreler						Model						Test					
	ÖO	MO	Girdi	Çıktı	GK	Nöron	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra	R^2	RMSE	MAE	BIC	AIC	Toplam Rölatif Sıra
TÜK1	0,1	0,1	14	1	1	2	0,83	45,24	34,29	6,45	31,81	73,77	0,74	56,78	46,61	6,68	32,04	64,62
TÜK2	0,1	0,2	14	1	1	2	0,89	36,19	26,43	6,23	31,59	6,81	0,71	59,52	43,76	6,73	32,09	69,76
TÜK3	0,1	0,3	14	1	1	2	0,86	40,67	31,81	6,34	31,71	42,98	0,69	61,79	50,25	6,76	32,12	79,72
TÜK4	0,1	0,4	14	1	1	2	0,88	37,23	27,52	6,26	31,62	14,96	0,71	59,62	45,88	6,73	32,09	71,31
TÜK5	0,1	0,5	14	1	1	2	0,88	37,35	28,02	6,26	31,62	16,67	0,68	63,21	47,79	6,79	32,15	81,66
TÜK6	0,1	0,6	14	1	1	2	0,89	35,90	26,54	6,22	31,58	5,20	0,74	57,11	45,58	6,68	32,04	64,79
TÜK7	0,1	0,7	14	1	1	2	0,89	37,10	26,72	6,25	31,61	12,68	0,77	53,94	40,88	6,63	31,99	53,62
TÜK8	0,1	0,8	14	1	1	2	0,87	39,89	29,55	6,33	31,69	34,34	0,76	54,61	44,67	6,64	32,00	57,75
TÜK9	0,1	0,9	14	1	1	2	0,82	46,99	35,07	6,49	31,85	85,00	0,68	63,42	52,12	6,79	32,15	85,00
TÜK10	0,2	0,1	14	1	1	2	0,89	37,04	26,45	6,25	31,61	11,90	0,71	59,74	47,28	6,73	32,09	72,60
TÜK11	0,3	0,1	14	1	1	2	0,89	36,82	28,00	6,25	31,61	13,31	0,70	61,23	47,97	6,75	32,11	76,78
TÜK12	0,4	0,1	14	1	1	2	0,88	37,85	28,74	6,27	31,63	20,92	0,72	59,00	47,64	6,72	32,08	70,97
TÜK13	0,5	0,1	14	1	1	2	0,88	37,31	26,99	6,26	31,62	14,33	0,77	53,56	41,38	6,62	31,98	52,92
TÜK14	0,6	0,1	14	1	1	2	0,88	37,66	28,35	6,27	31,63	19,13	0,74	56,99	45,92	6,68	32,04	64,71
TÜK15	0,7	0,1	14	1	1	2	0,88	36,80	29,68	6,24	31,61	17,14	0,87	38,99	27,59	6,30	31,66	5,00
TÜK16	0,8	0,1	14	1	1	2	0,89	36,93	27,69	6,25	31,61	13,44	0,77	53,79	41,58	6,62	31,99	53,65
TÜK17	0,9	0,1	14	1	1	2	0,88	37,64	28,05	6,27	31,63	18,47	0,73	57,72	44,98	6,69	32,06	65,89

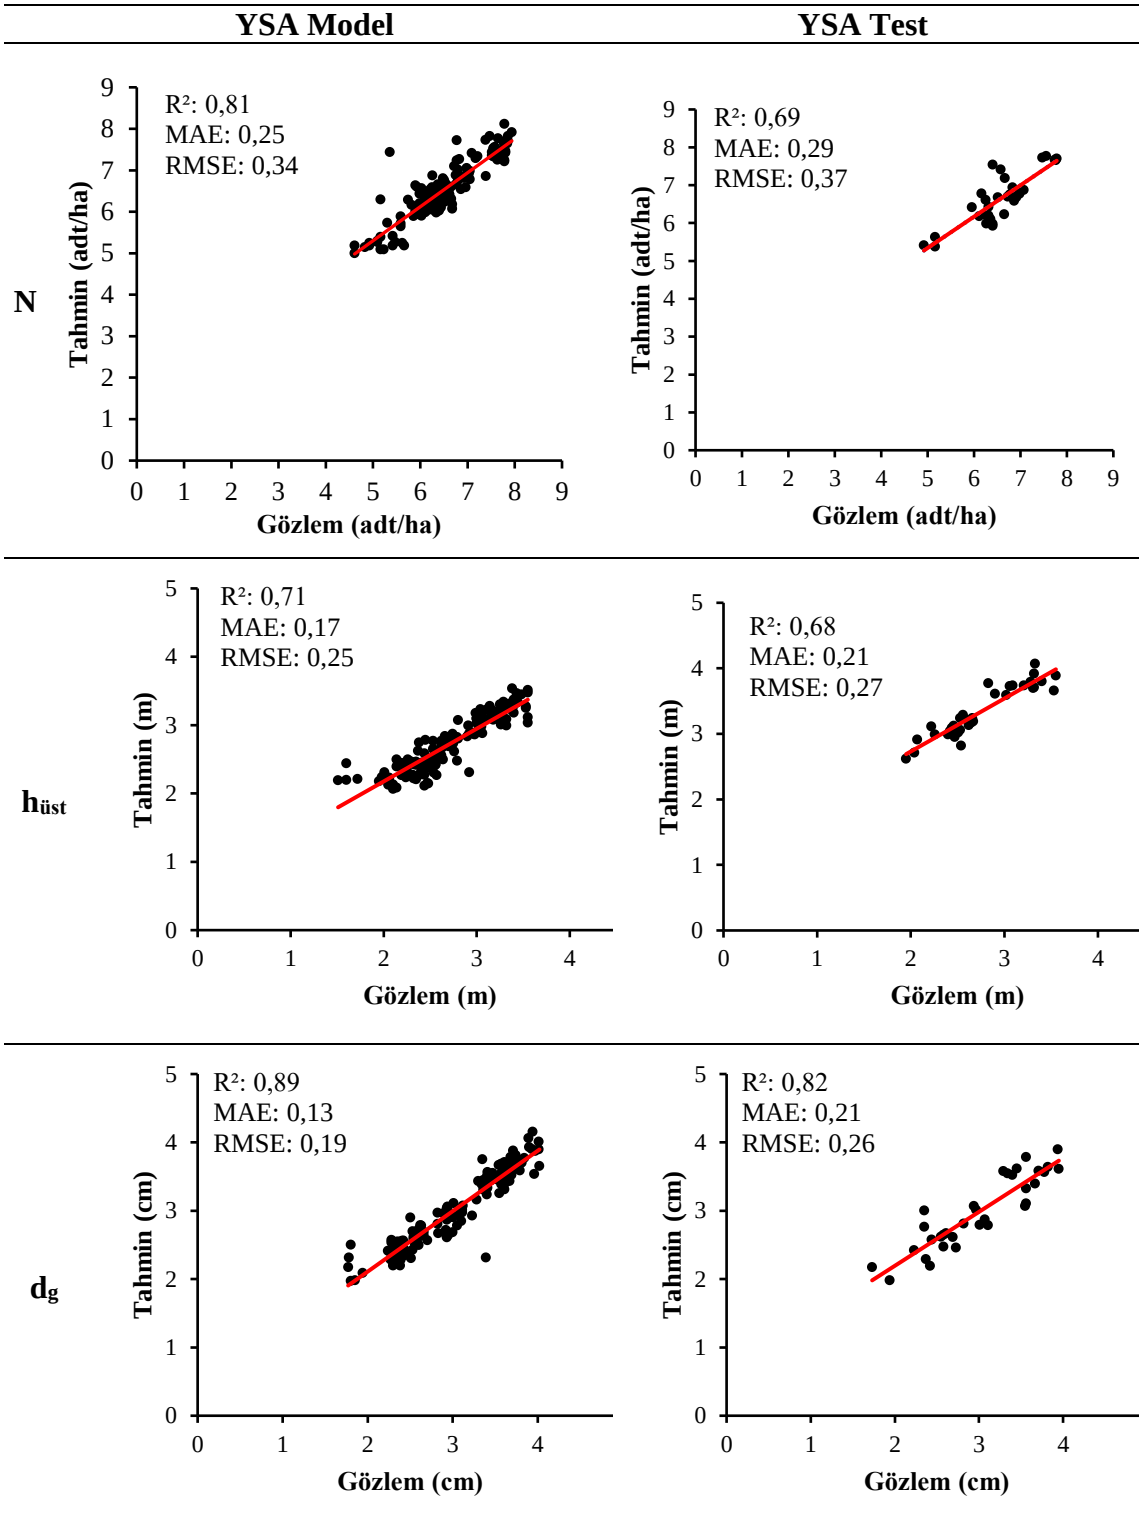
ÖO: Öğrenme oranı, MO: Momentum, GK: Gizli katman, TÜK1: Toprak üstü karbon 1. model

4.4.9. BYSAM meşçere parametreleri gözlem tahmin belirtme katsayısı ve hata grafikleri

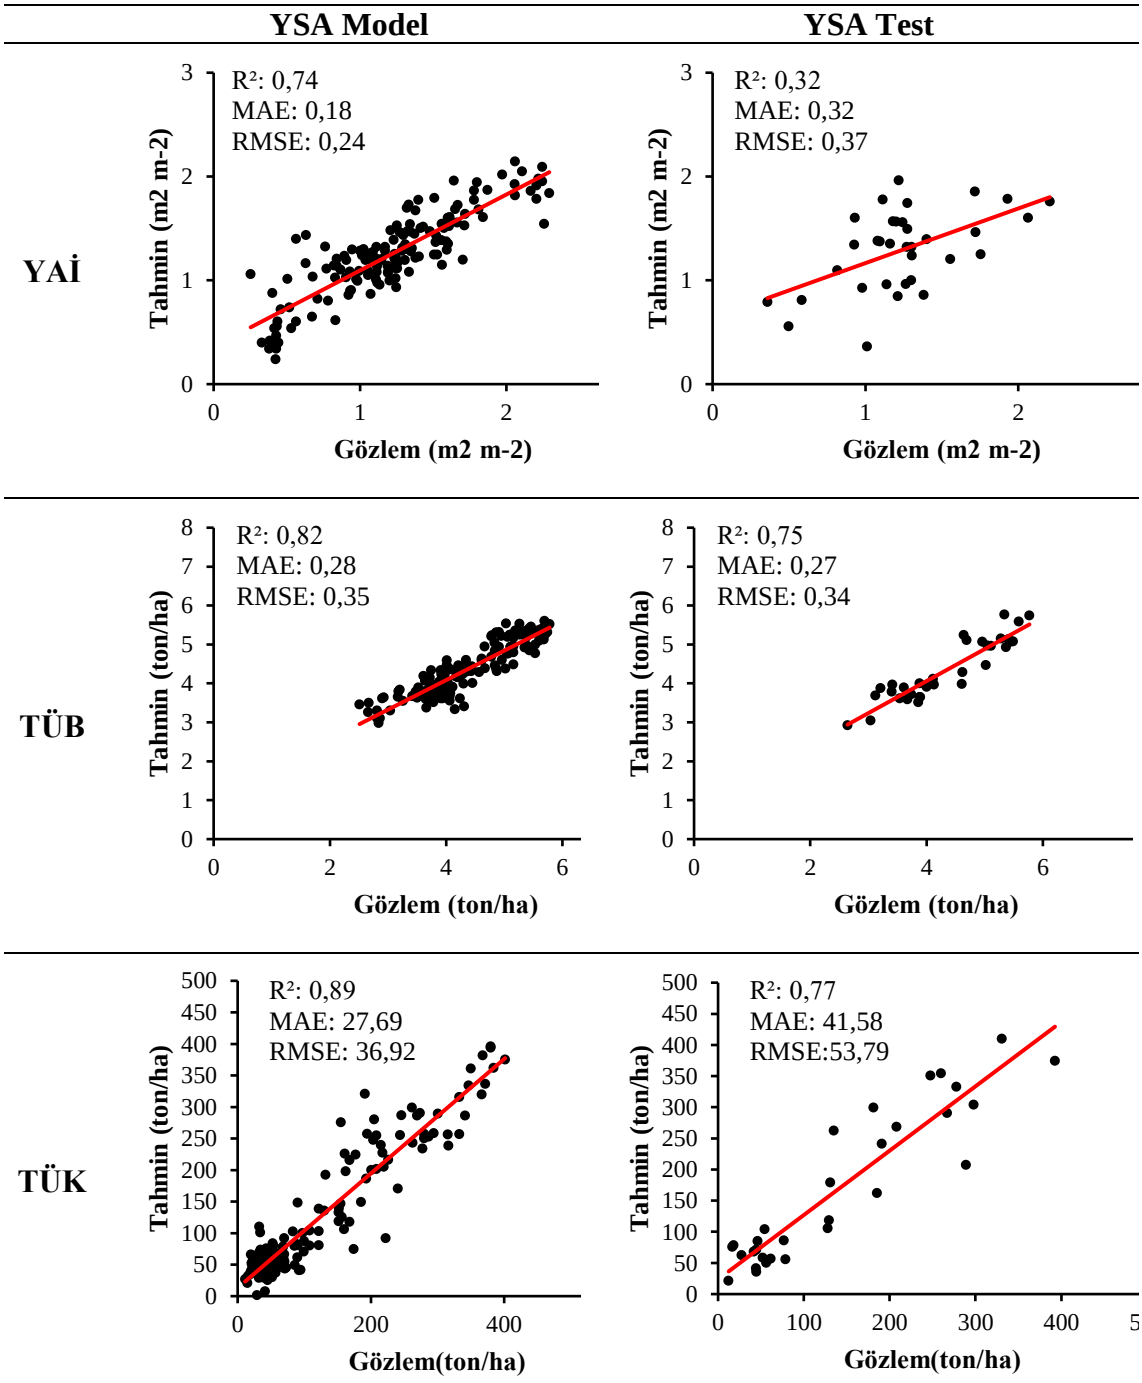
ÇRA model de meşçere parametreleri için en yüksek başarı sağlayan uzaktan algılama veri setleri ile Bayesçi yapay sinir ağı modeli (BYSAM) tahminler elde edilmiştir. Model ve test verilerine ait gözlem ve tahmin grafikleri Şekil 4.16'da, hata grafikleri ise Şekil 4.17'de verilmiştir.



Şekil 4.16 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri

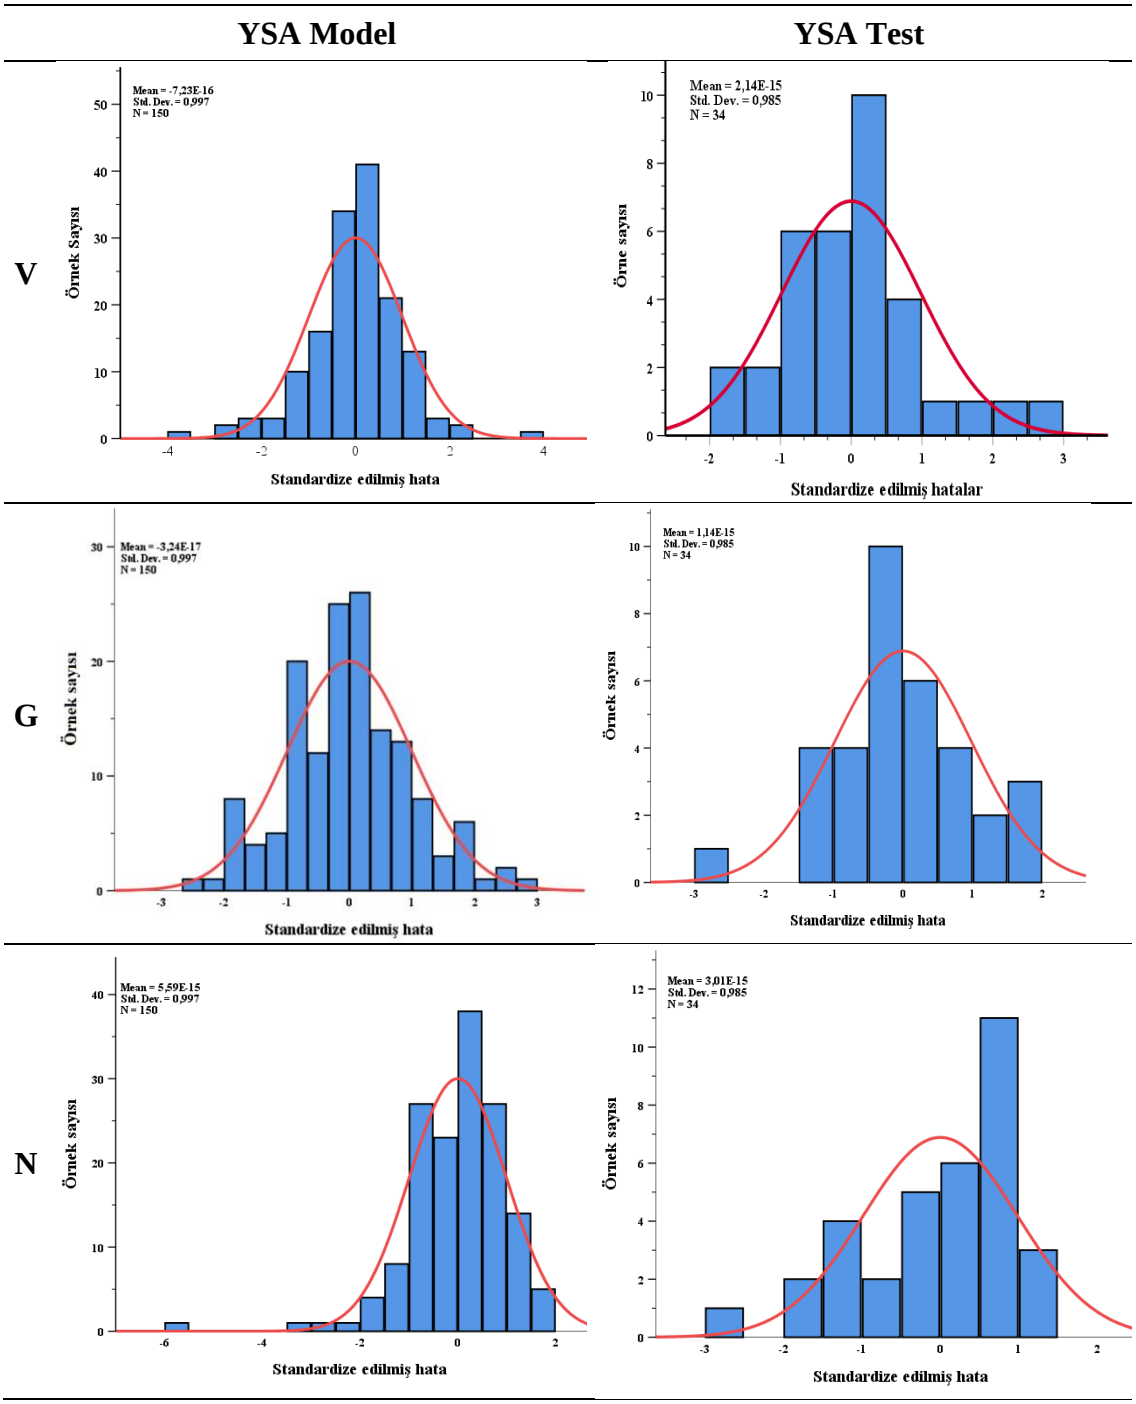


Şekil 4.16 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), hüst (S2, 5x5), dg (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri (devam)

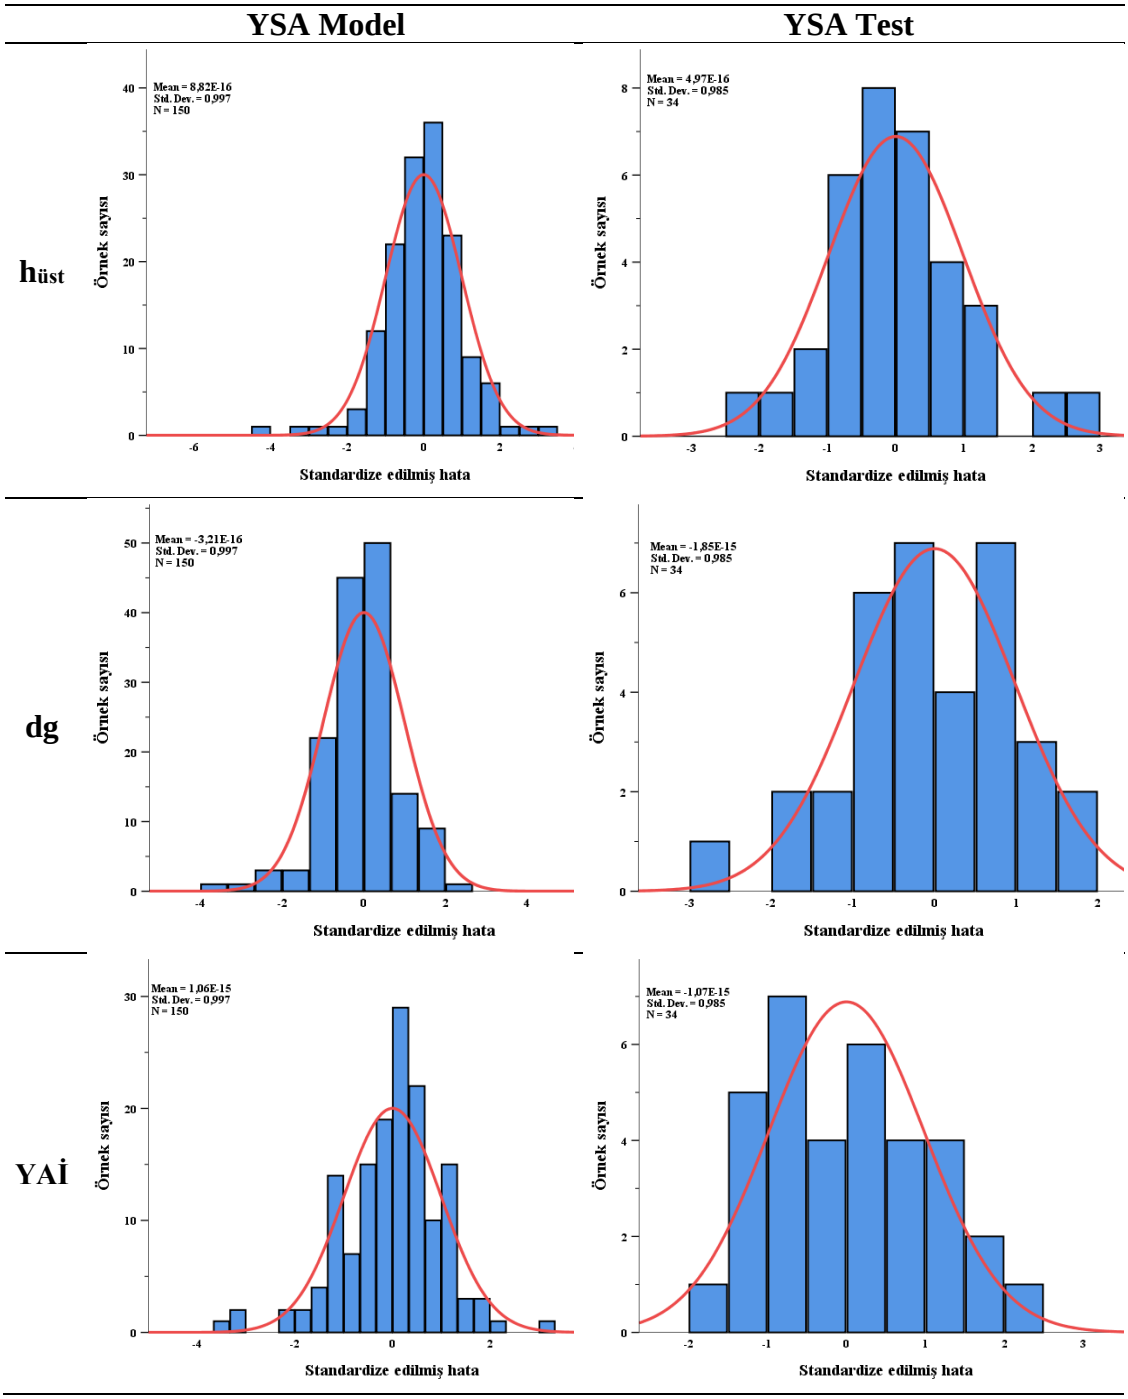


Şekil 4.16 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) modellerinin model- test için gözlem ve tahmin grafikleri (devam)

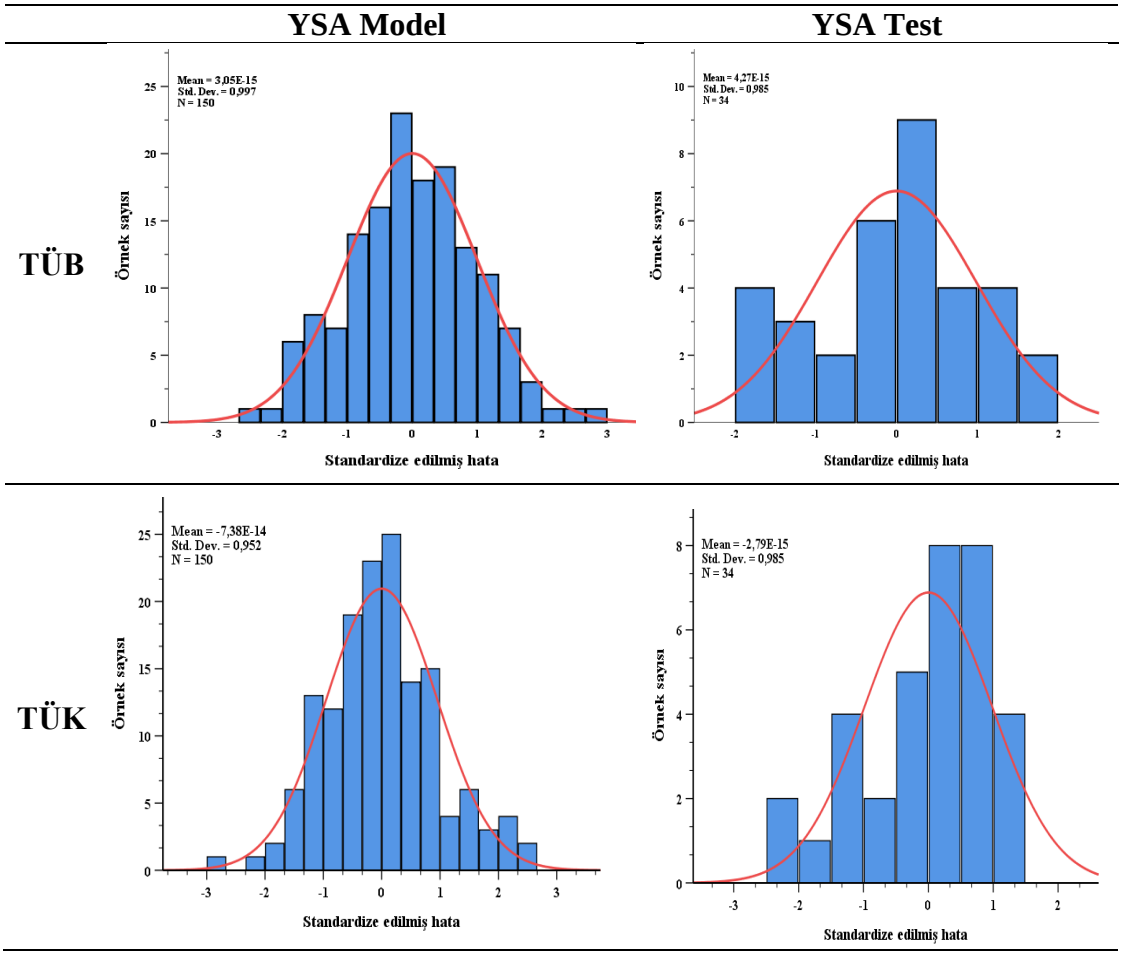
Kullanılan model performans ölçütlerine her bir bağımlı değişkenin modeline ilişkin standardize edilmiş hatalar hesaplanmıştır (BIAS). Meşçere parametrelerine ilişkin standardize edilmiş hata grafikleri Şekil 4.17'de verilmiştir.



Şekil 4.17 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri



Şekil 4.17 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri (devam)



Şekil 4.17 Tekstür değerleri ile elde edilen V (L8, 135°), G (S2, 15x15), N (S2, 15x15), $h_{üst}$ (S2, 5x5), d_g (S2, 7x7), YAİ (S2, 5x5), TÜB (S2, 9x9), ve TÜK (S2, 15x15) model- test için standardize edilmiş hata grafikleri (devam)

4.5. ÇRA ve YSA Metotlarına Ait Sonuçların Denetimi

Çalışmada uzaktan algılama verileri kullanılarak meşçere parametreleri, YAİ, TÜB ve TÜK, ÇRA ve YSA metotları ile modellenmiştir. Metotlara ilişkin performans ölçütlerinin hesaplanmasının yanında test tahminlerinin gözlem verileri ile uyumlu olup olmadığını kontrol etmek için "eşlendirilmiş *t*-testi" kullanılmıştır. Test bulgularına göre $p>0,05$ olması ilgili modelin 0,05 önem düzeyinde çalışma alanındaki meşcerelerde kullanılabilir olduğunu göstermektedir. Uygulanan teknikler ile elde edilen bütün tahminlere ilişkin performans ölçütleri (R^2, RMSE, MAE, BIC, AIC, BIAS) ve eşlendirilmiş *t*-testi sonuçları sunulmuştur (Çizelge 4.25-32).

Modellemede uzaktan algılama verileri bağımsız değişkenleri ile meşçere parametreleri, YAİ, TÜB ve TÜK ayrı ayrı iki metot da model elde edilmiştir. Meşcere hacminin uzaktan algılama verileri ile modellenmesine ait sonuçlar Çizelge 4.25'de verilmiş ve en yüksek belirtme katsayısı ÇRA metodunda elde edilmiştir (Model R^2=0,84; RMSE=0,34, Test R^2=0,67; RMSE=3,24). ÇRA model ve YSA model başarıları çok yakın olmasına rağmen YSA'nın test belirtme katsayısı ÇRA modelden daha yüksek bulunmuştur. ÇRA modelin başarısı yüksek bulunmasına rağmen test gözlem ve tahminleri arasında yapılan test sonucuna göre model 0,05 önem düzeyi ile kullanılabilir değildir (*t*=-2,764, p=0,021). YSA metoduna ait test gözlem ve tahminleri arasında yapılan test sonucuna göre model 0,05 önem düzeyi ile kullanılabilir çıkmıştır (*t*=-2,563, p=0,065).

Çizelge 4.24 Meşcere hacminin uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,84	0,34	0,27	1,37	13,93	$-2{,}31\times10^{-15}$		
	YSA	0,83	0,38	0,27	2,07	41,02	$-7{,}23\times10^{-16}$	***t***	**p**
Test	ÇRA	0,67	3,24	0,44	1,65	25,08	$2{,}14\times10^{-15}$	-2,764	0,021
	YSA	0,77	0,47	0,36	2,28	41,24	$2{,}14\times10^{-15}$	-2,563	0,065

Modellenen diğer meşçere parametrelerinden biri olan meşcere göğüs yüzeyine ilişkin ÇRA ve YSA metotlarının performans ölçütleri incelendiğinde (Çizelge 4.26) model ve test başarıları iki metot içinde başarılı olduğu görünmektedir.

Çizelge 4.25 Meşcere göğüs yüzeyinin uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,82	0,28	0,22	1,27	15,71	$-8{,}86\times10^{-15}$		
	YSA	0,84	0,27	0,21	1,26	24,70	$-3{,}24\times10^{-17}$	***t***	**p**
Test	ÇRA	0,63	0,46	0,36	1,78	25,21	$-4{,}20\times10^{-16}$	2,788	0,089
	YSA	0,77	0,33	0,26	1,47	24,90	$-1{,}14\times10^{-15}$	-0,980	0,334

Meşcere göğüs yüzeyi için en yüksek model ve test belirtme katsayısı YSA metodunda elde edilmiştir (Model R^2=0,83, Test R^2=0,77). ÇRA ve YSA metoduna ait test gözlem ve tahminleri arasında yapılan *t*-test sonucuna göre model 0,05 önem düzeyi ile

kullanılabilir çıkmıştır (ÇRA: *t*=2,788, p=0,089; YSA: t=-0,980, p=0,334). *T* Test sonuçları incelendiğinde YSA metodunun çalışma alanına daha uygulanabilir olduğu görülmüştür.

Meşcere ağaç sayısı için en yüksek ilişki Sentinel-2 uydu görüntüsünden elde edilen 15×15 tekstür verileri kullanılan bağımsız değişkenlerden elde edilmiştir. Kullanılan modelleme tekniklerinde en yüksek belirtme katsayısı YSA metodunda elde edilmiştir (Çizelge 4.27). Model ve test performans ölçütleri incelendiğinde YSA model belirtme katsayıları yüksek olmasına rağmen ÇRA metodu başarılı ve uygun bulunmuştur (Model R^2=0,79, RMSE=0,34 adet/ha, Test R^2=0,64, RMSE=0,40 adet/ha). ÇRA ve YSA motoduna ait test gözlem ve tahminleri arasında yapılan test sonucuna göre model 0,05 önem düzeyi ile kullanılabilir çıkmıştır (ÇRA: *t*=0,401, p=0,691 – YSA: t=-1,144, p=0,261). Test sonuçları da ÇRA metodunda gözlem ve tahmin verileri arasında YSA metoduna göre daha uygulanabilir olduğunu göstermektedir.

Çizelge 4.26 Meşcere ağaç sayısının uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,79	0,34	0,25	1,47	14,91	$8,35\times10^{-15}$		
	YSA	0,81	0,34	0,25	1,49	24,92	$5,59\times10^{-15}$	***t***	**p**
Test	ÇRA	0,64	0,40	0,33	1,65	25,08	$-2,79\times10^{-15}$	0,401	0,691
	YSA	0,69	0,37	0,29	1,58	25,01	$3,01\times10^{-15}$	-1,144	0,261

Meşcere üst boyunun modellenmesinde en yüksek model başarısını ÇRA metodu (R^2=0,82, RMSE=0,19 m, MAE=0,13), en yüksek test başarısını da yine ÇRA metodu (R^2=0,81, RMSE=0,16 m, MAE=0,13) ile elde edilmiştir (Çizelge 4.28). YSA metodunun başarısı ÇRA metoduna göre daha düşük belirtme katsayısına sahip olmasına rağmen t-test sonuçları YSA metodunun meşcere üst boyunun tahmininde daha uygulanabilir olduğunu göstermiştir (p=0,649). YSA belirtme katsayılarına bakıldığında uyum problemin olmadığı ve başarılı bir model olduğu görülmektedir (Model R^2=0,71, RMSE=0,25 m, Test R^2=0,68, RMSE=0,27 m). Meşcere üst boyunun tahmininde Sentinel-2 uydu görüntüsünden elde edilen 5×5 pencere boyutundaki tekstür verileri

bağımsız değişkenleri ile YSA metodu kullanılarak 0,05 önem düzeyi ile kullanılabileceği bulunmuştur.

Çizelge 4.27 Meşcere üst boyunun uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,82	0,19	0,14	0,40	14,32	$-3{,}26\times10^{-14}$		
	YSA	0,71	0,25	0,17	1,09	22,61	$8{,}82\times10^{-16}$	***t***	**p**
Test	ÇRA	0,81	0,16	0,13	0,66	22,17	$1{,}59\times10^{-15}$	-20,265	0,028
	YSA	0,68	0,27	0,21	1,17	22,69	$4{,}97\times10^{-16}$	-0,459	0,649

ÇRA ve YSA ile modellenen meşcere orta çapı için her iki teknikte de yüksek model ve test belirtme katsayıları elde edilmiştir (Çizelge 4.29). Parametreye ait performans ölçütleri incelendiğinde en başarılı ve en uygun model YSA metot da elde edilmiştir (Model R^2=0,89, RMSE=0,19 cm, Test R^2=0,81, RMSE=0,26 cm). ÇRA metodunda ise belirtme katsayısı 0,88 olarak bulunmuştur. Her iki metot için de eşlendirilmiş *t*-teste göre gözlem ve tahmin sonuçları 0,05 önem düzeyi ile kullanılabilir olduğunu göstermektedir (ÇRA: *t*=-0,170, p=0,866 – YSA: t=0,399, p=0,692). Meşcere orta çapının modellenen meşçere parametreleri arasında en yüksek başarıya sahip parametrelerden biri olmasının en büyük sebebinin modelleme veri ayrımının (model-test) meşcere orta çapına göre yapılmasında kaynaklanmaktadır.

Çizelge 4.28 Meşcere orta çapının uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,83	0,05	0,18	-0,84	13,08	$3{,}15\times10^{-14}$		
	YSA	0,89	0,19	0,13	0,92	24,35	$-3{,}21\times10^{-16}$	***t***	**p**
Test	ÇRA	0,81	0,26	0,21	1,20	24,64	$1{,}33\times10^{-15}$	-0,170	0,866
	YSA	0,81	0,26	0,22	1,22	24,66	$-1{,}85\times10^{-15}$	0,399	0,692

Yaprak alan indeksinin modellenmesinde Sentinel-2 uydu görüntüsünden elde edilen 5×5'lik tekstür verileri kullanılmıştır. YSA metodu en yüksek başarıyı göstermiştir (Çizelge 4.30). Her iki tekniğe ait model ve test başarı bulguları arasındaki fark yüksek

çıkmıştır (ÇRA Model R^2=0,69, Test R^2=0,17, YSA Model R^2=0,74, Test R^2=0,32). Eşlendirilmiş *t*-test sonuçlarına göre ÇRA metodu test tahminleri YSA metoduna göre daha uyumlu çıkmıştır (ÇRA p=0,563, YSA p=0,463). Uygulanan teknikler arasında yaprak alan indeksinin tahmininde Sentinel-2 uydu görüntüsünden elde edilen 5×5'lik pencere boyutundaki tekstür verileri bağımsız değişkenleri ile YSA metodu kullanılarak 0,05 önem düzeyi ile ÇRA metoduna göre daha uygulanabilir metot olduğu tespit edilmiştir.

Çizelge 4.29 Yaprak alan indeksinin uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,69	0,25	0,20	1,03	10,63	$1,88\times10^{-15}$		
	YSA	0,74	0,24	0,18	1,29	28,58	$1,06\times10^{-15}$	***t***	**p**
Test	ÇRA	0,17	0,36	0,29	1,67	28,96	$1,94\times10^{-16}$	-0,584	0,563
	YSA	0,32	0,37	0,32	1,72	29,01	$1,07\times10^{-15}$	-0,743	0,463

Bununla birlikte yaprak alan indeksi Sentinel-2 ve Landsat 8 OLI uydu görüntüleri ile hesaplanmış ve yersel ölçümlerden elde edilen yaprak alan indeksi sonuçları eşlendirilmiş *t*-testi ile karşılaştırılmıştır (Çizelge 4.31). Sonuçlar incelendiğinde her iki uydu görüntüsünden elde edilen YAİ değerlerine ait p değeri, uydu görüntülerinden elde edilen yaprak alan indeksi değerlerinin kullanılabileceğini göstermiştir. P ve korelasyon değeri yüksek olan Landsat 8 OLI uydu görüntüsü ile yaprak alan indeksinin hesaplanmasının Sentinel-2 uydu görüntüsüne nazaran daha uygulanabilir olduğu tespit edilmiştir.

Çizelge 4.30 Yaprak alan indeksinin uzaktan algılama verileri ile hesaplanmasına ait performans ölçütleri

Veri Seti	**Örnek Sayısı**	**Korelasyon**	**Eşlendirilmiş *t*-test**	
		R	***t***	**p**
YAİ- Sentinel 2 YAİ	184	60	-3.033	0.0756
YAİ- Landsat 8 YAİ	184	68	-3.611	0.0916

Topraküstü biyokütle (TÜB) parametresi için en yüksek ilişki Sentinel-2 uydu görüntüsünden elde edilen 9×9 pencere boyutundaki tekstür verileri kullanılan bağımsız

değişkenlerden elde edilmiştir. Kullanılan modelleme tekniklerinde en yüksek belirtme katsayısı ÇRA metodunda elde edilmiştir (R^2=0,84) (Çizelge 4.32). Model ve test performans ölçütleri incelendiğinde ÇRA model belirtme katsayıları yüksek olmasına rağmen model-test R^2 değerleri arasında uyumsuzluk olması dolayısı ile YSA metodu başarılı ve uygun bulunmuştur (Model R^2=0,82; RMSE=0,35 ton/ha, Test R^2=0,75; RMSE=0,34 ton/ha). ÇRA ve YSA metoduna ait test gözlem ve tahminleri arasında yapılan test sonucuna göre modeller 0,05 önem düzeyi ile kullanılabilir çıkmıştır (ÇRA t=-0,956, p=0,346 – YSA t=0,024, p=0,981). Test sonuçları da YSA metodunda gözlem ve tahmin verileri arasında ÇRA metoduna göre daha uygulanabilir olduğu tespit edilmiştir.

Çizelge 4.31 Topraküstü biyokütlenin uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,81	0,35	0,28	1,14	16,94	$-5{,}56\times10^{-15}$		
	YSA	0,82	0,35	0,28	1,58	26,94	$3{,}05\times10^{-15}$	***t***	**p**
Test	ÇRA	0,84	0,33	0,27	1,54	26,90	$6{,}11\times10^{-15}$	-0,956	0,346
	YSA	0,75	0,34	0,27	1,55	26,91	$4{,}27\times10^{-15}$	0,024	0,981

Topraküstü karbon (TÜK) parametresi için en yüksek ilişki Sentinel-2 uydu görüntüsünden elde edilen 15×15 pencere boyutundaki tekstür verileri ile elde edilmiştir. Kullanılan modelleme tekniklerinde en yüksek belirtme katsayısı YSA metodunda elde edilmiştir (R^2=0,89) (Çizelge 4.33).

Çizelge 4.32 Topraküstü karbonun uzaktan algılama verileri ile model performans ölçütleri

	Metot	**R^2**	**RMSE**	**MAE**	**BIC**	**AIC**	**BIAS**	**Eşlendirilmiş *t*-test**	
Model	ÇRA	0,86	39,74	31,17	5,88	21,68	$-7{,}38\times10^{-14}$		
	YSA	0,89	36,93	27,69	6,25	31,61	$-7{,}38\times10^{-14}$	***t***	**p**
Test	ÇRA	0,82	46,75	38,24	6,48	31,84	$7{,}13\times10^{-16}$	-2,054	0,726
	YSA	0,77	53,79	41,58	6,62	31,99	$-2{,}79\times10^{-15}$	-1,365	0,119

Her iki teknikte de modeller başarılı çıkmıştır. Fakat model-test başarıları birlikte değerlendirildiğinde en başarılı ve uygun metodun ÇRA da olduğu görülmektedir (Model R^2=0,88; RMSE=37,64 ton/ha, Test R^2=0,82; RMSE=46,75 ton/ha). ÇRA ve YSA metoduna ait test gözlem ve tahminleri arasında yapılan *t* test sonucuna göre modeller 0,05 önemle kullanılabilir çıkmıştır (ÇRA t=-2,054, p=0,726 – YSA t=-1,365, p=0,119). Test sonuçları da ÇRA metodunda gözlem ve tahmin verileri arasında YSA metoduna göre daha uygulanabilir olduğu tespit edilmiştir.

5. TARTIŞMA

5.1. Yersel Ölçümlere Ait Bulguların Değerlendirilmesi

5.1.1. Meşçere parametrelerine ait bulguların değerlendirilmesi

Her bir örnek alanda hesaplanan meşcere parametreleri (meşcere orta çapı (d_g), meşcere üst boyu ($h_{üst}$), meşcere ağaç sayısı (N), meşcere göğüs yüzeyi (G) ve meşcere hacmi (V), YAİ, TÜB ve TÜK) hektara çevirme katsayısı ile çarpılarak hektardaki değerleri hesaplanmıştır. Daha sonra yersel ölçümlere ait tanımlayıcı istatistikler hesaplanmıştır (Çizelge 4.1). Yersel ölçümlerden orta çapa ait istatistikler incelendiğinde; minimum d_g 5,6 cm, maksimum d_g 55,9 cm ve ortalama d_g 24,1 cm olduğu tespit edilmiştir. Maksimum ve minimum değer sonuçları orman amaenajman gelişim çağlarından en genç meşçere olan a çağı (çap ≤ 7,9 cm) ve en yaşlı meşçere olan e çağı (52,0 cm ≥) sınırlarını temsil yeteneğinde olduğu ve her gelişim çağından örnek alan alındığını göstermektedir. Ortalama çapın 24,1 cm olması örnek alanların ağırlıklı olarak genç meşcerelerden oluşmasından kaynaklanmaktadır. Yine önemli bi değişken olan ve orta çap değerinden türetilen hacim parametresine ait 184 örnek alan için veri istatistikleri incelendiğinde (Çizelge 4.1); minimum meşcere hacmi 21,05 m^3/ha, maksimum meşcere hacmi 865,65 m^3/ha, ortalama meşcere hacmi 259,39 m^3/ha ve son olarak standart sapma ise 225,17 m^3/ha olarak hesaplanmıştır. Meşcere hacmine ait ölçüm verileri incelendiğinde minimum ve maksimum hacim değerleri genç ve yaşlı meşcerelerden alınan örnek alanlara ait verilerden kaynaklandığını göstermektedir. Ortalama meşcere hacminin 259,39 m^3/ha olması örnek alanların ağırlıklı olarak genç meşcerelerden alınmasından kaynaklanmaktadır.

Meşçere parametrelerinden göğüs çap değerinden üretilen bir diğer parametre de meşcere göğüs yüzeyi (G) değeridir. Meşcere göğüs yüzeyine ait istatistiki sonuçlar incelendiğinde (Çizelge 4.1); minimum meşcere göğüs yüzeyi 4,21 m^2/ha, maksimum meşcere göğüs yüzeyi 79,41 m^2/ha ve ortalama meşcere göğüs yüzeyi ise 28,15 m^2/ha olarak hesaplanmıştır. Meşcere göğüs yüzeyinin meşçere orta çapından türetilmesi ve örnek alanların ağırlıklı olarak genç meşçerelerden oluşması dolaysı ile ortalama göğüs

yüzeyi değerinin maksimum göğüs yüzey değerinden uzak olma eğilimini açıklamaktadır. Ağaç sayısına (N) ait tanımlayıcı istatistikler (Çizelge 4.1) ise minimum ağaç sayısının 100 adet/ha, maksimum ağaç sayısı 2.800 adet/ha ve ortalama ağaç sayısı ise 689,74 adet/ha olarak hesaplanmıştır. Minimum ağaç sayısı genellikle gençleştirme çağına gelmiş ve kapalılığı kırılmış meşçerelerden kaynaklanmaktadır. Maksimum ağaç sayısının fazlalığı da tam tersi olarak genç sıkışık meşçerelerden kaynaklanmaktadır. Ortalama ağaç sayısı ise genç meşcerelerin yoğunlaşması dolayısı ile minimum ağaç sayısından uzaklaşma eğilimimde olduğunu göstermektedir. Son olarak herhangi bir meşcere parametresinden türetilmeyen bireysel ölçümler ile hesaplanan meşcere üst boyu ($h_{üst}$) değeri hesaplanmıştır. Meşcere üst boyu sonuçlarında ise minimum meşcere üst boyu 4,52 m, maksimum meşcere üst boyu 34,90 m ve ortalama meşcere üst boyu da 16,89 m olarak hesaplanmıştır. Maksimum ve minimum değerler yine meşçerelerin genç ve yaşlılık durumlarına göre değişiklik göstermektedir. Genç meşcereler boy büyümesini tamamlayamadığı için daha düşük boy değeri gösterir iken, yaşlı meşcereler özellikle gençleşme zamanı gelmiş idare sürelerini doldurmuş meşçereler olarak genel ortalama artımlarının maksimum oldukları zamana denk gelmesi dolayısı ile üst boyda yüksek değer sergilediği göstermektedir. Meşcere üst boyuna ait ortalama değer ise örnek alanlara ait üst boy değerlerinin homojen ve ormancılık büyüme yasaları doğrultusunda olduğunu göstermektedir. Genel olarak meşçere parametre sonuçları değerlendirildiğinde değişim aralıklarının (Mak.- Min.) oldukça açık olduğu ve örneklerin bu aralıklarda tamamlayıcı bir dağılım gösterdiği, yani genel olarak gelişim çağı, kapalılık ve bonitet değişkenlerinden her parametrenin örneklenebildiğini, örnek alan seçiminin iyi yapıldığını ve çalışmaya ait temsil yeteneğinin yüksek olduğunu göstermektedir. Saf sarıçam meşçerelerinde yapılmış orman envanterlerine ait bazı araştırma sonuçları aşağıda belirtilmiştir.

Yavuz vd. (2010) tarafından yapılan çalışma sonuçları incelendiğinde; meşcere orta çapı için minumun değeri 7,4 cm, maksimum 52 cm ve ortalam meşcere orta çapını 29,5 cm olarak tespit etmişlerdir. Ortalama meşcere üst boyunun ise 21,1 m olduğu görülmektedir. Ağaç sayısı için minimum 94 adet/ha, maksimum ağaç sayısının 9.694 adet/ha ve ortalama ağaç sayısı ise 874,8 adet/ha olarak hesaplamışlardır. Meşcere göğüs yüzeyi için minimum, maksimum ve ortalama değerler ise sırası ile 10,6, 76,4 ve 37,6 m^2/ha olarak

hesaplamışlardır. Son olarak meşcere hacmi incelendiğinde minimum meşcere hacmi 55,1 m^3/ha, maksimum meşcere hacmi 1.098 m^3/ha ve ortalama meşcere hacmi de 419,3 m^3/ha olarak hesaplanmıştır. Sonuçlar ağaç türü ve coğrafi konum olarak yapılan doktora çalışmasıyla benzerlik göstermesi ve sonuçların karşılaştırılması açısından önem arz etmektedir. Meşçere parametrelerine ait sonuçlar karşılaştırıldığında yersel ölçüm olarak yüksek benzerlikte olduğu görülmektedir. Meşcere orta çapı, meşcere göğüs yüzeyi, meşcere hacmi ve ağaç sayıları ortalama değerleri birbirine yakın sonuçlar göstermiştir.

Sarıçam için yapılan bir diğer çalışma olan Kastamonu ve Sinop yöresi doğal sarıçam (*Pinus slyvestris* L.) meşcereleri için ekolojik tabanlı büyüme modelleri (Sağlam 2021) çalışmasında yapılan örnek alan ölçüm sonuçları; göğüs çapı için minumum 17,7 cm, maksimum 90,2 cm ve ortalama 37,6 cm, ağaç boyu için minumum, maksimum ve ortalama boy değerleri sırası ile 11,1 m, 35,3 m ve 21,6 m olarak hesaplamışlardır. Yine bu çalışmanında yöre ve tür bakımından benzerlik göstermesi ile hesaplanan meşcere parametre sonuçlarının benzerliği çalışmaya ait yersel ölçümlerin tutarlılığını göstermektedir.

Dal (2019)'ın Kastamonu yöresi sarıçam meşcerelerinde çap dağılımlarının modellenmesi ile ilgili çalışmasında meşcere parametrelerine ilişkin sonuçlar değerlendirildiğinde de ağaç sayısının minimum 200 adet/ha olduğu, meşcere orta çapına ait minumum değerinin 8 cm ve maksimum meşcere orta çapının 62 cm olduğunu belirlemiştir.

Ercanlı vd. (2007) tarafından sarıçam için yapılan bir araştırmada ağaç sayısı minimum değerin 48 adet/ha, maksimum 1.000 adet/ha ve ortalama ağaç sayısının 349 adet/ha olduğunu tespit edilmiştir. Meşcere göğüs yüzeyinde ise minimum, maksimum ve ortalama değerler sırası ile 3 m^2/ha, 61,6 m^2/ha ve 29,8 m^2/ha olarak belirlemiştir. Son olarak meşcere hacmine ait istatistiki sonuçlar incelendiğinde minimum meşcere hacmi 32,7 m^3/ha, maksimum 590,7 m^3/ha ve ortalama meşcere hacmi ise 279,7 m^3/ha olarak hesaplamıştır.

Sarıçam için yapılan bir diğer araştırmada (Erkan and Güner 2018, Güner *et al.* 2012) örnek alanlara ait meşcere hacmi ve ağaç sayısına ait istatistiki sonuçlar incelendiğinde minimum meşcere hacmi 218,7 m^3/ha, maksimum meşcere hacmi 683,2 m^3/ha ve ortalama meşcere hacmi ise 411,3 m^3/ha olarak hesaplamışlardır. Ağaç sayısına ait sonuçlar incelendiğinde de minimum, maksimum ve ortalama ağaç sayıları sırası ile 500 adet/ha, 2.000 adet/ha ve 1.035 adet/ha olarak tespit edilmiştir.

5.1.2. Topraküstü biyokütle (TÜB) ve topraküstü karbon (TÜK) bulgularının değerlendirilmesi

Her bir örnek alan için hesaplan topraküstü biyokütle (TÜB) değerleri incelendiğinde minimum TÜB 12,34 ton/ha, maksimum 324,92 ton/ha ve 104,88 ton/ha ortalama değer hesaplanmıştır (Çizelge 4.1). Ortalama topraküstü biyokütle değeri örneklemenin ağırlıklı olarak genç meşcerelerde olmasının bir göstergesidir. Her bir örnek alan için hesaplan topraküstü karbon (TÜK) değerleri incelendiğinde (Çizelge 4.1) minimum TÜK 11,13 ton/ha, maksimum 401,50 ton/ha ve 122,98 ton/ha ortalama değer hesaplanmıştır. TÜB ve TÜK'ün hesaplanmasına ait bazı araştırmalar aşağıda verilmiştir.

Kocaman ve Durkaya, (2020)'de yapmış oldukları bir araştırmada; Bolu Orman Bölge Müdürlüğü, Aladağ Orman İşletme Müdürlüğü, Demirciler Orman İşletme Şefliği ormanlarının 1986-1995 ve 2009-2018 yıllarına ait biyokütle ve karbon tutma kapasiteleri hesaplamışlardır. Hesaplamada hem biyokütle denklemleri hem de BEF katsayıları kullanarak hesaplama yapmışlardır. Sonuçlar incelendiğinde 1986-1995 plan döneminde iğne yapraklı meşcerelerde biyokütle denklemleri ile 103,20 ton/ha karbon değeri tespit ederken, BEF yöntemiyle 92,18 ton/ha olarak hesaplamışlardır. 2009-2018 plan döneminde ise ABD yöntemi ile 127,63 ton/ha ve BEF yöntemi ile de 122,43 ton/ha karbon değeri hesaplamışlardır. Sonuçlar doktora çalışmasından elde edilen ortalama değerler ile benzerlik göstermektedir.

Okan (2018)'ın yapmış olduğu lisansüstü tez çalışmasında ise Bartın OİM Arıt ve Kurucaşile plan üniteleri için ibreli orman alanlarına ait hektardaki ortalama biyokütle ve karbon miktarları sarası ile Arıt için; 189,94 ton/ha ve 91,40 ton/ha olarak

hesaplamışlardır. Kurucaşile plan ünitesi için ise 190,93 ton/ha ve 95,46 ton/ha olarak hesaplamışlardır. Sonuçlar bu doktora çalışmasından elde edilen ait ortalama TÜB ve TÜK değerleri ile yakınlık göstermektedir.

5.1.3. Yaprak alan indeksine (YAİ) ait bulguların değerlendirilmesi

Çalışmada her bir örnek alan için hesaplanan yaprak alan indeksi (YAİ) değerleri minimum 0,253 m^2 m^{-2} ve maksimum 2,474 m^2 m^{-2} değerlerinden oluştuğu görülmüştür. Uç değerlere ait meşçere özellikleri incelendiğinde düşük YAİ değerlerinin yaşlı ve 1 kapalı meşçerelerde, yüksek YAİ değerlerinin ise 3 kapalı meşçerelerde elde edildiği tespit edilmiştir. Birçok çalışmada YAİ değerinin yetişme ortamı faktörleri dikkate alınarak 1 ile 20 m^2 m^{-2} arasında olabileceği belirtilmiştir (Kara vd. 2011). Çalışma Karadeniz şeridinde gerçekleştirilmiş olmasına rağmen çoğu örnek noktanın denizsellik etkisinden yararlanamayan karasallığın daha etkili olduğu örnek alanlarda YAİ değerinin 1 m^2 m^{-2}'nin altına düşebildiği görülmektedir. Örnek alanlara ilişkin YAİ değerleri ile çalışmada hesaplanan meşçere parametreleri arasında ilişkiler değerlendirilmiş ve YAİ'nin meşcere ağaç sayısı (N) hariç diğer bütün parametreler ile negatif yönlü ilişkide olduğu tespit edilmiştir. Sadece N ile pozitif yönde ve yüksek bir ilişki olduğu tespit edilmiştir (r = 0,71). Genel meşçere parametrelerine ait YAİ ilişkileri (r); meşcere hacmi, meşcere göğüs yüzeyi, meşcere üst boyu, meşcere orta çapı, topraküstü biyokütle ve karbon için sırası ile; -0,179, -0,170, -0,463, -0,540, -0,155 ve -0,221 olarak hesaplanmıştır.

Benzer çalışmalar incelendiğinde Göztaşı (2019) Taşköprü-Tekçam sarıçam klonal tohum bahçesi'nde yapmış olduğu lisansüstü tez çalışmasında sarıçam yaprak alan indeks değerlerinin 0,720 – 2,180 m^2 m^{-2} arasında değiştiğini ve 14,8 cm – 30,9 cm çap değerlerine ait uç YAİ değerleri ile çap basamakları arasında anlamlı bir ilişki bulunamadığını tespit etmiştir. Bir diğer araştırmada ise sarıçam için YAİ değerini ortalama 6,26 m^2 m^{-2} olarak hesaplamışlardır (Öner ve Çakır 2006).

Bulut (2021) yapmış olduğu doktora tez çalışmasında da saf karaçam meşçereleri için YAİ değerlerinin 0,332 m^2 m^{-2} ile 3,525 m^2 m^{-2} arasında değiştiğini, YAİ ile meşçere

parametreleri arasındaki en iyi ilişki meşcere ağaç sayısı için elde edilmiştir (r= 0,58). Bulut (2021)'in ulaştığı sonuçlar bu doktora çalışmasında da elde edilmiştir. Benzer olarak Ercanlı *et al.* (2018) yaptıkları çalışmada saf karaçam meşcereleri için YAİ ve meşcere yaşı arasında negatif bir ilişki bulmuşlar (r =-0,294) ve en yüksek ilişkiyi ağaç sayısı ile elde etmişlerdir (r = 0,564). Özbayram vd. (2015) kızılçam meşcerelerinde yaprak alan indeksi ve meşcere göğüs yüzeyi arasında pozitif yönlü korelasyon ilişkisi (r =0,69) bulmuşlardır.

Çalışmaya ait YAİ değerleri meşçere gelişim çağı ve kapalılık sınıfları itibari ile gruplandırılarak da ele alınmıştır. Sonuçlar a, b, c ve d gelişim çağları için YAİ'nin sırası ile 1,613 $m^2 m^{-2}$, 1,145 $m^2 m^{-2}$, 1,150 $m^2 m^{-2}$ ve 0,971 $m^2 m^{-2}$ olduğu tespit edilmiştir. YAİ değerleri incelendiğinde meşcere yaşlandıkça YAİ değerinin azaldığı, genç meşçereler de daha yüksek ortalama YAİ değerlerinin elde edildiği görülmüştür.

Genç sarıçam meşcerelerinde meşcere yaşı ile YAİ arasındaki ilişkiler araştırıldığı bir çalışmada (Jagodzinski and Kalucka 2008) ise örneklenen meşcerelerin yaşı 0-20 arasında değişmektedir. Meşcerelerde ilk 20 yılda meşcere yaşı ve YAİ ilişkisinin zamana bağlı olarak arttığı görülmüştür. Yapılan bu doktora çalışmasında benzer şekilde maksimum YAİ değeri genç yaşta (17) belirlenmiş (2,08 $m^2 m^{-2}$), sonraki yaşlarda hızla azalmaya başladığı gözlemlenmiştir (1,59 m^2 m^{-2}). Bu durum gençlik çağındaki meşcerelerin olgunlaşması sürecinde görülebildiği ve aynı yaşlı ormanlarda meşcerelerin kapalılık oluşumuna kadar YAİ'deki artış devam etmesi ile açıklanmaktadır (Ryan *et al.* 1997).

Kapalılık sınıflarına göre YAİ değerleri incelendiğinde ise sırası ile 1, 2 ve 3 kapılık sınıfı için sırası ile 0,570 $m^2 m^{-2}$, 1,110 $m^2 m^{-2}$ ve 1,481 $m^2 m^{-2}$ olarak hesaplanmıştır. Değerler incelendiğinde YAİ'nin kapalılık sınıfları ile doğru orantılı bir korelasyon ilişkisi sergilediği görülmektedir. Kapalılık derecesinin artması ile YAİ değerleri artış göstermektedir. Kapalılık ile YAİ arasındaki bu ilişki aynı zamanda meşcere ağaç sayısı için yüksek YAİ korelasyonunu da açıklamaktadır.

Çalışmada meşcere ağaç sayısı hariç diğer meşçere parametrelerinde negatif yönlü ve düşük korelasyon ilişkisi bulunmuştur. Bunun çeşitli sebepleri olması ile birlikte bu sebeplerden bir tanesi ve en önemlisi meşçere parametrelerinin birçoğunun göğüs çapından türetilmesi ve göğüs çapı ile YAİ arasında negatif yönlü (r=-0,540) bir korelasyon ilişkisinin bulunması, dolayısı ile YAİ'nin diğer meşcere parametreleri ile olan ilişkiyi etkileyebileceği söylenebilmektedir. Diğer bir neden ise YAİ'nin belirlenme yöntemin etkili olabileceği söylenebilir. Yarı-küresel çekilen fotoğraflar manuel bir şekilde belirlenen eşik değerleri ile analize tabi tutularak YAİ belirlenmiştir. Bu eşik değerinin olması gerektiğinden düşük veya yüksek seçilmesi de YAİ değerinde belirli oranlarda sapmalara neden olabilmektedir.

Meşçere parametreleri ile YAİ benzerliğinin araştırıldığı bazı çalışmalarda pozitif ve yüksek korelasyonda ilişkiler tespit edilmiştir. Aynı yaşlı saf ve doğal karaçam meşcereleri için yaprak alan indeksi (YAİ) ile çeşitli meşcere özellikleri (meşcere orta çapı, meşcere yaşı, meşcere üst boyu, bonitet endeksi, ağaç sayısı, meşcere göğüs yüzeyi, meşcere sıklık derecesi, tepe biyokütlesi ve tepe boyutları) arasındaki ilişkilerin belirlemeye çalışıldığı bir çalışmada, YAİ ile orta çap (r=0,185), meşcere üst boyu (r=0,398), bonitet endeksi (r=0,265), meşcere ağaç sayısı (r=0,334), meşcere göğüs yüzeyi (r=0,684), meşcere sıklık derecesi (r=0,687) ve tepe biyokütlesi (r=0,684) arasında pozitif yönlü ilişkiler tespit etmişlerdir (Yer and Sakıcı, 2022). Tropikal ormanlarda meşcere göğüs yüzeyi ile YAİ arasındaki ilişkinin araştırıldığı bir çalışmada korelasyon 0,95 olarak hesaplanmıştır (Amaral *et al.* 1996). Yine Buckley *et al.* (1999) meşe ve çam meşçerelerinden elde ettikleri göğüs yüzeyi parametresi ile yaprak alan indeksini modellemişler ve çam meşçereleri için meşcere göğüs yüzeyi ile YAİ arasında 0,90 ilişki tespit etmişlerdir. Meşcere göğüs yüzeyi ile YAİ arasında yüksek seviyedeki ilişkiler de yine YAİ'nin bitki örtüsü özellikleri bakımından önemli bir belirleyici olduğunu göstermektedir. Yukarıdaki çalışmalarda elde edilen yüksek ilişkiler elde edilmesin de Amaral *et al.* (1996) çalışmasının genç meşcerelerden ve Buckley *et al.* (1999) çalışmasının plantasyon sahalarından oluşmasının büyük etkisi olduğu düşünülmektedir.

Çalışmada ağaç sayısı dışındaki bütün parametrelerde negatif yönlü bir YAİ ilişkisinin birçok sebebi olması ile birlikte birkaçını sıralamak mümkündür. Araştırmalar YAİ

değerlerinin arazi şartlarının kuraklık-nemlilik durumlarına göre yüksek oranda değişkenliğe sahip olduğu belirtilmektedir (Kozlowski *et al.* 1991, Asner *et al.* 2003, Bulut 2021). YAİ deki değişimler sadece meşçere karakteristiklerine bağlı değil özellikle iklim ve yetişme ortamı faktörleri YAİ üzerinde yüksek belirleyici orana sahiptir. Çünkü YAİ bitkilerin yaprak yüzey alanları ile pozitif yönlü bir ilişki sergilemektedir. Özellikle yarı kurak ve kurak yetişme ortamlarında bitkiler aşırı solunum sonucu bünyelerinden stomalar ile su buharlaşmasının önüne geçebilmek için yaprak yüzey alanlarını daraltırlar ve bu da doğrudan YAİ değerleri üzerinde etkili olmaktadır. Verilen bu açıklamada da görüldüğü üzere orman alanlarının yaprak alanı gelişimini ve karakteristiğini anlamak için meşcere karakteristikleri, yetişme ortamı koşulları ve iklim özelliklerinin kavranması gerekmektedir (Tanaka and Hashimoto 2006, Kara vd. 2011, Bulut 2021).

5.2. Modelleme Bulgularının Değerlendirilmesi

Bu çalışmada yersel ve uzaktan algılama veri setleri kullanılmıştır. Yersel veriler kullanılarak elde edilen meşcere parametreleri (meşcere orta çapı (d_g), meşcere üst boyu ($h_{üst}$), meşcere ağaç sayısı (N), meşcere göğüs yüzeyi (G) ve meşcere hacmi (V)), yaprak alan indeksi (YAİ), topraküstü biyokütle (TÜB) ve topraküstü karbon (TÜK) değerlerinden oluşmaktadır. Uzaktan algılama verileri ise pasif algılayıcılardan Landsat 8 Operational Land Imager (OLI), Sentinel-2 ve dron, aktif algılayıcı olarak da Sentinel-1 uydu görüntüleri kullanılmıştır. Pasif algılayıcılardan elde edilen reflektans, vejetasyon indisi, tekstür ve parlaklık değerleri ile aktif algılayıcılardan her bir polarizasyon için elde edilen geri yansıtım değerleri hesaplanarak veri setleri hazırlanmıştır. Meşcere parametrelerinin, YAİ, TÜB ve TÜK'ün modellenmesinde uzaktan algılama verileri kullanılmıştır. Modelleme için çoğul regresyon analizi (ÇRA) ve yapay sinir ağları (YSA) teknikleri kullanılmıştır. İlk aşamada ÇRA metodu kullanılarak meşçere parametrelerinin her biri ve YAİ, TÜB, TÜK için ÇRA ile en yüksek ilişkili modeller üretilmiş ve en uygun bağımsız değişkenler belirlenmiştir. Uzaktan algılama verileri ile uygulanan ÇRA metodunda modellenen bütün parametreler için en yüksek başarı Landsat 8 OLI ve Sentinel-2 uydu görüntüsünden elde edilen tekstür verileri ile elde edilmiştir. İkinci aşamada ise en yüksek ilişkiyi gösteren modelin bağımsız değişkenleri kullanılarak YSA metodu uygulanmıştır. Ayrıca uygulanan bütün metotların model-test başarısı belirlenmiş

ve eşlendirilmiş *t*-testi ile test tahminlerinin gözlem verileri ile uyumlu olup olmadığı kontrol edilmiştir.

Son zamanlarda gelişen teknoloji ile birlikte yapay zekâ insan hayatında birçok alanda faaliyet göstermektedir. Ormancılıkta da son zamanlarda yapay sinir ağı yaklaşımı artım ve büyüme modelleri (Vinícius Oliveira Castro *et al.* 2013, Ashraf *et al.* 2013, Hamidi *et al.* 2021, Bolat 2021), çap dağılım modelleri (Yang and Yue 2014, Diamantopoulou *et al.* 2015), çap-boy modelleri (Ercanlı 2020) ve gövde çapı modelleri (Sakıcı and Özdemir 2018, Şenyurt and Ercanlı 2019, Özçelik *et al.* 2019) olmak üzere ormancılığın diğer birçok alanında (Mosaffaei and Jahani 2021, Günlü and Ercanlı 2020, Sothe *et al.* 2020, Bolat 2021) da sıklıkla kullanılmaktadır. Bu çalışmada da YSA olarak da Bayesçi yapay sinir ağı kullanılmıştır (BYSAM). Yapay sinir ağları için karşılaşılan en büyük problem modelde aşırı uyum ve uyumsuzluk durumlarıdır. Çalışmada bağımlı her bir değişken için farklı öğrenme ve momentum değerleri uygulayarak her değişkene ait 17 model oluşturulmuştur. Daha sonra model – test belirtme katsayılarındaki durumlar incelenerek uyum problemi olmadığı kararlaştırılan modeller çalışma kapsamında en başarılı model olarak tercih edilmiştir.

Bazı araştırmalarda YSA ve ÇRA model performansı karşılaştırılmış ve sırası ile; doğrusal olmayan regresyon model (Diamantopoulou and Özçelik 2012), doğrusal regresyon model (Liu and Zhang 2005) ve olasılık yoğunluk fonksiyonu (Diamantopoulou *et al.* 2015) gibi teknikler ile kıyaslanmış ve YSA metodunun daha başarılı sonuçlar verdiği tespit edilmiştir. YSA metodunu ÇRA dan avantajlı kılan bir diğer özellik ise YSA modellere yeni değişkenler ekleyebilerek kolayca geliştirebilme kolaylığı regresyon modeller kadar kısıtlı olmadığıdır. Başka bir çerçeveden bakıldığında özellikle doğrusal olmayan modellere yeni değişkenler eklenerek modellerin yakınsak çözüm sunması başlangıç parametre değerlerinin belirlenmesindeki zorluklardan dolayı kısıtlı kalmaktadır (Desta *et al.* 1999, Bolat 2021).

YSA'nın dezavantajlarına bakıldığında ise aşırı uyum (Overfitting) en büyük problem olarak karşımıza çıkmaktadır (Özçelik *et al.* 2010). Çalışmalarda aşırı uyum problemine karşı alınabilecek önlemler değerlendirildiğinde literatürde şu önerilerle

karşılaşılmaktadır; verilerin dengeli bir şekilde eğitim, test ve validasyon olarak ayrılması, ağın yeniden birkaç kez eğitilmesi, uygun transfer fonksiyonunu seçilmesi, seçilen transfer fonksiyonuna göre verilerin ölçeklendirilmesi ([0,1], [-1, 1]) ağın erken durdurma kriteri (early stopping), öğrenme oranının (learning rate) ve momentum değerinin belirlenmesi aşırı uyum problemi üzerinde ki en önemli faktörler olarak görülmektedir (Maier and Dandy 2000, Diamantopoulou *et al.* 2009, Bolat 2021).

Diamantopoulou *et al.* (2009) özellikle öğrenme oranının, momentum değerinin ve erken durdurma değerinin önemine vurgu yapmıştır. Bazı araştırmacılar öğrenme oranı ve momentum değerleri üzerinde tavsiyede bulunmuşlardır. Bunlardan Liu and Zhang (2005) öğrenme oranının 0,1-0,7 aralığında ve momentum değerinin 0,2-0,8 aralığında belirlenmesi önermiştir. Diğer bir çalışma ise Maier and Dandy (2000) öğrenme oranın 0,1-0,95 ve momentum değerinin 0,05-0,9 aralığında bir değer seçilmesini tavsiye etmiştir.

Bu çalışmada da BYSAM modelde [0,1], arasında değişen öğrenme ve momentum oranları kullanılarak her bir bağımlı değişken için 17 model elde edilmiştir. Bu modeller içerisinden uyum problemi olmadığı düşünülen modeller kararlaştırılmış ve bunlar içinden de en düşük toplam rölatif hataya sahip model ilgili parametre için en başarılı model olarak kabul edilmiştir.

Parametrelerden elde edilen BYSAM model sonuçlarına örnek verecek olursak; meşcere hacmi için model test belirtme katsayısı incelendiğinde 17 model içerisinde sadece 4 model için uyum problemi olmadığı kararlaştırılmıştır (Çizelge 4.17) ve bu modeller içerisinden model – test başarısı en yüksek ve toplam rölatif sırası en düşük olan model başarılı kabul edilmiştir (Model R^2=0,83, Test R^2=0,77). Normalde meşcere hacmi için en yüksek belirtme katsayısı V4 model de (Model R^2=0,86, Test R^2=0,83) olmasına rağmen aşırı uyum problemi (Overfitting) olabildiği düşünülerek uygun model olarak tercih edilmemiştir. Uyum probleminin oluşmasındaki nedenlerden bazıları eğitim veri setinin yetersiz, temsil kabiliyeti zayıf ve aykırı veri oranının yüksek olmasıdır (Ying 2019).

5.2.1. Meşcere parametrelerine ilişkin modelleme bulgularının değerlendirilmesi

Meşçere parametrelerine ilişkin sonuçlar değerlendirildiğinde bütün parametrelere ait en yüksek model ve test belirtme katsayıları ile en düşük toplam rölatif sıra Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen tekstür veri setleri ile elde edilmiştir. Meşcere hacmi için Landsat 8 OLI uydu görüntüleri 135°'lik tekstür verileri ile YSA metodunda en yüksek model ve test belirtme katsayıları elde edilmiştir (Model R^2=0,83, Test R^2=0,77) (Çizelge 4.25). Meşcere göğüs yüzeyi için ise Sentinel-2 15x15 pencere boyutundaki tekstür verileri ile YSA da en yüksek model ve test belirtme katsayıları elde edilmiştir (Model R^2=0,84, Test R^2=0,77) (Çizelge 4.26). Sentinel-2 15x15 pencere boyutundaki tekstür verileri ile modellenen meşcere ağaç saysına ilişkin başarı düzeyleri incelendiğinde de YSA metodunda en yüksek belirtme katsayısı bulunmuştur (Model R^2=0,81, Test R^2=0,69) (Çizelge 4.27). Meşcere üst boyuna ait sonuçlar ÇRA metodunda model ve test belirtme katasıyalar en yüksek olmasına rağmen (Model R^2=0,82, Test R^2=0,81) eşlendirilmiş t test sonuçlarında p değerinin 0,05'ten küçük olması dolayısı ile YSA ait sonuçlar istatistiki olarak uygulanabilir olması nedeniyle meşcere üst boyu için en uygun metot'un YSA olduğu tespit edilmiştir (Model R^2=0,71, Test R^2=0,68) (Çizelge 4.28). Bütün meşçere parametreleri içerisinde en yüksek model ve test belirtme katsayısı meşcere orta çapı için Sentinel-2 uydu görüntüsünden elde edilen 7x7 pencere boyutundaki tekstür verileri ile YSA metodu ile elde edilmiştir (Model R^2=0,89, Test R^2=0,81) (Çizelge 4.29). Meşcere orta çapına ait belirtme katsayılarının yüksek başarı göstermesi veri ayrımının meşcere orta çapına bağlı olarak gerçekleştirilmesinden kaynaklandığı söylenebilir. Uzaktan algılama verileri kullanılarak meşçere parametrelerinin tahminine yönelik yapılmış çalışmalara aşağıda değinilmiştir.

Landsat 7 ETM+ uydu görüntüsüne ait tekstür verileri kullanılarak ÇRA metodu ile meşcere orta çapı, meşcere üst boyu, meşcere göğüs yüzeyi ve meşcere hacmini tahmin edildiği bir çalışmada sırası ile 0,08, 0,16, 0,14 ve 0,17 belirtme katsayılarını elde etmişlerdir (İnan 2004). Yine Landsat 8 OLI uydu görüntüsüne ait farklı pencere boyutundaki tekstür verileri kullanılarak meşcere ağaç sayısı, meşcere orta çapı, meşcere hacmini ve meşcere göğüs yüzeyini ÇRA ve YSA metotlarını modellemeyi amaçlayan bir çalışmada ÇRA ve YSA metodlar için sırası ile belirtme katsayıları 0,18, 0,34, 0,33

ve 0,40, 0,61, 0,63, 0,65 ve 0,59 olarak hesaplamışlardır (Sakıcı and Günlü 2018). Çalışmada ÇRA metoduna ait sonuçlar YSA metodundan daha düşük olduğu görülmüştür. Bizim çalışmamızda da YSA belirtme katsayıları ÇRA'ya göre genel olarak daha yüksek çıkması ile benzerlik göstermektedir.

Demirel and Özkan (2018) tarafından yapılan çalışmada da dijital hava fotoğrafları kullanılarak karaçam meşcerelerinde; meşcere hacmi, hacim artımı ve ağaç sayısının modellenmesi araştırmışlardır. Sonuçlar incelendiğinde, meşcere hacmi, hacim artımı ve ağaç sayısı için R^2'ler sırasıyla 0,74, 0,73 ve 0,50 olarak tespit etmişlerdir. İstatistiksel modellerin koruma ve hizmet amaçlı ormanların bazı meşcere parametrelerinin tahminde kullanılabilir olduğu çıkarımında bulunmuşlardır.

Demirel (2022) saf sarıçam meşcerelerinde Sentinel-1 ve Sentinel-2 uydu görüntüleri ile meşçere orta çapı, ağaç sayısı, meşcere göğüs yüzeyi, meşcere hacmi ve meşcere sıklığını modellemeye çalıştığı araştırmada sonuçlar, orta çap için en yüksek başarıyı (R^2=0,31) Sentinel-2 uydu görüntüsü piksel değerleri ortalaması ile elde ettiğini göstermektedir. Ağaç sayısı, meşcere göğüs yüzeyi, meşcere hacmi ve meşcere sıklığında en yüksek başarıyı ise sırası ile R^2=0,28, R^2=0,34, R^2=0,12 ve R^2=0,43 Sentinel-2 uydu görüntüsünün piksel değerlerinin toplamından elde etmiştir. Sentinel-2 uydu görüntüsü ile yüksek belirtme katsayıları elde etmesi yönüyle çalışmamız ile benzerlik göstermektedir.

Karahalil vd. (2017) yapmış oldukları bir çalışmada Landsat 8 OLI ve WorldView-2 uydu görüntülerine ait piksel değerleri ile bazı meşcere parametrelerini ÇRA ile modellemişlerdir. Sonuçlar geliştirilen modeller içerisinde ağaç sayısı, meşcere hacmi ve meşcere göğüs yüzeyi dikkate alındığında en yüksek başarıyı Landsat 8 OLI uydu görüntüsüne ait verilerle elde edildiği görülmektedir. Ağaç sayısı, meşcere hacmi ve göğüs yüzeyi Kelkit araştırma alanı için belirtme katsayıları sırasıyla 0,44, 0,77 ve 0,77 ve İğdir araştırma alanı için ise 0,60, 0,75 ve 0,80 olarak hesaplamışlardır.

Chrysafis *et al.* (2019) yaptıkları çalışmada, Sentinel-2 uydu görüntüsünden elde edilen tekstür verileri ile meşcere hacmini modellemişlerdir. Farklı pencere boyutu ve dereceler

den elde edilen tekstür verileri ile meşcere hacmi arasındaki ilişkiler incelendiğinde; En yüksek başarıyı 0°'lik 3x3 pencere boyutuna ait tekstür verileri ile elde etmiştirler (R^2=0,91). Çalışmamızda da meşcere parametrelerine ilişkin en yüksek başarının pencere boyutundaki tekstür verileri ile elde edilmesi ile benzerlik göstermektedir.

Spot-5 uydu görüntüleri ile topoğrafik özelliklerine ait veriler kullanılarak bazı meşcere parametrelerini modellemeyi amaçlayan bir diğer çalışmaya ait sonuçlar incelenmiştir. En yüksek belirtme katsayılarını meşcere hacmi (R^2 = 0,82) ve meşcere göğüs yüzeyinin (R^2 = 0.78) modellenmesinde elde etmişlerdir. Topoğrafik verilerin model başarıları üzerine etkilerine bakıldığında da yükseklik ve eğim değerlerinin önemli derecede etkili olduğunu vurgulamışlardır. Özetle Spot-5 uydu görüntülerinden elde edilen veriler ile topografik verilerin kombine kullanımının meşcere parametrelerinin modellenmesinde başarıyı artırmaya yönelik iyi bir uygulama olasılığına sahip olduğunu ifade etmişlerdir. (Xie *et al.* 2020). Spot-5 uydu görüntüsü kullanılarak hesaplanan yansıma değerleri ve vejetasyon indisleri ile meşçere parametrelerini modellemeyi amaçlayan bir başka çalışmada sonuçlar yansıma değerlerine ait veri setleri ile meşcere orta çapı, meşcere üst boyu, ağaç sayısı, meşcere göğüs yüzeyi ve meşcere hacmi için sırası ile 0,50, 0,46, 0,23, 0,63 ve 0,55 belirtme katsayılarını elde etmişlerdir. Vejetasyon indisleri ile ÇRA metodu ile elde ettikleri model belirtme katsayılarını ise yine sırası ile 0,32, 0,31, 0,26, 0,28 ve 0,30 bulmuşlardır (Özkan 2003). Chrysafis *et al.* (2017) Sentinel-2 ve Landsat 8 OLI uydu görüntüsü kullanarak meşcere hacmini modellemeye çalıştıkları çalışmada; en yüksek başarıyı Sentinel-2 uydu görüntüsünden elde edilen yansıma değerleri (R^2=0,46) ve vejetasyon indisleri (R^2=0,52) ile elde etmişlerdir.

Meşcere parametrelerinin tahmininde elde edilen başarılı sonuçlarda, farklı pencere boyutu ve dereceler kullanılarak birçok bağımsız değişkenin modele dahil edilmesi ve yapay sinir ağlarının kullanılması model başarıları üzerinde büyük etkisi olduğu görülmektedir. En uygun pencere boyutu ve derecelerin belirlenmesi ile başarı düzeyi yüksek modeller üretilmiştir. Burada hangi parametre için hangi pencere boyutu ya da derecenin daha başarılı olacağı deneme yanılma yöntemiyle bütün pencere boyutu ve derece de veri setleri ile her bir parametre modellenmiş ve en düşük toplam rölatif hataya ve en yüksek belirtme katsayısına sahip veri seti tespit edilmiştir. Meşçere

parametrelerinin modellenmesinde özellikle algılayıcıya ait teknik özellikler, meşçere parametreleri ve arazi yapısı büyük etkiye sahiptir. Özellikle çalışmada faklı derecelerde veri setleri kullanılması (0°, 45°, 90° ve 135°) optimal derece değerinin belirlenmesinde uyduların gün içerisindeki algılama zamanı ile yakından ilgilidir. Çünkü çalışmada kullanılan Landsat 8 OLI ve Sentinel-2 uydu görüntülerinin ülkemizdeki algılama süreci sabah saatlerinde gerçekleşmektedir (USGS 2000). Bu saatlerdeki atmosfer şartları, algılayıcının yönü ve güneşin geliş açısı gerçekleştirilecek olan algılamayı doğrudan etkilemektedir (Ateşoğlu 2009, Bulut 2021). Yapılacak ölçümlerin bu doğrultuda gölge kalan yerlerde gerçekleştirilmesi, o alana ait elde edilecek uzaktan algılama verilerinin temsiliyet kabiliyetini azaltmaktadır. Bu dezavantajı farklı derecelerde veriler üretilerek minimize etmek amaçlanmıştır. Çalışmada kullanılan diğer bir pasif algılayıcı olan dron görüntüleri 90° kamera açısı ve güneş ışınlarının yer yüzene en dik açı ile geldiği zamanlarda çekim yapılmaya çalışılarak gölge yerlerin ve o alana ait elde edilecek uzaktan algılama verilerinin en yüksek temsiliyette elde edilmesi amaçlanmıştır.

Çalışmada meşçere parametreleri Landasat 8 OLI, Sentinel-2 ve dron görüntülerinden elde edilen reflektans ve vejetasyon indis değerleri ile de modellemeye çalışılmıştır. Meşçere parametrelerine ait bulgular incelendiğinde genel olarak en düşük belirtme katsayısı reflektans ve vejetasyon indisleri için dron görüntülerinden elde edilmiştir. Meşcere hacmi için en yüksek model başarısı Landsat 8 OLI uydu görüntüsü reflektans değerleri ile (R^2=0,55) buna karşın Sentinel-2 uydu görüntüsünde ise vejetasyon indis değerlerinden elde edilmiştir (R^2=0,60) (Çizelge, 4.2 ve 4.3). Meşcere göğüs yüzeyi için hem reflektans hem de vejetasyon indisleri için en yüksek başarı Landsat 8 OLI uydu görüntüsünden elde edilmiştir. Meşcere göğüs yüzeyine ait reflektans ve vejetasyon indis değerleri ile model başarıları sırası ile R^2=0,48 ve R^2=0,50 olarak hesaplanmıştır (Çizelge, 4.2 ve 4.3). Meşcere ağaç sayısı için reflektans değerlerine ait en yüksek belirtme katsayısı Senntinel-2 uydu görüntüsünden (R^2=0,66), buna karşın vejetasyon indisi ise Landsat 8 OLI uydu görüntüsünden elde edilmiştir (R^2=0,63) (Çizelge, 4.2 ve 4.3). Meşcere üst boyu ($h_{üst}$) reflektans ve vejetasyon indis değerlerine göre en yüksek belirtme katsayısı (Çizelge, 4.2 ve 4.3) sırası ile Sentinel-2 uydu görüntüsünden elde edilmiştir (R^2 = 0,69, R^2=0,71). Meşcere orta çapına ait reflektans ve vejetasyon indis değerlerine göre belirtme katsayıları sırası ile 0,72 ve 0,73'tür (Çizelge, 4.2 ve 4.3). Meşcere orta çapı için

en yüksek belirtme katsayısı sırası ile (Çizelge, 4.2 ve 4.3) Landsat 8 OLI uydu görüntüsünden elde edilen reflektans ve vejetasyon indis değerlerinden elde edilmiştir (R^2=0,72, R^2=0,73).

Şenyurt vd. (2017) tarafından yapılan bir çalışmada; Landsat TM uydu görüntüsü kullanılarak bazı meşcere parametrelerinin modellenmesi amaçlanmıştır. Çalışmadan elde edilen sonuçlar incelendiğinde; meşcere orta çapı ile TM 1, TM 3, TM 4, TM 5 ve TM 7 bant parlaklık değerlerinin bağımsız değişken olarak kullanıldığı modele ait belirtme katsayısı (R^2=0.488) ve SR53 ile ASVI vejetasyon indislerinin bağımsız değişken olarak kullanıldığı model belirtme katsayısı (R^2=0.525) hesaplamışlardır. Göğüs yüzeyi ile TM 1, TM 3 ve TM 4 bant parlaklık değerlerinin bağımsız değişken olarak yer aldığı modelde başarı düzeyi (R^2=0.409) ve ARVI, MSVAI ve NR vejetasyon indis değerlerine ait model başarı düzeylerini (R^2=0.479) hesaplamışlardır. Ağaç sayısını TM 1, TM 5 ve TM 7 bant parlaklık değerlerini ile (R^2=0.367), ND73 ve ASVI vejetasyon indis değerlerine (R^2=0.446) ait veri setleri ile modellemişlerdir. Meşcere hacmi ile TM 1, TM 3 ve TM 4 bant parlaklık değerlerinin bağımsız değişken olarak yer aldığı modelde başarı düzeyi (R^2=0.453) ve SR43, SR53, SR54, ND53, ND32, ND73, ASVI, MSAVI ile NR vejetasyon indislerinin bağımsız değişken olarak yer aldığı modelde ise başarı düzeyi (R^2=0.587) bulunmuştur. Meşcere parametrelerinin modellenmesinde vejetasyon indis değerleri kullanılarak elde edilen modellerin bant parlaklık değerlerine göre elde edilen modellerden daha iyi sonuç verdiği çıkarımına varmıştır. Bu doktora çalışmasındaki vejetasyon indis değerlerine ait sonuçlarla benzerlik göstermektedir.

ÇRA metodu kullanarak Quickbird ve Landsat 7 ETM+ uydu görüntülerinden elde edilen reflektans değerleri ile saf doğu kayını (*Fagus orientalis* Lipsky) meşcereleri için meşcere hacminin modellendiği başka bir çalışmada ise model belirtme katsayıları Quickbird uydu görüntüsü ile 0,70, Landsat 7 ETM+ uydu görüntüsü için 0,55 olarak bulmuşlardır (Günlü *et al.* 2013). Çalışmamız da da Landsat 8 OLI uydu görüntüsünden elde edilen reflektans değerleri ile meşcere hacmine ilişkin belirtme katsayısı 0,55 çıkması ile benzerlik göstermektedir. Quickbird uydu görüntüsüne ilişkin belirtme katsayısının yüksek çıkması uydu görüntüsü çözünürlüğünden kaynaklandığı söylenebilir. Kahriman *et al.* (2014) yaptıkları çalışmada, Landsat TM uydusu görüntüsü kullanarak, meşcere ağaç sayısı ve

kapalılığı tahmin etmiştir. Bant değerleri kullanılarak oluşturulan modelde ağaç sayısı ve kapalılık için belirtme katsayıları 0.61 olarak bulmuşlardır. Vejetasyon indis değerleri ile oluşturulan modelde ise sırasıyla 0.70 ve 0.67 olarak bulmuşlardır. Çalışmamıza ait vejetasyon indis değerleri ile ağaç sayısının modellenmesine ilişkin belirtme katsayısı yukarıdaki çalışmadan daha düşük elde edilmiştir. Çil vd. (2015) meşcere parametrelerini modellemek için Göktürk-2, Rasat ve Landsat 8 OLI uydu görüntüleri ile dijital kamera ile çekilmiş hava fotoğraflarını kullanmışlardır. En iyi model başarısını meşcere ağaç sayısı için Göktürk-2 uydusu ile elde etmişlerdir (R^2=0.54). Landsat 8 OLI uydu görüntüsü kullanarak da meşcere hacmi ve göğüs yüzeyi için sırasıyla 0.59 ve 0.67 R^2 değerlerini bulmuşlardır. Bulut *et al.* (2016) Göktürk-2 uydu görüntüsü kullanarak meşcere hacmi, meşcere göğüs yüzeyi ve ağaç sayısını modellemişlerdir. Meşcere hacmi, meşcere göğüs yüzeyi ve ağaç sayısı için R^2 değerlerini sırasıyla 0.61, 0.50 ve 0.31 elde etmişlerdir. Vejetasyon indis değerleri ile yapılan modellemede ise meşcere hacmi, meşcere göğüs yüzeyi ve ağaç sayısı için R^2 değerlerini sırasıyla 0.23, 0,21 ve 0,06 olarak bulmuşlardır.

Özkal (2017) Göktürk-2 uydu görüntüsünü kullanarak meşe ve sahil çamı meşcerelerinde meşcere hacmi, meşcere göğüs yüzeyi ve ağaç sayısını modellemiştir. Meşe meşcerelerinde meşcere hacmi için R^2 değerini 0,08, göğüs yüzeyi için 0,16 ve ağaç sayısı için ise 0,27 olarak bulmuştur. Sahilçamı meşcerelerinde ise meşcere hacmi için R^2 değerini 0.36, meşcere göğüs yüzeyi için 0,27 ve ağaç sayısı için ise 0,42 olarak bulmuştur. Jensen *et al.* (1999) Landsat TM uydu görüntüsüne ait veriler ile geri beslemeli yapay sinir ağları tekniğini (Back propagation neural network) YSA tooll kullanarak, iğne yapraklı ormanlarda meşcere yaşını modellemiştir (R^2=0,77).

Kuzugudenli *et al.* (2013) yaptıkları çalışmada yapay sinir ağları kullanarak Toros sediri için meşcere orta çapını 0,84'lük bir başarı ile modellemişlerdir. Ercanlı *et al.* (2015) farklı yapay sinir ağları tekniklerini (Kademeli Korelasyon Algoritmaları, İleri beslemeli yapay sinir ağı, geri beslemeli yapay sinir ağı vb.) kullanarak yaş ve boy arasındaki ilişkiyi modellemişlerdir (R^2=0,97).

Bolat and Ercanlı (2016) İleri beslemeli yapay sinir ağı tekniği ile çap sınıfının orta değerini, çap dağılımlarının %31 ve %63'lük değerlerini girdi değişkeni olarak kullanarak her bir çap sınıfındaki ağaç oranını tahmin etmişlerdir (PEM R^2=0,77, YSA R^2=0,77). Nouri *et al.* (2020) yapmış oldukları bir çalışmada; Landsat uydu görüntüsünden elde edilen vejetasyon indis değerlerini kullanarak meşcere parametrelerini modellemeye çalışmışlardır. Sonuçlar incelendiğinde; DVI, SAVI2 ve SRVI vejetasyon indis değerleri ile meşcere parametreleri arasında en yüksek korelasyonun sağlandığı tespit etmişlerdir. Sırası ile DVI, SAVI2 ve SRVI için korelasyonları 0,76, 0,77 ve 0,92 olarak bulmuşlardır. Dron görüntüleri kullanarak fıstık çamı plantasyonunda meşcere üst boyunu modellemeyi amaçlayan bir çalışmada ise meşcere üst boyu ve dron görüntüsünden elde edilen veriler arasında anlamlı ve yüksek ilişki (*F*–Score=0.99) bulmuşlardır (Gülci *et al.* 2021). Drone görüntülerinden elde edilen nokta bulutu kullanılarak oluşturulan sayısal arazi ve yüzey modeli ile bireysel ağaç yüksekliği ve tepe kapalılığın tahmin edilmeye çalışıldığı bir diğer çalışmada da %70'in üzerinde bir doğruluk oranıyla bireysel ağaç yüksekliği ve konumu ile kapalılık derecesinin belirlenebileceğini bulmuşlardır (Yılmaz *et al.* 2016).

Meşçere parametrelerinin uzaktan algılama verileri ile tahmin edilmesinde ÇRA metodun yanında BYSAM da kullanıldı. Modelleme sürecinde reflektans, vejetasyon indisi, tekstür, geri yansıtım ve dijital bant değerleri gibi uzaktan algılama verilerinden yararlanılmıştır. Meşcere parametreleri için en yüksek model ve test başarısı tekstür değerleri ile elde edilmiştir. Burada başarının tekstür değerlerinde en yüksek olmasının nedeni uydu görüntülerine farklı pencere boyutu, derece ve fonksiyonlar için tekstür hesaplanarak uydu görüntülerinin doku özelliklerini iyi derecede yansıtılması ve bu hesaplamalar sonucu birçok tekstür verisetinin oluşmasından kaynaklandığı söylenebilir (Pathak and Barooah 2013, Zheng *et al.* 2018, Bulut 2021).

Zhou *et al.* (2020), çamların hacmini tahmin etmeye çalıştıkları çalışmada Spot uydu görüntüsünün bant değerleri ve tekstür verileri YSA metodu ile modellemişlerdir. Sonuçlar %31,45 (45.44 m^3/ha) tahmini standart hata değerleri elde etmişlerdir. Ayrıca Santi *et al.* (2015) yapmış oldukları SAR görüntülerinin L ve C bantları ile, çam ve diğer meşe ormanlarının hacmini belirlemek için YSA modelleme tekniği uyguladıkları

çalışmada ağaç türleri için sırası ile 40 m^3/ha ve 30 m^3/ha standart hata değerleri elde etmişlerdir.

Önceden kesilmiş 5,3 ile 6,3 yaşları arasında değişen okaliptüs plantasyon verileri ile Sentinel-2 uydu görüntüsüne ait bant değerleri, vejetasyon indis ve bant oran değerleri ile R yazılımında modellemişlerdi. YSA modelleme tekniği ile yapılan araştırmada sonuçlar; meşcere hacmi için model ve test standart hataları sırası ile %10,63 ve %12,00 olarak bulmuşlardır (De Almeida *et al.* 2021).

Son olarak Bruggisser *et al.* (2021) meşcere üst boyunu Sentinel-1 geri yansıtım değerleri ile tahmin etmeye çalıştıkları araştırmada sonuçlar R^2=0,89, RMSE=4,76 m ve standart sapmayı 0,09 olarak bulmuşlardır. Sentinel-1 zaman serileri kullanılarak ağaç yüksekliğinin aktif uydu görüntüleri ile de hesaplanabileceği ortaya konulmuştur. Çalışmamızda Sentinel-1 veri setleri ile düşük başarılar elde edilmiştir. Bunun nedeni çalılmada kullanılan Sentinel-1 aktif görüntüsünün C bantlı diğer bir ifadeyle düşük penetrasyona sahip olması söyelenebilir. Yukarıdaki çalışmada yüksek belirtme katsayıları elde etmelerinin sebebi farklı polarizasyon ve farklı veri setleri kullanımından kaynaklandığı düşünülmektedir.

Çalışmada modelleme de kullanılan iki metoda ait test verileri karşılaştırılarak iki eş arasındaki ortalama farkını tespit etmek için eşlendirilmiş *t*-testi uygulanmıştır. Özellikle test sonuçları incelendiğinde meşcere hacmi, meşcere göğüs yüzeyi, meşcere ağaç sayısı, meşcere üst boyu ve meşcere orta çapı için YSA da eşlendirilmiş *t*-testine ilişkin p değeri ($p>0,05$) bulunmuş ve model ağının uygulanabilir olduğu tespit edilmiştir. Meşcere hacmi için ÇRA metodunda belirtme katsayısı (R^2=0,84) yüksek olmasına rağmen eşlendirilmiş *t*-testine ilişkin p değeri 0,021 ($p<0,05$) bulunmuş ve model uygulanabilir olmadığı için YSA ağ modeli kullanılmıştır (R^2=0,83). Aynı şekilde meşcere göğüs yüzeyinde de YSA model ve test belirtme katsayıları (Model R^2=0,84, Test R^2=0,77) ile eşlendirilmiş *t*-testine ilişkin p değeri 0,334 olarak ÇRA metoduna göre daha yüksek değerler elde edilmiştir. Burada YSA metodunun daha yüksek belirtme katsayısı ve uyum göstermesinin en önemli sebebi ağın değişik öğrenme ve momentum oranlarında defalarca eğitilmesinden kaynaklanmaktadır. YSA da defalarca deneme yanılma yöntemi

ile denemeler yaparak ağı eğiterek en başarılı ağın tespit edilmesi dolasıyı ile meşcere parametreleri için de genelde YSA metodunda en yüksek başarının oluşmasında büyük yer kaplamaktadır.

5.2.2. TÜB ve TÜK parametrelerine ilişkin modelleme bulgularının değerlendirilmesi

Çalışmada TÜB'e ait genel sonuçlar incelendiğinde en yüksek belirtme katsayıları meşçere parametrelerinde olduğu gibi tekstür değerleri ile elde edilmiştir. TÜB için en başarılı veri seti Sentinel-2 uydu görüntüsünden elde edilen 9x9 pencere boyutundaki tekstür değerleri ile bulunmuştur. TÜB için ÇRA metodu ile elde edilen sonuçlar en yüksek belirtme katsayısına sahiptir (Model R^2=0,81, Test R^2=0,84) (Çizelge 4.32). YSA metoduna ait performans ölçütleri incelendiğinde de yine yüksek bir belirtme katsayısı elde edildiği görülmektedir (Model R^2=0,82, Test R^2=0,75) (Çizelge 4.32). Her iki metodun test verilerine ait eşlendirilmiş *t*-testine ilişkin p değerleri ise sırası ile ÇRA ve YSA için 0,346 ve 0,981 olarak hesaplanmıştır (Çizelge 4.32). Her iki metotta da eşlendirilmiş *t*-testine ilişkin p değeri 0,05 önem düzeyinde olması model ağının uygulanabilir olduğu göstermektedir. Fakat TÜB için en yüksek belirtme katsayısı ÇRA modelde görünmesine rağmen ÇRA test belirtme katsayısının model den yüksek olması ve *t*-testine ilişkin p değerinin YSA metodundan daha düşük olması TÜB için YSA metodunun uygulanabilirlik açısından daha uygun olduğunu göstermektedir.

Topraküstü karbon (TÜK) verilerine ait sonuçlar incelendiğinde de çalışmada kullanılan bütün veri setleri içinde en yüksek başarı Serntinel-2 uydu görüntüsünden elde edilen 15x15 pencere boyutundaki tekstür değerleri ile elde edilmiştir. ÇRA ve YSA metodun her ikisinde de yüksek model belirtme katsayıları elde edilmiştir (ÇRA R^2=0,86, YSA R^2=0,89). Yine aynı şekilde her iki metodun test belirtme katsayıları da yüksek çıkmıştır (ÇRA R^2=0,82, YSA R^2=0,77). ÇRA ve YSA metotlarında TÜK için test verilerine ait eşlendirilmiş *t*-test sonuçları incelendiğinde p değeri sırası ile ÇRA ve YSA için 0,726 ve 0,119 olarak hesaplanmıştır (Çizelge 4.33). TÜK için hem model ve test belirtme katsayıları hem de eşlendirilmiş *t*-testine ilişkin p değeri göz önünde bulundurulduğunda en uygulanabilir metodun ÇRA olduğu bulunmuştur.

Purohit *et al.* (2021) yapmış oldukları çalışmada Landsat 8 OLI ve Sentinel-1 uydu görüntüsü verileri ile topraküstü biyokütleyi modellemek için rastgele orman (RF) algoritmasını kullanmışlardır. Sonuçlar, Landsat 8 OLI ve Sentinel-1 uydu görüntüsünden elde edilen veriler ile TÜB'ün tahininde iyi bir başarı (R^2 =0,87, RMSE=62,56 ton/ha) elde etmişlerdir. Tahmin edilen maksimum TÜB miktarı 596,15 ton/ha iken, minimum TÜB ise 46,36 ton/ha olarak bulmuşlardır. Çalışmamıza ait ÇRA metoduna ait TÜB belirtme katsayısı ilgili çalışmadan düşük çıkmıştır (R^2 =0,81). Bu durum modelleme metodundan kaynaklandığı düşünülmektedir.

Abdullah *et al.* (2021) İHA tabanlı uzaktan algılama verilerini kullanarak çöl çalılarının biyokütle ve karbon stokunu tahmin etmeyi amaçladıkları çalışmada sonuçlar, tahmini çalı yükseklikleri ile yersel ölçümler arasında makul bir korelasyon olduğunu göstermektedir (R^2=0,66). TÜB ile tepe çatısı (CA), çalı hacmi (SV) ve çalı yüksekliği (VH) parametreleri arasındaki ilişkiyi belirlemek için yapmış oldukları regresyon analiz sonuçları incelendiğinde de TÜB'ün CA (R^2=0,81) ve SV (R^2=0,74) parametreleri ile önemli ölçüde ilişkili olduğunu, ancak VH parametresinde daha düşük bir belirtme katsayısı gösterdiğini (R^2 = 0,24) tespit etmişlerdir. Çalışmamızda dron görüntülerinden elde edilen vejetasyon indis değerleri ile enyüksek belirtme katsayısı elde edilmiştir (R^2 =0,38) (Çizelge 4.3). İlgili çalışmada yüksek belirtme katsayısı elde etmelerinin sebebi TÜB hesabı için kullanılacak parametrelerin ayrı ayrı drone ile tespit edilmiş olmasından kaynaklandığı düşünülmektedir.

Günlü and Ercanlı (2020) Alos Palsar L-bant görüntüsü kullanarak saf kayın meşcerelerinde topraküstü meşcere karbonunu tahmin etmek amacıyla yapmış oldukları çalışmada 153 örnek alana ait topraküstü meşcere karbonu (TÜK) yersel ölçümlerle hesaplamış ve her bir örnek alana ilişkin Alos Palsar'dan oluşturulan farklı pencere boyutunda (3×3, 5×5, 7×7, 9×9 ve 11×11) ve sekiz tekstür özelliği (varyans, farklılık, homojenlik, entropi, kontrast, ortalama, ikinci moment ve korelasyon) değerleri arasındaki ilişkileri ÇRA ve YSA modelleme teknikleri ile modellenmiştir. Elde edilen sonuçlar incelendiğinde, YSA'nın TÜK değerlerini tahmin etme kabiliyetinin ÇRA'a göre daha iyi olduğu görülmüştür (YSA R^2 = 0,52, ÇRA R^2 = 0,38). Çalışmamıza kıyasla

çok yüksek başarılı modellerin elde edilmesinde ise kullanılan C bandının kısa dalga boyuna sahip olmasının etkili olduğu düşünülmektedir.

Eckert (2012) tarafından yapılan bir çalışmada Worldview- 2 uydu görüntüsü kullanarak topraküstü biyokütle ve karbonu modellemeye çalışmıştır. Sonuçlar, biyokütle için geliştirilen modeller, 0,57 ile 0,84 arasında değişen R^2 ve 52 ton/ha ile 32 ton/ha arasında değişen RMSE elde etmiştir. Karbon da ise 26 ton/ha ila 16 ton/ha RMSE ortalama hata tespit etmişlerdir. Günlü vd. (2017) yapmış oldukları bir diğer çalışmada ise örnek alanların topraküstü biyokütle ve karbonunu, (Yavuz vd. 2010) tarafından saf sarıçam meşcereleri için geliştirilen bölgesel allometrik biyokütle denklemler kullanarak modellemişlerdir. Daha sonra Landsat TM görüntülerine ait bant yansıtma değerleri ile belirlenen TÜB değerleri arasındaki ilişkiler ÇRA tekniği kullanarak modellemişlerdir. Elde edilen sonuçlar incelendiğinde, meşcere biyokütlesi için TM 1, TM 4 ve TM 5'in bağımsız değişkenleri ile (R^2=0.445; standart hata=11,179 ton/ha) düzeyinde ilişki bulmuşlardır.

Sentinel-1 uydu görüntüsünden elde edilen geri yansıtım değerleri ve ÇRA metodu ile topraküsütü biyokütlenin modellendiği bir başka çalışmada ise, Sentinel-1 veri setleri ile iyi bir tahmin doğruluğu (R^2=0,70) elde etmişlerdir (Laurin *et al.* 2018). Roy *et al.* (2021) yapmış oldukları bir çalışmada yine Sentinel-1 C-bandına ait geri yansıtım değerleri kullanılarak ÇRA metodu ile topraküstü biyokütleyi ve meşcere sıklığını modellemeye çalışmışlardır. TÜB için model ve test belirtme katsayıları sırası ile 0,63 ve 0,45 olarak bulunmuştur. Yine TÜB için RMSE 17 ton/ha olarak hesaplanmıştır. Ağaç yoğunluğu model başarısı ise daha yüksek çıktığı tespit edilmiştir (R^2=0,87). Gaofen-1 görüntüsü, Sentinel-1 görüntüsü ve makine öğretim algoritmaları kullanarak topraküstü biyokütleyi belirlemeye çalışan Han *et al.* (2021) ÇRA, MLA, RF ve BAYSAM metotları model başarılarını karşılaştırmış ve en yüksek tahmin doğruluğun RF modelde elde etmiştir (R^2=0,70, RMSE=16,26 ton/ha). Çalışmamızda da ÇRA ve YSA metotlarına ait belirtme katsayıları (ÇRA, R^2=0,81, YSA, R^2=0,84) ilgili çalışma ile benzerlik göstermektedir.

Jones *et al.* (2020) dron görüntülerinden elde edilen veriler kullanılarak ağaç biyokütlesini modellemişlerdir. Örnek alanlara ait dron görüntüleri alındıktan sonra,

deneme ağaçları kesilerek klasik biyokütle ve karbonu hesaplamışlardır. Drone görüntüsünden elde edilen veriler ile meşcere kapalılığı ve ağaç yüksekliğinin modellemesinde oldukça başarılı bir sonuç elde etmişlerdir (R^2=0,98). Muhsoni *et al.* (2021) dron görüntüleri kullanılarak Mangrov ağacının karbonunu modellemiyi amaçladığı çalışmada sonuçlar, ÇRA tekniği ile modellemede başarılı sonuçlar elde ettiklerini göstermektedir (R^2=0,75, RMSE=%35,4). Çalışmamızda dron görüntülerinden elde edilen reflektans ve vejetasyon indis değerlerine ait model belirtme katsayıları sırası ile 0,24 ve 0,34 olarak hesaplanmıştır. Çalışmamıza ilişkin sonuçların ilgili çalışmadan daha düşük belirtme katsayıları elde edilmesi doğal ormanlarda gerçekleştirilmiş olması ile alakalı olduğu düşünülmektedir.

Landsat 8 OLI ve Sentinel-1 uydu görüntülerine ait veriler kullanılarak üç farklı modelleme metodunda (LR: Doğrusal regresyon, RF: Rastgele orman ve XGBoost: Aşırı Gradyan Artırma Algoritmaları) topraküstü biyokütleyi modellemeyi amaçladıkları bir diğer çalışmada sonuçlar LR metodu için Landsat 8 OLI ve Sentinel-1 için sırası ile belirtme katsayıları 0,21 ve 0,03, RF metodu için 0,61 ve 0,28 son olarak XGBoost metodu için ise 0,66 ve 0,38 olarak bulmuşlardır (Li *et al.* 2020b).

Askar *et al.* (2018) Sentinel-2 uydu görüntüleri kullanarak elde edilen vejetasyon indisleri ile topraküsütü biyokütleyi ÇRA metodu kullanarak modellemişlerdi. Vejetasyon indisi ile topraküstü biyokütle arasında 0,81 belirtme katsayısı ile yüksek bir başarı elde etmişlerdir. Radarsat-2 ve Landsat 8 OLI verileri kullanılarak farklı modelleme teknikleri ile topraküsütü biyokütlenini tahmin edildiği bir çalışmada ise diğer teknikler arasında en yüksek başarının rasgele orman algoritması tekniği (R^2= 0,82) ile elde etmişlerdir (Shao and Zhang 2016). Kumar *et al.* (2016) Landsat8 OLI uydu görüntüsü ile elde ettikleri vejetasyon indis değerleri ile ALOS-2 uydu görüntüsünden elde ettikleri geri yansıtım değerleri ÇRA metodu kullanarak topraküstü biyokütleyi tahmin etmişlerdir. Landsat 8 OLI ve ALOS-2 verileri ile modellemeye ait belirtme katsayıları sırası ile 0,79 ve 0,74'tür.

Endonezya'da Sentinel-1uydu görüntüsünden elde edilen geri yansıtım ve Sentinel-2 uydu görüntüsünden hesaplanan yansıma ve vejetasyon indis değerleri ile topraküstü

biyokütle ÇRA metoduyla modellemişlerdir. Sonuçlar Sentinel-1 verilerinin Sentinel-2 veri setlerine nazaran daha düşük (R^2=0,34; R^2=0,82) tahmin yeteneği sergilediğini bulmuşlardır (Nuthammachot *et al.* 2022). Tavasoli *et al.* (2019) yapmış oldukları bir araştırmada ise Sentinel-1, Sentinel-2 ve Alos Palsar uydu görüntülerinden elde ettikleri geri yansıtım, vejetasyon indis ve tekstür değerleri ile topraküstü karbonu modellemeye çalışmışlardır. Çalışmadan elde edilen sonuçların belirtme katsayıları sırası ile Sentinel-1, Sentinel-2 ve Alos Palsar için 0,51, 0,60 ve 0,50 şeklindedir. Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans vejetasyon indis değerleri ile elde edilen model belirtme katsayıları ile benzerlik göstermektedir. Navarro *et al.* (2019) de yine Sentinel-1 ve Sentinel-2 uydu görüntülerinden elde ettikleri bant yansıma ile vejetasyon indis değerlerini kullanarak plantasyon alanlarında topraküstü biyokütleyi tahmin etmişlerdir. Sentinel-1 uydu görüntüsüne ait VH bant değeri ile 0,90 belirtme katsayısına sahip bir tahmin gerçekleştirmişlerdir. Sentinel-1 ve Sentinel-2 uydu görüntülerinden elde edilen veri setleri birlikte kullanılarak da 0,89 belirtme katsayısı bulmuşlardır.

Keleş *et al.* (2021) Sentinel-1 ve Sentinel-2 uydu görüntüleri kullanarak topraküstü karbonu modellemeye çalışmışlardır. TÜK, farklı polarizasyonlardaki geri yansıtım değerleri, bant ve vejetasyon indis değerleri ile SVM ve ÇRA modelleme teknikleri kullanılarak modellemişlerdir. En iyi sonucun SVM modelleme tekniği ile elde etmişlerdir (fit index (FI)=0,88). ÇRA metodunda ise FI'yi 0,75 olarak hesaplamışlardır.

Landsat TM uydu görüntüsünden elde edilen bant yansıma ve vejetasyon indis değerleri ile topraküstü biyokütyi ÇRA metodu ile modelleme çalışan Günlü *et al.* (2014); TM-1 ve TM2 bant değerleri ile model belirtme katsayısını 0,45 olarak bulmuştur. Vejetasyon indis değerleri ile modelleme sonucunda ise belirtme katsayısını 0,60 olarak bulmuşlardır.

5.2.3. Yaprak alan indeksine ilişkin modelleme bulgularının değerlendirilmesi

Çalışmada Landsat 8 OLI, Sentinel-2 ve dron görüntülerine ait bant reflektans değerleri YAİ ve ÇRA metodu ile modellenmiş ve sırası ile belirtme katsayıları 0,46, 0,58 ve 0,22 olarak elde edilmiştir. Aynı şekilde yine Landsat 8OLI, Sentinel-2 ve dron

görüntülerinden elde edilen vejetasyon indisleri ile YAİ'nin modellenmesinde ise sırası ile 0,47, 0,58 ve 0,23 belirtme katsayıları elde edilmiştir (Çizelge 4.2, 4.3 ve 4.4). Her iki değişken içinde en yüksek belirtme katsayısı Sentinel-2 uydu görüntülerine ait veriler ile elde edilmiştir.

ÇRA metodunda en yüksek başarı Sentinel-2 uydu görüntüsünden hesaplanan 5x5 pencere boyutundaki tekstür değerleri ile elde edilmiştir ($R^2 = 0,69$). Daha sonra ÇRA da en yüksek belirtme katsayısına sahip model bağımsız değişkenleri ile YAİ yapay sinir ağları (YSA) kullanılarak modellenmiştir. ÇRA ve YSA metotlarına ait sonuçlar incelendiğinde YSA metoduyla en yüksek model ve test belirtme katsayısı elde edilmiştir (Model R^2=0,74, Test R^2=0,32) (Çizelge 4.30). Genel itibari ile her iki modelleme tekniğinde de test başarıları düşük çıkmıştır. ÇRA metoduna ait belirtme katsayıları ise model ve test için sırası ile 0,69 ve 0,17 olarak hesaplanmıştır. Uygulanan tekniklerin yanı sıra çalışmada kullanılan bağımsız değişkenler de model başarısını ve temsiliyetini etkilediği düşünülmektedir. Bu çalışmaya benzer çalışmalar incelendiğinde de özellikle bölgesel benzerlik gösteren çalışmalar test başarısının model başarısından daha düşük olduğunu göstermektedir (Bulut 2021). Literatürde, YAİ modellemesi çeşitli uzaktan algılama verileri kullanılarak yapılmıştır. Bu veri kaynaklarını yansıma değerleri (Heiskanen 2006, Günlü *et al.* 2017, Bulut 2021), vejetasyon indisleri (Soudani *et al.* 2006, Yu *et al.* 2019) ve tekstür değerleri (Zhou *et al.* 2014, Pu and Cheng 2015) oluşturmaktadır. Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde ettikleri yansıma değerleri ve vejetasyon indis değerleri ile YAİ'ni modellemeyi amaçlamışlardır. Modellemede kullanılan verisetleri; yansıma değerleri, yansıma değerleri ile topoğrafik değerler, vejetasyon indisleri ile topoğrafik değerler ve yansıma değerleri, vejetasyon indisleri ile topografik değerlerden oluşan verisetleri ile koşturulan modellere ait belirtme katsayıları sırası ile 0,39, 0,59 ve 0,93 olarak bulmuşlardır. Sentinel-2 uydu görüntüsünden elde edilen değerler ile geliştirdikleri modellerin Landsat 8 OLI görüntüsünden elde edilen değerler ile geliştirdikleri modellere göre daha başarılı sonuçlar elde etmişlerdir (Günlü and Bulut 2022). Günlü *et al.* (2017) tarafından yapılan bir çalışmada Worldview-2 ve Aster uydu görüntüleri kullanılarak YAİ tahmin edilmeye çalışılmıştır. Worldview-2 uydu görüntüsünden elde edilen yansıma değerleri ile YAİ'nin modellemesine ait model belirtme katsayısı 0,41, vejetasyon indisleri ile modellemeye ait

belirtme katsayısı ise 0,45 olarak bulmuşlardır. Aster uydu görüntüsünden elde edilen yansıma değerleri ve vejetasyon indisleri ile elde edilen modellerin belirtme katsayıları ise sırası ile 0,12 ve 0,41 olarak bulmuşlardır. Genç sarıçam meşcerelerinin yaprak alan indeksinde yaşa bağlı değişikliklerinin incelendiği ve topraküstü biyokütle tahmin olanaklarının araştırıldığı bir çalışmada ise sonuçlar YAİ'nin meşcere yaşı ve meşcere sıklığına ($p<0.01$) büyük ölçüde bağımlı olduğunu ortaya koymuştur. Ayrıca, YAİ'nin meşcere biyokütlesi ile önemli ölçüde ilişkili olduğunu tespit etmişlerdir. En yüksek belirtme katsayısı toplam toprak üstü biyokütle için 0,84 olarak bulmuşlardır (Jagodzinski and Kalucka 2008).

Landsat TM uydu görüntülerinden elde edilen vejetasyon indis değerleri ile YAİ'ni modellemeyi amaçlayan bir diğer çalışmada 0,75 bir belirtme katsayısına sahip modeller geliştirmişlerdir (Stenberg *et al.* 2004). Ahmadi *et al.* (2020) tarafından yapılan bir çalışmada ise BYSAM metodu kullanılarak YAİ modellenmiştir. Modele ait belirtme katsayısı 0,48 olarak bulunmuştur. Ukrayna'daki ılıman yaprak döken ve karışık ormanların YAİ'nin modellendiği bir araştırmada ise Sentine-1 uydu görüntüsü kullanılmıştır. Sentine-1 uydu görüntüsüne ait VV-VH polarizasyon geri yansıtım değerleri ve topoğrafik veriler ile modellenen YAİ için 0,81 belirtme katsayısı elde etmişlerdir (Stankevich *et al.* 2017). Çalışmamızdan daha yüksek başarı elde etmeleri topoğrafik faktörlerinde modellemeye dahil edilmesinden kaynaklandığı düşünülmektedir.

Cañete-Salinas *et al.* (2020) Sentinel-2 uydu görüntülerinden elde edilen vejetasyon indis değerleri ile YAİ modellenmiş ve sonuçlar incelendiğinde, R^2 =0,57, ortalama mutlak hata (MAE)=0,22 ve RMSE 0,25 olarak bulmuşlardır.

Kinane *et al.* (2021) çam fidanlıklarında Landsat 5 ve 7 uydu görüntülerinden elde ettikleri vejetasyon indis değerleri ile YAİ arasındaki korelasyonu araştırmışlardır. Sonuçlar incelendiğinde korelasyon ve karekök ortalama hatayı sırası ile %76,4 ile 0,42 olarak hesaplamışlardır. Eklundh *et al.* (2001) Landsat TM görüntülerini kullanarak elde ettikleri reflektans ve vejetasyon indis değerleri ile YAİ arasındaki ilişkiyi araştırdıkları

bir çalışmada, reflektans ve vejetasyon indis değerleri ile olan korelasyonları sırası ile 0,84 ve 0,77 olarak bulmuşlardır.

Quickbird uydu görüntüsünü kullanarak YAİ'ni modelledikleri bir başka çalışmada ise farklı pencere boyutu ve derecelerde elde ettikleri tekstür değerleri kullanılmıştır. Çalışmada en başarılı model belirtme katsayısı 90^0'lik tekstür verileri ile elde edilerek 0,74 olarak hesaplanmıştır (Zhou *et al.* 2017).

6. SONUÇ VE ÖNERİLER

Yapılan bu çalışmada saf sarıçam meşçerelerine ait yersel ölçümler ile farklı uzaktan algılama verileri kullanılarak bazı meşçere parametreleri (meşçere orta çapı: d_g, meşçere üst boyu: $h_{üst}$, meşçere ağaç sayısı: N, meşçere göğüs yüzeyi: G, meşçere hacmi: V), YAİ, TÜB ve TÜK'e ilişkin modeller geliştirilmiştir. Çalışmadan elde edilen sonuçlar ve bu sonuçlar doğrultusunda gelecekte yapılacak çalışmalara ilişkin öneriler aşağıda yer almaktadır.

- Meşçere parametrelerinin modellenmesinde (meşçere orta çapı: d_g, meşçere üst boyu: $h_{üst}$, meşçere ağaç sayısı: N, meşçere göğüs yüzeyi: G, meşçere hacmi: V); Landsat 8 OLI, Sentinel-2 ve dron görüntülerinden elde edilen reflektans, dijital bant yansıtım, vejetasyon indis ve farklı tesktür değerleri ile Sentinel-1 uydu görüntüsünün farklı polarizasyonlarından elde edilen geri yansıtım ve dijital bant değerlerine ait verisetleri kullanılmıştır. Çalışmada, en başarılı modeller Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen tekstür verileri ile elde edilmiştir. Genel olarak bir değerlendirme yapıldığında meşcere parametrelerine ilişkin en yüksek başarılar Sentinel-2 uydu görüntüsünden elde edilen tekstür değerleri ile geliştirilen modellerde elde edilmiştir. V (m^3/ha), G (m^2/ha), N (adet/ha), $h_{üst}$ (m) ve dg (cm) için model başarıları sırası ile 0,84, 0,82, 0,79, 0,82 ve 0,83'tür.Meşcere hacminin modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Landsat 8 OLI uydu görüntüsünden elde edilen 135˚ tekstür değerleri ile elde edilmiştir (R^2=0,84) (Çizelge 4.7). Pencere boyutundaki tekstür değerleri ile en yüksek belirtme katsayısı ise Landsat 8 OLI 13×13 pencere boyutu verileri ile Sentinel-2 15×15 pencere boyutundaki verilerden elde edilmiştir (R^2=0,82) (Çizelge 4.7). Meşcere hacminin dijital bant ve geri yansıtım değerleri ile modellenmesine ilişkin belirtme katsayıları Sentinel-1 için sırası ile 0,02 ve 0,07 olarak bulunmuştur (Çizelge 4.4). Dron görüntülerinden elde edilen dijital bant değerleri ile meşcere hacmi arasında anlamlı bir model elde edilmemiştir. Reflektans değerleri ile meşcere hacminin modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,28, 0,55 ve 0,49 olarak bulunmuştur

(Çizelge 4.2). Son olarak meşcere hacminin vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayılarıda dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,35, 0,54 ve 0,60 olarak bulunmuştur (Çizelge 4.3). Meşcere hacmin YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,83 olarak bulunmuştur (Çizelge 4.17).

- Meşcere göğüs yüzeyinin modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde edilen 15×15 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,82) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Landsat 8 OLI 90˚ tekstür verilerden elde edilmiştir (R^2=0,80) (Çizelge 4.7). Meşcere göğüs yüzeyinin dijital bant ve geri yansıtım değerleri ile modellenmesine ilişkin belirtme katsayıları Sentinel-1 için sırası ile 0,04 ve 0,08 olarak bulunmuştur (Çizelge 4.4). Dron görüntülerinden elde edilen dijital bant değerleri ile meşcere göğüs yüzeyi arasında anlamlı bir model elde edilmemiştir. Reflektans değerleri ile meşcere göğüs yüzeyinin modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,32, 0,48 ve 0,45 olarak hesaplanmıştır (Çizelge 4.2). Son olarak meşcere göğüs yüzeyinin vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayılarıda dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,40, 0,50 ve 0,42 olarak bulunmuştur (Çizelge 4.3). Meşcere göğüs yüzeyinin YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,84 olarak bulunmuştur (Çizelge 4.18).

- Meşcere ağaç sayısının modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde edilen 15×15 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,79) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Landsat 8 OLI 90˚ tekstür verilerden elde edilmiştir (R^2=0,78) (Çizelge 4.7). Meşcere ağaç sayısı Sentinel-1 uydu görüntüsünden elde edilen dijital bant ve geri yansıtım değerleri ile anlamlı model elde edilmemiştir (Çizelge 4.4). Dron görüntülerinden elde edilen dijital bant değerleri ile meşcere

ağaç sayısına ilişkin belirtme katsayısı ise 0,06 olarak bulunmuştur. Reflektans değerleri ile meşcere ağaç sayısının modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,10, 0,62 ve 0,66 olarak bulunmuştur (Çizelge 4.2). Son olarak meşcere ağaç sayısının vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,17, 0,63 ve 0,59 olarak bulunmuştur (Çizelge 4.3). Meşcere ağaç sayısının YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,81 olarak bulunmuştur (Çizelge 4.19).

- Meşcere üst boyun modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde edilen 5×5 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,82) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Sentinel-2 0˚ tekstür verilerden elde edilmiştir (R^2=0,81) (Çizelge 4.7). Meşcere üst boyunun dijital bant ve geri yansıtım değerleri ile modellenmesine ilişkin belirtme katsayıları Sentinel-1 için sırası ile 0,02 ve 0,09 olarak bulunmuştur (Çizelge 4.4). Dron görüntülerinden elde edilen dijital bant ve reflektans değerleri ile meşcere üst boyu arasında anlamlı bir model elde edilmemiştir. Reflektans değerleri ile meşcere üst boyun modellenmesine ilişkin belirtme katsayıları Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,67 ve 0,69 olarak bulunmuştur (Çizelge 4.2). Son olarak meşcere üst boyun vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,44, 0,70 ve 0,71 olarak bulunmuştur (Çizelge 4.3). Meşcere üst boyunun YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,71 olarak bulunmuştur (Çizelge 4.20).

- Meşcere orta çapının modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde edilen 7×7 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,83) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Landsat 8 OLI 135˚ tekstür verilerden elde edilmiştir (R^2=0,82) (Çizelge 4.7). Meşcere orta çapının dijital bant ve geri yansıtım değerleri ile modellenmesine

ilişkin belirtme katsayıları Sentinel-1 için sırası ile 0,04 ve 0,08, dron dijital bant değerleri ile de 0,03 olarak bulunmuştur (Çizelge 4.4). Reflektans değerleri ile meşcere orta çapın modellenmesine ilişkin belirtme katsayıları Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,72 ve 0,70 olarak bulunmuştur (Çizelge 4.2). Dron görüntülerinden elde edilen reflektans değerleri ile meşcere orta çapı arasında anlamlı bir model elde edilmemiştir. Son olarak meşcere orta çapın vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,04, 0,73 ve 0,66 olarak bulunmuştur (Çizelge 4.3). Meşcere orta çapının YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,89 olarak bulunmuştur (Çizelge 4.21).

- Meşcere parametrelerine ilişkin genel sonuçlar değerlendirildiğinde en düşük belirtme katsayıları dron görüntüleri ile Sentinel-1 görüntülerine ait veri setlerinden elde edilmiştir. Başarının artırılması meşcere parametrelerini doğrudan dron ile hesaplamak ve dron'a entegre yakın kızıl ötesine ve aktif kamera sistem görüntüleri kullanılarak daha fazla vejetasyon indis ve dijital bant değerleri ile modellemek başarıyı artıracağı düşünülmektedir. Yine dron ile modellemelere ait başarıların artırılması için dron görüntülerinin olabildiğince güneş ışınlarının yer yüzüne dik açı ile ya da dik açıya yakın bir açı ile geldiği zamanlarda çekimlerin yapılması, uçuş yüksekliğinin olabilecek sınırlar içerisinde daha düşük ve son olarak da uçuş hızının daha yavaş olmasının yanında ön ve yan fotoğraf bindirme oranlarının artırılarak uçuşun gerçekleştirilmesi ve bu alınan görüntüler üzerinde gerekli hesaplamaların yapılması ile elde edilen verilerin tahmin kabiliyeti üzerine büyük etkisi olacağı önerilmektedir. Sentinel-1 uydu görüntüsünden elde edilen verilerle daha başarılı modellerin elde edilebilmesi için dalga boyu büyük diğer bir ifadeyle penetrasyonu iyi olan aktif uydu görüntülerin kullanılması önerilerbilir. Buna ilaveten topoğrafik faktörler (eğim, bakı ve yükseklik) gibi diğer bağımsız değişkenler modelleme sürecine dahil edilerek model başarı düzeyinin artırılabileceği söylenebilir. Genel olarak sonuçlar incelendiğinde bu çalışma için meşçere parametrelerinin tahminlerinde yüksek seviyede başarı elde etmek için farklı pencere boyutu-açı değerlerine göre tekstür verilerinin kullanılması önerilmektedir. Bununla birlikte YSA gibi makine

öğrenme teknikleri ile başarı seviyeleri daha yüksek seviyelere çıkarılabileceği düşünülmektedir.

- Çalışmada diğer bir bağımlı değişken olan yaprak alan indeks (YAİ) ilişkileri incelendiğinde YAİ'nin modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde edilen 5×5 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,69) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Sentinel-2 135˚ tekstür verilerden elde edilmiştir (R^2=0,62) (Çizelge 4.7). YAİ'nin dron dijital bant ve Sentinel-1 uydu görüntüsünden elde edilen geri yansıtım değerleri ile modellenmesine ilişkin model belirtme katsayıları sırası ile 0,18 ve 0,09 olarak bulunmuştur. Sentinel-1 uydu görüntüsünden elde edilen dijital bant değerleri ile YAİ arasında anlamlı model elde edilmemiştir (Çizelge 4.4). Reflektans değerleri ile YAİ'nin modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,22, 0,46 ve 0,58 olarak bulunmuştur (Çizelge 4.2). Son olarak YAİ'nin vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayılarıda dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,23, 0,47 ve 0,58 olarak bulunmuştur (Çizelge 4.3). YAİ'nin YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,74 olarak hesaplanmıştır (Çizelge 4.22). Genel olarak YAİ içinde en düşük modeller dron ve Sentinel-1 uydu görüntüsüne ait veri setleri ile elde edilmiştir. Dron görüntüsünden elde edilen veri setleri ile modelleme başarılarının artırılması için de dron görüntülerinin olabildiğince güneş ışınlarının yer yüzüne dik açı ile yada dik açıya yakın bir açı ile geldiği zamanlarda çekimlerin yapılması, uçuş yüksekliğinin olabilecek sınırlar içerisinde daha düşük ve son olarak da uçuş hızının daha yavaş olmasının yanında ön ve yan fotoğraf bindirme oranlarının artırılarak uçuşun gerçekleştirilmesi ve bu alınan görüntüler üzerinde gerekli hesaplamaların yapılması ile elde edilen verilerin tahmin kabiliyeti üzerine büyük etkisi olacağı önerilmektedir. Modelleme başarılarını etkileyen diğer bir neden olarak da YAİ'nin belirlenme yöntemi olabildiği söylenebilir. YAİ model başarısının artırılmasına yönelik bir diğer öneri ise; yarı-küresel çekilen fotoğraflar manuel bir şekilde belirlenen eşik

değerleri ile analize tabi tutularak YAİ belirlenmesi ve bu eşik değerinin olması gerektiğinden düşük veya yüksek seçilmesi de YAİ değerinde belirli oranlarda sapmalara neden olabilmektedir. Bu durumu bertaraf etmek açısında yersel olarak YAİ'nin tespitinde ya doğrudan YAİ değerini hesaplayabilen cihazlar kullanmak ya da örnek alanlar ilişkin alınan fotoğraf sayısını artırmak ve bu değerler üzerinde ortalama YAİ değeri hesaplayarak modellere tabii tutmak başarıyı pozitif yönde etkileyebileceği düşünülmektedir. Genel olarak sonuçlar incelendiğinde bu çalışma için YAİ tahminlerinde yüksek seviyede başarı elde etmek için farklı pencere boyutu-açı değerlerine göre tekstür verilerinin kullanılması önerilmektedir. Bununla birlikte YSA gibi makine öğrenme teknikleri ile başarı seviyeleri daha yüksek seviyelere çıkarılabileceği düşünülmektedir. Sentinel-1 uydu görüntüsünden elde edilen veri setleri ile YAİ model tahmin kabiliyetini artırmak için VV ve VH bantlara ait farklı polarizasyonlar ve topoğrafik faktörler (eğim, bakı ve yükseklik) gibi diğer bağımsız değişkenler modelleme sürecine dahil edilerek tahmin kabiliyeti artırılabileceği söylenebilir. Bununla birlikte aktif algılama sistemlerinin kullanılmasına ilişkin gelecekte yapılacak çalışmalarda penetrasyonu iyi dalga boyu uzun olan uydu görüntülerin kullanılması model başarılarını artırabilir. YAİ nin Landsat 8 OLI ve Sentinel-2 uydu görüntüleri üzerinden hesaplama sonuçları incelendiğinde ise en yüksek korelasyon Landsat 8 OLI görüntüsünden elde edilen YAİ için elde edilmiştir (R=0,68). Sentinel-2 için ise 0,60 korelasyon elde edilmiştir. İki görüntüden elde edilen YAİ eşlendirilmiş *t* test sonuçları incelendiğinde de Landsat 8 OLI'den elde edilen YAİ'nin bu çalışma için daha uygulanabilir olduğunu göstermiştir (p=0,091).

- İklim değişikliğinin büyük bir kriz olduğu günümüzde ülkemiz birçok uluslararası anlaşmaya taraf olma yolunda çalışmalar sürdürmektedir. Küresel ısınma ve iklim değişikliği ile ilgili taraf olunacak antlaşmalarda ülkemiz ormanlarında üretilen net karbon TÜK miktarlarının belirlenmesi gerçekçi karbon bütçelerinin belirlenmesi büyük öneme sahiptir. Bu yönüyle TÜB ve TÜK değerlerin hesaplanması bu çalışmada da diğer odak olarak öne çıkmaktadır. Topraüstü biyokütle (TÜB) modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde

edilen 9×9 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,81) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Sentinel-2 90˚ tekstür verilerden elde edilmiştir (R^2=0,80) (Çizelge 4.7). TÜB'ün dijital bant ve geri yansıtım değerleri ile modellenmesine ilişkin belirtme katsayıları Sentinel-1 için sırası ile 0,03 ve 0,07 olarak bulunmuştur (Çizelge 4.4). Dron görüntülerinden elde edilen dijital bant değerleri ile TÜB'ün arasında anlamlı bir model elde edilmemiştir. Reflektans değerleri ile TÜB'ün modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,29, 0,52 ve 0,47 olarak bulunmuştur (Çizelge 4.2). Son olarak TÜB'ün vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayılarıda dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,38, 0,53 ve 0,58 olarak bulunmuştur (Çizelge 4.3). TÜB'ün YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,82 olarak bulunmuştur (Çizelge 4.23). Genel olarak YAİ içinde en düşük modeller dron ve Sentinel-1 uydu görüntüsüne ait veri setleri ile elde edilmiştir. Topraküstü biyokütle (TÜK) modellendiği bütün veri setlerine ait ÇRA model performans ölçütleri incelendiğinde en başarılı model Sentinel-2 uydu görüntüsünden elde edilen 15×15 pencere boyutundaki tekstür değerleri ile elde edilmiştir (R^2=0,86) (Çizelge 4.7). Farklı derece tekstür değerleri ile en yüksek belirtme katsayısı ise Sentinel-2 0˚ tekstür verilerden elde edilmiştir (R^2=0,86) (Çizelge 4.7). TÜK'ün dijital bant ve geri yansıtım değerleri ile modellenmesine ilişkin belirtme katsayıları Sentinel-1 için sırası ile 0,03 ve 0,04 olarak h bulunmuştur (Çizelge 4.4). Dron görüntülerinden elde edilen dijital bant değerleri ile TÜK arasında anlamlı bir model elde edilmemiştir. Reflektans değerleri ile TÜK'ün modellenmesine ilişkin belirtme katsayıları dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,24, 0,41 ve 0,41 olarak bulunmuştur (Çizelge 4.2). Son olarak TÜK'ün vejetasyon indis değerleri ile modellenmesine ilişkin belirtme katsayılarıda dron, Landsat 8 OLI ve Sentinel-2 veri setleri için sırası ile 0,34, 0,43 ve 0,64 olarak bulunmuştur (Çizelge 4.3). TÜK'ün YSA metodu ile modellenmesine ilişkin en uygun model belirtme katsayısı 0,89 olarak hesaplanmıştır (Çizelge 4.24). Genel olarak YAİ içinde en düşük modeller dron ve Sentinel-1 uydu görüntüsüne ait veri setleri ile elde edilmiştir. Diğer

parametrelerde de olduğu gibi TÜB ve TÜK için en düşük başarılar dron ve Sentil-1 görüntülerinden elde edilmiştir. Modellemelerde yüksek başarılar elde edilmesi için dijital bant değerlerinin maksimum, minimum ve toplam değerleri kullanılarak modeller kurulması başarıyı olumlu yönde etkileyeceği düşünülmektedir. Başarının artırılması bir diğer yönü olarak da dron'a entegre yakın kızıl ötesine ve aktif kamera sistem görüntüleri kullanılarak daha fazla vejetasyon indis ve dijital bant değerleri modellemek başarıyı artıracağı düşünülmektedir. Yine dron ile modellemelere ait başarıların artırılması için dron görüntülerinin olabildiğince güneş ışınlarının yer yüzüne dik açı ile yada dik açıya yakın bir açı ile geldiği zamanlarda çekimlerin yapılması, uçuş yüksekliğinin olabilecek sınırlar içerisinde daha düşük ve son olarak da uçuş hızının daha yavaş olmasının yanında ön ve yan fotoğraf bindirme oranlarının artırılarak uçuşun gerçekleştirilmesi ve bu alınan görüntüler üzerinde gerekli hesaplamaların yapılması ile elde edilen verilerin tahmin kabiliyeti üzerine büyük etkisi olacağı önerilmektedir. Bunun yanında drona entegre aktif algılayıcı sistem (Lidar) ve yakın kızılötesine (NIR) sahip kameralar ile görüntüler alınarak daha fazla vejetasyon indisi hesaplama olanaklarını artırmak, modeleme için bağımsız değişken sayısı ile doğru orantılı olarak model başarılarının artıracağı söylenebilir. TÜB ve TÜK'ün direkt olarak hesaplandığı meşcere göğüs çapının (d_g) ağaç tepe çapından modellenerek ortaya koyulması hem zaman ve emek açısından büyük kazanç sağlayacak hem de başka diğer parametrelerin hesaplanmasına büyük katkı sunacaktır. Genel olarak sonuçlar incelendiğinde bu çalışma için TÜB ve TÜK tahminlerinde yüksek seviyede başarı elde etmek için farklı pencere boyutu-açı değerlerine göre tekstür verilerinin kullanılması önerilmektedir. Bununla birlikte YSA gibi makine öğrenme teknikleri ile başarı seviyeleri daha yüksek seviyelere çıkarılabileceği düşünülmektedir.

KAYNAKLAR

Abdullah, M.M., Al-Ali, Z.M. and Srinivasan, S. 2021. The use of UAV-based remote sensing to estimate biomass and carbon stock for native desert shrubs. MethodsX, 8, 101399.

Achard, F., Eva, H.D., Stibig, H.J., Mayaux, P., Gallego, J., Richards, T. and Malingreau, J.P. 2002. Determination of deforestation rates of the world's humid tropical forests. Science, 297(5583), 999-1002.

Ahmadi, K., Kalantar, B., Saeidi, V., Harandi, E.K., Janizadeh, S. and Ueda, N. 2020. Comparison of machine learning methods for mapping the stand characteristics of temperate forests using multi-spectral sentinel-2 data. Remote Sensing, 12(18), 3019.

Akıllı, A. and Hülya, A. 2020. Evaluation of normalization techniques on neural networks for the prediction of 305-day milk yield. Turkish Journal of Agricultural Engineering Research, 1, 354–367.

Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M. and Notarnicola, C. 2015. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. Remote Sensing, 7(12), 16398-16421.

Alonzo, M., Andersen, H.E., Morton, D.C. and Cook, B.D. 2018. Quantifying boreal forest structure and composition using UAV structure from motion. Forests, 9(3), 119.

Amaral, S., Soares, J.V., Alves, D.S., Mello, E.D., Almeida, S.A.S., Silva, O.D. and Silveira, A.M. 1996. Relações entre Índice de Área Foliar (LAI), Área Basal e Índice de Vegetação (NDVI) em relação a diferentes estágios de crescimento secundário na Floresta Amazônica em Rondônia. Simpósio Brasileiro de Sensoriamento Remoto, 8, 485-489.

Anlar, H.C., Günlü, A., Keleş, S. ve Bulut, S. 2015. SPOT-4 uydu görüntüsü yardımıyla bazı meşcere parametreleri (gelişim çağı ve kapalılık) ve arazi kullanım sınıflarının belirlenmesi; Devrez Planlama Birimi örneği. Anadolu Orman Araştırmaları Dergisi, 1(1-2), 33-40.

Anonim 2022. Sinop Orman Bölge Müdürlüğü, Orman İşletme Şeflikleri, Orman Amenajman Planları. T.C. Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Dairesi, Ankara.

Antropov, O., Rauste, Y., Ahola, H. and Hame, T. 2013. Stand-level stem volume of boreal forests from spaceborne SAR imagery at L-band. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 6(1), 35-44.

Asan, Ü. 2003. Orman Amenajmanı. İstanbul Üniversitesi, Orman Fakültesi, Orman Amenajmanı Anabilim Dalı, İstanbul (Ders notları).

Ashraf, M.I., Zhao, Z., Bourque, C.P.A., MacLean, D.A. and Meng, F.R. 2013. Integrating biophysical controls in forest growth and yield predictions with artificial intelligence technology. Canadian Journal of Forest Research, 43(12), 1162-1171.

Askar, A., Phairuang, W., Wicaksono, P. and Sayektiningsih, T. 2018. Estimating aboveground biomass on private forest using Sentinel-2 imagery. Journal of Sensors, 2018, 1-11.

Asner, G.P., Scurlock, J.M.A. and Hicke, J. 2003. Global synthesis of leaf area index observations: implications for ecological and remote sensing studies. Global Ecology and Biogeography, 12(3), 191-205.

Ateşoğlu, A. 2009. Farklı uydu görüntü verileri ile meşcere parametreleri arasındaki ilişkilerin araştırılması (Bartın-Mugada örneği). Doktora Tezi, Bartın Üniversitesi, 111 sayfa, Bartın.

Ateşoğlu, A. 2014. Farklı uydu görüntü verileri ile meşcere parametreleri arasındaki ilişkilerin araştırılması (Bartın-Mugada örneği). Doktora Tezi, Bartın Üniversitesi, Fen Bilimleri Enstitüsü, 111 sayfa, Bartın.

Başkent, E.Z. 1996. Türkiye ormancılığında coğrafi bilgi sistemi kurulmasına yönelik bir ön çalışma ve kavramsal yaklaşım. Özel Çalışma, Karadeniz Teknik Üniversitesi, Orman Fakültesi, Trabzon.

Başkent, E.Z. 1999. Ekosistem amenajmanı ve biyolojik çeşitlilik. Turkish Journal of Agriculture and Forestry, 23, Ek Sayı, 353-363.

Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M.L. and Bareth, G. 2015. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. International Journal of Applied Earth Observation and Geoinformation, 39, 79-87.

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.

Bolat, F. 2021. Ankara Orman Bölge Müdürlüğü Anadolu Karaçamı meşcerelerinde artım ve büyümenin yapay sinir ağları ile modellenmesi. Doktora Tezi, Çankırı Karatekin Üniversitesi, 193 sayfa, Çankırı.

Bolat, F. and Ercanlı, İ. 2016. Using artificial neural network in describing diameter distribution in an even-aged forest. In International Forestry Symposium (IFSA2016), Kastamonu, Turkey.

Briechle, S., Krzystek, P. and Vosselman, G. 2021. Silvi-Net–A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data. International Journal of Applied Earth Observation and Geoinformation, 98, 102292.

Bruggisser, M., Dorigo, W., Dostálová, A., Hollaus, M., Navacchi, C., Schlaffer, S. and Pfeifer, N. 2021. Potential of Sentinel-1 C-band time series to derive structural parameters of temperate deciduous forests. Remote Sensing, 13(4), 798.

Buckley, D.S., Isebrands, J.G. and Sharik, T.L. 1999. Practical field methods of estimating canopy cover, PAR, and LAI in Michigan oak and pine stands. Northern Journal of Applied Forestry, 16(1), 25-32.

Bulut, S. (2021). Ankara Orman Bölge Müdürlüğü saf Karaçam meşcerelerinde net birincil üretim ve yaprak alan indeksinin uzaktan algılama teknikleri ile modellenmesi. Doktora Tezi, Çankırı Karatekin Üniversitesi, 148 sayfa, Çankırı.

Bulut, S., Günlü, A. and Keleş, S. 2016. Estimation of some stand parameters using Göktürk-2 satellite image. In Proceedings of the 1st International Symposium of Forest Engineering and Technologies, Bursa, Turkey (pp. 118-124).

Bulut, S., Günlü, A. ve Sönmez, M.Y. 2021. Saf karaçam meşcerelerinde yaprak alan indeksi ile meşcere parametreleri arasındaki ilişkilerin modellenmesi. Bartın Orman Fakültesi Dergisi, 23(3), 980-989.

Cañete-Salinas, P., Zamudio, F., Yáñez, M., Gajardo, J., Valdés, H., Espinosa, C., Venegas, J., Retamal, L., Ortega-Farias, S. and Acevedo-Opazo, C. 2020. Evaluation of models to determine LAI on poplar stands using spectral indices from Sentinel-2 satellite images. Ecological Modelling, 428, 109058

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.

Chrysafis, I., Mallinis, G., Siachalou, S. and Patias, P. 2017. Assessing the relationships between growing stock volume and Sentinel-2 imagery in a Mediterranean forest ecosystem. Remote Sensing Letters, 8(6), 508-517.

Chrysafis, I., Mallinis, G., Tsakiri, M. and Patias, P. 2019. Evaluation of single-date and multi-seasonal spatial and spectral information of Sentinel-2 imagery to assess growing stock volume of a Mediterranean forest. International Journal of Applied Earth Observation and Geoinformation, 77, 1-14.

Çepel, N. 1976. Türkiye'nin önemli yetişme bölgelerinde saf sarıçam ormanlarının gelişimi ile bazı edafik ve fizyografik etkenler arasındaki ilişkiler. İstanbul Üniversitesi Orman Fakültesi Dergisi, 2(A), 25-64.

Çömez, A., 2010. Sündiken Dağlarında sarıçam (*Pinus sylvestris* L.) meşcerelerinde karbon birikiminin belirlenmesi. Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 233 sayfa, İstanbul.

Çil, B., Karahalil, U. ve Karslı, F. 2015. Uzaktan algılama verileri yardımıyla bazı meşcere parametrelerinin tahmin edilmesi: Kütahya/Tetik planlama birimi örneği. TUFUAB VIII. Teknik Sempozyumu. 21-23 Mayıs 2015, Konya.

Dal, E. 2019. Kastamonu yöresi Sarıçam meşcerelerinde çap dağılımlarının modellenmesi. Yüksek Lisans Tezi, Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, 189 s., Kastamonu.

De Almeida, A.A.A., Thiersch, M.F.B.M., Bernardi, L.K., de Pádua, F.A., Arteaga, A.J. M. and Thiersch, C.R. 2021. Artificial neural networks and remote sensing for volumetric prediction in a Eucalyptus sp. plantation. Research, Society and Development, 10(12), e250101220466-e250101220466.

Demirel, D. 2022. Saf karaçam ve sarıçam meşcerelerinde sentinel-1 ve sentinel-2 uydu görüntüleri yardımıyla bazı meşcere parametrelerinin tahmin edilmesi (Karadere Orman İşletme Müdürlüğü örneği). Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Kastamonu Üniversitesi, 269 s., Kastamonu.

Demirel, T. and Özkan, U.Y. 2018. Estimation of some stand parameters using digital aerial photographs for conservation and service oriented forests. Siberian Journal of Forest Science, 5, 85-91.

Desta, F., Mac Siurtain, M.P. and Colbert, J.J. 1999. Parameter estimation of nonlinear growth models in forestry. Silva Fennica, 33(4), 327-336.

Diamantopoulou, M.J. and Özçelik, R. 2012. Evaluation of different modeling approaches for total treeheight estimation in Mediterranean Region of Turkey. Forest Systems, 21(3), 383-397.

Diamantopoulou, M.J., Milios, E., Doganos, D. and Bistinas, I. 2009. Artificial neural network modeling for reforestation design through the dominant trees bole- volume estımation. Natural Resource Modeling, 22(4), 511-543.

Diamantopoulou, M.J., Özçelik, R., Crecente-Campo, F. and Eler, Ü. 2015. Estimation of Weibull function parameters for modelling tree diameter distribution using least squares and artificial neural networks methods. Biosystems Engineering, 133, 33-45.

DJI Store Turkey 2022. Web sitesi. https://www.djistoreturkiye.com/. Erişim Tarihi: 05.03.2022.

Du, M. and Noguchi, N. 2017. Monitoring of wheat growth status and mapping of wheat yield's within-field spatial variations using color images acquired from UAV-camera system. Remote Sensing, 9(3), 289.
Eckert, S. 2012. Improved forest biomass and carbon estimations using texture measures from Worldview-2 satellite data. Remote Sensing. 4(4), 810-829.
Eklundh, L., Harrie, L. and Kuusk, A. 2001. Investigating relationships between Landsat ETM+ sensor data and leaf area index in a boreal conifer forest. Remote Sensing of Environment, 78(3), 239-251.
Ercanlı, İ. 2020. Innovative deep learning artificial intelligence applications for predicting relationships between individual tree height and diameter at breast height. Forest Ecosystems, 7, 1-18.
Ercanlı, İ., Günlü, A., Şenyurt, M. and Keleş, S. 2018. Artificial neural network models predicting the leaf area index: a case study in pure even-aged Crimean pine forests from Turkey. Forest Ecosystems, 5(1), 29.
Ercanlı, İ., Kurt, A., Şenyurt, M., Günlü, A., Bolat, F. and Keleş, S (2018). Tarsus Yöresi Anadolu Karaçamı Ağaçlarında Hacim Tahminlerinin Yapay Sinir Ağları ile Elde Edilmesi. Anadolu Orman Araştırmaları Dergisi, 4(1), 25-37.
Ercanlı, İ., Kahriman, A. and Bolat, F. 2015. Applications of artificial neural network for predicting the relationships between height and age for oriental beech. The 10th International Beech Symposium, 1-6 September, 2015, Kastamonu, Safranbolu, Turkey.
Ercanlı, İ., Sivrikaya, F., Keleş, S. and Günlü, A. 2007. Sarıçam (*Pinus sylvestris* L.) meşcerelerinin hacim artımının meşcere yaşı, bonitet endeksi ve sıklık derecesine göre değişimi. Kastamonu University Journal of Forestry Faculty, 7(1), 24-37.
Erkan, N. and Güner, Ş.T. 2018. Determination of carbon concentration of tree components for Scotch pine forests in Türkmen Mountain (Eskişehir, Kütahya) Region. Forestist, 68(2), 87-92.
Erkan, N., Kaya, A. ve Kalkan, B. 2021. Sarıçamın (*Pinus silvestris* L.) doğal yayılış alanı dışında gösterdiği bir performans: Pütürge örneği. Ağaç ve Orman, 2(1), 15-21.
ESA 2022. Web sitesi. https://scihub.copernicus.eu/. Erişim tarihi: 06.04.2022.
Eva, H., Carboni, S., Achard, F., Stach, N., Durieux, L., Faure, J.F. and Mollicone, D. 2010. Monitoring forest areas from continental to territorial levels using a sample of medium spatial resolution satellite imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 65(2), 191-197.
FAO 2015. FAO Global Forest Resources Assessment 2015, UN Food and Agriculture Organization: Rome, Italy, 2015.
Foresee, F.D. and Hagan, M.T. 1997. Gauss-Newton approximation to Bayesian learning. In: Proceedings of "International Conference on Neural Networks (ICNN'97)", Houston, TX, USA, 1997, vol.3 pp. 1930-1935.
Gamon, J.A. and Surfus, J.S. 1999. Assessing leaf pigment content and activity with a reflectometer. The New Phytologist, 143(1),105-117.
García-Fernández, M., Sanz-Ablanedo, E. And Rodríguez-Pérez, J.R. 2021. High-Resolution Dron-Acquired RGB Imagery to Estimate Spatial Grape Quality Variability. Agronomy, 11(4), 655.
Getzin, S., Nuske, R.S. and Wiegand, K. 2014. Using unmanned aerial vehicles (UAV) to quantify spatial gap patterns in forests. Remote Sensing, 6(8), 6988-7004.

Giannetti, F., Chirici, G., Gobakken, T., Naesset, E., Travaglini, D. And Puliti, S. 2018. A new approach with DTM-independent metrics for forest growing stock prediction using UAV photogrammetric data. Remote Sensing of Environment, 213, 195-205.

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, 289-298.

Gitelson, A.A., Kaufman, Y.J., Stark, R. and Rundquist, D. 2002. Novel algorithms for remote estimation of vegetation fraction. Remote Sensing of Environment 80, 76-87.

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.

Gögerçin, R. 2017. ÇAKÜ Orman Fakültesi Araştırma Ormanı'nda Göktürk-2 uydu görüntüsü kullanılarak bazı meşcere parametrelerinin tahmin edilmesi. Yüksek Lisans Tezi, Çankırı Karatekin Üniversitesi, Fen Bilimleri Enstitüsü, 40 sayfa, Çankırı.

Gökmen, H., 1970. Açıktohumlular- Gymnospermae, Orman Genel Müdürlüğü Yayın No: 623, Ankara.

Göztaşı, S.M. 2019. Sarıçam klonal tohum bahçesinde yaprak alan indeksi ile kozalak verimi arasındaki ilişkiler. Yüksek Lisans Tezi, Kastamonu Üniversitesi, 39 sayfa, Kastamonu.

Gülci, S., Akay, A.E., Gülci, N. and Taş, İ. 2021. An assessment of conventional and drone-based measurements for tree attributes in timber volume estimation: A case study on stone pine plantation. Ecological Informatics, 63, 101303.

Güner, Ş.T., Çömez, A. and Özkan, K., 2012. Predicting soil and forest floor carbon stocks in Western Anatolian Scots pine stands, Turkey. African Journal of Agricultural Research 7(28), 4075-4083.

Günlü, A. and Bulut, S. 2022. Modeling leaf area index using time-series remote sensing and topographic data in pure Anatolian black pine stands. International Journal of Environmental Science and Technology, 1-20.

Günlü, A. 2012. Landsat TM uydu görüntüsü yardımıyla bazı meşcere parametreleri (gelişim çağı ve kapalılık) ve arazi kullanım sınıflarının belirlenmesi. Kastamonu University Journal of Forestry Faculty, 12(1), 71-79.

Günlü, A. and Ercanlı, İ. 2020. Artificial neural network models by ALOS PALSAR data for aboveground stand carbon predictions of pure beech stands: a case study from northern of Turkey. Geocarto International, 35(1), 17-28.

Günlü, A., Ercanlı, İ., Başkent, E. and Şenyurt, M. 2013. Predicting stand volume using Quickbird and Landsat 7 ETM+ satellite images for stands of oriental beech (*Fagus orientalis* Lipsky): A case study in Ayancık-Göldağ. Turkish Journal of Forestry, 14(1), 24-30.

Günlü, A., Keleş, S., Ercanlı, İ. and Şenyurt, M. 2017. Estimation of leaf area index using WorldView-2 and Aster satellite image: a case study from Turkey. Environmental Monitoring and Assessment, 189(11), 538.

Günlü, A., Özgün, M. ve Ercanlı, İ. 2014. Landsat TM Uydu görüntüsü yardımıyla bazı meşcere parametrelerinin tahmin edilmesi (Yapraklı Orman İşletme Şefliği örneği). Anadolu Orman Araştırmaları Dergisi, 1(1-2), 41-49.

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

Günlü, A., Sivrikaya, F., Baskent, E.Z., Keles, S., Çakir, G. and Kadiogullari, A.İ. 2008. Estimation of stand type parameters and land cover using Landsat-7 ETM image: A case study from Turkey. Sensors, 8(4), 2509-2525.

Hague, T., Tillett, N.D. and Wheeler, H. 2006. Automated crop and weed monitoring in widely spaced cereals. Precision Agriculture, 7(1), 21-32.

Hamidi, SK., Weiskittel, A., Bayat, M. and Fallah, A. 2021. Development of individual tree growth and yield model across multiple contrasting species using nonparametric and parametric methods in the Hyrcanian forests of northern Iran. European Journal of Forest Research, 140(2), 421-434.

Han, H., Wan, R. and Li, B. 2021. Estimating forest aboveground biomass using Gaofen-1 images, Sentinel-1 images, and machine learning algorithms: A case study of the Dabie Mountain Region, China. Remote Sensing, 14(1), 176.

Hansen, M.C., Stehman, S.V., Potapov, P.V., Arunarwati, B., Stolle, F. and Pittman, K. 2009. Quantifying changes in the rates of forest clearing in Indonesia from 1990 to 2005 using remotely sensed data sets. Environmental Research Letters, 4(3), 034001.

Hansen, M.C., Stehman, S.V., Potapov, P.V., Loveland, T.R., Townshend, J.R., DeFries, R.S., Pittman, K.W., Arunarwati, B. Stolle, F. Steininger, M.K., Carroll, M. and DiMiceli, C. 2008. Humid tropical forest clearing from 2000 to 2005 quantified by using multitemporal and multiresolution remotely sensed data. Proceedings of the National Academy of Sciences, 105(27), 9439-9444.

Haralick, R.M., Shanmugam, K. and Dinstein, I.H. 1973. Textural features for ımage classification. IEEE Transactions on Systems, Man, And Cybernetics, 3(6), 610-621.

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.

Huete, A.R. 1988. A Soil Adjusted Vegetation Index (SAVI). Remote Sensing of Environment, 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.

Hunt Jr, E.R., Doraiswamy, P.C., McMurtrey, J.E., Daughtry, C.S., Perry, E.M. and Akhmedov, B. 2013. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. International Journal of Applied Earth Observation and Geoinformation, 21, 103-112.

Hyyppä. J., Hyyppä. H., Inkinen. M., Engdahl. M., Linko. S. and Zhu. Y. 2000. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. Forest Ecology and Management, 128, 109-120

IBM 2021. Web sitesi. https://www.ibm.com/cloud/learn/overfitting Erişim tarihi: 07.09.2021.

İnan, M. 2004. Orman varlığının saptanmasında uzaktan algılama verileri. Doktora Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 142 s., İstanbul.

Jagodzinski, A.M. and Kalucka, I. 2008. Age-related changes in leaf area index of young Scots pine stands. Dendrobiology, 59, 57-65.

Jensen, J.R., Qiu, F. and Ji, M. 1999. Predictive modelling of coniferous forest age using statistical and artificial neural network approaches applied to remote sensor data. International Journal of Remote Sensing, 20(14), 2805-2822.

Jiang, F., Kutia, M., Sarkissian, A.J., Lin, H., Long, J., Sun, H. and Wang, G. 2020. Estimating the growing stem volume of coniferous plantations based on random forest using an optimized variable selection method. Sensors, 20(24), 7248.

Jiang, Z.Y., Huete, A.R., Didan, K. and Miura, T. 2008. Development of a two-band enhanced vegetation index without a blue band. Remote Sensing of Environment, 112, 3833-3845.

Jones, A.R., Raja Segaran, R., Clarke, K.D., Waycott, M., Goh, W.S. and Gillanders, B.M. 2020. Estimating mangrove tree biomass and carbon content: a comparison of forest inventory techniques and Dron imagery. Frontiers in Marine Science, 6, 784.

Kahriman, A., Günlü, A. and Karahalil, U. 2014. Estimation of crown closure and tree density using Landsat TM satellite images in mixed forest stands. Journal of the Indian Society of Remote Sensing, 42(3), 559-567.

Kaptan, S. (2018). Sosyo-ekonomik durum envanteri ve orman amenajman planlarına yansıtılması. Doktora Tezi, Fen Bilimleri Enstitüsü, Bartın Üniversitesi, 258 s., Bartın.

Kaptan, S., Aksoy, H. and Durkaya, B. 2022. Estimation of uneven-aged forest stand parameters, crown closure and land use/cover using the Landsat 8 OLI satellite image. Geocarto International, 1-18.

Kapucu, F. 2004. Orman amenajmanı, KTÜ, 215, 33, 515, Trabzon.

Kara, Ö., Şentürk, M., Bolat, İ. ve Çakıroğlu, K. 2011. Kayın, Göknar ve Göknar-Kayın meşcerelerinde yaprak alan indeksi ile toprak özellikleri arasındaki ilişkiler. Journal of the Faculty of Forestry, Istanbul University, 61(1), 47-54.

Karahalil, U., Karslı, F., Çil, B. ve Canaz Sevgen, S. 2017. Meşcere parametrelerinin yerel uydu ve dijital kamera görüntüleriyle tahmini ve farklı uydu görüntü verileri ile karşılaştırılması. Proje Yürütücüsü: Uzay Karahalil, Proje No: 1150013, TUBİTAK.https://openaccess.artvin.edu.tr/xmlui/bitstream/handle/11494/4118/uzay_karahalil.pdf?sequence=1&isAllowed=y

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.

Key, C.H. and Benson, N.C. 2006. Landscape assessment (LA). In: Lutes, Duncan C.; Keane, Robert E.; Caratti, John F.; Key, Carl H.; Benson, Nathan C.; Sutherland, Steve; Gangi, Larry J. 2006. FIREMON: Fire effects monitoring and inventory system. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins, CO: US Department of Agriculture, Forest Service, Rocky Mountain Research Station, p. LA-1-55: 164.

Kinane, S.M., Montes, C.R., Albaugh, T.J. and Mishra, D.R. 2021. A Model to Estimate Leaf Area Index in Loblolly Pine Plantations Using Landsat 5 and 7 Images. Remote Sensing, 13(6), 1140.

Kocaman, M. ve Durkaya, B. 2020. Karbon depolama miktarlarının zamansal değişimi. Bartın Orman Fakültesi Dergisi, 22(2), 591-603.

Komárek, J. 2020. The perspective of unmanned aerial systems in forest management: Do we really need such details?. Applied Vegetation Science, 23(4), 718-721.

Kozlowski, T.T., Kramer, P.J. and Pallardy, S.G. 1991. The Physiological ecology of woody plants. Academic Press, 657 p., New York.

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.

Kuzugudenli, E., Saplioglu, K., Kaya, C., Aday Kaya, A.G., Kaya, E., Senturk, E. and Arslan, S.S. 2013. The forecasting of cedar trees diameter with artificial neural networks. AWERProcedia Information Technology and Computer Science, 3(2013): 3rd World Conference on Information Technology (WCIT-2012), 1590-1595 p., Barcelona.

Lan, Y.B., Zhu, Z.H., Deng, X.L., Lian, B.Z., Huang, J.Y., Huang, Z.X. and Hu, J. 2019. Monitoring and classification of citrus Huanglongbing based on UAV hyperspectral remote sensing. Transactions of the CSAE, 35(3), 92-100.

Latifi, H. and Heurich, M. 2019. Multi-scale remote sensing-assisted forest inventory: A glimpse of the state-of-the-art and future prospects. Remote Sensing, 11(11), 1260.

Latifi, H., Fassnacht, F.E., Müller, J., Tharani, A., Dech, S. and Heurich, M. 2015. Forest inventories by LiDAR data: A comparison of single tree segmentation and metric-based methods for inventories of a heterogeneous temperate forest. International Journal of Applied Earth Observation and Geoinformation, 42, 162-174.

Laurin, G.V., Balling, J., Corona, P., Mattioli, W., Papale, D., Puletti, N., Rizzo, M., Truckenbrodt, J. and Urban, M. 2018. Above-ground biomass prediction by Sentinel-1 multitemporal data in central Italy with integration of ALOS2 and Sentinel-2 data. Journal of Applied Remote Sensing, 12(1), 016008.

Lawrence, S., Giles, C.L. and Tsoi, A.C. 1997. Lessons in neural network training: Overfitting may be harder than expected. In AAAI/IAAI (pp. 540-545).

Lebourgeois, V., Bégué, A., Labbé, S., Mallavan, B., Prévot, L., and Roux, B. 2008. Can commercial digital cameras be used as multispectral sensors? A crop monitoring test. Sensors, 8(11), 7300-7322.

Li, Y., Li, M., Li, C. and Liu, Z. 2020a. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. Scientific reports, 10(1), 1-12.

Li, X., Liu, Z., Lin, H., Wang, G., Sun, H., Long, J. and Zhang, M. 2020b. Estimating the growing stem volume of Chinese pine and larch plantations based on fused optical data using an improved variable screening method and stacking algorithm. Remote Sensing, 12(5), 871.

Liu, C. and Zhang, S.Y. 2005. Models for predicting product recovery using selected tree characteristics of black spruce. Canadian Journal of Forest Research, 35(4), 930-937.

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.

Louhaichi, M., Borman, M.M. and Johnson, D.E. 2001. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. Geocarto International 16, 65-70.

Maier, H.R. and Dandy, G.C. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. Environmental Modelling & Software, 15(1), 101-124.

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.

McKinley, D.C., Ryan, M.G., Birdsey, R.A., Giardina, C.P., Harmon, M.E., Heath, L.S., Houghton, R.A., Jackson, R.B., Morrison, J.F., Murray, B.C., Pataki, D.E. and Kenneth E. Skog, K.E. 2011. A synthesis of current knowledge on forests and carbon storage in the United States. Ecological applications, 21(6), 1902-1924.

Mosaffaei, Z. and Jahani, A. 2021. Modeling of Ash (*Fraxinus excelsior*) bark thickness in urban forests using Artificial Neural Network (ANN) and regression models. Modeling Earth Systems and Environment, 7(3), 1443-1452.

Muhsoni, F.F., Abida, I.W., Rini, D.A.S. and Putera, A.J. 2021. Estimation of mangrove carbon using Dron images. Depik, 10(1), 41-46.

Navarro, J.A., Algeet, N., Fernández-Landa, A., Esteban, J., Rodríguez-Noriega, P. and Guillén-Climent, M.L. 2019. Integration of UAV, Sentinel-1, and Sentinel-2 data for mangrove plantation aboveground biomass monitoring in Senegal. Remote Sensing, 11(1), 77.

Nouri, A., Kiani, B., Hakimi, M.H. and Mokhtari, M.H. 2020. Estimating oak forest parameters in the western mountains of Iran using satellite-based vegetation indices. Journal of Forestry Research, 31(2), 541-552.

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.

OGM 2017. OGM Orman İdaresi ve Planlama Dairesi Başkanlığı, Ekosistem Tabanlı Fonksiyonel Orman Amenajman Planlarının Düzenlenmesine Ait Usul ve Esaslar (299 sayılı tebliğ−düzeltmeli son baskı), 214 s., Ankara.

OGM 2020. Sinop Orman Bölge Müdürlüğü: Orman varlığı. https://sinopobm.ogm.gov.tr/Sayfalar/Ormanlarimiz/OrmanVarligi.aspx Erişim tarihi: 19.09.2020.

OGM 2021. Web sitesi. Ormancılık istatistikleri, https://web.ogm.gov.tr/ekutuphane/Sayfalar/Istatistikler.aspx Erişim tarihi: 09.05.2021.

Okan, E. 2018. Saf ve karışık meşcerelerde karbon depolama kapasitelerinin biyokütle modelleri ve BEF katsayıları yardımıyla tespitinin incelenmesi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Bartın Üniversitesi, 75 s., Bartın.

Okut, H. 2016. Bayesian regularized neural networks for small n big p data. Artificial Neural Networks-Models and Applications 28-48.

Ozkal, M.K. 2017. Models of forest inventory for Istanbul forest using airborne lidar and spaceborne imagery. Open Access Master's Thesis, Michigan Technological University.

Öner, N. ve Çakır, M. 2006. Yaprak alanının Anadolu Karaçamı (*Pinus nigra* subsp. nigra var. caramanica) ve Sarıçam (*Pinus sylvestris* L.) fidanlarında bitki çap, boy, hacim ve ağırlık artımı üzerine etkileri. Kastamonu University Journal of Forestry Faculty, 6(2), 167-178.

Özbayram, A.K., Çiçek, E. ve Yılmaz, F. 2015. Kızılçam ve Karaçam meşcerelerinde yaprak alanı indeksi (YAİ) ile bazı meşcere özellikleri arasındaki ilişkiler. Kastamonu University Journal of Forestry Faculty, 15(1), 78-85.

Özçelik, R., Diamantopoulou, M.J. and Trincado, G. 2019. Evaluation of potential modeling approaches for scots pine stem diameter prediction in north-eastern Turkey. Computers and Electronics in Agriculture, 162, 773-782.

Özçelik, R., Diamantopoulou, M.J., Brooks, J. R. and Wiant Jr, H.V. 2010. Estimating tree bole volume using artificial neural network models for four species in Turkey. Journal of Environmental Management, 91(3), 742-753.

Özdemir, G. 2018. Karabük Yöresi Kayın-Göknar Karışık Meşcerelerinde Gövde Çaplarının Yapay Sinir Ağları ile Tahmin Edilmesi, Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, Orman Mühendisliği Ana Bilimdalı Yüksek Lisans Tezi, 101 s.

Özdemir, İ. 2013. Havasal LIDAR verileri kullanılarak meşcere parametrelerinin tahmin edilmesi. Süleyman Demirel Üniversitesi Orman Fakültesi Dergisi, Seri: A, 14(1), 31-39.

Özdemir, İ. ve Mert, A. 2009. Düzlerçamı Kızılçam Ormanında Quickbird uydu verileri kullanılarak gövde hacminin tahmini. Türkiye Ormancılık Dergisi, 8(2), 107-118.

Özkan, U. 2006. Uydu görüntüleri yardımıyla meşcere parametrelerinin kestirilmesi ve orman amenajmanında kullanılması olanakları. Journal of the Faculty of Forestry Istanbul University, 56(2), 191-217.

Özkan, U. and Yeşil, A. 2016. Forest stand delineation using Ikonos image and object based image analysis. Journal of the Faculty of Forestry Istanbul University, 66(2), 600-612.

Özkan, U.Y. 2003. Uydu görüntüleri yardımıyla meşcere parametrelerinin kestirilmesi ve orman amenajmanında kullanılması olanakları. İstanbul Üniversitesi, Orman Fakültesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 70 s., İstanbul.

Pathak, B. and Barooah, D. 2013. Texture analysis based on the gray-level co-occurrence matrix considering possible orientations. International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 2(9), 4206-4212.

Pekkarinen, A., Reithmaier, L. and Strobl, P. 2009. Pan-European forest/non-forest mapping with Landsat ETM+ and CORINE Land Cover 2000 data. ISPRS Journal of Photogrammetry and Remote Sensing, 64(2), 171-183.

Piotrowski, A.P. and Napiorkowski, J.J. 2013. A comparison of methods to avoid overfitting in neural networks training in the case of catchment runoff modelling. Journal of Hydrology, 476, 97-111

Poudel, K.P. and Cao, Q.V. 2013. Evaluation of methods to predict Weibull parameters for characterizing diameter distributions. Forest Science, 59(2), 243-252.

Pu, R. and Cheng, J. 2015. Mapping forest leaf area index using reflectance and textural information derived from WorldView-2 imagery in a mixed natural forest area in Florida, US. International Journal of Applied Earth Observation and Geoinformation, 42, 11-23.

Purohit, S., Aggarwal, S.P. and Patel, N.R. 2021. Estimation of forest aboveground biomass using combination of Landsat 8 and Sentinel-1A data with random forest regression algorithm in Himalayan Foothills. Tropical Ecology, 62(2), 288-300.

Pyysalo, U. and Hyyppa, H. 2002. Reconstructing tree crowns from laser scanner data for feature extraction. International Archives Of Photogrammetry Remote Sensing And Spatial Information Sciences, 34(3/B),218-221.

Raši, R., Bodart, C., Stibig, H.J., Eva, H., Beuchle, R., Carboni, S., Simonetti, D. and Achard, F. 2011. An automated approach for segmenting and classifying a large sample of multi-date Landsat imagery for pan-tropical forest monitoring. Remote Sensing of Environment, 115(12), 3659-3669.

Reitberger, J., Schnörr, C., Krzystek, P. and Stilla, U. 2009. 3D segmentation of single trees exploiting full waveform LIDAR data. ISPRS Journal of Photogrammetry and Remote Sensing, 64(6), 561-574.

Remondino, F., Nex, F., Toschi, I., and Rupnik, E. 2014. Camere aeree oblique: sistemi, applicazioni e prospettive future. GEOmedia, 18(3).

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, 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.

Ryan, M.G., Binkley, D. and Fownes, J.H. 1997. Age-related decline in forest productivity: pattern and process. Advances in Ecological Research, 27, 213–262.

Sağlam, F. 2021. Kastamonu ve Sinop yöresi doğal Sarıçam (*Pinus sylvestris* L.) meşcereleri için ekolojik tabanlı büyüme modelleri. Doktora Tezi, Fen Bilimleri Enstitüsü, Kastamonu Üniversitesi, 242 s., Kastamonu.

Sakıcı, O.E. and Günlü, A. 2018. Artificial intelligence applications for predicting some stand attributes using Landsat 8 OLI satellite data: A case study from Turkey. Applied Ecology and Environmental Research, 16(4), 5269-5285.

Sakıcı, O.E. and Özdemir, G. 2018. Stem taper estimations with artificial neural networks for mixed oriental beech and Kazdağı fir stands in Karabük region, Turkey. CERNE, 24(4), 439-451.

Sakıcı, O.E. 2009. Ağaç Serveti Envanterinde Kullanılan Çeşitli Örnekleme Yöntemlerinin Karşılaştırılması. Doktora Tezi, Karadeniz Teknik Üniversitesi, 235 sayfa, Trabzon.

Santi, E., Paloscia, S., Pettinato, S., Chirici, G., Mura, M. and Maselli, F. 2015. Application of Neural Networks for the retrieval of forest woody volume from SAR multifrequency data at L and C bands. EuropeanJournal of Remote Sensing, 48(1), 673-687.

Santoro, M., Beer, C., Cartus, O., Schmullius, C., Shvidenko, A., McCallum, I., Wegmüller, U. and Wiesmann, A. 2011. Retrieval of growing stock volume in boreal forest using hyper-temporal series of Envisat ASAR ScanSAR backscatter measurements. Remote Sensing of Environment, 115(2), 490-507.

Saraçoğlu, N. 2018. Küresel iklim değişimi biyoenerji enerji ormancılığı ve yenilenebilir enerji kaynakları. Efil Yayınevi, 668 sayfa, Ankara.

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.

Sinha, S., Jeganathan, C., Sharma, L.K. and Nathawat, M.S. 2015. A review of radar remote sensing for biomass estimation. International Journal of Environmental Science and Technology, 12(5), 1779-1792.

Sivrikaya, F. 2008. Türkiye'de orman amenajman planlama model yazılımının geliştirilmesi. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 179 sayfa, Trabzon.

Skudnik, M. and Jevšenak, J. 2022. Artificial neural networks as an alternative method to nonlinear mixed-effects models for tree height predictions. Forest Ecology and Management, 507, 120017.

Soja, M.J., Quegan, S., d'Alessandro, M.M., Banda, F., Scipal, K., Tebaldini, S. and Ulander, L.M. 2021. Mapping above-ground biomass in tropical forests with ground-cancelled P-band SAR and limited reference data. Remote Sensing of Environment, 253, 112153.

Solberg, S., Naesset, E. and Bollandsas, O.M. 2006. Single tree segmentation using airborne laser scanner data in a structurally heterogeneous spruce forest. Photogrammetric Engineering & Remote Sensing, 72(12), 1369-1378.

Sothe, C., De Almeida, C.M., Schimalski, M.B., La Rosa, L.E.C., Castro, J.D.B., Feitosa, R.Q. and Tommaselli, A.M.G. 2020. Comparative performansce of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data. GIScience & Remote Sensing, 57(3), 369-394.

Soudani, K., François, C., Maire, G.L., Dantec, V.L. and Dufrêne, E. 2006. Comparative analysis of IKONOS, SPOT, and ETM+ data for leaf area index estimation in temperate coniferous and deciduous forest stands. Remote Sensing of Environment, 102, 161-175.

Stankevich, S.A., Kozlova, A.A., Piestova, I.O. and Lubskyi, M.S., 2017. Leaf area index estimation of forest using Sentinel-1 C-band SAR data. In 2017 IEEE Microwaves, Radar and Remote Sensing Symposium (MRRS), Kiev, Ukraine, 29-31 August 2017, (pp. 253-256).

Stenberg, P., Rautiainen, M., Manninen, T., Voipio, P. and Smolander, H. 2004. Reduced simple ratio better than NDVI for estimating LAI in Finnish pine and spruce stands.

Şenyurt, M. and Ercanli, İ. 2019. A comparison of artificial neural network models and regression models to predict tree volumes for crimean black pine trees in Cankiri forests. Šumarski List, 143(9-10), 413-423.

Şenyurt, M., Yılmaz, C. ve Günlü, A. 2017. Landsat TM uydu görüntüsü yardımıyla bazı meşcere parametrelerinin tahmin edilmesi (Reşadiye Orman İşletme Şefliği örneği). Anadolu Orman Araştırmaları Dergisi, 3(2), 200-209.

Tanaka, K. and Hashimoto, S. 2006. Plant canopy effects on soil thermal and hydrological properties and soil respiration. Ecological Modelling, 196(1-2), 32-44.

Tang, L. and Shao, G. 2015. Dron remote sensing for forestry research and practices. Journal of Forestry Research, 26(4), 791-797.

Tavasoli, N., Arefi, H., Samiei-Esfahany, S. and Ronoud, Q. 2019. Modelling the amount of carbon stock using remote sensing in urban forests and its relatıonshıp wıth land use change. In The international archives of the photogrammetry, remote sensing and spatial information sciences, volume XLII-4/W18, GeoSpatial conference–joint conferences of SMPR and GI research, 12-14 October 2019, Karaj, Iran

Themistocleous, K. 2019. DEM modeling using RGB-based vegetation indices from UAV images. In Seventh International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2019) (Vol. 11174, pp. 499-506). SPIE.

Torresan, C., Berton, A., Carotenuto, F., Di Gennaro, S.F., Gioli, B., Matese, A., Miglietta, F., Vagnoli, C., Zaldei, A. and Wallace, L. 2017. Forestry applications of UAVs in Europe: a review. International Journal of Remote Sensing, 38(8-10), 2427-2447.

Tucker, C.J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. Remote Sensing of Environment. 8(2), 127-150.

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.

Uça Avcı, Z.D., Kuşak, B. ve Kuşak, L. 2016. Meşcere tiplerinin uydu verileri ile belirlenmesinde farklı doku ölçütlerinin değerlendirilmesi. Akademik Bilişim'14 XVI. Akademik Bilişim Konferansı Bildiriler Kitabı, Mersin Üniversitesi, sayfa 121-128, ISBN: 978-605-85087-5-0, https://ab.org.tr/ab14/bildiri/163.pdf

USGS 2013. Web sitesi. USGS earth explorer. https://earthexplorer.usgs.gov/, Erişim tarihi: 06.02.2022.

Url-1. http://www.sinop.gov.tr/

Van Havre, Z., White, N., Rousseau, J. and Mengersen, K. 2015. Overfitting Bayesian mixture models with an unknown number of components. PloS one, 10(7), e0131739.

Vatandaşlar, C., Zeybek, M., Çankaya, E.Ç., Demiraslan, T., Şahin, C., Gündüz, Y., Korkmaz, Ü. ve Avcı, M.L. 2021. El tipi mobil LiDAR teknolojisinin orman envanterlerinde kullanımı: Artvin-Şavşat örneği. Ormancılık Araştırma Dergisi, 9(1), 81-96.

Vinícius Oliveira Castro, R., Boechat Soares, C.P., Leite, H.G., Lopes de Souza, A., Saraiva Nogueira, G. and Bolzan Martins, F. 2013. Individual growth model for Eucalyptus stands in Brazil using artificial neural network. International Scholarly Research Notices.

Woebbecke, D.M., Meyer, G.E., Von Bargen, K. and Mortensen, D.A. 1995. Shape features for identifying young weeds using image analysis. Transactions of the ASAE, 38(1), 271-281.

Xie, S., Wang, W., Wang, Z. and Huang, G. 2020. January. Modeling forest stand parameters using remote sensing images and topographic information. In Proceedings of the 5th International Conference on Multimedia and Image Processing (pp. 109-114).

Yang, F. and Yue, Z. 2014. Kernel density estimation of three-parameter Weibull distribution with neural network and genetic algorithm. Applied Mathematics and Computation, 247, 803-814.

Yazdani, M., Jouibary, S. S., Mohammadi, J., & Maghsoudi, Y. (2020). Comparison of different machine learning and regression methods for estimation and mapping of forest stand attributes using ALOS/PALSAR data in complex Hyrcanian forests. Journal of Applied Remote Sensing, 14(2), 024509.

Yavuz, H., Mısır, N., Tüfekçioğlu, A., Altun, L., Mısır, M., Ercanlı, İ., Sakıcı, O.E., Kahriman, A., Karahalil, U., Yılmaz, M., Sarıyıldız, T., Küçük, M., Meydan, G., Bayburtlu, Ş., Bilgili, F., Aydın, A.C., Kara, Ö., Bolat, İ. ve Usta, A., 2010. Karadeniz Bölgesi saf ve karışık Sarıçam (Pinus slyvestris L.) meşcereleri için mekanistik büyüme modellerinin geliştirilmesi, biyokütle ve karbon depolama miktarlarının belirlenmesi. (TÜBİTAK-TOVAG Projesi, Proje No: 106O274), Karadeniz Teknik Üniversitesi Orman Fakültesi, Trabzon.

Yer, B.M. and Sakıcı, O.E. 2022. Determination of relationships between leaf area index and stand characteristics in anatolian black pine stands of Kastamonu region, Turkey. CERNE, 28.

Yilmaz, V., Serifoglu, C. and Gungor, O. 2016. Determining stand parameters from UAS-based point clouds. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 1.

Ying, X. 2019. An overview of overfitting and its solutions. In Journal of Physics: Conference Series (Vol. 1168, No. 2, p. 022022). IOP Publishing.

Yu, Y., Wang, J., Liu, G. and Cheng, F. 2019. Forest leaf area ındex ınversion based on Landsat OLI data in the Shangri-La City. Journal of the Indian Society of Remote Sensing, 47(6), 967-976.

Zarco-Tejada, P.J., Berjón, A., López-Lozano, R., Miller, J.R., Martín, P., Cachorro, V., González, M.R. and De Frutos, A. 2005.Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. Remote Sensing of Environment, 99(3), 271-287.

Zheng, G., Li, X., Zhou, L., Yang, J., Ren, L., Chen, P., Zhang, H. and Lou, X. 2018. Development of a gray-level co-occurrence matrix-based texture orientation estimation method and its application in sea surface wind direction retrieval from SAR imagery. IEEE Transactions on Geoscience and Remote Sensing, 56(9), 5244-5260.

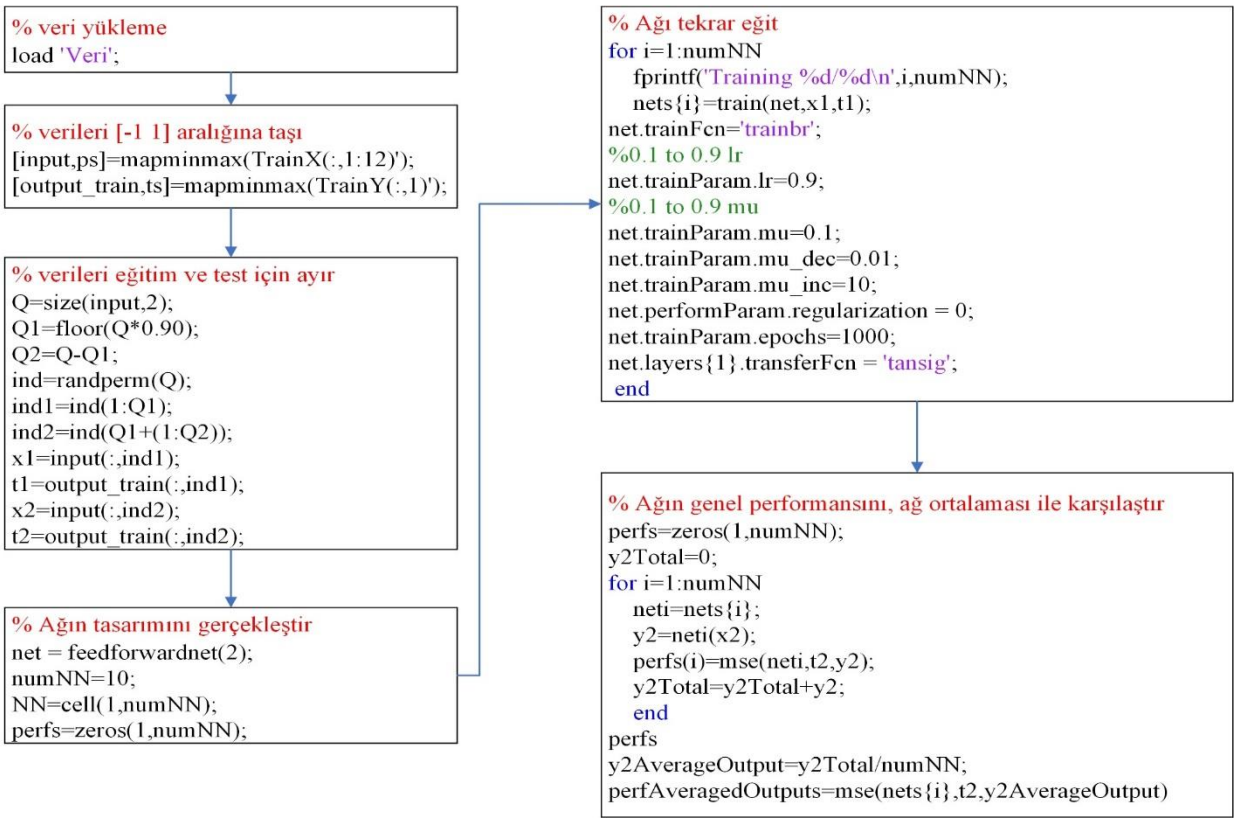
Zhou, J., Guo, R.Y., Sun, M., Di, T.T., Wang, S., Zhai, J. and Zhao, Z. 2017. The Effects of GLCM parameters on LAI estimation using texture values from Quickbird Satellite Imagery. Scientific reports, 7(1),1-12.

Zhou, J., Zhou, Z., Zhao, Q., Han, Z., Wang, P., Xu, J. and Dian, Y. 2020. Evaluation of different algorithms for estimating the growing stock volume of *Pinus massoniana* plantations using spectral and spatial ınformation from a SPOT6 Image. Forests, 11(5), 540.

Zhou, J.J., Zhao, Z., Zhao, J., Zhao, Q., Wang, F. and Wang, H. 2014. A comparison of three methods for estimating the LAI of black locust (*Robinia pseudoacacia* L.) plantations on the Loess Plateau, China. International Journal of Remote Sensing, 35(1), 171-188.

EKLER

Ek 1. Tezde Kullanılan Tasarlanan Yapay Sinir Ağı



ÖZGEÇMİŞ

Adı Soyadı : Hasan AKSOY
Doğum Yeri : Erzurum
Doğum Tarihi : 20.01.1991
Medeni Hali : Bekar
Yabancı Dili : İngilizce
Eğitim Durumu
Lise : Erzurum İMKB Lisesi (YDL) (2006)
Lisans : Bartın Üniversitesi, Bartın Orman Fakültesi, Orman Endüstri Mühendisliği Bölümü (2013)
Lisans : Bartın Üniversitesi, Bartın Orman Fakültesi, Orman Mühendisliği Bölümü (2016)
Yüksek Lisans: Bartın Üniversitesi, Fen Bilimleri Enstitüsü (2015)
Doktora : Çankırı Karatekin Üniversitesi, Fen Bilimleri Enstitüsü (2022)
Çalıştığı Kurum : Sinop Üniversitesi/Ayancık Meslek Yüksekokulu

SCI, SCI-Expanded, SSCI, AHCI gibi İndekslerce Taranan Dergilerdeki Makaleler

1. Aksoy, H., Kaptan S., Varol, T., Çetin, M. and Özel, H.B. 2022. Exploring land use/land cover change by using density analysis method in yenice. International Journal of Environmental Science and Technology, Doi: 10.1007/s13762-021-03847-5 (Yayın No: 7551923)
2. Aksoy, H. and Kaptan, S. 2021. Monitoring of land use/land cover changes using GIS and CA-Markov modeling techniques: a study in Northern Turkey. Environmental Monitoring and Assessment, 193(8), Doi: 10.1007/s10661-021-09281-x (Yayın No: 7138161)
3. Aksoy, H. and Kaptan, S. 2020. Simulation of Future Forest and Land Use/Cover Changes (2019-2039) Using the Cellular Automata-Markov Model. Geocarto International, 1-17. (Yayın No: 6283857)

4. Kaptan, S., Aksoy, H. and Durkaya, B. 2020. Estimation of Uneven-Aged Forest Stand Parameters, Crown Closure and Land Use/Cover Using the Landsat 8 OLI Satellite Image. Geocarto International, 1-19. (Yayın No: 6236449)

Ulusal Hakemli Dergilerdeki Makaleler

1. Gülsoy, S.K., Aksoy, H., Gül Türkmen, H. and Çanakçı, G. 2021. Fiber morphology and chemical composition of heartwood and sapwood of red gum, black willow, and oriental beech. Bartın Orman Fakültesi Dergisi, 23(1), 119-124., Doi: 10.24011/barofd.884128 (Kontrol No: 7026470)
2. Keskin, H., Aksoy, H., Gençer, A. ve Tümen, İ. 2018. Yabani Kızılcık odununun (*Cornus australis* L.) bazı kimyasal özellikleri. El Cezeri Fen ve Mühendislik Dergisi, 5(1), 251-258. (Kontrol No: 4176488)
3. Gençer, A. ve Aksoy, H. 2017. Yabani kızılcık (*Cornus australis* L.) odunundan kâğıt üretimi ve kabuğun kâğıt özelliklerine etkisi. Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi, 18(2), 186-191. (Kontrol No: 3930972)

Uluslararası Kongre/Sempozyum Bildirileri

1. Kaptan, S., Aksoy, H. ve Durkaya, B. 2019. Akgöl Orman İşletme Şefliği ormanlarının biyokütle ve karbon stok değişimlerinin incelenmesi. 8th International Vocational Schools Symposium, 1, 544-551. (Tam Metin Bildiri/Sözlü Sunum) (Yayın No:5176459)
2. Kaptan, S., Aksoy, H., Çavdar Aksoy, Ş. ve Durkaya, B. 2019. Coğrafi Bilgi sistemleri ile arazi örtüsü ve kullanımında yaşanan değişimlerin incelenmesi (Akgöl Orman İşletme Şefliği Örneği). 8th International Vocational Schools Symposium, 1(1), 535-542. (Tam Metin Bildiri/Sözlü Sunum) (Yayın No:5199513)
3. Keskin, H., Aksoy, H., Gençer, A. ve Tümen, İ. 2017. Yabani Kızılcık odununun (*Cornus australis* L.) bazı kimyasal özellikleri. Uluslararası Mühendislik

Araştırmaları Sempozyumu, 112-112. (Özet Bildiri/Sözlü Sunum) (Yayın No:3983981)

Projeler

1. "Yabani Kızılcık (*Cornus australis* L.) Kâğıt Hamuru Üretimine Uygunluğu ve Bazı Kimyasal Özellikleri", Araştırma Projesi, Yürütücü: Gençer, A., Araştırmacı: Aksoy, H., 02/10/2013- 02/11/2014 (Ulusal)

2. Günlü, A. ve Aksoy, H. 2022. Sinop Orman Bölge Müdürlüğü saf sarıçam meşcerelerinde uzaktan algılama verileri kullanılarak bazı meşcere parametrelerinin modellenmesi. Lisansüstü Tez Projesi, Destekleyen Kuruluş: Çankırı Karatekin Üniversitesi, Bilimsel Araştırma Projeleri, OF211221D08.