ÇANKIRI KARATEKİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

ANKARA ORMAN BÖLGE MÜDÜRLÜĞÜ SAF KARAÇAM MEŞCERELERİNDE NET BİRİNCİL ÜRETİM VE YAPRAK ALAN İNDEKSİNİN UZAKTAN ALGILAMA TEKNİKLERİ İLE MODELLENMESİ

Sinan BULUT

ORMAN MÜHENDİSLİĞİ ANABİLİM DALI

ÇANKIRI

2021

Her hakkı saklıdır

TEZ ONAYI

Sinan BULUT tarafından hazırlanan **"Ankara Orman Bölge Müdürlüğü Saf Karaçam Meşcerelerinde Net Birincil Üretim ve Yaprak Alan İndeksinin Uzaktan Algılama Teknikleri ile Modellenmesi"** adlı tez çalışması 09/04/2021 tarihinde aşağıdaki jüri tarafından oy birliği ile Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Anabilim Dalında **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Alkan GÜNLÜ

Eş Danışman : Doç. Dr. Onur ŞATIR

Jüri Üyeleri :

Başkan : Prof. Dr. Günay ÇAKIR
Gümüşhane Üniversitesi, Gümüşhane Meslek Yüksekokulu

Üye : Doç. Dr. Alkan GÜNLÜ
Çankırı Karatekin Üniversitesi, Orman Fakültesi

Üye : Prof. Dr. Sedat KELEŞ
Çankırı Karatekin Üniversitesi, Orman Fakültesi

Üye : Doç. Dr. Meriç ÇAKIR
Çankırı Karatekin Üniversitesi, Orman Fakültesi

Üye : Doç. Dr. Oytun Emre SAKICI
Kastamonu Üniversitesi, Orman Fakültesi

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 "**Ankara Orman Bölge Müdürlüğü Saf Karaçam Meşcerelerinde Net Birincil Üretim ve Yaprak Alan İndeksinin Uzaktan Algılama Teknikleri ile Modellenmesi**" başlıklı 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. (09/04/2021).

Öğrencinin Adı Soyadı
Sinan BULUT

ÖZET

Doktora Tezi

ANKARA ORMAN BÖLGE MÜDÜRLÜĞÜ SAF KARAÇAM MEŞCERELERİNDE NET BİRİNCİL ÜRETİM VE YAPRAK ALAN İNDEKSİNİN UZAKTAN ALGILAMA TEKNİKLERİ İLE MODELLENMESİ

Sinan BULUT

Çankırı Karatekin Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Alkan GÜNLÜ

Bu çalışmada, Ankara Orman Bölge Müdürlüğünde yayılış gösteren saf karaçam meşcerelerinde Carnegie-Ames-Stanford Approach (CASA) modeli kullanılarak hesaplanan net birincil üretimin (NBÜ) yersel ve uzaktan algılama verileri ile modelleme olanakları araştırılmıştır. Çalışmada toplam 180 adet geçici örnek alan alınmıştır. Her bir örnek alanda klasik envanter ölçümleri yapılmış ve her bir örnek alana ait bazı meşcere parametreleri (meşcere göğüs yüzeyi, meşcere hacmi, meşcere orta çapı, meşcere ağaç sayısı, meşcere üst boyu ve yaprak alan indeksi) hesaplanmıştır. Bununla birlikte çalışma kapsamında uzaktan algılama verisi olarak Landsat 8 OLI ve Sentinel-2 uydu görüntüleri kullanılmıştır. Bu uydu görüntülerinden reflektans, vejetasyon indisi ve tekstür değerleri elde edilmiştir. CASA modeli kullanılarak her bir örnek alana ilişkin elde edilen NBÜ değerleri, meşcere parametreleri ve uydu görüntülerinden elde edilen veriler arasındaki ilişkiler çoklu regresyon analizi, destek vektör makineleri ve derin öğrenme teknikleri kullanılarak modellenmiştir. Uygulanan modelleme teknikleri ile meşcere göğüs yüzeyi için 90° (Model R^2=0,91, Test R^2=0,90), meşcere hacmi için 90° (Model R^2=0,85, Test R^2=0,85), meşcere orta çapı için 9x9 filtre (Model R^2=0,88, Test R^2=0,88), meşcere ağaç sayısı için 45° (Model R^2=0,98, Test R^2=0,96), meşcere üst boyu için 135° (Model R^2=0,90, Test R^2=0,89), yaprak alan indeksi için 0° (Model R^2=0,96, Test R^2=0,96) ve net birincil üretim için 45° (Model R^2=0,96, Test R^2=0,95) tekstür değerleri kullanılarak en yüksek seviyede model başarıları elde edilmiştir. CASA model geçerliliğinin kontrolü için 30 adet örnek alan tesis edilmiş ve döküm miktarları elde edilmiştir. CASA modelinin geçerlilik kontrolünde, en yüksek ilişki seviyesi erkek çiçek dökümü ile elde edilmiştir (r=-0,75). Ayrıca NBÜ'nün yükselti ve meşcere yaşı ile negatif, sıcaklık ile pozitif yönde ilişki bulunmuştur. Bu çalışma ile NBÜ'in zamansal dağılımının izlenmesinde NDVI ve güneş radyasyonunun, konumsal açıdan değerlendirildiğinde ise meşcere özelliklerinin etkili olduğu belirlenmiştir. Filtre ve derece tekstür verilerinin birlikte kullanımının modelleme başarı seviyelerini iyileştirdiği görülmüştür.

2021, 148 sayfa

Anahtar Kelimeler: Net birincil üretim, Yaprak alan indeksi, Meşcere parametreleri, Uzaktan algılama, Modelleme, Destek vektör makineleri, Derin öğrenme

ABSTRACT

Doctorate Thesis

MODELING NET PRIMARY PRODUCTIVITY AND LEAF AREA INDEX WITH REMOTE SENSING TECHNIQUES IN PURE CRIMEAN PINE STANDS IN ANKARA REGIONAL DIRECTORATE OF FORESTRY

Sinan BULUT

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

Supervisor: Assoc. Prof. Dr. Alkan GÜNLÜ

In this study, the possibilities of modeling the net primary production (NBU) calculated using the Carnegie-Ames-Stanford Approach (CASA) model in pure Crimean pine stands spread in Ankara Regional Directorate of Forestry with field and remote sensing data were investigated. A total of 180 temporary samples were taken in the study. Classical inventory measurements were made in each sample area and some stand parameters (stand basal area, stand volume, stand mean diameter, stand number of trees, stand top height and leaf area index) were calculated for each sample area. In addition, Landsat 8 OLI and Sentinel-2 satellite images were used as remote sensing data in the study. The reflectance, vegetation index and texture values were obtained from satellite images. Relationships between NBU values obtained for each sample area using the CASA model, stand parameters and data obtained from satellite images were modeled using multiple regression analysis, support vector machines and deep learning techniques. With the applied modeling techniques, 90° for stand basal area (Model R^2=0,91, Test R^2=0,90), 90° for stand volume (Model R^2=0,85, Test R^2=0,85), stand mean diameter 9x9 filter (Model R^2=0,88, Test R^2=0,88), 45° for stand number of trees (Model R^2 = 0,98, Test R^2 = 0,96), 135° for stand top height (Model R^2=0,90, Test R^2=0,89), 0° for leaf area index (Model R^2=0,96, Test R^2=0,96) and 45° for NBU (Model R^2=0,96, Test R^2=0,95) using the texture values, the highest level of model success was obtained. In order to check the CASA model validity, 30 sample areas were established and litterfall amounts were obtained. In the validity check of the CASA model, the highest correlation level was obtained with the male flower fall (r=-0,75). In addition, a negative relationship was found with the elevation and stand age of the NBU, and a positive relationship with the temperature. It has been determined that NDVI and solar radiation are effective in monitoring the temporal distribution of NBU, and stand features when evaluated spatially. It has been observed that the combination of filter and degree texture data improves the modeling success.

2021, 148 pages

Key Words: Net primary productivity, Leaf area index, Stand parameters, Remote sensing, Modelling, Support vector machine, Deep learning

ÖNSÖZ VE TEŞEKKÜR

“Ankara Orman Bölge Müdürlüğü Saf Karaçam Meşcerelerinde Net Birincil Üretim ve Yaprak Alan İndeksinin Uzaktan Algılama Teknikleri ile Modellenmesi” adlı bu çalışma 2015-2021 yılları arasında hazırlanarak Çankırı Karatekin Üniversitesi Fen Bilimleri Enstitüsüne “Doktora Tezi” olarak sunulmuştur.

Bu çalışma, Çankırı Karatekin Üniversitesi BAP OF061218D07 nolu proje tarafından desteklenmiştir.

Çalışmamın her safhasında bana yol gösteren ve yakın ilgisi ile büyük destek sağlayan danışman hocam Doç. Dr. Alkan GÜNLÜ’ye sonsuz teşekkür ederim. Değerli fikir ve görüşlerinden yararlandığım, bilgisini ve yardımlarını esirgemeyen sayın Prof. Dr. Günay ÇAKIR, Prof. Dr. Sedat KELEŞ, Doç. Dr. Onur ŞATIR, Doç. Dr. İlker ERCANLI, Doç. Dr. Oytun Emre SAKICI ve Doç. Dr. Meriç ÇAKIR hocalarıma saygı ve teşekkürlerimi sunarım.

Orman Genel Müdürlüğü Dış İlişkiler, Eğitim ve Araştırma Daire Başkanlığı, Orman İdaresi ve Planlama Daire Başkanlığı, ve Meteoroloji Genel Müdürlüğü’ne teşekkürlerimi sunarım. Ayrıca, envanter çalışmaları sürecinde yardımlarını esirgemeyen Kızılcahamam Orman İşletme Müdürü (OİM) Mehmet PINAR, Nallıhan OİM vekili Abdülkadir ORTATAŞ, Nallıhan OİM Uluhan Orman İşletme (Oİ) Şefi Şafak YEKE, Ilgaz OİM Utku DANIŞ, Ilgaz OİM Eski Hızardere Oİ Şefi Uğur Melih KUDU, Ilgaz OİM Devrez Oİ Levent ÜNVER, Eskipazar OİM Hasan YILDIZ, Çerkeş OİM Sinan ADAŞ, Çamlıdere OİM Bayram ERSÖZ ve Orman Mühendisi Kutay KAYA’ya teşekkür ederim. Arazi çalışmalarını birlikte yaptığımız, bilgi ve katkılarını esirgemeyen Arş. Gör. Ferhat BOLAT’a teşekkürlerimi sunarım.

Bu aşamaya gelmemde bana emeği geçen aileme ve çalışmalarım süresince desteğini esirgemeyen sevgili eşim Merve ve oğlum Mustafa Giray’a şükranlarımı sunarım.

Sinan BULUT
Çankırı, Nisan 2021

İÇİNDEKİLER

ÖZET ..... **i**
ABSTRACT ..... **ii**
ÖNSÖZ VE TEŞEKKÜR ..... **iii**
SİMGELER VE KISALTMALAR ..... **vi**
ŞEKİLLER DİZİNİ ..... **vii**
ÇİZELGELER DİZİNİ ..... **ix**
1. GİRİŞ **1**
2. MATERYAL **9**
2.1 Çalışma Alanı Tanıtımı **9**
2.2 Yersel Veriler **12**
2.2.1 Örnek alan seçimi **12**
2.2.2 Döküm envanteri **12**
2.3 Uzaktan Algılama Verileri **13**
2.3.1 Landsat 8 OLI uydu görüntüsü **13**
2.3.2 Sentinel-2 uydu görüntüsü **14**
2.4 Meteoroloji Verileri **15**
3. YÖNTEM **17**
3.1 Arazi Çalışması **17**
3.2 Uzaktan Algılama Verilerinin Elde Edilmesi **19**
3.2.1 Reflektans değerleri **19**
3.2.2 Vejetasyon indis değerleri **19**
3.2.3 Tekstür değerleri **23**
3.3 Net Birincil Üretimin Hesaplanması **24**
3.3.1 CASA model **24**
3.3.2 Meşcere içi boşlukların elenmesi **28**
3.3.3 Net birincil üretimin farklı kriterlere göre değişiminin analizi **28**
3.4 Döküm Değerlerinin Elde Edilmesi **29**
3.4.1 CASA model geçerliliğinin kontrol edilmesi **31**
3.5 Yaprak Alan İndeksi Değerlerinin Elde Edilmesi **32**
3.6 Modelleme **33**
3.6.1 Çoklu regresyon analizi **34**
3.6.2 Destek vektör makineleri **35**
3.6.3 Derin öğrenme **35**
3.6.4 Performans ölçütleri **36**
4. BULGULAR **39**
4.1 Net Birincil Üretime İlişkin Bulgular **39**
4.1.1 CASA modeline ilişkin bulgular **39**
4.1.2 Ankara Orman Bölge Müdürlüğü içerisindeki Orman İşletme Müdürlüklerinin 2019 yılı net birincil üretim değerlerine ilişkin bulgular **46**
4.1.3 NBÜ'nün sıcaklık, yağış, yükseklik ve meşcere gelişim çağlarına göre değişimine ilişkin bulgular **51**
4.2 Yaprak Alan İndeksine İlişkin Bulgular **51**
4.3 Meşcere Parametrelerine İlişkin Bulgular **54**
4.4 Döküm Miktarlarına İlişkin Bulgular **54**
4.4.1 Döküm miktarlarının meşcere özelliklerine göre değişimi **58**

4.4.2 Döküm elemanları kullanılarak NBÜ verilerinin geçerlilik kontrolü.....60
4.5 Net Birincil Üretim, Yaprak Alan İndeksi ve Meşcere Parametrelerinin Modellenmesi.....62
4.5.1 Yersel veriler ile modelleme.....62
4.5.2 Uzaktan algılama verileri ile modelleme.....70
4.5.2.1 ÇRA metodunda en yüksek başarıyı sağlayan modeller.....71
4.5.2.2 ÇRA metodunda en yüksek başarıyı sağlayan uzaktan algılama veri setlerine DVM metodunun uygulanması.....79
4.5.2.3 ÇRA metodunda en yüksek başarıyı sağlayan uzaktan algılama veri setlerine DÖ metodunun uygulanması.....82
4.5.2.4 ÇRA, DVM ve DÖ metotlarına ait performans ölçütlerinin karşılaştırılması 89
5. TARTIŞMA.....98
5.1 Net Birincil Üretim Bulgularının Değerlendirilmesi.....98
5.2 Yaprak Alan İndeksine Ait Bulguların Değerlendirilmesi.....103
5.3 Döküm Bulgularının Değerlendirilmesi.....107
5.4 Modelleme Bulgularının Değerlendirilmesi.....115
5.4.1 Net birincil üretime ilişkin modelleme bulgularının değerlendirilmesi.....117
5.4.2 Yaprak alan indeksine ilişkin modelleme bulgularının değerlendirilmesi...120
5.4.3 Meşcere parametrelerine ilişkin modelleme bulgularının değerlendirilmesi 123
6. SONUÇ VE ÖNERİLER.....129
KAYNAKLAR.....132
ÖZGEÇMİŞ.....146

SİMGELER VE KISALTMALAR

ε_{max}	Maksimum ışık kullanım etkinliği
ε_n	Işık kullanım etkinliği
AIC	Akaike bilgi kriteri
APAR	Absorbe edilen fotosentetik aktif radyasyon
BBÜ	Brüt birincil üretim
C	Karbon
CASA	Carnegie-Ames-Stanford Approach
cm	Santimetre
dg	Meşcere orta çapı
FPAR	Fotosentetik aktif radyasyon fraksiyonu
G	Meşcere göğüs yüzeyi
g	Gram
ha	Hektar
$h_{üst}$	Meşcere üst boyu
m	Metre
m^2	Metrekare
MAE	Ortalama mutlak hata
MJ	Megajul
mm	Milimetre
N	Meşcere ağaç sayısı
NBÜ	Net birincil üretim
OBM	Orman Bölge Müdürlüğü
OİM	Orman İşletme Müdürlüğü
p	Önemlilik düzeyi
PAR	Fotosentetik aktif radyasyon
r	Korelasyon katsayısı
R^2	Belirtme katsayısı
R_A	Ototrofik solunum
RMSE	Karekök ortalama hata
R_S	Güneş radyasyonu
t	T hesap
T_{max}	Maksimum sıcaklık
T_{min}	Minimum sıcaklık
T_{opt}	Optimal sıcaklık
V	Meşcere hacmi
W	Yağış
YAİ	Yaprak alan indeksi

ŞEKİLLER DİZİNİ

Şekil 1.1 Atmosferdeki CO_2 oranının ve yüzey sıcaklık değişiminin yıllara göre projeksiyonu (IPCC 2018b) 1
Şekil 2.1 Çalışma alanının konumu 9
Şekil 2.2 Ankara Orman Bölge Müdürlüğü içerisinde bulunan ağaç türlerinin oransal alan dağılımı 10
Şekil 2.3 Landsat 8 OLI uydu görüntülerinin konumları 14
Şekil 2.4 Sentinel-2 uydu görüntülerinin konumları 15
Şekil 2.5 Meteoroloji istasyonlarının konumsal dağılımı 16
Şekil 3.1 Envanter çalışmasında alınan örnek alanların konumsal dağılımı 17
Şekil 3.2 Seçilen referans piksel (n) için açıların gösterimi 23
Şekil 3.3 Döküm envanteri için tesis edilen örnek noktaların konumsal dağılımı 30
Şekil 3.4 Saf karaçam meşcerelerine yerleştirilen döküm kapanları 30
Şekil 3.5 Döküm miktarlarının elde edilme aşamaları 31
Şekil 3.6 CASA modelinin uygulaması ve geçerliliğinin kontrolüne ilişkin iş akış diyagramı 32
Şekil 3.7 YAİ değerlerinin hesaplanması 33
Şekil 3.8 DVM metoduna ait iş akış diyagramı 35
Şekil 3.9 DÖ metodunda ağ eğitim sürecine ilişkin iş akış diyagramı 36
Şekil 3.10 Kavramsal çerçeve 38
Şekil 4.1 Çalışma alanına ait 2019 yılı için aylık ortalama a) NBÜ, b) NDVI, c) ortalama sıcaklık, d) yağış ve e) güneş radyasyonu (Sr) değerleri 42
Şekil 4.2 Saf karaçam meşcerelerine ait 2019 yılı Ocak, Şubat, Mart ve Nisan aylarına ait toplam NBÜ değerlerine ilişkin haritalar 43
Şekil 4.3 Saf karaçam meşcerelerine ait 2019 yılı Mayıs, Haziran, Temmuz ve Ağustos aylarına ait toplam NBÜ değerlerine ilişkin haritalar 44
Şekil 4.4 Saf karaçam meşcerelerine ait 2019 yılı Eylül, Ekim, Kasım ve Aralık aylarına ait toplam NBÜ değerlerine ilişkin haritalar 45
Şekil 4.5 Saf karaçam meşcerelerine ait 2019 yılı için yıllık toplam NBÜ değerlerine ilişkin harita 46
Şekil 4.6 Ankara Orman Bölge Müdürlüğü içerisindeki a) Ankara, b) Beypazarı, c) Çamlıdere, d) Çankırı, e) Çerkeş, f) Eskipazar, g) Ilgaz, h) Kızılcahamam ve i) Nallıhan Orman İşletme Müdürlükleri için 2019 yılı saf karaçam meşcerelerine ait yıllık toplam NBÜ haritaları 48
Şekil 4.7 Ankara Orman Bölge Müdürlüğü 2019 yılı için saf karaçam meşcerelerine ait yıllık toplam NBÜ haritası 50
Şekil 4.8 i) a-b gelişim çağı, ii) c gelişim çağı, iii) d gelişim çağı, iv) 1 kapalı, v) 2 kapalı ve vi) 3 kapalı alanlar için NBÜ gözlem-tahmin grafikleri 53
Şekil 4.9 2019 yılı için aylık ortalama ve toplam döküm değerleri 57
Şekil 4.10 Yıllık toplam döküm içerisinde ibre, dal, kozalak, kabuk, erkek çiçek ve diğer döküm oranları 58
Şekil 4.11 Döküm miktarlarının meşcere gelişim çağlarına göre değişimi 59
Şekil 4.12 Döküm miktarlarının kapalılık sınıflarına göre değişimi 59
Şekil 4.13 Döküm miktarlarının bakıya göre değişimi 60
Şekil 4.14 NBÜ ile döküm elemanları arasındaki ilişkiler; a) ibre, b) dal, c) kozalak, d) kabuk, e) erkek çiçek ve f) diğer döküm 61

Şekil 4.15 ÇRA metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri.....63
Şekil 4.16 DVM metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri.....65
Şekil 4.17 DÖ metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ model ve testlerinin değişen nöron ve katman sayılarına göre korelasyon değişimi 67
Şekil 4.18 DÖ metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri (N: nöron sayısı, K: katman sayısı) 68
Şekil 4.19 DÖ metoduna ilave argümanlar eklenerek koşturulan NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri 69
Şekil 4.20 ÇRA metou kullanılarak farklı filtrelere göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) grafiği, (Landsat 8 OLI: L8, Sentinel-2: S2) 72
Şekil 4.21 ÇRA metou kullanılarak farklı derecelere göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) grafiği, (Landsat 8 OLI: L8, Sentinel-2: S2) 72
Şekil 4.22 Tekstür değerleri ile elde edilen NBÜ (S2, 45°), YAİ (S2, 0°), dg (S2, 9x9), $h_{üst}$ (S2, 135°), N (S2, 45°), G (S2, 90°) ve V (S2, 90°) modellerinin model- test için gözlem ve tahmin grafikleri 77
Şekil 4.23 Tekstür verileri ile elde edilen NBÜ (S2, 45°), YAİ (S2, 0°), dg (S2, 9x9), $h_{üst}$ (S2, 135°), N (S2, 45°), G (S2, 90°) ve V (S2, 90°) modellerinin model- test için gözlem ve tahmin grafikleri 80
Şekil 4.24 DÖ metodu kullanılarak NBÜ, YAİ, dg, $h_{üst}$, N, G ve V'nin model ve testlerinin değişen nöron ve katman sayılarına göre korelasyon değişimi.....83
Şekil 4.25 Tekstür verileri ile elde edilen NBÜ (S2, 45°), YAİ (S2, 0°), dg (S2, 9x9), $h_{üst}$ (S2, 135°), N (S2, 45°), G (S2, 90°) ve V (S2, 90°) modellerinin model- test için gözlem ve tahmin grafikleri (N: nöron sayısı, K: katman sayısı) 87
Şekil 4.26 Tekstür verileri ile elde edilen NBÜ (S2, 45°) ve YAİ (S2, 0°) modellerinin ilave argümanlar kullanılarak model- test için gözlem ve tahmin grafikleri 89

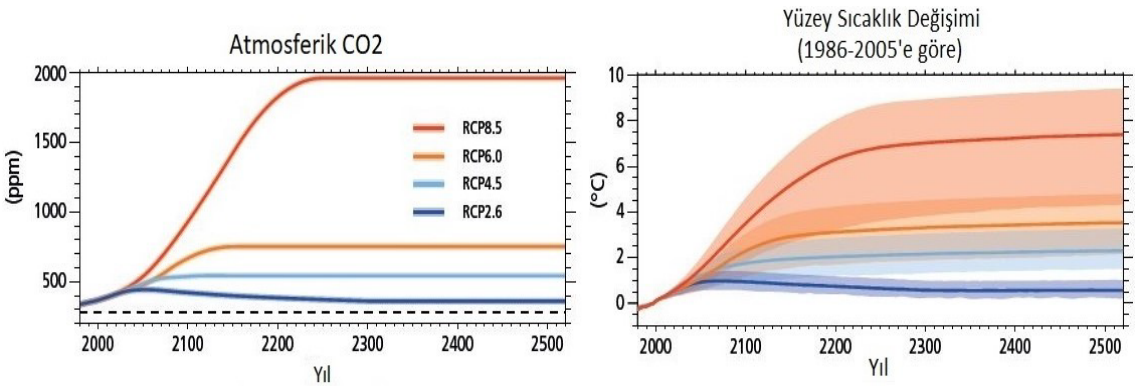
ÇİZELGELER DİZİNİ

Çizelge 2.1 Çalışma alanı saf karaçam meşcerelerine ilişkin detaylı alan dökümü.....11
Çizelge 2.2 Örnek alan seçim kriterleri ve ölçütleri 12
Çizelge 2.3 Landsat 8 OLI uydu görüntüsüne ait teknik özellikler 13
Çizelge 2.4 Sentinel-2 uydu görüntüsüne ait teknik özellikler 14
Çizelge 3.1 Meşcere parametreleri ve hesaplanması 18
Çizelge 3.2 Landsat 8 OLI uydu görüntüsü için hesaplanan vejetasyon indisleri 20
Çizelge 3.3 Sentinel-2 uydu görüntüsü için hesaplanan vejetasyon indisleri 21
Çizelge 3.4 Elde edilen 8 farklı tekstür verisine ilişkin fonksiyonlar 24
Çizelge 3.5 Varyans analizi için kullanılan değişkenlere ilişkin sınıf sınır değerleri.....29
Çizelge 4.1 2019 yılı için aylık ortalama NBÜ, NDVI, ortalama sıcaklık, yağış ve güneş radyasyonu değerleri 40
Çizelge 4.2 NBÜ'nün sıcaklık, yağış, yükseklik ve meşcere gelişim çağlarına göre değişimi 51
Çizelge 4.3 YAİ'nin gelişim çağları ve kapalılık sınıflarına göre NBÜ ile ilişkileri 52
Çizelge 4.4 Meşcere parametrelerine ilişkin tanımlayıcı istatistik değerleri 54
Çizelge 4.5 Döküm envanterinin yapıldığı örnek alanlara ait meşcere özellikleri 55
Çizelge 4.6 2019 yılına ait birim alan için toplam ve ortalama döküm değerleri (g m^{-2}) 56
Çizelge 4.7 NBÜ ve döküm elemanları arasındaki ilişki seviyeleri 61
Çizelge 4.8 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans ve vejetasyon indisleri ile NBÜ, YAİ ve meşcere parametreleri için uygulanan ÇRA model belirtme katsayıları (R^2) 70
Çizelge 4.9 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı filtre tekstür verileri ile NBÜ, YAİ ve meşcere parametreleri için uygulanan ÇRA model belirtme katsayıları (R^2) 71
Çizelge 4.10 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı derece tekstür verileri ile NBÜ, YAİ ve meşcere parametreleri için uygulanan ÇRA model belirtme katsayıları (R^2) 71
Çizelge 4.11 Sentinel-2 uydu görüntüsünden 45° tekstür verileri ile elde edilen NBÜ modeli.....73
Çizelge 4.12 Sentinel-2 uydu görüntüsünden 0° tekstür verileri ile elde edilen YAİ modeli.....73
Çizelge 4.13 Sentinel-2 uydu görüntüsünden 9x9 filtre tekstür verileri ile elde edilen dg modeli.....74
Çizelge 4.14 Sentinel-2 uydu görüntüsünden 135° tekstür verileri ile elde edilen $h_{üst}$ modeli.....74
Çizelge 4.15 Sentinel-2 uydu görüntüsünden 45° tekstür verileri ile elde edilen N modeli.....75
Çizelge 4.16 Sentinel-2 uydu görüntüsünden 90° tekstür verileri ile elde edilen G modeli.....75
Çizelge 4.17 Sentinel-2 uydu görüntüsünden 90° tekstür verileri ile elde edilen V modeli.....76
Çizelge 4.18 NBÜ'nün meşcere parametreleri ile model performans ölçütleri.....90
Çizelge 4.19 YAİ'nin meşcere parametreleri ile model performans ölçütleri 91
Çizelge 4.20 NBÜ'nün YAİ ile model performans ölçütleri 91

Çizelge 4.21 NBÜ'nün Sentinel-2 uydu görüntüsünden elde edilen 45°'lik tekstür verileri ile model performans ölçütleri.....92
Çizelge 4.22 YAİ'nin Sentinel-2 uydu görüntüsünden elde edilen 0°'lik tekstür verileri ile model performans ölçütleri 93
Çizelge 4.23 dg'nin Sentinel-2 uydu görüntüsünden elde edilen 9x9 filtreli tekstür verileri ile model performans ölçütleri.....93
Çizelge 4.24 $h_{üst}$'ün Sentinel-2 uydu görüntüsünden elde edilen 135°'lik tekstür verileri ile model performans ölçütleri 94
Çizelge 4.25 N'in Sentinel-2 uydu görüntüsünden elde edilen 45°'lik tekstür verileri ile model performans ölçütleri 94
Çizelge 4.26 G'nin Sentinel-2 uydu görüntüsünden elde edilen 90°'lik tekstür verileri ile model performans ölçütleri 95
Çizelge 4.27 V'nin Sentinel-2 uydu görüntüsünden elde edilen 90°'lik tekstür verileri ile model performans ölçütleri 96
Çizelge 4.28 DÖ metoduna ilave argümanlar eklenerek koşturulan NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen model- test için performans ölçütleri 97
Çizelge 4.29 DÖ metoduna ilave argümanlar eklenerek tekstür verileri ile elde edilen NBÜ (S2, 45°) ve YAİ (S2, 0°) modellerinin model- test için performans ölçütleri.....97

1. GİRİŞ

Üzerinde yaşadığımız yerküre yüzyıllar geçtikçe değişime uğramakta ve yapılan araştırmalar ile bu değişimler anlaşılmaya çalışılmaktadır. Özellikle arazi kullanım değişiklikleri, ormansızlaşma ve fosil yakıt tüketiminin kilit rol oynadığı küresel iklim değişikliği, günümüzde dünyayı tehdit eden en önemli sorunlardan biridir. Meydana gelen küresel iklim değişikliğinin yıkıcı etkileri hissedilmiş ve bu değişimin devam etmesi durumunda daha kötü sonuçların oluşabileceği kanaatine varılmıştır. İklim değişikliğinin başlangıcını, 18. yüzyılın ikinci yarısında başlayan sanayi devrimi sonucu atmosfere salınan sera gazlarındaki büyük oranlı artış oluşturmaktadır. Atmosferdeki karbondioksit oranı son yüzyıl içerisinde %31 oranında artarak 280 ppm'den 377 ppm'e yükselmiştir (IPCC 2013). Artan dünya nüfusu ve enerji ihtiyacı dikkate alındığında bu oranın herhangi bir önlem alınmadığı takdirde ilerleyen yıllarda daha da artacağı farklı iklim senaryolarının uygulanması ile ortaya konulmaktadır (IPCC 2018a, Şekil 1.1). Atmosferdeki karbondioksit oranının artışı ile birlikte sıcaklık artışı hızlı bir ivme kazanmaktadır. Bu durumun etkisini sadece sıcaklık artışı olarak değerlendirmek eksik ve yanlış olur. Bununla birlikte kuraklık, sel ve kasırga gibi doğal olayların sıklığı ve etkisinde artış, okyanus ve deniz sularının seviyelerinde artış ki bu da kıyı bölgelerinde toprak kaybı ve temiz su kaynaklarında bozulmaya neden olmaktadır. Buzulların erimesi sonucu okyanuslara karışacak suyun ısınması ve hava hareketlerinin olumsuz yönde etkilenmesi, bitki ve hayvan popülasyonlarında oluşacak dengesizlik küresel iklim değişikliğinin diğer olumsuz etkileri arasındadır (IPCC 2014, Köse 2018).



Şekil 1.1 Atmosferdeki CO_2 oranının ve yüzey sıcaklık değişiminin yıllara göre projeksiyonu (IPCC 2018b)

İklim değişikliğinin olumsuz etkileri üzerine, küresel ölçekli farkındalığın oluşarak ilgili bütün paydaşların bir araya gelme gerekliliği ortaya çıkmıştır. Küresel ısınma konusunda yapılan ilk küresel birliktelik, Birinci Dünya İklim Konferansı ile 1979 yılında başlamıştır. Devamında ise 1988 Uluslararası İklim Değişikliği Paneli, 1992 BM Çevre ve Kalkınma Konferansı (Rio Konferansı), 1997 Kyoto Protokolü, 2001 Marakeş Anlaşması ve 2002 Delhi Bildirgesi düzenlenmiştir (Köse 2018). Dünyada bu gelişmeler olurken, Türkiye için bu süreç 2004 Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi ile başlamıştır. Bu sözleşme gereği "Arazi Kullanımı, Arazi Kullanım Değişiklikleri ve Ormancılık İçin İyi Uygulamalar" isimli kılavuza göre ulusal verilerimiz hazırlanmaktadır. 2009 yılında ise Kyoto Protokolü'ne üye olan Türkiye, 2013 yılının Ocak ayında başlayan Kyoto Protokolü'nün İkinci Yükümlülük Dönemi için herhangi bir sorumluluk üstlenmemiştir (Türkeş 2001, WWF 2018a).

Küresel ısınma nedeniyle Türkiye'yi bekleyen çok sayıda olumsuz etki sayabiliriz. Ülkemizin bir bölümü Akdeniz Havzası gibi iklim değişikliğine en hassas bölgelerden birini kapsamaktadır. Özellikle bu bölgede sıcaklığın 2°C'lik artışı sıcak hava dalgalarının şiddetinde artışa, orman yangınlarının sıklığı ve şiddetinde artışa, kuraklığa, biyolojik çeşitliliğin azalmasına, tarımsal verimliliğin düşmesine ve turizm gelirlerinde azalmaya neden olabilmektedir. Hazırlanan farklı iklim değişikliği raporlarına göre Türkiye 2030 yılından itibaren hızlı bir sıcaklık artışı yaşayacaktır (WWF 2018b). Sıcaklık artışının kış mevsiminde ortalama 4°C, yaz mevsiminde ise 6°C'ye ulaşacağı belirtilmektedir. Daha sıcak, kurak ve hava koşulları açısından kararsız bir iklim yapısı beklenmektedir. Bununla birlikte su kaynaklarında azalma ve ekolojik bozulmalardan büyük oranda etkilenileceği öngörülmektedir. Bu yıkıcı etkilerin giderilmesi, en aza indirgenmesi veya durdurulması için ormansızlaşmanın önlenmesi ve ormanlık alanların artırılması büyük önem arz etmektedir (Demircan vd. 2015, Demircan vd. 2017).

Atmosfere salınan sera gazlarının seviyesi bugün itibariyle optimale ulaşsa dahi doğanın kendini onarıp bütün olumsuz iklim olaylarının normale dönmesi belki on yıllar belki de yüzyıllar sürecektir. Fakat verilen bu mücadelede bu etkilerin tersine dönmediği ve aynı şekilde devam ettiği takdirde de iklim değişikliği ile yapılan savaşı kazanma olasılığı

%90'dan %35'e düşecektir (WWF 2018a). Bu olasılığı artırmadaki en büyük silahlardan biri hiç şüphesiz orman ekosistemleridir. Ormansızlaşma ve arazi kullanım değişikliklerinden kaynaklı sera gazı salımı, küresel iklim değişikliği üzerinde %17'lik bir paya sahiptir (Dağdaş 2003). Ormanlar iklimi iyileştirme açısından oldukça etkin fonksiyonlara sahiptir. Örneğin ormanlık alanlarda yağış oranı, ormansız step örtülü alanlara göre %50 daha fazladır. Ortalama bir ağaç kökleri ile yılda 20 ton suyu topraktan alarak atmosfere verebilmekte ve havadaki nemi artırabilmektedir. Yıllık fotosentez ile üretilen 140,9 milyar ton oksijenin %70'i ormanlar tarafından sağlanmaktadır. Ayrıca ormanlar her bir hektar alan için 3-5 ton karbon depolayabilmektedir. Bu fonksiyonlarının yanında toz tutma, sıcaklık değişimini dengeleme ve havayı temizleme fonksiyonları da bulunmaktadır (Kırış ve Toprak 2008).

Karasal ekosistemlerde ormanlar, üstlendikleri fonksiyonlar ile küresel karbon döngüsünde önemli bir yere sahiptir. Orman ekosistemlerinin bu sürece olan etkisi depoladıkları karbon miktarı ile değerlendirilmektedir. Ormanların bünyesine kattığı net karbon miktarı ise net birincil üretim (NBÜ) ile belirlenmektedir. NBÜ, bitkilerin ürettiği toplam karbon miktarı ile ototrofik solunum yoluyla harcadığı miktarın farkıdır. Küresel ve bölgesel ölçekte yaygın şekilde araştırılan NBÜ, karbon salımı ve iklim değişikliğinin yorumlanması için değerli bir veridir. NBÜ, ekolojik tabanlı modellerde önemli parametreler arasında yer almaktadır (Field et al. 1995, Malhi et al. 2011). Özellikle NBÜ'deki değişim, iklim değişikliğinin etkisini gözlemlemede etkin bir göstergedir. Karasal ekosistemlerde değişkenler arası etkileşimler sıcaklık ve yağış gibi faktörlerden etkilenmektedir. Karmaşık bir sistem olan karasal ekosistemlerde iklim değişikliğinin vejetasyon üzerine etkilerinin değerlendirilmesinde NBÜ oldukça başarılı bir göstergedir (Gower *et al.* 1999, Yu and Chen 2016, Zhang *et al.* 2019).

Ekosistemler ve iklim arasındaki ilişkiyi iyi şekilde yansıtabilen NBÜ, bitki örtüsü gelişimini iklime bağlı olarak açıklamada kullanılmaktadır (Peng *et al.* 2010). Buna bağlı olarak orman üretkenliğinin belirlenmesi ve iklimin bu üretkenlik üzerindeki etkisine cevap aramada kullanılabilmektedir (Erşahin *et al.* 2016). İklim senaryoları (HadGEM2-ES, MPI-ESM-MR, GFDÖ-ESM2M, RCP vb.) ile geleceğe yönelik

tahminler yapılarak NBÜ'nün zamansal ve konumsal projeksiyonları yapılabilmekte, böylece iklim değişikliğinin etkilerinin hangi boyutlara varacağı yorumlanabilmektedir (Dönmez *et al.* 2016, Demircan vd. 2017). En yüksek miktarda karbon tutma kapasitesine sahip meşcere özelliklerinin belirlenmesinde ana değişken olarak kullanılmaktadır. Bununla birlikte NBÜ, orman amenajman planlarında iklim koruma fonksiyonu atanacak ormanlık alanların belirlenmesine yardımcı olabilmektedir (Bulut *et al.* 2019). NBÜ'nün belirlenmesinde doğrudan ve dolaylı metotlar kullanılmaktadır.

Orman ekosistemlerinde NBÜ, yersel ölçümler yapılarak doğrudan belirlenebilmekte ya da istatistiksel modeller veya süreç tabanlı modeller ile tahmin edilebilmektedir (Gülbeyaz 2018). Doğrudan belirleme yöntemi için ağaç kesimi yapılmakta ve ardından kuru ağırlığı tartılmaktadır. Bu şekilde ağaç türleri için katsayılar geliştirilerek NBÜ hesaplanmaktadır. Bu metot kesin bir yöntem olmasına karşın ağaç kesimi yapılmasını gerektirmesi, iş yükünün oldukça fazla oluşu, zamana ve çevresel şartlara göre uyumlu olmamaları gibi dezavantajları bulunmaktadır. İstatistiksel tahminler, bağımlı değişken ile açıklayıcı bağımsız değişkenler arasında oluşturulan regresyon modelleridir. Veriye dayalı bir yöntem olması nedeniyle zaman ve konum değişkenliğini yansıtmazlar. Bu durum modelin farklı koşullara olan uyumunu kısıtlamaktadır. Süreç tabanlı modeller ise bağımlı değişken ile sonuçlanan tüm sürecin modellenmesidir. Bu model yapısı için bir bağımlı durum değişkeni ve doğrudan-dolaylı olarak etkileyen bağımsız değişkenler gerekir. Örneğin, birincil üretimin gerçekleşmesinde güneş ışığı süreci doğrudan etkilemektedir. Sıcaklık ise bir stres faktörüdür. Doğrudan olmasa da dolaylı olarak süreci iyileştirebilir, yavaşlatabilir veya durdurabilir. Bu model yapısında bütün etkileyici faktörler yer alır, süreç modellenir ve bağımlı değişken tahmin edilir (Ollinger *et al.* 2007).

Gerek küresel gerekse bölgesel ölçekli NBÜ tahmini için kullanılan çok sayıda süreç tabanlı model tipi vardır. Bu modelleri uzaktan algılama tabanlı, mevsimsel biyojeokimyasal akış tabanlı ve mevsimsel biyojeokimyasal akış-bitki örtüsü yapısı tabanlı olmak üzere 3 gruba ayırabiliriz. Uydu verisi tabanlı modeller Carnegie Ames Stanford Approach (CASA) (Potter *et al.* 1993), GLO-PEM (Prince 1991), SDBM (Knorr and Heimann 1995), TURC (Ruimy *et al.* 1996) ve SIB 2 (Sellers *et al.* 1996)

modelleridir. Mevsimsel biyojeokimyasal akış tabanlı modeller HRBM 3.0 (Esser *et al.* 1994), CENTURY 4.0 (Parton *et al.* 1993), TEM 4.0 (McGuire *et al.* 1995), SILVAN 2.2 (Kaduk and Heimann 1996), CARAIB 2.1 (Warnant *et al.* 1994), FBM 2.2 (Kindermann *et al.* 1993), PLAI 0.2 (Plöchl and Cramer 1995), BIOME-BGC (Running and Hunt 1993) ve KGBM (Kergoat 1998) modelleridir. Mevsimsel biyojeokimyasal akış-bitki örtüsü yapısı tabanlı modeller ise BIOME3 (Haxeltine and Prentice 1996), DOLY (Woodward *et al.* 1995) ve HYBRID3.0 (Friend and Cox 1995) modelleridir (Cramer *et al.* 1999, Schloss *et al.* 1999, Ruimy *et al.* 1999).

Bu çalışmada NBÜ tahmini için süreç tabanlı bir model olan CASA modeli kullanılmıştır. Bu modelin dört ana hesaplama değişkeni bulunmaktadır. Bunlar absorbe edilen fotosentetik aktif radyasyon, ışık kullanım etkinliği, su ve sıcaklıktır (Potter *et al.* 1993). CASA modeli uzaktan algılama tabanlı olup esnek bir modeldir. Uzaktan algılama ve coğrafi bilgi sistemleri teknolojilerinin kullanımına olanak sağlaması ile özellikle büyük ölçekli alanlara ilişkin veri tabanları oluşturulabilir ve lokal alanlara ilişkin veriler kullanılarak kalibrasyon işlemleri gerçekleştirilebilir. Bununla birlikte kullanılan açıklayıcı değişkenler farklı bölgeler ve farklı zaman periyotları için güncellenerek çeşitli varyasyonlarda hesaplama yapılabilmektedir. Aylık, mevsimlik ve yıllık periyotlarda küresel, ulusal ve lokal ölçekli alanlar için NBÜ hesaplanmasına olanak sağlamaktadır (Gülbeyaz 2018).

NBÜ modellerinde sıklıkla kullanılan diğer parametrelerden biri de yaprak alan indeksi (YAİ)'dir. YAİ birim alana düşen ve aktif olarak fotosentez yapmakta olan yaprak alanı miktarıdır. Yapraklar fotosentezin gerçekleştiği dolayısı ile karbondioksit ve suyun güneş ışınları ile karbonhidrat ve oksijene dönüştüğü bitki organlarıdır. Büyüme ve verimlilik ile ilgili önemli bir gösterge olan YAİ, meşcere kapalılığının da etkin bir göstergesidir. Fırtına, kar ve rüzgâr kaynaklı devrilmeler, kuraklık gibi doğal afetler ve planlama uygulamaları sonucu YAİ'deki herhangi bir değişiklik verimlilik ve üretkenliği doğrudan etkilemektedir. Bir meşcerenin yüksek YAİ değerine sahip olması yetişme ortamın verimliliğinin iyi olduğunu göstermektedir (Vose and Allen 1988). Dolayısıyla meşcere parametrelerinin modellenmesinde yaygın olarak kullanılmakta ve özellikle artım, büyüme ve hacim gibi meşcere özellikleri ile yüksek oranda ilişkiler

göstermektedir. Ayrıca fotosentez, intersepsiyon, evapotranspirasyon, karbon, besin ve enerji dengesini etkileyen bir değişkendir. Uzun dönem izlenmesi ile orman ekosistem verimliliği ve iklim dinamiklerindeki değişim daha iyi bir şekilde yorumlanabilmektedir (Kara vd. 2011, Chianucci *et al.* 2015, Günlü *et al.* 2017).

YAİ'nin belirlenmesinde doğrudan ve dolaylı olmak üzere iki yöntem kullanılmaktadır. Doğrudan yöntem döküm toplama ve yaprak kapanları ile birim alandaki yaprak miktarının belirlenmesi şeklinde uygulanmaktadır. Bu metot fazla emek isteyen ve zaman alıcı bir yöntemdir. Dolaylı yöntem ise optik algılayıcılar (yarı-küresel fotoğraf) ve geliştirilen modeller kullanılarak YAİ'nin tahmin edilmesi şeklindedir. Bu metot ise büyük alanlar için uygulanması kolay, zaman ve maliyet açısından da bir o kadar avantajlıdır (Chen *et al.* 1997, Jonckheere *et al.* 2004).

Orman sağlığı ve orman ekosistem üretkenliğinin en önemli göstergelerinden biri de dökümdür (Pitman et al. 2010, Çakır and Akburak 2017). Döküm elemanları yaprak, dal, kabuk, kozalak, erkek çiçek ve diğer bölümlerden (meyve, çiçek, yosun, liken vb.) oluşmaktadır. Toplam döküm içerisindeki en büyük pay yaprak dökümüne aittir. Buradan hareketle YAİ ile doğrudan ilişkili olan döküm, orman ekosistemlerindeki en önemli besin ve karbon kaynağı olup NBÜ'nün en önemli bileşenlerindendir (Zhang *et al.* 2007, Shang *et al.* 2018). Karasal ekosistemlerdeki en önemli karbon havuzlarından olan orman toprağına büyük oranda karbon akışı sağlamakta ve orman ekosistemlerindeki yıllık karbon alımının yaklaşık üçte biri döküm yolu ile toprağa ulaşmaktadır. Bu bilgiler ışığında döküm, orman ekosistemlerindeki toprak verimliliği, karbon içeriği ve besin döngüsünün belirlenmesi ve modellenmesi için en önemli gösterge parametrelerdendir (Çömez *et al.* 2018, Erkan *et al.* 2018).

Döküm, orman topraklarının karbon içeriğinin ve zamana göre değişiminin modellenmesinde tahmin edici değişken olarak kullanılmaktadır (Palosuo *et al.* 2012, Ťupek *et al.* 2015). Bu çalışmalara ek olarak NBÜ'nün modellenmesinde ve NBÜ modellerinin doğrulanmasında da kullanılmaktadır (Evrendilek 2006, Taşkınsu Meydan 2008). İklim değişikliği ve çevresel faktörler döküm miktarını ve bu miktarın

mevsimlere göre dağılımını büyük oranda etkilemektedir. Bunlara ek olarak kapalılık, servet, artım, göğüs yüzeyi, yaş ve yetişme ortamı verim gücü gibi meşcere özellikleri dökümün karakterize edilmesi için oldukça önemlidir (Erkan *et al.* 2018). Döküm miktarının kontrol edilmesindeki en güçlü araçlardan biri ise meşcereye uygulanacak silvikültürel müdahalelerdir (Çömez *et al.* 2018).

NBÜ fotosentez aracılığı ile üretilen net organik madde birikimidir. YAİ ve döküm gibi parametreler de NBÜ'nün bileşenlerinden olup NBÜ ve meşcere parametreleri ile belirli oranlarda ilişkilidir. Ülkemizde hazırlanan orman amenajman planları için gerekli olan meşcere parametrelerinin gerek NBÜ ile gerekse YAİ ve döküm ile olan ilişkilerini ortaya koymak ilgili planlama ünitesindeki doğa kanuniyetlerinin daha iyi kavranmasını sağlayabilmektedir. Bu ilişkilerin hassas bir şekilde ortaya koyulması uygulanacak silvikültürel müdahalelere, orman sağlığının kontrolüne ve orman fonksiyonlarının daha tutarlı bir şekilde belirlenebilmesine yardımcı olabilmektedir. NBÜ, YAİ, döküm ve meşcere parametreleri arasındaki ilişkilerin belirlenmesi, hangi meşcere tipinde daha çok döküm olduğu ve hangi müdahale ile dökümün kontrol edileceği, hangi meşcerelerin net üretiminde azalma olduğu, hangi özelliklerdeki meşcerelerde en yüksek miktarda net karbon üretiminin olduğu ve hangi meşcerelere özellikle koruma ağırlıklı fonksiyonlar atanabileceği açısından önemlidir. Bu parametreler arasındaki ilişkiler kadar nasıl belirlendikleri de önemli bir husustur. Ormancılıkta çalışma alanları çok geniş olup özellikle meşcere parametrelerinin envanteri de oldukça güç ve zaman alıcıdır (Günlü *et al.* 2014a, Özbayram vd. 2015, Günlü *et al.* 2017, Ercanlı *et al.* 2018, Bulut *et al.* 2019).

Bu çalışmada tahmin edilen NBÜ verilerinin geçerliliği meşcerelerden elde edilen döküm miktarları ile yapılmıştır. NBÜ, YAİ ve meşcere parametreleri, uzaktan algılama verileri ile farklı modelleme teknikleri kullanılarak tahmin edilmiştir. Küresel iklim değişikliği, karbon salımı, orman ekosistemi ve verimliliği için son derece tanımlayıcı ve önemli olan bu parametrelerin kısa zamanda, az maliyetle ve az iş gücü ile tahmin edilme olanakları araştırılmıştır. Bu çalışmanın başlıca amaçları Ankara Orman Bölge Müdürlüğü sınırları içerisinde yayılış gösteren saf karaçam meşcerelerinde,

(i) NBÜ'yü Sentinel-2 uydu görüntüsü ve meteoroloji verileri kullanarak CASA modeli ile tahmin etmek,

(ii) Meşcerelerden elde edilen döküm miktarları ile tahmin edilen NBÜ'nün geçerliliğini doğrulamak,

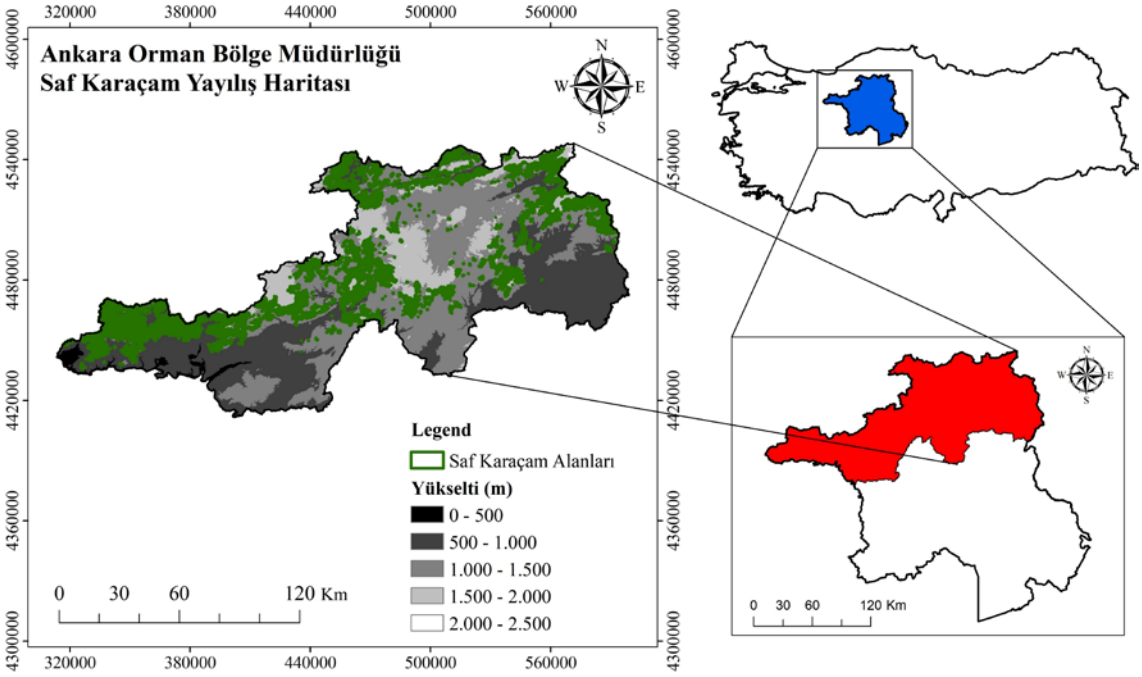
(iii) YAİ değerlerini yarı-küresel fotoğraflar aracılığı ile belirlemek,

(iv) Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans, vejetasyon indis ve tekstür değerlerini kullanarak NBÜ, YAİ ve meşcere parametrelerini çoklu regresyon analizi, destek vektör makineleri ve derin öğrenme metotları ile modellemektir.

2. MATERYAL

2.1 Çalışma Alanı Tanıtımı

Bu çalışma Ankara Orman Bölge Müdürlüğü (OBM) sınırları içerisinde yayılış gösteren saf karaçam meşcerelerinde gerçekleştirilmiştir (Şekil 2.1). Ankara OBM 11 adet Orman İşletme Müdürlüğü ve 44 adet Orman İşletme Şefliğinden oluşmaktadır. Çalışma alanı konum itibariyle 313096-598185 doğu boylamları ile 4414251-4544558 kuzey enlemleri arasındadır (WGS 1984). Ankara OBM'nin toplam alanı 4563247,07 ha olup saf karaçam meşcerelerinin toplam alanı 136985,96 ha'dır.

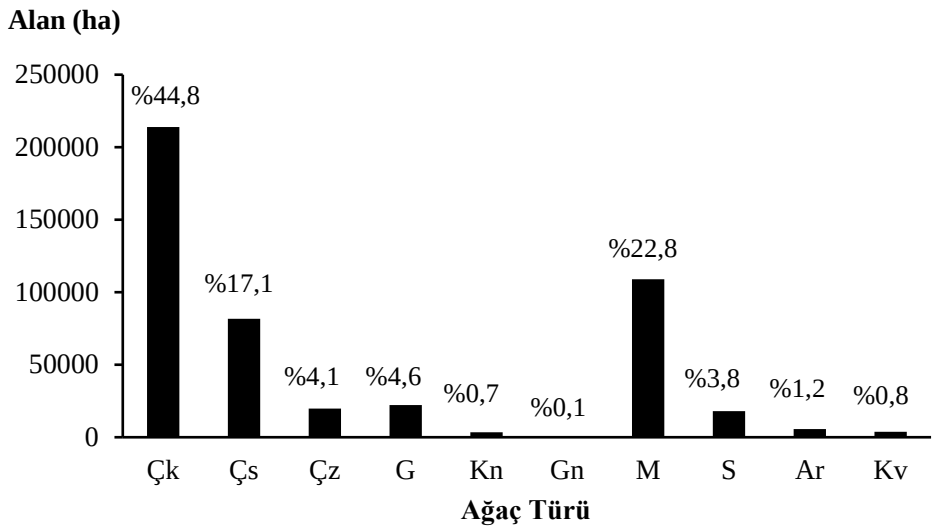


Şekil 2.1 Çalışma alanının konumu

Çalışma alanının yükseltisi 239 m ile 2541 m arasında değişmektedir. Ortalama yükselti 1071 m, ortalama eğim ise %17'dir. Yıllık ortalama sıcaklık 11,6 °C, yıllık ortalama en yüksek ve en düşük sıcaklık değerleri sırasıyla 17,9 ve 5,5 °C'dir. Yıllık toplam yağış miktarı ortalaması 399,75 mm'dir. Bununla birlikte son 90 yıllık süreçte aylık en yüksek sıcaklık değeri Temmuz ayında görülmüş olup 41,7 °C'dir. En düşük sıcaklık

değeri ise Ocak ve Aralık aylarında -25 °C olarak görülmüştür. Günlük toplam en yüksek yağış miktarı da 11.06.1997 tarihinde 88,9 mm olarak ölçülmüştür.

Ankara OBM'de yayılış gösteren ağaç türleri arasında büyük çoğunluğu *Pinus nigra* (Çk) oluşturmaktadır (Şekil 2.2). Ayrıca *Pinus sylvestris* (Çs), *Pinus brutia* (Çz), *Abies nordmanniana* (G), *Fagus orientalis* (Kn), *Carpinus betulus* (Gn), *Quercus (Quercus cerris, Quercus infectoria, Quercus frainetto, Quercus robur, Quercus petraea)* (M), *Cedrus libani* (S), *Juniperus sp.* (Ar) ve *Populus tremula* (Kv) yayılış gösteren diğer türlerdir. Karaçamın saf ve baskın olduğu meşcereler toplam ormanlık alanların %44,8'ini kapsamaktadır. Karaçamdan sonra en çok yayılış alanına sahip ağaç türü %22,8'lik oran ile meşedir. Sarıçam ise alanın %17,1'ini teşkil etmektedir. Diğer türlerin yayılış oranları ise %0,1 – 4,6 arasında değişmektedir (Anonim 2019).



Şekil 2.2 Ankara Orman Bölge Müdürlüğü içerisinde bulunan ağaç türlerinin oransal alan dağılımı

Çalışma alanında karaçam hakimiyetinde bulunan meşcereler toplamda 213868,56 ha olup, saf karaçam meşcereleri 136985,96 ha alan kaplamaktadır. Alanda saf karaçama ait 1, 2 ve 3 kapalılığında Çka, Çkab, Çkb, Çkbc, Çkc, Çkcd, Çkd ve Çke meşcereleri bulunmaktadır. Amenajman planlarındaki meşcere haritalarına göre bonitet, yaş ve kapalılık sınıflarına göre detaylı alan dağılımı Çizelge 2.1'de verilmiştir.

Çizelge 2.1 Çalışma alanı saf karaçam meşcerelerine ilişkin detaylı alan dökümü

BS	YS	K	Alan (ha)	BS	YS	K	Alan (ha)	BS	YS	K	Alan (ha)	BS	YS	K	Alan (ha)
I	1	1	1,39	III	1	1	932,64	IV	1	1	3310,99	V	1	1	8506,49
		3	2,12			2	3,90			2	76,96			3	195,09
	2	2	9,89			3	28,89			3	121,80		2	1	821,46
		3	4,31		2	1	55,89		2	1	182,15			2	1657,43
	3	3	29,36			2	730,66			2	2043,73			3	1687,44
	4	2	3,17			3	531,37			3	2344,49		3	1	4739,67
		3	10,89		3	1	200,07		3	1	1186,47			2	3670,09
	5	2	7,22			2	390,10			2	2116,40			3	3300,56
	6	3	3,76			3	1532,15			3	3866,67		4	1	3429,10
Toplam			**72,11**		4	1	404,60		4	1	1636,46			2	4743,01
II	1	1	337,73			2	908,47			2	3046,75			3	5020,99
		3	20,26			3	1361,56			3	6202,90		5	1	8663,65
	2	2	34,11		5	1	593,90		5	1	3362,96			2	9043,56
		3	24,00			2	1652,64			2	6270,33			3	4276,43
	3	1	32,55			3	2435,32			3	5512,32		6	1	4549,45
		2	8,18		6	1	704,17		6	1	1766,36			2	5303,28
		3	20,12			2	1550,64			2	4115,72			3	1378,67
	4	1	9,36			3	1158,22			3	1932,08	**Toplam**			**70986,37**
		2	46,47	**Toplam**			**15175,19**	**Toplam**			**49095,54**	**Genel Toplam**			**136985,96**
		3	101,58												
	5	1	71,21												
		2	157,34												
		3	239,39												
	6	1	103,11												
		2	258,19												
		3	193,15												
Toplam			**1656,75**												

"BS" Bonitet Sınıfı; "**YS"** Yaş Sınıfı; "**K"** Kapalılık

2.2 Yersel Veriler

2.2.1 Örnek alan seçimi

Bu çalışmada 5 farklı bonitet sınıfı, 6 farklı yaş sınıfı ve 3 farklı kapalılık sınıfından 2 tekerrürlü ölçüm yapılmak üzere (5 x 6 x 3 x 2) 180 örnek alanda orman envanter çalışması yapılmıştır (Çizelge 2.2). Örnek alanlar saf karaçam meşcereleri içerisinde ilgili bonitet, yaş sınıfı ve kapalılık sınıflarını temsil edecek şekilde bilinçli ve rastgele olarak seçilmiştir.

Çizelge 2.2 Örnek alan seçim kriterleri ve ölçütleri

Yaş Sınıfı	Yaş (yıl)	Bonitet	Bonitet endeksi (m)	Kapalılık	Yüzey örtüş oranı (%)
I	1-20	I	30-34	1	11-40
II	21-40	II	25-29	2	41-70
III	41-60	III	20-24	3	71-100
IV	61-80	IV	15-19		
V	81-100	V	10-14		
VI	101-120				

2.2.2 Döküm envanteri

Envanterde kullanılacak döküm kapanları için belirlenen meşcere özellikleri yaş sınıfı (genç: 0-40, orta:41-80 ve yaşlı: 80<), bonitet (iyi: I ve II, orta: III ve kötü: IV ve V) ve kapalılık (düşük: 0.10-0.40, orta: 0.41-0.70 ve tam: 0.71-100) olacak şekilde belirlenmiştir. Döküm envanteri için alınan örnek alan sayısı 3 yaş sınıfı, 3 bonitet sınıfı ve 3 kapalılık sınıfı için (3x3x3=27) 27 olarak hesaplanmıştır. Fakat veri sayısını artırarak daha tutarlı istatistiksel sonuçlar elde etmek amacı ile örnek alan sayısı 30'a tamamlanmıştır. Her bir örnek alanda 3 adet olmak üzere toplamda 90 adet döküm kapanı kullanılmıştır. Her bir kapan 0,5 m derinliğe, 38,5 cm çapa ve 0,47 m^2 üst açıklığa sahiptir.

2.3 Uzaktan Algılama Verileri

Bu çalışmada, iki amaca yönelik uydu görüntüsü kullanılmıştır. Birinci amaç CASA modeli kullanılarak 2019 yılının her bir ayı için NBÜ verilerinin hesaplanmasıdır. Bu amaca yönelik 2019 yılının her bir ayına ait Sentinel-2 uydu görüntüsü kullanılmıştır (USGS 2000). İkinci amaç ise NBÜ, YAİ ve meşcere parametrelerinin uzaktan algılama verileri ile modellenmesidir. Bunun için Landsat 8 Operational Land Imager (OLI) ve Sentinel-2 uydu görüntüleri kullanılmştır (USGS 2000).

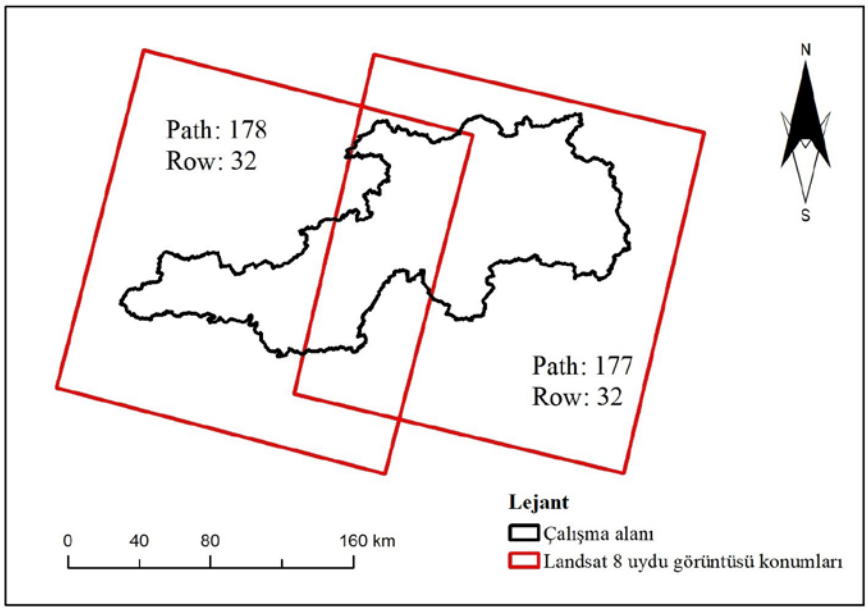
2.3.1 Landsat 8 OLI uydu görüntüsü

Landsat 8 OLI uydusu 2013 yılından beri veri sağlamaktadır. Pankromatik, multispektral ve termal olmak üzere 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. Elde edilen uydu görüntülerinin şerit genişliği 185 km olup zamansal çözünürlüğü 16 gündür. Landsat 8 OLI uydusuna ait kullanılan bantlara ilişkin detaylı bilgiler Çizelge 2.3'te verilmiştir.

Çizelge 2.3 Landsat 8 OLI uydu görüntüsüne ait teknik özellikler

Bant	Elektromanyetik alan	Dalga boyu (nm)	Konumsal çöz. (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 alanını kapsaması için her bir aya ait 2 adet Landsat 8 OLI uydu görüntüsü kullanılmıştır. Bu görüntülerin konumları Şekil 2.3'de gösterilmiştir (Path: 178 – Row: 32 ve Path: 177 – Row: 32).



Şekil 2.3 Landsat 8 OLI uydu görüntülerinin konumları

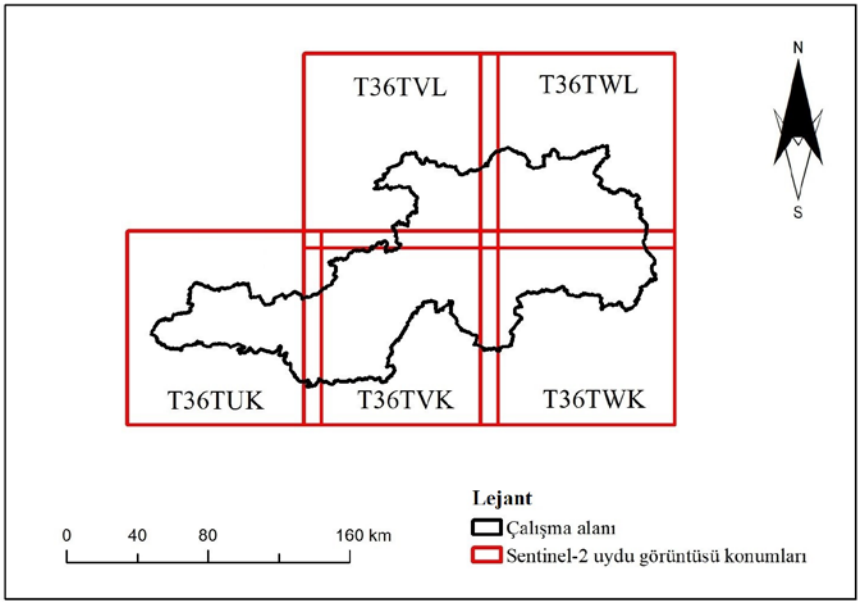
2.3.2 Sentinel-2 uydu görüntüsü

Sentinel-2 uydu görüntüsü toplamda 13 adet banda 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. Sentinel-2 uydusuna ait kullanılan bantlara ilişkin detaylı bilgiler Çizelge 2.4'te verilmiştir.

Çizelge 2.4 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 görüntüsünün her bir paftası Landsat 8 OLI uydu görüntüsüne göre daha az alan kaplamaktadır. Dolayısı ile alanı kapsaması için Landsat 8 OLI için 2 adet uydu görüntüsü gerekirken Sentinel-2 uydu görüntüsü için 5 adet gerekli olmaktadır. Böylece her ay için 5 adet olmak üzere toplamda 60 adet Sentinel-2 uydu görüntüsü verisi kullanılmıştır. Sentinel-2 uydu görüntülerinin konumları Şekil 2.4'de gösterilmiştir.

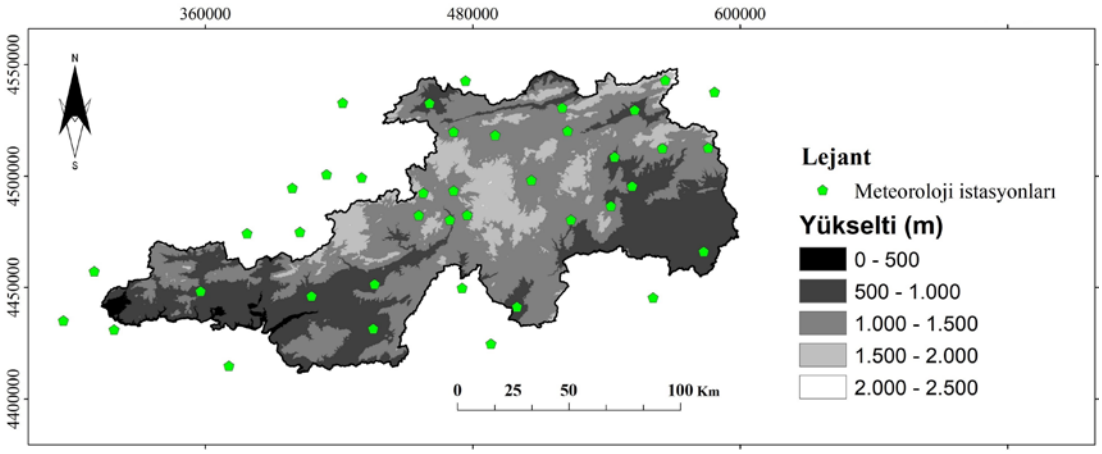


Şekil 2.4 Sentinel-2 uydu görüntülerinin konumları

2.4 Meteoroloji Verileri

2010-2019 yıllarını kapsayan 10 yıllık ve 40 farklı meteoroloji istasyonundan ortalama-minimum-maksimum sıcaklık, yağış ve güneş radyasyonu verileri elde edilmiştir (Şekil 2.5). Bu veriler ilgili meteoroloji istasyonuna ait aylık ortalama değerler olarak edinilmiştir. Meteoroloji istasyonlarından nokta bazlı alınan veriler çalışma alanını kapsayacak şekilde enterpole edilmiştir. Enterpolasyon işlemi için "Radial Basis Function" metodu kullanılmıştır. Elde edilen yüzey haritaları 2019 yılının her bir ayı için 10 m konumsal çözünürlüklü üretilmiştir. Meteoroloji verilerine ait yüzey haritaları CASA modelinin uygulanması ve özellikle aylık ölçekli hesaplanan NBÜ verilerinin

yorumlanması için kullanılmıştır. Meteorolji verilerine ilişkin bütün yüzey haritaları ArcGIS Desktop 10.6.1 programı kullanılarak elde edilmiştir.



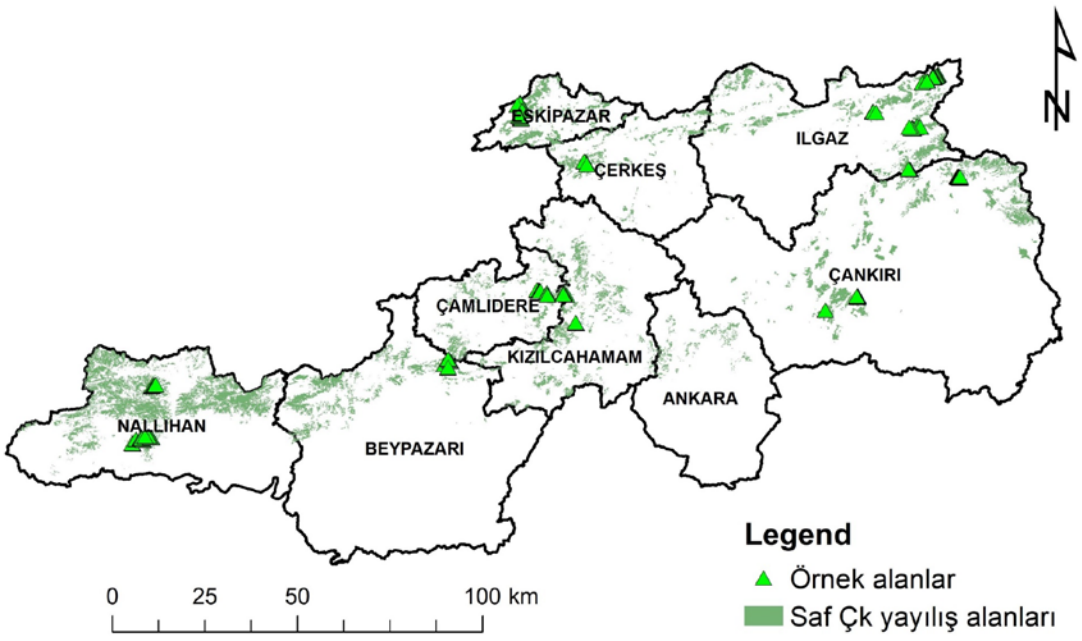
Şekil 2.5 Meteoroloji istasyonlarının konumsal dağılımı

3. YÖNTEM

Bu çalışmanın gerçekleştirilmesinde yersel ve uzaktan algılama veri setleri kullanılmıştır. Yersel veriler meşcere parametreleri, yaprak alan indeksi (YAİ) ve döküm miktarlarından oluşmaktadır. Uzaktan algılama verileri ise Landsat 8 Operational Land Imager (OLI) ve Sentinel-2 uydu görüntülerinden elde edilen reflektans, vejetasyon indisi ve tekstür verileridir. Bunun yanında net birincil üretim (NBÜ) hesaplaması için gerekli meteoroloji verileri hazırlanmıştır.

3.1 Arazi Çalışması

Yapılan arazi çalışması Ankara Orman Bölge Müdürlüğünde (OBM) saf karaçam meşcerelerinin yayılış gösterdiği Orman İşletme Müdürlüklerinde (OİM) gerçekleştirilmiştir. Örnek alan sayılarının OİM'lere dağılımı, ilgili OİM'de yayılış gösteren saf karaçam meşcerelerinin alanlarına oranlanarak düzenlenmiştir. Buna göre Ilgaz OİM'den 56, Çerkeş OİM'den 7, Çankırı OİM'den 24, Kızılcahamam OİM'den 12, Eskipazar OİM'den 21, Beypazarı OİM'den 8, Çamlıdere OİM'den 18 ve Nallıhan OİM'den 34 olmak üzere toplam 180 adet örnek alan alınmıştır (Şekil 3.1).



Şekil 3.1 Envanter çalışmasında alınan örnek alanların 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 180 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 ölçülmüş ve ortalaması alınmıştır. Orta yaşı belirlemek üzere orta çapa yakın 4-5 ağaçta yaş ölçümü, boniteti belirlemek için hektarda 100 ağaç yöntemine göre galip ve ortak galip ağaçlarda boy ölçümü yapılmıştır. Yapılan envanter çalışması sonucunda her bir örnek alana ilişkin meşcere orta çapı (dg), üst boyu ($h_{üst}$), ağaç sayısı (N), meşcere göğüs yüzeyi (G) ve meşcere hacmi (V) değerleri hesaplanmıştır (Çizelge 3.1). Meşcere hacminin hesaplanmasında Ankara OBM'de yayılış gösteren saf ve doğal karaçam meşcereleri için geliştirilen çap ve boya bağlı çift girişli hacim denklemi kullanılmıştır (Ercanlı ve Bolat 2020).

$$v = 0{,}000097\ x\ d^{1{,}740878}\ x\ h^{1{,}005521} \qquad (1)$$

Çizelge 3.1 Meşcere parametreleri ve hesaplanması

Meşcere parametresi	**Formül**	**Açıklama**
dg (cm)	$\bar{\mathrm{d}}_{\mathrm{g}} = \sqrt{\frac{\bar{d}_1^2 + \bar{d}_2^2 + \cdots + \bar{d}_n^2}{\mathrm{n}}}$	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)	$\mathrm{N} = \frac{10000}{\ddot{O}AB} \times n$	N= meşcere ağaç sayısı (ha) ÖAB= örnek alan büyüklüğü n= örnek alanın ağaç sayısı
G (m^2/ha)	$\mathrm{G} = \frac{10000}{\ddot{O}AB} \times g$	G= meşcere göğüs yüzeyi (ha) ÖAB= örnek alan büyüklüğü g= örnek alanın göğüs yüzeyi
V (m^3/ha)	$\mathrm{V} = \frac{10000}{\ddot{O}AB} \times \sum_{i=1}^{n} v_i$	V= meşcere hacmi (ha) ÖAB= örnek alan büyüklüğü v= tek ağacın hacmi

3.2 Uzaktan Algılama Verilerinin Elde Edilmesi

3.2.1 Reflektans değerleri

Örnek alanlara ilişkin reflektans verilerinin elde edilmesi iki aşamada gerçekleştirilmiştir. Birinci aşama uydu görüntülerinin (Landsat 8 OLI ve Sentinel-2) 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 edilmesidir. Bunun için ArcGIS Desktop 10.6.1 programı kullanılarak her bir bant "vektör" katmanına dönüştürülmüş ve üzerine her bir örnek alan için örnek alan büyüklüklerine göre (1 kapalı 800 m^2, 2 kapalı 600 m^2, 3 kapalı 400 m^2) "buffer zon" atılmıştır. Ardından üretilen "vektör" katmanı "buffer zon" ile "intersect" komutu kullanılarak çakıştırılmış ve örnek alan sınırına uygun "vektör" veri elde edilmiştir. "raster"-"vektör" dönüşümü yapılmasının nedeni, pikseller örnek alan sınırına göre dönüşüm yapılmadan kesildiğinde konumsal çözünürlüğüne göre sınırlarda boşluklar veya fazlalıklar kalmaktadır. 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.

3.2.2 Vejetasyon indis değerleri

Vejetasyon indislerinin hesaplanması için Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden her bir örnek alan için elde edilen reflektans değerleri kullanılmıştır. Landsat 8 OLI uydu görüntüsünün bantları kullanılarak 26 adet, Sentinel-2 uydu görüntüsünün bantları kullanılarak 36 adet olmak üzere toplamda 62 adet vejetasyon indisi hesaplanmıştır. Çalışmada kullanılan bütün vejetasyon indisleri ve formülleri Çizelge 3.2 ve Çizelge 3.3'de verilmiştir.

Çizelge 3.2 Landsat 8 OLI uydu görüntüsü için hesaplanan vejetasyon indisleri

Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
MID (Middle Infrared Wavelengths)	(B6 + B7)	Kaufman and Remer (1994)	GNDVI (Green Normalized Difference Vegetation Index)	(B05 - B03) / (B05 + B03)	Gitelson *et al.* (1996)
NDVI (Normalized Difference Vegetation Index)	(B5-B4) / (B5+B4)	Rouse *et al.* (1974)	NDWI (Normalized Difference Water Index)	(B5 - B6) / (B5 + B6)	McFeeters (1996)
MSI (Moisture Stress Index)	(B6 / B5)	Hunt and Rock (1989)	MSR (Modified Simple Ratio)	((B5 / B4) -1) / √ ((B5 / B4) +1)	Chen (1996)
NDMI (Normalized Difference Moisture Index)	(B5-B6) / (B5+B6)	Hardisky *et al.* (1983)	NLI (Non-Linear index)	(($B05^2$) - B04) / (($B05^2$) + B04)	Goel and Qin (1994)
NBR (Normalized Burn Ratio)	(B5-B7) / (B5+B7)	Key and Benson (2006)	PSSR (Pigment Specific Simple Ratio)	(B5 / B4)	Blackburn (1998)
EVI (Enhanced Vegetation Index)	2.5 x ((B5 – B4) / (B5 + 6 x B4 – 7.5 x B2 + 1))	Liu and Huete (1995)	IPVI (Infrared Percentage Vegetation Index)	(B5 / (B5 + B4))	Crippen (1990)
SAVI (Soil Adjusted Vegetation Index)	((B5 – B4) / (B5 + B4 + 0.5)) x (1.5)	Huete (1988)	RVI (Ratio Vegetation Index)	(B5 / B4)	Jordan (1969)
MSAVI (Modified Soil Adjusted Vegetation Index)	(2 x B5 + 1 – sqrt ((2 x B5 + 1)^2 – 8 x (B5 – B4))) / 2	Qi *et al.* (1994)	EVI2 (Enhanced Vegetation Index 2)	2.4 x (B05 - B04) / (B05 + B04 + 1.0)	Jiang *et al.* (2008)
ARVI (Atmospherically Resistant Vegetation Index)	(B5 -2(B4) + (B3) / (B5) + 2(B4) - (B3)	Kaufman and Tanre (1992)	DVI (Difference Vegetation Index)	(B5 - B4)	Tucker (1980)
ND32	(B4 - B3) / (B4 + B3)	Lu *et al.* (2004)	MID57	(B6 + B7)	Lu *et al.* (2004)
ND53	(B6 - B4) / (B6+B4)	Lu *et al.* (2004)	VIS123	(B2 + B3 + B4)	Lu *et al.* (2004)
ND73	(B7 - B4) / (B7 + B4)	Lu *et al.* (2004)	Albedo	(B2 + B3 + B4 + B5 + B6 + B7)	Lu *et al.* (2004)

Çizelge 3.3 Sentinel-2 uydu görüntüsü için hesaplanan vejetasyon indisleri

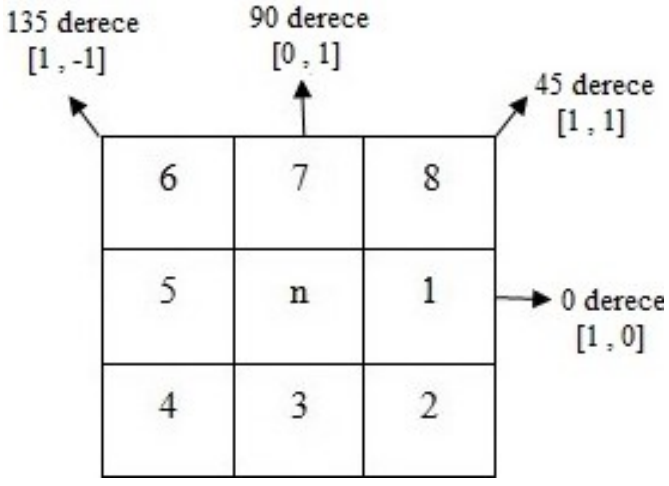
Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
SAVI (Soil Adjusted Vegetation Index)	(B08 - B04) / (B08 + B04 + L) x (1.0 + L); L = 0.428	Huete (1988)	EVI2 (Enhanced Vegetation Index 2)	2.4 x (B08 - B04) / (B08 + B04 + 1.0)	Jiang *et al.* (2008)
PSSR (Pigment Specific Simple Ratio)	(B08 / B04)	Blackburn (1998)	CHL-RED-EDGE (Chlorophyll Red-Edge)	(B07 / B05) -1	Gitelson *et al.* (2005)
NDWI (Normalized Difference Water Index)	(B08-B11) / (B08+B11)	McFeeters (1996)	ARI1 (Anthocyanin Reflectance Index)	(1.0 / B03 - 1.0 / B05)	Gitelson *et al.* (2001)
NDVI (Normalized Difference Vegetation Index)	(B08 - B04) / (B08 + B04)	Rouse *et al.* (1974)	BNDVI (Blue-normalized difference vegetation index)	(B08 - B02) / (B08 + B02)	Wang *et al.* (2007)
NBR (Normalized Burn Ratio)	(B08 - B12) / (B08 + B12)	Key and Benson (2006)	MNDVI (Modified Normalized Difference Vegetation Index)	(B08 - B12) / (B08 + B12)	Jurgens (1997)
MSI (Moisture Stress Index)	(B11 / B08)	Hunt and Rock (1989)	GBNDVI (Green-Blue NDVI)	(B08 - (B03 + B02)) / (B08 + (B03 + B02))	Wang *et al.* (2007)
MCARI (Modified Chlorophyll Absorption in Reflectance Index)	((B05 - B04) - 0.2 x (B05 - B03)) x (B05 / B04)	Haboudane *et al.* (2004)	GRNDVI (Green-Red NDVI)	(B08 - (B03 + B04)) / (B08 + (B03 + B04))	Gitelson and Merzlyak (1996)
GNDVI (Green Normalized Difference Vegetation Index)	(B08 - B03) / (B08 + B03)	Gitelson *et al.* (1996)	MCARI (Modified Chlorophyll Absorption in Reflectance Index)	((B05-B04)-0,2x(B06-B03))x(B05/B04)	Daughtry *et al.* (2000)
EVI (Enhanced Vegetation Index)	2.5 x (B08 - B04) / ((B08 + 6.0 x B04 - 7.5 x B02) + 1.0)	Liu and Huete (1995)	DVI (Difference Vegetation Index)	(B08 / B04)	Tucker (1980)

Çizelge 3.3 devamı

Vejetasyon indisi	Formül	Kaynak	Vejetasyon indisi	Formül	Kaynak
MSR (Modified Simple Ratio)	(B08 - B01) / (B04 - B01)	Chen (1996)	WDRVI (Wide Dynamic Range Vegetation Index)	(0.1 x B08 - B04) / (0.1 x B08 + B04)	Wang *et al.* (2007)
WDVI (Weighted Difference Vegetation Index)	(B08 - a x B04); a = 0.460	Clevers (1989)	GVMI (Global Vegetation Moisture Index)	((B08 + 0.1) - (B12 + 0.02)) / ((B08 + 0.1) + (B12 + 0.02))	Ceccato *et al.* (2002)
NLI (Nonlinear vegetation index)	(($B08^2$) - B04)) / (($B08^2$) + B04))	Goel and Qin (1994)	GARI (Green atmospherically resistant vegetation index)	(B08 - (B03 - (B02 - B04))) / (B08 - (B03 + (B02 - B04)))	Gitelson *et al.* (1996)
CCCI (Canopy Chlorophyll Content Index)	((B08 - B05) / (B08 + B05)) / ((B08 - B04) / (B08 + B04))	Fitzgerald *et al. (*2010)	GLI (Green leaf index)	(2.0 x B03 - B04 - B02) / (2.0 x B03 + B04 + B02)	Louhaichi *et al.* (2001)
ChlGreen (Chlorophyll Green)	(B07 / B03) -1	Gitelson *et al.* (2003)	GOSAVI (Green Optimized Soil Adjusted Vegetation Index)	(B08 - B03) / (B08 + B03 + Y); Y=0,723	Rondeaux *et al. (*1996)
Clrededge (Chlorophyll IndexRedEdge)	(B08 / B05) - 1.0	Gitelson *et al.* (2003)	GSAVI (Green Soil Adjusted Vegetation Index)	(B08 - B03) / (B08 + B03 + L) x (1.0 + L); Y=0,752	Sripada (2005)
CVI (Chlorophyll vegetation index)	B08 x (B04 / $B03^2$)	Vincini *et al. (*2007)	LCI (Leaf Chlorophyll Index)	(B08 - B05) / (B08 + B04)	Thenkabail *et al.* (1999)
CTVI (Corrected Transformed Vegetation Index)	(NDVI + 0,5) / abs(NDVI + 0,5) x sqrt(abs(NDVI + 0,5))	Perry *et al.* (1984)	PVR (Photosynthetic Vigour Ratio)	(B03 - B04) / (B03 + B04)	Metternicht (2003)
GEMI (Global Environment Monitoring Index)	(n x (1 - 0.25 x n) - (B08 - 0.125) / (1 – B08)); n=0,5	Pinty and Verstraete (1992)	SARVI (Soil and Atmospherically Resistant Vegetation Index)	(1.0 + L) x (B08 - (Rr - y x (RB - Rr))) / (B08 - (Rr - y x (RB - Rr)) + L) y = 0.735; Rr = 0.740; L = 0.487; RB = 0.560	Kaufman and Tanre (1992)

3.2.3 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 görüntülerinin her bir bandı için ayrı ayrı uygulanarak 8 farklı doku özelliği belirlenmiştir. Analiz sonucunda mean (M), variance (VAR), homogeneity (HOM), contrast (CONT), dissimilarity (DİS), entropy (ENT), second moment (SM) ve correlation (COR) tekstür verileri hesaplanmıştır (Çizelge 3.4). Ayrıca çalışmada 3x3, 5x5, 7x7 ve 9x9 olmak üzere 4 farklı filtre kullanılmıştır. Her bir filtre ise kendi içinde 4 farklı açı 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 3.2). Landsat 8 OLI ve Sentinel-2 uyduları için toplamda 17 bant kullanılmıştır. Böylece 17 bant, 8 tekstür, 4 filtre ve 4 farklı açı için toplam 2176 adet tekstür veri seti oluşturulmuştur. Tekstür verilerinin elde edilmesinde ENVI 5.2 programı ile gerçekleştirilmiştir.



Şekil 3.2 Seçilen referans piksel (n) için açıların gösterimi

Çizelge 3.4 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 Net Birincil Üretimin Hesaplanması

3.3.1 CASA model

Brüt Birincil Üretim (BBÜ), belirli bir zaman diliminde belirli bir bölgedeki bitkiler tarafından absorbe edilen toplam karbon miktarıdır. NBÜ bitkinin fotosentez ile üretip, ototrofik solunum (R_A) sonucu geriye kalan net karbon miktarıdır. Başka bir deyişle bitkinin birim alan ve zamanda bünyesine aldığı net karbon miktarıdır (Taşkınsu Meydan 2008, Bilgili *et al.* 2017, Chen *et al.* 2017).

$$NB\ddot{U} = BB\ddot{U} - R_A \quad (2)$$

Bu çalışmada NBÜ'nün hesaplanması için Carnegie-Ames-Stanford Approach (CASA) modeli kullanılmıştır. CASA modeli, NBÜ'nün tahmin edilmesinde kullanılan küresel bir modeldir. Gerek kullanım kolaylığı ve karşılaştırmalı analiz yeteneği, gerekse farklı verilerle validasyonunun yapılabilmesi ve açık kaynaklı olması nedeniyle farklı ölçeklerdeki bölgelere de adapte edilebilmesi açısından CASA modeli öncelikli olarak tercih edilmiştir. Atmosfer ile karasal biyosfer arasındaki karbon akışını çeşitli zaman dilimlerinde ve farklı konumsal çözünürlüklerde hesaplamaktadır. Bu modelin en önemli avantajlarından biri, bitki ve toprak karbonu döngüsü modeliyle mekanik olarak NBÜ ve karbon birikimini hesaplamada uzaktan algılama verilerini kullanmasıdır. Dolayısıyla ölçümü oldukça zor, maliyetli ve zaman alıcı olan NBÜ miktarının daha az zaman, maliyet ve emek ile elde edilmesine olanak sağlamaktadır. CASA modelinde ışık kullanım etkinliği (ε_n) ve absorbe edilen fotosentetik aktif radyasyon (APAR) verileri kullanılarak NBÜ değerleri hesaplanabilmektedir (Cramer *et al.* 1999).

$$NB\ddot{U} = \varepsilon_n x\, APAR \quad (3)$$

$$\varepsilon_n = \varepsilon_{max}\, x\, f(T) x\, f(W) \quad (4)$$

$$APAR = FPAR\, x\, PAR \quad (5)$$

$$NB\ddot{U} = \varepsilon_{max}\, x\, f(T) x\, f(W) x FPAR\, x\, PAR \quad (6)$$

Formülde ε_{max} maksimum ışık kullanım etkinliğini, f(T) sıcaklık fonksiyonunu, f(W) yağış fonksiyonunu, FPAR fotosentetik aktif radyasyon fraksiyonu ve PAR fotosentetik aktif radyasyonu temsil etmektedir.

ε_{max}, herhangi bir kısıtlama olmaksızın optimum çevre koşullarında, vejetasyonla fotosentetik olarak aktif radyasyonun kullanım oranıdır. İnorganik maddeye gelen güneş radyasyonunu kullanarak organik hale getirme yeteneğidir. Bu değer, bitkinin fizyolojik özelliklerine göre dolayısıyla bitki türlerine, arazi tiplerine, farklı iklim ve toprak özelliklerine göre değişkenlik göstermektedir. Alan ölçümünden elde edilen ε_{max}, yalnızca küçük bir alandaki değeri temsil edebilir ve farklı orman tipleri için değişkenlik göstermektedir. Farklı çalışmalarda benzer alanlar için kullanılan standart değerler de mevcuttur.

Zhu *et al.* (2006) yaptıkları çalışmada ε_{max} değerini herdem yeşil iğne yapraklı ormanlar için 0,389 gC MJ^{-1} olarak kullanmıştır. Field *et al.* (1995) yaptıkları çalışmada ise aynı vejetasyon tipi için 0,27 gC MJ^{-1} değerini kullanmıştır. Küresel ölçekte kabul gören ve farklı vejetasyon tipleri için belirlenmiş ε_{max} değeri 0,389 gC MJ^{-1} olarak birçok çalışmada kullanılmıştır (Dorman and Sellers 1989, Potter *et al.* 1993, Li *et al.* 2012, Chen *et al.* 2017). Li and Zhou (2015) yaptıkları çalışmada herdem yeşil ibreli ormanlarda ε_{max} değerini genç meşcereler için 0,72 gC MJ^{-1}, orta yaşlı meşcereler için 0,57 gC MJ^{-1} ve yaşlı meşcereler için de 0,52 gC MJ^{-1} olarak belirlemişlerdir. Bu çalışmada saf karaçam meşcereleri için NBÜ hesaplanacağından, Li and Zhou (2015) çalışmalarında herdem yeşil ibreli ormanlar için belirlenen ε_{max} değerleri kullanılmıştır.

f(T), maksimum ışık kullanım etkinliğinde sıcaklığın etkisini ifade etmektedir (°C).

$$f(T) = \frac{(T - Tmin) \text{ x } (T - Tmax)}{(T - Tmin)\ x\ (T - Tmax) - (T - Topt)^2} \quad (7)$$

T_{min} minimum sıcaklığı, T_{max} maksimum sıcaklığı, T_{opt} fotosentez aktiviteleri için optimal sıcaklığı ve T atmosferik sıcaklığı temsil etmektedir. Çalışma alanına ilişkin T_{min}, T_{max} ve T parametreleri meteoroloji istasyonlarından temin edilmiştir. T_{opt} ise yıllık sıcaklık ve NDVI değerlerinin bir fonksiyonudur. NDVI değerinin maksimuma ulaştığı ayın ortalama sıcaklığı alınarak hesaplanmıştır. Temmuz ayında en yüksek NDVI değerine ulaşılan çalışma alanında T_{opt} değeri 21,072 °C olarak belirlenmiştir (Huang *et al.* 2010, Gülbeyaz 2018).

f(W), bitki fotosentezindeki suyun etkisini ifade etmektedir (Xiao *et al.* 2004).

$$f(W) = \frac{1 + LSWI}{1 + LSWImax} \quad (8)$$

$$LSWI = \frac{\rho nir - \rho swir}{\rho nir + \rho swir} \quad (9)$$

LSWI arazi yüzeyi su indisini, $LSWI_{max}$ vejetasyon sürecindeki maksimum arazi yüzeyi su indisini, ρ_{nir} yakın kızılötesi (NIR) bandına ait yüzey yansıma değerini ve ρ_{swir} ise orta kızılötesi (MIR) bandına ait yüzey yansıma değerini temsil etmektedir. Bu parametreye ilişkin yansıma değerleri Sentinel-2 uydu görüntüsünden elde edilmiştir (Huang *et al.* 2010).

FPAR, vejetasyon örtüsü tarafından absorbe edilen fotosentetik aktif radyasyon fraksiyonunu ifade etmektedir. Bu parametrenin hesaplanmasında yaygın olarak NDVI kullanılmaktadır. Bu indisin yanında gelişmiş vejetasyon indisi (EVI) ve toprak etkisi azaltılmış vejetasyon indisi (SAVI) de kullanılabilmektedir.

$$FPAR = \frac{(NDVI - NDVImin)\ x\ 0{,}95}{(NDVImax - NDVImin)} + 0{,}05 \qquad (10)$$

Bu çalışmada FPAR hesaplanması için NDVI kombinasyonu olan formül kullanılmıştır (Los *et al.* 2000, Zhu *et al.* 2006).

PAR, fotosentetik aktif radyasyonu ifade etmektedir. Güneş radyasyonunun yaklaşık %50'si alınarak hesaplanmaktadır. Bitkilerin yüzeyine gelen güneş radyasyonunun, fotosentez için kullanılan kısmını ifade etmektedir.

$$PAR = R_s\ x\ 0{,}50 \qquad (11)$$

Rs, toplam güneş radyasyonunu (MJ m^{-2} $gün^{-1}$) ifade etmektedir. Bu veri meteoroloji istasyonlarından temin edilmiştir. Çalışma alanı için aylık (gC m^{-2} ay^{-1}) ve yıllık (gC m^{-2} $yıl^{-1}$) ölçekli hesaplanan NBÜ için 10 m konumsal çözünürlüğe sahip haritalar üretilmiştir.

3.3.2 Meşcere içi boşlukların elenmesi

Çalışma kapsamında gerçekleştirilmiş olan NBÜ tahmini saf karaçam meşcereleri için yapılmıştır. Çalışma alanında yayılış gösteren saf karaçam meşcerelerinin belirlenmesi için meşcere haritaları kullanılmıştır. Bu amaçla çalışma alanımızın ağaç türü, gelişim çağı ve kapalılığa ilişkin sınıflaması yapılmıştır. Fakat meşcere içi açıklıklar ile saf karaçam örtülü alanların NBÜ'sü birbirinden ayırt edilmesi gerekmektedir. Çünkü meşcere içi açıklıklarda bulunan bitki örtüsü ile karaçam ağaç türünün örtülü olduğu alanlardaki NBÜ farklılık arz etmektedir. Bunun için Ankara OBM'deki saf karaçam meşcerelerinin bulunduğu alanlar üzerinden kontrollü sınıflandırma yaparak ağaç örtülü ve ağaçsız alanlar (yol, açıklık, meşcere içi boşluk vb.) birbirinden ayrılmıştır. Bu işlemin gerçekleştirilmesinde Sentinel-2 uydu görüntüsüne ait 10 m konumsal çözünürlüğe sahip 2, 3, 4 ve 8. bantlar ile "maximum likelihood" kontrollü sınıflandırma tekniği kullanılmıştır. Böylece kullanılan CASA modelinde sadece saf karaçam meşcerelerindeki ağaç örtülü alanlar için tahmin yapılmış ve daha tutarlı sonuçlar elde edilmiştir.

3.3.3 Net birincil üretimin farklı kriterlere göre değişiminin analizi

NBÜ'nün saf karaçam meşcerelerinde gelişim çağları, sıcaklık, yağış ve yükselti gruplarına göre nasıl değiştiği tek yönlü varyans analizi kullanılarak belirlenmiştir. Oluşturulan gruplar meşcere gelişim çağları için 0 – 7,9 cm, 8 – 19,9 cm, 20 – 35,9 cm ve 36 cm ≤ olmak üzere 4 adettir (Çizelge 3.5). Sıcaklık ve yağış için yıllık ortalama veriler kullanılmıştır. Meteoroloji istasyonlarından elde edilen veriler enterpole edilerek çalışma alanını kapsayan yüzey haritaları oluşturulmuş ve her bir örnek alana ait veriler bu haritalardan elde edilmiştir. Yıllık ortalama sıcaklık 7 – 12 ^{o}C, yağış ise 34 – 54 mm arasında değişmektedir. Sıcaklık için 7 – 8 ^{o}C, 8,1 – 9 ^{o}C, 9,1 – 10 ^{o}C, 10,1 – 11 ^{o}C ve 11,1 – 12 ^{o}C olmak üzere 5 grup oluşturulmuştur. Yağış için oluşturulan gruplar 34 – 39 mm, 39,1 – 44 mm, 44,1 – 49 mm ve 49,1 – 54 mm olmak üzere 4 adettir. Yükseklik verileri her bir örnek alanda GPS yardımı ile elde edilmiştir. Örnek alanların bulunduğu mevcut yükselti değerleri 1000 ile 1500 m arasında değişmektedir. Yükseklik için 1000 – 1100 m, 1101 – 1200 m, 1201 – 1300 m, 1301 – 1400 m ve 1401 – 1500 m olmak

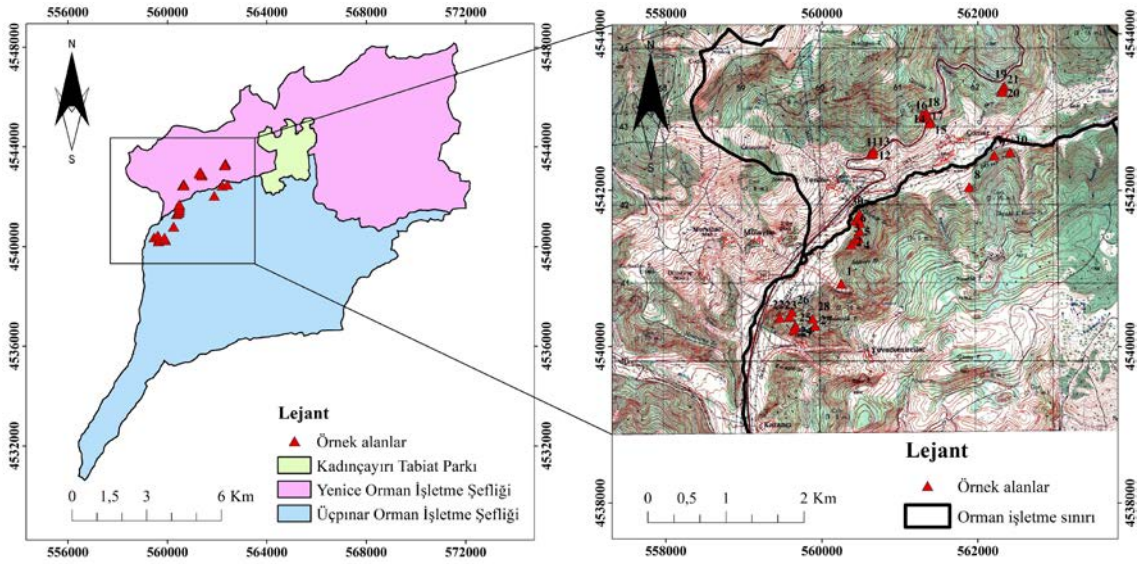
üzere 5 grup oluşturulmuştur. Basit varyans analizinde NBÜ ile meşcere gelişim çağları, sıcaklık, yağış ve yükseklik grupları arasındaki anlamlı farklılığı ortaya koymak için Duncan testi kullanılmıştır.

Çizelge 3.5 Varyans analizi için kullanılan değişkenlere ilişkin sınıf sınır değerleri

Kriter	Değer	Sınıf	Kriter	Değer	Sınıf
Sıcaklık (°C)	7 – 8	1	Yükseklik (m)	1000 – 1100	1
	8,1 – 9	2		1101 – 1200	2
	9,1 – 10	3		1201 – 1300	3
	10,1 – 11	4		1301 – 1400	4
	11,1 – 12	5		1401 – 1500	5
Yağış (mm)	34 – 39	1	Gelişim çağı (cm)	0 – 7,9	1
	39,1 – 44	2		8 – 19,9	2
	44,1 – 49	3		20 – 35,9	3
	49,1 – 54	4		36 ≤	4

3.4 Döküm Değerlerinin Elde Edilmesi

Döküm envanterinin yapılacağı örnek alanların tesisi farklı yapıdaki saf ve doğal karaçam meşcerelerinde gerçekleştirilmiştir. Bunun için Ankara OBM sınırları içerisinde yer alan Ilgaz Orman İşletme Müdürlüğüne bağlı Yenice ve Üçpınar Orman İşletme Şeflikleri seçilmiştir (Şekil 3.3). Bu işletme şefliklerinin seçimindeki temel nedenler 1690,80 ha gibi önemli düzeyde saf ve doğal karaçam meşcerelerine sahip olmaları ve her ay örnekleme yapılacağından mesafe açısından diğer şefliklere göre daha uygun olmalarıdır.



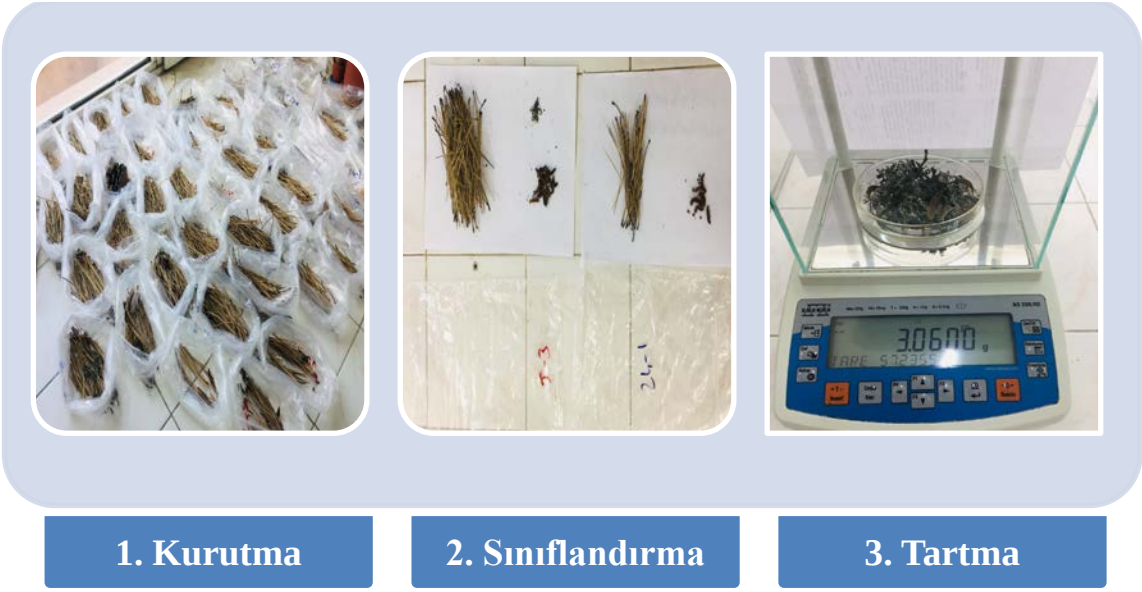
Şekil 3.3 Döküm envanteri için tesis edilen örnek noktaların konumsal dağılımı

Kapanlar meşcere kapalılığına uygun, ağaç gövdelerine yakın olmayacak, meşcereler içindeki boşluklara gelmeyecek şekilde ve yerden 1 m yükseklikte konumlandırılmıştır (Şekil 3.4). Kapanların üst kısmı yere yatay ve alt kısmı da su birikimi olmayacak şekilde delikli olarak hazırlanmıştır. (Ukonmaanaho *et al.* 2016).



Şekil 3.4 Saf karaçam meşcerelerine yerleştirilen döküm kapanları

Kapanlar içerisinden toplanan döküm örnekleri polietilen poşetlere konulmuş, örnek alan ve kapan numaraları yazılarak dikkatlice laboratuvara getirilmiştir. Çalışma alanında aşırı yağış olmadığından ve döküm örneklerine herhangi bir kimyasal analiz uygulanmayacağından dolayı tartı işleminden önce hava kurusu haline getirilmiştir. Bunun için örnekler 15 gün kurumaya bırakılmıştır. Laboratuvara getirilen döküm örnekleri ibre, dal, kozalak, kabuk, erkek çiçek ve diğer kısımlar (tohum, yosun, liken, ökse otu vb.) olmak üzere sınıflandırılmıştır. Döküm örnekleri her bir kova için ayrı ayrı değerlendirilerek 1/10000 g hassasiyetinde tartılmıştır (Şekil 3.5). Böylece elde edilen döküm miktarları ile NBÜ arasındaki ilişkiler incelenerek CASA modelinin geçerliliği kontrol edilmiştir.

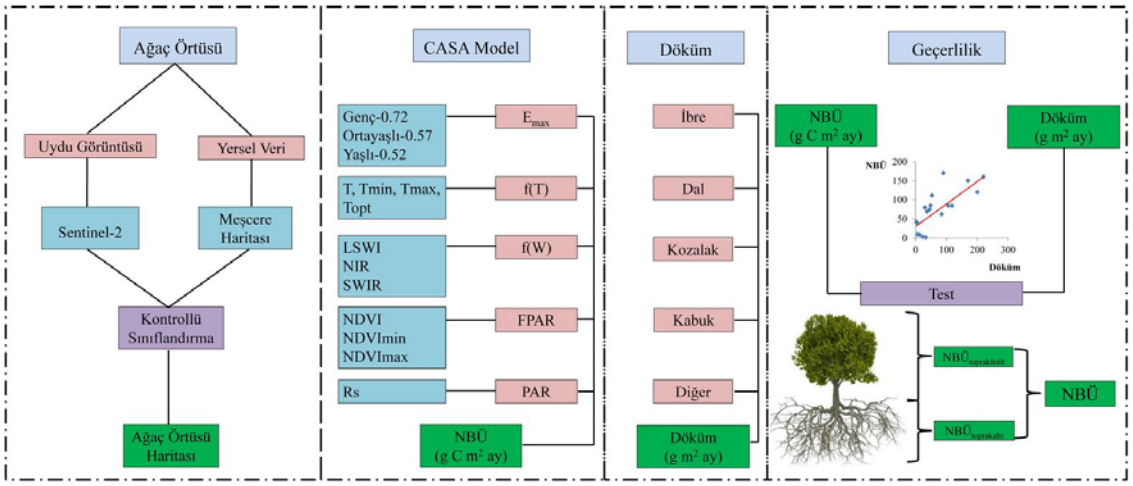


Şekil 3.5 Döküm miktarlarının elde edilme aşamaları

3.4.1 CASA model geçerliliğinin kontrol edilmesi

CASA modeli kullanılarak NBÜ değerleri hesaplanmıştır. Fakat NBÜ'ye ait yersel ölçüm verileri bulunmadığı için model validasyonu döküm verileri ile yapılmıştır. Bir değişken olarak döküm, birincil üretimin bir parçası olmakla birlikte farklı NBÜ hesaplama modellerinde kullanılmaktadır (Gower *et al.* 1999, Zhang *et al.* 2007, Shang *et al.* 2018). Geçerlilik kontrolü için 2019 yılının Mayıs-Aralık periyodundaki 8 aylık

periyotta döküm örneklemesi yapılmıştır. Aylık ölçekte hesaplanan NBÜ verilerinin, aynı yıla ilişkin aylık döküm verileri ile ilişkileri analiz edilmiştir. Döküm ve NBÜ verileri arasındaki ilişkinin gücü doğrultusunda CASA modelinin performansı belirlenmiştir. İlişki düzeyi korelasyon katsayısı (r) ve belirtme katsayısı (R^2) ile ortaya konmuştur. CASA modelinin koşturulması ve geçerliliğinin belirlenmesine ilişkin iş akış diyagramı Şekil 3.6'da gösterilmiştir.



Şekil 3.6 CASA modelinin uygulaması ve geçerliliğinin kontrolüne ilişkin iş akış diyagramı

3.5 Yaprak Alan İndeksi Değerlerinin Elde Edilmesi

Her bir örnek alanda YAİ değerini belirlemek için balıkgözü (Sigma 8 mm Fisheye lens) takılı fotoğraf makinesi (Canon EOS 50 D) kullanılmıştır. Balıkgözü sayesinde 180°'lik alanı kapsayan yarı-küresel fotoğraflar çekilmiştir. Bu fotoğraflar örnek alanı temsil edecek şekilde 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 yazılım programı kullanılarak analiz edilmiştir. Analiz sonucu elde edilen değerlerin ortalaması alınarak, her bir örnek alana ilişkin YAİ değerleri hesaplanmıştır (Şekil 3.7).



Şekil 3.7 YAİ değerlerinin hesaplanması

3.6 Modelleme

CASA modeli ile hesaplanan NBÜ, yapılan envanter çalışmalarından elde edilen meşcere parametreleri (YAİ, dg, $h_{üst}$, N, G ve V) ve coğrafi bilgi sistemi teknikleri ile uydu görüntülerinden (Landsat 8 OLI ve Sentinel-2) elde edilen uzaktan algılama verileri (reflektans, vejetasyon indisi ve tekstür değerleri) modelleme sürecine hazır hale getirilmiştir. Oluşturulan modelleri test edebilmek için veri setleri 2 gruba ayrılmıştır. Veri setlerinin %70'i model (126 adet) ve %30'u ise test (54 adet) için ayrılmıştır. Ayrılan veri setlerine çoklu regresyon analizi (ÇRA), destek vektör makineleri (DVM) ve derin öğrenme (DÖ) modelleme teknikleri uygulanmıştır. Bu tekniklerin kullanıldığı modelleme süreci 3 aşamada gerçekleştirilmiştir. İlk aşamada model veri seti kullanılarak metotlar uygulanmıştır. İkinci aşamada model veri seti ile oluşturulan modellerde test verileri koşturulmuştur. Üçüncü aşamada ise test bulgularına ilişkin tahminler ile gözlem verileri arasında fark olup olmadığını belirlemek için "eşlendirilmiş *t*-testi" kullanılmıştır.

3.6.1 Çoklu regresyon analizi

Uzaktan algılama verileri ile NBÜ, YAİ ve meşcere parametreleri arasındaki ilişkilerin modellenmesinde kullanılan yöntemlerden biri ÇRA'dır. Bu yöntem kullanılarak ölçümü zor olan parametreler, uzaktan algılama verileri (reflektans, vejetasyon indisi ve tekstür değerleri) ile modellenerek tahmin edilmiştir. Model yapıları ve kullanılacak parametreler şu şekildedir.

$$\text{Model 1: NBÜ} = \beta_0 + \beta_1 . X_1 + \beta_2 . X_2 + \cdots + \beta_n . X_n + \varepsilon \quad (12)$$

Model 1'de NBÜ bağımlı değişken olarak seçilmiştir. Bağımsız değişkenler ise verilen denklemde $X_1, X_2, \ldots, X_n$ olmak üzere YAİ, meşcere parametreleri, Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans, vejetasyon indisleri ve tekstür değerleridir.

$$\text{Model 2: } YA\dot{I} = \beta_0 + \beta_1 . X_1 + \beta_2 . X_2 + \cdots + \beta_n . X_n + \varepsilon \quad (13)$$

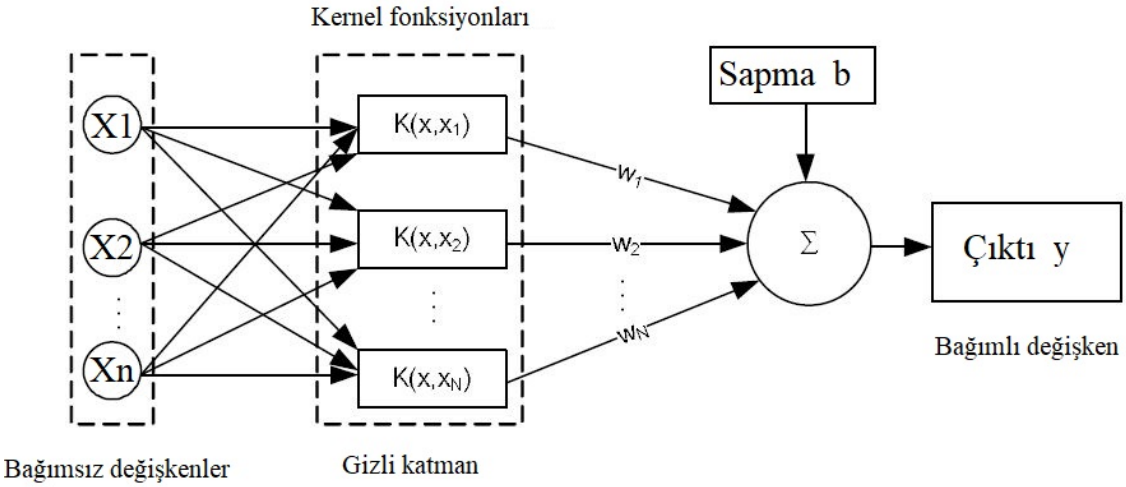
Model 2'de YAİ bağımlı değişken olarak seçilmiştir. Bağımsız değişkenler ise verilen denklemde $X_1, X_2, \ldots, X_n$ olmak üzere meşcere parametreleri, Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans, vejetasyon indisleri ve tekstür değerleridir.

$$\text{Model 3: Meşçere Parametresi} = \beta_0 + \beta_1 . X_1 + \beta_2 . X_2 + \cdots + \beta_n . X_n + \varepsilon \quad (14)$$

Model 3'te meşcere parametreleri bağımlı değişken olarak seçilmiştir. Bağımsız değişkenler ise verilen denklemde $X_1, X_2, \ldots, X_n$ olmak üzere Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans, vejetasyon indisleri ve tekstür değerleridir. Oluşturulan bu modellerde %95 güven düzeyi için farklı bağımsız değişken kombinasyonları üzerinden istatiksel olarak anlamlı model seçenekleri belirlenmeye çalışılmıştır.

3.6.2 Destek vektör makineleri

İstatistiksel öğrenme teorisi ve yapısal risk minimizasyonu yaklaşımına dayanan DVM, başlangıçta iki sınıfa ait verilerin en uygun biçimde birbirinden ayrılması için kullanılmıştır. Çok sınıflı ve doğrusal olmayan verilerin de birbirinden ayrılma problemini çözmek için geliştirilmiştir. Burada amaç sınıfları birbirinden ayırabilen optimal hiper düzlemin elde edilmesidir. Oluşan hiper düzlemin sınırını belirleyen noktalara destek vektör denilmekte ve bu metot ismini buradan almaktadır (Şekil 3.8). Bu sınırların oluşturulmasında kullanılabilecek farklı kernel fonksiyonları mevcuttur. Bu kernel fonksiyonları doğrusal, radyal, polinom ve sigmoid olmak üzere 4 adettir. Bu çalışmada diğer 3 fonksiyona göre daha üstün olduğu için radyal tabanlı fonksiyon uygulanmıştır (Rodriguez-Galiano *et al.* 2015, Zhao *et al.* 2019). DVM metodunun koşturulmasında "R" yazılımındaki "e1071" paketi kullanılmıştır (Meyer *et al.* 2015, Development Core Team R 2018).

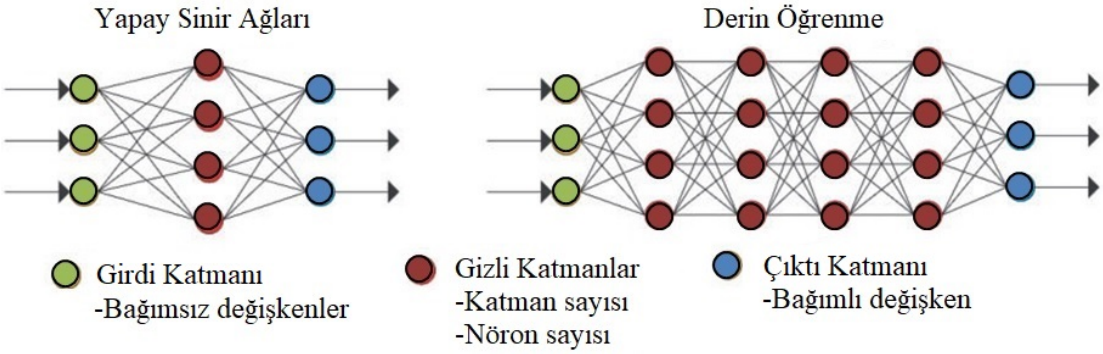


Şekil 3.8 DVM metoduna ait iş akış diyagramı

3.6.3 Derin öğrenme

Makine öğrenme yöntemlerinden biri olan DÖ, yapısal olarak yapay sinir ağlarının daha karmaşık halidir. Kullanım alanı çok geniş olup özellikle görüntü işleme, sanal yardımcılar, yüz tanıma, sürücüsüz araçlar, çeviriler ve görüntü renklendirme

konularında kullanılmaktadır. DÖ metodunun iş akışı giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Yapay sinir ağlarında bir adet gizli katman bulunurken DÖ metodu birden fazla gizli katman ile uygulanabilmektedir (Şekil 3.9). Dolayısı ile geleneksel sinir ağı sadece tek bir gizli katmanı işleyebiliyorken, DÖ metodu yapısındaki girdi verilerini çok sayıda gizli katman ile işleyebilmektedir. Giriş katmanı modelleme aşaması için kullanılacak bağımsız değişkenleri içermektedir. Eğitim aşamasının en önemli safhalarından biri en uygun gizli katman ve nöron sayısının belirlenmesidir. Bu metodun "derin" sıfatı birden fazla gizli katmana sahip olmasıdır ve uygulanması için belirlenecek minimum gizli katman sayısı ikidir. Bütün nöronlar arasında bağlantı bulunur ve her bağlantı ayrı bir ağırlık içerir. Her bir gizli katman, öncesindeki katmanın çıktısını girdi alarak devam etmektedir. Bu şekilde veri kümeleri sinir ağının tüm katmanlarından geçer ve bunun sonucunda bağımlı değişken çıktı katmanı olarak elde edilir. Metodun uygulanması için "R" yazılımındaki "H_2O" paketi kullanılmıştır (Aiello *et al.* 2015, Development Core Team R 2018).



Şekil 3.9 DÖ metodunda ağ eğitim sürecine ilişkin iş akış diyagramı

3.6.4 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 korelasyon katsayısı (r), belirtme katsayısı (R^2), ortalama mutlak hata (MAE), karekök ortalama hata (RMSE) ve Akaike bilgi kriteri (AIC)'dir. Model başarılarının yüksek olması için r ve R^2 değerlerinin büyük, MAE, RMSE ve AIC değerlerinin küçük olması beklenmektedir.

$$r = \frac{\sum \mathrm{XY} - (\sum \mathrm{X})(\sum \mathrm{Y})/\mathrm{n}}{\sqrt{\sum (X^2 - (\sum X^2)/n)(\sum Y^2 - (\sum Y)^2/n)}} \quad (15)$$

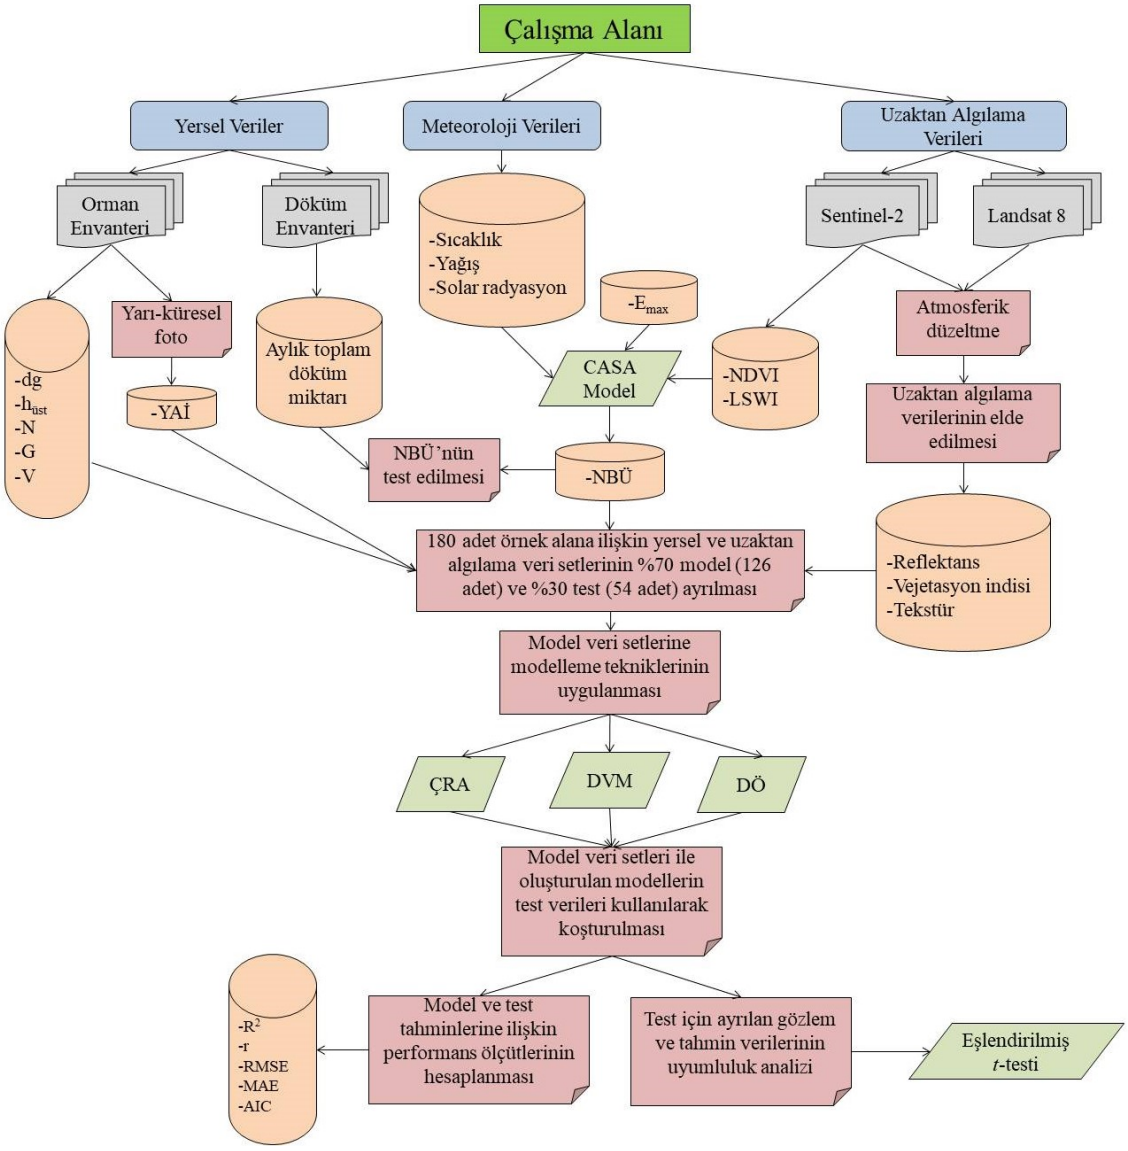
$$R^2 = 1 - \frac{\sum_{\mathrm{i}=1}^{\mathrm{n}} (\mathrm{y_g} - \mathrm{y_t})^2}{\sum_{\mathrm{i}=1}^{\mathrm{n}} (\mathrm{y_g} - \mathrm{y_{og}})^2} \quad (16)$$

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |h_i| \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (h_i)^2} \quad (18)$$

$$AIC = ln(RMSE) + 2k \quad (19)$$

İlgili formüllerde h; hata, X; birincil değişken, Y; ikincil değişken, y_g; gözlem, y_t; tahmin, y_{og}; ortalama gözlem, n; örnek sayısı ve k; modeldeki parametre sayısıdır. Tez çalışmasında gerçekleştirilen bütün işlemler kavramsal çerçeve şeklinde Şekil 3.10'da sunulmuştur.



Şekil 3.10 Kavramsal çerçeve

4. BULGULAR

Bu çalışma Ankara Orman Bölge Müdürlüğü sınırları içerisindeki saf ve doğal karaçam meşcereleri için gerçekleştirilmiştir. Carnegie Ames Stanford Approach (CASA) modeli ile net birincil üretim (NBÜ) tahmin edilmiştir. Yapılan envanter çalışması ile 180 adet örnek alan için yaprak alan indeksi (YAİ) ve meşcere parametreleri (meşcere orta çapı: dg, üst boyu: $h_{üst}$, ağaç sayısı: N, göğüs yüzeyi: G ve hacmi: V) hesaplanmıştır. Uzaktan algılama verileri için Landsat 8 OLI ve Sentinel-2 uydu görüntüleri kullanılarak reflektans, vejetasyon indisi ve tekstür değerleri elde edilmiştir. NBÜ, YAİ ve meşcere parametrelerinin modellenmesinde çoklu regresyon analizi (ÇRA), destek vektör makineleri (DVM) ve derin öğrenme (DÖ) metotları kullanılmıştır.

4.1 Net Birincil Üretime İlişkin Bulgular

4.1.1 CASA modeline ilişkin bulgular

Saf karaçam meşcerelerine ait alanlarda "maximum likelihood" metodu kullanılarak kontrollü sınıflandırma yapılmıştır (kappa=0,88, genel doğruluk başarısı=%98,10). Meşcere içindeki ağaç örtülü alanlar içerisindeki boşluklar tespit edilerek işlem dışı bırakılmıştır. Elde edilen saf karaçam meşcerelerindeki ağaç örtülü alanlar için NBÜ, CASA modeli kullanılarak 2019 yılı için aylık ve yıllık olarak hesaplanmıştır. Örnek alanlardaki saf karaçam meşcerelerinin yıllık minimum NBÜ miktarı 283,963 gC m^{-2} olup maksimum miktar 960,038 gC m^{-2}'dir. Meşcerelerin yıllık ortalama NBÜ miktarı ise 601,610 gC m^{-2} olarak hesaplanmıştır.

Aylık NBÜ dağılımına bakıldığında en yüksek üretim Temmuz ayında (171,702 gC m^{-2} ay^{-1}) görülmüştür (Çizelge 4.1). Buna paralel olarak aylık ortalama maksimum NDVI değeri yine Temmuz ayı için elde edilmiştir (0,584). Maksimum üretim ortalama hava sıcaklığının 21,1 ^{o}C olduğu ayda gerçekleşmiştir. En düşük üretim ise fotosentetik faaliyetlerin minimuma indiği Aralık (0,052 gC m^{-2} ay^{-1}) ve Ocak (0,067 gC m^{-2} ay^{-1}) aylarında görülmüştür. Fotosentetik faaliyetler 10 ^{o}C ve üzerindeki sıcaklık değerlerinde

gerçekleşmektedir ve çalışma alanındaki saf karaçam meşcerelerinde bu dönem mayıs-ekim ayları aralığını kapsamaktadır.

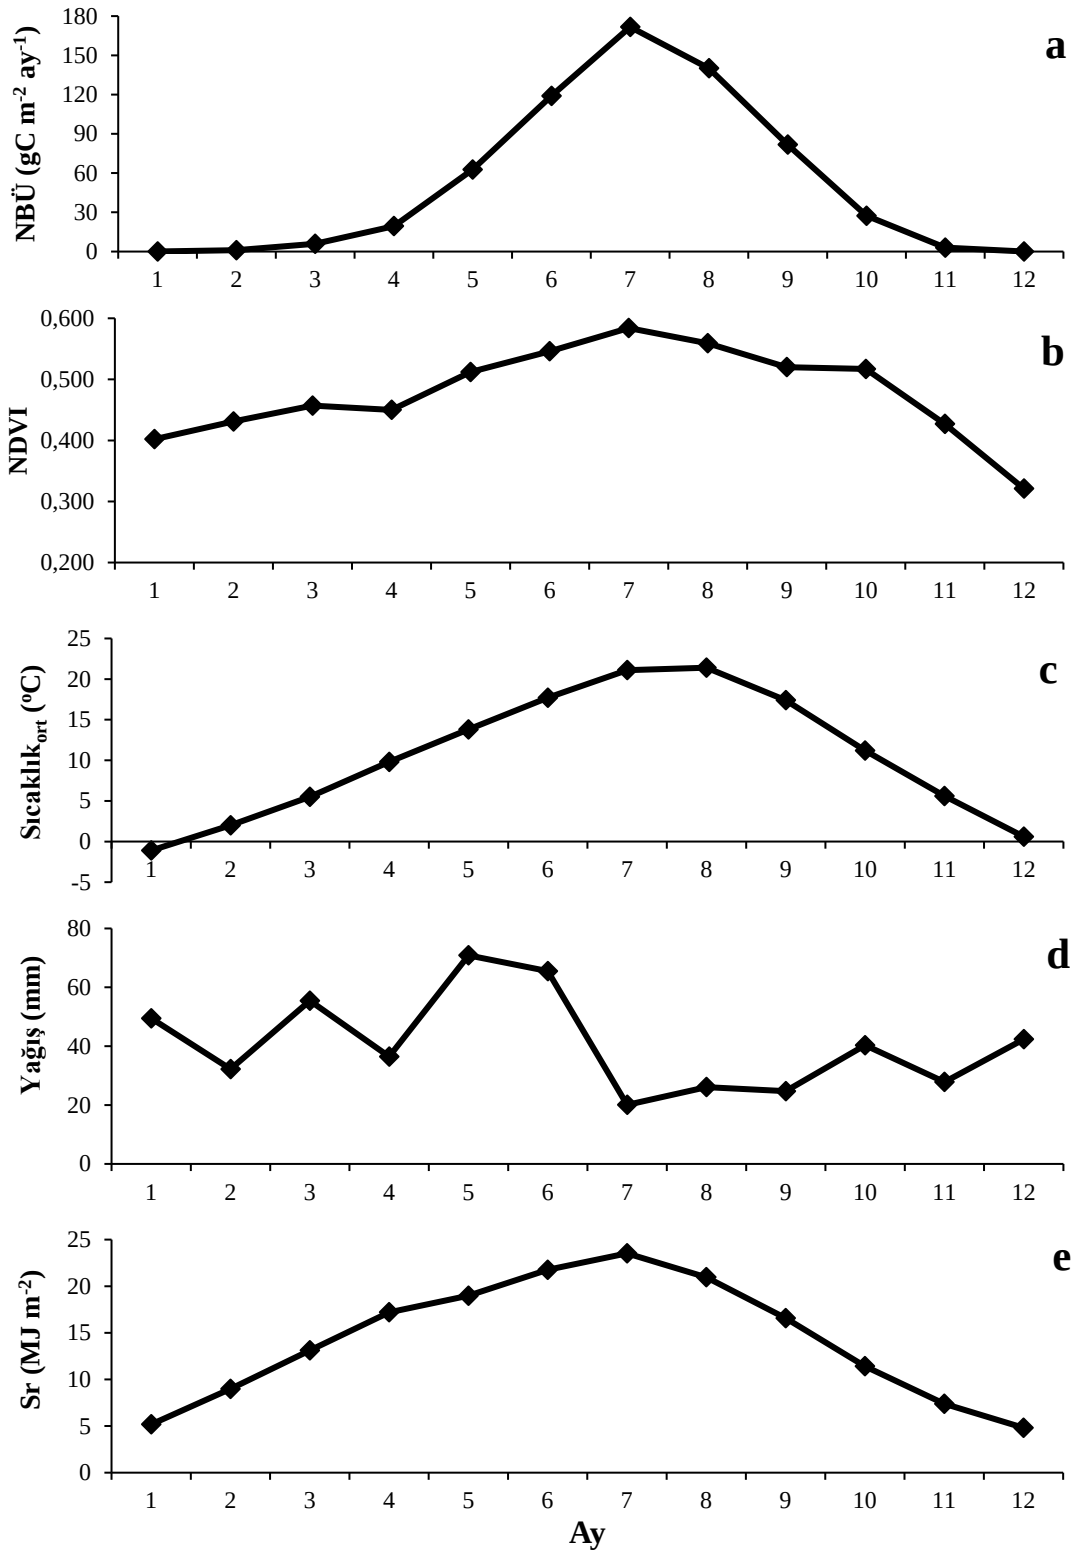
Çizelge 4.1 2019 yılı için aylık ortalama NBÜ, NDVI, ortalama sıcaklık, yağış ve güneş radyasyonu değerleri

Ay	NBÜ (gC m^{-2} ay^{-1})	NDVI	$Sıcaklık_{ort}$ (°C)	Yağış (mm)	Güneş radyasyonu (MJ m^{-2})
1	0,067	0,402	-1,1	49,463	5,180
2	1,035	0,431	2,0	32,219	8,981
3	5,919	0,457	5,5	55,448	13,112
4	19,416	0,450	9,8	36,461	17,199
5	62,683	0,512	13,8	70,851	18,978
6	118,963	0,546	17,7	65,487	21,758
7	171,702	0,584	21,1	20,065	23,523
8	140,096	0,559	21,4	26,085	20,956
9	81,692	0,520	17,4	24,712	16,570
10	27,307	0,517	11,2	40,322	11,415
11	2,977	0,427	5,6	27,824	7,390
12	0,052	0,321	0,6	42,350	4,814

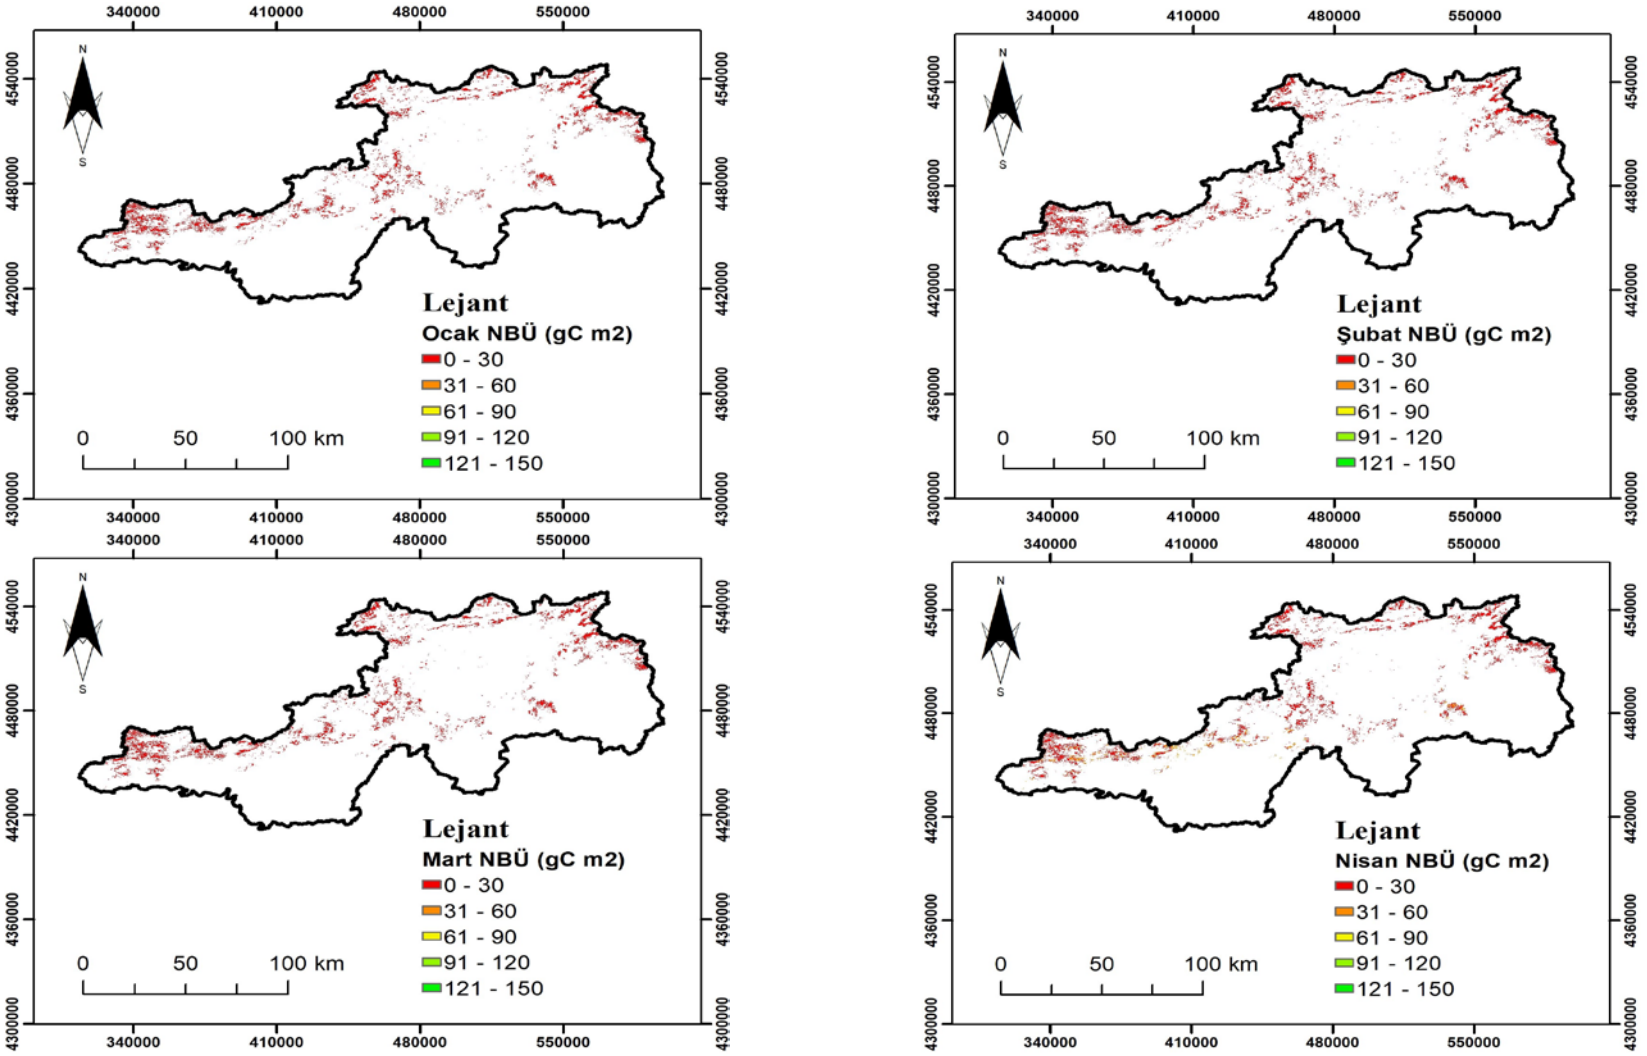
Ortalama NBÜ, NDVI, ortalama sıcaklık, yağış ve güneş radyasyonunun aylık dağılımları grafikler halinde sunulmuştur (Şekil 4.1). Ortalama NDVI, ortalama sıcaklık, güneş radyasyonu ile NBÜ'nün aylık dağılımı büyük oranda benzerdir. Aralarındaki korelasyon ilişkileri sırası ile 0,85, 0,92 ve 0,88'dir. Yağışın mevsimsel değişkenliğinden dolayı aylık trendi uyumsuz olmakla birlikte NBÜ ile aralarında -0,20 korelasyon ilişkisi bulunmaktadır. İlişkinin negatif çıkması fotosentetik aktivitelerin düşük olduğu aylarda ortalama yağış miktarının oldukça yüksek olması ile açıklanabilir. Özellikle Ocak ve Temmuz ayına kadar NBÜ düzenli artış gösterirken bu aylar süresince yağış azalış eğilimindedir. Bu durumda toprağın su tutma kapasitesi oldukça önemlidir. Yağış miktarının azalmasına karşın toprağın su tutma kapasitesinin yüksek olması, fotosentetik aktivitelerin artan bir şekilde devam edebilmesini sağlamaktadır.

Aylık ve yıllık toplam NBÜ miktarlarının konumsal dağılımları birincil üretimin hangi bölgede daha fazla veya az olduğunu göstermektedir (Şekil 4.2, 4.3, 4.4, 4.5). 2019 yılı Ocak – Nisan ayları süresince ortalama sıcaklık 10 °C'ye ulaşmamış ve bütün bölgede üretim 30 gC m^{-2}'nin altında kalmıştır. Alandaki saf karaçam meşcerelerinde Mayıs ayı ile başlayan hızlı bir NBÜ artışı görülmektedir. NBÜ'nün en yüksek olduğu Temmuz

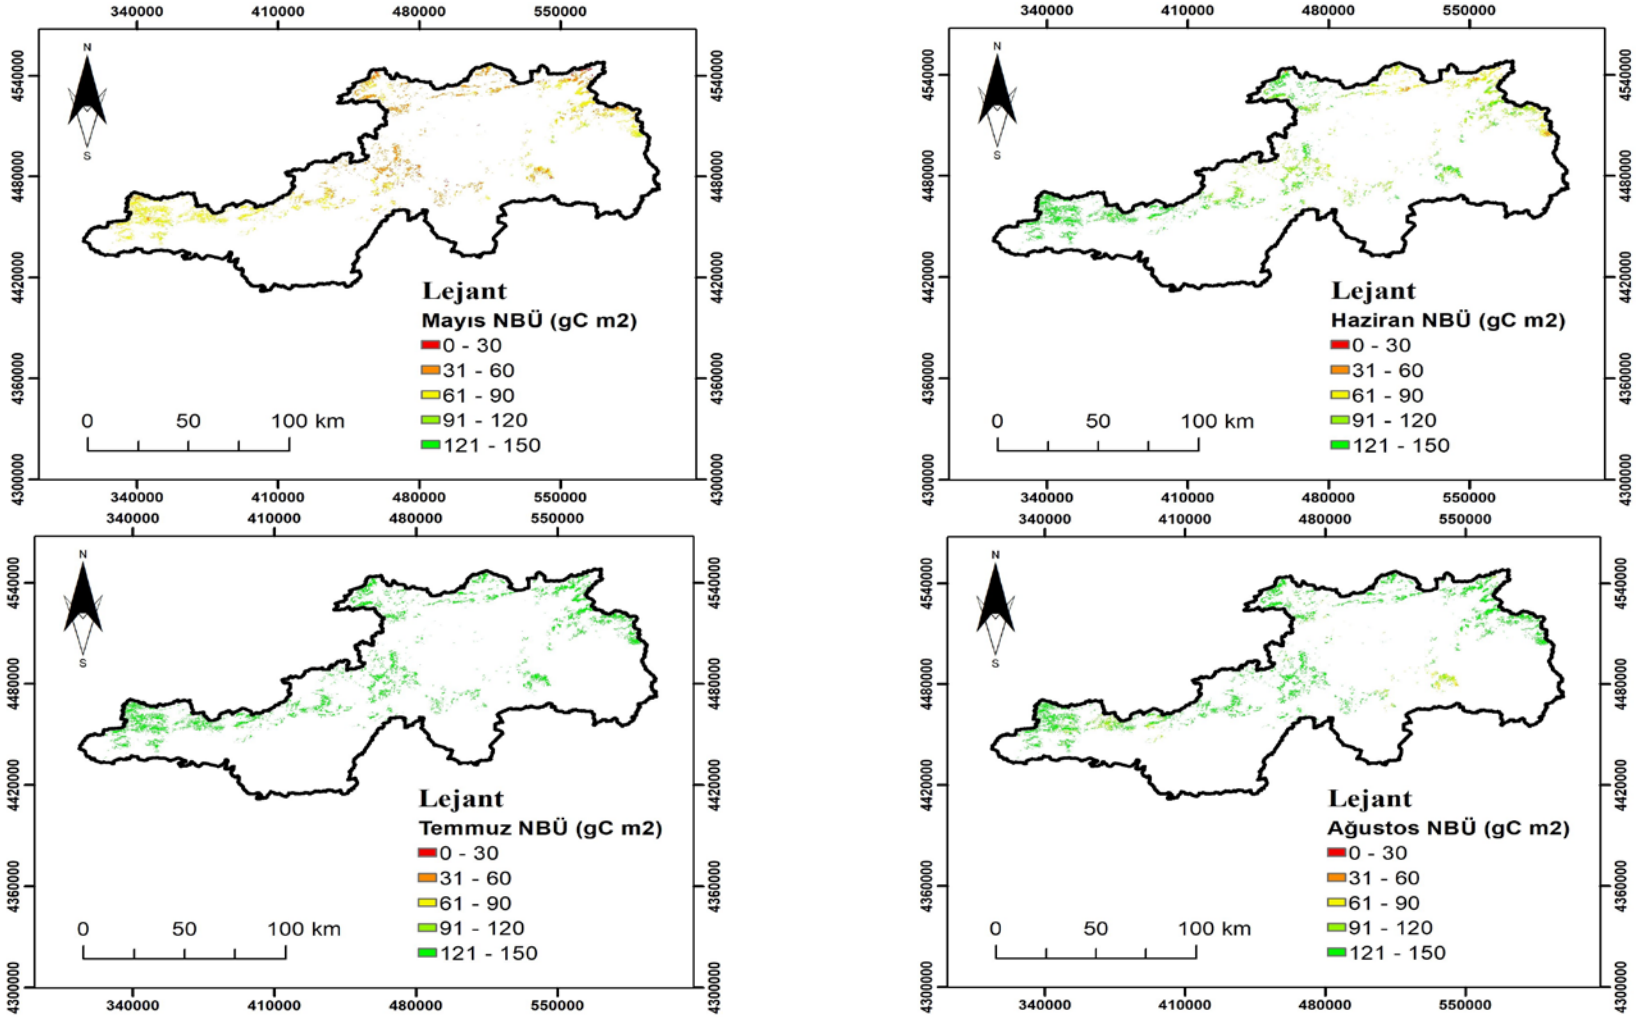
ayında bütün alan 800 gC m^{-2}'nin üzerinde üretim yapmıştır. Özellikle Haziran ayında bölgenin batıda kalan bölümlerinde üretimin daha fazla olduğu görülmektedir. Ekim – Aralık ayları sürecinde ise üretim yine 30 gC m^{-2}'nin altına düşmektedir.



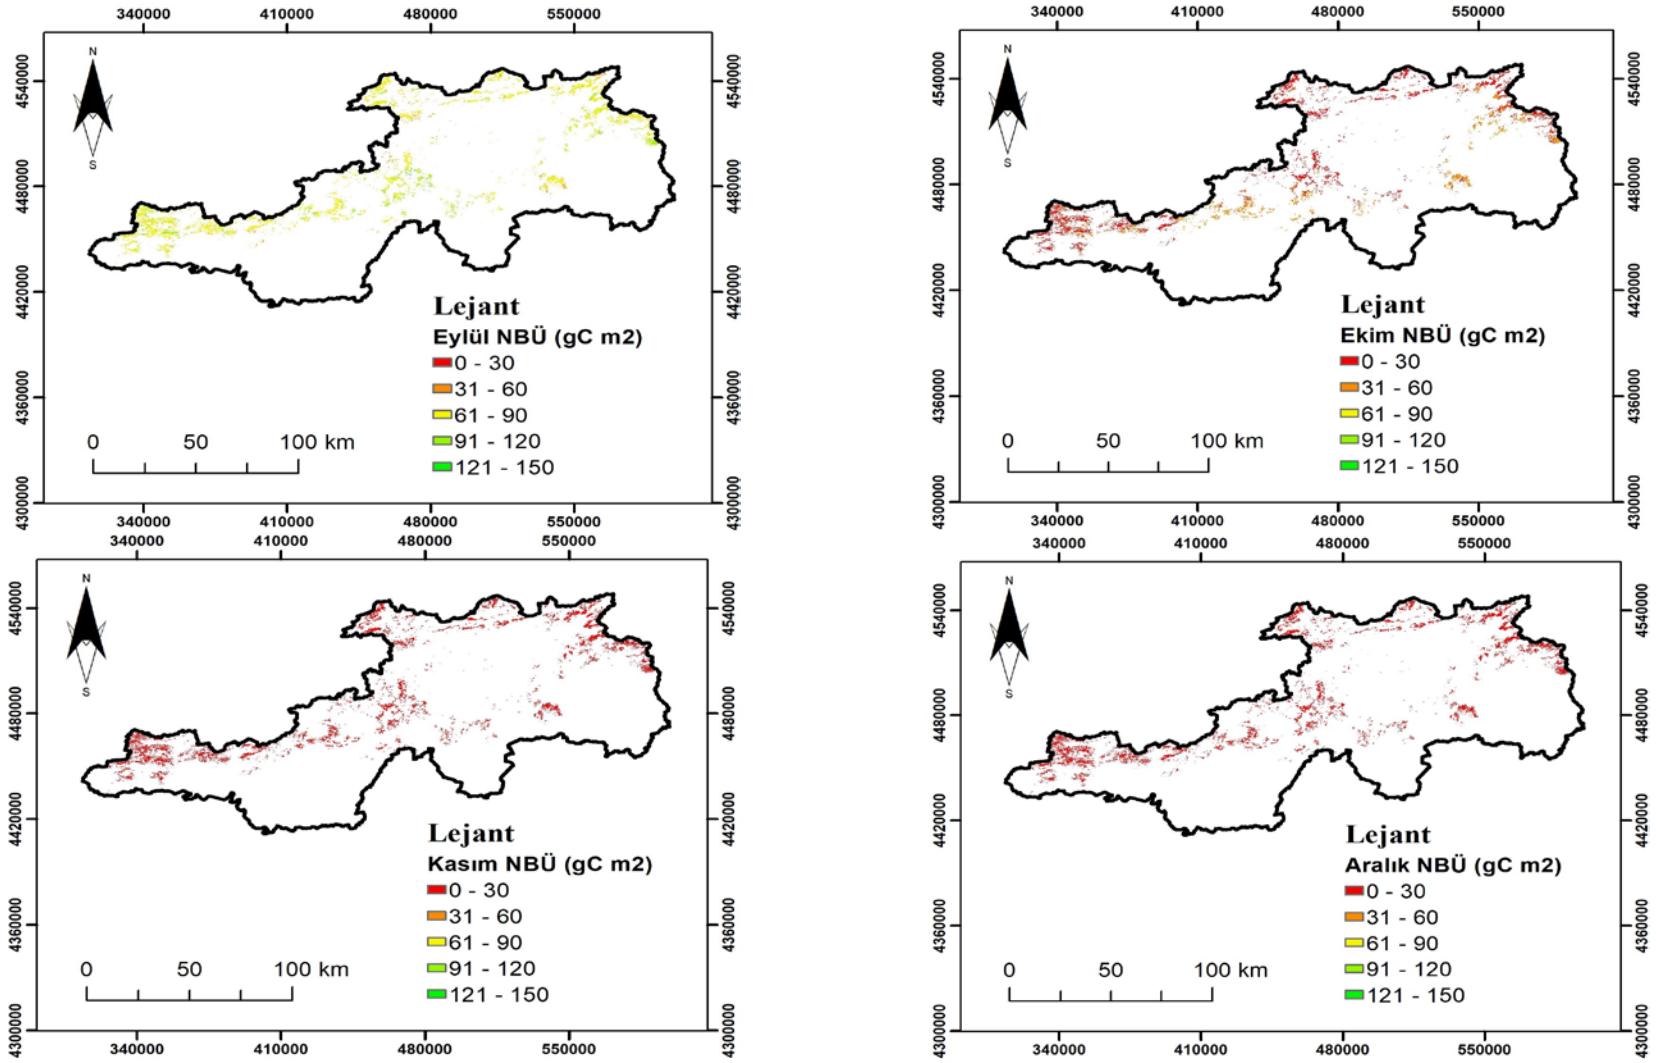
Şekil 4.1 Çalışma alanına ait 2019 yılı için aylık ortalama a) NBÜ, b) NDVI, c) ortalama sıcaklık, d) yağış ve e) güneş radyasyonu (Sr) değerleri



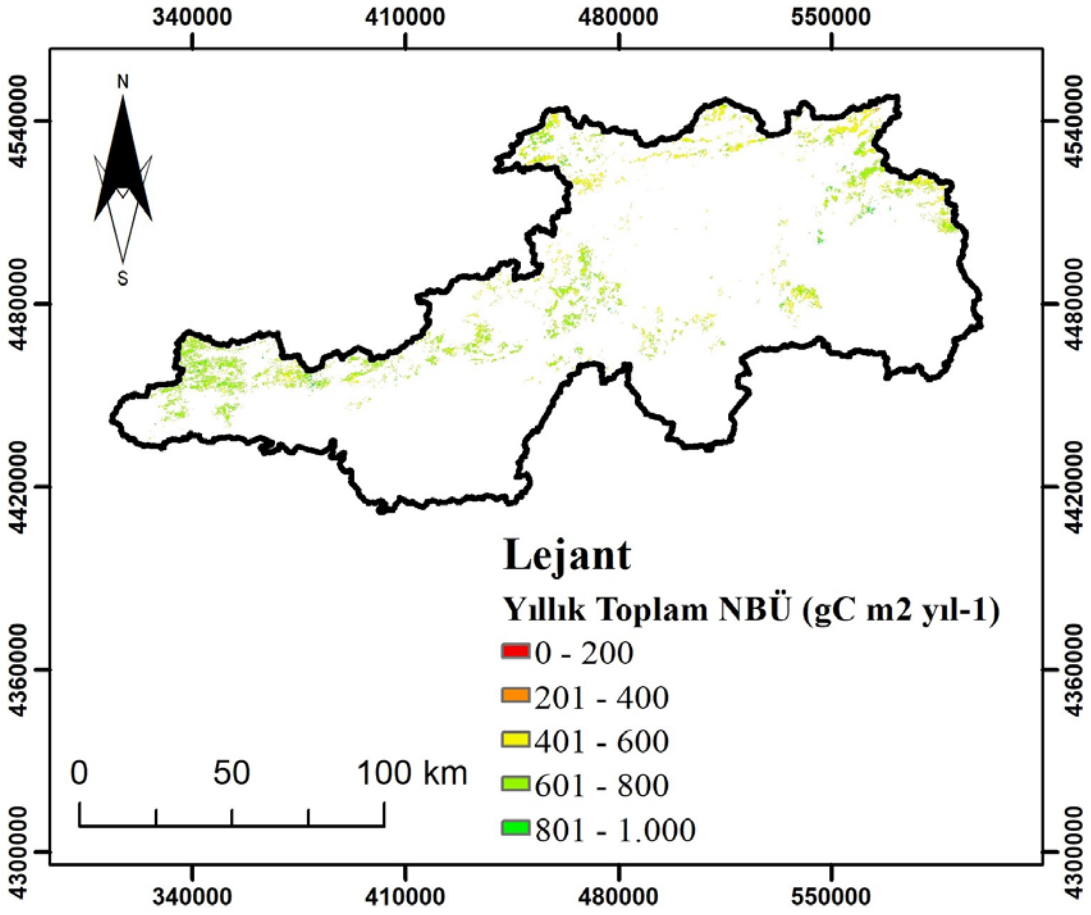
Şekil 4.2 Saf karaçam meşcerelerine ait 2019 yılı Ocak, Şubat, Mart ve Nisan aylarına ait toplam NBÜ değerlerine ilişkin haritalar



Şekil 4.3 Saf karaçam meşcerelerine ait 2019 yılı Mayıs, Haziran, Temmuz ve Ağustos aylarına ait toplam NBÜ değerlerine ilişkin haritalar



Şekil 4.4 Saf karaçam meşcerelerine ait 2019 yılı Eylül, Ekim, Kasım ve Aralık aylarına ait toplam NBÜ değerlerine ilişkin haritalar



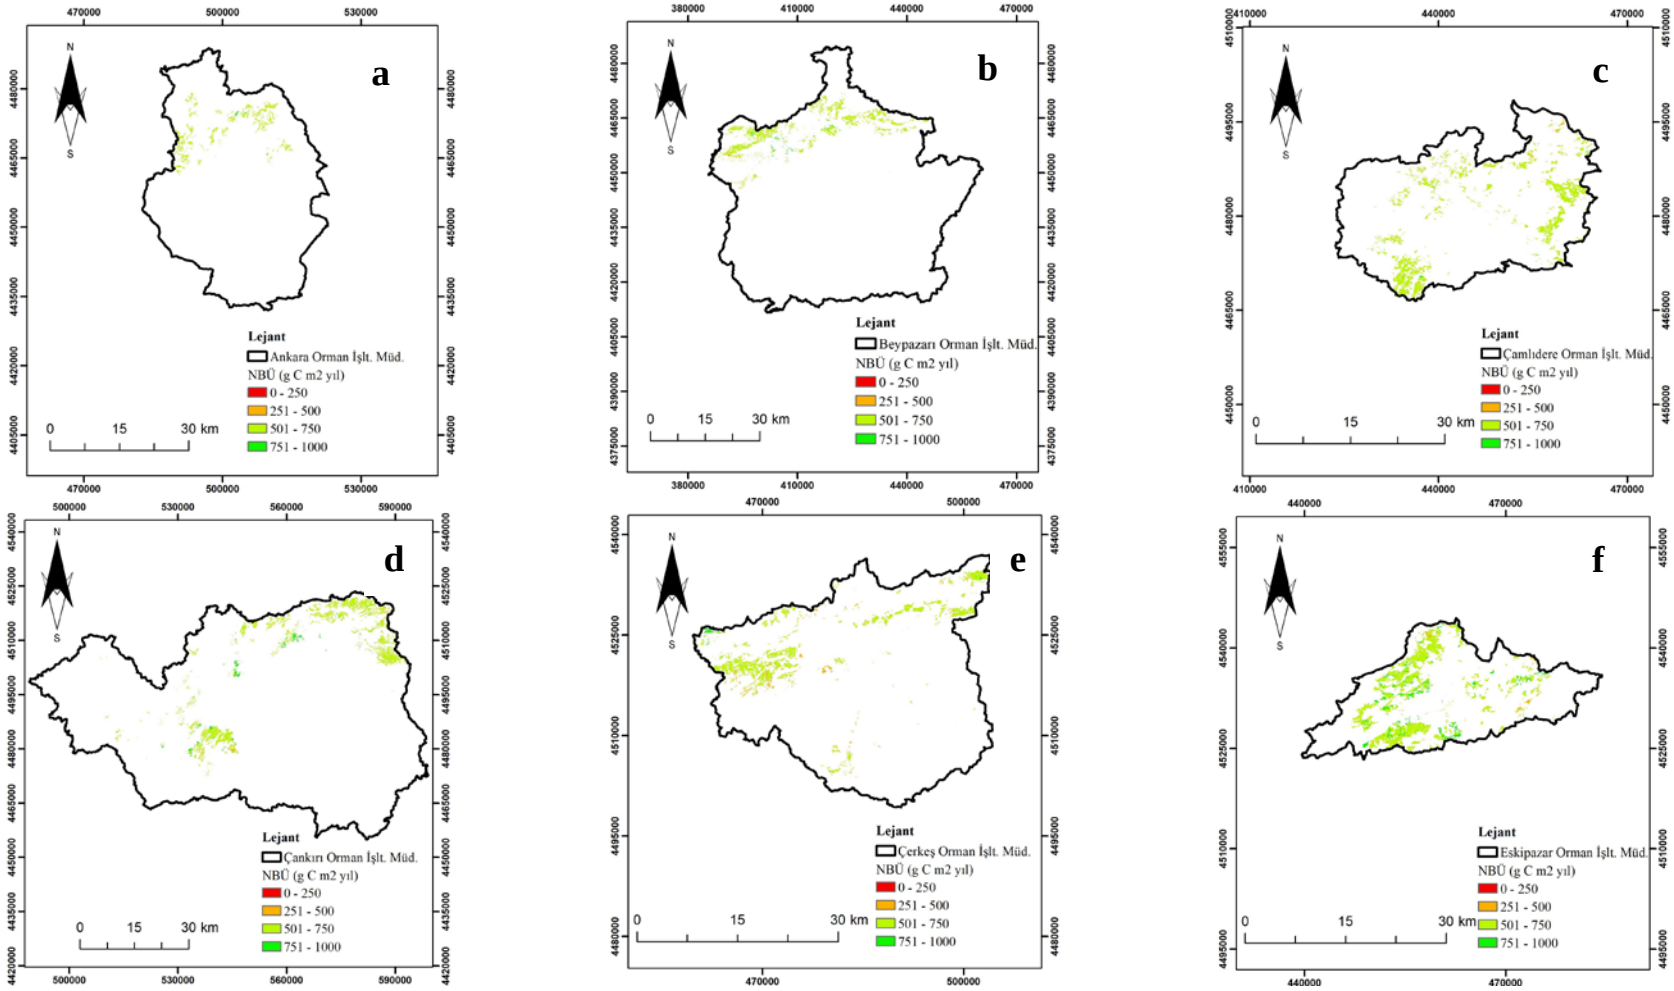
Şekil 4.5 Saf karaçam meşcerelerine ait 2019 yılı için yıllık toplam NBÜ değerlerine ilişkin harita

Saf karaçam meşcerelerinde 2019 yılında gerçekleşen toplam birincil üretim için haritalama yapılmıştır. Alanın kuzey kesiminde bulunan Eskipazar, Çerkeş ve Ilgaz Orman İşletme Müdürlüklerinde (OİM) yıllık toplam NBÜ 400 – 800 gC m^{-2} arasında değişmektedir. Bu kesimde en yüksek üretim 635,247 gC m^{-2} ile Eskipazar OİM'de, en düşük ise Çerkeş OİM'de (562,452 gC m^{-2}) gerçekleşmiştir. Batı kısmında yer alan Nallıhan OİM'de ise bu değer 600 – 1000 gC m^{-2} arasındadır. Bununla birlikte Ankara OBM'de en yüksek NBÜ Nallıhan OİM'de belirlenmiştir.

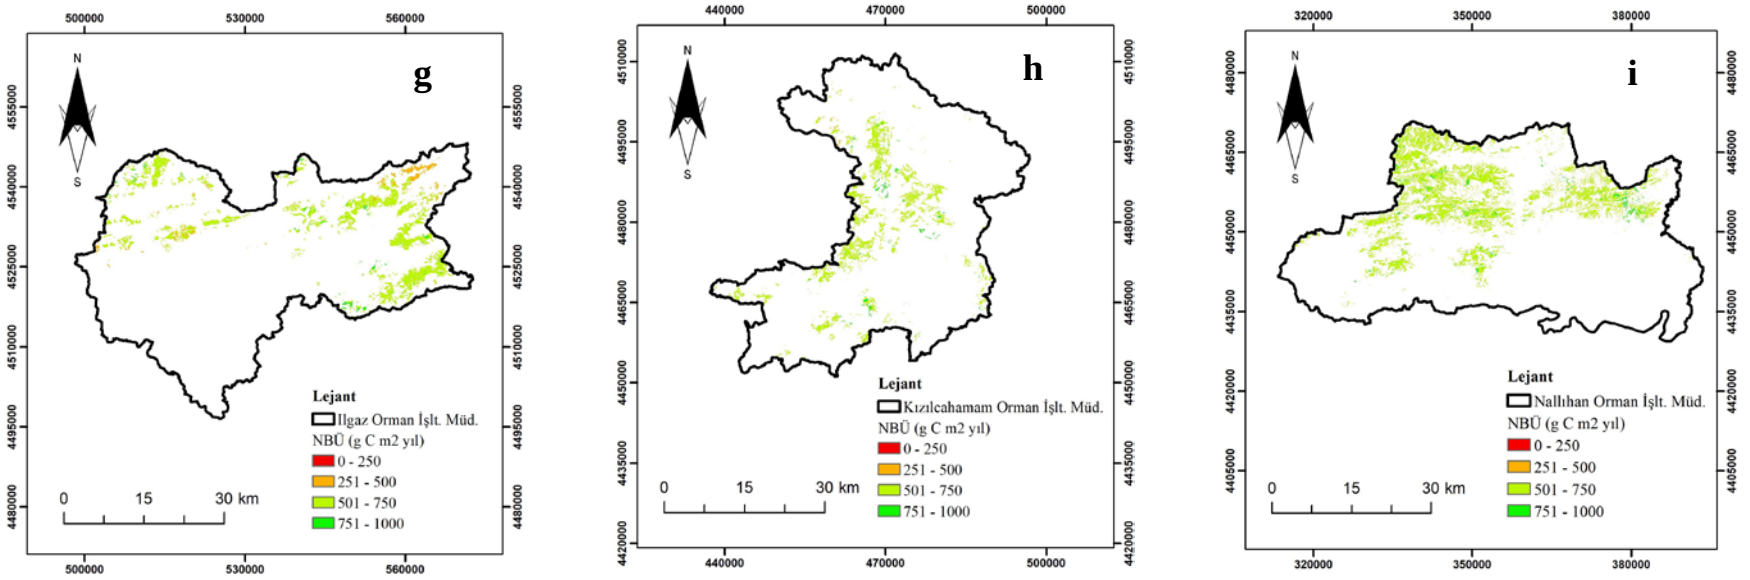
4.1.2 Ankara Orman Bölge Müdürlüğü içerisindeki Orman İşletme Müdürlüklerinin 2019 yılı net birincil üretim değerlerine ilişkin bulgular

Ankara Orman Bölge Müdürlüğü ve içerisindeki OİM'lerde yayılış gösteren saf karaçam meşcerelerinin yıllık toplam NBÜ miktarları haritalanmıştır (Şekil 4.6-4.7).

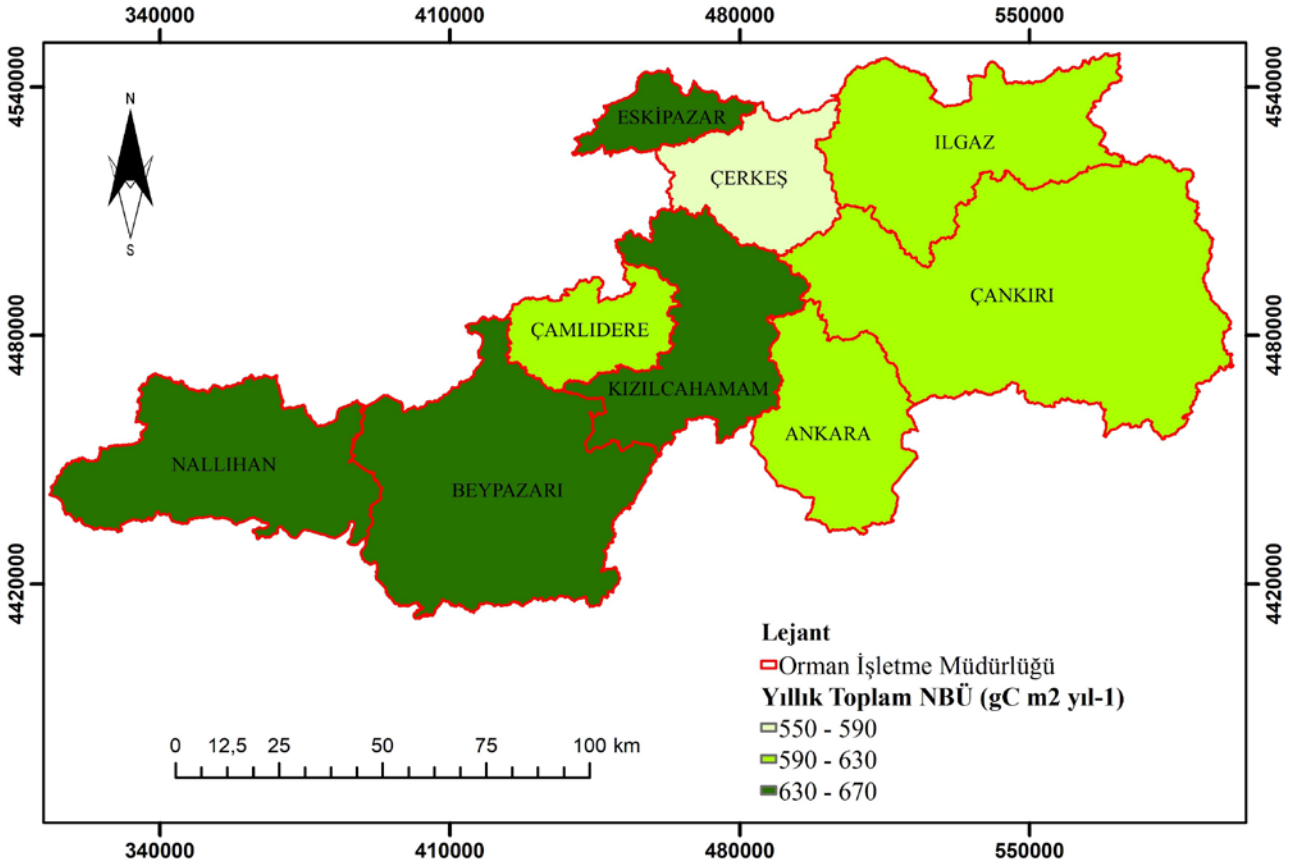
OİM'lerin ortalama NBÜ miktarları Nallıhan 664,378 gC m^{-2} $yıl^{-1}$, Beypazarı 650,810 gC m^{-2} $yıl^{-1}$, Çamlıdere 622,620 gC m^{-2} $yıl^{-1}$, Kızılcahamam 645,942 gC m^{-2} $yıl^{-1}$, Eskipazar 635,247 gC m^{-2} $yıl^{-1}$, Çerkeş 562,452 gC m^{-2} $yıl^{-1}$, Ilgaz 593,925 gC m^{-2} $yıl^{-1}$, Çankırı 620,672 gC m^{-2} $yıl^{-1}$ ve Ankara 629,746 gC m^{-2} $yıl^{-1}$'dir. Bölge Müdürlüğünde en yüksek ortalama NBÜ, Nallıhan OİM'de (664,378 gC m^{-2} $yıl^{-1}$) bulunmuştur. Bu verilerin yalnızca saf karaçam meşcerelerine ait olduğu unutulmamalıdır. Sadece bu bilgiler doğrultusunda OİM'ler arasında daha verimli/verimsiz yorumu yapmak yanlış olur. NBÜ'deki farklılıklara sebep olacak birçok etken bulunmakta ve OİM'lerdeki meşcere özellikleri, topoğrafik ve edafik faktörler bunlardan en önemlileridir. Ayrıca meşcerelere yapılan bakım müdahalelerinin zamanında ve doğru bir şekilde uygulanması meşcerelerdeki üretimi de büyük oranda etkilemektedir.



Şekil 4.6 Ankara Orman Bölge Müdürlüğü içerisindeki a) Ankara, b) Beypazarı, c) Çamlıdere, d) Çankırı, e) Çerkeş, f) Eskipazar, g) Ilgaz, h) Kızılcahamam ve i) Nallıhan Orman İşletme Müdürlükleri için 2019 yılı saf karaçam meşcerelerine ait yıllık toplam NBÜ haritaları



Şekil 4.6 devamı



Şekil 4.7 Ankara Orman Bölge Müdürlüğü 2019 yılı için saf karaçam meşcerelerine ait yıllık toplam NBÜ haritası

4.1.3 NBÜ'nün sıcaklık, yağış, yükseklik ve meşcere gelişim çağlarına göre değişimine ilişkin bulgular

NBÜ'nün sıcaklık, yağış, yükseklik ve meşcere gelişim çağlarına göre nasıl değişim gösterdiği analiz edilmiştir (Çizelge 4.2). Sıcaklık artışına göre NBÜ'de yükseliş meydana gelmektedir. En yüksek NBÜ yıllık ortalama sıcaklığın 11 – 12 ^{o}C olduğu alanlarda belirlenmiştir. Yağışın ortalama yıllık 34 – 44 mm olduğu bölgelerde NBÜ'nün daha yüksek olduğu gözlemlenmiştir. Yağış miktarının artışı oranında NBÜ seviyesinde azalış belirlenmiştir. 1000 – 1100 m rakım arasında en yüksek NBÜ belirlenmiş olup yükselti arttığında NBÜ'de azalış görülmüştür. Meşcere gelişim çağlarına göre ise genç meşcerelerde NBÜ daha yüksek bulunmuştur. Bunun nedeni de genç meşcerelerin büyüme potansiyellerinin daha yaşlı meşcerelere göre yüksek olmasıdır.

Çizelge 4.2 NBÜ'nün sıcaklık, yağış, yükseklik ve meşcere gelişim çağlarına göre değişimi

Kriter	Sınıf	N	Ortalama NBÜ	Kriter	Sınıf	N	Ortalama NBÜ
Sıcaklık (^{o}C)	7 – 8	30	424,565 ^{d}	Yükselti (m)	1000 – 1100	15	719,884 ^{a}
	8,1 – 9	10	528,919 ^{c}		1101 – 1200	25	632,666 ^{b}
	9,1 – 10	45	612,433 ^{b}		1201 – 1300	25	623,182 ^{b}
	10,1 – 11	51	654,828 ^{ab}		1301 – 1400	50	579,997 ^{b}
	11,1 – 12	44	666,090 ^{a}		1401 – 1500	65	570,700 ^{b}
Yağış (mm)	34 – 39	57	645,168 ^{a}	Gelişim çağı (cm)	0 – 7,9	2	884,995 ^{a}
	39,1 – 44	76	648,573 ^{a}		8 – 19,9	21	685,000 ^{b}
	44,1 – 49	29	485,827 ^{b}		20 – 35,9	88	617,822 ^{bc}
	49,1 – 54	18	451,927 ^{b}		36 ≤	69	547,341 ^{c}

a, b, c, d ve e harfleri %95 anlamlılık düzeyinde istatistiksel olarak farklı grupları gösterir (a>b>c>d>e)

4.2 Yaprak Alan İndeksine İlişkin Bulgular

Araştırma alanı içerisinde belirlenen 180 adet örnek alanda en düşük YAİ değeri 0,332 m^2 m^{-2}, en yüksek değer ise 3,525 m^2 m^{-2}'dir. Örnek alanlara ait ortalama YAİ değeri 1,254 m^2 m^{-2}'dir. Meşcere yaşı ile YAİ arasında negatif yönlü bir ilişki tespit edilmiştir (r = -0,30). Örnek alanlara ilişkin dg, $h_{üst}$, N, G ve V ile YAİ arasındaki korelasyon ilişki düzeyleri sırası ile -0,30, 0,11, 0,58, 0,35 ve 0,36'dır. YAİ, gelişim çağları ve kapalılık sınıflarına göre gruplandırılarak incelenmiş ve NBÜ ile bu sınıflar arasındaki ilişkiler incelenmiştir. Gelişim çağlarına göre sınıflandırıldığında en yüksek ortalama

değer (2,729 m^2 m^{-2}) gençlik ve sıklık (a) çağındaki meşcerelerde bulunmuştur. Çap arttığında meşcere yaşının da artacağı düşünüldüğünde, meşcere yaşı ile ters orantılı olarak YAİ değerlerinde azalma görülmektedir. Kapalılık sınıfları tepe çatısının yer yüzeyini örtme oranına göre belirlendiğinden dolayı örtüş miktarının artması birim alandaki ibre miktarının artmasından kaynaklanmaktadır. Bundan dolayı en yüksek ortalama YAİ değeri 3. (1,494 m^2 m^{-2}) ve en düşük ortalama değer ise 1. (0,654 m^2 m^{-2}) kapalılık sınıfında belirlenmiştir.

NBÜ ile YAİ arasındaki ilişkiler incelenirken, gelişim çağlarına ve kapalılık sınıflarına göre ayrı ayrı değerlendirilmiştir (Çizelge 4.3). Bağımsız değişken olarak kullanılan YAİ'ye dönüşümler uygulanarak analize dahil edilmiştir. Bunun için YAİ'ye ait veri setlerine $YAİ^2$, 1/YAİ, $1/YAİ^2$, lnYAİ, logYAİ, $\sqrt{YAİ}$ ve $1/\sqrt{YAİ}$ dönüşümleri uygulanmıştır. Analiz sürecinde "a" gelişim çağına ait 2 adet meşcere olduğu için analiz işleminde "b" gelişim çağı ile birleştirilerek uygulanmıştır. En yüksek YAİ ve NBÜ, "a" (gençlik ve sıklık çağı) gelişim çağı ve 3 kapalı meşcerelerde bulunmuştur. Birincil üretimin ve yaprak alan indeksinin en az olduğu karaçam meşcereleri "d" gelişim çağında ve 1 kapalı meşcerelerdir.

Çizelge 4.3 YAİ'nin gelişim çağları ve kapalılık sınıflarına göre NBÜ ile ilişkileri

		N	**Ort YAİ (m^2 m^{-2})**	**Ort NBÜ (gC m^{-2})**	**NBÜ modeli**	**R^2**	**r**
		180	1,254	601,610	Denklem 20	0,22	0,47
Gelişim çağı	**Sınır değerler**	**N**	**Ort YAİ (m^2 m^{-2})**	**Ort NBÜ (gC m^{-2})**	**NBÜ modeli**	**R^2**	**r**
a	0 – 7,9 cm	2	2,729	884,995	Denklem 21	0,70	0,84
b	8 – 19,9 cm	21	1,276	685,000			
c	20 – 35,9 cm	88	1,202	617,822	Denklem 22	0,52	0,72
d	36 cm <	69	1,012	547,341	Denklem 23	0,20	0,45
Kapalılık sınıfı	**Sınır değerler**	**N**	**Ort YAİ (m^2 m^{-2})**	**Ort NBÜ (gC m^{-2})**	**NBÜ modeli**	**R^2**	**r**
1	%11 – 40	26	0,654	569,744	Denklem 24	0,38	0,62
2	%41 – 70	68	0,974	572,195	Denklem 25	0,21	0,45
3	%71 – 100	86	1,494	660,714	Denklem 26	0,37	0,61

Modellere ilişkin bütün bağımsız değişkenler anlamlı bulunmuştur ($p<0,05$).

$$NBÜ = 543{,}949 + (36{,}119 \text{ x } YAİ^2) \quad (20)$$

$$NBÜ = 1093{,}488 - \left(649{,}391 \text{ X } \frac{1}{YAİ}\right) + (183{,}788 \text{ X } \frac{1}{YAİ^2}) \quad (21)$$

$$NBÜ = 894{,}244 - \left(322{,}221 \text{ X } \frac{1}{YAİ}\right) - (350{,}944 \text{ X } \ln YAİ) + (55{,}021 \text{ X } YAİ^2) \quad (22)$$

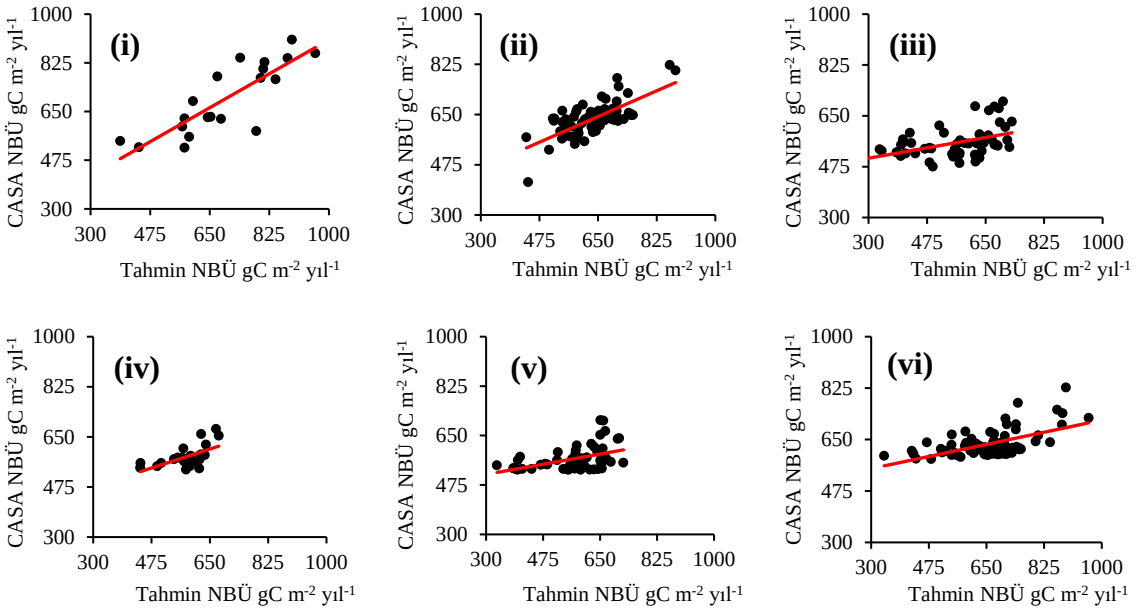
$$NBÜ = 456{,}589 + (91{,}165 \text{ X } YAİ^2) \quad (23)$$

$$NBÜ = 521{,}380 + (128{,}738 \text{ X } YAİ^2) \quad (24)$$

$$NBÜ = 388{,}628 + \left(171{,}250 \text{ X } \frac{1}{YAİ^2}\right) + (569{,}962 \text{ X } \ln YAİ) \quad (25)$$

$$NBÜ = 639{,}162 - \left(64{,}486 \text{ X } \frac{1}{YAİ^2}\right) + (24{,}652 \text{ X } YAİ^2) \quad (26)$$

NBÜ ve YAİ arasındaki ilişki gücünün en yüksek olduğu model "a" ve "b" gelişim çağlarına ait meşcerelerden üretilmiştir (Şekil 4.8). Tüm veri seti ve farklı gruplara ayrılarak bakılan ilişkilerde belirli sınıfların toplam veri setine göre daha yüksek ilişkiler verdiği görülmüştür. "a-b" ve "c" gelişim çağları ile "1" ve "3" kapalı meşcereler için ayrılan gruplarda, YAİ ve NBÜ ilişkilerinin daha kuvvetli olduğu görülmüştür.



Şekil 4.8 i) a-b gelişim çağı, ii) c gelişim çağı, iii) d gelişim çağı, iv) 1 kapalı, v) 2 kapalı ve vi) 3 kapalı alanlar için NBÜ gözlem-tahmin grafikleri

4.3 Meşcere Parametrelerine İlişkin Bulgular

Her bir örnek alan için yapılan envanter çalışması sonucunda dg (cm), $h_{üst}$ (m), N (adet/ha), G (m^2/ha) ve V (m^3/ha) hesaplanmıştır (Çizelge 4.4). Yapılan envanter çalışmasında örnek alanlar bütün yaş sınıflarına dağıtıldığı için yeni kapalılık oluşmuş Çka3 meşcerelerinden, gençleştirme aşamasına gelmiş Çkd1 meşcerelerine kadar bütün alanlarda örnekleme yapılmıştır. Alınan örnek noktalar için hektardaki ağaç sayıları 137,50 ile 6300,00 arasında değişmektedir. Bu değerler örnekleme yapılan gençlik ve idare süresini doldurmuş yaşlı alanlara ait verilerden kaynaklanmaktadır. N hariç hesaplanan bütün parametreler için minimum değerler örneklenen en genç alanlardan kaynaklanmaktadır (dg = 2,00 cm, $h_{üst}$ = 3,00 m, G = 1,97 m^2 ve V = 10,00 m^3). Genç meşcerelerde ağaç sayısı daha fazla olduğu için en yüksek ağaç sayısı genç meşcerelere aittir.

Çizelge 4.4 Meşcere parametrelerine ilişkin tanımlayıcı istatistik değerleri

Değişken	N	Min	Maks	Ort	Std.D
dg (cm)	180	2,0	56,3	27,0	10,72
$h_{üst}$ (m)	180	3,0	36,3	16,9	7,09
N (adet/ha)	180	137,5	6300,0	741,6	770,78
G (m^2/ha)	180	1,97	91,44	32,05	15,56
V (m^3/ha)	180	10,00	1027,36	327,03	207,64

4.4 Döküm Miktarlarına İlişkin Bulgular

Döküm verilerini elde etmek üzere farklı meşcere özelliklerine sahip 30 adet örnek alan tesis edilmiştir (Çizelge 4.5). Tesis edilen bu alanlarda 2019 yılı Mayıs-Aralık ayları süresince döküm verileri elde edilmiştir (Çizelge 4.6). Ocak – Nisan aylarında hava şartlarından dolayı veri alınamamıştır. Elde edilen dökümler ibre, dal, kozalak, kabuk, erkek çiçek ve diğer (tohum, yosun, liken, ökse otu vb.) olmak üzere 6 sınıfa ayrılarak ayrı ayrı değerlendirilmiştir. Elde edilen verilere göre ibre dökümü en fazla Eylül ayında olmuştur. Haziran ayında en fazla dal, kozalak, kabuk ve diğer dökümler gerçekleşmiştir. Erkek çiçek dökümünün birbirine yakın değerler olmakla birlikte Haziran ve Temmuz aylarında en yüksek miktarda olduğu görülmüştür. Mayıs, Haziran

ve Temmuz ayları ibre dökümünün minimum olduğu aylardır. Aralık ayında ise sert geçen hava şartlarından dolayı ani bir artış gözlemlenmiştir. Kasım ayında dal, Aralık ayında ise kozalak dökümüne rastlanmamıştır. Bu durum o aylarda hiç dal veya kozalak dökümü olmadığını göstermemektedir. Bu dökümler ağır materyaller oldukları ve birim alandaki sayıları daha az olduğu için kapanlara düşme ihtimalleri hafif materyallere göre daha düşüktür. O aylardaki dal ve kozalak döküm oranları da düşük olduğundan dolayı veri alınamamıştır.

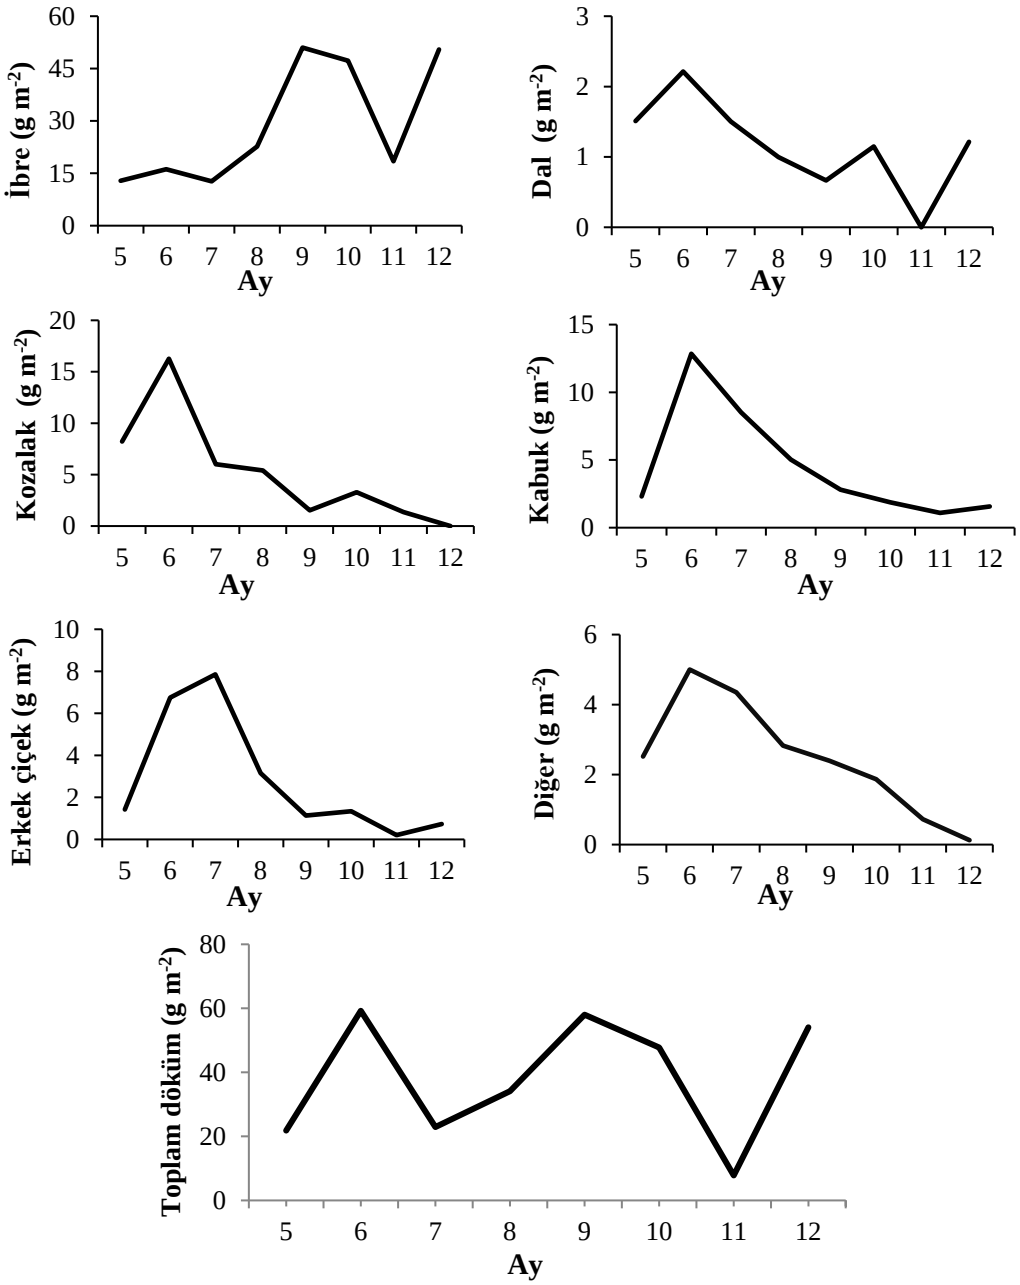
Çizelge 4.5 Döküm envanterinin yapıldığı örnek alanlara ait meşcere özellikleri

No	Meşcere tipi	Gelişim çağı	Bonitet	Yaş sınıfı	Kapalılık	Bakı	Yükselti
1	Çkbc3	c	2	3	3	K	1310
2	Çkcd3	d	2	6	3	K	1274
3	Çkcd3	d	2	6	3	K	1274
4	Çkcd3	d	2	6	3	K	1287
5	Çkcd3	d	2	6	3	K	1284
6	Çkbc3	b	2	3	3	K	1249
7	Çkbc3	b	2	3	3	K	1248
8	Çkd3	d	2	6	3	K	1331
9	Çkd3	d	2	6	3	K	1316
10	Çkd3	d	2	6	3	K	1333
11	Çkbc3	c	3	3	3	G	1365
12	Çkbc3	c	3	3	3	G	1403
13	Çkbc3	c	3	3	3	G	1361
14	Çkb3	b	3	2	3	G	1428
15	Çkb3	b	3	2	3	G	1428
16	Çkb3	b	3	2	3	G	1430
17	Çkc3	c	3	5	3	G	1477
18	Çkc3	c	3	5	3	G	1471
19	Çkcd3	d	2	5	3	G	1566
20	Çkcd3	d	2	5	3	G	1545
21	Çkcd3	d	2	5	3	G	1545
22	Çkd1	d	3	6	1	K	1251
23	Çkb3	b	3	2	3	K	1239
24	Çkd1	d	3	6	1	G	1298
25	Çkd1	d	3	6	1	G	1332
26	Çkd1	d	3	6	1	K	1254
27	Çkd1	d	3	6	1	K	1376
28	Çkc3	c	3	5	3	K	1365
29	Çkc3	c	2	5	3	K	1265
30	Çkc3	c	2	5	3	K	1256

Çizelge 4.6 2019 yılına ait birim alan için toplam ve ortalama döküm değerleri (g m^{-2})

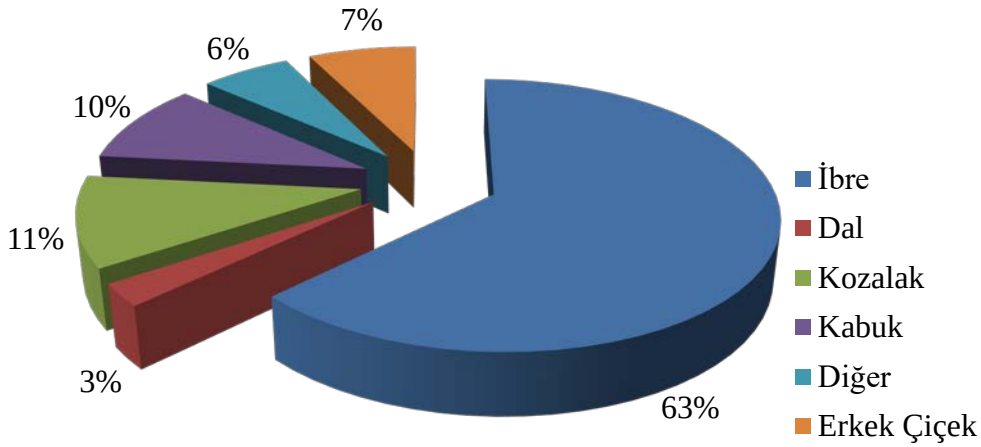
Yıl	Ay	İbre	Dal	Kozalak	Kabuk	Erkek Çiçek	Diğer	Toplam
2019	Mayıs	12,8510	1,5091	8,2272	2,3140	1,4235	2,5176	21,8424
	Haziran	16,1597	2,2137	16,2640	12,8446	6,7475	5,0004	59,2300
	Temmuz	12,7003	1,5038	6,0143	8,5139	7,8525	4,3527	22,9374
	Ağustos	22,6922	0,9976	5,4009	5,0240	3,1564	2,8276	34,0987
	Eylül	51,0090	0,6659	1,5246	2,8023	1,1385	2,3943	58,0100
	Ekim	47,2696	1,1479	3,2799	1,8750	1,3413	1,8689	47,7826
	Kasım	18,4410	0,0000	1,3513	1,0905	0,2047	0,7221	7,8095
	Aralık	50,4428	1,2150	0,0000	1,5693	0,7324	0,1262	54,0857

Dökümün alındığı aylar sürecinde ibre haricindeki döküm elemanlarının yıl içerisinde genel trendleri giderek azalan bir eğilim göstermiştir (Şekil 4.9). Aylara göre dağılımları ise birbirlerine oldukça benzer görülmektedir. İbre dökümünün zamana göre seyri ise artış eğilimindedir. İbre dökümü Ağustos ayı ile artışa başlayıp Eylül ayında maksimuma ulaşmıştır. İbre dökümü vejetasyon sürecinin bitmesine yakın yeniden artış göstermiştir. Bu süreçte diğer döküm elemanlarındaki döküm miktarlarının ise azalış eğiliminde olduğu görülmektedir.



Şekil 4.9 2019 yılı için aylık ortalama ve toplam döküm değerleri

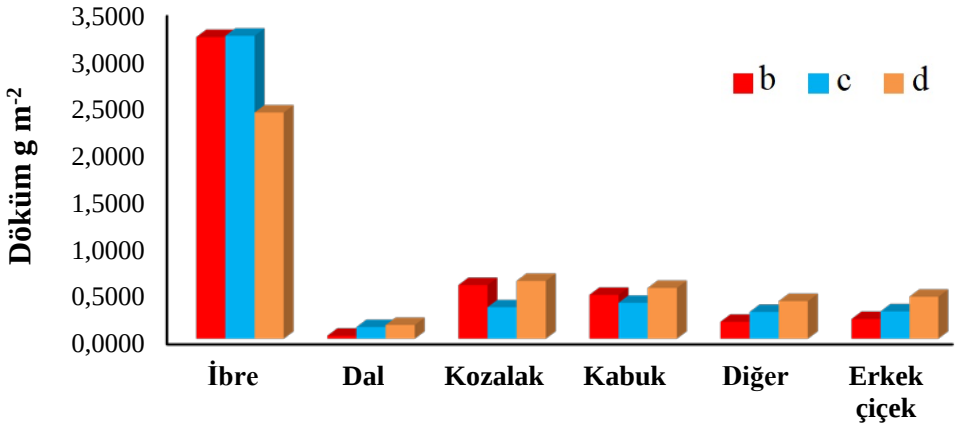
Toplam döküm oranlarında en büyük pay %63'lük oran ile ibre dökümüne aittir (Şekil 4.10). Ardından %10 ve 11'lik oran ile kabuk ve kozalak gelmektedir. En küçük pay ise dal dökümüne (%3) aittir. Toplam döküm oranlarına göre kabuk ve kozalak döküm miktarları birbirine çok yakındır. Aynı durum erkek çiçek ve diğer döküm için de geçerlidir.



Şekil 4.10 Yıllık toplam döküm içerisinde ibre, dal, kozalak, kabuk, erkek çiçek ve diğer döküm oranları

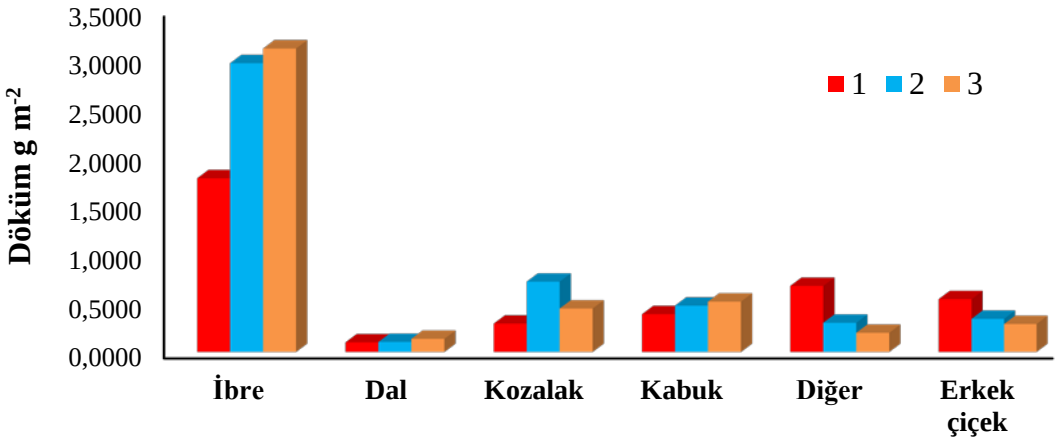
4.4.1 Döküm miktarlarının meşcere özelliklerine göre değişimi

Döküm envanteri için örnek alanlara yerleştirilen kapanlar “b” (8 – 19,9 cm), “c” (20 – 35,9 cm) ve “d” (36 cm <) gelişim çağları, 1 (%11 – 40), 2 (%41 - 70) ve 3 (%71 - 100) kapalılık sınıfları ve Güney – Kuzey bakılara göre yerleştirilmiştir. Bu özelliklere sahip meşcerelerden elde edilen döküm miktarlarının meşcere gelişim çağları, kapalılık sınıfları ve bakıya göre değişimleri incelenmiştir. Gelişim çağlarına göre ibre dökümü “b” ve “c” çağlarında benzer, “d” çağında ise daha az miktarda ölçülmüştür (Şekil 4.11). Döküm alanlarında “d” çağındaki meşcerelerin tamamı 1 kapalıdır. Yaşlı ve kapalılık oranı düşük meşcerelerde daha az miktarda ibre dökümü gerçekleşmiştir. Kozalak ve kabuk dökümü diğer çağlara göre “c” çağında daha düşüktür. Dal, erkek çiçek ve diğer dökümler ise çap artışı ile artan bir seyir göstermektedir.



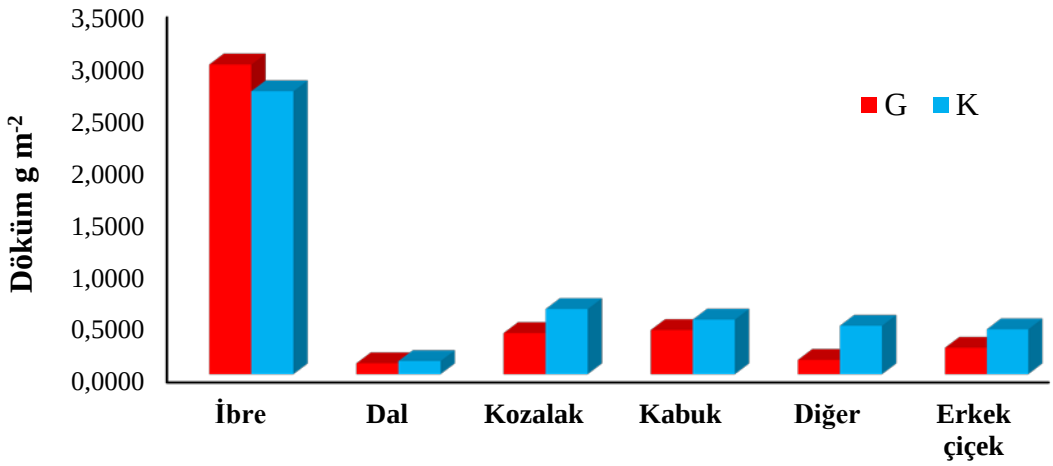
Şekil 4.11 Döküm miktarlarının meşcere gelişim çağlarına göre değişimi

İbre dökümü özellikle 2 ve 3 kapalı meşcerelerde, 1 kapalı meşcerelere göre daha fazladır (Şekil 4.12). 2 ve 3 kapalı meşcerelerde birim alandaki ibre miktarı daha fazla olduğundan dolayı bu beklenen bir durumdur. Kozalak dökümü daha çok 2 kapalı meşcerelerde tespit edilmiştir. Erkek çiçek ve diğer dökümler kapalılıkla ters orantılı olarak azalan bir eğilim göstermektedir. Diğer döküm miktarı 1 kapalı meşcerelerde daha yüksek ölçülmüştür.



Şekil 4.12 Döküm miktarlarının kapalılık sınıflarına göre değişimi

Güney bakılardaki ibre dökümünün kuzey bakılara göre kısmen daha fazla olduğu gözlemlenmiştir (Şekil 4.13). İbre haricindeki döküm elemanları ise farklı oranlarda olmakla birlikte kuzey bakılarda daha fazla belirlenmiştir.



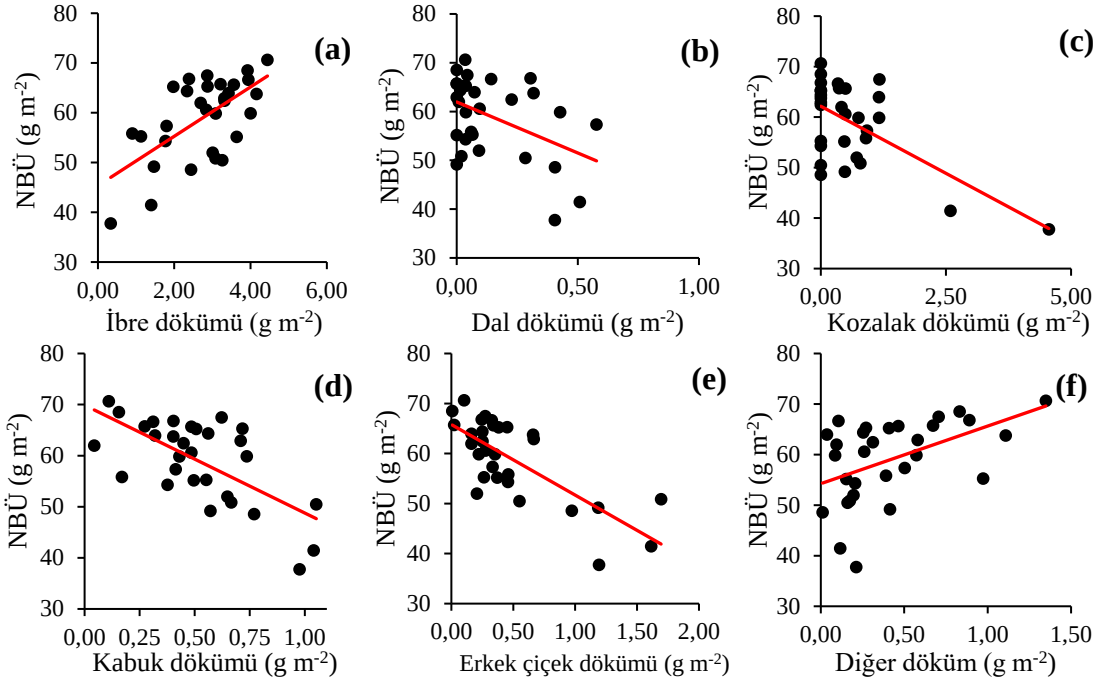
Şekil 4.13 Döküm miktarlarının bakıya göre değişimi

4.4.2 Döküm elemanları kullanılarak NBÜ verilerinin geçerlilik kontrolü

CASA modeli ile hesaplanan NBÜ'nün geçerliliğinin kontrolü için yersel birincil üretim verisi olmadığından dolayı bu kontrol döküm verileri ile yapılmıştır. NBÜ ve döküm verileri arasındaki ilişkinin gücü analiz edilmiş ve hesaplanan NBÜ verilerinin geçerliliği kontrol edilmiştir (Çizelge 4.7). Analiz için 90 adet kovadan döküm verileri alınarak her bir örnek alana ilişkin ortalama miktarlar hesaplanmıştır. 90 ayrı döküm verisi olmasına karşın her bir kovanın dahil olduğu alana ait NBÜ verisi üretilemediği için 90 veri yerine örnek alanlara ait 30 adet ortalama veri ile analiz yapılmıştır.

NBÜ ile döküm elemanları arasında ibre ve diğer döküm ile pozitif yönde, dal, kozalak, kabuk ve erkek çiçek ile negatif yönde ilişkili belirlenmiştir (Çizelge 4.7, Şekil 4.14). Meşcerelerin gelişim seyirlerinde birincil üretimin artış gösterdiği dönemlerde erkek çiçek dökümü azalırken, üretimin azaldığı yaşlı meşcerelerde erkek çiçek dökümü artmaktadır (Şekil 4.11). En yüksek ilişki seviyesi -0,75 korelasyon katsayısı ile NBÜ ile erkek çiçek dökümü arasında gözlemlenmiştir. Bununla birlikte 0,63'lük korelasyon

katsayısı ile ibre dökümü de NBÜ ile ilişkili bulunmuştur. Kabuk ve kozalak dökümü ile NBÜ arasında da 0,60'ın üzerinde korelasyon seviyesi bulunmaktadır.



Şekil 4.14 NBÜ ile döküm elemanları arasındaki ilişkiler; a) ibre, b) dal, c) kozalak, d) kabuk, e) erkek çiçek ve f) diğer döküm

Çizelge 4.7 NBÜ ve döküm elemanları arasındaki ilişki seviyeleri

	İbre	**Dal**	**Kozalak**	**Kabuk**	**Erkek çiçek**	**Diğer**
r	0,63	-0,45	-0,62	-0,66	-0,75	0,48
R^2	0,40	0,20	0,38	0,43	0,56	0,23
Denklem	27	28	29	30	31	32

$$NB\ddot{U} = 45{,}354 + (4{,}9588 x İbre\ dökümü) \quad (27)$$

$$NB\ddot{U} = 61{,}96 - (20{,}913 x Dal\ dökümü) \quad (28)$$

$$NB\ddot{U} = 62{,}157 - (5{,}3164 x Kozalak\ dökümü) \quad (29)$$

$$NB\ddot{U} = 69{,}876 - (21{,}106 x Kabuk\ dökümü) \quad (30)$$

$$NB\ddot{U} = 65{,}797 - (14{,}102 x Erkek\ çiçek\ dökümü) \quad (31)$$

$$NB\ddot{U} = 54{,}252 + (11{,}391 x Diğer\ döküm) \quad (32)$$

4.5 Net Birincil Üretim, Yaprak Alan İndeksi ve Meşcere Parametrelerinin Modellenmesi

4.5.1 Yersel veriler ile modelleme

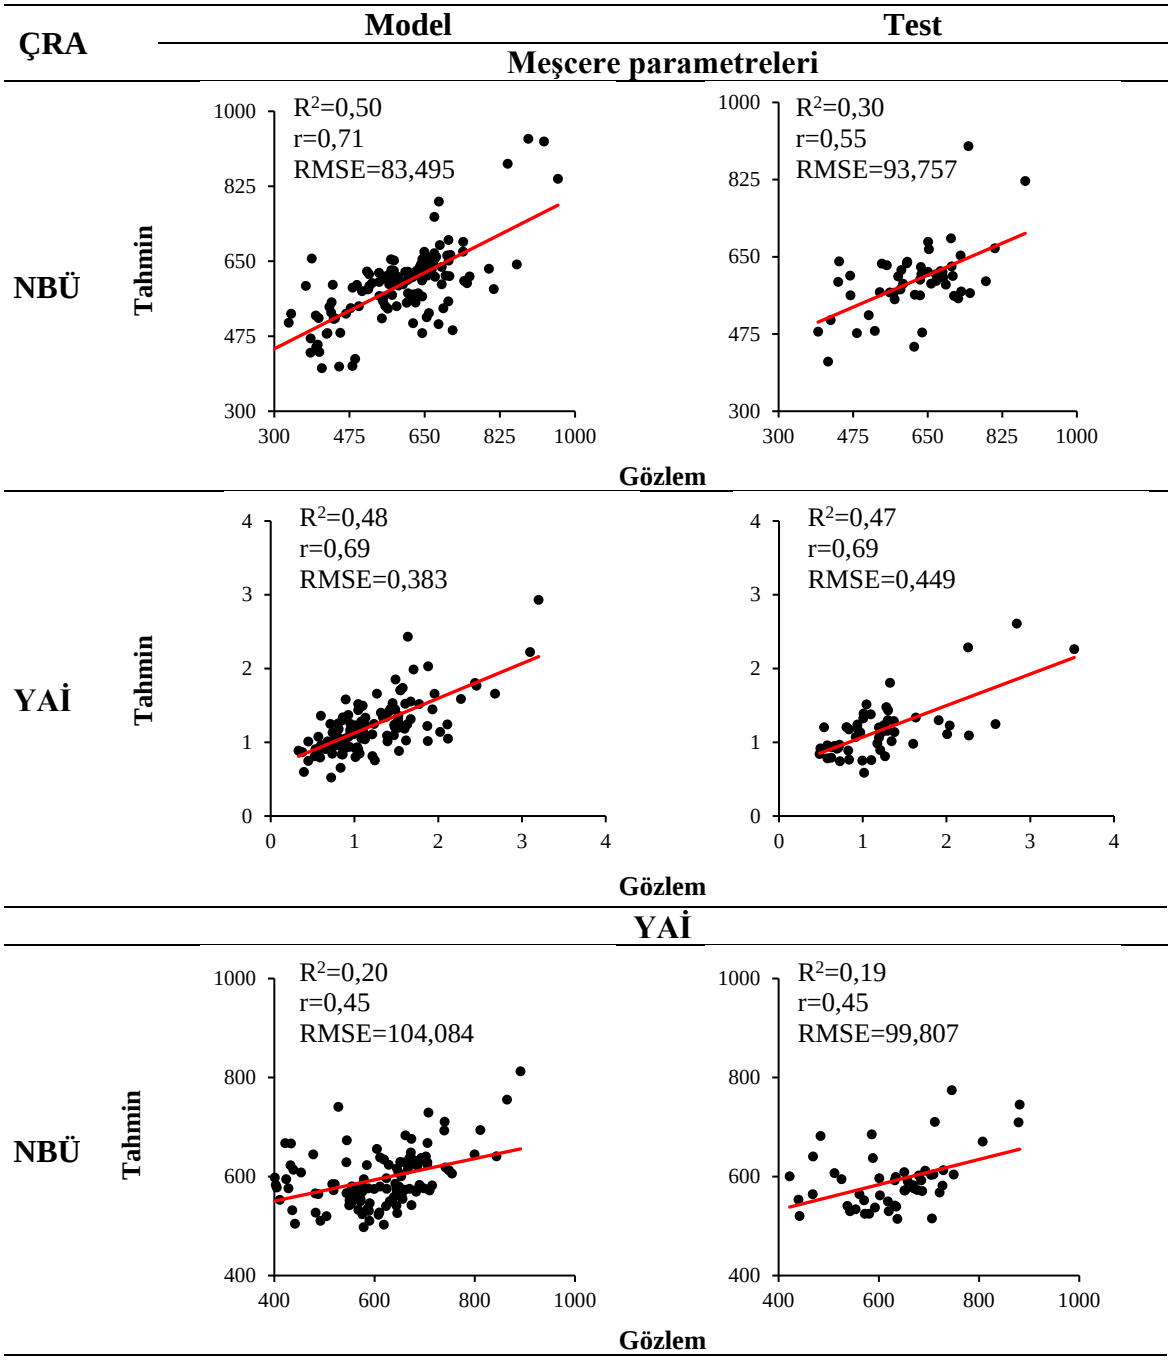
Envanter çalışmasından elde edilen yersel veri setleri, hesaplanan meşcere parametrelerinden (dg, $h_{üst}$, N, G ve V) oluşmaktadır. Meşcere parametreleri kullanılarak NBÜ ve YAİ modellenmiştir. Bunun yanında NBÜ'nün sadece YAİ kullanılarak modellenebilme seviyesini belirlemek için NBÜ-YAİ modeli oluşturulmuştur. Modelleme için veri setlerinin %70'i model, %30'u ise test için ayrılmıştır. Modelleme aşamasında ÇRA, DVM ve DÖ teknikleri kullanılmıştır.

$$NB\ddot{U} = 609{,}986 - (6{,}637\ x\ h\ddot{u}st) + (0{,}053\ x\ N) + (6{,}572\ x\ G) - (0{,}480\ x\ V) \quad (33)$$

$$YA\dot{I} = 0{,}917 - (0{,}018\ x\ dg) + (0{,}0000032\ x\ N) + (0{,}017\ x\ G) \quad (34)$$

$$NB\ddot{U} = 461{,}246 + (109{,}821\ x\ YA\dot{I}) \quad (35)$$

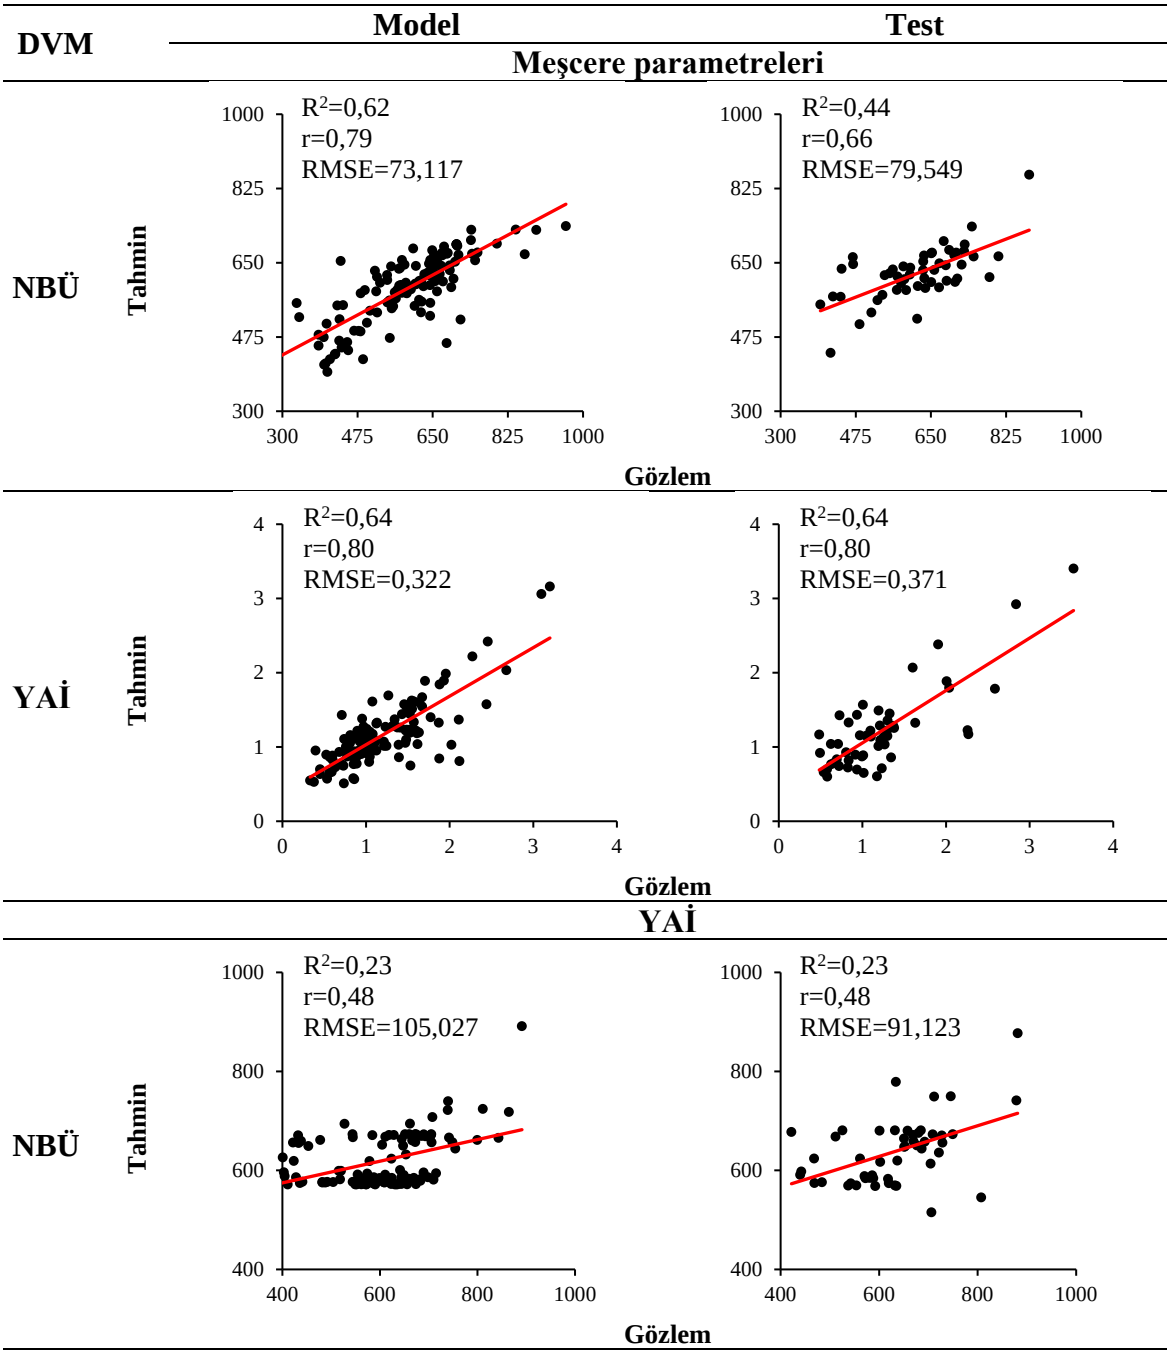
İlk aşama olarak ÇRA metodu uygulanmıştır. Böylece bağımlı değişken için oluşturulacak modelde anlamlı olan bağımsız değişkenler belirlenmiştir. NBÜ için oluşturulan modele giren meşcere parametreleri $h_{üst}$, N, G ve V'dir. Oluşan modelin belirtme katsayısı 0,50 bulunmuştur ve aynı modelde test verileri koşturulduğunda bu değer 0,30'a düşmüştür (Şekil 4.15). Test başarısının bir miktar düşmesi beklenen bir durumdur. Çünkü model, modelleme aşamasında hiç karşılaşmadığı ayrı bir veri seti ile denenmiştir. NBÜ modelinin test hatası ise 93,757 gC m^{-2} $yıl^{-1}$ bulunmuştur. YAİ için oluşturulan modelde dg, N ve G anlamlı parametreler olarak modele girmiştir. Model başarısı yüksek olmamakla birlikte, model-test arasında başarı farkı çıkmamıştır (Model R^2=0,48, Test R^2=0,47). Bu durum modelin başarı düzeyine göre farklı veriler için de uygulanabileceğini ve kararlı bir yapıda olduğunu göstermektedir. NBÜ'nün YAİ ile oluşturulan modelinde her ne kadar model-test arasında fark çıkmamasına rağmen, model başarısı düşük seviyede gözlemlenmiştir (R^2=0,20). Oluşturulan NBÜ-YAİ modelinin hata değeri 99,807 gC m^{-2} $yıl^{-1}$'dir.



Şekil 4.15 ÇRA metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri

Oluşturulan ÇRA modelleri ile anlamlı bağımsız değişkenler belirlenmiştir. Bu aşamanın ardından veri setleri model-test veri grupları şeklinde hazırlanmıştır. Bağımlı ve bağımsız değişkenler arasındaki ilişkiler DVM ve DÖ metotları kullanılarak modellenmiştir. NBÜ'nün meşcere parametreleri ile modellenmesinde DVM

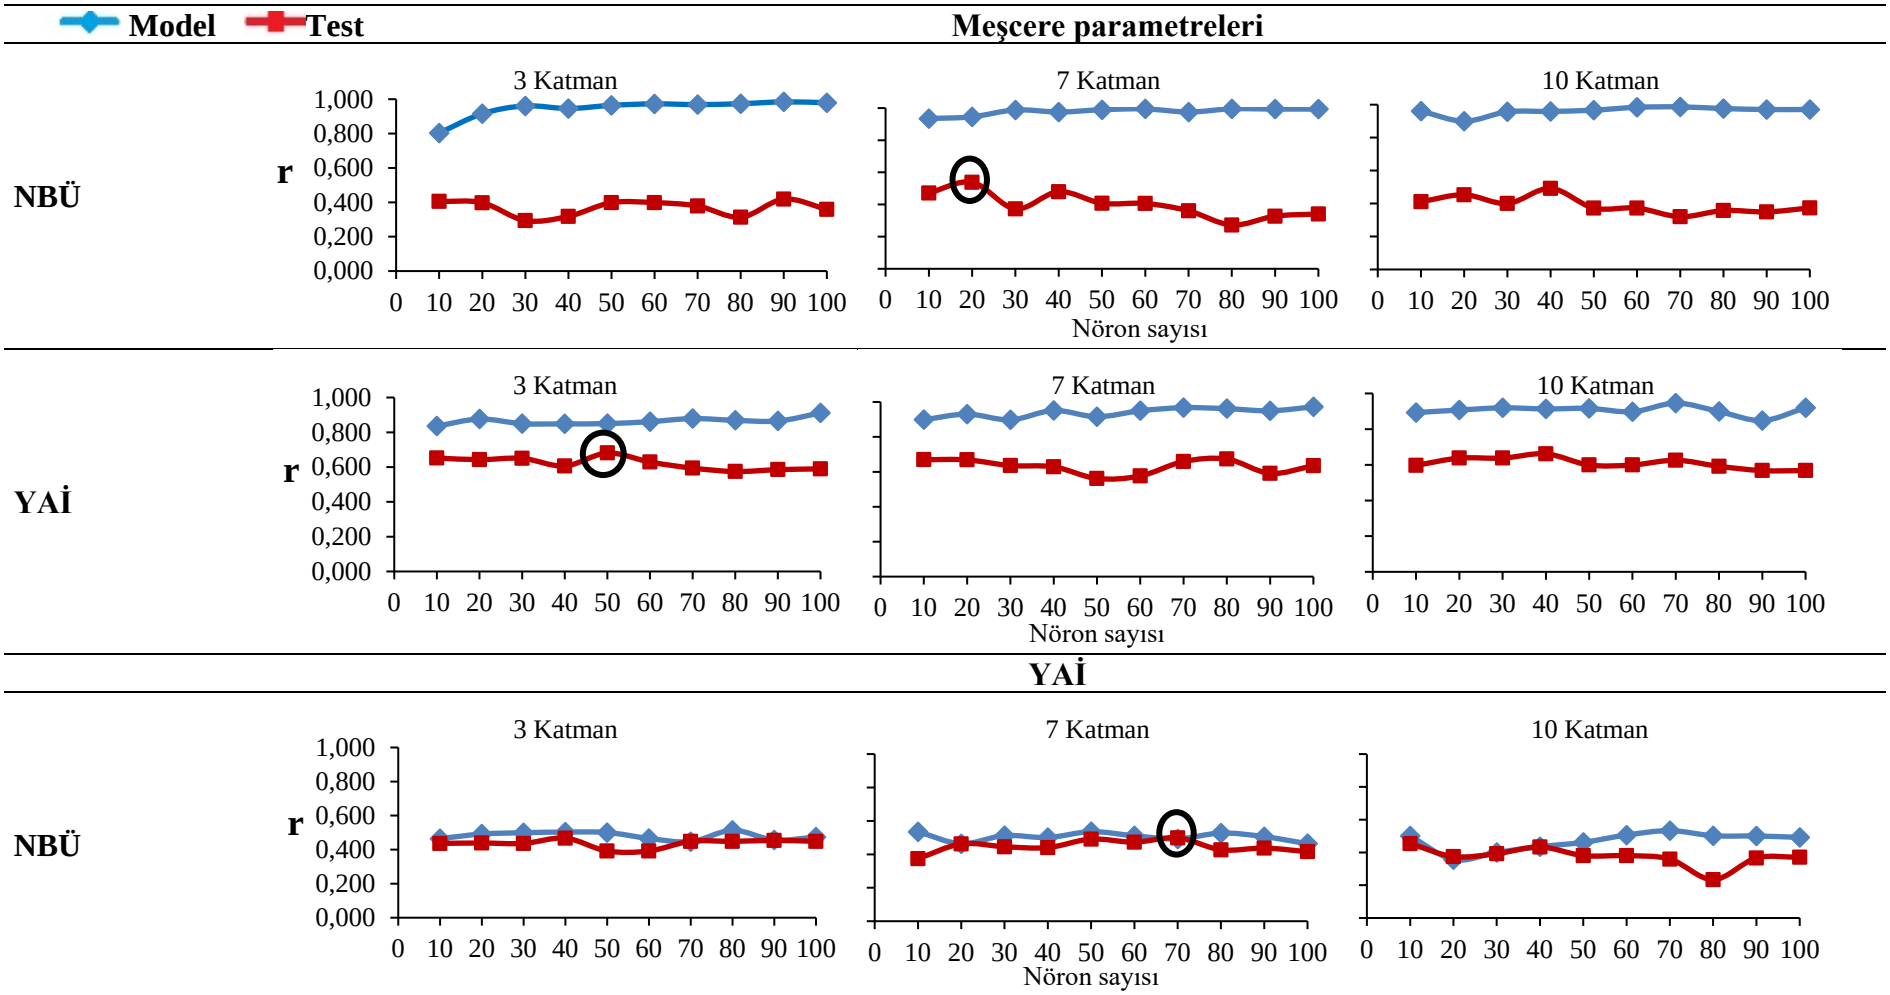
metodunun performansı ÇRA metoduna göre daha yüksek seviyede bulunmuştur (Şekil 4.16). Modellerin tahminleri ve gözlemleri arasındaki benzerlikler kıyaslandığında ÇRA metodunun benzerliği 0,71 iken DVM metodu için bu değer 0,79 bulunmuştur. Test sonucunda da DVM daha başarılı çıkmıştır (r=0,66). YAİ'nin modellenmesinde de başarı açısından benzer durum görülmektedir. ÇRA metodu model veri seti için YAİ'yi 0,383 m^2 m^{-2}'lik hata ile modellerken, DVM metoduna ait hata 0,322 m^2 m^{-2}'dir. Bunun yanında DVM metodunun model ve test başarısı arasında bir fark gözlemlenmemiştir (Model R^2=0,64, Test R^2=0,64). NBÜ ile YAİ arasındaki DVM modelinde ÇRA metoduna göre kayda değer bir başarı artışı elde edilememiştir.



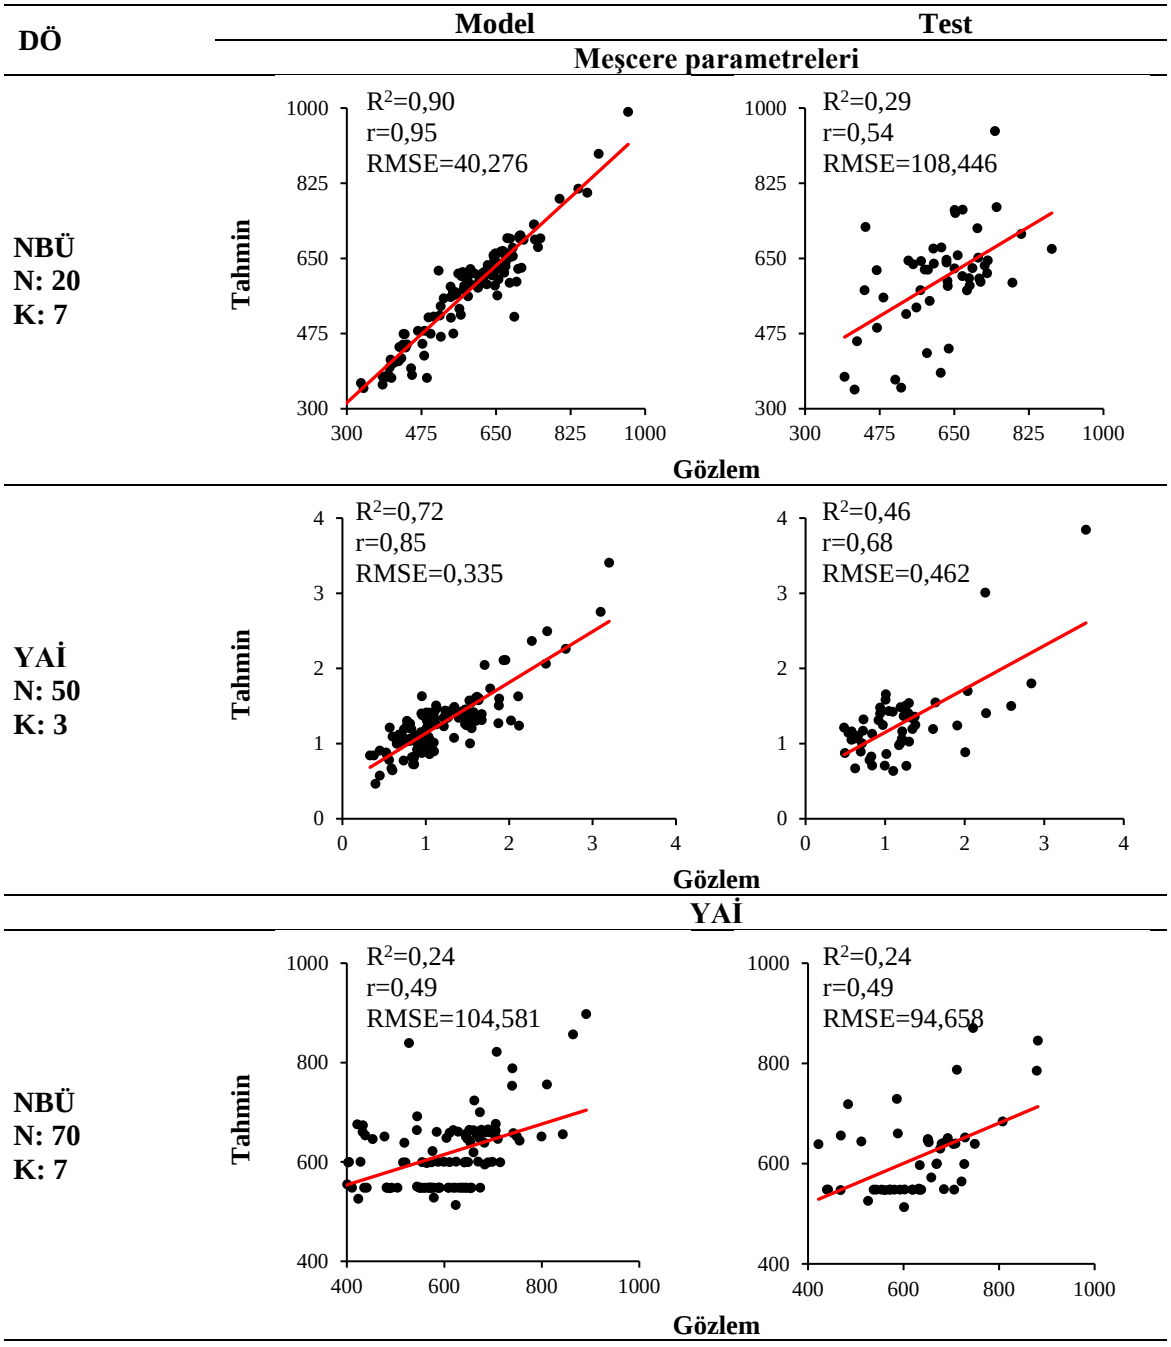
Şekil 4.16 DVM metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri

ÇRA modellerinden alınan bağımsız değişkenler ile DÖ metodu farklı nöron ve katman sayıları için uygulanmıştır (Şekil 4.17). Katmanlar 3, 7 ve 10 şeklinde, nöron sayıları ise 10'dan başlayarak onar aralıklar ile 100'e kadar denenmiştir. Böylece her bir model için 30 adet model ağ eğitimi yapılmıştır. Oluşturulan modellerden model-test başarıları

birbirine en yakın ve test başarısı en yüksek olan ağ seçilerek Şekil 4.17'de bulunan başarı grafikleri üzerinde işaretlenmiştir. Seçilen en uygun model bulguları ile diğer metotlar kıyaslama karşılaştırılmıştır (Şekil 4.18). Yapılan tahminlerde model ve test arasında yüksek oranda bir fark olmaması beklenmektedir. Fakat DÖ metodunda sıkça karşılaşılan aşırı uyum problemi nedeni ile model yüksek oranda başarı gösterirken, aynı modelde bağımsız bir veri seti ile test yapıldığında başarı çok düşük seviyelere inebilmektedir. NBÜ'nün meşcere parametreleri ile eğitilen model tahminleri yüksek başarı sağlamıştır (r=0,95). Fakat test başarısı düşük seviyede olup model başarısına denk değildir (r=0,54). Hazırlanan başarı grafiklerinde görüldüğü üzere NBÜ-meşcere parametreleri için model ve test başarı seviyeleri arasındaki fark oldukça fazladır (Model R^2=0,90, Test R^2=0,29). YAİ-meşcere parametreleri için bu fark daha az (Model R^2=0,72, Test R^2=0,46), NBÜ-YAİ için ise model-test başarı bulguları birbirine benzerdir (Model R^2=0,24, Test R^2=0,24).



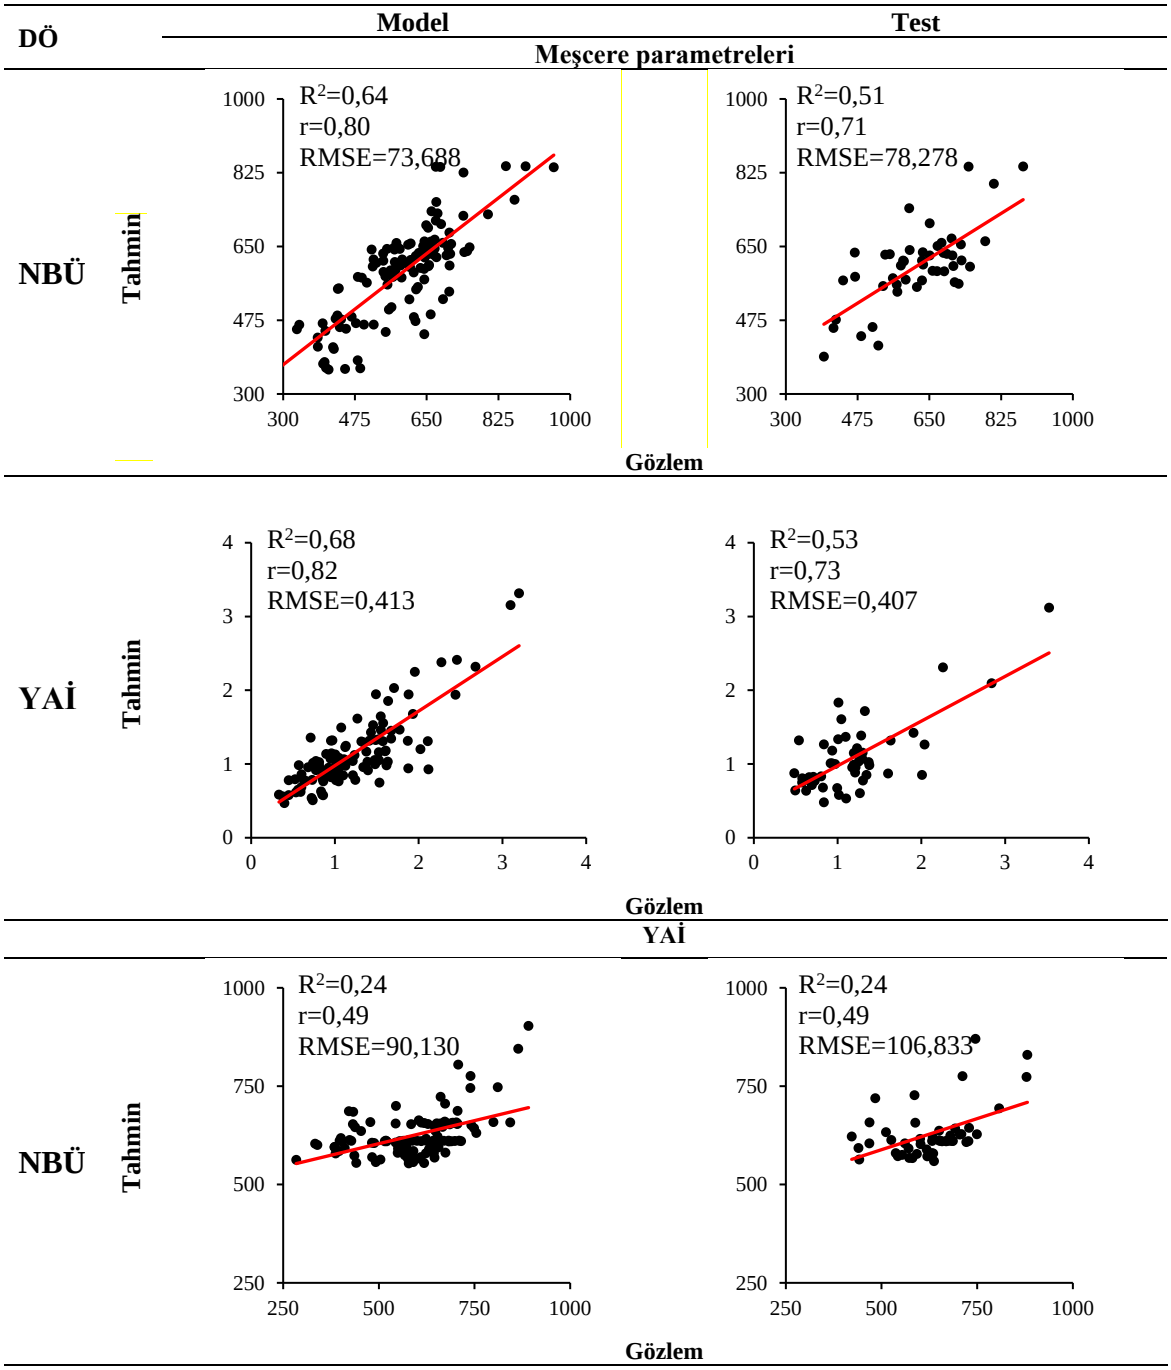
Şekil 4.17 DÖ metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ model ve testlerinin değişen nöron ve katman sayılarına göre korelasyon değişimi



Şekil 4.18 DÖ metodu kullanılarak NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri (N: nöron sayısı, K: katman sayısı)

Uygulanan DÖ metodunda özellikle NBÜ'nün ve YAİ'nin meşcere parametreleri ile oluşturulan modellerinde aşırı uyum problemi, NBÜ'nün YAİ ile modellenmesinde ise sıralı tahminler görülmüştür. Oluşan problemleri gidermek için metoda erken durdurma, ağ indirgeme, veri genişleme ve düzenleme argümanları eklenerek tekrar

koşturulmuştur. Bu argümanlar kullanılarak ağın model veri setini öğrenmesi, bağımsız veri gruplarında modelleme başarısının istenilen düzeylerde elde edilmesi ve temsil kabiliyeti yüksek bir model ağı oluşturmak amaçlanmıştır. İlgili argümanların ilave edilmesi ile elde edilen bulgular Şekil 4.19'da sunulmuştur.



Şekil 4.19 DÖ metoduna ilave argümanlar eklenerek koşturulan NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen gözlem ve tahmin grafikleri

4.5.2 Uzaktan algılama verileri ile modelleme

Modelleme için kullanılan uzaktan algılamaya dayalı bağımsız değişkenler Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans, vejetasyon indisleri ve tekstür değerleridir. Tekstür değerleri farklı bant, filtre ve derecelere göre ayrı ayrı hesaplanmıştır. İlk aşamada modellenmesi amaçlanan bağımlı değişken, uzaktan algılama ile üretilen bağımsız değişkenler ile ÇRA'ya tabi tutulmuştur (Çizelge 4.8, 4.9 ve 4.10). Ardından anlamlı olan ($p<0,05$) bağımsız değişkenler belirlenmiş ve en yüksek ilişkinin görüldüğü bağımsız değişkenler ile DVM ve DÖ metotları uygulanmıştır.

Reflektans verileri ile en yüksek başarı Sentinel-2 uydu görüntüsü kullanılarak V (m^3) için bulunmuştur ($R^2=0,44$). Vejetasyon indislerinde ise Landsat 8 OLI uydu görüntüsü ile NBÜ için en yüksek başarıya ulaşılmıştır ($R^2=0,50$). Tekstür veri setlerine ilişkin model başarılarında Sentinel-2 uydu görüntüsü Landsat 8 OLI'ye göre başarılı bulunmuştur. Genel değerlendirmede en yüksek başarıların tamamı Sentinel-2 uydu görüntüsünden üretilen tekstür değerleri ile elde edilmiştir.

Çizelge 4.8 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen reflektans ve vejetasyon indisleri ile NBÜ, YAİ ve meşcere parametreleri için uygulanan ÇRA model belirtme katsayıları (R^2)

Parametre	Landsat 8 OLI		Sentinel-2	
	Reflektans	Vejetasyon indisi	Reflektans	Vejetasyon indisi
NBÜ (gC m^{-2})	0,35	0,50	0,32	0,21
YAİ (m^2 m^{-2})	0,30	0,28	0,33	0,26
dg (cm)	0,23	0,25	0,23	0,20
$h_{üst}$ (m)	0,42	0,40	0,24	0,28
N (adet)	0,15	0,17	0,14	0,16
G (m^2)	0,34	0,42	0,41	0,45
V (m^3)	0,40	0,47	0,44	0,47

Çizelge 4.9 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı filtre tekstür verileri ile NBÜ, YAİ ve meşcere parametreleri için uygulanan ÇRA model belirtme katsayıları (R^2)

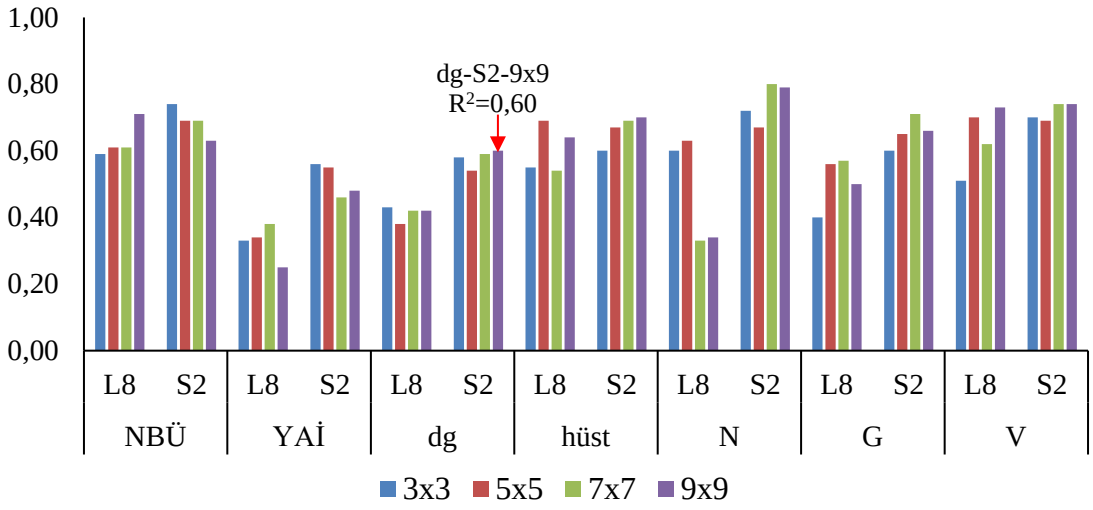
Parametre	Landsat 8 OLI				Sentinel-2			
	3x3	**5x5**	**7x7**	**9x9**	**3x3**	**5x5**	**7x7**	**9x9**
NBÜ (gC m^{-2})	0,59	0,61	0,61	0,71	0,74	0,69	0,69	0,63
YAİ (m^2 m^{-2})	0,33	0,34	0,38	0,25	0,56	0,55	0,46	0,48
dg (cm)	0,43	0,38	0,42	0,42	0,58	0,54	0,59	0,60
$h_{üst}$ (m)	0,55	0,69	0,54	0,64	0,60	0,67	0,69	0,70
N (adet)	0,60	0,63	0,33	0,34	0,72	0,67	0,80	0,79
G (m^2)	0,40	0,56	0,57	0,50	0,60	0,65	0,71	0,66
V (m^3)	0,51	0,70	0,62	0,73	0,70	0,69	0,74	0,74

Çizelge 4.10 Landsat 8 OLI ve Sentinel-2 uydu görüntülerinden elde edilen farklı derece tekstür verileri ile NBÜ, YAİ ve meşcere parametreleri için uygulanan ÇRA model belirtme katsayıları (R^2)

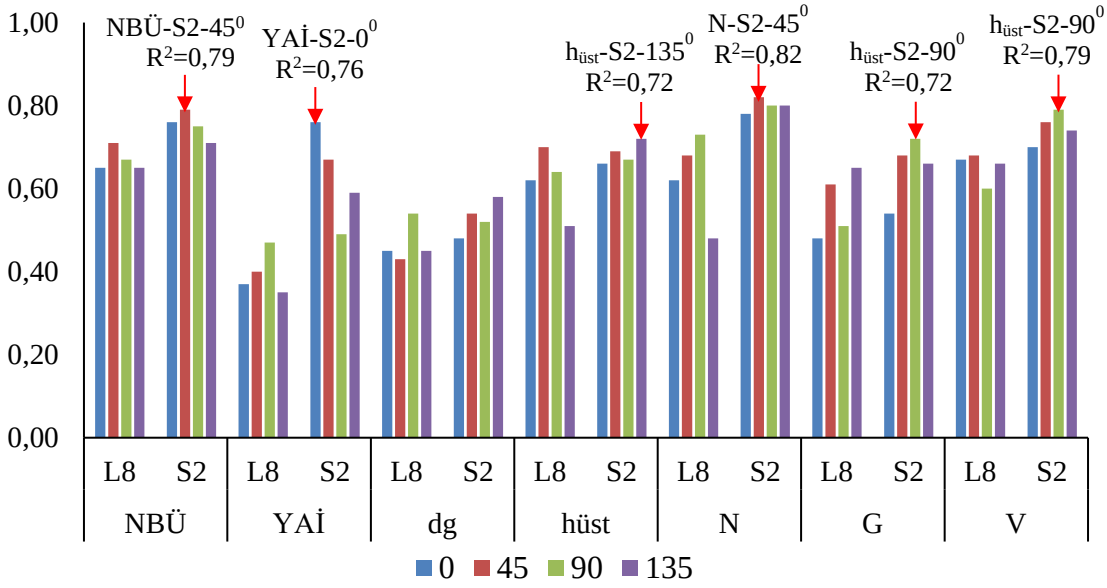
Parametre	Landsat 8 OLI				Sentinel-2			
	0°	**45°**	**90°**	**135°**	**0°**	**45°**	**90°**	**135°**
NBÜ (gC m^{-2})	0,65	0,71	0,67	0,65	0,76	0,79	0,75	0,71
YAİ (m^2 m^{-2})	0,37	0,40	0,47	0,35	0,76	0,67	0,49	0,59
dg (cm)	0,45	0,43	0,54	0,45	0,48	0,54	0,52	0,58
$h_{üst}$ (m)	0,62	0,70	0,64	0,51	0,66	0,69	0,67	0,72
N (adet)	0,62	0,68	0,73	0,48	0,78	0,82	0,80	0,80
G (m^2)	0,48	0,61	0,51	0,65	0,54	0,68	0,72	0,66
V (m^3)	0,67	0,68	0,60	0,66	0,70	0,76	0,79	0,74

4.5.2.1 ÇRA metodunda en yüksek başarıyı sağlayan modeller

Uygulanan ÇRA metoduna ait başarı bulgularına göre uzaktan algılama veri setlerinde en yüksek başarı tekstür değerleri ile sağlanmıştır. Özellikle veri setinin derece ve filtre bakımından çeşitlendirilmesi modellemenin başarısına büyük oranda katkı sağlamıştır. Farklı filtreler kullanılarak dg (cm) için en yüksek başarı 9x9 filtre ile sağlanmıştır (R^2=0,60). Diğer bütün parametreler için en yüksek başarı farklı dereceler için üretilen tekstür değerleri ile elde edilmiştir. 0° tekstür verileri ile YAİ, 45° tekstür verileri ile NBÜ ve N, 90° tekstür verileri ile G ve V, 135^0 tekstür verileri ile de $h_{üst}$ için en yüksek oranlı başarılar sağlanmıştır (Şekil 4.20, 4.21).



Şekil 4.20 ÇRA metou kullanılarak farklı filtrelere göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) grafiği, (Landsat 8 OLI: L8, Sentinel-2: S2)



Şekil 4.21 ÇRA metou kullanılarak farklı derecelere göre hesaplanan tekstür değerleri ile modellenen meşcere parametrelerinin belirtme katsayıları (R^2) grafiği, (Landsat 8 OLI: L8, Sentinel-2: S2)

Çizelge 4.11-17'de 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 filtre ve derece sırası ile kodlanmıştır.

Çizelge 4.11 Sentinel-2 uydu görüntüsünden 45° tekstür verileri ile elde edilen NBÜ modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	-421,378	-2,212	0,029
CONT_S7_9_45	-84,802	-4,272	0,000
M_S2_9_45	134,426	2,847	0,005
SM_S3_5_45	460,431	5,959	0,000
M_S12_3_45	-134,682	-8,670	0,000
VAR_S5_5_45	249,963	5,409	0,000
M_S5_5_45	164,483	5,518	0,000
HOM_S8_9_45	930,691	5,401	0,000
VAR_S6_3_45	134,663	4,203	0,000
SM_S8_9_45	-233,160	-3,884	0,000
HOM_S3_7_45	-598,540	-3,789	0,000
VAR_S3_5_45	679,465	3,920	0,000
VAR_S5_3_45	-169,123	-2,119	0,036
COR_S5_3_45	-41,713	-3,014	0,003
COR_S8A_3_45	29,063	2,556	0,012
HOM_S5_5_45	254,430	2,775	0,007
VAR_S4_3_45	-197,751	-2,380	0,019
ENT_S11_3_45	28,402	2,064	0,041
R^2 = 0,79	r = 0,89	MAE = 40,722	RMSE = 54,321

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 0° tekstür verileri ile elde edilen YAİ modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	11,821	7,925	0,000
M_S2_3_0	-2,004	-6,464	0,000
VAR_S3_9_0	2,199	7,684	0,000
M_S12_3_0	-,449	-7,464	0,000
M_S6_9_0	1,795	4,358	0,000
VAR_S6_9_0	-,307	-2,301	0,023
COR_S5_9_0	-,291	-2,228	0,028
SM_S8_3_0	,379	3,727	0,000
HOM_S12_3_0	-2,286	-6,151	0,000
COR_S6_3_0	,414	5,353	0,000
SM_S12_7_0	1,036	4,806	0,000
COR_S3_3_0	,394	5,806	0,000
CONT_S4_7_0	-1,160	-3,065	0,003
COR_S7_3_0	-,245	-3,450	0,001
DİS_S7_7_0	-1,004	-2,877	0,005
DİS_S5_7_0	-2,870	-5,329	0,000
HOM_S11_9_0	-2,857	-4,644	0,000
HOM_S5_5_0	-4,448	-4,018	0,000
M_S7_9_0	-1,147	-2,857	0,005
CONT_S11_5_0	-,291	-2,898	0,005
CONT_S5_3_0	-,655	-2,563	0,012
DİS_S8A_5_0	,551	2,241	0,027
R^2 = 0,76	r = 0,87	MAE = 0,235	RMSE = 0,288

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 9x9 filtre tekstür verileri ile elde edilen dg modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	82,156	8,761	0,000
DİS_S7_9_45	30,627	5,333	0,000
M_S2_9_90	-30,650	-7,099	0,000
COR_S12_9_135	-12,349	-2,723	0,007
COR_S3_9_135	-12,670	-4,570	0,000
VAR_S8_9_0	6,762	4,310	0,000
CONT_S7_9_0	-18,605	-3,276	0,001
COR_S8A_9_135	-8,216	-3,099	0,002
COR_S3_9_45	6,537	2,465	0,015
SM_S11_9_135	12,677	2,952	0,004
COR_S12_9_90	10,960	2,039	0,044
R^2 = 0,60	r = 0,78	MAE = 5,219	RMSE = 6,652

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

Çizelge 4.14 Sentinel-2 uydu görüntüsünden 135° tekstür verileri ile elde edilen $h_{üst}$ modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	27,706	3,294	0,001
M_S3_9_135	-5,204	-4,043	0,000
M_S2_9_135	-54,739	-3,516	0,001
COR_S8A_3_135	-2,833	-4,010	0,000
COR_S8A_9_135	-5,427	-3,564	0,001
COR_S6_7_135	3,150	2,110	0,037
ENT_S5_7_135	-2,908	-3,745	0,000
VAR_S8_9_135	4,485	7,521	0,000
COR_S5_7_135	-3,229	-2,411	0,018
ENT_S2_9_135	16,737	4,426	0,000
COR_S3_9_135	-2,703	-2,072	0,041
SM_S2_7_135	22,226	2,909	0,004
M_S2_7_135	45,042	2,785	0,006
R^2 = 0,72	r = 0,85	MAE = 2,873	RMSE = 3,735

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 45° tekstür verileri ile elde edilen N modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	-3529,115	-4,591	0,000
VAR_S4_9_45	-1377,121	-3,224	0,002
CONT_S4_7_45	1937,429	3,891	0,000
ENT_S7_5_45	-523,327	-4,047	0,000
DİS_S4_7_45	-2939,160	-4,219	0,000
VAR_S4_7_45	1575,171	2,531	0,013
VAR_S2_9_45	9395,033	8,178	0,000
SM_S2_3_45	1148,198	4,832	0,000
SM_S2_9_45	1512,600	3,813	0,000
CONT_S11_5_45	138,679	3,880	0,000
M_S7_5_45	252,378	4,319	0,000
HOM_S8_9_45	2464,238	5,587	0,000
COR_S8_5_45	-285,469	-3,914	0,000
COR_S6_3_45	298,374	4,245	0,000
VAR_S5_7_45	-459,998	-3,031	0,003
ENT_S7_3_45	364,713	3,197	0,002
HOM_S6_9_45	-1578,508	-2,557	0,012
R^2 = 0,82	r = 0,91	MAE = 205,585	RMSE = 281,722

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

Çizelge 4.16 Sentinel-2 uydu görüntüsünden 90° tekstür verileri ile elde edilen G modeli

Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	-80,071	-2,136	0,035
M_S2_9_90	-74,219	-7,979	0,000
CONT_S8A_3_90	28,484	5,712	0,000
M_S12_3_90	-14,201	-6,833	0,000
COR_S8_7_90	-15,424	-5,181	0,000
M_S4_5_90	40,991	5,295	0,000
COR_S12_5_90	-9,497	-2,993	0,003
CONT_S11_9_90	10,893	4,926	0,000
HOM_S5_7_90	78,809	4,654	0,000
CONT_S8_9_90	48,632	5,169	0,000
HOM_S8_7_90	111,106	4,353	0,000
HOM_S8A_5_90	43,488	2,650	0,009
COR_S2_3_90	10,287	2,849	0,005
ENT_S3_9_90	4,825	2,155	0,033
COR_S4_3_90	6,785	2,186	0,031
ENT_S4_9_90	10,390	3,267	0,001
CONT_S4_5_90	-25,258	-2,472	0,015
R^2 = 0,72	r = 0,85	MAE = 7,006	RMSE = 8,510

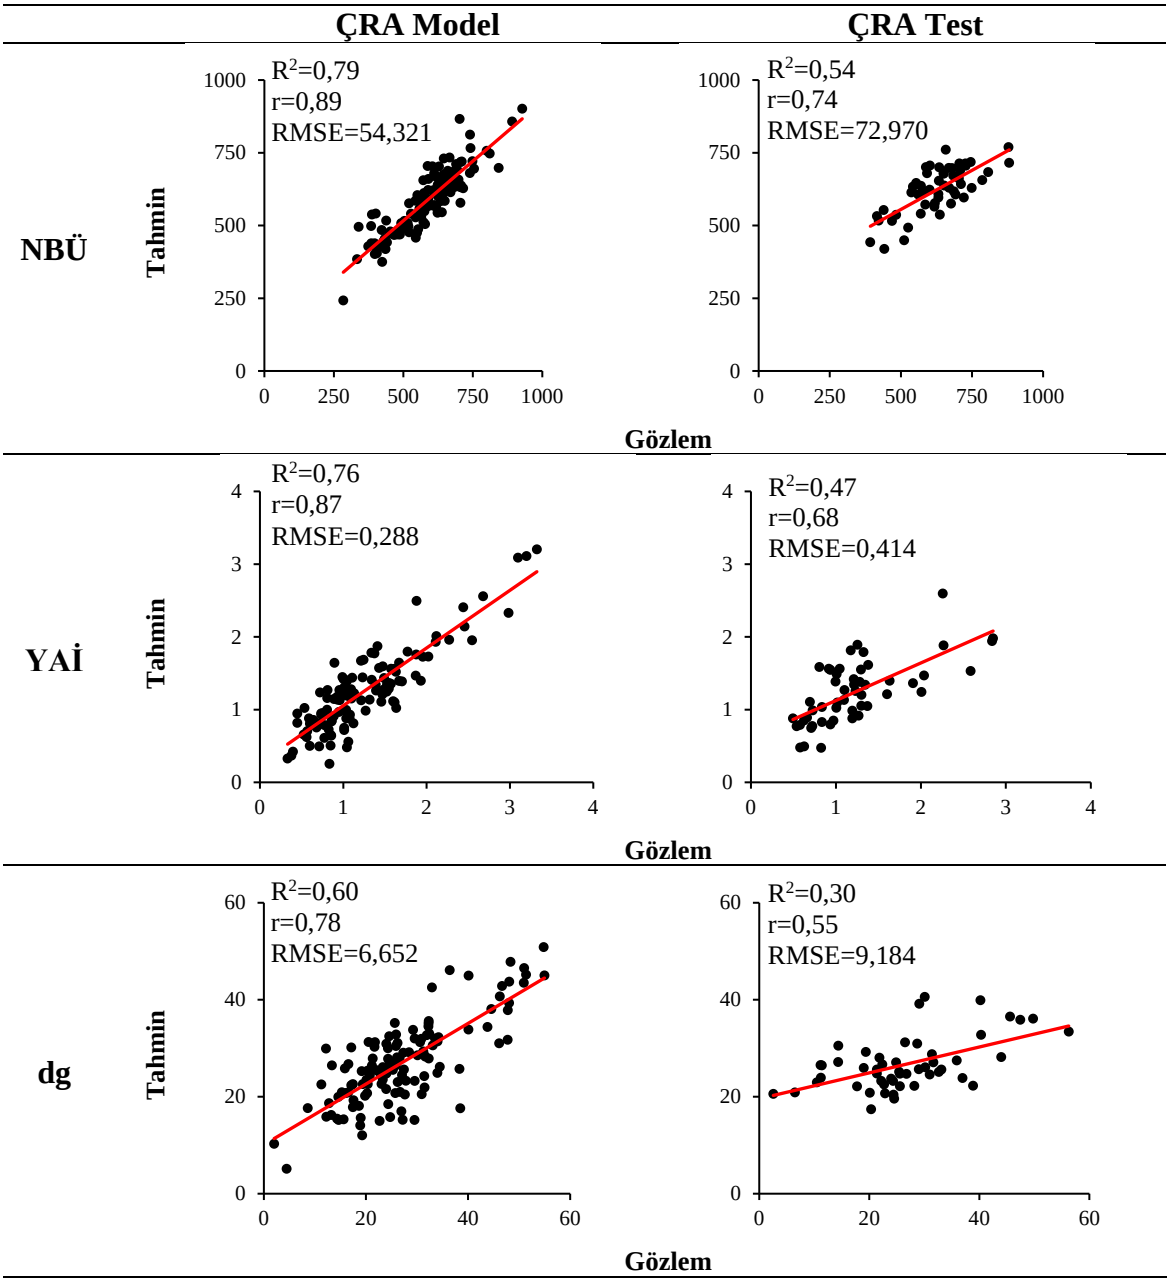
M: mean, VAR: variance, HOM: homogeneity, CONT: contrast, DİS: dissimilarity, ENT: entropy, SM: second moment ve COR: correlation

Çizelge 4.17 Sentinel-2 uydu görüntüsünden 90° tekstür verileri ile elde edilen V modeli

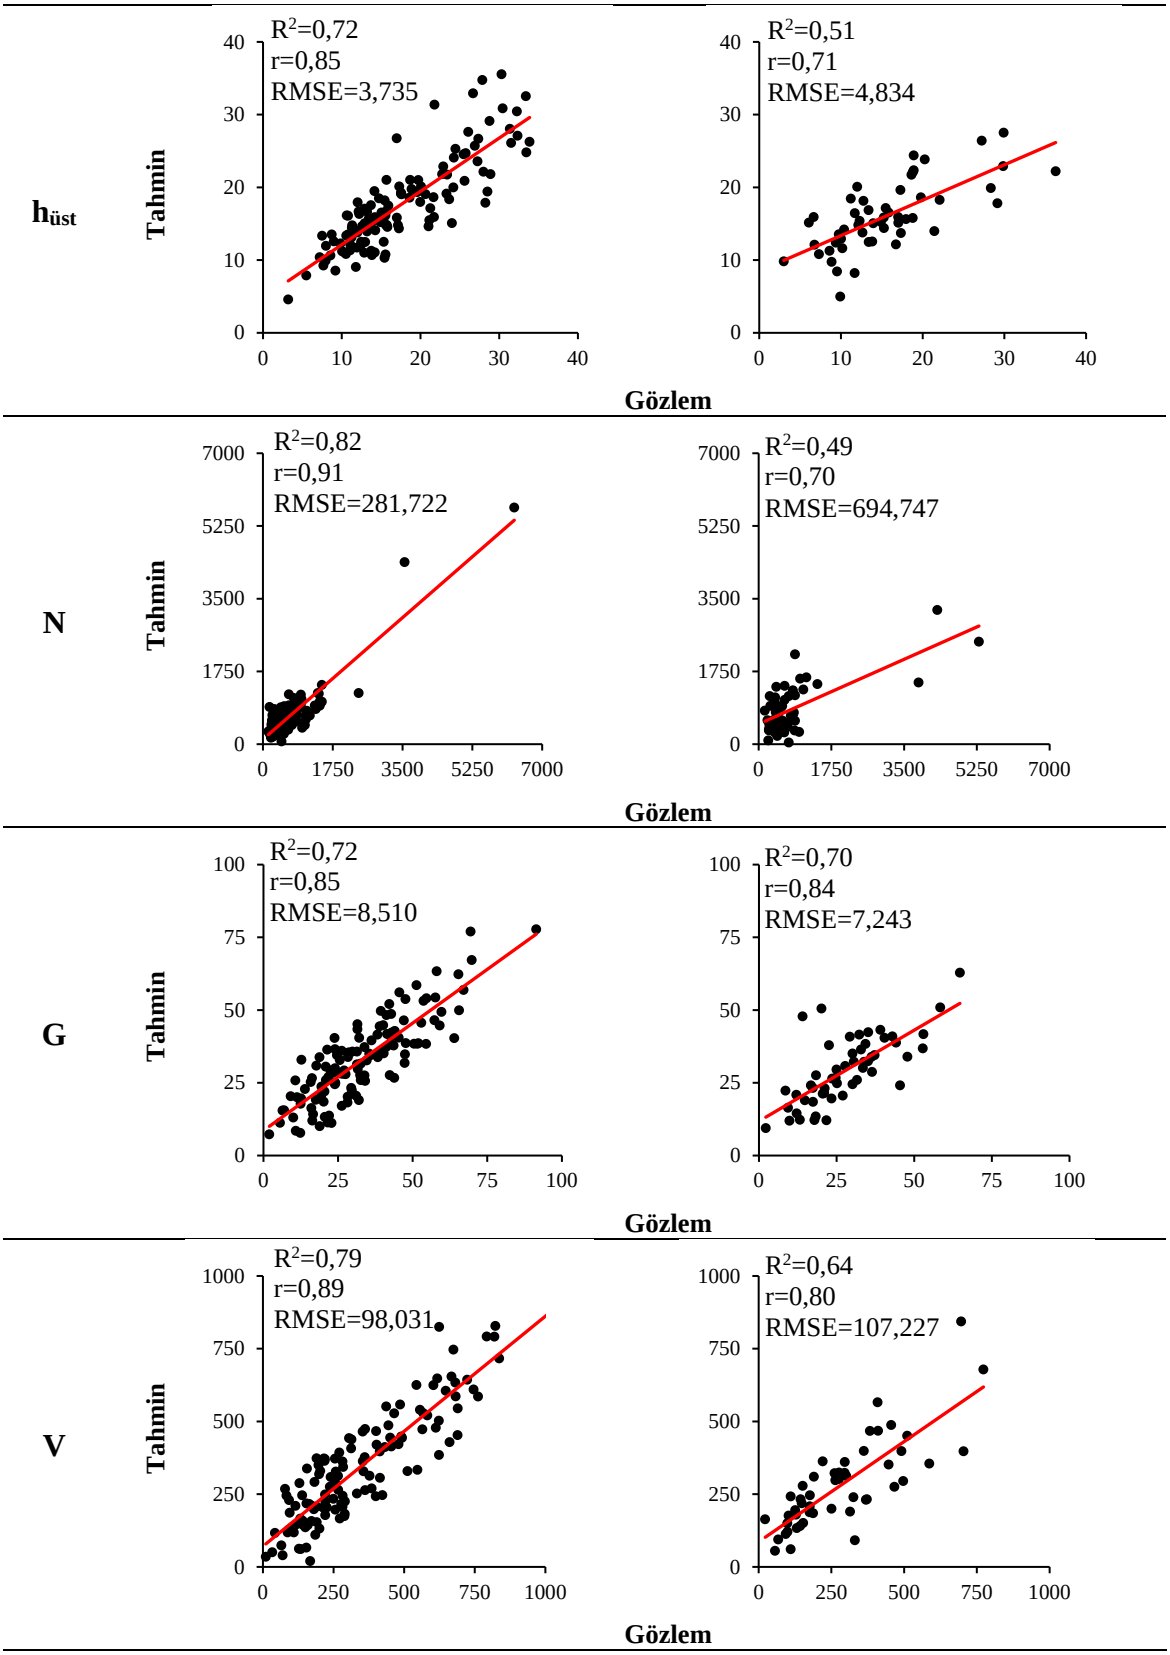
Bağımsız değişken	Katsayı	t	Önem düzeyi (p)
(Sabit katsayı)	521,191	2,771	0,007
M_S2_9_90	-1317,237	-7,064	0,000
CONT_S8A_9_90	491,384	6,712	0,000
M_S12_3_90	-145,320	-5,272	0,000
M_S4_9_90	685,995	6,444	0,000
COR_S8_7_90	-157,477	-4,604	0,000
VAR_S8_7_90	226,735	3,976	0,000
SM_S5_7_90	589,764	5,285	0,000
ENT_S11_9_90	134,596	4,695	0,000
M_S5_7_90	-170,244	-3,787	0,000
ENT_S5_5_90	190,739	3,625	0,000
M_S2_3_90	621,417	4,172	0,000
VAR_S8A_5_90	-267,395	-3,600	0,000
CONT_S8A_3_90	278,431	4,681	0,000
SM_S8A_5_90	165,393	2,934	0,004
SM_S11_3_90	196,611	3,659	0,000
VAR_S8_3_90	-169,289	-2,270	0,025
R^2 = 0,79	r = 0,89	MAE = 78,709	RMSE = 98,031

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 4.22'de verilmiştir. Grafikler incelendiğinde model-test uyumu en uygun parametrenin G olduğu görülmektedir (Model R^2= 0,72, Test R^2=0,70). Aynı zamanda en yüksek test başarısı da G için elde edilmiştir. dg ve N parametreleri için model ve test başarıları aralarındaki fark yüksek bulunmuştur (R^2 farkı: dg = 0,30, N = 0,33). NBÜ, YAİ, $h_{üst}$, G ve V için elde edilen model belirtme katsayıları 0,72 ile 0,79 arasında değişmektedir. Aynı parametrelere ilişkin test belirtme katsayıları ise 0,47 ile 0,64 arasında değişmektedir. Parametreler model ve test başarıları arasındaki fark oranında model-test hata farkına sahiptir. NBÜ model tahmininin hatası 54,321 gC m^{-2} $yıl^{-1}$ iken test sonucu hata 72,970 gC m^{-2} $yıl^{-1}$'e yükselmiştir. YAİ modelinin testi ise 0,414 m^2 m^{-2}'lik hataya sahiptir.



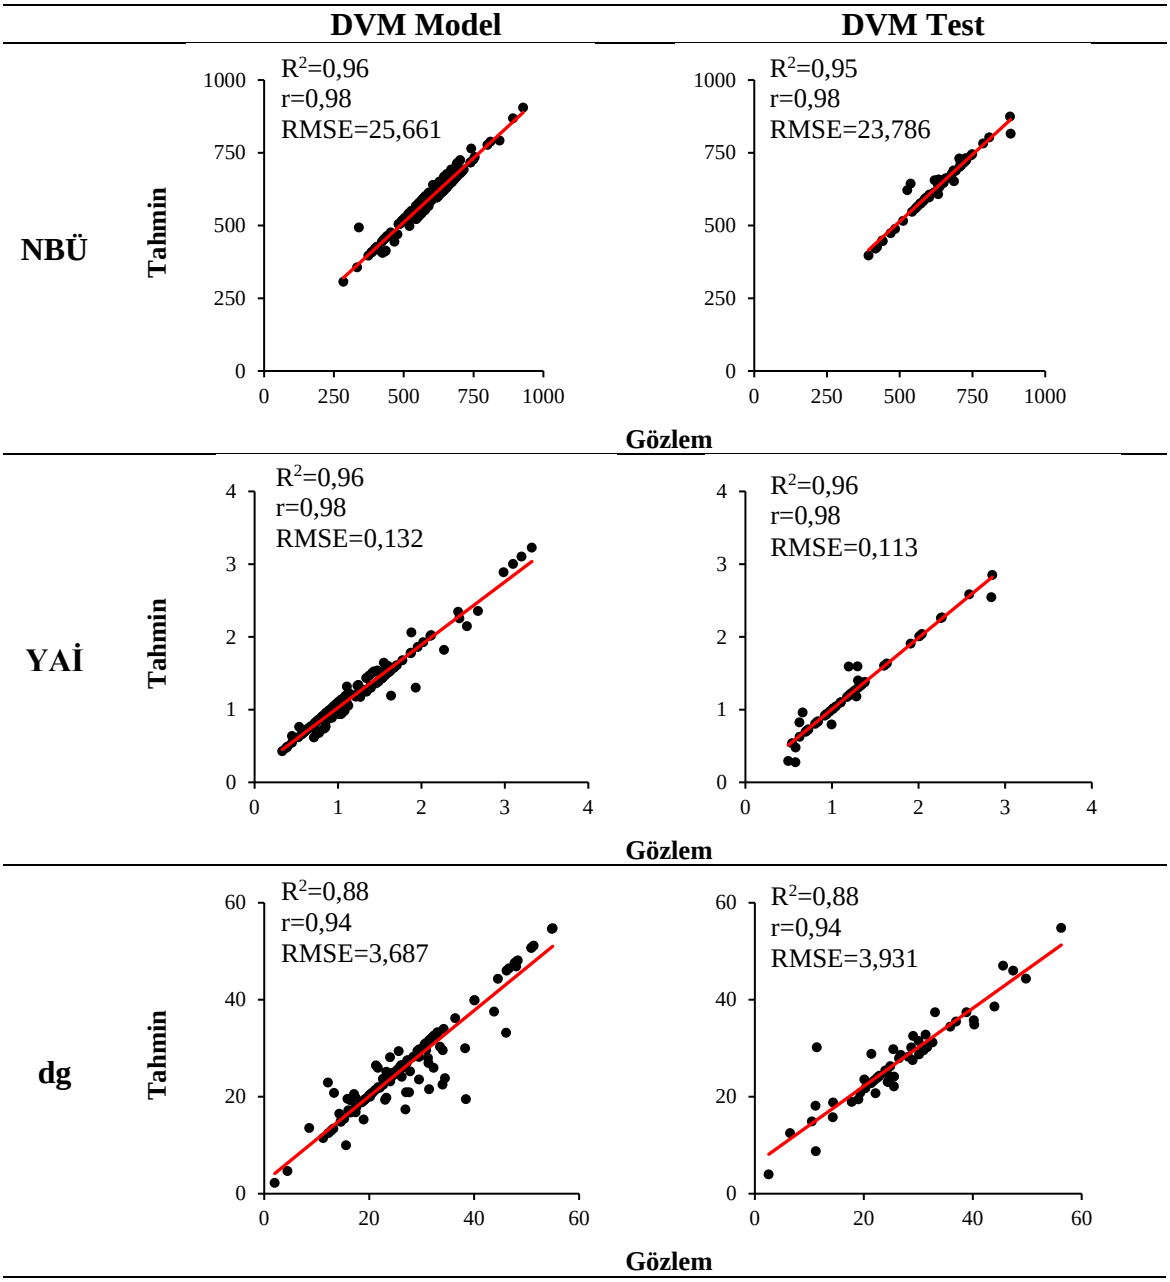
Şekil 4.22 Tekstür değerleri ile elde edilen NBÜ (S2, 45°), YAİ (S2, 0°), dg (S2, 9x9), $h_{üst}$ (S2, 135°), N (S2, 45°), G (S2, 90°) ve V (S2, 90°) modellerinin model-test için gözlem ve tahmin grafikleri



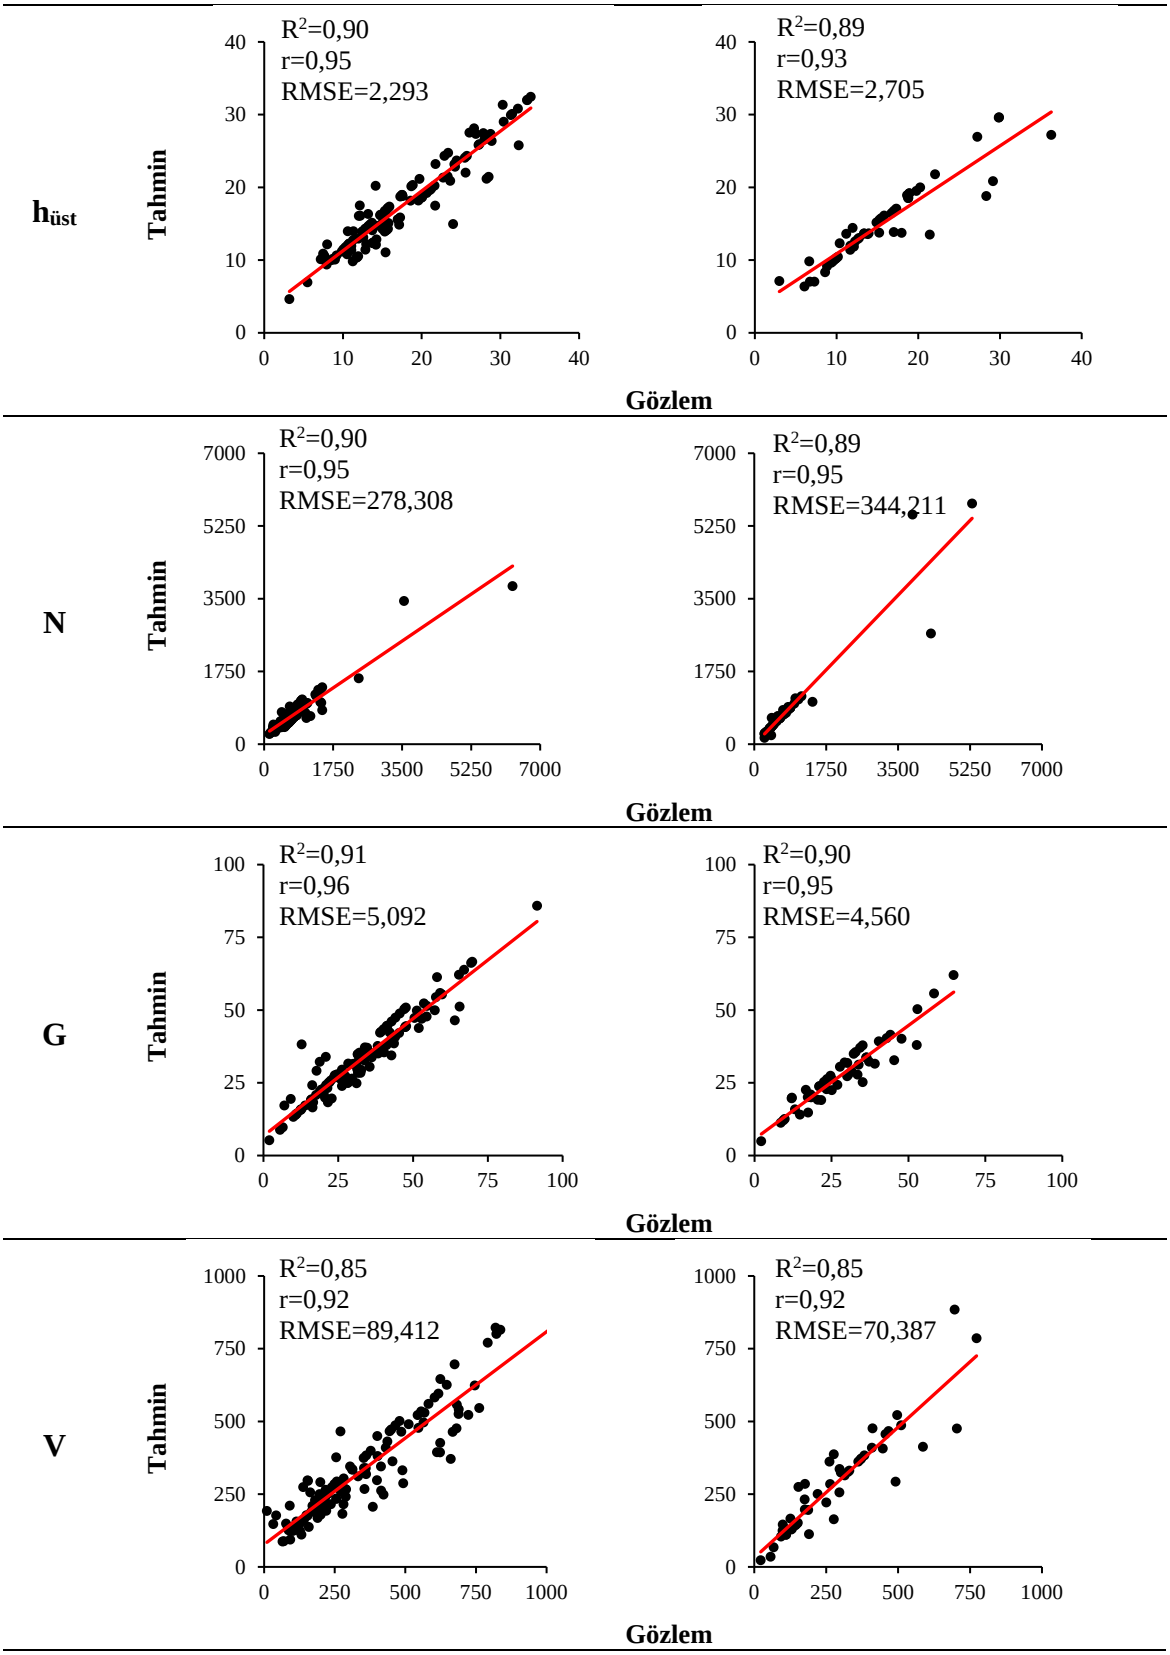
Şekil 4.22 devamı

4.5.2.2 ÇRA metodunda en yüksek başarıyı sağlayan uzaktan algılama veri setlerine DVM metodunun uygulanması

ÇRA metodunun uygulandığı model-test veri setlerine DVM metodu uygulanmıştır. Genel itibari ile DVM metodu model ve test veri setleri için oldukça kararlı sonuçlar vermiştir (Şekil 4.23). Model-test başarıları arasında belirtme katsayısı (R^2) açısından fark 0,01'i geçmemektedir. En yüksek model başarısı NBÜ ve YAİ için elde edilmiştir (Model R^2= 0,96). En yüksek test başarısı ise 0,96'lık belirtme katsayısı ile YAİ'ye aittir. DVM metoduna ait en düşük başarı V için elde edilmiştir (Model-Test R^2= 0,85). Makine öğrenme tekniklerinde aşırı uyum problemi olup olmadığını yorumlamak için model ve test başarıları arasındaki uyum oldukça önemlidir. DVM metodu NBÜ, YAİ ve meşcere parametrelerine ait model-test performans ölçütleri açısından yüksek bir başarı sergilemiştir.



Şekil 4.23 Tekstür verileri ile elde edilen NBÜ (S2, 45°), YAİ (S2, 0°), dg (S2, 9x9), $h_{üst}$ (S2, 135°), N (S2, 45°), G (S2, 90°) ve V (S2, 90°) modellerinin model-test için gözlem ve tahmin grafikleri

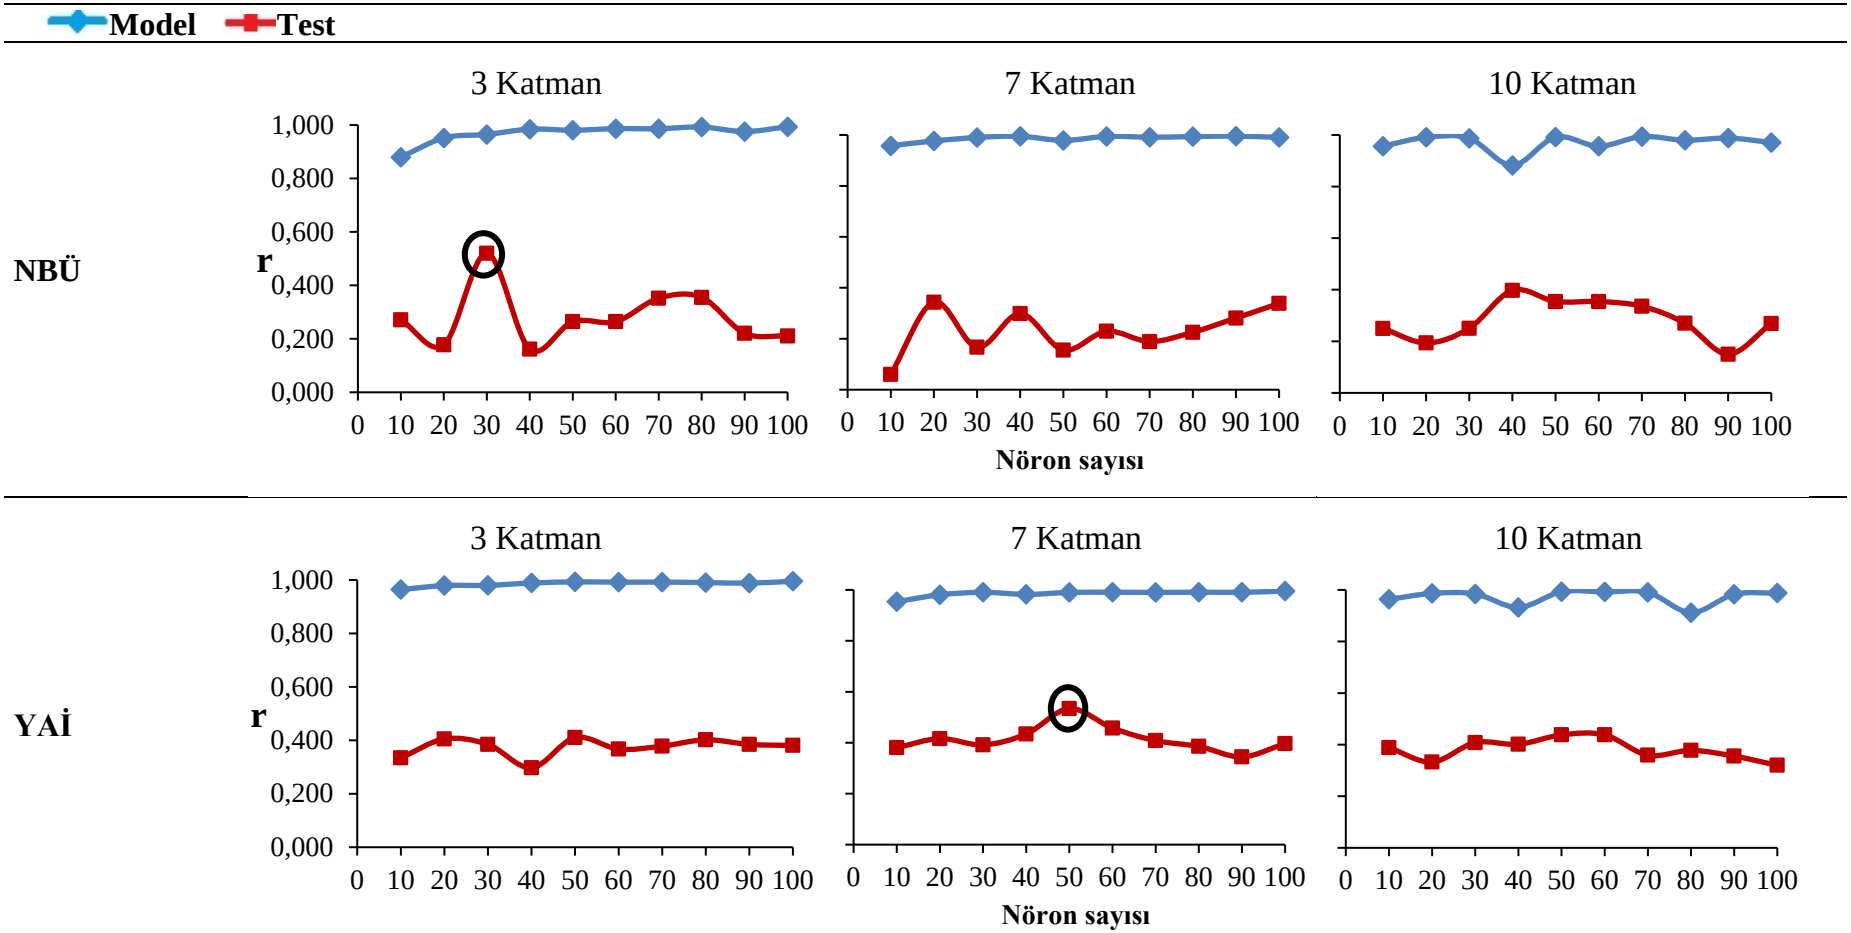


Şekil 4.23 devamı

4.5.2.3 ÇRA metodunda en yüksek başarıyı sağlayan uzaktan algılama veri setlerine DÖ metodunun uygulanması

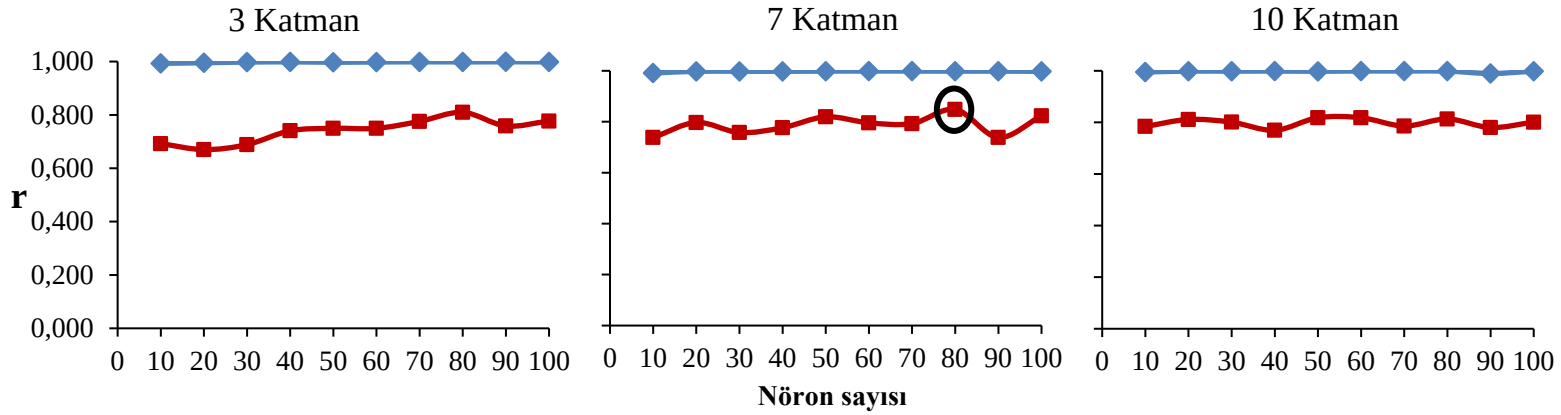
Modelleme aşaması için kullanılan bir diğer metot, makine öğrenme tekniklerinden olan DÖ'dür. DÖ metodunda ağ eğitim aşaması için farklı katman ve nöron sayıları denenmiştir (Şekil 4.24). En yüksek başarılar NBÜ için 3 katman 30 nöron, YAİ için 7 katman 50 nöron, dg için 7 katman 80 nöron, $h_{üst}$ için 10 katman 70 nöron, N için 3 katman 90 nöron, G için 10 katman 80 nöron ve V için 10 katman 50 nöron ile elde edilmiştir. Başarılı katman ve nöron sayılarının seçimi model başarı seviyesinden ziyade model-test uyumu ve özellikle bağımsız veri gruplarına olan tepki göstergesi olarak test bulgularına göre seçilmiştir. Buna göre NBÜ ve N için katman sayısı arttığında genel başarı azalmıştır. G, V ve $h_{üst}$ için ise katman sayısının artışı başarıyı olumlu etkilemiştir. Nöron sayılarında ise genellikle 50 ve yukarısı başarıyı artırmıştır.

Modellenen bütün parametrelere ilişkin model başarıları oldukça yüksektir. Fakat aynı başarı seviyesi test sonuçları için geçerli değildir. Korelasyon katsayılarına bakıldığında NBÜ ve YAİ için 0,99'luk model tahmin-gözlem benzerliği bulunmuşken, test için benzerlik seviyesi 0,50 seviyesine kadar düşmüştür (Şekil 4.24, 4.25). Dolayısı ile bu fark hata değerlerine de yansımıştır. NBÜ için elde edilen model hatası 31,390 gC m^{-2} iken test hatası 134,715 gC m^{-2}'dir. YAİ için ise model hatası 0,090 m^2 m^{-2}, test hatası da 0,630 m^2 m^{-2} bulunmuştur. Böylece model ve test arasındaki hata NBÜ için yaklaşık 4 kat, YAİ için yaklaşık 7 kat artmıştır. Eğitilen ağ model veri seti için yüksek oranda uyumlu hale gelmiş fakat aynı ağ test veri setini temsil etme kabiliyetini büyük ölçüde azaltmıştır. Diğer parametrelerdeki model ve test başarıları birbirine oldukça yakındır. Model ve test başarı bulgularının en yakın olduğu meşcere parametresi N'dir (Model r=0,99, Test r=0,98).

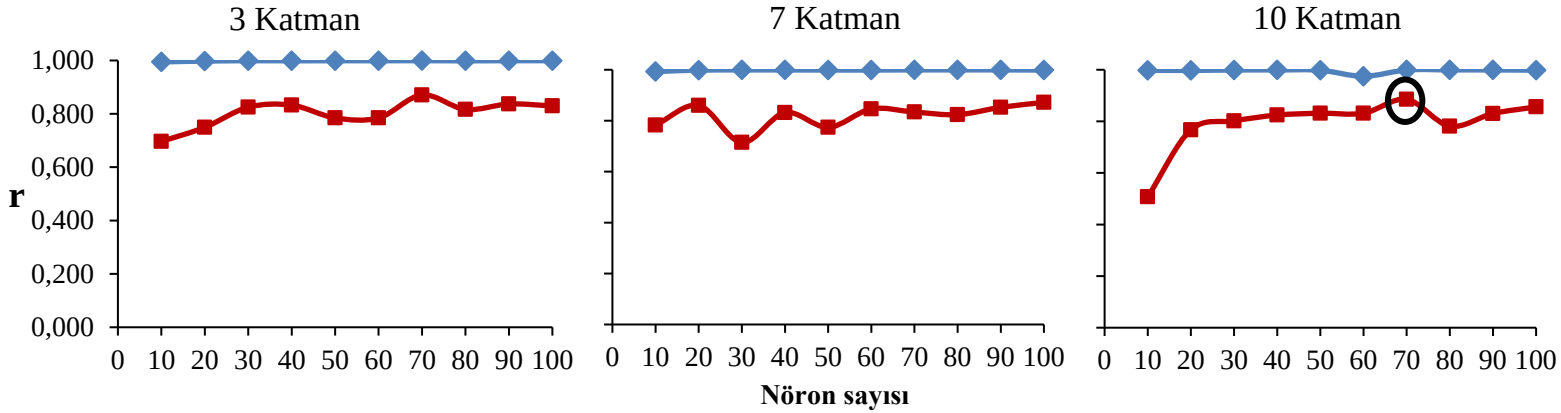


Şekil 4.24 DÖ metodu kullanılarak NBÜ, YAİ, dg, $h_{üst}$, N, G ve V'nin model ve testlerinin değişen nöron ve katman sayılarına göre korelasyon değişimi

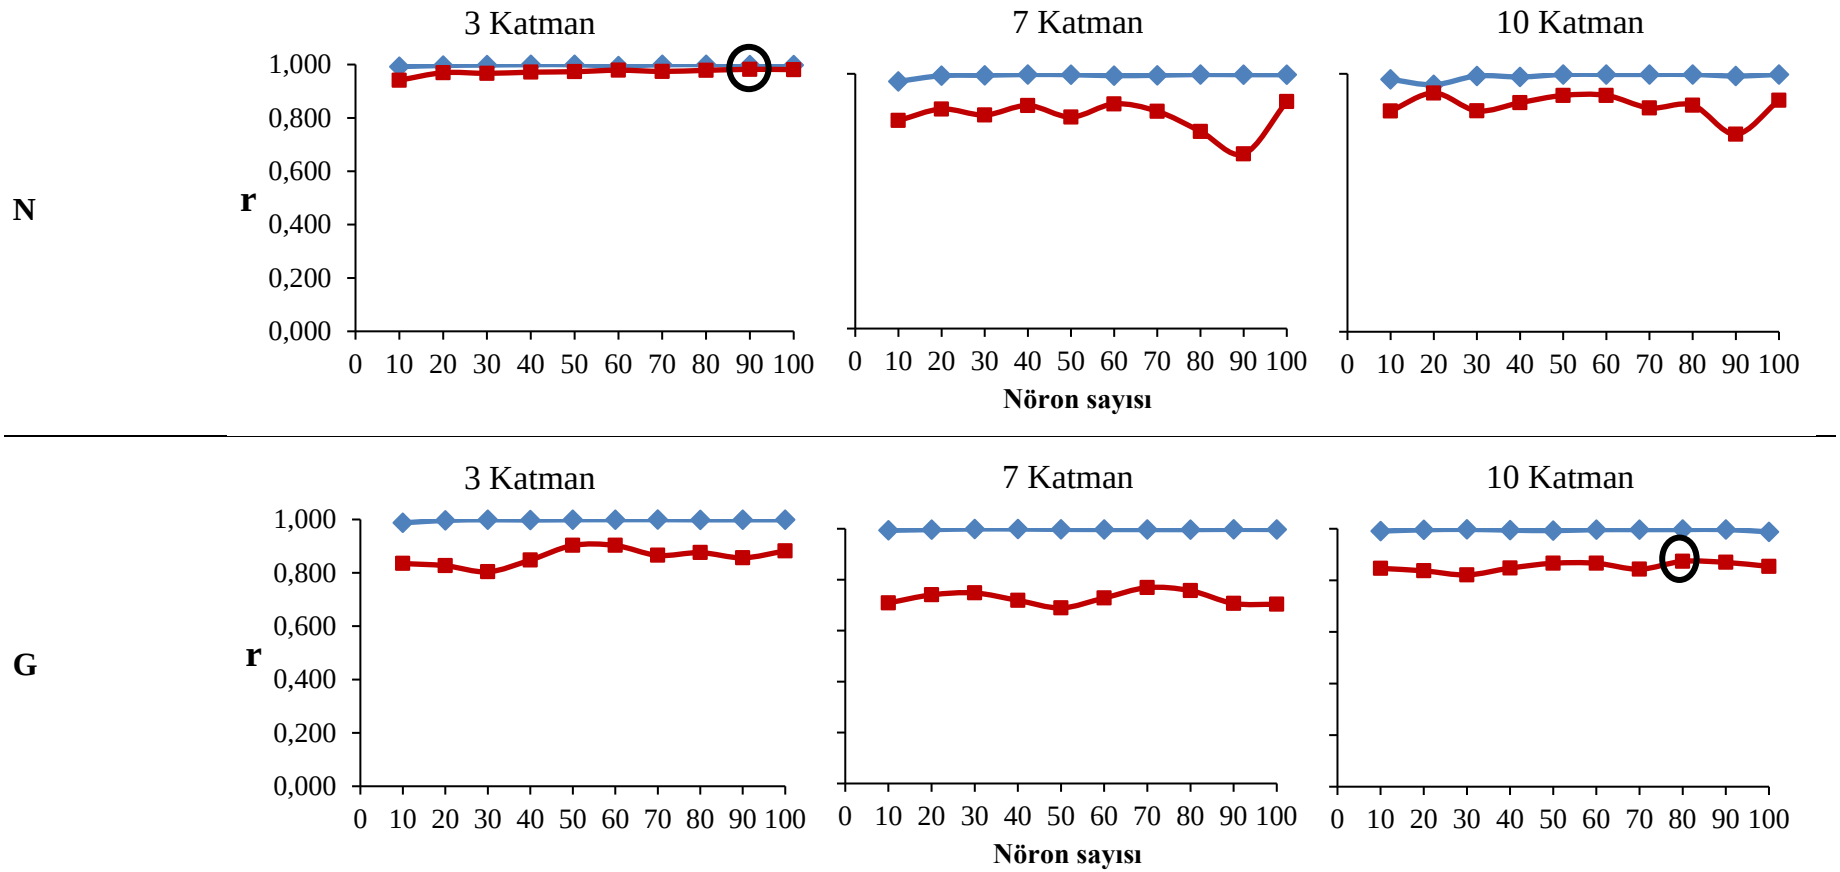
dg



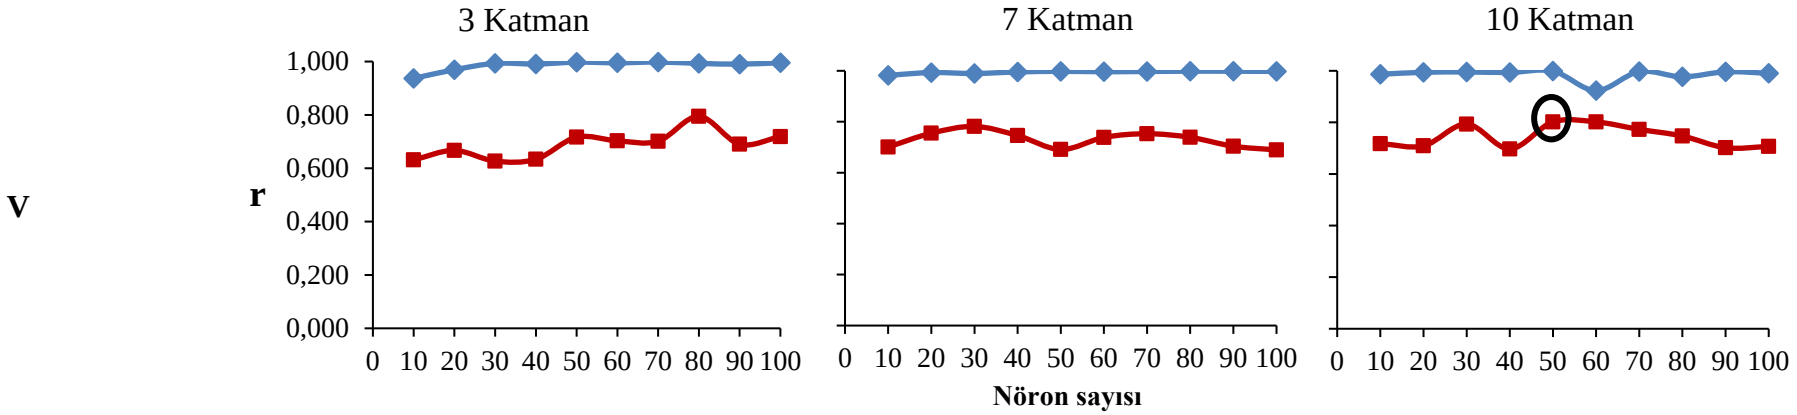
$h_{üst}$



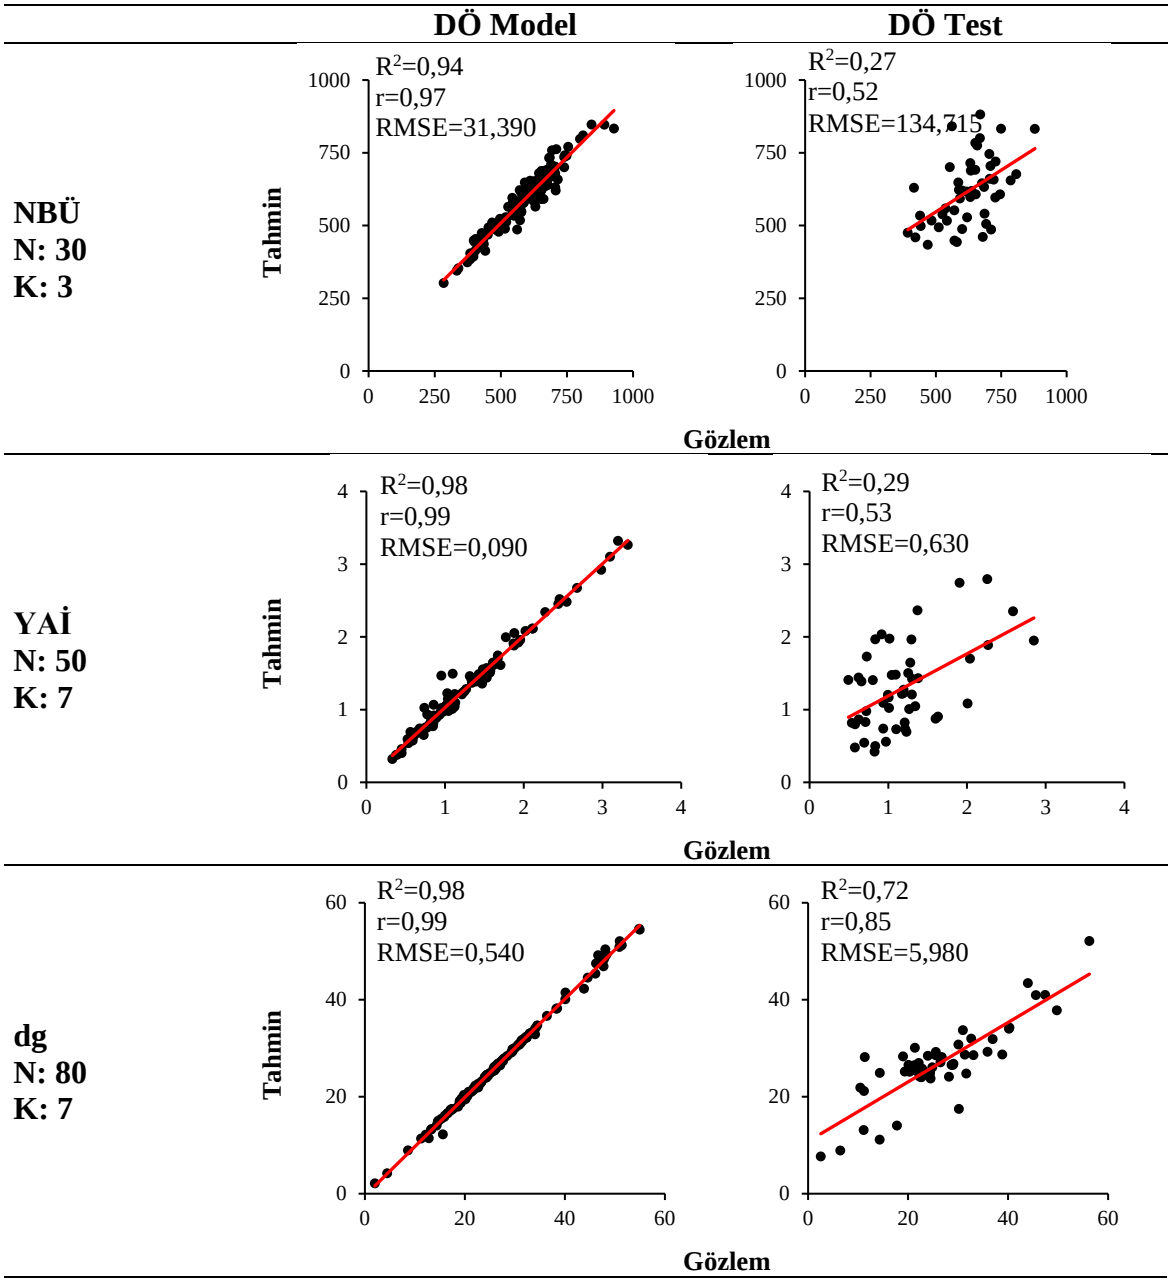
Şekil 4.24 devamı



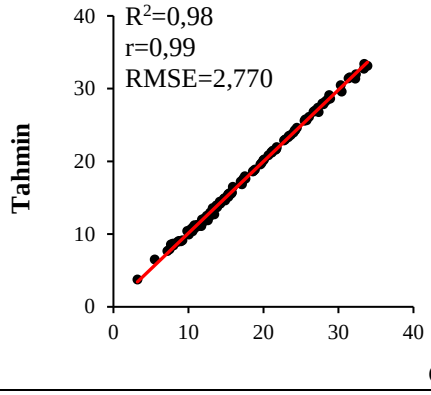
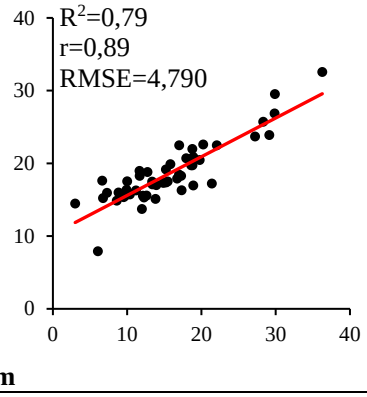
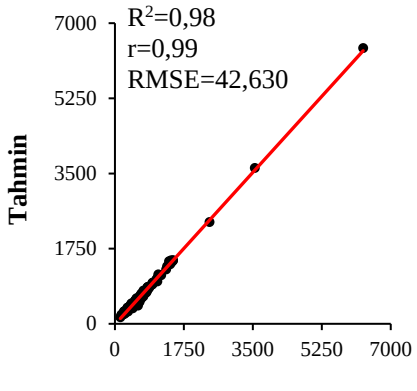
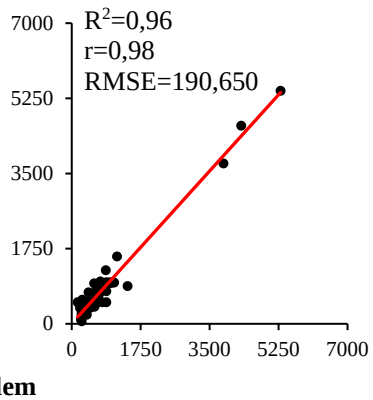
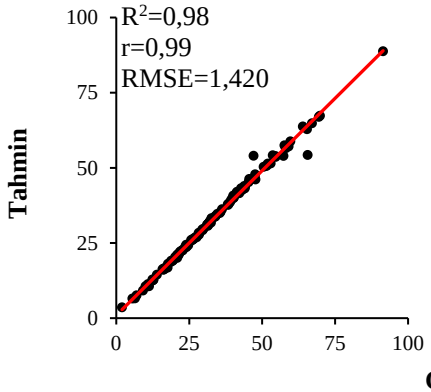
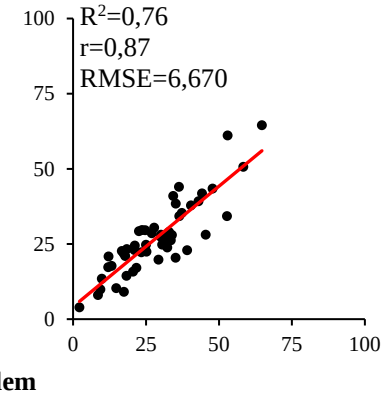
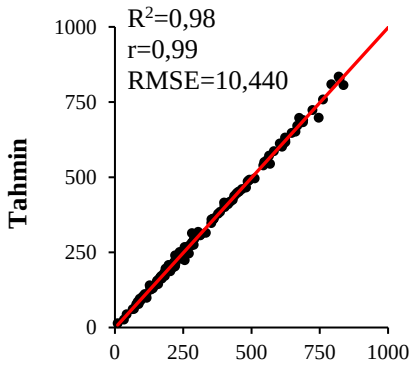
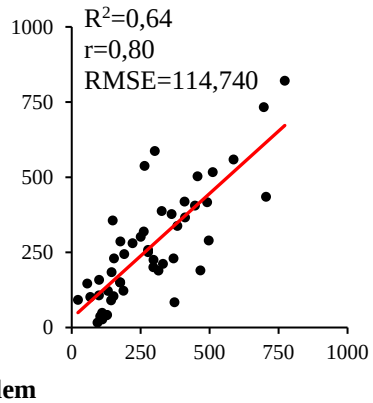
Şekil 4.24 devamı



Şekil 4.24 devamı

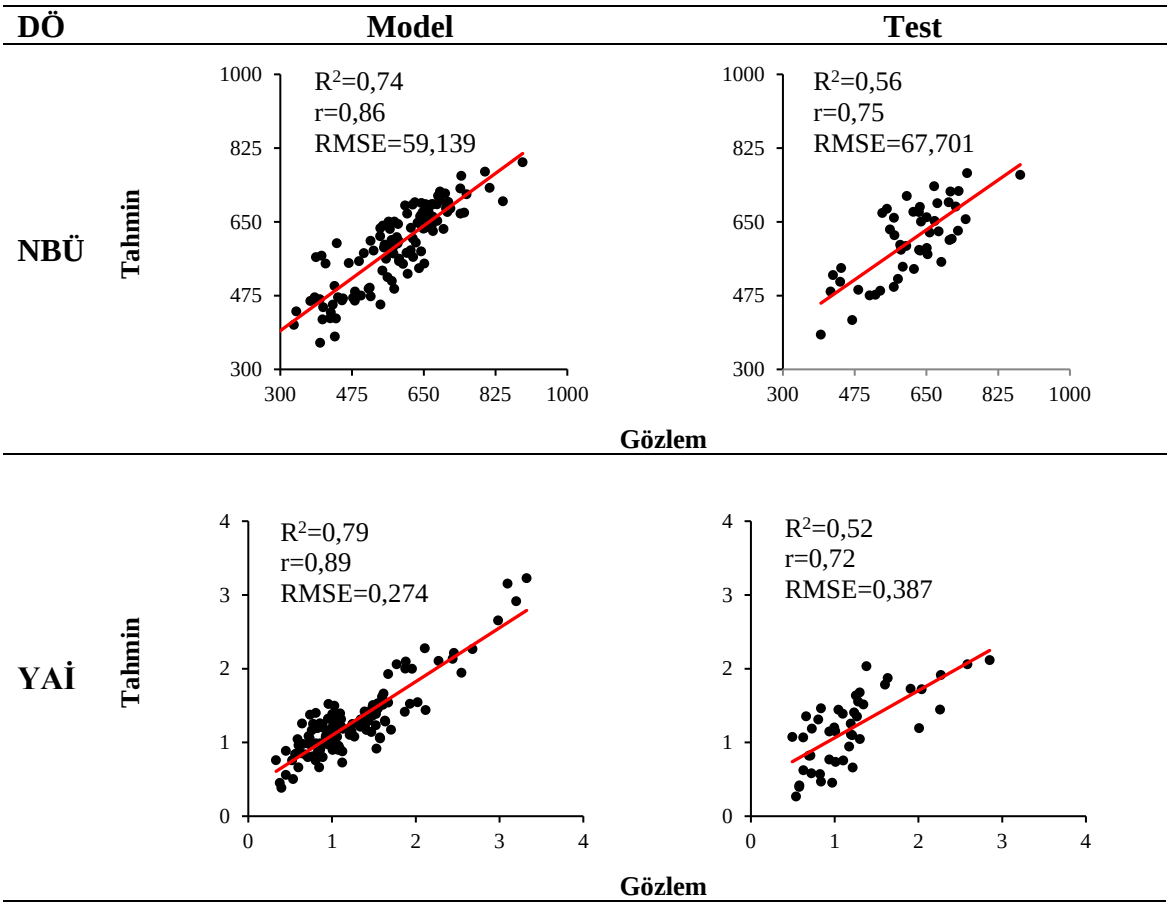


Şekil 4.25 Tekstür verileri ile elde edilen NBÜ (S2, 45°), YAİ (S2, 0°), dg (S2, 9x9), $h_{üst}$ (S2, 135°), N (S2, 45°), G (S2, 90°) ve V (S2, 90°) modellerinin model-test için gözlem ve tahmin grafikleri (N: nöron sayısı, K: katman sayısı)

$h_{üst}$ **N: 70** **K: 10**		
N **N: 90** **K: 3**		
G **N: 80** **K: 10**		
V **N: 50** **K: 10**		

Şekil 4.25 devamı

Yersel ölçümler ile uygulanan DÖ metodunda karşılaşılan aşırı uyum problemine, NBÜ ve YAİ'nin tekstür verileri ile modellenmesinde de karşılaşılmıştır. Aşırı uyum problemini çözmeye yönelik argümanlar kullanılmıştır. Model ve test başarıları arasında fark bulunsa da bu problemin etkisi minimize edilmiştir (Şekil 4.26).



Şekil 4.26 Tekstür verileri ile elde edilen NBÜ (S2, 45°) ve YAİ (S2, 0°) modellerinin ilave argümanlar kullanılarak model- test için gözlem ve tahmin grafikleri

4.5.2.4 ÇRA, DVM ve DÖ metotlarına ait performans ölçütlerinin karşılaştırılması

NBÜ, YAİ ve meşcere parametreleri ÇRA, DVM ve DÖ teknikleri kullanılarak modellenmiştir. Model ve test başarılarının kıyaslanmasının 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 %95 güvenle kullanılabilir olduğunu göstermektedir. Uygulanan teknikler ile elde edilen bütün

tahminlere ilişkin performans ölçütleri (R^2, r, RMSE, MAE, AIC) ve eşlendirilmiş *t*-testi sonuçları sunulmuştur (Çizelge 4.18-27).

Modellemede elde edilen bulgular kullanılan bağımsız değişkenlerin kaynağına göre yersel ve uzaktan algılama olmak üzere 2 ayrı kısımda incelenmiştir. Yersel veriler ile uygulanan modellerde NBÜ ve YAİ, meşcere parametreleri ile modellenmiştir. Ayrıca envanter çalışmalarında her bir örnek alan için belirlenen YAİ, NBÜ'nün modellenmesi için kullanılmıştır. NBÜ'nün meşcere parametreleri ile modellenmesinde en yüksek model başarısını DÖ metodu göstermiştir (Çizelge 4.18). Fakat aynı zamanda en düşük test başarısı da yine DÖ metoduna aittir (Model R^2=0,90 - RMSE=40,276 gC m^{-2} $yıl^{-2}$, Test R^2=0,29 - RMSE=108,446 gC m^{-2} $yıl^{-2}$). Buna rağmen test gözlem ve tahminleri arasında yapılan test sonucuna göre ortalamaların benzerliğinden dolayı model %95 güvenle kullanılabilir çıkmıştır (*t*=1,158, p=0,252). Benzer test başarısına sahip olan ÇRA metodu için de test tahminleri gözlem verileri ile uyumlu bulunmuştur (*t*=1,791, p=0,079). En yüksek test başarısı DVM metoduna aittir (R^2=0,44) ve uygulanan yöntemler arasında en başarılı metot DVM bulunmuştur (*t*=-0,592, p=0,557).

Çizelge 4.18 NBÜ'nün meşcere parametreleri ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,50	0,71	83,495	64,052	12,425		
Model	DVM	0,62	0,79	73,717	51,158	12,300	***t***	**p**
	DÖ	0,90	0,95	40,276	29,001	11,696		
	ÇRA	0,30	0,55	93,757	74,076	12,541	1,791	0,079
Test	DVM	0,44	0,66	79,549	60,065	12,376	-0,592	0,557
	DÖ	0,29	0,54	108,446	87,000	12,686	1,158	0,252

YAİ'nin meşcere parametreleri ile modellenmesinde ÇRA, DVM ve DÖ metotlarından üretilen modeller %95 güvenle (p>0,05) kullanılabilmektedir (Çizelge 4.19). ÇRA metodu için bulunan model ve test başarı sonuçları birbiri ile uyumludur. DÖ metodu en yüksek model başarısına sahip olsa da DVM metodunun model ve test başarısındaki benzerliği ve test tahminlerinin gözlem verileri ile uyumluluğu daha başarılıdır (*t*=0,209, p=0,835). Başarı kıyaslamasında model başarıları yanıltıcı olabilmektedir.

Örneğin ÇRA metodu her ne kadar düşük bir model başarısına sahip olsa da test hatası DÖ metoduna göre daha azdır (ÇRA Test RMSE=0,449 m^2 m^{-2}, DÖ Test RMSE=0,462 m^2 m^{-2}).

Çizelge 4.19 YAİ'nin meşcere parametreleri ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,48	0,69	0,383	0,305	5,040		
Model	DVM	0,64	0,80	0,322	0,225	4,867	***t***	**p**
	DÖ	0,72	0,85	0,335	0,243	4,905		
	ÇRA	0,47	0,69	0,449	0,337	5,199	0,918	0,363
Test	DVM	0,64	0,80	0,371	0,273	5,008	0,209	0,835
	DÖ	0,46	0,68	0,462	0,373	5,227	-0,871	0,388

NBÜ, büyüme ve verimlilik ile büyük oranda ilişkili olan YAİ kullanılarak modellenmiştir. Modelleme bulgularına göre ÇRA metodundan elde edilen test bulguları gözlem verileri ile uyumsuz çıkmıştır (Çizelge 4.20). NBÜ'nün YAİ ile modellenmesinde ÇRA, DVM ve DÖ metotları birbirine yakın düzeyde başarı göstermiştir. Model-test başarı sonuçları da birbirine çok yakındır. Mevcut bulgular doğrultusunda az bir farkla da olsa en iyi başarıyı DÖ metodu göstermiştir. Fakat test için tahmin ve gözlem benzerliği en yakın DVM metodu için bulunmuştur (*t*=-0,582, p=0,563). DVM ve DÖ metotları kullanılarak her ne kadar kullanılabilir modeller üretilse de (DVM p=0,563, DÖ p=0,197) modelleme performansı oldukça düşük elde edilmiştir (DVM R^2=0,23, MAE=63,471, AIC=6,512, DÖ R^2=0,24, MAE=77,332, AIC=6,550).

Çizelge 4.20 NBÜ'nün YAİ ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,20	0,45	104,084	83,657	6,645		
Model	DVM	0,23	0,48	105,027	77,153	6,654	***t***	**p**
	DÖ	0,24	0,49	104,581	78,904	6,650		
	ÇRA	0,19	0,45	99,807	85,999	6,603	2,943	0,005
Test	DVM	0,23	0,48	91,123	63,471	6,512	-0,582	0,563
	DÖ	0,24	0,49	94,658	77,332	6,550	1,308	0,197

Modelleme sürecinde kullanılan uzaktan algılama verilerinden en yüksek başarıyı Sentinel-2 uydu görüntüsünden elde edilen tekstür verileri sağlamıştır. NBÜ için üretilen modellerde 45°'lik tekstür verileri kullanılmıştır. Kullanılan 3 metodun da test tahminleri gözlem verileri ile uyumlu bulunmuştur (Çizelge 4.21). DVM metodu model-test başarılarının benzerliği ve başarı seviyesi açısından en iyi metot seçilmiştir. DÖ metodu için elde edilen test sonucu model başarısına göre düşük seviyededir (Model R^2=0,94, RMSE=31,390 gC m^{-2} $yıl^{-2}$, MAE=23,550, AIC=37,450, Test R^2=0,27, RMSE=134,715 gC m^{-2} $yıl^{-2}$, MAE=96,340, AIC=38,903). Test başarılarına bakıldığında DVM metodu ÇRA metoduna göre daha başarılı görünse de eşlendirilmiş *t*-testi sonucuna göre ÇRA test tahminleri gözlem verileri ile daha uyumlu çıkmıştır (ÇRA p=0,749, DVM p=0,238).

Çizelge 4.21 NBÜ'nün Sentinel-2 uydu görüntüsünden elde edilen 45°'lik tekstür verileri ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,79	0,89	54,321	40,722	37,995		
Model	DVM	0,96	0,98	25,661	21,901	37,245	***t***	**p**
	DÖ	0,94	0,97	31,390	23,550	37,450		
	ÇRA	0,54	0,74	72,970	61,454	38,290	0,321	0,749
Test	DVM	0,95	0,98	23,786	11,393	37,169	-1,193	0,238
	DÖ	0,27	0,52	134,715	96,340	38,903	0,348	0,729

YAİ'nin modellenmesinde Sentinel-2 uydu görüntüsünden elde edilen 0°'lik tekstür verileri kullanılmıştır. DVM metodu en yüksek başarıyı göstermiştir (Çizelge 4.22). DÖ metodunda ise NBÜ de olduğu gibi model ve test başarı bulguları arasındaki fark yüksek çıkmıştır (Model R^2=0,98, Test R^2=0,29). ÇRA metodunda da model-test başarıları birbirine çok yakın değildir (Model R^2=0,76, Test R^2=0,47). Fakat eşlendirilmiş *t*-test sonuçlarına göre ÇRA metodu test tahminleri DÖ metoduna göre daha uyumlu çıkmıştır (ÇRA p=0,771, DÖ p=0,180). Uygulanan teknikler arasında test tahminlerini gözlem verileri ile en uyumlu üreten metot ise DVM olmuştur (Test R^2=0,96, RMSE=0,113 m^2 m^{-2}, MAE=0,048, AIC=39,821, p=0,898).

Çizelge 4.22 YAİ'nin Sentinel-2 uydu görüntüsünden elde edilen 0°'lik tekstür verileri ile model performans ölçütleri

	Metot	R^2	r	RMSE	MAE	AIC	Eşlendirilmiş *t*-test	
	ÇRA	0,76	0,87	0,288	0,235	40,754		
Model	DVM	0,96	0,98	0,132	0,105	39,975	*t*	p
	DÖ	0,98	0,99	0,090	0,050	39,560		
	ÇRA	0,47	0,68	0,414	0,329	41,118	-0,292	0,771
Test	DVM	0,96	0,98	0,113	0,048	39,821	-0,129	0,898
	DÖ	0,29	0,53	0,630	0,490	41,540	-1,358	0,180

Modellenen dg için en yüksek model başarısı DÖ metodu (R^2=0,98, RMSE=0,540 cm), en yüksek test başarısı DVM metodu (R^2=0,88, RMSE=3,931 cm) ile elde edilmiştir (Çizelge 4.23). DÖ metodu için elde edilen model ve test başarıları arasında 0,26'lık bir model açıklayıcılığı farkı vardır. Bu fark ÇRA metodunda 0,30 olup DVM metodunda model-test başarıları birbirine benzer çıkmıştır. Test tahminlerinin gözlem verileri ile uyumuna bakacak olursak en uyumlu tahmini ÇRA metodunun yaptığı görülmektedir (p=0,941). Her ne kadar model-test başarıları benzer olsa da test tahminlerinin kıyaslanmasında en başarısız yöntem DVM metodu bulunmuştur (p=0,118).

Çizelge 4.23 dg'nin Sentinel-2 uydu görüntüsünden elde edilen 9x9 filtreli tekstür verileri ile model performans ölçütleri

	Metot	R^2	r	RMSE	MAE	AIC	Eşlendirilmiş *t*-test	
	ÇRA	0,60	0,78	6,652	5,219	21,895		
Model	DVM	0,88	0,94	3,687	1,850	21,305	*t*	p
	DÖ	0,98	0,99	0,540	0,290	19,380		
	ÇRA	0,30	0,55	9,184	7,273	22,217	-0,074	0,941
Test	DVM	0,88	0,94	3,931	2,692	21,369	-1,592	0,118
	DÖ	0,72	0,85	5,980	4,750	21,790	-0,611	0,544

$h_{üst}$'ün modellenmesinde uygulanan modelleme tekniklerinden en yüksek model başarısını DÖ metodu (R^2=0,98, RMSE=2,770 m, MAE=1,150, AIC=25,020), en yüksek test başarısını da DVM metodu (R^2=0,89, RMSE=2,705 m, MAE=1,322, AIC=24,995) göstermiştir (Çizelge 4.24). ÇRA metodunun başarısı en düşük seviyede olmasına rağmen test gözlem ve tahmin uyumu en iyidir (p=0,414). DÖ metodu için

belirtme katsayısına bakıldığında test başarısı 0,79 olmasına rağmen, eşlendirilmiş *t*-teste göre gözlem ve tahmin sonuçları uyumsuz bulunmuştur (p=0,022).

Çizelge 4.24 $h_{üst}$'ün Sentinel-2 uydu görüntüsünden elde edilen 135°'lik tekstür verileri ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,72	0,85	3,735	2,873	25,318		
Model	DVM	0,90	0,95	2,293	1,805	24,830	***t***	**p**
	DÖ	0,98	0,99	2,770	1,150	25,020		
	ÇRA	0,51	0,71	4,834	3,840	25,576	-0,823	0,414
Test	DVM	0,89	0,93	2,705	1,322	24,995	1,482	0,144
	DÖ	0,79	0,89	4,790	4,010	25,570	-2,367	0,022

N'in modellenmesinde başarısı en yüksek ilişkiler Sentinel-2 uydu görüntüsünden elde edilen 45°'lik tekstür verileri ile elde edilmiştir. Uygulanan teknikler arasında model ve test başarısı en yüksek olan metot DÖ bulunmuştur (Çizelge 4.25). Model ve test uyumuna bakıldığında DVM metodu başarılı bulunmuştur (Model R^2=0,90, RMSE=278,308 adet/ha, Test R^2=0,89, RMSE=344,211 adet/ha). ÇRA metodunda ise test başarısı model başarısına göre oldukça düşüktür (Model R^2=0,82, RMSE=281,722 adet/ha, Test R^2=0,49, RMSE=694,747 adet/ha). Her 3 metodun test tahminleri gözlem verileri ile uyumlu bulunmuştur. Önemlilik düzeylerine bakıldığında ise test uyumu en iyi olan metodun DVM olduğu görülmektedir (p=0,760).

Çizelge 4.25 N'in Sentinel-2 uydu görüntüsünden elde edilen 45°'lik tekstür verileri ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,82	0,91	281,722	205,585	37,641		
Model	DVM	0,90	0,95	278,308	141,402	37,629	***t***	**p**
	DÖ	0,98	0,99	42,630	31,410	35,750		
	ÇRA	0,49	0,70	694,747	457,900	38,544	-0,365	0,716
Test	DVM	0,89	0,95	344,211	107,921	37,841	-0,307	0,760
	DÖ	0,96	0,98	190,650	141,030	37,250	-0,706	0,483

G'nin modellenmesinde en iyi performansı Sentinel-2 uydu görüntüsünden elde edilen 90°'lik tekstür verileri göstermiştir. Uygulanan metotlardan ÇRA ve DVM için model ve test başarıları birbirleri ile uyumlu çıkmıştır (Çizelge 4.26). Model ve test başarıları sırası ile DÖ ve DVM metotları için en yüksektir. Model hatası en düşük metot DÖ (RMSE=1,420 m^2/ha, MAE=0,630, AIC=32,350), test hatası en düşük metot ise DVM'dir (RMSE=4,560 m^2/ha, MAE=3,618, AIC=33,517). ÇRA metodunun başarı düzeyi diğer metotların gerisinde kalsa da test tahminlerinin gözlem verileri ile uyumu daha iyidir (p=0,955).

Çizelge 4.26 G'nin Sentinel-2 uydu görüntüsünden elde edilen 90°'lik tekstür verileri ile model performans ölçütleri

	Metot	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	ÇRA	0,72	0,85	8,510	7,006	34,141		
Model	DVM	0,91	0,96	5,092	3,854	33,628	***t***	**p**
	DÖ	0,98	0,99	1,420	0,630	32,350		
	ÇRA	0,70	0,84	7,243	5,657	33,980	-0,056	0,955
Test	DVM	0,90	0,95	4,560	3,618	33,517	0,954	0,344
	DÖ	0,76	0,87	6,670	5,270	33,900	1,675	0,100

Modellenen parametrelerden V, Sentinel-2 uydu görüntüsünden elde edilen 90°'lik tekstür verileri ile modellenerek en başarılı tahminler yapılmıştır. Model ve test başarı kriterleri en uyumlu metot DVM'dir (Çizelge 4.27). Model ve test başarısı en uyumsuz ve farkı en yüksek metot ise DÖ metodudur (Model R^2=0,98, RMSE=10,440 m^3/ha, Test R^2=0,64, RMSE=114,740 m^3/ha). Test tahmin gücü en yüksek metot DVM olmakla birlikte (R^2=0,85, RMSE=70,387 m^3/ha), ÇRA (R^2=0,64, RMSE=107,227 m^3/ha) ve DÖ (R^2=0,64, RMSE=114,740 m^3/ha) metodunun test başarıları benzerdir. Eşlendirilmiş *t*-test bulgularına göre test tahminleri gözlem ile en uyumlu metot ÇRA metodu (p=0,914), en uyumsuz olanı ise DÖ metodu (p=0,291) olarak belirlenmiştir.

Çizelge 4.27 V'nin Sentinel-2 uydu görüntüsünden elde edilen 90°'lik tekstür verileri ile model performans ölçütleri

	Metot	R^2	r	RMSE	MAE	AIC	Eşlendirilmiş *t*-test	
	ÇRA	0,79	0,89	98,031	78,709	36,585		
Model	DVM	0,85	0,92	89,412	61,824	36,493	*t*	p
	DÖ	0,98	0,99	10,440	6,840	34,350		
	ÇRA	0,64	0,80	107,227	82,895	36,675	0,109	0,914
Test	DVM	0,85	0,92	70,387	40,674	36,254	-0,273	0,786
	DÖ	0,64	0,80	114,740	85,170	36,740	1,068	0,291

Genel itibari ile model başarıları en yüksek DÖ metodu olsa da test tahminlerinde başarı seviyesi oldukça düşmektedir. Elde edilen bulgulara göre DÖ metodunun en dikkat çekici özelliği bu olmuştur. Ayrıca eşlendirilmiş *t*-test sonuçlarında DÖ metodu hiçbir parametreyi en uyumlu şekilde tahmin edememiştir. Elde edilen DÖ tahminlerine bakıldığında metodun parametreleri olduğundan yüksek tahmin etme eğiliminde olduğu görülmüştür. Bu tahminin ortalamasını artırdığından gözlem verileri ile uyumsuz sonuçlar elde edilmiştir. ÇRA metodu NBÜ, dg, $h_{üst}$, G ve V için en uyumlu test tahminlerini gerçekleştirmiştir. DVM metodu ise YAİ ve N için en uyumlu test tahminlerini yapmıştır. Eşlendirilmiş *t*-test bulgularına göre uyumsuz olan test tahminleri ÇRA metodu için NBÜ-YAİ ve DÖ metodu için $h_{üst}$-135° tekstür modellerinden üretilmiştir (ÇRA p=0,005, DÖ p=0,022). Performans ölçütlerine göre benzerliği en yüksek, hatası en düşük ve model-test sonuçları birbirine en yakın metot DVM olmuştur. NBÜ için en yüksek model-test başarısı DVM, N için ise DÖ metoduna aittir. Diğer parametrelerde ise model başarıları DÖ, test başarıları ise DVM için en yüksek elde edilmiştir.

DÖ metodunda karşılaşılan aşırı uyum problemleri model ağı için düzenlenen argümanalr ile iyileştirilmiştir. NBÜ'nün meşcere parametreleri ile modellenmesinde model-test için belirtme katsayıları 0,90-0,29 iken düzenleme argümanları ile bu değerler 0,64-0,51 seviyesine gelmiştir (Çizelge 4.28). Bu bulgular neticesinde DVM metoduna göre daha iyi bir performans elde edilmiştir. YAİ ile meşcere parametreleri için uygulanan model ağında 0,72-0,46 olan model-test belirtme katsayıları da 0,68-0,53 seviyesine gelmiştir. Bu model için DVM metodu ile daha iyi bir performans

yakalanmıştır. NBÜ ile YAİ için elde edilen performans ölçütlerinde herhangi bir farklılık yoktur. Eşlendirilmiş *t*-test bulgularına göre ise oluşturulan modellere ait tahminler gözlem verileri ile uyumludur (p>0,05).

Çizelge 4.28 DÖ metoduna ilave argümanlar eklenerek koşturulan NBÜ-meşcere parametreleri, YAİ-meşcere parametreleri ve NBÜ-YAİ modellerinden elde edilen model- test için performans ölçütleri

	DÖ	**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
	NBÜ-MesPar	0,64	0,80	73,688	59,077	12,300		
Model	YAİ-MesPar	0,68	0,82	0,413	0,266	5,116	***t***	**p**
	NBÜ-YAİ	0,24	0,49	90,130	73,389	6,501		
	NBÜ-MesPar	0,51	0,71	78,278	63,846	12,360	1,479	0,146
Test	YAİ-MesPar	0,53	0,73	0,407	0,319	5,102	1,677	0,100
	NBÜ-YAİ	0,24	0,49	106,833	79,079	6,671	0,053	0,958

Uzaktan algılama veri setlerinden tekstür ile uygulanan sonuçlarda da aşırı uyum problemine rastlanmıştır. NBÜ ile 45°'lik tekstür verileri ile oluşturulan model-test belirtme katsayıları 0,94-0,27 iken düzenleme sonrasında bu değerler 0,74-0,56 seviyesine gelmiştir (Çizelge 4.29). YAİ ile 0°'lik tekstür verileri ile oluşturulan model-test belirtme katsayıları ise 0,98-0,29 seviyesinden 0,79-0,52 seviyesine kadar iyileşmiştir. Aşırı uyum problemi iyileştirilse de DÖ metodunun bulguları DVM metoduna göre düşük seviyede kalmıştır. Eşlendirilmiş *t*-test bulgularına göre ise oluşturulan iki model ağına ait tahminler gözlem verileri ile uyumludur (p>0,05).

Çizelge 4.29 DÖ metoduna ilave argümanlar eklenerek tekstür verileri ile elde edilen NBÜ (S2, 45°) ve YAİ (S2, 0°) modellerinin model- test için performans ölçütleri

DÖ		**R^2**	**r**	**RMSE**	**MAE**	**AIC**	**Eşlendirilmiş *t*-test**	
Model	NBÜ-45°	0,74	0,86	59,139	44,546	38,080		
	YAİ-0°	0,79	0,89	0,274	0,213	40,706	***t***	**p**
Test	NBÜ-45°	0,56	0,75	67,701	56,713	38,215	0,659	0,513
	YAİ-0°	0,52	0,72	0,387	0,328	41,051	0,114	0,910

5. TARTIŞMA

5.1 Net Birincil Üretim Bulgularının Değerlendirilmesi

Ankara Orman Bölge Müdürlüğünde yayılış gösteren saf karaçam meşcerelerinin net birincil üretimi (NBÜ) CASA model kullanılarak hesaplanmıştır. 2019 yılı ortalama net üretim 601,610 gC m^{-2} $yıl^{-1}$ iken minimum ve maksimum NBÜ değerleri 283,963 gC m^{-2} $yıl^{-1}$ ve 960,038 gC m^{-2} $yıl^{-1}$'dir. Vejetasyon süresi ortalama sıcaklığın $+10^0$C ve üzeri olduğu aylardır ve çalışma alanı için saf karaçamın yayılış yaptığı alanlarda Mayıs-Ekim aylarını kapsamaktadır. Bu süreçte en düşük ve en yüksek NBÜ değerleri sırası ile Ekim ayında 27,307 ve Temmuz ayında 171,702 gC m^{-2} ay^{-1}'dir. Çalışma alanında vejetasyon sürecindeki NDVI değerleri 0,500'ün altına düşmemiştir. Güneş radyasyonu 11,415 MJ m^{-2} ve 23,523 MJ m^{-2} arasında değişmektedir.

Bulut *et al.* (2019) yaptıkları çalışmada 2016 yılı için Çankırı Orman İşletme Şefliği sınırları içerisinde bulunan 5517,44 ha'lık saf karaçam meşcerelerinin NBÜ'sünü CASA modeli kullanarak hesaplamışlardır. Çalışmada saf karaçam meşcerelerinde yıllık ortalama NBÜ'yü 382,820 gC m^{-2} olarak belirlemişlerdir. Bu çalışma ile kıyaslandığında arada 218,79 gC m^{-2}'lik fark ortaya çıkmaktadır. Bu farklılığın temel nedenleri, çalışma alanlarının topoğrafik (eğim, bakı, arazi yüzü şekli, yükselti), edafik (toprak özellikleri), klimatik (ışık, sıcaklık, hava nemi, yağış, hava hareketleri, rüzgar) faktörler ve meşcere karakteristikleri (meşcere gelişim çağı, kapalılık sınıfı, meşcere yaşı, bonitet sınıfı vb.) açısından farklılık göstermeleridir.

Bu çalışmada en yüksek NBÜ değeri Temmuz ayında (171,702 gC m^{-2} ay^{-1}), Bulut *et al.* (2019) tarafından yapılan çalışmada ise Mayıs ayında (120,830 gC m^{-2} ay^{-1}) elde edilmiştir. Bölgenin genelinde saf karaçam meşcerelerindeki üretim Temmuz ayına kadar artan bir şekilde devam ederken, bölgedeki lokal ölçekli alanda Mayıs ayından sonra azalmaya başlamaktadır. Bunun farklı bir göstergesi de bitki örtüsü yoğunluğu ile ilişkili olan NDVI vejetasyon indisidir. Bölgede bu değer, Temmuz ayında maksimuma ulaşarak 0,584 olarak hesaplanmıştır. Lokal ölçekli alan ise en yüksek değere 0,455 ile Mayıs ayında ulaşmıştır.

Taşkınsu Meydan (2008) yaptığı tez çalışmasında farklı ağaç türleri ve karışık meşcerelerin NBÜ değerlerini CASA model kullanarak tahmin etmiştir. Akdeniz bölgesinde seçilen çalışma alanında karaçam meşcereleri için en yüksek NBÜ değerini Haziran ayında 52,250 gC m^{-2} ay^{-1}, en düşük değeri ise Mart ayında 0,280 gC m^{-2} $ay^{-}1$ olarak tahmin etmiştir. Yapılan bu tez çalışmasında ise en yüksek NBÜ değerine Temmuz ve en düşük değerine Aralık ayında ulaşılmış olup ortalama veriler sırası ile 171,702 ve 0,052 gC m^{-2} ay^{-1}'dir. İki alandaki NBÜ farkının esas nedenleri klimatik faktörler ve çalışma için kullanılan karaçam meşcerelerinin karakteristik özellikleridir. Bu çalışma için seçilen Karadeniz bölgesi ardı saf karaçam meşcerelerinin yayılış gösterdiği alanlarda ortalama sıcaklık en yüksek değerine 21 °C ile Ağustos ayında ulaşırken en düşük sıcaklık -1 °C ile Ocak ayında tespit edilmiştir. Akdeniz bölgesinde ise Ağustos ayında yılın en yüksek ortalama sıcaklık değeri 29 °C'yi göstermektedir. En düşük sıcaklık ise Ocak ayında 11 °C'dir. Bu veriler ışığında Karadeniz bölgesi ardında saf karaçam meşcereleri Temmuz ayında 171,702 gC m^{-2} ay^{-1} net üretim yaparken Akdeniz bölgesinde yağışın azalıp sıcaklığın yükselmesi ile en yüksek ortalama NBÜ değeri 52,250 gC m^{-2} ay^{-1} seviyesinde kalmaktadır. Akdeniz bölgesinde ortalama sıcaklığın yıl boyu 10 °C'nin altına düşmemesi de üretimin belirli bir düzeyde devam etmesini sağlamaktadır.

Bu çalışma ve Bulut *et al.* (2019) bulgularına göre ortalama sıcaklık ile yağış verilerinin aylara göre yıllık trendleri birbirleri ile uyumludur. Sıcaklık ve yağış uyumlu iken bitki örtüsündeki üretim farkı özellikle yetişme ortamı özellikleri ile ilgilidir. Geniş alandaki saf karaçam meşcerelerinin tamamı olmasa da 1. ve 2. bonitet alanlar net üretimdeki ortalamayı üst seviyelere çıkarabilmektedir. Lokal ölçekte yapılan çalışma için seçilen saf karaçam meşcereleri bonitet itibari ile yetişme ortamı verim gücünün düşük olduğu alanlardır (Anonim 2020). Sıcaklık ve yağış üretim için elverişli olsa da toprak özellikleri itibari ile suyun toprakta tutulamaması ve besin açısından fakir olması nedeni ile NBÜ değerleri düşük seviyede kalmaktadır.

Karşılaştırılan alanlardaki karaçam meşcere özelliklerinin farklı oluşu NBÜ değerleri arasındaki değişkenliğin nedenlerinden biridir. Bu çalışmada karaçam meşcerelerinde her bir yaş sınıfı için envanter yapılmıştır. Kullanılan yersel veri setleri içerisinde genç,

orta yaşlı ve yaşlı meşcerelere ilişkin değerler bulunmaktadır. Taşkınsu Meydan (2008) yaptığı tez çalışmasında ise karaçam meşcerelerine ait belirtilen ortalama yaş 92, bu çalışmada ise ortalama yaş 74'tür. Bu verilere göre NBÜ'sü hesaplanan meşcereler bu çalışmada daha genç iken Taşkınsu Meydan (2008) çalışmasında daha yaşlıdır. Genç meşcerelerde NBÜ seviyelerinin yüksek oluşundan dolayı bu çalışmaya ait karaçam meşcerelerinde NBÜ değerlerinin daha yüksek çıktığı ve ortalamayı artırdığı düşünülmektedir (Field *et al.* 1995, Wang *et al.* 2018).

NBÜ, bitki örtüsünün klimatik faktörlere olan tepkisini yorumlamak için kullanılan en önemli göstergelerden biridir. Ayrıca topoğrafik özellikler ve vejetasyon tipi, NBÜ ile önemli düzeyde ilişkilidir (Bilgili *et al.* 2020). Bu ilişkileri incelemek amacıyla saf karaçam meşcereleri için hesaplanan NBÜ ile yağış, sıcaklık, yükselti ve meşcere gelişim çağlarının değişimi basit varyans analizi kullanılarak incelenmiştir (Çizelge 4.2). Sıcaklık yükselişi ile NBÜ'de artış gözlemlenmiştir. Sıcaklık, vejetasyon döneminin başlangıcı ve bitkilerde fotosentez süreci için en önemli etkenlerden biridir. Farklı sıcaklık koşulları altında gelişen bitki türleri için optimal sıcaklık değerleri değikendir. Bitkilerde optimal sıcaklık değerine kadar fotosentez artışı görülmektedir. Sıcaklık optimal değerin üzerine çıktığında ise yıkıcı etkiler meydana gelmektedir (Taiz and Zieger 2008). Saf karaçam alanlarında sıcaklık artışı fotosentez için uyumlu optimal sıcaklık değerine kadar NBÜ'yü artırıcı etki yapmaktadır. Çalışma alanı için saf karaçam meşcerelerinde optimal sıcaklık 21,1 °C olarak belirlenmiştir. Sıcaklık sınıfları yapılan analizde optimal sıcaklık değerinin altında kaldığı için bu artış birim alandaki net üretime pozitif etki yapmıştır. Sıcaklık artışı NBÜ'yü her zaman pozitif yönde etkilemeyebilmektedir. Clark *et al.* (2003) yaptıkları çalışmada tropikal ormanların NBÜ'sünün sıcaklık artışı ile azaldığını tespit etmişlerdir. Sıcaklık artışı aynı zamanda solunumun hızlanmasına neden olmaktadır. Bitkilerde solunum ise madde kaybına neden olarak net üretimi azaltıcı etki yapmaktadır. Optimal sıcaklık değerine kadar NBÜ'yü artıran sıcaklık, eşik değeri aşıldığında bitki örtüsünün NBÜ seviyesini düşürebilmektedir.

Yağış için yapılan varyans analizinde NBÜ ile aralarında negatif yönlü bir ilişkinin olduğu görülmektedir. Yağışın olması topraktaki nemliliğe artırıcı etki yapmaktadır ve

bunun da NBÜ'ye olumlu etki yapması beklenmektedir. Bu kıyaslamada yağışın yanında etkili olan kriterlerden biri de yükseltidir. Yükselti artışı ile NBÜ'de azalış meydana geldiği belirlenmiştir (Çizelge 4.2). Yükselti artışında yağışta da artış meydana geldiğinden, çalışma alanı için NBÜ ile yağış arasında negatif yönlü bir ilişki bulunmuştur. Yükseltinin fazla olduğu alanlarda net üretimin düşük seviyelerde kalması ve yağışın artması ile böyle bir sonuca ulaşılmıştır.

Yükselti sınıflarına göre NBÜ için yapılan varyans analizinde yükselti arttıkça NBÜ'nün azaldığı belirlenmiştir. İstatistiksel olarak 2 grup oluşsa da NBÜ değerlerine bakıldığında yükselti artışı ile azalan bir NBÜ dağılımı görülmektedir. Çünkü yüksek dağ ekosistemlerindeki zorlu şartlarda bitkilerin üretim kabiliyetleri zayıflamaktadır. Dönmez *et al.* (2015) lokal olarak nitelenebilecek bir alan için yaptıkları çalışmada, NBÜ ve yükselti arasında negatif yönde ilişki bulmuşlardır.

Meşcere gelişim çağları ve NBÜ arasındaki ilişkiler incelendiğinde, "a" gelişim çağındaki genç meşcerelerin diğer çağlardaki meşcerelere göre daha yüksek oranda NBÜ'ye sahip oldukları tespit edilmiştir (Çizelge 4.2). Meşcerelerde a, b, c ve d gelişim çağları için hesaplanan ortalama NBÜ değerleri sırası ile 884,995, 685,000, 617,822 ve 547,341 gC m^{-2} $yıl^{-1}$'dir. Varyans analizi sonuçlarına göre gelişim çağları ortalama NBÜ değerlerine göre 3 farklı gruba ayrılmıştır. En fazla net üretim "a" gelişim çağında, en düşük "d" gelişim çağında görülmüştür. Wang *et al.* (2011) farklı orman tipleri için NBÜ belirleyerek, meşcere yaşına göre değişimini analiz etmişlerdir. Elde edilen bulgulara göre yaprak döken iğne yapraklı, herdem yeşil geniş yapraklı ve karışık geniş yapraklı ormanlarda ortalama 50 yaşına kadar NBÜ en yüksek seviyeye ulaşmaktadır. Tropik ve subtropikal bölgelerde herdem yeşil iğne yapraklı ormanlar ise 13 yaşında maksimum NBÜ'ye ulaşmaktadır. Ayrıca yaşlı meşcerelerde NBÜ, maksimuma ulaştığı değerin yarısına (Ryan *et al.* 2004) veya üçte birine (Luyssaert *et al.* 2008) kadar düşmesi beklenmektedir.

Yıllık ölçekli NBÜ araştırmalarının yanında belli bir zaman periyodunu kapsayan çalışmalar da vardır. Bu çalışmalar bitki örtüsünün iklim şartlarına olan tepkisini ortaya

koymak ve anlamak için oldukça önemlidir. Chen *et al.* (2017) yaptıkları çalışmada 1984 ve 2014 yılları arasında NBÜ'nün zamansal ve konumsal değişimini analiz etmişlerdir. NBÜ'ye ilişkin ölçüm verilerinin yanında CASA modeli ile de tahmin yapılmıştır. Sonucunda yıllık ortalama sıcaklık, yağış, güneş radyasyonu ve ortalama NDVI'nın NBÜ'yü etkilediği belirlenmiştir. Özellikle yağışın ve sıcaklığın artış gösterdiği yıllarda NBÜ seviyesi de yükselmiştir. Çalışmanın yapıldığı 31 yıllık süreçte en yüksek korelasyon ilişkisi NBÜ ile güneş radyasyonu arasında bulunmuş olup bunu yıllık ortalama NDVI ve sıcaklık izlemektedir. Ji *et al.* (2020) yaptıkları çalışmada 2000-2018 yılları arasındaki NBÜ dağılımını izlemiş ve yorumlamışlardır. Bulgulara göre yıllar sürecinde NBÜ'nün artış gösterdiği ve bu artışta en önemli faktörün yağış olduğu tespit edilmiştir. Erşahin *et al.* (2016) tarafından yapılan çalışmada Anadolu ormanlarının NBÜ'sünü MODIS uydu verisi kullanarak 2000-2010 yılları için yorumlamıştır. İklim anormalliklerinin NBÜ üzerinde kısa vadede etkili olduğu ve NBÜ'deki değişikliklerin iklimin orman ekosistemi üzerindeki etkilerini izlemede iyi bir gösterge olabileceği ifade edilmiştir. Wang *et al.* (2017) CASA model kullanarak 2001-2012 yılları için NBÜ tahmini yapmışlardır. NBÜ'nün farklı zaman aralıkları ve bölgelerde farklı etki faktörlerine sahip olduğu tespit edilmiş ve bazı bölgelerde NBÜ ile güneş radyasyonu arasında pozitif yönlü ilişki bulunmuştur. Wang *et al.* (2016) kurak ve yarı kurak alanlarda iklim değişikliğinin 2000-2010 yılları arasında NBÜ'ye etkisini araştırmışlardır. NBÜ, çalışma alanının %66,11'inde ortalama sıcaklık, %91,47'sinde ise yıllık yağış ile pozitif yönde korelasyon göstermiştir. NBÜ için sıcaklığın kış aylarında kısıtlayıcı, yağışın yaz aylarında en büyük destekleyici faktör olduğu belirtilmiştir.

Farklı bölgelerde ve iklim şartlarında gerçekleştirilen çalışmalar, meteorolojik veriler ile NBÜ arasındaki ilişkileri ortaya koymaktadır. Her bir bölgeyi yetişme ortamı ve klimatik özelliklerine göre sınıflandırarak analiz etmek, NBÜ'nün değişimini ve hangi kriterlerden etkilendiğini anlamak için oldukça faydalıdır. Özellikle kurak ve yarı kurak alanlarda iklim dinamiklerinin NBÜ'ye etkisi daha farklıdır. Yağışın artması toprak nemini yükseltmekte, fotosentezi ve bitki örtüsü verimliliğini artırmaktadır (Ciais *et al.* 2005). Bu alanlardaki sıcaklık artışı fotosentez ve solunumun yanında su kaybını artırmakta ve toprak nemini azaltmaktadır. Bunun sonucunda kuraklık oluşmakta ve

bitki örtüsü NBÜ'sünde azalış eğilimi meydana gelmektedir (Zhao *et al.* 2005, Brohan *et al.* 2006). Bu çalışmanın yapıldığı saf karaçam meşcereleri de yarı kurak bölgede bulunmaktadır. Yapılan çalışmada yılın 12 ayı için ortalama NBÜ ve iklim parametreleri incelenmiştir. Bölgede 2019 yılı için aylık yağış Haziran ayına kadar artış eğilimindedir. Bu aylar sürecinde ortalama sıcaklığın artışı ile NBÜ de artış göstermiştir. Temmuz ayında yağış miktarında ani bir azalma olsa da NBÜ seviyesi yükselmiştir. Bu durumda topraktaki nemlilik sayesinde sıcaklık artışı ile üretim artarak devam etmiştir. Kurak veya şiddetli kurak bölgelerde yağış azalışı bitki örtüsünde hızlı bir tepkiye ve NBÜ seviyesinde azalışa neden olabilmektedir. Eylül ayı sonrasında ise bölgede mevsim normalleri gereği yağış artsa da ortalama sıcaklık değerlerindeki düşüş NBÜ'nün azalmasına neden olmuştur.

İklimsel değişikliğinin lokal, ulusal ve küresel ölçeklerde bitki örtüsünün gelişimine nasıl yön verdiği NBÜ ile izlenebilmekte ve yorumlanabilmektedir. Yapılan araştırmalar, iklim şartlarının bitki örtüsü ile olan etkileşimini açıklamada NBÜ'nün çok önemli ve başarılı bir gösterge olduğunu ortaya koymaktadır. İklim değişikliğini ve küresel ısınmayı da hesaba katacak olursak bu parametrenin önemi daha da artmaktadır. Ülkemiz ormanları için bu konuda araştırmalar yapılması için NBÜ'nün farklı ölçeklerde ve zaman dilimlerinde belirlenmesi gerekmektedir. Bu doktora tezi ile saf karaçam ormanlarında meşcere parametreleri, meteorolojik veriler ve NBÜ arasındaki ilişkiler yorumlanmaya çalışılmıştır. Böylece hangi iklim şartlarında ve hangi meşcere gelişim sürecinde NBÜ'nün en düşük veya en yüksek seviyede olabileceği anlaşılmaya çalışılmıştır. Bunun sonucunda net üretim oranı yüksek meşecerelerin kurulması için uygulanacak silvikültürel müdahalelerin belirlenmesine fayda sağlayacaktır.

5.2 Yaprak Alan İndeksine Ait Bulguların Değerlendirilmesi

Bu çalışmada saf karaçam meşcereleri için hesaplanan yaprak alan indeksi (YAİ) değerleri 0,332 m^2 m^{-2} ile 3,525 m^2 m^{-2} arasında değişmektedir. Literatürde YAİ değerlerinin 1 ile 20 m^2 m^{-2} arasında değiştiği belirtilmiştir (Kara vd. 2011). Çalışma alanının yarı kurak bir bölgede olması, YAİ değerinin 1 m^2 m^{-2}'nin altına düşmesine neden olabilmektedir. Çünkü YAİ değerleri çeşitli ekosistemlere göre farklılık arz

etmesinin yanında kurak bölgelerde 1 m^2 m^{-2}'nin altına düşebilmektedir. Örnek alanlara ilişkin YAİ ve meşcere parametreleri arasındaki en yüksek ilişki pozitif yönde N ile YAİ arasındadır (r = 0,58). Buna karşın meşcere yaşı (r = -0,30) ve dg (r = -0,30) ile negatif yönde ilişkiler elde edilmiştir. Elde edilen bulgular doğrultusunda meşcere özelliklerinden YAİ'yi etkileyen en önemli parametrenin N olduğu tespit edilmiştir. Bununla birlikte, bu çalışmada meşcere yaşı arttıkça YAİ değerinin azaldığı görülmüştür. 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 N ile elde etmişlerdir (r = 0,564).

Yer (2021) yaptığı çalışmada saf karaçam meşcereleri için YAİ ile meşcere parametreleri arasındaki ilişkileri araştırmıştır. Çalışmada en yüksek ilişki seviyesi YAİ ile sıklık derecesi arasında elde edilmiştir (r=0,69). Ayrıca değişen sıklık derecelerine göre YAİ'de anlamlı farklılıkların olduğu, sıklık derecesi arttıkça YAİ'nin de arttığı tespit edilmiştir. Yer (2021) çalışmasında elde edilen bulgular, bu çalışma ve Ercanlı *et al.* (2018)'in elde ettiği bulguları destekleyebilmektedir. Her ne kadar ağaç sayısı ile sıklığın belirlenmesi yeterli olmasa da söz konusu iki değişken arasında doğrusal bir ilişki olduğu bilinmektedir (Reineke 1933).

Pokorny and Stojnic (2012) yaptıkları çalışmada, Norveç ladini (*Picea abies* [L.] Karst.) meşcereleri için YAİ ve meşcere yaşı arasındaki ilişkileri araştırmışlardır. Elde edilen sonuçlarda, genç meşcerelerde YAİ'nin en yüksek, yaşlı meşcerelerde ise en düşük seviyede olduğunu ifade etmişlerdir. Özbayram vd. (2015) yaptıkları çalışmada, kızılçam ve karaçam meşcereleri için YAİ ile meşcere yaşı arasındaki ilişkileri incelemişlerdir. Kızılçam meşcerelerinde bu ilişkiyi pozitif yönlü, karaçam meşcerelerinde ise negatif yönlü bulmuşlardır. Bu durum çalışmaya konu kızılçam meşcerelerinin yetişme ortamı ile ilgilidir. Karstik alanlarda yayılış yapması ve buna bağlı olarak genç meşcerelerinde kapalılığın düşük seviyeli olmasından dolayı YAİ değerleri genç meşcereler için düşük seviyede kalmıştır. Bu durum meşcere gelişim sürecini kapsayan veri seti için YAİ ve meşcere yaşı arasındaki ilişkinin pozitif yönlü olmasına neden olmuştur. Karaçam meşcerelerinde ise yaş artışı ile ağaç sayısının azalması ve tepe çatısının açılması YAİ seviyesini düşürmektedir.

Jagodzinski and Kalucka (2008) tarafından yapılan çalışmada genç sarıçam meşcerelerinde meşcere yaşı ile YAİ arasındaki ilişkiler araştırılmıştır. Bu çalışmada örneklenen meşcerelerin yaşı 0-20 arasında değişmektedir. Meşcerelerde ilk 20 yılda meşcere yaşı ve YAİ ilişkisinin zamana bağlı olarak arttığı görülmüştür. Maksimum YAİ değeri 17 yaşında belirlenmiş (2,08 m^2 m^{-2}), sonraki yaşlarda hızla azalmaya başlamıştır (1,59 m^2 m^{-2}). Bu durum gençlik çağındaki meşcerelerin olgunlaşması sürecinde görülebilmektedir. Özellikle aynı yaşlı ormanlarda meşcerelerin kapalılık oluşumuna kadar YAİ'deki artış devam etmektedir (Ryan *et al.* 1997). Ardından uygulanan müdahaleler ve doğal gövde ayrılmaları ile meşcere yoğunluğunun azalmasından dolayı YAİ kademeli olarak azalmaktadır (Parker and Russ 2004, Meng *et al.* 2006).

Bu çalışmada dg ile YAİ arasında negatif yönlü ilişki bulunmuştur (r = -0,30). Meşcere yaşı ile çap gelişimi devam ederken meydana gelen gövde ayrılmaları, tepe çatısının açılmasına ve ağaç sayısının azalmasına neden olmaktadır. Böylece dg'nin arttığı süreçte YAİ'de azalış meydana gelmektedir (Özbayram vd. 2015, Ercanlı *et al.* 2018). Bu ölçütlerin yanında meşcere kuruluş tipleri de YAİ'yi etkileyen faktörlerden biridir. Kara vd. (2011) yaptıkları çalışmada saf göknar, saf kayın ve karışık göknar-kayın meşcerelerinde YAİ değerlerinin nasıl değiştiği araştırılmıştır. Saf kayın meşcerelerindeki YAİ değeri saf göknar meşcerelerine göre daha yüksek bulunmuştur. En yüksek YAİ değerini karışık meşcereler için elde etmişlerdir. Karışık meşcerelerdeki düşey kapalılığın YAİ'yi artırıcı etki yaptığı ifade edilmiştir.

Bu çalışmada YAİ ile G arasında 0,35, YAİ ile $h_{üst}$ arasında 0,11 korelasyon ilişkisi bulunmuştur. Özbayram vd. (2015) kızılçam meşcerelerinde YAİ ve G arasında pozitif yönlü 0,69 korelasyon ilişkisi bulmuşlardır. Karaçam meşcerelerinde ise YAİ ile G ve $h_{üst}$ arasında anlamlı ilişkiler bulunamamıştır. Zayıf ilişkinin nedeni olarak yeterli örnek sayısının bulunmadığı belirtilmiştir. Bu çalışmada YAİ ile $h_{üst}$ arasında anlamlı bir ilişki bulunamamıştır (r=0,11). Meşcerelerde $h_{üst}$ artışı meşcere yaşı ile doğru orantılı gelişmektedir. Dolayısı ile meşcere yaşı ve YAİ arasındaki negatif ilişkiden dolayı $h_{üst}$ ile YAİ arasında da negatif ilişki beklenmektedir. Oysa elde edilen 180 adet örnek alan verileri ile YAİ ve $h_{üst}$ arasında pozitif yönlü ilişki bulunmuştur. Bunun birincil nedeni

araştırılan bu ilişkiye yönelik kullanılan veri setinde aykırı verilerin bulunmasıdır. Bu durum YAİ'nin 0,300 ve 0,750 m^2 m^{-2} aralığındaki kapalılık oranı düşük genç meşcereler (Çkab1, Çkb1, Çkbc1) ile 3,000 ve 3,500 m^2 m^{-2} aralığındaki kapalılık oranı yüksek yaşlı meşcerelerden (Çkcd3, Çkd3) kaynaklanmaktadır. Diğer bir neden olarak YAİ'nin belirlenme yöntemi 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.

Yapılan bazı çalışmalarda G ile YAİ arasında yüksek seviyede ilişki bulunmuştur. Amaral *et al.* (1996) tropikal ormanlardaki gençleştirme alanlarında, G ile YAİ arasındaki ilişkileri incelemişlerdir. İki parametre arasındaki korelasyon 0,95 olarak bulunmuştur. Buckley *et al.* (1999) yaptıkları çalışmada meşe ve çam meşcerelerinden elde ettikleri G'yi kullanarak YAİ'yi modellemişlerdir. Meşe meşcereleri için G ile YAİ arasındaki korelasyon 0,98, çam meşcerelerinde ise 0,99 bulunmuştur. Bu çalışmalarda, G gibi pratik ölçümlü değişkenlerin YAİ'nin modellenmesi için önemli seviyede potansiyele sahip olduğu ifade edilmiştir. Ayrıca yüksek seviyeli ilişki, YAİ'nin bitki örtüsünün yapısal özelliklerini belirleyici bir faktör olabileceği belirtilmiştir. İncelenen bu iki çalışmada da ilişki seviyeleri oldukça yüksektir. Amaral *et al.* (1996) çalışmasının genç meşcerelerden ve Buckley *et al.* (1999) çalışmasının plantasyon sahalarından oluşması yüksek ilişkinin nedenlerinden sayılabilir. Her iki çalışmanın da sahip olduğu diğer belirgin özellik kullanılan veri sayısının çok az sayıda olmasıdır. Amaral *et al.* (1996) çalışmasında 8, Buckley *et al.* (1999) ise 10 adet veri kullanmıştır. İki parametre de orman ekosisteminde yapısal özelliklerin yorumlanması için potansiyeli yüksek donelerdir. Fakat bu durumda ilişki gücü yüksek olsa da belirgin ve kesin sonuçlara ulaşmak için daha fazla sayıda örnekleme yapılmalı ve farklı yapıdaki orman tiplerinde bu ilişkileri araştırmak gerekmektedir.

Literatürde YAİ değerlerinin arazi şartlarının kuraklık-nemlilik durumlarına göre yüksek oranda değişkenliğe sahip olduğu belirtilmektedir (Kozlowski *et al.* 1991, Asner *et al.* 2003). Orman ekosistemlerinde YAİ'nin bu ölçüde değişimi tamamen meşcere karakteristiklerine bağlı değildir. İklim koşulları ve yetişme ortamı şartları da YAİ'yi

büyük ölçüde şekillendirmektedir. Yaprak alanı ne kadar artarsa intersepsiyon ve transpirasyon oranı o miktarda artış göstermektedir. Kurak mıntıkalarda su açığı seviyesi yüksek olduğu için bitkiler terleme ile su kaybını azaltmak için yaprak yüzeylerini küçük boyutta geliştirirler. Bu sayede meydana gelebilecek su kaybı azaltılmış olmaktadır. Bu dinamikler doğrultusunda 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).

5.3 Döküm Bulgularının Değerlendirilmesi

Saf karaçam meşcerelerinden aylık döküm miktarları 2019 yılı Mayıs-Aralık ayları süresince 6 farklı bileşene (ibre, dal, kozalak, kabuk, erkek çiçek ve diğer) ayrılarak elde edilmiştir. Döküm verilerinin elde edildiği 8 aylık süreç için birim alandaki toplam döküm miktarı 305,7964 g m^{-2} bulunmuştur. Toplam miktardaki en büyük pay 192,5657 g m^{-2} ile ibre dökümüne aittir (%63). En düşük pay ise 8,2530 g m^{-2} olup dal dökümü için tespit edilmiştir (%3). Bu oranlar kozalak (33,5375 g m^{-2}), kabuk (30,0335 g m^{-2}), erkek çiçek (22,5968 g m^{-2}) ve diğer (18,8098 g m^{-2}) döküm bileşenleri için sırası ile %11, %10, %7 ve %6'dır. Koray ve Tolunay (2020) toplam döküm içerisindeki ibre miktarının payını ortalama %53 olarak belirtmişlerdir. Çakır vd. (2019) yaptıkları çalışmada karaçam ağaçlandırma alanlarında "ab", "b" ve "c" gelişim çağındaki meşcerelerin ibre döküm oranının toplam dökümdeki paylarını sırası ile %76, %57 ve %55 olarak tespit etmişlerdir. Meşcere gelişim sürecinde ibre miktarının toplam dökümdeki oranının azaldığı görülmektedir. Tüfekçioğlu vd. (2005) Artvin Genya dağı doğu ladini (*Picea orientalis* L. Link) meşcereleri için yaptıkları çalışmada ibre döküm oranının %44 olduğunu bulmuşlardır. Pausas (1997) yaptığı çalışmada sarıçam ormanlarında toplam dökümdeki ibre döküm oranının %45-60 arasında olduğunu tespit etmiştir. Bu çalışmalar içerisinde Çakır vd. (2019) "ab" meşcereleri için buldukları %76'lık oran diğer bulgulara göre yüksek sayılabilecek bir orandır. Bu sonuca etki eden en önemli parametre meşcere sıklığıdır. Bununla birlikte farklı çalışmalar için elde edilen bu değişkenliğin sebepleri meşcere özellikleri, iklim özellikleri, toprak özellikleri

ve uygulanan silvikültürel müdahalelerdir (Berg and Meentemeyer 2001, Negash and Starr 2013).

Aylık toplam değerlere bakıldığında (Çizelge 4.6, Şekil 4.8) en az döküm Kasım ayında gerçekleşmiştir (7,8095 g m^{-2}). Dökümün en yüksek görüldüğü aylar Haziran (59,2300 g m^{-2}), Eylül (58,0100 g m^{-2}) ve Aralık (54,0857 g m^{-2}) aylarıdır. Carvalho *et al.* (2019) karışık (*Pinus caribaea, Pinus oocarpa* ve *Pinus taeda*) ve saf (*Pinus caribaea var. hondurensis*) çam meşcereleri için aylık döküm miktarlarını incelemişlerdir. Bulgulara göre en yüksek toplam döküm miktarı karışık meşcereler için Haziran (392,44 kg ha^{-1}), saf meşcereler için Nisan (368,43 kg ha^{-1}) ayında gerçekleşmiştir. En düşük döküm miktarları iki meşcere sınıfı için de Şubat (karışık 105,93 kg ha^{-1}, saf 81,13 kg ha^{-1}) ayında tespit edilmiştir. Karışık meşcerelerde toplam döküm miktarının daha yüksek seviyede olduğu görülmektedir. Bu meşcere yapılarında farklı katmanlarda bireylerin bulunması, meşcere sıklığının daha fazla ve kapalılık oranının yüksek seviyede olma koşulları bu bulguyu desteklemektedir.

İbre döküm miktarının Mayıs (12,8510 g m^{-2} ay^{-1}), Haziran (16,1597 g m^{-2} ay^{-1}) ve Temmuz (12,7003 g m^{-2} ay^{-1}) aylarında en düşük seviyede olduğu gözlemlenmiştir. Eylül (51,0090 g m^{-2} ay^{-1}) ve Aralık (50,4428 g m^{-2} ay^{-1}) aylarında en yüksek miktarda ibre dökümü gerçekleşmiştir. Kumar and Tewari (2015) çalışmalarında muson ikliminin hakim olduğu Hindistan'da (Kuamun Himalaya) *Pinus roxburghii* meşcereleri için ibre, odun ve toplam dökümün en fazla yaz mevsiminde gerçekleştiğini belirtmişlerdir. Bu çalışma bulgularının tez bulguları ile çelişmesinde bölgede yazın yağan muson yağmurlarının etkisi vardır. Mayıs ayı ile başlayıp Ekim ayına kadar devam eden yağışlar, bütün döküm öğelerinin Mayıs, Haziran ve Temmuz aylarında en yüksek seviyede tespit edilmelerine neden olmuştur. Döküm envanterinin yapıldığı bölgede ise hava hareketliliğinin (yağış ve rüzgâr) Eylül ayı itibari ile artış göstermesi, elde edilen bulgularda ibre dökümünün bu aydan itibaren artış göstermesine etki etmiştir. Duyar (2018) yaptığı çalışmada Türkiye'nin Batı Karadeniz bölümünde değişik yaşlı Uludağ göknarı (*Abies nordmanniana* (Stev.) subsp. *bornmuelleriana* (Matff.)) meşcerelerinde döküm miktarlarının mevsimsel dağılımlarını belirlemiştir. En fazla miktarda yaprak dökümünün bahar (78,42 g m^{-2} ay^{-1}) ve yaz (74,22 g m^{-2} ay^{-1}) aylarında gerçekleştiği

belirtilmiştir. Erkan *et al.* (2018) yaptıkları çalışmada ibre ve toplam dökümün mevsimlere göre değişimini incelemişlerdir. Çalışmalarını Türkiye'nin güney batı bölümündeki saf ve aynı yaşlı kızılçam (*Pinus brutia*) meşcerelerinde gerçekleştirmişlerdir. Elde edilen sonuçlara göre en yüksek miktarda dökümün yaz aylarında meydana geldiği görülmüştür. Sıcaklık artışında meydana gelen kuraklık stresine bağlı apsisik asit ve etilen hormonlarının yaz aylarındaki dökümü artırdığı belirtilmiştir.

Dal dökümü için veriler incelendiğinde aylar arasında yüksek miktarda değişkenliğin olmadığı görülmektedir (Çizelge 4.6). Kasım ayında döküm kapanlarında herhangi bir dal dökümüne rastlanmamıştır. Aralık ayında ise kozalak dökümü gözlemlenmemiştir. Her ne kadar bu aylarda döküm kapanlarında dal ve kozalak örneklerine rastlanmamış olsa da bu durum dal ve kozalak dökümü olmadığı anlamına gelmemektedir. Özellikle ağır materyallerin yerden belirli yükseklikteki kapanlara yakalanma olasılığı hafif materyallere göre daha düşüktür. Bunun nedenlerinden en önemlisi ağır materyallerin birim alandaki sayısının hafif materyallere göre çok daha az olmasıdır. Döküm örnekleri alındığında da gözlemlendiği üzere bu aylarda saf karaçam meşcerelerinde hem dal hem de kozalak dökümü gerçekleşmiştir. Fakat ilgili döküm elemanlarının kapanlara yakalanmaması, bu aylarda en az seviyede dal ve kozalak dökümünün gerçekleştiği anlamını taşımaktadır. Haziran ayında en yüksek miktarda kozalak (16,2640 g m^{-2}) ve kabuk (12,8446 g m^{-2}) dökümü gerçekleşmiştir. Toplam dökümün en fazla olduğu aylardan biri olan Haziran ayında kozalak ve kabuk gibi ağır materyal dökümlerinin etkisi büyüktür. İbre dökümünün yüksek olmamasına rağmen kozalak ve kabuk dökümlerinin fazla olması toplam döküm miktarına önemli ölçüde katkı sağlamıştır. Ağaçlarda üreme yapıları düşük sıcaklık ve yüksek nem koşullarında birikirler (Carvalho *et al.* 2019). Bunula birlikte sonbahar ve kış aylarında biriken erkek çiçekler, sıcaklığın artış gösterdiği vejetasyon sürecinde dökülmeye başlamaktadır. Bu bilgilere paralel olarak bu çalışmada elde edilen bulgulara göre erkek çiçek dökümü en fazla Haziran ve Temmuz aylarında gerçekleşmiştir. En düşük miktarlar ise Kasım ve Aralık ayları için tespit edilmiştir.

Gözlem yapılan Mayıs-Aralık ayları süresince ibre dökümünde pozitif yönde artış eğilimi gözlemlenmiştir. Vejetasyon sürecinde ağaçlar üretim faaliyetleri içerisindedirler. Sıcaklık seviyesinin düşmesi ve vejetasyon sürecinin sonlanması ile yapraklı ağaçlarda yaprak dökümü olduğu gibi ibreli ağaçlarda da ibre dökümü hızlanmaktadır. Ortalama 3 yılını geçiren ibreler olgunlaşmakta ve dökülme meydana gelmektedir. Bu da üretim periyodundan sonraki aylarda gerçekleşmektedir. Güneş radyasyonu seviyesindeki azalış fotosentez oranını düşürmektedir ve bu durum bitkilerde yaprak dökümü için tetikleyici bir unsurdur (Zhang *et al.* 2014). Alınan veriler doğrultusunda ibre dökümünün fotosentetik faaliyetlerin azalış gösterdiği Eylül ayı itibari ile artışa geçtiği belirlenmiştir. Özellikle hava hareketlerinin etkisi ve hava koşullarının sertleşmesi ile karaçam bireyleri üzerindeki ölü ibrelerin hızla döküldüğü tespit edilmiştir. Dal, kozalak, kabuk, erkek çiçek ve diğer döküm elemanları için Mayıs-Aralık ayları süresince negatif yönde ilişki tespit edilmiştir (Çizelge 4.6, Şekil 4.9). İbre haricindeki döküm elemanları için Aralık ayına doğru giderek azalan bir eğilim gözlemlenmiştir. Dal, kabuk ve diğer (tohum, yosun, liken, ökse otu vb.) gibi döküm öğeleri için yıl içerisinde zamansal bir trend tespit edilse de çoğunlukla düzenli bir zamansal dağılıma sahip değillerdir. Dökümlerinin zamansal dağılımını şiddetli rüzgârlar ve yağışlar belirlemektedir (Berg and Laskowsky 2005, Blanco *et al.* 2006). Hava şartlarının yanında dal dökümünde etkili olabilecek unsurlardan biri meşcere kapalılığıdır. Kapalılık oranı düşük olan meşcerelere daha fazla güneş ışığı girebilmektedir. Meşcere içerisine giren yoğun ışık enerjisi yeni dal oluşumunu arttırdığı ve doğal dal budanmasını yavaşlattığı gibi dal dökümüne de azaltıcı etki yapabilmektedir (Lopez *et al.* 2008). Kozalak dökümünde ise hava koşullarının yanında meşcere özellikleri de etkilidir. Kozalak miktarı meşcere yaşı ve sıklığı ile negatif yönde ilişkilidir. Yaşlanan ve sıklığı yüksek meşcerelerde kozalak miktarı ve dolayısı ile kozalak dökümü azalmaktadır (Ayari *et al.* 2012).

Döküm elemanları farklı meşcere gelişim çağları (b, c ve d), kapalılık sınıfları (1, 2 ve 3) ve bakılara (kuzey ve güney) göre karşılaştırılmıştır. İbre dökümü "b" (3,2164 g m^{-2}) ve "c" (3,2302 g m^{-2}) gelişim çağlarında birbirine yakınken "d" (2,4142 g m^{-2}) gelişim çağında daha az bulunmuştur. Çakır vd. (2019) saf karaçam meşcerelerinde ibre dökümünü Çkb (203,8487 g m^{-2} $yıl^{-1}$) ve Çkc (214,0741 g m^{-2} $yıl^{-1}$) meşcere tipleri için

birbirine benzer olduğunu tespit etmişlerdir. Koray ve Tolunay (2020) meşcerelerin kapalılığı ve yaşı arttıkça döküm miktarlarının arttığını ifade etmişlerdir. Bu çalışmada elde edilen farklı bir durum da söz konusudur. Döküm envanterinin yapıldığı alanlarda "d" çağındaki meşcerelerin tamamı 1 kapalı meşcerelerden oluşmaktadır (Çizelge 4.5). Dolayısı ile yaşlı ve 1 kapalı meşcerelerden oluşan alanlarda ibre döküm seviyesi oldukça düşük tespit edilmiştir. Çepel vd. (1988) kızılçam için yaptıkları çalışmada en yüksek miktarda dökümün meşcere orta yaşında meydana geldiğini bulmuşlardır. Diğer yandan, Ranger *et al.* (2003) ibre dökümünün meşcere yaşı arttıkça azaldığını belirtmişlerdir. Özellikle sıklık ve kapalılığın azaldığı yaşlı meşcerelerde birim alandaki ibre miktarı azalacağından meşcere yaşı arttıkça dökümün azalması beklenen bir durumdur. Bu değişkenliklerin sebebi örneklenen meşcerelerin karakteristik özelliklerindeki farklılıklar ve çevresel koşullardır (Erkan *et al.* 2018).

Meşcerelerde sıklık, ağaç sayısı ve kapalılık oranı döküm miktarlarını etkileyen en önemli parametrelerdendir. Çömez *et al.* (2018) sarıçam "c" gelişim çağındaki meşcerelere uygulanan bakım çalışmalarının döküm miktarını %22 oranında azalttığını tespit etmişlerdir. Müdahalelerin "d" gelişim çağındaki meşcerelerde azaltıcı etkisi önemli düzeyde görülmeyip %8 oranında bulunmuştur. Uygulanan silvikültürel müdahaleler sonucunda meşcerelerin sıklık, ağaç sayısı ve kapalılık oranlarının azalması, döküm miktarlarının azalmasında önemli rol oynamışlardır. Bu nedenle meşcerelerdeki döküm miktarını kontrol etmek ve düzenlemek için sıklık ve kapalılık derecesi kullanılabilecek uygun parametrelerdir. Ayrıca döküm sayesinde orman toprağına girecek olan karbon miktarında büyük ölçekli ani azalmaların yaşanmaması için yapılacak bakım müdahalelerinin şiddeti büyük önem arz etmekte ve hassas bir şekilde belirlenmesi gerekmektedir.

Kapalılık sınıflarına göre en yüksek miktarda ibre dökümü 3 kapalı meşcerelerde tespit edilmiştir. Sırası ile 1, 2 ve 3 kapalı meşcerelerde ortalama döküm miktarları 1,7834 g m^{-2}, 2,9578 g m^{-2} ve 3,1079 g m^{-2}'dir. Kapalılığın fazla olmasından dolayı birim tepe alanındaki ibre miktarının fazla olması ve kapalılık arttığında alt dallardaki ışıksızlıktan dolayı tam kapalı meşcerelerde ibre dökümü daha fazla olmaktadır (Koray ve Tolunay 2020). Diğer döküm miktarı 1 kapalı alanlarda daha yüksek elde edilmiştir. Burada 1

kapalı örnek alanların tamamının “d” çağındaki meşcerelerden oluşmasının etkisi vardır. Çünkü yaşlı meşcerelerde özellikle ökse otu oranının yüksek oluşu “d” çağı ve 1 kapalı meşcerelerde diğer döküm miktarının fazla olmasına neden olmuştur. Ayrıca 1 kapalı alanlarda meşcere içi boşluklar daha fazla olduğundan hava hareketleri daha etkili olup erkek çiçek ve diğer döküm miktarlarını artırıcı etki yapmıştır.

Bakılara göre karşılaştırma yapıldığında ibre dökümü güney bakılarda ortalama 2,9686 g m^{-2}, kuzey bakılarda ise 2,7118 g m^{-2} bulunmuştur. Diğer bütün döküm elemanlarının ise kuzey bakılarda daha fazla olduğu gözlemlenmiştir. Elde edilen bulgularda iki bakı arasında önemli bir farklılık gözlemlenmemiştir. Çömez *et al.* (2018) yaptıkları çalışmada güney bakılarda daha fazla miktarda dökümün olduğunu belirlemişlerdir. Sarıçam meşcerelerinin toplam döküm miktarını, kuzey bakılarda 3220 kg ha^{-1} $yıl^{-1}$, güney bakılarda ise 4650 kg ha^{-1} $yıl^{-1}$ bulmuşlardır. Meşcere gelişimi döküm üzerinde önemli ölçüde etkiye sahiptir. Meşcerelerin gelişimi ise kapalılık, servet ve bonitetin kontrolü altındadır (Erkan *et al.* 2018). Bu meşcere özelliklerinin değişkenliği ile döküm miktarları da yüksek oranda değişkenlik göstermektedir. Dolayısı ile farklı çalışmalardaki bu meşcere özelliklerinin standart olmadığı düşünüldüğünde çalışmalar arasında ters ilişkilerin bulunması olağandır. Bu ilişki sıcaklık farkının belirgin düzeyde hissedildiği bakılarda daha iyi bir şekilde gözlemlenebilir. Çünkü sıcaklık artışı meydana geldiğinde ağaçlar kuraklık stresine karşı apsisik asit ve etilen hormonlarını biriktirirler. Kuraklığa karşı gösterilen bu tepki ise ağaçlarda dökümü tetiklemektedir (Graham *et al.* 2004, MacKay *et al.* 2012, Zhang *et al.* 2014). Bu durumda sıcaklık seviyelerinin daha yüksek olduğu güney bakılarda dökümün daha fazla olması beklenmektedir.

Orman ekosistemlerinde NBÜ, döküm miktarları ile doğrudan ilişkilidir (Dubber et al. 2017). Döküm ve NBÜ arasındaki ilişki seviyelerinde meşcerelerin özellikleri ve yetişme ortamı koşulları etkili olmaktadır. Bray and Gorham (1964) yıllık toplam yaprak dökümünün, yıllık toplam orman NBÜ’sünün yaklaşık 1/3’ünü oluşturduğunu ve yıllık toplam yaprak döküm miktarını 3 ile çarparak orman NBÜ’sünün tahmin edilebileceğini öne sürmüştür. Bu çalışmada elde edilen bulgulara göre ibre dökümü, NBÜ ile pozitif yönde ilişkili bulunmuştur (r=0,63). Çünkü meşcere gelişiminde yaş

arttıkça büyüme potansiyeli azalmakta ve NBÜ düşük seviyede gözlemlenmektedir (Çizelge 4.2). Meşcere kapalılığı döküm miktarına etki eden önemli bir meşcere özelliğidir (Chianucci *et al.* 2014). Meşcere yaşı artıkça özellikle meşcere kapalılığının azaldığı alanlarda ibre miktarı ve paralel olarak ibre dökümü de azalmaktadır (Şekil 4.10, 4.11). Dolayısı ile NBÜ ve ibre dökümü arasında pozitif bir ilişkinin elde edilmesi beklenen bir durumdur.

Ayari *et al.* (2012) kozalak sayısının, meşcere yaşı ve sıklığı ile ters orantılı olduğunu ifade etmişlerdir. Bu bulgu yaşlı meşcerelerdeki kozalak dökümünün daha az olduğunu göstermektedir. Bu çalışmada elde edilen bulgularda, bu sonuç ile ters olmakla birlikte meşcere yaşı ile kozalak dökümü arasında pozitif yönlü ilişki bulunmuştur (r=0,56). Bu doğrultuda meşcere yaşı ile artan kozalak dökümü, NBÜ ile negatif yönde ilişki göstermiştir (r=-0,62). Burada döküm örneklerinin alındığı meşcerelerin sıklığı ve müdahale şekli önem arz etmektedir. Bakım müdahalelerinin yapıldığı olgun meşcerelerde kozalak dökümü artış göstermektedir (Çömez *et al.* 2018). Sıklık oranı düşük meşcerelerde yapılan bakım müdahaleleri olgun meşcerelerdeki kozalak miktarına ve dökümüne pozitif yönde katkı yapabilir. Böylece meşcere yaşı ile azalması beklenen kozalak dökümünde meydana gelen artış, NBÜ verileri ile negatif yönde ilişki gösterebilir.

NBÜ ile erkek çiçek dökümü arasında hem zamansal hem de konumsal olarak yüksek seviyeli ilişkiler tespit edilmiştir. Zamansal ilişki incelendiğinde Mayıs-Aralık ayları için ortalama NBÜ ile erkek çiçek dökümleri eşleştirilmiş ve önemli düzeyde pozitif yönlü bir ilişki bulunmuştur (r=0,85). Bu bulgu karaçam bireylerinde yıl içerisindeki üretim yoğunluğunun fazla olduğu aylarda daha fazla erkek çiçek dökümünün gerçekleştiğini göstermektedir. Konumsal ilişkiye bakıldığında döküm için tesis edilen meşcerelerde NBÜ ve erkek çiçek dökümü arasında negatif yönde ilişki bulunmuştur (r=-0,75). Erkek çiçek dökümü sırıklık-direklik çağındaki (b gelişim çağı) meşcerelerde ortalama 0,2114 g m^{-2}, ince ağaçlık çağındaki (c gelişim çağı) meşcerelerde ortalama 0,3427 g m^{-2} ve orta ağaçlık çağındaki (d gelişim çağı) meşcerelerde ortalama 0,4499 g m^{-2} tespit edilmiştir (Şekil 4.11). Böylece erkek çiçek dökümünün meşcere gelişim sürecinde artış gösterdiği belirlenmiştir. NBÜ ise genç meşcerelerden yaşlı meşcerelere

doğru giderek azalan bir eğilim gösterdiği için (Çizelge 4.2) NBÜ ve erkek çiçek dökümü arasında konumsal olarak negatif yönlü bir ilişki tespit edilmiştir. Çakır vd. (2019) saf karaçam meşcerelerinde yaptıkları çalışmada erkek çiçek döküm miktarlarını Çkab, Çkb ve Çkc meşcereleri için sırası ile 10,6373, 3,2583 ve 16,3543 g m^{-2} $yıl^{-1}$ olarak belirlemişlerdir. Bu çalışmada da en fazla erkek çiçek dökümünün daha yaşlı meşcerelerde gerçekleştiği görülmektedir.

Döküm elemanlarından ağır materyal (dal, kozalak, kabuk vb.) miktarının belirlenmesinde döküm toplama tekniğine göre tutarsızlıklar oluşabileceğinden genellikle ibre-yaprak ve erkek çiçek gibi hafif materyal miktarları daha sağlıklı bir şekilde belirlenebilmektedir. Bu tutarsızlıklara örnek olarak, meşcerelerde Kasım ayında dal ve Aralık ayında kozalak dökümü olmasına rağmen bu aylarda örnek alanlardaki kapanlarda herhangi bir dal ve kozalak dökümüne rastlanmayışı verilebilir. Bu durumda NBÜ ile döküm ilişkileri incelendiğinde ibre ve erkek çiçek döküm miktarlarının karşılaştırılması doğru olacaktır. Döküm elemanlarından hafif bir materyal olan erkek çiçeğin aylık olarak izlenmesi, bu çalışmada NBÜ ile erkek çiçek döküm miktarının incelenmesine olanak sağlamıştır. Yapılan incelemede en yüksek seviyeli ilişki NBÜ ile erkek çiçek dökümü arasında belirlenmiştir (R^2=0,56, r=-0,75). Ayrıca Mayıs-Aralık ayları süresince ortalama verilere göre zamansal seyir uyumu bakımından en iyi parametrelerin NBÜ ve erkek çiçek dökümü olduğu görülmüştür (R^2=0,73, r=-0,85). Bu bulgulardaki en önemli kısıtlardan biri incelenen verilerin 8 aylık bir süreci kapsaması ve uzun yıllar için gözlemlenememiş olmasıdır. Literatürde NBÜ ile erkek çiçek döküm miktarının ilişki analizine rastlanmamıştır. Buna rağmen farklı meşcere yapılarında NBÜ ve erkek çiçek döküm miktarlarındaki uyum, fotosentetik faaliyetlerin gerçekleşme sürecinde erkek çiçek dökümünün önemli bir gösterge olabileceği varsayımını güçlendirmektedir. Ayrıca hafif bir materyal olduğu için sağlıklı bir şekilde belirlenme olanakları ve çalışma kapsamında yapılan analizler ile en yüksek ilişkiye sahip olması, erkek çiçek döküm miktarının farklı model ve teknikler ile tahmin edilen NBÜ'nün geçerlilik kontrolünün yapılmasında faydalı bir parametre olacağı düşünülmektedir. Buna ek olarak NBÜ'nün tahmin edilmesi için oluşturulabilecek pratik modellerde bağımsız değişken olarak kullanılabilir. Çalışma kapsamında elde edilen bu bulgunun anlamlaşması ve varsayımların kesinleşmesi için bu ilişkilerin farklı

bölgelerde ve farklı türler için en az 3-5 yıl gözlemlenmesi ve ilişkilerin incelenmesi gerekmektedir.

5.4 Modelleme Bulgularının Değerlendirilmesi

Bu çalışma kapsamında, yapılan orman envanteri çalışmasında 180 adet örnek alan alınmış ve her bir örnek alan için YAİ ile meşcere parametreleri (dg, $h_{üst}$, N, G ve V) hesaplanmıştır. Ayrıca örnek alanlar için CASA modeli kullanılarak aylık ve yıllık ölçekte NBÜ tahmin edilmiştir. Hesaplanan parametrelerin modellenmesi için bağımlı ve bağımsız değişkenlere ait veri setleri hazırlanmıştır. NBÜ ile YAİ'nin modellenmesinde yersel veriler olan meşcere parametreleri ve Landsat 8 Operational Land Imager (OLI) ile Sentinel-2 uydu görüntülerinden elde edilen uzaktan algılama verileri (reflektans, vejetasyon indisi ve tekstür) kullanılmıştır. Meşcere parametrelerinin modellenmesinde ise uzaktan algılama verilerinden yararlanılmıştır. Modelleme için çoklu regresyon analizi (ÇRA), destek vektör makineleri (DVM) ve derin öğrenme (DÖ) teknikleri kullanılmıştır. İlk aşamada ÇRA metodu kullanılarak 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 Sentinel-2 uydu görüntüsünden elde edilen tekstür verileri ile elde edilmiştir. İkinci aşamada ise en yüksek ilişkiyi gösteren modelin bağımsız değişkenleri ile DVM ve DÖ metotları uygulanmıştır. Ayrıca uygulanan bütün metotların model-test başarısı belirlenmiş ve eşlendirilmiş *t*-testi ile test tahminlerinin gözlem verileri ile uyumlu olup olmadığı kontrol edilmiştir.

Makine öğrenme algoritmalarından DVM ve DÖ metotlarında sıkça karşılaşılan aşırı uyum problemi için model-test başarıları kıyaslanmıştır. Elde ettiğimiz bulgulara göre DVM metodu için model-test başarı seviyeleri birbirleri ile uyumlu bulunmuştur. DÖ metodunun uygulandığı NBÜ-meşcere parametreleri (Model R^2=0,90, Test R^2=0,29), YAİ-meşcere parametreleri (Model R^2=0,72, Test R^2=0,46), NBÜ-45° tekstür (Model R^2=0,94, Test R^2=0,27) ve YAİ-45° tekstür (Model R^2=0,98, Test R^2=0,29) modellerinde model ve test başarıları arasındaki farktan dolayı aşırı uyum probleminin olduğu belirlenmiştir. Bu problemin oluşmasındaki nedenlerden bazıları eğitim veri

setinin yetersiz, temsil kabiliyeti zayıf ve aykırı veri oranının yüksek olmasıdır (Ying 2019). Problemin giderilmesi için modele erken durdurma (Raskutti *et al.* 2013), ağ indirgeme (Bramer 2002), veri genişleme (Karystinos and Pados 2000) ve düzenleme (Warde-Farley *et al.* 2013) argümanları eklenmiştir (Candel *et al.* 2016, MathWorks 2019). Bu işlemin sonucunda aşırı uyum probleminin etkileri büyük ölçüde giderilmiştir. Elde edilen bulgular NBÜ-meşcere parametreleri için Model R^2=0,64, Test R^2=0,51, YAİ-meşcere parametreleri için Model R^2=0,68, Test R^2=0,53, NBÜ-45° tekstür için Model R^2=0,74, Test R^2=0,56 ve YAİ-45° tekstür için Model R^2=0,79, Test R^2=0,52'dir.

DÖ metodunda ağın eğitilme sürecinde bağımlı ve bağımsız değişkenler arasındaki ilişkinin trendi belirlenmektedir. Mevcut veriler ile kurulan bu trend gerçeği yansıttığında model doğruluk oranı yeterli ve temsil kabiliyeti yüksek olmaktadır. Böylece eğitilen model ağı bağımsız veri gruplarına uygulandığında yeterli başarı düzeyinde sonuçlar alınabilmektedir. Bu durumda, modelleme için kullanılacak veri setlerinin karakteristiği büyük önem arz etmektedir. Aralarında herhangi bir organik bağ olmayan parametrelerin modellenmesinde belirgin bir trend oluşmamaktadır (Aertsen *et al.* 2010). Bu şekilde oluşturulan model ağının da genelleştirilmesi oldukça güç olmaktadır. Böylece oluşturulan model ağında koşturulan bağımsız veriler ile tutarlı bir tahmin yapılamamaktadır. Eğitim sürecindeki başarı yüksek olsa da makine öğrenme algoritmalarında sıkça karşılaşılan aşırı uyum problemi ortaya çıkmaktadır. Bunun sonucunda temsil kabiliyeti olmayan ve bağımsız veri gruplarının uygulanmasına olanak sağlamayan tutarsız tahminlere neden olmaktadır (Ying 2019).

NBÜ ve YAİ için üretilen modellerde aşırı uyum problemi ile karşılaşılmıştır. NBÜ çok sayıda veri grubu (fotosentetik veriler, meteorolojik veriler, uzaktan algılama verileri) kullanılarak tahmin edilen, YAİ ise meşcere yapılarına göre büyük oranda değişkenlik gösterebilen parametrelerdir. Modellenmelerinde kullanılan bağımsız değişkenler ile aralarında doğrudan bir ilişki ve bağ olmadığı için eğitilen ağda net bir trend oluşamamaktadır. Böylece test verileri de üretilen model ağında başarısız kalmaktadır. Bu metotların, aralarında kesin bir kanuniyetin olduğu ve doğrudan ilişkilerin bulunduğu ağaç çapı ve boyu (Ercanlı 2020) gibi parametreler arasında uygulanması bu

problemin ortaya çıkma oranını azaltabilmekte ve model-test başarılarını daha yüksek seviyelere çıkarabilmektedir.

Yapay zeka tekniklerinin farklı alanlarda uygulanması ve geliştirilmesi ile yüksek başarı oranlarına sahip modelleme çalışmaları yapılmaktadır. Bu teknikler yüksek başarı potansiyeline sahip olsa da uygulaması basit ve kullanıcı dostu metotlar değillerdir (Aertsen *et al.* 2010). Yapılan yapay zeka çalışmalarında model ağının eğitilme süreci için gerekli argümanların ve en uygun nöron ile katman sayılarının bulunması oldukça güç ve zaman alıcıdır. Ayrıca gizli katman ve doğrusal olmayan aktivasyon fonksiyonlarından kaynaklı yorumlanamayan ağırlıklara sahip olması, ekolojik süreçlerin yorumlanmasını kısıtlamaktadır (Peng and Wen 1999). Bu soruna çözüm olarak literatürde bağımsız değişkenlerin katkısını belirlemeye yönelik teknikler bulunmaktadır (Maier and Dandy 2000). NBÜ ve YAİ gibi meşcerelerin üretim ve gelişimi ile ilgili parametrelerde ilişkilerin basit bir şekilde ortaya konulması için daha sade, şeffaf ve yorumlanabilir tekniklerin kullanılması faydalı ve açıklayıcı olabilmektedir.

5.4.1 Net birincil üretime ilişkin modelleme bulgularının değerlendirilmesi

NBÜ, ÇRA metodu ile meşcere parametreleri kullanılarak modellenmiştir. Bu modelde yer alan anlamlı bağımsız değişkenler ise $h_{üst}$, N, G ve V olmuştur. Model-test için belirtme katsayıları 0,50-0,30 bulunmuştur. DVM ve DÖ metotları için model-test belirtme katsayıları sırası ile 0,62-0,44 ve 0,64-0,51'dir. Eşlendirilmiş *t*-test bulgularına göre NBÜ için ÇRA (p=0,079), DVM (p=0,557) ve DÖ (p=0,146) tahminleri, gözlem verileri ile uyumludur (p>0,05). NBÜ, meşcere parametrelerine ek olarak YAİ ile de modellenmiştir. ÇRA metodu ile %95 güven düzeyinde kullanılabilir model üretilememiştir (p=0,005). DÖ metodu kullanılarak yapılan modellemede model-test için belirtme katsayısı 0,24 elde edilmiştir (p=0,197). DÖ tekniğinde düzenleme argümanları denenerek başarı seviyesinin değişimi kontrol edilmiştir. Fakat eklenen argümanlar soncunda da model-test başarılarında herhangi bir değişiklik gözlemlenmemiştir (Model-Test R^2=0,24, *P*=0,958). Bulut *et al.* (2019) çalışmalarında ÇRA metodunu kullanarak NBÜ'yü meşcere hacmi, hacim artımı ve karbonu ile ayrı

ayrı modellemişlerdir. Meşcere hacmi ve hacim artımı ile elde edilen model belirtme katsayıları sırası ile 0,78 ve 0,75'tir. En yüksek başarıyı ise meşcere karbonu ile elde etmişlerdir (R^2=0,85). Kullanılan bağımsız değişkenler meşceredeki birikimi temsil ettikleri için ilişki seviyeleri yüksek oranda elde edilmiştir. NBÜ de meşcerelerdeki net üretilen karbon miktarını verdiği için, aralarında en yüksek seviyede ilişkinin meşcere karbonu ile tespit edilmesi beklenen bir durumdur.

Gholz (1982) çalışmasında NBÜ'nün G ve YAİ ile ilişkilerini incelemiştir. NBÜ ve G arasındaki ÇRA modelinin belirtme katsayısını 0,95 bulmuştur. Bu değer NBÜ ve YAİ arasında 0,96 elde edilmiştir. Elde edilen bulgular parametreler arasında yüksek seviyede doğrusal ilişkilerin bulunduğunu göstermektedir. Bu çalışma ile Gholz (1982) arasında oldukça yüksek oranda farklılıklar bulunmaktadır. Bu çalışmada NBÜ'nün modellenmesinde ÇRA metodu ile meşcere parametreleri ($h_{üst}$, N, G ve V) kullanılmış ve 0,50 model belirtme katsayısı elde edilmiştir. NBÜ modellemek için YAİ kullanıldığında ise 0,20 model belirtme katsayısı bulunmuştur. Elde edilen bulgulardaki farklılıklar kullanılan örnek sayılarından kaynaklanabilmektedir. Gholz (1982) çalışmasında 12 farklı ana vejetasyon tipinden alınan 8 adet örnek veri ile ilişkileri incelemiştir. Az sayıda veri kullanılması hem farklılığa hem de yapılan çalışmanın temsil kabiliyetinin zayıf olmasına neden olabilmektedir. Scurlock *et al.* (2001) çalışmalarında küresel ölçekte NBÜ ve YAİ arasındaki ilişkiyi araştırmışlardır. Yanlı tahminlerden kaçınmak için YAİ için 10, NBÜ için 4000 g m^{-2} $yıl^{-1}$'den yüksek aykırı veriler ayıklanarak 681 adet veri kullanılmış ve aralarında orta düzeyde bir ilişki bulunmuştur (R^2=0,33, r=0,58).

NBÜ'nün YAİ ile modellenmesinde parametrik bir metot olan ÇRA ve parametrik olmayan DVM ile DÖ tekniklerinin performansları birbirine yakın bulunmuştur. Bunda, NBÜ ve YAİ arasında direkt olarak belirgin bir ilişkinin olmayışının etkisi büyüktür. Çünkü aralarında belirgin bir ilişki ve trend gözlemlenmeyen veriler arasında yapay zeka teknikleri modelleme başarısı açısından yetersiz kalabilmektedir (Aertsen *et al.* 2010). Burada farklı yapıdaki bütün örnek alanlara ilişkin verilerin tamamı ile modelleme yapılmasının da etkisi vardır (Çil 2014). Bunun etkisini görmek için veriler meşcere gelişim çağları ve kapalılık sınıflarına göre ayrı ayrı modellenmiştir. Veri

setleri model ve test olarak ayrıldığında DVM ve DÖ metotlarını uygulayacak yeterli sayıda veri bulunmadığı için sadece ÇRA metodu uygulanmıştır. NBÜ ve YAİ üzerinde büyük oranda etkisi olan meşcere gelişim çağları ve kapalılığa göre sınıflama yapıldığında, ikili arasındaki ilişkilerin gücü artmış ve model başarısına etki etmiştir (Çizelge 4.3, Şekil 4.7). Meşcere gelişim çağları için ayrılan sınıflarda en yüksek ilişki "a-b" gelişim çağındaki meşcereler için elde edilmiştir (R^2=0,71, r=0,84). Kapalılık sınıflarında ise en yüksek ilişkiler birbirine yakın olmakla birlikte 1 (R^2=0,38, r=0,62) ve 3 (R^2=0,37, r=0,61) kapalı meşcereler için elde edilmiştir. Bunun sonucunda birbiri ile doğrudan güçlü bir ilişkiye sahip olmayan parametreler, onlar için belirleyici olan etkenler açısından gruplandırılarak modellendiğinde başarı oranının yükseldiği görülmüştür. Yapılan envanter çalışmalarında örnek alan sayılarının çalışmaya özgü kriterler açısından benzer sayıda alınması bu tür gruplandırmalar için önemlidir. Böylece her bir sınıf, modelleme için yeterli sayıda veriye sahip olabilmektedir. Özellikle sınıflara ait veri sayısının model-test için ayrılabilir yoğunlukta olması, makine öğrenme algoritmalarının uygulanmasına da olanak sağlamaktadır.

45^0'lik tekstür verileri kullanılarak NBÜ modellenmiş ve uygulanan teknikler arasında performansı en iyi seçilen metot DVM olmuştur (Model R^2=0,96, Test R^2=0,95). ÇRA (Model R^2=0,79, Test R^2=0,54) ve DÖ (Model R^2=0,74, Test R^2=0,56) metotları ise birbirine yakın performans göstermişlerdir. Maguigan et al. (2016) yaptıkları çalışmada Landsat 8 OLI uydu görüntüsü kullanarak vejetasyon indisleri hesaplamış ve NBÜ'nün modellenmesinde kullanmışlardır. Elde edilen sonuçlara göre en yüksek ilişkiyi NBÜ ve DVI arasında bulmuşlardır (R^2=0,37). Aynı çalışmada, SAVI ve RDVI vejetasyon indisleri ile NBÜ arasındaki ilişkiler sırası ile 0,14 ve 0,11 elde edilmiştir. Maguigan et al. (2016) çalışmalarında bazı kısıtlar bulunmaktadır. Araştırma bölgesindeki ağaçlık alanın sınırlı olması, uydu görüntüsündeki gölgelilik ve tarih uyumsuzluğundan dolayı modellemede kullanılan örnek sayısı oldukça az (4 adet) sayıdadır. Bu çalışmada kullanılan reflektans ve vejetasyon indisleri arasında en yüksek başarı, Landsat 8 OLI uydu görüntüsü kullanılarak hesaplanan vejetasyon indisleri ile elde edilmiştir. Bağımsız değişken olarak ND73, SAVI ve PSSR vejetasyon indislerinin seçildiği ÇRA modelinde belirtme katsayısı 0,50 bulunmuştur. Daha fazla sayıda bağımsız değişkenin modele dahil olması, NBÜ'de gözlemlenen değişkenliğin açıklanmasına ve dolayısı ile

NBÜ'nün model başarısına katkı sağlamıştır. NBÜ'nün sadece uydu görüntülerinden elde edilen uzaktan algılama verileri ile modellenmesine ait çalışmalar çok az sayıdadır. NBÜ uzaktan algılama verileri ile doğrudan orantılı değillerdir (Ollinger *et al.* 2007). NBÜ literatürde yaygın olarak fotosentetik parametreler, meteorolojik veriler ve uzaktan algılama verileri kombine edilerek algoritmalardan türetilen denklemler ve süreç tabanlı modeller ile tahmin edilmektedir (Gower *et al.* 1999, Cramer *et al.* 1999, Chen *et al.* 2017).

5.4.2 Yaprak alan indeksine ilişkin modelleme bulgularının değerlendirilmesi

YAİ için bağımsız değişken olarak meşcere parametrelerinin kullanıldığı modellemede ÇRA metoduna göre seçilen anlamlı parametreler dg, N ve G'dir. Uygulanan teknikler arasında en yüksek başarıyı DVM metodu göstermiştir (Test R^2=0,64). DÖ metodu ile yapılan tahminin hatası 0,462 m^2 m^{-2} iken DVM metodunun hatası 0,371 m^2 m^{-2}'dir. Model performanslarına bakıldığında DÖ metodu (Model R^2=0,68) DVM metoduna (Model R^2=0,64) göre daha başarılıdır. Fakat ÇRA, DVM ve DÖ metotlarının kıyaslanmasında bağımsız veri gruplarındaki başarıyı gösteren test bulgularına bakılmıştır. Khosravi *et al.* (2012) meşcere parametrelerini kullanarak meşe ormanları için YAİ tahmini yapmışlardır. Belirtme katsayıları dg ile 0,36, G ile 0,36 ve meşcere orta boyu (h) ile 0,45 elde edilmiştir. Ercanlı *et al.* (2018) saf karaçam meşcerelerinden aldıkları 108 örnek alan için YAİ'yi yarı-küresel fotoğraf alımı ile belirlemişlerdir. Örnek alanlarda meşcere parametreleri de ölçülmüş ve YAİ'yi meşcere parametrelerini kullanarak ÇRA ve yapay sinir ağları (ANN) teknikleri ile modellemişlerdir. ÇRA ve ANN metotları için elde edilen belirtme katsayıları sırası ile 0,5431 ve 0,6392'dir. ANN metodu ile tahminleme iyileştirilmiş ve hata miktarı 0,3935 m^2 m^{-2}'den 0,3497 m^2 m^{-2}'ye düşürülmüştür.

Bu çalışmada YAİ için ÇRA ile elde edilen 0,50 belirtme katsayısı, DVM ve DÖ gibi makine öğrenme algoritmaları ile 0,60 seviyesinin üzerine çıkmıştır. Doğrusal olmayan teknikler ile daha doğru tahminlerin yapılabildiği görülmüştür. Burada amaç doğrusal ilişkilerin analiz edilmesi ve basit ilişkilerin yorumlanması ise orta düzeyde ÇRA metodu buna cevap verebilmektedir. Meşcerelerden elde edilebilecek ölçümü kolay

parametreler ile üretilen doğrusal modeller, YAİ tahmininde faydalı görülmektedir. YAİ tahmininde model başarısının ön plana çıktığı durumlarda DVM ve DÖ gibi parametrik olmayan teknikler kullanılabilmektedir. Başarı oranı daha yüksek ve kullanılabilir seviyede tahminlerin ve haritalamaların yapımında, makine öğrenme metotlarının yararlı olduğu düşünülmektedir. Uygulanan tekniklere ek olarak kullanılan bağımsız değişkenler de model başarısını ve temsiliyetini etkilemektedir. Bu çalışmada, YAİ ile meşcere özellikleri arasındaki ilişkiler araştırılmıştır. Fakat üretilecek doğrusal modellerde sadece meşcere özelliklerinin kullanılması yetersiz kalmaktadır. Çünkü meşcere özelliklerinin yanında edafik koşulların tamamı YAİ ile olan allometrik ilişkileri etkilemektedir. Dolayısı ile YAİ tahmini için üretilecek doğrusal modellerde meşcere parametrelerinin yanında edafik faktör olan toprak özelliklerinin de kullanılması modelin başarısına ve temsil kabiliyetine büyük oranda katkı sağlamaktadır (Gower *et al.* 1999, Asner *et al.* 2003).

YAİ için 0^0'lik tekstür verileri ile en yüksek başarı DVM metodu ile elde edilmiştir (Model R^2=0,96, Test R^2=0,96). Literatürde, YAİ tahmini çeşitli uzaktan algılama verileri kullanılarak yapılmıştır. Bu veri kaynaklarını yansıma değerleri (Heiskanen 2006, Günlü *et al.* 2017), vejetasyon indisleri (Soudani *et al.* 2006, Yu *et al.* 2019) ve tekstür değerleri (Zhou *et al.* 2014, Pu and Cheng 2015, Zhou *et al.* 2017) oluşturmaktadır. Bu çalışmada reflektans ve vejetasyon indisleri ile YAİ modellenmiştir. ÇRA metodu kullanılarak en yüksek ilişki Sentinel-2 uydu görüntüsünden elde edilen reflaktans değerleri ile bulunmuştur (R^2=0,33). Günlü *et al.* (2017) YAİ'nin tahmininde Worldview-2 ve Aster uydu görüntüleri kullanmışlardır. Elde edilen bulgulara göre Worldview-2 uydu görüntüsü daha başarılı bulunmuştur. Yansıma değerleri ile elde edilen model belirtme katsayısı 0,41, vejetasyon indisleri ile 0,45 elde edilmiştir. Aster uydu görüntüsü ile yansıma değerleri kullanılarak 0,12, vejetasyon indisleri kullanılarak 0,41 model belirtme katsayıları elde edilmiştir. Yu *et al.* (2019) çalışmalarında ÇRA metodu ile Landsat 8 OLI uydu görüntüsü kullanarak vejetasyon indisleri ile YAİ'yi modellemişlerdir. Elde edilen model belirtme katsayısı 0,63'tür.

YAİ ile yansıma değerleri arasında güçlü ve doğrusal olmayan bir ilişki vardır (Baret *et al.* 2012). Bu çalışmada elde edilen bulgularda doğrusal bir metot olan ÇRA ile model başarısı 0,76 ve doğrusal olmayan DVM metodu ile 0,96 elde edilmiştir. Bitki örtüsü indislerinin birçoğu, kırmızı bant dalga boyunda algılanan klorofil pigmentlerinden kaynaklı maksimum absorpsiyon ile yaprak hücresel yapısının neden olduğu kızılötesinde maksimum yansıma arasındaki farka dayanmaktadır. Bu temsiliyet sayesinde YAİ ile vejetasyon indisleri arasında yakın ilişkiler belirlenebilmektedir. Fakat YAİ için bazı veri aralıklarında vejetasyon indisleri ile olan ilişkilerinde yüksek oranda toprak üstü biyokütle ve vejetasyon örtüsünün etkisiyle doygunluk problemi meydana gelmektedir (Zhao *et al.* 2012). YAİ, 1,500 m^2 m^{-2} ve 3,500 m^2 m^{-2} arasında olduğunda NDVI (Ferrara 2010), 3,000 m^2 m^{-2} ve 6,000 m^2 m^{-2} arasında olduğunda ise MSR, RVI, NDWI, OSAVI, MSAVI vb. gibi vejetasyon indisleri genellikle doygunluğa ulaşmaktadır (Haboudane 2004). Doygunluğa ulaşmak, belirtilen YAİ aralıklarında vejetasyon indislerinde herhangi bir değişimin olmadığını göstermektedir. YAİ değerleri bu aralıklarda değiştiğinde vejetasyon indisleri daha stabil kalarak değişkenliği karşılayamamakta ve dolayısı ile ilişkilerin düşük seviyede kalmasına neden olmaktadır (Zhao *et al.* 2012).

Zhou *et al.* (2017) yaptıkları çalışmada Quickbird uydu görüntüsünden elde ettiği tekstür değerleri ile YAİ'yi tahmin etmişlerdir. Farklı filtre ve derecelerin kullanıldığı çalışmada en başarılı model belirtme katsayısı 0,74 bulunmuştur. Zhou *et al.* (2017) çalışması ile bu çalışmada elde edilen model başarıları benzerdir. Bu çalışmada ÇRA metodu için elde edilen en başarılı modele ait belirtme katsayısı 0,76 bulunmuştur. Başarı düzeyleri benzer olsa da başarının elde edildiği tekstür dereceleri farklıdır. Zhou *et al.* (2017) en yüksek başarıyı 90^0'lik tekstür verileri ile elde ederken, bu çalışmada 0^0'de elde edilmiştir. Farklı derecelerde başarıya ulaşmanın birçok nedeni bulunmaktadır. İki çalışma arasındaki her bir farklılık (veri karakteristiği, tür, klimatik ve edafik faktörler), ilişkinin kurulduğu parametreler arasındaki eğilimi etkilemektedir. Bu çalışmada elde edilen YAİ değerleri 0,332 m^2 m^{-2} ile 3,525 m^2 m^{-2} arasında değişirken, diğer çalışmada 0,950 m^2 m^{-2} ile 6,800 m^2 m^{-2} arasında değişmektedir. Modellenen parametre her ne kadar aynı olsa da elde edilen verilerin karakteristiği (ortalama, değişkenlik, standart sapma vb.) birbirinden oldukça farklıdır. Bunun

yanında uydu görüntüsünün (Günlü *et al.* 2017), çevresel şartların (Brantley 2011) ve çalışılan türün farklı olması (Zhang 2000) görüntünün yansıma seviyesini etkileyeceği için farklılıklar olabilmektedir.

5.4.3 Meşcere parametrelerine ilişkin modelleme bulgularının değerlendirilmesi

Meşcere parametrelerinin modellenmesine ilişkin bulgular değerlendirildiğinde, dg için en iyi sonuç 9x9 filtreli tekstür verileri ile DVM metodunun kullanılmasında elde edilmiştir (Model R^2=0,88, Test R^2=0,88). DÖ metodunun model başarısı (Model R^2=0,98, Test R^2=0,72) daha yüksek olsa da DVM metodunun test başarısı daha yüksek ve model-test başarıları daha uyumludur. 135°'lik tekstür verileri ile modellenen $h_{üst}$ için test performansları esas alındığında en başarılı metot DVM olmuştur (Model R^2=0,90, Test R^2=0,89). 45°'lik tekstür verileri ile modellenen N için en iyi metot DÖ (Model R^2=0,98, Test R^2=0,96) olmuştur. 90°'lik tekstür verileri ile modellenen G (Model R^2=0,91, Test R^2=0,90) ve V (Model R^2=0,85, Test R^2=0,85) için en iyi metot DVM olmuştur. İnan (2004) yaptığı çalışmada Landsat 7 ETM+ uydu görüntüsü kullanarak tekstür verileri ile dg, h, G ve V'yi tahmin etmiştir. ÇRA metodu ile elde edilen modellerin belirtme katsayıları dg, h, G ve V için sırası ile 0,08, 0,16, 0,14 ve 0,17'dir. İnan (2004) çalışmasında elde edilen modellerde bağımsız değişken olarak kullandığı tekstür verilerini tek tek kullanıldığı için başarı seviyeleri düşük seviyede kalmıştır. Kayitakire *et al.* (2006) yaptıkları çalışmada ÇRA metodu kullanarak IKONOS-2 uydu görüntüsünden elde edilmiş tekstür verileri ile $h_{üst}$, N ve G'yi tahmin etmişlerdir. Model belirtme katsayıları $h_{üst}$, N ve G için sırası ile 0,76, 0,82 ve 0,35 elde edilmiştir. Özdemir and Karnieli (2011) çalışmalarında WorldView-2 uydu görüntüsü ile tekstür değerlerini hesaplayarak N, G ve V'yi tahmin etmişlerdir. Kullanılan ÇRA metoduna ilişkin elde edilen model belirtme katsayıları sırası ile 0,38, 0,54 ve 0,42 elde edilmiştir.

Sakıcı and Günlü (2018) tarafından yapılan çalışmada Landsat 8 OLI uydu görüntüsü ile farklı filtrelerde tekstür değerleri hesaplanarak N, G, V ve dg'yi ÇRA ve ANN metotlarını kullanarak modellemişlerdir. N, G, V ve dg için elde edilen model belirtme katsayıları sırası ile ÇRA metodu için 0,18, 0,34, 0,33 ve 0,40, ANN metodu için 0,61,

0,63, 0,65 ve 0,59 olarak elde edilmiştir. Crysafis *et al.* (2019) yaptıkları çalışmada, Sentinel-2 uydu görüntüsünden elde edilen tekstür verileri ile V'yi tahmin etmişlerdir. Farklı filtre ve dereceler kullanarak tekstür ve V arasındaki ilişkileri incelemişlerdir. En yüksek başarı 3x3 fitreli 0°'lik tekstür verileri ile elde edilmiştir (R^2=0,91). Bu çalışmadan (V için R^2=0,85) ve Crysafis *et al.* (2019) (V için R^2=0,91) çalışmalarından elde edilen bulgular değerlendirildiğinde İnan (2004), Kayitakire *et al.* (2006), Özdemir and Karnieli (2011) ve Sakıcı and Günlü (2018) çalışmalarına göre daha yüksek düzeyde başarı elde edildiği görülmüştür. Sakıcı and Günlü (2018) tarafından yapılan çalışmada kullanılan ANN metodu model başarılarını artırmıştır. Fakat farklı tekstür derece verileri ile elde edilen başarı düzeyine göre daha düşük oranda başarı elde etmişlerdir. Dolayısı ile tekstür derece verilerinin meşcere parametre tahmininde başarıyı yüksek oranda iyileştirebildiği görülmüştür.

Meşcere parametrelerinin tahmininde elde edilen başarılı sonuçlarda, farklı filtre ve dereceler kullanılarak çok sayıda bağımsız değişkenin modele dahil edilmesi ve makine öğrenme algoritmalarının kullanılmasının etkili olduğu görülmüştür. En uygun filtre ve derecelerin belirlenmesi ile başarı düzeyi yüksek modeller üretilmiştir. En yüksek başarıyı veren filtre ve derecelerin belirlenmesi ise deneme yanılma yolu ile kararlaştırılmıştır. Meşcere parametrelerinin tahminlerinde en uygun filtre ve derece için genelleme yapmak mümkün olmasa da arazi yapısı, meşcere özellikleri ve algılayıcıya ait teknik özelliklere göre değişim göstermektedir (Crysafis *et al.* 2019). Optimal derece değerinin belirlenmesinde uyduların gün içerisindeki algılama zamanı oldukça önemlidir. Bu 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). Yapılacak ölçümlerin bu doğrultuda gölge kalan yerlerde gerçekleştirilmesi, o alana ait elde edilecek uzaktan algılama verilerinin temsiliyet kabiliyetini azaltmaktadır. Tekstür verilerinde en yüksek başarıların 45° ve 90°'de elde edilmesinde, uydu görüntülerinin alım zamanına bağlı olarak algılama yönü ve o andaki güneşin geliş açısının etkili olduğu düşünülmektedir.

Meşcere parametrelerinin reflektans ve vejetasyon indis değerleri ile modellenmesinde farklı ağaç türleri için çeşitli uydu görüntülerinin kullanıldığı çok sayıda çalışma mevcuttur (Günlü *et al.* 2014a, Günlü *et al.* 2014b, Günlü vd. 2015, Crysafis *et al.* 2017, Günlü and Kadıoğulları 2018). Özkan (2003) tarafından yapılan çalışmada ÇRA metodu ile Spot 5 uydu görüntüsünden elde edilen yansıma ve vejetasyon indislerini kullanarak meşcere parametrelerini tahmin etmiştir. Yansıma değerleri ile elde edilen modellerin belirtme katsayıları dg, h, N, G ve V için sırası ile 0,50, 0,46, 0,23, 0,63 ve 0,55'tir. Model belirtme katsayıları dg, h, N, G ve V için sırası ile 0,32, 0,31, 0,26, 0,28 ve 0,30 elde edilmiştir. İnan (2004) tarafından yapılan çalışmada ÇRA metodu kullanarak Landsat 7 ETM+ uydu görüntüsü ile G, V, h ve dg'yi tahmin etmiştir. G, V, h ve dg için model belirtme katsayıları yansıma değerleri ile 0,66, 0,67, 0,61 ve 0,37, vejetasyon indisleri ile 0,66, 0,71, 0,66 ve 0,42 elde edilmiştir. Ateşoğlu (2009) tarafından yapılan çalışmada Landsat 7 ETM+ uydu görüntüsü kullanılarak ÇRA metodu ile dg, h, N, G ve V tahmin edilmiştir. Yansıma değerleri ve vejetasyon indisleri birlikte kullanılarak dg, h, N, G ve V için model belirtme katsayıları sırası ile 0,24, 0,65, 0,33, 0,78 ve 0,52 elde edilmiştir. Günlü *et al.* (2013) tarafından yapılan çalışmada, ÇRA metodu kullanarak Quickbird ve Landsat 7 ETM+ uydu görüntülerinden elde edilen reflektans değerleri ile doğu kayını (*Fagus orientalis* Lipsky) meşcereleri için V tahmini yapmışlardır. Model belirtme katsayıları Quickbird uydu görüntüsü ile 0,70, Landsat 7 ETM+ ile 0,55 elde edilmiştir. Çil (2014) yaptığı çalışmada Landsat 8 OLI, Rasat, Göktürk-2 ve dijital hava fotoğrafı kullanarak N, G ve V'yi tahmin etmiştir. Örnek alanlar hem tamamı ile hem de meşcere gelişim çağlarına göre gruplandırarak modelleme işlemini gerçekleştirmiştir. Meşcere gelişim çağlarına göre gruplandırılarak modelleme işleminin yapılması, verilerdeki homojenliği artırdığı (değişkenliği azalttığı) için başarıya artırıcı etki yapmıştır. Uydu görüntüleri arasında en yüksek başarı Landsat 8 OLI uydu görüntüsü ile elde edilmiştir. ÇRA metodu kullanılarak bant değerleri ve vejetasyon indisleri ile N, G ve V için model belirtme katsayıları sırası ile 0,60, 0,62 ve 0,60 elde edilmiştir. Günlü *et al.* (2014a) yaptıkları çalışmada IKONOS uydu görüntüsü kullanarak yansıma ve vejetasyon indisi değerleri ile ÇRA metodunu kullanarak G, V ve $h_{üst}$'ü tahmin etmişlerdir. G, V ve $h_{üst}$ için model belirtme katsayıları sırası ile yansıma değerleri için 0,43, 0,41 ve 0,45, vejetasyon indisleri için 0,59, 0,55 ve 0,57 olarak bulunmuştur. Crysafis *et al.* (2017) çalışmalarında Sentinel-2 ve Landsat 8 OLI uydu görüntüsü

kullanarak V'yi tahmin etmişlerdir. En yüksek başarı Sentinel-2 uydu görüntüsünden elde edilen yansıma değerleri (R^2=0,46) ve vejetasyon indisleri (R^2=0,52) ile elde edilmiştir.

Bu çalışmada dg, $h_{üst}$, N, G ve V için ÇRA modellerinde Landsat 8 OLI ve Sentinel-2 uydu görüntüsünden elde edilen reflektans ve vejetasyon indisleri kullanılmıştır. dg, $h_{üst}$, N, G ve V için en yüksek model belirtme katsayıları reflektans verileri ile 0,23, 0,42, 0,15, 0,41 ve 0,44 elde edilmiştir. Vejetasyon indisleri kullanılarak elde edilen model belirtme katsayıları sırası ile 0,25, 0,40, 0,17, 0,45 ve 0,47'dir. Meşcere parametrelerinin karakteristiği, arazi yapısı, güneşin geliş açısı, uydu görüntülerinin alım zamanı ve uydu görüntülerinin özellikleri model başarısına büyük oranda etki etmektedir. Uydu görüntülerinin çözünürlük özelliklerine göre (konumsal, radyometrik, zamansal ve spektral çözünürlük) ilgi alanını tanımlamadaki ve temsil etmedeki kabiliyeti ile model başarıları değişkenlik göstermektedir (Ateş ve Demir 2009). Konu ile ilgili yapılan çalışmalardan elde edilen sonuçlara göre vejetasyon indisleri meşcere parametrelerinin modellenmesinde yansıma değerlerine göre genellikle daha başarılı görülmüştür (Günlü *et al.* 2014b). Uydu tarafından algılanan yansıma değerlerinde oluşan hatalar (gölgelilik, eğim, güneş açısı vb.), yansıma değerlerinin algılanan bölgenin temsil edilme oranını zayıflatabilmektedir. Vejetasyon indislerinde ise bant kombinasyonları alınarak bu hataların etkisi minimuma indirilmektedir. Ayrıca bantlar belirli dalga boylarını temsil etmektedirler. Vejetasyon indisleri ise farklı dalga boylarındaki bantların kombinasyonları olduğu için alana ait özellikleri daha iyi bir şekilde yansıtabilmektedir. Bu durum vejetasyon indislerini meşcere parametrelerinin tahmininde daha avantajlı hale getirmektedir (Çil 2014).

Bu çalışmada elde edilen bulgularda 2 önemli husus gözlemlenmiştir. Birincisi $h_{üst}$ modellemesi için kullanılan DÖ metodu bulgularında test başarısının yüksek olmasına rağmen, eşlendirilmiş *t*-testine göre test gözlem ve tahmin verilerinin uyumsuz çıkmasıdır. İkincisi kullanılan DVM ve DÖ metotlarının ikisi de makine öğrenme tekniği olmasına rağmen, sadece DÖ metodunda model-test başarıları arasında yüksek fark elde edilmesidir.

Uygulanan DÖ metodu ile $h_{üst}$ parametresinin belirtme katsayıları model için 0,98, test için 0,79'dur. Elde edilen test tahminlerine ilişkin belirtme katsayısı 0,79 olmasına rağmen eşlendirilmiş *t*-testine ilişkin p değeri 0,022 ($p<0,05$) bulunmuş ve model ağının kullanılamaz olduğu tespit edilmiştir. Eşlendirilmiş *t*-testi iki eş arasındaki ortalamaların farkına bakmaktadır. Test aşaması için ayrılan gözlem veri setine ilişkin verilerin ortalaması 15,49 m, DÖ ile yapılan test tahminine ilişkin ortalama ise 18,51 m'dir. Tahmin ortalamaları ÇRA metodu için 16,04 ve DVM metodu için 14,94 bulunmuştur. Ortalamalar arasında en büyük fark DÖ metodunda gözlemlenmiştir. DÖ metodu kullanılarak üretilen model ağının iki eş arasında uyumlu bir trend oluşturması ilişki gücünün yüksek seviyede çıkmasını sağlamıştır. İlişki seviyesinin yüksek olması her zaman temsil kabiliyetinin yüksek olduğu anlamına gelmemektedir. Gözlem verilerinin tamamı belli bir oranda yüksek ve düşük tahmin edildiğinde de arada yüksek oranda benzerlik gösteren ilişkiler gözlemlenebilmektedir. Örneğin herhangi bir değişken için 1 birimlik ölçütü 2, 2 birimlik ölçütü 4, 4 birimlik ölçütü 8 vb. tahmin edildiğinde ilişki gücü çok yüksek fakat temsil kabiliyeti ve model kullanılabilirliği açısından oldukça yetersiz bir sonuç edinilmiş olunmaktadır. DÖ metodu ile yapılan $h_{üst}$ tahmininde bu şekilde bir durum ile karşılaşılmıştır. Gözlem ve tahmin ortalamaları arasında 3,02 m'lik fark bulunmuştur. Çünkü üretilen ağ $h_{üst}$ verilerini sistematik olarak olduğundan daha yüksek tahmin etmiş ve DÖ metodu iyi bir genelleştirme yapamamıştır. Dolayısı ile 3,02 m'lik farkı örnek sayısına göre önemli bulduğu için sonuç uyumsuz bulunmuştur (t=-2,367, p=0,022). Bu nedenden dolayı DÖ metodu ile başarısı yüksek bir tahmin yapılsa da eşlendirilmiş *t*-testi sonucuna göre kullanılabilir bir model üretilememiştir.

Modelleme sürecinde reflektans, vejetasyon indisi ve tekstür gibi uzaktan algılama verilerinden yararlanılmıştır. En yüksek başarı tekstür verileri kullanılarak elde edilmiştir. Aradaki başarı farkının en önemli nedenlerinden bazıları çok sayıda tekstür veri setinin kullanılması ve farklı filtre, derece ve fonksiyonlar için hesaplanarak uydu görüntülerinin doku özelliklerini iyi derecede yansıtılmasıdır (Pathak and Barooah 2013, Zheng *et al.* 2018). Tekstür verileri ile uygulanan metotlarda N için DÖ metodu, diğer parametreler için DVM metodu daha başarılı bulunmuştur. Bu sonuca rağmen dg, $h_{üst}$, G ve V için DÖ metodunun model performansları daha yüksektir. Test başarıları

daha düşük elde edildiği için en iyi metot DVM seçilmiştir. Sonucun bu şekilde çıkmasında DVM ve DÖ metotlarının uygulanma sürecinin etkisi oldukça büyüktür. DVM metodunda kullanılan kernel fonksiyonuna ek olarak uygulanan iyileştirme argümanı (tuneResult) ağ eğitiminden sonra test aşamasında da başarının yüksek seviyede kalmasını sağlamıştır (Meyer *et al.* 2015). DÖ metodunda ise ağın eğitim sürecinde manuel olarak deneme yanılma ile belirlenen argümanlar, aktivasyon fonksiyonu, nöron sayısı ve katman sayısı hem ağın eğitim sürecini uzatmakta hem de optimal tahminlere ulaşmayı zorlaştırmaktadır (Aertsen *et al.* 2010). DÖ metodu için her ne kadar model başarıları yüksek seviyede olsa da ağ eğitim sürecinin zorluğu ve aşırı uyum probleminin etkisinden dolayı test başarıları daha düşük seviyelerde kalmıştır. DVM metodu ise uygulama süreci açısından daha kullanıcı dostu olması ve iyileştirici argümanlar sayesinde model ve test başarı düzeyleri oldukça benzer ve yüksek seviyede elde edilmiştir.

6. SONUÇ VE ÖNERİLER

Yapılan bu çalışmada elde edilen bulgular değerlendirildiğinde belirtilmesi gereken genel sonuçlar ve öneriler şu şekildedir:

- Saf karaçam meşcerelerinde 2019 yılı için aylık ortalama NBÜ, NDVI, sıcaklık, yağış ve güneş radyasyonunun zamansal değişimi incelenmiştir. En yüksek seviyede NBÜ'nün Temmuz ayında (171,702 gC m^{-2} ay^{-1}) gerçekleştiği görülmüştür. Temmuz ayı için yağış ortalaması 20 mm'ye kadar düşmüş olsa da sıcaklık ve güneş radyasyonunun artış eğiliminde olması NBÜ'ye pozitif etki yapmıştır. Bu durumda çalışmaya konu meşcerelerde toprağın su tutma kapasitesinin NBÜ seviyesinde önemli bir etken olduğu ortaya çıkmıştır. Toprakta su ne kadar tutulabilirse artan sıcaklık ile NBÜ de o oranda artmaya devam edebilmektedir. Ayrıca, araştırma alanında NDVI ve güneş radyasyonunun zamansal dağılımı ile NBÜ arasında daha net bir ilişkinin olduğu tespit edilmiştir. Bölgede yapılacak NBÜ analizlerinin zamansal olarak izlenmesinde NDVI ve güneş radyasyonunun kullanılması faydalı olacaktır.

- NBÜ'nün YAİ ile modellenmesinde kullanılan ÇRA, DVM ve DÖ metotları ile elde edilen model belirtme katsayıları 0,20 ile 0,24 arasında değişmektedir. Meşcere gelişim çağları (R^2 a-b=0,70, c=0,52, d=0,20) ve kapalılık sınıfları (R^2 1=0,38, 2=0,21, 3=0,37) açısından gruplandırma yapılarak modelleme süreci ayrı ayrı denenmiştir. NBÜ ve YAİ parametreleri için belirleyici olan etkenler açısından gruplandırma işlemi yapmak başarıya artırıcı etki yapmıştır. Bu şekilde gerçekleştirilecek olan bir modelleme sürecinde her bir grup için olabildiğince eşit sayıda veri almak ilişkilerin daha iyi bir şekilde yorumlanmasına ve parametreler arasındaki kanuniyetlerin sağlanmasına katkı sağlayacaktır. Yeterli sayıda veri almak ise veri setini model ve test için gruplandırmaya ve modelleme açısından hem farklı tekniklerin uygulanmasına hem de tahminlerin test edilebilmesine olanak sağlayacaktır. Bu şekilde gerçekleştirilecek olan bir modelleme sürecinde herhangi bir kısıt ile

karşılaşmamak için, her bir meşcere gelişim çağı ve kapalılık sınıfından olabildiğince eşit ve yeterli sayıda veri alınması önerilmektedir.

- NBÜ'nün hesaplanması için kullanılan CASA modelinin geçerlilik kontrolü döküm verileri ile yapılmıştır. Geçerlilik kontrolü genellikle ibre döküm miktarları ile yapılmaktadır. Bu çalışmada döküm elemanları incelenmiş ve ibre dökümü ile NBÜ arasında 0,63 oranında korelasyon tespit edilmiştir (R^2=0,40). En yüksek oranda benzerlik ise NBÜ ve erkek çiçek dökümü arasında bulunmuştur (r=-0,75, R^2=0,56). Elde edilen döküm verileri 8 ay gibi kısıtlı bir zaman periyodunu kapsıyor olsa da bulunan bu ilişkilerde erkek çiçek dökümünün geçerlilik kontrolündeki performansı, NBÜ'nün modellenmesi için de umut vadetmektedir. İbre ve erkek çiçek döküm miktarlarının uzun süreli izlenerek, NBÜ için oluşturulabilecek basit doğrusal regresyon modellerinde bağımsız değişken olarak kullanılmaları önerilmektedir.

- NBÜ (Model R^2=0,96, Test R^2=0,95), YAİ (Model R^2=0,96, Test R^2=0,96), dg (Model R^2=0,88, Test R^2=0,88), $h_{üst}$ (Model R^2=0,90, Test R^2=0,89), N (Model R^2=0,98, Test R^2=0,96), G (Model R^2=0,91, Test R^2=0,90) ve V (Model R^2=0,85, Test R^2=0,85) modellenmelerinde en yüksek başarı Sentinel-2 uydu görüntüsünden elde edilen tekstür değerleri kullanılarak elde edilmiştir. Bununla birlikte DVM ve DÖ gibi makine öğrenme teknikleri ile başarı seviyeleri daha yüksek seviyelere çıkmıştır. Uzaktan algılama ile yapılacak meşcere parametre tahminlerinde yüksek seviyede başarı elde etmek için farklı filtre-açı değerlerine göre tekstür verilerinin kullanılması önerilmektedir.

- Çalışma kapsamında üretilen NBÜ yüzey haritası ve güncel meşcere haritası çakıştırılarak mevcut saf karaçam meşcerelerine ait NBÜ miktarları elde edilebilmektedir. Bu sayede her bir meşcere tipinin aylık ve yıllık ölçekte yaptıkları net üretim ortaya konabilmektedir. Bunun sonucunda NBÜ miktarları orman amenajman planlarına entegre edilebilmektedir. Bu entegrasyon işlemi ile birlikte ülkemizde orman ekosistemlerindeki ağaç örtüsünün iklim değişikliği ve

uygulanan silvikültürel müdahaleler karşısında ne seviyede net üretim yaptıkları ortaya konulabilecektir. Ayrıca ülkemiz ormanlarındaki net karbon üretimlerinin belirli düzeyde ve dengede tutulabilmesi için NBÜ miktarlarının belirlenmesi gerekli görülmektedir. Bu bağlamda orman amenajman planları orman işletme şefliği bazında yapıldığından, NBÜ'nün de işletme şeflikleri sınırlarına göre haritalandırılması planlayıcılar açısından faydalı olacaktır. Orman amenajman planlarında kullanılabilecek karar destek sistemleri ile aylık ve yıllık net üretimin maksimize edilme imkanı doğacaktır. Diğer yandan iklim değişikliğinin büyük bir kriz olduğu günümüzde, Avrupa Birliği uyum sürecinde olan ülkemiz birçok uluslararası anlaşmaya taraf olma yolunda çalışmalar sürdürmektedir. Küresel ısınma ve iklim değişikliği ile ilgili taraf olunacak antlaşmalarda ülkemiz ormanlarında üretilen net karbon miktarlarının ve gerçekçi karbon bütçelerinin belirlenmesi daha da önem kazanacaktır. Bu doğrultuda NBÜ'nün ülkemizde yayılış gösteren diğer ağaç türleri için değişen çevre şartlarına ve iklime duyarlı modeller ile belirlenmesi ve orman amenajman planlarına entegre edilmesi önerilmektedir.

KAYNAKLAR

Aertsen, W., Kint, V., Van Orshoven, J., Özkan, K. and Muys, B. 2010. Comparison and ranking of different modelling techniques for prediction of site index in Mediterranean mountain forests. Ecological Modelling, 221(8), 1119-1130.

Aiello, S., Kraljevic, T. and Maj, P. 2015. Package 'h2o'. dim, 2, 12.

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.

Anonim 2019. Ankara Orman Bölge Müdürlüğü, Orman İşletme Şeflikleri, Orman Amenajman Planları. T.C. Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Dairesi, Ankara.

Anonim 2020. Ankara Orman Bölge Müdürlüğü, Çankırı Orman İşletme Müdürlüğü, Çankırı Orman İşletme Şefliği Orman Amenajman Planı. T.C. Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Dairesi, Ankara.

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.

Ateş, S. ve Demir, E. 2009. Uzaktan algılamada çözünürlüğe bağlı veri kazanımı potansiyeli. TMMOB Harita ve Kadastro Mühendisleri Odası 12. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.

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

Ayari, A., Zubizarreta-Gerendiain, A., Tome, M., Tome, J., Garchi, S. and Henchi, B. 2012. Stand, tree and crown variables affecting cone crop and seed yield of Aleppo pine forests in different bioclimatic regions of Tunisia. Forest Systems, 21(1):128–140.

Baret, F., Pacholczyk, P. and Lacaze, R. 2012. BioPar Product User Manual LAI, FAPAR, FCover from AVHRR-LTDR data. "geoland2", Towards an Operational GMES Land Monitoring Core Service.

Berg, B. and Meentemeyer, V. 2001. Litter fall in some European coniferous forests as dependent on climate: a synthesis. Canadian Journal of Forest Research 31 (2): 292-301.

Berg, B. and Laskowsky, R. 2005. Litter decomposition—a guide to carbon and nutrient turnover. In: Advances in Ecological Research, vol 38, Elsevier Academic Press, California.

Bilgili, B. C. Erşahin, S. Dikmen, Ü. ve Karahan, G. 2017. Konya Kapalı Havzasında Farklı Arazi Örtülerinde Net Birincil Üretimin Jeoistatistiksel Analizi. Anadolu Orman Araştırmaları Dergisi, 3(1); 14–22.

Bilgili, B.C., Erşahin, S., Kavaklıgil, S.S. and Öner, N. 2020. Net primary productivity of a mountain forest ecosystem as affected by climate and topography. CERNE, v. 26, n. 3, p.356-368.

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.

Blanco, J.A., Imbert, J.B. and Castillo, F.J. 2006. Influence of site characteristics and thinning intensity on litterfall production in two Pinus sylvestris L. forests in the western Pyrenees. Forest Ecology and Management, 237:342–352.

Bramer, M. 2002. Using J -pruning to reduce overfitting in classification trees. Knowledge-Based Systems, 15(5–6):301-308.

Brantley, S.T., Zinnert, J.C. and Young, D.R. 2011. Application of hyperspectral vegetation indices to detect variations in high leaf area index temperate shrub thicket canopies. Remote Sensing of Environment, 115(2), 514-523.

Bray, J.R. and Gorham, E. 1964. Litter production in forests of the world. Advances in Ecological Research 2:101-157.

Brohan, P., Kennedy, J.J., Harris, I., Tett, S.F. and Jones, P.D. 2006. Uncertainty estimates in regional and global observed temperature changes: A new data set from 1850. Journal of Geophysical Research: Atmospheres, 111(D12).

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., Şatır, O. and Günlü, A. 2019. Determining the interactions of black pine net primary productivity and forest stand parameters in northern Turkey. Applied Ecology and Environmental Research.

Candel, A., Parmar, V., LeDell, E. and Arora, A. 2016. Deep learning with H2O. H2O. ai Inc.

Carvalho, F.F.D., Barreto-Garcia, P.A.B., Aragão, M.A. and Virgens, A.P.D. 2019. Litterfall and Litter Decomposition in Pinus and Native Forests. Floresta e Ambiente, 26(2).

Ceccato, P., Gobron, N., Flasse, S., Pinty, B. and Tarantola, S. 2002. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1: Theoretical approach. Remote Sensing of Environment, 82(2-3), 188-197.

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.

Chen, J. M., Rich, P. M., Gower, S. T., Norman, J. M., Plummer, S. 1997. Leaf area index of boreal forests: Theory, techniques, and measurements. Journal of Geophysical Research: Atmospheres, 102(D24), 29429-29443.

Chen, S. Jiang, H. Jin, J. and Wang, Y. 2017. Changes in net primary production in the Tianmu Mountain Nature Reserve, China, from 1984 to 2014. International Journal of Remote Sensing, 38(1); 211–234.

Chianucci, F., Cutini, A., Corona, P. and Puletti, N. 2014. Estimation of leaf area index in understory deciduous trees using digital photography. Agricultural and Forest Meteorology, 198, 259-264.

Chianucci, F., Macfarlane, C., Pisek, J., Cutini, A. and Casa, R. 2015. Estimation of foliage clumping from the LAI-2000 Plant Canopy Analyzer: effect of view caps. Trees, 29(2), 355-366.

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.

Ciais, P., Reichstein, M., Viovy, N., Granier, A., Ogée, J., Allard, V., ... and Chevallier, F. 2005. Europe-wide reduction in primary productivity caused by the heat and drought in 2003. Nature, 437(7058), 529-533.

Clark, D.A., Piper, S.C., Keeling, C.D. and Clark, D.B. 2003. Tropical rain forest tree growth and atmospheric carbon dynamics linked to interannual temperature variation during 1984–2000. Proceedings of the national academy of sciences, 100(10), 5852-5857.

Clevers, J.G.P.W. 1989. Application of a weighted infrared-red vegetation index for estimating leaf area index by correcting for soil moisture. Remote Sensing of Environment, 29(1), 25-37.

Cramer, W., Kicklighter, D.W., Bondeau, A., Iii, B. M., Churkina, G., Nemry, B., Ruimy, A., Schloss, A. L., Intercomparison, TPOTP. 1999. Comparing global models of terrestrial net primary productivity (NPP): overview and key results. Global Change Biology, 5, 1–15.

Crippen, R.E. 1990. Calculating the vegetation index faster. Remote Sensing of Environment, 34, 71–73.

Çakır, M. and Akburak, S. 2017. Litterfall and nutrients return to soil in pure and mixed stands of oak and beech. Journal of The Faculty of Forestry Istanbul University, 67, 185-200.

Çakır, M., Akburak, S., Sargıncı, M. ve Tunç, T. 2019. Çankırı bölgesi Karaçam (Pinus nigra Arnold.) meşcerelerinde ölüörtü ayrışması ile mikroeklembacaklılar ve mikrobiyal aktivitenin zamansal değişimi ve toprağa verilen besin maddeleri. TÜBİTAK 3501 Projesi, Proje Sonuç Raporu, Proje Numarası: 215O572, Ankara.

Çepel, N., Dündar, M., Özdemir, T. ve Neyisci, T. 1988. Kızılcam (Pinus brutia Ten.) ekosistemlerinde iğne yaprak dokumu ve bu yolla toprağa geri verilen besin maddeleri miktarları. Orman Araştırma Enstitüsü Yayınları. Teknik Bülten Serisi No: 194: 20 s. Ankara. Türkiye.

Çil, B. 2014. Bazı meşcere parametrelerinin farklı uydu görüntüleri yardımıyla tahmin edilmesi: Kelkit ve İğdir Planlama Birimi örneği. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 72 s., Trabzon.

Çömez, A., Tolunay, D. and Güner, Ş.T. 2018. Litterfall and the effects of thinning and seed cutting on carbon input into the soil in Scots pine stands in Turkey. European Journal of Forest Research, 1-14.

Dağdaş, S. 2003. Ormanların Ekolojik İşlevlerinden Bir Demet. Orman ve Ekonomi Dergisi, (8).

Daughtry, C.S.T., Walthall, C.L., Kim, M.S., Brown de Colstoun, E. and McMurtrey, J.E., 2000. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. Remote Sensing Environment, 74 (229 239), 141–152.

Demircan, M., Demir, Ö., Atay, H., Eskioğlu, O., Yazıcı, B., Gürkan, H., Tuvan, A. and Akçakaya, A. 2015. Türkiye'de Yeni Senaryolara Göre İklim Değişikliği Projeksiyonları. OGM, Ankara.

Demircan, M., Gürkan, H., Eskioğlu, O., Arabacı, H. ve Coşkun, M. 2017. Türkiye için iklim değişikliği projeksiyonları: Üç model ve iki senaryo. Türkiye Su Bilimleri ve Yönetimi Dergisi, 1(1), 22-43.

Development Core Team R 2018. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna

Dorman, J. L. and Sellers, P. J. 1989. A Global Climatology of Albedo, Roughness Length and Stomatal Resistance for Atmospheric General Circulation Models as Represented by the Simple Biosphere Model (SiB). Journal of Applied Meteorology, 28(9); 833–855.

Dönmez, C. Berberoglu, S. and Cilek, A. 2015. Spatial variations of NPP in different altitudes at a mediterranean watershed. Fresenius Environmental Bulletin, 24(7); 2264–2274.

Dönmez, C. Berberoglu, S. Cilek, A. and Evrendilek, F. 2016. Spatiotemporal modeling of net primary productivity of eastern mediterranean biomes under different regional climate change scenarios. International Journal of Environmental Research, 10(2); 341–356.

Dubber, W., Eklundh, L. and Lagergren, F. 2017. Comparing field inventory with mechanistic modelling and light-use efficiency modelling based approaches for estimating forest net primary productivity at a regional level. Boreal Environment Research, 22, 337-352.

Duyar, A. 2018. Uludağ Göknarı'nda ölü örtü dökümünün zamansal değişimi. Ziraat, Orman ve Su Ürünlerinde Akademik Araştırmalar, Gece Kitaplığı, ISBN: 9786052884010, s. 75-85.

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. 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. ve Bolat, F. 2020. Ankara Orman Bölge Müdürlüğü Anadolu karaçamı meşcereleri için tek ağaç gövde çapı ve gövde hacminin uyumlu gövde çapı denklemleri ve yapay sinir ağları ile tahmin edilmesi. TÜBİTAK, 119O061 nolu 1002 projesi.

Erkan, N., Comez, A., Aydin, A.C., Denli, O. and Erkan, S. 2018. Litterfall in relation to stand parameters and climatic factors in Pinus brutia forests in Turkey. Scandinavian Journal of Forest Research, 33(4), 338-346.

Erşahin, S., Bilgili, B.C., Dikmen, Ü. and ErcanlI, i. 2016. Net primary productivity of Anatolian forests in relation to climate, 2000–2010. Forest Science, 62(6), 698-709.

Esser, G., Hoffstadt, J., Mack, F. and Wittenberg, U. 1994. High Resolution Biosphere Model: Documentation Model, Version 3.00.00. Institut für Pflanzenökologie, Justus-Liebig-Universitat Gieben.

Evrendilek, F., Berberoğlu, S., Taşkınsu Meydan, S. and Yılmaz, E. 2006. Quantifying carbon budgets of conifer Mediterranean forest ecosystems, Turkey. Environmental Monitoring and Assessment, 119(1-3), 527-543.

Ferrara, R.M., Fiorentino, C., Martinelli, N., Garofalo, P. and Rana, G. 2010. Comparison of different ground-based NDVI measurement methodologies to evaluate crop biophysical properties. Italian Journal of Agronomy, 145-154.

Field, C.B., Randerson, J.T., Malmström, C.M. 1995. Global net primary production: Combining ecology and remote sensing. Remote Sens. Environ. 51, 74–88.

Fitzgerald, G., Rodriguez, D. and O'Leary, G. 2010. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index – the Canopy Chlorophyll Content Index (CCCI). Field Crops Research, 18–324.

Friend, A.D. and Cox, P.M. 1995. Modelling the effects of atmospheric CO2 on vegetation-atmosphere interactions. Agricultural and Forest Meteorology, 73, 285-295.

Gholz, H.L. 1982. Environmental limits on aboveground net primary production, leaf area, and biomass in vegetation zones of the Pacific Northwest. Ecology, 63(2), 469-481.

Gitelson, A.A. and Merzlyak, M.N. 1996. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing. Journal of Plant Physiology, 148, 493–500.

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., Merzlyak, M.N. and Chivkunova, O.B. 2001. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. Photochemistry and Photobiology, 74(1), 38-45.

Gitelson, A.A., Gritz, U. and Merzlyak, M.N. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. Journal of Plant Physiology, 160(3), 271-282.

Gitelson, A.A., Vina, A., Ciganda, V., Rundquist, D.C. and Arkebauer, T.J. 2005. Remote estimation of canopy chlorophyll content in crops. Geophysical Research Letters, 32, L08403.

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.

Gower, S.T., Kucharik, C.J. and Norman, J.M. 1999. Direct and indirect estimation of leaf area index, fAPAR, and net primary production of terrestrial ecosystems. Remote sensing of environment, 70(1), 29-51.

Graham, L.E., Graham, J.M. and Wilcox, L.W. 2004. Plant biology. Prentice Hall, Inc.- 1 st ed., ISBN: 0-13-030371-2.

Gülbeyaz, Ö. 2018. Estimating net primary productivity of forest ecosystems over Turkey using remote sensıng approach. The Degree of Doctor of Philosophy, METU, Natural and Applied Sciences.

Günlü, A., Ercanlı, İ., Başkent, E.Z. ve Şenyurt, M. 2013. Quickbird ve Landsat 7 ETM+ uydu görüntüleri kullanılarak Ayancık-Göldağ kayın (Fagus orientalis Lipsky) meşcerelerinde hacim tahmini. SDÜ Orman Fakültesi Dergisi, SDU Faculty of Forestry Journal, 14, 24-30.

Günlü, A., Ercanlı, İ., Sönmez, T. and Başkent, E.Z. 2014a. Prediction of some stand parameters using pan-sharpened Ikonos satellite Image. European Journal of Remote Sensing, 47(1), 329-342.

Günlü, A., Ercanlı, İ., Başkent, E.Z. and Çakır, G. 2014b. 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., Özgün, M. ve Ercanlı, İ. 2015. 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., 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. and Kadıoğulları, A.İ. 2018. Modeling forest stand attributes using Landsat ETM+ and QuickBird satellite images in western Turkey. Bosque, 39(1), 49-60.

Haboudane, D., Miller, J.R., Pattey, E., Zarco-Tejada, P.J. and Strachan, I.B. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. Remote Sensing of Environment, 90, 337–352.

Haralick, R.M., Shanmugam, K. and Dinstein, I.H. 1973. Textural features for ımage classification. Systems Man & Cybernetics IEEE Transactions on smc 3, 610–621.

Hardisky, M.A., Klemas, V. and Smart, R.M. 1983. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of Spartina alterniflora canopies. Photogrammetric Engineering and Remote Sensing, 49, 77 – 83.

Haxeltine, A. and Prentice, I.C. 1996. BIOME3: an equilibrium biosphere model based on ecophysiological constraints, resource availability and competition among plant functional types. Global Biogeochemical Cycles, 10, 693-709.

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.

Huang, N. Niu, Z. Wu, C. and Tappert, M. C. 2010. Modeling net primary production of a fast-growing forest using a light use efficiency model. Ecological Modelling, 221(24); 2938–2948.

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.

IPCC 2013. Summary for Policymakers. In: Climate Change. The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, edited by: Stocker, T.F., Qin, D., Plattner, G.-K., Tignor, M., Allen, S.K., Boschung, J., Nauels, A., Xia, Y., Bex, V., and Midgley, P.M., Cambridge University Press, Cambridge, 1535 pp.

IPCC 2014. Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, edited by: Core Writing Team, R.K. Pachauri and L.A. Meyer (eds.), IPCC, Geneva, Switzerland, 151 pp.

IPCC 2018a. Summary for Policymakers. In: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty, edited by: Masson-Delmotte, V., P. Zhai, H.-O. Pörtner, D. Roberts, J. Skea, P.R. Shukla, A. Pirani, W. Moufouma-Okia, C. Péan, R. Pidcock, S. Connors, J.B.R. Matthews, Y. Chen, X. Zhou, M.I.

Gomis, E. Lonnoy, T. Maycock, M. Tignor, and T. Waterfield (eds.), World Meteorological Organization, Geneva, Switzerland, 32 pp.
IPCC 2018b. Graphics (https://www.ipcc.ch/sr15/graphics/, 2018).
İnan, M. 2004. Orman varlığının saptanmasında uzaktan algılama verileri. İstanbul Üniversitesi. Fen Bilimleri Enstitüsü, Doktora Tezi, 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.
Ji, Y., Zhou, G., Luo, T., Dan, Y., Zhou, L. and Lv, X. 2020. Variation of net primary productivity and its drivers in China's forests during 2000–2018. Forest Ecosystems, 7(1), 1-11.
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.
Jonckheere, I., Fleck, S., Nackaerts, K., Muys, B., Coppin, P., Weiss, M. and Baret, F. 2004. Review of methods for in situ leaf area index determination: Part I. Theories, sensors and hemispherical photography. Agricultural and Forest Meteorology, 121(1-2), 19-35.
Jordan, C.F. 1969. Derivation of leaf area index from quality of light on the forest floor. Ecology, 50, 663–666.
Jurgens, C. 1997. The modified normalized difference vegetation index (mNDVI) a new index to determine frost damages in agriculture based on Landsat TM data. International Journal of Remote Sensing, 18(17), 3583-3594.
Kaduk, J. and Heimann, M. 1996. A prognostic phenology scheme for global terrestrial carbon cycle models. Climate Research, 6, 1-19.
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.
Karystinos, G.N. and Pados, D.A. 2000. On overfitting, generalization, and randomly expanded training sets. IEEE Transactions on Neural Networks, 11(5):1050.
Kaufman, Y.J. andTanre, D. 1992. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. IEEE transactions on Geoscience and Remote Sensing, 30(2), 261-270.
Kaufman, Y.J., and Remer, L.A. 1994. Detection of forests using mid-IR reflectance: An application for aerosol studies. IEEE Transactions on Geoscience and Remote Sensing, 32, 672:683.
Kayitakire, F., Hamel, C. and Defourny, P. 2006. Retrieving forest structure variables based on image texture analysis and IKONOS-2 imagery. Remote Sensing of Environment, 102(3-4), 390-401.
Kergoat, L. 1998. A model for hydrologic equilibrium of leaf area index on a global scale. Journal of Hydrology, 212-213, 267-286.
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.

Khosravi, S., Namiranian, M., Ghazanfari, H. and Shirvani, A. 2012. Estimation of leaf area index and assessment of its allometric equations in oak forests: northern Zagros, Iran. Journal of Forest Science, 58(3):116–122.

Kırış, R. ve Toprak, S. 2008. İklim değişikliğinde ormanların rolü. TÜCAUM V. Coğrafya Sempozyumu, s 379-384, Ankara.

Kindermann, J., LuÈ deke, M.K.B., Badeck, F.W. et al. 1993. Structure of a global and seasonal carbon exchange model for the terrestrial biosphere - The Frankfurt Biosphere Model (FBM). Water, Air and Soil Pollution, 70, 675-684.

Knorr, W. and Heimann, M. 1995. Impact of drought stress and other factors on seasonal land biosphere CO2 exchange studied through an atmospheric tracer transport model. Tellus, 47B, 471-489.

Koray, E.Ş. ve Tolunay, D. 2020. Türkmen Dağı karaçam meşcerelerinde döküm ile ekosisteme giren besin maddesi miktarları. Türkiye Ormancılık Dergisi, 21(3), 201-214.

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

Köse, İ. 2018. İklim değişikliği müzakereleri: Türkiye'nin Paris Anlaşması'nı imza süreci. Ege Stratejik Araştırmalar Dergisi, 9(1), 55-81.

Kumar, S. and Tewari, L.M. 2015. Pattern of litter fall in Pinus roxburghii Sarg. forest in Kumaun Himalaya, India. Indian Journal of Ecology, 42(1), 219-223.

Li, A. Bian, J. Lei, G. and Huang, C. 2012. Estimating the maximal light use efficiency for different vegetation through the CASA model combined with time-series remote sensing data and ground measurements. Remote Sensing, 4(12); 3857–3876.

Li, Z. and Zhou, T. 2015. Optimization of forest age-dependent light-use efficiency and its implications on climate-vegetation interactions in China. In International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives (Vol. 40, pp. 449–454).

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.

Lopez, O.R., Farris-Lopez, K., Montgomery, R.A. and Givnish, T.J. 2008. Leaf phenology in relation to canopy closure in southern Appalachian trees. American Journal of Botany, 95(11), 1395-1407.

Los, S. O. Pollack, N. H. Parris, M. T. Collatz, G. J. Tucker, C. J. Sellers, P. J. … Dazlich, D. A. 2000. A Global 9-yr Biophysical Land Surface Dataset from NOAA AVHRR Data. Journal of Hydrometeorology, 1(2); 183–199.

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 (1): 65–70.

Lu, D., Mausel, P., Brondizio, E. and Moran, E. 2004. Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. Forest Ecology and Management, 198(1–3): 149–167.

Luyssaert, S., Schulze, E.D., Börner, A., Knohl, A., Hessenmöller, D., Law, B.E., Ciais, P. and Grace, J. 2008. Old-growth forests as global carbon sinks. Nature, 455(7210), 213-215.

MacKay, S.L., Arain, M.A., Khomik, M., Brodeur, J.J., Schumacher, J., Hartmann, H. and Peichl, M. 2012. The impact of induced drought on transpiration and growth in a temperate pine plantation forest. Hydrological Processes. 26 (12):1779–1791.

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.

Malhi, Y., Doughty, C. and Galbraith, D. 2011. The allocation of ecosystem net primary productivity in tropical forests. Philosophical Transactions of the Royal Society B: Biological Sciences, 366(1582), 3225-3245.

MathWorks Inc., 2019. Improve shallow neural network generalization and avoid overfitting. Software Manual.

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.

McGuire, A.D., Melillo, J.M., Kicklighter, D.W. and Joyce, L.A. 1995. Equilibrium responses of soil carbon to climate change ± empirical and processbased estimates. Journal of Biogeography, 22 (4-5), 785-796.

Meng, S.X., Rudnicki, M., Lieffers, V.J., Reid, D.E.B. and Silins, U. 2006. Preventing crown collisions increases the crown cover and leaf area of maturing lodgepole pine. Journal of Ecology, 94: 681–686.

Metternicht, G. 2003. Vegetation Indices derived from high-resolution airborne videogaphy for precision crop management. International Journal of Remote Sensing 24: 2855–2877.

Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A. and Leisch, F., 2015. e1071: Misc Functions of the Department of Statistics, Probability Theory Group (Formerly: E1071), TU Wien, 2015. R package version, 1.6-7.

Negash, M. and Starr, M. 2013. Litterfall production and associated carbon and nitrogen fluxes of seven woody species grown in indigenous agroforestry systems in the south-eastern Rift Valley escarpment of Ethiopia. Nutrient Cycling in Agroecosystems, 97: 29–41.

Ollinger, S.V., Treuhaft, R.N., Braswell, B.H., Anderson, J.E., Martin, M.E. and Smith, M.L. 2007. The role of remote sensing in the study of terrestrial net primary production. Principles and standards for measuring primary production, 204-237.

Özbayram, A.K., Çiçek, E. ve Yılmaz, F. 2015. Kızılçam ve Karaçam meşcerelerinde yaprak alanı indeksi (YAİ) ile bazı meşcere özellikleri arasındaki ilişkiler. Kastamonu Üniversitesi Orman Fakültesi Dergisi, 15(1).

Özdemir, İ. and Karnieli, A. 2011. Predicting forest structural parameters using the image texture derived from WorldView-2 multispectral imagery in a dryland forest, Israel. International Journal of Applied Earth Observation and Geoinformation, 13(5), 701-710.

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.

Palosuo, T., Foereid, B., Svensson, M., Shurpali, N., Lehtonen, A., Herbst, M., Linkosalo, T., Ortiz, C., Todorovic, G.R., Marcinkonis, S., Li, C. and Jandl, R. 2012. A multi-model comparison of soil carbon assessment of a coniferous forest stand. Environmental Modelling & Software, 35:38–49.

Parker, G.G. and Russ, M.E. 2004. The canopy surface and stand development: assessing forest canopy structure and complexity with near-surface altimetry. Forest Ecology and Management, 189(1-3), 307-315.

Parton WJ, Scurlock JMO, Ojima DS et al. 1993. Observations and modeling of biomass and soil organic matter dynamics for the grassland biome worldwide. Global Biogeochemical Cycles, 7, 785-809.

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.

Pausas, J.G. 1997. Litterfall and litter decomposition in Pinus sylvestris forests of the eastern Pyrenees. Journal of Vegetation Science, 8: 643-650.

Peng, C. and Wen, X. 1999. Recent applications of artificial neural networks in forest resource management: an overview. Environmental decision support Systems and artificial intelligence. In: Aaai Workshop, pp. 15–22.

Peng, D., J. Huang, A.R. Huete, T. Yang, P. Gao, Y. Chen, H. Chen, J. Li, and Z. Liu. 2010. Spatial and seasonal characterization of net primary productivity and climate variables in southeastern China using MODIS data. Journal of Zhejiang University (Science B), 11(4):275–285.

Perry Jr, C. and Lautenschlager, L.F. 1984. Functional equivalence of spectral vegetation indices. Remote Sensing of Environment, 14(1-3):169-182.

Pinty, B. and Verstraete, M.M. 1992. GEMI: A non-linear index to monitor global vegetation from satellites. Vegetatio, vol. 101, pp. 15-20, 1992.

Pitman, R., Bastrup-Birk, A., Breda, N. and Rautio, P. 2010. Sampling and Analysis of Litterfall. In, Manual on methods and criteria for harmonized sampling, assessment, monitoring and analysis of the effects of air pollution on forests. UNECE ICP Forests Programme Co-ordinating Centre, Hamburg, Germany.

Plöchl, M. and Cramer, W. 1995. Coupling global models of vegetation structure and ecosystem processes ± an example from arctic and boreal ecosystems. Tellus Series B - Chemical and Physical Meteorology, 47, 240-250.

Pokorny, R. and Stojnic, S. 2012. Leaf area ındex of Norway spruce stands in relation to age and defoliation. Beskydy, 5(2):173-180.

Potter, C.S., Randerson, J.T., Field, C.B., Matson, P.A., Vitousek, P.M., Mooney, H.A. and Klooster, S.A. 1993. Terrestrial ecosystem production: A process model based on global satellite and surface data. Global Biogeochemical Cycles, 7, 811–841.

Prince, S.D. 1991. A model of regional primary production for use with coarse-resolution satellite data. International Journal of Remote Sensing, 12, 1313-1330.

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.

Qi, J., Chehbouni, A.L., Huete, A.R., Kerr, Y.H. and Sorooshian, S., 1994. A modified soil adjusted vegetation index (MSAVI). Remote Sensing of Environment 48, 119–126.

Ranger, J., Gerard, F., Lindemann, M., Gelhaye, D. and Gelhaye, L. 2003. Dynamics of litterfall in a chronosequence of Douglas-fir (Pseudotsuga menziesii Franco) stands in the Beaujolais mounts (France). Annals of Forest Science, 60:475–488.

Raskutti, G., Wainwright, M.J. and Yu, B. 2013. Early stopping for non-parametric regression: An optimal data-dependent stopping rule. Communication, Control, and Computing. IEEE, pp.1318-1325.

Reineke, L.H. 1933. Perfection a stand-density index for even-aged forest. Journal of agricultural research, 46, 627-638.

Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M. and Chica-Rivas, M., 2015. Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines. Ore Geology Reviews. 71, 804–818.

Rondeaux, G., Steven, M. and Baret, F. 1996. Optimization of soil-adjusted vegetation indices. Remote Sensing of Environment, 55, 95–107.

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.

Ruimy, A., Dedieu, G. and Saugier, B. 1996. TURC: a diagnostic model of continental gross primary productivity and net primary productivity. Global Biogeochemical Cycles, 10, 269-286.

Ruimy, A., Kergoat, L., Bondeau, A., Model, POTPN. 1999. Comparing global models of terrestrial net primary productivity (NPP): Analysis of differences in light absorption and light-use efficiency. Global Change Biology, 5(S1), 56-64.

Running, S.W. and Hunt, E.R. 1993. Generalization of a forest ecosystem process model for other biomes, Biome-BGC, and an application for global-scale models. Scaling processes between leaf and landscape levels. In: Scaling Physiological Processes: Leaf to Globe (Ehleringer JR, Field CB, eds.), pp. 141-158. Academic Press, San Diego.

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.

Ryan, M.G., Binkley, D., Fownes, J.H., Giardina, C.P. and Senock, R.S. 2004. An experimental test of the causes of forest growth decline with stand age. Ecological Monographs, 74(3), 393-414.

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.

Schloss, A. L., Kicklighter, D. W., Kaduk, J., Wittenberg, U., Model, POTPN. 1999. Comparing global models of terrestrial net primary productivity (NPP): comparison of NPP to climate and the Normalized Difference Vegetation Index (NDVI). Global Change Biology, 5(S1), 25-34.

Scurlock, J.M.O., Asner, G.P. and Gower, S.T. 2001. Worldwide historical estimates of leaf area index, 1932–2000. ORNL/TM-2001/268, 34.

Sellers, P.J., Randall, D.A., Collatz, G.J. et al. 1996. A revised land surface parameterization (SiB2) for atmospheric GCMs. Part I: Model formulation. Journal of Climate, 9, 676-705.

Shang, E., Xu, E., Zhang, H. and Liu, F. 2018. Analysis of spatiotemporal dynamics of the Chinese vegetation net primary productivity from the 1960s to the 2000s. Remote Sensing, 10(6), 860.

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.
Sripada, R.P. 2005. Determining in-season nitrogen requirements for corn using aerial color-infrared photography.
Taiz, L. and Zeiger, E. 2008. Plant physiology. Sinauer Associates, Inc., Publishers, ISBN: 0-87893-823-0.
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.
Taşkınsu Meydan, H.S. 2008. Yukarı Seyhan Havzası'nda uzaktan algılama yöntemleri ile arazi örtüsünün sınıflandırılması ve bazı orman meşcerelerinde verimliliğin modellenmesi. ÇÜ Fen Bilimleri Enstitüsü, Doktora Tezi, 194 s., Adana.
Thenkabail, P.S., Smith, R.B. and De Pauw, E. 1999. Hyperspectral vegetation indices for determining agricultural crop characteristics. CEO research publication series No. 1. Center for Earth Observation, Yale University Press, New Haven.
Tucker, C.J. 1980. A spectral method for determining the percentage of green herbage material in clipped sample. Remote Sensing of Environment, 9, 175–181.
Ťupek, B., Mäkipää, R., Heikkinen, J., Peltoniemi, M., Ukonmaanaho, L., Hokkanen, T., Nöjd, P., Nevalainen, S., Lindgren, M. and Lehtonen, A. 2015. Foliar turnover rates in Finland-comparing estimates from neeDÖe-cohort and litterfall-biomass methods. Boreal Environment Research, 20:283–304.
Tüfekçioğlu, A., Sarıyıldız, T., Güner, S. ve Küçük, M. 2005. Artvin Genya Dağı doğu ladini meşcerelerinde kök kütlesi, yıllık ibre dökümü ve toprak solunumu miktarlarının değişimleri. Ladin Sempozyumu, 20-22 Ekim, Trabzon, s. 123-129.
Türkeş, M. 2001. Küresel iklimin korunması, İklim Değişikliği Çerçeve Sözleşmesi ve Türkiye. Tesisat Mühendisliği, TMMOB Makina Mühendisleri Odası, Süreli Teknik Yayın 61: 14-29.
Ukonmaanaho, L., Pitman, R., Bastrup-Birk, A., Breda, N. and Rautio, P. 2016. Part XIII: Sampling and Analysis of Litterfall. In: UNECE ICP Forests Programme Co-ordinating Centre (ed.): Manual on methods and criteria for harmonized sampling, assessment, monitoring and analysis of the effects of air pollution on forests. Thünen Institute for Forests Ecosystems, Eberswalde, Germany, 15 p.
USGS 2000. USGS earth explorer. (https://earthexplorer.usgs.gov/, 2019).
Vincini, M., Frazzi, E. and D'Alessio, P. (2007). Comparison of narrow-band and broad-band vegetation indexes for canopy chlorophyll density estimation in sugar beet. In J. V. Stafford (Ed.), Precision agriculture '07: Proceedings of the 6th European Conference on Precision Agriculture (pp. 189–196). Wageningen, The Netherlands: Wageningen Academic Publishers.
Vose, J.M. and Allen, H.L. 1988. Leaf area, stemwood growth, and nutrition relationships in loblolly pine. Forest Science, 34, 547-563.
Wang, F., Huang, J., Tang, Y. and Wang, X. 2007. New vegetation index and its application in estimating leaf area index of rice. Rice Science, 14:195-203.
Wang, S., Zhou, L., Chen, J., Ju, W., Feng, X. and Wu, W. 2011. Relationships between net primary productivity and stand age for several forest types and their influence on China's carbon balance. Journal of Environmental Management, 92(6), 1651-1662.

Wang, H., Liu, G., Li, Z., Ye, X., Wang, M. and Gong, L. 2016. Impacts of climate change on net primary productivity in arid and semiarid regions of China. Chinese Geographical Science, 26(1), 35-47.

Wang, X., Tan, K., Chen, B. and Du, P. 2017. Assessing the spatiotemporal variation and impact factors of net primary productivity in China. Scientific Reports, 7, 44415.

Wang, B., Li, M., Fan, W., Yu, Y. and Chen, J.M. 2018. Relationship between net primary productivity and forest stand age under different site conditions and its implications for regional carbon cycle study. Forests, 9(1), 5.

Warde-Farley, D., Goodfellow, I.J., Courville, A. and Bengio, Y. 2013. An empirical analysis of dropout in piecewise linear networks. Computer Science.

Warnant, P., FrancËois, L., Strivay, D. and GeÂrard, J-C. 1994. CARAIB: a global model of terrestrial biological productivity. Global Biogeochemical Cycles, 8, 255-270.

Woodward, F.I., Smith, T.M. and Emanuel, W.R. 1995. A global land primary productivity and phytogeography model. Global Biogeochemical Cycles, 9, 471-490.

WWF 2018a. Küresel iklim değişikliği (http://www.wwf.org.tr/, 2018).

WWF 2018b. Küresel iklim değişikliği ve Türkiye (http://www.wwf.org.tr/, 2018).

Xiao, X. Hollinger, D. Aber, J. Goltz, M. Davidson, E. A. Zhang, Q. and Moore, B. 2004. Satellite-based modeling of gross primary production in an evergreen neeDÖeleaf forest. Remote Sensing of Environment, 89(4); 519–534.

Yer, B.M. 2021. Kastamonu yöresi karaçam meşcerelerinde yaprak alan indeksi ile çeşitli meşcere özellikleri arasındaki ilişkilerin belirlenmesi. Kastamonu Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 45 s., Kastamonu.

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, B. and Chen, F. 2016. The global impact factors of net primary production in different land cover types from 2005 to 2011. SpringerPlus, 5(1), 1235.

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.

Zhang, Y., Tian, Y., Knyazikhin, Y., Martonchik, J.V., Diner, D.J., Leroy, M. and Myneni, R.B. 2000. Prototyping of MISR LAI and FPAR algorithm with POLDER data over Africa. IEEE Transactions on Geoscience and Remote Sensing, 38(5), 2402-2418.

Zhang, J., Ge, Y., Chang, J., Jiang, B., Jiang, H., Peng, C., Zhu, J., Yuan, W., Qi, L. and Yu, S. 2007. Carbon storage by ecological service forests in Zhejiang Province, subtropical China. Forest Ecology and Management, 245(1-3), 64-75.

Zhang, H., Yuan, W., Dong, W. and Liu, S. 2014. Seasonal patterns of litterfall in forest ecosystem worldwide. Ecological Complexity, 20:240–247.

Zhang, M., Lin, H., Wang, G., Sun, H. and Cai, Y. 2019. Estimation of vegetation productivity using a Landsat 8 time series in a heavily urbanized area, Central China. Remote Sensing, 11(2), 133.

Zhao, M., Heinsch, F.A., Nemani, R.R. and Running, S.W. 2005. Improvements of the MODIS terrestrial gross and net primary production global data set. Remote sensing of Environment, 95(2), 164-176.

Zhao, J., Lia, J., Liua, Q. and Yanga, L. 2012. A preliminary study on mechanism of LAI inversion saturation. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 39, B1.

Zhao, Q., Yu, S., Zhao, F., Tian, L. and Zhao, Z. 2019. Comparison of machine learning algorithms for forest parameter estimations and application for forest quality assessments. Forest Ecology and Management, 434, 224-234.

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. 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.

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.

Zhu, W. Pan, Y. He, H. Yu, D. and Hu, H. 2006. Simulation of maximum light use efficiency for some typical vegetation types in China. Chinese Science Bulletin, 51(4); 457–463.

ÖZGEÇMİŞ

Adı Soyadı : Sinan BULUT

Doğum Yeri : Akçaabat

Doğum Tarihi : 01.05.1987

Medeni Hali : Evli

Yabancı Dili : İngilizce

Eğitim Durumu

Lise : Akçaabat Lisesi (2004)

Lisans : Karadeniz Teknik Üni. Orman Fak. Orman Müh. Bölümü (2005)

Yüksek Lisans: Çankırı Karatekin Üni. Fen Bilimleri Enstitüsü (2012)

Doktora : Çankırı Karatekin Üni. Fen Bilimleri Enstitüsü (2015)

Çalıştığı Kurum : Çankırı Karatekin Üniversitesi

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

1. Bolat, F. Bulut, S. Günlü, A. Ercanlı, İ. and Şenyurt, M. 2020. Regression kriging to improve basal area and growing stock volume estimation based on remotely sensed data, terrain indices and forest inventory of black pine forests. New Zealand Journal of Forestry Science, 50(4).
2. Şenyurt, M. Ercanlı, İ. Günlü, A. Bolat, F. and Bulut, S. 2020. Artificial neural network models for predicting relationships between diameter at breast height and stump diameter: Crimean pine stands at ÇAKÜ Forest. Bosque 41(1):25-34.
3. Günlü, A., Bulut, S., Keleş, S. and Ercanlı, İ. 2020. Evaluating different spatial interpolation methods and modeling techniques for estimating spatial forest site index in pure beech forests: a case study from Turkey. Environmental Monitoring and Assessment, 192(1), 1-11.
4. Bulut, S., Şatır, O. and Günlü, A. 2019. Determining the interactions of black pine net primary productivity and forest stand parameters in northern Turkey. Applied Ecology and Environmental Research, 17(2), 4459-4473.
5. Karahalil, U., Başkent, E.Z. and Bulut, S. 2018. The effects of spatiotemporal changes on forest carbon storage: A case study in Çaykara, Turkey. Internatıonal Journal of Global Warming, vol.14, pp.1-17.
6. Göl, C., Bulut, S. and Bolat, F. 2017. Comparison of different interpolation methods for spatial distribution of soil organic carbon and some soil properties in the Black Sea backward region of Turkey. . Journal of African Earth Sciences, 134; 85–91.
7. Kadıoğulları, A.İ., Sayın, M.A., Çelik, D.A., Borucu, S., Çil, B. and Bulut, S. 2014. Analysing land cover changes for understanding of forest dynamics using

temporal forest management plans. Environmental Monitoring and Assessment, 186(4), 2089-2110.

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

1. Bulut, S., Günlü, A. and Keleş, S. 2019. Estimation of forest development stage and crown closure using different classification methods and satellite images: A case study from Turkey. Journal of Forest Science, 65(1), 18-26.

Ulusal Hakemli Dergilerdeki Makaleler

1. Bulut, S. and Günlü, A. 2016. Arazi kullanım sınıfları için farklı kontrollü sınıflandırma algoritmalarının karşılaştırılması. Kastamonu University Journal of Forestry Faculty, 16(2), 528-535.
2. Bulut, S., Keleş, S. and Günlü, A. 2016. Değişikyaşlı orman amenajman planlamasında bilgisayar destekli model. Anadolu Orman Araştırmaları Dergisi, 2(1-2), 25-31.
3. 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.

Uluslararası Kongre/Sempozyum Bildirileri

1. Şenyurt, M., Ercanlı, İ., Günlü, A., Bolat, F., Bulut, S. 2017. Predicting breast height diameterfrom stump diameters of crimean pine stands in ÇAKÜ Research Forest. International Symposium on New Horizons in Forestry.
2. Bulut, S., Günlü, A. and Keleş, S. 2017. Evaluation of different supervised classification algorithms for crown closure classes: a case study of Yapraklı Forest Planning Unit, Çankırı. International Symposium on New Horizons in Forestry, ISFOR 2017, s. 133-137.
3. Bulut, S., Günlü, A. and Keleş, S. 2016. Estimation of some stand parameters using Göktürk-2 satellite image. 1st International Symposium of Forest Engineering and Technologies, FETEC 2016, s. 118-124.
4. Bolat, F. and Bulut, S. 2016. Spatial distribution of stand carbon in even-aged mixed forests. International Forestry Symposium, IFS 2016.
5. Keleş, S. ve Bulut, S. 2015. Orman ekosistemlerinin ekoturizm ve rekreasyon fonksiyonunun orman amenajman planlaması açısından değerlendirilmesi. 1. Uluslararası Türk Dünyası Turizm Sempozyumu.

Ulusal Kongre/Sempozyum Bildirileri

1. Keleş, S. ve Bulut, S. 2014. Aynıyaşlı ve değişikyaşlı orman formlarının orman ekosistem fonksiyonları kapsamında karşılaştırılması. II. Ulusal Akdeniz Orman ve Çevre Sempozyumu, s. 136-146.

Projeler

1. Günlü, A., Sönmez, M.Y. ve Bulut, S. 2020-2021. Ilgaz Orman İşletme Müdürlüğü Yenice Orman İşletme Şefliği sınırları içerisinde yayılış gösteren saf karaçam meşcerelerinde net birincil üretim, yaprak alan indeksi ve bazı meşcere parametreleri arasındaki ilişkilerin incelenmesi. Araştırma Projesi, Destekleyen Kuruluş: Çankırı Karatekin Üniversitesi, Bilimsel Araştırma Projeleri.
2. Günlü, A. ve Bulut, S. 2019-2021. Ankara Orman Bölge Müdürlüğü saf karaçam meşcerelerinde net birincil üretim ve yaprak alan indeksinin uzaktan algılama teknikleri ile modellenmesi. Lisansüstü Tez Projesi, Destekleyen Kuruluş: Çankırı Karatekin Üniversitesi, Bilimsel Araştırma Projeleri.
3. Ercanlı, İ., Şenyurt, İ., Günlü, A., Bolat, F. ve Bulut, S. 2016-2017. ÇNÜ araştırma ormanı karaçam meşcereleri için artım ve büyüme tahminlerinin yapay sinir ağları tekniği ile elde edilmesi. Araştırma Projesi, Destekleyen Kuruluş: Çankırı Karatekin Üniversitesi, Bilimsel Araştırma Projeleri.
4. Keleş, S. ve Bulut, S. 2013-2015. Değişikyaşlı ormanların amenajman planlama esasları ve ETÇAP Karar Destek Sistemine entegrasyonu. Lisansüstü Tez Projesi, Destekleyen Kuruluş: Çankırı Karatekin Üniversitesi, Bilimsel Araştırma Projeleri.