

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**İNSANSIZ HAVA ARACI VE YERSEL HİPERSPEKTRAL VERİLER İLE
NARENCİYE AĞAÇLARINDA VERİM TAHMİNİ**

Mesut ÇOŞLU

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

DOKTORA TEZİ

HAZİRAN 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**İNSANSIZ HAVA ARACI VE YERSEL HİPERSPEKTRAL VERİLER İLE
NARENCİYE AĞAÇLARINDA VERİM TAHMİNİ**

Mesut ÇOŞLU

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

DOKTORA TEZİ

HAZİRAN 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**İNSANSIZ HAVA ARACI VE YERSEL HİPERSPEKTRAL VERİLER İLE
NARENCİYE AĞAÇLARINDA VERİM TAHMİNİ**

**Mesut ÇOŞLU
UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ
ANABİLİM DALI
DOKTORA TEZİ**

Bu tez TÜBİTAK tarafından 120O990 nolu proje ile desteklenmiştir.

HAZİRAN 2023

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**İNSANSIZ HAVA ARACI VE YERSEL HİPERSPEKTRAL VERİLER İLE
NARENCİYE AĞAÇLARINDA VERİM TAHMİNİ**

Mesut ÇOŞLU

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

DOKTORA TEZİ

Bu tez 16/06/2023 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Prof.Dr. Namık Kemal SÖNMEZ (Danışman)

Prof.Dr. Levent BAŞAYİĞİT

Doç.Dr. Mustafa Tolga ESETLİLİ

Doç.Dr. Serdar SELİM

Dr.Öğr.Üyesi Gülçin Ece ASLAN

ÖZET

İNSANSIZ HAVA ARACI VE YERSEL HİPERSPEKTRAL VERİLER İLE NARENCİYE AĞAÇLARINDA VERİM TAHMİNİ

Mesut ÇOŞLU

Doktora Tezi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Prof.Dr. Namık Kemal SÖNMEZ

Haziran 2023; 165 sayfa

Antalya ili, turizm sektörüne katkısının yanı sıra gerek meteorolojik koşullar gerekse toprak özellikleri bakımından tarım sektöründe hem ülkemizde hem de dünyada önemli bir yere sahiptir. Tarım sektöründe iç ve dış piyasa açısından önemli ürün gruplarından biri olan turuncgillerin Antalya’da çok farklı çeşitleri yetiştirilmektedir. Bu çalışmada, turuncgiller olarak da ifade edilen farklı narenciye ağacı çeşitlerinde (Washington, Valencia, Clementine, Satsuma) farklı uzaktan algılama teknikleri ile verim tahmini amaçlanmıştır. Çalışma, narenciye ağaçlarının 2021-2022 yıllarını kapsayan meyve olum dönemlerinde Antalya İli Serik İlçe sınırlarında bulunan Batı Akdeniz Tarımsal Araştırma Enstitüsü’nün (BATEM) Kayaburnu arazisinde yürütülmüştür. Tez çalışması, verilerin temin edilmesi, insansız hava aracı (İHA) ve light detection and ranging (LiDAR) verilerinin ön işleme, yersel ölçüm verileri dahil tüm veri setleri için veri tabanlarının oluşturulması, istatistiksel analizler, verim tahmini ve değerlendirme temel aşamalarından oluşmaktadır. Çalışma kapsamında meyve olum dönemindeki farklı narenciye çeşitlerinin verim tahmininde İHA ve İHA-LiDAR sistemlerinden alınan verilerden elde edilen ağaç taç yapısı, ağaç taç alanı ve ağaç yükseklikleri belirlenmiştir. Bu iki farklı uzaktan algılama sisteminden elde edilen ağaç dendrometrik bileşenleri arasında gerçekleştirilen istatistiksel analizler sonucunda yüksek korelasyonlar tespit edilmiş olup elde edilen bulgular ışığında narenciye ağaçlarının verim tahmininde İHA’dan hesaplanan ağaç dendrometrik bileşenlerinin kullanılmasına karar verilmiştir. Çalışmanın bir diğer aşamasında, İHA’ya monte edilen multispektral (MS) kameradan alınan görüntülerden basit oran (SR) indeksi ve normalize edilmiş fark bitki indeksi (NDVI), spektrometre cihazından ölçülen yersel hiperspektral verilerden ise SR, NDVI, hiperspektral normalize edilmiş fark bitki indeksi (HNDVI) ve normalize edilmiş pigment klorofil indeksi (NPCl) hesaplanmıştır. Ayrıca arazi çalışmaları ile narenciye ağaçlarının gövde yükseklikleri ve yaprak klorofil değerleri de ölçülmüş, tüm narenciye ağaçlarının gerçek verim değerleri temin edilmiştir. Çalışmada elde edilen tüm veri setlerine yönelik yürütülen istatistiksel analizler kapsamında tüm değişkenler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları, histogram grafikleri, normalite testleri ve korelasyon analizleri gerçekleştirilmiştir. Ayrıca meyve olum dönemindeki narenciye ağaçlarının verim tahmininde, verimi açıklayan 9 değişken kullanılarak 4 farklı verim tahmin modeli oluşturulmuştur. Çalışmada tüm değişkenler arasında gerçekleştirilen istatistiksel analizler sonucu yapılan değerlendirme ile verim tahmininde kısmi en küçük kareler regresyonunun (PLSR) kullanılmasına karar verilmiştir. Her bir model için uygulanan PLSR analizi sonuçlarına göre tüm deneme alanlarında bağımsız değişkenlerin tamamının yer aldığı modelin verim bağımlı değişkenini en yüksek açıklama yüzdesine sahip olduğu belirlenmiştir. Ayrıca

arařtırmadan elde edilen bulgular, İHA verilerinden üretilen bazı bitki indeksleri ve bazı ağaç dendrometrik bileřenlerinin meyve olum dönemindeki narenciye bahçelerinde verimi açıklamada önemli parametreler olduğunu göstermiştir. Bu tez çalışması ile elde edilen model karşılaştırma sonuçlarına göre en yüksek belirleme katsayısı (R^2), Satsuma mandalinası deneme alanında ($R^2=0.841$) tespit edilmiştir. Diğer deneme alanlarında elde edilen belirleme katsayıları ise sırasıyla Washington portakalı ($R^2=0.719$), Valencia portakalı ($R^2=0.685$), Clementine mandalinasıdır ($R^2=0.302$).

ANAHTAR KELİMELEER: Bitki indeksi, İHA, LiDAR, Narenciye, PLSR, Verim tahmini

JÜRİ: Prof.Dr. Namık Kemal SÖNMEZ

Prof.Dr. Levent BAŞAYİĞİT

Doç.Dr. Mustafa Tolga ESETLİLİ

Doç.Dr. Serdar SELİM

Dr.Öğr.Üyesi Gülçin Ece ASLAN

ABSTRACT

YIELD ESTIMATION OF CITRUS TREES WITH UNMANNED AERIAL VEHICLE AND TERRESTRIAL HYPERSPECTRAL DATA

Mesut OŞLU

PhD Thesis in Remote Sensing and Geographic Information Systems Department

Supervisor: Prof.Dr. Namık Kemal SÖNMEZ

June 2023; 165 pages

Antalya province has an important place in the agricultural sector both in our country and in the world in terms of meteorological conditions and soil characteristics as well as its contribution to the tourism sector. Many different varieties of citrus fruits, which are one of the important product groups in the agricultural sector in terms of domestic and foreign markets, are grown in Antalya. In this study, it was aimed to estimate the yield of different citrus tree varieties (Washington, Valencia, Clementine, Satsuma), which are also expressed as citrus fruits, with different remote sensing techniques. The study was carried out in the period of fruit ripening of citrus trees covering the years 2021-2022 in the Kayaburnu land of the West Mediterranean Agricultural Research Institute (BATEM) located in the Serik District of Antalya Province. The thesis work consists of the basic stages of data acquisition, preprocessing of unmanned aerial vehicle (UAV) and light detection and ranging (LiDAR) data, creation of databases for all datasets including terrestrial measurement data, statistical analyses, yield estimation and evaluation. Within the scope of the study, the tree crown structure, tree crown area and tree heights obtained from the data obtained from UAV and UAV-LiDAR systems were determined in the yield estimation of different citrus varieties in the fruit ripening period. As a result of the statistical analyses performed between the tree dendrometric components obtained from these two different remote sensing systems, high correlations were determined, and in the light of the findings obtained, it was decided to use the tree dendrometric components calculated from the UAV in the yield estimation of citrus trees. In another stage of the study, simple ratio (SR) index and normalized difference vegetation index (NDVI) from the images taken from the UAV mounted multispectral (MS) camera and SR, NDVI, hyperspectral normalized difference vegetation index (HNDVI) and normalized pigment chlorophyll index (NPCl) from the terrestrial hyperspectral data measured from the spectroradiometer device were calculated. In addition, trunk heights and leaf chlorophyll values of citrus trees were measured during the field studies, and the actual yield values of all citrus trees were obtained. Within the scope of the statistical analyses carried out for all data sets obtained in the study, descriptive statistics values, skewness-kurtosis coefficients, histogram graphics, normality tests and correlation analyses were performed for all variables. In addition, in the estimation of the yield of citrus trees in the fruit ripening period, 4 different yield estimation models were created by using 9 variables to explain the yield. In the study, it was decided to use the partial least squares regression (PLSR) in the estimation of the yield as a result of the evaluation considering the statistical analyses performed between all the variables. According to the results of the PLSR analysis applied for each model, it was determined that the model with all independent variables

in all trial areas had the highest percentage of explanation of the yield dependent variable. In addition, the findings obtained from the research showed that some plant indices and some tree dendrometric components obtained from the UAV data are important parameters in explaining the yield in citrus orchards in the fruit ripening period. According to the model comparison results obtained with this thesis study, the highest determination coefficient (R^2) was determined in the Satsuma mandarin trial area ($R^2=0.841$). The coefficients of determination obtained in other trial areas were Washington orange ($R^2=0.719$), Valencia orange ($R^2=0.685$), and Clementine mandarin ($R^2=0.302$), respectively.

KEYWORDS: Citrus, LiDAR, PLSR, UAV, Vegetation index, Yield estimation

COMMITTEE: Prof.Dr. Namık Kemal SÖNMEZ

Prof.Dr. Levent BAŞAYIĞIT

Assoc.Prof.Dr. Mustafa Tolga ESETLİ

Assoc.Prof.Dr. Serdar SELİM

Asst.Prof.Dr. Gülçin Ece ASLAN

ÖNSÖZ

Bu tez çalışmasında 2021-2022 yıllarını kapsayan meyve olum dönemindeki dört farklı narenciye ağacı çeşidinde farklı uzaktan algılama teknikleri kullanarak verim tahmininin yapılması amaçlanmıştır. Çalışma, Antalya ilinin Serik ilçesinde bulunan Batı Akdeniz Tarımsal Araştırma Enstitüsü'nde yürülmüş olup Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 120O990 nolu proje kapsamında desteklenmiştir.

Son yıllarda sensör ve aviyonik sistemlerin gelişmesine paralel olarak sivil ya da askeri anlamda kullanımı hızla artan İHA sistemleri tarımsal uygulamalarda da sıkça kullanılmaktadır. Bu sistemlerin tarımda genellikle haritalama ve püskürtme uygulamalarında kullanıldığı kanısı oldukça yaygındır. Ancak İHA'lar özellikle sensör teknolojilerindeki gelişmeler, maliyet ve zaman gibi önemli avantajlara sahip olmaları nedeniyle fotogrametri ve dijital görüntü analizlerinde de kullanılabilmektedir. Bu kapsamda tarımsal ürünlerin belirli dönemlerinde elde edilecek verilerden bitki boyu, ağaç taç yapısı, bitki sağlığı ve bitki yoğunluğu gibi önemli bilgilerin çıkarımı gerçekleştirilebilmektedir. Bu tez çalışması, proksimal uzaktan algılamanın yanı sıra İHA ve İHA-LiDAR sistemlerinin birlikte kullanımı ile farklı narenciye ağaçlarından çıkarılan bazı özelliklerden verimin tahmin edilebilmesinde önemli ve özgün bir yere sahiptir.

Gerek lisansüstü çalışmalarında gerekse genel anlamda uzaktan algılama teknolojisi ile tanışmamda en büyük paya sahip olan kıymetli hocam Prof.Dr. Namık Kemal SÖNMEZ'e sonsuz şükranlarımı sunarım. Ayrıca tez izleme komitesinde yer alan hocalarım Doç.Dr. Serdar SELİM ve Dr.Öğr.Üyesi Gülçin Ece ASLAN'a, TÜBİTAK 120O990 nolu proje ekibine, TÜBİTAK'a ve meteoroloji verilerini tarafımızla paylaşan Meteoroloji 4. Bölge Müdürlüğüne teşekkür ederim.

Hayatıma girdikleri andan itibaren mutluluk kaynağım olan ve her konuda desteklerini sürekli hissettiğim eşim Bahar ile oğullarım Mehmet Ata ve Türkay Efe'ye teşekkür eder sonsuz sevgilerimi sunarım.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
ÖNSÖZ	v
AKADEMİK BEYAN	viii
SİMGELER VE KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	xv
ÇİZELGELER DİZİNİ	xvii
1. GİRİŞ	1
2. KAYNAK TARAMASI	4
2.1. Uydu Uzaktan Algılama Teknolojisinin Tarımda Kullanımı	4
2.2. Hiperspektral Uzaktan Algılamanın Tarımda Kullanımı	6
2.3. SPAD Cihazının Tarımda Kullanımı	9
2.4. İHA Sistemlerinin Tarımda Kullanımı	10
2.5. LiDAR Sistemlerinin Tarımda Kullanımı	13
2.6. Uzaktan Algılama Teknolojisi İle Tarım Alanlarında Verim Tahmini	18
3. MATERYAL VE METOT	24
3.1. Materyal.....	24
3.1.1. Çalışma alanı	24
3.1.2. İHA ve MS kamera	25
3.1.3. İHA ve LiDAR (İHA-LiDAR) sistemleri.....	28
3.1.4. Spektrometre.....	30
3.1.5. Klorofilmetre	31
3.1.6. Meteorolojik veriler	32
3.1.7. Toprak verileri	37
3.2. Metot	39
3.2.1. İHA-LiDAR verilerinin alınması, ön işleme ve analiz	41
3.2.2. Fotogrametrik ve MS-İHA verilerinin alınması, ön işleme ve analiz	44
3.2.3. Yaprak örneklemeleri, hiperspektral ölçümler ve indeks hesaplamaları.....	52
3.2.4. Yersel ölçüm verileri	53
3.2.5. İstatistiksel analizler	55
3.2.6. Verim tahmin modelleri.....	56

4. BULGULAR VE TARTIŞMA	58
4.1. İHA-LiDAR Verilerinden Ağaç Dendrometrik Bileşenlerinin Belirlenmesi.....	58
4.2. İHA Verilerinden Ağaç Dendrometrik Bileşenlerinin Belirlenmesi	60
4.3. İHA-LiDAR ve Fotogrametrik İHA Verilerinin Korelasyon Analizi	66
4.4. Yersel Hiperspektral Verilerden Hesaplanan Bitki İndeks Değerleri	74
4.5. MS-İHA Verilerinden Hesaplanan Bitki İndeks Değerleri	78
4.6. Yersel Ölçüm Verileri	80
4.7. İstatistiksel Analizler	81
4.7.1. Washington deneme alanı için istatistiksel analizler	82
4.7.2. Valencia deneme alanı için istatistiksel analizler	84
4.7.3. Clementine deneme alanı için istatistiksel analizler	88
4.7.4. Satsuma deneme alanı için istatistiksel analizler	91
4.8. Verim Tahmin Modelleri.....	94
4.8.1. Washington deneme alanı için verim tahmin modelleri	95
4.8.2. Valencia deneme alanı için verim tahmin modelleri	107
4.8.3. Clementine deneme alanı verim tahmin modelleri	119
4.8.4. Satsuma deneme alanı verim tahmin modelleri.....	130
5. SONUÇLAR	145
6. KAYNAKLAR	150
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Doktora Tezi olarak sunduğum “İnsansız Hava Aracı Ve Yersel Hiperspektral Veriler İle Narenciye Ağaçlarında Verim Tahmini” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

16/06/2023

Mesut ÇOŞLU



SİMGELER VE KISALTMALAR

Simgeler

°	: Derece
'	: Dakika
"	: Saniye
%	: Yüzde
<	: Küçüktür
>	: Büyüktür
≤	: Küçük Eşittir
≥	: Büyük Eşittir
°C	: Derece Celsius
°F	: Derece Fahrenheit
cm	: Santimetre
Ca	: Kalsiyum
Cu	: Bakır
g	: Gram
Fe	: Demir
GHz	: Gigahertz
ha	: Hektar
Hz	: Hertz
K	: Potasyum
kg	: Kilogram
m	: Metre
Mg	: Magnezyum
Mn	: Mangan
mAh	: Milliampere Hour

mm	: Milimetre
μmol	: Mikromol
N	: Azot
nm	: Nanometre
P	: Fosfor
pH	: Hidrojen İyonu Konsantrasyonu Eksi Logaritması
ppm	: Part Per Million
ρ	: Spearman’ın Korelasyon Katsayısı
V	: Volt
Zn	: Çinko
“21.01”	Ondalık Ayırıcı

Kısaltmalar

3B	: 3 Boyutlu
AGL	: Yer Seviyesi Üstü
AS	: Alpha-Shape
ASBS	: Alpha-Shape By Slices
ASD	: Analytical Spectral Devices
AÜ	: Akdeniz Üniversitesi
AYK	: Ağaç Yüksekliği
BATEM	: Batı Akdeniz Tarımsal Araştırma Enstitüsü Müdürlüğü
BP	: Geri Yayılım
CAR	: Sabit Allometrik Oranlı
CBS	: Coğrafi Bilgi Sistemleri
CCL	: Bağlı Bileşenler Etiketleme
CH	: Convex Hull

Chl	: Klorofil
CNN	: Evrişimsel Sinir Ağı
CORS	: Continuously Operating Reference Stations
CSF	: Cloth Simulation Filtering
DSM	: Sayısal Yüzey Modeli
DTM	: Sayısal Arazi Modeli
EC	: Elektriksel İletkenlik
ETM	: Geliştirilmiş Tematik Haritacı
EVI	: Geliştirilmiş Bitki Örtüsü İndeksi
FAO	: Birleşmiş Milletler Gıda ve Tarım Örgütü
FVC	: Kısmi Bitki Örtüsü Kapsamı
GBR	: Gradyan Artırma Regresyon
GEE	: Google Earth Engine
GLCM	: Gri Seviye Eş Olum Matrisi
GLONASS	: Küresel Uydu Konumlandırma Sistemi
GPR	: Gauss Süreç Regresyonu
GPS	: Küresel Konumlama Sistemi
GSD	: Yer Örneklem Mesafesi
GYK	: Gövde Yüksekliği
HLB	: Huanglongbing
HNDVI	: Hiperspektral Normalize Edilmiş Fark Bitki İndeksi
HNY	: Hiperspektral Normalize Edilmiş Fark Bitki İndeksi-Yersel
HSV	: Hue-Saturation-Value
ICP	: Iterative Closest Point
IMU	: Inertial Measurement Unit
INS	: Inertial Navigation System

İHA	: İnsansız Hava Aracı
KNN	: K-En Yakın Komşu
KYM	: Kanopi Yükseklik Modeli
LAI	: Yaprak Alan İndeksi
LDM	: Leaf Dry Matter
LiDAR	: Light Detection and Ranging veya Laser Imaging Detection and Ranging
LiPo	: Lityum Polimer
Li Ion	: Lityum İyon
LOO	: Birini Dışarıda Bırakma
LNC	: Yaprak Nitrojen İçeriği
LSTM	: Uzun Kısa Süreli Bellek
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MCC	: Mapir Camera Control
MGM	: Meteoroloji Genel Müdürlüğü
MP	: Mega Piksel
MLP	: Çok Katmanlı Algılayıcı
MLR	: Çoklu Lineer Regresyon
MRS	: Çoklu Çözünürlüklü Segmentasyon
MSE	: Ortalama Karesel Hata
MTA	: Maden Tetkik Arama
MVS	: Çoklu Görüş Stereo
NDI	: Normalize Edilmiş Fark Bitki İndeksi-İHA
NDPI	: Normalize Edilmiş Fark Plastik İndeksi
NDSM	: Normalize Edilmiş Fark Yüzey Modeli
NDVI	: Normalize Edilmiş Fark Bitki İndeksi

NDY	: Normalize Edilmiş Fark Bitki İndeksi-Yersel
NIPALS	: Nonlinear Iterative Partial Least Squares
NIR	: Yakın Kızılötesi
NPCI	: Normalize Edilmiş Pigment Klorofil İndeks
NPY	: Normalize Edilmiş Pigment Klorofil İndeks-Yersel
NRMSE	: Normalize Edilmiş Kök Ortalama Kare Hata
OBIA	: Nesne Tabanlı Görüntü Analizi
OM	: Organik Materyal
OMGİ	: Otomatik Meteoroloji Gözlem İstasyonu
PAR	: Fotosentetik Aktif Radyasyon
PCA	: Temel Bileşenler Analizi
PCL	: Nokta Bulutu Kütüphanesi
PLSR	: Kısmi En Küçük Kareler Regresyonu
POS	: Position And Orientation Systems
RGB	: Kırmızı-Yeşil-Mavi
RF	: Rastgele Orman
RFR	: Rastgele Orman Regresyonu
RMPRESS	: Kök Ortalama Tahmin Edilen Artık Hata Kareler Toplamı
RMSE	: Kök Ortalama Karesel Hata
SAM	: Sayısal Arazi Modeli
SE	: Standart Hata
SAMIR	: Satellite Monitoring of Irrigation
SD	: Standart Sapma
SfM	: Hareketten Yapı
SIMPLS	: Statistically Inspired Modification Of The Partial Least Squares
SLAM	: Simultaneous Localization and Mapping

SPD	: SPAD
SOR	: Statistical Outlier Removal
SPAD	: Toprak ve Bitki Analizleri Geliştirme
SR	: Basit Oran
SRI	: Basit Oran-İHA
SRY	: Basit Oran-Yersel
SVR	: Destek Vektör Regresyonu
SWIR	: Kısa Dalga Kızılötesi
SYM	: Sayısal Yüzey Modeli
TAL	: Taç Alanı
TEPGE	: Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü
TİGEM	: Tarım İşletmeleri Genel Müdürlüğü
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
TGI	: Üçgen Yeşillik İndeksi
UAV	: İnsansız Hava Aracı
UGV	: İnsansız Kara Aracı
USA	: Amerika Birleşik Devletleri
VB	: Voksel Tabanlı
VIF	: Varyans Enflasyon Faktörü
VIP	: Projeksiyondaki Değişken Önemi
VNIR	: Görünür Yakın Kızılötesi
VRM	: Verim
WS	: Havza Segmentasyonu
YKN	: Yer Kontrol Noktası
YSA	: Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 3.1. Çalışma alanının genel görünümü	24
Şekil 3.2. Deneme alanlarının çalışma alanındaki konumu	25
Şekil 3.3. Çalışmada kullanılan İHA	26
Şekil 3.4. Çalışmada kullanılan MS kamera ve İHA'ya montaj aparatı	27
Şekil 3.5. Çalışmada kullanılan İHA ve LiDAR sistemleri	29
Şekil 3.6. Çalışmada kullanılan spektrometre	30
Şekil 3.7. Çalışmada kullanılan klorofilmetre ve okuma kontrolcüsü	31
Şekil 3.8. SPAD-502 çalışma teorisi	32
Şekil 3.9. Aylık ortalama sıcaklık grafiği	33
Şekil 3.10. Aylık ortalama toprak sıcaklığı grafiği	33
Şekil 3.11. Aylık ortalama nisbi nem grafiği	34
Şekil 3.12. Aylık ortalama yağış grafiği	34
Şekil 3.13. Aylık ortalama rüzgâr hızı grafiği	35
Şekil 3.14. Günlük meteorolojik veriler grafiği	35
Şekil 3.15. PAR metre cihazı	36
Şekil 3.16. Toprak örneklemeleri	37
Şekil 3.17. İş akışı	40
Şekil 3.18. İHA-LiDAR operasyonları	41
Şekil 3.19. Yörünge dosyası ve base station (ANTL) verileri	42
Şekil 3.20. Nokta bulutu verileri	43
Şekil 3.21. LiDAR verilerine uygulanan SOR filtresi ve parametreler	44
Şekil 3.22. Yer kontrol noktaları ve ölçümü	45
Şekil 3.23. Fotogrametrik ve MS-İHA uçuşları	46
Şekil 3.24. Dört bant ortomozaik görüntü ve KYM üretimi işlem adımları	48
Şekil 3.25. Segmentasyon işlemi sonuçları	49
Şekil 3.26. MAPIR kamera yansıma kalibrasyonu	50
Şekil 3.27. Görüntü kalibrasyon işlemi	51
Şekil 3.28. Yaprak örneklemeleri	52
Şekil 3.29. Yaprak örneklerinin hiperspektral ölçümleri	53
Şekil 3.30. Yaprak klorofil ölçümleri	54
Şekil 3.31. Ağaç gövde yüksekliği ölçümü	54
Şekil 4.1. Narenciye ağaçlarının taç yapıları (İHA-LiDAR)	58
Şekil 4.2. Dört bant İHA görüntüleri (Gerçek renk kombinasyonu)	61
Şekil 4.3. Dört bant İHA görüntüleri (Yanlış renk kombinasyonu)	61
Şekil 4.4. Kanopi yükseklik modelleri	62
Şekil 4.5. Narenciye ağaçlarının taç yapıları (İHA)	62
Şekil 4.6. Narenciye ağaçlarının taç alanları grafiği (İHA)	63
Şekil 4.7. Narenciye ağaçlarının yükseklik grafiği (İHA)	65
Şekil 4.8. Washington deneme alanı histogram grafikleri	70
Şekil 4.9. Valencia deneme alanı histogram grafikleri	71
Şekil 4.10. Clementine deneme alanı histogram grafikleri	72
Şekil 4.11. Satsuma deneme alanı histogram grafikleri	73
Şekil 4.12. Spektral yansıtım grafikleri	75

Şekil 4.13. Tüm deneme alanlarının ortalama spektral grafikleri.....	75
Şekil 4.14. Klorofil ölçüm grafikleri	80
Şekil 4.15. Washington deneme alanı histogram grafikleri.....	83
Şekil 4.16. Valencia deneme alanı histogram grafikleri	86
Şekil 4.17. Clementine deneme alanı histogram grafikleri.....	89
Şekil 4.18. Satsuma deneme alanı histogram grafikleri.....	92
Şekil 4.19. Washington Model-1 için açıklanan yüzde değişim.....	96
Şekil 4.20. Washington Model-1 için değişken önem grafiği	97
Şekil 4.21. Washington Model-2 için açıklanan yüzde değişim.....	98
Şekil 4.22. Washington Model-2 değişken önem grafiği	99
Şekil 4.23. Washington Model-3 için açıklanan yüzde değişim.....	100
Şekil 4.25. Washington 3 modele göre tahmin edilen ve gerçekleşen verim grafiği ...	103
Şekil 4.27. Washington Model-4 değişken önem grafiği	105
Şekil 4.28. Washington 4 modele göre tahmin edilen ve gerçekleşen verim grafiği ...	107
Şekil 4.29. Valencia Model-1 için açıklanan yüzde değişim.....	108
Şekil 4.31. Valencia Model-2 için açıklanan yüzde değişim.....	110
Şekil 4.32. Valencia Model-2 değişken önem grafiği.....	111
Şekil 4.33. Valencia Model-3 için açıklanan yüzde değişim.....	112
Şekil 4.34. Valencia Model-3 değişken önem grafiği.....	113
Şekil 4.35. Valencia 3 modele göre tahmin edilen ve gerçekleşen verim grafiği.....	115
Şekil 4.36. Valencia Model-4 için açıklanan yüzde değişim.....	116
Şekil 4.37. Valencia Model-4 değişken önem grafiği.....	117
Şekil 4.38. Valencia 4 modele göre tahmin edilen ve gerçekleşen verim grafiği.....	119
Şekil 4.39. Clementine Model-1 için açıklanan yüzde değişim.....	120
Şekil 4.40. Clementine Model-1 Değişken önem grafiği	121
Şekil 4.41. Clementine Model-2 için açıklanan yüzde değişim.....	122
Şekil 4.42. Clementine Model-2 değişken önem grafiği	123
Şekil 4.43. Clementine Model-3 için açıklanan yüzde değişim.....	124
Şekil 4.44. Clementine Model-3 değişken önem grafiği	125
Şekil 4.45. Clementine 3 modele göre tahmin edilen ve gerçekleşen verim grafiği	127
Şekil 4.46. Clementine Model-4 için açıklanan yüzde değişim.....	128
Şekil 4.47. Clementine Model-4 değişken önem grafiği	129
Şekil 4.48. Clementine 4 modele göre tahmin edilen ve gerçekleşen verim grafiği	130
Şekil 4.49. Satsuma Model-1 için açıklanan yüzde değişim	131
Şekil 4.50. Satsuma Model-1 değişken önem grafiği	132
Şekil 4.51. Satsuma Model-2 için açıklanan yüzde değişim	133
Şekil 4.52. Satsuma Model-2 değişken önem grafiği	134
Şekil 4.53. Satsuma Model-3 açıklanan yüzde değişim	135
Şekil 4.54. Satsuma Model-3 değişken önem grafiği	137
Şekil 4.55. Satsuma 3 modele göre tahmin edilen ve gerçekleşen verim grafiği	138
Şekil 4.56. Satsuma Model-4 için açıklanan yüzde değişim	139
Şekil 4.57. Satsuma Model-4 değişken önem grafiği	140
Şekil 4.58. Satsuma 4 modele göre tahmin edilen ve gerçekleşen verim grafiği	141
Şekil 5.1. Narenciye verim tahmin protokolü.....	149

ÇİZELGELER DİZİNİ

Çizelge 3.1. Phantom 3 Advanced İHA'nın özellikleri	26
Çizelge 3.2. MS kameranin özellikleri	28
Çizelge 3.3. Matrice 200 V2 İHA'nın özellikleri	28
Çizelge 3.4. İHA-LiDAR sisteminin özellikleri	30
Çizelge 3.5. Toprak analiz sonuçları.....	38
Çizelge 3.6. Pix4Dmapper Pro işlem ayarları.....	47
Çizelge 3.7. MS-İHA verilerinden hesaplanan bitki indeksleri.....	51
Çizelge 3.8. Hiperspektral (yersel) verilerden hesaplanan bitki indeksleri	53
Çizelge 3.9. Bağımlı ve bağımsız değişkenler	56
Çizelge 4.1. Narenciye ağaçlarının ortalama taç alanları (İHA-LiDAR)	59
Çizelge 4.2. Narenciye ağaçlarının ortalama yükseklikleri (İHA-LiDAR)	60
Çizelge 4.3. Narenciye ağaçlarının ortalama taç alanları (İHA).....	64
Çizelge 4.4. Narenciye ağaçlarının ortalama yükseklikleri (İHA)	66
Çizelge 4.5. Washington dendrometrik özelliklerinin tanımlayıcı istatistik değerleri ...	67
Çizelge 4.6. Valencia dendrometrik özelliklerinin tanımlayıcı istatistik değerleri	67
Çizelge 4.7. Clementine dendrometrik özelliklerinin tanımlayıcı istatistik değerleri	67
Çizelge 4.8. Satsuma dendrometrik özelliklerinin tanımlayıcı istatistik değerleri	68
Çizelge 4.9. Çarpıklık-basıklık değerleri ve Shapiro-Wilk normallik testi sonucu	69
Çizelge 4.10. Spearman'ın korelasyon katsayıları.....	74
Çizelge 4.11. Hiperspektral (yersel) verilerden hesaplanan ortalama bitki indeks değerleri (Washington ve Valencia).....	76
Çizelge 4.12. Hiperspektral (yersel) verilerden hesaplanan ortalama bitki indeks değerleri (Clementine ve Satsuma)	77
Çizelge 4.13. MS-İHA verilerden hesaplanan ortalama bitki indeks değerleri	78
Çizelge 4.14. Washington deneme alanı için tanımlayıcı istatistik ve test sonuçları	82
Çizelge 4.15. Washington deneme alanı Spearman'ın korelasyon analizi sonuçları	84
Çizelge 4.16. Valencia deneme alanı için tanımlayıcı istatistik ve test sonuçları	85
Çizelge 4.17. Valencia deneme alanı Spearman'ın korelasyon analizi sonuçları.....	87
Çizelge 4.18. Clementine deneme alanı için tanımlayıcı istatistik ve test sonuçları	88
Çizelge 4.19. Clementine deneme alanı Spearman'ın korelasyon analizi sonuçları	90
Çizelge 4.20. Satsuma deneme alanı için tanımlayıcı istatistik ve test sonuçları	91
Çizelge 4.21. Satsuma deneme alanı Spearman'ın korelasyon analizi sonuçları	93
Çizelge 4.22. Verim tahmin modelleri.....	95
Çizelge 4.23. Washington Model-1 karşılaştırma özeti.....	96
Çizelge 4.24. Washington Model-1 RMPRESS değerleri	97
Çizelge 4.25. Washington Model-2 karşılaştırma özeti.....	98
Çizelge 4.26. Washington Model-2 RMPRESS değerleri	99
Çizelge 4.27. Washington Model-3 karşılaştırma özeti.....	100
Çizelge 4.28. Washington Model-3 RMPRESS değerleri	101
Çizelge 4.29. Washington 3 Model için karşılaştırma sonuçları ve model eşitlikleri ..	103
Çizelge 4.30. Washington Model-4 karşılaştırma özeti.....	104
Çizelge 4.31. Washington Model-4 RMPRESS değerleri	105
Çizelge 4.32. Washington 4 model için karşılaştırma sonuçları ve model eşitlikleri...	106

Çizelge 4.34. Valencia Model-1 RMPRESS değerleri	108
Çizelge 4.35. Valencia Model-2 karşılaştırma özeti	109
Çizelge 4.36. Valencia Model-2 RMPRESS değerleri	110
Çizelge 4.37. Valencia Model-3 karşılaştırma özeti	112
Çizelge 4.38. Valencia Model-3 RMPRESS değerleri	113
Çizelge 4.39. Valencia 3 Model için karşılaştırma sonuçları ve model eşitlikleri	114
Çizelge 4.40. Valencia Model-4 karşılaştırma özeti	115
Çizelge 4.41. Valencia Model-4 RMPRESS değerleri	117
Çizelge 4.42. Valencia 4 Model için karşılaştırma sonuçları ve model eşitlikleri	118
Çizelge 4.43. Clementine Model-1 karşılaştırma özeti.....	119
Çizelge 4.45. Clementine Model-2 karşılaştırma özeti.....	121
Çizelge 4.47. Clementine Model-3 karşılaştırma özeti.....	123
Çizelge 4.49. Clementine 3 model için karşılaştırma sonuçları ve model eşitlikleri....	126
Çizelge 4.50. Clementine Model-4 karşılaştırma özeti.....	127
Çizelge 4.51. Clementine Model-4 RMPRESS değerleri.....	128
Çizelge 4.52. Clementine 4 model için karşılaştırma sonuçları ve model eşitlikleri....	130
Çizelge 4.53. Satsuma Model-1 karşılaştırma özeti.....	131
Çizelge 4.54. Satsuma Model-1 RMPRESS değerleri.....	132
Çizelge 4.55. Satsuma Model-2 karşılaştırma özeti.....	133
Çizelge 4.56. Satsuma Model-2 RMPRESS değerleri.....	134
Çizelge 4.57. Satsuma Model-3 karşılaştırma özeti.....	135
Çizelge 4.59. Satsuma 3 model için karşılaştırma sonuçları ve model eşitlikleri.....	138
Çizelge 4.60. Satsuma Model-4 karşılaştırma özeti.....	139
Çizelge 4.61. Satsuma Model-4 RMPRESS değerleri.....	140
Çizelge 4.62. Satsuma 4 model için karşılaştırma sonuçları ve model eşitlikleri.....	141
Çizelge 4.63. Tüm deneme alanları için model karşılaştırma çizelgesi.....	143

1. GİRİŞ

Citrus cinsi meyve ağaçlarından olan turunçgillerin anavatanı Çin, Güneydoğu Asya ve Hindistan olmasına rağmen son yıllarda subtropik iklimlere sahip pek çok ülkede yetiştiriciliği yapılmaktadır. Turunçgil bitkileri portakal, mandalina, limon, greylort gibi ekonomik türler olmak üzere farklı boyutlarda ve değişik şekillerde, kokulu, sulu ve farklı tatlarda meyve türlerini ve çeşitlerini içermektedir. Üretimi her geçen yıl artan turunçgillerin özellikle yüksek oranda C vitamini içermesi nedeniyle insan sağlığına önemli yararları bulunmaktadır. Turunçgiller meyve olarak tüketilmelerinin yanı sıra yoğun bir şekilde reçel yapımında ve özellikle son yıllarda kozmetik sanayisinde de kullanılmaktadırlar (Qin vd. 2016; Uysal ve Polatöz 2017; Atlı ve Söyler 2018; TEPGE 2022).

Turunçgil bitkilerinin farklı tüketim alanlarına yönelik olarak meydana gelen talep artışı, dünyada üretim alanlarının da artmasına neden olmuştur. Gıda ve Tarım Örgütü (FAO) verilerine göre dünyada 2020 yılında 8.6 milyon hektar alanda üretim gerçekleştirilmiştir. Dünyada turunçgil üretimi yapılan alanların %45'ini portakal, %35'ini mandalina, %15'ini limon ve % 4'ünü greylort oluşturmaktadır. Belirtilen yılda ülkemizde 157833 ha alanda turunçgil üretimi yapılmıştır. 2021-2022 üretim döneminde gerçekleşen 103 milyon tonluk turunçgil üretiminin %47'sini portakalın oluşturması bu ağaçların daha çok meyve suyu üretiminde kullanılmasından kaynaklanmaktadır. Dünyada en çok turunçgil ithal eden ülkeler sırasıyla Avrupa Birliği (AB) üyesi ülkeler ve Rusya olup en çok ihraç eden ülkeler ise Güney Afrika, Türkiye ve Mısır'dır (TEPGE 2022).

Türkiye'de 2021 yılında 5.4 milyon ton civarında turunçgil üretimi gerçekleştirilmiştir. Üretim alanlarımızın tamamına yakını Ege ve Akdeniz Bölgeleri'nde olup yoğun olarak Adana, Mersin, Antalya, Hatay, Muğla ve Osmaniye illerinde üretim yapılmaktadır. Türkiye toplam portakal üretiminin %84'ü, mandalina üretiminin %92'si, limon üretiminin %93'ü, greylort üretiminin ise %97'si Akdeniz Bölgesi'nde yapılmaktadır. Türkiye'de bir önceki sezona göre %31'lik bir üretim artışının görüldüğü portakalda, 2021 yılındaki 1.7 milyon tonluk üretimde %31'lik üretim oranı ile Antalya ilk sırada yer alırken bu ili Hatay, Adana, Muğla, Mersin ve Aydın illeri takip etmiştir. Bir önceki sezona göre %15'lik üretim artışının olduğu mandalina için ise 2021 yılında 1.8 milyon ton üretim gerçekleştirilmiştir. Mandalina üretiminde de portakalda olduğu gibi bölge ölçeğinde Akdeniz bölgesi ilk sırada yer alırken il ölçeğinde Hatay'ın %39'luk bir üretim payı ile ilk sırada yer aldığı görülmüştür. Bu ili sırasıyla Adana, Mersin, İzmir, Aydın ve Muğla takip etmiştir. Türkiye'de üretilen mandalina çeşitlerinin neredeyse yarısını (%44) Satsuma, %50'sini diğer ve %5'ini ise Clementine çeşitleri oluşturmuştur (TEPGE 2022).

Günümüzde tarım sektörü küresel ekonominin önemli yapı taşlarından biri durumundadır. Dünya nüfusunun hızla artması ve bu nedenle artan gıda ihtiyacı özellikle tarım sektörü üzerindeki baskının da artmasına neden olmaktadır. Son yıllarda hassas tarım olarak da bilinen ancak daha çok dijital tarım terimi olarak kullanımı yaygınlaşan sistemler, tarım sektörü üzerindeki bu baskıyı azaltmayı, çevresel etkileri en aza indirmeyi ve tarımda üretkenliği artırmayı amaçlayan ve yoğun veri kullanan yaklaşımları ortaya çıkarmıştır (Liakos vd. 2018). Bu teknolojik gelişmelere paralel olarak yeryüzü

hakkında gerçek zamanlı bilgiler temin edebilme kabiliyetinin artması bu teknolojilerin özellikle hassas tarım uygulamalarında sıkça kullanımı da beraberinde getirmiştir. Bu akıllı teknolojiler sayesinde elde edilen yüksek çözünürlüklü verilerin tarımsal uygulamalarda kullanımı bu alanlarda verilecek gerek çiftçi bazında bireysel gerekse yönetsel kararların daha hızlı, düşük maliyetli ve tahribatsız olmasına neden olacaktır (Tsouros vd. 2019).

Uydu uzaktan algılama verileri ile başta çok yıllık tarımsal ürünler olmak üzere, pek çok üretim modeli izlenebilmekte ve bu tarımsal üretim modellerine yönelik çeşitli planlamalar yapılabilmektedir. Son yıllarda özellikle yüksek çözünürlüklü verilerin kullanılması ile geniş alanlarda alan ve ürün çeşidi belirleme işlemlerinde doğruluğu yüksek sonuçlara ulaşılabilir. Örneğin, narenciye bahçelerinin Landsat ETM+ (Enhanced Thematic Mapper) uydu verileri ve hava fotoğrafları ile değerlendirildiği bir çalışmada araştırmacılar düşük çözünürlüklü uydu verileri ile yapılan sınıflandırma doğruluğunda yer gerçeklerine göre ciddi tutarsızlıkların olduğunu, hava fotoğrafları ile yapılan çalışmalarda ise yer gerçekleri arasında yüksek doğruluk oranı elde edildiğini belirtmiştir (Shrivastava ve Gebelein 2007).

Narenciye üretim alanlarında uzaktan algılama verileri ile alan, ürün ve verim tahmini modelleme çalışmalarının yapılabilmesi için, bu bitkilerin farklı gelişim devrelerindeki fizyolojik özellikleri ile spektral karakteristikleri arasındaki ilişkilerin belirlenmesi gerekmektedir (Sönmez 2004). Sönmez (2004), Washington Navel (*Citrus sinensis* (L.) Osbeck) portakal ağaçlarının toplam klorofil içerikleri ile kanopi reflektansları arasındaki ilişkilerden yararlanılarak, bitkilerdeki çeşitli biyokimyasal değişimlerin ve kanopi özelliklerinin uzaktan algılama teknikleri ile belirlenmesinde en uygun büyüme ve gelişme dönemini tespit etmeye yönelik olarak bir doktora çalışması yürütmüştür. Araştırmacı bitkinin çiçeklenme (Nisan-Mayıs), meyve tutum (Haziran-Temmuz), meyve olum (Kasım-Aralık) ve durgun (Şubat-Mart) dönem olmak üzere dört farklı fizyolojik gelişim dönemindeki enerji kullanım ilişkisini irdelemiştir. Araştırmacı bu fizyolojik gelişim dönemleri içerisinde Akdeniz bölgesinde üretimi yapılan narenciye ağaçlarında uzaktan algılamaya dayalı yapılacak çalışmalarda bitki enerji kullanımında en belirleyici dönemin meyve tutum dönemi olduğunu belirlemiştir.

Uzaktan algılama çalışmalarında sıkça kullanılan uydu verileri, tarımsal üretim alanlarının haritalanması ve izlenmesi çalışmalarında başarılı bir şekilde kullanılsa da temelde uydu görüntülerinin spektral ve konumsal çözünürlükleri düşüktür. Bu nedenle son yıllarda tarımsal araştırmalarda özellikle düşük maliyet ve yüksek esneklik kabiliyetleri ile İHA'lar sıkça kullanılmaktadır. Uydulara nazaran oldukça avantajlı olan İHA'ların en önemli dezavantajı, daha küçük kapsama alanlarına sahip olmasıdır. Özellikle 5 hektardan küçük alanlarda İHA'lar ile çalışmak daha avantajlı olabilmektedir (Matese vd. 2013). Hassas tarım uygulamaları kapsamında değerlendirilen İHA'lar ile ülkemizde de pek çok çalışma yapılmaktadır. Bu çalışmalara; İHA ile otonom uçuş yaparak alçak irtifadan ilaçlamaların yapılabilmesi (Ay ve İnce, 2015), Demir vd. (2018) tarafından gerçekleştirilen alçak irtifa görüntüleme ile tarla şartlarında farklı genotiplerdeki buğdayların bitki yüksekliklerinin belirlenmesi, İHA'dan alınan görüntülerden üretilen SYM'den otomatik narenciye ağacı bulunmasına yönelik yaklaşımlar (Ok ve Ozdarici-Ok, 2018), Sönmez vd. (2021) tarafından farklı özelliklere sahip İHA'lar ile üç farklı tarihte görüntü alımı yapılan makarnalık buğdayda bitki

boyplarının hesaplanması, İHA kullanarak çoklu çözünürlüklü segmentasyon ve yerel ekstrama algoritmaları ile zeytin ağaçlarının bazı dendrometrik bileşenlerinin belirlemesi (Çoşlu ve Sönmez 2022) ve Tunca vd. (2023) tarafından tarımsal uygulamalarda gelişmiş doğruluk için makine öğrenme tekniklerini kullanarak İHA termal sensörlerini kalibre etme örnek olarak verilebilir.

Tarımsal üretim alanlarında yetiştirilen mahsullere ilişkin izleme çalışmalarında havadan çekilen görüntüler oldukça önemlidir. Özellikle bitkilerin farklı dönemlerde farklı yansıma karakteristiği sergilediği yakın kızılötesi (NIR) bölgeden alınacak verilerden hesaplanacak olan indeksler bu kapsamda sıkça kullanılmaktadır. Bu çalışmalardan birinde Geipel vd. (2014) bitki indeksi haritaları ve detaylı üç boyutlu ürün yüzey modellerinin ürün rekolte kestiriminde kullanıldığı bir araştırmada, mısır bitkisinin erken ve orta gelişme dönemlerinde İHA ile RGB görüntüleri alınarak rekolte tahmini çalışması yapmışlardır. Bir başka çalışmada ise Fletcher vd. (2004) NDVI verileri kullanarak Texas eyaletinde üretimi yapılan stres altındaki ve sağlıklı narenciye ağaçlarının tespit edilmesine yönelik bir çalışma yürütmüşlerdir. Çalışmada tek motorlu alçak irtifa uçağı ile görünür-yakın kızılötesi bölgede çekimler yapılmış ve bu verilerden alana ait NDVI hesaplaması yapılmıştır. Araştırmacılar, NDVI verilerinin narenciye ağaçlarının stres koşullarının belirlenmesinde etkili olduğunu ifade etmişlerdir. Tarımsal uygulamalarda verim ve kalite tespiti için gerek konunun uzmanı gerekse çiftçiler tarafından arazi gözlemlerine dayalı çeşitli klasik yöntemler kullanılabilmektedir (Dorj vd. 2017).

Yapılan kaynak taramasında farklı uydu verileri ve İHA'lar kullanarak bu konuda çalışmaların yapıldığı görülmüştür (Ye vd. 2007; Mann vd. 2011; Ye ve Sakai 2012; Csillik vd. 2018; Rahman vd. 2018; Stateras ve Kalivas 2020; Johansen vd. 2020; Malo vd. 2021). Bu çalışma ise literatürde bir boşluk olarak değerlendirilen, farklı çeşitlerdeki narenciye bahçelerinde bitkinin meyve tutum ve meyve olum dönemleri dikkate alınarak yüksek çözünürlüklü algılayıcıların (Spektrometre, İHA-RGB, İHA-MS ve LiDAR) birlikte ve eş zamanlı kullanılmasıyla verim tahminlerinin geliştirilebileceği hipotezi üzerine kurgulanmıştır. Böylece bu tez çalışmasında farklı uzaktan algılama teknikleri ile farklı çeşitlerdeki narenciye ağaçlarının meyve olum dönemlerinde verim tahminlerinin gerçekleştirilmesi amaçlanmıştır. Bu maksatla verime yatmış Washington ve Valencia portakal çeşitleri ile Satsuma ve Clementine mandalina çeşitlerinin, hem İHA hem de İHA-LiDAR verilerinden üç boyutlu nokta bulutu yöntemi ile ağaç dendrometrik bileşenlerinin (nesne tabanlı görüntü analizi ile ağaç taç yapıları, taç alanları ve ağaç yükseklikleri) belirlenmesi, spektrometrik ölçümlerle elde edilen hipersektrel veriler ve İHA'ya takılan RGB ve MS kameradan alınan dört bandlı (mavi, yeşil, kırmızı ve yakın kızılötesi) verilerden yüksek çözünürlüklü ortomozaik görüntülerin üretilmesi, bitki örtüsü indekslerinin hesaplanması, ağaç gövde yüksekliği, yaprak bağıl klorofil ölçümleri ve ağaç başına ortalama verim değerlerinin yer gerçeği verisi olarak elde edilmesi, elde edilen tüm bu veri setlerinin birlikte değerlendirilerek verim ve birbirleri arasındaki ilişkilerin istatistiksel analizler ile değerlendirilmesi gerçekleştirilmiştir. Çalışma kapsamında son olarak, yapılan bu istatistiksel değerlendirme sonucunda gerçekleştirilen PLSR analizi ile dört farklı narenciye çeşidi için bitkilerin meyve olum dönemlerinde verim tahmin modelleri elde edilmiştir.

2. KAYNAK TARAMASI

Uzaktan algılama, incelenen bir nesne, yer veya olay ile ilgili verilerin bir cihaz tarafından toplanması, bu verilerin depolanması ve analiz edilmesi ile bilgi elde etme tekniğidir. Uzaktan algılamada kullanılan platforma bağlı olarak yer, uçak ve uydu tabanlı sistemler bulunmakla birlikte genellikle en yaygın olarak kullanılan platformlar uydu ve uçak tabanlı sistemlerdir (Lillesand vd. 2004; Sunar vd. 2013). Uzaktan algılama teknolojisinin tarımsal uygulamalarda kullanımı, özellikle erken uyarı sistemi görevi görebilen bir teşhis aracı olması ile alanda meydana gelebilecek sorunların daha fazla yayılmadan ve üretimi olumsuz etkilemeden önce erkenden müdahale edilmesine olanak tanımaktadır. Uzaktan algılama teknolojisindeki sensör, veri yönetimi ve veri çözümlemedeki son gelişmelerle birlikte tarımda kullanılan çeşitli uzaktan algılama seçenekleri mevcuttur. Bununla birlikte tarım sektörü, yeterlik ve uygunluk gibi bilgi boşlukları nedeniyle uzaktan algılama teknolojilerini henüz tam olarak uygulayamamaktadır (Khanal vd. 2020). Bu bölüm, uydu uzaktan algılama teknolojisinin tarımda kullanımı, hiperspektral uzaktan algılamanın tarımda kullanımı, toprak ve bitki analizleri geliştirme cihazının (SPAD) tarımda kullanımı, İHA sistemlerinin tarımda kullanımı, LiDAR sistemlerinin tarımda kullanımı ve uzaktan algılama teknolojisi ile tarım alanlarında verim tahmini alt bölümlerinden oluşmaktadır.

2.1. Uydu Uzaktan Algılama Teknolojisinin Tarımda Kullanımı

Tarım alanlarında uydu uzaktan algılama teknolojilerinin kullanımı, yetiştirilen ürünleri ve arazi koşullarını izleme ile yetiştiricilere ve yönetim kademesine karar verebilme desteği sağlamaktadır. Bu kapsamda özellikle son yıllarda verim tespiti, bitki örtüsü haritalama, arazi kullanımındaki değişim, su stresinin belirlenmesi, hastalık ve zararlıların tespiti, ürün-toprak ilişkilerini izleme, evapotranspirasyon ve su kıtlığının tahmin edilmesi hatta ürünlerin yetiştirme dönemleri boyunca tarladaki durumlarını bütünsel olarak gösteren ürün simülasyon modellerinin oluşturulması gibi çalışmalar yapılmaktadır (Jindo vd. 2021).

Öztekin vd. (2011), Landsat 7 ETM uydu verilerinden narenciye üretim ortamlarının belirlenmesine yönelik bir çalışma gerçekleştirmişlerdir. Araştırmacılar üç yıllık aralıklarla alınan Landsat 7 ETM uydu verilerinden Çukurova bölgesindeki narenciye bahçelerini belirlemişlerdir. Çalışmada uydu verilerinin yanı sıra kadastro parselleri de kullanılmıştır. Bu parseller arazi çalışması öncesinde sayısallaştırılarak üzerlerine geliştirilmiş görüntüler bindirilmiştir. Landsat 7 ETM uydu görüntüleri daha sonra kontrollü ve kontrolsüz sınıflandırma yöntemleri ile meyve bahçelerinin konumları, çeşitleri ve yaşlarının belirlenmesi için sınıflandırılmıştır. Sınıflandırılmış uydu görüntüleri doğruluk analizi kapsamında yer gerçeği verileri ile değerlendirilmiştir. Araştırmacılar tarafından elde edilen en doğru sonuç 6 sınıflı kontrolsüz sınıflandırma yönteminden elde edilmiştir. Bu çalışma ile son üç yıldaki değişimler belirlenerek narenciye dikim alanlarının tüm çalışma alanında 71.2 ha arttığı tespit edilmiştir. Araştırmacılara göre Landsat 7 ETM uydu verilerinin kullanımının narenciye üretim alanlarının belirlenmesinde ve dağılımındaki değişimlerin izlenmesinde faydalı olduğu görülse de yansıma değerlerindeki benzerlikler nedeniyle çeşit ve tür tespiti yapılamamıştır.

Torbick vd. (2017) tarafından Landsat-8 ve PALSAR-2 destekli Sentinel-1 uyduları ile çeltik tarımının izlenmesi amacıyla yürütülen çalışmada Myanmar genelinde çeltik kapsamını, mahsul takvimini, su baskınını ve mahsul yoğunluğunu haritalamak için Sentinel-1A'nın interferometrik geniş zaman serisi görüntüleri kullanılmıştır. Araştırmacıların elde ettiği bulgulara göre bu uydu verileri ile yapılan analizler sonucu elde edilen çeltik hasat alanı ile resmi istatistikler arasında uyum olduğu ve bu verilerin bulutlu alanlarda orta ölçekte çeltik üretimini değerlendirme ve izleme konusunda güçlü olduğu tespit edilmiştir.

Aguilar vd. (2021), WorldView-3 VNIR ve SWIR verileri ile nesne tabanlı sera haritalama çalışmalarında nesne tabanlı görüntü analizi (OBIA) ile VNIR ve SWIR verilerinin kapasitesini araştırmayı amaçlamışlardır. Bu kapsamda araştırmacılar tarafından geliştirilen üç strateji uygulanmıştır; (yalnızca VNIR bantlarından türetilen nesne özellikleri, yalnızca SWIR bantlarından türetilen nesne özellikleri ve hem VNIR hem de SWIR bantlarından türetilen nesne özellikleri). Araştırmacıların elde ettiği sonuçlar, öngörme gücünde SWIR bantlardan üretilen indekslerin, özellikle de normalize edilmiş fark plastik indeksinin (NDPI) ön plana çıktığını göstermiştir. Genel olarak, VNIR, SWIR ve tüm özellikler stratejileri için sırasıyla %90.85, %96.79 ve %97.38 doğruluk değerleri elde edilmiştir.

Meraj vd. (2022), uydu uzaktan algılama tabanlı makine öğrenme algoritmaları ve simülasyon modellemesi ile buğday veriminin belirlenmesine yönelik bir çalışma gerçekleştirmişlerdir. Araştırmacılar Sentinel 2 uydu görüntüleri, RF ve SVM sınıflandırıcılarını kullanarak denetimli sınıflandırma yapmışlardır. Denetimli sınıflandırma işleminin doğruluğu yer gerçeği verileri ile test edilmiştir. Araştırmacıların elde ettiği bulgulara göre RF sınıflandırıcısı SVM'ye göre daha doğru bir sonuç vermiştir. Daha sonra araştırmacılar Carnegie-Ames-Stanford Yaklaşımı modelini kullanarak verim tahminleri gerçekleştirmişlerdir. Araştırmacılara göre bu çalışmada, RF sınıflandırıcı tabanlı verim tahmininin daha doğru sonuçlar gösterdiği ve bölgesel ölçekte buğday tanesi verim tahmininin gereksinimlerini karşılayabildiği ve bu nedenle politika ve karar vermede oldukça faydalı olabileceği sonucuna varılmıştır.

Moussaid vd. (2022), uydu görüntüleri, arazi verileri ve makine öğrenme teknikleri kullanarak narenciye bahçelerinde verim tahmini çalışması gerçekleştirmişlerdir. Bu çalışmada araştırmacılar hasat döneminden önce narenciye verimini tahmin etmek için akıllı bir sistem tanımlamayı amaçlamışlardır. Çalışma kapsamında, uydu görüntülerinden çıkarılan spektral bilgilerle birleştirilmiş geçmiş yıllara ait alan verileri üzerinde eğitilmiş bir makine öğrenimi algoritması kullanılmıştır. Bu veriler 50 parselden oluşan bir meyve bahçesinden alınan 5 yıllık veriler olup iklim, sulamada kullanılan su miktarı, doz bazında gübreleme ürünleri, bitki sağlığı uygulama dozu, parsel büyüklüğü ve her parseldeki anaç tiplerini içermektedir. Ayrıca çalışmada tahmin sonuçlarını iyileştirmek için Sentinel 2 ve Landsat uydu görüntülerinden NDVI ve NDWI hesaplanmıştır. Araştırmacılar tarafından elde edilen bulgular, 0.249 (MAE-Ortalama Mutlak Hata) ve 0.084 (MSE-Ortalama Karesel Hata) değerleri ile çalışmada izlenen yaklaşımın narenciye bahçelerinde meyve verimi tahmininde iyi bir potansiyele sahip olduğunu göstermiştir.

El Hachimi vd. (2022), entansif tarımda ürünlerin su ihtiyacının tahmininde Sentinel 2 ve meteorolojik verilerin birleştirildiği bir çalışma gerçekleştirmişlerdir. Bu çalışmada araştırmacılar tarafından ürün su gereksinimlerinin tahmin edilmesi ve buna göre sulama stratejilerinin belirlenmesi amaçlanmıştır. Sentinel 2 uydu görüntüleri ürün türlerinin tespit edilip haritalanması ve NDVI verilerine dayalı basal ürün katsayısının (Kcb) tespitinde kullanılmıştır. Bitki su gereksinimlerinin tahmininde ise Gıda ve Tarım Örgütü'nün (FAO) FAO-56 modelinin ikili yaklaşımı kullanılmıştır. Ayrıca araştırmacılar SAMIR (satellite monitoring of irrigation) yazılımı ve meteorolojik verileri kullanarak da ürünlerin su ihtiyacının simülasyonunu gerçekleştirmişlerdir. Araştırmacıların elde ettiği bulgulara göre, ürünlerin su ihtiyacının Mart ve Nisan aylarında maksimum seviyede olduğu ve çoğu ürün için kritik dönemin Şubat ayından itibaren başladığı belirlenmiştir. Ayrıca çalışma sonucunda su gereksinimlerini gösteren haritalar geliştirilmiş ve ürün gelişiminin zaman içindeki değişkenliği ve tahmini su ihtiyaçları ortaya konmuştur.

Morell-Monzó vd. (2023) tarafından narenciye parsellerinin durumunun haritalanması için yüksek çözünürlüklü spektral, altimetrik ve dokusal tanımlayıcıların yeteneklerinin değerlendirilmesi amacıyla bir çalışma gerçekleştirilmiştir. Araştırmacılara göre narenciye yetiştiriciliği yapılan alanların parsel düzeyinde durumunun belirlenmesi tarımdaki politika yapıcılar için oldukça önemlidir. Bu kapsamda araştırmacılar WorldView-3 uydu verileri, hareketten yapı (SfM) ve çok yüksek çözünürlüklü hava fotoğrafları ile SVM ve RFR makine öğrenme algoritmalarını kullanmışlardır. Sınıflandırma doğruluğu üzerindeki etkiyi değerlendirmek için üç veri kaynağının kombinasyonlarını içeren farklı analizler yapılmıştır. Araştırmacıların elde ettiği bulgular, hava fotoğrafları ve WorldView-3'ün tek bir görüntü kullanarak parsel durumunu tespit etme potansiyelinin SfM verilerine göre daha yüksek olduğunu göstermiştir. Çalışmadan elde edilen diğer sonuçlara göre MS bilgiye SfM nokta bulutu verilerini eklemek sınıflandırma doğruluğunda küçük iyileştirmelere neden olmuştur. Sınıf ayrılabilirlik analizi WV-3 SWIR bantlarının 1570nm–2330nm spektrumundaki üretken parseller üzerinde daha fazla spektral ayrılabilirlik ürettikleri için terk edilmiş parselleri tespit etmedeki önemini göstermiştir. Ayrıca araştırma bulguları meyve mahsullerine özgü mekânsal dikim modellerini modelleme yetenekleri nedeniyle metre altı görüntülerden çıkarılan gri seviye eş olum matrisi (GLCM) doku özelliklerinin önemini de ortaya koymuştur.

2.2. Hiperspektral Uzaktan Algılamanın Tarımda Kullanımı

Yaşadığımız ekosistemin fonksiyonlarını, bitki büyümesini ve besin döngüsünü daha iyi kavrayabilmek için kullanılan ve bu kapsamda önemli avantajlara sahip olan hiperspektral uzaktan algılama, bitki örtüsünün türü, yaprak alan indeksi (LAI), biyokütle, klorofil ve yaprak besin konsantrasyonu hakkında değerli bilgiler sağlamaktadır. Bitki örtüsünün hiperspektral analizi, elektromanyetik spektrumdaki yüzlerce bantta spektral yansıma ölçümlerinin elde edilmesini içermektedir. Bu ölçümler, elde tutulan ve proksimal cihazlar olan spektrometreler, uçak veya uydulara yerleştirilen hiperspektral uzaktan algılama cihazları kullanılarak elde edilebilmektedir. Hiperspektral ve taşınabilir spektrometre cihazları elektromanyetik spektrumun ultraviyole, görünür ve kızılötesi bölgeleri boyunca birçok nispeten dar, bitişik ve/veya bitişik olmayan spektral dalga boylarında yansıyan veya yayılan verileri toplamaktadır.

Bu kapsamda hiperspektral sensörlerden anlamsal olarak toplanan veriler ile bitki örtüsünün tipi, miktarı ve fonksiyonel sağlığının tespiti ve bu kapsamda bitki koruma önlemlerinin zamanında ve rasyonel bir şekilde uygulanmasında kullanılabilecek önemli spektral bilgiler elde edilebilmektedir (Im ve Jensen 2008; Terentev vd. 2022).

Sankaran ve Ehsani (2011), görünür-yakın kızılötesi spektroskopi ile narenciye yeşillenme hastalığının tespitinde spektral özellik çıkarma tekniklerinin değerlendirilmesi amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar tarafından spektral yansıma bantları ve bitki örtüsü indeksleri, iki özellik çıkarma yöntemi (diskriminant analizi ve regresyon analizi) kullanılarak 350-2500 nm spektral yansıma verilerinden türetilmiştir. Spektral özelliklerin seçilmesinin ardından, özellikler, genel ve bireysel sınıf sınıflandırma doğruluklarını belirlemek için iki sınıflandırıcı, ikinci dereceden ayırım analizi (QDA) ve sınıflandırma analojilerinin yumuşak bağımsız modellemesi (SIMCA) kullanılarak değerlendirilmiştir. Sınıflandırma sonuçları, hem spektral özelliklerin, QDA tabanlı algoritma kullanılarak genel olarak iyi (>%80) hem de sağlıklı sınıf (%85'ten yüksek) sınıflandırma doğrulukları verdiğini göstermiştir. SIMCA tabanlı algoritma, seçilen spektral özellikleri kullanarak iyi bir ortalama narenciye yeşillenme sınıfı sınıflandırma doğruluğu (>%83) vermiştir. Araştırmacılara göre bu çalışma turuncgillerde yeşillenmenin saptanması için spektral özelliklerin kullanılmasının uygulanabilirliğini göstermiştir.

Sönmez vd. (2015), farklı tuzluluk seviyelerine sahip sulama sularının domatesin enerji kullanımı üzerine etkilerini belirlemek amacıyla gerçekleştirdikleri çalışmada elektromanyetik tayfın 325-1075 nm aralığında algılama yapan spektrometre ile her bir deneme konusu için spektral ölçümler gerçekleştirmişlerdir. Bu ölçüm değerlerinden farklı bitki örtüsü indeksleri de hesaplayan araştırmacılara göre yapılan istatistiksel analizlerde, tuz stresinin belirlenmesinde domates bitkisinin yansıma değerleri ile üretilen bitki indeks değerleri arasında önemli ilişkiler bulunmuştur.

Zhang vd. (2015), farklı fenolojik fazlarda elma ağacı yaprağının spektral özelliklerine dayalı olarak elma şekeri içeriğinin tahmin edilmesi amacıyla bir çalışma yürütmüşlerdir. Yaprak örneklerinin görünür ve NIR spektral yansıtması, bir Shimadzu UV-2450 spektrografi (300-900 nm, spektral çözünürlüğü 1 nm) kullanılarak ölçülmüştür. Ayrıca her yaprak örneğinin yakınında büyüyen her meyve örneğinin şeker içeriği, laboratuvar yöntemleri kullanılarak ölçülmüştür. Daha sonra iki boyutlu korelasyon spektrum analizine geçilmiş ve pertürbasyon miktarı olarak şeker içerikleri kullanılarak farklı fenolojik fazlardaki dinamik spektrumlar elde edilmiştir. Yaprak örneklerinin spektral özelliklerine ilişkin kapsamlı gözlem, hem eşzamanlı hem de eşzamansız iki boyutlu korelasyon spektrumlarının analiz edilmesiyle çok daha doğru bir şekilde gerçekleştirilmiştir. Daha sonra şeker içeriklerinin etkili spektral tepki bantları ve farklı dönemlerde meyve şeker birikimine katkı oranı incelenmiş ve her bir bandın katkı oranı, tek dönemlik ağırlıklandırma faktörü olarak kullanılarak meyve şekerine duyarlı dalga boyu bantları elde edilmiştir. Araştırmacılar tarafından son olarak meyve şekeri içeriği, farklı fenolojik fazlarda hassas bantlar kullanılarak tahmin edilmiş ve elde edilen bulgular ile bu modelin elma meyvesindeki şeker içeriğinin tahmin edilmesinde kullanılabileceği ortaya konmuştur.

Liang vd. (2018), yeni hiperspektral indeksler (İlk türev normalleştirilmiş fark nitrojen indeksi (FD-NDNI) ve birinci türev oran nitrojen bitki örtüsü indeksi (FD-SRNI)) ile rastgele orman regresyon (RFR) algoritması kullanılarak buğdaydaki yaprak azotu içeriğinin (LNC) tahmini amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar tarafından buğdayın büyüme mevsimi boyunca farklı nitrojen ve su uygulama oranları ile tarla stresi deneyleri gerçekleştirilmiş ve çeşitli işlemler altında kanopi spektrumları ve yaprak nitrojen içerikleri üzerinde 190 ölçüm toplanmıştır. Araştırmacılar tarafından elde edilen sonuçlar, yeni hiperspektral indekslerin LNC'yi tahmin etmek için en uygun hiperspektral indeksler olduğunu ve RFR algoritmasının tercih edilen modelleme yöntemi olduğunu göstermiştir.

Ta vd. (2021) tarafından elma ağacı yapraklarının klorofil içeriğinin makine öğrenme yöntemleri ile tahmin edilmesi amacıyla bir çalışma gerçekleştirilmiştir. Araştırmacılar tarafından elma ağaçlarının beş büyüme aşamasında dört farklı yaklaşım (tek değişkenli doğrusal regresyon, MLR, SVR ve RFR) değerlendirilmiştir. Çalışmada, elma yapraklarının spektral yansımaları ölçmek için 1024 spektral kanala ve 350-2500 nm spektral aralığa sahip bir spektrometre kullanılmıştır. Yaprak spektrumuna klorofil yanıt bandı esas olarak görünür ve yansıyan kızılötesi bantlarda olduğundan, analiz için öncelikle 350-1000 nm bandı kullanılmış ve spektrum 2 nm'ye yeniden örneklenmiştir. Daha sonra spektral dönüşüm, bitki örtüsü indeksleri ve üç kenar parametresi kullanılarak regresyon analizleri gerçekleştirilmiştir. Çalışmadan elde edilen bulgular, rastgele orman regresyonunun diğerlerine göre daha iyi bir tahmin sonucu verdiğini ortaya koymuştur.

Feng vd. (2022), proksimal (ASD FieldSpec 3) ve İHA tabanlı olmak üzere iki farklı hiperspektral uzaktan algılama verilerine dayalı kışlık buğdayda verim tahmininin karşılaştırılması amacıyla bir çalışma yürütmüşlerdir. Araştırmacılar tarafından kanopi yansımalarına dayalı olarak hesaplanan farklı bitki indeksleri ve kırmızı kenar parametreleri ile verimi tahmin etmek için PLSR ve yapay sinir ağı (YSA) yöntemleri kullanılmıştır. Çalışmadan elde edilen sonuçlara göre, PLSR yöntemi kullanılarak oluşturulan verim tahmin modeli daha iyi bir tahmin etkisine sahip olup, PLSR ve YSA yöntemleri kullanılarak verim tahmininin doğruluğu daha da artırılabilir. Ayrıca bulgular, proksimal hiperspektral sensörler kullanılarak elde edilen verim tahmin modelinin, İHA hiperspektral uzaktan algılama verileri kullanılarak elde edilen modelden daha yüksek bir uyum ve doğruluğa sahip olduğunu göstermiştir. Araştırmacılara göre bu çalışma, vejetasyon indekslerinin ve kırmızı kenar parametrelerinin bir kombinasyonunun kullanılmasının, tek başına bitki indekslerinin kullanımına kıyasla daha iyi bir verim tahmini sağladığını göstermiştir.

Terentev vd. (2023) tarafından hiperspektral uzaktan algılama ile erken dönemde buğday yaprak pası algılama olasılığını belirlemeye yönelik olarak bir çalışma gerçekleştirilmiştir. Araştırmacılar çalışma kapsamında öncelikle hiperspektral uzaktan algılama verilerini işleyerek analize hazır hale getirmişlerdir. Daha sonra buğday yaprağı biyokimyasal profilini kromatografik ve spektrofotometrik yöntemlerle analiz etmişlerdir. Son olarak araştırmacılar hiperspektral uzaktan algılama verileri ile buğday yaprakları, biyokimyasal profil analizi sonuçları arasındaki olası ilişkiyi ortaya koymuşlardır. Çalışmadan elde edilen bulgulara göre VIS-NIR spektrometri veri analizi, hiperspektral uzaktan algılama verileri ile yüksek bir korelasyon göstermiş ve hastalık

tanımlaması için en önemli dalga boyu bantları (502, 466, 598, 718, 534, 766, 694, 650, 866, 602, 858 nm) ortaya konmuştur. Ayrıca araştırmacılar SVM kullanarak dördüncü günde %97-100'lük erken hastalık saptama doğruluğunu elde etmişlerdir.

2.3. SPAD Cihazının Tarımda Kullanımı

Klorofil, bitkilere yeşil karakteri sağlayan ve ışığı absorbe ederek biyokimyasal enerji üretilip bu sayede fotosentetik aktivitede benzersiz rol oynayan önemli bir pigmenttir (Porcar-Castell vd. 2014; Croft vd. 2017). Klorofil içeriği yaprağın fotosentetik kapasitesinin önemli bir göstergesi ve aynı zamanda bitkilerin nitrojen besin durumunu karakterize etmek için önemli bir indekstir. Yaprak bağıl klorofil içeriği, bitki fizyolojik durumunun anlaşılmasını geliştirmek için oldukça önemli olup bu kapsamda tahribatsız ölçümler yapılabilen SPAD cihazları sıkça kullanılmaktadır (Ling vd. 2011; Zhang vd. 2022; Wu vd. 2023).

Monostori vd. (2016) tarafından SPAD değerindeki genetik ve çevresel varyasyonun değerlendirilmesi ve SPAD değeri ile dane verimi arasındaki ilişkiyi belirlemek amacıyla yürütülen çalışmada, üç hasat sezonunda tarla denemeleri yapılmış ve kırk kışlık buğday çeşidi iki nitrojen seviyesinde test edilmiştir. Araştırmacılar, her ne kadar çeşitlerden etkilenmiş olsa da dane verimi ve SPAD değerleri arasında önemli seviyede güçlü ve pozitif yönlü korelasyonlar bulmuşlardır. Ayrıca çalışmadan elde edilen bulgular, çeşitlere özgü SPAD değerinin buğdaydaki nihai verimin daha doğru bir şekilde tahmin edilmesini sağlayabileceğini göstermiştir.

Jiang vd. (2017), domates bitkisinin yaprak klorofil içeriği ile SPAD klorofilmetre cihazından alınan bağıl klorofil içeriği arasındaki ilişkiyi araştırmak amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar bitkinin farklı dönemlerinde yapraklarını inceleyerek en uygun modeli elde edebilmek için istatistiksel analizler uygulamışlardır. Sonuçlar, domates yapraklarında SPAD değeri ile klorofil a, klorofil b içeriği ve toplam klorofil içeriği arasındaki korelasyonun önemli ölçüde ilişkili olduğunu göstermiştir. Araştırmacılara göre bu sonuçlar, SPAD-502'nin domatesteki yaprak klorofil içeriğinin hızlı ve tahribatsız tahmininde kullanılan etkili bir araç olabileceğini kanıtlamıştır.

Wang vd. (2018), alçak irtifa uzaktan algılama ve biyo-sensörlere dayalı olarak narenciye bahçelerinde klorofil içeriğinin ve dağılımının hızlı tespitine yönelik bir çalışma gerçekleştirmişlerdir. Araştırmacılar Multiplex 3.6 sensörüne dayalı yaprakların ve kanopinin flüoresan değerlerini, FieldSpec4 spektrometresine dayalı kanopi hiperspektral yansıma verilerini ve alçak irtifa MS uzaktan algılamaya dayalı spektral yansıma değerlerini toplayıp analiz etmişlerdir. Ayrıca çalışma kapsamında yaprak SPAD değeri ile oran bitki örtüsü indeksi ve NDVI arasındaki ilişkiler de analiz edilmiştir. Çalışmada narenciye ağaçlarının yaprak SPAD değeri tahmin modeli tek değişkenli, MLR ve PLSR yöntemleri ile oluşturulmuştur. Meyve bahçesindeki spektral yansıma dayalı bağıl kanopi klorofil içeriğinin değişken dağılım haritaları otomatik olarak oluşturulmuştur. Elde edilen bulgular farklı uzaktan algılama teknikleri ile elde edilen veriler ile SPAD değerleri arasındaki korelasyonların oldukça anlamlı olduğunu göstermiştir.

Glenn ve Tabb (2019) tarafından turuncgil ve elma bitkisinde özel bir NDVI sensörü, RGB ve NIR bantlarının doğrudan ölçümü ile karşılaştırıldığında, düşük maliyetli web kameraları tarafından birleştirilmiş NIR ve görünür algılamayı kullanan teknikleri değerlendirmek amacıyla bir çalışma yürütülmüştür. Ayrıca araştırmacılar bu bitkilerdeki stresi tahmin etmek ve NDVI'nin doğruluğunu değerlendirmek amacıyla SPAD değerlerini kullanmışlardır. Araştırmacılara göre bulgular NDVI'nin klorofildeki farklılıklarla sonuçlanan stresle ilgili değişikliklerin kullanışlı bir ölçüsü olduğunu ve bu klorofil değişikliklerinin SPAD teknolojisi ile de ölçülebileceğini göstermiştir.

Aparicio-Durán vd. (2021), narenciyede Huanglongbing hastalığına toleransı olduğu bildirilen üç yeni narenciye anacının su stresi uygulamaları altında davranışını yaygın bir ticari narenciye anacı ile karşılaştırarak değerlendirmek amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar çalışma kapsamında SPAD değerleri, boydaki büyüme, bağıl büyüme hızı, biyokütle (taze ve kuru ağırlık) ve bitki su durumu değerlendirilmiştir. SPAD değerleri her 10 günde bir olmak üzere SPAD klorofilmetre cihazı kullanılarak alınmıştır. Çalışmanın SPAD değerleri ile ilgili bulgularına göre yaprakların bağıl klorofil değerlerinin deneme süresi boyunca her anaç için farklı olduğu tespit edilmiştir.

Wu vd. (2023), buğday bitkisindeki bağıl klorofil içeriğinin çok zamanlı İHA verileri ile tahminine yönelik bir çalışma gerçekleştirmişlerdir. Araştırmacılar çalışmada 26 MS bitki indeksi oluşturmuşlar, elde taşınan bir klorofil ölçer kullanarak eş zamanlı olarak buğdayın SPAD değerlerini elde etmişler ve içlerinde PLSR'nin de yer aldığı dört makine öğrenme algoritması kullanmışlardır. Model değerlendirme için ise R^2 , RMSE ve MAPE kriterlerini kullanmışlardır. Araştırma bulguları buğdayın büyüme aşamalarının farklı dönemleri için optimum SPAD değeri tahmin modellerinin farklı olduğunu, PLSR'nin başaklanmadan sonraki 7. ve 14. günlerde en uygun tahmin modeli olduğunu, RF'nin ise başaklanmadan 21 gün sonra en uygun tahmin modeli olduğunu göstermiştir. Çalışmada SPAD değerlerini tahmininde en yüksek doğruluk başaklanmadan sonraki 14. günde PLSR modeli kullanılarak elde edilmiştir.

2.4. İHA Sistemlerinin Tarımda Kullanımı

İHA sistemleri, İHA, kontrol istasyonu, komuta ve kontrol veri bağı, kalkış ve iniş sistemi gibi uçuşun sağlanması için olması gereken birbirinden ayrı sistem elemanlarının tamamını kapsamaktadır (SHGM 2016). Kanat yapısı bakımından genellikle sabit ve döner kanatlı olarak ikiye ayrılan İHA'ların eğlence sektöründen askeri amaçlarla kullanımına kadar pek çok uygulama alanı bulunmaktadır. Son yıllarda gelişmiş teknolojilerin İHA platformlarında kullanımı, bu araçların hassas tarım uygulamaları kapsamında kullanımını da artırmıştır. Drone olarak da adlandırılan İHA'ların tarımda kullanımını sınırlayan bazı kısıtlama ve zorluklar olsa da bu araçlar girdi ve maliyetleri en aza indirirken üretimi artırma yeteneğine sahiptir. İHA'lar yüksek kalite, aralık ve çözünürlük ile hızlı veri toplama, 3B kanopi yüksekliği ve ortofoto bilgilerini birleştirme, SfM ile nokta bulutlarından kanopi yükseklik modelleri oluşturma, çok açılı verileri yakalama (özellikle anlık fotoğraf kameralarından) ve aynı anda birden fazla sensörü çalıştırma kapasitesi ile diğer uzaktan algılama platformlarına göre daha avantajlıdır. İHA'lar bu avantajları ile tarım sektöründe çalışan tüm paydaşlara yüksek kaliteli görüntü ve veriler sağlayabilmektedir. Hassas tarım kapsamında İHA'lar ile haritalama, verim

tahmini, bitki ve toprak sağlığının tespiti, sulama yönetimi, tohum ekimi, biyokütle tahmini, gübre uygulamaları, püskürtme işlemleri, yabancı ot yönetimi ve meteorolojik analizler gibi pek çok tarımsal uygulamada kullanılmaktadır (Delavarpour vd. 2021).

Csillik vd. (2018), İHA görüntüleri ve konvolüsyonel sinir ağları (CNN) kullanarak narenciye ağaçlarının tanımlanması amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar tarafından öncelikle İHA görüntülerinden narenciye ağaçları ve diğer ağaçlar tespit edilmiş ve ardından basit doğrusal yinelemeli kümeleme (SLIC) algoritmasından türetilen süper pikselleri kullanan bir sınıflandırma iyileştirmesi gerçekleştirilmiştir. Araştırmacılara göre çalışma alanı nispeten karmaşık bir tarımsal ortam olmasına rağmen çalışmadan yüksek doğruluk elde edilmiştir.

Garza vd. (2020), gerçek renkli İHA görüntüleri ile narenciye ağacı sağlığının belirlenmesine yönelik bir çalışma yürütmüşlerdir. Çalışmada Huanglongbing (HLB), Phytophthora ayak ve kök çürüklüğü narenciye üretimini ve karlılığını etkileyen hastalıklar olduğu ve bu hastalıklarla ilişkili belirtiler ve fizyolojik değişikliklerin, pahalı ve zaman alan saha ölçümleriyle teşhis edilebileceği belirtilmiştir. Araştırmacılar RGB görüntüleme kullanan İHA'ların bitki hastalıklarının teşhisinde ekonomik bir alternatif olabileceğini belirterek narenciye sağlığını değerlendirmek için RGB kameralı bir İHA kullanan bir yöntem geliştirmişlerdir. İHA uçuşları Nisan 2018'de bu hastalıklar ile enfekte olmuş bir greyfurt tarlasında gerçekleştirilmiştir. Araştırma bulguları, üçgen yeşillik indeksi (TGI) görüntüleri, ağaç beslenme durumu, yaprak alanı, SPAD, ayak çürüklüğü hastalığı şiddeti ve HLB gibi saha ölçümleri ile ilişkilendirilmiştir.

Su vd. (2021), buğday tarlalarındaki karaçimen otunu spektral olarak analiz etmek ve haritalamak amacıyla İHA, MS görüntü ve makine öğrenimi tekniklerini entegre eden bir çalışma gerçekleştirmişlerdir. Çalışmada kullanılan İHA, RedEdge kamera takılan DJI S-1000 olup, uçuşlar 20 m yükseklikten gerçekleştirilmiştir. Elde edilen MS görüntülerin mekânsal çözünürlüğü 1.16 cm'dir. Araştırmacılar çalışmada, yaygın olarak kullanılan 18 spektral indeks üretmişler ve model basitliği ile deneysel yorumlanabilirliği geliştirmek için çeşitli özellik seçim algoritmaları kullanmışlardır. Sınıflandırma algoritması olarak Bayesian hiperparametre optimizasyonlu random forest sınıflandırıcısı tercih edilmiştir. Araştırmacılar tarafından elde edilen sonuçlar, geliştirilen sistem tarafından iyi bir sonuç (%93.8, %93.8, %93.0 ortalama kesinlik, hatırlama ve doğruluk) elde edildiğini ve en ayırt edici spektral indeksin üçgen yeşillik indeksi (TGI) olduğunu göstermiştir.

Dönmez vd. (2021), İHA görüntülerini kullanarak bilgisayarla görü tabanlı narenciye ağacı tespiti çalışmalarında yüksek çözünürlüklü İHA görüntülerine dayalı olarak narenciye ağaçlarını tespit etmek ve saymak için bağlı bileşenler etiketleme (CCL) algoritmasını kullanmışlardır. Araştırmacılar çalışmayı MS ve 5 bantlı ortofoto görüntüler üzerinden yürütmüşlerdir. Çalışma sonuçlarına göre teterojen bir meyve bahçesinde coğrafi konum belirleme ve ağaçları tek tek sayma için önemli ölçüde performans gösterdiği tespit edilmiştir. Ayrıca önerilen yöntemin ağaç sayısını (narenciye) tahmin etmek için tatmin edici bir performans sağladığı sonucuna varılmıştır. Bu sonuçlara göre araştırmacılar tarafından önerilen yöntemin, karmaşık tarım bölgelerinde meyve bahçesi ağaçlarını tespit etmek için geleneksel ağaç tespit tekniklerinin yerini alabileceği değerlendirilmiştir.

Qi vd. (2021), İHA tabanlı nokta bulutu ve derin öğrenme ile narenciye ağaçlarının kanopi hacminin çıkarımı çalışmasını gerçekleştirmişlerdir. Araştırmacılar çalışmada, narenciye ağaç kanopilerini segmentlere ayırmak için nokta bulutu derin öğrenme algoritması ile hacim hesaplama algoritmasını birleştirmişlerdir. Çalışmada üç derin öğrenme modelinin (PointNet++, MinkowskiNet ve FPConv), ağaçlar ve zemin üzerindeki segmentasyon etkileri karşılaştırılmıştır. Ayrıca üç hacim algoritması (dilimlere göre dışbükey gövde, vokselle tabanlı yöntem ve 3B dışbükey gövde) ile ağaçların hacimleri hesaplanmıştır. Araştırmacıların elde ettiği bulgular, MinkowskiNet modelinin genel doğruluğunun (%94.57) diğer iki modelden daha yüksek olduğunu ve hacim hesabında ise 3B dışbükey gövde algoritmasının en yüksek R^2 (0.821) ve en düşük kök ortalama karesel hata (RMSE) (0.318 m³) değerlerini aldığını göstermektedir.

Çoşlu ve Sönmez (2022), İHA kullanarak çoklu çözünürlüklü segmentasyon ve yerel ekstrama algoritmaları ile zeytin ağaçlarının bazı dendrometrik bileşenlerini belirlemek amacıyla bir çalışma gerçekleştirmişlerdir. Çalışmada, İHA ile otonom uçuş gerçekleştirilerek alanın dijital görüntüleri toplanmış ve bu görüntüler işlenerek ortomozaik görüntü, SYM ve SAM üretilmiştir. Zeytin ağaçlarının taç sınırlarını, ağaç sayısını ve ağaç yüksekliklerini yarı otomatik olarak hesaplayabilmek için DSM ve DTM kullanılarak ağaçların KYM'leri oluşturulmuştur. Ayrıca çalışmada yersel ölçümler yapılarak alandaki zeytin ağaçlarının sayısı ve yükseklikleri; İHA'dan elde edilen ortomozaik görüntü üzerinden manuel dijitalleştirme ile de ağaç taç sınırları belirlenmiştir. Araştırmadan elde edilen bulgular ile yersel ölçümlerin değerlendirilmesi sonucunda İHA ile zeytin ağacının bazı dendrometrik bileşenlerinin oldukça başarılı bir şekilde belirlenebileceği ortaya konmuştur.

Costa vd. (2022), MS-İHA görüntüleri ve yapay zeka kullanarak narenciye ağaçlarının yaprak besin konsantrasyonlarını belirlemek amacıyla yeni bir metodoloji önermişlerdir. Çalışma dört farklı deneme alanında, Hamlin ve Valencia portakallarında yürütülmüştür. Alandan toplanan yaprak örnekleri geleneksel kimyasal yöntemler kullanılarak makro ve mikro besin konsantrasyonunu belirlemek için laboratuvar ortamına analiz için gönderilmiştir. MS görüntüleri beş farklı bantta (R, G, B, RedEdge ve NIR) MS kamerası ile donatılmış bir İHA kullanılarak elde edilmiştir. Tahmin modelinin oluşturulmasında gradyan artırma regresyon (GBR) ağacı kullanılmış ve model ortalama mutlak yüzde hata (MAPE), RMSE, MAPE-varyans katsayısı oranı ve fark grafiği dahil olmak üzere çeşitli kriterler kullanılarak değerlendirilmiştir. Araştırmacılar tarafından elde edilen bulgulara göre bu yeni model makro besinleri yüksek, mikro besinleri ise orta düzeyde doğrulukla belirleyebilmiştir.

Saad El Imanni vd. (2023) tarafından makine öğrenimi ve Google Earth Engine (GEE) ile narenciye bahçelerinde yabancı otları tespit edebilmek amacıyla bir çalışma yürütülmüştür. Araştırmacılar tarafından MS-İHA bantları (kırmızı, yeşil, mavi, yakın kızılötesi ve kırmızı kenar) SYM, SAM ve bu verilerden üretilen KYM ile RF ve KNN makine öğrenimi algoritmaları kullanılmıştır. Araştırmacıların elde ettiği bulgulara göre spektral bantlar ve KYM kombinasyonu narenciye ağaçları ile yabancı otları %96.87 genel doğrulukla sınıflandırabilmiş ve KYM'nin veri setine eklenmesi %13,36 (KNN) ve %1,79 (RF) oranlarında sınıflandırmaya katkı sağlamıştır. Ayrıca sonuçlar RF algoritmasının KNN'e göre daha iyi performans gösterdiğini ortaya koyarken İHA

görüntülerinin GEE'ye entegrasyonu, İHA görüntüleri işlemenin otomasyonu açısından oldukça verimli olduğunu göstermiştir.

2.5. LiDAR Sistemlerinin Tarımda Kullanımı

Işık koşullarından etkilenmeyen LiDAR cihazları üzerinde bulunan sensörlerden hedef nesnelere gönderilen darbeli ışık dalgalarının katettiği mesafe, sensöre dönme süresi ile ölçülmektedir (Debnath vd. 2023). LiDAR sistemleri havadan ve karadan olmak üzere ikiye ayrılmaktadır. Hava LiDAR sistemlerinin çoğunluğu LiDAR sensörleri, veri depolama cihazları, yerleşik bir bilgisayar, GPS ve IMU'dan oluşmaktadır (Lohani ve Ghosh 2017). Bunlardan GPS, hava aracının konumunu belirlerken IMU ise sensörün tam olarak yönünü kaydetmektedir. Karasal LiDAR sistemleri hava LiDAR sistemleri ile aynı çalışma prensibine sahip olup hava LiDAR sistemlerinin ulaşamadığı ağaç kanopileri gibi alanlarda veri elde etmede önemli avantajları bulunmaktadır. LiDAR sistemleri tahribatsız veri temin edebilme gibi kabiliyetleri nedeniyle son yıllarda tarım sektöründe de sıkça kullanılmaktadır. Bu sistemlerin tarımda kullanımına biyokütle tahmini, kanopi yapısının belirlenmesi, 3B modelleme, hasar tespiti ve verim tahmini çalışmaları örnek olarak verilebilmektedir (Debnath vd. 2023).

Wang vd. (2008), hem dikey kanopi yapı analizi hem de 3B tek ağaç modellemesi için LiDAR nokta bulutu verisi kullanmışlardır. Araştırmacılar tüm alanı, bir raster ağı ile küçük çalışma hücrelerine böldükten sonra her hücre için orijinal LiDAR ham nokta bulutundan nokta yükseklikleri, yer nesnelerinin mutlak yüksekliklerini temsil eden normalize edilmiş bir nokta bulutu oluşturmuşlardır. Ana ağaç kanopi katmanları ve katmanların yükseklik aralıkları, normalize edilmiş ham noktaların yükseklik dağılımı olasılığının istatistiksel analizine göre tespit edilmiştir. Çalışma kapsamında ağaçların 3B modellemesi için, ağaçlar tek tek algılanmış ve bu yalnızca üst kanopi katmanından değil, aynı zamanda alt kanopi katmanından da belirlenmiştir. Normalize edilmiş noktalar, yerel bir voksel uzayına yeniden örneklenerek voksel boşluğuna göre farklı yükseklik seviyelerinde bir dizi yatay 2B projeksiyon görüntüsü oluşturulmuştur. Daha sonra projeksiyon görüntülerinden ağaç taç bölgeleri tespit edilmiştir. Araştırmacılar son olarak, çıkarılan bireysel ağaçların 3B ağaç taç modellerini yeniden oluşturmuşlardır. Araştırmacılar tarafından bireysel ağaç taçlarının 3B modelleri üzerinde daha fazla analiz yapılarak, farklı yükseklik seviyelerinde taç yükseklik aralığı, taç hacmi ve taç konturları gibi önemli parametreler elde edilebileceği değerlendirilmiştir.

Rosell vd. (2009), bitkilerin 3B yapısal özelliklerini elde etmek için tarımda 2B LiDAR tarayıcının kullanımına yönelik bir çalışma yapmışlardır. Araştırmacılar narenciye bahçelerinde ve üzüm bağlarında yürütülen bu çalışma ile LiDAR sisteminin çoğu tarımsal uygulama için bitkilerin geometrik özelliklerini yeterli hassasiyetle ölçebildiği sonucuna varmışlardır. Araştırmacılara göre geliştirilen sistem, yükseklik, genişlik, hacim, yaprak alan indeksi ve yaprak alan yoğunluğu gibi büyük miktarda bitki bilgisinin elde edilebildiği, mahsullerin 3B dijitalleştirilmiş görüntülerini elde etmeyi mümkün kılmıştır. Bu çalışma ile 3B dijital bitki yapısının fiziksel boyutları, şekli ve küresel görünümü ile gerçek bitkiler arasında büyük bir uyum olduğu ve geliştirilen sistemden elde edilen 3B ağaç modelinin gerçek yapıya göre tutarlılığı ortaya konmuştur. Araştırmacılar tarafından elde edilen bulgulara göre seçilen bazı ağaçlar için manuel

olarak ölçülen hacimler ile 3B LiDAR modellerinden elde edilenler arasında yüksek bir ilişki (0.976) bulunduğu tespit edilmiştir.

Sanz-Cortiella vd. (2011), meyve ağacı yaprak alanının tahmini için yenilikçi LiDAR 3B dinamik ölçüm sistemi çalışmalarında, iki adet 3B nokta bulutu elde edebilmek amacıyla ağaçları iki zıt yönden taramışlardır. Çalışma LiDAR sensör lazer ışınının bitki örtüsü üzerindeki etki sayısı ile ağaç yaprak alanı arasında doğrusal bir ilişkinin varlığı hipotezine dayanmaktadır. Bir süs ağacı ve daha sonra bir armut ağacı bahçesinde laboratuvar koşullarında gerçekleştirilen testler, araştırmacılara göre sunulan ölçüm sisteminin doğru çalıştığını göstermektedir. Hem laboratuvar hem arazi testlerinden elde edilen sonuçlar, araştırmacıların hipotezini doğrulamakla birlikte bu, araştırmacılara göre tarım alanında ve daha spesifik olarak hassas meyve yetiştiriciliğinde ağaç mahsullerinin geometrik karakterizasyonuna odaklanan yeni araştırmalara kapı açacağı değerlendirilmektedir.

Sans vd. (2013), 3B LiDAR sistemi ile meyve bahçeleri ve üzüm bağlarında ağaç sıralı LiDAR hacmi ve yaprak alan yoğunluğu arasındaki ilişkiyi belirlemek amacıyla elma, armut ve üzüm bağlarında geometrik karakterizasyon için iki boyutlu yersel lazer tarayıcı tabanlı 3B LiDAR dinamik ölçüm sistemi kullanmışlardır. Çalışma alanındaki ağaçlar LiDAR sistemi ile zıt yönlerden taranarak iki adet 3B nokta bulutu elde edilmiştir. Çalışmadaki hipotez bu iki değişken arasında doğrusal olmayan bir ilişki olabileceğine dayanmaktadır. Araştırmacılar tarafından 35 bitki üzerinde yapılan bu çalışmada iyi bir logaritmik uyum olduğu vurgulanmaktadır. Üç üründe de yapraklar ve bu yaprakların kapladığı alan arasındaki ışık rekabeti benzer bir model ortaya koymaktadır. Araştırmacılarca yürütülen bu çalışmanın sonuçlarına göre yaprak alan yoğunluğunun ağaç sıralı LiDAR hacminden belirlenebileceği anlaşılmaktadır.

Colaço vd. (2017), manuel ve LiDAR tabanlı yöntemlerle portakal ağacı kanopi hacim tahmini çalışmalarında, manuel yöntemlere ve LiDAR sensörüne dayalı olarak farklı türdeki portakal ağaçlarının kanopi hacim tahminlerini karşılaştırmayı amaçlamışlardır. Bir lazer tarama sistemi kullanılarak 25 ayrı ağaç için bir nokta bulutu oluşturularak dışbükey gövde ve alfa şekilli yüzey rekonstrüksiyon algoritmaları test edilmiştir. LiDAR'dan türetilen modeller, portakal ağaçlarını geleneksel yöntemlerden daha doğru bir şekilde temsil edebildiği belirlenirken sonuçların mevcut manuel yöntemden önemli ölçüde farklı olduğu görülmüştür. Ayrıca farklı 3B modelleme algoritmaları, farklı kanopi hacmi tahminleri ile sonuçlandığından araştırmacılar tarafından yeni bir standart yöntemin geliştirilmesi ve oluşturulması önerilmiştir.

Meng vd. (2019), beyaz huş ağacının (*Betula platyphylla*) biyokütlesinin yersel 3B lazer tarama sistemine dayalı olarak modellenmesi çalışmalarında ağaç yüksekliği, gövde yüksekliği ve biyokütle ölçümü gerçekleştirmişlerdir. Araştırmacılar tarafından bu kapsamda gövde hacmi, taç hacmi ve taç yüzey alanı gibi parametreleri elde edebilmek için bir 3B nokta bulutu modeli oluşturulmuştur. Ardından, yersel 3B lazer tarama sistemi tabanlı parametreler geleneksel sabit allometrik oranlı (CAR) biyokütle modellerine dahil edilerek modifiye edilmiş modellerin hassasiyeti, geleneksel CAR modelleriyle karşılaştırılmıştır. Araştırmacıların bulguları, gövde hacmi, taç hacmi ve biyokütle modellerinin belirleme katsayılarının optimal olduğunu (toplam, gövde, dal ve yaprak biyokütle modellerinin R^2 'si sırasıyla 0.990, 0.966, 0.960 ve 0.936); gövde hacmi, taç

hacmi ve değiştirilmiş biyokütle modelleri için hataların en küçük değerleri verdiğini göstermiştir.

Mendez vd. (2019) tarafından Cordoba'da (Güney İspanya) 24 (12'si budanmış ve 12'si budanmamış) 'Salustiana' çeşidi portakal ağacı (*Citrus sinensis* L. Osbeck) üzerinde 3B lazer tarama ile meyvelerin sayısı ve boyutunun tahminine yönelik bir çalışma yapılmıştır. Araştırmacılar tarafından hem hasat büyüklüğü hem de meyve sayısı ve meyvelerin birim ağırlıkları ile çapları belirlenmiştir (N=160). Portakal ağaçları ayrıca bir K-ortalama algoritması kullanılarak daha sonraki segmentasyonları ve meyve tespiti için renk yakalama ile 3B modellenmiştir. Araştırmadan elde edilen bulgulara göre budanan ağaçlarda gerçek ve modellenen meyve sayısı arasında ($R^2=0.63$, $p=0.01$) önemli bir regresyon elde edilirken budama yapılmayanlarda ($p=0.18$) yaprak tıkanıklık sorunu nedeniyle tam tersi durum meydana gelmiştir. Kullanılan algoritma ile oranlanan ortalama çaplar (72.15 ± 22.62 mm), meyvelerde ölçülenlerle (72.68 ± 5.728 mm) önemli farklılıklar göstermemiştir ($p=0.35$). Araştırmacılar çalışma sonucunda, özellikle 3B LiDAR taramalarının kullanımının zaman alıcı olmasına rağmen bu araştırmada elde edilen hasat boyutu tahmininin çok doğru olduğunu belirtmişlerdir.

Hobart vd. (2020) tarafından bir elma bahçesinde İHA fotogrametrisi kullanılarak ağaç yüksekliklerinin belirlenmesi amacıyla bir çalışma gerçekleştirilmiştir. Araştırmacılar ağaç yüksekliklerini hesaplamak ve modellemek için SfM yöntemi ve 3B nokta bulutu verilerini kullanmışlardır. Ortaya çıkan yükseklik modelleri, referans olarak alınan LiDAR verileri ile karşılaştırılmıştır. Araştırmacılar tarafından çalışmadan elde edilen sonuçlar referans olarak alınan bu LiDAR verileri ile karşılaştırıldığında her iki yılda da oldukça yüksek korelasyonlar ($R^2=0.83$ ve $R^2=0.88$) tespit edilmiştir.

Zhang vd. (2020), yersel lazer tarama ve sırt çantasına monte LiDAR'dan elma ağacı dallarıyla ilgili topolojik ve yapısal bilgi çıkarma çalışmalarında bir yöntem sunarak bu yöntemin meyve ağacı dallarının incelenmesinde uygulanabilirliğini ortaya koymuşlardır. Araştırma sonuçları, yersel lazer tarama bazında, dal uzunluğu ve sayısındaki bağıl hataların birinci derece dallar için %7,43 ve %12, ikinci derece dallar için %16,75 ve %9,67 olduğunu gösterirken toplam dal bilgilerinin doğruluğu %15.34 ve %2.89'a ulaşabilmiştir. Araştırmacılar çalışma kapsamında ayrıca, 10 örnek ağacın saha ölçümleri ve nicel yapısal model (QSM) değerlendirmelerini karşılaştırarak sırt çantası-LiDAR'ın potansiyelini değerlendirmişlerdir. Bu karşılaştırma, birinci dereceden dal bilgilerine ek olarak, dalların diğer sıralarına ait bilgilerin de değişen derecelerde eksik tahmin edildiğini göstermiştir. Birinci mertebeden dalların uzunluğunun ve sayısının RMSE değeri, 3.91 ve 1.30 m, bağıl kök ortalama kare hatası (NRMSE) sırasıyla %14.62 ve %11.96 olarak bulunmuştur. Araştırmacılara göre bu çalışma, hassas meyve ağacı budama, kantitatif verim tahmini, meyve ağacı büyümesinin değerlendirilmesi ve meyve bahçelerinin modern yönetimini desteklemek için kullanılabilen meyve ağacı dallarının ilk otomatik sınıflandırmasını temsil etmektedir.

Chen vd. (2020), havadan LiDAR verilerine dayalı bireysel ağaç konumu çıkarımı ve bu ağaçların yapısal parametrelerini belirleme çalışmalarında dört farklı algoritmanın performans değerlendirmesini yaparak bir karşılaştırma gerçekleştirmişlerdir. Araştırmacılar çalışmada öncelikle yer ve kanopi noktalarını ayırarak sayısal arazi modeli (SAM) ve sayısal yüzey modeli (SYM) oluşturmuşlardır. Daha sonra SYM ve SAM

kullanarak bir KYM elde etmişlerdir. Ardından dört algoritma (nokta bulutu tabanlı yerel maksimum algoritma, KYM tabanlı yerel maksimum algoritması, havza algoritması ve şablon eşleme algoritması), bireysel ağaçların yapısal parametrelerini çıkarmak için karşılaştırmalı olarak kullanılmıştır. Araştırmacılar tarafından elde edilen sonuçlar, iki yerel maksimum algoritmanın ağaç tepesini etkili bir şekilde algılayabildiğini; havza algoritmasının her bir ağaç yüksekliğini doğru bir şekilde çıkarabildiğini ve ağaç taç kenarını belirleyebildiğini; şablon eşleştirme algoritmasının ise doğru taç genişliğini elde etmek için başarılı sonuçlar verdiğini göstermiştir.

Murcia vd. (2021), bir insansız kara aracı (UGV) ve LiDAR'ı entegre ederek 3B meyve bahçesi haritalaması için düşük maliyetli bir sistem geliştirmek amacıyla bir çalışma yürütmüşlerdir. Veri toplama için algılama sistemi, mekanik, elektronik, kontrol ve yazılım katmanlarındaki tasarımdan geliştirilmiştir. Doğrulama testi, bir narenciye bahçesi üzerinde, oluşturulan nokta bulutundan elde edilen uzaklık ve gölgelik yükseklik değerlerinin bir fotogrametri yöntemiyle elde edilen referans değerlerle karşılaştırılmasıyla gerçekleştirilmiştir. Araştırmacılar tarafından Python destekli bir araç kullanılarak bireysel bitki özelliklerinin belirlenmesine yol açan farklı bölümlerdeki ağaç kanopilerinin yoğunluğunun grafiksel bir görünümünü sağlamak için bir 3B mahsul haritası oluşturulmuştur.

Wang vd. (2021), meyve bahçelerinde ağaç tacı parametrelerinin değerlendirilmesi için kanopi morfolojisi çıkarma yöntemleri ile birleştirilmiş mobil LiDAR tarama sistemi ile ilgili çalışmalarında 3B eşzamanlı konumlandırma ve haritalama (SLAM) algoritmasına dayalı bir mobil tarama sistemi tasarlamışlardır. Araştırmacılar tarafından geliştirilen sistem, meyve bahçesinin bir nokta bulutu haritasını yeniden oluşturmak için hafif bir LiDAR-Atalet Ölçüm Birimi (LiDAR-IMU) durum tahmincisi ve rotasyon kısıtlı bir optimizasyon algoritması kullanmaktadır. Çalışma kapsamında araştırmacılar, yer bilgisinin ayrıldığı meyve bahçesi nokta bulutunu segmentlere ayırmak için istatistiksel aykırı değer kaldırma (SOR) filtrelemesini, Avrupa kümeleme algoritmasını ve filtrelenmiş nokta bulutunu geri yüklemek için k-en yakın komşu (KNN) arama algoritmasını kullanmışlardır. Son olarak, meyve ağaçlarının yüksekliği ve kanopi hacmini, nokta bulutu istatistiksel yöntemi ve 3B alfa şekli algoritması ile elde etmişlerdir. Algoritmayı doğrulamak için, standart bir meyve bahçesinde LiDAR ve IMU ile donatılmış paletli robotlar kullanmışlardır. Araştırmacılara göre bulgular, bu makaledeki sistemin meyve bahçesi nokta bulutu ortamını yüksek doğrulukla yeniden oluşturabildiğini ve meyve bahçesi ortamındaki tüm meyve ağaçlarının nokta bulutu bilgilerini elde edebildiğini göstermektedir. Araştırmacılar önerdikleri sistemin (meyve ağaçlarının nokta bulutu tabanlı bölütlenmesi doğruluğu %95.4, taç yüksekliği R^2 ve RMSE değerleri sırasıyla 0.936 ve 0.043, kanopi hacminin karşılık gelen değerleri ise sırasıyla 0.840 ve 1.573'dir) meyve bahçesindeki ağaç taç bilgilerini iyi bir şekilde hesaplayabildiği ve bunun meyve ağaçlarının akıllı ölçümünde önemli uygulama değerine sahip olduğu şeklinde değerlendirmişlerdir.

Zhang vd. (2021), otlaklardaki bitki örtüsü parametrelerini belirlemek amacıyla İHA-LiDAR teknolojisini kullanmışlardır. Bu kapsamda araştırmacılar, LiDAR verilerinin 0.1 m piksel çözünürlükte ve farklı otlatma yoğunlukları altında modelleme yeteneğini araştırmışlardır. LiDAR'dan türetilen minimum, ortalama ve tüm otlatma platformunda yer üstü biyokütleyi (AGB) tahmin etmek için maksimum kanopi

yükseklikleri ve kısmi bitki örtüsü kapsamını (FVC) kullanmışlardır. Araştırmacılar aynı zamanda LiDAR'dan türetilen bitki örtüsü parametrelerinin uçuş yüksekliğini de analiz etmişlerdir. Çalışma bulgularına göre, LiDAR'dan türetilen maksimum kanopi yüksekliği ve FVC'nin, AGB için en iyi tahmin edici olduğu aynı zamanda uçuş yüksekliğinin (40 m'den 110 m'ye kadar) üretilen kanopi yüksekliği üzerinde önemli bir etki göstermediği tespit edilmiştir. İHA uçuş irtifalarının artmasıyla LiDAR'dan türetilen kanopi yüksekliği 9.19 cm'den 8.17 cm'ye, LiDAR'dan türetilen kanopi yüksekliğinin standart sapması 3.31 cm'den 2.35 cm'ye düştüğü belirlenmiştir.

Gao vd. (2021), meyve ağaçlarının robotik platform yüklü LiDAR verilerini kullanarak kanopi hacim ölçümü çalışmalarında bir meyve ağacı modeli rekonstrüksiyon algoritması geliştirmişlerdir. Öncelikle elde edilen nokta bulutu verileri işlenmiştir. Yeniden yapılandırılmış modelin nokta bulutu dağılımını tek tip hale getirebilmek, robotun ayrıca belirli bir yürüyüş rotasını eşleştirmesi ve ağaca göre bağımsız olarak yürüyüş rotasını çıkarmak için Hough dönüşümü ve K-Means kümeleme algoritmaları kullanılmıştır. Sonuçlar, harita modeli hatasının 0.160 m'den az olduğunu ve hacim ölçümü için kanopi modelinin korelasyon katsayısı R^2 ve RMSE sırasıyla 0.984 ve 0.102 m³ olduğunu göstermektedir. Araştırmacılara göre robotik platforma dayalı olarak toplanan LiDAR verileri, meyve kanopi hacmi hesaplama gereksinimini karşılamaktadır.

Liu vd. (2021), 3B LiDAR nokta bulutu verilerinden *Citrus grandis* var. Longanyou ağaçlarında kanopi parametrelerinin belirlenmesi amacıyla bir çalışma yürütmüşlerdir. Araştırmacılar bu ağaçlarda kanopi özellikleri belirlenmesinin verim ve pestisit püskürtme işlemleri açısından önemli olduğunu vurgulamışlardır. Araştırmacılar öncelikle çalışma alanı için nokta bulutu verilerini toplanmış daha sonra bu nokta bulutu verileri, cloth simulation filter (CSF) ve European clustering algoritmaları kullanılarak ağaç kanopileri çıkarılmıştır. Ağaçların kanopi yüksekliği ve genişliği hesaplandıktan sonra kanopi rekonstrüksiyonu ve hacim hesaplaması altı yaklaşım kullanılarak gerçekleştirilmiştir. Bunlar manuel yöntem ve nokta bulutlarına dayalı beş algoritma (dışbükey gövde, CH; dışbükey gövde dilimler; voksel tabanlı, VB; alfa-şekil, AS; dilimlere göre alfa şekli, ASBS)'dir. Araştırmacıların çalışmadan elde ettikleri bulgulara göre, ASBS, AS'yi dilim optimizasyonu ile birleştiren ve gerçek gölgelik şeklini en iyi şekilde tahmin edebilen yenilikçi bir algoritmadır. Ayrıca bulgulara göre CH algoritmasının en kısa çalışma süresine sahip olduğu ve CH, VB, AS ve ASBS algoritmalarının R^2 değerlerinin 0.87'nin üzerinde olduğu görülmüştür. En yüksek doğruluğa sahip ağaç hacmi ASBS algoritmasından elde edilirken CH algoritmasının en kısa hesaplama süresine sahip olduğu belirlenmiştir.

Gu vd. (2022) tarafından LiDAR nokta bulutu verilerine dayalı meyve bahçesi ağaçlarında yenilikçi yaprak alanı tespit modelleri üzerine bir çalışma yürütülmüştür. Bu maksatla bir elma bahçesindeki ağaç kanopilerinin nokta bulutu verilerini otomatik olarak elde edebilmek amacıyla mobil bir LiDAR algılama platformu kurulmuştur. Ayrıca bir test platformundan kanopi alanları manuel olarak ölçülmüştür. Daha sonra, meyve bahçesi kanopi nokta bulutu ve yaprak alanları arasındaki ilişkiyi incelemek için polinom regresyon, geri yayılım (BP) sinir ağı regresyon ve PLSR algoritmaları kullanılmıştır. BP sinir ağı algoritması (%86.1 ve %73.6 test ve doğrulama verileri için sırasıyla doğruluk) ve PLSR algoritması (%78.46 ve %60.3 sırasıyla) polinom regresyonunun Fourier fonksiyonundan (%59,73 doğruluk) daha iyi performans göstermiştir. Araştırmacılar elde

edilen bulgulara göre, PLSR modelinin sezgisel ve basit, BP sinir ağı algoritmasının ise daha doğru ve yüksek hassasiyetli olduğu sonucuna varmışlardır.

Yang vd. (2022), LiDAR nokta bulutundan ağaç dalı iskeleti çıkarımı için geometrik karakteristiklere dayalı yeni bir algoritma öneren çalışma gerçekleştirmişlerdir. Çalışmada Amerikan kavağı ağacı (*Populus deltoides*) ve yersel bir lazer tarayıcı kullanılmıştır. Araştırmacılar tarafından C++ ve PCL kitaplığı ile, ağaç dalı iskelet çıkarımında geometrik özelliklere dayalı, su ve besin aktaran ağaç tamamlanmamış simülasyon algoritması geliştirilmiş olup bu algoritma, su ve besinleri ileten ağacın tamamlanmamış bir simülasyonunu göstermektedir.

Forero vd. (2022), üç boyutlu (3B) bitki fenotipleme veri tabanının oluşturulmasında LiDAR platformu kullanmışlardır. Araştırmacılar çalışmalarında kullandıkları toplam 362 mısır fidesini, RGB kamera ve lazer tarayıcı kullanarak sırasıyla 45° ve 0.5° açısız çözünürlüğe sahip olarak kaydetmişlerdir. Bitki fiderleri, 10-40 cm olmakla birlikte iç mekân ortamında farklı ışık koşullarında ekimden sonra 7-24 gün arasında taranmıştır. Nokta bulutu verisi, 0.03 cm'lik ortalama mutlak hassasiyet hatasına sahip olup gürültü ve kusurları gidermek için öncelikle işlenmiştir. Daha sonra görüntülerle senkronize edilerek time-stamped uygulanmıştır. Veri tabanı, ham ve işlenmiş verileri ve manuel olarak atanan kök ve yaprak etiketlerini içermektedir. Araştırmacılar tarafından gerçekleştirilen bu veri tabanı oluşturma çalışmasında, Rastgele Orman sınıflandırıcısı ve morfolojik tanımlayıcılara dayalı olarak fide parçaları %89.41 doğrulukla tanımlanmıştır.

Dian vd. (2023) tarafından narenciye bahçelerinde İHA tabanlı LiDAR verileri kullanarak emek açısından tasarruf sağlayan farklı yetiştirme modları altında bu ağaçların fotosentez ve dikey kanopi mimari özelliklerinin belirlenmesi amacıyla bir çalışma yürütülmüştür. Portakal ağaçlarında gerçekleştirilen çalışmada yaprakların azot içeriği ve fotosentetik azot kullanım etkinliği belirlenmiştir. Araştırma kapsamında ağaç dikey mimarisinin belirlenmesi amacıyla da İHA-LiDAR verileri kullanılmıştır. Araştırma bulguları, farklı modlarda dikilen narenciye ağaçlarının farklı katmanlarında farklı fotosentetik azot kullanım etkinliği belirlendiğini ayrıca İHA-LiDAR verilerinin narenciye ağaçlarının dikey kanopi mimarisindeki farklılıkları etkili bir şekilde ortaya çıkardığını göstermiştir.

2.6. Uzaktan Algılama Teknolojisi İle Tarım Alanlarında Verim Tahmini

Tarım alanlarında hasat öncesi, zamanında ve uygun maliyetle verim tahmini özellikle lojistik planlaması, yönetimi ve ilgili ticari kararların alınmasında oldukça önem arz etmektedir. Bu kapsamda farklı uzaktan algılama sistemleri kullanarak tarım alanlarında verim tahmini yapılabilmektedir. Uzaktan algılama ile tarım alanlarında gerçekleştirilecek verimi tahmininin en önemli avantajları, bu teknolojinin ürünlerin farklı büyüme aşamalarında güvenilir bir şekilde kullanılabilmesi, uygun maliyetli olması ve süreç yönetimini kolaylaştırmasıdır (Kumar vd. 2023).

Ye vd. (2007), havadan hiperspektral görüntüler kullanarak narenciye ağaçlarında verimin tahmin edilmesi amacıyla bir çalışma yürütmüşlerdir. Araştırmacılar hasattan birkaç ay önce elde edilen havadan hiperspektral görüntüleri kullanarak Satsuma

mandalinasında meyve verimini tahmin etmek için PLSR analizini kullanmışlardır. Bu kapsamda 72 görünür ve NIR dalga boyundaki (407-898 nm) hiperspektral görüntüler, 2003, 2004 ve 2005'in erken büyüme mevsimlerinde bir narenciye bahçesinden elde edilmiştir. Tek ağaçların kanopi özellikleri, piksel tabanlı sınıflandırma yöntemi kullanılarak belirlenmiş ve elde edilen kanopi özellikleri daha sonra verim tahmin modelleri geliştirmek için tahmin değişkenleri olarak kullanılmıştır. Araştırmacılar NDVI, SR ve fotokimyasal yansıma indeksi (PRI), MLR modelleri ve PLS regresyon modelleri olmak üzere üç model kullanmışlardır. Hasat mevsiminden birkaç ay önce verimi tahmin etmeyi amaçlayan araştırmacılar, geleneksel tekniklere (bitki örtüsü indeksleri ve MLR) karşılık, PLS modellerinin üç yıl için başarılı tahmin sonuçları verdiğini belirlemişlerdir. Araştırmacılara göre bu sonuçlar, kanopi özellikleri ile narenciye verimi arasındaki varsayılan korelasyonu doğrulamıştır. Bu kapsamda araştırmacılar tarafından hasat mevsiminden birkaç ay hatta bir yıl önce verimlerin başarılı bir şekilde tahmin edilebilmesinin, hasat programlarının planlanmasına, belirli ağaçlardaki verim dalgalanmalarıyla başa çıkabilmek için reçete haritalarının oluşturulabilmesine, kontrol önlemlerine ve yönetim uygulamalarına katkıda bulunabileceği değerlendirilmiştir.

Ye vd. (2010), havadan hiperspektral görüntülemeye dayalı narenciye verimi tahmin modelinin geliştirilmesi çalışmasında, hiperspektral görüntüler ve PLSR analizini kullanmışlardır. Araştırmacılar tarafından PLSR faktörlerinin optimum sayısı belirlenmiş ve bu faktörler MLR ve YSA modelleme teknikleri ile geliştirilen narenciye verim tahmin modellerinin girdileri olarak kullanılmıştır. Araştırmacıların elde ettiği sonuçlar, Mayıs ayında elde edilen hiperspektral görüntülere dayalı modellerin en iyi narenciye verim tahminine ulaştığını ve PLS-MLR modelinin PLS-YSA modelinden daha iyi bir kararlılık ve tutarlılığa sahip olduğunu göstermiştir.

Bargoti ve Underwood (2017), elma bahçelerinde meyve tespiti ve verim tahmini için görüntü segmentasyonu yöntemini kullanmışlardır. Çalışma meyve tespiti ve sayımı için bir görüntü işleme çerçevesi sunmaktadır. Araştırmacılar İki özellik öğrenme algoritması (çok ölçekli çok katmanlı algılayıcılar (MLP) ve evrişimli sinir ağları (CNN)) dahil olmak üzere genel amaçlı bir görüntü bölütleme yaklaşımı kullanmışlardır. Elde edilen sonuçlar sayma makinesinden elde edilen hasat sonrası meyve sayılarıyla karşılaştırıldığında, CNN ve havza segmentasyonu (WS) kullanılarak yapılan sayım tahminlerinin, bu veri seti için en iyi performansı verdiği tespit edilmiştir.

Dorj vd. (2017), narenciye bahçelerinde görüntü işleme tekniği kullanarak meyve tespiti ve sayımı yoluyla bir verim tahmini çalışması gerçekleştirmişlerdir. Çalışmada görüntü işleme tekniklerini kullanarak ağaçtaki turuncgilleri tespit etmek ve saymak için etkili, basit, uygun bir bilgisayarlı görü algoritması geliştirmek, verimi tahmin etmek ve çeşitli yöntemlerle elde edilen verim tahmin sonuçlarını karşılaştırmak amaçlanmıştır. Araştırmacılar tarafından geliştirilen bu yeni narenciye tanıma ve sayma algoritması, narenciye veriminin bir tahminini sunmak için renk özelliklerinden yararlanmış ve narenciye veriminin erken bir tahminini sağlamak için ilgili modeller geliştirilmiştir. 21 ağaçtan 84 görüntü üzerinde narenciye tanıma ve sayma algoritması test edilmiştir. Narenciye sayma algoritması kapsamında araştırmacılar tarafından ilk önce RGB görüntüsü HSV'ye dönüştürülmüş daha sonra sırasıyla eşikleme, turuncu renk algılama, parazit giderme, havza segmentasyonu işlemleri uygulanmış ve son olarak meyve sayım

işlemi gerçekleştirilmiştir. Bu çalışmada ayrıca daha iyi bir sonuç elde etmek için narenciye meyvelerinde otomatik havza segmentasyonu için mesafe dönüşümü ve işaret kontrollü havza algoritmaları değerlendirilmiştir. Araştırmacılar tarafından önerilen algoritmanın, narenciye ağaçlarının veriminin erken tahmini için büyük potansiyel ortaya koyduğu tespit edilmiştir.

Chen vd. (2019) tarafından çilek bitkisinde yüksek çözünürlüklü ortofotolardan derin sinir ağına dayalı verimi tahmini çalışması gerçekleştirilmiştir. Araştırmacılar tarafından geliştirilen sistem ile tarladaki çiçek ve çilek meyvesinin hem tespit edilmesi hem de sayımı ile çiftçilerin verimi daha hızlı, kesin ve periyodik olarak tahmin etmek için meyve haritaları oluşturabileceği ortaya konmuştur.

Nevavuori vd. (2020), çok zamanlı İHA verileri ve uzamsal-zamansal derin öğrenme modellerini kullanarak mahsul verim tahmini gerçekleştirmişlerdir. Araştırmacılar tarafından Finlandiya, Pori'deki yaklaşık 85 hektar olan ve ürün çeşidi olarak buğday, arpa ve yulaf bulunan dokuz ürün alanı çalışmaya dahil edilmiş ve alandan toplanan zaman serisi İHA-RGB ve hava durumu verileri kullanılmıştır. Çalışmada RGB zaman serisi verileriyle mahsul verimi zaman serisi modelleme ve tahmininde uzaysal-zamansal derin öğrenme mimarilerinin fizibilitesi değerlendirilmiştir. Sonuç olarak araştırmacılar tarafından, çok zamanlı uzaktan algılama verilerinin kullanımının sadece yaygın değil, aynı zamanda mahsul verimi modelleme ve tahmininde de faydalı olduğu değerlendirilmiştir. Ayrıca, ticari olarak temin edilebilen İHA'lara monte edilmiş RGB sensörlere kolay erişilebilirlik, uydulara kıyasla daha yüksek çözünürlüklerde görüntü verisi elde edilmesini sağlama avantajı ile alan içi ölçekte modelleme ve tahminler gerçekleştirme olasılıklarını ortaya koymaya yardımcı olabilmektedir. Araştırmacılara göre İHA tabanlı verilerin ve uygun mekânsal-zamansal derin öğrenme tekniklerinin kullanılması, tarım alanında daha karmaşık karar destek sistemlerinin etkinleştirilmesini sağlayabilmektedir.

Feng vd. (2020), çok sensörlü görüntüleri kullanarak pamukta verim tahmini çalışmalarında İHA tabanlı bir uzaktan algılama sisteminin performansını değerlendirmeyi amaçlamışlardır. Çalışmada RGB, MS ve kızılötesi termal kameralı bir İHA sistemi, farklı iki büyüme aşamasında bir pamuk tarlasının görüntülerini almak için kullanılmıştır. Üç kameradan gelen görüntüler ve bir hasat makinesine monte edilmiş verim monitörü tarafından elde edilen coğrafi referanslı verim verileri bir SYM oluşturmak için işlenmiş ve NDVI dahil olmak üzere sekiz görüntü özelliği çıkarılmıştır. Sonuçlar her iki dönemde toplanan İHA tabanlı görüntülerin pamuk verimini doğru bir şekilde tahmin edebildiğini ortaya koymuştur.

Sunoj vd. (2021) İHA sistemi ve MS görüntülerden mısır bitkisinde tane verimi tahmini ve haritalaması çalışmalarında altı bitki indeksini değerlendirmişlerdir. Araştırmacılar bitkinin farklı büyüme aşamalarında farklı dozlarda azot uygulamaları gerçekleştirmişler ve çalışma sonucunda NDVI ve EVI2 bitki indeksleri kullanılarak doğru verim tahminlerinin elde edilebileceği sonucuna varmışlardır.

Apolo-Apolo vd. (2020) tarafından derin öğrenme tekniklerini kullanarak tek tek ağaçlardaki narenciye meyvelerinin boyutunu tespit etmek, saymak ve tahmin etmek için görüntü işleme yöntemi geliştirilmiştir. Üç yıl süren araştırma kapsamında, ticari bir

narenciye bahçesinden toplam 20 ağaç İHA'dan alınan görüntüler kullanılarak izlenmiştir. Bu ağaçlar elle hasat edilmiş ve meyve boyları ölçülmüştür. Elde edilen görüntülerdeki portakalları algılamak için özel bir veri kümesi kullanılarak daha hızlı bir derin öğrenme modeli eğitilmiştir. Görsel sayım ile modelin meyve tespiti arasında %6.59'luk bir ortalama standart hata (SE) elde edilmiştir. Çalışmada tespit edilen meyveler kullanılarak meyve boyu tahmini de yapılmıştır. Araştırmacılara göre elde edilen sonuçlar, boyut tahmin yönteminin hasattan önce boyut ayrımı için kullanılabileceğini göstermiştir. Ağaç başına verim tahmini ve toplam verim tahmini için uzun kısa süreli belleğe (LSTM) dayalı bir model eğitilmiş ve ağaç başına gerçek ve tahmini verimler karşılaştırılarak yaklaşık $SE=4.53$ hata ve standart sapma $SD=0.97$ kg ile sonuçları elde edilmiştir. Gerçek toplam verim, tahmini toplam verim ve uzman bir teknisyen tarafından tahmin edilen toplam verim karşılaştırılmıştır. Teknisyenin tahminindeki hata $SE=13.74$ iken, modeldeki hatalar $SE=7.22$ ve $SD=4083.58$ kg olarak belirlenmiştir. Araştırmacılara göre, mevcut tekniğin narenciye meyveleri ve hatta diğer meyve türleri için verim tahminleri sağlama potansiyeli açısından önemli olduğu değerlendirilmiştir.

Gené-Mola vd. (2020), LiDAR kullanarak meyve tespiti, verim tahmini ve kanopi geometrik karakterizasyonu amacıyla bir çalışma yürütmüşlerdir. Bu araştırma meyve tespiti için LiDAR teknolojisini kullanırken, verimin eksik tahmin edilmesine yol açan meyve tıkanıklıklarının meydana gelmesi ihtimali sorununu iki farklı yaklaşımla ele almaya odaklanmıştır (hava destekli bir püskürtücü aracılığıyla cebri hava akışı uygulamak ve çok görüntülü algılama kullanmak). Araştırma sonuçlarına göre sistem, görünen meyvelerin %80'inden fazlasını edebilmiş, %6'dan daha düşük bir ortalama karekök hatasıyla verimi tahmini yapabilmiş ve kanopi yüksekliğini, genişliğini, kesit alanını ve yaprak alanını karakterize edebilmiştir. Güçlü hava akışı ve çoklu görünüm yaklaşımları, sırasıyla %6.7 ve %6.5 daha fazla meyve tespit ederek meyve tıkanıklıklarının sayısını azaltmaya yardımcı olabilmıştır. Bu nedenle araştırmacılar tarafından, önerilen sistemin potansiyel olarak verimi izleyebileceği ve elma ağaçlarındaki geometriyi karakterize edebileceği belirtilmektedir.

Fu vd. (2020), buğdayda büyüme izleme ve verim tahmini çalışmalarında çok rotorlu bir İHA ve bitki indeksleri kullanmışlardır. Çalışma 2018-2019 yıllarında Jiangsu Eyaletinin üç bölgesinde farklı nitrojen seviyeleri ve tohumlama yoğunlukları ile işlenmiş buğday denemeleri üzerinde gerçekleştirilmiştir. Araştırmacılar çalışmada LAI, yaprak kuru maddesi (LDM), verim, bazı bitki indeksleri ile basit doğrusal regresyon (LR), çoklu doğrusal regresyon (MLR), aşamalı çoklu doğrusal regresyon (SMLR), PLSR, YSA ve rasgele orman (RF) modelleme yöntemlerini kullanmışlardır. Araştırmacılar tarafından elde edilen bulgular, İHA üzerine monte edilmiş MS bir kameranın ve bu kameradan hesaplanan indekslerin potansiyelinin önemli olduğunu ve özellikle makine öğrenme yöntemlerinin (PLSR, YSA, RF) verim tahmininde daha iyi performans gösterdiğini ortaya koymuştur.

Demir (2021) tarafından Isparta yağ gülü (*Rosa damascana* mill.) yetiştirilen alanlarda verim üzerinde etkili parametrelerin dönemsel olarak belirlenmesi ve spektral ölçümlerle birleştirilerek verim tahmin modellerinin geliştirilmesi amacıyla bir çalışma yürütülmüştür. Araştırmacı 2019-2020 vejetasyon döneminde Isparta gülünün fenolojik, morfolojik ve biyokimyasal değişimleri dönemsel olarak incelenmiş, vejetasyon süreci

boyunca biyotik ve abiyotik stres faktörlerinin etkileri belirlemiştir. Ayrıca hiperspektral veriler kullanarak organik ve konvansiyonel tarım yapılan Isparta gülünün spektral imzalarını oluşturmuştur. Araştırmacı tarafından Isparta gülünün erken dönem verim değerlendirmesi için İHA-MS görüntülerden farklı bitki indeksleri ve makine öğrenme algoritmaları kullanılarak verim tahmin modelleri elde edilmiştir. Bulgular neticesinde araştırmacı özellikle sürdürülebilir tarım sistemlerinde erken dönem verim tahmini için İHA ve spektral verilerin kullanılması gerektiğini önermiştir.

He vd. (2022), verim tahmini ve tahmin teknolojilerinin gelişimini özetlemeyi ve meyve bahçesi akıllı yönetimi için önerilerde bulunmayı amaçlayan bir inceleme çalışması gerçekleştirmişlerdir. Araştırmacılar meyve bahçelerinde verim tahmininde kullanılan hem doğrudan hem de dolaylı yöntemler için son teknolojileri kapsamlı bir şekilde değerlendirmişlerdir. Araştırmacılara göre verim tahmin sistemlerinde en yaygın olarak kullanılan girdi bitki indeksleri, en çok uygulanan modelleme yöntemi ise makine öğrenmesidir. Ayrıca görüntü işleme ve derin öğrenmeye dayalı yapay görme sistemleri tarım alanında hızlı bir şekilde gelişmeye başlamış ve meyve bahçesi verim tahmininde de yaygın olarak kullanılmasına rağmen günümüzde hala meyve bahçelerinde verim tahmininde büyük zorluklar olduğu ve bu zorluklara karşı geliştirilmiş karşı önlemlerin sıkça tartışıldığı sonucunu önermişlerdir.

Bian vd. (2022), makine öğrenme yöntemi ve MS-İHA verileri kullanarak buğdayda bitkisinde verim tahmini çalışmasında, MS-İHA verilerine ve makine öğrenme yöntemlerine dayalı olarak kışlık buğday verimi için bölgesel tahmin modelleri oluşturmayı amaçlamışlardır. Araştırmacılar tarafından verim tahmin modellerinin oluşturulması için gauss süreç regresyonu (GPR), destek vektör makine regresyonu (SVR) ve rastgele orman regresyonu (RFR) dahil olmak üzere altı makine öğrenme yöntemi kullanılmıştır. MS bir İHA'dan elde edilen kışlık buğdayın spektral görüntülerinden elde edilen on bitki örtüsü indeksi, modellerin değişkenleri olarak seçilmiştir. Ayrıca tahmin algoritması modellemesi ve doğrulaması için örnekleme yöntemiyle buğday veriminin yerinde ölçümleri elde edilmiştir. Sonuçlar, GPR modelinin farklı ölçeklerde güçlü bir uyarlanabilirliğe sahip olduğunu göstermiştir. Araştırmacılara göre bu bulgular, makine öğrenme yöntemleri ve MS-İHA verileri kullanımının, tarla ölçeğinde mahsul verimini doğru bir şekilde tahmin edebileceğini ve çiftlik ölçeğinde tarla mahsul yönetimi için değerli bir uygulama referansı sunabileceğini göstermektedir.

Torgbor vd. (2023), mango bitkisinin verim tahmininde makine öğrenme yaklaşımını kullanarak uzaktan algılama verilerine meteoroloji değişkenlerini entegre etmişlerdir. Araştırmacılar çalışmada Landsat 7 ve Landsat 8 uydu verilerinden hesapladıkları dört bitki örtüsü indeksi, beş meteoroloji verisi ve içinde PLSR'nin de yer aldığı altı makine öğrenme algoritması kullanmışlardır. Araştırmacılara göre bulgular farklı makine öğrenme algoritmalarının, Landsat uydu verilerinden hesaplanan bitki örtüsü indekslerinden hasat döneminden en az 3 ay önce mango verimini tahmin etme yeteneğini göstermiştir. Ayrıca çalışmada RF algoritmasını yalnızca uydu verisi değişkenleriyle uygulamanın hem uydu verisi hem de hava durumu değişkenlerini birleştiren modellerle karşılaştırılabilir bulgular ürettiği sonucuna varılmıştır. Araştırmacılar bu nedenle bu tür araştırmalar için bloğa özgü meteoroloji verileri mevcut değilse, blok düzeyinde verimi tahmin etmek için yalnızca uzaktan algılama değişkenlerine odaklanılmasını önermişlerdir.

Vijayakumar vd. (2023) tarafından yersel ve havadan veriler kullanarak makine öğrenimi teknikleri ile narenciye ağaçlarında verim tahmini çalışması gerçekleştirmişlerdir. Araştırmacılar tarafından portakal ağaçlarında gerçekleştirilen ve PLSR de dahil olmak üzere farklı makine öğrenme algoritmalarının değerlendirildiği çalışmada 3 farklı model oluşturulmuştur. Bu modellerden PLSR ve Model 2 (MS veriler, ağaç yapı parametreleri ve tek taraflı meyve sayıları), ağaç düzeyinde verim tahmininde daha düşük mutlak ortalama yüzde hata değeri ve veri toplama kolaylığı nedeniyle en iyi model olarak seçilmiştir.


Tez çalışması kapsamında yapılan kaynak taraması sonucu, farklı uzaktan algılama sistemleri ve tekniklerinin tarımsal üretim alanlarında farklı amaçlarla kullanıldığı görülmüştür. Bu kapsamda özellikle son yıllarda yersel hiperspektral ve uydu sistemlerine ek olarak SPAD, MS görüntüleme, İHA ve LiDAR sistemlerinin de tarım alanlarında yaprak bağlı klorofil içeriğinin belirlenmesi, haritalama, ağaç kanopi parametreleri olan dendrometrik bileşenlerin hesaplanması, 3B modelleme ve verim tahmini gibi çalışmalarda kullanıldığı belirlenmiştir.

3. MATERYAL VE METOT

3.1. Materyal


3.1.1. Çalışma alanı

Bu tez çalışması, Batı Akdeniz Tarımsal Araştırma Enstitüsü'nde (BATEM) gerçekleştirilmiştir (Şekil 3.1). Çalışma alanı 36°55'24.55" kuzey enlemleri ile 31°00'25.03" doğu boylamları arasında yer almaktadır. İl merkezinden 34 km uzaklıkta bulunan bu alanda başta narenciye olmak üzere çeşitli koleksiyon bahçeleri bulunmaktadır. BATEM meyvecilik bölümünün yer aldığı bu alanda günümüze kadar yürütülen farklı turuncgil ve subtropik bitkilerin ıslah çalışmaları sonucunda 81 adet çeşit BATEM adına tescil edilmiştir (BATEM 2023).



Şekil 3.1. Çalışma alanının genel görünümü

BATEM'in Kayaburnu arazisinde gerçekleştirilen bu çalışma, 4 farklı deneme alanında yürütülmüştür. Her birinden 30 ağaç olmak üzere toplam 120 ağaçtan oluşan bu deneme alanları Washington ve Valencia portakalları ile Clementine ve Satsuma mandalinalarından oluşmaktadır. Söz konusu bu parsellerdeki narenciye ağaçları 1991 yılında dikilmiştir (Şekil 3.2).



Şekil 3.2. Deneme alanlarının çalışma alanındaki konumu

Çalışma, deneme alanlarında yer alan bu dört narenciye ağacı çeşidinin meyve olum dönemlerinde gerçekleştirilmiştir. Bu dönemler iklim koşulları nedeniyle zaman zaman kaymalar gösterse de Washington portakalı için 15 Kasım-15 Aralık, Valencia portakalı için 20 Şubat-30 Mart, Clementine mandalinası için 1-30 Kasım, Satsuma mandalinası için ise 1-31 Ekim tarihleri arasını kapsamaktadır. Bu tarih aralıkları bölge için bu çeşitlerin aynı zamanda hasat zamanları olarak da kabul edilmektedir.

3.1.2. İHA ve MS kamera

Çalışmada kullanılan ve MS kameranın takıldığı ilk İHA 1280 g ağırlığa, yaklaşık 23 dk uçuş süresine ve 12 MP kameraya sahip olan Phantom 3 Advanced (DJI, Shenzhen, China)'dir (Şekil 3.3).



Şekil 3.3. Çalışmada kullanılan İHA

Çalışmada narenciye ağaçlarının bazı dendrometrik bileşenlerinin hesaplanması ve MS verilerin alınmasında kullanılan İHA'nın teknik özellikleri Çizelge 3.1'de gösterilmiştir.

Çizelge 3.1. Phantom 3 Advanced İHA'nın özellikleri (DJI 2021)


Hava Aracı	
Ağırlık (Batarya+pervane)	1280 g
Maksimum hız	16 m sn ⁻¹
Maksimum uçuş süresi	Yaklaşık 23 dk
Kamera	
Sensör	1/2.3" CMOS
Lens	FOV 94° 20 mm (35 mm format eşdeğeri) f/2.8
ISO aralığı	100-3200 (video) 100-1600 (foto)
Shutter hızı	8 - 1/8000 s
Görüntü boyutu	4000×3000
Foto	JPEG, DNG (RAW)
Gimbal	
Stabilizasyon	3-axis (pitch, roll, yaw)
Ayarlanabilir aralık	Pitch: -90° to +30°

(Devamı Arkada)

Çizelge 3.1'in devamı

Uzaktan Kumanda	
Çalışma Frekansı	2.400 - 2.483 GHz
Çalışma Sıcaklık Aralığı	32 °F - 104 °F (0 °C - 40 °C)
Pil	6000 mAh LiPo 2S
Video Çıkış Bağlantı Noktası	USB
Görüş Sistemi	
Görüş sistemi	Aşağı görüş sistemi
Hız aralığı	$\leq 8 \text{ m s}^{-1}$ (yerden 2 m yukarıda)
Rakım Aralığı	30-300 cm
Çalışma aralığı	50-300 cm
Çalışma ortamı	Net desenli ve yeterli aydınlatmaya sahip yüzey (lux> 15)
Uygulama	
Mobil uygulama	DJI GO

Narenciye ağaçlarının dendrometrik bileşenlerinin belirlenmesine yönelik gerçekleştirilen uçuşlarla eş zamanlı olarak 4 band (Mavi-Yeşil-Kırmızı-Yakın Kızılötesi) görüntü elde edebilmek ve bitki indeksleri hesaplayabilmek amacıyla İHA'ya elektromanyetik spektrumun görünür ve yakın kızılötesi bölgesinden yansımaları alabilen bir MS kamera takılmıştır (Şekil 3.4).



Şekil 3.4. Çalışmada kullanılan MS kamera ve İHA'ya montaj aparatı; a) Ön; b) Arka

Çalışmada kullanılan Survey3W (MAPIR, San Diego, CA 92126 USA) Kırmızı-Yeşil-Yakın Kızılötesi (Red+Green+NIR - RGN) MS kamera pilli 76 g ağırlığında olup 12 MP sensöre sahiptir (Çizelge 3.2).

Çizelge 3.2. MS kameranın özellikleri (MAPIR 2021)

Görüntü formatı	RAW + JPG, JPG (RAW kanal başına 12 bit, JPG kanal başına 8 bit)
Lens optiği	41° HFOV (47 mm) f / 3.0 Açıklık, % -1 Aşırı Düşük Bozulma (Balık Gözü Olmayan) Cam Lens
Yer örneklem mesafesi	2.3 cm/ x (0.9 inç px ⁻¹), 120 m (~ 400 ft) AGL'de
Algılayıcı	Sony Exmor R IMX117 12MP (Bayer RGB)
GPS / GNSS (Harici)	ublox UBX-G7020-KT
Pil	Çıkarılabilir Li Ion (1200 mAh) (USB destekli olduğunda gerekmez)
Ağırlık	50 g (Pilsiz), 76 g (Pilli)
Boyutlar	59 x 41.5 x 36 mm (Uzunluk x Yükseklik x Derinlik)
Bellek saklama alanı	Micro SD (128 GB'a Kadar Kart) (64 GB Kart ≈ 15,000 JPG, 2,200 RAW + JPG)
Ölçüm	Ortalama / Merkez / Nokta
Sıklık	60 Hz / 50 Hz

3.1.3. İHA ve LiDAR (İHA-LiDAR) sistemleri

Tez çalışmasında kullanılan ikinci İHA, Matrice 200 V2 (DJI, Shenzhen, China)'dir. Oldukça dayanıklı bir İHA olan Matrice 200 V2, gerekli iyileştirmeler ile gelen özellikle veri ve uçuş güvenliği, yüksek performans ve akıllı kontrol sistemleri ile donatılmış endüstriyel bir İHA'dır (DJI 2022). Matrice 200 V2 İHA'ya ait bazı teknik özellikler Çizelge 3.3'de verilmiştir.

Çizelge 3.3. Matrice 200 V2 İHA'nın özellikleri (DJI 2022)


Hava Aracı	
Ağırlık (2 adet TB55 batarya dahil)	4690 g
Maksimum kalkış ağırlığı	6.14 kg
Maksimum faydalı yük ağırlığı	1.45 kg
Maksimum uçuş süresi	38 dk (yüksüz), 24 dk (Kalkış ağırlığı: 6.14 kg)
Desteklenen DJI gimbal	Zenmuse X4S/X5S/X7/XT/XT2/Z30
Global navigation satellite systems (GNSS)	GPS+GLONASS
Uzaktan Kumanda	
Çalışma Frekansı	4000-2.4835 GHz; 5.725-5.850 GHz
Çalışma Sıcaklık Aralığı	-4 °F-22 °F (-20°C-50 °C)
Pil	WB37-4920mAh-7.6V
Video Çıkış Bağlantı Noktası	1 A= 5.2 V (maksimum)

(Devamı Arkada)

Çizelge 3.3'ün devamı

Görüş Sistemi	
Görüş sistemi	Aşağı görüş sistemi
Hız aralığı	$\leq 8 \text{ m s}^{-1}$ (yerden 2 m yukarıda)
Yükseklik	10 m
Çalışma aralığı	10 m
Çalışma ortamı	Net desenli ve yeterli aydınlatmaya sahip yüzey ($\text{lux} > 15$)
Ultrasonic Sensor Çalışma Aralığı	0.1-5 m
Ultrasonic Sensor Çalışma Ortamı	Emici olmayan malzeme, sert yüzey
Yukarı Kızılötesi Tespit Sistemi	
Obje Tespit Aralığı	0-5m
FOV	$\pm 5^\circ$
Çalışma Ortamı	Büyük, dağınık ve yansıtıcı engeller($\text{reflectivite} > 10\%$)
Uygulama	
Mobil uygulama	DJI Pilot

Çalışmada bitkilerin meyve olum dönemlerinde İHA'ya monte edilmiş kameradan elde edilen veriler kullanılarak belirlenen ağaç dendrometrik bileşenlerinin doğruluk analizlerinin yapılması amacı ile normal RGB kameralardan üretilen ve nokta bulutlarına göre oldukça hassas veriler sunan LiDAR cihazı kullanarak gerçekleştirilmiştir (Estornell vd. 2021; Qi vd. 2021; Chen vd. 2022). Bu kapsamda, çalışmada DJI Matrice 200 V2 İHA'ya takılabilen Genius mini İHA-LiDAR (Surestar, Hefei, China) sistemi kullanılmıştır (Şekil 3.5).



Şekil 3.5. Çalışmada kullanılan İHA ve LiDAR sistemleri; a) İHA; b) LiDAR


Genius mini İHA-LiDAR, R-fans çok ışınlı lazer tarayıcı, POS (GNSS/IMU), bilgisayar kontrol birimi ve veri depolama birimlerinin entegre olduğu bir sistemdir. Lazer dalga boyu 905 nm olan sistemin ağırlığı 1.2 kg'dır (Çizelge 3.4).

Çizelge 3.4. İHA-LiDAR sisteminin özellikleri (Surestar 2022)

Lazer dalga boyu	905 nm
Lazer Frekansı	320 kHz/640 kHz
Maks Ölçüm Aralığı	200 m ($\rho = \%20$) 250 m ($\rho = \%60$)
Tipik Operasyonel İrtifa	50-150 m
Tarayıcı FOV	360° x 30°
Yankı numarası	2 dönüş
Yansıma okuması	8 bit veya 12 bit
Sistem dikey doğruluğu	<0.1m
Çalışma sıcaklığı	- 20 °C, +55 °C
Sistem ağırlığı	1.2 kg (DJI M200/M210 yükü ile)
İletişim arabirimi	Ethernet, PPS
Güç kaynağı	9 ~ 32VDC
Güç tüketimi	≤ 8W

3.1.4. Spektroradyometre

Bitki örtüsünün karmaşık üç boyutlu geometrisi nedeniyle; bitki kanopisinden yansıyan ışık, çok sayıda yansıyan ve/veya iletilen bileşenlerin kompleks bir karışımıdır. Bitki kanopi seviyesinin optik sinyali, aydınlatmaya ve görüntüleme geometrisine, kanopi yapısına, yaprak optik özelliklerine ve kanopinin içindeki ve altındaki diğer bitki olan veya olmayan tüm bileşenlerin optik özelliklerine bağlıdır (Artisan, 2022).



Şekil 3.6. Çalışmada kullanılan spektroradyometre; **a)** Plant probe; **b)** Leaf clip

Hiperspektral uzaktan algılama ile bitkilerde çeşitler arası spektral özelliklerin belirlenmesi sayesinde tür ayırımından bitki besin maddesi içeriğinin tahmin edilebilmesine kadar pek çok çalışmada yersel ölçüm cihazlarından olan spektrometreler kullanılabilmektedir (Ferreira vd. 2013; Dedeoğlu 2020). Bu çalışmada narenciye yapraklarının spektral değerlerinin ölçülmesinde yersel hiperspektral algılayıcı olarak ASD/FieldSpec®3 Plant Probe+Leaf Clip (Analytical Spectral Devices (ASD), Inc., Boulder, Colorado) cihazı kullanılmıştır (Şekil 3.6). ASD FieldSpec HandHeld, 325-1075 nm dalga boyu aralığı 1.5 nm örnekleme (bant genişliği), 3.5 nm çözünürlük ve 17 ms'ye kadar kısa tarama sürelerine sahip 512 elemanlı bir fotodiyot dizi spektrometredir (Artisan 2022).

3.1.5. Klorofilmetre


Bitki yapraklarındaki SPAD değerinin yaprakların bağlı klorofil içeriğini ve ürün azot durumunu doğru bir şekilde temsil edebileceğini gösteren araştırmalar bulunmaktadır (Delegido vd. 2014; Wang vd. 2016; Yuan vd. 2016). Bu çalışmada narenciye ağaçlarının yaprak klorofil ölçümleri için SPAD-502 (Konica Minolta, Inc., Tokyo 100-7015, Japan) klorofilmetre cihazı kullanılmıştır (Şekil 3.7). SPAD-502 portatif bir klorofil ölçüm cihazı olup -9.9-199.9 SPAD birimi arasında ölçüm değerleri vermektedir. SPAD-502 klorofilmetresi 30 ölçüm değerini hafızasına kaydedebilmenin yanı sıra ölçüm değerlerinin ortalamasının alınması ve silinmesi gibi özelliklere de sahiptir.



Şekil 3.7. Çalışmada kullanılan klorofilmetre ve okuma kontrolcüsü

SPAD-502 klorofilmetresi, yaprağın iki dalga boyu bölgesindeki emilimi ölçerek yapraktaki mevcut klorofilin bağlı miktarını belirlemektedir. Şekil 3.8, %80 aseton

kullanılarak, iki yaprak örneğinden ekstrakte edilen klorofilin spektral emilimini göstermektedir. Klorofilin mavi (400-500 nm) ve kırmızı (600-700 nm) bölgelerde emiliminin tepe noktalarına sahip olduğu yakın kızılötesi bölgede ise emilimin olmadığı görülmektedir (Konica Minolta 2022).




Şekil 3.8. SPAD-502 çalışma teorisi (Konica Minolta 2022)

SPAD502, klorofilin elektromanyetik spektrumun ilgili bölgelerdeki özelliğinden yararlanarak kırmızı ve yakın kızılötesi bölgelerde yaprağın emilimini ölçmektedir. Sonuçta bu cihaz, iki emilimi kullanarak yaprakta bulunan klorofil miktarıyla orantılı sayısal bir SPAD değeri hesaplamaktadır (Konica Minolta 2022).


3.1.6. Meteorolojik veriler

Çalışmada meteorolojik veriler olarak T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü (MGM), Meteoroloji 4. Bölge Müdürlüğü'nden temin edilen 17895 numaralı Aksu/Boztepe TİGEM istasyonuna ait veriler ve arazi çalışmaları ile elde edilen fotosentetik aktif radyasyon (PAR) ölçüm değerleri kullanılmıştır. İlgili meteoroloji istasyon verilerinden alınan meteorolojik değerler aylık ve günlük olarak iki kategoride düzenlenmiştir. Aylık olarak düzenlenen ve 01 Mart 2021-31 Mart 2022 tarihleri arasını kapsayan veriler, ortalama sıcaklık (°C), toprak sıcaklıkları (5 cm, 10 cm, 20 cm ve 100 cm) (°C), nisbi nem (%) otomatik meteoroloji gözlem istasyonlarından (OMGİ) alınan yağış ve rüzgâr hızıdır.



Şekil 3.9. Aylık ortalama sıcaklık grafiği


Çalışma alanının aylık ortalama sıcaklık değerlerine göre, en düşük sıcaklığın Mart ayında belirlendiği ve bu aydan itibaren arttığı, en yüksek hava sıcaklığının ise Temmuz ayında kaydedildiği ve bu aydan itibaren ortalama aylık sıcaklığın azalmaya başladığı tespit edilmiştir (Şekil 3.9). Şekil 3.10'da verilen aylık ortalama toprak sıcaklıkları grafiği incelendiğinde ise, hava sıcaklıklarındaki artışla toprak sıcaklığının da Mart ayından itibaren arttığı, toprak derinliğine bağlı olarak 100 cm'de diğerlerine göre daha düşük olduğu tespit edilmiştir. Bu verilere göre özellikle yaz aylarında 5 cm'lik toprak yüzeyi sıcaklığı en yüksek değere ulaşmaktadır.



Şekil 3.10. Aylık ortalama toprak sıcaklığı grafiği


Aylık ortalama nisbi nem değerleri, narenciye ağaçlarının yetiştirme dönemleri boyunca zaman zaman artış ya da azalışlar gösterse de en yüksek Nisan 2021

(%69.80)'de, en düşük ise Ekim 2021 (%53.10)'de ölçülürken tüm dönemler için ortalama %62.61 olarak tespit edilmiştir (Şekil 3.11).



Şekil 3.11. Aylık ortalama nisbi nem grafiği


Otomatik meteoroloji gözlem istasyonundan (OMGİ) alınan yağış verilerine göre 2021 yılının Ekim ayına kadar oldukça düşük değerler elde edilirken özellikle Kasım ayından itibaren 2022 yılının Şubat ayına kadar yüksek yağış değerleri ölçülmüştür. Bu dört ayın yağış ortalaması $280.70 \text{ mm kg m}^{-2}$ iken diğer aylar için ortalama $14.56 \text{ mm kg m}^{-2}$ 'dir (Şekil 3.12).



Şekil 3.12. Aylık ortalama yağış grafiği


Deneme alanlarının aylık ortalama rüzgâr hızı verilerine göre, en yüksek değer (2.10 m sn^{-1}) 2022 yılının şubat ayında tespit edilirken en düşük değer (1.40 m sn^{-1}) 2021

yılının Mart ayında belirlenmiştir. Rüzgâr verileri için tüm yetiştirme dönemleri aylık ortalama değeri ise 1.72 m sn^{-1} olarak ölçülmüştür (Şekil 3.13).



Şekil 3.13. Aylık ortalama rüzgâr hızı grafiği

Narenciye deneme alanları için düzenlenen günlük meteorolojik veriler, aylık veriler de olduğu gibi ortalama sıcaklık ($^{\circ}\text{C}$), toprak sıcaklıkları (5 cm, 10 cm, 20 cm ve 100 cm) ($^{\circ}\text{C}$), nisbi nem (%) otomatik meteoroloji gözlem istasyonlarından (OMGİ) alınan yağış ve rüzgâr hızı verilerini içermektedir (Şekil 3.14). Bu veriler tüm deneme alanlarının meyve olum dönemlerine ait farklı tarihleri kapsamaktadır. Bu tarihler Satsuma mandalinası için 12 Ekim 2021, Washington portakalı ve Clementine mandalinası için 16 Kasım 2021 ve Valencia portakalı için ise 16 Mart 2022'dir.



Şekil 3.14. Günlük meteorolojik veriler grafiği

Günlük ortalama sıcaklık değerlerine göre en sıcak tarih 12 Ekim 2022 (Satsuma mandalinası olum dönemi) iken en soğuk tarih 16 Mart 2022'dir (Valencia portakalı olum

dönemi). Toprak sıcaklıkları açısından değerlendirildiğinde, hava sıcaklığında olduğu gibi en yüksek ölçüm değerleri 12 Ekim 2022 ve en düşük ölçüm değerleri 16 Mart 2022 tarihinde kaydedilmiştir. Ayrıca toprak sıcaklığı değerlerinde, 16 Mart 2022 tarihinde diğer tarihlerden farklı olarak 20 cm ve 100 cm’de artış gözlenmiştir. Günlük minimum nisbi nem değerleri için 12 Ekim 2021 tarihinde en yüksek değer elde edilirken hava sıcaklığında 16 Kasım 2021 tarihine göre daha düşük değer elde edilen 16 Mart 2022 tarihinde bir önceki tarihe göre daha yüksek nisbi nem tespit edilmiştir. Tüm deneme alanları için belirlenen olum dönemi tarihlerinde herhangi bir yağış değeri kaydedilmemiştir. Tüm olum dönemlerinde rüzgâr hızları bakımından birbirine yakın değerler elde edilmiştir. Diğer verilerde olduğu gibi en yüksek rüzgâr hızı 12 Ekim 2021 tarihinde alınırken takip eden diğer iki dönemde birbirine oldukça yakın değerler ölçülmüştür.

Arazi çalışmaları kapsamında tüm deneme alanları için farklı noktalardan narenciye ağaçlarının PAR ölçümleri gerçekleştirilmiştir. Bu ölçümler için MQ-500 PAR metre cihazı (Apogee Instruments Inc., North Logan, USA) kullanılmıştır (Şekil 3.15). Bu cihazda elektromanyetik spektrumun görünür bölgesindeki (400-700 nm) ışığı, PPFD (fotosentetik foton akı yoğunluğu) veya ışık yoğunluğunu, μmol cinsinden ölçmek üzere tam olarak kalibre edilmiş bir kuantum optik dedektör bulunmaktadır. MQ-500 PAR metre cihazı, %5 belirsizlik ile $\mu\text{mol m}^{-2} \text{s}^{-1}$ cinsinden tek bir PAR okuması vermek için 400 ve 700 nm arasındaki tüm fotonların yoğunluğunu hassas bir şekilde ölçen, %2’den daha düşük bir doğruluk sapma oranı ile kararlı ve doğru bir kalibrasyona sahiptir (Apogee 2022a). Mikromol, saniyede metrekare başına ($\mu\text{mol m}^{-2} \text{s}^{-1}$) belirli bir dalga boyu aralığındaki foton sayısının Avogadro sabitine ($6.022 \times 10^{23} \text{ mol}^{-1}$) bölünmesine dayanmakta olup 400-700 nm dalga boyu aralığında PAR’ı tanımlamak için yaygın olarak kullanılmaktadır (Apogee 2022b).



Şekil 3.15. PAR metre cihazı

Narenciye ağaçlarının olum dönemlerini kapsayan arazi çalışmalarının gerçekleştirildiği 12 Ekim 2021, 16 Kasım 2021 ve 16 Mart 2022 tarihlerinde tüm deneme

alanlarında 5 farklı noktada gerçekleştirilen ortalama PAR ölçümleri sonucu en düşük değer 16 Kasım 2022 tarihinde Washington ($814 \mu\text{mol m}^{-2} \text{s}^{-1}$) ve Clementine ($911 \mu\text{mol m}^{-2} \text{s}^{-1}$) deneme alanlarında kaydedilmiştir. Çalışma alanında en yüksek fotosentetik aktif radyasyon değerleri ise sırasıyla 12 Ekim 2021 tarihinde Satsuma ($1050 \mu\text{mol m}^{-2} \text{s}^{-1}$) ve 16 Mart 2022 tarihinde Valencia ($1767 \mu\text{mol m}^{-2} \text{s}^{-1}$) narenciye ağaçlarında ölçülmüştür.

3.1.7. Toprak verileri

Çalışma alanı toprak oluşumu ve toprak özellikleri açısından değerlendirildiğinde, alanda Sarı ve ark. (2008) tarafından yürütülen temel toprak ve etüd ve haritalama çalışmasında alana ait temel toprak özellikleri belirlenmiş olup yapılan çalışmada Canada Serisi olarak tespit edilen toprak serisi proje alanının bulunduğu kısmı kapsamaktadır. Canada (Cn) serisi toprakları, flüviyal nitelikli fizyografyadaki aluviyal taşkın düzlüğü ünitesinin allokon ana materyalleri üzerinde gelişmiş topraklar olarak tanımlanmıştır. Bu alanlar Quaterner yaşlı genç sedimentler üzerinde gelişmekte olan topraklar olup, A/C horizonludur. Çalışma alanını da kapsayan toprakların killi-tın, tın bünyeli, düz düze yakın, orta-fena drenajlı topraklar olduğu belirlenmiştir. Ayrıca deneme alanlarında benzer amenajman teknikleri uygulanmakla birlikte, meyve tutum döneminde (1200990 No'lu TÜBİTAK 1001 proje verileri) çalışma alanı topraklarında, her bir deneme alanını temsil edecek şekilde toprak örnekleme işlemleri gerçekleştirilmiştir (Şekil 3.16).



Şekil 3.16. Toprak örnekleme işlemleri; **a)** Meyve tutum başlangıcı **b)** Meyve tutum sonu

Elde edilen bulgulara göre deneme alanları topraklarının pH'larının nötr, EC değerlerinin tuzsuz, organik maddelerinin genel olarak humusça fakir, tekstürlerinin orta bünyeli, toplam azot içeriklerinin yeterli, alınabilir P içeriklerinin fazla, değişebilir K içeriklerinin 0-30 cm derinlikte yeterli iken, 30-40 cm derinlikte az sınıfına girdiği, değişebilir Ca içeriklerinin fazla, değişebilir Mg içeriklerinin yeterli, alınabilir Fe içeriklerinin fazla, alınabilir Mn içeriklerinin yeterli, alınabilir Zn içeriklerinin az ve alınabilir Cu içeriklerinin ise yeterli sınıfa girdiği tespit edilmiştir (Çizelge 3.5).

Çizelge 3.5. Toprak analiz sonuçları


Parametre		Satsuma				Clementine				Valencia				Washington			
		*Ö.B.		**Ö.S.		*Ö.B.		**Ö.S.		*Ö.B.		**Ö.S.		*Ö.B.		**Ö.S.	
		Derinlik (cm)		Derinlik (cm)		Derinlik (cm)		Derinlik (cm)		Derinlik (cm)		Derinlik (cm)		Derinlik (cm)		Derinlik (cm)	
		0-30	30-60	0-30	30-60	0-30	30-60	0-30	30-60	0-30	30-60	0-30	30-60	0-30	30-60	0-30	30-60
pH		6.96	7.03	6.88	6.97	7.11	7.13	7.10	7.22	7.12	7.19	7.31	7.21	7.10	7.17	7.23	7.20
EC		354	328	378	418	328	334	376	436	336	329	303	370	392	317	296	464
OM (%)		2.28	0.89	1.63	1.56	1.70	0.62	1.39	1.49	1.69	1.04	2.34	1.36	1.56	1.11	1.69	1.04
Kum (%)		37.96	53.68			40.6	34.96			31.68	31.68			35.68	37.68		
Kil (%)		23.04	21.04			25.04	26.32			31.04	29.04			31.04	26.32		
Silt (%)		42.00	25.28			34.00	38.72			37.28	39.28			33.28	36.00		
Tekstür		Tın	Siltli Killi Tın			Tın	Tın			Killi Tın	Killi Tın			Killi Tın	Tın		
Top. N (%)		0.16	0.12	0.15	0.13	0.15	0.11	0.15	0.13	0.15	0.10	0.16	0.12	0.18	0.13	0.15	0.12
P	(ppm)	77.55	64.79	56.83	43.32	67.05	73.05	43.17	44.37	71.55	76.35	73.80	61.94	64.04	52.18	53.23	55.63
K		183.73	82.60	128.91	140.3	149.7	81.80	171.29	141.52	162.42	76.23	153.85	105.97	191.1	92.3	103.7	119.4
Ca		4403.8	5064.9	5493.9	5771.9	4550.4	4897.9	4992.4	5340.6	5203.2	4684.2	5420.9	5615.7	4960.1	5138.6	4417.6	5306.7
Mg		311.6	430.3	470.22	473.55	6.35	467.0	416.2	463.8	463.3	501.1	549.3	538.9	441.2	509.8	300.2	463.9
Fe		14.610	8.853	10.524	4.767	9.113	9.107	8.845	9.803	8.371	8.293	8.575	7.081	8.275	8.012	7.134	7.036
Mn		14.35	5.843	10.523	3.016	13.303	8.366	12.594	12.762	10.371	7.043	8.651	6.504	10.284	6.528	7.48	7.968
Zn		0.272	0.050	0.177	0.041	0.195	0.050	0.160	0.174	0.157	0.040	0.193	0.159	0.175	0.068	0.197	0.242
Cu		6.872	1.629	3.158	1.652	4.759	1.629	2.896	2.906	3.379	1.155	2.934	1.851	3.916	1.589	2.404	2.197

*Örneklemeden önce **Örneklemeden sonra

3.2. Metot

Tez çalışması meyve olum dönemini kapsayan dört farklı çeşitteki narenciye ağaçları için, verilerin toplanması, veri tabanlarının oluşturulması, istatistiksel analizler, verim tahminlerinin elde edilmesi ve değerlendirme temel aşamalarından oluşmaktadır. Tezin arazi çalışmaları, İHA ve LiDAR verilerinin temini, yaprak örnekleme, yersel ölçüm verilerinin temin edilmesi aşamalarını kapsamaktadır. Laboratuvar çalışmaları ise İHA ve LiDAR verilerinin ön işleme, yaprak örneklerinin spektral değerlerinin elde edilmesi ve veri tabanlarının oluşturulması, İHA ve LiDAR verilerinden hem ağaç dendrometrik bileşenlerinin çıkarılması hem de İHA MS ve yersel hiperspektral verilerden görüntü zenginleştirme kapsamında bitki indeksi hesaplamaları, yaprak klorofil ölçümleri ve verime etki eden bağımsız değişkenler için veri tabanlarının oluşturulması, istatistiksel analizler, verim tahminlerinin oluşturulması ve değerlendirme aşamalarını kapsamaktadır (Şekil 3.17).






Şekil 3.17. İş akışı

3.2.1. İHA-LiDAR verilerinin alınması, ön işleme ve analiz

Deneme alanında LiDAR cihazı monte edilen Matrice 200 İHA ile planlanan otonom uçuşlar 50 m yükseklikten gerçekleştirilmiştir (Şekil 3.18). DJI Pilot uygulamasında planlanan otonom uçuşlardaki uçuş yüksekliğinin belirlenmesinde metrekarede elde edilebilecek nokta sayısı dikkate alınmıştır. İHA-LiDAR uçuşları her bir deneme alanındaki narenciye çeşidinin meyve olum dönemine denk gelen 3 farklı tarihte gerçekleştirilmiştir (Satsuma için 12 Ekim 2021, Washington ve Clementine için 16 Kasım 2021 ve Valencia için 16 Mart 2022).




Şekil 3.18. İHA-LiDAR operasyonları; **a)** İHA-LiDAR; **b)** Uçuşlar; **c)** Portakal deneme alanları için uçuş planı; **d)** Mandalina deneme alanları için uçuş planı

LiDAR cihazı takılan Matrice 200 V2 ile otonom uçuş operasyonuna başlamadan önce LiDAR cihazının kalibrasyon işlemlerinin gerçekleştirilmesi gerekmektedir. Bu kapsamda öncelikli olarak, deneme alanında açılan LiDAR cihazı açık bir alanda 5 dk hareketsiz bekletilmiştir. Daha sonra kalkış ve otonom uçuş güzergâhına girmeden önce İHA ile iki kez yukarı/aşağı olarak hızlanma ve yavaşlama işlemi ile position and

orientation systems (POS) sisteminin başlatılması tamamlanmıştır (0 m s^{-1} 'den 8 m s^{-1} 'ye hızlanma, ardından 0 m s^{-1} 'ye hızlı yavaşlama). Alandaki POS başlatma işlemi tamamlandıktan sonra belirlenen rotada uçuş görevi tamamlanmıştır. Başarılı bir şekilde tamamlanan uçuş görevinin ardından İHA iniş yapmadan önce yeniden hızlanma yavaşlama hareketi yapılmıştır. İniş işleminin ardından İHA iniş yapmadan önce yeniden hızlanma yavaşlama hareketi gerçekleştirilmiş ve iniş işleminin ardından 5 dakika bekledikten sonra LiDAR cihazı kapatılmıştır. Bu işlemler sonucu elde edilen ve inertial navigation system (INS) biriminde depolanan POS verileri ile LiDAR biriminde depolanan orijinal nokta bulutu verileri arazide kontrol edilerek işlem tamamlanmıştır.


İHA-LiDAR verilerinin ön işleme aşamasına başlamadan önce LiDAR cihazından alınan verilerin konumsal doğruluğunda kullanmak üzere deneme alanlarındaki narenciye ağaçlarının olum dönemlerinde gerçekleştirilen uçuş zamanlarına ait TUSAGA-Aktif Sabit GNSS İstasyonlarına ait Receiver Independent Exchange Format (RINEX) dosyaları temin edilmiştir. Daha sonra gerçekleştirilen iki aşamalı ve birbirini takip eden işlem adımları ile ham nokta bulutu verileri elde edilmiştir. Bu işlem adımlarından ilkinde POS data (*.T04) ve POSpac UAV (Applanix, Ontario, Canada) yazılımı kullanılarak trajectory (uçuş güzergahı) dosyası üretilmiştir. Ayrıca daha önceden tüm uçuş tekrarları için temin edilen RINEX dosyaları da konum doğruluğu amacıyla base station verileri olarak kullanılmıştır. Gerekli hassasiyet kontrollerinin ardından üretilen trajectory dosyası (*.out) bir sonraki işlem adımında kullanılmak üzere dışarı aktarılmıştır (Şekil 3.19). Çalışmada yörünge (trajectory) dosyalarının hassasiyet kontrolleri kapsamında POSpac UAV yazılımı kullanarak pozisyon doğruluğu, konum doğruluğu, PDOP değerleri ve baseline mesafe kontrolleri gerçekleştirilmiştir.



Şekil 3.19. Yörünge dosyası ve base station (ANTL) verileri; **a)** Portakal deneme alanları; **b)** ANTL verileri; **c)** Mandalina deneme alanları

İkinci alt işlem adımında orijinal nokta bulutu verileri (*.isf), bir önceki aşamada üretilen trajectory (*.out) dosyası ve StarSolve v1.1.7 (Surestar, Hefei, China) yazılımı (LiDAR sistemi üreticisinden excel formatında temin edilen parametre ve değerler)


kullanılarak tüm deneme alanları için üç tekrarlı nokta bulutu verileri (*.las) elde edilmiştir (Şekil 3.20).



Şekil 3.20. Nokta bulutu verileri; **a)** Tüm alanlar için 3 tekrarlı; **b)** Yakınlaştırılmış yoğun nokta bulutu verisi

Narenciye ağaçlarının meyve olum dönemindeki dendrometrik bileşenlerinin İHA-LiDAR verileri ile belirlenmesi aşaması, 120O990 numaralı proje kapsamında Doç.Dr. Nusret DEMİR'in katkısı ile gerçekleştirilen LiDAR verisi işleme çalışmalarında olduğu gibi gürültü giderme, filtreleme, kanopi modelleme ve ağaç tespiti işlem adımlarından oluşmaktadır. Gürültü giderme için Cloudcompare yazılımında ICP (Iterative Closest Point) yöntemi, gürültü filtrelemesi için CloudCompare yazılımında tanımlı SOR (Statistical Outlier Removal) filtresi uygulanmıştır. Proje kapsamında gerçekleştirilen çalışmada CloudCompare tarafından önceden tanımlı varsayılan parametreler, değişikliğe gidilmeden olduğu gibi kullanılmıştır (Şekil 3.21). Gürültü

etkileri giderilen verilerde ağaç ve araziye ait olan noktaların birbirinden ayrıştırılması için kumaş simülasyon filtresi (Cloth Simulation Filtering-CSF) yöntemi uygulanmıştır (Zhang vd. 2016). Ağaç yüksekliklerinin belirlenmesi amacıyla tepe noktaları ve taç genişlikleri Roussel vd. (2020) tarafından geliştirilen yöntem kullanılarak Dalponte ve Coomes (2016) tarafından geliştirilen yöntemle dayanarak ilgili tarama penceresinin boyutunun değişken olarak tasarlanmasıyla hesaplanmıştır.




Şekil 3.21. LiDAR verilerine uygulanan SOR filtresi ve parametreler **a) Öncesi; b) Sonrası**

3.2.2. Fotogrametrik ve MS-İHA verilerinin alınması, ön işleme ve analiz


Fotogrametrik ve MS-İHA verilerinin temini için gerçekleştirilecek uçuşlar öncesinde, bu verilerin ön işlem adımında geometrik düzeltme işlemlerinde kullanmak üzere tüm deneme alanlarında toplam 16 adet yer kontrol noktası (YKN) tesis edilerek bu noktaların ölçümleri CORS cihazı ile santimetre hassasiyetinde belirlenmiştir (Şekil 3.22). Narenciye ağaçlarının meyve olum dönemleri dikkate alındığında bu döneme en son ulaşan Valencia portakalı için 16 Mart 2022 tarihindeki arazi çalışmalarında deneme alanındaki YKN'ler kontrol edilerek eksik, kırık, dağılmış, yerinden oynamış ve rengi

solmuş olanlar için YKN'ler yeniden tesis edilmiştir. Daha sonra alandaki tüm YKN'lerin koordinat ve yükseklik değerleri CORS cihazı ile yeniden alınarak kaydedilmiştir.



Şekil 3.22. Yer kontrol noktaları ve ölçümü; **a)** YKN'ler; **b)** YKN ölçümleri

Çalışmada kullanılan narenciye ağaçlarından meyve olum dönemlerine ulaşan Satsuma mandalinası (Ekim ayı), Washington portakalı (Kasım ayı), Clementine (Kasım ayı) mandalinası ve Valencia portakalı deneme alanlarında İHA uçuşları yapılmıştır. Phantom 3 Advanced İHA ile tek ağaç bazında ağaç dendrometrik bileşenlerinin belirlenmesi amacıyla otonom uçuşlar planlanmış olup bu uçuşlar 55 m yükseklikten %80 üst ve %70 yan bindirme oranlarında ve normal hız modunda gerçekleştirilmiştir (Şekil 3.23).



Şekil 3.23. Fotogrametrik ve MS-İHA uçuşları; **a)** İHA uçuşları; **b)** RGB ve MS kamera; **c)** Mandalina deneme alanları uçuş planı; **d)** Portakal deneme alanları uçuş planı

Fotogrametrik ve MS-İHA verilerinin alınması amacıyla gerçekleştirilen İHA uçuşları sonrası, İHA'dan elde edilen ham verilerde görüntüleri yapılandırmak amacı ile sıkça kullanılan SfM ve çoklu görüş stereo (MVS) yaklaşımları ile Pix4Dmapper Pro (Pix4D Inc., Denver, USA) yazılımı kullanılarak alana ait ortomozaik görüntü, SYM ve SAM oluşturulmuştur. Bu işlem için Pix4Dmapper Pro yazılımında İHA ile çekilmiş bir dizi görüntüden 3 boyutlu bir model üretilebilmesi için önce SfM daha sonra MVS işlemleri uygulanmıştır.


Çalışma alanına ait veri işleme aşamasının ilk alt adımında, bağlantı noktaları oluşturmak üzere Pix4Dmapper Pro yazılımı tarafından otomatik olarak tüm görüntülerde mevcut olan belirli özellikler (keypoint) dikkate alınarak eşleştirme işlemi gerçekleştirilmiş ve görüntüler hizalanmıştır. Hizalama işleminin ardından her alan için uygulanan YKN'ler kullanılarak görüntülerin ortorektifikasyon işlemleri yapılmıştır. İşlemin ikinci alt adımında ise, yoğunlaştırılmış bir nokta bulutu ve üç boyutlu dokulu bir

ağ üretilmiştir. Son olarak daha önce oluşturulan nokta bulutuna dayalı olarak ters mesafe ağırlıklandırma yöntemi ile bir SYM oluşturulmuştur. Bu aşamada SYM'e ek olarak ortorektifiye edilmiş bir ortomozaik görüntü ile Pix4Dmapper Pro yazılımındaki ek modül kullanılarak SYM'e dayalı bir SAM oluşturulmuştur. Sayısal arazi modelinin yer örneklem mesafesi (GSD), ortomozaik görüntünün GSD'sinin Pix4Dmapper Pro yazılımında optimum değer olarak yer alan ve en yüksek değeri veren 5 katına ayarlanmıştır. Daha sonra elde edilen ve SYM'e göre 5 kat daha düşük çözünürlükte olan SAM'a uygulanan yeniden örnekleme (resampling) işlemi ile aynı tarihli tüm görüntülerin çözünürlükleri aynı değere ayarlanmıştır. Çalışmanın SYM, ortomozaik ve SAM işlem ayarları Çizelge 3.6'da verilmiştir. Çizelge 3.6'daki GSD değerleri her bir deneme alanı için gerçekleştirilen 3 tekrarlı İHA uçuşunun ortalama değerlerini göstermektedir.

Çizelge 3.6. Pix4Dmapper Pro işlem ayarları

Alt işlem adımı	Parametre	Ayar	
		Tarih	GSD (Ortalama)
SYM	Çözünürlük	12.10.2021 (Satsuma)	2.69 (cm pixel ⁻¹)
		16.11.2021 (Clementine)	2.67 (cm pixel ⁻¹)
		16.11.2021 (Washington)	2.60 (cm pixel ⁻¹)
		16.03.2022 (Valencia)	2.58 (cm pixel ⁻¹)
	Ortomozaik	SYM filtre: evet / Yüzey yumuşatma: evet / Tip: Sharp	
SAM	Raster SYM	Üretildi: evet / Metod: Ters mesafe ağırlıklandırma / Döşeme birleştirme: evet	
	Ortomozaik	Üretildi: evet / Döşeme birleştirme: evet	
	Raster SAM	Üretildi: evet / Çözünürlük: 5*GSD (cm pixel ⁻¹)	

İHA verilerinden deneme alanındaki nerenciye ağaçlarının ağaç taç yapılarının belirlenmesi, ağaç yükseklikleri ve ağaç taç alanlarının yarı otomatik olarak hesaplanması aşamasında, öncelikle tüm deneme alanlarındaki bireysel nerenciye ağaçlarının taç yapıları belirlenmiştir. Bu amaçla kullanılan temel veriseti olan ve bir önceki aşamada üretilen SYM ve SAM kullanılarak hesaplanan KYM ve dört bantlı ortomozaik görüntü üretimi işlem adımları Şekil 3.24'de verilmiştir. Bu işlem adımları ArcGIS (ESRI, California, USA) yazılımında yer alan ve CBS'de iş akışları oluşturmaya yönelik görsel bir programlama dili olan modelbuilder kullanılarak gerçekleştirilmiştir (ESRI 2022).




Şekil 3.24. Dört bant ortomozaik görüntü ve KYM üretimi işlem adımları

Modelbuilder kullanarak oluşturulan iş akışında iki temel işlem adımı bulunmaktadır. Bunlardan ilki olan ortomozaik görüntülerin üretilmesinde İHA'ya monte edilen hem RGB kameradan (RGB) hem de MS kameradan (NIR) alınan dört bant (mavi, yeşil, kırmızı ve yakın kızılötesi) kullanılmıştır. İkinci temel işlem adımı olan KYM'nin üretilmesinde SYM ve SAM kullanılmıştır. Kanopi yükseklik modeli, bu iki modelin (SYM ve SAM) ArcGIS yazılımında yer alan raster hesaplayıcısında (raster calculator) Eşitlik 3.1 kullanılarak üretilmiştir.

$$KYM = SYM - SAM \quad (3.1)$$

Alandaki narenciye ağaçlarının taç yapılarının belirlenmesinde eCognition yazılımı (Trimble Inc., Sunnyvale, CA, USA) kullanılmıştır. Özellikle nesne tespitinde kullanılan bu yazılımda objelerin belirlenmesi iki temel aşamadan oluşmaktadır. Bunlar segmentasyon ve sınıflandırma aşamalarıdır. Bu tez çalışmasında, en sık kullanılan segmentasyon yöntemlerinden biri olan çoklu çözünürlüklü segmentasyon (Multiresolution Segmentation-MRS) algoritması kullanılmıştır (Baatz ve Schape 2000; Selim vd. 2019; Nuijten vd. 2019; Çoşlu vd. 2021; Modica vd. 2021; Zhang vd., 2022). Bu kapsamda öncelikle KYM'ne MRS algoritması uygulanarak görüntü bölütlenmiştir (Şekil 3.25). Segmentasyon algoritmasında kullanılan ölçek parametresi 10, şekil ve bütünlük kriterleri ise sırasıyla 0.1 ve 0.5 olarak ayarlanmıştır. Bu değerler deneme yanılma yoluyla belirlenmiştir. Segmentasyon işleminin ardından ağaç nesnelerini belirlemek amacıyla elde edilen objelere öncelikle eşik değeri uygulanmış ve ağaç nesneleri diğer nesnelerden ayrılmıştır. Daha sonra ağaç nesnelerini temsil eden objeler eCognition yazılımında bölge birleştirme (merge region) algoritması ile birleştirilerek ağaç nesneleri elde edilmiştir. Bu aşamada son olarak obje tabanlı görüntü analizi ile edilen ağaç nesneleri shapefile (.shp) formatında dışarı aktararak veriler CBS ortamına taşınmıştır.




Şekil 3.25. Segmentasyon işlemi sonuçları; **a)** Tüm deneme alanları; **b)** Yakınlaştırılmış örnek bölgeler

Çalışmanın bir diğer aşamasında ise, MS-İHA verilerinden bitki indeksi hesaplama işlemleri gerçekleştirilmiştir. Bu işlem aşamasında öncelikli olarak RGN (kırmızı-yeşil-yakın kızılötesi) kameradan elde edilen görüntülerin ön işleme kapsamında kalibrasyon işlemleri gerçekleştirilmiştir. Kalibrasyon işleminde artan dalga boylarında ölçülen ve bilinen yansıma değerlerini içeren 4 hedefin olduğu MAPİR kamera yansıma kalibrasyonu yer hedef paketi kullanılmıştır (Şekil 3.26). Gerçekleştirilecek kalibrasyon işlemi ile görüntüler, bilinen bir yansıma standardına göre kalibre edilmiş olacak ve bu sayede farklı yerlerde, farklı saatlerde ve değişen aydınlatma koşullarında alınacak görüntülerin piksel değerleri yansıma yüzdelere dönüştürülerek daha sağlıklı bir şekilde karşılaştırılmaları mümkün olabilecektir (MAPİR 2022).



Şekil 3.26. MAPIR kamera yansıma kalibrasyonu; **a)** Yer hedef paketi (V2); **b)** Orijinal piksel değerleri; **c)** Kalibrasyon sonrası piksel değerleri (MAPIR 2022)

Alanda yürütülen çalışmalarda kalibrasyon işlemi için, görüntü alımlarına başlamadan önce Şekil 3.26'da görülen hedef paketin fotoğrafı çekilmiştir. Daha sonra çalışma alanında çekilen tüm görüntülerin piksel değerleri ile hedefin bilinen yansıma değerleri MAPIR Camera Control (MCC) (MAPIR, San Diego, CA 92126 USA) yazılımı kullanılarak karşılaştırılmış ve sonuçta kalibre edilmiş görüntüler ayrı bir klasöre kaydedilmiştir (Şekil 3.27).



Şekil 3.27. Görüntü kalibrasyon işlemi; **a)** MCC uygulaması; **b)** Kalibrasyon öncesi; **c)** Kalibrasyon sonrası

Deneme alanından İHA ile elde edilen MS görüntülerin kalibrasyon işlemi tamamlandıktan sonra bu veriler Pix4Dmapper Pro yazılımı ile işlenerek ortomozaik görüntü oluşturulmuştur. Ayrıca her ne kadar MS kamerasının üzerine harici bir GPS modülü takılmış olsa da hem konumsal hassasiyetin sağlanması hem de geometrik distorsiyonların giderilmesi (%-1 aşırı düşük bozulmaya sahip balıkgözü olmayan bir lens optiğine sahip olsa da) amacıyla çalışma alanındaki YKN'ler kullanılarak görüntülerin geometrik düzeltmeleri yapılmıştır. Tüm bu ön işlem adımlarından sonra MS kameradan alınan görüntülerdeki bu üç bant (R=660 nm, G=550 nm ve NIR=850 nm) kullanılarak Çizelge 3.7'deki bitki indeksleri hesaplanmıştır.

Çizelge 3.7. MS-İHA verilerinden hesaplanan bitki indeksleri

Bitki İndisi	Eşitlik	Kaynak
Normalize edilmiş fark bitki indeksi (NDVI)	$\frac{(NIR - Red)}{(NIR + Red)}$	Rouse vd. (1973)
Basit oran indeksi (SR)	$\frac{(NIR)}{(Red)}$	Birth ve McVey (1968)

3.2.3. Yaprak örneklemeleri, hiperspektral ölçümler ve indeks hesaplamaları

Tez çalışmasının bir diğer aşamasında ise meyve olum dönemindeki her bir narenciye bahçesinin hiperspektral yansıma karakteristiklerinin belirlenmesi ve bitkilere ait daha detaylı spektral analizlerin yapılabilmesi amacı ile yaprak örneklemeleri gerçekleştirilmiştir. Bu kapsamda, İHA uçuşları ile aynı tarihlere denk gelen ve narenciye ağaçlarının meyve olum dönemleri için en uygun dönemler olan 12 Ekim 2021, 16 Kasım 2021 ve 16 Mart 2022 tarihlerinde çalışma alanındaki her bir ağacın dört farklı yönünden yaprak örneklemeleri yapılmıştır. Yaprak örneklemeleri, Chapman (1964) tarafından tarif edildiği şekilde deneme alanlarındaki narenciye ağaçlarının üstten itibaren 5. ve 6. yaprakları alınarak gerçekleştirilmiştir (Şekil 3.28).



Şekil 3.28. Yaprak örneklemeleri

Deneme alanlarından toplanan yaprak örneklerinin hiperspektral yansıma özellikleri yersel hiperspektral algılayıcı kullanarak belirlenmiştir. Bu ölçüm işleminde ASD/FieldSpec Plant Probe+Leaf Clip spektoradyometre cihazı ve RS3 yazılımı kullanılmıştır (Şekil 3.29). Her narenciye çeşidi için spektral okumalara başlamadan önce beyaz referans (white reference) alçı bloktan yapılmış spektralon kullanılarak, ASD/FieldSpec spektoradyometre cihazının kalibrasyon işlemi gerçekleştirilmiştir. (Zhang ve Huang 2013). Yaprakların hiperspektral ölçümler sonrası elde edilen spektral değerleri, Viewspec yazılımı ile hem grafik veri hem de metin dosyası olarak dışarı aktarılmıştır.



Şekil 3.29. Yaprak örneklerinin hiperspektral ölçümleri

Narenciye ağaçlarında gerçekleştirilen hiperspektral ölçümler sonucu her bir deneme alanı için 637 olmak üzere toplam 2548 satırdan oluşan hiperspektral veri seti oluşturulmuştur. Spektrometrik ölçümlerle elde edilen bu veriler 325-1075 nm dalga boyu gibi geniş bir ölçüm aralığı içerdiğinden, veri karmaşasına neden olmamak ve bitkinin farklı dalga boylarındaki enerji kullanımını daha net ortaya koyabilmek ve ayrıca İHA'ya monte edilen çok bandlı kameralar ile entegrasyonu sağlamak amacı ile elektromanyetik spektrumun mavi (400-500 nm), yeşil (501-570 nm), kırmızı (610-700 nm) ve yakın kızılötesi (701-1075 nm) dalga boyu aralıklarında ayrı ayrı incelenmiştir (Campbell 2006; Crisp 2011). Her spektral bölgeye ait bu ortalama yansıma değerleri kullanılarak Çizelge 3.8'de verilen bitki indeksleri hesaplanmıştır.

Çizelge 3.8. Hiperspektral (yersel) verilerden hesaplanan bitki indeksleri

Bitki İndisi	*Eşitlik	Kaynak
Normalize edilmiş fark bitki indeksi (NDVI)	$\frac{(NIR - Red)}{(NIR + Red)}$	Rouse vd. (1973)
Basit oran indeksi (SR)	$\frac{(NIR)}{(Red)}$	Birth ve McVey (1968)
Hiperspektral normalize edilmiş fark bitki indeksi (HNDVI)	$\frac{(IR_{900} - Red_{685})}{(IR_{900} + Red_{685})}$	Rouse vd. (1973)
Normalize edilmiş pigment klorofil indeksi (NPCl)	$\frac{(Red_{680} - Blue_{430})}{(Red_{680} + Blue_{430})}$	Penuelas vd. (1994)

*NIR: Yakın kızılötesi, Red: Kırmızı, IR: Kızılötesi

3.2.4. Yersel ölçüm verileri

Narenciye bahçelerindeki yersel ölçüm verileri, yaprak klorofil ölçümleri, ağaç gövde yüksekliği ölçümleri ve verim değerleridir. Klorofil ölçümleri kapsamında deneme alanlarından toplanan ve hiperspektral ölçümlerde de kullanılan yaprak örneklerinde ölçümler yapılmıştır (Şekil 3.30).



Şekil 3.30. Yaprak klorofil ölçümleri; **a)** SPAD okuma kontrolü; **b)** Klorofil ölçümleri

Çalışmada narenciye ağaçlarının yaprak klorofil değerlerinin ölçülmesinde kullanılan SPAD502 klorofilmetre cihazı ile her narenciye çeşidinde ölçümlere başlamadan önce kalibrasyon işlemi ve okuma kontrolcüsü (reading checker) kullanılarak ölçülen değerlerin okuma kontrolcüsü üzerindeki değer aralığında olup olmadığı kontrol edilmiştir (Şekil 3.30). Cihaz kalibrasyonu ve okuma kontrolü işlemleri için cihazın kullanma klavuzunda yer alan işlem adımları uygulanmıştır (Konica Minolta 2022). Ağaç gövde yüksekliği kapsamında tezde deneme materyali olarak kullanılan tüm ağaçların (120 ağaç) gövde yükseklikleri ölçülmüştür (Şekil 3.31). Ağaç gövde yüksekliği ölçüm işlemi kapsamında şeritmetre kullanılarak ağaç gövdesinin toprak ile temas ettiği en alt nokta ile kanopinin başladığı üst nokta arasındaki yükseklik ölçülmüştür (Verma vd. 2016). Çalışmanın bağımlı değişkeni olan ve istatistiksel analiz kapsamında tahmin modelleri oluşturulan verim değerleri, deneme alanlarındaki narenciye bahçelerindeki tüm ağaçlar için BATEM'den temin edilmiştir.



Şekil 3.31. Ağaç gövde yüksekliği ölçümü

3.2.5. İstatistiksel analizler

Tez çalışmasından elde edilen verilerin istatistiksel analizleri aşamasında SPSS (IBM SPSS Statistics) yazılımından yararlanılmıştır. İstatistiksel analizler kapsamında öncelikle İHA'ya monte edilen kameradan elde edilen veriler kullanılarak hesaplanan ağaçların bazı dendrometrik özellikleri ile normal RGB kameralardan üretilen nokta bulutlarına göre oldukça hassas veriler sunan LiDAR cihazından hesaplanan dendrometrik özellikler arasındaki ilişkinin belirlenmesi amacıyla korelasyon analizleri gerçekleştirilmiştir.

Korelasyon analizleri öncesinde her bir deneme alanı ve her bir değişken için tanımlayıcı istatistik değerleri hesaplanmış ve verilerin normal dağılım gösterip göstermediği test edilmiştir. Bu kapsamda çalışmada kullanılan değişkenlerin çarpıklık (skewness) ve basıklık (kurtosis) değerleri, Shapiro-Wilk testi ve değişkenlik gösteren verilerin merkezi değeri ile bu değer etrafındaki dağılımın şeklini ortaya koymak için histogram grafikleri oluşturulmuştur. Normal dağılımı test etmek için kullanılan çarpıklık ve basıklık katsayılarının normal dağılımdan anlamlı düzeyde farklılık göstermemesi -1, +1 (Hair vd. 2013); -1.5, +1.5 (Tabachnick vd. 2007; Akoğlu vd. 2018) ve -2, +2 (George 2011; George ve Mallery 2019) aralığında olması beklenmektedir. Bu kapsamda -2, +2 arasının kabul edilebilir değer aralığı olduğu değerlendirilmiştir. Burada hesaplanan çarpıklık katsayısı 0'a eşit ise simetrik, 0'dan büyük (pozitif çarpıklık katsayısı) ise sağa çarpık, 0'dan küçük (negatif çarpıklık katsayısı) ise dağılımın sola çarpık olduğu anlamına gelmektedir. Basıklık katsayısının 0'a eşit olması normal dağılım, 0'dan büyük (pozitif basıklık katsayısı) olması sivri (dik) dağılım, 0'dan küçük (negatif basıklık katsayısı) olması ise basık dağılımı ifade etmektedir (Alaboz vd. 2020). Verilerin normal dağılıp dağılmadığının kontrol edildiği bir diğer yöntem olan Shapiro-Wilk testi (küçük örneklem büyüklükleri (<50 örneklem) için daha uygun bir yöntem) sonucu elde edilen p değerinin 0.05'den (%5 anlamlılık düzeyinde) büyük olması beklenmektedir. Bu durumda ($p>0.05$), sıfır hipotezi kabul edilmekte ve verilerin normal dağıldığı ifade edilmektedir (Mishra vd. 2019).

Çalışmanın korelasyon analizlerinde, veri dağılımlarından etkilenmeyen, özellikle normal dağılım göstermeyen verilerde kullanılan ve parametrik olmayan Spearman korelasyon analizi kullanılmıştır (Ampatzidis 2019; Myers ve Sirois 2006). Adını İngiliz Psikiyatr Charles Spearman'dan alan Spearman'ın sıralama korelasyon katsayısı, iki değişken arasında ilişki olup olmadığını ve bu ilişkinin yönünü ortaya koymaktadır. Parametrik olmayan bir korelasyon tekniği olan Spearman'ın sıralama korelasyon analizi mekan bilimciler tarafından yaygın olarak kullanılmaktadır (Çubukçu 2015). Bu aşamadan sonra narenciye ağaçlarının dendrometrik özellikleri ile ilgili elde edilen yüksek ilişki ve anlamlılık neticesinde, bu değişkenler için İHA verilerinin kullanılmasına karar verilmiştir. Daha sonraki aşamalarda da bir önceki aşamada olduğu gibi tüm değişkenler için normallik testleri, tanımlayıcı istatistik hesaplamaları ve korelasyon analizleri gerçekleştirilmiştir. Tüm deneme alanları aynı meteoroloji istasyonu bölgesinde olduğundan meteorolojik verilerin istatistiksel anlamda verim üzerine etkili olmayacağı değerlendirilmiş ve bu veriler istatistiksel analizlerde kullanılmamıştır.

Tezin istatistiksel analizler ve verim tahmini aşamasında kullanmak üzere bağımsız değişken olarak, narenciye ağaçlarının dendrometrik bileşenlerinden olan ağaç

gövde yüksekliği ve İHA'dan hesaplanan ağaç taç alanı ve ağaç yüksekliğinin yanı sıra yersel hiperspektral veriler ve İHA'dan hesaplanan bitki indeksleri belirlenmiştir. Tüm bu veri setleri excel ortamında birleştirilerek istatistiksel analize hazır hale getirilmiştir. Verim tahmini amacıyla gerçekleştirilecek istatistiksel analizlerde kullanılacak bağımsız ve bağımlı değişkenleri Çizelge 3.9'da görüldüğü gibidir.

Çizelge 3.9. Bağımlı ve bağımsız değişkenler

Bağımsız değişkenler				Bağımlı değişken
Hiperspektral Verilerden Hesaplanan İndisler (Yersel)	MS Verilerden Hesaplanan İndisler (İHA)	Ağaç Dendrometrik Bileşenleri (İHA ve Yersel)	Yaprak Klorofil Ölçümleri (SPAD)	Verim
• NDVI • SR • HNDVI • NPCI	• NDVI • SR	• Ağaç Taç Alanı (İHA) • Ağaç Yüksekliği (İHA) • Ağaç Gövde Yüksekliği (Yersel)	• Klorofil değerleri (SPAD birimi)	

3.2.6. Verim tahmin modelleri

Tarım teknolojileri ve hassas tarım faaliyetlerinde disiplinlerarası çalışmalar beraberinde büyük boyutlu ve yüksek performanslı verilerin işlenebildiği makine öğrenme tekniklerinin kullanımını da yaygınlaştırmıştır (Liakos vd. 2018). Makine öğrenme tekniklerinden biri olan ve genellikle çok fazla bağımsız değişkenin olduğu durumlarda kullanılan MLR modelinde kullanılan bu bağımsız değişkenler arasında korelasyonun olmaması ya da çok düşük olması yani çoklu bağlantı sorununun olmaması istenmektedir. Bu sorunun olduğu durumlarda regresyonun katsayıları daha yüksek çıkmakta ve bu da varyansın artmasına neden olabilmektedir. Çoklu bağlantı sorunu olan durumlarda elde edilecek değerlerle yapılacak modeller ve bu modellerden üretilen tahminler düşük olabilecektir. Yanlı regresyon tekniklerinden biri olarak ifade edilen ve özellikle kimyanın yanı sıra teknolojik çalışmalar ve uygulamalı araştırmalarda yaygın olarak kullanılan PLSR, çoklu bağlantı sorunu olan bağımsız değişkenlerin olduğu durumlarda kullanılabilen bir yöntemdir. Bu regresyon modelinde geleneksel regresyondan farklı olarak hem bağımsız hem de bağımlı değişkenin yapısı modellenmektedir (Wold vd. 2001; Polat ve Günay 2009; Nengsih vd. 2019). Varyans şişme faktörü (Variance Inflation Factors-VIF) değişkenler arasındaki çoklu bağlantı sorununun tespitinde sıkça kullanılan bir yöntemdir. Bu yöntem sonucu elde edilen VIF değerlerinin 10'a eşit ya da 10'dan büyük olması o veri için çoklu bağlantı sorunu olduğu anlamına gelmektedir. Ayrıca veri setinde gözlem sayısının az olması, bağımsız değişken sayısının fazla olması ve bu değişkenlerden doğrusal ilişkili olanların bulunması normal en küçük kareler analizinin varsayımlarından sapmalara neden olabilmektedir. Bu sapmalar da yapılacak regresyon analizinde düşük parametre tahminlerine yol açabilmektedir. Bu durumda istatistiksel bir analiz yöntemi olan PLSR, MLR analizi ile çalışılamayacak durumlarda etkili olabilmektedir (Bulut 2010). Kısaca PLSR'nin en

cazip yanı, bağımsız değişkenlerin doğrusal olarak bağımsız olması veya değişkenler arasında büyük oranda çoklu bağlantı sorunu olması gibi durumlarda daha az sayıda faktör ya da bileşenle sade bir model üretebilmesi ve normal olmayan veri dağılımını önleyebilmesidir (Polat 2009; Kasim vd. 2017; Fu vd. 2020).


PLSR'de, modeli elde etmede en çok kullanılan algoritmalar doğrusal olmayan yinelemeli en küçük kareler (NIPALS) ve PLS yönteminin istatistiksel olarak esinlenilmiş değişikliğinin basit bir uygulaması (SIMPLS) algoritmalarıdır. NIPALS algoritması, tek bir bağımlı değişken olduğunda PLS1 ve çoklu bağımlı değişken olduğunda ise PLS2 adını almaktadır. Ayrıca NIPALS algoritması eksik veriler üzerinde tahmin parametreleri de üretebilmektedir (Alin 2009; Polat 2014; Nengsih vd. 2019). Günümüzde gizli yapılar üzerine projeksiyon (projection on latent structures) olarak da adlandırılan PLSR, temel bileşen analizi (PCA) ve MLR'nin özelliklerini birleştiren ve genelleştiren yeni bir tekniktir. PLSR'nin amacı, bir dizi bağımsız değişkenden bir dizi bağımlı değişkeni tahmin etmektir. Bu tahmin, öngörücüler olan bağımsız değişkenlerden gizli adı verilen ve en iyi tahmin gücüne sahip bir dizi ortogonal faktörün çıkarılmasıyla elde edilmektedir. Bir PLSR modelinden elde edilen tahmini genelleştirme kapasitesi standart parametrik yaklaşımlarla değerlendirilememektedir. Bu nedenle PLSR'nin tahmin kalitesi, veri setinin parçalara ayrıldığı çapraz doğrulama (cross validation) veya önyükeme (bootstrap) gibi yeniden örnekleme teknikleriyle değerlendirilmektedir. Bu kapsamda kullanılan ve çapraz doğrulama tekniklerinden olan ve jackknife olarak da adlandırılan birini dışarıda bırakma (LOO) en popüler olan yöntemlerden biridir (Abdi 2003; Abdi 2010).

Bu tez çalışmasında gözlem sayısının az olması, bağımsız değişken sayısının fazla olması, bağımsız değişkenler arasında doğrusal ilişkili olanların bulunması ve bazı değişkenler için yüksek VIF değerlerinin elde edilmesi gibi nedenlerle verim tahmin modellerinin oluşturulmasında PLSR analizi kullanılmıştır. Çalışmada PLSR algoritmalarından NIPALS algoritması ve faktör seçiminde ise LOO yöntemi tercih edilmiştir. Verim tahmini için yapılan istatistiksel analizler sonucu elde edilen modelin veri seti ile uyum gücünün belirlenmesi amacıyla model değerlendirme kriterleri kullanılmıştır. Bu kriterler bağımsız değişkenlerin verim bağımlı değişkendeki değişimi açıklama yüzdesi, faktör sayıları ve tahmin edilen artık hata kareler toplamı (Root Mean Predicted Residual Error Sum of Squares-RMPRESS); model karşılaştırma sonuçlarının değerlendirilmesinde ise R^2 , RMSE ve MAE'dir.

4. BULGULAR VE TARTIŞMA

4.1. İHA-LiDAR Verilerinden Ağaç Dendrometrik Bileşenlerinin Belirlenmesi

Çalışmada, arazi uçuşları ile elde edilen ve sonrasında İHA-LiDAR nokta bulutu verilerinden üretilen narenciye ağaçlarının taç yapıları CBS ortamına aktarılmış ve yüksek çözünürlüklü İHA görüntüleri kullanılarak kontrol edilmiştir. Nokta bulutu verilerinden üretilen ağaç taç yapıları Şekil 4.1’de görüldüğü gibidir.



Şekil 4.1. Narenciye ağaçlarının taç yapıları (İHA-LiDAR)

İHA-LiDAR verilerinden elde edilen narenciye ağaçlarının ortalama taç alanları Çizelge 4.1’de verilmiştir. Buna göre Washington portakalı ağaçları için en düşük taç alanının 18.660 m^2 (W03), en yüksek taç alanının 39.967 m^2 (W25) ve ortalama taç alanının ise 30.439 m^2 olarak hesaplandığı tespit edilmiştir. Valencia portakalı deneme alanında, en düşük taç alanı 12.639 m^2 (V20) en yüksek taç alanı 34.797 m^2 (V09) ve ortalama taç alanı ise 27.317 m^2 olarak belirlenmiştir. Mandalina deneme alanlarından Clementine narenciye ağaçları için en düşük taç alanı 27.891 m^2 (C19) en yüksek taç alanı 46.191 m^2 (C04) ve ortalama taç alanı ise 36.394 m^2 olarak hesaplanmıştır. Satsuma mandalinası deneme alanı için ise en düşük taç alanı 13.053 m^2 (S27) en yüksek taç alanı 51.478 m^2 (S18) ve ortalama taç alanı ise 35.628 m^2 olarak tespit edilmiştir.

Çizelge 4.1. Narenciye ağaçlarının ortalama taç alanları (İHA-LiDAR)

ID	Ağaç Taç Alanı (m ²)	ID	Ağaç Taç Alanı (m ²)	ID	Ağaç Taç Alanı (m ²)	ID	Ağaç Taç Alanı (m ²)
W01	32.208	V01	19.376	C01	36.884	S01	49.212
W02	30.988	V02	22.431	C02	43.263	S02	37.480
W03	18.660	V03	28.454	C03	42.016	S03	15.966
W04	24.754	V04	32.349	C04	46.191	S04	36.204
W05	35.710	V05	30.116	C05	38.482	S05	42.366
W06	29.715	V06	31.138	C06	38.622	S06	35.872
W07	33.684	V07	29.582	C07	33.060	S07	41.721
W08	30.009	V08	27.362	C08	40.822	S08	36.253
W09	30.867	V09	34.797	C09	40.535	S09	39.603
W10	26.380	V10	21.345	C10	34.807	S10	39.482
W11	31.634	V11	29.272	C11	30.993	S11	42.807
W12	29.426	V12	27.850	C12	31.333	S12	37.335
W13	28.565	V13	33.208	C13	35.212	S13	26.161
W14	27.849	V14	18.121	C14	30.809	S14	40.423
W15	32.747	V15	31.803	C15	45.099	S15	39.816
W16	32.633	V16	28.829	C16	33.376	S16	37.893
W17	28.064	V17	33.667	C17	35.488	S17	25.198
W18	35.061	V18	25.880	C18	34.872	S18	51.478
W19	37.651	V19	25.510	C19	27.891	S19	38.544
W20	25.651	V20	12.639	C20	33.703	S20	28.607
W21	27.011	V21	34.695	C21	38.509	S21	33.841
W22	27.686	V22	26.001	C22	32.176	S22	19.173
W23	34.436	V23	23.391	C23	33.684	S23	38.469
W24	22.069	V24	34.763	C24	35.419	S24	43.628
W25	39.967	V25	23.961	C25	38.031	S25	36.445
W26	32.428	V26	21.147	C26	34.474	S26	41.375
W27	28.396	V27	28.094	C27	30.814	S27	13.053
W28	39.152	V28	33.652	C28	39.061	S28	42.484
W29	31.217	V29	31.970	C29	38.367	S29	39.026
W30	28.556	V30	18.099	C30	37.829	S30	18.936


İHA-LiDAR'dan hesaplanan ortalama ağaç yükseklik değerleri ise Çizelge 4.2'de verilmiştir. Çizelgeden de görüleceği üzere, Washington portakalı için en düşük değer 3.349 m (W03), en yüksek değer 4.944 m (W12) ve ortalama değer ise 4.312 m olarak hesaplanmıştır. Valencia portakalı deneme alanında, en düşük ağaç yüksekliği 2.138 m (V20) en yüksek ağaç 5.355 m (V28) ve ortalama ağaç yüksekliği ise 4.333 m olarak belirlenmiştir. Clementine mandalinası için ağaç yükseklik değerleri en düşük 4.361 m (C16) en yüksek 5.864 m (C20) ve ortalama 4.989 m'dir. Satsuma mandalinası deneme alanı için ise en düşük ağaç yüksekliği 1.756 m (S30), en yüksek değer 5.282 m (S15) ve ortalama değer ise 4.434 m olarak hesaplanmıştır.

Çizelge 4.2. Narenciye ağaçlarının ortalama yükseklikleri (İHA-LiDAR)


ID	Ağaç Yüksekliği (m)	ID	Ağaç Yüksekliği (m)	ID	Ağaç Yüksekliği (m)	ID	Ağaç Yüksekliği (m)
W01	3.916	V01	3.860	C01	4.681	S01	5.021
W02	4.272	V02	4.045	C02	5.505	S02	4.818
W03	3.349	V03	4.139	C03	5.226	S03	3.191
W04	4.583	V04	3.835	C04	5.351	S04	4.284
W05	4.402	V05	4.744	C05	5.606	S05	4.550
W06	3.899	V06	4.790	C06	5.500	S06	4.840
W07	4.097	V07	4.908	C07	4.875	S07	5.088
W08	4.471	V08	4.476	C08	5.555	S08	4.936
W09	4.118	V09	5.315	C09	4.520	S09	5.199
W10	4.601	V10	3.767	C10	5.174	S10	4.557
W11	4.830	V11	4.338	C11	4.658	S11	4.916
W12	4.944	V12	4.263	C12	4.522	S12	5.055
W13	4.037	V13	4.913	C13	4.891	S13	4.405
W14	4.206	V14	3.668	C14	4.756	S14	4.732
W15	4.092	V15	4.771	C15	5.037	S15	5.282
W16	4.563	V16	5.292	C16	4.361	S16	4.548
W17	4.285	V17	4.297	C17	4.739	S17	4.087
W18	4.930	V18	4.255	C18	4.793	S18	5.281
W19	4.716	V19	3.901	C19	5.151	S19	5.147
W20	3.770	V20	2.138	C20	5.864	S20	3.641
W21	4.619	V21	4.864	C21	5.127	S21	3.824
W22	3.752	V22	4.057	C22	4.678	S22	3.886
W23	4.849	V23	4.051	C23	4.476	S23	4.655
W24	4.032	V24	4.719	C24	4.738	S24	5.060
W25	4.322	V25	4.088	C25	5.256	S25	4.524
W26	4.514	V26	4.331	C26	4.613	S26	4.871
W27	4.311	V27	4.773	C27	4.391	S27	1.759
W28	4.271	V28	5.355	C28	5.315	S28	4.652
W29	4.386	V29	5.103	C29	5.070	S29	4.449
W30	4.379	V30	2.928	C30	5.239	S30	1.756

4.2. İHA Verilerinden Ağaç Dendrometrik Bileşenlerinin Belirlenmesi

Deneme alanında İHA ile yapılan uçuşlarda spektrumun görünür ve yakın kızılötesi bölgesinde elde edilen verilerde, ArcGIS yazılımı kullanılarak bant birleştirme (composite bands) işlemi gerçekleştirilmiştir. Söz konusu bu işlem ile üretilen her bir narenciye çeşidi için, bir döneme ait örnek dört bantlı veri setleri Şekil 4.2’de gerçek renk kombinasyonunda ve Şekil 4.3’de ise yanlış renk kombinasyonunda verilmiştir.




Şekil 4.2. Dört bant İHA görüntüleri (Gerçek renk kombinasyonu)




Şekil 4.3. Dört bant İHA görüntüleri (Yanlış renk kombinasyonu)

Çalışmanın yöntem kısmında da açıklandığı üzere, meyve olum dönemindeki narenciye ağaçlarının KYM'leri de oluşturulmuştur. Sayısal yükseklik modeli ile sayısal arazi modeli kullanarak oluşturulan ağaç KYM'leri Şekil 4.4'de görüldüğü gibidir.




Şekil 4.4. Kanopi yükseklik modelleri

İHA verilerinden hesaplanan kanopi yükseklik modelleri, daha sonrasında obje tabanlı görüntü analizi ile segmente edilmiş ve eşik değeri sınıflandırma yöntemi ile ağaç nesneleri çıkarılmıştır. Çıkarılan bu ağaç nesneleri, CBS ortamında hem doğru renk kombinasyonu hem de yanlış renk kombinasyonu görüntülerinin altlık veri setleri olarak kullanılmasıyla kontrol edilmiş ve sonrasında yapılan değerlendirmeye göre, fotogrametrik İHA yöntemiyle ağaç taç yapılarının oldukça başarılı bir şekilde belirlenebildiği görülmüştür (Şekil 4.5).



Şekil 4.5. Narenciye ağaçlarının taç yapıları (İHA)

Tüm bu işlemlerden sonra ise deneme alanlarındaki narenciye ağaçlarının öznitelik tablolarına ID'leri girilerek ağaç taç yapılarını gösteren poligonların geometrileri hesaplanmıştır. Üç tekrarlı gerçekleştirilen ağaç taç alanı hesaplamalarına göre elde edilen değerlerin birbirine oldukça yakın olduğu tespit edilmiştir (Şekil 4.6).




Şekil 4.6. Narenciye ağaçlarının taç alanları grafiği (İHA); **a)** Washington; **b)** Valencia; **c)** Clementine; **d)** Satsuma

Narenciye ağaçlarının üç tekrarlı taç alanlarını gösteren grafikler ve ortalama alansal değerlerinin yer aldığı Çizelge 4.3 incelendiğinde; Washington portakalı ağaçları için en düşük taç alanının 14.096 m^2 (W03), en yüksek taç alanının 33.208 m^2 (W25) ve ortalama taç alanının ise 25.333 m^2 olarak hesaplandığı tespit edilmiştir. Valencia portakalı deneme alanında, en düşük taç alanı 8.764 m^2 (V20) en yüksek taç alanı 28.852 m^2 (V24) ve ortalama taç alanı ise 22.308 m^2 olarak belirlenmiştir. Portakal deneme alanlarına göre daha büyük taç yapılarına sahip olan mandalina deneme alanlarından Clementine narenciye ağaçları için en düşük taç alanı 23.481 m^2 (C19) en yüksek taç alanı 43.258 m^2 (C04) ve ortalama taç alanı ise 32.622 m^2 olarak hesaplanmıştır. Satsuma mandalinası deneme alanı için ise en düşük taç alanı 9.089 m^2 (S27) en yüksek taç alanı 42.306 m^2 (S18) ve ortalama taç alanı ise 29.284 m^2 olarak tespit edilmiştir.

Çizelge 4.3. Narenciye ağaçlarının ortalama taç alanları (İHA)

ID	Ağaç Taç Alanı (m ²)	ID	Ağaç Taç Alanı (m ²)	ID	Ağaç Taç Alanı (m ²)	ID	Ağaç Taç Alanı (m ²)
W01	27.625	V01	14.192	C01	33.753	S01	41.688
W02	25.582	V02	18.242	C02	37.776	S02	29.144
W03	14.096	V03	23.174	C03	39.558	S03	11.857
W04	21.641	V04	26.968	C04	43.258	S04	27.756
W05	29.215	V05	26.585	C05	36.080	S05	34.726
W06	24.722	V06	24.196	C06	37.098	S06	33.977
W07	27.268	V07	25.020	C07	29.903	S07	31.697
W08	25.178	V08	22.431	C08	38.803	S08	26.223
W09	24.979	V09	28.634	C09	37.522	S09	32.071
W10	21.376	V10	18.553	C10	28.061	S10	31.946
W11	28.627	V11	23.702	C11	28.132	S11	35.984
W12	24.096	V12	20.651	C12	26.460	S12	30.171
W13	23.694	V13	25.615	C13	31.146	S13	20.287
W14	22.919	V14	11.982	C14	27.582	S14	33.648
W15	28.431	V15	26.329	C15	41.059	S15	36.081
W16	28.343	V16	23.448	C16	28.159	S16	32.456
W17	23.208	V17	28.056	C17	30.565	S17	18.885
W18	28.514	V18	21.370	C18	32.193	S18	42.306
W19	30.912	V19	22.362	C19	23.481	S19	31.617
W20	21.966	V20	8.764	C20	31.909	S20	24.998
W21	22.593	V21	28.149	C21	34.191	S21	28.750
W22	24.284	V22	22.615	C22	27.012	S22	12.931
W23	29.215	V23	20.321	C23	28.436	S23	32.962
W24	17.277	V24	28.852	C24	30.797	S24	39.849
W25	33.208	V25	19.795	C25	33.205	S25	33.322
W26	26.014	V26	17.740	C26	29.532	S26	35.012
W27	23.531	V27	23.327	C27	25.435	S27	9.089
W28	30.357	V28	26.829	C28	36.433	S28	34.240
W29	28.187	V29	27.224	C29	36.672	S29	31.171
W30	22.927	V30	14.114	C30	34.442	S30	13.675

Deneme alanlarındaki narenciye ağaçlarının yüksekliklerinin hesaplanmasında temel veriseti olarak KYM kullanılmıştır. Bu kapsamda daha önce belirlenen ağaç taç alanlarını gösteren poligonlar ve mekânsal analiz araçları arasında yer alan bölgesel istatistik (zonal statistic as table) aracı kullanılarak ağaç yükseklikleri belirlenmiştir. Ağaç yükseklikleri tespit edilirken her bir ağaç tacı içerisindeki yüksekliklerin maksimum değerleri tüm poligonlar için ayrı ayrı otomatik olarak hesaplanmıştır. Hesaplanan ağaç yüksekliklerine göre elde edilen değerlerin ağaç taç alanlarında olduğu gibi birbirine oldukça yakın olduğu tespit edilmiştir (Şekil 4.7).



Şekil 4.7. Narenciye ağaçlarının yükseklik grafiği (İHA); **a)** Washington; **b)** Valencia; **c)** Clementine; **d)** Satsuma

Tüm deneme alanlarındaki narenciye ağaçlarının üç tekrarlı yükseklik değerleri Şekil 4.7’de ve ortalama yükseklik değerleri ise Çizelge 4.4’de verilmiştir. Ağaç yükseklik değerlerine göre; Washington portakalı için en düşük değer 3.229 m (W03), en yüksek değer 4.688 m (W23) ve ortalama değer ise 4.181 m olarak belirlenmiştir. Valencia portakalı deneme alanında, en düşük ağaç yüksekliği 2.284 m (V20) en yüksek ağaç 4.866 m² (V16) ve ortalama ağaç yüksekliği ise 4.136 m’dir. Clementine mandalinası için ağaç yükseklik değerleri en düşük 4.355 m (C16) en yüksek 5.377 m (C20) ve ortalama 4.825 m’dir. Satsuma mandalinası deneme alanı için ise en düşük ağaç yüksekliği 2.579 m (S27), en yüksek değer 4.987 m (S09) ve ortalama değer ise 4.110 m olarak hesaplanmıştır.

Çizelge 4.4. Narenciye ağaçlarının ortalama yükseklikleri (İHA)

ID	Ağaç Yüksekliği (m)	ID	Ağaç Yüksekliği (m)	ID	Ağaç Yüksekliği (m)	ID	Ağaç Yüksekliği (m)
W01	3.962	V01	3.716	C01	4.493	S01	4.575
W02	4.240	V02	3.880	C02	5.145	S02	4.555
W03	3.229	V03	3.813	C03	5.106	S03	3.171
W04	4.092	V04	3.844	C04	5.114	S04	3.965
W05	4.023	V05	4.329	C05	5.166	S05	4.074
W06	4.186	V06	4.513	C06	5.090	S06	3.867
W07	4.351	V07	4.389	C07	4.583	S07	4.266
W08	4.036	V08	4.240	C08	5.077	S08	4.093
W09	4.134	V09	4.791	C09	4.699	S09	4.987
W10	4.074	V10	3.466	C10	4.693	S10	4.355
W11	4.484	V11	4.151	C11	4.393	S11	4.767
W12	4.679	V12	4.342	C12	4.364	S12	4.697
W13	4.202	V13	4.462	C13	4.554	S13	4.045
W14	4.044	V14	3.832	C14	4.550	S14	4.247
W15	4.343	V15	4.246	C15	5.146	S15	4.633
W16	4.414	V16	4.866	C16	4.355	S16	4.018
W17	4.247	V17	4.298	C17	4.847	S17	3.577
W18	4.439	V18	4.273	C18	4.443	S18	4.414
W19	4.274	V19	4.048	C19	5.017	S19	4.387
W20	3.652	V20	2.284	C20	5.377	S20	3.805
W21	4.363	V21	4.606	C21	4.950	S21	4.024
W22	3.684	V22	4.435	C22	4.411	S22	3.658
W23	4.688	V23	3.913	C23	4.924	S23	4.128
W24	3.823	V24	4.093	C24	4.881	S24	4.356
W25	4.097	V25	4.234	C25	4.885	S25	3.947
W26	4.477	V26	3.709	C26	4.812	S26	4.473
W27	4.286	V27	4.677	C27	4.525	S27	2.579
W28	4.456	V28	4.495	C28	4.988	S28	4.589
W29	4.011	V29	4.686	C29	5.062	S29	4.373
W30	4.445	V30	3.447	C30	5.113	S30	2.663

4.3. İHA-LiDAR ve Fotogrametrik İHA Verilerinin Korelasyon Analizi

Çalışmanın bu aşamasında, fotogrametrik olarak İHA verilerinden üretilen ağaç dendrometrik veri setlerinin güvenilirliğini test edebilmek amacı ile yer gerçeği olarak kabul edilen İHA-LiDAR verileri arasındaki ilişkilerin sorgulanması işlemi gerçekleştirilmiştir. Bu kapsamda İHA-LiDAR ve fotogrametrik İHA verilerinin korelasyon analizleri öncesinde taç alanları ve yükseklikler için tanımlayıcı istatistik değerleri hesaplanmıştır. Çizelge 4.5’de verilen tanımlayıcı istatistik değerlerine göre, Washington deneme alanında İHA-LiDAR ile hesaplanan ağaç taç alanı için ortalama değer 30.440 m² ve değişkenlik katsayısı %15.424 iken, fotogrametrik İHA ile fotogrametrik olarak hesaplanan ağaç taç alanı ortalama değer 25.333 m² ve değişkenlik

katsayısı %15.896 olarak belirlenmiştir. Ayrıca Washington deneme alanında İHA-LiDAR ile hesaplanan ortalama ağaç yükseklik değeri 4.317 m ve değişkenlik katsayısı %8.663 iken İHA ile fotogrametrik olarak hesaplanan ortalama ağaç yüksekliği 4.181 m ve değişkenlik katsayısı ise %7.438 olarak hesaplanmıştır.

Çizelge 4.5. Washington ağaç dendrometrik özelliklerinin tanımlayıcı istatistik değerleri

Değişken	N	Minimum	Maksimum	Ortalama	Standart Sapma	Değişkenlik Katsayısı (%)
LiDAR Taç alanı	30	18.660	39.967	30.440	4.695	15.424
İHA Taç alanı	30	14.096	33.208	25.333	4.027	15.896
LiDAR Yükseklik	30	3.349	4.944	4.317	0.374	8.663
İHA Yükseklik	30	3.229	4.688	4.181	0.311	7.438

Çizelge 4.6’da Valencia ağaçlarının tanımlayıcı istatistik değerleri incelendiğinde ise, LiDAR ile hesaplanan taç alanı için ortalama değer 27.317 m² ve değişkenlik katsayısı %21.099 olarak belirlenmiş iken, İHA ile hesaplanan taç alanı için ortalama değer 22.308 m² ve değişkenlik katsayısı ise %23.042’dir. Yine, Valencia ağaçları için LiDAR verileri ile hesaplanan yükseklik verilerinin ortalama değeri 4.333 m ve değişkenlik katsayısı %16.017 iken, İHA verileri ile yükseklik hesaplamalarının ortalama değeri 4.136 m ve değişkenlik katsayısı ise %12.366 olarak tespit edilmiştir.

Çizelge 4.6. Valencia ağaç dendrometrik özelliklerinin tanımlayıcı istatistik değerleri

Değişken	N	Minimum	Maksimum	Ortalama	Standart Sapma	Değişkenlik Katsayısı (%)
LiDAR Taç alanı	30	12.639	34.797	27.317	5.764	21.099
İHA Taç alanı	30	8.764	28.852	22.308	5.140	23.042
LiDAR Yükseklik	30	2.138	5.355	4.333	0.694	16.017
İHA Yükseklik	30	2.284	4.866	4.136	0.511	12.366

Clementine ağaçlarının tanımlayıcı istatistik değerleri Çizelge 4.7’de verilmiştir. Çizelgeden görüleceği üzere, LiDAR ile hesaplanan taç alanı için ortalama değer 36.394 m² ve değişkenlik katsayısı %12.190, İHA ile hesaplanan taç alanı için ortalama değer 32.622 m² ve değişkenlik katsayısı ise %15.352’dir. Ayrıca Clementine deneme alanında LiDAR ile hesaplanan ağaç yükseklik verilerinin ortalama değeri 4.989 m ve değişkenlik katsayısı %8.021 iken, İHA ile fotogrametrik olarak hesaplanan ağaç yükseklik özelliği için ortalama değer 4.825 m ve değişkenlik katsayısı %6.130 olarak belirlenmiştir.

Çizelge 4.7. Clementine ağaç dendrometrik özelliklerinin tanımlayıcı istatistik değerleri

Değişken	N	Minimum	Maksimum	Ortalama	Standart Sapma	Değişkenlik Katsayısı (%)
LiDAR Taç alanı	30	27.891	46.191	36.394	4.437	12.190
İHA Taç alanı	30	23.481	43.258	32.622	5.008	15.352
LiDAR Yükseklik	30	4.361	5.864	4.989	0.400	8.021
İHA Yükseklik	30	4.355	5.377	4.825	0.296	6.130

Çizelge 4.8’de verilen Satsuma ağaçlarının tanımlayıcı istatistik değerleri incelendiğinde ise, LiDAR ile hesaplanan ağaç taç alanı için ortalama değer 35.628 m² ve değişkenlik katsayısı %26.177, İHA ile hesaplanan ağaç taç alanı için ortalama değer 29.284 m² ve değişkenlik katsayısı %29.516 olarak belirlenmiştir. Ayrıca Valencia deneme alanında LiDAR ile belirlenen ağaç yükseklik özelliği için ortalama değer 4.434 m ve değişkenlik katsayısı %19.920, İHA ile belirlenen yükseklik özelliği için ise ortalama değer 4.110 m ve değişkenlik katsayısı %13.575’dir.

Çizelge 4.8. Satsuma ağaç dendrometrik özelliklerinin tanımlayıcı istatistik değerleri

Değişken	N	Minimum	Maksimum	Ortalama	Standart Sapma	Değişkenlik Katsayısı (%)
LiDAR Taç alanı	30	13.053	51.478	35.628	9.327	26.177
İHA Taç alanı	30	9.089	42.306	29.284	8.644	29.516
LiDAR Yükseklik	30	1.756	5.282	4.434	0.883	19.920
İHA Yükseklik	30	2.579	4.987	4.110	0.558	13.575

Çalışmada, narenciye ağaçlarına ait tanımlayıcı istatistik değerleri hesaplandıktan sonra, yer gerçeği olarak kabul edilen İHA-LiDAR verileri ile İHA’dan fotogrametrik yöntem ile üretilen taç alanı ve ağaç yüksekliği verileri arasında korelasyon analizleri gerçekleştirilmiş ve böylelikle fotogrametrik yöntemin güvenilirliği test edilmiştir. Bu kapsamda yapılacak olan korelasyon analizleri öncesi, verilerin normal dağılıp dağılmadığı kontrol edilmiştir. Bu aşamada çarpıklık (skewness) ve basıklık (kurtosis) değerleri, Shapiro-Wilk testi ve histogram grafikleri oluşturulmuştur (Çizelge 4.9). Çarpıklık ve basıklık katsayıları için her ne kadar literatürde farklı değer aralıkları (-1, +1; -1.5, +1.5; -2, +2; -3, +3) kabul edilmiş olsa da bu çalışmada diğer çalışmalarda olduğu gibi bu katsayılar için genel kabul gören -2, +2 (George 2011; George ve Mallery 2019) aralığında olması kabul edilmiştir.

Çizelge 4.9. Çarpıklık-basıklık değerleri ve Shapiro-Wilk normallik testi sonucu

Değişken	Test	Washington	Valencia	Clementine	Satsuma
LiDAR-Taç alanı	Çarpıklık	-0.147	-0.681	0.371	-0.989
	Basıklık	0.565	-0.113	-0.235	0.558
	Shapiro-Wilk	0.933	0.120	0.728	0.004*
İHA-Taç alanı	Çarpıklık	-0.617	-0.943	0.236	-0.966
	Basıklık	1.064	0.478	-0.747	0.320
	Shapiro-Wilk	0.330	0.035*	0.740	0.006*
LiDAR-Yükseklik	Çarpıklık	-0.385	-1.098	0.287	-2.022
	Basıklık	0.213	2.383*	-0.814	4.199
	Shapiro-Wilk	0.793	0.026*	0.394	0.000*
İHA-Yükseklik	Çarpıklık	-1.005	-1.642	-0.183	-1.272
	Basıklık	1.893	4.755*	-1.246	1.890
	Shapiro-Wilk	0.085	0.003*	0.043*	0.008*


*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılmayan veriler

Çizelge 4.9’da Washington, Valencia, Clementine ve Satsuma ağaçları için hesaplanan çarpıklık ve basıklık katsayıları incelendiğinde, çarpıklık ve basıklık katsayılarına göre, Washington ve Clementine deneme alanları için tüm değişkenler normal dağılım gösterdiği belirlenmiştir. Yapılan değerlendirmede, Valencia deneme alanı için LiDAR-Yükseklik ve İHA-Yükseklik değişkenleri normal dağılım göstermediği ortaya çıkmıştır. Satsuma deneme alanı için yapılan değerlendirmede ise çarpıklık ve basıklık değerlerine göre, LiDAR-Yükseklik değişkeni normal dağılım göstermemektedir.

Çizelge 4.9’da ayrıca Shapiro-Wilk normalite testi sonuçları da verilmiştir. Test sonuçlarına göre, elde edilen değerlerin 0.05’den (%5 anlamlılık düzeyinde) büyük olması beklenmektedir. Çizelgeye göre Valencia deneme alanı için, İHA-Taç alanı, LiDAR-Yükseklik ve İHA-Yükseklik; Clementine deneme alanı için İHA-Yükseklik; Satsuma deneme alanı için, LiDAR-Taç alanı, İHA-Taç alanı, LiDAR-Yükseklik ve İHA-Yükseklik değişkenlerinin normal dağılım göstermediği belirlenmiştir. Tüm deneme alanlarında hem çarpıklık-basıklık hem de Shapiro-Wilk normalite testi sonuçlarına göre özellikle LiDAR-Yükseklik verilerinin normal dağılmadığı tespit edilmiştir.


Washington deneme alanı için Şekil 4.8’de verilen histogram grafikleri incelendiğinde, tüm verilerin normal dağılım gösterdiği görülmektedir. Bu grafikler çarpıklık ve basıklık katsayıları ile birlikte değerlendirildiğinde (pozitif çarpıklık katsayısı sağa çarpık dağılımı, negatif çarpıklık katsayısı sola çarpık dağılımı; pozitif basıklık katsayısı sivri dağılımı, negatif basıklık katsayısı ise basık dağılımı ifade eder)

bu alanda normal dağılım gösteren tüm değişkenler için çarpıklık katsayısının negatif olması dağılımın hafif sola çarpık ve basıklık katsayısının pozitif olması ise dağılımın hafif dik olduğunu göstermektedir.




Şekil 4.8. Washington deneme alanı histogram grafikleri

Valencia deneme alanı için histogram grafikleri Şekil 4.9’da verilmiştir. Şekil 4.9 incelendiğinde, LiDAR-Taç alanı için verilerin hafif sola çarpık ve hafif basık olduğu; İHA-Taç alanı için hafif sola çarpık ve hafif sivri olduğu; LiDAR-Yükseklik ve İHA-Yükseklik verileri için ise sola çarpık ve basık olduğu tespit edilmiştir.




Şekil 4.9. Valencia deneme alanı histogram grafikleri

Çarpıklık ve basıklık değerlerine göre normal dağılım gösteren Clementine deneme alanı verileri ve histogram grafiklerine göre, LiDAR-Taç alanı, İHA-Taç alanı ve LiDAR-Yükseklik verileri hafif sağa çarpık ve hafif basık dağılım gösterirken; İHA-Yükseklik verileri hafif sola çarpık ve basık dağılım göstermektedir (Şekil 4.10).



Şekil 4.10. Clementine deneme alanı histogram grafikleri

Satsuma deneme alanı histogram grafikleri ve çarpıklık-basıklık katsayılarına göre, LiDAR-Taç alanı ve İHA-Taç alanı verileri hafif sola çarpık ve hafif sivri, LiDAR-Yükseklik ve İHA-Yükseklik verileri ise sola çarpık ve dik dağılım göstermektedir.



Şekil 4.11. Satsuma deneme alanı histogram grafikleri

Yapılan değerlendirmeler sonucunda, İHA-LiDAR ve Fotogrametrik İHA verilerinden bazılarının normal dağılım göstermemesi nedeniyle parametrik olmayan korelasyon analizleri gerçekleştirilmiştir. Bu kapsamda Eşitlik 4.1’de verilen Spearman’ın sıralama korelasyon katsayıları (*Spearman’s rank correlation coefficient* veya *Spearman’s rho*) hesaplanmıştır.

$$\rho = 1 - \frac{6 \sum_{i=1}^n (x_i - y_i)^2}{n(n^2 - 1)} \quad (4.1)$$

Korelasyon katsayısı eşitliğinde yer alan x_i , i gözleminin x değişkenindeki sırasını, y_i , i gözleminin y değişkenindeki sırasını ve n de gözlem sayısını göstermektedir. Spearman’ın sıralama korelasyon katsayısı -1 ile 1 arasında değer almakta ve katsayının pozitif olması durumunda incelenen iki değişken arasında doğru ilişki olduğu, negatif

olması durumunda ise ters ilişki olduğu anlaşılmaktadır. Kısacası katsayının +1'e yakın olması güçlü ve pozitif ilişkiyi, -1'e yakın olması ise güçlü negatif ilişkiyi ifade etmektedir. Ayrıca bu korelasyon katsayısının 0 ya da 0'a yakın değerler alması iki değişken arasında ilişkinin çok zayıf ya da hiç olmadığı anlamına gelmektedir. İki değişken arasında ilişki olduğunun istatistiksel olarak anlamlı kabul edilebilmesi için $|r| \geq r_{\alpha}$ koşulunun sağlanması yani yokluk hipotezinin reddedilmesi gerekmektedir (Çubukçu 2015).

Çizelge 4.10. Spearman'ın korelasyon katsayıları


Değişken	Washington	Valencia	Clementine	Satsuma
Ağaç taç alanı	0.968**	0.983**	0.962**	0.897**
Ağaç yüksekliği	0.623**	0.858**	0.793**	0.807**

**Correlation is significant at the 0.01 level (2-tailed).

Yapılan analizler sonucunda, deneme alanlarındaki narenciye ağaçlarının taç alanları ve ağaç yükseklikleri için hesaplanan Spearman sıralama korelasyon katsayılarına ait bulgulara göre, LiDAR ve İHA verilerinden hesaplanan hem ağaç taç alanı hem de ağaç yükseklikleri arasında aynı yönde ve güçlü bir ilişki olduğu ortaya çıkmıştır (Çizelge 4.10). İki veri seti arasında en güçlü ilişki (0.983) ağaç taç alanları değişkeninde ve Valencia çeşidinde tespit edilmiştir. Elde edilen sonuçların istatistiksel olarak anlamlı olup olmadığının test edilmesi sonucunda; örneklem büyüklüğü 30 olduğunda, Spearman'ın sıralama korelasyon katsayısı çift kuyruklu eşik değeri $\alpha=0.05$ güven düzeyinde 0.362 ve $\alpha=0.05$ güven düzeyinde 0.467'dir (Çubukçu 2015; Zar 1972). Bu durumda hesaplanan tüm korelasyon katsayılarının tamamı her iki güven düzeyi için belirlenen eşik değerlerden büyük olduğundan ($|r| \geq r_{\alpha}$) yokluk hipotezi reddedilmektedir. Yani bu değişkenler arasında $\alpha=0.01$ (%1) ve $\alpha=0.05$ (%95) güven düzeyinde istatistiksel açıdan anlamlılık olduğu belirlenmiştir. Nitekim Hobart vd. (2020) tarafından elma ağaçlarında İHA fotogrametrisi kullanılarak gerçekleştirilen çalışmada elde edilen sonuçlar referans olarak alınan LiDAR verileri ile karşılaştırıldığında oldukça yüksek korelasyonlar tespit edilmiştir. Bu tez çalışmasından elde edilen sonuçlar araştırmacı ile paralellik göstermektedir.


4.4. Yersel Hiper spektral Verilerden Hesaplanan Bitki İndeks Değerleri

Çalışma alanında İHA uçuşları ile eş zamanlı olarak her bir narenciye ağacından yaprak örneklemeleri yapılmış ve söz konusu bu örneklerde, leaf-clip kullanılarak spektrumun 325-1075 nm dalgaboyu aralığında ASD spektrometresi ile spektral ölçümler gerçekleştirilmiştir. Bu ölçümler neticesinde deneme alanında bireysel ağaç düzeyinde meyve olum dönemindeki narenciye bahçelerinin yansıma karakteristikleri ortaya konulmuştur. Şekil 4.12' den de görüleceği üzere, tüm deneme alanlarındaki portakal ve mandalina ağaçları tipik bitki yansıtımı özelliği göstermiştir. Nitekim narenciye ağaçları, diğer bitki türlerinde olduğu gibi spektrumun mavi ve kırmızı dalga boyu bölgesinde enerji soğurumu nedeni ile düşük yansımalar verir iken, yeşil dalga boyunda yüksek yansıma göstermişlerdir. Narenciye ağaçları, elektromanyetik spektrumun yakın kızılötesi bölgesinde ise yapraklarının strüktürel yapısına bağlı olarak oldukça yüksek yansıma değeri vermişlerdir.



Şekil 4.12. Spektral yansıtım grafikleri; **a)** Washington; **b)** Valencia; **c)** Clementine; **d)** Satsuma

Yapılan ölçümler neticesinde her bir deneme alanındaki ortalama spektral grafiğine göre, tüm deneme alanlarındaki ortalama yansıtımın birbirine yakın olduğu bununla birlikte portakal deneme alanlarındaki Washington ve Valencia ağaçlarının oldukça benzer spektral yansıtım gösterdiği; mandalina deneme alanlarındaki Satsuma ve Clementine ağaçlarının yine benzer yansıtım eğrisine sahip olmakla birlikte Satsuma ağaçlarının hem görünür hem de yakın kızılötesi bölgede diğer deneme alanlarına göre daha yüksek yansıtım verdiği tespit edilmiştir (Şekil 4.13).



Şekil 4.13. Tüm deneme alanlarının ortalama spektral grafikleri

Meyve olum dönemindeki narenciye ağaçlarından alınan yaprak örneklerinde gerçekleştirilen hiperspektral okumalar sonrasında elde edilen verilerden SR, NDVI, HNDVI ve NPCI bitki indeksleri hesaplanmıştır. Deneme alanındaki her bir ağaç için hesaplanan bitki indeks değerleri Çizelge 4.11’de verilmiştir. Çizelgeden görüleceği üzere, Washington portakal ağaçları için hesaplanan en küçük NDVI değeri 0.719 (W16), en büyük NDVI değeri 0.930 (W20) ve ortalama NDVI değeri ise 0.858’dir. Basit oran indeksi (SR) için en küçük değer 6.112 (W16), en büyük değer (W20) ve ortalama değer 15.128 olarak hesaplanmıştır. Hiperspektral fark bitki indeksi (HNDVI) için en küçük değer 0.744 (W04), en büyük değer 0.942 (W20) ve ortalama değer ise 0.880’dir. Normalize edilmiş pigment klorofil indeksinin (NPCI) hesaplanması sonucu en küçük, en büyük ve ortalama değer sırasıyla 0.158 (W06), 17.714 (W13) ve 1.720’dir. Valencia ağaçlarında NDVI değerleri en küçük 0.738 (V20), en büyük 0.906 (V19) ve ortalama 0.862’dir. Valencia ağaçlarında basit oran indeksi en küçük 6.634 (V20), en büyük 20.366 (V19) ve ortalama 14.404’dür. Hiperspektral fark bitki indeksi (HNDVI) için en küçük değer 0.810 (V20), en büyük değer 0.936 (V15) ve ortalama değer ise 0.894 iken NPCI en küçük -0.390 (V28), en büyük 1.527 (V10) ve ortalama 0.395’dir.

Çizelge 4.11. Hiperspektral (yersel) verilerden hesaplanan ortalama bitki indeks değerleri

Washington					Valencia				
ID	NDVI	SR	HNDVI	NPCI	ID	NDVI	SR	HNDVI	NPCI
W01	0.868	14.142	0.888	0.295	V1	0.821	10.191	0.854	0.173
W02	0.819	10.078	0.841	0.243	V2	0.861	13.405	0.896	0.529
W03	0.900	19.035	0.929	1.133	V3	0.827	10.591	0.862	0.129
W04	0.722	6.193	0.744	0.170	V4	0.898	18.597	0.922	0.033
W05	0.792	8.620	0.821	0.302	V5	0.877	15.288	0.920	0.307
W06	0.844	11.829	0.863	0.158	V6	0.870	14.365	0.902	0.607
W07	0.848	12.161	0.868	0.210	V7	0.812	9.629	0.843	0.299
W08	0.838	11.315	0.862	0.539	V8	0.884	16.196	0.925	0.432
W09	0.891	17.398	0.915	1.000	V9	0.900	19.075	0.930	1.448
W10	0.820	10.106	0.843	0.330	V10	0.899	18.708	0.917	1.527
W11	0.915	22.591	0.927	0.211	V11	0.834	11.014	0.865	0.551
W12	0.733	6.499	0.764	0.213	V12	0.891	17.362	0.920	0.958
W13	0.898	18.586	0.927	17.714	V13	0.850	12.293	0.888	0.750
W14	0.821	10.154	0.853	0.403	V14	0.826	10.496	0.880	0.513
W15	0.922	24.633	0.924	1.763	V15	0.905	20.116	0.936	-0.386
W16	0.719	6.112	0.762	0.183	V16	0.897	18.409	0.918	1.110
W17	0.877	15.297	0.910	0.560	V17	0.833	10.974	0.856	0.460
W18	0.843	11.752	0.865	0.270	V18	0.862	13.532	0.903	0.432
W19	0.913	22.071	0.916	1.544	V19	0.906	20.366	0.923	0.654
W20	0.930	27.654	0.942	12.125	V20	0.738	6.634	0.810	0.211
W21	0.864	13.665	0.882	0.354	V21	0.827	10.543	0.855	0.095
W22	0.865	13.799	0.891	1.459	V22	0.899	18.765	0.925	-0.115
W23	0.824	10.386	0.865	1.061	V23	0.877	15.230	0.918	1.288
W24	0.919	23.595	0.933	3.545	V24	0.873	14.789	0.903	-0.179
W25	0.905	19.943	0.921	0.705	V25	0.892	17.444	0.910	-0.278

(Devamı Arkada)

Çizelge 4.11'in devamı

W26	0.902	19.406	0.929	2.244	V26	0.883	16.059	0.904	-0.193
W27	0.870	14.370	0.894	0.815	V27	0.839	11.413	0.879	-0.158
W28	0.878	15.452	0.905	0.417	V28	0.871	14.470	0.893	-0.390
W29	0.907	20.615	0.926	1.000	V29	0.884	16.274	0.919	1.027
W30	0.885	16.374	0.905	0.635	V30	0.817	9.900	0.841	0.010

Clementine ve Satsuma mandalina ağaçları için hesaplanan indeksler ise Çizelge 4.12'de verilmiştir. Çizelgeden de görüleceği üzere, Clementine mandalinası için en küçük NDVI değeri 0.771 (C16), en büyük NDVI değeri 0.912 (C02) ve ortalama NDVI değeri ise 0.852'dir. Basit oran indeksi (SR) için en küçük değer 7.726 (C16), en büyük değer 21.611 (C02) ve ortalama değer 13.526 olarak hesaplanmıştır. Hiperspektral fark bitki indeksi (HNDVI) için en küçük değer 0.796 (C16), en büyük değer 0.940 (C05) ve ortalama değer ise 0.876'dir. Normalize edilmiş pigment klorofil indeksi (NPCI) için en küçük değer 0.113 (C17), en büyük 5.917 (C24) ve ortalama değer 1.023'dür. Satsuma NDVI değerleri en küçük 0.741 (S26), en büyük 0.872 (S19) ve ortalama 0.837 iken SR indeksi için en küçük 6.733 (S26), en büyük 14.674 (S19) ve ortalama 11.672'dir. Hiperspektral fark bitki indeksi (HNDVI) için en küçük değer 0.776 (S26), en büyük değer 0.903 (S02) ve ortalama değer ise 0.874 iken NPCI en küçük -0.170 (S23), en büyük 0.545 (S12) ve ortalama 0.042'dir.

Çizelge 4.12. Hiperspektral (yersel) verilerden hesaplanan ortalama bitki indeks değerleri

Clementine					Satsuma				
ID	NDVI	SR	HNDVI	NPCI	ID	NDVI	SR	HNDVI	NPCI
C1	0.894	17.924	0.920	0.834	S1	0.846	11.954	0.895	0.208
C2	0.912	21.611	0.933	1.404	S2	0.869	14.254	0.903	-0.129
C3	0.822	10.259	0.836	0.414	S3	0.837	11.290	0.886	0.047
C4	0.843	11.749	0.856	0.563	S4	0.852	12.505	0.894	-0.069
C5	0.911	21.383	0.940	2.000	S5	0.833	10.986	0.884	0.283
C6	0.897	18.441	0.911	0.910	S6	0.843	11.776	0.891	0.006
C7	0.812	9.610	0.841	0.268	S7	0.842	11.683	0.882	0.047
C8	0.881	15.805	0.910	0.579	S8	0.866	13.890	0.892	-0.119
C9	0.846	11.974	0.883	0.827	S9	0.829	10.669	0.876	-0.079
C10	0.874	14.867	0.892	0.483	S10	0.823	10.314	0.864	-0.095
C11	0.835	11.093	0.856	0.187	S11	0.865	13.860	0.892	0.064
C12	0.836	11.168	0.862	0.354	S12	0.861	13.392	0.881	0.545
C13	0.874	14.855	0.904	1.730	S13	0.847	12.053	0.886	-0.028
C14	0.804	9.223	0.835	0.454	S14	0.836	11.168	0.884	0.122
C15	0.844	11.843	0.882	0.982	S15	0.846	11.993	0.882	-0.032
C16	0.771	7.726	0.796	0.238	S16	0.854	12.702	0.886	-0.151
C17	0.835	11.143	0.860	0.113	S17	0.865	13.780	0.894	0.015
C18	0.838	11.350	0.854	0.540	S18	0.867	14.011	0.891	0.186
C19	0.841	11.586	0.862	0.377	S19	0.872	14.674	0.897	0.137
C20	0.828	10.595	0.854	0.816	S20	0.850	12.295	0.886	0.107

(Devamı Arkada)

Çizelge 4.12'nin devamı

C21	0.880	15.728	0.912	2.029	S21	0.858	13.096	0.895	0.244
C22	0.804	9.200	0.830	0.418	S22	0.790	8.537	0.828	-0.074
C23	0.900	19.060	0.932	1.362	S23	0.862	13.471	0.894	-0.170
C24	0.896	18.234	0.913	5.917	S24	0.756	7.208	0.802	0.117
C25	0.890	17.159	0.920	3.852	S25	0.843	11.748	0.883	0.019
C26	0.812	9.648	0.832	0.373	S26	0.741	6.733	0.776	-0.066
C27	0.792	8.635	0.815	0.280	S27	0.793	8.652	0.837	-0.042
C28	0.795	8.763	0.824	0.493	S28	0.860	13.298	0.893	0.105
C29	0.880	15.643	0.902	1.025	S29	0.796	8.806	0.830	0.195
C30	0.902	19.498	0.928	0.861	S30	0.807	9.352	0.838	-0.128

4.5. MS-İHA Verilerinden Hesaplanan Bitki İndeks Değerleri

Çalışma alanında gerçekleştirilen İHA uçuşlarında, narenciye bahçelerinde İHA takılan MS kameralar ile çok bandlı veriler elde edilmiştir. Söz konusu bu verilerde daha sonrasında görüntü zenginleştirme işlemi kapsamında aritmetik bant oranlaması ile SR ve NDVI bitki indeksleri hesaplanmıştır. Çizelge 4.13'de tüm deneme alanlarında hesaplanan indeks değerleri görülmektedir. Elde edilen bulgulara göre, Washington ağaçlarında en düşük NDVI değeri 0.393 (W03), en yüksek NDVI değeri 0.649 (W22) ve ortalama NDVI değeri ise 0.568'dir. Diğer bir portakal çeşidi olan Valencia ağaçları için en düşük NDVI değeri 0.572 (W20), en yüksek NDVI değeri 0.649 (V21) ve ortalama NDVI değeri ise 0.725 olarak hesaplanmıştır. Mandalina deneme alanlarında yer alan Clementine ağaçlarında en düşük NDVI değeri 0.460 (C24), en yüksek NDVI değeri 0.685 (C06) ve ortalama NDVI değeri 0.617'dir. Satsuma mandalinası ağaçlarında ise en düşük NDVI değeri 0.483 (S03), en yüksek NDVI değeri 0.767 (S10) ve ortalama NDVI değeri 0.631'dir.

Çizelge 4.13. MS-İHA verilerden hesaplanan ortalama bitki indeks değerleri

Washington			Valencia			Clementine			Satsuma		
ID	NDVI	SR	ID	NDVI	SR	ID	NDVI	SR	ID	NDVI	SR
W01	0.632	4.000	V1	0.637	4.000	C1	0.664	4.667	S1	0.690	5.000
W02	0.584	3.000	V2	0.640	4.000	C2	0.684	5.000	S2	0.650	4.333
W03	0.393	2.000	V3	0.697	5.000	C3	0.673	4.667	S3	0.483	2.333
W04	0.500	2.333	V4	0.772	7.333	C4	0.650	4.333	S4	0.584	3.000
W05	0.484	2.333	V5	0.729	5.667	C5	0.669	4.667	S5	0.615	3.667
W06	0.541	3.000	V6	0.747	6.667	C6	0.685	4.667	S6	0.601	3.333
W07	0.576	3.333	V7	0.709	5.667	C7	0.656	4.333	S7	0.661	4.667
W08	0.564	3.000	V8	0.754	7.000	C8	0.670	4.667	S8	0.631	3.667
W09	0.564	3.000	V9	0.744	6.333	C9	0.650	4.333	S9	0.715	5.667
W10	0.590	3.333	V10	0.775	7.333	C10	0.610	4.000	S10	0.767	7.000
W11	0.620	4.000	V11	0.778	7.667	C11	0.646	4.333	S11	0.754	6.667
W12	0.574	3.333	V12	0.740	6.000	C12	0.646	4.000	S12	0.711	5.333
W13	0.579	3.333	V13	0.707	5.667	C13	0.633	4.000	S13	0.648	4.333
W14	0.598	3.333	V14	0.656	4.333	C14	0.652	4.333	S14	0.659	4.667

(Devamı Arkada)

Çizelge 4.13'ün devamı

W15	0.556	3.000	V15	0.697	5.000	C15	0.662	4.667	S15	0.649	4.000
W16	0.533	3.000	V16	0.711	5.667	C16	0.594	3.333	S16	0.588	3.000
W17	0.538	3.000	V17	0.767	7.000	C17	0.565	3.333	S17	0.502	2.667
W18	0.524	2.667	V18	0.753	6.667	C18	0.576	3.333	S18	0.586	3.000
W19	0.606	3.667	V19	0.696	5.000	C19	0.591	3.333	S19	0.631	4.000
W20	0.595	3.333	V20	0.572	3.000	C20	0.612	4.000	S20	0.677	4.667
W21	0.636	4.000	V21	0.813	9.333	C21	0.638	4.000	S21	0.671	4.667
W22	0.649	4.333	V22	0.722	6.000	C22	0.559	3.333	S22	0.534	2.667
W23	0.590	3.333	V23	0.736	6.000	C23	0.489	2.333	S23	0.584	3.333
W24	0.516	3.000	V24	0.761	7.000	C24	0.460	2.333	S24	0.597	3.667
W25	0.588	3.000	V25	0.753	6.333	C25	0.521	2.667	S25	0.605	3.667
W26	0.573	3.000	V26	0.742	6.333	C26	0.576	3.333	S26	0.631	4.000
W27	0.600	3.333	V27	0.680	4.667	C27	0.597	3.333	S27	0.543	2.667
W28	0.582	3.333	V28	0.754	6.333	C28	0.606	3.333	S28	0.665	4.667
W29	0.583	3.333	V29	0.752	6.667	C29	0.600	3.333	S29	0.673	4.667
W30	0.571	3.000	V30	0.769	7.000	C30	0.679	4.667	S30	0.634	4.000

İHA'ya takılan MS kameradan elde edilen verilerden hesaplanan bitki indekslerinden diğeri SR'dir. Meyve olum dönemindeki ağaçlarda hesaplanan söz konusu bu indeks için Washington ağaçlarında en düşük değer 2.000 (W03), en yüksek değer 4.333 (W22) ve ortalama değer ise 3.189'olarak belirlenmiştir. Valencia ağaçları için en düşük SR değeri 3.000 (W20), en yüksek SR değeri 9.333 (V21) ve ortalama SR değeri ise 6.022'dir. Basit oran indeks değerleri Clementine ağaçlarında en düşük 2.333 (C24 ve C25), en yüksek 5.000 (C02) ve ortalama ise 3.889 iken Satsuma mandalinası ağaçlarında en düşük 2.333 (S03), en yüksek 7.000 (S10) ve ortalama 4.100 olarak belirlenmiştir.


Yersel hiperspektral ölçümler olarak ta belirtilen spektrometrik ölçümler ile İHA uçuşları ile elde edilen MS verilerin bireysel ağaç düzeyinde yansıma karakteristiklerinin daha detaylı olarak incelenmesi amacı ile çeşitli bitki indekslerinin hesaplanması işlemi gerçekleştirilen bu çalışmadan elde edilen bulgulara göre, Washington ve Valencia portakalı ile Clementine ve Satsuma mandalinası ağaçlarının bireysel ağaç bazında gelişim düzeyleri ve çeşitlerine bağlı olarak farklılıklar göstermekle birlikte, literatürlerde belirtilen tipik bitki örtüsünün gösterdiği yansıma değerlerini verdiği görülmüştür. Bireysel ağaç bazında ortaya çıkan bazı farklılıkların nedeni olarak ise, bireysel ağaç düzeyinde ağaçların bir kısmındaki stres durumlarından kaynaklandığı düşünülmektedir. Nitekim Fletcher vd. (2004), Texas eyaletinde üretimi yapılan stresli ve sağlıklı narenciye ağaçlarının tespit edilmesine yönelik yaptığı bir çalışmada, alçak irtifa uçağından temin edilen multispektral verilerden hesaplanan indekslerin narenciye ağaçlarının stres koşullarının belirlenmesinde etkili olduğunu ifade etmiştir. Elde edilen bu sonuçlar, gerek yersel ölçümlerle ve gerek İHA verilerinden hesaplanan indekslerin narenciye ağaçlarının izlenmesi ve bu ağaçlara yönelik çeşitli verim tahmini kestirimlerinin yapılmasında önemli rol oynayacağını, bireysel ağaç bazında belirlenen bu farklılıklardan yola çıkılarak, verim tahmin parametreleri olarak bu verilerin kullanılmasının mümkün olduğunu göstermektedir. Nitekim bitkinin fizyolojik durumunu gösteren çeşitli indekslerin verim tahmini parametresi olarak kullanıldığı pek çok araştırma bulunmaktadır. Örneğin, Geipel vd. (2014) bitki indeksi haritaları ve detaylı

üç boyutlu ürün yüzey modellerinin verim tahmini çalışmalarında parametre olarak kullanıldığı bir araştırmada, mısır bitkisinin erken ve orta gelişme dönemlerinde verim modelleri başarı ile gerçekleştirmişlerdir. Tez çalışmasının bu aşamasında elde edilen bulgular literatürler ile paralellik göstermektedir.

4.6.Yersel Ölçüm Verileri

Tez çalışmasında gerek İHA'lar ile yapılan uçuşlar esnasında, bu uçuşlarla eş zamanlı olarak portakal ve mandalina bahçelerinden yersel ölçüm verileri temin edilmiştir. Bu kapsamda çalışmada yersel veriler olarak, yaprak klorofil ölçümleri, ağaç gövde yüksekliği ölçümleri ve verim değerleri kullanılmıştır. Yaprak örneklerinde SPAD502 klorofilmetre cihazı ile gerçekleştirilen klorofil ölçüm sonuçlarına göre, Washington portakalı ağaçları için maksimum klorofil değeri, 80.500 SPAD birimi (W20); minimum klorofil değeri, 61.200 SPAD birimi (W27) ve ortalama klorofil değeri ise 70.317 SPAD birimi olarak tespit edilmiştir. Diğer bir portakal deneme alanı olan Valencia için maksimum klorofil değeri, 72.000 SPAD birimi (V19); minimum klorofil değeri, 45.800 SPAD birimi (V20) ve ortalama klorofil değeri ise 65.213 SPAD birimi olarak belirlenmiştir.

Mandalina deneme alanlarından Clementine deneme alanında yer alan ağaç yapraklarından ölçülen maksimum klorofil değeri, 69.200 SPAD birimi (C11); minimum klorofil değeri, 48.600 SPAD birimi (C9) ve ortalama klorofil değeri ise 55.947 SPAD birimi olarak ölçülmüştür. Satsuma mandalinası ağaçları için maksimum klorofil değeri, 74.800 SPAD birimi (S19); minimum klorofil değeri, 52.700 SPAD birimi (S5) ve ortalama klorofil değeri ise 63.877 SPAD birimi olarak tespit edilmiştir (Şekil 4.14). Tüm deneme alanları değerlendirildiğinde narenciye ağacı yapraklarından ölçülen en yüksek klorofil değerleri W20, V19, C11 ve S19 ağaçlarından elde edilirken en düşük klorofil değerleri W27, V20, C9 ve S5 ağaçlarından elde edilmiştir.



Şekil 4.14. Klorofil ölçüm grafikleri; **a)** Washington; **b)** Valencia; **c)** Clementine; **d)** Satsuma

Bitki yapraklarındaki klorofil seviyeleri ile ilişkili yaprak yeşilliğinin bir ölçüsü ve bitki besin durumunu ölçmek için bir teşhis aracı olarak kullanılabilen SPAD, birçok araştırmacı tarafından narenciye ağaçlarında da kullanılmıştır. Örneğin Garza vd. (2020) tarafından gerçek renkli İHA görüntülerinden narenciye ağaçlarında bitki sağlığının ölçülmesi amacıyla gerçekleştirilen çalışmada yaprak yeşilliğinin ölçümlerinde SPAD kullanılmıştır. Rivas vd. (2007) mandalina ağacı yaprak klorofil konsantrasyonunu belirlemek için tahribatsız bir yöntem olan SPAD prosedürünü deneysel koşullar (büyüme ortamı ve yaprak anatomisi) altında doğrulamak amacıyla bir çalışma gerçekleştirmişlerdir. Araştırmacılar tarafından yürütülen bu çalışma ile SPAD okumaları ve klorofil konsantrasyonları arasında güçlü ve pozitif bir korelasyon ($r^2=0.962$) olduğu ortaya konmuştur. Bu kapsamda SPAD cihazından elde edilen narenciye ağacı yapraklarının bağlı klorofil içeriklerinin bitkinin klorofil konsantrasyonlarının belirlenmesinde kullanılabileceği değerlendirilmiştir.

Yersel ölçüm verilerinden bir diğeri ise, ağaç gövde yükseklikleri ölçümleridir. Ağaç gövde yüksekliği ölçümlerine göre ortalama gövde yüksekliği değerleri için tüm deneme alanlarında birbirine oldukça yakın değerler elde edilirken; ortalama Washington portakalı ağaçları için 1.42 m, Valencia portakalı ağaçları için 1.04 m, Clementine mandalinası ağaçları için 1.32 ve Satsuma mandalinası ağaçları için ise 1.36 olarak ölçülmüştür. Batı Akdeniz Tarımsal Araştırma Enstitüsü'nden temin edilen verim değerleri, Washington ağaçları için ortalama 66.17 kg ağaç⁻¹, Valencia ağaçları için 104.33 kg ağaç⁻¹, Clementine ağaçları için 109.17 kg ağaç⁻¹ ve Satsuma ağaçları için ise 107.69 kg ağaç⁻¹ olarak tespit edilmiştir.

4.7. İstatistiksel Analizler

Tez çalışmasından elde edilen verilerde gerçekleştirilen istatistiksel analizlerde, yersel hiperspektral verilerden hesaplanan indeksler, basit oran (SRY), normalize edilmiş fark bitki indeksi (NDY), hiperspektral normalize edilmiş fark bitki indeksi (HNY), normalize edilmiş pigment klorofil oran indeksi (NPY); yaprak klorofil ölçümleri SPAD (SPD); İHA verilerinden hesaplanan MS indeksler normalize edilmiş fark bitki indeksi (NDI), basit oran indeksi (SRI) olarak kısaltılmıştır. Ayrıca istatistiksel analizlerde İHA verilerinden hesaplanan ağaç dendrometrik bileşenleri, ağaç taç alanı (TAL), ağaç yüksekliği (AYK); yersel ölçümlerden elde edilen ağaç gövde yüksekliği (GYK) ve verim (VRM) için kısaltmalar kullanılmıştır. Çalışmanın istatistiksel analizlerinde, üzerinde meyve bulunmadığı için herhangi bir verim değeri alınamayan ve sonuçları doğrudan etkileyebileceği değerlendirilen W03 ID numaralı ağaç veri setinden çıkarılmıştır.

Deneme alanlarındaki narenciye ağaçlarının tüm değişkenler için tanımlayıcı istatistik değerleri hesaplanmıştır. Daha sonra ise tüm veri setleri için normallik testleri gerçekleştirilmiştir. Veri setlerinin normal dağılım gösterip göstermediği, çarpıklık (skewnes) ve basıklık (kurtosis) katsayıları, Shapiro-Wilk normallik testleri ve histogram grafikleri ile kontrol edilmiştir. Bu kapsamda çarpıklık (skewnes) ve basıklık (kurtosis) katsayıları için -2, +2 (George 2011; George ve Mallery 2019) aralığının ve Shapiro-Wilk normalite testi sonuçlarına göre elde edilen değerlerden 0.05'den (%5 anlamlılık düzeyinde) büyük olanların normal dağılım gösterdiği kabul edilmiştir. Sonrasında ise çalışmadan elde edilen verisetlerinde normal dağılım göstermeyen değişkenler bulunduğu için normallik varsayımı gerektirmeyen Spearman'ın sıralama korelasyon katsayıları

(Spearman's rank correlation coefficient veya Spearman's rho) hesaplanmıştır (Eşitlik 4.1).

4.7.1. Washington deneme alanı için istatistiksel analizler

Washington portakalı deneme alanındaki ağaçlar için hesaplanan tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testlerine ait sonuçlar Çizelge 4.14'de verilmiştir. Çizelgeden de görüleceği üzere, Washington deneme alanı için test sonuçları ortalama SRY 14.993, NDY 0.856, HNY 0.879, NPY 1.740, SPD 70.424, NDI 0.574, SRI 3.230, TAL 33.208, AYK 4.214, GYK 1.440 ve VRM ise 68.448'dir.


Çizelge 4.14. Washington deneme alanı için tanımlayıcı istatistik, çarpıklık-basıklık ve Shapiro-Wilk normalite testi sonuçları

Değişken	N	Min.	Mak.	Ort.	Standart Sapma	Değişkenlik Katsayısı (%)	Çarpıklık	Basıklık	Shapiro Wilk
SRY	29	6.112	27.654	14.993	5.792	38.631	0.387	-0.618	0.443
NDY	29	0.719	0.930	0.856	0.058	6.776	-1.079	0.709	0.007*
HNY	29	0.744	0.942	0.879	0.053	6.030	-1.247	0.978	0.002*
NPY	29	0.158	17.714	1.740	3.801	218.448	3.596*	12.935*	0.000*
SPD	29	61.200	80.500	70.424	4.295	6.099	0.035	0.224	0.457
NDI	29	0.484	0.649	0.574	0.039	6.794	-0.376	0.145	0.674
SRI	29	2.333	4.333	3.230	0.455	14.087	0.429	0.773	0.008*
TAL	29	17.277	33.208	25.720	3.483	13.542	-0.620	-0.036	0.787
AYK	29	3.652	4.688	4.214	0.258	6.123	-0.303	1.893	0.667
GYK	29	1.160	1.760	1.440	0.163	11.319	0.008	-0.781	0.597
VRM	29	15.000	130.000	68.448	30.388	44.396	0.312	-0.235	0.309

*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normalite testine göre normal dağılım göstermeyen veriler

Çizelge 4.14'de verilen çarpıklık ve basıklık katsayıları ve Şekil 4.15'de verilen histogram grafiklerine göre normal dağılım gösteren verim değişkeni için çarpıklık katsayısının (0.312) pozitif olması, dağılımın hafif sağa çarpık ve basıklık katsayısının (-0.235) negatif olması, dağılımın hafif basık olduğunu göstermektedir. Bu deneme alanı için ağaçların dendrometrik bileşenlerinden taç alanının hafif sola çarpık basık dağılım, ağaç yüksekliğinin sola çarpık sivri dağılım ve gövde yüksekliğinin ise hafif sağa çarpık basık dağılım gösterdiği belirlenmiştir. MS verilerden hesaplanan indekslerden NDI'nın çarpıklık katsayısı bakımından sola çarpık ve basıklık katsayısı bakımından sivri dağılım gösterdiği, SRI'nın hafif sağa çarpık ve sivri dağılım gösterdiği tespit edilmiştir. Yersel hiperspektral verilerden hesaplanan indekslerden NDY'nin sola çarpık ve sivri dağılım gösterdiği, SRY'nin sağa çarpık ve basık dağılım gösterdiği, HNY'nin sola çarpık ve sivri

dağılım gösterdiği ve NPY'nin ise hem çarpıklık hem de basıklık katsayıları bakımından normal dağılım göstermediği belirlenmiştir. Ağaç yapraklarının klorofil ölçüm değerlerini içeren SPD bağımsız değişkeninin ise hafif sağa çarpık ve hafif sivri dağılım sergilediği görülmüştür. Narenciye deneme alanlarındaki ağaçlara ait değişkenlerin normal dağılım gösterip göstermediği çarpıklık ve basıklık katsayılarının yanı sıra Shapiro-Wilk testleri ile de kontrol edilmiştir. Shapiro-Wilk testleri ($P>0.05$) sonuçlarına göre SRI, NDY, HNY ve NPY bağımsız değişkenlerinin normal dağılım göstermediği belirlenmiştir. Sonuç olarak Washington deneme alanı için, hem çarpıklık-basıklık hem de Shapiro-Wilk testi sonuçlarından herhangi biri dikkate alındığında SRI, NDY, HNY ve NPY'nin; bu üç değerin tümünün aynı anda dikkate alındığında ise sadece NPY'nin normal dağılım göstermediği ve diğer tüm bağımsız değişkenlerin normal dağılım gösterdiği tespit edilmiştir.



Şekil 4.15. Washington deneme alanı histogram grafikleri

Yapılan bu değerlendirme sonucunda, Washington deneme alanındaki ağaçlardan elde edilen verilerin bazılarının normal dağılım göstermemesi nedeniyle korelasyon analizi kapsamında parametrik olmayan Spearman'ın sıralama korelasyon katsayıları hesaplanmıştır (Çizelge 4.15).

Çizelge 4.15. Washington deneme alanı Spearman'ın korelasyon analizi sonuçları

	SRY	NDY	HNY	NPY	SPD	NDI	SRI	TAL	AYK	GYK	VRM
SRY	1.000	1.000**	0.972**	0.697**	0.618**	0.220	0.233	0.104	-0.102	-0.314	0.213
NDY	1.000**	1.000	0.972**	0.697**	0.618**	0.220	0.233	0.104	-0.102	-0.314	0.213
HNY	0.972**	0.972**	1.000	0.750**	0.520**	0.203	0.225	0.049	-0.081	-0.247	0.181
NPY	0.697**	0.697**	0.750**	1.000	0.234	0.193	0.162	-0.063	-0.216	-0.403*	0.045
SPD	0.618**	0.618**	0.520**	0.234	1.000	0.164	0.146	0.106	-0.139	-0.211	0.458*
NDI	0.220	0.220	0.203	0.193	0.164	1.000	0.893**	0.043	-0.034	-0.083	0.222
SRI	0.233	0.233	0.225	0.162	0.146	0.893**	1.000	-0.005	0.015	0.013	0.168
TAL	0.104	0.104	0.049	-0.063	0.106	0.043	-0.005	1.000	0.347	-0.034	-0.002
AYK	-0.102	-0.102	-0.081	-0.216	-0.139	-0.034	0.015	0.347	1.000	0.200	0.200
GYK	-0.314	-0.314	-0.247	-0.403*	-0.211	-0.083	0.013	-0.034	0.200	1.000	0.231
VRM	0.213	0.213	0.181	0.045	0.458*	0.222	0.168	-0.002	0.200	0.231	1.000

*Correlation is significant at the 0.05 level (2-tailed).

**Correlation is significant at the 0.01 level (2-tailed).

Washington portakalı deneme alanındaki ağaçlar için hesaplanan Spearman'ın korelasyon katsayıları incelendiğinde, verim (VRM) bağımlı değişkeni ile klorofil ölçüm değerleri (SPD) arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (0.05 güven düzeyinde). VRM ile ağaç taç alanı arasında zayıf düzeyde negatif ilişki bulunurken, VRM ile diğer tüm bağımsız değişkenler arasında ise zayıf düzeyde pozitif yönlü ilişkiler tespit edilmiştir. Bu deneme alanında yersel hiperspektral ölçümlerden hesaplanan NDVI (NDY) ile yine yersel hiperspektral ölçümlerden hesaplanan basit oran indeksi (SRY) arasında mükemmel ilişki; yersel hiperspektral ölçümlerden hesaplanan HNDVI (HNY) ile SRY ve NDY arasında güçlü ve pozitif ilişki, yersel hiperspektral ölçümlerden hesaplanan NPCI (NPY) ile SRY, NDY ve HNY arasında ise yine güçlü ve pozitif yönlü ilişkiler tespit edilmiştir. SPD ile SRY, NDY ve HNY arasında pozitif güçlü ilişkiler belirlenirken, SPD ve NPY arasında zayıf ve pozitif yönlü ilişki tespit edilmiştir. Ayrıca bu alanda İHA verilerinden hesaplanan indeks değerleri (SRI ve NDI) arasında güçlü ve pozitif yönlü ilişki tespit edilmiştir.

4.7.2. Valencia deneme alanı için istatistiksel analizler

Valencia portakalı deneme alanındaki ağaçlar için hesaplanan tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testlerine ait sonuçlar

Çizelge 4.16’de görüldüğü gibidir. Bu sonuçlara göre, Valencia deneme alanı için ortalama SRY 14.404, NDY 0.862, HNY 0.894, NPY 0.395, SPD 65.213, NDI 0.728, SRI 6.022, TAL 22.308, AYK 4.136, GYK 1.045 ve VRM ise 104.333 olarak hesaplanmıştır.


Çizelge 4.16. Valencia deneme alanı için tanımlayıcı istatistik, çarpıklık-basıklık ve Shapiro-Wilk normalite testi sonuçları

Değişken	N	Min.	Mak.	Ort.	Standart Sapma	Değişkenlik Katsayısı (%)	Çarpıklık	Basıklık	Shapiro Wilk
SRY	30	6.634	20.366	14.404	3.689	25.611	-0.119	-1.000	0.222
NDY	30	0.738	0.906	0.862	0.038	4.408	-1.238	2.163*	0.004*
HNY	30	0.810	0.936	0.894	0.032	3.579	-0.858	-0.102	0.011*
NPY	30	-0.390	1.527	0.395	0.531	134.430	0.514	-0.427	0.258
SPD	30	45.800	72.000	65.213	5.223	8.009	-2.143*	6.437*	0.000*
NDI	30	0.560	0.845	0.728	0.059	8.104	-0.918	1.242	0.085
SRI	30	3.000	9.333	6.022	1.289	21.405	-0.085	0.798	0.603
TAL	30	8.764	28.852	22.308	5.140	23.041	-0.943	0.478	0.035*
AYK	30	2.284	4.866	4.136	0.512	12.379	-1.642	4.755*	0.003*
GYK	30	0.850	1.320	1.045	0.146	13.971	0.377	-0.991	0.076
VRM	30	20.000	150.000	104.33	27.125	25.999	-1.027	2.345*	0.031*

*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normalite testine göre normal dağılım göstermeyen veriler

Çizelge 4.16’da verilen çarpıklık ve basıklık katsayıları ve Şekil 4.16’da verilen histogram grafiklerine göre, verim değişkeni için çarpıklık katsayısının (-1.027) negatif olması dağılımın sola çarpık ve basıklık katsayısının (2.345) belirlenen aralığın dışında ve pozitif olması dağılımın sivri olduğunu göstermektedir. Yapılan analizlerde, yersel hiperspektral verilerden hesaplanan indekslerden SRY’nin hafif sola çarpık ve hafif basık dağılım, NDY’nin hafif sola çarpık ve sivri dağılım gösterdiği, HNY’nin hafif sola çarpık ve hafif basık dağılım gösterdiği, NPY’nin ise hafif sağa çarpık ve hafif basık dağılım gösterdiği belirlenmiştir. Ayrıca ağaç yapraklarının klorofil ölçüm değerlerini içeren SPD bağımsız değişkeni için elde edilen ölçüm değerlerinin belirlenen aralığın dışında olduğu ve normal dağılım göstermediği tespit edilmiştir. MS verilerden hesaplanan indekslerde ise NDI’nin çarpıklık katsayısı bakımından hafif sola çarpık ve basıklık katsayısı bakımından sivri dağılım gösterdiği, SRI’nin ise hafif sola çarpık ve hafif sivri dağılım gösterdiği tespit edilmiştir. Bu deneme alanı için ağaçların dendrometrik bileşenlerinden taç alanının hafif sola çarpık hafif sivri dağılım, ağaç yüksekliğinin sola çarpık ve basıklık katsayısı bakımından normal dağılım göstermediği ve gövde yüksekliğinin ise hafif sağa çarpık hafif basık dağılım gösterdiği belirlenmiştir. Narenciye deneme alanlarındaki ağaçlara ait değişkenlerin normal dağılım gösterip göstermediği çarpıklık ve basıklık katsayılarının yanı sıra Shapiro-Wilk testleri ile de kontrol edilmiştir. Yapılan bu

değerlendirmelerde Shapiro-Wilk testleri ($P>0.05$) sonuçlarına göre NDY, HNY, SPD, TAL, AYK bağımsız değişkenleri ile VRM bağımlı değişkeninin; üç normallik katsayısının tümünün aynı anda dikkate alındığında ise sadece SPD'nin normal dağılım göstermediği ve diğer tüm değişkenlerin normal dağılım gösterdiği belirlenmiştir.



Şekil 4.16. Valencia deneme alanı histogram grafikleri

Washington ağaçlarında olduğu gibi Valencia deneme alanındaki ağaçlardan elde edilen verilerin bazılarının normal dağılım göstermemesi nedeniyle korelasyon analizi kapsamında parametrik olmayan Spearman'ın sıralama korelasyon katsayıları hesaplanmıştır (Çizelge 4.17).

Çizelge 4.17. Valencia deneme alanı Spearman'ın korelasyon analizi sonuçları

	SRY	NDY	HNY	NPY	SPD	NDI	SRI	TAL	AYK	GYK	VRM
SRY	1.000	1.000**	0.940**	0.164	0.612**	0.204	0.160	0.225	0.243	0.136	0.158
NDY	1.000**	1.000	0.940**	0.164	0.612**	0.204	0.160	0.225	0.243	0.136	0.158
HNY	0.940**	0.940**	1.000	0.194	0.429*	0.138	0.105	0.227	0.255	0.271	0.155
NPY	0.164	0.164	0.194	1.000	0.059	0.012	0.031	-0.030	0.174	0.290	0.108
SPD	0.612**	0.612**	0.429*	0.059	1.000	0.338	0.363*	0.235	0.187	-0.316	0.260
NDI	0.204	0.204	0.138	0.012	0.338	1.000	0.929**	0.469**	0.131	-0.066	0.452*
SRI	0.160	0.160	0.105	0.031	0.363*	0.929**	1.000	0.413*	0.112	-0.041	0.405*
TAL	0.225	0.225	0.227	-0.030	0.235	0.469**	0.413*	1.000	0.669**	0.049	0.191
AYK	0.243	0.243	0.255	0.174	0.187	0.131	0.112	.669**	1.000	0.061	0.193
GYK	0.136	0.136	0.271	0.290	-0.316	-0.066	-0.041	0.049	0.061	1.000	-0.054
VRM	0.158	0.158	0.155	0.108	0.260	0.452*	0.405*	0.191	0.193	-0.054	1.000

*Correlation is significant at the 0.05 level (2-tailed).

**Correlation is significant at the 0.01 level (2-tailed).

Çizelge 4.17'den görüleceği üzere, Valencia portakalı deneme alanındaki ağaçlarda, verim (VRM) bağımlı değişkeni ile MS verilerden hesaplanan normalize edilmiş fark bitki indeksi (NDI) ve basit oran indeksi (SRI) arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (0.05 güven düzeyinde). Ayrıca VRM ile yersel hiperspektral verilerden hesaplanan bitki indeksleri (SRY, NDY, HNY, NPY), klorofil ölçümleri (SPD) ve ağaç dendrometrik özelliklerinden ağaç taç alanı (TAL) ve ağaç yüksekliği (AYK) arasında zayıf düzeyde pozitif yönlü ilişki bulunurken, verim ve gövde yüksekliği arasında zayıf ve negatif yönlü bir ilişki tespit edilmiştir. Bu deneme alanında yersel hiperspektral ölçümlerden hesaplanan NDVI (NDY) ile yine yersel hiperspektral ölçümlerden hesaplanan basit oran indeksi (SRY) arasında mükemmel ilişki; yersel hiperspektral ölçümlerden hesaplanan HNDVI (HNY) ile SRY ve NDY arasında güçlü ve pozitif ilişki, yersel hiperspektral ölçümlerden hesaplanan NPCI (NPY) ile SRY, NDY ve HNY arasında ise zayıf ve pozitif yönlü ilişkiler tespit edilmiştir. Yaprak klorofil ölçüm değerleri olan SPD ile SRY, NDY ve HNY arasında güçlü pozitif yönlü ilişkiler belirlenirken, SPD ve SRI arasında orta düzeyde pozitif yönlü ve SPD ile NPY arasında ise zayıf ve pozitif yönlü ilişki tespit edilmiştir. Bu alanda İHA verilerinden hesaplanan indeks değerleri (SRI ve NDI) arasında güçlü ve pozitif yönlü ilişki belirlenmiştir. MS verilerden hesaplanan bu indekslerden NDI ile ağaç taç alanı (TAL) arasında ve yine TAL ile SRI arasında güçlü ve pozitif yönlü ilişkiler bulunmuştur. Ayrıca Valencia narenciye ağaçlarının yüksekliği ve taç alanı arasında güçlü ve pozitif yönlü bir ilişki olduğu tespit edilmiştir.

4.7.3. Clementine deneme alanı için istatistiksel analizler

Clementine mandalinası deneme alanındaki ağaçlar için hesaplanan tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testlerine ait sonuçlar Çizelge 4.18’de görüldüğü gibidir. Bu sonuçlara göre, Clementine deneme alanı için ortalama SRY 13.526, NDY 0.852, HNY 0.876, NPY 1.023, SPD 55.947, NDI 0.617, SRI 3.889, TAL 32.622, AYK 4.826, GYK 1.322 ve VRM ise 109.177’dir.


Çizelge 4.18. Clementine deneme alanı için tanımlayıcı istatistik, çarpıklık-basıklık ve Shapiro-Wilk normalite testi sonuçları

Değişken	N	Min.	Mak.	Ort.	Standart Sapma	Değişkenlik Katsayısı (%)	Çarpıklık	Basıklık	Shapiro Wilk
SRY	30	7.726	21.611	13.526	4.117	30.438	0.507	-1.017	0.023*
NDY	30	0.771	0.912	0.852	0.040	4.695	-0.138	-1.101	0.132
HNY	30	0.796	0.940	0.876	0.041	4.680	-0.109	-1.183	0.144
NPY	30	0.113	5.917	1.023	1.199	117.204	2.950*	9.885*	0.000*
SPD	30	48.600	69.200	55.947	4.753	8.496	0.561	0.708	0.278
NDI	30	0.460	0.685	0.617	0.057	9.238	-1.109	0.951	0.009*
SRI	30	2.333	5.000	3.889	0.734	18.874	-0.540	-0.551	0.010*
TAL	30	23.481	43.258	32.622	5.008	15.352	0.236	-0.747	0.740
AYK	30	4.355	5.377	4.826	0.296	6.133	-0.183	-1.246	0.043*
GYK	30	1.080	1.650	1.322	0.117	8.850	0.161	1.362	0.340
VRM	30	80.000	140.000	109.17	13.27	12.155	0.038	0.178	0.226

*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normalite testine göre normal dağılım göstermeyen veriler

Clementine mandalinası deneme alanı için hesaplanan Çizelge 4.18’de verilen çarpıklık ve basıklık katsayıları ve Şekil 4.17’de verilen histogram grafiklerine göre, verim değişkeni hafif sağa çarpık ve hafif sivri olmak üzere normal dağılım göstermektedir. Yersel hiperspektral verilerden hesaplanan indekslerden SRY’nin hafif sağa çarpık ve basık dağılım, NDY’nin hafif sola çarpık ve basık dağılım, HNY’nin hafif sola çarpık ve basık dağılım gösterdiği, NPY’nin ise normal dağılım göstermediği belirlenmiştir. Clementine mandalinası için ağaç yapraklarının klorofil ölçüm değerlerini içeren SPD bağımsız değişkeni için elde edilen ölçüm değerlerinin ise hafif sağa çarpık ve hafif sivri dağılım gösterdiği tespit edilmiştir. Ayrıca MS verilerden hesaplanan indekslerden NDI’nin çarpıklık katsayısı bakımından sola çarpık ve basıklık katsayısı bakımından hafif sivri dağılım gösterdiği, SRI’nin ise hafif sola çarpık ve hafif basık dağılım gösterdiği tespit edilmiştir. Bu deneme alanı için ağaçların dendrometrik bileşenlerinden taç alanının hafif sağa çarpık hafif basık dağılım, ağaç yüksekliğinin hafif sola çarpık ve basık dağılım ve gövde yüksekliğinin ise hafif sağa çarpık sivri dağılım gösterdiği belirlenmiştir. Clementine mandalinası deneme alanlarındaki ağaçlara ait

değişkenlerin normal dağılım gösterip göstermediği çarpıklık ve basıklık katsayılarının yanı sıra Shapiro-Wilk testleri ile de kontrol edilmiştir. Clementine mandalinası için elde edilen sonuçlara göre, Shapiro-Wilk testlerinde ($P>0.05$), SRY, NPY, NDI, SRI ve AYK bağımsız değişkenlerinin normal dağılım göstermediği ve ayrıca bunlardan sadece NPY verilerinin hem çarpıklık-basıklık hem de Shapiro-Wilk testi sonucuna göre normal dağılmadığı belirlenmiştir.



Şekil 4.17. Clementine deneme alanı histogram grafikleri

Portakal ağaçlarında olduğu gibi, Clementine mandalinası deneme alanındaki ağaçlardan elde edilen verilerin bazılarının normal dağılım göstermemesi nedeniyle korelasyon analizi kapsamında parametrik olmayan Spearman'ın sıralama korelasyon katsayıları hesaplanmıştır (Çizelge 4.19).

Çizelge 4.19. Clementine deneme alanı Spearman'ın korelasyon analizi sonuçları

	SRY	NDY	HNY	NPY	SPD	NDI	SRI	TAL	AYK	GYK	VRM
SRY	1.000	1.000**	0.982**	0.789**	-0.032	0.293	0.302	0.440*	0.479**	-0.132	0.130
NDY	1.000**	1.000	0.982**	0.789**	-0.032	0.293	0.302	0.440*	0.479**	-0.132	0.130
HNY	0.982**	0.982**	1.000	0.778**	-0.081	0.267	0.279	0.367*	0.414*	-0.121	0.167
NPY	0.789**	0.789**	0.778**	1.000	-0.301	0.106	0.092	0.504**	0.502**	-0.007	0.301
SPD	-0.032	-0.032	-0.081	-0.301	1.000	0.342	0.363*	0.002	-0.081	0.053	-0.096
NDI	0.293	0.293	0.267	0.106	0.342	1.000	0.974**	0.557**	0.395*	-0.179	0.210
SRI	0.302	0.302	0.279	0.092	0.363*	0.974**	1.000	0.546**	0.384*	-0.166	0.270
TAL	0.440*	0.440*	0.367*	0.504**	0.002	0.557**	0.546**	1.000	0.685**	-0.085	0.115
AYK	0.479**	0.479**	0.414*	0.502**	-0.081	0.395*	0.384*	0.685**	1.000	0.135	-0.041
GYK	-0.132	-0.132	-0.121	-0.007	0.053	-0.179	-0.166	-0.085	0.135	1.000	0.025
VRM	0.130	0.130	0.167	0.301	-0.096	0.210	0.270	0.115	-0.041	0.025	1.000

*Correlation is significant at the 0.05 level (2-tailed).

**Correlation is significant at the 0.01 level (2-tailed).

Çizelgede verilen Spearman'ın korelasyon katsayıları incelendiğinde, verim (VRM) bağımlı değişkeni ile MS verilerden hesaplanan normalize edilmiş fark bitki indeksi (NDI), basit oran indeksi (SRI) ve yersel hiperspektral verilerden hesaplanan bitki indeksleri (SRY, NDY, HNY, NPY) arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (0.05 güven düzeyinde). Ayrıca VRM ile ağaç dendrometrik özelliklerinden ağaç taç alanı (TAL) ve gövde yüksekliği (GYK) arasında zayıf düzeyde pozitif yönlü ilişki bulunurken, verim ile klorofil ölçümleri (SPD) ve ağaç yüksekliği (AYK) arasında zayıf ve negatif yönlü bir ilişki tespit edilmiştir. Bu deneme alanında yersel hiperspektral ölçümlerden hesaplanan NDVI (NDY) ile yine yersel hiperspektral ölçümlerden hesaplanan basit oran indeksi (SRY) arasında mükemmel ilişki; yersel hiperspektral ölçümlerden hesaplanan HNDVI (HNY) ile SRY ve NDY arasında güçlü ve pozitif ilişki, yersel hiperspektral ölçümlerden hesaplanan NPCI (NPY) ile SRY, NDY ve HNY arasında ise güçlü ve pozitif yönlü ilişkiler tespit edilmiştir. Yaprak klorofil ölçüm değerleri olan SPD ile SRY, NDY ve HNY arasında zayıf negatif yönlü ilişkiler belirlenirken, SPD ile NDI ve SRI arasında orta düzeyde pozitif yönlü ve SPD ile NPY arasında ise zayıf ve negatif yönlü ilişki tespit edilmiştir. Bu alanda MS-İHA verilerinden hesaplanan indeks değerleri (SRI ve NDI) arasında güçlü ve pozitif yönlü ilişki belirlenmiştir. MS verilerden hesaplanan bu indekslerden NDI ve SRI ile ağaç taç alanı (TAL) ağaç yüksekliği (AYK) arasında yine TAL ile SRI arasında güçlü ve pozitif yönlü

ilişkiler bulunmuştur. Ayrıca Clementine narenciye ağaçlarının yüksekliği (AYK) ve taç alanı (TAL) arasında güçlü ve pozitif yönlü bir ilişki olduğu; TAL ve AYK ile hem hiperspektral hem de MS indeksler arasında pozitif yönlü ilişkiler olduğu tespit edilmiştir.

4.7.4. Satsuma deneme alanı için istatistiksel analizler

Satsuma mandalinası deneme alanındaki ağaçlar için hesaplanan tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testlerine ait sonuçlar Çizelge 4.20’de verilmiştir. Bu sonuçlara göre, Clementine deneme alanı için ortalama SRY 11.672, NDY 0.837, HNY 0.874, NPY 0.042, SPD 63.877, NDI 0.631, SRI 4.100, TAL 29.283, AYK 4.110, GYK 1.367 ve VRM ise 107.69’dur.


Çizelge 4.20. Satsuma deneme alanı için tanımlayıcı istatistik, çarpıklık-basıklık ve Shapiro-Wilk normalite testi sonuçları

Değişken	N	Min.	Mak.	Ort.	Standart Sapma	Değişkenlik Katsayısı (%)	Çarpıklık	Basıklık	Shapiro Wilk
SRY	30	6.733	14.674	11.672	2.111	18.086	-0.784	-0.075	0.057
NDY	30	0.741	0.872	0.837	0.033	3.943	-1.503	1.898	0.000*
HNY	30	0.776	0.903	0.874	0.031	3.547	-1.858	2.887*	0.000*
NPY	30	-0.170	0.545	0.042	0.157	373.809	1.176	2.169*	0.027*
SPD	30	52.700	74.800	63.877	5.384	0.084	-0.221	0.260	0.376
NDI	30	0.483	0.767	0.631	0.066	10.460	-0.194	0.235	0.869
SRI	30	2.333	7.000	4.100	1.125	27.439	0.760	0.672	0.117
TAL	30	9.089	42.306	29.283	8.644	29.519	-0.966	0.320	0.006*
AYK	30	2.579	4.987	4.110	0.558	13.577	-1.272	1.890	0.008*
GYK	30	0.900	1.700	1.367	0.214	15.655	-0.400	-0.458	0.458
VRM	30	0.750	195.000	107.69	52.177	48.451	-0.146	-0.907	0.488

*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normalite testine göre normal dağılım göstermeyen veriler

Satsuma mandalinası deneme alanı için hesaplanan ve Çizelge 4.20’de verilen çarpıklık ve basıklık katsayıları ve Şekil 4.18’de verilen histogram grafiklerine göre, verim değişkeni hafif sola çarpık ve hafif basık olmak üzere normal dağılım göstermektedir. Yersel hiperspektral verilerden hesaplanan indekslerden SRY’nin hafif sola çarpık ve hafif basık dağılım, NDY’nin sola çarpık ve sivri dağılım, HNY’nin sola çarpık ve basık dağılım, NPY’nin ise sağa çarpık ve sivri dağılım gösterdiği belirlenmiştir. Satsuma ağaç yapraklarının klorofil ölçüm değerlerini içeren SPD bağımsız değişkeni için elde edilen ölçüm değerlerinin hafif sola çarpık ve hafif sivri dağılım gösterdiği tespit edilmiştir. MS verilerden hesaplanan indekslerden NDI’nın çarpıklık katsayısı bakımından hafif sola çarpık ve basıklık katsayısı bakımından hafif sivri dağılım gösterdiği, SRI’nın ise hafif sağa çarpık ve hafif sivri dağılım gösterdiği

tespit edilmiştir. Bu deneme alanı için ağaçların dendrometrik bileşenlerinden taç alanının hafif sola çarpık hafif sivri dağılım, ağaç yüksekliğinin sola çarpık ve sivri dağılım ve gövde yüksekliğinin ise hafif sola çarpık ve hafif basık dağılım gösterdiği belirlenmiştir. Satsuma mandalinası deneme alanlarındaki ağaçlara ait değişkenlerin normal dağılım gösterip göstermediği çarpıklık ve basıklık katsayılarının yanı sıra Shapiro-Wilk testleri ile de kontrol edilmiştir. Sonuç olarak, Shapiro-Wilk testlerine göre ($P>0.05$), SRY, NDY, HNY, NPY, TAL ve AYK bağımsız değişkenlerinin normal dağılım göstermediği ve ayrıca bunlardan çarpıklık katsayısına göre normal dağılım gösteren NPY verilerinin hem basıklık hem de Shapiro-Wilk testi sonucuna göre normal dağılmadığı belirlenmiştir. Satsuma deneme alanı için üç normallik katsayısının tümü aynı anda dikkate alındığında ise tüm değişkenlerin normal dağılım gösterdiği belirlenmiştir.



Şekil 4.18. Satsuma deneme alanı histogram grafikleri

Clementine mandalinası ve portakal bahçelerinde olduğu gibi Satsuma deneme alanındaki ağaçlardan elde edilen verilerin bazılarının normal dağılım göstermemesi nedeniyle korelasyon analizi kapsamında parametrik olmayan Spearman'ın sıralama korelasyon katsayıları hesaplanmıştır (Çizelge 4.21).

Çizelge 4.21. Satsuma deneme alanı Spearman'ın korelasyon analizi sonuçları

	SRY	NDY	HNY	NPY	SPD	NDI	SRI	TAL	AYK	GYK	VRM
SRY	1.000	1.000**	0.833**	0.055	0.675**	0.044	0.028	0.040	0.239	0.140	0.317
NDY	1.000**	1.000	0.833**	0.055	0.675**	0.044	0.028	0.040	0.239	0.140	0.317
HNY	0.833**	0.833**	1.000	0.083	0.352	-0.026	-0.020	0.018	0.060	0.157	0.205
NPY	0.055	0.055	0.083	1.000	0.120	0.273	0.293	0.298	0.239	0.345	0.140
SPD	0.675**	0.675**	0.352	0.120	1.000	0.109	0.097	-0.050	0.239	0.154	0.291
NDI	0.044	0.044	-0.026	0.273	0.109	1.000	0.983**	0.249	0.628**	0.655**	-0.177
SRI	0.028	0.028	-0.020	0.293	0.097	0.983**	1.000	0.279	0.656**	0.684**	-0.124
TAL	0.040	0.040	0.018	0.298	-0.050	0.249	0.279	1.000	0.653**	0.339	0.397*
AYK	0.239	0.239	0.060	0.239	0.239	0.628**	0.656**	.653**	1.000	0.710**	0.406*
GYK	0.140	0.140	0.157	0.345	0.154	0.655**	0.684**	0.339	0.710**	1.000	0.255
VRM	0.317	0.317	0.205	0.140	0.291	-0.177	-0.124	0.397*	0.406*	0.255	1.000

*Correlation is significant at the 0.05 level (2-tailed).

**Correlation is significant at the 0.01 level (2-tailed).

Satsuma mandalinası deneme alanındaki ağaçlar için hesaplanan Spearman'ın korelasyon katsayıları incelendiğinde, verim (VRM) bağımlı değişkeni ile ağaç dendrometrik özelliklerinden TAL ve AYK arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (0.05 güven düzeyinde). Ayrıca VRM ile SRY, NDY, HNY, NPY, SPD ve GYK bağımsız değişkenleri arasında zayıf ve pozitif yönlü ilişkiler belirlenirken yine VRM ile sadece İHA MS verilerden hesaplanan indeksler arasında zayıf ve negatif yönlü ilişkiler tespit edilmiştir. Bu deneme alanında yersel hiperspektral ölçümlerden hesaplanan NDVI (NDY) ile yine yersel hiperspektral ölçümlerden hesaplanan basit oran indeksi (SRY) arasında mükemmel ilişki; yersel hiperspektral ölçümlerden hesaplanan HNDVI (HNY) ile SRY ve NDY arasında güçlü ve pozitif ilişki, yersel hiperspektral ölçümlerden hesaplanan NPCI (NPY) ile SRY, NDY ve HNY arasında ise zayıf ve pozitif yönlü ilişkiler tespit edilmiştir. Yaprak klorofil ölçüm değerleri olan SPD ile SRY ve NDY arasında güçlü ve pozitif, SPD ile HNY arasında ise orta pozitif yönlü ilişkiler belirlenirken, SPD ile NPY, NDI, SRI ve AYK arasında zayıf düzeyde pozitif yönlü ilişki tespit edilmiştir. Bu alanda MS-İHA verilerinden hesaplanan indeks değerleri (SRI ve NDI) arasında güçlü ve pozitif yönlü ilişki belirlenmiştir. MS verilerden hesaplanan bu indekslerden NDI ve SRI ile ağaç ağaç yüksekliği (AYK) ve gövde yüksekliği (GYK) arasında güçlü pozitif ve taç alanı (TAL) zayıf pozitif yönlü ilişkiler bulunmuştur. Ayrıca

Satsuma narenciye ağaçlarının dendrometrik özelliklerinden AYK ve GYK arasında güçlü ve pozitif yönlü ilişkiler olduğu tespit edilmiştir.

Çalışma alanında bulunan tüm narenciye ağaçlarında gerçekleştirilen istatistiksel analizler sonucunda, verim bağımlı değişkeni ile bağımsız bazı değişkenler arasında %95 güven seviyesinde ve orta düzeyde ilişkiler tespit edilirken bazı değişkenler ile de negatif yönlü ilişkiler olduğu olduğu belirlenmiştir. Chang vd. (2020) narenciye ağaçlarında yeşillenme hastalığının karakterizasyonu amacıyla gerçekleştirdikleri bir çalışmada İHA MS görüntülerinden elde edilen narenciye ağaçlarının kanopi şekli ve bitki örtüsü indekslerini karşılaştırmışlardır. Araştırma sonuçları, İHA ve yersel ölçümler arasındaki ağaç yüksekliği ve taç çapı korelasyon katsayılarının sırasıyla 0.7 ve 0.8 olduğunu göstermiştir. Ayrıca aynı araştırmacılar İHA tabanlı kanopi hacminin, yersel ölçümlerle de yüksek oranda ilişkili ($R^2 > 0,9$) olduğunu ortaya koymuşlardır. Bostan ve İşbakan (2020) fındık verimi üzerine yaptıkları çalışmada, verim ile toplam çotanak sayısı arasında pozitif ilişki olduğunu, yan dal sayısı ile negatif yönlü ilişki olduğunu belirtmişlerdir. Çalışma ile elde eden sonuçlarda çotanak sayısı ile verim arasında pozitif yönlü ilişki olması benzerlik göstermektedir. Ayrıca, toplam çotanak sayısı ile verim arasındaki pozitif yönlü ilişki fındık üzerine yapılan çalışmalarda da pozitif önemli ilişkiler belirtilmektedir (Bozkurt ve Bostan, 2017; Bostan ve İşbakan, 2020). Sumesh vd. (2021) İHA kullanarak şeker kamışında verim tahmini için RGB tabanlı bitki örtüsü indeksi, ekin yüzey modeli ve nesne tabanlı görüntü analizi yaklaşımının entegrasyonu ile ilgili bir çalışma gerçekleştirmişlerdir. Araştırmacıların elde ettiği bulgular, İHA ve OBIA yaklaşımından elde edilen çok yüksek çözünürlüklü RGB tabanlı görüntülerin, bitki boyu ve sap yoğunluğunun uzamsal değişkenliğini haritalamak ve verimi tahmin etmek için önemli bir potansiyel olduğunu göstermiştir. Araştırmacıların elde ettikleri bulgular, tez çalışmasından elde edilen bulgular ile paralellik göstermektedir.

4.8. Verim Tahmin Modelleri

Verim tahmini tek yıllık ya da çok yıllık bitkisel üretim alanlarında etkili bir tarım politikasının oluşturulması bakımından oldukça önemlidir. Geleneksel verim tahmin yöntemleri hem zaman alıcı hem de maliyetli uygulamaları içerdiğinden bu kapsamda uzaktan algılama verileri kullanılabilir (Sishodia vd. 2020; Kumar vd. 2023). Tarımsal üretim alanlarında verim tahmini, istatistiksel olmayan toprak ya da meteorolojik veriler gibi daha fazla parametrenin kullanımı ile gerçekleştirilebilmektedir. Ancak bu yöntem hem daha fazla parametre kullanımı hem de veri işleme karmaşıklığı gibi bazı dezavantajları nedeniyle geniş çapta uygulanamamaktadır. Bir başka verim tahmin yöntemi olan istatistiksel modellemede ise ürün parametreleri ve elde edilen uzaktan algılama verileri arasında doğrudan bir ilişki kurulabilmektedir. Bu yöntemin temel avantajı, az sayıda bağımsız değişken ve daha kolay hesaplama ile verim tahmini yapılabilmesidir (Feng vd. 2022). Bu kapsamda, farklı bitki türlerinde MS ve hiperspektral veriler ile bu verilerden hesaplanan bitki örtüsü indeksleri girdi olarak kullanılmıştır. Araştırmacılar bu çalışmalarda, YSA, çoklu doğrusal regresyon, RFR, doğrusal regresyon, GBR ve PLSR gibi farklı istatistiksel makine öğrenme algoritmaları kullanarak verim tahmini gerçekleştirmişlerdir (Zhou vd. 2017; Zhu vd. 2018; Uno vd. 2005; Ye vd. 2010; Vijayakumar vd. 2023).

Verim tahmininde istatistiksel modelleme kullanılan çalışmada Zeng vd. (2018) PLSR ve YSA modelleri kullanarak ayçiçeğinde verim tahmini gerçekleştirmişlerdir.

Araştırmacılar bu iki istatistiksel modelin ayçiçeğinin tohum verimindeki etkinliğini test etmeyi amaçlamışlardır. Araştırmacılar tarafından elde edilen bulgulara göre, PLSR karşılaştırılabilir bir doğruluk değeri vermiş ancak YSA modeli PLSR'ye göre daha iyi performans göstermiştir. Her ne kadar Zeng vd. (2018) tarafından yapılan bu çalışmada YSA, PLSR'ye göre da iyi bir sonuç vermiş olsa da Vijayakumar vd. (2023) tarafından portakal ağaçlarında gerçekleştirilen ve PLSR de dahil olmak üzere farklı makine öğrenme algoritmalarının değerlendirildiği çalışmada PLSR tek ağaç düzeyinde verim tahmininde daha düşük mutlak ortalama yüzde hata değeri ve veri toplama kolaylığı nedeniyle en iyi model olarak seçilmiştir. Bu kapsamda çalışmada verim tahmin modellerinin oluşturulmasında PLSR analizleri gerçekleştirilmiştir.

Verim bağımlı değişkeninin PLSR analizi ile tahmininde kullanılacak bağımsız değişkenlerden oluşturulan 4 farklı verim tahmin modeli Çizelge 4.22'de verilmiştir. Uzaktan algılama çalışmalarında ağaç dendrometrik bileşenlerinin tespit edilmesine yönelik araştırmalarda genellikle ağaç yüksekliği (Sarron vd. 2018; Chen vd. 2022; Çoşlu ve Sönmez 2022), taç yapısı (Özdarıcı-Ok 2015; Özcan vd. 2017; Csillik vd. 2018; Koç-San vd. 2018) ve taç alanı (Sarron vd. 2018; Dong vd. 2020; Chen vd. 2022) gibi parametreler yaygın olarak hesaplandığı için, narenciye ağaçlarının verim tahmin modellerinde bu parametreler dikkate alınmıştır. Çalışmada kullanılan Model-1 yersel hiperspektral verilerden hesaplanan indeksler ve yaprak klorofil ölçüm değerlerinden, Model-2 MS-İHA verilerinden hesaplanan indeks değerleri ve ağaç dendrometrik bileşenleri ve Model-3 tüm bağımsız değişkenlerden oluşmaktadır. Model-4 ise bu 3 modelin karşılaştırma sonuçlarına göre en yüksek belirleme katsayısına sahip modelin projeksiyondaki değişken önem (VIP) değerleri 0.8 eşik değerinin üzerinde olan bağımsız değişkenlerinden oluşmaktadır. Çalışma alanındaki portakal ve mandalina ağaçlarında, arazide şerit metre ile ölçülen gövde yüksekliği değişkeni ise narenciye çeşitleri içerisinde benzer değerler aldığından dolayı bu değişkene verim tahmin modellerinde yer verilmemiştir.

Çizelge 4.22. Verim tahmin modelleri

Model adı	Bağımsız değişkenler	Bağımlı değişken
Model-1	SRY-NDY-HNY-NPY-SPD	VRM
Model-2	NDI-SRI- TAL-AYK	
Model-3	SRY-NDY-HNY-NPY-SPD-NDI-SRI-TAL-AYK	
Model-4*	VIP > 0.8	

*En yüksek belirleme katsayısına sahip modelin bağımsız değişkenlerinden VIP > 0.8 olanlar


4.8.1. Washington deneme alanı için verim tahmin modelleri

Beş bağımsız değişkenden oluşan Model 1 için (Yersel, NDY-SRY-HNY-NPY-SPD) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 5 (%29.453) olarak bulunmuştur. Analiz sonucu karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin

%13.573'den %29.453'e yükseldiği görülmektedir. Ancak bu değişimin faktör sayısındaki artışla orantılı olarak artmadığı ve 2 faktörden sonra yatay olarak devam ettiği tespit edilmiştir (Çizelge 4.23 ve Şekil 4.19).

Çizelge 4.23. Washington Model-1 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	60.939	13.573	1
2	82.791	25.979	4
3	96.169	27.442	4
4	99.901	29.251	4
5	100	29.453	4



Şekil 4.19. Washington Model-1 için açıklanan yüzde değişim


Çizelge 4.24'de verilen ve PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen kök ortalama PRESS (RMPRESS) değerleri en düşük 1 faktörlü (1.023), en yüksek 5 faktörlü (1.274) olarak belirlenmiştir. Her ne kadar verim değişkenini açıklama oranı en yüksek 5 faktör için elde edilmiş olsa da Çizelge ve grafik incelendiğinde en düşük RMPRESS değerinin (1.023) 1 faktör kullanıldığında elde edildiği tespit edilmiştir. Ancak Şekil 4.19 incelendiğinde faktör sayısının 2 olarak alınması durumunda bağımlı değişkenini açıklama oranının %13.573'den % 25.979'a yükseldiği görülmektedir. Bu nedenle verim tahmin modeli için 2 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.24. Washington Model-1 RMPRESS değerleri



*RMPRESS 1.023 ve minimum faktör sayısı 1'dir.

Değişken önem grafiği ve tablosu incelendiğinde 2 faktörlü PLSR NIPALS analiz sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde yer alan 4 bağımsız değişkenden (SPD, SRY, NDY ve HNY), klorofil ölçüm değerlerinden elde edilen SPD (1.586) değişkeninin en yüksek değere sahip olduğu görülmektedir. Bu model için yersel hiperspektral verilerden hesaplanan NPY için (0.484) ise en düşük VIP değeri hesaplandığı belirlenmiştir (Şekil 4.20).




Şekil 4.20. Washington Model-1 için değişken önem grafiği

Washington portakalı deneme alanında Model 2 için (İHA, NDI-SR-TAL-AYK) uygulanan PLSR analizi sonucunda, verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 4 (%28.686) olarak bulunmuştur. Analiz sonucu karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %24.147'den %28.686'a yükseldiği görülmektedir. Ancak bu artışın faktör sayısının artışıyla doğru orantılı olarak artmadığı ve faktör sayısındaki artışa rağmen verim değişkenini açıklamada sadece %4.5'lik bir artış sağlayabildiği belirlenmiştir (Çizelge 4.25 ve Şekil 4.21).


Çizelge 4.25. Washington Model-2 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	59.080	24.147	3
2	72.793	26.328	3
3	95.262	27.055	3
4	100	28.686	4




Şekil 4.21. Washington Model-2 için açıklanan yüzde değişim

Çizelge 4.26 ve grafikte verilen NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 1 faktörlü (0.943) ve en yüksek 0 faktörlü (1.035) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 4 faktör için elde edilmiş olsa da Çizelge incelendiğinde en düşük RMPRESS değerinin (0.943) 1 faktör kullanıldığında elde edildiği tespit edilmiştir. Bu nedenle tahmin için 1 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.26. Washington Model-2 RMPRESS değerleri

*RMPRESS 0.943 ve minimum faktör sayısı 1'dir.

Değişken önem grafiği ve tablosu incelendiğinde 1 faktörlü PLSR NIPALS analiz sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde 3 bağımsız değişken olduğu ve bu değişkenlerin VIP değerlerine göre sırasıyla NDI (1.23), AYK (1.03) ve SRI (0.93) olduğu tespit edilmiştir. Ayrıca bu model için ağaç taç alanı (TAL) değişkeninin en düşük VIP değeri (0.740) sahip olduğu belirlenmiştir (Şekil 4.22).


**Şekil 4.22.** Washington Model-2 değişken önem grafiği

Çalışmada kullanılan tüm bağımsız değişkenlerden oluşan Model 3 için (Yersel NDY-SRY-HNY-NPY-SPD ve İHA NDI-SR-TAL-AYK) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 9 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %33.63'den %49.60'a yükseldiği görülmektedir.

Ancak faktör sayısının 9 kat artmasının verim bağımlı değişkeninde önemli ölçüde bir artışa neden olmadığı tespit edilmiştir. Hatta bu model için 3 faktörden sonra verim bağımlı değişkenini açıklamada sadece %2’lik bir artışın olduğu belirlenmiştir (Çizelge 26 ve Şekil 4.23).

Çizelge 4.27. Washington Model-3 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	31.588	33.628	5
2	61.296	40.450	5
3	73.629	47.598	5
4	82.683	48.636	5
5	88.452	49.195	5
6	91.084	49.590	5
7	99.220	49.595	5
8	99.947	49.600	5
9	100	49.602	5




Şekil 4.23. Washington Model-3 için açıklanan yüzde değişim

Çizelge 4.28’de verilen NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 1 faktörlü (0.97) ve en yüksek 9 faktörlü (1.37) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 9 faktör için elde edilmiş olsa da çapraz doğrulama sonucu elde edilen


Çizelge ve grafik incelendiğinde en düşük RMPRESS değerinin (0.97) 1 faktör kullanıldığında elde edildiği tespit edilmiştir. Ancak Şekil 4.23 incelendiğinde faktör sayısının 3 olarak alınması durumunda bağımlı değişkenini açıklama oranının %33.628'den %47.598'e yükseldiği görülmektedir. Bu nedenle verim tahmin modeli için 3 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.28. Washington Model-3 RMPRESS değerleri



*RMPRESS 0.966 ve minimum faktör sayısı 1'dir.

Model-3 için değişken önem grafiği ve tablosu incelendiğinde 1 faktörlü analiz sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde 5 bağımsız değişken olduğu görülmektedir. Bu değişkenler VIP değerlerine göre sırasıyla SPD (1.536), NDI (1.287), AYK (1.180), SRI (1.061) ve TAL (1.007)'dir. Bu model için her ne kadar yersel verilerden elde edilen bağımsız değişkenlerden biri olan SPD için en yüksek VIP değeri elde edilmiş olsa da İHA'dan elde edilen bağımsız değişkenlerin sayısının daha fazla olduğu tespit edilmiştir (Şekil 4.24).



Şekil 4.24. Washington Model-3 değişken önem grafiği


Washington portakalı deneme alanında, Model-1 sadece 2 faktörle verim bağımlı değişkenindeki varyasyonun %25.979'unu, Model-2 1 faktörle %24.147 ve Model-3 ise %47.598'ini açıklamaktadır. Faktör sayıları bakımından değerlendirildiğinde tüm modeller için en düşük RMPRESS değeri 1 faktör ile elde edilmiştir. Ancak iki faktörlü PLSR NIPALS sonuçlarına göre, Model-1'de dört, Model-2'de üç ve Model-3'de ise beş bağımsız değişken önem eşik değerinin ($VIP > 0.8$) üzerinde bir değere sahip olup, bu durum diğerlerine göre daha yüksek VIP değerine sahip bu bağımsız değişkenlerin daha önemli olduğu anlamına gelmektedir.

Washington portakalı ağaçlarında verim tahmini için oluşturulan modellerin karşılaştırılması amacıyla, deneme alanındaki 30 ağacın 23'ü eğitim ve 7'si de doğrulama için ayrılmıştır. Modellerin karşılaştırılması sonucu elde edilen ve en yüksek R^2 , en düşük RMSE ve MAE değerlerine göre sıralanan modeller Çizelge 4.29 ve Şekil 4.25'de görüldüğü gibidir.

Çizelge 4.29. Washington 3 Model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R ²	RMSE	MAE	Verim Model Eşitliği
Model-3	0.720	21.775	18.114	-0.339 * SRY + -6.931 * NDY + -25.339 * HNY + -0.098 * NPY + 4.380 * SPD + 117.714 * NDI + -0.017 * SRI + -0.498 * TAL + 39.018 * AYK + (-425.591)
Model-1	0.472	29.871	25.067	-0.482 * SRY + -6.647 * NDY + -31.555 * HNY + -0.919 * NPY + 4.398 * SPD + (-200.699)
Model-2	0.223	36.222	31.798	127.097 * NDI + 9.664 * SRI + 0.958 * TAL +17.340 * AYK + (-133.605)


Washington portakalı deneme alanındaki modellerin karşılaştırma sonuçlarına göre, Model-2 en düşük (0.223), Model-3 ise en yüksek (0.720) belirleme katsayısına sahip olduğu ortaya çıkmıştır. Çalışma kapsamında oluşturulan üç modelden biri olan ve tüm bağımsız değişkenlerin yer aldığı Model-3, en düşük RMSE ve MAE ile en yüksek R² değerine sahip olup diğer modellerle karşılaştırıldığında en iyi performansı göstermiştir.

**Şekil 4.25.** Washington üç modele göre tahmin edilen ve gerçekleşen verim grafiği


Bu deneme alanında tüm bağımsız değişkenlerin yer aldığı Model-3 (İHA ve yersel) için gerçekleştirilen PLSR analizi sonucunda elde edilen VIP değerlerine göre daha önemli (>0.8) olan değişkenler (SPD, NDI, SRI, TAL, AYK) kullanılarak yeniden PLSR analizi yapılmıştır. Uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 5 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %36.209'dan %48.069'a yükseldiği görülmektedir. Ancak faktör sayısının 1'den 2'ye yükselmesi durumunda verimdeki değişimi açıklama yüzdesi 36.209'dan 45.391'e yükselirken, 2 faktörden sonra sadece %3'lük bir artışın olduğu belirlenmiştir (Çizelge 4.30 ve Şekil 4.26).

Çizelge 4.30. Washington Model-4 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	47.278	36.209	4
2	63.649	45.391	4
3	77.351	47.442	4
4	98.231	47.632	4
5	100	48.069	4


**Şekil 4.26.** Washington Model-4 için açıklanan yüzde değişim

Çizelge 4.31’de verilen ve PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 1 faktörlü (0.878), en yüksek 5 faktörlü (0.945) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 5 faktör için elde edilmiş olsa da Çizelge 4.31 incelendiğinde en düşük RMPRESS değerinin (0.878) 1 faktör kullanıldığında elde edildiği tespit edilmiştir. Ancak Şekil 4.26 incelendiğinde faktör sayısının 2 olarak alınması durumunda bağımlı değişkenini açıklama oranının %36.209’dan %45.391’e yükseldiği görülmektedir. Bu nedenle verim tahmin modeli için 2 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.31. Washington Model-4 RMPRESS değerleri

*RMPRESS 0.878 ve minimum faktör sayısı 1'dir.

Değişken önem grafiği incelendiğinde 2 faktörlü PLSR NIPALS analiz sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde yer alan 5 bağımsız değişkenden (SPD, NDI, SRI, TAL ve AYK), klorofil ölçüm değerlerinden elde edilen SPD (1.270) değişkeninin en yüksek değere sahip olduğu görülmektedir. Bu model için İHA verilerinden elde edilen değişkenler önem sırasına göre NDI (1.071), SRI (0.916) ve AYK (0.900) olup, ağaç taç alanı için Model-2'de (İHA) olduğu gibi en düşük VIP değeri (0.769) hesaplandığı belirlenmiştir. Ağaç taç alanı için elde edilen bu değer (0.769) eşik değere (0.8) yakın olduğundan modelde kalmasına karar verilmiştir. (Şekil 4.27).


**Şekil 4.27.** Washington Model-4 değişken önem grafiği

Model-4'den (İHA+SPAD) elde edilen bulgular Model-2 (İHA) sonuçları ile karşılaştırıldığında, 1 faktörlü sonucun (%36.209) 4 faktörlü Model-2 sonucundan (%28.686) daha yüksek olduğu tespit edilmiştir. Ayrıca Model-4'ün 2 faktörlü sonucunun Model-2'nin 2 faktörlü sonucuna kıyasla verim bağımlı değişkenini %19.063'lük bir farkla daha iyi açıklayabildiği belirlenmiştir. Model-4, tüm bağımsız değişkenlerin dahil edildiği Model-3 ile karşılaştırıldığında ise değerlerin birbirine yakın olduğu tespit edilmiştir. Özellikle 1 ve 2 faktörler için Model-4'ün daha yüksek açıklama oranına sahip olduğu ve diğer faktör sayıları için de Model-3 ile oldukça yakın değerler aldığı belirlenmiştir (Çizelge 4.32 ve Şekil 4.28).

Çizelge 4.32. Washington 4 model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R ²	RMSE	MAE	Verim Model Eşitliği
Model-3	0.719	21.775	18.114	-0.339 * SRY + -6.931 * NDY + -25.339 * HNY + -0.098 * NPY + 4.380 * SPD + 117.714 * NDI + -0.017 * SRI + -0.498 * TAL + 39.018 * AYK + (-425.591)
Model-4	0.670	23.606	21.063	3.950 * SPD + 107.666 * NDI + 1.553 * SRI + -0.047 * TAL + 32.087 * AYK + (-410.677)
Model-1	0.472	29.871	25.067	-0.482 * SRY + -6.647 * NDY + -31.555 * HNY + -0.919 * NPY + 4.398 * SPD + (-200.699)
Model-2	0.223	36.222	31.798	127.097 * NDI + 9.664 * SRI + 0.958 * TAL +17.340 * AYK + (-133.605)
Yersel hiperspektral okumalar (Spektrodymetre) SRY; Basit oran, NDY; Normalize edilmiş fark bitki indeksi, HNY; Hiperspektral normalize edilmiş fark bitki indeksi, NPY; Normalize edilmiş pigment klorofil indeksi İHA Uçuşları (MS alımlar ve LiDAR alımları) SRI; Basit oran, NDI; Normalize edilmiş fark bitki indeksi, TAL; Ağaç taç alanı, AYK; Ağaç yüksekliği Arazi Ölçümleri VRM; Verim, SPD; Yaprak klorofil okumaları				

Washington portakalı deneme alanında uygulanan 3 modelin karşılaştırma sonuçlarına Model-4 de dahil edilerek yeniden karşılaştırma yapılmıştır. Buna göre, Model-4'ün Model-3'e yakın bir R² (0.670), RMSE (23.606) ve MAE (21.063) sonucu verdiği tespit edilmiştir. Yapılan bu modellemelere göre, Washington portakalı deneme alanında yapılacak olan verim tahminin çalışmalarında, İHA'dan üretilen bitki indeksleri (NDI, SRI) ile İHA verileri ile hesaplanan ağaç dendrometrik bileşenlerin (TAL, AYK) birlikte kullanıldığı ayrıca bu veri setine ilaveten yersel klorofil ölçümlerinin yapıldığı (SPD) bağımsız değişkenler kullanılarak daha az sayıda faktör ve düşük maliyetle Model-4'ün verim tahmininde kullanılabileceği değerlendirilmiştir.




Şekil 4.28. Washington dört modele göre tahmin edilen ve gerçekleşen verim grafiği

4.8.2. Valencia deneme alanı için verim tahmin modelleri

Valencia portakalı deneme alanında Model 1 için (Yersel, NDY-SRY-HNY-NPY-SPD) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 5 (%46.574) olarak bulunmuştur. Analiz sonucu karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %23.272'den %46.574'e yükseldiği görülmektedir. Ancak bu değişimin faktör sayısındaki artışla orantılı olarak artmadığı tespit edilmiştir (Çizelge 4.33 ve Şekil 4.29).

Çizelge 4.33. Valencia Model-1 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	67.647	23.272	4
2	79.111	30.539	4
3	91.195	35.336	4
4	99.487	41.384	5
5	100	46.574	5



Şekil 4.29. Valencia Model-1 için açıklanan yüzde değişim


Çizelge 34’de verilen ve PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 4 faktörlü (0.948), en yüksek 5 faktörlü (1.012) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 5 faktör için elde edilmiş olsa da Çizelge ve grafik incelendiğinde en düşük RMPRESS değerinin (0.948) 4 faktör kullanıldığında elde edildiği tespit edilmiştir. Bu nedenle verim tahmin modeli için 4 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.34. Valencia Model-1 RMPRESS değerleri

Faktör sayısı	RMPRESS	Root Mean PRESS Plot
0	1.034	
1	1.008	
2	1.050	
3	0.993	
4	0.948*	
5	1.012	

*RMPRESS 0.948 ve minimum faktör sayısı 4’dür.

Değişken önem grafiği ve tablosu incelendiğinde 4 faktörlü PLSR NIPALS analiz sonuçlarına göre, tüm değişkenlerin Wold'un kriteri olan 0.8 değerinin üzerinde olduğu görülmektedir. Bu model için en yüksek önem değerine sahip değişken SPD, en düşük önem değerine sahip değişken ise HNY olup, değişken önem değerleri sırasıyla SPD (1.207), NDY (1.069), SRY (0.972), NPY (0.884) ve HNY (0.822)'dir (Şekil 4.30).




Şekil 4.30. Valencia Model-1 değişken önem grafiği

Model 2 (İHA, NDI-SR-TAL-AYK) için uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 4 (%46.105) olarak bulunmuştur. Analiz sonucu karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %36.725'den %46.105'e yükseldiği görülmektedir. Ancak bu artışın faktör sayısının artışıyla doğru orantılı olarak artmadığı ve faktör sayısındaki artışa rağmen verim değişkenini açıklamada sadece %9.38'lik bir artış sağlayabildiği belirlenmiştir (Çizelge 4.35 ve Şekil 4.31).

Çizelge 4.35. Valencia Model-2 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	71.522	36.725	4
2	89.722	39.500	4
3	96.93	43.888	4
4	100	46.105	4



Şekil 4.31. Valencia Model-2 için açıklanan yüzde değişim


Çizelge 4.36 ve grafikte verilen NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 1 faktörlü (0.984) ve en yüksek 3 faktörlü (1.175) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 4 faktör için elde edilmiş olsa da Çizelge incelendiğinde faktör sayısındaki artışın verim bağımlı değişkeninde çok fazla bir artışa neden olmadığı anlaşılmaktadır. Bu nedenle tahmin için 3 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.36. Valencia Model-2 RMPRESS değerleri



*RMPRESS 0.984 ve minimum faktör sayısı 1'dir.

Şekil 4.32’de verilen değişken önem grafiği ve tablosu incelendiğinde 3 faktörlü PLSR NIPALS analiz sonuçlarına göre, Wold’un kriteri olan 0.8 değerinin üzerinde 4 bağımsız değişken olduğu ve bu değişkenlerin VIP değerlerine göre sırasıyla NDI (1.177), SRI (1.049), AYK (0.875) ve TAL (0.865) olduğu tespit edilmiştir. Bu model için İHA verilerinden hesaplanan indeks değerleri ve ağaç dendrometrik bileşenlerinin kendi aralarında yakın öneme sahip oldukları belirlenmiştir.




Şekil 4.32. Valencia Model-2 değişken önem grafiği

Çalışmada kullanılan tüm bağımsız değişkenlerden oluşan Model 3 için (Yersel NDY-SRY-HNY-NPY-SPD ve İHA NDI-SR-TAL-AYK) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 9 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %39.048’den %54.949’a yükseldiği görülmektedir. Ancak faktör sayısının 9 kat artmasının verim bağımlı değişkeninde önemli ölçüde bir artışa neden olmadığı tespit edilmiştir. Hatta bu model için 4 faktörden sonra verim bağımlı değişkenini açıklamada sadece yaklaşık %4’lük bir artışın olduğu belirlenmiştir (Çizelge 4.37 ve Şekil 4.33).


Çizelge 4.37. Valencia Model-3 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	52.334	39.048	7
2	70.533	42.529	8
3	80.788	44.772	8
4	84.139	50.726	8
5	89.473	52.808	7
6	95.781	53.658	7
7	99.273	54.061	7
8	99.637	54.684	7
9	100	54.949	8




Şekil 4.33. Valencia Model-3 için açıklanan yüzde değişim

Çizelge 4.38’de verilen NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 1 faktörlü (0.881) ve en yüksek 4 faktörlü (1.116) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 9 faktör için elde edilmiş olsa da çapraz doğrulama sonucu elde edilen Çizelge ve grafik incelendiğinde en düşük RMPRESS değerinin (0.881) 1 faktör kullanıldığında elde edildiği tespit edilmiştir. Ancak Şekil 4.33 incelendiğinde faktör sayısının 5 olarak alınması durumunda bağımlı değişkenini açıklama oranının %39.048’den %50.726’a yükseldiği görülmektedir. Bu nedenle verim tahmin modeli için 4 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.38. Valencia Model-3 RMPRESS değerleri

*RMPRESS 0.966 ve minimum faktör sayısı 1'dir.

Model-3 için değişken önem grafiği ve tablosu incelendiğinde 4 faktörlü analiz sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde 8 bağımsız değişken olduğu görülmektedir. Bu değişkenler VIP değerlerine göre sırasıyla NDI (1.333), SRI (1.183), NDY (1.006), SPD (1.000), TAL (0.972), AYK (0.920), SRY (0.886) ve HNY (0.811)'dir. Bu model için yersel hiperspektral verilerden hesaplanan NPCI (NPY) en düşük önem değerine sahiptir (Şekil 4.34).

**Şekil 4.34.** Valencia Model-3 değişken önem grafiği


Valencia portakalı deneme alanında, Model-1 4 faktörle verim bağımlı değişkenindeki varyasyonun %41.384'ünü, Model-2 3 faktörle %43.888'ini ve Model-3 ise 4 faktörle %50.726'sını açıklamaktadır. Faktör sayıları bakımından değerlendirildiğinde tüm modeller için en düşük RMPRESS değeri 1 faktör ile elde edilmiştir. Ancak 4 faktörlü PLSR NIPALS sonuçlarına göre, Model-1'de beş, Model-2'de dört ve Model-3'de ise sekiz bağımsız değişken önem eşik değerinin ($VIP > 0.8$) üzerinde bir değere sahip olup, bu durum diğerlerine göre daha yüksek VIP değerine sahip bu bağımsız değişkenlerin daha önemli olduğu anlamına gelmektedir.

Valencia deneme alanında verim tahmini için oluşturulan modellerin karşılaştırılması amacıyla, 30 ağacın 23'ü eğitim ve 7'si de doğrulama için ayrılmıştır. Modellerin karşılaştırılması sonucu elde edilen ve en yüksek R^2 , en düşük RMSE ve MAE değerlerine göre sıralanan modeller Çizelge 4.39 ve Şekil 4.35'de görüldüğü gibidir.

Çizelge 4.39. Valencia 3 Model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R^2	RMSE	MAE	Verim Model Eşitliği
Model-3	0.685	9.887	9.174	$-3.997 * SRY + 356.759 * NDY + 50.082 * HNY$ $+2.503 * NPY + 1.230 * SPD + 362.761 * NDI +$ $-7.166 * SRI + -1.373 * TAL + 11.983 * AYK + (-511.434)$
Model-2	0.369	13.996	11.867	$355.653 * NDI + -3.720 * SRI + -1.535 * TAL$ $+20.990 * AYK + (-184.809)$
Model-1	0.317	14.555	12.426	$-9.218 * SRY + 947.676 * NDY + 97.485 * HNY$ $+5.372 * NPY + 1.500 * SPD + (-766.617)$

Bu deneme alanındaki modellerin karşılaştırma sonuçlarına göre, Model-1 en düşük (0.369), Model-3 ise en yüksek (0.685) belirleme katsayısına sahip olduğu belirlenmiştir. Çalışma kapsamında oluşturulan üç modelden biri olan ve tüm bağımsız değişkenlerin yer aldığı Model-3, en düşük RMSE ve MAE ile en yüksek R^2 değerine sahip olup diğer modellerle karşılaştırıldığında en iyi performansı göstermiştir. Bu alanda İHA verilerinin yer aldığı Model-2, ikinci en iyi model olup yersel hiperspektral verilerden elde edilen Model-3 ile yakın belirleme katsayısı ve hata değerlerine sahiptir.




Şekil 4.35. Valencia üç modele göre tahmin edilen ve gerçekleşen verim grafiği

Valencia portakalı deneme alanında tüm bağımsız değişkenlerin yer aldığı Model-3 (İHA ve yersel) için gerçekleştirilen PLSR analizi sonucunda elde edilen VIP değerlerine göre daha önemli (>0.8) olan 8 değişken (Yersel NDY-SRY-HNY-NPY-SPD ve İHA NDI-SR-TAL-AYK) kullanılarak yeniden PLSR analizi yapılmıştır. Uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 8 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %38.730'dan %53.633'e yükseldiği görülmektedir. Ancak faktör sayısında 4'den sonra meydana gelen artışların verim bağımlı değişkenini açıklama yüzdesini çok fazla etkilemediği ve Şekil 4.36'da verilen grafiğe göre yatay seyrettiği belirlenmiştir (Çizelge 4.40 ve Şekil 4.36).

Çizelge 4.40. Valencia Model-4 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	58.426	38.730	6
2	79.220	41.890	8
3	87.814	44.980	7
4	92.299	49.792	7
5	94.880	52.514	7
6	99.192	52.961	7
7	99.642	53.397	7
8	100	53.633	7



Şekil 4.36. Valencia Model-4 için açıklanan yüzde değişim


Çizelge 4.41’de verilen ve PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 1 faktörlü (0.878), en yüksek 1 faktörlü (1.072) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama oranı en yüksek 8 faktör için elde edilmiş olsa da Çizelge 4.41 incelendiğinde en düşük RMPRESS değerinin (0.878) 1 faktör kullanıldığında elde edildiği tespit edilmiştir. Ancak Şekil 4.36 incelendiğinde faktör sayısının 4 olarak alınması durumunda bağımlı değişkenini açıklama oranının %38.730’dan %49.792’ye yükseldiği görülmektedir. Bu nedenle verim tahmin modeli için 4 faktörlü PLSR NIPALS algoritması sonuçları kullanılmıştır.

Çizelge 4.41. Valencia Model-4 RMPRESS değerleri



*RMPRESS 0.878 ve minimum faktör sayısı 1'dir.

Değişken önem grafiği incelendiğinde, 4 faktörlü PLSR NIPALS analiz sonuçlarına göre, HNY dışında diğer tüm bağımsız değişkenlerin Wold'un kriteri olan 0.8 değerinin üzerinde yer aldığı görülmektedir. İHA'dan elde edilen indekslerin (NDI ve SRI) önem sırasına göre üst sırada yer aldığı ve hiperspektral verilerden hesaplanan HNY'nin ise en düşük (0.775) öneme sahip olduğu belirlenmiştir. Ancak yersel hiperspektral NDVI (HNY) için elde edilen bu değer (0.775) eşik değere (0.8) yakın olduğundan bu bağımsız değişkenin modelde kalmasına karar verilmiştir. (Şekil 4.37).




Şekil 4.37. Valencia Model-4 değişken önem grafiği

Yersel hiperspektral NPCI (NPY) hariç diğer tüm bağımsız değişkenlerin yer aldığı Model-4'den elde edilen bulgular Model-2 (İHA) sonuçları ile karşılaştırıldığında, 4 faktörlü Model-4 sonucunun (%49.792) 3 faktörlü Model-2 sonucundan (%43.888) daha yüksek olduğu tespit edilmiştir. Model-4, tüm bağımsız değişkenlerin dahil edildiği Model-3 ile karşılaştırıldığında ise değerlerin birbirine yakın olduğu tespit edilmiştir. İki model arasında NPY bağımsız değişkeninden kaynaklandığı değerlendirilen bu durum, NPY değişkenin modelden çıkarıldığında sonucu çok etkilemediğini göstermiştir.

Çizelge 4.42. Valencia 4 Model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R ²	RMSE	MAE	Verim Model Eşitliği
Model-3	0.685	9.887	9.174	-3.997 * SRY + 356.759 * NDY + 50.082 * HNY +2.503 * NPY + 1.230 * SPD + 362.761 * NDI + -7.166 * SRI + -1.373 * TAL + 11.983 * AYK + (-511.434)
Model-4	0.543	11.902	10.453	-3.777 * SRY + 335.351 * NDY + 91.208 * HNY +0.733 * SPD + 355.411 * NDI + -5.878 * SRI + -1.511 * TAL + 14.750 * AYK + (-510.266)
Model-2	0.369	13.996	11.867	355.653 * NDI + -3.720 * SRI + -1.535 * TAL +20.990 * AYK + (-184.809)
Model-1	0.317	14.555	12.426	-9.218 * SRY + 947.676 * NDY + 97.485 * HNY +5.372 * NPY + 1.500 * SPD + (-766.617)
Yersel hiperspektral okumalar (Spektrodymetre) SRY; Basit oran, NDY; Normalize edilmiş fark bitki indeksi, HNY; Hiperspektral normalize edilmiş fark bitki indeksi, NPY; Normalize edilmiş pigment klorofil indeksi İHA Uçuşları (MS alımlar ve LiDAR alımları) SRI; Basit oran, NDI; Normalize edilmiş fark bitki indeksi, TAL; Ağaç taç alanı, AYK; Ağaç yüksekliği Arazi Ölçümleri VRM; Verim, SPD; Yaprak klorofil okumaları				

Valencia portakalı deneme alanında uygulanan 3 modelin karşılaştırma sonuçlarına Model-4 de dahil edilerek yeniden karşılaştırma yapılmıştır (Çizelge 4.42). Buna göre, Model-4 ile Model-3 arasında %14.2'lik bir fark olduğu ve Valencia portakalı için yapılacak verim tahmini çalışmalarında Model-3'ün daha etkili bir şekilde kullanılabileceği sonucuna ulaşılmıştır (Şekil 4.38).




Şekil 4.38. Valencia dört modele göre tahmin edilen ve gerçekleşen verim grafiği

4.8.3. Clementine deneme alanı verim tahmin modelleri

Clementine mandalinası deneme alanında Model 1 için (Yersel, NDY-SRY-HNY-NPY-SPD) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 5 (%22.401) olarak bulunmuştur. Analiz sonucu karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %2.342'den %22.401'e yükseldiği görülmektedir (Çizelge 4.43 ve Şekil 4.39).

Çizelge 4.43. Clementine Model-1 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	66.835	2.342	2
2	78.324	6.266	2
3	88.587	13.507	4
4	99.755	17.197	4
5	100	22.401	5



Şekil 4.39. Clementine Model-1 için açıklanan yüzde değişim

Çizelge 4.44’de verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 0 faktörlü (1.035), en yüksek 3 faktörlü (1.546) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama bakımından çapraz doğrulama işlemi sonrası faktör sayısı sıfır olarak belirtilmiş olsa da verim tahmin modeli için en yüksek açıklama yüzdesine sahip faktör sayısı olan 5 faktör kullanılmıştır.


Çizelge 4.44. Clementine Model-1 RMPRESS değerleri



*RMPRESS 1.035 ve minimum faktör sayısı 0'dır.

Değişken önem grafiği ve tablosu incelendiğinde ise 5 faktörlü PLSR NIPALS analiz sonuçlarına göre, tüm değişkenlerin Wold’un kriteri olan 0.8 değerinin üzerinde

olduğu görülmektedir. Bu model için en yüksek önem değerine sahip değişken SPD, en düşük önem değerine sahip değişken ise HNY olup, değişken önem değerleri sırasıyla SPD (1.179), NPY (0.978), NDY (0.978), SRY (0.971), ve HNY (0.869)'dir (Şekil 4.40).




Şekil 4.40. Clementine Model-1 Değişken önem grafiği

Model 2 (İHA, NDI-SR-TAL-AYK) için uygulanan PLSR analizi sonucunda verim bağımlı değişkenini açıklama yüzdesi bakımından önemli bir fark tespit edilmemiştir. Analiz sonucu karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %9.083'den %11.573'e yükseldiği ve verim değişkenini açıklamada bir ve dört faktör arasında sadece %2.49'luk bir artış sağlayabildiği belirlenmiştir (Çizelge 4.45 ve Şekil 4.41).

Çizelge 4.45. Clementine Model-2 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	60.073	9.083	3
2	88.322	10.470	3
3	99.090	11.190	3
4	100	11.572	3



Şekil 4.41. Clementine Model-2 için açıklanan yüzde değişim

Çizelge 4.46’da verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 0 faktörlü (1.035), en yüksek 4 faktörlü (1.110) olarak belirlenmiştir. Her ne kadar verim bağımlı değişkenini açıklama bakımından çapraz doğrulama işlemi sonrası faktör sayısı sıfır olarak belirtilmiş olsa da verim tahmin modeli için en uygun faktör ve açıklama yüzdesine sahip olduğu değerlendirilen 1 faktör kullanılmıştır.


Çizelge 4.46. Clementine Model-2 RMPRESS değerleri



*RMPRESS 1.035 ve minimum faktör sayısı 0'dir.

Değişken önem grafiği ve tablosu incelendiğinde 1 faktörlü PLSR NIPALS analiz sonuçlarına göre, Wold’un kriteri olan 0.8 değerinin üzerinde 3 bağımsız değişken olduğu

ve bu değişkenlerin VIP değerlerine göre sırasıyla NDI (1.227), SRI (1.310), ve TAL (0.878) olduğu tespit edilmiştir (Şekil 4.42). Bu model için İHA verilerinden hesaplanan ağaç dendrometrik bileşenlerinden olan ağaç yüksekliğinin (AYK) önem değeri bakımından oldukça düşük bir değer aldığı belirlenmiştir.




Şekil 4.42. Clementine Model-2 değişken önem grafiği

Çalışmada kullanılan tüm bağımsız değişkenlerden oluşan Model 3 için (Yersel NDY-SRY-HNY-NPY-SPD ve İHA NDI-SR-TAL-AYK) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 9 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %10.380'den %31.854'e yükseldiği görülmektedir (Çizelge 4.47 ve Şekil 4.43).


Çizelge 4.47. Clementine Model-3 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	36.634	10.380	4
2	58.939	16.474	7
3	77.192	20.330	8
4	84.367	21.812	8
5	92.662	24.267	7
6	97.170	28.053	8
7	99.557	29.069	8
8	99.757	31.597	9
9	100	31.854	9




Şekil 4.43. Clementine Model-3 için açıklanan yüzde değişim

Çizelge 4.48’de verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 0 faktörlü (1.035), en yüksek 5 faktörlü (1.582) olarak belirlenmiştir. Bu modelde her ne kadar verim bağımlı değişkenini açıklama bakımından çapraz doğrulama işlemi sonrası faktör sayısı sıfır olarak belirtilmiş olsa da verim tahmin modeli için en uygun faktör ve açıklama yüzdesine sahip olduğu değerlendirilen 6 faktör kullanılmıştır.

Çizelge 4.48. Clementine Model-3 RMPRESS değerleri

*RMPRESS 1.035 ve minimum faktör sayısı 0'dır.

Model-3 için değişken önem grafiği ve çizelgesi incelendiğinde 6 faktörlü analiz sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde 8 bağımsız değişken olduğu görülmektedir. Bu değişkenler VIP değerlerine göre sırasıyla SRI (1.105), AYK (1.090), NDI (1.066), SPD (1.052), HNY (1.046), NPY (1.005), SRY (0.917), TAL (0.913)'dir. Çizelge ve grafiğe göre en düşük önem değerine sahip bağımsız değişken NDY (0.756)'dir (Şekil 4.44).

**Şekil 4.44.** Clementine Model-3 değişken önem grafiği


Clementine mandalinası deneme alanında tüm modeller için PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 0 faktörlü (1.035) olarak bulunmuştur. Bu nedenle verim tahmin modeli için faktör sayısı seçiminde, en düşük faktör ve en yüksek varyasyon açıklama yüzdesi dikkate alınarak karar verilmiştir. Buna göre, Model-1 5 faktörle verim bağımlı değişkenindeki varyasyonun %22.401'ini, Model-2 1 faktörle %9.083'ünü ve Model-3 ise 6 faktörle %28.053'ünü açıklamaktadır. Faktör sayıları bakımından değerlendirildiğinde tüm modeller için en düşük RMPRESS değeri 0 faktör ile elde edilmiştir. Ancak 5 faktörlü PLSR NIPALS sonucuna göre Model-1'de beş, 3 faktörlü PLSR NIPALS sonucuna göre Model-2'de üç ve 8 faktörlü PLSR NIPALS sonucuna göre Model-3'de ise sekiz bağımsız değişken önem eşik değerinin ($VIP > 0.8$) üzerinde bir değere sahip olup, bu durum diğerlerine göre daha yüksek VIP değerine sahip bu bağımsız değişkenlerin daha önemli olduğu anlamına gelmektedir.

Clementine mandalinası deneme alanında verim tahmini için oluşturulan modellerin karşılaştırılması amacıyla, 30 ağacın 23'ü eğitim ve 7'si de doğrulama için ayrılmıştır. Modellerin karşılaştırılması sonucu elde edilen ve en yüksek R^2 , en düşük RMSE ve MAE değerlerine göre sıralanan modeller Çizelge 4.49 ve Şekil 4.45'de görüldüğü gibidir.

Çizelge 4.49. Clementine 3 model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R^2	RMSE	MAE	Verim Model Eşitliği
Model-1	0.302	10.811	8.999	$-2.809 * SRY + -680.192 * NDY + 999.006 * HNY + 0.806 * NPY + 0.675 * SPD + (-187.625)$
Model-3	0.131	12.059	10.240	$-3.631 * SRY + -64.839 * NDY + 405.403 * HNY + 4.506 * NPY + 0.010 * SPD + 61.267 * NDI + 4.773 * SRI + -0.132 * TAL + -4.974 * AYK + (-174.998)$
Model-2	0.019	12.814	9.947	$28.510 * NDI + 2.372 * SRI + 0.233 * TAL + -0.389 * AYK + 76.627$

Bu deneme alanındaki modellerin karşılaştırma sonuçlarına göre, Model-1 en yüksek (0.302), Model-2 ise en düşük (0.685) belirleme katsayısına sahiptir. Çalışma kapsamında oluşturulan üç modelden biri olan ve yersel hiperspektral veriler ile SPAD verilerini içeren değişkenlerin yer aldığı Model-1, en düşük RMSE ve MAE ile en yüksek R^2 değerine sahip olup diğer modellerle karşılaştırıldığında en iyi performansı göstermiştir.




Şekil 4.45. Clementine üç modele göre tahmin edilen ve gerçekleşen verim grafiği

Clementine mandalinası deneme alanında tüm bağımsız değişkenlerin yer aldığı Model-3 (İHA ve yersel) için gerçekleştirilen PLSR analizi sonucunda elde edilen VIP değerlerine göre daha önemli (>0.8) olan 8 değişken (Yersel NPY-SRY-HNY-NPY-SPD ve İHA NDI-SR-TAL-AYK) kullanılarak yeniden PLSR analizi yapılmıştır. Uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 8 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %11.179'dan %28.066'ya yükseldiği görülmektedir. Ancak faktör sayısında 6'dan sonra meydana gelen artışların verim bağımlı değişkenini açıklama yüzdesini çok fazla etkilemediği ve grafiğe göre yatay seyrettiği belirlenmiştir (Çizelge 4.50 ve Şekil 4.46).

Çizelge 4.50. Clementine Model-4 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	34.907	11.179	4
2	46.275	19.181	6
3	74.985	20.349	7
4	84.080	21.789	6
5	92.767	23.934	6
6	97.047	27.315	8
7	99.664	27.946	8
8	100	28.066	8



Şekil 4.46. Clementine Model-4 için açıklanan yüzde değişim

Çizelge 4.51’de verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 0 faktörlü (1.035), en yüksek ise 5 faktörlü (1.574) olarak belirlenmiştir. Bu modelde her ne kadar verim bağımlı değişkenini açıklama bakımından çapraz doğrulama işlemi sonrası faktör sayısı sıfır olarak belirtilmiş olsa da verim tahmin modeli için en uygun faktör ve açıklama yüzdesine sahip olduğu değerlendirilen 6 faktör kullanılmıştır.

Çizelge 4.51. Clementine Model-4 RMPRESS değerleri


Faktör sayısı	RMPRESS
0	1.035*
1	1.160
2	1.451
3	1.398
4	1.474
5	1.574
6	1.535
7	1.535
8	1.532

Root Mean PRESS Plot

Bar Color: Number of factors

*RMPRESS 1.035 ve minimum faktör sayısı 0'dır.

Model-4 için değişken önem grafiği incelendiğinde ise, 6 faktörlü PLSR NIPALS analiz sonuçlarına göre, analize dahil edilen tüm bağımsız değişkenlerin (8 bağımsız değişken) Wold'un kriteri olan 0.8 değerinin üzerinde yer aldığı görülmektedir. Bu değişkenlerden İHA'dan elde edilen AYK en yüksek önem değerine (1.223) sahipken NPY en düşük önem değerine (0.848) sahiptir (Şekil 4.47).



Şekil 4.47. Clementine Model-4 değişken önem grafiği


Yersel hiperspektral NDVI (NDY) hariç diğer tüm bağımsız değişkenlerin yer aldığı Model-4'den elde edilen bulgulara göre 6 faktörlü Model-4 sonucunun (%27.315), yine 6 faktörlü Model 3 (28.053) sonucuyla verim bağımlı değişkenini oldukça yakın bir açıklama yüzdesine sahip olduğu ayrıca 1 faktörlü Model-2 (%9.083) ve 5 faktörlü Model 1 (22.401) sonucundan daha yüksek olduğu tespit edilmiştir. Ayrıca bu sonuçlar, Clementine mandalinası deneme alanında Model-3'den çıkarılan yersel NDVI (NDY) bağımsız değişkeninin Model-4'ün performansında herhangi bir değişikliğe neden olmadığını göstermiştir.

Çizelge 4.52. Clementine 4 model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R ²	RMSE	MAE	Verim Model Eşitliği
Model-1	0.302	10.811	8.999	-2.809 * SRY + -680.192 * NDY + 999.006 * HNY +0.806 * NPY + 0.675 * SPD + (-187.625)
Model-3	0.131	12.059	10.240	-3.631 * SRY + -64.839 * NDY + 405.403 * HNY +4.506 * NPY + 0.010 * SPD + 61.267 * NDI +4.773 * SRI + -0.132 * TAL + -4.974 * AYK + (-174.998)
Model-4	0.120	12.133	10.371	-3.632 * SRY + 346.459 * HNY + 4.378 * NPY + -0.035 * SPD + 61.605 * NDI + 4.677 * SRI + -0.105 * TAL + -5.812 * AYK + (-172.600)
Model-2	0.019	12.814	9.947	28.510 * NDI + 2.372 * SRI + 0.233 * TAL + -0.389 * AYK + 76.627

Yersel hiperspektral okumalar (Spektrodymetre)
SRY; Basit oran, **NDY**; Normalize edilmiş fark bitki indeksi, **HNY**; Hiperspektral normalize edilmiş fark bitki indeksi, **NPY**; Normalize edilmiş pigment klorofil indeksi
İHA Uçuşları (MS alımları ve LiDAR alımları)
SRI; Basit oran, **NDI**; Normalize edilmiş fark bitki indeksi, **TAL**; Ağaç taç alanı, **AYK**; Ağaç yüksekliği
Arazi Ölçümleri
VRM; Verim, **SPD**; Yaprak klorofil okumaları

Elde edilen bu bulgular ışığında, Clementine mandalinası deneme alanı için gerçekleştirilen verim tahmini modellerinin karşılaştırma sonuçlarına göre, oluşturulan modellerin oldukça düşük değerlerde belirleme katsayısına sahip oldukları ve Model-1'in en yüksek, Model-2'nin ise en düşük değer aldığı belirlenmiştir (Çizelge 4.52 ve Şekil 4.48).



Şekil 4.48. Clementine dört modele göre tahmin edilen ve gerçekleşen verim grafiği


4.8.4. Satsuma deneme alanı verim tahmin modelleri

Çalışmanın bir diğer narenciye bahçesi olan Satsuma mandalinası deneme alanında gerçekleştirilen modelleme çalışmalarında, Model 1 için (Yersel, NDY-SRY-

HNY-NPY-SPD) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 5 (%43.055) olarak bulunmuştur. Analiz sonucu karşılaştırma özet çizelgesi incelendiğinde, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %8.898'den %43.055'e yükseldiği görülmektedir (Çizelge 4.53 ve Şekil 4.49).

Çizelge 4.53. Satsuma Model-1 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	52.311	8.898	3
2	82.549	12.774	4
3	97.029	17.320	3
4	99.877	36.271	3
5	100	43.055	4



Şekil 4.49. Satsuma Model-1 için açıklanan yüzde değişim


Çizelge 4.54'de verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 5 faktörlü (0.929), en yüksek 2 faktörlü (1.099) olarak belirlenmiştir. Bu kapsamda verim tahmini amacıyla gerçekleştirilen PLSR analizinde, hem çapraz doğrulama işlemi sonrası elde edilen en düşük RMPRESS değeri hem de verim bağımlı değişkenindeki değişimi en yüksek açıklama yüzdesine sahip olan 5 faktör kullanılmıştır.

Çizelge 4.54. Satsuma Model-1 RMPRESS değerleri



*RMPRESS 0.929 ve minimum faktör sayısı 5'dir.

Değişken önem grafiği ve çizelgesi incelendiğinde 5 faktörlü PLSR NIPALS analiz sonuçlarına göre, HNY (0.775) bağımsız değişkeni dışında tüm değişkenlerin Wold'un kriteri olan 0.8 değerinin üzerinde olduğu görülmektedir. Bu model için diğer bağımsız değişkenlerin önem değerleri sırasıyla NPY (1.315), SPD (1.115), SRY (0.850), NDY (0.840) ve HNY (0.869)'dır (Şekil 4.50).




Şekil 4.50. Satsuma Model-1 değişken önem grafiği

Model 2 (İHA, NDI-SR-TAL-AYK) için uygulanan PLSR analizi karşılaştırma özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %33.845'den %50.094'e yükseldiği ve verim değişkenini açıklayan en yüksek faktör sayısının 4 olduğu belirlenmiştir (Çizelge 4.55 ve Şekil 4.51).

Çizelge 4.55. Satsuma Model-2 karşılaştırma özeti


Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	53.080	33.845	2
2	94.885	47.171	3
3	99.195	49.793	2
4	100	50.094	2



Şekil 4.51. Satsuma Model-2 için açıklanan yüzde değişim


Çizelge 4.56'da verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 2 faktörlü (0.804), en yüksek 0 faktörlü (1.035) olarak belirlenmiştir. Bu kapsamda verim tahmini amacıyla gerçekleştirilen PLSR analizinde, hem çapraz doğrulama işlemi sonrası elde edilen en düşük RMPRESS değeri hem de verimdeki değişimi en uygun açıklama yüzdesine sahip olan 2 faktör kullanılmıştır.

Çizelge 4.56. Satsuma Model-2 RMPRESS değerleri



*RMPRESS 0.804 ve minimum faktör sayısı 2'dir.

Değişken önem grafiği ve çizelgesi incelendiğinde 2 faktörlü PLSR NIPALS analizi sonuçlarına göre, Wold'un kriteri olan 0.8 değerinin üzerinde 3 bağımsız değişken bulunmaktadır. Bu değişkenler VIP değerlerine göre sırasıyla AYK (1.188), TAL (1.185) ve SRI (0.808)'dir. Ayrıca bu model için İHA verilerinden hesaplanan NDVI (NDI)'ın önem değeri bakımından Wold'un kriterinin hemen altında bir değer (0.729) aldığı belirlenmiştir (Şekil 4.52).




Şekil 4.52. Satsuma Model-2 değişken önem grafiği

Bağımsız değişkenlerin tamamının yer aldığı Model 3 için (Yersel NDY-SRY-HNY-NPY-SPD ve İHA NDI-SR-TAL-AYK) uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 9 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %32.539'dan %62.290'a yükseldiği görülmektedir (Çizelge 4.57 ve Şekil 4.53).

Çizelge 4.57. Satsuma Model-3 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	33.525	32.539	3
2	51.301	51.989	5
3	69.393	53.215	5
4	86.714	54.319	5
5	90.712	56.816	6
6	94.700	59.633	6
7	99.628	61.553	7
8	99.887	61.888	7
9	100	62.290	7




Şekil 4.53. Satsuma Model-3 açıklanan yüzde değişim

Çizelge 4.58’de verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 3 faktörlü (0.830), en yüksek 0


faktörlü (1.035) olarak belirlenmiştir. Satsuma mandalinası deneme alanında Model-3 için verim tahmini amacıyla gerçekleştirilen PLSR analizinde, hem çapraz doğrulama işlemi sonrası elde edilen en düşük RMPRESS değeri hem de verimdeki değişimi en uygun açıklama yüzdesine sahip olan 3 faktör kullanılmıştır.

Çizelge 4.58. Satsuma Model-3 RMPRESS değerleri



*RMPRESS 0.830 ve minimum faktör sayısı 3'dür.

Model-3 için, 3 faktörlü değişken önem grafiği ve çizelgesine göre, Wold'un kriteri olan 0.8 değerinin üzerinde 5 bağımsız değişken olduğu ve bu değişkenlerin İHA verilerinden elde edilen indeks değerlerinin yanı sıra yaprak klorofil ölçüm değerleri olduğu tespit edilmiştir. Bu değişkenler VIP değerlerine göre sırasıyla AYK (1.417), TAL(1.405), SRI(1.069), NDI (0.978) ve SPD (0.903)'dir. Ayrıca Wold'un kriterine oldukça yakın değerler alan ve yersel ölçüm teknikleriyle elde edilen bağımsız değişkenlerin birbirlerine yakın önem değerlerine sahip oldukları belirlenmiştir (Şekil 4.54).



Şekil 4.54. Satsuma Model-3 değişken önem grafiği


Satsuma mandalinası deneme alanında verim tahmin modeli için faktör sayısı seçiminde, tüm modeller için PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen en düşük RMPRESS değerleri, en düşük faktör ve en yüksek varyasyon açıklama yüzdesi dikkate alınarak karar verilmiştir. Buna göre Model-1, 5 faktörle verim bağımlı değişkenindeki varyasyonun %43.055'ini; Model-2, 2 faktörle %47.171'ini ve Model-3 ise 3 faktörle %53.215'ini açıklamaktadır. PLSR NIPALS algoritması sonuçları faktör ve VIP bakımından değerlendirildiğinde, 5 faktörlü sonuca göre Model-1'de dört, 2 faktörlü sonuca göre Model-2'de üç ve 3 faktörlü sonuca göre Model-3'de ise beş bağımsız değişken önem eşik değerinin ($VIP > 0.8$) üzerinde bir değere sahiptir. Bu durum diğerlerine göre daha yüksek VIP değerine sahip bu bağımsız değişkenlerin daha önemli olduğu anlamına gelmektedir.

Satsuma mandalinası deneme alanında diğer deneme alanlarında olduğu gibi verim tahmini için oluşturulan modellerin karşılaştırılması amacıyla, 30 ağacın 23'ü eğitim ve 7'si de doğrulama için ayrılmıştır. Modellerin karşılaştırılması sonucu elde edilen ve en yüksek R^2 , en düşük RMSE ve MAE değerlerine göre sıralanan modeller Çizelge 4.59 ve Şekil 4.55'de görüldüğü gibidir.

Çizelge 4.59. Satsuma 3 model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R ²	RMSE	MAE	Verim Model Eşitliği
Model-3	0.841	24.639	22.872	3.558 * SRY + -61.490 * NDY + -215.333 * HNY +1.533 * NPY + 1.847 * SPD + -204.158 * NDI + -14.567 * SRI + 2.214 * TAL + 41.608 * AYK + 140.601
Model-2	0.797	27.804	26.305	-188.462 * NDI + -14.419 * SRI + 2.554 * TAL +41.127 * AYK + 41.992
Model-1	0.604	38.825	27.042	95.725 * SRY + -6354.092 * NDY + 622.917 * HNY +53.884 * NPY + -1.734 * SPD + 3872.632


Bu deneme alanındaki modellerin karşılaştırma sonuçlarına göre, Model-3'ün en yüksek (0.841), Model-1'in ise en düşük (0.604) belirleme katsayısına sahip olduğu belirlenmiştir. Çalışma kapsamında oluşturulan üç modelden biri olan ve tüm bağımsız değişkenlerin yer aldığı Model-3, en düşük RMSE ve MAE ile en yüksek R² değerine sahip olup diğer modellerle karşılaştırıldığında en iyi performansı göstermiştir.

**Şekil 4.55.** Satsuma üç modele göre tahmin edilen ve gerçekleşen verim grafiği

Satsuma mandalinası deneme alanında tüm bağımsız değişkenlerin yer aldığı Model-3 (İHA ve yersel) için gerçekleştirilen PLSR analizi sonucunda elde edilen VIP değerlerine göre daha önemli (>0.8) olan 5 değişken (Yersel SPD ve İHA NDI-SR-TAL-AYK) kullanılarak yeniden PLSR analizi yapılmıştır. Uygulanan PLSR analizi sonucunda verim bağımlı değişkenini en yüksek oranda açıklayan faktör sayısı 5 olarak bulunmuştur. Analiz sonucu özet çizelgesine göre, faktör sayısı arttıkça bağımlı değişkenini açıklamadaki değişimin %37.845'den %52.536'ya yükseldiği görülmektedir. Ancak faktör sayısında 2'den sonra meydana gelen artışların verim bağımlı değişkenini açıklama yüzdesini çok fazla etkilemediği ve grafiğe göre yatay seyrettiği belirlenmiştir (Çizelge 4.60 ve Şekil 4.56).


Çizelge 4.60. Satsuma Model-4 karşılaştırma özeti

Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
1	43.080	37.845	3
2	78.583	50.467	3
3	94.270	51.527	4
4	99.414	52.490	4
5	100.000	52.536	4

**Şekil 4.56.** Satsuma Model-4 için açıklanan yüzde değişim


Çizelge 4.61’de verilen PLSR NIPALS algoritması ve LOO çapraz doğrulama metoduyla elde edilen RMPRESS değerleri en düşük 2 faktörlü (0.795), en yüksek ise 0 faktörlü (1.035) olarak belirlenmiştir. Bu kapsamda verim tahmini amacıyla gerçekleştirilen PLSR analizinde, hem çapraz doğrulama işlemi sonrası elde edilen en düşük RMPRESS değeri (0.795) hem de verimdeki değişimi en uygun açıklama yüzdesine (50.467) sahip olan 2 faktör kullanılmıştır.

Çizelge 4.61. Satsuma Model-4 RMPRESS değerleri



*RMPRESS 0.795 ve minimum faktör sayısı 2'dir.

Model-4 için değişken önem grafiği incelendiğinde, 2 faktörlü PLSR NIPALS analiz sonuçlarına göre analize dahil edilen 5 bağımsız değişkenden AYK, TAL ve SRI'nın Wold'un kriteri olan 0.8 değerinin üzerinde yer aldığı ve bu değer altında yer alan SPD ile NDI'nın ise hem Wold'un kriterine hem de birbirlerine oldukça yakın değerler aldıkları görülmektedir (Şekil 4.57).



Şekil 4.57. Satsuma Model-4 değişken önem grafiği


İHA'dan elde edilen verilerden hesaplanan bağımsız değişkenler (NDI, SRI, TAL ve AYK) ile yaprak klorofil ölçüm değerlerini içeren SPAD (SPD) değişkeninin yer aldığı Model-4'den elde edilen bulgulara göre, verim bağımlı değişkenini açıklamada 2 faktörlü

Model-4 (%50.467) ile 3 faktörlü Model 3 (%53.215) sonuçlarının yakın olduğu belirlenmiştir. Ayrıca Model-4'ün verim bağımlı değişkenini açıklama oranının, aynı faktör sayısına sahip Model-2 (%47.171) ve 5 faktörlü Model-1 (%43.055) ile karşılaştırıldığında daha yüksek olduğu tespit edilmiştir. Üç modelin karşılaştırma sonuçlarına Model-4 de dahil edilerek yeniden model karşılaştırma yapılmıştır (Çizelge 4.62 ve Şekil 4.58). Satsuma mandalinası deneme alanı için 4 modelin karşılaştırma sonuçlarına göre belirleme katsayıları sırasıyla, Model-3 (0.841), Model-4 (0.811), Model-2 (0.797) ve Model-1 (0.604)'dir.

Çizelge 4.62. Satsuma 4 model için karşılaştırma sonuçları ve model eşitlikleri

Tahmin Modeli	R ²	RMSE	MAE	Verim Model Eşitliği
Model-3	0.841	24.639	22.872	3.558 * SRY + -61.490 * NDY + -215.333 * HNY +1.533 * NPY + 1.847 * SPD + -204.158 * NDI + -14.567 * SRI + 2.214 * TAL + 41.608 * AYK + 140.601
Model-4	0.811	26.834	24.781	2.583 * SPD + -178.945 * NDI + -13.281 * SRI +2.313 * TAL + 36.013 * AYK + (-105.626)
Model-2	0.797	27.804	26.305	-188.462 * NDI + -14.419 * SRI + 2.554 * TAL +41.127 * AYK + 41.992
Model-1	0.604	38.825	27.042	95.725 * SRY + -6354.092 * NDY + 622.917 * HNY +53.884 * NPY + -1.734 * SPD + 3872.632

Yersel hiperspektral okumalar (Spektrometre)
SRY; Basit oran, **NDY;** Normalize edilmiş fark bitki indeksi, **HNY;** Hiperspektral normalize edilmiş fark bitki indeksi, **NPY;** Normalize edilmiş pigment klorofil indeksi
İHA Uçuşları (MS alımları ve LiDAR alımları)
SRI; Basit oran, **NDI;** Normalize edilmiş fark bitki indeksi, **TAL;** Ağaç taç alanı, **AYK;** Ağaç yüksekliği
Arazi Ölçümleri
VRM; Verim, **SPD;** Yaprak klorofil okumaları



Şekil 4.58. Satsuma dört modele göre tahmin edilen ve gerçekleşen verim grafiği

Yapılan bu hesaplamalar sonucunda portakal ve mandalina bahçelerinde tüm deneme alanları için oluşturulan modeller, faktör sayıları, verim bağımlı değişkeni için

açıklanan yüzde değişim, RMPRESS ve VIP sayıları Çizelge 4.63’de verilmiştir. Çizelge incelendiğinde, portakal ve mandalina deneme alanlarının tamamında bağımsız değişkenlerin hepsinin (9 değişken) yer aldığı Model-3’ün en yüksek açıklama yüzdesine sahip olduğu belirlenmiştir. Vijayakumar vd. (2023) tarafından portakal ağaçlarında gerçekleştirilen ve PLSR de dahil olmak üzere farklı makine öğrenme algoritmalarının değerlendirildiği çalışmada, 3 farklı model oluşturulmuştur. Bu modellerden PLSR ve Model 2 (mulispektral veriler, ağaç yapı parametreleri ve tek taraflı meyve sayıları), ağaç düzeyinde verim tahmininde daha düşük mutlak ortalama yüzde hata değeri ve veri toplama kolaylığı nedeniyle en iyi model olarak seçilmiştir.

Araştırma sonuçlarına göre, Washington portakalı deneme alanında yersel hiperspektral ve yaprak klorofil ölçüm değerleri ile İHA verilerinden hesaplanan bağımsız değişkenlerin oluşturduğu Model-1 (25.979) ve Model-2 (24.147)’nin birbirine yakın değerler aldığı tespit edilmiştir. Ayrıca bu modellerin, Model-3 (47.598) ve Model-4 (45.391)’e göre oldukça düşük değerlere sahip olduğu belirlenmiştir. Elde edilen bulgulara göre Washington portakalı deneme alanında, en yüksek belirleme katsayısına sahip Model-3 için daha önemli olan bağımsız değişkenler kullanılarak elde edilen Model-4 ve özellikle bu modelde yer alan İHA verileri ile daha az sayıda faktör, daha düşük maliyet ve daha kısa sürede verimin tahmin edilebileceği tespit edilmiştir. Valencia portakalı deneme alanında ise, Washington portakalı deneme alanından farklı olarak verimin açıklanan yüzde değişimi Model-1 (41.384) ve Model-2 (43.888) için daha yüksek bulunmuştur. Bu deneme alanı için en yüksek verim açıklama değerine sahip Model-3 (50.726) ile Model-4 (49.792)’ün aynı faktör sayıları ile birbirlerine oldukça yakın değerler aldığı tespit edilmiştir.

Clementine mandalinası deneme alanında, tüm modeller için daha düşük verim açıklama değerleri elde edilmiştir. Bu alanda Model-3 (28.053) en yüksek değere sahip olup diğer deneme alanlarında olduğu gibi Model-4 (27.315)’ün ise aynı faktör sayısı (6 faktör) ile Model-3’e daha yakın bir değer aldığı belirlenmiştir. Clementine deneme alanında, en düşük verim açıklama yüzde değişim değerine 1 faktör ile Model-2 (9.083) sahip olup bu modele faktör eklemenin verimi açıklamaya daha fazla katkı sağlamayacağı ve Model 1’de ise tüm faktörler (5 faktör) dahil edildiğinde ancak 22.401 değerinin elde edildiği tespit edilmiştir. Satsuma mandalinası deneme alanında, diğer deneme alanlarına göre nispeten daha yüksek değerler elde edilmiştir. Bu deneme alanında da Model-3 (53.215) için en yüksek açıklama değeri tespit edilmiştir. Satsuma deneme alanında, Model-4 (50.467)’ün daha az sayıda faktörle Model-3’e oldukça yakın bir değer aldığı belirlenmiştir. Model-2 (47.171)’nin diğer deneme alanlarına göre daha az sayıda faktörle daha yüksek bir açıklama değerine sahip olduğu ve Model-1 (43.055) ise yine diğer deneme alanlarına göre 5 faktörle nispeten daha yüksek bir değer aldığı belirlenmiştir. Ye vd. (2007) narenciye ağaçlarında hiperpsektral verilerden elde edilen indeksler kullanarak verim tahmini amacıyla gerçekleştirdikleri çalışmada, Satsuma mandalinası ağaçları ve PLSR analizini kullanmışlardır. Araştırmacıların elde ettiği bulgulara göre, ağaç kanopi özellikleri ve verim arasında önemli korelasyonlar olduğu ve verimin hasattan birkaç ay önce hatta bir yıl önce tahmin edilebilmesinin hasat programları ve verim dalgalanmalarıyla başa çıkabilmede önemli katkılar sağlayabileceği değerlendirilmiştir.

Çizelge 4.63. Tüm deneme alanları için model karşılaştırma çizelgesi

Deneme alanı	Model	Faktör sayısı	Verim için açıklanan yüzde değişim	RMPRESS	VIP > 0.8
Washington	Model 1	2	25.979	1.210	4 (SRY-NDY-HNY-SPD)
	Model 2	1	24.147	0.943	3 (NDI-SRI-AYK)
	Model 3	3	47.598	1.108	5 (SPD-NDI-SRI-TAL-AYK)
	Model 4	2	45.391	0.898	4 (SPD-NDI-SRI-AYK)
Valencia	Model 1	4	41.384	0.948	5 (SRY-NDY-HNY-NPY-SPD)
	Model 2	3	43.888	1.175	4 (NDI-SRI-TAL-AYK)
	Model 3	4	50.726	1.116	8 (SRY-NDY-HNY-SPD-NDI-SRI-TAL-AYK)
	Model 4	4	49.792	1.072	7 (SRY-NDY-SPD-NDI-SRI-TAL-AYK)
Clementine	Model 1	5	22.401	1.402	5 (SRY-NDY-HNY-NPY-SPD)
	Model 2	1	9.083	1.052	3 (NDI-SRI-TAL)
	Model 3	6	28.053	1.542	8 (SRY-HNY-NPY-SPD-NDI-SRI-TAL-AYK)
	Model 4	6	27.315	1.535	8 (SRY-HNY-NPY-SPD-NDI-SRI-TAL-AYK)
Satsuma	Model 1	5	43.055	0.929	4 (SRY-NDY-NPY-SPD)
	Model 2	2	47.171	0.804	3 (SRI-TAL-AYK)
	Model 3	3	53.215	0.830	5 (SPD-NDI-SRI-TAL-AYK)
	Model 4	2	50.467	0.795	3 (SRI-TAL-AYK)
Yersel hiperspektral okumalar (Spektroradyometre) SRY; Basit oran, NDY; Normalize edilmiş fark bitki indeksi, HNY; Hiperspektral normalize edilmiş fark bitki indeksi, NPY; Normalize edilmiş pigment klorofil indeksi İHA Uçuşları (MS alımlar ve LiDAR alımları) SRI; Basit oran, NDI; Normalize edilmiş fark bitki indeksi, TAL; Ağaç taç alanı, AYK; Ağaç yüksekliği Arazi Ölçümleri VRM; Verim, SPD; Yaprak klorofil okumaları					

Yürütülen bu tez çalışması, narenciye ağaçlarının meyve olum dönemi için hesaplanan verim modellerini içermektedir. Bununla birlikte bu tez çalışmasının da desteklendiği başka bir çalışmada (TÜBİTAK 120O990 numaralı proje) ise narenciye ağaçlarının meyve tutum döneminde de verim tahmin modelleri oluşturulmuştur. Çalışmanın bu aşamasında söz konusu bu projeden elde edilen modeller ile tez çalışmasında elde edilen modeller arasında bir karşılaştırma yapılmıştır. Elde edilen sonuçlara göre gerek portakal ve gerekse mandalina bahçelerinde Model-3'ün meyve olum döneminde olduğu gibi meyve tutum döneminde de verim bağımlı değişkenini en yüksek açıklama yüzdesine sahip olduğu tespit edilmiştir.

Washington portakalı deneme alanı için meyve olum döneminde Model-3'ün verim bağımlı değişkenini %47.598 oranında açıklayabildiği ve meyve tutum döneminde (14.07.2021) ise yine Model-3'ün %71.439 oranında açıklayabildiği belirlenmiştir. Bir diğer portakal deneme alanı olan Valencia deneme alanı için meyve olum döneminde Model-3'ün verim bağımlı değişkenini %50.726 oranında açıklayabildiği ve meyve tutum döneminde (29.07.2021) ise yine Model-3'ün %75.534 oranında açıklayabildiği tespit edilmiştir. Clementine mandalinası deneme alanı için meyve olum döneminde Model-3'ün verim bağımlı değişkenini %28.053 oranında açıklayabildiği ve meyve tutum döneminde (03.06.2021) ise yine Model-3'ün %36.000 oranında açıklayabildiği belirlenmiştir. Satsuma deneme alanı için meyve olum döneminde Model-3'ün verim bağımlı değişkenini %53.215 oranında açıklayabildiği ve meyve tutum döneminde (29.07.2021) ise yine Model-3'ün %66.595 oranında açıklayabildiği tespit edilmiştir.

Bu bulgulara göre narenciye ağaçlarının verim tahmininde meyve tutum dönemlerinde meyve olum dönemlerine göre daha yüksek doğrulukta sonuçlar ortaya çıkmıştır. Nitekim narenciye ağaçlarının meyve tutum ve olum dönemlerinde özellikle Washington ve Valencia portakalı deneme alanlarında sırasıyla 23.841 ve 24.808'lik fark elde edilirken Clementine ve Satsuma mandalinası deneme alanlarında bu farkın sırasıyla 7.947 ve 13.380 olduğu belirlenmiştir.

5. SONUÇLAR

Bu tez çalışmasında meyve olum dönemindeki dört farklı narenciye çeşidinde İHA, İHA-LiDAR, yersel hiperspektral uzaktan algılama ve SPAD teknikleri ile elde edilen bazı verim bileşenleri ve makine öğrenme algoritması kullanarak verim tahminlerinin yapılması amaçlanmıştır. Çalışma, kamuya ait yer gerçeği bilinen Batı Akdeniz Tarımsal Araştırma Enstitüsü (BATEM) Kayaburnu arazisinde yer alan portakal ve mandalina bahçelerinde yürütülmüştür. Çalışma kapsamında, verim üzerinde etkili olabileceği değerlendirilen ve narenciye ağaçlarının bazı dendrometrik bileşenlerinden olan ağaç taç yapısı, taç alanı ve yükseklikleri hem fotogrametrik İHA ile hem de İHA-LiDAR sistemleriyle belirlenmiş olup yapılan analizler sonucunda, her iki sistem arasında yüksek ve pozitif yönlü korelasyonlar tespit edilmiştir. Bu kapsamda, hassas sayısal yüzey ve arazi modelleri üretilebilen İHA-LiDAR sistemleri ile fotogrametrik İHA sistemleri arasındaki istatistiksel olarak anlamlı ilişkiler dikkate alındığında, nispeten daha uygun maliyetli fotogrametrik İHA sistemlerinin de narenciye ağaçlarının dendrometrik bileşenlerinin hesaplanmasında kullanılabileceği sonucuna ulaşılmıştır.

Çalışmanın bir diğer aşamasında ise, meyve olum dönemlerindeki portakal ve mandalina ağaçlarında yersel hiperspektral ölçümler ile bitkiye ait bireysel ağaç düzeyinde spektral yansıma grafikleri ve veri tabanları oluşturulmuştur. Washington, Valencia, Clementine ve Satsuma narenciye ağaçlarından elde edilen ortalama yansıtım değerlerine göre, elektromanyetik spektrumun görünür (özellikle yeşil) ve yakın kızılötesi bölgelerinde, meyve olum dönemindeki Satsuma mandalinasının daha yüksek yansıtım karakteristiği gösterdiği tespit edilmiştir. Narenciye ağaçlarının meyve olum dönemlerine ait bireysel ağaç bazında gerçekleştirilen ortalama bağıl klorofil ölçüm değerlerine (SPAD) göre ise en yüksek SPAD değeri, Washington (70.317) deneme alanında ortaya çıkmış olup bunu sırasıyla azalan oranda Valencia (65.213), Satsuma (63.877) ve Clementine (55.947) ağaçları takip etmiştir.

Çalışmada yersel hiperspektral ölçümler ve İHA MS çekimlerinden hesaplanan indeksler ile yine İHA verilerinden hesaplanan bitkilere ait ağaç taç alanı, ağaç yüksekliği gibi dendrometrik karakteristikler için istatistiksel analizler gerçekleştirilmiştir. Bu kapsamda çalışma alanında bulunan tüm narenciye ağaçlarının tüm değişkenler için tanımlayıcı istatistik değerleri belirlenmiştir. Tanımlayıcı istatistik değerlerine göre, Washington deneme alanı için ortalama SRY 14.993, NDY 0.856, HNY 0.879, NPY 1.740, SPD 70.424, NDI 0.574, SRI 3.230, TAL 33.208, AYK 4.214, GYK 1.440, VRM 68.448, Valencia deneme alanı için ortalama SRY 14.404, NDY 0.862, HNY 0.894, NPY 0.395, SPD 65.213, NDI 0.728, SRI 6.022, TAL 22.308, AYK 4.136, GYK 1.045, VRM 104.333, Clementine deneme alanı için ortalama SRY 13.526, NDY 0.852, HNY 0.876, NPY 1.023, SPD 55.947, NDI 0.617, SRI 3.889, TAL 32.622, AYK 4.826, GYK 1.322, VRM-109.177, Satsuma deneme alanı için ise ortalama SRY 11.672, NDY 0.837, HNY 0.874, NPY 0.042, SPD 63.877, NDI 0.631, SRI 4.100, TAL 29.283, AYK 4.110, GYK 1.367 ve VRM ise 107.69 olarak hesaplanmıştır. Daha sonra tüm veri setlerinin çarpıklık (skewnes) ve basıklık (kurtosis) katsayıları, Shapiro-Wilk normallik testleri ve histogram grafikleri ile normal dağılım gösterip göstermediği farklı yöntemlerle kontrol edilmiştir. Çalışmada kullanılan bazı değişkenlerin normal dağılım göstermemesi nedeniyle parametrik olmayan Spearman'ın korelasyon katsayıları hesaplanmıştır. Washington portakalı deneme alanındaki ağaçlar için hesaplanan Spearman'ın korelasyon

katsayılarına göre verim (VRM) bağımlı değişkeni ile klorofil ölçüm değerleri (SPD) arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (%95 güven düzeyinde). Elde edilen bu sonuç, bitki klorofil içeriği ile verim arasında oldukça önemli bir ilişkinin olduğunu göstermektedir. Nitekim Kandel (2020), Ramesh vd. (2022) ve Shanmugapriya vd. (2022) gibi araştırmacılar da bitki klorofil miktarındaki artışa bağlı olarak gelişim dönemlerine göre verimde artışın olduğunu ifade etmişlerdir.

Çalışmada, Washington ağaçlarının verim (VRM) değerleri ile ağaç taç alanı arasında zayıf düzeyde negatif ilişki belirlenmiştir. Ayrıca VRM ile diğer tüm bağımsız değişkenler arasında zayıf düzeyde pozitif yönlü ilişkiler tespit edilmiştir. Elde edilen bu bulgu, meyve olum dönemindeki Washington portakal ağaçlarının bitki taç alanı ile verimleri arasında anlamlı bir ilişkinin olmadığını ortaya koymakla birlikte diğer dendrometrik bileşenlerin ise anlamlı sonuçlar vereceğini göstermiştir.

Valencia portakalı deneme alanındaki ağaçlar için hesaplanan Spearman'ın korelasyon katsayıları incelendiğinde ise, verim (VRM) bağımlı değişkeni ile MS verilerden hesaplanan normalize edilmiş fark bitki indeksi (NDI) ve basit oran indeksi (SRI) arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (%95 güven düzeyinde). Ayrıca VRM ile yersel hiperspektral verilerden hesaplanan bitki indeksleri (SRY, NDY, HNY, NPY), klorofil ölçümleri (SPD) ve ağaç dendrometrik özelliklerinden ağaç taç alanı (TAL) ve ağaç yüksekliği (AYK) arasında zayıf düzeyde pozitif yönlü ilişki belirlenmiştir. Valencia portakalı için elde edilen bu bulgular, bitki klorofil içeriği ile doğrudan ilişkili olan indekslerin bitki verimi arasındaki ilişkisini ortaya koymuştur. Ayrıca hesaplanan dendrometrik bileşenlerin de verim tahmininde kullanılabileceğini göstermiştir. Nitekim Ye vd. (2007), Feng vd. (2022), Tuğaç vd. (2022) ve Zongpeng vd. (2022) gibi araştırmacılar da farklı bitkilerde verim tahmininde bu indekslerin çok önemli bağımsız değişkenler olduğunu belirtmişlerdir. Yapılan analizlerde Valencia ağaçlarında verim ile bitkinin gövde yüksekliği arasında zayıf ve negatif yönlü bir ilişkinin olduğu da tespit edilmiştir. Elde edilen bu bulgu ise Valencia ağaçlarında bitki gövde yüksekliğinin verim tahmininde önemli bir parametre olamayacağını ortaya koymuştur.

Clementine mandalinası deneme alanındaki ağaçlar için hesaplanan Spearman'ın korelasyon katsayılarına göre ise, bitki verim (VRM) bağımlı değişkeni ile MS verilerden hesaplanan normalize edilmiş fark bitki indeksi (NDI), basit oran indeksi (SRI) ve yersel hiperspektral verilerden hesaplanan bitki indeksleri (SRY, NDY, HNY, NPY) arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (%95 güven düzeyinde). Bu bulgu portakal ağaçlarında olduğu gibi Clementine mandalinasında da çeşitli indeksler ile verim arasında önemli ilişkilerin olduğunu ortaya koymaktadır. Ayrıca, Clementine ağaçlarının verim değerleri ile taç alanı (TAL) ve gövde yüksekliği (GYK) arasında zayıf düzeyde pozitif yönlü ilişkiler belirlenmiş olup, verim ile ağaç yüksekliği (AYK) arasında zayıf ve negatif yönlü bir ilişkiler tespit edilmiştir. Bu durum söz konusu ağaçlar için verim tahmininde ağaç dendrometrik bileşenlerinin verim tahmininde önemli bir parametre olabileceğini göstermektedir.

Satsuma mandalinası deneme alanındaki ağaçlar için hesaplanan Spearman'ın korelasyon katsayıları incelendiğinde ise, verim (VRM) bağımlı değişkeni ile ağaç dendrometrik özelliklerinden TAL ve AYK arasında orta düzeyde ve pozitif yönlü bir ilişki bulunmuştur (%95 güven düzeyinde). Ayrıca bitki verimi ile SRY, NDY, HNY

NPY, SPD ve GYK bağımsız değişkenleri arasında zayıf ve pozitif yönlü ilişkiler belirlenmiştir. Bu bulgu da diğer narenciye ağaçlarından elde edilen verim ilişkileri ile benzerlik göstermektedir.


Çalışmanın verim tahmin modellemesi sonuçları değerlendirildiğinde, Washington deneme alanında Model-3 (47.598) ve Model-4 (45.391)'ün birbirine yakın ve en yüksek değerlere ulaştığı, Model-1 ve Model-2'nin ise yine birbirine yakın ve nispeten daha düşük değerlere sahip olduğu belirlenmiştir. Valencia portakalı deneme alanında, verimin açıklanan yüzde değişimi Model-1 için 41.384 ve Model-2 için ise 43.888 olarak bulunmuştur. Bu deneme alanı için en yüksek verim açıklama değerine sahip Model-3 (50.726) ile Model-4 (49.792)'ün aynı faktör sayıları ile birbirlerine oldukça yakın değerler aldığı tespit edilmiştir. Clementine mandalinası deneme alanında, tüm modeller için daha düşük verim açıklama değerleri elde edilmiştir. Bu alanda Model-3 (28.053) en yüksek değere sahip olup diğer deneme alanlarında olduğu gibi Model-4 (27.315)'ün ise aynı faktör sayısı (6 faktör) ile Model-3'e daha yakın bir değer aldığı belirlenmiştir. Bu deneme alanında, en düşük verim açıklama yüzde değişim değerine 1 faktör ile Model-2 (9.083) sahip olup bu modele faktör eklemenin verimi açıklamaya daha fazla katkı sağlamayacağı ve Model 1'de ise tüm faktörler (5 faktör) dahil edildiğinde ancak 22.401 değerinin elde edildiği tespit edilmiştir. Satsuma mandalinası deneme alanında ise, Model-3 (53.215) için en yüksek verim açıklama yüzde değişim değeri tespit edilmiştir. Bu deneme alanında, Model-4 (50.467)'ün daha az sayıda faktörle Model-3'e oldukça yakın bir değer aldığı belirlenmiştir. Model-2 (47.171)'nin diğer deneme alanlarına göre daha az sayıda faktörle daha yüksek bir açıklama değerine sahip olduğu ve Model-1 (43.055) ise yine diğer deneme alanlarına göre 5 faktörle nispeten daha yüksek bir değer aldığı belirlenmiştir.

Yapılan bu değerlendirmeler neticesinde, Washington, Valencia, Clementine ve Satsuma narenciye bahçelerini kapsayan tüm deneme alanlarında her bir parselde yer alan 30 ağacın 23'ü eğitim ve 7'sinin de doğrulama için ayrılması ile elde edilen model karşılaştırma sonuçlarına göre en iyi modelin, Clementine mandalinası deneme alanı hariç, Model-3 olduğu belirlenmiştir. Model karşılaştırma sonuçlarına göre en iyi model, Washington portakalı deneme alanında Model-3 ($R^2=0.719$, $RMSE=21.775$, $MAE=18.114$), Valencia portakalı deneme alanında Model-3 ($R^2=0.685$, $RMSE=9.887$, $MAE=9.174$), Clementine mandalinası deneme alanında Model-1 ($R^2=0.302$, $RMSE=10.811$, $MAE=8.999$) ve Satsuma mandalinası deneme alanında ise Model-3 ($R^2=0.841$, $RMSE=24.639$, $MAE=22.872$)'tür. Elde edilen bu bulgular farklı uzaktan algılama teknikleri ile gerek yersel ölçümler ve gerekse İHA verilerini birlikte kullanılması ile üretilen veri setlerinin verim tahmini modellemelerinde daha başarılı sonuçlar vereceğini göstermiştir. Bununla birlikte yalnızca İHA'dan üretilen çeşitli parametrelerin de verim tahmini çalışmalarında kullanılabileceği de çalışmada ortaya konmuştur.

Verim tahmininde spektral veriler ve ağaç dendrometrik bileşenlerini içeren kanopi bilgileri önemli parametreler olup tahmin sonuçlarının iyileştirilmesi için saha verileriyle desteklenmesi gerekmektedir (Moussaid vd. 2022). Akdeniz havzasındaki iklim değişikliği ve bunun verim ve kalite açısından mahsul verimliliğine etkisi üzerine portakal, mandalina, zeytin ve bağda De Ollas vd. (2019) tarafından yürütülen bir çalışmada, iklim değişikliğinin önemli olduğu vurgulanmıştır. Bir başka çalışmada ise

Vogel vd. (2019) iklim değişikliğinin verim üzerindeki etkisini incelemek için bazı tarımsal ürünlerde RF algoritmasını kullanmışlardır. Araştırmacılar sıcaklık, yağış ve don gibi bazı iklim değişkenlerinin verimi %20-%49 arasında değişen oranlarda etkileyebileceğini bulmuşlardır. Her ne kadar bazı araştırmacılar tarafından iklim değişikliğinin verim üzerinde etkisinin olduğu belirtilmiş olsa da, yürütülen bu çalışma alanının tipik Akdeniz iklim kuşağında yer alması, küçük bir alan olması ve narenciye ağaçlarının meyve olum dönemlerini içeren tarihler için ilgili bölümde (3.1.6. Meteorolojik veriler) verilen meteoroloji verilerinde herhangi bir olumsuzluk bulunmaması nedeniyle söz konusu bu çalışmada iklim parametresi verileri verim tahmin modellerinde değişken olarak kullanılmamıştır. Ancak narenciye ağaçlarında özellikle çiçeklenme dönemlerinde olası yaşanabilecek düşük sıcaklık ve donlu gün sayısından kaynaklı üşüme zararı ihtimaline karşı daha geniş alanlarda yürütülecek çalışmalarda söz konusu bu ekstrem durum dikkate alınarak, Moussaïd vd. (2022), De Ollas vd. (2019) ve Vogel vd. (2019) tarafından da belirtildiği gibi verim tahmin modellerinde ilgili meteoroloji verilerine yer verilmesinin uygun olacağı değerlendirilmektedir.

Bu tez çalışmasının bugüne kadar narenciye ağaçlarının alansal tahminine yönelik yapılan uzaktan algılama çalışmalarından farklı olarak, birden fazla uzaktan algılama tekniğinin bir arada kullanılması sonucu elde edilen parametrelerin meyve olum dönemindeki portakal ve mandalina ağaçlarının verim tahminindeki başarısını ortaya koymuş olması oldukça önemli bir kazanımdır. Bu bakımdan çalışma sonucunda elde edilen bulgular narenciye ağaçlarının meyve olum dönemlerinde İHA sistemlerinin en uygun maliyet, zaman ve daha az sayıda değişken ile ancak yersel ölçümlerle birlikte kullanıldığında bu bitkiler için verimin güvenilir bir şekilde tahmin edilebileceğini göstermiştir. Bununla birlikte, bitkilerin meyve olum dönemlerinin sonbahar/kış ayları olması nedeniyle güneşli gün sayısı ve uygun hava koşullarının kısıtlı olması, İHA sistemleri ile gerçekleştirilecek arazi çalışmaları için bu çalışmanın en temel zorluklarından biri olarak karşımıza çıkmaktadır. Çalışmada karşılaşılan bir başka zorluk ise bitkilerin olum dönemlerinin tutum dönemine göre uzun bir periyotta gerçekleşiyor olması, arazi çalışmalarında kullanılan ağaç kimlik etiketlerinin ve görüntülerin geometrik düzeltmelerinde kullanılan YKN'lerin her İHA operasyonu öncesinde mutlaka kontrol edilmesi gerekliliğidir. Tez çalışması sonucu elde edilen verim tahmin modelleri, benzer iklim ve çevresel koşullar ile benzer amenajman tekniklerinin uygulandığı Washington, Valencia, Clementine ve Satsuma parsellerinde homojen dağılım gösteren uygun meteorolojik koşullar için hazırlanmış olup bu kapsamda bölgede üretimi yapılan söz konusu narenciye çeşitlerinin meyve olum dönemleri için oluşturulmuş verim tahmin protokolü Şekil 5.1'de verilmiştir.



Şekil 5.1. Narenciye verim tahmin protokolü

Sonuç olarak bu çalışma ile İHA sistemlerine monte edilebilen MS algılayıcılar, LiDAR uygulamaları, yersel spektrometrik ölçümler gibi farklı uzaktan algılama tekniklerinin eş zamanlı olarak gerçekleştirilmesi ve tüm bu veri setlerinin verim ile ilişkilendirilmiş olması, tarımsal uzaktan algılama çalışmaları kapsamında çok yıllık tarımsal ürünlerin parsel düzeyinde izlenmesi açısından yeni bir yaklaşım getirilmiştir. Ayrıca yersel ölçümlerle tahribatsız ve portatif olarak ölçülen yaprak bağlı klorofil içeriğinin narenciye ağaçlarının verim tahmin modellemesinde önemli bir değişken olarak ortaya konulmuş olması da dikkat çekici bir kazanım olarak değerlendirilmiştir.

6. KAYNAKLAR

- Abdi, H. 2003. Partial least squares regression (PLS-regression). In: Lewis-Beck, M., Bryman, A., Futing, T., eds. *Encyclopedia for Research Methods for the Social Sciences*. Thousand Oaks, CA: Sage, pp. 792-795.
- Abdi, H. 2010. Partial least squares regression and projection on latent structure regression (PLS Regression). *WIREs Computational Statistics*, 2: 97-106. <https://doi.org/10.1002/wics.51>.
- Aguilar, M.A., Jiménez-Lao, R., and Aguilar, F.J. 2021. Evaluation of object-based greenhouse mapping using WorldView-3 VNIR and SWIR data: a case study from Almería (Spain). *Remote Sensing*, 13(11), 2133. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13112133>.
- Akoğlu, G., Şahin, H. ve Çakmak, A. 2018. Özel Gereksinimli Çocuğa Sahip Annelerin Aile Yaşam Kalitesi ve Mutluluk Düzeyleri Arasındaki İlişkinin İncelenmesi. In ICPESS (International Congress on Politic, Economic and Social Studies) (No. 4).
- Alaboz, P., Demir, S., Dengiz, O. 2020. Farklı Enterpolasyon yöntemleri kullanılarak toprakların nem sabitelerine ait konumsal dağılımların belirlenmesi, Isparta Atabey Ovası Örneği. *Tekirdağ Ziraat Fakültesi Dergisi*, 17(3), 432-444. <https://doi.org/10.33462/jotaf.710411>.
- Alin, A. 2009. Comparison of PLS algorithms when number of objects is much larger than number of variables. *Stat Papers* 50, 711–720. <https://doi.org/10.1007/s00362-009-0251-7>.
- Ampatzidis, Y., Partel, V., Meyering, B., Albrecht, U. 2019. Citrus rootstock evaluation utilizing UAV-based remote sensing and artificial intelligence. *Computers and Electronics in Agriculture*, Volume 164, 104900, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2019.104900>.
- Artisan. 2022. Spectroradiometer. <https://www.artisan-tg.com/Scientific/90717-1/Spectris-ADS-Analytical-Spectral-Devices-FieldSpec-HandHeld-FSHH-325-3075P-Spectroradiometer> [Son erişim tarihi: 19.11.2022].
- Aparicio-Durán, L., Gmitter Jr., F.G., Arjona-López, J.M., Calero-Velázquez, R., Hervalejo, Á., and Arenas-Arenas, F.J. 2021. Water-Stress influences on three new promising HLB-Tolerant citrus rootstocks. *Horticulturae*, 7(10), 336. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/horticulturae7100336>.
- Apogee. 2022a. MQ-500: Full-Spectrum Quantum Meter. <https://www.apogeeinstruments.com/mq-500-full-spectrum-quantum-meter/> [Son erişim tarihi: 05.12.2022].
- Apogee. 2022b. Conversion - PPFD to Lux <https://www.apogeeinstruments.com/conversion-ppfd-to-lux/> [Son erişim tarihi: 05.12.2022].
- Apolo-Apolo, O.E., Martínez-Guanter, J., Egea, G., Raja, P., Pérez-Ruiz, M. 2020. Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. *European Journal of Agronomy*, Volume 115, 2020, 126030, ISSN 1161-0301. <https://doi.org/10.1016/j.eja.2020.126030>.

- Atlı, H.F. ve Söyler, O. 2018. Dünyada ve Türkiye’de turunçgil üretiminin ve ihracatının değerlendirilmesi. *The Journal of Academic Social Sciences*, 79, 357-369. DOI:10.16992/ASOS.14174.
- Ay, F. ve İnce, G. 2015. Application of Pesticide Using Unmanned Aerial Vehicle. 23rd Signal Processing and Communications Applications Conference (SIU), 2015, pp. 1268-1271. <https://doi.org/10.1109/SIU.2015.7130069>.
- Baatz, M. and Schape, A. 2000. Multiresolution Segmentation: An Optimization Approach for High Quality Multi-Scale Image Segmentation. In: Strobl, J., Blaschke, T. and Griesbner, G., Eds., *Angewandte Geographische Informations-Verarbeitung, XII*, Wichmann Verlag, Karlsruhe, Germany, 12-23.
- Bargoti, S. and Underwood, J.P. 2017. Image segmentation for fruit detection and yield estimation in apple orchards. *Journal of Field Robotics*, 34, 1039-1060. <https://doi.org/10.1002/rob.21699>.
- BATEM. 2023. Batı Akdeniz Tarımsal Araştırma Enstitüsü Müdürlüğü Meyvecilik Bölümü. <https://arastirma.tarimorman.gov.tr/batem/Menu/111/Bolumler> [Son erişim tarihi: 03.07.2023].
- Bian, C., Hongtao, S., Suqin, W., Kefei, Z., Meng, W., Yindi, Z., Yaqin, S., Huifu, Z., Xuewei, Z., and Shuo, C. 2022. Prediction of field-scale wheat yield using machine learning method and multi-spectral UAV data. *Remote Sensing*, 14(6): 1474. <https://doi.org/10.3390/rs14061474>.
- Birth, G.S. and Mcvey, G.R. 1968. Measuring the color of growing turf with a reflectance spectrophotometer. *Agronomy Journal*, 60(6): pp. 640–643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>.
- Bostan, S.Z., İşbakan, H. 2020. Fındıkta bitki morfolojik özellikleri ile verim ve meyve kalite özellikleri arasındaki ilişkiler. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 10(1): 32-45. Retrieved from <https://dergipark.org.tr/tr/pub/ordubtd/issue/55660/745656>.
- Bozkurt, E., Bostan, S.Z. 2017. Variation in yield of 'Çakıldak' hazelnut at different elevations and years”. In IX International Congress on Hazelnut, 1226,157-160. <https://doi.org/10.17660/ActaHortic.2018.1226.23>.
- Bulut, E. 2010. Model Selection Methods For Multivariate Linear Partial Least Squares Regression. Doktora tezi, Dokuz Eylül Üniversitesi İzmir, 88 s.
- Campbell, J.B. 2006. Introduction to Remote Sensing. Fourth Edition, The Guilford Publications, New York.
- Chang, A., Yeom, J., Jung, J., and Landivar, J. 2020. Comparison of canopy shape and vegetation indices of citrus trees derived from UAV multispectral images for characterization of citrus greening disease. *Remote Sensing*, 12(24), 4122. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12244122>.
- Chen, Y., Lee, W.S., Gan, H., Peres, N., Fraisse, C., Zhang, Y. and He, Y. 2019. Strawberry yield prediction based on a deep neural network using high-resolution aerial orthoimages. *Remote Sensing*, 11(13), 1584. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs11131584>.

- Chen, W., Xiang, H. and Moriya, K. 2020. Individual tree position extraction and structural parameter retrieval based on airborne LiDAR data: performance evaluation and comparison of four algorithms. *Remote Sensing*, 12(3): 571. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12030571>.
- Chen, Q., Gao, T., Zhu, J., Wu, F., Li, X., Lu, D. and Yu, F. 2022. Individual tree segmentation and tree height estimation using leaf-off and leaf-on UAV-LiDAR data in dense deciduous forests. *Remote Sensing*, 14(12): 2787. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs14122787>.
- Chen, R., Zhang, C., Xu, B., Zhu, Y., Zhao, F., Han, S., Yang, G., Yang, H. 2022. Predicting individual apple tree yield using UAV multi-source remote sensing data and ensemble learning. *Computers and Electronics in Agriculture*, Volume 201, 107275, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2022.107275>.
- Colaço, A.F., Trevisan, R.G., Molin, J.P., Rosell-Polo, J.R. and Escolà, A. 2017. Orange tree canopy volume estimation by manual and LiDAR-based methods. *Advances in Animal Biosciences*, Volume 8, Issue 2, Pages 477-480, ISSN 2040-4700. <https://doi.org/10.1017/S2040470017001133>.
- Costa, L., Kunwar, S., Ampatzidis, Y., and Albrecht, U. 2022. Determining leaf nutrient concentrations in citrus trees using UAV imagery and machine learning. *Precision Agriculture*, 23, 854–875. <https://doi.org/10.1007/s11119-021-09864-1>.
- Crisp 2011. Principles on remote sensing. Centre for remote imaging, sensing and processing. <http://www.crisp.nus.edu.sg/~research/tutorial/em.htm>.
- Croft, H., Chen, J.M., Luo, X., Bartlett, P., Chen, B., and Staebler, R.M. 2017. Leaf Chlorophyll Content as a Proxy for Leaf Photosynthetic Capacity. *Glob. Chang. Biol.* 2017, 23, 3513–3524. <https://doi.org/10.1111/gcb.13599>.
- Csillik, O., Cherbini, J., Johnson, R., Lyons, A., and Kelly, M. 2018. Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. *Drones*, 2(4): 39. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/drones2040039>.
- Çoşlu, M., Sönmez, N.K. and Selim, S. 2021. Determination of land use changes with OBIA method and Sentinel images: Manavgat-greenhouses sample. In *Planning, Design and Management in Landscape Architecture*, Ankara: Iksad International Publishers, 2021, pp.166-186.
- Çoşlu, M., and Sönmez, N.K. 2022. Determination of olive tree (*Olea europaea* L.) some dendrometric components from unmanned aerial vehicle (UAV) data with local extrema and multiresolution segmentation algorithms. *Ziraat Fakültesi Dergisi*, 17(2), 95-103. <https://doi.org/10.54975/isubuzfd.1150068>.
- Çubukçu, K.M. 2015. Planlamada ve Coğrafyada Temel İstatistik ve Mekânsal İstatistik Kitabı. Nobel Akademik Yayıncılık, Yayın No:1097, Ankara, 346 s.
- Dalponte, M. and Coomes D.A. 2016. Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. *Methods in Ecology and Evolution*, 7(10): 1236-1245. <https://doi.org/10.1111/2041-210X.12575>.
- Daughtry, C.S.T., Walthall, C.L., Kim, M.S., De Colstoun, E.B. and McMurtrey III, J.E. 2000. Estimating corn leaf chlorophyll concentration from leaf and canopy

- reflectance. *Remote Sensing of Environment*, 74(2): 229-239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9).
- De Ollas, C. Morillón, R. Fotopoulos, V. Puértolas, J. Ollitrault, P. Gómez-Cadenas, A. Arbona, V. 2019. Facing climate change: Biotechnology of iconic Mediterranean woody crops. *Front. Plant Sci.*, 10, 427. <https://doi.org/10.3389/fpls.2019.00427>.
- Debnath, S., Paul, M., and Debnath, T. 2023. Applications of LiDAR in Agriculture and Future Research Directions. *Journal of Imaging*, 9(3), 57. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/jimaging9030057>.
- Dedeoglu, M. 2020. Estimation of critical nitrogen contents in peach orchards using visible-near infrared spectral mixture analysis. *Journal of Near Infrared Spectroscopy*, 28(5-6): 315-327. <https://doi.org/10.1177/0967033520939>.
- Delavarpour, N., Koparan, C., Nowatzki, J., Bajwa, S., and Sun, X. 2021. A technical study on UAV characteristics for precision agriculture applications and associated practical challenges. *Remote Sensing*, 13(6), 1204. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13061204>.
- Delegido, J., Wittenberghe, S.V., Verrelst, J., Ortiz, V., Veroustraete, F., Valcke, R., Samson, R., Rivera, J.P., Tenjo, C. and Moreno, J. 2014. Chlorophyll content mapping of urban vegetation in the city of Valencia based on the hyperspectral NAOC index. *Ecological Indicators*, 40, 34-42. <https://doi.org/10.1016/j.ecolind.2014.01.002>.
- Demir, N., Sönmez, N.K., Akar, T. ve Ünal S. 2018. Automated measurement of plant height of wheat genotypes using a DSM derived from UAV imagery. *Proceedings*, 2(7): 350. <https://doi.org/10.3390/ecrs-2-05163>.
- Demir, S. 2021. Isparta yağ gülü (*Rosa damascena* mill.) bahçelerinin insansız hava araçları (İHA) ile izlenmesi ve verim tahmin modellerinin geliştirilmesi. Doktora tezi, Uygulamalı Bilimler Üniversitesi, Isparta, 317 s.
- Dian, Y., Liu, X., Hu, L., Zhang, J., Hu, C., Liu, Y., Zhang, J., Zhang, W., Hu, Q., Zhang, Y., Fang, Y., and Zhou, J. 2023. Characteristics of photosynthesis and vertical canopy architecture of citrus trees under two labor-saving cultivation modes using unmanned aerial vehicle (UAV)-based LiDAR data in citrus orchards. *Horticulture Research*, Volume 10, Issue 3. <https://doi.org/10.1093/hr/uhad018>.
- DJI. 2021. Phantom 3 Advanced Specs. <https://www.dji.com/phantom-3-adv/info>. [Son erişim tarihi: 18.10.2021].
- DJI. 2022. Matrice 200 Series V2 Specs. <https://www.dji.com/matrice-200-series-v2/info>. [Son erişim tarihi: 19.11.2022].
- Dong, X., Zhang, Z., Yu, R., Tian, Q., and Zhu, X. 2020. Extraction of Information about individual trees from high-spatial-resolution UAV-acquired images of an orchard. *Remote Sensing*, 12(1), 133. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12010133>.
- Donmez, C., Villi, O., Berberoglu, S., and Cilek, A. 2021. Computer vision-based citrus tree detection in a cultivated environment using UAV imagery. *Computers and Electronics in Agriculture*, Volume 187, 106273, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2021.106273>.

- Dorj, U.S., Malrey Lee, M., and Yun, S.S. 2017. An yield estimation in citrus orchards via fruit detection and counting using image processing. *Computers and Electronics in Agriculture*, Volume 140, Pages 103-112, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2017.05.019>.
- ESRI. 2022. What is ModelBuilder. <https://pro.arcgis.com/en/pro-app/latest/help/analysis/geoprocessing/modelbuilder/what-is-modelbuilder-.htm> [Son erişim tarihi: 26.09.2022].
- Estornell, J., Hadas, E., Martí, J. And López-Cortés, I. 2021. Tree extraction and estimation of walnut structure parameters using airborne LiDAR data. *International Journal of Applied Earth Observation and Geoinformation*, Volume 96, 102273, ISSN 1569-8432. <https://doi.org/10.1016/j.jag.2020.102273>.
- Feng, A., Zhou, J., Vories, E.D, Kenneth A. Sudduth, K.A., and Zhang, M. 2020. Yield estimation in cotton using UAV-based multi-sensor imagery. *Biosystems Engineering*, Volume 193, Pages 101-114, ISSN 1537-5110. <https://doi.org/10.1016/j.biosystemseng.2020.02.014>.
- Feng, H., Tao, H., Fan, Y., Liu, Y., Li, Z., Yang, G., and Zhao, C. 2022. Comparison of winter wheat yield estimation based on near-surface hyperspectral and UAV hyperspectral remote sensing data. *Remote Sensing*, 14(17), 4158. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs14174158>.
- Ferreira, M.P., Grondona, A.E., Rolim, S. and Shimabukuro, Y. 2013. Analyzing the spectral variability of tropical tree species using hyperspectral feature selection and leaf optical modeling. *Journal of Applied Remote Sensing* 7(1), 073502. <https://doi.org/10.1117/1.JRS.7.073502>.
- Fletcher, R.S., Escobar, D.E. and Skaria, M. 2004. Evaluating airborne normalized difference vegetation index imagery for citrus orchard surveys. *HortTechnology*, 14(1). <https://doi.org/10.21273/HORTTECH.14.1.0091>.
- Forero, M.G., Murcia, H.F., Méndez, D., and Betancourt-Lozano, J. 2022. LiDAR platform for acquisition of 3D plant phenotyping database. *Plants*, 11(17): 2199. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/plants11172199>.
- Fu, Z., Jiang, J., Gao, Y., Krienke, B., Wang, M., Zhong, K., Cao, Q., Tian, Y., Zhu, Y., Cao, W., and Liu, X. 2020. Wheat Growth Monitoring and Yield Estimation based on Multi-Rotor Unmanned Aerial Vehicle. *Remote Sensing*, 12(3): 508. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12030508>.
- Gao, P., Jiang, J., Song, J., Xie, F., Bai, Y., Fu, Y., Wang, Z., Zheng, X. Xie, S. and Li, B. 2021. Canopy volume measurement of fruit trees using robotic platform loaded LiDAR data. in *IEEE Access*, vol. 9, pp. 156246-156259. doi: 10.1109/ACCESS.2021.3127566.
- Garza, B. N., Ancona, V., Enciso, J., Perotto-Baldivieso, H.L., Kunta, M., and Simpson, C. 2020. Quantifying citrus tree health using true color UAV images. *Remote Sensing*, 12(1): 170. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12010170>.
- Geipel, J., Link, J., and Claupein, W. 2014. Combined spectral and spatial modeling of corn yield based on aerial images and crop surface models acquired with an

- unmanned aircraft system. *Remote Sensing*, 6(11): 10335–10355. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs61110335>.
- Gené-Mola, J., Gregorio, E., Cheein, F.A., Guevara, J., Llorens, J., Sanz-Cortiella, R., Escolà, A., and Rosell-Polo, J.R. 2020. Fruit detection, yield prediction and canopy geometric characterization using LiDAR with forced air flow. *Computers and Electronics in Agriculture*, Volume 168, 2020, 105121, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2019.105121>.
- George, D. 2011. SPSS for windows step by step: A simple study guide and reference, 17.0 update. 10/e. Pearson Education India.
- George, D. and Mallery, P. 2019. IBM SPSS statistics 26 step by step: A simple guide and reference. Routledge. <https://doi.org/10.4324/9780429056765>.
- Gitelson, A.A., Kaufman, Y.J. and Merzlyak, M.N. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3): 289-298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7).
- Gitelson, A.A., Stark, R., Grits, U., Rundquist, D., Kaufman, Y. and Derry, D. 2002. Vegetation and soil lines in visible spectral space: a concept and technique for remote estimation of vegetation fraction. *International Journal of Remote Sensing*, 23(13): 2537-2562. <https://doi.org/10.1080/01431160110107806>.
- Glenn, D.M., and Tabb, A. 2019. Evaluation of five methods to measure normalized difference vegetation index (NDVI) in apple and citrus. *International Journal of Fruit Science*, 19:2, 191-210. DOI: 10.1080/15538362.2018.1502720.
- Gu, C., Zhao, C., Zou, W., Yang, S., Dou, H., and Zhai, C. 2022. Innovative leaf area detection models for orchard tree thick canopy based on LiDAR point cloud data. *Agriculture*, 12(8): 1241. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agriculture12081241>.
- El Hachimi, J., El Harti, A., Lhissou, R., Ouzemou, J.-E., Chakouri, M., and Jellouli, A. 2022. Combination of Sentinel-2 satellite images and meteorological data for crop water requirements estimation in intensive agriculture. *Agriculture*, 12(8), 1168. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agriculture12081168>.
- Feng, H., Tao, H., Fan, Y., Liu, Y., Li, Z., Yang, G., and Zhao, C. 2022. Comparison of winter wheat yield estimation based on near-surface hyperspectral and UAV hyperspectral remote sensing data. *Remote Sensing*, 14(17), 4158. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs14174158>.
- Hair, J.F., Black, W.C., Babin, B.J., Anderson, R. E. and Tatham, R.L. 2013. Multivariate Data Analysis. Essex, England.
- He, L., Fang, W., Zhao, G., Wu, Z., Fu, L., Li, R., Majeed, Y. and Dhupia, J. 2022. Fruit yield prediction and estimation in orchards: A state-of-the-art comprehensive review for both direct and indirect methods. *Computers and Electronics in Agriculture*, Volume 195, 106812, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2022.106812>.
- Hobart, M., Pflanz, M., Weltzien, C., and Schirrmann, M. 2020. Growth height determination of tree walls for precise monitoring in apple fruit production using

- UAV photogrammetry. *Remote Sensing*, 12(10), 1656. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12101656>.
- Huete, A.R. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*. 25(3): pp. 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).
- Im, J. and Jensen, J.R. 2008. Hyperspectral remote sensing of vegetation. *Geography Compass*, 2: 1943-1961. <https://doi.org/10.1111/j.1749-8198.2008.00182.x>.
- Jiang, C., Johkan, M., Hohjo, M., Tsukagoshi, S., and Maruo, T. 2017. A correlation analysis on chlorophyll content and SPAD value in tomato leaves. *HortResearch*, 71(71), 37-42.
- Jindo, K., Kozan, O., Iseki, K., Maestrini, B., Evert, F.K., Wubengeda, Y., Arai, E., Shimabukuro, Y.E., Sawada, Y., and Kempenaar, C. 2021. Potential utilization of satellite remote sensing for field-based agricultural studies. *Chemical Biological Technologies Agriculture*, 8:58. <https://doi.org/10.1186/s40538-021-00253-4>.
- Johansen, K., Duan, Q., Tu, Y.H., Searle, C., Wu, D., Phinn, S., Robson, A. and McCabe, M.F. 2020. Mapping the condition of macadamia tree crops using multi-spectral UAV and WorldView-3 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 165, Pages 28-40. <https://doi.org/10.1016/j.isprsjprs.2020.04.017>.
- Kandel, B.P. 2020. Spad value varies with age and leaf of maize plant and its relationship with grain yield. *BMC Res Notes* 13, 475. <https://doi.org/10.1186/s13104-020-05324-7>.
- Kasim, N., Shi, Q., Wang, J., Sawut, R., Nurmemet, I., and Isak, G. 2017. Estimation of spring wheat chlorophyll content based on hyperspectral features and PLSR model. *Transactions of the Chinese Society of Agricultural Engineering*, 33, 208-216.
- Khanal, S., Kushal, K.C., Fulton, J.P., Shearer, S., and Ozkan, E. 2020. Remote Sensing in agriculture-accomplishments, limitations, and opportunities. *Remote Sensing*, 12(22): 3783. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12223783>.
- Koc-San, D., Selim, S., Aslan, N., San, B.T. 2018. Automatic citrus tree extraction from UAV images and digital surface models using circular Hough transform, *Computers and Electronics in Agriculture*, Volume 150, Pages 289-301, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2018.05.001>.
- Konica Minolta. 2022. SPAD-502. <https://www.konicaminolta.eu/eu-en/hardware/measuring-instruments/colour-measurement/chlorophyll-meter/spad-502plus>. [Son erişim tarihi: 19.11.2022].
- Kumar, C., Mubvumba, P., Huang, Y., Dhillon, J., and Reddy, K. 2023. Multi-stage corn yield prediction using high-resolution UAV multispectral data and machine learning models. *Agronomy*, 13(5), 1277. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agronomy13051277>.
- Li, Z., Chen, Z., Cheng, Q., Duan, F., Sui, R., Huang, X., and Xu, H. 2022. UAV-based hyperspectral and ensemble machine learning for predicting yield in winter wheat.

- Agronomy*, 12(1), 202. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agronomy12010202>.
- Liakos, K., Busato, P., Moshou, D., Pearson, S., and Bochtis, D. 2018. Machine learning in agriculture: a review. *Sensors*, 18(8): 2674. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/s18082674>.
- Liang, L., Di, L., Huang, T., Wang, J., Lin, L., Wang, L., and Yang, M. 2018. Estimation of leaf nitrogen content in wheat using new hyperspectral indices and a random forest regression algorithm. *Remote Sensing*, 10(12), 1940. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs10121940>.
- Lillesand, T., M., Kiefer, R., W., and Chipman, J., W. 2004. Remote Sensing and Image Interpretation (Fifth Edition). 10.2307/634969. USA.
- Ling, Q., Huang, W., and Jarvis, P. 2011. Use of a SPAD-502 meter to measure leaf chlorophyll concentration in *Arabidopsis thaliana*. *Photosynthesis research*, 107(2), 209–214. <https://doi.org/10.1007/s11120-010-9606-0>.
- Liu, X., Wang, Y., Kang, F., Yue, Y. and Zheng, Y. 2021. Canopy parameter estimation of citrus grandis var. longanyou based on LiDAR 3D point clouds. *Remote Sensing*, 13(9): 1859. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13091859>.
- Lohani, B., and Ghosh, S. 2017. Airborne LiDAR technology: a review of data collection and processing systems. *Proceedings of the National Academy of Sciences, India Section A: Physical Sciences*, 87, 567–579. <https://doi.org/10.1007/s40010-017-0435-9>.
- Malo, S., Bayala, T.R., Ouattara, I. and Visala, A. 2021. Cashew Trees Detection and Yield Analysis Using UAV-Based Map. 16th Iberian Conference on Information Systems and Technologies (CISTI), pp. 1-5. doi: 10.23919/CISTI52073.2021.9476517.
- Mann, K.K., Schumann, A.W. and Obreza, T.A. 2011. Delineating productivity zones in a citrus grove using citrus production, tree growth and temporally stable soil data. *Precision Agriculture*, 12, 457–472. <https://doi.org/10.1007/s11119-010-9189-y>.
- MAPIR. 2021. Survey 3 Camera Specifications. <https://www.mapir.camera/pages/survey3-cameras#specs> [Son erişim tarihi: 18.10.2021].
- MAPIR. 2022. MAPIR Camera Control (MCC). <https://www.mapir.camera/products/mapir-camera-control> [Son erişim tarihi: 19.11.2022].
- Matese, A., Capraro, F., Primicerio, J., Gualato, G., Di Gennaro S.F. and Agati, G. 2013. Mapping of Vine Vigor by UAV and Anthocyanin Content by a Non-Destructive Fluorescence Technique. In Proceedings of the 9th European Conference on Precision Agriculture (ECPA), 7–11 July, Lleida, Spain.
- Méndez, V., Pérez-Romero, A., Sola-Guirado, R., Miranda-Fuentes, A., Manzano-Agugliaro, F., Zapata-Sierra, A. and Rodríguez-Lizana, A. 2019. In-field estimation of orange number and size by 3D laser scanning. *Agronomy*, 9(12): 885. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agronomy9120885>.

- Meng, Y., Dong, X., Liu, W. and Lin, W. 2020. Modeling biomass of white birch (*Betula platyphylla*) in the Lesser Khingan Range of China based on terrestrial 3D laser scanning system. *Natural Resource Modeling*, 33(1): e12240. <https://doi.org/10.1111/nrm.12240>.
- Meraj, G., Kanga, S., Ambadkar, A., Kumar, P., Singh, S. K., Farooq, M., Johnson, B.A., Rai, A., and Sahu, N. 2022. Assessing the yield of wheat using satellite remote sensing-based machine learning algorithms and simulation modeling. *Remote Sensing*, 14(13), 3005. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs14133005>.
- Mishra, P, Pandey, C.M., Singh, U., Gupta, A., Sahu, C., Keshri, A. 2019. Descriptive statistics and normality tests for statistical data. *Ann Card Anaesth*, 22(1): 67-72. doi: 10.4103/aca.ACA_157_18.
- Modica, G., De Luca, G., Messina, G. And Praticò, S. 2021. Comparison and assessment of different object-based classifications using machine learning algorithms and UAVs multispectral imagery: a case study in a citrus orchard and an onion crop. *European Journal of Remote Sensing*, 54:1, 431-460, DOI: 10.1080/22797254.2021.1951623.
- Monostori, I., Árendás, T., Hoffman, B., Galiba, G., Gierczik, K., Szira, F., and Vagujfalvi, A. 2016. Relationship between SPAD value and grain yield can be affected by cultivar, environment and soil nitrogen content in wheat. *Euphytica*, 211, 103–112. <https://doi.org/10.1007/s10681-016-1741-z>.
- Morell-Monzó, S., Estornell, J., and Sebastiá-Frasquet, M.T. 2023. Assessing the capabilities of high-resolution spectral, altimetric, and textural descriptors for mapping the status of citrus parcels. *Computers and Electronics in Agriculture*, Volume 204, 107504, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2022.107504>.
- Moussaid, A., El Fkihi, S., Zennayi, Y., Lahlou, O., Kassou, I., Bourzeix, F., El Mansouri, L., and Imani, Y. 2022. Machine learning applied to tree crop yield prediction using field data and satellite imagery: a case study in a citrus orchard. *Informatics*, 9(4): 80. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/informatics9040080>.
- Murcia, H.F., Tilaguy, S. and Ouazaa, S. 2021. Development of a low-cost system for 3D orchard mapping integrating UGV and LiDAR. *Plants*, 10(12): 2804. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/plants10122804>.
- Myers, L., Sirois, M.J. 2006. Spearman correlation coefficients, differences between. *Encyclopedia of statistical sciences*, 12. 10.1002/0471667196.ess5050.pub2.
- Nengsih, T., Bertrand, F., Maumy-Bertrand, M. and Meyer, N. 2019. Determining the number of components in PLS regression on incomplete data set. *Statistical Applications in Genetics and Molecular Biology*, 18(6), 20180059. <https://doi.org/10.1515/sagmb-2018-0059>.
- Nevavuori, P., Narra, N., Linna, P., and Lipping, T. 2020. Crop yield prediction using multitemporal UAV data and spatio-temporal deep learning models. *Remote Sensing*, 12(23): 4000. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12234000>.

- Nuijten, R.J.G., Kooistra, L., and De Deyn, G.B. 2019. Using unmanned aerial systems (UAS) and object-based image analysis (OBIA) for measuring plant-soil feedback effects on crop productivity. *Drones*, 3(3): 54. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/drones3030054>.
- Ok, A. O. and Ozdarici-Ok, A. 2018. 2-D delineation of individual citrus trees from UAV-based dense photogrammetric surface models. *International Journal of Digital Earth*, 11 (6): 583-608. <https://doi.org/10.1080/17538947.2017.1337820>.
- Ozdarici-Ok, A. 2015. Automatic detection and delineation of citrus trees from VHR satellite imagery. *Int. J. Remote Sens.*, 36, 4275–4296. <https://doi.org/10.1080/01431161.2015.1079663>.
- Özcan, A.H., Hisar, D., Sayar, Y., Ünsalan, C. 2017. Tree crown detection and delineation in satellite images using probabilistic voting. *Remote Sens. Lett.*, 8, 761–770. <https://doi.org/10.1080/2150704X.2017.1322733>.
- Öztekin, M.E. , Şenol, S., Atatanir, L., Dingil, M., and Dinc, O. 2011. Determination and monitoring of citrus plantation by using Landsat 7 ETM data in a selected area from the Cukurova region. *Journal of Food Agriculture and Environment*, vol.9, no.2, 498-503.
- Penuelas, J., Gamon, J.A., Fredeen, A.L., Merino, J. and Field, C.B. 1994. Reflectance Indices Associated with physiological changes in nitrogen-and water – limited sunflower leaves. *Remote Sensing of Environment*, 48(2): 135-146. [https://doi.org/10.1016/0034-4257\(94\)90136-8](https://doi.org/10.1016/0034-4257(94)90136-8).
- Polat, E. 2009. Kısmi En Küçük Kareler Regresyonu. Yüksek lisans tezi, Hacettepe Üniversitesi Ankara, 170 s.
- Polat, E. ve Gunay, S. 2009. Kısmi En Küçük Kareler ve Bir Uygulama. VI. İstatistik Günleri Sempozyumu Bildiriler Kitabı, ss. 437-444, Ondokuz Mayıs Üniversitesi, Samsun.
- Polat, E. 2014. Sağlam Kısmi En Küçük Kareler Regresyon Analizinde Yeni Yaklaşımlar. Doktora tezi, Hacettepe Üniversitesi Ankara, 151 s.
- Porcar-Castell, A., Tyystjärvi, E., Atherton, J., Van Der Tol, C., Flexas, J., Pfündel, E.E., Moreno, J., Frankenberg, C., Berry, J.A. 2014. Linking chlorophyll a fluorescence to photosynthesis for remote sensing applications: mechanisms and challenges. *J. Exp. Bot.*, 65, 4065–4095.
- Qin, W., Assinck, F.B.T., Heinen, M., and Oenema, O. 2016. Water and nitrogen use efficiencies in citrus production: A meta-analysis. *Agriculture, Ecosystems & Environment*, Volume 222, Pages 103-111, ISSN 0167-8809. <https://doi.org/10.1016/j.agee.2016.01.052>.
- Qi, Y., Dong, X., Chen, P., Lee, K.H., Lan, Y., Lu, X., Jia, R., Deng, J. and Zhang, Y. 2021. Canopy volume extraction of citrus reticulate blanco cv. shatangju trees using UAV image-based point cloud deep learning. *Remote Sensing*, 13(17): 3437. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13173437>.
- Rahman, M., M., Robson, A., J., Bristow, M. 2018. Exploring the potential of high resolution WorldView-3 imagery for estimating yield of mango. *Remote. Sensing*, 10(12): 1866. <https://doi.org/10.3390/rs10121866>.

- Ramesh, K., Chandrasekaran, B., Balasubramanian, T.N., Bangarusamy, U., Sivasamy, R. and Sankaran, N. 2002. Chlorophyll dynamics in rice (*Oryza Sativa*) before and after flowering based on SPAD (Chlorophyll) meter monitoring and its relation with grain yield. *Journal of Agronomy and Crop Science*, 188: 102-105. <https://doi.org/10.1046/j.1439-037X.2002.00532.x>.
- Rivas, F., Gravina, A. and Agusti, M. 2007. Girdling effects on fruit set and quantum yield efficiency of PSII in two citrus cultivars. *Tree Physiology*, 27, 527-535. <https://doi.org/10.1093/treephys/27.4.527>.
- Rosell, J. R., Llorens, J., Sanz, R., Arnó, J., Ribes-Dasi, M., Masip, J., Escolà, A., Camp, F., Solanelles, F., Gràcia, F., Gil, E., Val, L., Planas, S. and Palacín, J. 2009. Obtaining the three-dimensional structure of tree orchards from remote 2D terrestrial LIDAR scanning. *Agricultural and Forest Meteorology*, Volume 149, Issue 9, Pages 1505-1515, ISSN 0168-1923. <https://doi.org/10.1016/j.agrformet.2009.04.008>.
- Roussel, J.R., Auty, D., Coops, N.C., Tompalski, P., Goodbody, T.R.H., Meador, A.S., Bourdon, J.F., Florian de Boissieu, F. and Achim, A. 2020. lidR: An R package for analysis of airborne laser scanning (ALS) data. *Remote Sensing of Environment*, Volume 251, 112061, ISSN 0034-4257. <https://doi.org/10.1016/j.rse.2020.112061>.
- Rouse, J.W., Haas, R.H., Schell, J.A. and Deering, D.W. 1973. Monitoring vegetation systems in the Great Plains with ERTS. In Third Earth Resources Technology Satellite-1 Symposium, pp. 309–317, 10–14 December, Washington DC (Washington, DC: NASA).
- Saad El Imanni, H., El Harti, A., Bachaoui, E.M., Mouncif, H., Eddassouqui, F., Hasnai, M.A., Zinelabidine, M.A. 2023. Multispectral UAV data for detection of weeds in a citrus farm using machine learning and Google Earth Engine: Case study of Morocco. *Remote Sensing Applications: Society and Environment*, Volume 30, 100941, ISSN 2352-9385. <https://doi.org/10.1016/j.rsase.2023.100941>.
- Sankaran, S., and Ehsani, R. 2011. Visible-near infrared spectroscopy based citrus greening detection: Evaluation of spectral feature extraction techniques. *Crop Protection*, Volume 30, Issue 11, 2011, Pages 1508-1513, ISSN 0261-2194. <https://doi.org/10.1016/j.cropro.2011.07.005>.
- Sanz-Cortiella, R., Llorens-Calveras, J., Escolà, A., Arnó-Satorra, J., Ribes-Dasi, M., Masip-Vilalta, J., Camp, F., Gràcia-Aguilá, F., Solanelles-Batlle, F., Planas-DeMartí, S. et al. 2011. Innovative LIDAR 3D dynamic measurement system to estimate fruit-tree leaf area. *Sensors*, 11(6): 5769–5791. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/s110605769>.
- Sanz, R., Rosell, J.R., Llorens, J. Gil, E. and Planas, S. 2013. Relationship between tree row LIDAR volume and leaf area density for fruit orchards and vineyards obtained with a LIDAR 3D Dynamic Measurement System. *Agricultural and Forest Meteorology*, Volumes 171–172, Pages 153-162, ISSN 0168-1923. <https://doi.org/10.1016/j.agrformet.2012.11.013>.
- Sarı, M., Sönmez, N.K., Aksoy, E., Tunç, E., Saydam, Ş. 2008. Kadriye Beldesi Sürtődülebilir Arazi Yönetim Planı. Proje Raporu, Antalya.

- Sarron, J., Malézieux, É., Sané, C., and Faye, É. 2018. Mango yield mapping at the orchard scale based on tree structure and land cover assessed by UAV. *Remote Sensing*, 10(12), 1900. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs10121900>.
- Selim, S., Sonmez, N.K., Coslu, M. and Onur, I. 2019. Semi-automatic tree detection from images of unmanned aerial vehicle using object-based image analysis method. *Journal of the Indian Society of Remote Sensing*, 47, 193–200. <https://doi.org/10.1007/s12524-018-0900-1>.
- Shanmugapriya, P.K., Latha, R., Pazhanivelan, S. Kumaraperumal, R., Karthikeyan, G. and Sudarmanian. N.S. 2022. Cotton yield prediction using drone derived LAI and chlorophyll content. *Journal of Agrometeorology*, 24(4), 348–352. <https://doi.org/10.54386/jam.v24i4.1770>.
- SHGM. 2016. İnsansız hava aracı sistemleri talimatı (SHT-İHA). https://web.shgm.gov.tr/documents/sivilhavacilik/files/mevzuat/sektorel/talimatlar/2020/SHT-IHA_Rev-04.pdf. [Son erişim tarihi: 12.06.2023].
- Shrivastavaa, R.J. and Gebelein J.L. 2007. Land cover classification and economic assessment of citrus groves using remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 61(5): 341-353. <https://doi.org/10.1016/j.isprsjprs.2006.10.003>.
- Sishodia, R.P., Ray, R.L., and Singh, S.K. 2020. Applications of remote sensing in precision agriculture: a review. *Remote Sensing*, 12(19), 3136. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12193136>.
- Sönmez, N.K. 2004. Washington Navel portakal çeşidinin klorofil içerikleri ile uzaktan algılamaya dayalı spektral özellikleri arasındaki ilişkilerin belirlenmesi. Doktora tezi, Akdeniz Üniversitesi, Antalya, 200 s.
- Sönmez, N.K. , Aslan, G.E. ve Kurunç, A. 2015. Farklı tuz stresi altındaki domates bitkisinin spektral yansıma ilişkileri. *Journal of Agricultural Sciences*, 21 (4), 585-595. https://doi.org/10.1501/Tarimbil_0000001359.
- Sönmez, N.K., Çoşlu, M. ve Demir, N. 2021. Farklı insansız hava araçlarından (İHA) elde edilen veriler ile buğday bitkisinin boyunun belirlenmesi. *Mediterranean Agricultural Sciences*, 34(2): 195-203. <https://doi.org/10.29136/mediterranean.823440>.
- Stateras, D. and Kalivas, D. 2020. Assessment of olive tree canopy characteristics and yield forecast model using high resolution UAV imagery. *Agriculture*, 10(9): 385. <https://doi.org/10.3390/agriculture10090385>.
- Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., and Chen, W.H. 2021. Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, Volume 192, 106621, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2021.106621>.
- Sumesh, K.C., Sarawut Ninsawat, Jaturong Som-ard. 2021. Integration of RGB-based vegetation index, crop surface model and object-based image analysis approach for sugarcane yield estimation using unmanned aerial vehicle. *Computers and*

- Electronics in Agriculture*, Volume 180, 2021, 105903, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2020.105903>.
- Sunar, F., Özkan, C., ve Osmanoğlu, B. 2013. Uzaktan Algılama (2.Baskı). T.C. Anadolu Üniversitesi, Yayın No: 2320, Açıköğretim Fakültesi Yayın No:1317, Eskişehir.
- Sunoj, S., Cho, J., Guinness, J., van Aardt, J., Czymmek, K. J., and Ketterings, Q. M. 2021. Corn grain yield prediction and mapping from unmanned aerial system (UAS) multispectral imagery. *Remote Sensing*, 13(19): 3948. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13193948>.
- Ta, N., Chang, Q., and Zhang, Y. 2021. Estimation of apple tree leaf chlorophyll content based on machine learning methods. *Remote Sensing*, 13(19), 3902. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13193902>.
- Tabachnick, B.G., Fidell, L.S. and Ullman, J.B. 2007. Using Multivariate Statistics. California State University, Northridge, Boston, MA: Pearson.
- TEPGE. 2022. Turunçgiller ürün raporu. <https://arastirma.tarimorman.gov.tr/tepge/Belgeler/PDF%20%C3%9Cr%C3%BCn%20Raporlar%C4%B1/2022%20%C3%9Cr%C3%BCn%20Raporlar%C4%B1/Turun%C3%A7giller%20%C3%9Cr%C3%BCn%20Raporu-TEPGE-353.pdf> [Son erişim tarihi: 03.07.2023].
- Terentev, A., Dolzhenko, V., Fedotov, A., and Eremenko, D. 2022. Current state of hyperspectral remote sensing for early plant disease detection: A review. *Sensors*, 22(3), 757. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/s22030757>.
- Terentev, A., Badenko, V., Shaydayuk, E., Emelyanov, D., Eremenko, D., Klabukov, D., Fedotov, A., and Dolzhenko, V. 2023. Hyperspectral remote sensing for early detection of wheat leaf rust caused by puccinia triticea. *Agriculture*, 13(6), 1186. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agriculture13061186>.
- Torbick, N., Chowdhury, D., Salas, W., and Qi, J. 2017. Monitoring rice agriculture across Myanmar using time series Sentinel-1 assisted by Landsat-8 and PALSAR-2. *Remote Sensing*, 9(2), 119. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs9020119>.
- Torgbor, B.A., Rahman, M.M., Brinkhoff, J., Sinha, P., and Robson, A. 2023. Integrating remote sensing and weather variables for mango yield prediction using a machine learning approach. *Remote Sensing*, 15(12), 3075. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs15123075>.
- Tsouros, D.C., Bibi, S., and Sarigiannidis, P.G. 2019. A review on UAV-based applications for precision agriculture. *Information*, 10(11): 349. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/info10110349>.
- Tucker, C.J. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2): 127-150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0).
- Tuğaç, M.G., Özbayoğlu, A.M., Torunlar, H. and Karakurt, E. 2022. Wheat yield prediction with machine learning based on MODIS and Landsat NDVI data at field scale. *International Journal of Environment and Geoinformatics*, 9 (4) , 172-184. <https://doi.org/10.30897/ijgeo.1128985>.

- Tunca, E., Köksal, E.S., ve Çetin Taner, S. 2023. Calibrating UAV thermal sensors using machine learning methods for improved accuracy in agricultural applications. *Infrared Physics & Technology*, Volume 133, 104804, ISSN 1350-4495. <https://doi.org/10.1016/j.infrared.2023.104804>.
- Uno, Y., Prasher, S.O., Lacroix, R., Goel, P.K., Karimi, Y., Viau, A., and Patel, R.M. 2005. Artificial neural networks to predict corn yield from compact airborne spectrographic imager data. *Computers and Electronics in Agriculture*, Volume 47, Issue 2, Pages 149-161, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2004.11.014>.
- Uysal, O. ve Polatöz, S. 2017. Dünyada ve Türkiye'de turunçgil üretimi ve dış ticareti. <https://www.turktob.org.tr/dergi/makaleler/dergi22/6-11.pdf> [Son erişim tarihi: 19.11.2022].
- Verma, N., Lamb, D., Reid, N., and Wilson, B. 2016. Comparison of canopy volume measurements of scattered eucalypt farm trees derived from high spatial resolution imagery and LiDAR. *Remote Sensing*, 8(5): 388. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs8050388>.
- Vijayakumar, V., Ampatzidis, Y., and Costa, L. 2023. Tree-level citrus yield prediction utilizing ground and aerial machine vision and machine learning. *Smart Agricultural Technology*, Volume 3, 2023, 100077, ISSN 2772-3755. <https://doi.org/10.1016/j.atech.2022.100077>.
- Vogel, E., Donat, M.G., Alexander, L.V., Meinshausen, M., Ray, D.K., Karoly, D., Meinshausen, N., and Frieler, K. 2019. The effects of climate extremes on global agricultural yields. *Environ. Res. Lett.*, 2019, 14, 054010. DOI: 10.1088/1748-9326/ab154b.
- Wang, H.F., Huo, Z.G., Zhou, G.S., Liao, Q.H., Feng, H.K. and Wu, L. 2016. Estimating leaf SPAD values of freeze-damaged winter wheat using continuous wavelet analysis. *Plant Physiology and Biochemistry*, 98: 39–45. <https://doi.org/10.1016/j.plaphy.2015.10.032>.
- Wang, Y., Weinacker, H. and Koch, B. 2008. A Lidar point cloud based procedure for vertical canopy structure analysis and 3d single tree modelling in forest. *Sensors*, 8(6): 3938-3951. doi:10.3390/s8063938.
- Wang, K.J., Li, W.T., Deng, L., Lyu, Q., Zheng, Y.Q., Yi, S.L, X, R., Ma, Y., and He, S. 2018. Rapid detection of chlorophyll content and distribution in citrus orchards based on low-altitude remote sensing and bio-sensors. *Int J Agric and Biol Eng.*, 11(2): 164–169.
- Wang, K., Zhou, J., Zhang, W. and Zhang, B. 2021. Mobile LiDAR scanning system combined with canopy morphology extracting methods for tree crown parameters evaluation in orchards. *Sensors*, 21(2): 339. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/s21020339>.
- Wold, S., Sjöström, M., and Eriksson, L. 2001. PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, Volume 58, Issue 2, Pages 109-130, ISSN 0169-7439. [https://doi.org/10.1016/S0169-7439\(01\)00155-1](https://doi.org/10.1016/S0169-7439(01)00155-1).

- Wu, Q., Zhang, Y., Zhao, Z., Xie, M., and Hou, D. 2023. Estimation of relative chlorophyll content in spring wheat based on multi-temporal UAV remote sensing. *Agronomy*, 13(1), 211. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/agronomy13010211>.
- Yang, J., Wen, X., Wang, Q., Ye, J.-S., Zhang, Y. and Sun, Y. 2022. A novel algorithm based on geometric characteristics for tree branch skeleton extraction from LiDAR point cloud. *Forests*, 13(10): 1534. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/f13101534>.
- Ye, X., Sakai, K., Manago, M., Asada, S., and Sasao, A. 2007. Prediction of citrus yield from airborne hyperspectral imagery. *Precision Agriculture*, 8(3): 111–125. <https://doi.org/10.1007/s11119-007-9032-2>.
- Ye, X.J, Kenshi, S., and He, Y. 2010. Development of citrus yield prediction model based on airborne hyperspectral imaging. *Guang Pu Xue Yu Guang Pu Fen Xi*. 2010 May;30(5):1295-300. Chinese. PMID: 20672621. <https://pubmed.ncbi.nlm.nih.gov/20672621/>.
- Ye, X. and Sakai, K. 2012. Fruit Yield Estimation Through Multispectral Imaging. In: Srivastava A. (eds) *Advances in Citrus Nutrition*. Springer, Dordrecht. https://doi.org/10.1007/978-94-007-4171-3_30.
- Yuan, Z., Cao, Q., Zhang, K., Ata-Ul-Karim, S.T., Tian, Y., Zhu, Y., Cao, W. and Liu, X. 2016. Optimal leaf positions for SPAD meter measurement in rice. *Frontier Plant Science*, 7:719. <https://doi.org/10.3389/fpls.2016.00719>.
- Zar, J.H. 1972. Significance testing of the Spearman rank correlation. *Journal of the American Statistical Association*, 67:339, 578-580. <https://doi.org/10.2307/2284441>.
- Zeng, W., Xu, C., Gang, Z., Wu, J., and Huang, J. 2018. Estimation of sunflower seed yield using partial least squares regression and artificial neural network models. *Pedosphere*, Volume 28, Issue 5, 2018, Pages 764-774, ISSN 1002-0160. [https://doi.org/10.1016/S1002-0160\(17\)60336-9](https://doi.org/10.1016/S1002-0160(17)60336-9).
- Zhang, Z. and Huang, R. 2013. Analysis of malondialdehyde, chlorophyll proline, soluble sugar, and glutathione content in Arabidopsis seedling. *Bio-protocol* 3, e817. <https://doi.org/10.21769/BioProtoc.817>.
- Zhang, Y., Zheng, L., Li, M., Deng, X., and Ji, R. 2015. Predicting apple sugar content based on spectral characteristics of apple tree leaf in different phenological phases. *Computers and Electronics in Agriculture*, Volume 112, 2015, Pages 20-27, ISSN 0168-1699. <https://doi.org/10.1016/j.compag.2015.01.006>.
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., and Yan, G. 2016. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 8(6): 501. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs8060501>.
- Zhang, C., Yang, G., Jiang, Y., Xu, B., Li, X., Zhu, Y., Lei, L., Chen, R., Dong, Z. and Yang, H. 2020. Apple tree branch information extraction from terrestrial laser scanning and backpack-LiDAR. *Remote Sensing*, 12(21): 3592. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs12213592>.

- Zhang, X., Bao, Y., Wang, D., Xin, X., Ding, L., Xu, D., Hou, L. and Shen, J. 2021. Using UAV LiDAR to extract vegetation parameters of inner Mongolian grassland. *Remote Sensing*, 13(4): 656. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs13040656>.
- Zhang, R., Yang, P., Liu, S., Wang, C., and Liu, J. 2022. Evaluation of the methods for estimating leaf chlorophyll content with SPAD chlorophyll meters. *Remote Sensing*, 14(20), 5144. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/rs14205144>.
- Zhang, K., Maskey, S., Okazawa, H., Hayashi, K., Hayashi, T., Sekiyama, A., Shimada, S. and Fiwa, L. 2022. Assessment of three automated identification methods for ground object based on UAV imagery. *Sustainability*, 14(21): 14603. MDPI AG. Retrieved from <http://dx.doi.org/10.3390/su142114603>.
- Zhou, X., Zheng, H.B., Xu, X.Q., He, J.Y., Ge, X.K., Yao, X., Cheng, T., Zhu, Y., Cao, W.X., and Tian, Y.C. 2017. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS J. Photogramm. Remote Sensing*, 130, 246–255. <https://doi.org/10.1016/j.isprsjprs.2017.05.003>.
- Zhu, W., Li, S., Zhang, X., Li, Y., and Sun, Z. 2018. Estimation of winter wheat yield using optimal vegetation indices from unmanned aerial vehicle remote sensing. *Nongye Gongcheng Xuebao/Trans. Chinese Society of Agricultural Engineering*, 34, 78–86.

ÖZGEÇMİŞ

MESUT ÇOŞLU

ÖĞRENİM BİLGİLERİ

Doktora 2020-2023	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Antalya
Yüksek Lisans 2017-2019	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Antalya
Lisans 2012-2018	Anadolu Üniversitesi İktisat Fakültesi, Kamu Yönetimi Bölümü, Eskişehir
Yüksek Lisans 2014-2016	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Tarım Ekonomisi Anabilim Dalı, Antalya
Lisans 1996-2000	Atatürk Üniversitesi Ziraat Fakültesi, Tarla Bitkileri Bölümü, Erzurum

MESLEKİ VE İDARİ GÖREVLER

Mühendis 2022-Devam Ediyor	Akdeniz Üniversitesi Yapı İşleri ve Teknik Daire Başkanlığı, Antalya
Mühendis 2011-2022	Akdeniz Üniversitesi Uzaktan Algılama Araştırma ve Uygulama Merkezi (AKUZAL), Antalya
Mühendis 2010-2011	Akdeniz Üniversitesi Yapı İşleri ve Teknik Daire Başkanlığı, Antalya
Subay 2001-2010	Türk Silahlı Kuvvetleri Kara Kuvvetleri Komutanlığı

ESERLER

SCI, SSCI, AHCI indekslerine giren dergilerde yayınlanan makaleler

Selim S., Sönmez, N.K., Çoşlu, M., Onur, I. (2019). Semi-automatic Tree Detection from Images of Unmanned Aerial Vehicle Using Object-Based Image Analysis Method. *Journal of the Indian Society of Remote Sensing*, vol.47, no.1, pp.193-200. <https://doi.org/10.1007/s12524-018-0900-1>.

Diğer dergilerde yayınlanan makaleler

Çoşlu, M., Sönmez, N.K. (2022). Determination of Olive Tree (*Olea europaea* L.) Some Dendrometric Components from Unmanned Aerial Vehicle (UAV) Data with Local Extrema and Multiresolution Segmentation Algorithms. *Ziraat Fakültesi Dergisi*, 17(2), 95-103. <https://doi.org/10.54975/isubuzfd.1150068>.

Sönmez, N.K., Çoşlu, M., Demir, N. (2021). Farklı insansız hava araçlarından (İHA) elde edilen veriler ile buğday bitkisinin boyunun belirlenmesi. *Mediterranean Agricultural Sciences*, 34(2), 195-203. <https://doi.org/10.29136/mediterranean.823440>.

Sönmez, N.K., Sönmez, S., Turkkan, H., Altın, R., Çoşlu, M. (2020). Tarımsal Üretimde Kullanılan Sulama Sularının Elektriksel İletkenliğinin (EC) Uzaysal Değişkenlik Analizi: Dalaman-Muğla Örneği. *Ziraat Fakültesi Dergisi*, 15(1), 12-26. <https://dergipark.org.tr/tr/pub/sduzfd/issue/55288/652515>.

Selim, S., Çoşlu, M., Sönmez, N.K., Karakuş, N. (2016). Köyceğiz Gölü ve Dalyan Kanallarında Kıyı Kenar Çizgisinin UA ve CBS Teknikleri ile Belirlenmesi, Alanda Karşılaşılan Sorunlar. *Süleyman Demirel Üniversitesi Fen Bilimleri*

Hakemli kongre/sempozyumların bildiri kitaplarında yer alan yayınlar

- Çoşlu, M., Sönmez, N.K. (2019). Aşırı Yağışlar Sonucu Zarar Gören Alanların Sentetik Açıklıklı Radar (SAR) Görüntüleri İle Tespit Edilmesi, II. International Eurasian Agriculture and Natural Sciences Congress, Antalya, Türkiye, 17-20 Ekim 2019, vol.1, no.1, pp.279-286.
- Çoşlu, M., Sönmez, N.K. (2019). Normalize Edilmiş Sayısal Yüzey Modeli (NDSM) İle Bitki Boyu Ölçümü ve Verim İlişkisi, II. International Eurasian Agriculture and Natural Sciences Congress, Antalya, Türkiye, 17-20 Ekim 2019, vol.1, no.1, pp.271-278.
- Çoşlu, M., Sönmez, N.K., Türkkan, H.R. (2018). Determination of Annual Agricultural Areas by High Resolution Satellite Data and Object-Based Classification Method. I. International Agricultural Science Congress, Van, Turkey, 9-12 May 2018, vol.1, no.1, pp.644.
- Çoşlu, M., Sönmez, N.K., Türkkan, H.R. (2018). Görüntü Füzyonu ve Sınıflandırma Teknikleri Kullanarak Su Yüzeyindeki Alansal Değişimin Belirlenmesi. VII. Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2018), 18-21 Eylül 2018, Eskişehir. <http://dx.doi.org/10.15659/uzalcbs2018.6671>.
- Çoşlu, M., Sönmez, N.K., Türkkan, H.R. (2018). Analysis of Forest Fire with Remote Sensing and Geographical Information Systems, International Academic Research Congress, Türkiye, vol.1, pp.1827-1834.
- Sönmez, N.K., Sönmez, S., Çoşlu, M., Türkkan, H.R. (2018). Determination of Appropriate Areas of Apple (Malus Domestica) Cultivation with AHP and GIS Techniques. International Conference on Agriculture, Forestry Life Sciences, Budapeşte, Macaristan, vol.1, pp.130-138.
- Türkkan, H.R., Sönmez, N.K., Çoşlu, M. (2018). Determination of Time Changes in the Surface of Burdur Lake with Different Remote Sensing Techniques. International Academic Research Congress, Türkiye, vol.1, pp.2140-2147.
- Türkkan, H.R., Sönmez, N.K., Çoşlu, M. (2018). Determination of Groundwater Deposit and Water Analysis by Spatial Statistical Methods Korkuteli-Antalya Example. International Academic Research Congress, Türkiye, vol.1, pp.2356-2363.
- Onur, I., Sönmez, N.K., Çoşlu, M. (2018). Evaluation of Vegetation Cover by Supervised Classification and Four Vegetation Indices with Sentinel 2 Image of Kemer in Antalya, Turkey. International Academic Research Congress, vol.1, pp.1993-2000.
- Selim, S., Sönmez, N.K., Çoşlu, M. (2017). İnsansız Hava Araçları (İHA) ile Alınan Görüntülerin Kalitesini Etkileyen Faktörler. II. International Academic Research Congress, Antalya, Türkiye, 18-21 Ekim 2017, pp.675-675.

- Selim, S., Sönmez, N.K., Onur, I., Çoşlu, M. (2017). Determination of the ecological connectivity between landscape patches obtained using the knowledge engineer (expert) classification technique. SPIE Remote Sensing, Varşova, Polonya, 11-14 Eylül 2017, pp.1-9.
- Çoşlu, M., Sönmez, N.K. (2016). Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Teknikleri Kullanarak İtfaiye İstasyonlarının Ulaşabilirliğinin Analizi. 6. Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2016), 5-7 Ekim 2016, Adana, 599-606.
- Çoşlu, M., Sönmez, N.K., Koç San, D. (2016). Object-Based Greenhouse Classification from High Resolution Satellite Imagery: a Case Study Antalya-Turkey", XXIII Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS), Prag, Çek Cum., 12-19 Temmuz 2016, vol. XLI-B7, pp.183-187.

Kitap ve kitap bölümleri

- Çoşlu M., Karakuş N., Selim S., Sönmez N.K. (2021). Evaluation of the Relationship Between Land Use and Land Surface Temperature in Manavgat Sub-Basin, in: Planning, Design and Management in Landscape Architecture, Altuntaş A., Eds., IKSAD International Publishers , Ankara, pp.3-34.
- Çoşlu M., Sönmez N.K., Selim, S. (2021). Determination of Land Use Changes with OBIA Method and Sentinel Images: Manavgat-Greenhouses Sample", in: Planning, Design and Management in Landscape Architecture, Altuntaş A., Eds., IKSAD International Publishers , Ankara, pp.166-186.
- Selim, S., Çoşlu, M., Sönmez, N.K. (2018). Erişilebilirlik Analizi: Zaman ve Mekan Koordinasyonunun Sağlanmasında CBS Tabanlı Mekânsal Erişim Planlaması. Mühendislik ve Mimarlık Çalışmaları, Çiftçi, N., Yanar, Y., Ed., Çizgi Kitabevi Yayınları, Ankara, ss.1-8.
- Türkkan, H.R., Sönmez, N.K., Çoşlu, M. (2018). Nar (Punica Granatum) Yetiştiriciliğine Uygun Alanların AHP ve CBS Teknikleri İle Belirlenmesi", Mühendislik Ve Mimarlık Çalışmaları, Nizamettin ÇİFTÇİ, Yusuf YANAR, Ed., Çizgi Kitabevi, ss.157-165.
- Çoşlu, M., Yelboğa, M.N.M., Türkkan, H.R. (2017). Organik Tarım Faaliyetinde Bulunan Ticari İşletmelerin Coğrafi Bilgi Sistemleri İle Mekânsal Analizi", Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları, Çiftçi, N., Kara, Y., Yalçınkaya, İ., Şahin, M., Ağaçayak, T., Ed., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.263-270.
- Çoşlu, M., Sönmez, N.K., Koç San, D., Aslan, N. (2017). Sentinel-2A Görüntülerinden Nesne Tabanlı Arazi Kullanımı/Arazi Örtüsü Haritalamasında Makine Öğrenme Algoritmalarının Değerlendirilmesi", Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları, Çiftçi, N., Kara, Y., Yalçınkaya, İ., Şahin, M., Ağaçayak, T., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.71-76, 2017.

Aslan, N., Koç San, D., Sönmez, N.K., Çoşlu, M. (2017). Landsat-8 ve Sentinel-2A Uydu Görüntülerinin Arazi Kullanımı/Arazi Örtüsü Sınıflandırma Performanslarının Karşılaştırılması. Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları, Çiftçi, N., Kara, Y., Yalçinkaya, İ., Şahin, M., Ağaçayak, T., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.65-70, 2017.

Sönmez, N.K., Çoşlu, M., Selim S. (2017). Farklı Çözünürlüklerdeki İnsansız Hava Aracı (İHA) Görüntülerinin Nesne Tabanlı Sınıflandırma Sonuçlarına Etkileri", Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları 2017, Çiftçi, N., Kara, Y., Yalçinkaya, İ., Şahin, M., Ağaçayak, T., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.57-64.

Çoşlu, M., Selim, S., Sönmez, N.K., Koç San, D. (2016). Network Analysis; Accessibility to Hospitals with Remote sensing and Geographic Information Systems Techniques: A Case Study of Konyaaltı, Antalya-Turkey. In: Recent Advances in Health Sciences, A. Adil Çamlı, Bilal AK, Ramiz Arabacı, Recep EFE, Eds., St. Kliment Ohridski University Press, Sofia, pp.640-647.