

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**HİPERSPEKTRAL VERİLER KULLANILARAK SATSUMA MANDARİNİNDE
MEVSİMSEL KLOROFİL DEĞİŞİMİNİN KİSMİ EN KÜÇÜK KARELER
REGRESYONU (PLSR) MAKİNE ÖĞRENME
ALGORİTMASI İLE MODELLENMESİ**

Dilara AYDUS SARI

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

OCAK 2025

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**HİPERSPEKTRAL VERİLER KULLANILARAK SATSUMA MANDARİNİNDE
MEVSİMSEL KLOROFİL DEĞİŞİMİNİN KİSMİ EN KÜÇÜK KARELER
REGRESYONU (PLSR) MAKİNE ÖĞRENME
ALGORİTMASI İLE MODELLENMESİ**

Dilara AYDUS SARI

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

OCAK 2025

ANTALYA

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

**HİPERSPEKTRAL VERİLER KULLANILARAK SATSUMA MANDARİNİNDE
MEVSİMSEL KLOROFİL DEĞİŞİMİNİN KİSMİ EN KÜÇÜK KARELER
REGRESYONU (PLSR) MAKİNE ÖĞRENME
ALGORİTMASI İLE MODELLENMESİ**

**Dilara AYDUS SARI
UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

OCAK 2025

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİPERSPEKTRAL VERİLER KULLANILARAK SATSUMA MANDARİNİNDE
MEVSİMSEL KLOROFİL DEĞİŞİMİNİN KISMİ EN KÜÇÜK KARELER
REGRESYONU (PLSR) MAKİNE ÖĞRENME
ALGORİTMASI İLE MODELLENMESİ

Dilara AYDUS SARI
UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ

Bu tez 31/01/2025 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Prof. Dr. Sahriye SÖNMEZ (Danışman)

Doç. Dr. İlker ÜNAL

Dr. Öğr. Üyesi Gülçin Ece ASLAN

ÖZET

HİPERSPEKTRAL VERİLER KULLANILARAK SATSUMA MANDARİNİNDE MEVSİMSEL KLOROFİL DEĞİŞİMİNİN KİSMİ EN KÜÇÜK KARELER REGRESYONU (PLSR) MAKİNE ÖĞRENME ALGORİTMASI İLE MODELLENMESİ

Dilara AYDUS SARI

Yüksek Lisans Tezi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Prof. Dr. Sahriye SÖNMEZ

II. Danışman: Dr. Öğr. Üyesi Mesut ÇOŞLU

Ocak 2025; 69 sayfa

Son yıllarda sürdürülebilir tarım, hassas tarım gibi birçok kavram hayatımızın her alanında karşımıza çıkmaktadır. Ekolojik, ekonomik ve her açıdan tasarruf sağlayan tarım uygulamaları tercih edilmektedir. Uzaktan algılama ve bilgisayar bilimi ile oluşturulan çalışma modelleri de tarım alanında hızlı ve tahribatsız üretim sürecine olanak sağlamaktadır. Üretim sezonu boyunca bitki sağlığını korumak tüm tarım girdileri için önemli bir kriterdir. Bitki sağlığının önemli göstergelerinden biri olan klorofil içeriği de bu sebeple araştırmalarda temel parametre olarak görülmektedir. Uzaktan algılama çalışmalarında; spektral yansıma değerlerinde, 700 nm'ye yakın ve 530-630 nm aralığında duyarlı olması klorofil içeriğinin dolayısıyla bitki sağlığının yorumlanmasına ve tarımsal faaliyetlerin yürütülmesine rehberlik etmektedir. Son yıllarda popülerliğini artıran makine öğrenmesi algoritmaları, yoğun veri setlerinin hızlı ve güvenilir bir şekilde analiz edilmesinde ve tahmin modellerinin oluşturulmasında önemli avantajlar sağlamaktadır. Nitekim çeşitli makine öğrenmesi algoritmaları kullanılarak farklı modellerin eğitilmesi, klorofil gibi bitki için önemli bir parametrenin mevcut ve gelecek tahminlerinin yapılması mümkün olabilmektedir. Bu makine öğrenme algoritmalarından birisi de en küçük kareler regresyonu (PLSR) yöntemidir. Yürütülen bu çalışmada, Antalya ilinde üretimi yapılan Satsuma mandarin bahçesi ağaçlarından 12 ay boyunca her ay alınan yaprak örneklerinde ASD FieldSpec El Tipi Spektrometre cihazı ile hiperspektral yansıma ölçümleri ve SPAD-502Plus klorofil ölçüm cihazı ile de klorofil ölçümleri gerçekleştirilmiştir. Çalışmada, bitkinin uzaktan algılamaya dayalı spektral özelliklerinin dönemsel olarak sorgulanarak yansıma ve klorofil ilişkisinin istatistiksel olarak belirlenmesi ve PLSR yöntemi ile klorofil tahmininde bitki spektral özelliklerinin başarısının ortaya konulması amaçlanmıştır. Elde edilen bulgular sonucunda, spektral ölçümlerden hesaplanan TGI (Üçgen Yeşillik İndeksi), VARI (Görünür Atmosferik Dayanıklılık İndeksi), GRVI (Yeşil Kırmızı Bitki Örtüsü İndeksi), HNDVI (Hiperspektral Normalize Edilmiş Fark Bitki İndeksi), CIG (Klorofil indeksi – Yeşil) ve LCI (Yaprak Klorofil İndeksi) bağımsız değişkenleri ile klorofil (SPAD) bağımlı değişkeninin tahmin edilmesinde önemli başarılarla ulaşılmıştır. Satsuma mandarininde her bir ay için gerçekleştirilen tahmin modelleri içerisinde ise hem en yüksek R^2 değerini (RMSE: 1.88; MAPE: 4.06) veren, hem de SPAD bağımlı değişkenini en iyi tahmin eden dönemin aynı zamanda çiçeklenme ve meyve tutum dönemine denk gelen Mayıs ayı olduğu sonucuna varılmıştır. Mayıs ayı

modelinin, SPAD bağımlı değişkenini %83.57 oranında 2 faktörle en yüksek başarıyı sağladığı ve R^2 değerinin 0.84 ile en yüksek doğruluğa ulaştığı belirlenmiştir.

ANAHTAR KELİMELEER: Klorofil, Makine öğrenmesi, Satsuma Mandarin, SPAD, Uzaktan Algılama

JÜRİ: Prof. Dr. Sahriye SÖNMEZ

Doç. Dr. İlker ÜNAL

Dr. Öğr. Üyesi Gülçin Ece ASLAN



ABSTRACT

MODELING SEASONAL CHLOROPHYLL CHANGE IN SATSUMA MANDARIN USING HYPERSPECTRAL DATA WITH PARTIAL LEAST SQUARES REGRESSION (PLSR) MACHINE LEARNING ALGORITHM

Dilara AYDUS SARI

MSc Thesis in Remote Sensing and Geographic Information Systems Department

Supervisor: Prof. Dr. Sahriye SÖNMEZ

II. Supervisor: Assist. Prof. Dr. Mesut ÇOŞLU

January 2025; 69 pages

In recent years, many concepts such as sustainable agriculture and precision agriculture have emerged in every aspect of our lives. Agricultural practices that are ecological, economical and provide savings in every aspect are preferred. Working models created with remote sensing and computer science also enable fast and non-destructive production processes in the field of agriculture. Protecting plant health throughout the production season is an important criterion for all agricultural inputs. For this reason, chlorophyll content, which is one of the important indicators of plant health, is also seen as a basic parameter in research. In remote sensing studies; In spectral reflectance values, being sensitive close to 700 nm and in the range of 530-630 nm guides the interpretation of chlorophyll content and therefore plant health and the execution of agricultural activities. Machine learning algorithms, which have increased their popularity in recent years, provide significant advantages in analyzing intensive data sets quickly and reliably and creating prediction models. As a matter of fact, it is possible to train different models using various machine learning algorithms and to make current and future predictions of an important parameter for plants such as chlorophyll. One of these machine learning algorithms is partial least squares regression (PLSR) method. In this study, hyperspectral reflectance measurements were performed with ASD FieldSpec Handheld Spectroradiometer and chlorophyll measurements were performed with SPAD-502Plus chlorophyll measurement device on leaf samples taken every month for 12 months from Satsuma mandarin orchard trees produced in Antalya province. The aim of the study was to determine the reflectance and chlorophyll relationship statistically by periodically questioning the spectral properties of the plant based on remote sensing and to reveal the success of plant spectral properties in chlorophyll estimation with PLSR method. As a result of the findings, significant success was achieved in estimating the dependent variable of chlorophyll (SPAD) with the independent variables of TGI (Triangular Greenness Index), VARI (Visible Atmospheric Resistant Index), GRVI (Green Red Vegetation Index), HNDVI (Hyperspectral Normalized Difference Vegetation Index), CIG (Chlorophyll Index – Green) and LCI (Leaf Chlorophyll Index) calculated from spectral measurements. Among the estimation models performed for each month in Satsuma mandarin, it was concluded that the period that gave the highest R^2 value (RMSE: 1.88; MAPE: 4.06) and best predicted the dependent variable of SPAD was May, which also coincides with the flowering and fruit set period. It was determined

that the May model provided the highest success in the dependent variable of SPAD by a factor of 2 at a rate of 83.57% and the highest accuracy was reached with an R^2 value of 0.84.

KEYWORDS: Chlorophyll, Machine learning, Satsuma Mandarin, SPAD, Remote Sensing

COMMITTEE: Prof. Dr. Sahriye SÖNMEZ

Assoc. Prof. Dr. İlker ÜNAL

Assist. Prof. Dr. Gülçin Ece ASLAN



ÖNSÖZ

Son yıllarda sürdürülebilir tarım, hassas tarım gibi birçok kavram hayatımızın her alanında karşımıza çıkmaktadır. Ekolojik, ekonomik ve her açıdan tasarruf sağlayan tarım uygulamaları tercih edilmektedir. Uzaktan algılama ve bilgisayar bilimi ile oluşturulan çalışma modelleri de tarım alanında hızlı ve tahribatsız üretim sürecine olanak sağlamaktadır. Üretim sezonu boyunca bitki sağlığını korumak tüm tarım girdileri için önemli bir kriterdir. Bitki sağlığının önemli göstergelerinden biri olan klorofil içeriği de bu sebeple araştırmalarda temel parametre olarak görülmektedir. Uzaktan algılama çalışmalarında; spektral yansıma değerlerinde, 700 nm'ye yakın ve 530-630 nm aralığında duyarlı olması klorofil içeriğinin dolayısıyla bitki sağlığının yorumlanmasına ve tarımsal faaliyetlerin yürütülmesine rehberlik etmektedir. Son yıllarda popülerliğini artıran makine öğrenmesi algoritmaları, yoğun veri setlerinin hızlı ve güvenilir bir şekilde analiz edilmesinde ve tahmin modellerinin oluşturulmasında önemli avantajlar sağlamaktadır. Nitekim çeşitli makine öğrenmesi algoritmaları kullanılarak farklı modellerin eğitilmesi, klorofil gibi bitki için önemli bir parametrenin mevcut ve gelecek tahminlerinin yapılması mümkün olabilmektedir. Makine öğrenme algoritmalarından birisi de en küçük kareler regresyonu (PLSR) yöntemidir. En Küçük Kareler Regresyonu (PLSR), çok boyutlu ve karmaşık veri setlerinde bağımsız ve bağımlı değişkenler arasındaki ilişkileri ortaya koymak için etkili bir yöntemdir. Yaprak spektral verileri üzerinde yapılan analizlerde, PLSR'nin verilerdeki gereksiz etkileri azaltılarak klorofil tahmininde diğer modellere kıyasla daha iyi bir performans sergilediği görülmektedir. Yüksek doğruluk ve genelleme kapasitesi sayesinde, yaprak klorofil tahmini için en etkili model olarak PLSR öne çıkmaktadır.

Yürütülen çalışma satsuma mandarininin on iki ay boyunca spektral yansımalarını ve klorofil içeriğinin ölçümünü kapsamaktadır. Her ay için spektral yansıma indeksleri oluşturularak klorofil tahmin modellerinin başarı oranları ortaya konulmaya çalışılmıştır. Literatür taraması yapıldığında klorofil içeriğinin tahmini için farklı makine öğrenmesi algoritmaları kullanıldığı ve bitkilerin belirli dönemlerinde değerlendirilmelerin yapıldığı görülmektedir. Farklı türlerde ve farklı amaçlarla yapılan bu çalışmalarda modellerin başarı doğruluk oranlarının da değişiklik gösterdiği belirlenmiştir. Satsuma mandarininde makine öğrenme algoritmalarından birisi olan en küçük kareler regresyonu (PLSR) yöntemi kullanılarak klorofil tahmininde bitki spektral özelliklerinin başarısının ortaya konulması amaçlanmıştır.

Yüksek lisans eğitim ve tez süresince bilgi ve birikimini benden esirgemeyen en başta danışman hocam Prof. Dr. Sahriye SÖNMEZ olmak üzere, Prof. Dr. Namık Kemal SÖNMEZ ve Dr. Öğretim Üyesi Mesut ÇOŞLU hocalarıma en içten teşekkürlerimi sunarım.

Lisansüstü eğitim sürecimi maddi ve manevi anlamda her zaman destekleyen eşim Arif SARI ve tüm aile üyelerime sonsuz teşekkürlerimi ve sevgilerimi sunarım.

İÇİNDEKİLER

ÖZET	i
ABSTRACT	iii
ÖNSÖZ	v
AKADEMİK BEYAN	viii
SİMGELER VE KISALTMALAR	ix
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xiv
1. GİRİŞ	1
2. KAYNAK TARAMASI	5
3. MATERYAL VE METOT	13
3.1. Materyal	13
3.1.1. Çalışma alanı	13
3.1.2. Kullanılan donanımlar	14
3.2. Metot	16
3.2.1. Yaprak örneklerinin alınması	16
3.2.2. Spektrometre ölçümleri ve indekslerin hesaplanması	18
3.2.3. Klorofilmetre ölçümleri	20
3.2.4. İstatistiksel analizler	21
3.2.5. Klorofil tahmin modeli	21
4. BULGULAR VE TARTIŞMA	23
4.1. Hiperspektral Veriler	23
4.2. Klorofil Ölçümleri ve Elde Edilen Verilerden Hesaplanan Bitki İndeksleri	26
4.3. İstatistiksel Analizler	28
4.3.1. Nisan ayına ait istatistiksel analizler	29
4.3.2. Mayıs ayına ait istatistiksel analizler	31
4.3.3. Haziran ayına ait istatistiksel analizler	33
4.3.4. Temmuz ayına ait istatistiksel analizler	36
4.3.5. Ağustos ayına ait istatistiksel analizler	38
4.3.6. Eylül ayına ait istatistiksel analizler	40
4.3.7. Ekim ayına ait istatistiksel analizler	42
4.3.8. Kasım ayına ait istatistiksel analizler	44

4.3.9. Aralık ayına ait istatistiksel analizler.....	46
4.3.10. Ocak ayına ait istatistiksel analizler	48
4.3.11. Şubat ayına ait istatistiksel analizler	51
4.3.12. Mart ayına ait istatistiksel analizler	53
4.4. Klorofil Tahmin Modelleri	55
5. SONUÇLAR.....	61
6. KAYNAKLAR	64
ÖZGEÇMİŞ	



AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Hiperspektral Veriler Kullanılarak Satsuma Mandarininde Mevsimsel Klorofil Değişiminin Kısmi En Küçük Kareler Regresyonu (PLSR) Makine Öğrenme Algoritması ile Modellenmesi” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

20/02/2025

Dilara AYDUS SARI

İmzası

(Faint, stylized signature watermark)

SİMGELER VE KISALTMALAR

Simgeler

°	: Derece
'	: Dakika
"	: Saniye
%	: Yüzde
<	: Küçüktür
>	: Büyüktür
≤	: Küçük Eşittir
≥	: Büyük Eşittir
°C	: Derece Celsius
Ca	: Kalsiyum
Cu	: Bakır
Fe	: Demir
ha	: Hektar
K	: Potasyum
m	: Metre
Mg	: Magnezyum
mm	: Milimetre
ms	: Milisaniye
N	: Azot
nm	: Nanometre
P	: Fosfor
R ²	: Belirleme Katsayısı

ρ : Spearman’ın Korelasyon Katsayısı

Zn : Çinko

“21.01” Ondalık Ayırıcı

Kısaltmalar

AÜ : Akdeniz Üniversitesi

BATEM : Batı Akdeniz Tarımsal Araştırma Enstitüsü Müdürlüğü

BPNN : Geri Yayılımlı Sinir Ağı

BRNN : Bayesian Regularization Neural Network

CBS : Coğrafi Bilgi Sistemleri

Chl : Klorofil

CIG : Klorofil indeksi – Yeşil (Chlorophyll Index Green)

CNN : Evrimsel Sinir Ağı

EVI2 : Enhanced Vegetation Index 2

FAO : Birleşmiş Milletler Gıda ve Tarım Örgütü

FLTL : Dört Katmanlı On İki Seviyeli Veri Yönetim Yapısı

GRVI : Yeşil Kırmızı Bitki Örtüsü indeksi (Green-Red Vegetation Index)

HNDVI : Hipspektral Normalize Edilmiş Fark Bitki İndeksi (Hyperspectral NDVI)

IR : Kızılötesi (Infrared)

İHA : İnsansız Hava Aracı

KNNR : K-En Yakın Komşu Regresyonu

LCC : Yaprak Klorofil İçeriği

LCI : Yaprak Klorofil indeksi (Leaf Chlorophyll Index)

LOO : Birini Dışarıda Bırakma

LUT	: Arama Tablosu
MAE	: Ortalama Mutlak Hata
Mak	: Maksimum
MAPE	: Ortalama Mutlak Yüzde Hata
MCARI	: Modified Chlorophyll Absorption Ratio Index
MCC	: Mapir Camera Control
MGM	: Meteoroloji Genel Müdürlüğü
Min	: Minimum
MLR	: Çoklu Lineer Regresyon
MLRA	: Makine Öğrenimi Regresyon Algoritmaları
MSAVI	: Modified Soil Adjusted Vegetation Index
MSE	: Ortalama Karesel Hata
mSR4	: Modified Simple Ratio 4
MTVI2	: Modified Triangular Vegetation Index 2
ND705	: Normalized Difference (705 and 750 nm)
NDVI	: Normalize Edilmiş Fark Bitki İndeksi
NIPALS	: Nonlinear Iterative Partial Least Squares
NIR	: Yakın Kızılötesi
OLI	: Landsat-8 Operasyonel Kara Görüntüleyicisi
Ort	: Ortalama
OSAVI	: Optimized Soil Adjusted Vegetation Index
PLS	: Kısmi En Küçük Kareler
PLSR	: Kısmi En Küçük Kareler Regresyonu
RE	: Kırmızı Kenar

RGB	: Kırmızı-Yeşil-Mavi
RF	: Spektral Yansım
RFR	: Rastgele Orman Regresyonu
RMPRESS	: Kök Ortalama Tahmin Edilen Artık Hata Kareler Toplamı
RMSE	: Kök Ortalama Karesel Hata
RVI	: Ratio Vegetation İndex
SIMPLS	: Statistically Inspired Modification Of The Partial Least Squares
SR4	: Simple Ratio 4
SPAD	: Toprak ve Bitki Analizleri Geliştirme
SVR	: Destek Vektör Regresyonu
TEPGE	: Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Müdürlüğü
TGI	: Üçgen Yeşillik İndeksi (Triangular Greenness Index)
USA	: Amerika Birleşik Devletleri
VARI	: Görünür Atmosferik Dayanıklılık indeksi (Visible Atmospheric Resistant Index)
VI	: Bitki Örtüsü İndeksleri
VIP	: Projeksiyondaki Değişken Önemi
VNIR	: Görünür Yakın Kızılötesi
VOG2	: Vogelmann index 2
VRM	: Verim
YSA	: Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 1.1. Elektromanyetik spektrum ve hiperspektral alan	1
Şekil 1.2. Spektral eğriler ve eğrilerin kaynağa göre farklılıkları	2
Şekil 1.3. Son 5 yıllık turunçgil üretim miktarı (bin ton)	4
Şekil 1.4. Son 5 yıllık turunçgil tüketim miktarı (bin ton)	4
Şekil 3.1. Çalışma alanına ait uydu görüntüleri	13
Şekil 3.2. Laboratuvar ortamında kullanılan donanımlar	15
Şekil 3.3. ASD FieldSpec el tipi spektrometre	15
Şekil 3.4. SPAD-502 Plus klorofil ölçüm cihazı	16
Şekil 3.5. İş Akışı.....	17
Şekil 3.6. Yaprak örnekleme çalışması.....	18
Şekil 3.7. Spektral ölçüm aşaması	18
Şekil 3.8. Ortalama bir yaprağın spektral yansıması	19
Şekil 3.9. Klorofil ölçüm cihazı ile SPAD okuması	21
Şekil 4.1. Satsuma mandarin ağaçlarının spektral yansıtım değişimleri	24
Şekil 4.2. Satsuma mandarin ağaçlarının ortalama yansıtım grafikleri	25
Şekil 4.3. Klorofil ölçümlerindeki aylık değişim.....	27

ÇİZELGELER DİZİNİ

Çizelge 3.1. Yaprak örneklerinin alındığı aylara ait iklimsel veriler.....	14
Çizelge 3.2. Satsuma mandarini ağaçlarının fenolojik dönemleri	14
Çizelge 3.3. Kullanılan bitki indeksleri	20
Çizelge 4.1. Yaprak örneklerinin ortalama klorofil ile bitki indeks değerleri	27
Çizelge 4.3. Nisan 2022 Spearman korelasyon analiz sonuçları	29
Çizelge 4.2. Nisan 2022 tanımlayıcı istatistik değerleri ve histogram grafikleri.....	30
Çizelge 4.4. Mayıs 2022 tanımlayıcı istatistik değerleri ve histogram grafikleri.....	32
Çizelge 4.5. Mayıs 2022 Spearman korelasyon analiz sonuçları.....	33
Çizelge 4.7. Haziran 2022 Spearman korelasyon analiz sonuçları.....	34
Çizelge 4.6. Haziran 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri	35
Çizelge 4.9. Temmuz 2022 Spearman korelasyon analiz sonuçları	36
Çizelge 4.8. Temmuz 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri	37
Çizelge 4.11. Ağustos 2022 Spearman korelasyon analiz sonuçları	38
Çizelge 4.10. Ağustos 2022 tanımlayıcı istatistik değerleri ile histogram dağılımı	39
Çizelge 4.12. Eylül 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri	41
Çizelge 4.13. Eylül 2022 Spearman korelasyon analiz sonuçları.....	42
Çizelge 4.14. Ekim 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri	43
Çizelge 4.15. Ekim 2022 Spearman korelasyon analiz sonuçları.....	44
Çizelge 4.16. Kasım 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri	45
Çizelge 4.17. Kasım 2022 Spearman korelasyon analiz sonuçları	46
Çizelge 4.18. Aralık 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri	47
Çizelge 4.19. Aralık 2022 tarihine ait Spearman korelasyon analiz sonuçları	48
Çizelge 4.21. Ocak 2023 Spearman korelasyon analiz sonuçları	49
Çizelge 4.20. Ocak 2023 tanımlayıcı istatistik değerleri ile histogram grafikleri	50
Çizelge 4.23. Şubat 2023 Spearman korelasyon analiz sonuçları	51
Çizelge 4.22. Şubat 2023 tanımlayıcı istatistik değerleri ile histogram grafikleri.....	52
Çizelge 4.24. Mart 2023 tanımlayıcı istatistik değerleri ile histogram grafikleri.....	54
Çizelge 4.25. Mart 2023 Spearman korelasyon analiz sonuçları.....	55
Çizelge 4.26. Aylara göre Model karşılaştırma özeti	56
Çizelge 4.27. Aylara göre faktör RMPRESS değerleri	57
Çizelge 4.28. Aylara göre değişken önem tablosu.....	58

Çizelge 4.29. Klorofil tahmin modelleri	59
Çizelge 4.30. Model değ�erlendirmesi sonu�ları	60




1. GİRİŞ

İnsanlık, tarih boyunca değişen yaşam standartlarına göre beslenme alışkanlığı geliştirmiştir. Sadece avcılık değil yerleşik hayat ile başlayan düzenli tarım sistemi gıda çeşitliliği sunmuştur. Artan nüfus ise her zaman gıda talebinde artışa neden olmuştur (Khan vd. 2021). Gıda talebini ise sürdürülebilir tarım çalışmaları uzun vadede karşılayabilecektir. Günümüzde azalan tarım toprakları, doğal kaynakların kıtlığı, çevre kirliliği vb. küresel sorunlar bitkisel üretim için giderek artan bir tehdit oluşturmaktadır. Bitkisel üretimin en verimli şekilde gerçekleştirilebilmesi için üretim sürecinin önceden planlanması ve süreç içerisinde takibinin sağlanması büyük önem arz etmektedir. Bu nedenle bitkisel üretimin mevcut kısıtlar içerisinde devamlılığı teknolojik gelişmeler, koruyucu ve geliştirici politikaların geliştirilmesi ile mümkün olabilecektir (Mızırak ve Ceylan 2023).

Tüm dünyayı etkileyen sanayi devrimi ile yenilikçi teknolojiler tarım alanlarını da etkilemiş ve akıllı tarım uygulamalarının başlamasına öncülük etmiştir (Kaya 2019). Bu uygulamalar için temel oluşturan uzaktan algılama, yazılım uygulamaları ve akıllı araçlar gibi güncel teknolojiler tercih edilmektedir.


Uzaktan algılama, hakkında bilgi elde edilmek istenen veri kaynağına herhangi bir fiziksel temas olmadan, donanımlı araçlar ile erişilip veri toplanması ve analiz edilmesidir. Bu işlemler, elektromanyetik spektrumun görünür ve görünür olmayan bölgelerinde yansıma ve soğrulma gibi fiziksel özelliklerin analiz edilmesi yoluyla gerçekleştirilmektedir (Lillesand vd. 2018). Bu sayede, uzaktan algılama sistemleri, çeşitli çevresel ve tarımsal verileri yüksek hassasiyetle elde edebilmekte ve analiz edebilmektedir.

Literatür çalışmaları değerlendirildiğinde, bitkisel üretim çalışmalarında hiperspektral uzaktan algılamanın tercih edilen yöntemler arasında olduğu görülmektedir. Hiperspektral uzaktan algılama ile görünür ışık; yakın, orta ve uzak kızılötesi dar spektral bantlara ayrılarak analiz sağlanmaktadır (Şekil 1.1). Bu yöntem, diğer spektral ölçüm yöntemlerine göre çok daha detaylı ve zengin spektral bilgi elde edilmesini sağlamaktadır (Chutia vd. 2016).



Şekil 1.1. Elektromanyetik spektrum ve hiperspektral alan (Bock vd. 2020)

Elektromanyetik spektrumdaki dalga boylarının yansımaları ve soğrulmaları veri kaynağına ait spektral yansımalar eğrilerinin oluşturulmasını sağlamaktadır (Su-Yin Tan 2017). Veri kaynağının fiziksel ve kimyasal özelliklerine bağlı olarak oluşan bu eğriler; farklı kaynakların sınıflandırılmasına ve takip edilmesine olanak sağlamaktadır (Şekil 1.2).



Şekil 1.2. Spektral eğriler ve eğrilerin kaynağa göre farklılıkları (Shaw ve Burke 2003)

Hiperspektral uzaktan algılama ölçümleri; uydulara entegre edilen donanımlarla yapıldığı gibi arazi veya laboratuvar ortamlarında kullanıma uygun araçlarla da yapılabilmektedir. Bitkisel üretim analizlerinde tercih edilen taşınabilir spektrometreler bu araçlara örnek verilebilir. Spektrometreler ile ölçümler, güneş ya da yapay ışık altında gerçekleştirilebilmekte ve genel olarak fiber optik kablo, spektrometre ve bir bilgisayar ile kullanılmaktadır (Keskin 2007).

Uzaktan algılama yöntemleri ile veri toplama, analiz etme ve yorumlama süreçleri azalmakta ve kolaylaşmaktadır. Ayrıca bilgisayar biliminin günümüzde geldiği nokta bu süreçlerin daha da kolaylaşmasına yardımcı olmaktadır. Öyle ki günlük hayatta bile makine öğrenmesi, yapay zekâ gibi kavramlar oldukça sık duyulmaya başlanmıştır. İnsanların yapacağı işleri otomasyon sistemleri ile makineler yaparken artık insanların yaptığı analiz ve yorumlama aşamaları da bilgisayarlar ile yapılabilmektedir. Eski ve mevcut verilerden makinelerin ilgili programlar ile eğitilmesi, insanlara nazaran daha hızlı tarama, öğrenme ve analiz edebilme yeteneklerini ortaya koymaktadır.

Makine öğrenmesi çalışmaları zamanla izlenen yollara bağlı olarak alt sınıflara ayrılmaktadır. Gözetimli, gözetimsiz ve pekiştirmeli öğrenme olarak sınıflandırılan makine öğrenmesi, öğrenme prensiplerine göre de bu başlıklar altında yeni alt başlıklara ayrılmakta; regresyon, sınıflandırma ve kümeleme analiz türleri sıklıkla tercih edilen çalışma başlıkları olarak karşımıza çıkmaktadır. Makine öğrenmesi yöntemleri yanında insan beyninin çalışma düzeni örnek alınarak geliştirilen yapay sinir ağları teknolojisi de literatürde sık tercih edilen bir yöntem olarak görülmektedir (Sebetci 2023).

Makine öğreniminde temel öneme sahip unsurlardan biri, girdiler ile çıktılar arasındaki ilişkiyi tanımlayan modelin doğru bir şekilde oluşturulmasıdır. Eğer çıktılar, girdilerin ağırlıklı toplamı ile açıklanabiliyorsa, bu ilişkiyi temsil etmek için doğrusal bir model tercih edilmektedir. Farklı makine öğrenimi algoritmalarında ise kullanılan model

türleri, optimize edilen performans kriterleri ve bu optimizasyon sürecindeki parametre ayarlama yöntemleri birbirlerinden ayrılmaktadır. Bununla birlikte, makine öğreniminin temel amacı, yalnızca eğitim verilerini yeniden üretmek değil, eğitimde yer almayan yeni durumlar için doğru tahminlerde bulunabilmektir. Bu bağlamda, bir modelin genelleme yeteneği ve farklı veri kümelerindeki doğruluğu, başarıyı belirleyen kritik faktörlerdir (Alpaydin 2021).

Kısmi En Küçük Kareler Regresyonu (PLSR), çok boyutlu ve karmaşık veri setlerinde bağımsız ve bağımlı değişkenler arasındaki ilişkileri ortaya koymak için etkili bir yöntemdir. Yaprak spektral verileri üzerinde yapılan analizlerde, PLSR'nin verilerdeki gereksiz etkileri azaltılarak klorofil tahmininde diğer modellere kıyasla daha iyi bir performans sergilediği görülmektedir. Yüksek doğruluk ve genelleme kapasitesi sayesinde, yaprak klorofil tahmini için en etkili model olarak PLSR öne çıkmaktadır (Huang vd. 2024). Bu çalışmada da yüksek boyutlu ve sınırlı gözlem sayısına sahip veri setine sahip olmasından dolayı PLSR en uygun yöntem olarak görülmektedir.

Hem uzaktan algılama hem de makine öğrenmesi yöntemlerinin bir arada kullanımının, öncelikli küresel problemler olan gıdanın üretimi, güvenliği ve temininde verim ve zaman kazancına sebep olması beklenmekte ve bu yüzden tarım uygulamaları da dahil pek çok alanda araştırma konusu olarak sık tercih edilmektedir.


Hassas tarım uygulamaları da üzerinde araştırma yapılan alanlardan olup; bu uygulamalarda, hedeflenen az kayıp ve yüksek verim için mahsul takibinin yapılması son derece önemlidir. Mahsullerin takibinde klorofil içeriği; bitkisel üretim döneminde hem bitki gelişimi hem verim hem de çevresel koşulları yorumlamada önemli bir parametre olarak karşımıza çıkmaktadır (Singhal vd. 2019). Çünkü klorofil pigmentleri bitki gelişim sürecinde yaşanan olumsuzluklardan (stres koşullarından) hızlı etkilenmektedir (Başayığıt ve Ersan 2014). Klorofil pigmentlerinin ölçümünde hiperspektral uzaktan algılama sıklıkla kullanılmaktadır (Bannari vd. 2007).

Bitkisel üretimde kullanıma uygun birçok yersel ölçüm araçları mevcuttur. Yersel ölçüm araçları içerisinde yaprakların klorofil miktarını belirlemek için SPAD502 tercih edilebilmektedir. SPAD502, iki farklı dalga boyundaki ışığın yaprak tarafından ne kadar emildiğini ölçmekte ve bunu bir SPAD değeri olarak sunmaktadır (Anonim 1 2022). Böylece ölçümler sırasında tahribat oluşturulmazken, laboratuvar ölçümlerinde geçen süreden de tasarruf sağlanmaktadır.


İnsan sağlığı için faydalı ve sürdürülebilir bitkisel üretim, tüm bu gelişmeler göz önünde bulundurularak planlanmalı, mevcut üretim yöntemleri ve süreçleri güncellenmelidir. Bu amaçla bu çalışmada, özellikle aroması ve insan sağlığına faydalı vitamin içeriği ile tercih edilen, turunçgiller ailesinden olan Satsuma mandarini araştırma konusu olarak seçilmiştir.

FAO verileri incelendiğinde: 2021 yılı dünya turunçgil üretim alanının 8.7 milyon ha olduğu ve bu toplam üretim alanının %45'ini portakalın, %36'sını mandarinin, %15'ini limonun ve %4'ünü greyfurtun oluşturduğu görülmektedir. Dünya çapında en çok turunçgil ihracatı yapan ülkeler arasında yer alan Türkiye'nin ise turunçgil üretim alanının 2021 verilerine göre 166 bin ha olduğu tespit edilmiştir. Turunçgillere ait Ürün Raporu incelendiğinde: son 5 yıl içerisinde dünya çapında turunçgil üretiminin %2'lik

azalma gösterdiği ancak bu pay içerisinde mandarinin %12’lik artış gösterdiği saptanmıştır. Dünyada son 5 yıl içerisinde gerçekleştirilen turunçgil üretim miktarı Şekil 1.3’te, turunçgil tüketim miktarları ise Şekil 1.4.’de verilmiştir (Anonim 2 2023).



Şekil 1.3. Son 5 yıllık turunçgil üretim miktarı (bin ton) (Anonim 2 2023)



Şekil 1.4. Son 5 yıllık turunçgil tüketim miktarı (bin ton) (Anonim 2 2023)

Hem üretim hem de tüketimde artış gösteren mandarin çeşidinin, üretim alanlarının artması da dikkat çekmektedir. Yine Turunçgiller 2023 raporuna göre 2022 Türkiye verilerinde üretilen mandarin çeşitlerinin %46’sını 855 bin ton üretim miktarı ile Satsuma mandarininin oluşturduğu görülmektedir (Anonim 2 2023). Ülkemizde Satsuma mandarinini adıyla bilinen Owari çeşidi ilk defa Japonya’dan Batum yolu ile Doğu Karadeniz Bölgesine gelmiş ve buradan Ege Bölgesi ve diğer bölgelere yayılmıştır. Verimli, depolamaya ve taşımaya elverişli, soğuğa dayanıklı bir çeşit olan Satsuma mandarinin meyveleri; aromalı, yüksek kaliteli ve çekirdeksizdir (Turgutoğlu 2023). Aynı zamanda ticari öneme sahip turunçgil çeşitleri arasında yer almaktadır (Saraçoğlu vd. 2010).

Bu çalışmada; Antalya ilinde belirlenen Satsuma mandarin bahçesinin ağaçlarından 12 ay boyunca her ay alınan yaprak örneklerinde spektral yansıma ve klorofil değerleri ile makine öğrenmesi algoritmalarından biri olan PLSR (Kısmi En Küçük Kareler Regresyonu) kullanılarak klorofil içeriğinin tahmininde en başarılı modelin ortaya konulması amaçlanmıştır. Bu sayede hem Satsuma mandarin bahçesi ağaçları yapraklarının klorofil tahmininin tahribatsız, doğru ve hızlı bir şekilde yapılabilirliği ortaya konulmuş hem de mevsimsel üretim sezonu boyunca takip edilebilirliği kolaylaşmış olacaktır.

2. KAYNAK TARAMASI

Teknoloji geliřtikçe bitkisel üretim süreci yönetimi de deęiřmektedir. Uzaktan algılama ile önemi kanıtlanmış olan hassas ve akıllı tarım olarak adlandırılan uygulamalar, üretim girdilerinin verimli yönetimi için güvenilir araçlardır (Singhal vd. 2019). Uzaktan algılama ve bilgisayar bilimi temelli çalışma modelleri, bitkisel üretim alanlarında hızlı, güvenilir ve tahribatsız analizlere olanak tanıyarak üretim süreçlerinin planlanmasını, izlenmesini ve yönetimini kolaylařtırmaktadır. Bu sistemler, girdi maliyetlerinin optimize edilmesi ve verimliliğin artırılması açısından modern tarım için kritik bir araç haline gelmiştir.

Son yıllarda artan gıda talebi ve yoğun bitkisel uygulamalar; çevre kirlilięi, doęal kaynakların azalması ve biyolojik çeřitlilik kaybı gibi sorunları beraberinde getirmiřtir. Bu durumlara karřılık sürdürülebilir tarım anlayıřı kapsamında, çevreye zarar vermeden üretim saęlama, gıda güvenilirliğini artırma ve doęal kaynakları koruma hedeflenmektedir. Bu bağlamda, uzaktan algılama ve coęrafi bilgi sistemleri gibi modern teknolojilerin entegrasyonu hassas tarım uygulamalarında verimlilięi artırmada önemli bir rol oynamaktadır (Tařdemir vd. 2023).

Uydu, hava ve kara tabanlı platformlardan elde edilen yansıma verileri, bitkisel üretimde ürün yönetimini optimize etmek ve çevresel sürdürülebilirlięi desteklemek için kullanılmaktadır. Spektral analiz, hiperspektral görüntüleme ve termal sensörler gibi uzaktan algılama yöntemleri; bitki saęlığı, ürün verimi tahmini ve toprak özelliklerinin deęerlendirilmesi gibi kritik süreçlerde önem arz etmektedir. Çok zamanlı veri analizleri, farklı büyüme dönemlerinde ürünlerin durumunu izlemeye olanak saęlarken, coęrafi bilgi sistemleri ve yapay zekâ destekli yaklařımlar, uzaktan algılama verilerinin entegrasyonunu ve yorumlanmasını daha etkin hale getirerek tarımsal verimlilięi artırma ve kaynak kullanımını optimize etme yönünde önemli katkılar sunmaktadır (Wójtowicz vd. 2016).

Son yıllarda, gözlem teknolojilerindeki hızlı ilerlemeler ve uzaktan algılama çalışmaları büyük verilerinin artışıını saęlarken, bu verilerin etkili işlenmesi ve analizi konusunda önemli zorluklar yaratmıştır. Derin öğrenmeye dayalı algoritmaların uzaktan algılama çalışmalarında kullanımı da bu alanda yeni fırsatlar sunmuş; geometrik ve radyometrik işleme, bulut maskeleme, veri birleřtirme, nesne tespiti, arazi kullanımı/örtü sınıflandırması, deęişim tespiti ve çok zamanlı analiz gibi çeřitli uygulamalarda kullanımına imkân saęlamıştır (Zhang vd. 2021). Bu gelişmeler, tarımsal uzaktan algılamanın uydu platformları, insansız hava araçları ve kara tabanlı sensörlerden elde edilen verilerle bitkisel üretimi optimize eden kritik bir teknoloji olarak önemini artırmıştır. Huang vd. (2018) yapmış oldukları çalışmada; büyük verinin avantajlarından yararlanan ve sahaya özgü yönetim uygulamalarını destekleyen dört katmanlı on iki seviyeli (FLTL) veri yönetim yapısı ile yerel ve bölgesel tarımsal uygulamalarda veri entegrasyonu ve yönetimini kolaylařtıracak, gelecekteki hassas tarım uygulamaları için bir çerçeve sunmuşlardır.

Veri analizinde farklı bir çalışma gerçekleřtiren Kganyago vd. (2024), çalışmalarında tarımda biyofiziksel ve biyokimyasal parametrelerin izlenmesi için makine öğrenimi tabanlı yaklařımların potansiyelini vurgulamışlardır. Buna göre, Sentinel-2 ve SuperDove gibi yüksek çözünürlüklü sensörlerden elde edilen veriler ile

makine öğrenimi regresyon algoritmalarını (MLRA) ve hibrit modellerini birleştirerek tarımsal stres parametrelerinin doğru ve zamanında izlenmesinin sağlanabilirliğini ortaya koymuşlardır. Özellikle kırmızı kenar bantları ve Radyasyon Transfer Modelleri (RTM) ile desteklenen makine öğrenimi modellerinin, hassas tarımsal kararlara katkıda bulunabileceğini ancak, veri kıtlığının ve bölgesel uyum eksikliğinin modellerin performansını sınırlandırdığı da bildirmişlerdir.

Uzaktan algılama teknolojilerinin etkin kullanımı için doğru ve etkili parametrelerle çalışmak büyük önem taşımaktadır. Toplanan verilerin analiz edilmesi ve yorumlanması aşamasında parametreler arasındaki ilişkilerin doğru bir şekilde kurulması, karar verme süreçlerinin başarısını doğrudan etkilemektedir. Özellikle bitkisel üretimde, bitkilerin sağlık durumu ve büyüme koşullarını anlamaya yardımcı olan klorofil içeriği gibi parametreler, ürün gelişiminin izlenmesi, zamanında müdahale ve üretim planlamasında stratejik bir rol üstlenmektedir. Bu parametrelerin doğru ve hassas bir şekilde tespit edilmesi, tarımsal süreçlerin verimli yönetimi ve sürdürülebilir tarım uygulamalarının desteklenmesi açısından büyük önem taşımaktadır.

Klorofil; bitkiler, algler ve siyanobakterilerde bulunan ve fotosentez için hayati öneme sahip bir pigment olup özellikle kırmızı ve mavi dalga boylarındaki ışığı emip yeşil ışığı yansıtarak bitkilere yeşil rengini vermektedir. Klorofil, emilen bu ışık enerjisini kimyasal enerjiye dönüştürerek fotosentezin temel reaksiyonlarını gerçekleştirmektedir (Masaló ve Oca 2020). Bitkisel üretimin akıllı tarım sistemleriyle yönetilebilmesi, klorofil gibi bitki sağlığına dair önemli göstergelerin düzenli ve takip edilebilir bir şekilde izlenmesi ile mümkün olabilmektedir. Klorofil seviyeleri, bitkilerin azot durumu, fotosentetik aktivitesi ve genel sağlığı ile doğrudan ilişkilidir. Bu nedenle, klorofil verilerinin tarım sistemleriyle entegre edilmesi, bitki sağlığına dair karar destek süreçlerini optimize edilmesini sağlamakta ve üretimin verimliliğini artırabilmektedir.

Demiralay vd. (2019), sapsız meşe (*Quercus petraea*) yapraklarında klorofil içeriğini tahmin etmek için SPAD-502Plus ve CCM-300 klorofil ölçüm cihazlarını, geleneksel %80 aseton ekstraksiyon yöntemi ile karşılaştırmışlardır. Sonuçlara göre, SPAD-502Plus cihazı birim alan başına klorofil içeriği tahmininde daha yüksek doğruluk ($R^2=0.94$) göstermiştir. CCM-300 ise küçük ve düzensiz yapraklı bitkiler için avantaj sağlamıştır. Çalışmada, tahminleme süreçlerinde bitki türüne bağlı olarak daha doğru sonuçların alınabileceği vurgulanmıştır. Masaló ve Oca (2020) ise yeşil deniz yosunu *Ulva Ohnoi*'nin klorofil ölçümü için farklı bir optik ölçüm cihazı modeli olan MC-100'ü kullanarak ölçümlerde yüksek doğruluk elde etmişlerdir. Bu yöntemin klorofil içeriğini hızlı ve tahribatsız bir şekilde ölçtüğü ve çevresel atık üretimini azalttığı sonucuna da dikkat çekmişlerdir.

Jiang vd. (2017) domates yaprakları üzerinde gerçekleştirdikleri çalışmada, SPAD-520 değeri ile klorofil içeriği arasında anlamlı bir ilişki tespit etmişlerdir. Ancak bu ilişkinin, büyüme aşamalarına bağlı olarak farklılık gösterdiğini de gözlemlemişlerdir. Bu durumun, klorofil içeriğinin doğru bir şekilde tahmin edilmesi için büyüme evresine uygun şekilde optimize edilmiş model seçimlerinin önemini ortaya koyduğunu ifade etmişlerdir.

Atar vd. (2020) büyüme periyodunun başlangıcında (20 Mayıs 2019) ve sonunda (15 Ekim 2019) yerli ve yabancı ağaç ve çalı türlerini içeren toplam 20 tür üzerinde

klorofil ölçümü gerçekleştirmişlerdir. Sonuçlar, birçok türde, dönemler arası anlamlı farklar ($p<0.05$) olduğunu, ayrıca her iki dönemde türler arasında %99 güven aralığında farklılık bulunduğunu göstermiştir. Çalışma, farklı türlerin klorofil içeriğindeki değişimleri ortaya koyarak bitki türleri arasındaki fizyolojik farklılıkların altını çizmiştir. Çalışma; türler arasındaki farklılıkların ve fenolojik dönemlerin klorofil ölçümünü önemli ölçüde etkilediğini ortaya koymuştur.

Sönmez (2003) farklı yaş gruplarına ayrılmış Washington Navel portakal ağaçlarından alınan yaprak örneklerinde toplam klorofil içerikleri ile kanopi yansımaları arasındaki ilişkilerden faydalanarak, bitkilerdeki biyokimyasal değişimlerin ve kanopi özelliklerinin uzaktan algılama teknikleri ile belirlenebileceği en uygun büyüme ve gelişim dönemini belirlemeyi amaçlayan bir doktora tezi yürütmüştür. Çalışma sonucu mavi ve kırmızı dalga boyu bölgelerinde, meyve tutum döneminin tüm bahçelerde toplam klorofil miktarı ile kanopi yansımaları arasında en güçlü istatistiksel ilişkiye sahip olduğunu ortaya koymuştur.

Laboratuvar ortamlarında yapılan toprak ve yaprak analizleri ile üretim alanlarına ait besin içeriği tespit edilebilmekte ve analiz sonuçlarına bağlı üretim süreci planlanabilmektedir (Sönmez vd. 2014). Bitki besin elementlerinin eksikliğinin üretimde yarattığı olumsuz etkilerin ciddi kayıplara sebebiyet verdiği göz önüne alındığında geleneksel analiz yöntemlerine göre uzaktan algılama tekniklerinin tercih edilmesi daha erken ve daha hızlı analizler yapılabilmesine olanak tanımaktadır.

Bitki beslemede makro elementlerden biri olan azot, özellikle bitki sağlığı ve gelişiminin takibinde önemli rol almaktadır. Bu durum yapılan çalışmalarda da azot ile ilgili analiz çalışmalarına sebebiyet vermektedir. Taş (2021), azot ile klorofil içeriği arasındaki ilişkiyi ortaya koymak adına yaptığı çalışmada SPAD ölçümlerini tercih etmiştir. Çalışma sonucunda; R^2 değeri 0.98 ile anlamlı bir ilişkiyi ortaya koymuştur. Jagdeep-Singh ve Varinderpal-Singh (2022)'in; azot ve SPAD ilişkisini analiz eden çalışmalarında; büyüme evrelerinde güçlü ve pozitif korelasyon değerlerinin elde edildiği, gübre planlamasında SPAD ölçümlerinden faydalanmanın önemli bir yardımcı araç olacağı belirtilmiştir.

Gözükara vd. (2019)'nin taşınabilir spektrometre ile yaptıkları çalışmada, özellikle olgunlaşma ve hasat dönemlerinde, üretim alanında herhangi bir tahribat oluşturmadan daha kısa sürede bitki besin içeriklerinin tahmininin yapılabileceği bildirilmiştir. Ayrıca bitkilerin mikro bitki besin elementlerinden olan çinko (Zn), demir (Fe) ve bakır (Cu) içeriklerinin özellikle hasat döneminde yeşil dalga boyunda tahmin edilebilirliğinin mümkün olduğu sonucuna varılmıştır.

Barlas ve İrget (2012) çalışmalarında Satsuma mandarinin üretiminde makro elementlerinin önemini vurgulayarak bu elementlerin meyvelerdeki içeriklerini ortaya koymuşlardır. Temel gübrelemede yer alan azot (N), fosfor (P), potasyum (K), kalsiyum (Ca) ve magnezyum (Mg) elementlerinin üretim sezonu boyunca takibinin son derece önemli olduğunu ifade etmişlerdir. Bu sebeple bitkilere zarar vermeden bitki besin içeriklerinin ortaya konulmasında, laboratuvar ölçümleri ile uzaktan algılama teknikleri arasında ilişkilerin belirlenmesi konularında yapılan çalışmalar büyük önem kazanmaktadır.

Hiperspektral verilerden hesaplanan indekslerin başarı oranlarının belirlenmesi, makine öğrenmesi algoritmaları ile model eğitimi için temel bir adımdır. Çevre kirliliği ve kuraklık gibi günümüzün önemli çevre problemleri, bitkisel üretimi olumsuz yönde etkilemektedir. Bu nedenle geniş tarım alanlarında hızlı, tahribatsız takip ve etkin yönetim, bu tür sorunlarla mücadelede kritik bir rol oynamaktadır. Uzaktan algılama teknolojileri ve makine öğrenmesi yöntemleri, tarımsal alanların izlenmesi ve yönetilmesini mümkün kılmakta, tarımda karar destek sistemlerine entegre edilebilecek hızlı ve verimli çözümler sunmaktadır. Makine öğrenmesi regresyon yaklaşımları, kısa işlem süreleri sayesinde tarım sektöründe önemli bir uygulama potansiyeline sahiptir (Singhal vd. 2019).

Klorofil içeriği ölçümü için tercih edilen uzaktan algılama yöntemleri içinde bulunan hiperspektral ölçümlerin, dar bantlar ile zengin spektral ölçüm imkânı sunması ve bu bantların kombinasyonları ile oluşturulan hiperspektral vejetasyon indeksleri ışık-klorofil ilişkisinin analizinde güçlü sonuçlar vermesi oldukça önem arz etmektedir (Karakoç ve Karabulut 2021). Yapılan çalışmalarda özellikle kırmızı kenar bölgesinde meydana gelen değişimlerin analizi için kullanılan indekslerin klorofil içeriği ile güçlü korelasyon değerleri ($0.70 \leq R^2 \leq 0.81$) verdiği görülmektedir (Haboudane vd. 2008).

Tong ve He (2014) çalışmalarında; analizler için 144 indeks belirlemiş ve içlerinden yaprak düzeyinde en iyi performansı gösteren indekslerin dar bantlı mSR₄ (Değiştirilmiş Basit Oran 4) ve SR₄ (Basit Oran 4) indeksleri olduğunu ortaya koymuşlardır. Aynı çalışmada kırmızı ve kırmızı kenar bölgelerine ait bantlar ile gerçekleştirilecek analizlerin performans değerlendirmelerinin yüksek olduğu, ancak performans başarılarının bölgeye ve üzerinde çalışma yapılacak ürüne göre değişebileceğini bildirmişlerdir.

Shi vd. (2023) çalışmalarında soya fasulyesinin farklı büyüme aşamalarında hiperspektral indeks verileri ve klorofil içeriğini analiz etmiş, en uygun tahmin modelini belirlemeyi amaçlamışlardır. Destek vektör makinesi (SVM), rastgele orman (RF) ve geri yayımlı sinir ağı (BPNN) yöntemlerini kullanarak klorofil tahmin modelleri oluşturmuşlardır. Çalışma, RF yönteminin en yüksek doğruluğu göstermesi ile sonuçlanmıştır. Özellikle, tam bakla evresi olarak sınıflandırdıkları R4 aşaması, klorofil içeriği ile en yüksek korelasyonu ($R^2=0.85$) sağlayan büyüme dönemi olarak belirlenmiştir. Bu çalışma, soya fasulyesi bitkisinin farklı büyüme evrelerinde hiperspektral veriler ve klorofil indekslerinin analizine dayanarak, bitki büyümesinin ve sağlığının izlenmesine yönelik teorik bir çerçeve sunmaktadır.

Altunbas vd. (2018) marul bitkisinin büyüme süreci boyunca spektral yansımaları (RF) ile; klorofil a-b ve besin elementleri içerikleri arasındaki ilişkileri ortaya koymak amacıyla yürütmüş oldukları çalışmada; olgunlaşma döneminde RF ile klorofil a-b, N, Ca, Mg ve Fe arasında yüksek düzeyde istatistiksel bir ilişki olduğunu ortaya koymuşlardır. Ayrıca, olgunlaşma döneminde RF ve NDVI (Normalize Edilmiş Fark Bitki Örtüsü İndeksi) kullanılarak bitki besin elementleri ve klorofil b içeriklerinin daha başarılı bir şekilde tahmin edilebildiğini tespit etmişlerdir. Bu çalışma, spektral yansıma analizlerinin hızlı, düşük maliyetli ve tahribatsız bir yöntem olarak bitkinin fizyolojik durumunun değerlendirilmesinde kritik bir araç olabileceğini göstermiştir.

Changchun vd. (2021) yaptıkları çalışmada, insansız hava araçlarından (İHA) elde edilen hiperspektral verileri kullanarak patatesin farklı büyüme aşamalarındaki klorofil (Chl) içeriğini tahmin etmişlerdir. Kesirli farklılaşma yöntemiyle spektral veriler işlenmiş ve tomurcuklanma, yumru oluşumu, yumru büyümesi ve nişasta birikimi aşamalarında destek vektör makinesi (SVM) modelleri ile Chl içeriği tahmin edilmiştir. Sonuçlar, en yüksek doğruluğun tomurcuklanma evresinde ($R^2 = 0.83$) ve yumru oluşumu evresinde ($R^2 = 0.80$) elde edildiğini göstermiştir. Kesirli farklılaşma, arka plan gürültüsünü azaltarak spektral bilgileri daha etkili bir şekilde ortaya çıkarmış ve hiperspektral verilerin Chl tahminindeki başarısını arttırdığı gözlemlenmiştir.

Demirel vd. (2010) Çanakkale Bölgesi'nde karpuz bitkisi üzerinde klorofil okumaları ve yaprak su içeriği ölçümlerini kullanarak bitkideki su stresinin belirlenmesini amaçlamışlardır. Damla sulama yöntemiyle altı farklı sulama konusu oluşturmuş ve büyüme dönemi çiçeklenme, meyve oluşumu ve olgunlaşma-hasat olmak üzere üç kategoriye ayırmışlardır. Klorofil okumaları ve yaprak su içerikleri, sulama öncesi ve sonrası ölçülerek ANOVA analiziyle değerlendirilmiştir. Çalışma; klorofil okumaları ve yaprak su içeriklerinin, sulama seviyesi düştükçe azaldığını göstermiştir. Belirtme katsayıları (R^2), çiçeklenme döneminde 0.75, meyve oluşumu döneminde 0.81 ve olgunlaşma-hasat döneminde 0.88 olarak bulunmuştur. Sonuçlar, çiçeklenme ve meyve oluşumu dönemlerinde klorofil okumaları ve yaprak su içeriği ölçümlerinin su stresinin belirlenmesinde etkili bir gösterge olduğunu ortaya koymuştur.

Spektral ölçümler, yalnızca bitkilerin farklı fenolojik dönemlerine bağlı olarak değil, aynı zamanda farklı yaş gruplarındaki bitkilerde de belirgin farklılıklar gösterebilmektedir. Bu konuda çalışma gerçekleştiren Sönmez vd. (2008), farklı yaş gruplarındaki Washington Navel portakal ağaçlarının mineral içerikleri ile spektral yansımaları arasındaki ilişkileri analiz etmişlerdir. Özellikle 25 yaşındaki ağaçlarda, spektral ölçümler ile azot, fosfor, magnezyum ve diğer besin maddeleri arasında anlamlı ilişkiler tespit etmişlerdir. Bu yaş grubunda kırmızı bant ve NDVI gibi spektral özellikler, besin içeriklerini belirlemede güçlü göstergeler olarak öne çıkmıştır. Sonuçlar, 25 yaşındaki ağaçların, spektral yansıma ve besin içeriği ilişkilerini doğru bir şekilde temsil etme açısından diğer yaş gruplarından daha üstün olduğunu, dolayısıyla Akdeniz ikliminde bu yaş grubunun uzaktan algılama çalışmaları için ideal olduğunu göstermiştir.

Sibanda vd. (2020) çalışmalarında farklı gübre kombinasyonlarıyla desteklenen otların yaprak klorofil içeriğini incelemişler ve klorofil içeriğinin gübreleme kombinasyonlarına bağlı olarak önemli ölçüde değişiklik gösterdiğini tespit etmişlerdir. Hiperspektral çok bantlı veriler ve bitki örtüsü indekslerinin birlikte kullanımıyla klorofil içeriğini yüksek doğrulukla tahmin etmişlerdir ($R^2=0.91$, $RMSE=4.02 \mu g m^2$). Çalışmalarında belirli dalga boyu oranlarının (ör. $sR 435/835$ nm ve $nDVI 415/735$ nm) klorofil tahmini için temel değişkenler olduğunu belirlemişlerdir. Bu bulgular, gübreleme uygulamalarının etkilerinin değerlendirilmesinde ve çayır yönetimi stratejilerinin geliştirilmesinde dalga boyu oranlarının değerli birer araç olabileceğini ortaya koymuştur.

Uzaktan algılama ve yer ölçümleri ile desteklenen ve eğitilen makine öğrenmesi modelleri tarım çalışmalarını kolaylaştıran önemli programları oluşturmaktadır. Literatürde makine öğrenmesi ile ilgili yapılan çalışmalarda en çok kullanılan algoritmalar Gauss Süreç Regresyonu, Rassal Orman (Shah SH vd. 2019), Kernel-Ridge Regresyonu (Singhal vd. 2019), K En Yakın Komşu, Destek Vektör Makineleri, Naive

Bayes (Altun 2021) çeşitleri olarak karşımıza çıkmaktadır. Farklı amaçlarla ve farklı ürünler ile kullanılan bu algoritmaların başarı oranlarının yüksek olduğu ifade edilmektedir. Ayrıca sınıflandırmada yüksek başarı gösteren derin öğrenme modelleri de son yıllarda yapılan çalışmalarda tercih edilmektedir (Yaman ve Tuncer 2022). Uygun modellerde çalışma, her alandan erişimi sağladığı gibi herkesin de kullanımına uygun çalışma ortamı oluşturmaktadır. Ayrıca spektral özellikler makine öğrenmesi teknikleri ile kullanıldığında, küçük bir alan üzerindeki verilerle eğitilen sistem sayesinde büyük bir alan üzerinde yüksek doğruluklu çalışmaların yapılması mümkün olabilmektedir (Altun 2021).

Wang vd. (2024) multispektral bantların SPAD tahmini üzerindeki potansiyelini keşfetmek amacıyla gerçekleştirdikleri çalışmada bir tahmin modeli geliştirmişlerdir. Kışlık buğday bitkilerinde SPAD değerlerinin hızlı ve doğru bir şekilde tahmini için İHA multispektral görüntülerini ve makine öğrenimi yöntemlerini incelemişlerdir. Bitki örtüsü indeksleri ile SPAD değerleri arasındaki ilişkiyi analiz etmişler ve farklı büyüme aşamaları ile su stres koşulları altında SPAD tahmini için bir destek vektör makinesi (SVM) modeli oluşturmuşlardır. Sonuçlar, normal sulama koşullarında SPAD değerlerinin kuraklık stresi altındaki değerlerden daha yüksek olduğunu ve seçilen indekslerin SPAD tahminiyle önemli ölçüde ilişkili olduğunu göstermiştir. SVM modeli hem normal sulama hem de su kısıtlaması durumlarında yüksek tahmin doğruluğu sağlamış ve bu yöntem, kışlık buğday SPAD değerlerinin etkin bir şekilde tahmini için umut vaat eden bir yaklaşım olarak değerlendirilmiştir.

Singh vd. (2024), buğdayın klorofil içeriğini hızlı, tahribatsız ve düşük maliyetli bir şekilde tahmin etmek amacıyla RGB (Kırmızı-Yeşil-Mavi) tabanlı bitki örtüsü indekslerini kullanarak 16 farklı makine öğrenme modelini test etmişlerdir. En yüksek doğruluğun, $R^2 = 0.71$, $r = 0.84$ ve $RMSE = 2.52$ değerleriyle BRNN (Bayes Düzenlemeli Sinir Ağı) modelinde elde edildiğini belirtmişlerdir. RGB sensörlerinin düşük maliyetli olması, bu modellerin hassas tarım uygulamalarında, drone tabanlı ve mobil tabanlı sistemlerde uygulanabilirliğini artırmaktadır. Çalışmada önerilen indekslerin, sadece klorofil tahmini değil, aynı zamanda besin eksikliği, stres durumları ve bitkinin fizyolojik durumunu izlemek için de etkili olabileceğini ifade etmişlerdir. Sonuç olarak, RGB tabanlı indekslerin makine öğrenimi ile birleştirilerek tüm bitkiler için uygulanabilir bir klorofil tahmin yöntemi olduğunu ve ileri çalışmalar için umut vadettiğini vurgulamışlardır.

Zhang vd. (2022a) yaptıkları çalışmada; RGB, hiperspektral ve floresans görüntüleme tekniklerinin sorgum bitkilerinin klorofil içeriğini tahmin etme potansiyelini incelemişlerdir. NDVI, RVI (Oran Bitki Örtüsü Endeksi) ve MCARI (Değiştirilmiş Klorofil Emilim Oranı Endeksi) gibi hiperspektral indekslerin laboratuvar ölçümleriyle yüksek korelasyon gösterdiğini belirtmişlerdir. Çalışmada, Kısmi En Küçük Kareler Regresyonu (PLSR) modelinin, üç görüntüleme modülünden elde edilen tüm değişkenleri birleştirerek klorofil tahmini performansını önemli ölçüde artırdığını ve $R^2 = 0.90$ ile en iyi performansı sergilediğini ifade etmişlerdir.

Zhou vd. (2024) 530-780 nm dalga boylarında çalışan, çok spektral bir modül ile dijital kamera, kontrol ünitesi ve güneş pili düzeneğini içeren ekonomik ve verimli bir yer tabanlı dijital cihazın tasarımını ve performansını değerlendirmişlerdir. Cihaz, tahribatsız bitki örtüsü izleme ve bitki büyüme dinamiklerinin değerlendirilmesi için

sürekli veri toplama sağlamış ve çok spektral modülün doğruluğu, çeşitli ışık koşullarında ve açık havada yürütülen analizlerle doğrulanmış; %6'nın altında RMSE ve 0.8'e yakın belirleme katsayıları (R^2) elde edilmiştir. Özellikle ND705 gibi kırmızı kenar tabanlı bitki örtüsü indeksleri, yaprak klorofil içeriğini (LCC) tahmin etmede yüksek doğruluk göstermiştir. Ayrıca, cihazdan elde edilen dijital görüntüler ve spektral verilerin entegrasyonu, pirinç zararlıları ve hastalıklarının %95,12 doğrulukla sınıflandırılmasını sağlamıştır. Bu bulgular, cihazın ürün izleme ve tarımsal müdahaleler için uygulanabilir bir çözüm sunduğunu göstermiştir.

Zhou vd. (2020) yaptıkları çalışmada; Landsat-8 Operasyonel Kara Görüntüleyicisi (OLI), Landsat gözlem projesindeki sensör verilerini buğdayın yaprak klorofil içeriğinin tahmininde değerlendirmişlerdir. Çalışmada; bitki örtüsü indeksleri (VI'lar), makine öğrenimi regresyon algoritmaları (MLRA'lar), arama tablosu (LUT) tabanlı inversiyon ve hibrit regresyon yaklaşımlarını kullanarak klorofil içeriği modelleme ve tahminini gerçekleştirmişlerdir. Sonuçlar, özellikle MTVI2 (Değiştirilmiş Üçgen Bitki Örtüsü İndeksi) indeksinin klorofil tahmininde en iyi performansı gösterdiğini ortaya koymuştur. Ayrıca, kırmızı ve yakın kızılötesi (NIR) bantlarından türetilen MSAVI (Değiştirilmiş Toprak Ayarlı Bitki Örtüsü Endeksi), EVI2 (Geliştirilmiş Bitki Örtüsü Endeksi 2) ve OSAVI (Optimize Edilmiş Toprak Ayarlı Bitki Örtüsü Endeksi) gibi diğer bitki örtüsü indekslerle de yüksek doğruluk elde edildiği belirtilmiştir. Genel olarak, çalışmada, Landsat-8 OLI multispektral verilerinin bitki klorofil içeriğinin tahmininde güvenilir ve doğru bir araç olduğu ortaya konularak, bu yöntemin geniş ölçekli tarımsal izleme uygulamalarında da uygulanabilirliği vurgulanmıştır.

Brewer vd. (2022) Güney Afrika'daki küçük çiftçiler için İHA tabanlı multispektral görüntülemenin, mısırın farklı büyüme aşamalarındaki klorofil içeriğini tahmin etme potansiyelini incelemişlerdir. Çalışma sonuçları; Rastgele Orman makine öğrenme algoritması kullanılarak yakın kızılötesi ve kırmızı kenar dalga boylarından türetilen bitki örtüsü indekslerinin, klorofil içeriği tahmininde kritik öneme sahip olduğunu göstermiştir. En yüksek doğruluk, erken vejetatif, geç vejetatif ve erken üreme aşamalarında elde edilirken; dolu fırtınası nedeniyle doğruluğun, orta ve geç üreme dönemlerinde düştüğü belirlenmiştir. Bulgular, İHA'ların mekânsal-zamansal tarım verilerini sağlama kapasitesini vurgulayarak, küçük çiftliklerin yönetim ve karar alma süreçlerinde etkin bir araç olabileceğini ortaya koymuştur.

Yu vd. (2016), hiperspektral görüntüleme ve kısmi en küçük kare regresyon (PLSR) yöntemini kullanarak biber yapraklarındaki klorofil ve SPAD değerlerinin mekânsal dağılımını belirlemişlerdir. Görünür ve yakın kızılötesi bölgeyi (420-1000 nm) kapsayan hiperspektral veriler, bitkinin farklı pozisyonlarından alınan yapraklardan elde edilmiş ve kimyasal analizlerle doğrulanmıştır. Çalışmada; klorofil a, b, toplam klorofil (a+b) ve SPAD tahmini için etkili dalga boyları belirlenmiş ve bu dalga boyları ile oluşturulan PLSR modellerinin yüksek doğruluk sağladığı belirlenmiştir (R^2 : 0,74-0,91). Sonuçlar, yaprakların klorofil ve SPAD değerlerinin mekânsal-zamansal dağılımını tespit etmede hiperspektral görüntüleme ile istatistiksel analiz yöntemlerinin analizlerin etkili bir yöntem olduğunu ortaya koymuştur.

Li vd. (2023) tarafından yapılan çalışmada, hiperspektral yansıma verileri kullanılarak narenciye ağaçlarının yaprak klorofil içeriği tahmin edilmiştir. Çalışmada doğrusal regresyon ve rastgele orman regresyonu (RFR), K-en yakın komşu regresyonu

(KNNR) ile destek vektör regresyonu (SVR) gibi makine öğrenimi modelleri karşılaştırılmıştır. RFR modeli, Ekim ve Aralık aylarında 0.83'lük R^2 değeri ile en iyi performansı sergileyerek, sınırlı spektral parametre kullanımıyla mevsimsel ve meteorolojik değişimlere karşı dayanıklılık göstermiştir. Fenolojik değişimlerin klorofil içeriği tahmini üzerindeki etkisi belirgin şekilde gözlemlenmiş ve turuncu ağaçlarının fizyolojik durumunu izlemek için bu yaklaşımın önemli avantajlar sunduğu ortaya konulmuştur. Bu çalışma, hiperspektral verilerle desteklenen makine öğrenimi modellerinin, doğruluk ve verimlilik açısından geleneksel yöntemlere alternatif olarak kullanılabileceğini göstermiştir.

Çoşlu (2023), farklı narenciye ağaçları üzerinde uzaktan algılama teknikleri ve bu tekniklere bağlı modelleri kullanarak verim tahmini yapmayı amaçlamıştır. Sönmez (2003)'in doktora tezinde meyve tutum döneminin yansıma verilerinin değerlendirilmesinde en verimli dönem olduğunu belirtmesi üzerine meyve tutum dönemi bu çalışmada tercih edilmiştir. Çalışma kapsamında model karşılaştırma sonuçlarına göre en yüksek belirleme katsayısı (R^2), Satsuma mandarinine ait deneme alanında ($R^2=0.84$) tespit edilmiştir. Uzaktan algılama tekniklerinin hem yersel ölçümlerle hem de İHA verileriyle birleştirilerek oluşturulan veri setlerinin, verim tahmini modellerinde daha yüksek başarı sağladığını da çalışma sonucunda vurgulamıştır.

Günümüzde iklim değişikliklerinin gerçekleşmesi bitkisel üretimi ciddi derecede etkileyen etmenlerdendir. Sawant vd. (2016) narenciye yetiştiriciliğinde doğal kaynakların yönetilebilirliğini sağlamak için narenciye bahçelerinde mahsul büyüme aşamalarını anlamak ve su gereksinimlerini belirlemek amacıyla, Landsat uydu verilerine dayalı NDVI zaman serisi analizlerini kullanmışlardır. Sonuçlar, Dünya gözlemi (EO) zaman serisi analizlerinin narenciye bahçelerinin coğrafi farklılıklarını ve su ihtiyacını etkili bir şekilde ortaya koyduğunu göstermiştir. Çalışma, kıt su kaynaklarının yönetimi için sulama programlarının tasarlanmasında ve mahsul verimliliğinin artırılmasında önemli katkılar sunmakta olup, ayrıca Sentinel-2 gibi yüksek çözünürlüklü uydu verileri ile gelecekte daha kapsamlı analizlerin yapılmasını önermiştir.

Satsuma mandarinini üzerinde yapılan bitki besleme ve bitki koruma çalışmaları, tahribatsız yöntemlerin kullanımının önemini ortaya koymaktadır (Köseoğlu ve Çolakoğlu 1989; Yoldaş vd. 2011; Korkmaz 2008). Özellikle sezon boyunca bitki sağlığını ve gelişimini izlemeye olanak sağlayacak yöntemler hem tarımsal verimliliği artırmak hem de bitki üzerindeki olası fiziksel zararları en aza indirmek açısından kritik bir role sahiptir. Bu bağlamda, tahribatsız izleme tekniklerinin tercih edilmesi, hassas tarım uygulamalarının etkinliğini artırarak sürdürülebilir üretim hedeflerine katkı sağlayacaktır.


3. MATERYAL VE METOT

3.1. Materyal

Bu bölümde, yüksek lisans tez çalışmasının yürütüldüğü çalışma alanı ve kullanılan donanımlar hakkında bilgi verilmiştir.

3.1.1. Çalışma alanı

Yüksek lisans tez çalışması, 36°55'23" kuzey enlemleri ve 31°00'24" doğu boylamları yer alan, Antalya Batı Akdeniz Tarımsal Araştırma Enstitüsü Müdürlüğü'nün Antalya, Serik ilçesi sınırları içerisinde bulunan meyvecilik bölümünde yürütülmüştür (Şekil 3.1). Farklı narenciye bahçelerini de içeren bu alanda yürütülen çalışma, 1991 yılında dikimi gerçekleştirilen 30 adet Satsuma mandarini bahçesinde gerçekleştirilmiştir.



Şekil 3.1. Çalışma alanına ait uydu görüntüleri

Satsuma mandarini parselinden 12 ay boyunca alınan yaprak örnekleri materyal olarak kullanılmıştır. Satsuma mandarin ağaçlarından yaprak örnekleme çalışmalarının yapıldığı aylara ait iklimsel veriler Çizelge 3.1'de ve Satsuma mandarini ağaçlarının fenolojik dönemleri ile ilgili bilgiler ise Çizelge 3.2'de sunulmuştur.

Çizelge 3.1. Yaprak örneklerinin alındığı aylara ait iklimsel veriler

Aylar	Sıcaklık (°C)			Toplam Yağış (mm)	Ortalama Nem (%)
	Ortalama Sıcaklık	Ortalama en yüksek sıcaklık	Ortalama en düşük sıcaklık		
Nisan 2022	17.5	24.5	10.7	14	68.1
Mayıs 2022	21.9	29.5	15.2	2	61.1
Haziran 2022	26.1	31.78	20.35	9	69.8
Temmuz2022	29.5	37.2	21.4	0	54.2
Ağustos 2022	28.0	32.8	22.9	1	80.4
Eylül 2022	24.21	31.09	17.54	0.6	65.62
Ekim 2022	21.26	29.07	15.18	38.2	64.35
Kasım 2022	16.04	23.36	10.47	78	74.51
Aralık 2022	13.1	19.1	9.0	138	78.7
Ocak 2023	11.2	17.9	6.2	190	80.0
Şubat 2023	9.9	16.1	3.9	16	60.15
Mart 2023	14.16	20.09	9.13	150.4	76.56

Çizelge 3.2. Satsuma mandarini ağaçlarının fenolojik dönemleri

Mart	Sürgün oluşturma
Nisan-Mayıs	Çiçeklenme – Meyve tutumu
Haziran-Temmuz-Ağustos	Meyve gelişimi
Eylül-Ekim sonu	Meyve olgunlaşması
Ekim başı-Kasım-Aralık sonu	Hasat zamanı
Aralık başı-Ocak-Şubat sonu	Kış dinlenmesi

3.1.2. Kullanılan donanımlar

3.1.2.1. Spektrometre

Hiperspektral uzaktan algılama; dar ve yüzlerce spektral aralıktan oluşmasından dolayı, bitkilerin yaşam faaliyetleri ve stres koşulları hakkında veri toplanmasına olanak tanımaktadır (Karakoç ve Karabulut 2022). Hiperspektral ölçümler; spektrometre, fiber optik kablo, bitki probu (Plant Probe), yaprak klipsi (Leaf Clip) ve özel yazılımın kullanımını sağlayan bilgisayardan oluşan donanımlar ile laboratuvar ortamında veya uygun koşullar sağlanarak gerçekleştirilebilmektedir (Şekil 3.2). Sistem, içerisinde yapay

ışınım ile yapraktan yansıyan ışınımı kaydetmekte ve spektral grafiklerin oluşturulmasını sağlamaktadır.



Şekil 3.2. Laboratuvar ortamında kullanılan donanımlar: **a)** Spektroradyometre; **b)** Fiber kablo; **c)** Bitki probu ve yaprak klipsi; **d)** Bilgisayar

Çalışmada kullanılan ASD FieldSpec el tipi spektoradyometre (Analytical Spectral Devices Inc., Boulder, Colorado, USA) (Şekil 3.3), 325-1075 nm dalga boyları arasında ölçüm yapmaktadır. Cihaz, 1.5 nm bant genişliğinde, 3.5 nm çözünürlükte ve 17 ms'ye kadar kısa tarama sürelerine sahip 512 elemanlı bir fotodiyot dizi spektoradyometredir (Artisan 2022).



Şekil 3.3. ASD FieldSpec el tipi spektoradyometre

3.1.2.2. Klorofilmetre

Klorofil içeriği, bitki sağlığını ve besin durumunu belirlemede önemli bir göstergedir. SPAD-502Plus cihazı yaprak tarafından emilen iki farklı dalga boyundaki ışığı ölçerek, bitkinin klorofil içeriğini tahribatsız bir şekilde belirleyen bir SPAD değeri üretir. SPAD değeri klorofil miktarıyla doğru orantılıdır. Su geçirmez olması, 30 değere kadar veri kaydedip ortalama alabilmesi, kablosuz kullanım imkânı cihazın sezon boyunca arazi kullanımına uygun kılmaktadır (Konica Minolta 2024).




Şekil 3.4. SPAD-502 Plus klorofil ölçüm cihazı

3.2. Metot

Satsuma mandarin parselinden alınan yaprak örneklerinin klorofil tahmin modellerinin oluşturulmasında izlenen yöntemler; yaprak örneklerinin alınması, spektrometre ile hiperspektral ölçümler ve indekslerin hesaplanması, klorofilmetre ölçümleri, istatistiksel analizler ve klorofil tahmin modelleri olmak üzere 5 başlıktan oluşmakta olup, iş akışı Şekil 3.5'te gösterilmiştir.

3.2.1. Yaprak örneklerinin alınması

Satsuma mandarin parselinde yer alan toplam 30 ağaç; çiçeklenme, meyve tutumu, meyve gelişimi, olgunlaşma, hasat ve kış dinlenme dönemlerini içeren 12 aylık bir süreç boyunca incelenmiştir. Bu süreçte, her ay düzenli periyotlarla, Chapman (1964)'ün belirttiği gibi her ağacın üst kısmından 5. ve 6. yapraklar seçilmiş ve ağacın dört farklı yönünden yaprak örnekleme gerçekleştirilmiştir (Şekil 3.6). Bu örnekleme yöntemi, tüm ağacın homojen şekilde temsil edilmesi ve analizlerde güvenilir sonuçların elde edilmesi açısından önem taşımaktadır.



Şekil 3.5. İş Akışı



Şekil 3.6. Yaprak örnekleme çalışması

3.2.2. Spektrometre ölçümleri ve indekslerin hesaplanması

Çalışma alanından yaprak örneklemesinin yapılmasının ardından örneklerin bozulmaması için alınan yaprak örnekleri plastik torbalara konularak, buz çantalarının içerisinde laboratuvara taşınmıştır. Laboratuvara getirilen yaprak örneklerinin yüzeylerindeki tozlar temizlenerek hiperspektral ölçümler için hazırlanmıştır.


Spektrometre ile ölçümlerin doğruluğunu sağlamak için ölçüm öncesi beyaz referans (White Reference) ile kalibrasyon yapılmıştır. Ölçüme hazır hale getirilen yaprak örneklerinde; ASD FieldSpec el tipi spektrometre, bitki probu, yaprak klipsi ve RS3 yazılımı kullanılarak hiperspektral ölçümler gerçekleştirilmiştir (Şekil 3.7). Spektral veriler, ViewSpec yazılımı kullanılarak işlenmiş ve grafik ile metin dosyası formatlarında çıktılar elde edilmiştir.



Şekil 3.7. Spektral ölçüm aşaması

Toplanan veriler, 325-1075 nm dalga boyu aralığındaki ölçümleri kapsamaktadır. Ancak veri seti oluşturulurken 350-400 nm arasında değişen spektral bantlar, o bölgedeki önemli sinyal gürültüsü nedeniyle kaldırılmıştır (Shah SH vd. 2019). Klorofil içeriğinin spektral yansıma değerleri için 700 nm'ye yakın ve 530-630 nm aralığının duyarlı olması

da uzaktan algılama ile bu değişimleri takip etmeyi mümkün kılmaktadır (Gitelson ve Merzlyak 1998). Bitkilerin elektromanyetik spektrum üzerindeki farklı dalga boylarına verdiği yansıma tepkileri (Şekil 3.8), klorofil içeriklerinin ve genel sağlık durumlarının belirlenmesi açısından önemlidir. Ayrıca, gruplamalar arasında kesin sınırlar olmadığı belirtilmekle birlikte, elektromanyetik spektrumun mavi (400-500 nm), yeşil (501-570 nm), kırmızı (610-700 nm) ve yakın kızılötesi (701-1075 nm) dalga boyu aralıkları temel alınmıştır. Bu yaklaşım, verilerin daha düzenli bir şekilde değerlendirilmesini sağlamak ve analizlerin daha anlamlı sonuçlar üretmesine olanak tanımaktadır (Campbell ve Wynne 2011).



Şekil 3.8. Ortalama bir yaprağın spektral yansıması (Campbell ve Wynne 2011)

Çalışmada elde edilen hiperspektral verilerden elde edilen ve en yaygın kullanılan bitki indeksleri aşağıda belirtilmiştir. Bu indeksler;

Üçgen Yeşillik indeksi TGI (Üçgen Yeşillik İndeksi), yaprak klorofil içeriğini tahmin etmek için hızlı ve düşük maliyetli bir indeks olması, dijital kameralar gibi ucuz sensörlerle kullanılabilirliği ve teorik olarak PROSPECT ve SAIL model simülasyonlarıyla doğrulanmış olması nedeniyle tercih edilmektedir.

Görünür Atmosferik Dayanıklılık indeksi VARI (Görünür Atmosferik Dayanıklılık İndeksi), atmosferik etkileri azaltarak yeşil, kırmızı ve mavi bantlar arasındaki ilişkileri kullanmasıyla bitki sağlığını doğru şekilde yansıtmaktadır.

Yeşil Kırmızı Bitki Örtüsü indeksi GRVI (Yeşil Kırmızı Bitki Örtüsü İndeksi), Tucker (1979) tarafından ortaya konulan NDVI temelinden türetilmiş ve yeşil bantı dahil ederek fotosentetik aktiviteyi daha hassas ölçmesiyle öne çıkmıştır. Rouse vd. (1973)'nin çalışması NDVI'nin temellerini atmış, Hiperspektral Normalize Edilmiş Fark Bitki indeksi (HNDVI) ise bu yaklaşımı hiperspektral verilerle genişleterek daha yüksek çözünürlükte analizler yapılmasına imkân sağlamıştır.

Klorofil indeksi – Yeşil CIG (Klorofil İndeks – Yeşil), Gitelson vd. (2003) tarafından tanımlanmış ve düşük klorofil seviyelerinde dahi yüksek doğruluk sağlamasıyla dikkat çekmiştir.

Yaprak Klorofil indeksi LCI (Yaprak Klorofil İndeksi) ise Datt (1999) tarafından yaprak klorofil içeriğini değerlendirmek üzere yeşil, kırmızı ve NIR bantlarının kullanımıyla geliştirilmiştir. Bu indeksler, bitki fenolojisini anlamak ve klorofil içeriğini doğru şekilde modellemek için çalışmada kritik bir rol oynamaktadır.

Çizelge 3.3'te çalışmada kullanılan bu bitki indekslerinin formülleri ayrıntılı bir şekilde verilmiş olup, bu indeksler 12 ay boyunca tek tek hesaplanmıştır.

Çizelge 3.3. Kullanılan bitki indeksleri

Bitki İndeksi	Formül	Kaynak
Üçgen Yeşillik İndeksi (TGI)	$Green - (0.39 \times Red) - (0.61 \times Blue)$	Hunt vd. (2011)
Görünür Atmosferik Dayanıklılık İndeksi (VARI)	$\frac{(Green - Red)}{(Green + Red - Blue)}$	Gitelson vd. (2002)
Yeşil Kırmızı Bitki Örtüsü İndeksi (GRVI)	$\frac{(Green - Red)}{(Green + Red)}$	Tucker (1979)
Hiperspektral Normalize Edilmiş Fark Bitki İndeksi (HNDVI)	$\frac{(IR_{900} - Red_{685})}{(IR_{900} + Red_{685})}$	Rouse vd. (1973)
Klorofil İndeks – Yeşil (CIG)	$\frac{(NIR)}{(Green)} - 1$	Gitelson vd. (2003)
Yaprak Klorofil İndeksi (LCI)	$\frac{(NIR - RE)}{(NIR + RE)}$	Datt (1999)
IR: Kızılötesi (Infrared) NIR: Yakın kızılötesi (Near infrared) RE: Kırmızı kenar (Red edge)		

3.2.3. Klorofilmetre ölçümleri

Çalışma alanından toplanan yaprak örneklerinin klorofil ölçümleri SPAD502 klorofilmetre cihazı ile gerçekleştirilmiştir (Şekil 3.9). Ölçüm doğruluğu için klorofil okuma işlemine başlamadan önce cihaz kalibrasyonu yapılmıştır. Her ağaçtan 4 yaprak okuma yapılarak ortalama SPAD değeri alınmıştır.



Şekil 3.9. Klorofil ölçüm cihazı ile SPAD okuması

3.2.4. İstatistiksel analizler

Çalışmada elde edilen verilerin istatistiksel analizleri, JMP istatistik yazılımı kullanılarak gerçekleştirilmiştir. SPAD değerleri ile bitki indeksleri arasında klorofil tahminine yönelik gerçekleştirilen analizler, verilerin temel özelliklerini belirlemek ve sonraki aşamalara temel oluşturmak amacıyla tanımlayıcı istatistiklerin hesaplanmasıyla başlamıştır. Ayrıca, verilerin normal dağılım gösterip göstermediği Shapiro-Wilk testi ile incelenmiştir. Bu yaklaşım, veri yapısının anlaşılması ve doğru analiz yöntemlerinin seçilmesi açısından kritik bir rol oynamıştır. Normal dağılım göstermeyen veriler için Spearman korelasyon analizi ile çalışmalar sürdürülmüştür (Ampatzidis 2019; Myers ve Sirois 2006).

3.2.5. Klorofil tahmin modeli

Kısmi En Küçük Kareler (PLS), özellikle bağımsız değişkenlerin fazla sayıda olduğu ve bu değişkenler arasında yüksek derecede çoklu bağlantı bulunduğu durumlarda, bağımlı değişkenlerin tahmini için tercih edilen bir yöntemdir (Polat ve Günay 2009). Tez çalışmasında elde edilen veriler değerlendirildiğinde, bağımsız değişkenlerin sayısının fazla olması ve verilerin normal dağılım göstermediği istatistiksel analiz sonuçları dikkate alınarak, Kısmi En Küçük Kareler Regresyonu (PLSR; Partial Least Squares Regression) yöntemi tercih edilmiştir.

Modelin performansını değerlendirmek için literatürde yaygın olarak kullanılan model değerlendirme kriterleri (1, 2 ve 3) olan, belirleme katsayısı (R^2), kök ortalama karesel hata (RMSE) ve ortalama mutlak yüzde hata (MAPE) kriterleri kullanılmıştır.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (3)$$

Eşitlikte yer alan n değeri gözlem sayısını, y gerçek değeri, $\hat{y}$ ise tahmin değerini belirtmektedir. R^2 değerinin 1'e yaklaşması modelin güçlü bir uyum sağladığını gösterirken, RMSE ve MAPE değerlerinin sıfıra yaklaşması ise tahminin gerçeğe oldukça yakın olduğunu ifade etmektedir.

4. BULGULAR VE TARTIŞMA


4.1. Hiperspektral Veriler


Çalışma alanındaki Satsuma mandarin ağaçlarından 12 ay boyunca alınan yaprak örneklerinde ASD spektrometresi kullanılarak yaprak klipsi ile 325-1075 nm dalga boyu aralığında yapılan spektral ölçümlerin yansıtım değişimleri Şekil 4.1’de ve ortalama spektral yansıtım grafikleri ise Şekil 4.2’de verilmiştir.





Şekil 4.1. Satsuma mandarin ağaçlarının spektral yansıtım değişimleri; **a)** Nisan 2022; **b)** Mayıs 2022; **c)** Haziran 2022; **d)** Temmuz 2022; **e)** Ağustos 2022; **f)** Eylül 2022; **g)** Ekim 2022; **h)** Kasım 2022; **i)** Aralık 2022; **j)** Ocak 2023; **k)** Şubat 2023; **l)** Mart 2023





Şekil 4.2. Satsuma mandarin ağaçlarının ortalama yansıtım grafikleri; **a)** Nisan 2022; **b)** Mayıs 2022; **c)** Haziran 2022; **d)** Temmuz 2022; **e)** Ağustos 2022; **f)** Eylül 2022; **g)** Ekim 2022; **h)** Kasım 2022; **i)** Aralık 2022; **j)** Ocak 2023; **k)** Şubat 2023; **l)** Mart 2023


Şekil 4.1 ve Şekil 4.2 incelendiğinde, spektrumun görünür bölgesinde yeşil dalga boyundaki yansımanın en yüksek değere Nisan ve Mayıs 2022 dönemlerinde ulaştığı görülmektedir. Bu durum, bitkinin çiçeklenme dönemine denk gelmesiyle ilişkilendirilebilir. Ayrıca, çevresel faktörler (örneğin, ışık yoğunluğu, sıcaklık, nem) de spektral yansımayı etkilemekte olup Nisan ve Mayıs aylarında bu koşulların daha elverişli olması yansıma artışına neden olduğunu düşündürmektedir. Şekil 4.1 ve 4.2 incelendiğinde; yeşil dalga boyundaki yansımaların özellikle kış dinlenmesi ve sürgün oluşturma dönemlerinde düşük seviyelerde olduğu görülmektedir. Bu durum, kış dinlenmesi döneminde bitkilerin fotosentetik aktivitenin azalması, sürgün oluşturma döneminde ise oluşan yeni yaprakların henüz yeterince gelişmemiş olmasından dolayı klorofil pigmentlerinin oluşmaya devam etmesinden kaynaklandığını düşündürmektedir.


SPAD klorofil ölçümleri bitkinin büyüme durumu ve sağlığı hakkında önemli bilgiler vermektedir (Parida vd. 2024). Çalışmamızda elde edilen klorofil tahmin sonuçları, literatürdeki bulgularla uyumlu bir şekilde, bitkilerin fenolojik dönemleri ve fizyolojik durumları ile klorofil içerikleri arasında güçlü ilişkiler olduğunu ortaya koymaktadır. Narenciye (Sönmez vd. 2003), marul (Altunbas vd. 2018) ve soya fasulyesi (Shi vd. 2023) gibi farklı bitki türlerinde gerçekleştirilen çalışmalar; genel olarak meyve tutum ve olgunlaşma dönemlerinde klorofil içeriği ile spektral yansıma değerleri arasında

anlamlı ilişkiler olduğunu ortaya koymaktadır.

4.2. Klorofil Ölçümleri ve Elde Edilen Verilerden Hesaplanan Bitki İndeksleri

Çalışma alanındaki Satsuma mandarin ağaçlarından 12 ay boyunca alınan yaprak örneklemelerinde SPAD502 klorofil ölçüm cihazı kullanılarak gerçekleştirilen ölçümlerdeki aylık klorofil değişimleri Şekil 4.3’de; ortalama klorofil değerleri (SPAD değerleri) ve bu değerler ile hesaplanan bitki indeks değerleri (TGI (Üçgen Yeşillik İndeksi), VARI (Görünür Atmosferik Dayanıklılık İndeksi), GRVI (Yeşil Kırmızı Bitki Örtüsü İndeksi), HNDVI (Hiperspektral Normalize Edilmiş Fark Bitki İndeksi), CIG (Klorofil İndeks – Yeşil) ve LCI (Yaprak Klorofil İndeksi)) ise Çizelge 4.1’de verilmiştir.





Şekil 4.3. Klorofil ölçümlerindeki aylık değişim; **a)** Nisan 2022; **b)** Mayıs 2022; **c)** Haziran 2022; **d)** Temmuz 2022; **e)** Ağustos 2022; **f)** Eylül 2022; **g)** Ekim 2022; **h)** Kasım 2022; **i)** Aralık 2022; **j)** Ocak 2023; **k)** Şubat 2023; **l)** Mart 2023

Çizelge 4.1. Yaprak örneklerinin ortalama klorofil ile bitki indeks değerleri

Aylar	Bitki İndeks Değerleri						Klorofil Değeri (SPAD)
	TGI	VARI	GRVI	HNDVI	CIG	LCI	
Nisan 2022	0.064	0.363	0.309	0.900	7.342	0.258	68.103
Mayıs 2022	0.127	0.433	0.395	0.897	4.570	0.219	40.317
Haziran 2022	0.068	0.452	0.335	0.895	6.765	0.257	59.400
Temmuz 2022	0.057	0.297	0.247	0.873	6.556	0.246	59.990
Ağustos 2022	0.056	0.397	0.280	0.884	7.062	0.274	66.273
Eylül 2022	0.056	0.406	0.301	0.906	7.217	0.278	73.643
Ekim 2022	0.059	0.298	0.299	0.910	10.047	0.275	72.980
Kasım 2022	0.045	0.395	0.299	0.921	9.697	0.291	70.720
Aralık 2022	0.027	0.645	0.308	0.906	9.167	0.288	70.433
Ocak 2023	0.045	0.334	0.255	0.898	9.051	0.282	68.427
Şubat 2023	0.033	0.327	0.234	0.916	10.946	0.266	61.297
Mart 2023	0.040	0.188	0.176	0.929	12.245	0.272	59.987

Çizelge 4.1'den de görüldüğü üzere, aylık periyotlara göre ortalama klorofil ölçümleri (SPAD değerleri) en yüksek 73.6 ile Eylül 2022'de, en düşük ise 40.3 ile Mayıs 2022'de elde edilmiştir. Bu sonuçlar, klorofil içeriğinin mevsimsel değişimlere bağlı olarak önemli farklılıklar gösterdiğini ortaya koymaktadır.

TGI (0.127) ve GRVI (0.395) indekslerine ait en yüksek değerler Mayıs 2022 ayında elde edilmiştir. Diğer indekslere ait en yüksek değer ve aylar sırasıyla; VARI 0.645 ile Aralık 2022, HNDVI 0.029 ile Mart 2023, CIG 12.245 ile Mart 2023 ve LCI 0.291 ile Kasım 2022 olarak elde edilmiştir. SPAD değerleri gibi indeks değerleri de mevsimsel değişimlere bağlı olarak farklılıklar göstermiştir.

Yaprak klorofil içeriği ile SPAD değerleri arasında anlamlı bir doğrusal ilişki olduğu yapılan birçok çalışma ile ortaya konulmuştur (Demiralay vd. 2019; Jiang vd. 2017; Liv vd. 2023; Taş 2021; Zhang vd. 2022b). Bu ilişki, SPAD ölçümlerinin bitki sağlığını ve beslenme durumunu değerlendirmek için kullanılabilir bir yöntem olduğunu göstermektedir. Ancak yapılan çalışmalarda farklı tür ve farklı büyüme aşamalarında bu ilişkinin değişiklik gösterebileceği ve tahmin modellerinin her aşamaya özgü optimize edilmesi gerektiği de vurgulanmaktadır (Atar vd. 2020; Demiralay vd. 2019; Jiang vd. 2017).

Bitki indeksleri, yaprak klorofil içeriğini doğru ve düşük maliyetli bir şekilde tahmin etmek için seçilmiştir. TGI ve VARI gibi görünür bölge odaklı indeksler, ucuz sensörlerle kullanılabilirliği ve atmosferik etkileri azaltma kapasitesiyle öne çıkmaktadır (Hunt Jr vd. 2011; Gitelson vd. 2002). GRVI ise görünür bölgeyi (yeşil ve kırmızı bantları) kullanarak fotosentetik aktiviteyi daha hassas şekilde değerlendirmek için geliştirilmiştir (Tucker 1979). Öte yandan, HNDVI, CIG ve LCI gibi multispektral indeksler, geniş bir spektral bant kullanımı (özellikle NIR) sayesinde klorofil tahmininde daha yüksek doğruluk sağlamaktadır (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). Özellikle CIG ve LCI, düşük klorofil seviyelerinde bile doğru sonuçlar vermesiyle dikkat çekmektedir. Bu indeksler, bitki sağlığını ve fenolojisini modellemede etkin ve güvenilir araçlar olarak çalışmada kritik bir rol oynamaktadır.

4.3. İstatiksel Analizler

Satsuma mandarin bahçesinde yürütülen bu çalışmada istatistiksel analizler tanımlayıcı istatistik değerlerinin hesaplanması ve normallik testlerinin gerçekleştirilmesi ile başlatılmıştır. Normallik testleri için veri setine ait çarpıklık ve basıklık katsayıları, Shapiro-Wilk normallik testi sonucu ve histogram grafikleri dikkate alınmıştır.

Elde edilen sonuçların değerlendirilmesinde George (2011) ve George ve Mallery (2019) dikkate alınmıştır. Araştırmacılara göre; çarpıklık ve basıklık katsayılarının -2, +2 aralığında ve Shapiro-Wilk normallik testi sonucunun 0.05'ten büyük olması normal dağılım gösterdiğini ifade etmektedir. Bu değerlendirmelere göre veri setinde normal dağılım standartlarına uymayan değişkenlerin bulunmasından dolayı normallik varsayımı gerektirmeyen Spearman'ın sıralama korelasyon katsayıları hesaplanmıştır. Bu analizler, verilerin dağılımını ve normaliteyi değerlendirmek amacıyla yapılmış olup, elde edilen sonuçlar istatistiksel modellemeler için uygunluklarının belirlenmesine olanak sağlamaktadır. Çalışmada istatistiksel analizler her ay için ayrı ayrı gerçekleştirilmiş ve uygunlukları belirlenmiştir.

4.3.1. Nisan ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Nisan 2022 tarihli ilk ölçümler için histogram grafikleri, tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar Çizelge 4.2'de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.064, VARI için 0.363, GRVI için 0.309, HNDVI için 0.900, CIG için 7.342, LCI için 0.258 ve SPAD için 68.103'tür.

Satsuma mandarini çalışma alanına ait hesaplanan ve Çizelge 4.2'de verilen tanımlayıcı istatistik değerleri ve histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve hafif basık olmak üzere normal dağılım göstermektedir. Çalışmada hesaplanan indeks değerleri incelendiğinde ise; TGI hafif sağa çarpık ve hafif basık dağılım, VARI, GRVI ve HNDVI sola çarpık ve sivri dağılım, CIG hafif sağa çarpık ve sivri dağılım ve LCI hafif sola çarpık ve hafif sivri dağılım gösterdiği tespit edilmiştir. Nisan ayına ait değişken değerlerinin normal dağılım gösterip göstermediği aynı zamanda Shapiro-Wilk testleri ile de kontrol edilmiştir. Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$); bağımlı değişken SPAD değeri 0.600 değeri ile normal dağılım göstermektedir. Bağımsız değişkenler olan TGI, CIG, LCI'nin normal dağılım gösterdiği, VARI, GRVI ve HNDVI'nin ise normal dağılım göstermediği belirlenmiştir.

Bu kapsamda, nisan ayı Satsuma mandarin ağaçlarına ait değerlendirmelerde normal dağılım göstermeyen sonuçların olması sebebi ile parametrik olmayan Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.3'de verilmiştir.

Çizelge 4.3. Nisan 2022 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	0.280	0.340	0.224	-0.341	-0.361	-0.559**
VARI	0.280	1.000	0.966**	0.945**	0.696**	0.686**	0.266
GRVI	0.340	0.966**	1.000	0.956**	0.735**	0.681**	0.314
HNDVI	0.224	0.945**	0.956**	1.000	0.779**	0.798**	0.406*
CIG	-0.341	0.696**	0.735**	0.779**	1.000	0.924**	0.731**
LCI	-0.361	0.686**	0.681**	0.798**	0.924**	1.000	0.776**
SPAD	-0.559**	0.266	0.314	0.406*	0.731**	0.776**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.2. Nisan 2022 tanımlayıcı istatistik değerleri ve histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.049	0.209	0.135	0.743	3.627	0.223	58.400
Mak.	0.084	0.430	0.379	0.947	12.734	0.285	75.400
Ort.	0.064	0.363	0.309	0.900	7.342	0.258	68.103
Standart Sapma	0.010	0.049	0.059	0.045	1.773	0.014	4.429
Değişkenlik Katsayısı (%)	15.277	13.616	19.195	4.951	24.145	5.267	6.504
Çarpıklık	0.239	-2.033*	-1.764	-2.553*	0.572	-0.700	-0.382
Basıklık	-0.842	4.688*	3.260*	6.930*	2.203*	0.679	-0.459
Shapiro-Wilk	0.467	<.0001*	0.0002*	<.0001*	0.195	0.412	0.600
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							

TGI

HNDVI

VARI

CIG

GRVI

LCI

SPAD

Çizelge 4.3 incelendiğinde SPAD klorofil değerlerinin, hiperspektral verilerden hesaplanan indeksler ile genel olarak pozitif yönlü bir ilişkinin olduğu görülmektedir. Sonuçlara göre, SPAD bağımlı değişkeni, TGI indeksi ile güçlü ve negatif yönlü, HNDVI indeksi ile orta düzeyde ve pozitif yönlü, CIG ve LCI indeksleri ile de güçlü ve pozitif yönlü ilişkiler bulunurken aynı zamanda %95 güven düzeyinde ilişkiler gösterdiği tespit edilmiştir. Ayrıca indeks değişkenleri arasında; GRVI ile VARI arasında, HNDVI ile VARI arasında, HNDVI ile GRVI arasında ve LCI ile CIG arasında güçlü ve pozitif yönlü ilişkiler olduğu belirlenmiştir.

Nisan ayına ait bulgulara; TGI bağımsız değişkeninin SPAD bağımlı değişkeni ile yaptığı yüksek korelasyon ilişkisi, klorofil içeriği tahmininde RGB tabanlı indekslerin yüksek ilişkiler gösterdiği yapılan çalışmalar ile uyumlu sonuç vermiştir (Singh vd. 2024; Zhang vd. 2022a). Geniş spektral bant aralığını kullanan CIG ve LCI indeksleri ile SPAD değerleri arasındaki yüksek ilişkiler ise özellikle Gitelson vd. (2003) yaptıkları çalışmada, CIG indeksinin düşük klorofil seviyelerinde bile doğru sonuçlar verdiğine dikkat çekmesi ile paralellik göstermiştir.

4.3.2. Mayıs ayına ait istatistiksel analizler

Satsuma mandarini bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Mayıs 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ve histogram grafikleri Çizelge 4.4'de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.127, VARI için 0.433, GRVI için 0.395, HNDVI için 0.897, CIG için 4.570, LCI için 0.219 ve SPAD için 40.317 olarak belirlenmiştir. Satsuma mandarini çalışma alanına ait hesaplanan ve Çizelge 4.4'de verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve hafif basık olmak üzere normal dağılım göstermektedir. Çalışmada elde edilen hiperspektral ölçümler ile hesaplanan indeks değerleri incelendiğinde ise; TGI hafif sağa çarpık ve sivri dağılım, VARI hafif sağa çarpık ve hafif basık dağılım, GRVI ve CIG hafif sola çarpık ve hafif basık dağılım, HNDVI hafif sola çarpık ve sivri dağılım ve LCI hafif sola çarpık ve hafif sivri dağılım gösterdiği belirlenmiştir. Mayıs ayına ait değişken değerlerinin normal dağılım gösterip göstermediği aynı zamanda Shapiro-Wilk testleri ile de kontrol edilmiştir. Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$) bağımlı ve bağımsız tüm değişkenlerin normal dağılım gösterdiği tespit edilmiştir.

Mayıs ayı için Satsuma mandarinine ait değerlendirmelerde parametrik olmayan Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.5'de verilmiştir.

Çizelge 4.5 incelendiğinde SPAD klorofil değerlerinin, hesaplanan indeksler ile pozitif ve negatif yönlü ilişkiler gösterdiği görülmektedir. SPAD bağımlı değişkenin; TGI indeksi ile güçlü ve negatif yönlü; HNDVI, CIG ve LCI indeksleri ile güçlü ve pozitif yönlü ilişkiler bulunurken aynı zamanda %95 güven düzeyinde ilişkiler gösterdiği tespit edilmiştir. Ayrıca indeks değişkenleri arasında; CIG ile TGI arasında ve LCI ile TGI arasında güçlü ve negatif yönlü ilişkiler olduğu saptanmıştır.

Çizelge 4.4. Mayıs 2022 tanımlayıcı istatistik değerleri ve histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.093	0.378	0.356	0.859	3.082	0.194	29.500
Mak.	0.176	0.501	0.420	0.917	5.586	0.250	48.700
Ort.	0.127	0.433	0.395	0.897	4.570	0.219	40.317
Standart Sapma	0.018	0.034	0.016	0.013	0.685	0.012	4.718
Değişkenlik Katsayısı (%)	14.352	7.854	4.017	1.408	14.983	5.592	11.702
Çarpıklık	0.932	0.388	-0.399	-0.687	-0.476	-0.203	-0.458
Basıklık	1.033	-0.763	-0.044	1.459	-0.392	0.723	-0.416
Shapiro-Wilk	0.074	0.336	0.557	0.255	0.320	0.098	0.365
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							

TGI

HNDVI

VARI

CIG

GRVI

LCI

SPAD

Çizelge 4.5. Mayıs 2022 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.126	-0.310	-0.629**	-0.912**	-0.919**	-0.835**
VARI	-0.126	1.000	-0.113	0.001	-0.094	-0.016	-0.060
GRVI	-0.310	-0.113	1.000	0.467**	0.475**	0.285	0.180
HNDVI	-0.629**	0.001	0.467**	1.000	0.790**	0.660**	0.709**
CIG	-0.912**	-0.094	0.475**	0.790**	1.000	0.878**	0.853**
LCI	-0.919**	-0.016	0.285	0.660**	0.878**	1.000	0.869**
SPAD	-0.835**	-0.060	0.180	0.709**	0.853**	0.869**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Hiperspektral uzaktan algılama, mavi ve kırmızı dalga boylarına olan duyarlılığı sayesinde klorofil ölçümünde etkili bir yöntemdir ve bitki sağlığını izlemek ve tarımsal uygulamaları planlamak için değerli bilgiler sunar (Bannari vd. 2007; Gitelson ve Merzlyak 1998). TGI ve SPAD ilişkisi de RGB tabanlı indekslerin klorofil tahminindeki başarısını vurgulayan önceki araştırmalarla örtüşmektedir (Singh vd. 2024; Zhang vd. 2022a).

HNDVI, CIG ve LCI indeksleri ise NIR bantlarıyla klorofil tahmininde yüksek doğruluk sunar. Özellikle CIG ve LCI, düşük klorofil seviyelerinde bile güvenilir sonuçlar vererek bitki sağlığı değerlendirmesinde önemli bir rol oynar (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). Mayıs ayında elde edilen SPAD ile HNDVI, CIG ve LCI indeksleri arasındaki güçlü ve pozitif yönlü ilişkiler de bu çalışmalarla paralellik göstermiştir.

Klorofil tahmininde değerlendirilebilecek bu indekslerin, bitki sağlığını ve fenolojisini modellemede etkin ve güvenilir araçlar olarak kullanılabileceği düşünülmektedir.

4.3.3. Haziran ayına ait istatistiksel analizler

Satsuma mandarini bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Haziran 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.6'da sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.068, VARI için 0.452, GRVI için 0.335, HNDVI için 0.895, CIG için 6.765, LCI için 0.257 ve SPAD için 59.400'dür. Satsuma mandarini çalışma alanına ait hesaplanan ve Çizelge 4.6'da verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni sağa çarpık ve sivri dağılım göstermektedir. Çalışmada elde edilen hesaplanan indeks değerleri incelendiğinde ise; TGI ve VARI hafif sağa çarpık ve hafif basık dağılım,

GRVI, HNDVI ve CIG hafif sola çarpık ve hafif basık dağılım, LCI'in ise hafif sağa çarpık ve hafif basık dağılım gösterdiği belirlenmiştir.

Haziran ayına ait değişken değerlerinin normal dağılım gösterip göstermediği aynı zamanda Shapiro-Wilk testleri ile de kontrol edilmiştir. Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$); VARI ve SPAD değişkenlerinin normal dağılım göstermediği tespit edilmiştir. Haziran ayı Satsuma mandarin ağaçlarına ait değerlendirmelerde normal dağılım göstermeyen sonuçların olması sebebi ile parametrik olmayan Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.7'de verilmiştir.

Çizelge 4.7. Haziran 2022 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.799**	-0.195	-0.272	-0.654**	-0.899**	-0.542**
VARI	-0.799**	1.000	0.490**	0.234	0.257	0.695**	0.332
GRVI	-0.195	0.490**	1.000	0.647**	0.297	0.364*	0.075
HNDVI	-0.272	0.234	0.647**	1.000	0.666**	0.508**	0.360
CIG	-0.654**	0.257	0.297	0.666**	1.000	0.787**	0.537**
LCI	-0.899**	0.695**	0.364*	0.508**	0.787**	1.000	0.688**
SPAD	-0.542**	0.332	0.075	0.360	0.539**	0.688**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.


**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.7 incelendiğinde SPAD klorofil değerleri ile hesaplanan indeksler arasında genel olarak pozitif yönlü ilişkilerin olduğu görülmektedir. SPAD bağımlı değişkeni, TGI indeksi ile güçlü ve negatif yönlü, CIG ve LCI indeksleri ile güçlü ve pozitif yönlü ilişkiler bulunurken aynı zamanda %95 güven düzeyinde ilişkiler gösterdiği tespit edilmiştir.

SPAD bağımlı değişkeni ile TGI bağımsız değişkeninin arasındaki yüksek ilişkinin gözlenmesi, Singh vd. (2024) ve Zhang vd. (2022a) gibi çalışmalarda klorofil içeriğinin tahmininde RGB tabanlı indekslerin başarı göstermesi örtüşmektedir. Yine düşük klorofil içeriğinde bile başarılı sonuçlar veren ve geniş bir spektral bant kullanımı sayesinde klorofil tahmininde daha yüksek doğruluk sağlamasıyla dikkat çeken CIG ve LCI indeksleri ile SPAD arasındaki yüksek ilişki yapılan çalışmaları desteklemiştir (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999).

Çizelge 4.6. Haziran 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.042	0.346	0.287	0.865	4.886	0.237	54.800
Mak.	0.099	0.649	0.370	0.918	8.359	0.286	67.700
Ort.	0.068	0.452	0.335	0.895	6.765	0.257	59.400
Standart Sapma	0.015	0.086	0.019	0.014	0.926	0.012	3.150
Değişkenlik Katsayısı (%)	22.730	19.058	5.754	1.527	13.685	4.789	5.303
Çarpıklık	0.230	0.635	-0.623	-0.482	-0.182	0.142	1.086
Basıklık	-0.620	-0.718	-0.043	-0.506	-0.815	-0.555	1.317
Shapiro-Wilk	0.386	0.016*	0.166	0.400	0.583	0.447	0.0193*
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							



4.3.4. Temmuz ayına ait istatistiksel analizler

Satsuma mandarinini bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Temmuz 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.8’de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.057, VARI için 0.297, GRVI için 0.247, HNDVI için 0.873, CIG için 6.556, LCI için 0.246 ve SPAD için 59.990’dır.

Satsuma mandarinini çalışma alanına ait hesaplanan ve Çizelge 4.8’de verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni, hafif sola çarpık ve hafif basık dağılım göstermektedir. Çalışmada hesaplanan indeks değerleri incelendiğinde ise; TGI ve CIG’nin hafif sağa çarpık ve sivri dağılım, VARI ve LCI’nin hafif sağa çarpık ve hafif basık dağılım, GRVI’nin hafif sola çarpık ve hafif basık dağılım, HNDVI’nin hafif sağa çarpık ve hafif sivri dağılım gösterdiği belirlenmiştir. Shapiro-Wilk normallik test sonuçlarına göre de ($P>0.05$); CIG değişkeninin normal dağılım göstermediği görülmektedir.

Temmuz ayı Satsuma mandarinine ait değerlendirmelerde normal dağılım göstermeyen sonucun olması sebebi ile parametrik olmayan Spearman’ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.9’da verilmiştir.

Çizelge 4.9 incelendiğinde; SPAD bağımlı değişkeninin, TGI indeksi ile orta düzeyde ve negatif yönlü, CIG ve LCI indeksleri ile güçlü ve pozitif yönlü ilişkiler gösterdiği tespit edilmiştir.

Çizelge 4.9. Temmuz 2022 Spearman korelasyon analiz sonuçları


	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.007	0.195	-0.104	-0.555*	-0.602**	-0.408*
VARI	-0.007	1.000	0.925**	0.734**	0.352	0.366*	-0.052
GRVI	0.195	0.925**	1.000	0.845**	0.400*	0.290	-0.035
HNDVI	-0.104	0.734**	0.845**	1.000	0.774**	0.648**	0.352
CIG	-0.555**	0.352	0.400*	0.774**	1.000	0.842**	0.575**
LCI	-0.602**	0.366*	0.290	0.648**	0.842**	1.000	0.699**
SPAD	-0.408*	-0.052	-0.035	0.352	0.575**	0.699**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.8. Temmuz 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.045	0.213	0.179	0.840	5.200	0.222	50.000
Mak.	0.079	0.386	0.306	0.912	9.697	0.275	70.900
Ort.	0.057	0.297	0.247	0.873	6.556	0.246	59.990
Standart Sapma	0.008	0.045	0.033	0.017	1.009	0.013	4.643
Değişkenlik Katsayısı (%)	13.430	15.007	13.151	1.936	15.383	5.260	7.739
Çarpıklık	0.600	0.306	-0.053	0.160	1.615	0.375	-0.261
Basıklık	1.079	-0.452	-0.104	0.196	3.188*	-0.011	0.510
Shapiro-Wilk	0.189	0.543	0.379	0.695	0.0007*	0.664	0.142
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							



Temmuz ayında CIG ve LCI gibi yakın kızılötesi (NIR) bant kullanımı ile düşük klorofil içeriğinde bile güçlü sonuçlar veren indeksler SPAD ile %95 güven düzeyinde güçlü ilişkiler göstermiştir (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). Buna göre, SPAD ile yüksek ilişki gösteren bu indeksler benzer fenolojik dönemlerde bitki sağlığını izlemede güvenilir araçlar olarak değerlendirilebilir.

4.3.5. Ağustos ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Ağustos 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.10'da sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.056, VARI için 0.397, GRVI için 0.280, HNDVI için 0.884, CIG için 7.062, LCI için 0.274 ve SPAD için 66.273 olarak belirlenmiştir. Çizelge 4.10'da verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve hafif sivri dağılım göstermektedir. İndeks değerleri incelendiğinde ise; TGI'nin hafif sağa çarpık ve hafif basık dağılım, VARI, HNDVI, CIG ve LCI indekslerinin hafif sola çarpık ve hafif basık dağılım, GRVI'in hafif sola çarpık ve hafif sivri dağılım gösterdiği görülmektedir. Ağustos ayına ait değişken değerlerinin normal dağılım gösterip göstermediğini belirlemek için yapılan Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$); bağımlı değişken olan SPAD değerinin normal dağılım göstermediği belirlenmiştir.

Ağustos ayı için Satsuma mandarin ağaçlarına ait değerlendirmelerde parametrik olmayan değerler için Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.11'de verilmiştir.

Çizelge 4.11. Ağustos 2022 Spearman korelasyon analiz sonuçları


	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.307	0.049	-0.276	-0.728**	-0.828**	-0.619**
VARI	-0.307	1.000	0.867**	0.748**	0.548**	0.424*	-0.015
GRVI	0.049	0.867**	1.000	0.859**	0.461*	0.249	-0.108
HNDVI	-0.276	0.748**	0.859**	1.000	0.768**	0.538**	0.200
CIG	-0.728**	0.548**	0.461*	0.768**	1.000	0.877**	0.492**
LCI	-0.828**	0.424*	0.249	0.538**	0.877**	1.000	0.645**
SPAD	-0.619**	-0.015	-0.108	0.200	0.492**	0.645**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.10. Ağustos 2022 tanımlayıcı istatistik değerleri ile histogram dağılımı

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.036	0.280	0.200	0.848	5.304	0.245	54.700
Mak.	0.075	0.491	0.329	0.912	8.544	0.294	72.200
Ort.	0.056	0.397	0.280	0.884	7.062	0.274	66.273
Standart Sapma	0.009	0.053	0.033	0.016	0.959	0.012	4.213
Değişkenlik Katsayısı (%)	16.982	13.225	11.815	1.828	13.587	4.390	6.357
Çarpıklık	0.123	-0.248	-0.710	-0.639	-0.082	-0.567	-0.998
Basıklık	-0.472	-0.255	0.052	-0.275	-0.989	-0.251	0.731
Shapiro-Wilk	0.846	0.864	0.164	0.132	0.332	0.386	0.030*
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							



Çizelge 4.11 incelendiğinde; SPAD değişkeninin, bitki indekslerinden TGI indeksi ile güçlü ve negatif yönlü, CIG ve LCI indeksleri ile güçlü ve pozitif yönlü ilişkiler bulunurken aynı zamanda %95 güven düzeyinde ilişkiler gösterdiği tespit edilmiştir. Ayrıca indeks bağımsız değişkenleri arasında; GRVI ile VARI arasında, HNDVI ile GRVI arasında ve LCI ile HNDVI arasında güçlü ve pozitif yönlü bir ilişki; LCI ile TGI arasında ise güçlü ve negatif ilişki olduğu görülmektedir.

Farklı stres ve fenolojik dönemlere bağlı klorofil değişiminin değerlendirmesinde; geniş bir spektral bant aralığı kullanımının klorofil tahmininde daha yüksek doğruluk sağladığı yapılan çalışmalarla ortaya konmuştur (Brewer vd. 2022; Haboudane vd. 2008; Sibanda vd. 2020; Zhou vd. 2024). Ağustos ayına ait sonuçlarında hem RGB hem de NIR tabanlı TGI, CIG ve LCI indekslerin SPAD ile güçlü ilişkiler kurması bu yorumları destekler niteliktedir.

4.3.6. Eylül ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlarına ait yaprak örnekleri üzerinde gerçekleştirilen Eylül 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.12’de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.056, VARI için 0.406, GRVI için 0.301, HNDVI için 0.906, CIG için 7.217, LCI için 0.278 ve SPAD için 73.643’tür.

Çizelge 4.12’de verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve hafif basık olmak üzere normal dağılım göstermiştir. Çalışmada indeks değerleri incelendiğinde ise; TGI ve VARI indeksleri hafif sola çarpık ve hafif sivri dağılım, GRVI ve HNDVI indeksleri hafif sola çarpık ve sivri dağılım, CIG hafif sağa çarpık ve hafif basık dağılım ve LCI’nin hafif sola çarpık ve hafif basık dağılım gösterdiği belirlenmiştir. Eylül ayına ait değişken değerlerinin normal dağılım gösterip göstermediğini belirlemek için gerçekleştirilen Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$); TGI, VARI, CIG, LCI ve SPAD değişkenlerinin normal dağılım gösterdiği, GRVI ve HNDVI bağımsız değişkenlerinin normal dağılım göstermediği tespit edilmiştir.

Eylül ayına ait değerlendirmelerde normal dağılım göstermeyen sonuçların olması sebebi ile parametrik olmayan Spearman’ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.13’de verilmiş olup çizelge incelendiğinde; SPAD bağımlı değişkeni, TGI indeksi ile güçlü ve negatif yönlü, CIG indeksi ile orta düzeyde ve pozitif yönlü ve LCI indeksi ile güçlü ve pozitif yönlü ilişkileri olduğu belirlenmiştir.

Klorofil içeriği tahmininde RGB tabanlı indekslerin yüksek ilişkiler gösterdiği yapılan çalışmalar ile ortaya konmuştur (Singh vd. 2024; Zhang vd. 2022a). TGI ile SPAD değerleri arasında elde etmiş olduğumuz bulgularımızın bu çalışmalarla uyum içerisinde olduğu görülmüştür. CIG ve LCI gibi indeksler, özellikle NIR bantlarını kullanarak düşük klorofil seviyelerinde bile doğru sonuçlar vermesiyle öne çıkar ve bitki sağlığını değerlendirme ile fenolojik süreçlerin modellenmesinde etkili araçlardır (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). SPAD ile CIG ve LCI indeksleri arasındaki ilişkilerin yüksek olması bulgularımızın bu çalışmalarla uyum içerisinde olduğunu göstermiştir.

Çizelge 4.12. Eylül 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.036	0.304	0.215	0.853	5.897	0.252	63.900
Mak.	0.072	0.486	0.338	0.928	9.621	0.299	83.400
Ort.	0.056	0.406	0.301	0.906	7.217	0.278	73.643
Standart Sapma	0.009	0.038	0.027	0.016	0.921	0.013	5.304
Değişkenlik Katsayısı (%)	15.550	9.459	8.848	1.740	12.766	4.604	7.203
Çarpıklık	-0.269	-0.080	-1.244	-1.323	0.569	-0.107	-0.073
Basıklık	0.121	0.778	2,508*	2,746*	-0.025	-0.949	-0.755
Shapiro-Wilk	0.463	0.275	0.022*	0.0060*	0.260	0.311	0.794
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							

TGI

HNDVI

VARI

CIG

GRVI

LCI

SPAD

Çizelge 4.13. Eylül 2022 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.157	0.479**	0.008	-0.566**	-0.673**	-0.510**
VARI	-0.157	1.000	0.617**	0.461*	0.163	0.351	0.073
GRVI	0.479**	0.617**	1.000	0.705**	0.184	0.054	-0.189
HNDVI	0.008	0.461*	0.705**	1.000	0.671**	0.533**	0.117
CIG	-0.566**	0.163	0.184	0.671**	1.000	0.708**	0.373*
LCI	-0.673**	0.351	0.054	0.533**	0.708**	1.000	0.687**
SPAD	-0.510**	0.073	-0.189	0.117	0.373*	0.687**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

4.3.7. Ekim ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Ekim 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.14'te sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.059, VARI için 0.298, GRVI için 0.299, HNDVI için 0.910, CIG için 10.047, LCI için 0.275 ve SPAD için 72.980'tür.

Ekim ayı için hesaplanan ve Çizelge 4.14'de verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sağa çarpık ve hafif sivri olmak üzere normal dağılım göstermektedir. Çalışmada hesaplanan indeks değerleri incelendiğinde ise; TGI ve GRVI indeksleri hafif sola çarpık ve hafif basık dağılım, VARI hafif sağa çarpık ve hafif sivri dağılım, HNDVI'nin hafif sola çarpık ve hafif sivri dağılım, CIG hafif sağa çarpık ve hafif basık dağılım ve LCI'nin hafif sağa çarpık ve hafif sivri dağılım gösterdiği belirlenmiştir. Ekim ayına ait değişken değerlerinin normal dağılım gösterip göstermediğini belirlemek için yapılan Shapiro-Wilk testleri sonucunda değişkenlerin normal dağılım gösterdiği tespit edilmiştir. Bağımlı değişken SPAD değeri ise 0.874 değeri ile normal dağılım göstermektedir.

Bu aya ait değerlendirmeler için Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.15'da verilmiştir.

Çizelge 4.15 incelendiğinde; SPAD bağımlı değişkeni, TGI indeksi ile güçlü ve negatif yönlü, CIG indeksi ile orta düzeyde ve pozitif yönlü, LCI indeksi ile güçlü ve pozitif yönlü ilişkilerinin olduğu saptanmıştır.

Çizelge 4.14. Ekim 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.046	0.220	0.242	0.883	7.670	0.252	66.700
Mak.	0.072	0.409	0.354	0.931	13.450	0.297	82.000
Ort.	0.059	0.298	0.299	0.910	10.047	0.275	72.980
Standart Sapma	0.007	0.041	0.030	0.011	1.717	0.011	3.532
Değişkenlik Katsayısı (%)	12.247	13.912	10.021	1.231	17.095	3.865	4.840
Çarpıklık	-0.062	0.796	-0.052	-0.610	0.500	0.045	0.269
Basıklık	-0.882	0.846	-0.476	0.075	-0.797	0.089	0.172
Shapiro-Wilk	0.561	0.239	0.709	0.281	0.091	0.884	0.874

TGI

HNDVI

VARI

CIG

GRVI

LCI

SPAD

Çizelge 4.15. Ekim 2022 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.027	0.117	-0.201	-0.640**	-0.646**	-0.471**
VARI	-0.027	1.000	0.679**	0.523**	-0.233	0.092	-0.265
GRVI	0.117	0.679**	1.000	0.783**	0.224	0.140	-0.259
HNDVI	-0.201	0.523**	0.783**	1.000	0.489**	0.532**	0.067
CIG	-0.640**	-0.233	0.224	0.489**	1.000	0.702**	0.407*
LCI	-0.646**	0.092	0.140	0.532**	0.702**	1.000	0.717**
SPAD	-0.471**	-0.265	-0.259	0.067	0.407*	0.717**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Eylül ayı ile aynı fenolojik dönem içerisinde olan Ekim ayında da hemen hemen aynı korelasyon ilişkileri görülmüştür. TGI bağımsız değişkeni ile SPAD bağımlı değişkeni arasında görülen yüksek ilişki, RGB tabanlı indekslerin klorofil tahminindeki başarısını vurgulayan önceki araştırmalarla örtüşmektedir (Singh vd. 2024; Zhang vd. 2022a). NIR tabanlı ve düşük klorofil seviyelerinde bile doğru sonuçlar vermesiyle öne çıkan ve bitki sağlığını değerlendirme ile fenolojik süreçlerin modellenmesinde etkili olan CIG ve LCI indeksleri Ekim ayına ait değerlendirmelerde SPAD bağımlı değişkeni ile yüksek ilişkili sonuçlar vermiştir (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999).

4.3.8. Kasım ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örneklerinde gerçekleştirilen Kasım 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.16'da sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.045, VARI için 0.395, GRVI için 0.299, HNDVI için 0.921, CIG için 9.697, LCI için 0.291 ve SPAD için 70.720'dir.

Çizelge 4.16'da verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sağa çarpık ve hafif sivri dağılım göstermektedir. Çalışmada hesaplanan indeks değerleri incelendiğinde ise; TGI hafif sola çarpık ve hafif sivri dağılım, VARI ve GRVI indeksleri hafif sağa çarpık ve sivri dağılım, HNDVI ve CIG indeksleri hafif sağa çarpık ve hafif basık dağılım, LCI'nin ise hafif sağa çarpık ve basık dağılım gösterdiği saptanmıştır. Kasım ayına ait değişken değerlerinin normal dağılım gösterip göstermediği Shapiro-Wilk testleri ile de kontrol edilmiş olup normal dağılım gösterdikleri görülmektedir.

Kasım ayı Satsuma mandarinine ait değerlendirmeler için Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.17'te verilmiştir.

Çizelge 4.16. Kasım 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.020	0.260	0.203	0.894	7.359	0.275	62.500
Mak.	0.064	0.584	0.379	0.955	12.748	0.312	81.500
Ort.	0.045	0.395	0.299	0.921	9.697	0.291	70.720
Standart Sapma	0.009	0.066	0.036	0.016	1.497	0.012	3.929
Değişkenlik Katsayısı (%)	21.126	16.727	12.210	1.712	15.441	3.958	5.556
Çarpıklık	-0.207	0.773	0.011	0.266	0.385	0.200	0.423
Basıklık	0.559	1.138	1.333	-0.610	-0.781	-1.319	0.893
Shapiro-Wilk	0.903	0.115	0.199	0.665	0.255	0.070	0.780

TGI

HNDVI

VARI

CIG

GRVI

LCI

SPAD

Çizelge 4.17. Kasım 2022 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.294	0.566**	0.303	-0.392*	-0.653**	-0.128
VARI	-0.294	1.000	0.376*	-0.083	-0.321	-0.241	-0.267
GRVI	0.566**	0.376*	1.000	0.713**	-0.031	-0.361	-0.172
HNDVI	0.303	-0.083	0.713**	1.000	0.580**	0.233	0.090
CIG	-0.392*	-0.321	-0.031	0.580**	1.000	0.836**	0.269
LCI	-0.653**	-0.241	-0.361	0.233	0.836**	1.000	0.488**
SPAD	-0.128	-0.267	-0.172	0.090	0.269	0.488**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.17 incelendiğinde; SPAD bağımlı değişkeninin yalnızca LCI indeksi ile güçlü ve pozitif yönlü ilişki gösterdiği tespit edilmiştir. Benzer şekilde, Liang, Zhao ve Zhu (2012) yaptıkları çalışmada LCI değişkeni ve birinci türev değişkeninin elma yaprağı klorofil içeriğinin tahmininde önemli araçlar olduğunu göstermiştir. Ayrıca indeks değişkenleri arasında LCI ile CIG arasında güçlü ve pozitif yönlü ilişki olduğu belirlenmiştir.

4.3.9. Aralık ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Aralık 2022 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.18’de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.027, VARI için 0.645 GRVI için 0.308, HNDVI için 0.906, CIG için 9.167, LCI için 0.288 ve SPAD için 70.433’tür.

Çizelge 4.18’de verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sağa çarpık ve hafif basık dağılım göstermektedir. Çalışmada elde edilen indeks değerleri incelendiğinde ise; TGI hafif sağa çarpık ve sivri dağılım, VARI sağa çarpık ve sivri dağılım, GRVI ve LCI indekslerinin hafif sağa çarpık ve hafif sivri dağılım, HNDVI ve CIG indeksleri hafif sola çarpık ve hafif basık dağılım gösterdiği belirlenmiştir. Aralık ayına ait değişken değerlerinin normal dağılım gösterip göstermediği aynı zamanda Shapiro-Wilk testleri ile de kontrol edilmiştir. Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$); VARI ve CIG değişkenlerinin normal dağılım göstermediği tespit edilmiştir.

Aralık ayına ait değerlendirmelerde normal dağılım göstermeyen sonuçların olması sebebi ile parametrik olmayan Spearman’ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.19’da verilmiştir.

Çizelge 4.18. Aralık 2022 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.005	0.323	0.279	0.889	7.297	0.269	64.900
Mak.	0.059	1.322	0.342	0.919	12.072	0.311	78.200
Ort.	0.027	0.645	0.308	0.906	9.167	0.288	70.433
Standart Sapma	0.011	0.192	0.014	0.009	1.292	0.010	3.069
Değişkenlik Katsayısı (%)	39.759	29.746	4.705	1.040	14.096	3.494	4.357
Çarpıklık	0.904	1.395	0.251	-0.404	0.758	0.721	0.457
Basıklık	1.832	4.710*	0.277	-0.853	-0.195	0.204	-0.009
Shapiro-Wilk	0.061	0.001*	0.856	0.102	0.0499*	0.071	0.781
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							

Çizelge 4.19. Aralık 2022 tarihine ait Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.849**	-0.138	0.136	-0.188	-0.464**	-0.538**
VARI	-0.849**	1.000	0.343	-0.092	0.046	0.398*	0.438*
GRVI	-0.138	0.343	1.000	0.027	-0.190	-0.237	-0.274
HNDVI	0.136	-0.092	0.027	1.000	0.745**	0.498**	-0.089
CIG	-0.188	0.046	-0.190	0.745**	1.000	0.814**	0.122
LCI	-0.464**	0.398*	-0.237	0.498**	0.814**	1.000	0.325
SPAD	-0.538**	0.438*	-0.274	-0.089	0.122	0.325	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.19 incelendiğinde; SPAD bağımlı değişkeni, TGI indeksi ile güçlü ve negatif yönlü, VARI indeksi ile güçlü ve pozitif yönlü ilişkiler gösterdiği görülmektedir. Ayrıca indeks değişkenleri arasında; VARI ve TGI arasında güçlü ve negatif, LCI ile CIG arasında güçlü ve pozitif yönlü ilişkiler olduğu belirlenmiştir.

Uzaktan algılama çalışmalarında yaprak klorofil içeriğini düşük maliyetle tahmin etmek amacıyla geliştirilen TGI ve VARI indeksleri, görünür bölge dalga boylarını kullanarak hesaplanmaktadır. Bu indekslerin, atmosferik etkileri azaltma yeteneği ve ucuz sensörlerle uyumlu olması önemli avantajlar sunmaktadır (Hunt Jr vd. 2011; Gitelson vd. 2002). Çalışmada, TGI ve VARI indeksleri ile SPAD ölçümleri arasında yüksek bir ilişki bulunması, bu indekslerin klorofil tahmininde güvenilir araçlar olduğunu ve tarımsal analizlerde etkin bir şekilde kullanılabileceğini göstermektedir.

4.3.10. Ocak ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Ocak 2023 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.20’de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.045, VARI için 0.334, GRVI için 0.255, HNDVI için 0.898, CIG için 9.051, LCI için 0.282 ve SPAD için 68.427’dir.

Çizelge 4.20’de verilen tanımlayıcı istatistik değerleri ve histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve hafif basık dağılım göstermektedir. Çalışmada elde edilen indeks değerleri incelendiğinde ise; TGI ve VARI

indekslerinin hafif sağa çarpık ve hafif basık dağılım, GRVI hafif sağa çarpık ve hafif sivri dağılım, HNDVI hafif sola çarpık ve hafif sivri dağılım, CIG sağa çarpık ve hafif sivri dağılım ve LCI hafif sola çarpık ve hafif basık dağılım gösterdiği görülmektedir. Ocak ayına ait değişken değerlerinin normal dağılım gösterip göstermediğini belirlemek için gerçekleştirilen Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$) değişkenlerin normal dağılım gösterdiği belirlenmiştir.

Ocak ayı Satsuma mandarin ağaçlarının değerlendirmelerine ait Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.21'de verilmiştir.

Çizelge 4.21 incelendiğinde, SPAD bağımlı değişkeni, CIG ve LCI indeksleri ile güçlü ve pozitif ilişki gösterirken HNDVI ile orta düzeyde ve pozitif ilişki gösterdiği belirlenmiştir.

Çizelge 4.21. Ocak 2023 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.456*	0.310	-0.182	-0.652**	-0.765**	-0.348
VARI	-0.456*	1.000	0.590**	0.402*	0.225	0.263	-0.033
GRVI	0.310	0.590**	1.000	0.589**	0.053	-0.114	-0.095
HNDVI	-0.182	0.402*	0.589**	1.000	0.649**	0.521**	0.462*
CIG	-0.652**	0.225	0.053	0.649**	1.000	0.827**	0.575**
LCI	-0.765**	0.263	-0.114	0.521**	0.827**	1.000	0.577**
SPAD	-0.348	-0.033	-0.095	0.462*	0.575**	0.577**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

SPAD değişkeni ile HNDVI, CIG ve LCI indeksleri arasında yüksek ilişkilerin bulunması, bu indekslerin bitki sağlığını değerlendirme konusunda ne kadar etkili olduğunu gösterir. Özellikle bu multispektral indeksler, klorofil içeriği ile doğrudan bağlantılı olup, bitkilerin sağlıklı durumunu ve fenolojik süreçlerini doğru bir şekilde modellemede güvenilir araçlar olup özellikle düşük klorofil seviyelerinde bile doğru sonuçlar vermesi, bitki sağlığını izleme ve tarımsal verimliliği artırma açısından büyük bir avantaj sağlamaktadır (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999).

Çizelge 4.20. Ocak 2023 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.032	0.255	0.216	0.876	6.941	0.259	59.900
Mak.	0.060	0.417	0.304	0.912	11.663	0.305	75.300
Ort.	0.045	0.334	0.255	0.898	9.051	0.282	68.427
Standart Sapma	0.008	0.038	0.021	0.008	1.057	0.011	3.853
Değişkenlik Katsayısı (%)	18.009	11.475	8.116	0.891	11.676	3.869	5.630
Çarpıklık	0.270	0.436	0.465	-0.619	0.156	-0.177	-0.142
Basıklık	-0.817	-0.170	0.248	0.705	0.492	-0.381	-0.574
Shapiro-Wilk	0.303	0.350	0.335	0.680	0.571	0.706	0.686

The figure displays seven histograms, each corresponding to a variable: TGI, HNDVI, VARI, CIG, GRVI, LCI, and SPAD. Each histogram shows the frequency distribution of the variable, with a green normal distribution curve overlaid. Above each histogram is a box plot showing the median, quartiles, and range of the data. The variables are arranged in two rows: TGI, HNDVI, VARI, CIG in the top row and GRVI, LCI, SPAD in the bottom row.

4.3.11. Şubat ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Şubat 2023 tarihli ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.22'de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.033, VARI için 0.327, GRVI için 0.234, HNDVI için 0.916, CIG için 10.946, LCI için 0.266 ve SPAD için 61.297'dir

Çizelge 4.22'de verilen tanımlayıcı istatistik değerleri ve histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve hafif sivri olmak üzere normal dağılım göstermektedir. Çalışmada elde edilen indeks değerleri incelendiğinde ise; TGI ve GRVI indekslerinin hafif sola çarpık ve hafif basık dağılım, VARI'nın hafif sağa çarpık ve hafif sivri dağılım, HNDVI'nın hafif sola çarpık ve sivri dağılım, CIG ve LCI indekslerinin hafif sağa çarpık ve hafif basık dağılım gösterdiği görülmektedir. Şubat ayına ait değişken değerlerinin normal dağılım gösterip göstermediği belirlemek için yapılan Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$), HNDVI bağımsız değişkeninin normal dağılım göstermediği görülmektedir. Bağımlı değişken SPAD değeri ise 0.643 değeri ile normal dağılım göstermektedir.

Şubat ayı Satsuma mandarin ağaçlarına ait değerlendirmelerde normal dağılım göstermeyen bir sonucun olması sebebi ile parametrik olmayan Spearman'ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.23'de verilmiştir.

Çizelge 4.23. Şubat 2023 Spearman korelasyon analiz sonuçları


	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	-0.259	0.497**	0.140	-0.478**	-0.806**	-0.551**
VARI	-0.259	1.000	0.575**	0.038	-0.276	0.111	-0.167
GRVI	0.497**	0.575**	1.000	0.482**	-0.213	-0.292	-0.333
HNDVI	0.140	0.038	0.482**	1.000	0.528**	0.233	0.357
CIG	-0.478**	-0.276	-0.213	0.528**	1.000	0.682**	0.636**
LCI	-0.806**	0.111	-0.292	0.233	0.682**	1.000	0.743**
SPAD	-0.551**	-0.167	-0.333	0.357	0.636**	0.743**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.


**Korelasyon 0,01 düzeyinde anlamlıdır.

Çizelge 4.22. Şubat 2023 tanımlayıcı istatistik değerleri ile histogram grafikleri


Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.018	0.244	0.180	0.889	8.204	0.246	50.500
Mak.	0.043	0.445	0.273	0.931	13.787	0.292	70.100
Ort.	0.033	0.327	0.234	0.916	10.946	0.266	61.297
Standart Sapma	0.006	0.043	0.023	0.009	1.373	0.011	4.690
Değişkenlik Katsayısı (%)	19.765	13.267	9.837	1.025	12.543	4.273	7.651
Çarpıklık	-0.264	0.298	-0.400	-0.970	0.223	0.226	-0.450
Basıklık	-0.445	0.782	-0.100	1.980	-0.199	-0.552	0.073
Shapiro-Wilk	0.756	0.565	0.843	0.031*	0.828	0.746	0.643
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							




TGI




HNDVI




VARI




CIG



GRVI



LCI



SPAD

Çizelge 4.23 incelendiğinde SPAD klorofil değerlerinin, TGI indeksi ile güçlü ve negatif yönlü, CIG ve LCI indeksleri ile de güçlü ve pozitif yönlü ilişkiler gösterdiği belirlenmiştir.

Yapılan araştırmalar, RGB tabanlı indekslerin klorofil içeriği tahmininde yüksek ilişki gösterdiğini ortaya koymuştur (Singh vd. 2024; Zhang vd. 2022a). Elde ettiğimiz Şubat ayına ait SPAD ve TGI indeksine ait bulgular da bu çalışmalara paralel bir sonuç sunmuştur. NIR bantlarını kullanan CIG ve LCI gibi indeksler, düşük klorofil seviyelerinde bile doğru sonuçlar vererek bitki sağlığını değerlendirme ve fenolojik süreçlerin modellenmesinde etkili araçlar olarak öne çıkmaktadır (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). SPAD ile CIG ve LCI indeksleri arasındaki güçlü ilişkiler, bulgularımızın mevcut literatürle tutarlı olduğunu göstermiştir.

4.3.12. Mart ayına ait istatistiksel analizler

Satsuma mandarin bahçesindeki ağaçlardan toplanan yaprak örnekleri üzerinde gerçekleştirilen Mart 2023 tarihli son ölçümler için tanımlayıcı istatistik değerleri, çarpıklık-basıklık katsayıları ve Shapiro-Wilk testine ait sonuçlar ile histogram grafikleri Çizelge 4.24’de sunulmuştur. Bu sonuçlara göre ortalamalar; TGI için 0.040, VARI için 0.188, GRVI için 0.176, HNDVI için 0.929, CIG için 12.245, LCI için 0.272 ve SPAD için 59.987’dir.

Mart ayına ait hesaplanan ve Çizelge 4.24’de verilen tanımlayıcı istatistik değerleri ile histogram grafikleri incelendiğinde; SPAD bağımlı değişkeni hafif sola çarpık ve sivri dağılım göstermektedir. Çalışmada elde edilen indeks değerleri incelendiğinde ise; TGI ve HNDVI indekslerinin hafif sola çarpık ve hafif basık dağılım, VARI ve GRVI indekslerinin hafif sağa çarpık ve hafif basık dağılım, CIG ve LCI indekslerinin ise hafif sola çarpık ve hafif sivri dağılım gösterdiği belirlenmiştir. Mart ayına ait değişken değerlerinin normal dağılım gösterip göstermediği aynı zamanda Shapiro-Wilk testleri ile de kontrol edilmiştir. Shapiro-Wilk normallik test sonuçlarına göre ($P>0.05$) değişkenlerin normal dağılım gösterdiği tespit edilmiştir.

Mart ayı Satsuma mandarin ağaçlarının değerlendirmelerine ait Spearman’ın sıralama korelasyonu katsayıları hesaplanmış ve Çizelge 4.25’de verilmiştir.

Çizelge 4.25 incelendiğinde; SPAD klorofil değerleri ile hiperspektral verilerden hesaplanan indeksler arasında genel olarak pozitif yönlü bir ilişki olduğu görülmektedir. SPAD bağımlı değişkeninin, TGI indeksi ile güçlü ve negatif yönlü, CIG ve LCI indeksleri ile de güçlü ve pozitif yönlü ilişkiler bulunurken aynı zamanda %95 güven düzeyinde ilişkiler gösterdiği tespit edilmiştir. Ayrıca indeks değişkenleri arasında GRVI ile VARI arasında güçlü ve pozitif yönlü ilişki olduğu tespit edilmiştir.

Hiperspektral uzaktan algılama, mavi ve kırmızı dalga boylarına duyarlı olmasıyla klorofil ölçümünde etkili bir yöntem olması bitki sağlığını izlemek ve tarımsal uygulamaları planlamak için değerli bilgiler sağlar (Bannari vd. 2007; Gitelson ve Merzlyak 1998). Elde edilen RGB tabanlı TGI indeksi ve SPAD arasındaki yüksek ilişki, klorofil tahminindeki başarısını gösteren önceki çalışmalara paralel bir bulgular sunmuştur (Singh vd. 2024; Zhang vd. 2022a)

Çizelge 4.24. Mart 2023 tanımlayıcı istatistik değerleri ile histogram grafikleri

Değişken	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
N	30	30	30	30	30	30	30
Min.	0.028	0.129	0.113	0.902	9.118	0.250	45.800
Mak.	0.054	0.262	0.259	0.952	14.812	0.288	68.100
Ort.	0.040	0.188	0.176	0.929	12.245	0.272	59.987
Standart Sapma	0.006	0.035	0.035	0.013	1.350	0.009	4.530
Değişkenlik Katsayısı (%)	16.175	18.879	20.000	1.407	11.025	3.135	7.552
Çarpıklık	-0.007	0.305	0.222	-0.234	-0.141	-0.441	-0.937
Basıklık	-0.568	-0.526	-0.372	-0.822	0.090	0.573	2.114*
Shapiro-Wilk	0.433	0.565	0.808	0.605	0.947	0.631	0.134
*Çarpıklık-basıklık katsayıları ve Shapiro-Wilk normallik testine göre normal dağılım göstermeyen veriler							

TGI

HNDVI

VARI

CIG

GRVI

LCI

SPAD

Çizelge 4.25. Mart 2023 Spearman korelasyon analiz sonuçları

	TGI	VARI	GRVI	HNDVI	CIG	LCI	SPAD
TGI	1.000	0.008	0.402*	0.307	-0.113	-0.691**	-0.574**
VARI	0.008	1.000	0.863**	0.518**	0.303	0.268	0.117
GRVI	0.402*	0.863**	1.000	0.763**	0.494**	0.046	0.002
HNDVI	0.307	0.518**	0.763**	1.000	0.785**	0.119	0.185
CIG	-0.113	0.303	0.494**	0.785**	1.000	0.393*	0.466**
LCI	-0.691**	0.268	0.046	0.119	0.393*	1.000	0.684**
SPAD	-0.574**	0.117	0.002	0.185	0.466**	0.684**	1.000

*Korelasyon 0,05 düzeyinde anlamlıdır.

**Korelasyon 0,01 düzeyinde anlamlıdır.

Öte yandan, HNDVI, CIG ve LCI gibi indeksler, NIR bantlarının kullanımı sayesinde klorofil tahmininde yüksek doğruluk sağlamaktadır. Özellikle CIG ve LCI, düşük klorofil seviyelerinde dahi güvenilir sonuçlar vererek, bitki sağlığını değerlendirmede önemli bir yer tutar (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). Mart ayında elde edilen SPAD ile CIG ve LCI indeksleri arasındaki güçlü ve pozitif yönlü ilişkiler, mevcut araştırmalarla uyumlu sonuçlar göstermiştir.

Bu indekslerin, bitki sağlığını ve fenolojik süreçleri modellemede etkili ve güvenilir araçlar olarak kullanılabileceğini, tarımsal uygulamalarda daha doğru ve verimli sonuçlar elde edilmesine olanak tanıyacağı düşünülmektedir.

4.4. Klorofil Tahmin Modelleri

Bitkisel üretim sürecinde ekonomi, doğal kaynak yönetimi ve verim kayıplarının en aza indirilmesi adına tahribatsız klorofil tahmini büyük önem taşımaktadır. Klorofil içeriği, bitkilerin fotosentetik kapasitesini, besin durumunu ve fizyolojik sağlığını yansıtan önemli bir parametredir. Bu nedenle, bitki gelişiminin izlenmesi ve tarımsal verimliliğin artırılması için klorofil ölçümlerinin hızlı, ekonomik ve tahribatsız bir şekilde gerçekleştirilmesi büyük önem arz etmektedir. Bu bağlamda, uzaktan algılama teknolojileri, geniş alanlarda etkin ve hızlı tarama imkânı sağlayarak önemli bir araç olarak öne çıkmaktadır (Singhal vd. 2019). Ancak uzaktan algılama yöntemlerinin saha koşullarında uygulanabilirliğinin sağlanabilmesi için detaylı çalışmaların yapılması ve bu yöntemlerin güvenilirliğinin test edilmesi gerekmektedir. Ayrıca, doğru girdilerin belirlenmesi amacıyla farklı algoritmalar ve modelleme tekniklerinin uygulanması, güvenilir tarımsal takip sistemlerinin oluşturulmasına olanak tanımaktadır.

Bilgisayar biliminin hızlı gelişimi, araştırmacılara makine öğrenmesi, yapay zekâ ve derin öğrenme gibi yeni nesil hızlı ve eğitilebilir analiz yöntemlerini kullanma fırsatı sunmaktadır. Özellikle bitkisel üretime yönelik modelleme çalışmalarında bu yöntemler, tahmin modellerinin performansını artırmak ve en doğru sonuçları elde etmek için yaygın olarak tercih edilmektedir. Yapılan araştırmalar, en iyi performans gösteren spektral indekslerin ve uygun makine öğrenmesi yöntemlerinin belirlenmesinin tahmin doğruluğunu artırmada kritik bir rol oynadığını vurgulamaktadır (Rasooli Sharabiani vd., 2023; Nijat vd., 2017). Bu çalışmada; bağımsız değişkenlerin ve verilerin çok fazla olması ile elde edilen verilerin normal dağılım göstermemesi gibi istatistiksel analiz sonuçları dikkate alınarak PLSR (Partial Least Squares Regression) modelleme yöntemi tercih edilmiştir.

PLSR, bağımlı ve bağımsız değişkenler arasındaki karmaşık ilişkileri modelleyerek eksik, gürültülü veya yüksek boyutlu verilerde güvenilir ve etkili tahminler sunan bir istatistiksel yöntemdir (Wold vd. 2001). Satsuma mandarin ağaçlarından oluşan çalışma alanında, SPAD tahmini için PLSR analizi gerçekleştirilmiş ve bu süreçte NIPALS algoritması ile faktör seçiminde LOO yöntemi kullanılmıştır. Modelin veri setiyle uyum gücünü değerlendirmek amacıyla bağımsız değişkenlerin (hesaplanan bitki indekslerinin) SPAD bağımlı değişkenindeki değişimi; açıklama yüzdesi, faktör sayıları ve tahmin edilen artık hata kareler toplamı (Root Mean Predicted Residual Error Sum of Squares-RMPRESS) gibi model değerlendirme kriterleri uygulanarak belirlenmiştir. Ayrıca, model değerlendirilmesinde R^2 (Belirleme Katsayısı), RMSE (Kök Ortalama Karesel Hata) ve MAPE (Ortalama Mutlak Yüzde Hata) değerleri analiz edilerek sonuçların güvenilirliği ve doğruluğu değerlendirilmiştir.

Çalışma alanı için 12 aylık tahmin modeli kapsamında yapılan PLSR analizi sonucunda, SPAD bağımlı değişkenini en yüksek oranda açıklayan faktör sayısının 2 olduğu (%83.568) ve bu sonucun Mayıs ayında elde edildiği belirlenmiştir. Tüm aylara ait model özetlerine ise Çizelge 4.26'da yer verilmiştir.

Çizelge 4.26. Aylara göre Model karşılaştırma özeti

Dönemler		Faktör sayısı	Kümülatif X için Açıklanan Yüzde Değişim	Kümülatif Y için Açıklanan Yüzde Değişim	VIP > 0.8
Çiçeklenme- Meyve Tutumu	Nisan	2	96.419	68.604	3
	Mayıs	2	74.023	83.568	4
Meyve Gelişimi	Haziran	5	99.749	58.246	5
	Temmuz	5	99.862	63.399	4
	Ağustos	2	91.101	49.277	3

(Devamı Arkada)

Çizelge 4.26'nın devamı

Meyve Olgunlaşması	Eylül	4	97.490	56.741	3
	Ekim	6	100.000	78.977	3
Hasat Zamanı	Kasım	3	73.048	41.580	4
	Aralık	2	62.122	40.614	4
Kış Dinlenmesi	Ocak	1	48.901	37.030	4
	Şubat	1	42.278	60.989	3
Sürgün Oluşturma	Mart	3	94.141	55.890	3

Çalışma alanına ait 12 aylık PLSR analizi, NIPALS algoritması ve LOO çapraz doğrulama yöntemi kullanılarak gerçekleştirilmiş ve elde edilen RMPRESS değerleri Çizelge 4.27'de sunulmuştur. En uygun faktör sayısı RMPRESS'nin en düşük olduğu değere denk gelmektedir (Anonim 3 2025).

Çizelge 4.27. Aylara göre faktör RMPRESS değerleri

Root Mean PRESS	Faktör Sayısı						
	0	1	2	3	4	5	6
Nisan 2022	1.034	0.788	0.656*	0.703	0.792	0.730	0.748
Mayıs 2022	1.034	0.542	0.497*	0.499	0.503	0.535	0.541
Haziran 2022	1.034	0.870	0.871	0.831	0.825	0.818*	0.828
Temmuz 2022	1.034	0.878	0.821	0.785	0.770	0.762*	0.790
Ağustos 2022	1.034	0.873	0.832*	0.842	0.875	0.844	0.852
Eylül 2022	1.034	0.855	0.852	0.844	0.812*	0.836	0.845
Ekim 2022	1.034	0.807	0.770	0.721	0.699	0.660	0.617*
Kasım 2022	1.034	1.003	1.005	0.929*	0.935	1.010	1.038
Aralık 2022	1.034	0.921	0.916*	0.932	0.980	1.085	1.102
Ocak 2023	1.034	0.891*	0.902	0.896	0.917	0.936	0.960
Şubat 2023	1.034	0.708*	0.745	0.768	0.780	0.815	0.787
Mart 2023	1.034	0.813	0.795	0.791*	0.839	0.890	0.908
* : SPAD bağımlı değişkenini en yüksek oranda açıklayan faktör RMPRESS değeri							

Çizelge 4.27 incelendiğinde; Nisan, Mayıs, Ağustos ve Aralık 2022 ayları için en düşük RMPRESS değerinin 2 faktör, Haziran ve Temmuz 2022 ayları için 5 faktör, Eylül 2022 ayı için 4 faktör, Ekim 2022 ayı için 6 faktör, Kasım 2022 ayı için 3 faktör, Ocak ve Şubat 2023 ayları için 1 faktör, Şubat 2023 ayı için 1 faktör ve son ay olan Mart 2023 ayı için (0.791) 3 faktör kullanıldığında elde edildiği tespit edilmiştir.

Değişkenlere ait 12 aylık VIP değerleri Çizelge 4.28’de verilmiştir. VIP (Variable Importance in Projection) değeri, bağımsız değişkenin bağımlı değişken üzerindeki etkisini gösterir. Wold’a göre bu değer 0.8’in üzerinde ise değişken model üzerinde önemli etkiye sahiptir. Değişken önem tablosu olarak sunulan Çizelge 4.28’de tüm değişkenlerin VIP değeri, Wold’un kriteri olan 0.8 değerinin üzerinden olup olmadığı incelenmiştir. Bu kapsamda aylara göre Çizelge 4.28’deki VIP değerleri incelendiğinde; TGI ve LCI indeksleri tüm aylarda, CIG ise Aralık ayı dışında tüm 11 ayda 0.8 değeri üzerinde ve birbirlerine yakın VIP değerleri göstermiştir. VARI indeksi Haziran, Kasım ve Aralık aylarında; HNDVI ise Mayıs, Haziran ve Temmuz aylarında bu kriteri sağlamıştır. GRVI indeksi yalnızca Aralık ayında etkin değer göstermiştir.

Çizelge 4.28. Aylara göre değişken önem tablosu

VIP	İndeks					
	TGI	VARI	GRVI	HNDVI	CIG	LCI
Nisan	1.129	0.753	0.723	0.790	1.187	1.266
Mayıs	1.190	0.149	0.714	1.012	1.215	1.246
Haziran	1.037	0.800	0.779	0.862	1.082	1.328
Temmuz	1.065	0.718	0.610	0.826	1.156	1.400
Ağustos	1.314	0.712	0.654	0.576	1.067	1.367
Eylül	1.217	0.445	0.761	0.539	0.929	1.609
Ekim	1.077	0.729	0.796	0.672	1.006	1.487
Kasım	0.938	1.192	0.468	0.431	1.050	1.480
Aralık	1.466	1.199	1.001	0.444	0.539	0.962
Ocak	0.849	0.081	0.233	1.128	1.402	1.408
Şubat	1.093	0.332	0.661	0.708	1.261	1.473
Mart	1.340	0.436	0.285	0.473	1.087	1.590

Klorofilin (SPAD değeri) tahminine yönelik Satsuma mandarini için 12 farklı tarihte elde edilen veriler ve kısmi en küçük kareler regresyonu (PLSR) kullanılarak 12

farklı klorofil tahmin modeli oluşturulmuştur (Çizelge 4.29). Oluşturulan modellerin tahmin gücü ve başarı oranı R^2 , RMSE ve MAPE ile değerlendirilmiş olup sonuçlar Çizelge 4.30'da verilmiştir.

Çizelge 4.29. Klorofil tahmin modelleri

Model	Tarih	Model Eşitliği
1	Nisan	$-171.22 * :TGI + -4.36 * :VARI + -0.35 * :GRVI$ $+4.87 * :HNDVI + 0.72 * :CIG + 107.65 * :LCI + 43.31$
2	Mayıs	$-70.75 * :TGI + -9.54 * :VARI + -65.66 * :GRVI$ $+74.10 * :HNDVI + 1.78 * :CIG + 125.44 * :LCI + (-22.75)$
3	Haziran	$74.71 * :TGI + -5.01 * :VARI + -54.41 * :GRVI$ $+50.57 * :HNDVI + -1.06 * :CIG + 349.36 * :LCI + (-53.12)$
4	Temmuz	$-15.71 * :TGI + -59.17 * :VARI + -16.28 * :GRVI$ $+166.67 * :HNDVI + -1.75 * :CIG + 305.75 * :LCI + (-$
5	Ağustos	$-132.78 * :TGI + -11.68 * :VARI + -21.41 * :GRVI$ $+3.47 * :HNDVI + 0.78 * :CIG + 107.45 * :LCI + 46.39$
6	Eylül	$57.65 * :TGI + -19.93 * :VARI + -8.93 * :GRVI +$ $-67.44 * :HNDVI + -0.74 * :CIG + 416.08 * :LCI + 32.11$
7	Ekim	$-342.20 * :TGI + -111.48 * :VARI + 114.12 * :GRVI$ $+ -51.35 * :HNDVI + -2.91 * :CIG + 441.78 * :LCI + 46.68$
8	Kasım	$150.10 * :TGI + -10.13 * :VARI + 6.61 * :GRVI +$ $-27.77 * :HNDVI + -1.84 * :CIG + 436.41 * :LCI + (-17.77)$
9	Aralık	$-91.42 * :TGI + 3.71 * :VARI + -66.68 * :GRVI +$ $-44.86 * :HNDVI + -0.06 * :CIG + 32.59 * :LCI + 122.87$
10	Ocak	$-61.42 * :TGI + -1.23 * :VARI + -6.53 * :GRVI$ $+81.71 * :HNDVI + 0.77 * :CIG + 74.90 * :LCI + (-28.24)$
11	Şubat	$-159.71 * :TGI + -7.23 * :VARI + -27.19 * :GRVI$ $+71.26 * :HNDVI + 0.87 * :CIG + 122.53 * :LCI + (-32.09)$
12	Mart	$-209.37 * :TGI + -7.01 * :VARI + -7.94 * :GRVI$ $+34.48 * :HNDVI + 0.89 * :CIG + 197.55 * :LCI + (-25.68)$

Çizelge 4.30. Model değerlendirmesi sonuçları

Model	Tarih	R²	RMSE	MAPE
1	Nisan	0.69	2.44	3.02
2	Mayıs	0.84	1.88	4.06
3	Haziran	0.58	2.00	2.64
4	Temmuz	0.63	2.76	3.90
5	Ağustos	0.49	2.95	3.93
6	Eylül	0.57	3.43	3.69
7	Ekim	0.79	1.59	1.94
8	Kasım	0.42	2.95	3.40
9	Aralık	0.41	2.33	2.60
10	Ocak	0.37	3.01	3.73
11	Şubat	0.61	2.88	3.57
12	Mart	0.56	2.96	3.97

Sönmez (2003) çalışmasında, Washington Navel portakal ağaçları meyve tutum döneminin toplam klorofil içerikleri ile kanopi reflektansları arasında en yüksek istatistiksel ilişkiye sahip dönem olduğunu belirlemiştir. Benzer şekilde narenciye grubundan olan Satsuma mandarin ağaçlarına ait bu çalışmada, R² değerlendirmesine göre SPAD bağımlı değişkenini en iyi tahmin eden modelin 2 numaralı model olup Çiçeklenme ve Meyve Tutumu dönemine denk gelen Mayıs ayı olduğu tespit edilmiştir. 2 numaralı Mayıs ayına ait model, SPAD bağımlı değişkenini %83.568 (Çizelge 4.26) oranında açıklayan 2 faktörle en yüksek başarıyı sağlamış ve R² değeri 0.84 ile en yüksek doğruluğa ulaşmıştır. Bu bulgular, her iki çalışmanın sonuçlarının uyumlu olduğunu ve meyve tutum döneminin klorofil tahmini açısından kritik bir önem taşıdığını göstermektedir.

Li vd. (2023), hiperspektral yansıma verilerini kullanarak narenciye ağaçlarındaki yaprak klorofil içeriğini tahmin etmek için doğrusal regresyon ve makine öğrenimi yöntemlerini incelemişlerdir. Beş farklı büyüme mevsiminde (Mayıs, Haziran, Ağustos, Ekim ve Aralık) yaprak klorofil içeriği ve spektral yansıma ölçümlerini alarak, tek değişkenli ve çok değişkenli regresyon ile rastgele orman, K-en yakın komşu ve destek vektör regresyonu gibi makine öğrenimi algoritmalarıyla değerlendirmişlerdir. Bu çalışma sonucuna göre rastgele orman (RFR) modelinin, özellikle Mayıs, Haziran, Ekim ve Aralık aylarında narenciye ağaçlarındaki yaprak klorofil içeriğini tahmin etmede en yüksek doğruluğa sahip model olduğunu belirlemişlerdir. Özellikle Ekim ayında VOG2 ve Carte4 parametreleriyle birlikte RFR modelinin en iyi performansı gösterdiğini bildirmişlerdir (R² = 0,83, RMSE = 6,67).

5. SONUÇLAR

Çalışmada, Satsuma mandarin ağaçlarının uzaktan algılamaya dayalı spektral özelliklerinin dönemsel olarak sorgulanarak spektral yansıma ve klorofil ilişkisinin istatistiksel olarak belirlenmesi, makine öğrenmesi algoritmasından biri olan kısmi kareler regresyonu (PLSR) yöntemi ile klorofil tahmininde bitki spektral yansıma verilerinden hesaplanan indekslerden elde edilen en yüksek ilişkiyi veren modelin ve dönemin belirlenmesi amaçlanmıştır. Çalışma Antalya Batı Akdeniz Tarımsal Araştırma Enstitüsü Müdürlüğü (BATEM) meyvecilik bölümünde yer alan Satsuma mandarin ağaçlarında, Nisan 2022 ile Mart 2023 tarihleri arasında yürütülmüştür.

Bitkisel üretim sezonu boyunca bitki sağlığını korumak tüm tarım girdileri için önemli bir kriterdir. Bitki sağlığının önemli göstergelerinden biri olan klorofil içeriği de bu sebeple araştırmalarda temel parametre olarak ele alınmaktadır (Demiralay vd. 2019; Jiang vd. 2017; Singh vd. 2024; Sönmez 2003). Klorofil içeriği, bitkinin fenolojik dönemlerine göre değişim göstermekte ve bu değişimler bitkinin fizyolojik süreçlerine yansımaktadır. Bu sebeple farklı büyüme aşamalarına klorofil dinamiklerinin optimize edilmiş modellerle değerlendirilmesi ve özellikle büyüme açısından kritik dönemlerde, klorofil miktarındaki artışın izlenmesi ile ilgili çalışmalarda önem kazanmaktadır (Jiang vd. 2017). Klorofil pigmentlerinin ölçümünde hiperspektral uzaktan algılama sıklıkla kullanılmakta olup spektrumun mavi ve kırmızı dalga boylarında bitki yapraklarının klorofil içeriğindeki duyarlılık, bitki sağlığının yorumlanmasına ve tarımsal faaliyetlerin yürütülmesine rehberlik etmektedir (Bannari vd. 2007; Gitelson ve Merzlyak 1998). SPAD klorofil ölçümleri de fotosentetik dokunun varlığıyla doğrudan ilişkili olup bitkinin büyüme durumu ve sağlığı hakkında önemli bilgiler vermektedir (Parida vd. 2024). Bu değerlendirmeler göz önüne alınarak çalışma alanında satsuma mandarini için 12 ay süresince spektral yansıma ve SPAD ölçümleri yapılarak veri setleri oluşturulmuştur. Bu kapsamda TGI (Triangular Greenness Index), VARI (Visible Atmospheric Resistant Index), GRVI (Green-Red Vegetation Index) HNDVI (Hyperspectral Normalized Difference Vegetation Index), CIG (Chlorophyll Index Green), LCI (Leaf Chlorophyll Index) indeksleri ile klorofil verileri istatistiksel olarak incelenmiştir.

Her bir aya ait ortalama spektral yansıtım grafikleri incelendiğinde, görünür bölgedeki yeşil dalga boyundaki yansımanın Mayıs 2022 döneminde en yüksek seviyeye ulaştığı dikkat çekmektedir. Elde edilen bu bulgu, satsuma ağaçlarının çiçeklenme veya yaprak büyümesi gibi pigment artışına neden olan fenolojik dönemde olması ve elverişli çevresel koşullarla ilişkili olabileceğini düşündürmektedir. Buna karşılık, kış dinlenmesi ve sürgün oluşturma dönemlerinde ise satsuma ağaçlarında yansıma değerlerinin düştüğü gözlemlenmiştir. Bu durum ise, fotosentetik aktivitenin azalması ve yeni yapraklardaki klorofil miktarının henüz yeterince gelişmemesiyle açıklanabilir. Liv vd. (2023) çalışmalarında, klorofil içeriğindeki dalgalanmaların Haziran ayında zirve yapmasını bitkideki büyüme aktivitelerine, Ağustos, Ekim ve Aralık aylarında ise azalan ışık ve sıcaklık seviyeleriyle bağlantılı fotosentetik aktivitedeki düşüşüne ve sezonluk iklim koşullarından kaynaklanan stres faktörlerine bağlamışlardır. Yansıma değerlerine karşılık aylara göre SPAD ortalama değerleri incelendiğinde en yüksek ortalamanın 73.6 ile Eylül 2022 ayında, en düşük ortalamanın ise 40.3 ile Mayıs 2022 ayında olduğu görülmektedir.

Uzaktan algılama çalışmalarında, yaprak klorofil içeriğini doğru ve düşük maliyetli bir şekilde tahmin etmek amacı ile çeşitli indeksler oluşturulmuştur. Bu indekslerden TGI ve VARI indeksleri spektrumun görünür bölgesindeki dalga boyları kullanılarak oluşturulmuştur. Söz konusu indeksler görünür bölgeyi çeken ucuz sensörler kullanılarak hesaplanabilmekte ve atmosferik etkileri azaltma kapasitesiyle de öne çıkmaktadır (Hunt Jr vd. 2011; Gitelson vd. 2002). Benzer şekilde GRVI indeksi de görünür bölgedeki yeşil ve kırmızı bantları kullanarak fotosentetik aktiviteyi daha hassas şekilde değerlendirmeye imkân vermektedir (Tucker 1979). Diğer HNDVI, CIG ve LCI gibi multispektral indeksler ise, geniş bir spektral bant kullanımı (özellikle NIR) sayesinde klorofil tahmininde daha yüksek doğruluk sağlamasıyla dikkat çekerken özellikle CIG ve LCI indeksleri, düşük klorofil seviyelerinde bile doğru sonuçlar vermesiyle oldukça önemlidir (Rouse vd. 1973; Gitelson vd. 2003; Datt 1999). Bu indeksler, bitki sağlığını değerlendirme ve fenolojik süreçleri modelleme konusunda etkili ve güvenilir araçlar olarak çalışmamızda önemli bir yere sahiptir.

Günümüzde tarımsal üretimde geleneksel yöntemlerden, hassas ve düşük hata oranlı karar destek sistemlerine geçiş önem kazanmıştır (Ghazal vd. 2024). Çevre kirliliği ve kuraklık gibi problemlere çözüm sağlamak amacıyla uzaktan algılama ve makine öğrenmesi kullanımı yaygınlaşmıştır. Makine öğrenmesi, hızlı işlem süreleri ve yüksek doğruluk oranlarıyla tarımsal karar destek sistemlerinde etkili bir yöntem olarak öne çıkmaktadır (Singhal vd. 2019). Gauss Süreç Regresyonu, Rastal Orman, Kernel-Ridge Regresyonu, K-En Yakın Komşu ve Destek Vektör Makineleri gibi algoritmalar bu alanda sıklıkla kullanılmaktadır. Ayrıca derin öğrenme modelleri; sınıflandırma ve tahminde yüksek başarı oranları sunarak son yıllarda tarım çalışmalarında daha fazla tercih edilmektedir (Yaman ve Tuncer 2022). Makine öğrenmesi ve spektral özelliklerin bir arada kullanımı; küçük alanlardan elde edilen verilerle, geniş alanlarda yüksek doğrulukla çalışılmasını mümkün kılarak tarımsal süreçleri verimli ve sürdürülebilir hale getirmektedir.

Bu çalışmada klorofil tahminini gerçekleştirmeye yönelik model seçimi için algoritma seçiminde bağımsız değişkenlerin sayısının fazla olması ve verilerin normal dağılım göstermemesi göz önüne alınarak PLSR (Kısmi Kareler Regresyonu) yöntemi model değerlendirilmesinde tercih edilmiştir.

SPAD ve bitki indekslerinin, tanımlayıcı istatistik ve normallik testleri değerlendirilmesinde çarpıklık ve basıklık katsayıları -2, +2 aralığında olması (George 2011; George ve Mallery 2019) ve Shapiro-Wilk normallik testi sonucunun 0.05'ten büyük olması durumunda normal dağılım gösterdiği kabul edilmiş ve histogram grafikleri incelenmiştir. Yapılan değerlendirmelerde bazı aylara ait değişkenlerin normal dağılım göstermemesinden dolayı parametrik olmayan Spearman'ın korelasyon katsayıları hesaplanmıştır. Elde edilen bulgulara göre, SPAD değerleri ile hiperspektral verilerden hesaplanan indeksler arasındaki ilişkiler incelendiğinde, SPAD klorofil değerlerinin genel olarak CIG ve LCI indeksleri ile güçlü ve pozitif, TGI indeksi ile ise güçlü ve negatif yönlü ilişkiler sergilediği tespit edilmiştir. Çalışma sonuçları, CIG ve LCI indekslerinin klorofil tahmininde yüksek doğruluk sağladığını ve bu durumun literatürdeki çalışmalarla uyumlu olduğunu göstermektedir. Özellikle Gitelson vd. (2003), CIG'nin düşük klorofil seviyelerinde dahi doğru sonuçlar verdiğine dikkat çekmiştir. Benzer şekilde, TGI ve SPAD ilişkisi de RGB tabanlı indekslerin klorofil tahminindeki başarısını vurgulayan önceki araştırmalarla örtüşmektedir (Singh vd. 2024;

Zhang vd. 2022a). Sonuçlar, geniş spektral bant aralığının ve uygun indekslerin kullanımının, fenolojik dönemlere ve stres koşullarına bağlı olarak klorofil değişimlerini daha doğru bir şekilde değerlendirme potansiyeli sunduğunu göstermektedir. Bu indeksler, bitki sağlığını ve fenolojisini modellemede güvenilir araçlar olarak öngörülmektedir.

Satsuma mandarin ağaçlarına ait klorofil tahmin modelleme sonuçları incelendiğinde; 2 numaralı modelin en yüksek SPAD yüzde değişim değerini (83.568) 2 faktör ile Mayıs ayında verdiği belirlenmiştir. Değişken önem tablosu incelendiğinde ise TGI ve LCI indeksleri tüm aylarda, CIG ise Aralık ayı hariç diğer 11 ayda 0.8'in üzerinde ve birbirine oldukça yakın VIP değerleri sergilemiştir. Model değerlendirme sonuçlarında en yüksek R^2 değerinin yine Mayıs ayında olduğu görülmektedir. Mayıs ayı RMSE değeri 1.88 ve MAPE değeri 4.06 olarak belirlenmiştir.

Yaprak klorofil içeriği ile SPAD değerleri arasında anlamlı bir doğrusal ilişki olduğu yapılan birçok çalışma ile ortaya konulmuştur (Demiralay vd. 2019; Jiang vd. 2017; Taş 2021). Bu ilişki, SPAD ölçümlerinin bitki sağlığını ve beslenme durumunu değerlendirmek için kullanılabilir bir yöntem olduğunu göstermektedir. Ancak yapılan çalışmalarda SPAD ölçümlerinin farklı tür, farklı fenolojik dönem ve dış çevresel faktörlere bağlı olarak değişkenlik gösterdiğini ortaya koymaktadır. Bu ilişkinin değişiklik gösterebileceği ve tahmin modellerinin her aşamaya özgü optimize edilmesi gerektiği de vurgulanmaktadır (Atar vd. 2020; Demiralay vd. 2019; Jiang vd. 2017; Sönmez vd. 2016).

Spektral bitki örtüsü indeksleri ile SPAD tahmininin birleştirilmesi, bitkinin büyümesi ve verimini tahmin etmede doğruluğu artırmaktadır (Parida vd. 2024). Çalışmadan elde edilen klorofil tahmin sonuçları, literatürdeki bulgularla uyumlu bir şekilde, bitkilerin fenolojik dönemleri ve fizyolojik durumları ile klorofil içerikleri arasında güçlü ilişkiler olduğunu ortaya koymaktadır. Örneğin, Sari vd. (2006) ve Altunbas vd. (2018) gibi araştırmacılar, özellikle meyve tutum ve olgunlaşma dönemlerinde klorofil içeriği ile spektral yansıma değerleri arasında anlamlı ilişkiler tespit etmişlerdir. Benzer şekilde, çalışmada da klorofil içeriği, Mayıs ayındaki yoğun büyüme dönemi sırasında en yüksek değerlere ulaşmış ve bu dönemdeki fizyolojik süreçlerin klorofil içeriği üzerinde belirleyici olduğu görülmüştür. Ayrıca, Jiang vd. (2017) ve Shi vd. (2023) tarafından vurgulanan, klorofil içeriği tahmini için farklı büyüme aşamalarına özgü model optimizasyonunun önemi, bizim sonuçlarımızda da karşılık bulmaktadır; farklı dönemlerde klorofil içeriğinin değişim göstermesi, bu süreçlerin izlenmesinde dönemsel farkların dikkate alınması gerektiğini göstermiştir. Çalışma, özellikle fenolojik dönemlere özgü klorofil ölçüm ve tahmin çalışmalarının, bitki sağlığını ve verimini anlamada kritik bir araç olduğunu doğrulamaktadır. Bu sonuçlar hem literatürdeki bulguları desteklemekte hem de farklı bitki türlerinde klorofil içeriklerini izleme konusunda gelecekteki çalışmalar için önemli bir temel oluşturmaktadır.

6. KAYNAKLAR

- Alpaydin, E. (2021). Machine learning. MIT press, Cambridge, Massachusetts, 224 p.
- Altun, M. 2021. Landsat 8 uydu görüntü indeksleri kullanılarak tarımsal ürünlerin makine öğrenme yöntemleri ile tespit edilmesi. Yüksek Lisans Tezi, Batman Üniversitesi, Batman, 74 s.
- Altunbas, S., Gozukara, G., Sonmez, N. K., Maltas, A. S., & Kaplan, M. (2018). Relationship between spectral reflectance and plant nutrient element-chlorophyll content in lettuce (*Lactuca sativa* L.) growing.
- 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>.
- Anonim 1: Konica Minolta. 2022. SPAD-502. <https://www.konicaminolta.eu/euen/hardware/measuring-instruments/colour-measurement/chlorophyllmeter/spad-502plus>. [Son erişim tarihi: 25.11.2024].
- Anonim 2: Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü. Ürün Raporu TURUNÇGİLLER (2023). 25.11.2024.
- Anonim 3: Cross Validation Report. <https://www.jmp.com/support/help/en/18.1/index.shtml#page/jmp/cross-validation-report.shtml> [Son erişim tarihi: 01.01.2025].
- Artisan 2022. Spectroradiometer. <https://www.artisanng.com/Scientific/90717-1/Spectris-ADS-Analytical-Spectral-Devices-FieldSpec-HandHeld-FSHH-325-3075P-Spectroradiometer> [Son erişim tarihi: 25.11.2024].
- Atar, F., Güney, D., Bayraktar, A., Yıldırım, N., vd. (2020). SEASONAL CHANGE OF CHLOROPHYLL CONTENT (SPAD VALUE) IN SOME TREE AND SHRUB SPECIES. Turkish Journal of Forest Science, 4(2), 245-256. <https://doi.org/10.32328/turkjforsci.711389>
- Bannari, A., Khurshid, K. S., Staenz, K. and Schwarz, J. W. 2007. A comparison of hyperspectral chlorophyll indices for wheat crop chlorophyll content estimation using laboratory reflectance measurements. IEEE Transactions on Geoscience and Remote Sensing, 45(10), 3063-3074.
- Barlas, N. T. and İrget, M. E. (2012). Satsuma Mandarininin (Citrus unshiu Marcovitch) Meyve İle Topraktan Kaldırdığı Besin Elementi Miktarının Belirlenmesi (I)- Makro Elementler. Çukurova Tarım ve Gıda Bilimleri Dergisi, 31(3), 81-88.
- Başayığit, L., Ersan, R. 2014. Isparta Güllü (*Rosa damascena* Mill.) Klorofil İçeriğinin Hiperspektral Algılama Teknikleriyle Tahmini. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 17(2), 18-22.
- Bock, C. H., Barbedo, J. G., Del Ponte, E. M., Bohnenkamp, D. and Mahlein, A. K. (2020). From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. Phytopathology Research, 2, 1-30.
- Brewer, K., Clulow, A., Sibanda, M., Gokool, S., Naiken, V. and Mabhaudhi, T. (2022). Predicting the Chlorophyll Content of Maize over Phenotyping as a Proxy for Crop Health in Smallholder Farming Systems. Remote Sensing, 14(3), 518. <https://doi.org/10.3390/rs14030518>

- Campbell, J. B. and Wynne, R. H. (2011). Introduction to remote sensing, Sixth Edition. Guilford press, New York, 667 p.
- Changchun, L. I., Chunyan, M. A., Peng, C. H. E. N., Yingqi, C. U. I., Jinjin, S. H. I. and Yilin, W. A. N. G. (2021). Machine learning-based estimation of potato chlorophyll content at different growth stages using UAV hyperspectral data. *Zemdirbyste-Agriculture*, 108(2).
- Chapman, HD. 1964. Foliar sampling for determining the nutrient status of crops. *World Crops*. 16 (3): 36-36.
- Chutia, D., Bhattacharyya, D. K., Sarma, K. K., Kalita, R., and Sudhakar, S. (2016). Hyperspectral remote sensing classifications: a perspective survey. *Transactions in GIS*, 20(4), 463-490.
- Çoşlu, M. 2023. İnsansız Hava Aracı Ve Yersel Hiperspektral Veriler İle Narenciye Ağaçlarında Verim Tahmini. Doktora tezi, Akdeniz Üniversitesi, Antalya, 165 s.
- Datt, B. (1999). A new reflectance index for remote sensing of chlorophyll content in higher plants: tests using Eucalyptus leaves. *Journal of plant physiology*, 154(1), 30-36.
- Demiralay, M., Sadıklar, M. S., and Tilki, F. (2019). İki farklı tip tahribatsız portatif klorofil metre kullanarak Artvin’de yayılış gösteren sapsız meşede (*Quercus*, *Fagaceae*) klorofil tahmini. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 20(1), 28-35.
- Demirel, K., Genç, L., Çamoğlu, G., Aşık., Ş. (2010). Karpuz Bitkisinde Yaprak Su İçeriği ve Klorofil Okumalarından Yararlanılarak Su Stresinin Belirlenmesi. *Tekirdağ Ziraat Fakültesi Dergisi*, 7(3), 155-162.
- 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>.
- Ghazal, S., Munir, A., and Qureshi, W. S. (2024). Computer vision in smart agriculture and precision farming: Techniques and applications. *Artificial Intelligence in Agriculture*.
- Gitelson, A. A., Gritz, Y., and Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of plant physiology*, 160(3), 271-282.
- Gitelson, A. A., Kaufman, Y. J., Stark, R., and Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote sensing of Environment*, 80(1), 76-87.
- Gitelson, A. A., and Merzlyak, M. N. 1998. Remote sensing of chlorophyll concentration in higher plant leaves. *Advances in Space Research*, 22(5), 689-692.
- Gözükara, G., Altunbaş, S., Şimşek, O., Sarı, O., vd. (2019). Roka (*Eruca vesicaria*) yetiştiriciliğinde spektral yansıma ile bitki besin maddesi konsantrasyonu arasındaki ilişkinin belirlenmesi. *Mediterranean Agricultural Sciences*, 32, 55-62. <https://doi.org/10.29136/mediterranean.559787>
- Haboudane, D., Tremblay, N., Miller, J. R., and Vigneault, P. (2008). Remote estimation of crop chlorophyll content using spectral indices derived from hyperspectral data. *IEEE Transactions on Geoscience and remote Sensing*, 46(2), 423-437.

- Huang, Y., Chen, Z. X., Tao, Y. U., Huang, X. Z., and Gu, X. F. (2018). Agricultural remote sensing big data: Management and applications. *Journal of Integrative Agriculture*, 17(9), 1915-1931
- Huang, P., Yang, P., Yang, L., Xiao, F., Feng, Y., and Wang, Y. (2024). Non-Destructive Detection and Visualization of Chlorophyll Content in Cherry Tomatoes Based on Hyperspectral Technology and Machine Learning. *Agriculture*, 14(12), 2247. <https://doi.org/10.3390/agriculture14122247>
- Hunt Jr, E. R., Daughtry, C. S. T., Eitel, J. U., and Long, D. S. (2011). Remote sensing leaf chlorophyll content using a visible band index. *Agronomy journal*, 103(4), 1090-1099.
- Jagdeep-Singh, and Varinderpal-Singh. (2022). Chlorophyll meter based precision nitrogen management in spring maize. *Journal of Plant Nutrition*, 46(1), 17-27.
- 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.
- Karakoç, A., and Karabulut, M. (2022). Hiperspektral Vejetasyon İndeksleri Kullanarak Otlaklarda Kanopi Düzeyinde Klorofil İçeriğinin Tahmin Edilmesi. *Journal of Geography*(43), 77-91. <https://doi.org/10.26650/JGEOG2021-865289>
- Kaya, M. (2019). AGRİ’NİN KALKINMASI İÇİN AKILLI TARIM (TARIM 4.0) ÖNERİSİ. *Akademik Bakış Uluslararası Hakemli Sosyal Bilimler Dergisi* (75), 130-156.
- Keskin, M. (2007). Spektrometreler ve tarımda kullanım alanları. *Tarımsal Mekanizasyon*, 24, 5-6.
- Khan, N., Ray, R. L., Sargani, G. R., Ihtisham, M., Khayyam, M., and Ismail, S. (2021). Current progress and future prospects of agriculture technology: Gateway to sustainable agriculture. *Sustainability*, 13(9), 4883.
- Kganyago, M., Adjorlolo, C., Mhangara, P., and Tsoeleng, L. (2024). Optical remote sensing of crop biophysical and biochemical parameters: An overview of advances in sensor technologies and machine learning algorithms for precision agriculture. *Computers and Electronics in Agriculture*, 218, 108730.
- Konica Minolta. 2024. SPAD-502. <https://www.konicaminolta.eu/euen/hardware/measuring-instruments/colour-measurement/chlorophyllmeter/spad-502plus>. [Son erişim tarihi: 29.11.2024].
- Korkmaz, S. Ö. S. (2008). Edremit Körfez Bölgesi’ndeki Satsuma Owari Mandarinlerinde Yaygın Olan Virüs ve Viroid Hastalıklarının Biyolojik ve Serolojik Yöntemlerle Saptanması. *Tekirdağ Ziraat Fakültesi Dergisi*, 5(2), 205-214.
- Köseoğlu, A. T., and Çolakoğlu, H. (1989). Genç Satsuma Mandarin (Citrus unshlu Marc.) Ağaçlarında Klmyasal Gübrelerin Meyve Kalitesine Etkisi. *Akdeniz University Journal of the Faculty of Agriculture*, 2(1), 91-104.
- Li, D., Hu, Q., Ruan, S., Liu, J., Zhang, J., Hu, C., Liu, Y., Dian, Y., and Zhou, J. (2023). Utilizing Hyperspectral Reflectance and Machine Learning Algorithms for Non-Destructive Estimation of Chlorophyll Content in Citrus Leaves. *Remote Sensing*, 15(20), 4934.
- Liang, S., Zhao, G. X., & Zhu, X. C. (2012). Hyperspectral estimation models of chlorophyll content in apple leaves. *Spectroscopy and spectral analysis*, 32(5), 1367-1370.

- Lillesand T. M., Kiefer R. W., W. Chipman J. W. (2018). Uzaktan Algılama ve Görüntü Yorumlama. Palme Yayınevi, 1-2 s.
- Masaló, I., and Oca, J. (2020). Evaluation of a portable chlorophyll optical meter to estimate chlorophyll concentration in the green seaweed *Ulva ohnoi*. *Journal of Applied Phycology*, 32(6), 4171-4174.
- Mızırak, Z., and Ceylan, A. (2023). 100. YILINDA TÜRKİYE'DEKİ TARIM POLİTİKALARININ YAPISAL DEĞİŞİMİ. *Necmettin Erbakan Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*, 5(Özel Sayı), 131-147.
- Myers, L., Sirois, M.J. 2006. Spearman correlation coefficients, differences between. *Encyclopedia of statistical sciences*, 12. 10.1002/0471667196.ess5050.pub2.
- Nijat, K., Shi, Q., Wang, J., Rukeya, S., Ilyas, N., and Gulnur, I. (2017). Estimation of spring wheat chlorophyll content based on hyperspectral features and PLSR model. *Transactions of the Chinese Society of Agricultural Engineering*, 33(22), 208-216.
- Parida, P. K., Somasundaram, E., Krishnan, R., Radhamani, S., Sivakumar, U., Parameswari, E., Raja, R., Shri Rangasami, S. R., Sangeetha, S. P., and Gangai Selvi, R. (2024). Unmanned Aerial Vehicle-Measured Multispectral Vegetation Indices for Predicting LAI, SPAD Chlorophyll, and Yield of Maize. *Agriculture*, 14(7), 1110. <https://doi.org/10.3390/agriculture14071110>
- Polat, A. G. E., and Günay, S. 2009. Kısmi en küçük kareler ve bir uygulama. İçinde VI: İstatistik Günleri Sempozyumu Bildiriler Kitabı, ss. 437-444, Ağustos, On Dokuz Mayıs Üniversitesi.
- Rasooli Sharabiani, V., Soltani Nazarloo, A., Taghinezhad, E., Veza, I., Szumny, A., and Figiel, A. (2023). Prediction of winter wheat leaf chlorophyll content based on VIS/NIR spectroscopy using ANN and PLSR. *Food Science and Nutrition*, 11(5), 2166-2175.
- Rouse, J. W., Haas, R. H., Schell, J. A., and Deering, D. W. (1973, December). Monitoring Vegetation Systems in the Great Plains with ERTS (Earth Resources Technology Satellite). In 3rd Earth Resources Technology Satellite-1 Symposium, 1973. Proceedings. (pp. 309-317). NASA.
- Saraçoğlu, T., Necmiye, Ü. Ç. E. R., Özyılmaz, Ü., and Özarslan, C. 2010. Satsuma Mandarin (*Citrus Unshiu* Marc.) Çeşidinin Sıçrama Özellikleri. *Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi*, 7(1), 87-93.
- Sari, M., Sonmez, N. K., and Karaca, M. (2006). Relationship between chlorophyll content and canopy reflectance in Washington navel orange trees (*Citrus sinensis* (L.) Osbeck). *Pakistan Journal of Botany*, 38(4), 1093.
- Sebetci Ö. Yapay Zekâyı Kodlamak Yapay Zekâ – Makine Öğrenmesi Derin Öğrenme – Sinir Ağları (2023). Seçkin Yayıncılık, 340-342.
- Shah SH, Angel Y, Houborg R, Ali S, McCabe MF 2019. A Random Forest Machine Learning Approach for the Retrieval of Leaf Chlorophyll Content in Wheat. *Remote Sensing*, 11(8):920. <https://doi.org/10.3390/rs11080920>
- Shaw, G. A., and Burke, H. K. (2003). Spectral imaging for remote sensing. *Lincoln laboratory journal*, 14(1), 3-28.
- Shi, H., Guo, J., An, J., Tang, Z., Wang, X., Li, W., Zhao, X., Jin, L., Xiang, Y., Li, Z., and Zhang, F. (2023). Estimation of Chlorophyll Content in Soybean Crop at Different Growth Stages Based on Optimal Spectral Index. *Agronomy*, 13(3), 663. <https://doi.org/10.3390/agronomy13030663>

- Sibanda, M., Mutanga, O., Dube, T., and Mafongoya, P. L. (2020). Spectrometric proximally sensed data for estimating chlorophyll content of grasslands treated with complex fertilizer combinations. *Journal of Applied Remote Sensing*, 14(2), 024517-024517.
- Singh, B., Elangovan, A., Kumar, S. et al. (2024). Non-destructive chlorophyll prediction by machine learning techniques using RGB-based vegetation indices in wheat. *Plant Physiology Reports*, 1-12.
- Singhal, G., Bansod, B., Mathew, L., Goswami, J., Choudhury, B. U., and Raju, P. L. N. 2019. Chlorophyll estimation using multi-spectral unmanned aerial system based on machine learning techniques. *Remote Sensing Applications: Society and Environment*, 15, 100235.
- Sonmez, N. K. 2003. Washington Navel Portakal Çeşidinin Klorofil İçerikleri İle Uzaktan Algılamaya Dayalı Spektral Özellikleri Arasındaki İlişkilerin Belirlenmesi. Doktora tezi, Akdeniz Üniversitesi, Antalya, 114 s.
- Sonmez, N. K., Sari, M., and Sonmez, S. (2008). Relationship between mineral contents and canopy reflectance in Washington navel orange trees (*Citrus sinensis* L. Osbeck).
- Sönmez, N., and Sarı, M. (2016). Uzaktan Algılama Temel Prensipleri Ve Uygulama Alanları. *Derim*, 19(2), 16-30.
- Sönmez, S., Orman, Ş., Çıtak, S., Kocabas Oğuz, İ., vd. (2014). Kumluca ve Finike yöreleri turuncgil bahçelerinin beslenme durumlarının belirlenmesi. *Akdeniz University Journal of the Faculty of Agriculture*, 27(1), 51-59.
- Su-Yin Tan, 2017. Developments in Hyperspectral Sensing. In: *Handbook of Satellite Applications*. Springer International Publishing, Cham, pp. 1137 - 1157.
- Sawant, S. A., Chakraborty, M., Suradhaniwar, S., Adinarayana, J., and Durbha, S. S. (2016). Time series analysis of remote sensing observations for citrus crop growth stage and evapotranspiration estimation. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 1037-1042.
- Taş, T. (2021). GAP Bölgesi Koşullarında Atıdışı Hibrit Mısır Çeşidine (*Zea mays* L.) Uygulanan Farklı Azot Gübresi Seviyelerinin Tane Verimi ve Kalite ile Klorofil İçeriklerine Etkisi. *Turkish Journal of Agricultural and Natural Sciences*, 8(3), 655-665. <https://doi.org/10.30910/turkjans.909545>
- Taşdemir, M. K., Sönmez, N. K., and Çoşlu, M., (2023). ANTEP FISTIĞI (*PISTACIA VERA* L.) YETİŞTİRİCİLİĞİNDE UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİNİN KULLANIMI. Cumhuriyetimizin 100. Yılı Anısına Peyzaj Mimarlığı, Mimarlık ve Çevre (pp.48-74), Ankara: Platanus Yayın Grubu.
- Tong, A., and He, Y. (2014, July). Remote sensing of grassland chlorophyll content: assessing the spatial-temporal performance of spectral indices. In *2014 IEEE Geoscience and Remote Sensing Symposium* (pp. 2846-2849). IEEE.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
- Turgutoğlu, E. 2023. Mandarin Yetiştiriciliği. <https://arastirma.tarimorman.gov.tr/batem/Belgeler/Kutuphane/Teknik%20Bilgiler/Mandarin%20Yeti%C5%9Ftiricili%C4%9Fi.pdf> [Son erişim tarihi: 04.2013].
- Wold, S., Sjöström, M., and Eriksson, L. (2001). PLS-regression: a basic tool of chemometrics. *Chemometrics and intelligent laboratory systems*, 58(2), 109-130.

- Yaman, O., and Tuncer, T. (2022). Bitkilerdeki Yaprak Hastalığı Tespiti için Derin Özellik Çıkarma ve Makine Öğrenmesi Yöntemi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 123-132.
- Yoldaş, Z. ., Güncan, A. ., and Koçlu, T. . (2011). İzmir ili Satsuma mandarini bahçelerindeki yaprakbiti türleri ve doğal düşmanlarının mevsimsel değişimi. *Turkish Journal of Entomology*, 35(1), 59-74.
- Yu, K. Q., Zhao, Y. R., Zhu, F. L., Li, X. L., and He, Y. (2016). Mapping of chlorophyll and SPAD distribution in pepper leaves during leaf senescence using visible and near-infrared hyperspectral imaging. *Transactions of the ASABE*, 59(1), 13-24.
- Wang, W., Sun, N., Bai, B., Wu, H., et al. (2024). Prediction of wheat SPAD using integrated multispectral and support vector machines. *Frontiers in Plant Science*, 15, 1405068.
- Wójtowicz, M., Wójtowicz, A., and Piekarczyk, J. (2016). Application of remote sensing methods in agriculture. *Communications in biometry and crop science*, 11(1), 31-50.
- Zhang, X., Zhou, Y., and Luo, J. (2021). Deep learning for processing and analysis of remote sensing big data: a technical review. *Big Earth Data*, 6(4), 527–560. <https://doi.org/10.1080/20964471.2021.1964879>
- Zhang, H., Ge, Y., Xie, X., Atefi, A., Wijewardane, N. K., and Thapa, S. (2022a). High throughput analysis of leaf chlorophyll content in sorghum using RGB, hyperspectral, and fluorescence imaging and sensor fusion. *Plant Methods*, 18(1), 60.
- Zhang, R., Yang, P., Liu, S., Wang, C., and Liu, J. (2022b). Evaluation of the methods for estimating leaf chlorophyll content with SPAD chlorophyll meters. *Remote Sensing*, 14(20), 5144.
- Zhang, Y., Han, X., and Yang, J. (2024). Selection of optimal spectral features for leaf chlorophyll content estimation. *Scientific Reports*, 14(1), 25598.
- Zhou, X., Zhang, J., Chen, D., Huang, Y., Kong, W., Yuan, L., Ye, H. and Huang, W. 2020. Assessment of leaf chlorophyll content models for winter wheat using Landsat-8 multispectral remote sensing data. *Remote Sensing*, 12(16), 2574.
- Zhou, X., Zhang, J., Wu, K., Chen, D., et al. (2024). A digital sensor with non-imaging multi-spectral and image modules for continuous monitoring of plant growth conditions: Development and validation. *Computers and Electronics in Agriculture*, 225, 109299.

ÖZGEÇMİŞ

Dilara AYDUS SARI

ÖĞRENİM BİLGİLERİ

Yüksek Lisans	Akdeniz Üniversitesi
2022-2025	Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Antalya
Lisans	Uludağ Üniversitesi
2012-2017	Ziraat Fakültesi, Biyosistem Mühendisliği Bölümü, Bursa